Linux: Сеть

Как она устроена и как это использовать

Проект книги

Автор: Олег Цилюрик

Редакция **2.43**

03.05.2023г.

Оглавление

Содержание

Введение (от автора)

Первоначальный текст был подготовлен на заказ, как конспект учебного курса для программистов-разработчиков крупной международной софтверной фирмы Global Logic. В каковом качестве учебный курс и был прочитан один раз. После чего, существенно дополняемый он использовался автором как, пусть и достаточно фрагментарная, «памятка для себя любимого», конспект, справочник: отдельные вопросы сетевого программирования, которые, как мне казалось, нужно выделить. Кроме того, позволяющая другим коллегам на **начальном этапе** работы с Linux как можно быстрее «въехать» в прямую программистскую деятельность затрагивающую сетевую область. В таком виде он (собственно, без ведома автора) и разошёлся достаточно широко по Интернет, примерно в 2014-2015 годах.

Настоящая ревизия (правильнее сказать: радикальная переделка дотла, оставив только скелет) мотивирована следующими соображениями:

- Предыдущие 30 лет компьютерные сети, не только в Linux, но во всех средах, развивались базируясь неявно на протоколе IPv4. В несколько последних лет (с 2012 года, об этом будет ниже) произошло официальное введение в эксплуатацию в Интернет IPv6. И это радикально поменяло, по крайней мере в синтаксисе, привычное использование многочисленного сетевого инструментария.
- Расширение сферы использования IPv6 идёт, вопреки ожиданиям, гораздо медленнее прогнозируемому. Но это — будущее Интернет и, как следствие, сетевых технологий вообще. И в этом будущем IPv6 полностью вытеснит привычный IPv4. Поэтому именно с таким упором должен быть пересмотрен текст.
- В первоначальном варианте конспект планировался на аудиторию программистов, как учебный курс именно этого контингента. К настоящему времени создалось много разнообразных средств использование сетевых возможностей потребительского уровня, не требующих написания программного кода. Вплоть до формирования парадигмы и специализации DevOps — разработка крупных инфраструктурных проектов через администрирование. Это потребовало сильно расширить охват в область пользовательского уровня.
- Изложение строится, по возможности, так, что те главы, где обсуждаются образцы программного кода, могут без ущерба для общей картины опущены всеми теми, кого не интересуют вопросы сетевой реализации в программном коде.
- Появляются, и ещё более будут появляться, архитектуры передачи данных, использующие транспортные механизмы традиционного Интернет, но работающие **над** (сверх) его базовыми механизмами (это начиналось от прокси-серверов и VPN, и далее к ячеистым mesh-сетям и альтернативным DNS). Это нельзя оставить в стороне от рассмотрения.

Большинство поясняющих графических иллюстраций, рисунков в тексте заимствовано из книг У. Р. Стивенса (точная библиография указывается после каждо).

Что есть и чего нет в книге?

Конечно, дать исчерпывающую картину сетевого мира в Linux на таком ограниченном объёме (да и на любом обозримом) невозможно! Но задача ставилась не так: дать основу понятий архитектуры сети и наметить общую схему задач, решаемых в сетевом программировании, администрировании и использовании. В итоге, в тексте отчётливо сложились несколько совершенно различных части:

1. Архитектура и терминология сети.
2. Программные инструменты работы с сетью.
3. Сокетное программирование. Программирование приложений пользовательского адресного

пространства.

4. Сетевые драйверы и протоколы. Программирование модулей ядра Linux — драйверов сетевых адаптеров и протоколов.
5. Новые, экспериментальные и экстравагантные проекты над Интернет. Тенденции и отдельные примеры.

Каждая из этих областей требует для своего детального описания отдельной книги под 1000 страниц. И такие книги есть, они приведены в рекомендуемой библиографии в конце каждой части, и именно к ним следует переходить для детального изучения каждого из этих предметов.

Задачей же данного текста ставилось дать цельную картину взаимодействия различных сетевых составляющих в Linux, назвать ключевые моменты, указать источники, целеуказание (стандарты, RFC, заголовочные файлы, ссылки в сети), где искать уточняющую информацию по таким ключевым моментам.

Соглашения и выделения, принятые в тексте

Для ясности чтения текста, он размечен шрифтами по функциональному назначению. Для выделения фрагментов текста по назначению используется разметка:

– Отдельные ключевые понятия и термины в тексте, на которые нужно обратить особое внимание, будут выделены **жирным шрифтом**.

– Тексты программных листингов, вывод в ответ на консольные команды пользователя размечен `моноширинным шрифтом`.

– Таким же моноширинным `шрифтом` (прямо в тексте) будут выделяться: имена команд, программ, файлов ... т.е. всех терминов, которые должны оставаться неизменяемыми, например: `/proc`, `mkdir`, `./myprog`, ...

– Программным листингам предшествует имя файла (отдельной строкой), где находится этот код в архивах примеров, это имя файла выделяется ***жирным курсивом с подчёркиванием***.

– Ввод пользователя в консольных командах (сами команды, или ответы пользователя в диалоге), кроме того, выделены **жирным моноширинным** шрифтом, чтобы отличать от ответного вывода системы, который набран `просто` моноширинным шрифтом.

– Текст, цитируемый из другого указанного источника, выделяется (для ограничения) *курсивным написанием*.

Код примеров и замеченные опечатки

Все протоколы выполнения команд и программные листинги, приводимые в качестве примеров, были опробованы и испытаны. Все примеры, обсуждаемые в тексте, предполагают воспроизведение и повторяемость результатов. Примеры программного кода сгруппированы по темам в архивы, поэтому всегда будет указываться имя архива (например, `xxx`) и имя файла (например, `yyy.c`); некоторые архивы могут содержать подкаталоги, тогда указывается и подкаталог для текущего примера. Большинство архивов (вида `xxx`) содержат одноимённые файлы вида `xxx.hist` — в них содержится скопированные с терминала результаты выполнения примера (протокол работы, журнал), показывающие как этот пример должен выполняться, в более сложных случаях здесь же могут содержаться команды, показывающие порядок компиляции и сборки примеров архива.

Конечно, и при самой тщательной выверке и вычитке, не исключены недосмотры и опечатки в таком объёмном тексте, могут проскочить мало внятные стилистические обороты и подобное. О замеченных таких дефектах я прошу сообщать по электронной почте o.tsiliuric@yandex.ru, и я был бы признателен за любые указанные недостатки рукописи, замеченные ошибки, или высказанные пожелания по её доработке.

Источники использованной информации

Я воздержался от создания более привычного и академического раздела в конце текста под названием «Библиография», исходя из нескольких соображений:

– Из за тематической разнородности частей текста общая библиография только вносила бы путаницу. Поэтому тематические указатели источников относящейся информации помещены

раздельно, в конце **каждой части** книги.

– Помимо публикаций (книг, статей) здесь указываются электронные публикации в Интернет, по которым, обычно, доступно гораздо меньше информации (часто автор, или дата написания, или дата публикации … оказываются неизвестными).

– Указанные ниже позиции никак не упорядочены, как это принято в настоящей библиографии. Это связано не столько с тем, что мне просто лень это делать, но ещё и с тем, что я просто не представляю как упорядочить смесь традиционных бумажных источников с электронными публикациями, когда всё это представлено единым списком.

– Приводятся источники не из соображения их фундаментальности, приводятся те источники которые оказались полезными при работе над рукописью и, главное, те которые позволяют уточнить в деталях то, что сказано в иексте.

2. Сетевой стек, архитектура

Сетевой стек Linux предназначен для обслуживания самого различного коммуникационного оборудования (физический и канальный уровень: Ethernet, TokenRing, WiFi, последовательные линии передачи RS-232 и подобные, USB ...) и реализации над ним самых различных протоколов сетевого уровня (например, IPX/SPX от Novell). Но так сложилось со временем, что в подавляющем большинстве случаев в качестве сетевого уровня потребителя интересует протокол IP, а из физического оборудования наиболее частым случаем будет Ethernet (ну, и иногда WiFi). Далее мы будем рассматривать реализацию именно таких технологий, но не стоит упускать из виду, что точно такими же методами сетевой стек Linux обеспечивает и поддержку всех других используемых на практике протоколов (например, сетевой трафик можно направить через последовательный интерфейс RS-232 или USB).

Протокол IP является **маршрутизируемым**. В противовес этому, протоколы, используемые в локальной сети (LAN), например Ethernet, являются **немаршрутизируемыми** — это означает, что пакеты такого протокола не могут распространяться за пределы одного сегмента сети, к которому напрямую подключены сетевые интерфейсы. Также немаршрутизируемым, например, являлся первоначальный сетевой протокол Windows NetBEUI (NetBIOS Frame Protocol) разработки IBM, поддержка которого позже (с Windows 2003) была прекращена именно по причине немаршрутизируемости и заменена на NetBIOS over TCP/IP (NBT).

Таким образом, для того, чтобы сделать протокол LAN (протокол MAC уровня) маршрутизируемым в глобальной сети (WAN), его нужно «посадить сверху» на протокол сетевого уровня как наездника на коня. Функции такого сетевого протокола и выполняет IP. А поскольку в такой схеме 2 эти протокола имеют совершенно различный формат адреса (MAC адрес и IP адрес, соответственно), то возникает необходимость в протоколах взаимного разрешения таких адресов: ARP (Address Resolution Protocol) — разрешение IP в MAC, и RARP (Reverse Address Resolution Protocol) — разрешение MAC в IP.

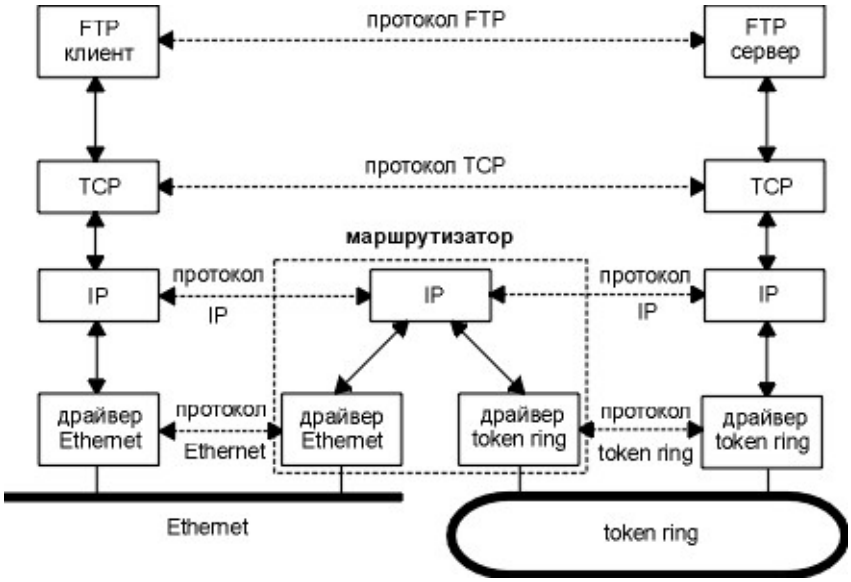

RFC

Так сложилось исторически (с 1969 года и поныне), что все аспекты работы сети регламентируются и описываются не стандартами международных комитетов и комиссий (как в других технических отраслях), а набором последовательно пронумерованных (их несколько тысяч) общедоступных описаний RFC (**R**equest **F**or **C**omments — заявка на отзывы, тема для обсуждения).

В настоящее время первичной публикацией документов RFC занимается IETF (Internet Engineering Task Force — Инженерный совет Интернета) под эгидой открытой организации ISOC (Internet Society — Общество Интернета). Правами на RFC обладает именно Общество Интернета.

Принципы сетевого стека

«Теория, мой друг, сухá, но зеленеет жизни древо»

К началу 80-х годов международной организацией по стандартизации (ISO — **I**nternational **O**rganization for **S**tandardization) была разработана модель взаимодействия открытых систем (OSI — **O**pen **S**ystem **I**nterconnection). Средства взаимодействия в модели OSI делятся на семь уровней, каждый из которых призван решать свой круг задач:

1. Физический;
2. Канальный;
3. Сетевой;
4. Транспортный;
5. Сеансовый;
6. Представительный;
7. Прикладной.

Чаще всего именно эту модель привлекают к рассмотрению и её изучают студенты. Но нужно отчётливо представлять, что реальный TCP/IP стек Linux заметно отличается от модели OSI, как по границам разбиения уровней, так и по функциональной нагрузке каждого из слоёв. В сетевом стеке Linux (основной направленностью которого, всё-таки, при его широте охвата является протокол TCP/IP) выделяют 4 уровня (L, level):

1. Канальный: модуль ядра — драйвер устройства и сетевой интерфейс, ARP, RARP — называемый как L1;
2. Сетевой: IP, ICMP, IGMP — называемый как L2;
3. Транспортный: UDP, TCP, и более поздние SCTP и DCCP — называемый как L3;
4. Прикладной: HTTP, Telnet, FTP, e-mail и все другие сервисы — эта огромная (по объёму и числу служб) часть реализуется уже не в ядре, а в адресном пространстве пользователя;

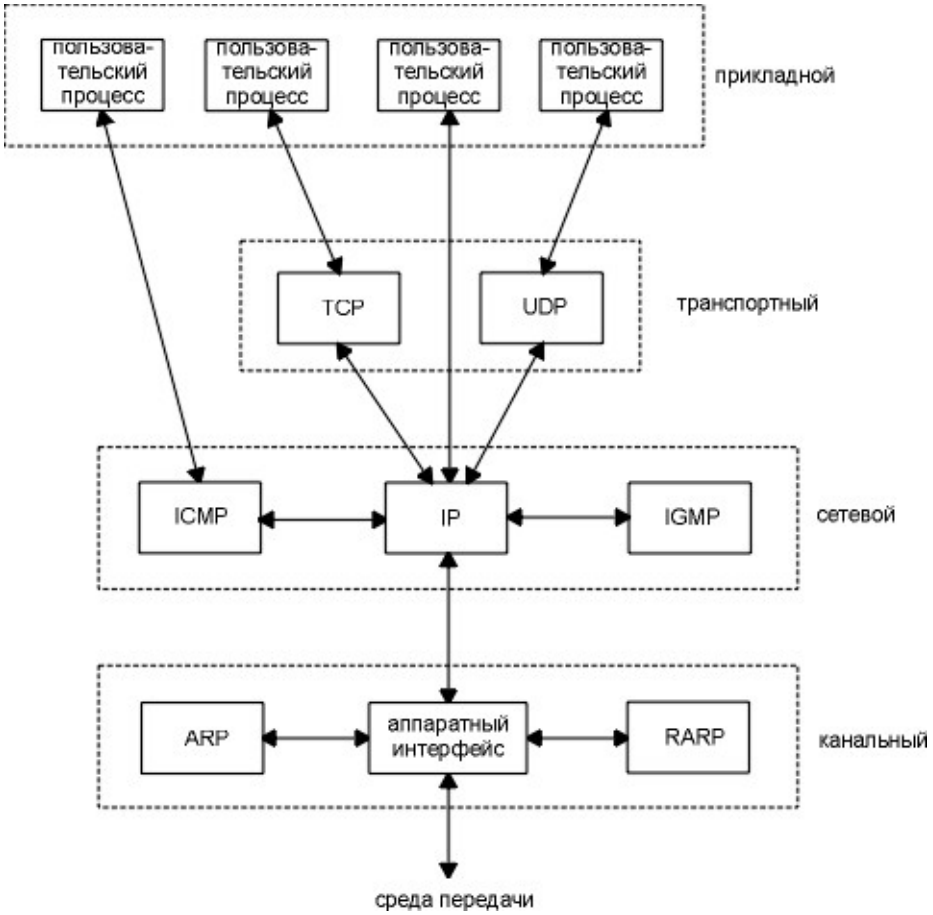

Нижний, физический уровень OSI, не рассматривается в стеке протоколов Linux поскольку считается, что он реализуется аппаратно. Уровни канальный, сетевой и транспортный реализуются в коде ядра и модулей ядра (драйвера), в **привилегированном** режиме работы процессора (кольцо защиты 0 процессора x86). Инструменты прикладного уровня реализуются в коде **пространства**

пользователя, в пользовательском режиме работы процессора (кольцо защиты 3 процессора x86).

Примечание: Сетевая передача производится в принципиально последовательных средах (бит за битом) распространения: проводные Ethernet или TokenRing, радиочастотные или инфракрасные среды в беспроводной передаче. Именно поэтому, на физическом и канальном уровне протоколов уместно и правильно рассматривать форматы и информацию в битовом представлении, которое, вообще то говоря, громоздко и непривычно с программистской точки зрения и протоколов вышележащих уровней. Поэтому даже относительно такой форматной информации физического представления мы зачастую будем условно пересчитывать битовые значения в байтовые, хотя никакого разграничения на байты в последовательно потоке передаваемых бит не происходит.

Инкапсуляция данных

Пакеты сетевых уровней TCP/IP вкладываются друг в друга, при этом заголовки пакетов каждого уровня несут исчерпывающую информацию своего уровня. Такую структура физически передаваемых пакетов называют **инкапсуляция** (вложение).

Такая же инкапсуляция на уровне структур данных, логическом — будет наблюдаться в структуре сокетных буферов в ядре Linux (и в модулях ядра, драйверах), что будет детально рассмотрено позже.

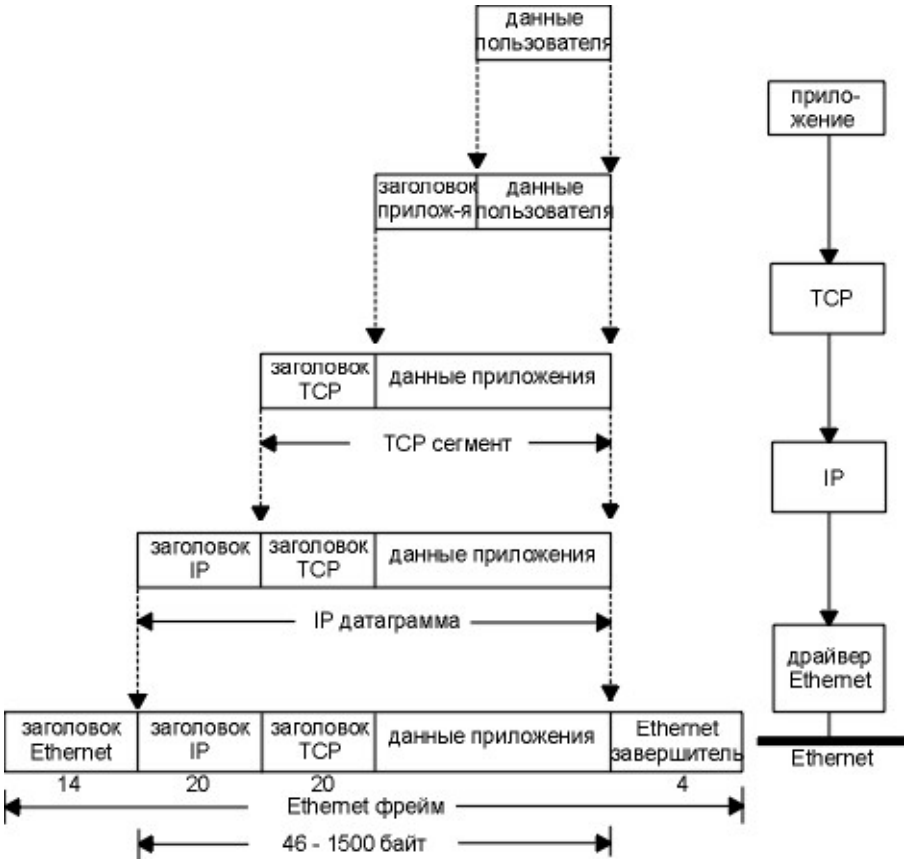

Сетевой порядок байт

Для 16-битового двоичного числа возможны 2 способа хранения его 2-х байт в памяти. Если первым (меньший адрес) идёт младший байт, то такой порядок называется прямым порядком байт (litle-endian), а если первым идёт старший байт — обратным порядком байт (big-endian). Не существует единого стандарта, и на разных процессорных архитерктурах используются разные порядки байт. При сетевом взаимодействии разных архитектур это вызовет проблемы. В самих сетевых протоколах используется сетевой порядок байт. Поэтому наша задача — всегда выполнить преобразование из порядка байт узла в сетевой и наоборот. Стандарт POSIX 1.g определяет для этого функции:

```
#include <arpa/inet.h>
uint32_t htonl(uint32_t hostlong);
```

```
uint16_t htons(uint16_t hostshort);
uint32_t ntohl(uint32_t netlong);
uint16_t ntohs(uint16_t netshort);
```

Первые 2 функции возвращают значения, записанные в сетевом порядке байт, 2 последние — в порядке байт узлов.

Как мы увидим из кода, **любые** данные (константы) размерностью больше байта, передаваемые в сеть, перед передачей **должны** преобразовываться в сетевой порядок байт. На приёмной стороне, соответственно, должны восстанавливаться в порядок байт принимающего хоста. Это особенно хорошо видно на примере 16-битового значения **номера порта** транспортного уровня. Достаточно часто (почти всегда) мы не будем видеть подобных преобразований над **пользовательскими** данными, передаваемыми по сети. Но это только потому, и только до тех пор, пока эти пользовательские данные представляются текстовым форматом, **потоком байт** ASCII или UNICODE кодированием в его многобайтным представлением UTF-8. Но при обмене в UTF-16 или UTF-32 представлении для UNICODE (тип данных `wchar_t`) — у нас уже возникнут те же вопросы сетевого порядка байт. (Но это, UTF-16 или UTF-32 данные, в высшей степени не характерно для Linux, это чаще проблема в Windows, и она нас не интересует.)

Адреса MAC

Адреса MAC (Media Access Control) — это адреса непосредственно физического, аппаратного уровня. Это уникальный идентификатор, присваиваемый каждой единице сетевого оборудования (физическому адаптеру или логическому сетевому интерфейсу).

Большинство сетевых протоколов канального уровня (L1 в терминологии Linux) используют одно из 3-х пространств MAC-адресов, управляемых комитетом IEEE (или MAC-48, или EUI-48, или EUI-6 — первые 2 48-бит, последнее 64-бит). Адреса из пространства MAC-48 наиболее распространены — они используются в таких технологиях, как Ethernet, TokenRing, FDDI, WiMAX и других. Идентификаторы EUI-64 состоят из 64 бит и используются в FireWire, а также в IPv6 (в качестве младших 64 бит локального сетевого адреса назначаемого узлу).

Сетевой интерфейс — это, как мы вскоре увидим детально, **логическое** понятие. Сетевому интерфейсу может соответствовать реальный сетевой адаптер, а может и не соответствовать. Реальный сетевой адаптер — это уже **физическое** понятие, и он имеет адрес MAC уровня, который для Ethernet (IEEE 802.3) имеет длину 6 байт и записывается, например, так: 00:15:60:c4:ee:02.

Именно по MAC адресам обращаются друг к другу адаптеры Ethernet в локальной сети (LAN). В единой LAN все MAC адреса должны быть **уникальны**, нарушение этого условия приведёт к нарушению работы LAN.

Примечание: До определённого времени выдвигалось требование, чтобы все MAC адреса всех сетевых адаптеров в мире были уникальными, распределялись определённым комитетом, и были зашиты в ROM адаптера. В настоящее время эти требования изменены, и **произвольный** MAC адрес может быть программным путём записан через аппаратные регистры адаптера.

Протоколы канального уровня — не маршрутизируемые. Для выхода за пределы локальной сети пакеты MAC-уровня должны быть инкапсулированы в пакеты маршрутизируемого протокола. Чаще всего в этом качестве выступает протокол IP (другие протоколы сетевого уровня мы не рассматриваем здесь). Адреса уровня MAC (вида 00:15:60:c4:ee:02) должны преобразовываться в адреса уровня IP (вида 192.168.1.1) и наоборот. Для преобразования MAC-адресов в адреса сетевого уровня и обратно применяются специальные протоколы (например, ARP и RARP в сетях IPv4, и NDP в сетях IPv6).

Адреса IP

Каждый **сетевой интерфейс** имеет свой IP адрес. Конечные точки коммуникаций в сети знают друг-друга **только** по их IP адресам. Все прочие сущности о которых мы будем говорить (имена хостов и интерфейсов, сетевые URL, маски и префиксы адреса ... да и всё другое) являются вторичными, предназначенными только для однозначного определения IP адресов.

IPv4

Адреса IPv4 — это те адреса протокола TCP/IP, к которым мы привыкли пользоваться на протяжении 3-х десятилетий (с ранних 90-х). Это 4-х байтная (32 бита) система IP адресов, называемая IP версии 4 или IPv4. 4 байта адреса IPv4 принято записывать как **десятичные** значения (0-255) разделённые символом '.', например: 192.168.1.5.

Такой размер IP адреса позволяет создать (всего) 4.3 миллиарда различающихся комбинаций (для ранних 90-х это было «чудовищно много», для 2020-х это «до смешного мало»).

Далее **в этой главе** будет рассматриваться только адресацию IPv4.

Маски и подсети

Первоначально для разделения всего диапазона IP адресов на **подсети** было введено разделение на классы:

Класс	Диапазон	Назначение
A	**0**.0.0.0 - **127**.255.255.255	Сверхбольшие подсети
B	**128**.0.0.0 - **191**.255.255.255	Большие подсети
C	**192**.0.0.0 - **223**.255.255.255	Малые подсети
D	**224**.0.0.0 - **239**.255.255.255	Групповые операции
E	**240**.0.0.0 - **247**.255.255.255	Резерв

Позже, с введением в обращение масок сети для разграничения подсетей (RFC 1219, бесклассовые сети, CIDR), классы утратили свой смысл (кроме групповых операций — multicast) и стало использоваться бесклассовое выделение подсетей. **Маска** в IPv4 является битовым образом, в котором ненулевые позиции определяют сеть (и подсеть), а нулевые позиции определяют те биты IP адреса, которые являются значащими при идентификации индивидуального адреса хоста в пределах подсети.

Таким образом маска полностью и однозначно определяет **предельное число** хостов, которое может работать в этой подсети. Младший адрес этого диапазона считается **адресом подсети** (например для записи в таблицы маршрутизации). Старший адрес этого же диапазона считается **широковещательным** (broadcast) адресом этой подсети. Все остальные адреса этого диапазона (минус 2 крайних) являются индивидуальными адресами хостов этой подсети. Например, следующие маски позволят организовать подсети следующих размерностей:

255.255.255.255 => ... 1111 1110 : 1 изолированный хост

255.255.255.248 => ... 1111 1000 : 8-2 = 6 хостов

255.255.255.240 => ... 1111 0000 : 16-2 = 14 хостов

255.255.255.224 => ... 1111 0000 : 32-2 = 30 хостов

255.255.255.248 => ... 1110 0000 : 64-2 = 62 хоста

IP адрес совместно с маской полностью определяют конфигурацию подсети и хоста. Для записи пары адреса и маски применяются 2 различные, но эквивалентные формы записи, например (это эквивалентно):

192.168.1.5 : 255.255.255.240 или 192.168.1.5 / 28

Здесь во 2-й форме записи 28 (называемое **префиксом**) — это число ведущих единиц в записи маски

(число ведущих бит, относящихся к адресу сети в записи 32-бит адреса, это IPv4).

Примечание: Как термин «префикс» довольно редко фигурирует в обсуждениях IPv4. Но в IPv6, где отсутствует понятие маски, он становится основополагающим!

Примечание: Первоначально, и это работает и сейчас, допускались «рваные» маски, когда единичные биты могли чередоваться с нулевыми произвольным порядком, не составляя единого ведущего блока единичных бит. Это работает, но это крайне сложно для интерпретации и толкования поведения хостов сети. Поэтому позже было принято решение о использовании только «цельных» масок с ведущим блоком сплошных единичных бит. При таком ограничении, понятно, необходимость в длинной и сложного формата маске исчезает, и вместо этого может использоваться просто короткое число префикс — это же мы и видим в IPv6.

Широковещательный и групповой обмен

Вообще то, существуют три типа IP адресов: персональный (unicast), широковещательный (broadcast) и групповой (multicast). Широковещательные и групповые запросы применимы только к UDP и SCTP, подобные типы запросов позволяют приложению разослать одно сообщение нескольким получателям одновременно. TCP — протокол, ориентированный на соединение, с его помощью устанавливается соединение между **двумя** хостами (по указанному IP адресу) с использованием одного адресата на каждом хосте (который идентифицируется по номеру порта).

Широковещательный адрес подсети (subnet-directed broadcast address) имеет идентификатор хоста, определяемый маской, установленный во все единицы (самый старший адрес диапазона адресов подсети, самый младший адрес этого диапазона есть адресом самой подсети):

```
$ ifconfig enp2s14
enp2s14: flags=4163<UP,BROADCAST,RUNNING,MULTICAST>  mtu 1500
        inet 192.168.1.5  netmask 255.255.255.0  broadcast 192.168.1.255
        inet6 fe80::215:60ff:fec4:ee02  prefixlen 64  scopeid 0x20<link>
        ether 00:15:60:c4:ee:02  txqueuelen 1000  (Ethernet)
        RX packets 280605  bytes 107024700 (102.0 MiB)
        RX errors 0  dropped 0  overruns 0  frame 0
        TX packets 326133  bytes 60602689 (57.7 MiB)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0
        device interrupt 16
```

Групповой адрес (multicast group address) состоит из четырех старших бит IP, установленных в 1110, и идентификатора группы (28 младших бит, определяющих конкретную группу). В десятичной записи групповые адреса находятся в диапазоне от 224.0.0.0 до 239.255.255.255. Групповая адресация позволяет направить датаграмму только выделенному подмножеству узлов, включённых в группу.

Для работы с группой прежде нужно включить (или исключить) в группу каждый хост, который должен участвовать в этой групповой рассылке. Для этого существует отдельный протокол управления группами IGMP (Internet Group Management Protocol, RFC 1112), который используется хостами и маршрутизаторами, для того чтобы организовывать групповую рассылку сообщений. Он позволяет всем узлам физической сети знать, какие хосты в настоящее время объединены в группы и к каким группам они принадлежат. Эта информация необходима для групповых маршрутизаторов, именно так они узнают, какие групповые датаграммы необходимо перенаправлять и на какие интерфейсы.

Частные адреса

В RFC 1918 (1996г.) были специфицированы 3 блока адресов — по одному ка каждый из классов A, B, C, которые не будут распределяться пользователям (организацией IANA) и которые **не маршрутизируются** шлюзами IP. Это адреса из диапазонов:

10.0.0.0 — 10.255.255.255 (префикс 10/8)

172.16.0.0 — 172.31.255.255 (префикс 172.16/12)

192.168.0.0 — 192.168.255.255 (префикс 192.168/16)

Адреса из **любого** из этих диапазонов можно выбирать для своей LAN (для организации Intranet).

Но их проблема в том, что такие хосты из LAN не смогут обращаться к внешним (за пределами LAN)

ресурсам: шлюз по умолчанию LAN не пропустит IP пакеты с таким исходящим адресом (а если даже и пропустит, то их порежет ближайший следующий маршрутизатор по трассе).

Для решения этой новой возникшей проблемы предложены несколько способов, основные из которых два:

1. На уровне протоколов прикладного уровня — прокси (proxy). При этом программа прокси-сервера **ретранслирует** запрос хоста с частным IP **от своего имени** в интерфейс с глобальным IP. Получив ответ, прокси-сервер перенаправляет ответ получателю (через интерфейс LAN). Известнейшим примером такой техники является HTTPS-прокси и реализующий сервер `squid`.

2. На сетевом уровне — преобразование сетевых адресов (NAT — Network Address Translation). При этом хост IP шлюза **подменяет** в маршрутизируемых пакетах IP **адрес оправителя**, подставляя IP собственного интерфейса с глобальным IP. Получив на этот адрес ответ, шлюз подменяет в этом пакете **адрес получателя**, и маршрутизирует его в интерфейс LAN получателю. Самыми известными проектами реализации в разное время были последовательно: `ipfw`, `ipfilter`, `iptables`. На сегодня самым частым является:

```
$ which iptables
/usr/sbin/iptables
```

Но и предыдущие реализации (`ipfw` и `ipfilter`) находят до сих пор применение в малых и встраиваемых архитектурах.

Частные IPv4 и NAT

32-бит локальные адреса IPv4 в сети Интернет, раздаваемые организацией IANA, исчерпались бы количественно, наверное, ещё лет 10-15 назад, если бы не было принято расширение стандарта и не введены 3 диапазона показанных выше частных IPv4 адресов. После этого вы (или любая организация, компания, фирма...) в своей LAN можете произвольно, по собственному усмотрению, администрировать по IP хосты. Такое решение снижает общую потребность в индивидуальных IPv4 адресах (в просторечии называемых как «белые») в сотни и тысячи раз.

Но если эти частные адреса не маршрутизируются шлюзами IP в сеть WAN, то нужно искать способ вывода хостов LAN с такими адресами в глобальную сеть. И такой способ был предложен, и это механизм NAT (Network Address Translation — «преобразование сетевых адресов», ещё употребляются термины Masquerading, Network Masquerading и Native Address Translation). Способ NAT состоит в преобразовании IPv4 адресов транзитных, осуществляемом на шлюзе в WAN.

Очень коротко, «на пальцах»:

- заголовок IP пакета из локальной сети (на сетевом уровне, L2), с частным IPv4, преобразуется в заголовок пакета с «белым» адресом IP интерфейса шлюза, глядящим в WAN…
- и подменяется номер порта (чтобы различать ответные пакеты, адресованные разным локальным компьютерам)...
- пакет отправляется в WAN (forwarding между интерфейсами)
- заголовок приходящего в ответ (от сервера) на отправленный пакет из WAN модифицируется: «белый» адрес получателя подменяется на исходный частный IPv4 отправителя…
- и пересылается в LAN реальному получателю.

На сегодня (с ядра 2.4) это механизм в Linux реализуется ядром (это к вопросу эффективности), механизмом `netfilter` и соответствующей ему утилитой пространства пользователя `iptables` — для управления работой (правилами) этого ядерного механизма. (В Linux исторически, в разное время, прошли для этих целей разные механизмы, известные под названиями проектов `ipchains` и `ipfwadm`).

Примечание: Как альтернатива этому механизму сетевого уровня L2 (в ядре) для выхода в WAN локальных хостов из LAN может, в некоторых случаях, использоваться механизм транспортного уровня L3 (пользовательского пространства), работающий через прокси-сервер на шлюзе в WAN. Прокси-сервер может использовать транспортный протокол HTTP/HTTPS, или TCP (прокси SOCKS4/SOCKS5). О прокси-серверах мы ещё поговорим коротко позже.

IPv6

6 июня 2012 года крупнейшие провайдеры единовременно перешли к использованию **параллельно** с IPv4 16-ти байтовых (128 бит) IP адресов. Эту систему адресации, разрабатываемую

с 1992 года, называют IP версии 6 или IPv6. Адреса IPv6 записываются как последовательности 4-х шестнадцатеричных значений (0000-ffff), разделённых ':', например: fe80::215:60ff:fec4:ee02.

Протокол IPv6 разработан как преемник протокола IPv4. Основные преимущества IPv6 над IPv4 заключаются в увеличенном адресном пространстве (IPv4 имел 32 бита, что равнялось 2^{32} адресам, а IPv6 имел 128 бит, что равнялось 2^{128} адресам).

Адрес протокола IPv6 состоит из 128 бит, то есть, он в 4 раза длиннее 32-битного IPv4 адреса. Подобно IPv4, в этом адресе можно выделить две части: сеть и хост. То есть, не все биты в адресе имеют одинаковое значение. Часть битов слева (сколько именно зависит от префикса) обозначают сеть, остальные биты справа – идентифицируют устройство внутри сети. Часть, ответственная за хранение информации о хосте называется идентификатор интерфейса (interface id).

Здесь сразу же зафиксируем важнейшее для пользователя отличие, которое несёт ему IPv6: здесь **нет отличия** между «глобальными» хостами подключенными в Интернет, и «локальными» находящимися в LAN. Здесь любой хост равнозначно доступен извне, если он не закрыт файерволом каким-то образом.

Префикс адреса

В отличие от предыдущей версии протокола, в IPv6 не применяются маски подсети, так как они получились бы очень длинными, вместо этого используется префикс. который записывается так же через слеш после адреса. Например, префикс /64 означает, что из 128 бит, первые 64 – это сеть, а оставшаяся часть (в данном случае вторые 64) – это хост. Префикс описывает, сколько бит в адресе используется под хранение информации о сети.

Сам адрес записывают не в десятичном, а в шестнадцатеричном виде – так короче. Адрес разбивается на группы по 16 бит (хекстеты) и каждая группа представляется четырьмя шестнадцатеричными цифрами. Хекстеты отделяются друг от друга знаком двоеточия. Таким образом, адрес состоит из 8 хекстетов ([8 хекстетов]*[16 бит в хекстете]=[128 бит] – общая длина адреса).

Сокращения записи IPv6

Пример адреса: 2001:0DB8:AA10:0001:0000:0000:0000:00FB. С таким длинным адресом работать достаточно неудобно, поэтому для IPv6 применяют сокращённую по специальным правилам запись. Для того чтобы сократить данный адрес надо **последовательно** применить два правила.

Правило №1:

В каждом хекстете (группе из 4-х цифр) ведущие нули удаляются. Например, во втором хекстете 0DB0 заменяется на DB0. То есть ноль слева удаляется, ноль справа мы не трогаем. Если хекстет состоит из одних нолей, то он заменяется на один ноль. Таким образом адрес 2001:0DB0:0000:123A:0000:0000:0000:0030 преобразуется в 2001:DB0:0:123A:0:0:0:30. А, например, адрес loopback 0000:0000:0000:0000:0000:0000:0000:0001 таким правилом заменяется на 0:0:0:0:0:0:0:1.

Правило №2:

Это правило применяется **только после** первого. В адресе выбирается одна самая длинная группа, состоящая из полностью нулевых хекстетов, то есть самая длинная последовательность «:0:0:0:» и заменяется на два двоеточия «::». Эту замену можно произвести **только один раз** и только **с самой длинной** последовательностью (так как, если бы мы, например, сделали такую замену в двух местах адреса, то потом нельзя было бы восстановить, сколько именно хекстетов мы заменили в первом и во втором случае). Важный момент: нельзя заменять одну группу из :0: на ::, правило два применимо только если есть более одной нулевой группы.

Для примера возьмём адрес из предыдущей замены 2001:DB0:0:123A:0:0:0:30. Самая длинная последовательность из полностью пустых хекстетов – это «:0:0:0:», она начинается сразу после хекстета «123A». Есть ещё последовательность из одного пустого хекстета (между «DB0» и «123A»), но эта – длиннее, так что заменять будем её. Адрес станет совсем небольшим: 2001:DB0:0:123A::30. Это, конечно, длиннее IPv4 адреса, но гораздо короче исходного.

Обратное восстановление исходного адреса по сокращённой записи (должно производиться редко в представлении для человека, но выполняется каждый раз в сетевой подсистеме при обращении по адресу) достаточно тривиально, если мы уже умеем сокращать адреса.

Сначала надо посчитать, сколько хекстетов в адресе осталось. В нашем случае, в адресе 2001:DB0:0:123A::30 осталось 5 хекстетов. Мы знаем, что адрес должен состоять из **восьми** хекстетов – значит вместо «::» возвращаем три недостающих нулевых, получаем 2001:DB0:0:123A:0:0:0:30. Теперь в каждой группе, где меньше четырёх цифр дописываем слева такое количество нулей, чтобы в этой группе стало четыре цифры. В результате получим исходный адрес 2001:0DB0:0000:123A:0000:0000:0000:0030.

Несколько примеров сокращения адресов, сокращать будем по правилам в два этапа:

```
FF80:0000:0000:0000:0123:1234:ABCD:EF12 -> FF80:0:0:0:123:1234:ABCD:EF12 ->
FF80::123:1234:ABCD:EF12
FF02:0000:0000:0000:0000:0001:FF00:0300 -> FF02:0:0:0:0:1:FF00:300 -> FF02::1:FF00:300
2001:0DB8:0000:1111:0000:0000:0000:0200 -> 2001:DB8:0:1111:0:0:0:200 -> 2001:DB8:0:1111::200
0000:0000:0000:0000:0000:0000:0000:0001 -> 0:0:0:0:0:0:0:1 -> ::1
0000:0000:0000:0000:0000:0000:0000:0000 -> 0:0:0:0:0:0:0:0 -> ::
```

Предпоследний из показанных IPv7 адресов ::1 — это петлевой интерфейс, соответствующий в IPv4 привычному 127.0.0.1

Локальные адреса

IPv6 адреса различаются по области действия. Глобальный адрес IPv6 действует в интернете. Глобальные адреса должны быть уникальными в Интернете, поэтому адреса IPv6 распределяются организации IANA.

Локальные адреса IPv6 (unique local address), могут использоваться внутри организации без обращения в IANA, такие адреса не маршрутизируются в интернет, поэтому ничего страшного не произойдет, если несколько организаций будут использовать одни и те же локальные адреса. Локальные адреса IPv6 это аналоги приватных или частных адресов IPv4.

В IPv6 есть локальные адреса канала связи (link-local address), которые вообще не маршрутизируются, они назначаются автоматически и действуют **в пределах одного сегмента сети**, одного коммутатора или несколько связанных между собой коммутаторов. Через маршрутизатор сообщения с такими IPv6 адресами не проходят.

Локальный адрес канала связи, действующий в рамках одного сегмента сети, начинается с цифр FE80. Если у вас для сетевого **интерфейса** (интерфейсы конфигурируются индивидуально) разрешён протокол IPv6 (проще всего это сделать через NetworkManager) то вы можете для интерфейса видеть что-то подобное следующему:

```
$ ip a s dev eno1
2: eno1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
    link/ether 70:71:bc:a3:c5:c0 brd ff:ff:ff:ff:ff:ff
    altname enp0s25
    inet 192.168.1.11/24 brd 192.168.1.255 scope global noprefixroute eno1
       valid_lft forever preferred_lft forever
    inet6 fe80::762:c6bf:9eaa:93a9/64 scope link noprefixroute
       valid_lft forever preferred_lft forever
```

А на любом другом хосте этой LAN можно выполнить:

```
$ ping -6 -c3 fe80::762:c6bf:9eaa:93a9%eno1
PING fe80::762:c6bf:9eaa:93a9%eno1(fe80::762:c6bf:9eaa:93a9%eno1) 56 data bytes
64 bytes from fe80::762:c6bf:9eaa:93a9%eno1: icmp_seq=1 ttl=64 time=8.54 ms
64 bytes from fe80::762:c6bf:9eaa:93a9%eno1: icmp_seq=2 ttl=64 time=3.64 ms
64 bytes from fe80::762:c6bf:9eaa:93a9%eno1: icmp_seq=3 ttl=64 time=3.68 ms

--- fe80::762:c6bf:9eaa:93a9%eno1 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2004ms
rtt min/avg/max/mdev = 3.635/5.284/8.544/2.304 ms
```

Синтаксис записи IPv6

Характерно, что если вы выполните ту же команду `ping` что и показанную выше, но в более

привычном виде, то получите неожиданную ошибку:

```
$ ping -6 -c3 fe80::762:c6bf:9eaa:93a9
PING fe80::762:c6bf:9eaa:93a9(fe80::762:c6bf:9eaa:93a9) 56 data bytes

--- fe80::762:c6bf:9eaa:93a9 ping statistics ---
3 packets transmitted, 0 received, 100% packet loss, time 2039ms
```

Это связано с тем, что даже в рамках одной локальной сети (LAN) соседние хосты могут иметь, в принципе, совпадающие **локальные** IPv6 для своих интерфейсов. Поэтому мы должны обязательно указывать (суффикс) с какого интерфейса мы намереваемся посылать ICMP пакеты (ping — это ICMP). В качестве суффикса может указываться не только **имя**, но и **номер** передающего интерфейса:

```
$ ip link
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue state UNKNOWN mode DEFAULT group default
qlen 1000
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
2: eno1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc mq state UP mode DEFAULT group default
qlen 1000
    link/ether 90:b1:1c:54:3a:46 brd ff:ff:ff:ff:ff:ff
    altname enp2s0f0
3: eno2: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc mq state UP mode DEFAULT group default
qlen 1000
    link/ether 90:b1:1c:54:3a:47 brd ff:ff:ff:ff:ff:ff
    altname enp2s0f1
4: tun0: <POINTOPOINT,MULTICAST,NOARP,UP,LOWER_UP> mtu 53049 qdisc fq_codel state UNKNOWN mode
DEFAULT group default qlen 500
    link/none

$ ping -6 -c3 fe80::762:c6bf:9eaa:93a9%3
PING fe80::762:c6bf:9eaa:93a9%3(fe80::762:c6bf:9eaa:93a9%eno2) 56 data bytes
64 bytes from fe80::762:c6bf:9eaa:93a9%eno2: icmp_seq=1 ttl=64 time=18.9 ms
64 bytes from fe80::762:c6bf:9eaa:93a9%eno2: icmp_seq=2 ttl=64 time=3.46 ms
64 bytes from fe80::762:c6bf:9eaa:93a9%eno2: icmp_seq=3 ttl=64 time=3.66 ms

--- fe80::762:c6bf:9eaa:93a9%3 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2003ms
rtt min/avg/max/mdev = 3.458/8.681/18.924/7.243 ms
```

Если вам смущает такая запись локальных IPv6 адресов в такой, несколько замысловатой, форме как показано здесь и/или чуть выше, то это может быть записано и в более традиционной форме:

```
$ ping -6 -c3 fe80::522d:d0bd:b221:a526 -Ieno2
ping: Warning: source address might be selected on device other than: eno2
PING fe80::522d:d0bd:b221:a526(fe80::522d:d0bd:b221:a526) from :: eno2: 56 data bytes
64 bytes from fe80::522d:d0bd:b221:a526%eno2: icmp_seq=1 ttl=64 time=3.46 ms
64 bytes from fe80::522d:d0bd:b221:a526%eno2: icmp_seq=2 ttl=64 time=3.44 ms
64 bytes from fe80::522d:d0bd:b221:a526%eno2: icmp_seq=3 ttl=64 time=3.44 ms

--- fe80::522d:d0bd:b221:a526 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2003ms
rtt min/avg/max/mdev = 3.435/3.444/3.459/0.010 ms
```

Это всё показано и обсуждаем для того, что синтаксически адреса IPv6 должны записываться, иногда, в некоторой более сложной (уточнённой) форме, чем мы это привыкли делать для IPv4.

Например, IPv6 адреса в WEB URL мы должны указывать помещая их в квадратные скобки […], если в URL нужно указать TCP порт, то указывает его за пределами скобок. Вот как это выглядит (не обращайте, пока, внимания на «странную» доменную зону `.lib` — мы к этому вскоре вернёмся, нас пока интересуют только **синтаксические** формы записи адресов IPv6):

```
$ host ygg.linux-ru.lib
ygg.linux-ru.lib has IPv6 address 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
```

```
$ curl [221:58c9:9a6:99be:f3d:c1ac:2b5b:9771] > /dev/null
  % Total    % Received % Xferd  Average Speed   Time    Time     Time  Current
                                 Dload  Upload   Total   Spent    Left  Speed
100 52692    0 52692    0     0  44686      0 --:--:--  0:00:01 --:--:-- 44692
$ wget http://[221:58c9:9a6:99be:f3d:c1ac:2b5b:9771]:80/index.php -O - > /dev/null
--2023-04-21 17:11:23--  http://[221:58c9:9a6:99be:f3d:c1ac:2b5b:9771]/index.php
Подключение к [221:58c9:9a6:99be:f3d:c1ac:2b5b:9771]:80… соединение установлено.
HTTP-запрос отправлен. Ожидание ответа… 200 OK
Длина: нет данных [text/html]
Сохранение в: ‘STDOUT’
-                                           [ <=>                ]  51,54K  --.-KB/s    за 0,1s
2023-04-21 17:11:24 (419 KB/s) - записан в stdout [52782]
```

(Я не показываю здесь графической картинки браузера, во избежание перегрузки места в тексте, но именно в таком синтаксисе мы должны показывать IPv6 в адресной строке браузера. А вот такой формой команды `wget` мы будем проверять работоспособность сетевых WEB-сервера.)

В других случаях, мы можем рассчитывать на привычный синтаксис записи IPv6 в консольных командах, здесь для `ping` используется не локальный IPv6 (удалённый в Интернет), когда сетевой стек может (из таблицы роутинга) однозначно определить трассу прохождения запроса, интерфейс отправки ICMP:

```
$ ping -6 -c3 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
PING 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771(221:58c9:9a6:99be:f3d:c1ac:2b5b:9771) 56 data bytes
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=1 ttl=64 time=115 ms
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=2 ttl=64 time=117 ms
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=3 ttl=64 time=115 ms

--- 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2002ms
rtt min/avg/max/mdev = 114.620/115.602/117.062/1.052 ms
```

Вот так мы можем определять открытость портов (файервол) и работоспособность WEB серверов на удалённых хостах Интернет, готовность их работать по HTTP (TCP порт 80) или HTTP (TCP порт 443):

```
$ telnet 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771 80
Trying 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771...
Connected to 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771.
Escape character is '^]'.
^]
telnet> Connection closed.

$ telnet 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771 443
Trying 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771...
Connected to 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771.
Escape character is '^]'.
^]
telnet> Connection closed.
```

Наконец, вот так мы сканируем открытые порты удалённого хоста где-то далеко в Интернет (вспомним, что для IPv6, в отличие от IPv4, нет разницы в доступности хостов «логальные» они или «глобальные»):

```
$ nmap -6 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
Starting Nmap 7.80 ( https://nmap.org ) at 2023-04-21 14:59 EEST
Nmap scan report for 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
Host is up (0.13s latency).
Not shown: 997 filtered ports
PORT     STATE  SERVICE
80/tcp   open   http
443/tcp  open   https
8080/tcp closed http-proxy
```

```
Nmap done: 1 IP address (1 host up) scanned in 23.21 seconds
```

Прогноз

Система IPv6 была официально введена в эксплуатацию 6 июня 2012 года (крупнейшими провайдерами единовременно). Вместо 2^{32} индивидуальных адресов IPv6 предоставляет 2^{128} адресов.

Проблема, казалось бы, решена… Однако переход с протокола IPv4 на IPv6 вызывает трудности, потому что эти протоколы несовместимы. И повсеместный переход пошёл гораздо медленнее, чем прогнозировалось на момент ввода в эксплуатацию. И изюминкой причины такого тяжелого перехода на 6-ю версию протокола является денежная стоимость! Многие компании просто не готовы вкладывать достаточное количество средств для перехода.

Но, как бы то ни было, IPv6 — это будущее Интернет! А вслед за ним и локальных сетей. Что приведёт со временем к полному вытеснения и отмиранию IPv4. Вопрос такого прогноза только в темпах и сроках.

Конечно, любой прогноз — дело неблагодарное...

Адресные переменные в программном коде

Прототипы функций для работы с адресными переменными описаны `<arpa/inet.h>` .

Функция `inet_pton()` преобразовывает символьное изображение IP адреса в структуру адреса:

```
int inet_pton( int af, const char *src, void *dst );
```

Здесь:

- `af` — семейство адресов, может быть записано только одной из 2-х символьных констант: `AF_INET` или `AF_INET6`, что означает адрес IPv4 или IPv6, соответственно (`</usr/include/bits/socket.h>`);
- `src` — символьная строка, в которой записан исходный IP адрес. Для IPv4 адрес записывается в привычной точечной нотации: "d.d.d.d", где d — это **десятичное** число 0-255. Для IPv6 адрес может записываться в нескольких формах: h:h:h:h:h:h:h:h или h:h:h:h:h:h:d.d.d.d, где h — это до 4-х знаков шестнадцатеричные числа (0-ffff), кроме того, нулевые адресные группы в IPv6, как обычно, могут опускаться, например: ::FFFF:204.152.189.116.
- `dst` — результат преобразования, структура адреса, вид которой зависит от семейства адресов.

Для `AF_INET` это (определяется в `<linux/in.h>`):

```
struct in_addr {
        __be32  s_addr;
};
```

Для `AF_INET6` это (определяется в `<linux/in6.h>`):

```
struct in6_addr {
        union {
                __u8            u6_addr8[16];
        ...
        } in6_u;
```

Вообще, в ядре Linux определено весьма много поддерживаемых семейств адресов (или семейств протоколов), что сильно усложняет поиск информации:

```
$ cat socket.h | grep 'AF_' | wc -l
44
```

Возвращаемое значение функции `inet_pton()` указывает на успешность операции преобразования:

1 — успешное преобразование;

0 — строка src не содержит строчное представление в специфицированном семействе адресов;

-1 — в качестве параметра `af` указано недопустимое семейство адресов, при этом глобальная переменная `errno` устанавливается в `EAFNOSUPPORT`;

Функция `inet_ntop()` делает в точности наоборот: преобразовывает структуру сетевого адреса в символьное изображение IP адреса:

```
const char *inet_ntop( int af, const void *src, char *dst, socklen_t size );
```

Здесь:

- `af` — семейство адресов `AF_INET` или `AF_INET6`;
- `dst` — строка результат преобразования, это же значение возвращается `inet_ntop()` при успешном выполнении;
- `size` — длина запрашиваемой строки результата, специфицируемая при вызове, это может быть символьная константа типа `INET6_ADDRSTRLEN`;

В заголовочном файле `<arpa/inet.h>` представлено ещё весьма много полезных функций манипуляции с IP адресами — они оставляются на самостоятельное изучение.

Чтобы не изобретать велосипед, в качестве примера работы с адресами (каталог архива `address`) воспользуемся кодом примера непосредственно из `man` страницы:

adr.c :

```
#include <arpa/inet.h>
#include <stdio.h>
#include <stdlib.h>
#include <string.h>

int main(int argc, char *argv[]) {
   unsigned char buf[sizeof(struct in6_addr)];
   int domain, s;
   char str[INET6_ADDRSTRLEN];
   if (argc != 3) {
      fprintf(stderr, "Usage: %s {i4|i6|<num>} string\n", argv[0]);
      exit(EXIT_FAILURE);
   }
   domain = (strcmp(argv[1], "i4") == 0) ? AF_INET :
            (strcmp(argv[1], "i6") == 0) ? AF_INET6 :
            atoi(argv[1]);
   s = inet_pton(domain, argv[2], buf);
   if (s <= 0) {
      if (s == 0)
         fprintf(stderr, "Not in presentation format");
      else
         perror("inet_pton");
         exit(EXIT_FAILURE);
   }
   if (inet_ntop(domain, buf, str, INET6_ADDRSTRLEN) == NULL) {
      perror("inet_ntop");
      exit(EXIT_FAILURE);
   }
   printf("%s\n", str);
   exit(EXIT_SUCCESS);
}
```

Программа выполняет прямое, а затем обратное (для контроля) преобразование строчного изображения IP адреса. Выполнение примера иллюстрирует выше сказанное о форматах вызова функций:

```
$ ./adr i6 0:0:0:0:0:0:0:0
::
$ ./adr i6 1:0:0:0:0:0:0:8
1::8
$ ./adr i6 0:0:0:0:0:FFFF:204.152.189.116
::ffff:204.152.189.116
$ ./adr i4 204.152.189.116
```

204.152.189.116

Разрешение адресов и имён

В принципе, сеть Интернет вполне могла бы работать **только** на основании адресации через числовые IP адреса (а как уже должно стать понятно и эти числовые записи в условных форматах — есть запись битовой последовательности длиной 32 или 64 бит). Однако человеку крайне сложно визуально воспринимать такие длинные числовые последовательности. Поэтому адресуемым единицам в сети стали присваивать более-менее осмысленные имена, легко воспринимаемые человеком. Но тогда возникает задача поддержания устойчивых таблиц соответствий имён адресам, и задача быстрого разрешения имён в адреса и наоборот.

Для решения этих задач была создана (ещё на заре Интернет) система DNS (Domain Name System, система доменных имён) — компьютерная распределённая система для получения информации о доменах. Чаще всего она используется для получения IP адреса по имени хоста, получения информации о маршрутизации почты и некоторой другой адресной информации. Распределённая база данных DNS рассредоточена на иерархии выделенных DNS-серверов и по соответствующему (только для этих целей) протоколу. Из сказанного уже должно быть понятно, что протокол DNS — это один из старейших протоколов Интернет … но он претерпел и множество изменений и имеет множество модификаций.

В POSIX/UNIX (утилитах) предусмотрен достаточный набор команд и функций для взаимного преобразования имён и адресов хостов и получения информации о хостах. Для таких адресных преобразований все эти инструменты должны привлекать информацию из файла `/etc/hosts`, или обращаться к механизму DNS.

Из командной строки подобное разрешение выглядит так (в 1-й команде для разрешения имени мы явно затребовали Интернет DNS-сервер 1.1.1.1):

```
$ nslookup qnx.org.ru 1.1.1.1
Server:         1.1.1.1
Address:        1.1.1.1#53

Non-authoritative answer:
Name:   qnx.org.ru
Address: 89.223.70.101

$ host rus-linux.net
rus-linux.net has address 178.208.91.21
rus-linux.net has IPv6 address b2d0:5b15:400d:802::1004
rus-linux.net mail is handled by 10 mail.rus-linux.net.
```

Ещё вариант (здесь мы тоже явно указываем требуемый DNS-сервер 8.8.4.4):

```
$ dig @8.8.4.4 linux-ru.ru
; <<>> DiG 9.18.12-0ubuntu0.22.04.1-Ubuntu <<>> @8.8.4.4 linux-ru.ru
; (1 server found)
;; global options: +cmd
;; Got answer:
;; ->>HEADER<<- opcode: QUERY, status: NOERROR, id: 12764
;; flags: qr rd ra; QUERY: 1, ANSWER: 1, AUTHORITY: 0, ADDITIONAL: 1

;; OPT PSEUDOSECTION:
; EDNS: version: 0, flags:; udp: 512
;; QUESTION SECTION:
;linux-ru.ru.                   IN      A

;; ANSWER SECTION:
linux-ru.ru.            600     IN      A       90.156.230.27

;; Query time: 96 msec
;; SERVER: 8.8.4.4#53(8.8.4.4) (UDP)
;; WHEN: Thu Apr 20 19:36:36 EEST 2023
;; MSG SIZE  rcvd: 56
```

Мы ещё не раз и много будем говорить о механизме DNS-разрешения дальше, а пока взглянем на то как разрешение адресов и имён происходит в программном коде...

Разрешение имён в программном коде

Необходимость взаимного разрешения **имён** узлов (например `yandex.ru`) WAN в соответствующие им IP **адреса** (как 213.180.204.11) и наоборот возникает постоянно: показанные в этой фразе имя и адрес являются изображением одного и того же узла в разной системе адресации. Для осуществления этого преобразования в сети существует целая связная сеть серверов DNS.

А из предназначенных для этих целей **функций**:

```
#include <netdb.h>
struct hostent *gethostbyname(const char *name);
```

Функция возвращает информацию о хосте по его имени:

```
struct hostent {
  char *h_name;                 /* Official name of host.                */
  char **h_aliases;             /* Alias list.                           */
  int h_addrtype;               /* Host address type AF_INET or AF_INET6 */
  int h_length;                 /* Length of address 4 or 16             */
  char **h_addr_list;           /* List of addresses from name server.   */
};
```

Ещё один образец — функция `gethostbyaddr()`ищущая информацию о хосте по IP адресу (обратная функциональность `gethostbyname()`)

```
#include <sys/socket.h>       /* for AF_INET */
struct hostent *gethostbyaddr( const void *addr, socklen_t len, int type );
```

Функция `getaddrinfo()`, введенная более поздним стандартом POSIX 1.g, скрывает все зависимости в параметрах от типа протокола:

```
#include <netdb.h>
int getaddrinfo(const char *node, const char *service,
                const struct addrinfo *hints,
                struct addrinfo **res);
```

Через указатель `res` функция возвращает указатель на связный **список** структур `addrinfo` (создаваемый динамически средствами `malloc()`):

```
struct addrinfo {
               int              ai_flags;
               int              ai_family;   /* AF_xxx */
               int              ai_socktype; /* SOCK_DGRAM, SOCK_STREAM, ... */
               int              ai_protocol;
               socklen_t        ai_addrlen;
               struct sockaddr *ai_addr;
               char            *ai_canonname;
               struct addrinfo *ai_next;     /* поле связи */
           };
```

Поскольку список создаётся динамически, его позже нужно обязательно удалить вызовом:

```
void freeaddrinfo( struct addrinfo *res );
```

Пример использования `getaddrinfo()` показан в каталоге архива `address` на примере ретранслирующего сервера UDP (пример взят непосредственно из `man` функции `getaddrinfo()`):

- клиент:

```
$ ./gclie localhost 60000 привет
Received 13 bytes: привет
```

- сервер:

```
$ ./gserv 60000
Received 13 bytes from notebook.localdomain:58355
^C
```

Сетевые интерфейсы

В отличие от всех прочих **устройств** в системе, которым соответствуют имена (и номера) устройств в каталоге `/dev`, сетевые устройства создают сетевые **интерфейсы**, которые не отображаются как именованные устройства в `/dev`, но каждый из которых имеет набор своих характеристических параметров (MAC адрес, IP адрес, маска сети, префикс ...). Интерфейсы могут быть физическими (отображающими реальные аппаратные сетевые устройства, например, `eth0` — адаптер Ethernet), или логическими (отражающими некоторые моделируемые понятия, например, `tap0` — туннельный интерфейс). Одному аппаратному сетевому устройству может соответствовать одновременно **несколько** различных сетевых интерфейсов.

Сетевые интерфейсы **создаются** поддерживающими их драйверами — модулями ядра Linux. В общем случае, разработчик драйвера (модуля ядра) специфического сетевого устройства может выбрать имя для его интерфейса **произвольно** (определяется программным кодом драйвера).

Примечание: Продолжительные годы (десятилетия) существовала традиция (унаследованная из ранних UNIX) именовать сетевые интерфейсы по их принадлежности к той или иной физической **среде** (протоколу) передачи, например, интерфейс устройства WiFi должен был именоваться как `wlan0`. Но в текущих реализациях Linux (ядра 3.x и далее) имена сетевых интерфейсов могут конструироваться автором кода **драйвера** не исходя из принадлежности к протоколам физического уровня (например, `eth0, eth1,` ... — для проводных Ethernet соединений), а совершенно произвольно. Временами предпринимаются попытки (Fedora 16, Fedora 17) ввести единообразное именование интерфейсов исходя, например, из расположения (адреса) данного сетевого адаптера на аппаратной шине PCI. Тогда имя интерфейса (для того же проводного Ethernet) может принять вид: `p7p1` или `p2p1`. Но и такие привязки не прижились широко.

Имена сетевых интерфейсов, как мы увидим вскоре, могут быть **произвольными** и определяются **модулем** ядра, реализующим интерфейс для устройств такого типа. В системе не может быть интерфейсов с совпадающими именами, поэтому поддерживающий модуль должен будет как-то модифицировать имена интерфейсов однотипных устройств, в соответствии с принятой схемой именований (например, добавляя суффикс: цифру, литеру, ...).

Посмотреть текущие существующие сетевые интерфейсы на узле можно, например, так:

```
$ ip link
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue state UNKNOWN mode DEFAULT group default
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
2: enp2s14: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc mq state UP mode DEFAULT group
default qlen 1000
    link/ether 00:15:60:c4:ee:02 brd ff:ff:ff:ff:ff:ff
3: wlp8s0: <BROADCAST,MULTICAST> mtu 1500 qdisc mq state DOWN mode DORMANT group default qlen 1000
    link/ether 00:13:02:69:70:9b brd ff:ff:ff:ff:ff:ff
```

Этим же интерфейсам соответствуют подкаталоги с соответствующими именами в `/proc`, каждый такой каталог содержит псевдофайлы-параметры (по диагностике или управлению) соответствующего интерфейса:

```
$ ls /proc/sys/net/ipv4/conf
all  default  enp2s14  lo  wlp8s0

$ ls -w80 /proc/sys/net/ipv4/conf/enp2s14/
accept_local          disable_xfrm                        proxy_arp_pvlan
accept_redirects    force_igmp_version                    route_localnet
accept_source_route forwarding                            rp_filter
arp_accept            igmpv2_unsolicited_report_interval  secure_redirects
arp_announce          igmpv3_unsolicited_report_interval  send_redirects
arp_filter            log_martians                        shared_media
arp_ignore            mc_forwarding                       src_valid_mark
arp_notify            medium_id                           tag
```

```
bootp_relay           promote_secondaries
disable_policy        proxy_arp
```

Так же, как для блочных устройств (дисков) в Linux, когда они ещё не пригодны для работы пока их не смонтируют, так и сетевые интерфейсы, сами по себе, ещё не пригодны для работы в сети, пока их не подготовят к использованию. Эта подготовка (конфигурирование) сетевых интерфейсов состоит в том, что сетевой интерфейс привязывается к своему индивидуальному IP адресу (одному или нескольким) и к подсети.

Важно: хотя определяем мы сетевые интерфейсы на уровне их имён, **вся** дальнейшая работа из программного кода с сетевым трафиком через интерфейсы происходит исключительно в терминах IP адресов. Корректное конфигурирование сетевых интерфейсов происходит на уровне **команд** системы, а уже дальнейшее их использование из программного кода — на уровне IP адресов.

Самым старым и известным инструментом диагностирования и управления сетевыми интерфейсами является утилита `ifconfig`. Вот как может выглядеть представляемая ею картина одновременно существующих интерфейсов:

```
$ ifconfig
cipsec0   Link encap:Ethernet  HWaddr 00:0B:FC:F8:01:8F
          inet addr:192.168.27.101  Mask:255.255.255.0
          inet6 addr: fe80::20b:fcff:fef8:18f/64 Scope:Link
          UP RUNNING NOARP  MTU:1356  Metric:1
          RX packets:4 errors:0 dropped:3 overruns:0 frame:0
          TX packets:18 errors:0 dropped:5 overruns:0 carrier:0
          collisions:0 txqueuelen:1000
          RX bytes:538 (538.0 b)  TX bytes:1670 (1.6 KiB)

em1: flags=4163<UP,BROADCAST,RUNNING,MULTICAST>  mtu 1500
        inet 192.168.1.20  netmask 255.255.255.0  broadcast 192.168.1.255
        inet6 fe80::a21d:48ff:fef4:935c  prefixlen 64  scopeid 0x20<link>
        ether a0:1d:48:f4:93:5c  txqueuelen 1000  (Ethernet)
        RX packets 1039  bytes 751246 (733.6 KiB)
        RX errors 0  dropped 0  overruns 0  frame 0
        TX packets 932  bytes 128724 (125.7 KiB)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0
        device interrupt 17  memory 0xd4700000-d4720000

lo: flags=73<UP,LOOPBACK,RUNNING>  mtu 65536
        inet 127.0.0.1  netmask 255.0.0.0
        inet6 ::1  prefixlen 128  scopeid 0x10<host>
        loop  txqueuelen 0  (Local Loopback)
        RX packets 13  bytes 1360 (1.3 KiB)
        RX errors 0  dropped 0  overruns 0  frame 0
        TX packets 13  bytes 1360 (1.3 KiB)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0

ppp0: flags=4305<UP,POINTOPOINT,RUNNING,NOARP,MULTICAST>  mtu 1500
        inet 77.52.137.120  netmask 255.255.255.255  destination 80.255.73.34
        ppp  txqueuelen 3  (Point-to-Point Protocol)
        RX packets 57  bytes 3113 (3.0 KiB)
        RX errors 0  dropped 0  overruns 0  frame 0
        TX packets 6  bytes 111 (111.0 B)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0

wlo1: flags=4163<UP,BROADCAST,RUNNING,MULTICAST>  mtu 1500
        inet 192.168.1.200  netmask 255.255.255.0  broadcast 192.168.1.255
        inet6 fe80::3623:87ff:fed6:850d  prefixlen 64  scopeid 0x20<link>
        ether 34:23:87:d6:85:0d  txqueuelen 1000  (Ethernet)
        RX packets 17  bytes 2022 (1.9 KiB)
        RX errors 0  dropped 0  overruns 0  frame 0
        TX packets 61  bytes 7534 (7.3 KiB)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0
```

```
          device interrupt 19
```

Здесь представлены одновременно различные (по природе) сетевые интерфейсы:

- виртуальный интерфейс `cipsec0` (виртуальная частная сеть, VPN) созданный программными средствами (Cisco Systems VPN Client, от Cisco Systems), работающий через один из реальных физических каналов (что подтверждает сказанное выше о возможности нескольких сетевых интерфейсов над одним каналом).

- интерфейс физического проводного Ethernet адаптера `em1`.

- интерфейс физической беспроводной сеть Wi-Fi `wlo1` чипсета Broadcom Corporation BCM43228, и именно это имя `wlo1` определяется использованием проприетарного драйвера от Broadcom.

- интерфейс `ppp0` физического беспроводного 3G CDMA модема на USB шине.

- логический петлевой интерфейс `lo`, создающийся в любой системе, и поддерживающий любой из IP адресов локального диапазона 127.X.X.X:

```
$ ping 127.254.254.254
PING 127.254.254.254 (127.254.254.254) 56(84) bytes of data.
64 bytes from 127.254.254.254: icmp_seq=1 ttl=64 time=0.087 ms
64 bytes from 127.254.254.254: icmp_seq=2 ttl=64 time=0.071 ms
^C
--- 127.254.254.254 ping statistics ---
2 packets transmitted, 2 received, 0% packet loss, time 999ms
rtt min/avg/max/mdev = 0.071/0.079/0.087/0.008 ms
```

Команда `ifconfig` имеет очень развитую функциональность, она позволяет выполнять не только диагностику, но и **управление** интерфейсами: запуск и останов интерфейса (операции `up` и `down`), присвоение IP адреса, маски, создание IP алиасов и многое другое. Для управления создаваемым сетевым интерфейсом (например, операции `up` или `down`), в отличие от диагностики, утилита `ifconfig` потребует прав `root`.

Более современным (более поздним), но и более развитым инструментом, является утилита `ip` (в некоторых дистрибутивах может потребоваться отдельная установка из репозитария пакета, известного под именем `iproute2`), вот результаты выполнения такой команды для несколько другой аппаратной конфигурации:

```
$ ip link
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 16436 qdisc noqueue state UNKNOWN
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
2: eth0: <NO-CARRIER,BROADCAST,MULTICAST,UP> mtu 1500 qdisc mq state DOWN qlen 1000
    link/ether 00:15:60:c4:ee:02 brd ff:ff:ff:ff:ff:ff
3: wlan0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc mq state UP qlen 1000
    link/ether 00:13:02:69:70:9b brd ff:ff:ff:ff:ff:ff
4: vboxnet0: <BROADCAST,MULTICAST> mtu 1500 qdisc noop state DOWN qlen 1000
    link/ether 0a:00:27:00:00:00 brd ff:ff:ff:ff:ff:ff
5: pan0: <BROADCAST,MULTICAST> mtu 1500 qdisc noop state DOWN
    link/ether ae:4c:18:a0:26:1b brd ff:ff:ff:ff:ff:ff
6: cipsec0: <NOARP,UP,LOWER_UP> mtu 1356 qdisc pfifo_fast state UNKNOWN qlen 1000
    link/ether 00:0b:fc:f8:01:8f brd ff:ff:ff:ff:ff:ff

$ ip addr show dev cipsec0
6: cipsec0: <NOARP,UP,LOWER_UP> mtu 1356 qdisc pfifo_fast state UNKNOWN qlen 1000
    link/ether 00:0b:fc:f8:01:8f brd ff:ff:ff:ff:ff:ff
    inet 192.168.27.101/24 brd 192.168.27.255 scope global cipsec0
    inet6 fe80::20b:fcff:fef8:18f/64 scope link
       valid_lft forever preferred_lft forever
```

Утилита `ip` имеет очень разветвлённый синтаксис, но, к счастью, и такую же разветвлённую, древовидную систему подсказок с **детализацией по ключевым словам**:

```
$ ip help
Usage: ip [ OPTIONS ] OBJECT { COMMAND | help }
       ip [ -force ] -batch filename
where  OBJECT := { link | addr | addrlabel | route | rule | neigh | ntable |
```

```
                  tunnel | maddr | mroute | monitor | xfrm }
       OPTIONS := { -V[ersion] | -s[tatistics] | -d[etails] | -r[esolve] |
                    -f[amily] { inet | inet6 | ipx | dnet | link } |
                    -o[neline] | -t[imestamp] | -b[atch] [filename] }
```

```
$ ip addr help
Usage: ip addr {add|change|replace} IFADDR dev STRING [ LIFETIME ]
                                                      [ CONFFLAG-LIST]
       ip addr del IFADDR dev STRING
       ip addr {show|flush} [ dev STRING ] [ scope SCOPE-ID ]
                            [ to PREFIX ] [ FLAG-LIST ] [ label PATTERN ]
...
```

Примечание: Утилита ip допускает в записи команд сокращения ключевых слов до однозначного распознавания контекста, часто это всего одна буква. Вот такие «скороговорки»: `ip a s` — вместо записи `ip address show`, или `ip l` — вместо `ip link`. Это очень экономит время, удобно, и вы неоднократно будете видеть такие сокращения далее по тексту.

Широкое применение беспроводных сетевых технологий (в частности WiFi) породили целый круг новых специфических инструментов для их анализа и настройки их интерфейсов. Некоторые из них:

```
$ which iwconfig
/sbin/iwconfig

$ ls /sbin/iw*
/sbin/iw  /sbin/iwconfig  /sbin/iwevent  /sbin/iwgetid  /sbin/iwlist  /sbin/iwpriv  /sbin/iwspy

$ iwconfig
lo        no wireless extensions.
em1       no wireless extensions.
wlo1      IEEE 802.11abg  ESSID:"ZTE"
          Mode:Managed  Frequency:2.412 GHz  Access Point: C8:64:C7:8A:50:16
          Retry short limit:7   RTS thr:off   Fragment thr:off
          Power Management:off

$ iw wlo1 info
Interface wlo1
        ifindex 3
        wdev 0x1
        addr 34:23:87:d6:85:0d
        ssid ZTE
        type managed
        wiphy 0

$ rfkill list
0: hci0: Bluetooth
        Soft blocked: no
        Hard blocked: no
1: phy0: Wireless LAN
        Soft blocked: no
        Hard blocked: no

$ iw phy0 info
Wiphy phy0
        max # scan SSIDs: 1
        max scan IEs length: 0 bytes
        Coverage class: 0 (up to 0m)
        Supported Ciphers:
                * WEP40 (00-0f-ac:1)
                * WEP104 (00-0f-ac:5)
                * TKIP (00-0f-ac:2)
```

```
                * CCMP (00-0f-ac:4)
                * CMAC (00-0f-ac:6)
        Available Antennas: TX 0 RX 0
        Supported interface modes:
                 * IBSS
                 * managed
        Band 1:
                Bitrates (non-HT):
                         * 1.0 Mbps
                         * 2.0 Mbps (short preamble supported)
                         * 5.5 Mbps (short preamble supported)
                         * 11.0 Mbps (short preamble supported)
                         * 6.0 Mbps
                         * 9.0 Mbps
                         * 12.0 Mbps
                         * 18.0 Mbps
                         * 24.0 Mbps
                         * 36.0 Mbps
                         * 48.0 Mbps
                         * 54.0 Mbps
                Frequencies:
                         * 2412 MHz [1] (20.0 dBm)
                         * 2417 MHz [2] (20.0 dBm)
...
                         * 2467 MHz [12] (20.0 dBm)
                         * 2472 MHz [13] (20.0 dBm)
                         * 2484 MHz [14] (disabled)
        Band 2:
                Bitrates (non-HT):
                         * 6.0 Mbps
                         * 9.0 Mbps
                         * 12.0 Mbps
                         * 18.0 Mbps
                         * 24.0 Mbps
                         * 36.0 Mbps
                         * 48.0 Mbps
                         * 54.0 Mbps
                Frequencies:
                         * 5160 MHz [32] (20.0 dBm)
                         * 5170 MHz [34] (20.0 dBm)
                         * 5180 MHz [36] (20.0 dBm)
...
                         * 5480 MHz [96] (disabled)
                         * 5490 MHz [98] (disabled)
                         * 5500 MHz [100] (20.0 dBm) (radar detection)
                           DFS state: usable (for 5694 sec)
                         * 5510 MHz [102] (20.0 dBm) (radar detection)
                           DFS state: usable (for 5694 sec)
...
                         * 6130 MHz [226] (disabled)
                         * 6140 MHz [228] (disabled)
        Supported commands:
                 * set_interface
                 * new_key
                 * join_ibss
                 * set_pmksa
                 * del_pmksa
                 * flush_pmksa
                 * connect
                 * disconnect
        software interface modes (can always be added):
```

```
        interface combinations are not supported
        Device supports scan flush.
```

Их использование специфично, но может быть в достаточной мере изучено и понято, используя возможности справочной системы (`man` и `—help`).

За последние годы, практически в любой графический (GUI) менеджер рабочего стола (DE — Desktop Environment) включен такой апплет управления окружения, как `NetworkManager` (NM):

```
$ ls /sbin/N*
/sbin/NetworkManager
```

Такой инструмент присутствует в любом графическом менеджере (GNOME, KDE, Xfce, LXDE, Mate, ...), хотя конкретные его реализации под разные DE могут в деталях отличаться. Этого инструмента, зачастую, вполне достаточно для создания, конфигурирования и настройки параметров как реальных, так и виртуальных (OpenVPN) сетевых интерфейсов:

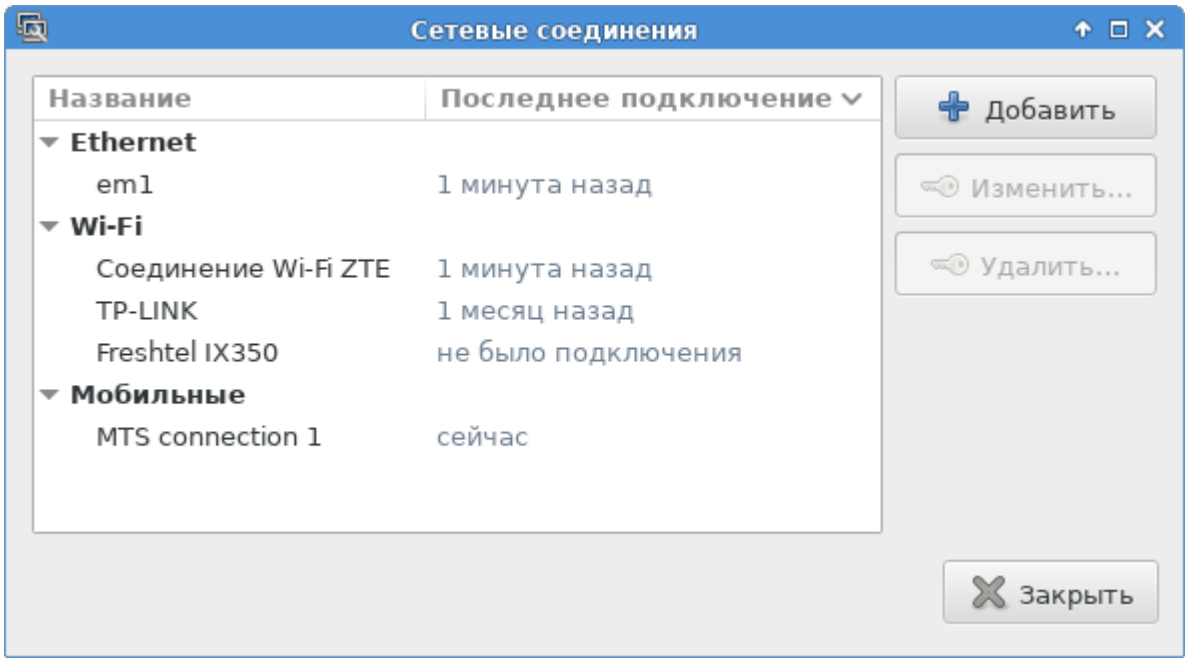

Кроме графического (GUI) интерфейса NetworkManager имеет ещё и развитый консольный (CLI) интерфейс `nmcli` (command-line tool for controlling NetworkManager):

```
$ nmcli --help
Использование: nmcli [ПАРАМЕТРЫ] ОБЪЕКТ { КОМАНДА | help }

ПАРАМЕТРЫ
  -a, --ask                                запрос отсутствующих параметров
  -c, --colors auto|yes|no                 использовать ли цветной вывод
  -e, --escape yes|no                      опускать разделители столбцов в значениях
  -f, --fields <field,...>|all|common      указать выводимые поля
  -g, --get-values <field,...>|all|common  краткая форма для -m tabular -t -f
  -h, --help                               показать данную справку
  -m, --mode tabular|multiline             режим вывода
  -o, --overview                           режим обзора
  -p, --pretty                             красивый вывод
  -s, --show-secrets                       разрешить показ паролей
  -t, --terse                              краткий вывод
  -v, --version                            показать версию программы
  -w, --wait <seconds>                     настроить таймаут завершения операций

ОБЪЕКТ
  g[eneral]       общий статус и операции NetworkManager
  n[etworking]    общее управление сетями
```

```
r[adio]         переключатели NetworkManager
c[onnection]    подключения NetworkManager
d[evice]        устройства, которыми управляет NetworkManager
a[gent]         агент секретов или агент polkit для NetworkManager
m[onitor]       отслеживание изменений в NetworkManager
```

Командный интерфейс NetworkManager очень обширный, желающие его использовать должны изучить его возможности по:

```
$ man 1 nmcli
...
```

NetworkManager — это целая огромная подсистема управления сетевыми интерфейсами, прирастающая год от года возможностями для конфигурирования новых сетевых служб. Это альтернативный (или дополняющий) сетевым утилитам способ **быстрого** управления сетевой подсистемой Linux. Эту дополнительную возможность нужно «держать в уме» (особенно для краткосрочных изменений). Но мы, в дальнейшем изложении, для большей наглядности не будем его использовать, а станем оперировать исключительно утилитами.

Таблица маршрутизации

Настолько же важной информацией как параметры интерфейсов (IP адреса, маски и др.) является таблица маршрутизации (ядра операционной системы). При нарушенной структуре таблицаы маршрутизации работоспособность сетевого хоста невозможна (что часто упускают из виду), и нужно только корректно восстановить записи (строки) этой таблицы.

Если все рассматриваемые ранее параметры: IP, маска, префикс… — это атрибуты сетевого интерфейса, то таблица роутинга — это отрибут сетевого хоста в целом, это таблица ядра операционной системы.

Таблица маршрутизации хоста может быть диагностирована, например в таком виде:

```
$ route -n
Kernel IP routing table
Destination     Gateway         Genmask         Flags Metric Ref    Use Iface
0.0.0.0         192.168.1.1     0.0.0.0         UG    1024   0        0 em1
80.255.73.34    0.0.0.0         255.255.255.255 UH    0      0        0 ppp0
192.168.1.0     0.0.0.0         255.255.255.0   U     0      0        0 em1
192.168.1.0     0.0.0.0         255.255.255.0   U     0      0        0 wlo1
```

Этой же командой (`route`), с соответствующими параметрами, производится редактирование таблицы (добавление, удаление строк).

Один из сетевых интерфейсов всегда отмечается в таблице маршрутизации как шлюз по умолчанию. Все пакеты в сетевом стеке (порождённые приложениями этого хоста, или пришедшие извне по другим внешним интерфейсам), чей адрес получателя не относится ни к одной строке таблицы маршрутизации — отправляется в **шлюз по умолчанию**. Маршрут по умолчанию обозначается записью 0.0.0.0 в численном изображении (опция `-n`), или записью default в символьном изображении таблицы.

Обычно, при управлении сетевыми интерфейсами (командами `ifconfig`, `ip`, или GUI апплетом `NetworkManager`) в таблице маршрутизации корректно добавляются или удаляются соответствующие строки. Однако иногда это соответствие разрушается, что полностью нарушает работу сети. Тогда возникает необходимость редактировать таблицу вручную (добавлять или удалять строки). Делается это той же командой `route` с разнообразным набором опций и параметров. Простейший пример использования утилиты `route` для изменений в таблице роутинга будет показан ниже, в примере переименований сетевого интерфейса.

Для адресов IPv6 и IPv6 в ядре сохраняются 2 разных таблицы роутинга одновременно (показано для сравнения с одного и того же хоста):

```
$ route -n
Таблица маршутизации ядра протокола IP
Destination Gateway Genmask Flags Metric Ref Use Iface
0.0.0.0         192.168.1.3     0.0.0.0         UG    100    0        0 eno1
0.0.0.0         192.168.1.3     0.0.0.0         UG    600    0        0 wlx008736005357
```

```
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 eno1
192.168.1.0     0.0.0.0         255.255.255.0   U     100    0        0 eno1
192.168.1.0     0.0.0.0         255.255.255.0   U     600    0        0 wlx008736005357
```

```
$ route -n -6
Таблица маршрутизация ядра IPv6
Destination                    Next Hop                   Flag Met Ref Use If
::1/128                        ::                         U    256 1     0 lo
fe80::/64                      ::                         U    1024 3     0 eno1
fe80::/64                      ::                         U    1024 1     0 wlx008736005357
::/0                           ::                         !n   -1  1     0 lo
::1/128                        ::                         Un   0   6     0 lo
fe80::762:c6bf:9eaa:93a9/128   ::                         Un   0   5     0 eno1
fe80::46a4:9424:cb31:2bd6/128  ::                         Un   0   2     0 wlx008736005357
ff00::/8                       ::                         U    256 5     0 eno1
ff00::/8                       ::                         U    256 5     0 wlx008736005357
::/0                           ::                         !n   -1  1     0 lo
```

Если вы как-то изменяете правила роутинга для интерфейса в IPv6, то они никак не изменяют и не отображаются в роутинге для IPv6.

Ещё больше глубину и гибкость управления роутингом предоставляет уже упоминавшаяся команда ip, в новой нотации это выглядит так:

```
$ ip --help route
Usage: ip [ OPTIONS ] OBJECT { COMMAND | help }
       ip [ -force ] -batch filename
where  OBJECT := { address | addrlabel | fou | help | ila | ioam | l2tp | link |
                   macsec | maddress | monitor | mptcp | mroute | mrule |
                   neighbor | neighbour | netconf | netns | nexthop | ntable |
                   ntbl | route | rule | sr | tap | tcpmetrics |
                   token | tunnel | tuntap | vrf | xfrm }
       OPTIONS := { -V[ersion] | -s[tatistics] | -d[etails] | -r[esolve] |
                    -h[uman-readable] | -iec | -j[son] | -p[retty] |
                    -f[amily] { inet | inet6 | mpls | bridge | link } |
                    -4 | -6 | -M | -B | -0 |
                    -l[oops] { maximum-addr-flush-attempts } | -br[ief] |
                    -o[neline] | -t[imestamp] | -ts[hort] | -b[atch] [filename] |
                    -rc[vbuf] [size] | -n[etns] name | -N[umeric] | -a[ll] |
                    -c[olor]}
```

Диагностика для того же хоста что показан выше:

```
$ ip route show
default via 192.168.1.3 dev eno1 proto static metric 100
default via 192.168.1.3 dev wlx008736005357 proto dhcp metric 600
169.254.0.0/16 dev eno1 scope link metric 1000
192.168.1.0/24 dev eno1 proto kernel scope link src 192.168.1.11 metric 100
192.168.1.0/24 dev wlx008736005357 proto kernel scope link src 192.168.1.235 metric 600
```

```
$ ip -6 route show
::1 dev lo proto kernel metric 256 pref medium
fe80::/64 dev eno1 proto kernel metric 1024 pref medium
fe80::/64 dev wlx008736005357 proto kernel metric 1024 pref medium
```

Управление роутингом

Пример управление роутинга IPv6 с помощью утилиты ip (всё тот же хост) …

```
$ ip a s dev eno1
2: eno1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
    link/ether 70:71:bc:a3:c5:c0 brd ff:ff:ff:ff:ff:ff
    altname enp0s25
```

```
    inet 192.168.1.11/24 brd 192.168.1.255 scope global noprefixroute eno1
       valid_lft forever preferred_lft forever
    inet6 fe80::762:c6bf:9eaa:93a9/64 scope link noprefixroute
       valid_lft forever preferred_lft forever
```

Добавляю (физическому Ethernet) интерфейсу eno1, который не имеет никакого IPv6 адреса кроме локального (fe80::762:c6bf:9eaa:93a9), новый глобальный IPv6:

```
$ sudo ip address add 31e:af75:7a27:75::5/64 dev eno1
$ ip a s dev eno1
2: eno1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
    link/ether 70:71:bc:a3:c5:c0 brd ff:ff:ff:ff:ff:ff
    altname enp0s25
    inet 192.168.1.11/24 brd 192.168.1.255 scope global noprefixroute eno1
       valid_lft forever preferred_lft forever
    inet6 31e:af75:7a27:75::5/64 scope global
       valid_lft forever preferred_lft forever
    inet6 fe80::762:c6bf:9eaa:93a9/64 scope link noprefixroute
       valid_lft forever preferred_lft forever
```

В таблице роутинга IPv6 **автоматически** добавилась одна новая строка:

```
$ ip -6 route show
::1 dev lo proto kernel metric 256 pref medium
31e:af75:7a27:75::/64 dev eno1 proto kernel metric 256 pref medium
fe80::/64 dev eno1 proto kernel metric 1024 pref medium
fe80::/64 dev wlx008736005357 proto kernel metric 1024 pref medium
```

Но это ещё не всё что хотелось бы получить. Добавлю вручную через этот интерфейс/адрес ещё одну строку роутинга в реальную удалённую сеть 0200::/7 (это mesh-сеть Yggdrasil, но это пока не важно — об этом подробно будет позже):

```
$ sudo ip -6 route add 0200::/7 via 31e:af75:7a27:75::1
$ ip -6 route show
::1 dev lo proto kernel metric 256 pref medium
31e:af75:7a27:75::/64 dev eno1 proto kernel metric 256 pref medium
200::/7 via 31e:af75:7a27:75::1 dev eno1 metric 1024 pref medium
fe80::/64 dev eno1 proto kernel metric 1024 pref medium
fe80::/64 dev wlx008736005357 proto kernel metric 1024 pref medium
```

Всё! Теперь этот локальный хост LAN легко ping-ится по IPv6 к реальному удалённому хосту, находящемуся за тысячи километров в Казахстане:

```
$ ping -c3 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
PING 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771(221:58c9:9a6:99be:f3d:c1ac:2b5b:9771) 56 data bytes
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=1 ttl=63 time=862 ms
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=2 ttl=63 time=118 ms
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=3 ttl=63 time=118 ms

--- 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2001ms
rtt min/avg/max/mdev = 118.003/365.914/861.613/350.512 ms
```

Аналогичное управление роутингом хоста можно производить (add, del, ...) с равным успехом и утилитой «старого стиля» `route`:

```
$ route --help
Использование: route [-nNvee] [-FC] [<AF>] Отобразить таблицу маршрутизации ядра
       route [-v] [-FC] {add|del|flush} ... Изменить таблицу маршрутизации для AF.

       route {-h|--help} [<AF>] Детальное описание использование указанной AF.
       route {-V|--version} Отобразить версию/автора и выйти.
```

```
          -v, --verbose более детальный вывод
          -n, --numeric не преобразовывать адреса в имена
          -e, --extend отображать другую/больше информации
          -F, -fib отобразить информацию форвардинга базы (по умолчанию)
          -C, --cache отобразить кэш маршрутизации вместо FIB

    <AF>=Use -4, -6, '-A <af>' or '--<af>'; default: inet
    Список возможный адресных семейств (которые поддерживают маршрутизацию):
      inet (DARPA Internet) inet6 (IPv6) ax25 (AMPR AX.25)
      netrom (AMPR NET/ROM) ipx (Novell IPX) ddp (Appletalk DDP)
      x25 (CCITT X.25)
```

Вот как выглядит «в старой нотации» таблица роутинга IPv6 после только-что проделанных мной манипуляций:

```
$ route -6
Таблица маршрутизация ядра IPv6
Destination                    Next Hop                   Flag Met Ref Use If
ip6-localhost/128              [::]                       U    256 2     0 lo
31e:af75:7a27:75::/64          [::]                       U    256 2     0 eno1
200::/7                        raspberrypi                UG   1024 2     0 eno1
fe80::/64                      [::]                       U    1024 3     0 eno1
fe80::/64                      [::]                       U    1024 1     0 wlx008736005357
[::]/0                         [::]                       !n   -1  1     0 lo
ip6-localhost/128              [::]                       Un   0   7     0 lo
nvidia/128                     [::]                       Un   0   3     0 eno1
nvidia/128                     [::]                       Un   0   5     0 eno1
nvidia/128                     [::]                       Un   0   3     0 wlx008736005357
ip6-mcastprefix/8              [::]                       U    256 5     0 eno1
ip6-mcastprefix/8              [::]                       U    256 5     0 wlx008736005357
[::]/0                         [::]                       !n   -1  1     0 lo
```

Попутно тут же убеждаемся, что никакие манипуляции (достаточно сложные выше проведенные) с таблицей роутинга для IPv6 **никак** не затрагивают таблицу роутинга для IPv4 для тех же сетевых интерфейсов:

```
$ route
Таблица маршутизации ядра протокола IP
Destination Gateway Genmask Flags Metric Ref Use Iface
default         GPON            0.0.0.0         UG    100    0        0 eno1
default         GPON            0.0.0.0         UG    600    0        0 wlx008736005357
link-local      0.0.0.0         255.255.0.0     U     1000   0        0 eno1
192.168.1.0     0.0.0.0         255.255.255.0   U     100    0        0 eno1
192.168.1.0     0.0.0.0         255.255.255.0   U     600    0        0 wlx008736005357
```

Алиасные IP адреса

Простейшим примером множественности **логических** сетевых интерфейсов, разделяющих общий **физический** адаптер, могут служить **сетевые алиасы**, когда существующему интерфейсу дополнительно присваиваются адрес и маска, делающие его представленным ещё в другой подсети.

Рассмотрим пример … положим, в LAN подсеть 192.168.1.0/24, хост с локальным именем:

```
$ hostname
nvidia
$ ip -4 a s dev eno1
2: eno1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
     altname enp0s25
     inet 192.168.1.11/24 brd 192.168.1.255 scope global noprefixroute eno1
        valid_lft forever preferred_lft forever

$ route -n
Таблица маршутизации ядра протокола IP
```

```
Destination Gateway Genmask Flags Metric Ref Use Iface
0.0.0.0         192.168.1.3     0.0.0.0         UG    100    0        0 eno1
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 eno1
192.168.1.0     0.0.0.0         255.255.255.0   U     100    0        0 eno1
```

Тривиальный случай… Добавим этому физическому (проводному Ethernet) интерфейсу eno1 ещё один алиасный адрес IPv4 из совершенно другой подсети 10.0.0.2/24 :

```
$ sudo ifconfig eno1:1 10.0.0.2 up
$ ifconfig
eno1: flags=4163<UP,BROADCAST,RUNNING,MULTICAST>  mtu 1500
        inet 192.168.1.11  netmask 255.255.255.0  broadcast 192.168.1.255
        inet6 fe80::762:c6bf:9eaa:93a9  prefixlen 64  scopeid 0x20<link>
        ether 70:71:bc:a3:c5:c0  txqueuelen 1000  (Ethernet)
        RX packets 4890  bytes 496512 (496.5 KB)
        RX errors 0  dropped 1  overruns 0  frame 0
        TX packets 2637  bytes 261068 (261.0 KB)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0
        device interrupt 20  memory 0xfe400000-fe420000

eno1:1: flags=4163<UP,BROADCAST,RUNNING,MULTICAST>  mtu 1500
        inet 10.0.0.2  netmask 255.0.0.0  broadcast 10.255.255.255
        ether 70:71:bc:a3:c5:c0  txqueuelen 1000  (Ethernet)
        device interrupt 20  memory 0xfe400000-fe420000

lo: flags=73<UP,LOOPBACK,RUNNING>  mtu 65536
        inet 127.0.0.1  netmask 255.0.0.0
        inet6 ::1  prefixlen 128  scopeid 0x10<host>
        loop  txqueuelen 1000  (Локальная петля (Loopback))
        RX packets 772  bytes 68251 (68.2 KB)
        RX errors 0  dropped 0  overruns 0  frame 0
        TX packets 772  bytes 68251 (68.2 KB)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0
```

Таблица маршрутизации этого хоста автоматически (не требует нашего участия) поменяется — в ней добавилась строка (маршрут) для новой подсети:

```
$ route -n
Таблица маршутизации ядра протокола IP
Destination Gateway Genmask Flags Metric Ref Use Iface
0.0.0.0         192.168.1.3     0.0.0.0         UG    100    0        0 eno1
10.0.0.0        0.0.0.0         255.0.0.0       U     0      0        0 eno1
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 eno1
192.168.1.0     0.0.0.0         255.255.255.0   U     100    0        0 eno1
```

На хосте у нас появился новый, фиктивный интерфейс eno1:1 с алиасным IPv4, который (адрес), естественно, не видится в исходной LAN, у него по маске другая подсеть. С любого хоста LAN он недоступен:

```
$ ping -c3 10.0.0.2
PING 10.0.0.2 (10.0.0.2) 56(84) bytes of data.

--- 10.0.0.2 ping statistics ---
3 packets transmitted, 0 received, 100% packet loss, time 2025ms
```

Теперь выберем другой, произвольно взятый, хост этой LAN:

```
$ hostname
nvme

$ ip -4 a s dev enp3s0
2: enp3s0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP group default qlen
1000
```

```
    inet 192.168.1.138/24 brd 192.168.1.255 scope global dynamic noprefixroute enp3s0
       valid_lft 165109sec preferred_lft 165109sec
```

```
$ /sbin/route -n
Kernel IP routing table
Destination     Gateway         Genmask         Flags Metric Ref    Use Iface
0.0.0.0         192.168.1.3     0.0.0.0         UG    100    0        0 enp3s0
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 enp3s0
192.168.1.0     0.0.0.0         255.255.255.0   U     100    0        0 enp3s0
```

(Здесь у меня работает другой дистрибутив Linux, у которого каталог `/sbin` не прописан в переменную окружения $PATH, что потребует указывать полный путь при вызове некоторых сетевых команд. Такая возможность довольно частая, и не должна вводить вас в недоумение.)

Проделаю с этим хостом примерно то же самое, что и с предыдущим:

```
$ sudo ifconfig enp3s0:1 10.0.0.5 up
$ echo $?
0
```

(Иногда целесообразно сразу же проверить код успешности завершения только-что выполненной команды.)

Интерфейс поменял вид:

```
$ /sbin/ifconfig enp3s0
enp3s0: flags=4163<UP,BROADCAST,RUNNING,MULTICAST>  mtu 1500
        inet 192.168.1.138  netmask 255.255.255.0  broadcast 192.168.1.255
        inet6 fe80::921b:eff:fe2b:fe3a  prefixlen 64  scopeid 0x20<link>
        ether 90:1b:0e:2b:fe:3a  txqueuelen 1000  (Ethernet)
        RX packets 442744  bytes 152787250 (145.7 MiB)
        RX errors 0  dropped 51  overruns 0  frame 0
        TX packets 133419  bytes 13095746 (12.4 MiB)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0
```

```
$ /sbin/ifconfig enp3s0:1
enp3s0:1: flags=4163<UP,BROADCAST,RUNNING,MULTICAST>  mtu 1500
        inet 10.0.0.5  netmask 255.0.0.0  broadcast 10.255.255.255
        ether 90:1b:0e:2b:fe:3a  txqueuelen 1000  (Ethernet)
```

Примечание: Характерно, что как в этом, так и в предыдущем случае (там я не стал акцентироваться на этом для экономии места) команда `ip` (в отличие от `ifconfig`) не знает о новом (фиктивном, расщеплённом) интерфейсе `enp3s0:1`, но видит новый алиасный IPv4 для интерфейса, как в его «новом», так и «старом» именовании:

```
$ ip -4 a s dev enp3s0
2: enp3s0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP group default qlen
1000
    inet 192.168.1.138/24 brd 192.168.1.255 scope global dynamic noprefixroute enp3s0
       valid_lft 161823sec preferred_lft 161823sec
    inet 10.0.0.5/8 brd 10.255.255.255 scope global enp3s0:1
       valid_lft forever preferred_lft forever
$ ip -4 a s dev enp3s0:1
2: enp3s0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP group default qlen
1000
    inet 192.168.1.138/24 brd 192.168.1.255 scope global dynamic noprefixroute enp3s0
       valid_lft 161816sec preferred_lft 161816sec
    inet 10.0.0.5/8 brd 10.255.255.255 scope global enp3s0:1
       valid_lft forever preferred_lft forever
```

Таблица роутинга, как и для предыдущего хоста, поменялась:

```
$ /sbin/route -n
Kernel IP routing table
Destination     Gateway         Genmask         Flags Metric Ref    Use Iface
```

```
0.0.0.0         192.168.1.3     0.0.0.0         UG    100    0        0 enp3s0
10.0.0.0        0.0.0.0         255.0.0.0       U     0      0        0 enp3s0
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 enp3s0
192.168.1.0     0.0.0.0         255.255.255.0   U     100    0        0 enp3s0
```

Маршруты к двум разным подсетям (192.168.1.0/24 и 10.0.0.0/8) представлены в таблице маршрутизации разными записями (строками). И теперь мы имеем прозрачность трафика в новой подсети 10.0.0.0/8 (то, собственно, для чего всё и делалось):

```
$ ping -c3 10.0.0.2
PING 10.0.0.2 (10.0.0.2) 56(84) bytes of data.
64 bytes from 10.0.0.2: icmp_seq=1 ttl=64 time=0.554 ms
64 bytes from 10.0.0.2: icmp_seq=2 ttl=64 time=0.250 ms
64 bytes from 10.0.0.2: icmp_seq=3 ttl=64 time=0.368 ms

--- 10.0.0.2 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2032ms
rtt min/avg/max/mdev = 0.250/0.390/0.554/0.125 ms
```

Естественно, ping (прозрачность) тех же «препарированных» хостов в исходной подсети 192.168.1.0/24 прекрасно сохранился!

Но ещё интереснее эксперимент со сканированием хостов подсети (я его показываю с первого из рассмотренных хостов, поскольку у меня только там есть установленная утилита `nmap`):

```
$ ping -c3 10.0.0.5
PING 10.0.0.5 (10.0.0.5) 56(84) bytes of data.
64 bytes from 10.0.0.5: icmp_seq=1 ttl=64 time=0.328 ms
64 bytes from 10.0.0.5: icmp_seq=2 ttl=64 time=0.205 ms
64 bytes from 10.0.0.5: icmp_seq=3 ttl=64 time=0.259 ms

--- 10.0.0.5 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2045ms
rtt min/avg/max/mdev = 0.205/0.264/0.328/0.050 ms

$ nmap -sP 10.0.0.0/24
Starting Nmap 7.80 ( https://nmap.org ) at 2023-04-22 05:18 EEST
Nmap scan report for nvidia (10.0.0.2)
Host is up (0.00019s latency).
Nmap scan report for 10.0.0.5
Host is up (0.00027s latency).
Nmap done: 256 IP addresses (2 hosts up) scanned in 3.00 seconds
```

Сканер подсети 10.0.0.0, работающей **над** физической LAN с добрым десятком хостов подсети 192.168.1.0, видит только 2 хоста (10.0.0.2 и 10.0.0.5). Фактически, мы создали виртуальную сеть над реальной физической.

Техника создания и работы с сетевыми алиасами является в высшей степени полезной при отработке сетевых проектов и написании модулей ядра, обсуждаемых далее.

Примечание: Я показал работу с алиасными адресами пользуясь утилитами «старого стиля» (`ifconfig` и `route` из Linux пакета `net-tools`). То же самое можно наверняка проделывать и с утилитой «нового стиля» (`ip` из Linux пакета `iproute2`). Я этого не делал и не проверял … и оставляю это в качестве задания для самостоятельной проработки читателям.

Петлевой интерфейс

На любом компьютерном хосте (даже если он вообще не использует сеть, или даже просто никак не подключен к сети) присутствует петлевой интерфейс (loopback, интерфейс `lo`)

Группа адресов 127/8 выделены под петлевой интерфейс:

```
$ ifconfig lo | head -n2
lo: flags=73<UP,LOOPBACK,RUNNING>  mtu 65536
        inet 127.0.0.1  netmask 255.0.0.0
```

Иногда указывается (в публикациях), что адресом петлевого интерфейса является 127.0.0.1 — это заблуждение: адресами петлевого интерфейса являются **все** IP адреса подсети 127.0.0.0:255.0.0.0 класса A:

```
$ ping 127.255.255.254
PING 127.255.255.254 (127.255.255.254) 56(84) bytes of data.
64 bytes from 127.255.255.254: icmp_seq=1 ttl=64 time=0.061 ms
64 bytes from 127.255.255.254: icmp_seq=2 ttl=64 time=0.065 ms
^C
--- 127.255.255.254 ping statistics ---
2 packets transmitted, 2 received, 0% packet loss, time 999ms
rtt min/avg/max/mdev = 0.061/0.063/0.065/0.002 ms
```

Для семейства IPv6 адрес петлевого интерфейса (loopback) выглядит в сокращённой записи особенно элегантно ::1. Даже если вы не пользуетесь IPv6, но работаете на одной из современных операционных, систем, у вас наверняка установлен этот протокол. Это легко проверить, пропинговав loopback.

```
$ ping -c3 ::1
PING ::1(::1) 56 data bytes
64 bytes from ::1: icmp_seq=1 ttl=64 time=0.025 ms
64 bytes from ::1: icmp_seq=2 ttl=64 time=0.036 ms
64 bytes from ::1: icmp_seq=3 ttl=64 time=0.036 ms

--- ::1 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2024ms
rtt min/avg/max/mdev = 0.025/0.032/0.036/0.005 ms
```

Этот интерфейс позволяет клиенту и серверу на одном и том же компьютере общаться друг с другом используя стек TCP/IP. Можно предположить, что транспортный уровень распознает, что указанный ему удаленный адрес — это петлевой адрес и каким-либо образом сокращает процесс обработки датаграмм. Однако это не так. Осуществляется **полная** обработка данных на транспортном и сетевом уровнях, после чего IP датаграмма направляется по петле назад, двигаясь вверх достигает пользовательского приложения, ожидающего приёма с этого интерфейса. Но IP датаграмма, посылаемая в петлевой интерфейс, никогда не попадает в физическую среду передачи (кабель). Может показаться неэффективным то что транспортный и сетевой уровни обрабатывают данные, которые посылаются по петле. Но на такую реализацию есть два основания:

- проще реализовать обработку единообразно, когда петлевой интерфейс для сетевого уровня выглядит просто как еще один интерфейс канального уровня (мы будем реализовывать такие интерфейсы при рассмотрении сетеввых драйверов далее);

- полновесная и единообразная обработка трафика по петлевому интерфейсу делает его незаменимым инструментом отладки, тестирования и диагностики для сетевых инструментов и проектов в локальном окружении.

Петлевой интерфейс активно используют различные подсистемы Linux и установленных сторонних программ. Неаккуратное использование и разрушение петлевого интерфейса может поэтому привести к дефектам работы в самых неожиданных местах. Никогда не удаляйте петлевой интерфейс, даже если он кажется вам совершенно лишним: этим вы полностью разрушите операционную систему Linux, и добьётесь только её новой полной инсталляции!

Переименование сетевого интерфейса

Имя сетевого интерфейса, как было уже сказано, задаётся модулем, создающим этот интерфейс (мы увидим это на примерах написания модулей позже). Но имя сетевого интерфейса (созданного модулем, или присутствующего ранее в системе) не есть совершенно константное значение, которое должно оставаться неизменным во всё время работы интерфейса в системе. Мы можем интерфейс динамически переименовать (в произвольное имя)! И начнём мы это делать с традиционного Ethernet проводного интерфейса:

```
$ ip -4 a s dev eno1
2: eno1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
```

```
    altname enp0s25
    inet 192.168.1.11/24 brd 192.168.1.255 scope global noprefixroute eno1
       valid_lft forever preferred_lft forever
```

И зафиксируем нормальное состояние в котором находится таблица маршрутизации (IPv4 в данном случае):

```
$ route -n
Таблица маршутизации ядра протокола IP
Destination Gateway Genmask Flags Metric Ref Use Iface
0.0.0.0         192.168.1.3     0.0.0.0         UG    100    0        0 eno1
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 eno1
192.168.1.0     0.0.0.0         255.255.255.0   U     100    0        0 eno1
```

Переименовываем интерфейс командой:

```
$ sudo ip link set dev eno1 name eth0
RTNETLINK answers: Device or resource busy
```

Закономерный итог: нельзя манипулировать интерфейсом который активен (поднят) ! Поэтому правильный путь будет несколько сложнее:

```
$ sudo ifconfig eno1 down
$ sudo ip link set dev eno1 name eth0
$ ip l
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue state UNKNOWN mode DEFAULT group default
qlen 1000
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
2: eth0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP mode DEFAULT group
default qlen 1000
    link/ether 70:71:bc:a3:c5:c0 brd ff:ff:ff:ff:ff:ff
    altname enp0s25
    altname eno1
3: wlx008736005357: <BROADCAST,MULTICAST> mtu 1500 qdisc mq state DOWN mode DEFAULT group default
qlen 1000
    link/ether 00:87:36:00:53:57 brd ff:ff:ff:ff:ff:ff
```

Подымаем интерфейс и восстанавливаем его IP (я экспериментировал с интерфейсом со статически присвоенным IP, при DHCP, возможно, адрес можно не указывать и всё будет проще):

```
$ sudo ifconfig eth0 192.168.1.11 up
$ ip -4 a s dev eth0
2: eth0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
    altname enp0s25
    altname eno1
    inet 192.168.1.11/24 brd 192.168.1.255 scope global eth0
       valid_lft forever preferred_lft forever
```

Адрес восстановлен, но этого мало: команда `ip`, манипулируя с интерфейсом, зачастую портит таблицу маршрутизации:

```
$ route -n
Таблица маршутизации ядра протокола IP
Destination Gateway Genmask Flags Metric Ref Use Iface
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 eth0
192.168.1.0     0.0.0.0         255.255.255.0   U     0      0        0 eth0
```

Восстанавливаем маршрут по умолчанию на роутер из LAN во внешнюю WAN:

```
$ sudo ip route add default via 192.168.1.3
$ route -n
Таблица маршутизации ядра протокола IP
Destination Gateway Genmask Flags Metric Ref Use Iface
0.0.0.0         192.168.1.3     0.0.0.0         UG    0      0        0 eth0
```

```
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 eth0
192.168.1.0     0.0.0.0         255.255.255.0   U     0      0        0 eth0
```

Вот теперь можно проверять прозрачность трафика для нового интерфейса (указывается явно в команде) и для локальной сети, и для Интернет:

```
$ ping 192.168.1.3 -c3 -Ieth0
PING 192.168.1.3 (192.168.1.3) from 192.168.1.11 eth0: 56(84) bytes of data.
64 bytes from 192.168.1.3: icmp_seq=1 ttl=64 time=0.679 ms
64 bytes from 192.168.1.3: icmp_seq=2 ttl=64 time=0.670 ms
64 bytes from 192.168.1.3: icmp_seq=3 ttl=64 time=0.606 ms

--- 192.168.1.3 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2032ms
rtt min/avg/max/mdev = 0.606/0.651/0.679/0.032 ms

$ ping 1.1.1.1 -c3 -Ieth0
PING 1.1.1.1 (1.1.1.1) from 192.168.1.11 eth0: 56(84) bytes of data.
64 bytes from 1.1.1.1: icmp_seq=1 ttl=57 time=9.50 ms
64 bytes from 1.1.1.1: icmp_seq=2 ttl=57 time=8.79 ms
64 bytes from 1.1.1.1: icmp_seq=3 ttl=57 time=9.07 ms

--- 1.1.1.1 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2004ms
rtt min/avg/max/mdev = 8.785/9.116/9.499/0.293 ms
```

Далее с этим новым именем интерфейса (eth0) работают все сетевые утилиты и протоколы.

Эта возможность оказывается чрезвычайно **мощным** инструментом при тестировании, при экспериментах, или при конфигурировании программных пакетов, включающих модули ядра сетевых устройств, которые создают свои новые сетевые интерфейсы.

Примечание: Существует и описан в публикациях (и не один) способ (ищите) изменить имя интерфейса перманентно (постоянно от загрузки) конфигурационными параметрами операционной системы. Но меня не интересует такой способ, а интересует возможность изменять имена динамически, многократно (при необходимости) и без перезагрузки.

В порядке итога сформулируем те правила, которые нужно соблюсти при **динамическом** переименовании сетевого интерфейса:

- Изменить имя можно только для остановленного (down) интерфейса, в противном случае интерфейс будет «занят» для операции;
- После переименования интерфейс нужно сделать активным (up) с присвоением (восстановление) ему IP адреса;
- Последним действием нужно в таблице роутинга восстановить маршрут по умолчанию на шлюз во внешнюю сеть, Интернет (если у вас интерфейс ходил вовне, что зачастую так и бывает);
- для восстановления маршрута используем команду, как это было показано выше, вида:

```
# ip route add default via 192.168.1.3
```

Или, в «старой нотации» (`net-tools`), для тех же значений (сравните):

```
# route add default gw 192.168.1.3 eth0
```

В обязательном порядке проверяйте реальную прозрачность трафика (команды `ping`, `traceroute`, … с явным указанием имени интерфейса в команде) по завершению переименований.

Альтернативные имена

Есть ещё одна возможность из подобной области, появившаяся в пакете iproute2 относительно недавно, утверждается что с версии v5.4.0 (это примерно год 2019) — это альтернативные имена интерфейсов:

```
$ ip -V
```

```
ip utility, iproute2-5.15.0, libbpf 0.5.0

$ sudo ip link property add dev eth0 altname eno2

$ ip l show dev eth0
2: eth0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP mode DEFAULT group
default qlen 1000
    link/ether 70:71:bc:a3:c5:c0 brd ff:ff:ff:ff:ff:ff
    altname enp0s25
    altname eno1
    altname eno2

$ ip -4 a s dev eth0
2: eth0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
    altname enp0s25
    altname eno1
    altname eno2
    inet 192.168.1.11/24 brd 192.168.1.255 scope global eth0
       valid_lft forever preferred_lft forever
```

Обратите внимание: я добавляю новое альтернативное имя интерфейсу (а позже удалю другой имя) не останавливая (down) его, делается «на ходу»! При этом, естественно, что изменения в альтернативных именах никак не влияет на таблицу роутинга, а поэтому и не нарушает работу интерфейса.

Симметрично, альтернативное имя может быть удалено (ликвидировано), даже если это первичное имя интерфейса, данное ему при загрузке системы:

```
$ sudo ip link property del dev eno2 altname eno1
$ ip l sh dev eno2
2: eth0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP mode DEFAULT group
default qlen 1000
    link/ether 70:71:bc:a3:c5:c0 brd ff:ff:ff:ff:ff:ff
    altname enp0s25
    altname eno2
```

Важно чтобы удаляемое имя интерфейса не фигурировало как целевой интерфейс в записях таблицы маршрутизации:

```
$ route -n
Таблица маршутизации ядра протокола IP
Destination Gateway Genmask Flags Metric Ref Use Iface
0.0.0.0         192.168.1.3     0.0.0.0         UG    0      0        0 eth0
169.254.0.0     0.0.0.0         255.255.0.0     U     1000   0        0 eth0
192.168.1.0     0.0.0.0         255.255.255.0   U     0      0        0 eth0
```

Эта относительно новая возможность решает многие проблемы с именованием интерфейсов.

Порты транспортного уровня

Адрес назначения для сетевого интерфейса характеризуется его IP адресом. Но на хосте, которому принадлежит этот интерфейс со своим IP адресом, может работать одновременно много самых различных сетевых приложений. Для разграничения принадлежности пакетов между процессами (серверами, сервисами, службами) и прикладными протоколами вводится ещё один уровень адресации сверх того: порты транспортного уровня (на уровне протоколов TCP, UDP, SCTP, ...).

Каждому протоколу более **высоких уровней** (SSH, FTP, HTTP, ...) соответствует свой стандартный порт. Порт выражается как 16-битовое целочисленное значение, количество портов ограничено с учётом 16-битной адресации (2^{16}=65536, начало — «0»). Порты TCP и порты UDP — это совершенно разные сущности, а их возможное численное **совпадение** для отдельных служб делается только для удобства. Все порты разделены на три диапазона — **общеизвестные** (или **системные**, 0—1023), **зарегистрированные** (или **пользовательские**, 1024—49151) и **динамические** (или

частные, 49152—65535).

Работа с системными портами всегда требует прав `root`. Зарегистрированные порты — это порты, которые комиссия по регистрации IANA официально зарегистрировала за определёнными протоколами (рекомендуемые). Динамические и/или приватные порты — от 49152 до 65535. Эти порты динамические, в том смысле, что они могут быть использованы любым процессом и с любой целью. Часто, программа, работающая на зарегистрированном порту (от 1024 до 49151) порождает другие дочерние процессы, которые затем используют свои динамические порты. Самая свежая информация о регистрации номеров портов может быть найдена здесь: http://www.iana.org/numbers.htm#P .

Соответствия протоколов их **численным значениям портов** UDP или TCP смотрим в файле описания **сетевых служб** `/etc/services` :

```
$ cat /etc/services
...
ftp             21/tcp
ftp             21/udp          fsp fspd
ssh             22/tcp                          # SSH Remote Login Protocol
ssh             22/udp                          # SSH Remote Login Protocol
telnet          23/tcp
telnet          23/udp
...

$ grep -v ^$ /etc/services | grep -v ^# | wc -l
318
```

Вот такое число сервисов предопределено для различных протоколов комиссией IANA. Но это не значит что любой протокол обязан **использовать** этот свой порт — это только значения по умолчанию, рекомендуемые. Мы вполне можем, например, проверять работает ли на каком-то WEB сервер (стандартный порт 80) протокола HTTP (мы не собираемся вести диалог, и тут же прерываем коннект):

```
$ telnet linux-ru.ru 80
Trying 90.156.230.27...
Connected to linux-ru.ru.
Escape character is '^]'.
^]
telnet> Connection closed.
```

А если нас интересует прозондировать защищённый WEB сервер протокола HTTPS (стандартный порт 443), то поступаем так:

```
$ telnet linux-ru.ru 443
Trying 90.156.230.27...
Connected to linux-ru.ru.
Escape character is '^]'.
^]
telnet> Connection closed.
```

Но и сами WEB сервера используют порты (80, 443) рекомендуемые для них в `/etc/services` — весьма часто вы сможете наблюдать WEB сервера на портах 8080, 3128 и других.

Главное правило состоит в том, что на одном сервере не могут работать 2 сервиса одного транспортного протокола (UDP с TCP) с **совпадающими номерами** порта! Не могут один порт прослушивать одновременно 2 серверных приложения.

Но прежде, чем обсуждать возможности и особенности работы с любым из сетевых протоколов, нужно убедиться, что использование этого протокола не запрещено в настройках файервола вашей системы. После этого (уточнив характеристики интересующего нас протокола) разрешаем его к использованию средствами конфигурирования файервола (утилиты `iptables` или GUI оболочки для её управления).

Источники использованной информации

[1] Таблица ссылок на документы RFC по основным протоколам сети — http://ru.wikipedia.org/wiki/RFC

[2] У. Р. Стивенс : «Протоколы TCP/IP. В подлиннике», BHV, СПб, 2003, ISBN: 5-94157-300-6, 672 стр. — http://www.books.ru/books/protokoly-tcpip-v-podlinnike-82277/?show=1

У. Р. Стивенс : «Протоколы TCP/IP. В подлиннике», Невский Диалект, СПб, 2004, ISBN: 5-7940-0093-7, 672 стр. — http://www.books.ru/books/protokoly-tcpip-prakticheskoe-rukovodstvo-186726/?show=1

(оригинал: TCP/IP Illustrated, Volume 1: The Protocols, Addison-Wesley, 1994, ISBN 0-201-63346-9)

Книгу можно скачать здесь: http://dfiles.ru/files/swr1b0e7p

[3] TCP/IP Illustrated, Volume 1: The Protocols, 2nd Edition W. Richard Stevens, Kevin R. Fall, May 05, 2012

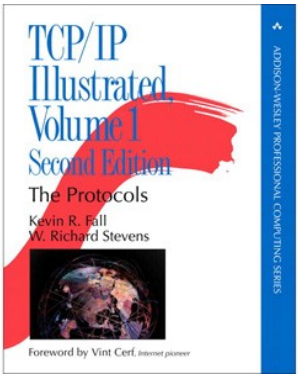

[4] NAT (Network Address Translation) для новичков — https://habr.com/ru/articles/583172/

[5] IPv6 теория и практика: введение в IPv6 — https://habr.com/ru/post/210100/

[6] Адреса протокола IPv6 — локальный и глобальный тип — https://zvondozvon.ru/tehnologii/kompyuternye-seti/adresa-ipv6

3. Протоколы и инструменты прикладного уровня

Число утилит предназначенных для работы с сетевым стеком огромно. Оно превосходит любую другой раздел работы компьютера. Значительную часть доступных утилит мы уже видели по тексту ранее. Здесь же мы проведём только некоторую их систематизацию.

Часть обсуждаемых утилит устанавливается в Linux по умолчанию при инсталляции системы (и то какая это часть — зависит от конкретного дистрибутива Linux). Другая часть может быть установлена из стандартного репозитория дистрибутива типовым способом (`apt`, `dnf` и другие). Я, за очень редкими исключениями, не буду назвать никаких утилит и проектов, отсутсвующих в стандартных репозиториях (и вам советую того же и не обольщаться сторонними источниками). В тех редких случаях, когда речь будет идти о сборке из программных исходных кодов, это будет оговариваться явно.

Инструменты диагностики

Важнейшими характеристиками сетевой подсистемы хоста являются конфигурация сетевых интерфейсов и таблица марщрутизации ядра, которая полностью и однозначно определяет направления распространения трафика между интерфейсами, например:

```
$ ip link
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue state UNKNOWN mode DEFAULT group default
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
2: em1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP mode DEFAULT group
default qlen 1000
    link/ether a0:1d:48:f4:93:5c brd ff:ff:ff:ff:ff:ff
3: wlo1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP mode DORMANT group
default qlen 1000
    link/ether 34:23:87:d6:85:0d brd ff:ff:ff:ff:ff:ff
4: ppp0: <POINTOPOINT,MULTICAST,NOARP,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UNKNOWN mode
DEFAULT group default
    link/ppp
```

```
$ route -n
Kernel IP routing table
Destination     Gateway         Genmask         Flags Metric Ref    Use Iface
0.0.0.0         192.168.1.1     0.0.0.0         UG    1024   0        0 em1
80.255.73.34    0.0.0.0         255.255.255.255 UH    0      0        0 ppp0
192.168.1.0     0.0.0.0         255.255.255.0   U     0      0        0 em1
192.168.1.0     0.0.0.0         255.255.255.0   U     0      0        0 wlo1
```

Таблицы маршрутизации для IPv4 и IP v6 различные

Несоответствие таблицы роутинга состояниям сетевых интерфейсов (что весьма часто случается при экспериментах и отладке сетевых модулей ядра) — наиболее частая причина отличия поведения сети от ожидаемого (картина восстанавливается соответствующими командами `route`, добавляющими или удаляющими направления в таблицу). Самое краткое и **исчерпывающее** описание работы TCP/IP сети (из известных автору) дал У. Р. Стивенс:

1. *IP-пакеты (создающиеся на хосте или приходящие на него снаружи), если они не предназначены данному хосту, ретранслируются в соответствии с одной из строк таблицы роутинга на основе IP адреса **получателя**.*
2. *Если ни одна строка таблицы не соответствует адресу получателя (подсеть или хост), то пакеты ретранслируются в интерфейс, который обозначен как интерфейс по умолчанию, который **всегда** присутствует в таблице роутинга (интерфейс с Destination равным 0.0.0.0 в примере показанном выше).*
3. *Пакет, пришедший с некоторого интерфейса, **никогда** не ретранслируется в этот же интерфейс.*

По этому алгоритму всегда можно разобрать картину происходящего в системе с любой самой сложной конфигурацией интерфейсов.

Основные инструменты управления сетевыми **интерфейсами** (`ip`, `ifconfig`, `route`, `NetworkManager`, nmcli ...) были обсуждены ранее. Они применимы как для реальных, так и для виртуальных сетевых интерфейсов, например, разнообразных VPN (Virtual Private Network):

```
$ ifconfig
...
cipsec0   Link encap:Ethernet  HWaddr 00:0B:FC:F8:01:8F
          inet addr:192.168.27.101  Mask:255.255.255.0
          inet6 addr: fe80::20b:fcff:fef8:18f/64 Scope:Link
          UP RUNNING NOARP  MTU:1356  Metric:1
          RX packets:4 errors:0 dropped:3 overruns:0 frame:0
          TX packets:18 errors:0 dropped:5 overruns:0 carrier:0
          collisions:0 txqueuelen:1000
          RX bytes:538 (538.0 b)  TX bytes:1670 (1.6 KiB)
...
```

Здесь показан виртуальный интерфейс (виртуальная частная сеть, VPN) созданный программными средствами (Cisco Systems VPN Client) от Cisco Systems (`cipsec0`), работающий через один из физических каналов хоста. Показательно, что если тот же VPN-канал создать «родными» Linux средствами OpenVPN (с помощью `NetworkManager`) к тому же удалённому серверу-хосту, то мы получим совершенно другой (и даже, если нужно, ещё один **дополнительно**, параллельно) сетевой интерфейс — различия в интерфейсах обусловлены **модулями ядра**, которые их создавали:

```
$ ifconfig
...
tun0      Link encap:UNSPEC  HWaddr 00-00-00-00-00-00-00-00-00-00-00-00-00-00-00-00
          inet addr:192.168.27.112  P-t-P:192.168.27.112  Mask:255.255.255.0
          UP POINTOPOINT RUNNING NOARP MULTICAST  MTU:1412  Metric:1
          RX packets:13 errors:0 dropped:0 overruns:0 frame:0
          TX packets:13 errors:0 dropped:0 overruns:0 carrier:0
          collisions:0 txqueuelen:500
          RX bytes:1905 (1.8 KiB)  TX bytes:883 (883.0 b)
```

Но кроме базовых инструментов управления сетевыми интерфейсами, для отработки сетевых проектов необходим ещё достаточно широкий набор средств диагностики, управления, отладки и тестирования.

Инструменты наблюдения

Поскольку представление сетевых интерфейсов достаточно мудрёно и принципиально отличается от символьных или блочных устройств (в `/dev`), то при отработке модулей ядра поддержки сетевых средств (да и других сетевых компонент пространства пользователя) используется совершенно особое множество **команд-утилит**. Их мы используем для контроля, диагностики и управления сетевыми интерфейсами. Набор сетевых утилит, используемых в сетевой разработке — огромен! Ниже мы только назовём некоторые из них, без которых такая работа просто невозможна...

Простейшими инструментами **диагностики** в нашей отработке примеров будет посылка «пульсов» — тестирующих ICMP пакетов `ping` (проверка достижимости хоста) и `traceroute` (задержка прохождения промежуточных хостов на трассе маршрута):

```
$ ping 8.8.8.8
PING 8.8.8.8 (8.8.8.8) 56(84) bytes of data.
64 bytes from 8.8.8.8: icmp_seq=1 ttl=51 time=57.3 ms
64 bytes from 8.8.8.8: icmp_seq=2 ttl=51 time=58.5 ms
^C
--- 8.8.8.8 ping statistics ---
2 packets transmitted, 2 received, 0% packet loss, time 1001ms
rtt min/avg/max/mdev = 57.374/57.959/58.544/0.585 ms

$ traceroute 80.255.64.23
traceroute to 80.255.64.23 (80.255.64.23), 30 hops max, 60 byte packets
 1  192.168.1.1 (192.168.1.1)  1.052 ms  1.447 ms  1.952 ms
 2  * * *
 3  10.50.21.14 (10.50.21.14)  32.584 ms  34.609 ms  34.828 ms
 4  umc-10G-gw.ix.net.ua (195.35.65.50)  37.521 ms  38.751 ms  39.052 ms
 5  * * *
```

Ещё одно представление сетевых интерфейсов и отображение статистики использования в динамике:

```
$ netstat -i
Kernel Interface table
Iface       MTU Met    RX-OK RX-ERR RX-DRP RX-OVR    TX-OK TX-ERR TX-DRP TX-OVR Flg
eth0       1500   0        0      0      0      0        0      0      0      0 BMU
lo        16436   0     5508      0      0      0     5508      0      0      0 LRU
wlan0      1500   0   154771      0      0      0   165079      0      0      0 BMRU
```

Установленные TCP соединения:

```
$ netstat -t
Active Internet connections (w/o servers)
Proto Recv-Q Send-Q Local Address               Foreign Address             State
tcp        0      0 notebook.localdomain:56223  2ip.ru:http                 TIME_WAIT
tcp        0      0 notebook.localdomain:45804  178-82-198-81.dynamic:31172 ESTABLISHED
tcp        0      0 notebook.localdomain:48314  c-76-19-81-120.hsd1.ct:9701 ESTABLISHED
tcp        0      0 notebook.localdomain:56228  2ip.ru:http                 TIME_WAIT
tcp        0      0 notebook.localdomain:56220  2ip.ru:http                 TIME_WAIT
tcp        0      0 notebook.localdomain:41762  mail.ukrpost.ua:imap        ESTABLISHED
tcp        0      0 notebook.localdomain:46302  bw-in-f16.1e100.net:imaps   ESTABLISHED
tcp        0      0 notebook.localdomain:56222  2ip.ru:http                 TIME_WAIT
tcp        0      0 notebook.localdomain:ssh    192.168.1.20:57939          ESTABLISHED
tcp        0      0 notebook.localdomain:56204  2ip.ru:http                 TIME_WAIT
tcp        0      0 notebook.localdomain:48861  mail1.ks.pochta.ru:imap     ESTABLISHED
```

Диагностика и управление таблицей разрешения MAC адресов в адреса IP (этот механизм определён только для IPv4):

```
$ arp
Address                  HWtype  HWaddress           Flags Mask            Iface
192.168.1.20             ether   f4:6d:04:60:78:6f   C                     wlan0
192.168.1.1              ether   94:0c:6d:a5:c1:1f   C                     wlan0
```

Утилиты `nslookup`, `host`, `dig` используются для работы с DNS серверами разрешения Интернет имён и IP адресов. Такое многообразие альтернативных утилит определяется, наверное, фундаментальностью этого процесса в ходе работы всемирной сети. Примеры запросов к DNS на прямое и обратное разрешение имени:

```
$ nslookup fedora.com
Server: 192.168.1.1
Address:         192.168.1.1#53

Non-authoritative answer:
Name:   fedora.com
Address: 174.137.125.92

$ nslookup  174.137.125.92
Server:          192.168.1.1
Address:         192.168.1.1#53

Non-authoritative answer:
92.125.137.174.in-addr.arpaname = mdnh-siteboxparking.phl.marchex.com.

Authoritative answers can be found from:
125.137.174.in-addr.arpa   nameserver = c.ns.marchex.com.
125.137.174.in-addr.arpa   nameserver = d.ns.marchex.com.
125.137.174.in-addr.arpa   nameserver = a.ns.marchex.com.
125.137.174.in-addr.arpa   nameserver = b.ns.marchex.com.
```

Вторым (необязательным) параметром команды `nslookup` может быть IP адрес DNS-сервера, через который требуется выполнить разрешение имён (при его отсутсвии будет использована последовательность DNS, конфигурированных в системе по умолчанию).

```
$ host fedora.com
fedora.com has address 86.105.245.69

$ host 86.105.245.69
69.245.105.86.in-addr.arpa domain name pointer 86-105-245-69.haip.transip.net.

$ dig fedora.com
; <<>> DiG 9.18.12-0ubuntu0.22.04.1-Ubuntu <<>> fedora.com
;; global options: +cmd
;; Got answer:
;; ->>HEADER<<- opcode: QUERY, status: NOERROR, id: 31162
;; flags: qr rd ra; QUERY: 1, ANSWER: 1, AUTHORITY: 0, ADDITIONAL: 1

;; OPT PSEUDOSECTION:
; EDNS: version: 0, flags:; udp: 65494
;; QUESTION SECTION:
;fedora.com.                    IN      A

;; ANSWER SECTION:
fedora.com.             42      IN      A       86.105.245.69

;; Query time: 0 msec
;; SERVER: 127.0.0.53#53(127.0.0.53) (UDP)
;; WHEN: Wed Apr 26 14:14:25 EEST 2023
;; MSG SIZE  rcvd: 55
```

Для **анализа трафика** разрабатываемого сетевого интерфейса вам безусловно потребуются что-то из числа известных утилит **сетевых сниферов**, таких как `tcpdump` (http://www.tcpdump.org/), или её GUI эквивалент `Wireshark` (http://www.wireshark.org/). Посмотрим как будет выглядеть результат `tcpdump` для вот такого сетевого интерфейса (`p7p1`):

```
$ ip addr show dev p7p1
3: p7p1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP qlen 1000
    link/ether 08:00:27:9e:02:02 brd ff:ff:ff:ff:ff:ff
    inet 192.168.56.101/24 brd 192.168.56.255 scope global p7p1
    inet6 fe80::a00:27ff:fe9e:202/64 scope link
       valid_lft forever preferred_lft forever
```

Здесь мы можем рассмотреть полученный в `tcpdump` дамп сетевого трафика (показано только начало) при выполнении операции `ping` на этот интерфейс с внешнего хоста LAN:

```
$ sudo tcpdump -i p7p1
tcpdump: verbose output suppressed, use -v or -vv for full protocol decode
listening on p7p1, link-type EN10MB (Ethernet), capture size 65535 bytes
08:57:53.070217 ARP, Request who-has 192.168.56.101 tell 192.168.56.1, length 46
08:57:53.070271 ARP, Reply 192.168.56.101 is-at 08:00:27:9e:02:02 (oui Unknown), length 28
08:57:53.070330 IP 192.168.56.1 > 192.168.56.101: ICMP echo request, id 2478, seq 1, length 64
08:57:53.070373 IP 192.168.56.101 > 192.168.56.1: ICMP echo reply, id 2478, seq 1, length 64
08:57:54.071415 IP 192.168.56.1 > 192.168.56.101: ICMP echo request, id 2478, seq 2, length 64
08:57:54.071464 IP 192.168.56.101 > 192.168.56.1: ICMP echo reply, id 2478, seq 2, length 64
...
```

Видно работу ARP механизма разрешения IP адресов в локальной сети (начало протокола), и приём и передачу IP пакетов (тип протокола ICMP).

С помощью программы `tcpdump`, формируя сложные **условия фильтра** отбора пакетов для протокола (по сетевым интерфейсам, протоколам, адресам источника и получателя...) можно локализовать проблемы и изучить практически любой сетевой обмен.

Альтернативой (функционально) `tcpdump`, но уже с графическим интерфейсом (GUI) является программа `WireShark.`

Утилита `WireShark`, в отличии от `tcpdump` содержит, кроме того, большое количество парсеров для сетевых пакетов (например можно прослушать не закодированные видео/аудио поток, передающийся в пакетах протокола RTP при SIP соединениях в IP-телефонии), а также позволяет

добавлять собственные парсеры для своих пакетов. Это очень полезно, например, если содержимоепакета закодировано (encrypted), что очень распространено в коммерческих проектах.

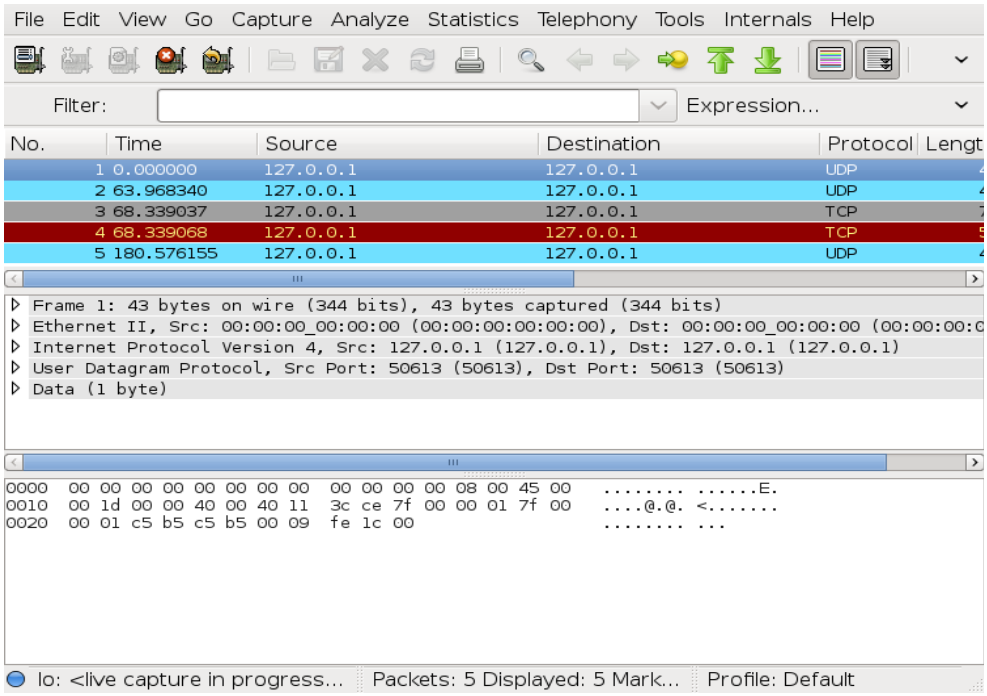

Инструменты тестирования

В системе Linux (POSIX-совместимой, UNIX-like) наилучшими инструментами тестирования являются сами стандартные утилиты POSIX/GNU, такие как `echo`, `cat`, `cp` и другие (в этом проявляется симметричность и ортогональность систем UNIX). Для тестирования и отладки сетевых модулей ядра также хорошо бы предварительно определиться с набором тестовых инструментов (утилит), которые также были бы относительно стандартизованы (или широко используемые), и которые позволяли бы проводить тестирование быстро, достоверно и с наименьшими затратами.

Один из удачных вариантов тестеров могут быть утилиты передачи файлов по протоколу SSH — `sftp` и `scp`. Обе утилиты копируют указанный (по URL) **сетевой файл**. Разница состоит в том, что `sftp` требует указания только источника и копирует его в текущий каталог, а для `scp` указывается и источник и приёмник (и каждый из них может быть сетевым URL, таким образом допускается выполнение копирования и из 3-го, стороннего узла):

```
$ sftp olej@192.168.1.9:/home/olej/YYY
olej@192.168.1.137's password:
Connected to 192.168.1.9.
Fetching /home/olej/YYY to YYY
/home/olej/YYY                              100% 98MB 10.9MB/s 00:09

$ scp olej@192.168.1.137:/boot/initramfs-3.6.11-5.fc17.i686.img img1
olej@192.168.1.137's password:
initramfs-3.6.11-5.fc17.i686.img            100%   18MB  17.6MB/s   00:01
```

Один из лучших инструментов сетевого программиста для тестирования и отладки — утилита Netcat (имя исполнимого файла `nc`). Подобно утилите `cat` она позволяет отправлять (или получать) байтовый поток, но не в поток ввода-вывода, а в сетевой сокет. У этой утилиты есть множество возможностей (описанных в `man`), в частности она позволяет как передавать данные в сеть (клиент), так и ожидать принимаемые эти данные из сети (сервер, с опцией `-l`). Простейший пример использования `nc` может быть показан, если мы в одном терминале запустим экземпляр `nc` в режиме прослушивания сокета (**сервер**, TCP порт 1234), того, что будет вводиться с терминала другим экземпляром `nc`, работающим в режиме **клиента**:

```
$ nc -l 1234
входная строка
```

```
1111111111111
2222222222
333333
^C
```

А вот терминал с которого та же программа nc работала как клиент, копирующий в сетевой сокет ввод с клавиатуры (то, что мы и получаем на стороне сервера):

```
$ nc 127.0.0.1 1234
входная строка
1111111111111
2222222222
333333
```

Пример упрощён и схематичен, но многочисленными опциями запуска nc можно варьировать: адреса сетевых узлов, протоколы (TCP по умолчанию и UDP при опции `-u`), порты и многое другое. Это делает утилиту универсальным **отладочным** инструментом практически неограниченных возможностей. Во многих случаях, при отладочных работах, nc может заменить протокол и утилиту `telnet` рассматриваемые далее.

P.S. Обратите внимание (это важно и может сэкономить много напрасно потерянного времени), что в современных дистрибутивах может быть (в пакетной системе, в виде пакетов) **две** совершенно разные реализации, названные: традиционный Netcat и Netcat BSD. Более того, по умолчанию может устанавливаться именно Netcat BSD, а традиционный Netcat потребует ручной установки. Реализации **несовместимы** ни по командному интерфейсу, ни по сетевому **протоколу**! Поскольку nc предназначен для связывания разных сетевых хостов — следите чтобы на разных концах работали сходные реализации nc (это можно выяснить запустив утилиту с опцией `-h`).

Две реализации допускают **одновременную** установку в систему, а быстрое переключение текущей использующейся версии обеспечивает система управления альтернативами Linux:

```
$ galternatives
...
```

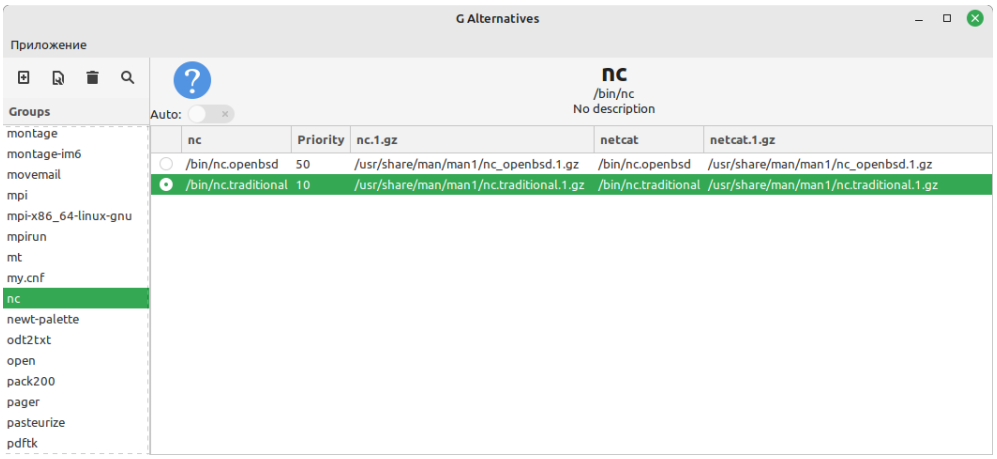


```
$ update-alternatives --display nc
nc - ручной режим
  лучшая версия ссылки — /bin/nc.openbsd
  ссылка сейчас указывает на /bin/nc.traditional
  ссылка nc — /bin/nc
  подчинённая nc.1.gz — /usr/share/man/man1/nc.1.gz
  подчинённая netcat — /bin/netcat
  подчинённая netcat.1.gz — /usr/share/man/man1/netcat.1.gz
/bin/nc.openbsd — приоритет 50
  подчинённый nc.1.gz: /usr/share/man/man1/nc_openbsd.1.gz
  подчинённый netcat: /bin/nc.openbsd
  подчинённый netcat.1.gz: /usr/share/man/man1/nc_openbsd.1.gz
/bin/nc.traditional — приоритет 10
  подчинённый nc.1.gz: /usr/share/man/man1/nc.traditional.1.gz
  подчинённый netcat: /bin/nc.traditional
```

```
подчинённый netcat.1.gz: /usr/share/man/man1/nc.traditional.1.gz
```

Как легко отсюда видеть, сами оригинальные программы-утилиты инсталлируются в систему под именами `nc.traditional` и `nc.openbsd`:

```
$ nc.traditional -h
[v1.10-47]
connect to somewhere:      nc [-options] hostname port[s] [ports] ...
listen for inbound:        nc -l -p port [-options] [hostname] [port]
...
$ nc.openbsd -h
OpenBSD netcat (Debian patchlevel 1.218-4ubuntu1)
usage: nc [-46CDdFhklNnrStUuvZz] [-I length] [-i interval] [-M ttl]
          [-m minttl] [-O length] [-P proxy_username] [-p source_port]
          [-q seconds] [-s sourceaddr] [-T keyword] [-V rtable] [-W recvlimit]
          [-w timeout] [-X proxy_protocol] [-x proxy_address[:port]]
          [destination] [port]
...
```

Сервисы сети и systemd

Практически все далее рассматриваемые сетевые сервисы (и ещё множество не рассматриваемых) построены на клиент-сервисной архитектуре: клиенты запрашивают обслуживания у сервера по сетевому протоколу. Структура практически всех свободно развиваемых сетевых проектов (Linux — операционная система свободная и с открытыми исходными кодами всех её продуктов!), из-за их сетевой специфичности, совершенно одинакова, и состоит из 3-х компонент основных: 1). протокол XXX, 2). клиент xxx, 3). сервер xxx. Клиент, как правило, готов для использования, хотя иногда требует предварительной конфигурации. Запуск серверов, в современных дистрибутивах (в подавляющем большинстве) обеспечивается средствами systemd.

Схема установки и запуска в эксплуатацию всех сетевых проектов однотипна и единообразна, и поэтому, чтобы не повторять её далее каждый раз в деталях и относительно каждого нового сервиса, вспомним единую схему обращения с сетевыми дистрибутивными пакетами, общую для подавляющего большинства сетевых проектов:

1. Установка выбранного проекта (условно назовём его xxx) из сетевого репозитория своего дистрибутива:

   `$ apt install xxx`

   Или для RPM дистрибутивов:

   `$ dnf install xxx`
2. Конфигурируем сервер устанавливаемого протокола XXX. Местоположение конфигурационных файлов, обычно, уточняется во время установки, смотрим для начала файлы /etc/default/xxx, /etc/xxx.conf, /etc/xxx.d/xxx.conf
3. Запускаем сервер средствами systemd:

   `$ sudo systemctl start xxx`
4. Проверяем статус запущенного сервера на предмет отсутствия ошибок:

   `$ systemctl status xxx`
   ```
   ...
   ```

   Повторяем снова начиная с п.2 до тех пор, пока этот шаг не проходим без ошибок.
5. Если планируем долгосрочно использовать сервер протокола XXX, устанавливаем для него автоматический запуск при загрузке операционной системы:

   `$ sudo systemctl enable xxx`

SSH

Протокол SSH (**S**ecure **SH**ell) пришёл на смену протоколу telnet и, как понятно и из самого названия, первоначальное и основное его предназначение было — организация защищённых шифрованием в канале терминальных сессий (в защищённости и состоит главное отличие от telnet). Но в дальнейшем SSH так «пришёлся ко двору», что на него было возложено множество других возможностей (только малую часть которых мы сейчас и посмотрим).

Для Linux существует несколько реализаций для протокола SSH. Но самая широко используемая из них — это openssh. Клиент `openssh-client` установлен по умолчанию в любом дистрибутиве Linux — это основной и любимый инструмент любого сетевого администратора. Сервер же из того же проеукта `openssh-server` (и по желанию `openssh-sftp-server`) нужно установить дополнительно (что я рекомендовал бы делать первейшим действием после инсталляции любого дистрибутива Linux):

```
$ aptitude search openssh- | grep ^i
i  openssh-client - клиент протокола SSH, для защищённого удалённого доступа
i  openssh-server - Сервер SSH для бесопасного доступа с удалённых компьютеров
i  openssh-sftp-server - secure shell (SSH) sftp server module, for SFTP access from remote
machines
```

После установки сервер запускается через `systemd` стандартным способом:

```
$ sudo systemctl start sshd
$ systemctl status sshd
● ssh.service - OpenBSD Secure Shell server
     Loaded: loaded (/lib/systemd/system/ssh.service; enabled; vendor preset: enabled)
     Active: active (running) since Sun 2023-04-23 07:07:20 EEST; 6h ago
       Docs: man:sshd(8)
             man:sshd_config(5)
    Process: 1313 ExecStartPre=/usr/sbin/sshd -t (code=exited, status=0/SUCCESS)
   Main PID: 1331 (sshd)
      Tasks: 1 (limit: 115786)
     Memory: 3.2M
        CPU: 25ms
     CGroup: /system.slice/ssh.service
             └─1331 "sshd: /usr/sbin/sshd -D [listener] 0 of 10-100 startups"

апр 23 07:07:20 R420 systemd[1]: Starting OpenBSD Secure Shell server...
апр 23 07:07:20 R420 sshd[1331]: Server listening on 0.0.0.0 port 22.
апр 23 07:07:20 R420 sshd[1331]: Server listening on :: port 22.
апр 23 07:07:20 R420 systemd[1]: Started OpenBSD Secure Shell server.
$ pgrep sshd
1331
19252
19262
```

Что означают последние 2 строчки вывода (1-я это понятно, это PID стартовавшего сервера sshd, совпадающий и с значением в статусе systemd показанным выше). А 2 последние строчки: а). соответствуют каждая одной подключенной клиентской сессии, б). указывают на то что SSH-сервер это fork-ающий сервер, в). и каждая из этих строк это PID дочернего процесса для обслуживания своей терминальной сессии.

И я сразу же после установки сервера SSH разрешил бы через `systemd` его автоматический запуск после перезагрузки системы:

```
$ sudo systemctl start sshd
```

Синтаксис **клиента** SSH[1]:

```
$ ssh olej@192.168.1.13
olej@192.168.1.13's password:
olej@R420:~$ hostname
R420
olej@R420:~$ exit
выход
Connection to 192.168.1.13 closed.
```

Или так:

```
$ ssh -l olej 192.168.1.13
olej@192.168.1.13's password:
```

1 Я везде в примерах показываю в примерах своё регистрационное имя пользователя olej (чтобы не городить каких-то условных конструкция типа <user> не похожих на синтаксис реальных команд). Вы, естественно, должны подставить вместо регистрационное имя пользователя в своей системе.

```
...
```

Показано это для того чтобы подтвердить: клиент SSH **всегда запросит** пароль пользователя (это пароль этого имени пользователя на удалённом хосте, а не где-то в недрах самой системы SSH). (Это если на удалённом хосте не разрешён беспарольный SSH доступ, но разрешать такой доступ — это последнее дело.) Нет никакой синтаксической формы запроса SSH-коннекта в которой явно указывался бы пароль одновременно с именем (через знак двоеточия как это допускают многие сетевые протоколы и команды). Это сделано для предотвращения видимости пароля при наборе на терминале.

Иногда нас может интересовать в клиенте не возможность установить долговременную терминальную сессию, а запустить удалённо программу (или несколько программ), с отображением на наш локальный терминал. Тогда формат команды немного изменится:

```
$ ssh olej@192.168.1.13 df -h
olej@192.168.1.13's password:
Файл.система   Размер Использовано  Дост Использовано% Смонтировано в
tmpfs            9,5G         2,1M  9,5G            1% /run
/dev/sda5        109G          45G   60G           43% /
tmpfs             48G          20K   48G            1% /dev/shm
tmpfs            5,0M         4,0K  5,0M            1% /run/lock
/dev/nvme0n1p1   229G          58G  160G           27% /home
/dev/sdb2        229G          83G  135G           39% /home/olej/Загрузки
/dev/sda1        511M         3,3M  508M            1% /boot/efi
/dev/sdc2        910G          19G  846G            3% /mnt/sdc2
/dev/sdc3        576G         140G  408G           26% /mnt/sdc3
tmpfs            9,5G         132K  9,5G            1% /run/user/1000
```

Или, если нам нужно выполнить последовательность нескольких (сколь угодно много) команд, то объединяете из в одну общую строку:

```
$ ssh olej@192.168.1.13 "uptime && free -m"
olej@192.168.1.13's password:
 18:59:04 up 11:51,  1 user,  load average: 3,74, 2,27, 1,71
               total        used        free      shared  buff/cache   available
Память:       96607        7194       85954         389        3458       88249
Подкачка:      2047           0        2047
```

Примечание: Напомню, что в цепочке (последовательности) команд могут использоваться в качестве разделителя либо а). условный && — выполнять только при успешном завершении предыдущей команды, либо б). безусловный ; — выполнять при любом исходе предыдущей команды.

Возможности системы SSH на сегодня просто необозримы: туннели для других сетевых протоколов, проксирование с одного ресурса на другой и многое другой… Мы рассмотрим только некоторые из возможностей, которые очень полезны на практике, но недостаточно широко известны.

Передача файлов по SSH

К содружеству утилит SSH позже были добавлены утилиты копирования удалённых файлов через протокол SSH: команды `sftp` и `scp`.

Команда копирует `sftp` удалённый файл на файловую систему локального компьютера на котором мы работаем (или из локального хоста на удалённый). Это немного напоминает протокол FTP, но передача идёт в зашифрованном канале. Для чистоты эксперимента копирование делаю в вновь созданный пустой каталог:

```
$ mkdir tmp && cd tmp
$ ls -l
итого 0
```

Копируем файл по сети … с сервера находящегося за тысячи километров (хостинг в Казахстане):

```
$ sftp olej@linux-ru.ru:prefix
olej@linux-ru.ru's password:
Connected to linux-ru.ru.
Fetching /home/olej/prefix to prefix
prefix                                                100%   36     0.2KB/s   00:00
```

Полученный результат:

```
$ ls -l
итого 4
-rwxr-xr-x 1 olej olej 36 апр 23 15:01 prefix
```

Обращаем внимание на несколько необычный синтаксис указания локализации копируемого файла на удалённом хосте: 1). имя сервера отделяется от путевого имени файла двоеточием, 2). путевое имя файла, после двоеточия, отсчитывается не абсолютно (от корня удалённой файловой системы), а от домашнего каталога того пользователя, который регистрируется в команде (перед символом @).

Команда `scp` ещё интереснее: она копирует файл между двумя локациями, каждая из которых может быть удалённой (но может и локальной). В следующем примере мы копируем файл всё с того же весьма удалённого ресурса (за тысячи километров), но не на свой локальный компьютер, а на соседний хост в нашей локальной сети:

```
$ scp olej@linux-ru.ru:prefix olej@192.168.1.11:
olej@linux-ru.ru's password:
```

На хосте получателя наблюдаем (и тут же контролируем время создания, чтобы убедиться что это только-что полученный файл):

```
$ ls -l prefix
-rwxr-xr-x 1 olej olej 36 апр 23 15:05 prefix
$ date
Вс 23 апр 2023 15:06:05 EEST
```

Команды эти хоть и просты, но обладают возможностями гораздо большими чем те, что мы уже успели посмотреть:

```
$ sftp --help
unknown option -- -
usage: sftp [-46AaCfNpqrv] [-B buffer_size] [-b batchfile] [-c cipher]
          [-D sftp_server_path] [-F ssh_config] [-i identity_file]
          [-J destination] [-l limit] [-o ssh_option] [-P port]
          [-R num_requests] [-S program] [-s subsystem | sftp_server]
          destination

$ scp --help
scp: unknown option -- -
usage: scp [-346ABCOpqRrsTv] [-c cipher] [-D sftp_server_path] [-F ssh_config]
           [-i identity_file] [-J destination] [-l limit]
           [-o ssh_option] [-P port] [-S program] source ... target
```

Из самых очевидных вещей: 1). команды работают как с IPv4 так и с IPv6, 2). если команды выполнять с опцией -r, то копируется не отдельный файл, а весь каталог рекурсивно со всем его содержимым.

Естественно, что для этих команд на хосте источнике (а для `scp` и на хосте получателе) должен работать сервер SSH.

SSH и mc

Не достаточно известно, что то, что в 2-панельном файловом менеджере `mc` для операций для панелей названо как «Shell-соединение» — это и есть соединение этой панели к сетевому хосту по шифрованному протоколу SSH.

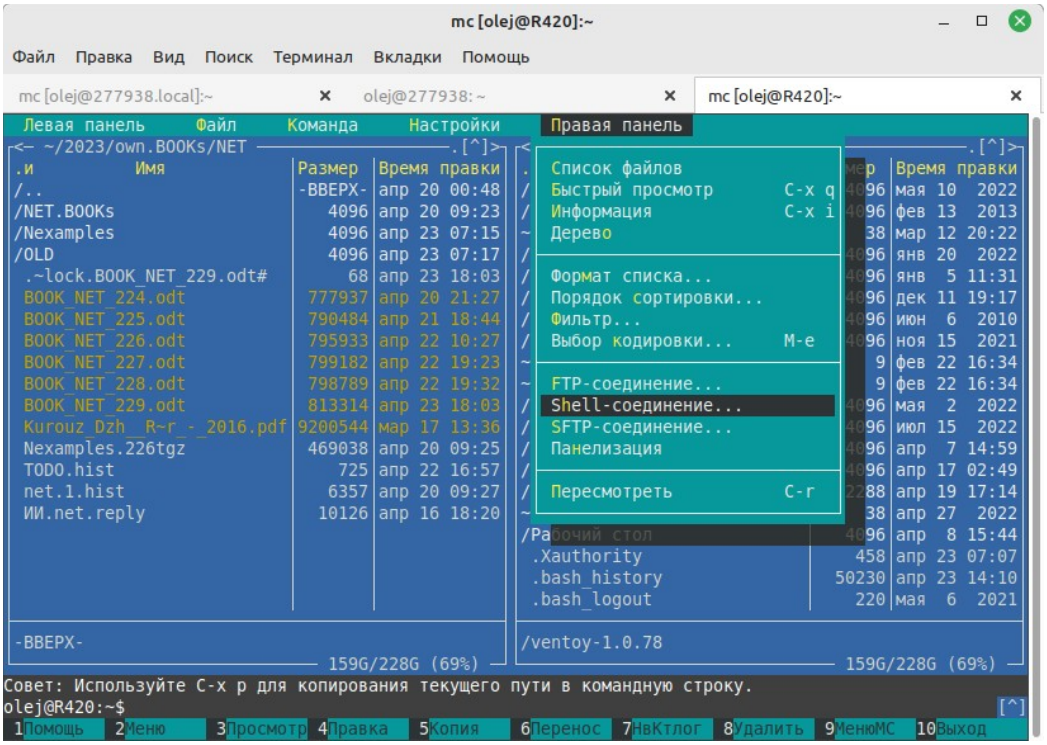

Тогда, для наглядности, мы можем в правой панели, например, указать соседний хост в локальной сети:

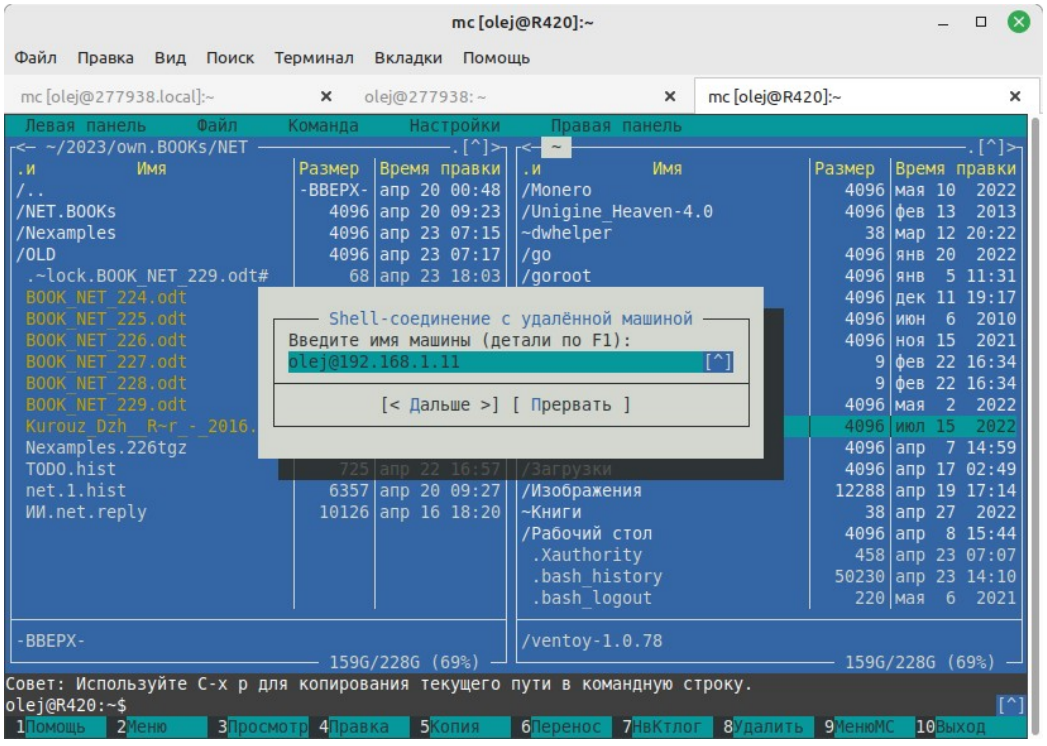

А в правой панели, аналогично, можем определить для подключения, например, удалённый (на несколько тысяч километров) сервер:

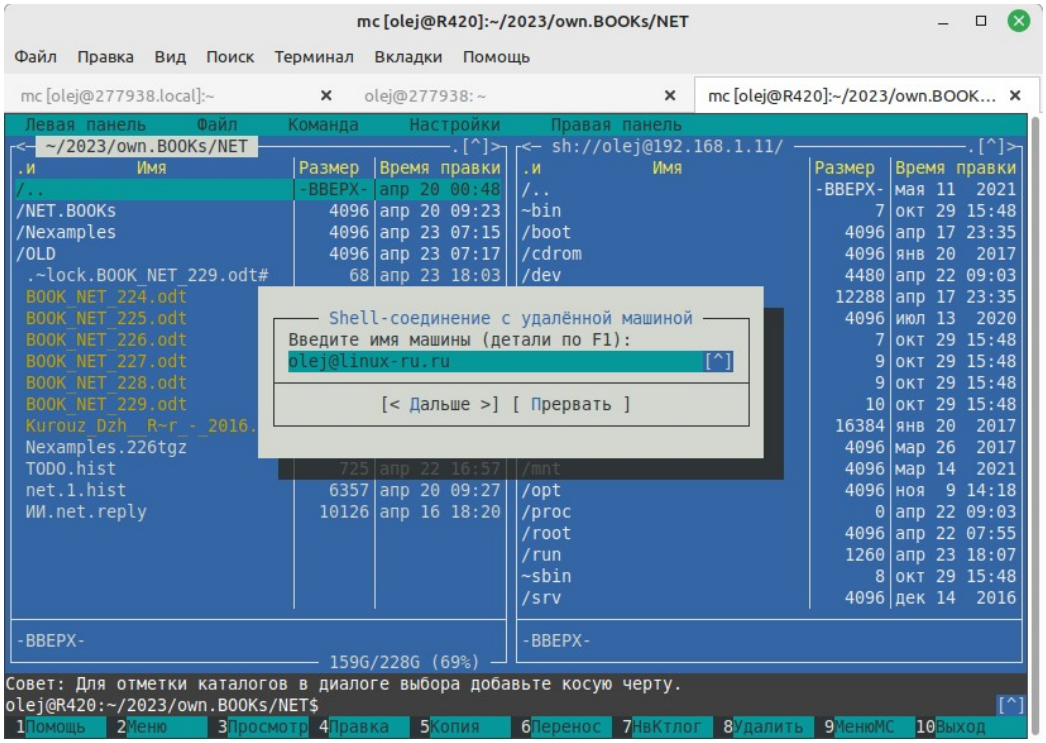

Естественно, и в том и в другом подключении у нас попросят пароли авторизации для указанного имени пользователя. Вот итоговая картина панелей файлового менеджера после осуществления подключений:

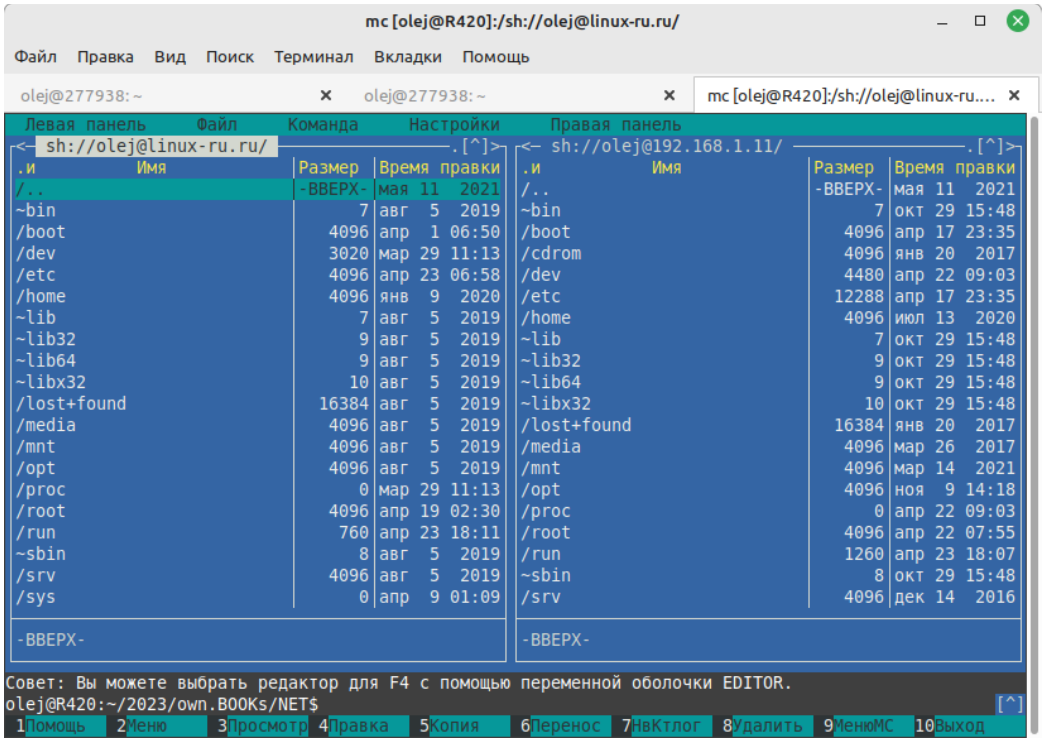

Теперь мы можем (простыми действиями с визуальным контролем):

- по Tab перемещаться между левой-правой локации;
- свободно перемещаться по файловой иерархии каждой из локаций пользуясь для этого стрелкам клавиатуры (и Enter);
- копировать (по F5) или перемещать (по F6) файлы между локациями (не взирая на то что их разделяет тысячи километров);
- просматривать (по F3) или даже редактировать (по F4) содержимое файлов, находящихся от

нас за тысячи километров...

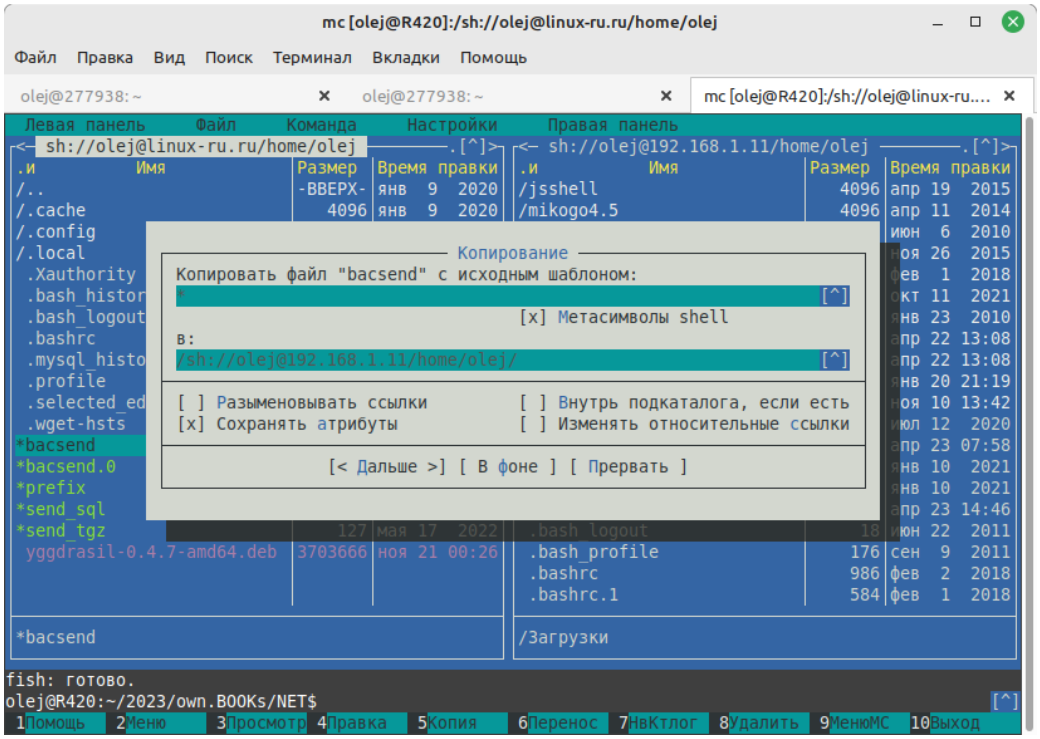

Графическая сессия в SSH

Выше было уже вскользь упомянуто о том, что протокол SSH может использоваться как туннель для многих других сетевых протоколов внутри себя. Это очень обширная отдельная тема, но нас здесь интересует частность: SSH может туннелировать, в том числе, и графический протокол X11 (на котором построена вся графика в UNIX/Linux). А это значит что мы можем на (сколь угодно) удалённом сервере запускать любые привычные графические GUI приложения с тем, чтобы их графический экран отображался (и взаимодействовал) на нашем локальном мониторе (локального хоста).

Для того чтобы SSH сессия запускалась с туннелированием протокола X11, команду SSH клиента нужно запускать с опциями -X, или даже -Y, что предусматривает, во втором случае **отсутствие** шифрования в SSH протоколе. Второй вариант (-Y) делает соединение ещё быстрее, и может применяться в локальных сетях, когда у вас есть доверие к трассе прохождения IP пакетов.

Простейшее GUI приложение выполняющееся удалённо:

```
$ ssh -X olej@192.168.1.13 xclock
olej@192.168.1.13's password:
```

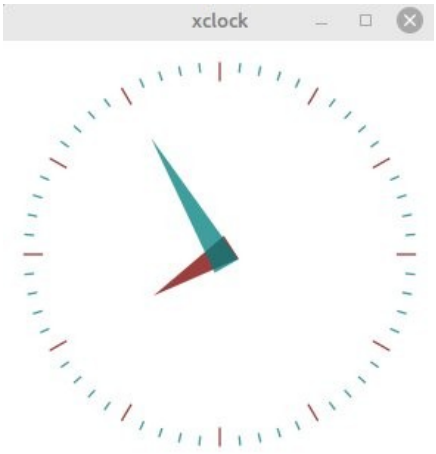

Более сложное (весьма сложное) GUI приложение, выполняемое удалённо — это может быть, например, менеджер виртуальных машин VirtualBox, когда виртуальные машины будут выполнятся на одном хосте LAN, а отображение (десктопов виртуальных машин) направлять на другом:

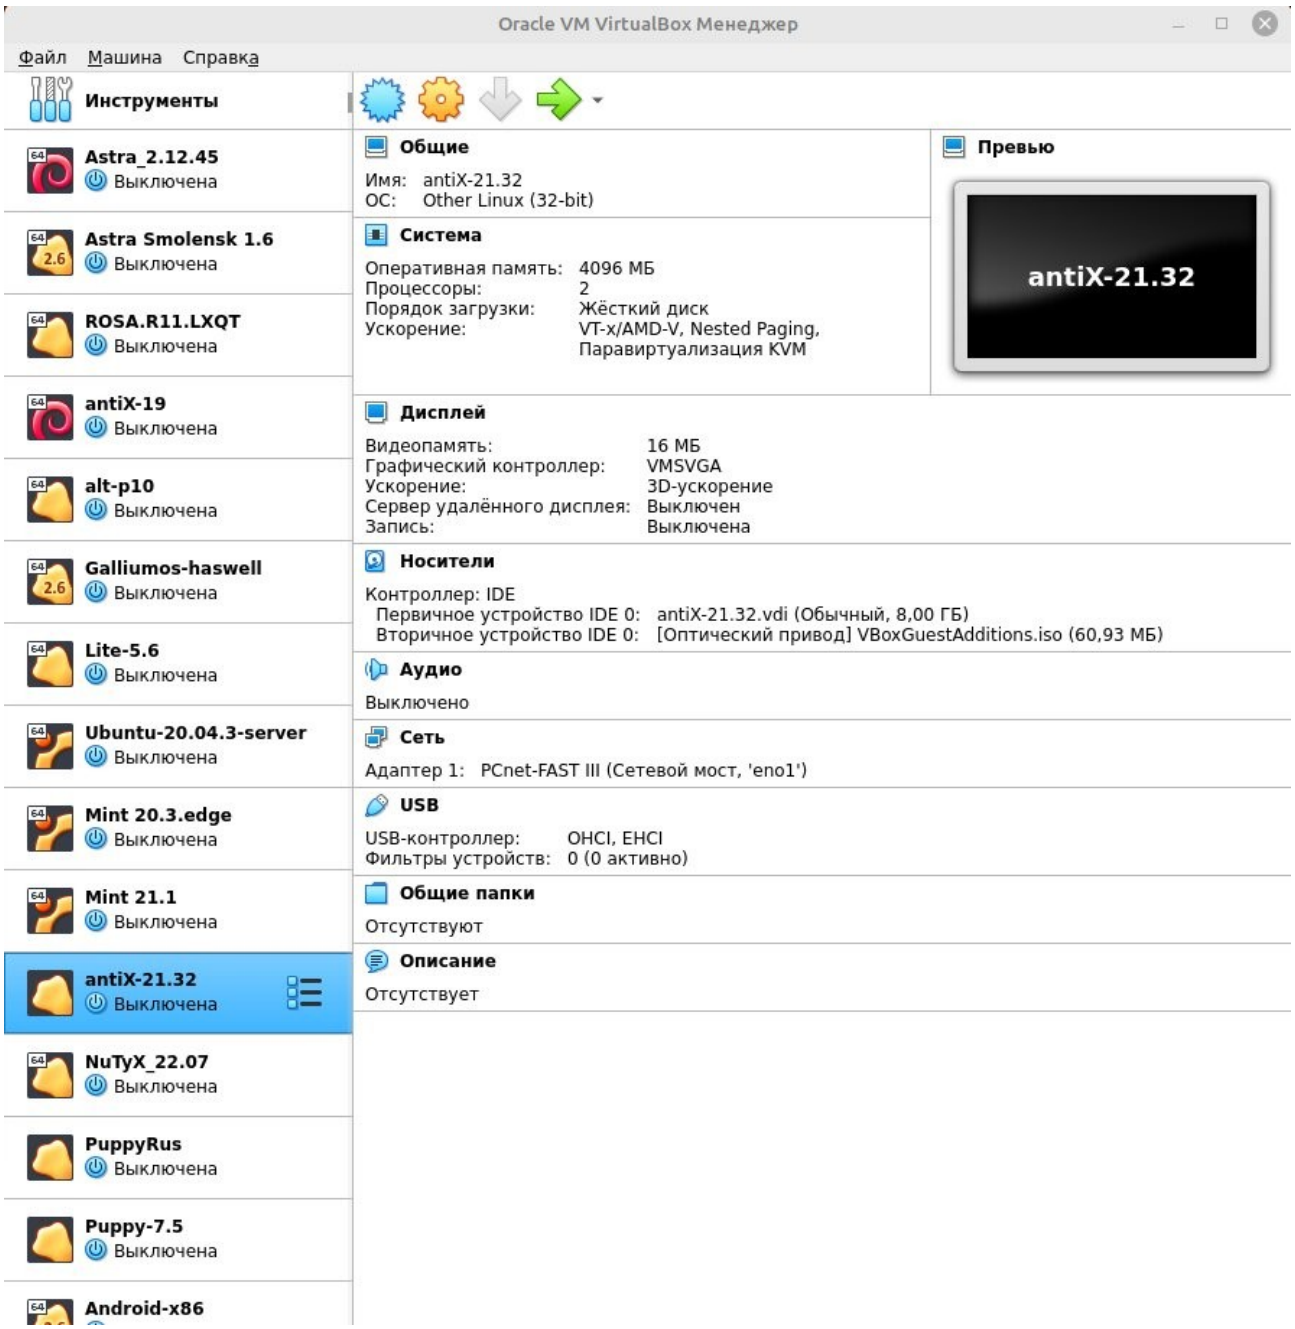

SSH в скриптах

Как последнюю из особенностей пользования SSH хотелось бы затронуть возможность использования команд клиента SSH в исполнимых скриптах. Как уже упоминалось ранее, у команды ssh, при всём богатстве выбора, нет синтаксической формы, которая позволяла бы записать символьную строку пароля непосредственно в команду — это для того, чтобы такую команду можно было выполнять в составе скрипта, не требующего диалогового вмешательства пользователя. Это бывает здорово нужно при работе в собственной доверенной LAN, или с собственными виртуальными машинами … но не только.

Для таких целей в Linux (в стандартных репозиториях пакетных систем) имеется такое небольшое приложение, которое нужно отдельно установить:

```
$ sudo apt install sshpass
Чтение списков пакетов… Готово
```

```
Построение дерева зависимостей
Чтение информации о состоянии… Готово
Следующие НОВЫЕ пакеты будут установлены:
  sshpass
Обновлено 0 пакетов, установлено 1 новых пакетов, для удаления отмечено 0 пакетов, и 6 пакетов не обновлено.
Необходимо скачать 11,3 kB архивов.
После данной операции объём занятого дискового пространства возрастёт на 31,7 kB.
Пол:1 http://deb.debian.org/debian buster/main amd64 sshpass amd64 1.06-1 [11,3 kB]
Получено 11,3 kB за 1с (11,2 kB/s)
Выбор ранее не выбранного пакета sshpass.
(Чтение базы данных … на данный момент установлено 379076 файлов и каталогов.)
Подготовка к распаковке …/sshpass_1.06-1_amd64.deb …
Распаковывается sshpass (1.06-1) …
Настраивается пакет sshpass (1.06-1) …
Обрабатываются триггеры для man-db (2.8.5-1) …
```

После этого вы любые команды клиента SSH можете передавать приложению `sshpass` на выполнение. Проще чем объяснять это показать на примере, вот как может выглядеть терминальная сессия:

```
$ sshpass -p 'xyz123' ssh -l vasja -Y 192.168.1.107
You have new mail.
Last login: Fri Jul 19 16:23:52 2019 from 192.168.1.103
$ uname -a
Linux astra 4.19.0-1-generic #astra1 SMP Wed Mar 20 12:59:21 UTC 2019 x86_64 GNU/Linux
$ whoami
vasja
...
```

Здесь (как должно быть понятно):

- vasja — это логин пользователя на хосте 192.168.1.107
- xyz123 — это пароль к этому логину

Естественно, что в такой же манере для sshpass можно передавать **все** синтаксические формы ssh рассматриваемые ранее.

DHCP

Все показанные выше примеры относительно использования IP адресов были показаны на примерах фиксированных значений адреса, типа: 192.168.1.11 — такие адреса присваивались интерфейсам вручную. Для локальной сети в которой до десятка хостов это вполне приемлемо. Но что делать с LAN и как её администрировать если в ней сотня хостов? Для этого предложен протокол DHCP (**D**ynamic **H**ost **C**onfiguration **P**rotocol, протокол динамической конфигурации узлов) и реализующие его службы (сервер, клиенты, управление).

Протокол DHCP — это клиент-серверный протокол, который автоматически предоставляет хосту, в момент его загрузки, для него IP-адрес (из определённого пула адресов) и другие связанные сведения о конфигурации, такие как маска подсети и шлюз по умолчанию. Идея DHCP крайне простая:

- Серверу в конфигурациях прописывается один или несколько диапазон IP адресов (пул адресов);
- Для этого диапазона устанавливается единый набор сопутствующей информации (маска, шлюз по умолчанию, DNS сервер подсети);
- На запрос очередного загружающегося клиента сервер DNS выбирает ему свободный (не занятый ещё) IP адрес из пула (если там, конечно, ещё остался незанятый адрес)…
- .. и возвращает его клиенту вместе с комплектом сопутствующей информации для этого диапазона;
- После выделения IP по запросу сервер хранит информацию о нём как о занятом (зарезервированном) ещё некоторое время, называемое временем аренды (связывая эту аренду с MAC адресом клиента которому был возвращён этот IP).

RFC 2131 и 2132 определяют протокол DHCP в качестве стандарта Internet Engineering Task Force (IETF), основанного на более раннем протоколе начальной загрузки (BOOTP)[2], протокола, через который DHCP и предоставляет много нужных сведений.

DHCP клиент в Linux присутствует изначально в любой инсталляции системы, другой вопрос, что он может быть включен для отдельного сетевого интерфейса, или выключен и тогда никак себя не проявляет.

DHCP сервер менее известен, но это только потому, что он на сегодня встраивается в любой сетевой роутер, даже в простейшие и дешёвые SOHO, домашнего использования, класса. Таким образом, все мы и каждый день пользуемся услугами DHCP сервера просто об этом часто не зная, и его не замечая. Но каждый (почти) роутер на сегодня — это Linux, и на нём работает типовой DHCP сервер.

Но иногда требуется по необходимости и возникает такое желание установить DHCP сервер отдельно на автономном хосте локальной сети (при этом отключив, как правило, встроенный DHCP сервер роутера — 2 и более DHCP сервера в одной LAN это, как правило, трудно диагностируемые проблемы!).

Один из самых популярных в Linux DHCP серверов `isc-dhcp-server` (ранее известный как `dhcp3-server`):

```
$ aptitude search isc-dhcp-server
p   isc-dhcp-server                       - ISC DHCP server for automatic IP address assignment
p   isc-dhcp-server-ldap                  - DHCP server that uses LDAP as its backend
```

Стандартный репозиторий — стандартная установка:

```
$ sudo apt install isc-dhcp-server
Чтение списков пакетов… Готово
Построение дерева зависимостей… Готово
Чтение информации о состоянии… Готово
Будут установлены следующие дополнительные пакеты:
  libirs-export161 libisccfg-export163 policycoreutils selinux-utils
...
```

После такой установки сервер уже присутствует, но он пока остановлен, что вполне естественно — перед 1-м запуском его нужно конфигурировать:

```
$ systemctl status isc-dhcp-server
● isc-dhcp-server.service - LSB: DHCP server
     Loaded: loaded (/etc/init.d/isc-dhcp-server; generated)
     Active: inactive (dead)
       Docs: man:systemd-sysv-generator(8)
```

После установки есть смысл определить какие сетевые интерфейсы будет прослушивать DHCP сервер и, соответственно, куда он будет отвечать:

```
$ ip l sh
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue state UNKNOWN mode DEFAULT group default
qlen 1000
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
2: enp3s0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP mode DEFAULT group
default qlen 1000
    link/ether 90:1b:0e:2b:fe:3a brd ff:ff:ff:ff:ff:ff

# tail -n3 /etc/default/isc-dhcp-server
#       Separate multiple interfaces with spaces, e.g. "eth0 eth1".
INTERFACESv4="enp3s0"
#INTERFACESv6="enp3s0"
```

Как видите из заготовки этого файла (созданного при установке `isc-dhcp-server`) а). сервер может обслуживать как DHCP4 так и DHCP6, б). можно выборочно указать интерфейсы на хосте со многими интерфейсами и в). по каждому протоколу можно указать по несколько (при необходимости)

2 BOOTP первоначально создавался и широко используется для начальной загрузки через сеть всяких разнообразных встраиваемых (embedded) и автономных устройств в не обслуживаемом режиме.

интерфейсов.

А сами конфигурации сервера находятся (если этот путь не переопределен в файле `/etc/default/isc-dhcp-server`) в `/etc/dhcp/` :

```
# ls -l /etc/dhcp/dhcpd*.conf
-rw-r--r-- 1 root root 3331 окт  4  2022 /etc/dhcp/dhcpd6.conf
-rw-r--r-- 1 root root 3496 окт  4  2022 /etc/dhcp/dhcpd.conf
```

Конфигурационные файлы отлично прокомментированы (как это чаще всего и бывает в сетевых инструментах) и там из значащих полей нужно оставить и/или вписать, например для IPv4, что-то типа:

```
$ grep -v ^# /etc/dhcp/dhcpd.conf | grep -v ^$
default-lease-time 600;
max-lease-time 7200;
subnet 192.168.1.0 netmask 255.255.255.0 {
    option routers 192.168.1.3;
    option subnet-mask 255.255.255.0;
    option domain-name-servers 192.168.1.3,8.8.4.4,1.1.1.1;
    range 192.168.1.25 192.168.1.35;
    range 192.168.1.240 192.168.1.250;
}
```

Здесь некоторые параметры записаны с предшествующим `option`, а другие без. Вот то что записано с `option` — это и будет передаваться клиенту в ответ на его запрос.

Здесь: `default-lease-time` и `max-lease-time` — время аренды выделенного IP в секундах, соответственно по умолчанию и максимальный лимит если клиент запросил явно; параметры подсети, шлюз по умолчанию для неё и список DNS серверов сети; `range` — диапазон IP из которого DHCP сервер, по своему усмотрению, выделяет в аренду IP на запрос клиента. Я специально показал 2 range участка чтобы было понятно, что диапазон аренды может быть «рваный» и состоять из нескольких участков.

Таких секций `subnet` может быть одна или несколько (например, для DHCP4 и DHCP6, или для нескольких разных подсетей).

Поскольку на практике конфигурирование DHCP сервера — дело трудоёмкое, хлопотное и требующее большой тщательности, проект предусматривает возможность автономной (без запуска) проверки подготовленного файла конфигурации на отсутствие ошибок синтаксиса.

```
# which dhcpd
/usr/sbin/dhcpd
```

Правим файл конфигурации до тех пор пока не получим что-то подобное (сообщения с отсутствующими ошибками):

```
# dhcpd -t -cf /etc/dhcp/dhcpd.conf
Internet Systems Consortium DHCP Server 4.4.1
Copyright 2004-2018 Internet Systems Consortium.
All rights reserved.
For info, please visit https://www.isc.org/software/dhcp/
Config file: /etc/dhcp/dhcpd.conf
Database file: /var/lib/dhcp/dhcpd.leases
PID file: /var/run/dhcpd.pid
```

Вот теперь всё готово чтобы запустить приготовленный сервер (**предупреждение:** если вы не конфигурировали нормально файл /etc/dhcp/dhcpd6.conf, а мы по тексту этого не делали — то закомментируйте интерфейс IPv6 в /etc/default/isc-dhcp-server, без этого DHCP сервер не стартует, он завершится фатально на старте DHCP6!)

```
$ sudo systemctl start isc-dhcp-server
$ sudo systemctl status isc-dhcp-server
● isc-dhcp-server.service - LSB: DHCP server
     Loaded: loaded (/etc/init.d/isc-dhcp-server; generated)
     Active: active (running) since Sun 2023-04-23 13:33:10 EEST; 17s ago
       Docs: man:systemd-sysv-generator(8)
```

```
     Process: 14925 ExecStart=/etc/init.d/isc-dhcp-server start (code=exited, status=0/SUCCESS)
      Tasks: 4 (limit: 14232)
     Memory: 4.4M
        CPU: 42ms
     CGroup: /system.slice/isc-dhcp-server.service
             └─14941 /usr/sbin/dhcpd -4 -q -cf /etc/dhcp/dhcpd.conf enp3s0

апр 23 13:33:08 esprimop420 systemd[1]: Starting LSB: DHCP server...
апр 23 13:33:08 esprimop420 isc-dhcp-server[14925]: Launching IPv4 server only.
апр 23 13:33:08 esprimop420 dhcpd[14941]: Wrote 0 leases to leases file.
апр 23 13:33:08 esprimop420 dhcpd[14941]: Server starting service.
апр 23 13:33:10 esprimop420 isc-dhcp-server[14925]: Starting ISC DHCPv4 server: dhcpd.
апр 23 13:33:10 esprimop420 systemd[1]: Started LSB: DHCP server.

$ ps -A | grep dhcpd
  14941 ?        00:00:00 dhcpd
```

Всё! У вас работает собственный DHCP сервер!

Разрешение имён, служба DNS

Система доменных имен (DNS, domain name system) представляет собой распределенную систему хранения и обработки информации о доменных зонах. Она необходима, в первую очередь, для соотнесения (прямого и обратного) IP адресов устройств в сети и более удобных для человеческого восприятия удобочитаемых символьных имен.

Система доменных имён разработана в еще 80-х годах прошлого века и продолжает обеспечивать удобство работы с адресным пространством Интернета до сих пор. И естественно поэтому для неё существует множество тонких модификаций.

Организационно и топологически система DNS представляет собой иерархическую систему непрерывно работающих DNS-серверов. Во главе иерархии располагаются 13 DNS-серверов отвечающий за корневые зоны, с учётом дублирующих серверов, на самом деле, как утверждается, их 123. Они управляются различными операторами и организациями, что исключает сбои по подчинённости.

По логике работа системы DNS (на качественном уровне, «на пальцах») выглядит так:

- Для вашей LAN или для вашего хоста в LAN назначено (указанием их собственных IP) несколько (1, 2, 3, 4 … обычно не больше) DNS-серверов сети. Это назначение долгосрочное и может происходить самым разным образом: предоставляться вашим сетевым провайдером, назначаться вручную, при указании в NetworkManager и другие механизмы.
- Когда вы набираете URL в адресной строке браузера он через сетевой стек (сам браузер ничего не умеет — это общее свойство стека для всех сетевых приложений), он посылает запрос DNS-серверу сети в специальном сетевом DNS-протоколе. DNS-сервер сети, в свою очередь, либо отвечает сам (если этот URL ему известен), либо пересылает запрос по иерархии одному из доменных серверов более высокого уровня (или, в конце цепочки корневому серверу).
- Затем запрос начинает свое путешествие – корневой сервер пересылает его серверу первого уровня (поддерживающего, например, доменную зону .ru). Тот – серверу второго уровня в запрошенном URL (отделяемых точкой), и так далее, пока не найдется сервер, который точно знает запрошенное имя и адрес, либо выясняется, что такого имени не существует вообще.
- После получения ответа запрос начинает движение обратно ровно по тому же пути, только в обратной последовательности.
- Практически все сервера в узлах этой иерархии являются кэширующими, локально запоминают часто повторяющиеся имена в потоке запросов, поэтому вся названная выше цепочка оказывается многократно короче — популярные Интернет имена разрешаются на первых уровнях иерархии из локального кэша очередного сервера.

Сам DNS-протокол может базироваться либо на UDP, либо на TCP транспорте (на ранних этапах это был только UDP), и использует по умолчанию порт 53 (и в UDP и в TCP — раньше мы уже говорили что порты UDP и TCP это очень разные вещи и могут быть численно равны).

Вот на качественном уровне описание DNS того уровня детализации, которой достаточно для конкретизации темы использования DNS.

Из сказанного главным является следующие требования к DNS:

- Работа его должна быть бесперебойная 24x365 (всё время работы хоста);
- Обслуживание запросов должно быть как можно быстрее — именно оно определяет, во многом, «темп» работы хоста с Интернет;

Локальный DNS резолвер bind

Уже несколько десятилетий классикой DNS резолвера является bind9. Вы можете найти его в репозитории используемого вами дистрибутива.

```
$ apt search bind9
p   bind9                                  - служба DNS
p   bind9:i386                             - служба DNS
p   bind9-dev                              - Static Libraries and Headers used by BIND 9
p   bind9-dev:i386                         - Static Libraries and Headers used by BIND 9
i   bind9-dnsutils                         - Clients provided with BIND 9
p   bind9-dnsutils:i386                    - Clients provided with BIND 9
p   bind9-doc                              - Documentation for BIND 9
p   bind9-dyndb-ldap                       - LDAP back-end plug-in for BIND
i   bind9-host                             - утилита для выполнения запросов DNS
p   bind9-host:i386                        - утилита для выполнения запросов DNS
i   bind9-libs                             - Shared Libraries used by BIND 9
p   bind9-libs:i386                        - Shared Libraries used by BIND 9
p   bind9-utils                            - Utilities for BIND 9
p   bind9-utils:i386                       - Utilities for BIND 9
p   bind9utils                             - Transitional package for bind9-utils
v   bind9utils:i386                        -
```

Что-то из его клиентов, почти наверняка, установлено у вас (по умолчанию) прямо при инсталляции Linux, и они используют список используемых DNS-серверов сети (о которых упоминалось ранее) из файла:

```
$ cat /etc/resolv.conf
# Generated by NetworkManager
nameserver 1.1.1.1
nameserver 8.8.8.8
nameserver 192.168.1.3
```

Это список DNS-серверов 1-го уровня к которому за разрешениями имён обращается с запросами сетевая подсистема вашего хоста. (Здесь, для большей общности, первые 2 IP указывают на DNS-сервера далеко в глобальной сети, а 3-й — на местном роутере, служащим шлюзом из локальной сети в глобальную. Таким образом, территориальность размещения, «далеко/близко», для работы резолвера DNS не имеет значения — что ему указали то он и использует.)

Идея локального резолвера состоит в том, что:

- Установить кэширующий сервер `bind9` на один из хостов LAN, скажем 192.168.1.53;
- Указать ему список DNS-серверов верхнего уровня подобный показанному;
- А для всех остальных хостов LAN указывать в качестве DNS-сервера сети 192.168.1.53;

Идея состоит в том, что для каждого пользователя массированная часть его запросов идёт к очень небольшому набору URL, и все они повторно будут разрешаться не выходя за пределы своей же локальной сети.

Я не буду показывать здесь установку и запуск `bind9` потому что:

- За долгие годы это многократно и подробно описано в публикациях;
- Сам `bind9` — это крупная громоздкая система, которую локально имеет смысл устанавливать только для LAN очень крупных организаций, насчитывающей многие десятки или даже сотни хостов.

- Мне важно зафиксировать сам принцип кэширующего DNS, который остаётся неизменным независимо от способа реализации — приблизить резолвер как можно ближе к месту создания запросов и тем радикально уменьшить время ожидания разрешения запроса.

Кэширующий DNS dnsmasq

Один из популярных кэширующих DNS для небольших сетей Dnsmasq — нетребовательный, простой в настройке DNS транслятор и DHCP сервер. Разработан для предоставления служб DNS и, дополнительно, DHCP для небольших сетей. Может обслуживать имена локальных машин не находящихся в глобальной DNS. DHCP сервер интегрирован с DNS сервером и позволяет машинам с адресами, полученными по DHCP, публиковать в DNS имена, заданные на самом хосте или в глобальном файле настроек. Dnsmasq поддерживает статическое и динамическое выделение адресов по DHCP, а также протокол BOOTP/TFTP для удалённой загрузки бездисковых машин.

Проект Dnsmasq за годы стал настолько популярным в Linux, что во многих дистрибутивах он установлен пакетной системой даже по умолчанию:

```
$ lsb_release -a
No LSB modules are available.
Distributor ID: Debian
Description:    Debian GNU/Linux 11 (bullseye)
Release:        11
Codename:       bullseye

$ aptitude search dnsmasq
p   dnsmasq                                 - Small caching DNS proxy and DHCP/TFTP server
i A dnsmasq-base                            - Small caching DNS proxy and DHCP/TFTP server
p   dnsmasq-base-lua                        - Small caching DNS proxy and DHCP/TFTP server
p   dnsmasq-utils                           - Utilities for manipulating DHCP leases
```

По крайней мере в его базовых компонентах …

```
$ aptitude show dnsmasq-base
Пакет: dnsmasq-base
Версия: 2.85-1
Состояние: установлен
Установлен автоматически: да
Приоритет: необязательный
Раздел: net
Сопровождающий: Simon Kelley <simon@thekelleys.org.uk>
Архитектура: amd64
Размер в распакованном виде: 963 k
Зависит: adduser, libc6 (>= 2.28), libdbus-1-3 (>= 1.9.14), libgmp10, libhogweed6 (>= 2.4-3),
libidn2-0 (>= 2.0.0), libnetfilter-conntrack3 (>=
         1.0.1), libnettle8 (>= 2.4-3)
Рекомендует: dns-root-data
Конфликтует: dnsmasq-base-lua
Ломает: dnsmasq (< 2.63-1~)
Заменяет: dnsmasq (< 2.63-1~), dnsmasq-base
Предоставляется: dnsmasq-base-lua (2.85-1)
Описание: Small caching DNS proxy and DHCP/TFTP server
 This package contains the dnsmasq executable and documentation, but not the infrastructure
required to run it as a system daemon. For that,
 install the dnsmasq package.
Домашняя страница: http://www.thekelleys.org.uk/dnsmasq/doc.html
Метки: admin::boot, admin::configuring, implemented-in::c, interface::daemon, network::server,
protocol::dhcp, protocol::dns, protocol::tftp,
       role::program, scope::utility, use::proxying
```

Для использования его как серверной службы нужно его доустановить до полного состава:

```
$ sudo apt install dnsmasq
Чтение списков пакетов… Готово
Построение дерева зависимостей… Готово
```

```
Чтение информации о состоянии… Готово
Предлагаемые пакеты:
  resolvconf
Следующие НОВЫЕ пакеты будут установлены:
  dnsmasq
Обновлено 0 пакетов, установлено 1 новых пакетов, для удаления отмечено 0 пакетов, и 1 пакетов не обновлено.
Необходимо скачать 32,0 kB архивов.
После данной операции объём занятого дискового пространства возрастёт на 120 kB.
Пол:1 http://deb.debian.org/debian bullseye/main amd64 dnsmasq all 2.85-1 [32,0 kB]
Получено 32,0 kB за 0с (226 kB/s)
Выбор ранее не выбранного пакета dnsmasq.
(Чтение базы данных … на данный момент установлено 351157 файлов и каталогов.)
Подготовка к распаковке …/dnsmasq_2.85-1_all.deb …
Распаковывается dnsmasq (2.85-1) …
Настраивается пакет dnsmasq (2.85-1) …
Created symlink /etc/systemd/system/multi-user.target.wants/dnsmasq.service → /lib/systemd/system/dnsmasq.service.
invoke-rc.d: policy-rc.d denied execution of start.

$ /sbin/dnsmasq -v
Dnsmasq version 2.85  Copyright (c) 2000-2021 Simon Kelley
Compile time options: IPv6 GNU-getopt DBus no-UBus i18n IDN2 DHCP DHCPv6 no-Lua TFTP conntrack ipset auth cryptohash DNSSEC loop-detect inotify dumpfile

This software comes with ABSOLUTELY NO WARRANTY.
Dnsmasq is free software, and you are welcome to redistribute it
under the terms of the GNU General Public License, version 2 or 3.

$ systemctl status dnsmasq
● dnsmasq.service - dnsmasq - A lightweight DHCP and caching DNS server
     Loaded: loaded (/lib/systemd/system/dnsmasq.service; enabled; vendor preset: enabled)
     Active: inactive (dead)
```

Дальше, как и для всех сетевых сервисов о чём и как уже говорилось ранее, предстоит конфигурировать и запустить сервис. Но, в данном случае (сервер DNS) предварительно следовало бы проверить какое разрешение имён DNS используется на хосте на данный момент, и убедиться не работает ли здесь уже какая-то система кэширования DNS:

```
$ cat /etc/resolv.conf
# Generated by NetworkManager
nameserver 1.1.1.1
nameserver 8.8.8.8
nameserver 192.168.1.3

$ nslookup linux-ru.ru | grep -i server
Server:         1.1.1.1
```

При установке `dnsmasq` создаётся структура его конфигурационных файлов. Заготовка файла `/etc/dnsmasq.conf` очень обстоятельная, и исчерпывающе в комментариях описывает конфигурирование, но все строки этого большого файла комментированы:

```
$ grep -v ^$ /etc/dnsmasq.conf | grep -v ^#
$ ls -l /etc/dnsmasq.conf
-rw-r--r-- 1 root root 27381 апр  4  2021 /etc/dnsmasq.conf
$ ls -l /etc/dnsmasq.d
итого 4
-rw-r--r-- 1 root root 211 апр  4  2021 README
```

Я бы в общем конфигурационном файле убрал знак комментария только с одной строки, а раздельные файлы конфигураций `/etc/dnsmasq.d`:

```
$ grep -v ^$ /etc/dnsmasq.conf | grep -v ^#
```

```
conf-dir=/etc/dnsmasq.d/,*.conf
```

А для DNS и DHCP сделал бы отдельные конфигурационные файлы `/etc/dnsmasq.d/dhcp.conf` и `/etc/dnsmasq.d/dns.conf` в каталог `/etc/dnsmasq.d`, скопировав в них, за основу, этот обстоятельный `/etc/dnsmasq.conf`, а дальше убрав комментарии только с нужных мне строк (это только иллюстрация для простых случаев, но ни в коем случаев не рекомендация для подражания):

```
$ ls /etc/dnsmasq.d/*.conf
/etc/dnsmasq.d/dhcp.conf  /etc/dnsmasq.d/dns.conf

$ grep -v ^$ /etc/dnsmasq.d/dhcp.conf | grep -v ^#
dhcp-range=192.168.1.30,192.168.1.45,255.255.255.0,12h   # объявляем диапазон адресов для аренды
dhcp-option=option:router,192.168.1.3                    # основной шлюз для этой под сети
log-dhcp                                                 # записывать отладочную информацию

$ grep -v ^$ /etc/dnsmasq.d/dns.conf | grep -v ^#
listen-address=127.0.0.1   # принимаем запросы на локальном адресе
interface=enp3s0           # слушать только эти интерфейсы (из LAN)
domain-needed                       # никогда не пересылать адреса без доменной части
bogus-priv                          # никогда не пересылать адреса
                                    # из немаршрутизируемого пространства
stop-dns-rebind                     # отклонять ответы от вышестоящих DNS серверов
                                    # с IP адресами локальной сети (блокировать DNS атаки)
rebind-localhost-ok                 # отключить проверки для 127.0.0.0/8
strict-order                        # пересылать запросы, с первого и по порядку
no-resolv                           # не использовать /etc/resolv.conf
no-hosts                            # не требуется читать /etc/hosts
domain=localdomain
local-ttl=7200                      # настройки времени жизни кэша в секундах 7200=2h (два часа)
neg-ttl=14400
max-ttl=86400
server=192.168.1.3                  # LAN router to WAN
server=8.8.4.4#53                   # google OpenDNS
server=4.2.2.6#53                   # Verizon DNS
```

Теперь можно запускать сконфигурированный сервер:

```
# systemctl start dnsmasq
# systemctl --no-pager --full status dnsmasq
● dnsmasq.service - dnsmasq - A lightweight DHCP and caching DNS server
     Loaded: loaded (/lib/systemd/system/dnsmasq.service; enabled; vendor preset: enabled)
     Active: active (running) since Tue 2023-04-25 15:17:26 EEST; 3min 59s ago
    Process: 19486 ExecStartPre=/etc/init.d/dnsmasq checkconfig (code=exited, status=0/SUCCESS)
    Process: 19494 ExecStart=/etc/init.d/dnsmasq systemd-exec (code=exited, status=0/SUCCESS)
    Process: 19505 ExecStartPost=/etc/init.d/dnsmasq systemd-start-resolvconf (code=exited,
status=0/SUCCESS)
   Main PID: 19504 (dnsmasq)
      Tasks: 1 (limit: 14232)
     Memory: 588.0K
        CPU: 44ms
     CGroup: /system.slice/dnsmasq.service
             └─19504 /usr/sbin/dnsmasq -x /run/dnsmasq/dnsmasq.pid -u dnsmasq -7
/etc/dnsmasq.d,.dpkg-dist,.dpkg-old,.dpkg-new --local-service --trust-
anchor=.,20326,8,2,e06d44b80b8f1d39a95c0b0d7c65d08458e880409bbc683457104237c7f8ec8d

 апр 25 15:17:26 esprimop420 systemd[1]: Starting dnsmasq - A lightweight DHCP and caching DNS
server...
 апр 25 15:17:26 esprimop420 dnsmasq[19504]: started, version 2.85 cachesize 150
 апр 25 15:17:26 esprimop420 dnsmasq[19504]: compile time options: IPv6 GNU-getopt DBus no-UBus
i18n IDN2 DHCP DHCPv6 no-Lua TFTP conntrack ipset auth cryptohash DNSSEC loop-detect inotify
dumpfile
 апр 25 15:17:26 esprimop420 dnsmasq-dhcp[19504]: DHCP, IP range 192.168.1.30 -- 192.168.1.45,
lease time 12h
```

```
апр 25 15:17:26 esprimop420 dnsmasq[19504]: using nameserver 4.2.2.6#53
апр 25 15:17:26 esprimop420 dnsmasq[19504]: using nameserver 8.8.4.4#53
апр 25 15:17:26 esprimop420 dnsmasq[19504]: using nameserver 192.168.1.3#53
апр 25 15:17:26 esprimop420 dnsmasq[19504]: cleared cache
апр 25 15:17:26 esprimop420 systemd[1]: Started dnsmasq - A lightweight DHCP and caching DNS server.
```

```
# cat /var/log/syslog | grep dnsmasq-dhcp
Apr 25 15:17:26 esprimop420 dnsmasq-dhcp[19504]: DHCP, IP range 192.168.1.30 -- 192.168.1.45, lease time 12h
```

Вот теперь мы можем поэкспериментировать с DNS сервером, и оценить что даёт нам факт кэширования…

Проверяем: разрешение через сетевой DNS (это Google DNS, из числа популярных и лучших), для 2-х произвольно взятых имён[3]:

```
$ host -v qnx.org.ru | grep Received
Received 44 bytes from 1.1.1.1#53 in 348 ms
Received 80 bytes from 1.1.1.1#53 in 60 ms
Received 57 bytes from 1.1.1.1#53 in 48 ms
$ host -v linux-ru.ru | grep Received
Received 45 bytes from 1.1.1.1#53 in 60 ms
Received 81 bytes from 1.1.1.1#53 in 64 ms
Received 77 bytes from 1.1.1.1#53 in 56 ms
```

А теперь делаем то же самое, но обращаясь за разрешением к только-что запущенному локальному кэширующему DNS. Делаем последовательно 2 запроса, парами (по 1-му локальный DNS обратится в сеть по иерархии, 2-й станет разрешаться из внутреннего кэша):

```
$ host -v linux-ru.ru 127.0.0.1 | grep Received
Received 45 bytes from 127.0.0.1#53 in 108 ms
Received 81 bytes from 127.0.0.1#53 in 128 ms
Received 77 bytes from 127.0.0.1#53 in 76 ms
$ host -v linux-ru.ru 127.0.0.1 | grep Received
Received 45 bytes from 127.0.0.1#53 in 0 ms
Received 29 bytes from 127.0.0.1#53 in 0 ms
Received 77 bytes from 127.0.0.1#53 in 56 ms
```

```
$ host -v qnx.org.ru 127.0.0.1 | grep Received
Received 44 bytes from 127.0.0.1#53 in 144 ms
Received 80 bytes from 127.0.0.1#53 in 76 ms
Received 57 bytes from 127.0.0.1#53 in 228 ms
$ host -v qnx.org.ru 127.0.0.1 | grep Received
Received 44 bytes from 127.0.0.1#53 in 0 ms
Received 28 bytes from 127.0.0.1#53 in 0 ms
Received 57 bytes from 127.0.0.1#53 in 44 ms
```

Видно насколько значительно ускоряется запрос разрешения имени, которое уже находится в кэше сервера. Остаётся вопрос: почему работает (успешно как видим) кэширующий DNS, но запросы по умолчанию (без явного указания сервера) идут по-прежнему к удалённым сетевым DNS? Потому что всё ещё:

```
$ cat /etc/resolv.conf
# Generated by NetworkManager
nameserver 1.1.1.1
nameserver 8.8.8.8
nameserver 192.168.1.3
```

Меняем:

```
$ cat /etc/resolv.conf
# Generated by NetworkManager
```

3 Команда host отправляет последовательно 3 запроса и получает 3 ответа для получения DNS записей, соответственно, типов: A (IPv4), AAAA (IPv6), MX (запись для электронной почты, указывающая, какими серверами она обрабатывается). Поэтому для оценки общего времени ответа можно использовать **сумму** этих 3-х значений.

```
nameserver 127.0.0.1
```

И теперь:

```
$ host -v linux-ru.ru | grep Received
Received 45 bytes from 127.0.0.1#53 in 0 ms
Received 29 bytes from 127.0.0.1#53 in 0 ms
Received 77 bytes from 127.0.0.1#53 in 60 ms
$ host -v qnx.org.ru | grep Received
Received 44 bytes from 127.0.0.1#53 in 0 ms
Received 28 bytes from 127.0.0.1#53 in 0 ms
Received 57 bytes from 127.0.0.1#53 in 40 ms
```

Наконец, пусть любой другой хост этой LAN запросит разрешение имени у этого вновь созданного DNS сервера:

```
$ host -v linux-ru.ru 192.168.1.138 | grep Received
Received 45 bytes from 192.168.1.138#53 in 116 ms
Received 81 bytes from 192.168.1.138#53 in 84 ms
Received 77 bytes from 192.168.1.138#53 in 1156 ms
$ host -v linux-ru.ru 192.168.1.138 | grep Received
Received 45 bytes from 192.168.1.138#53 in 4 ms
Received 29 bytes from 192.168.1.138#53 in 4 ms
Received 77 bytes from 192.168.1.138#53 in 72 ms
```

Показанные результаты позволяют убедиться в том, что использование локального кэширующего сервера DNS позволяет снизить задержку разрешения имени часто используемых URL в несколько десятков раз (в разных ситуациях автор наблюдал уменьшение времени ответов до 60 раз).

Кэширующий DNS средствами systemd

Первый выпуск проекта Dnsmasq относится к 2001 (последняя редакция 2.89 — это 04.02.2023). Успех проекта на протяжении 22 лет, наверное, и побудил разработчиков `systemd` (Lennart Poettering с сотоварищи) ввести функциональность кэширующего DNS непосредственно в состав системы управления сервисами Linux.

Запуск `systemd` встроенной системы кэшированного DNS я покажу, для разнообразия и убедительности, на микро-архитектуре ARM одноплатного (SoC — system on a chip) компьютера Raspberry Pi:

```
$ lsb_release -a
No LSB modules are available.
Distributor ID:  Raspbian
Description:     Raspbian GNU/Linux 11 (bullseye)
Release:         11
Codename:        bullseye
$ uname -a
Linux raspberrypi 6.1.21-v7+ #1642 SMP Mon Apr  3 17:20:52 BST 2023 armv7l GNU/Linux
```

Резолвер `systemd` носит название `systemd-resolved.service`, но в отличие от множества других сетевых сервисов-серверов (рассмотренных выше и тех которые будут ещё рассмотрены позже) **не требует инсталляции**! Он присутствует (установлен) в системе изначально, по умолчанию, вместе с самой подсистемой systemd, но не активирован:

```
$ systemctl status systemd-resolved.service --no-pager --full
● systemd-resolved.service - Network Name Resolution
     Loaded: loaded (/lib/systemd/system/systemd-resolved.service; disabled; vendor preset:
enabled)
     Active: inactive (dead)
       Docs: man:systemd-resolved.service(8)
             man:org.freedesktop.resolve1(5)
...
$ resolvectl status
Failed to get global data: Unit dbus-org.freedesktop.resolve1.service not found.
```

А разрешение имён в не модифицированной системе идёт традиционным образом, через список сетевых серверов DNS:

```
$ nslookup linux-ru.ru
Server:         1.1.1.1
Address:        1.1.1.1#53

Non-authoritative answer:
Name:   linux-ru.ru
Address: 90.156.230.27
$ cat /etc/resolv.conf
# Generated by resolvconf
nameserver 1.1.1.1
nameserver 8.8.8.8
```

Нам остаётся некоторым образом заполнить конфигурацию и запускать сервис. Конфигурация резолвера находится в /etc/systemd/resolved.conf, прекрасно документирована (в комментариях) и, в простейшем виде, туда достаточно заполнить только одну секцию:

```
$ grep -v ^# /etc/systemd/resolved.conf | grep -v ^$
[Resolve]
DNS=1.0.0.1 8.8.4.4 9.9.9.9
```

Всё! Можно запускать:

```
# systemctl start systemd-resolved.service
# systemctl status systemd-resolved.service --no-pager --full
● systemd-resolved.service - Network Name Resolution
     Loaded: loaded (/lib/systemd/system/systemd-resolved.service; disabled; vendor preset:
enabled)
     Active: active (running) since Tue 2023-04-18 15:00:59 EEST; 2s ago
       Docs: man:systemd-resolved.service(8)
             man:org.freedesktop.resolve1(5)
             https://www.freedesktop.org/wiki/Software/systemd/writing-network-configuration-
managers
             https://www.freedesktop.org/wiki/Software/systemd/writing-resolver-clients
   Main PID: 22564 (systemd-resolve)
     Status: "Processing requests..."
      Tasks: 1 (limit: 1595)
        CPU: 702ms
     CGroup: /system.slice/systemd-resolved.service
             └─22564 /lib/systemd/systemd-resolved

апр 18 15:00:58 raspberrypi systemd[1]: Starting Network Name Resolution...
апр 18 15:00:58 raspberrypi systemd-resolved[22564]: Positive Trust Anchors:
апр 18 15:00:58 raspberrypi systemd-resolved[22564]: . IN DS 20326 8 2
e06d44b80b8f1d39a95c0b0d7c65d08458e880409bbc683457104237c7f8ec8d
апр 18 15:00:58 raspberrypi systemd-resolved[22564]: Negative trust anchors: 10.in-addr.arpa
16.172.in-addr.arpa 17.172.in-addr.arpa 18.172.in-addr.arpa 19.172.in-addr.arpa 20.172.in-addr.arpa
21.172.in-addr.arpa 22.172.in-addr.arpa 23.172.in-addr.arpa 24.172.in-addr.arpa 25.172.in-addr.arpa
26.172.in-addr.arpa 27.172.in-addr.arpa 28.172.in-addr.arpa 29.172.in-addr.arpa 30.172.in-addr.arpa
31.172.in-addr.arpa 168.192.in-addr.arpa d.f.ip6.arpa corp home internal intranet lan local private
test
апр 18 15:00:59 raspberrypi systemd-resolved[22564]: Using system hostname 'raspberrypi'.
апр 18 15:00:59 raspberrypi systemd[1]: Started Network Name Resolution.
```

В итоге получаем:

```
$ ps -A | grep resolve
22564 ?        00:00:00 systemd-resolve
$ resolvectl status
Global
         Protocols: +LLMNR +mDNS -DNSOverTLS DNSSEC=no/unsupported
  resolv.conf mode: foreign
Current DNS Server: 1.0.0.1
```

```
       DNS Servers: 1.0.0.1 8.8.4.4 9.9.9.9

Link 2 (eth0)
Current Scopes: LLMNR/IPv4 LLMNR/IPv6
     Protocols: -DefaultRoute +LLMNR -mDNS -DNSOverTLS DNSSEC=no/unsupported

Link 3 (tun0)
Current Scopes: LLMNR/IPv6
     Protocols: -DefaultRoute +LLMNR -mDNS -DNSOverTLS DNSSEC=no/unsupported
```

И проверяем его работоспособность:

```
$ host -6 ya.ru 127.0.0.53
Using domain server:
Name: 127.0.0.53
Address: ::ffff:127.0.0.53#53
Aliases:

ya.ru has address 77.88.55.242
ya.ru has address 5.255.255.242
ya.ru has IPv6 address 2a02:6b8::2:242
ya.ru mail is handled by 10 mx.yandex.ru.
```

(Обращаем внимание, что резолвер `systemd` использует не вообще какой-то адрес петлевого интерфейса `localhost`, а выделенный для этого IP 127.0.0.53)

Но дефаултное разрешение, пока ещё, будет происходить через список адресов DNS серверов:

```
$ cat /etc/resolv.conf
# Generated by resolvconf
nameserver 1.1.1.1
nameserver 8.8.8.8
```

Один из вариантов состоит в том, чтобы заменить содержимое `/etc/resolv.conf` строкой:

```
nameserver 127.0.0.53
```

Но документация systemd рекомендует другой способ: сделать вместо `/etc/resolv.conf` ссылку на подготовленный файл `/run/systemd/resolve/stub-resolv.conf` (возможно сохранив старый `/etc/resolv.conf` под новым именем, типа `/etc/resolv.conf.old`, на всякий случай, на будущее):

```
# sudo ln -svi /run/systemd/resolve/stub-resolv.conf /etc/resolv.conf
ln: заменить '/etc/resolv.conf'? y
'/etc/resolv.conf' -> '/run/systemd/resolve/stub-resolv.conf'
$ grep -v ^# /etc/resolv.conf | grep -v ^$
nameserver 127.0.0.53
options eth0 trust-ad
search .
```

Проверяем:

```
$ host ya.ru
ya.ru has address 77.88.55.242
ya.ru has address 5.255.255.242
ya.ru has IPv6 address 2a02:6b8::2:242
ya.ru mail is handled by 10 mx.yandex.ru.
```

Оптимизация используемых серверов DNS

Как уже было замечено ранее, главная (и, пожалуй, единственная) задача пользователя DNS (мы не говорим о тех кто предоставляет услуги DNS) состоит в том, чтобы максимально ускорить получение ответов на запросы DNS. Ведь по большинству случаев пользователь (или пользователи LAN одной организации) занимаются сёрфингом по весьма ограниченной группе доменов и

субдоменов, связанных с их целевой деятельностью. А скорость отклика DNS и создаёт, в значительной мере, субъективное ощущение «быстрого Интернет».

Но, будь то простая сетевая схема разрешения через список серверов в /etc/resolv.conf, или любая изощрённая схема кэширования, запросы в иерархической системе запросов DNS, в конечном счёте, идут к тем нескольким серверам DNS, которые определены как сетевые сервера 1-го уровня для хоста. Адреса которых, в конечном итоге, мы вручную прописываем, например, в процессе конфигурирования кэширования DNS.

Очень часто в качестве серверов 1-го уровня ваш провайдер Интернет «подбрасывает» свои собственные сервера DNS. И это может быть совсем не плохое решение. С другой стороны вы можете самостоятельно выбрать адреса оптимальных серверов 1-го уровня, оптимальность которых определяется, например, вашим территориальным расположением и доступом к этим серверам. В любом случае стоит произвести анализ и выбор набора оптимальных серверов для своей ситуации. Здесь общие рекомендации не помогут!

Тестирование и сравнение скорости DNS (по порядку величины) можно производить и типовыми утилитами (`host`, `dig`, …), но нужно учитывать что время отклика DNS — величина статистическая. Для оценки скорости DNS сериями запросов, потому как это задача насущная, было сделано достаточно много приложений … но они, по большинству, для Windows/MacOS, а это нас не интересует. Один из пригодных проектов для тестирования может быть получен из архивов Google (`https://code.google.com/archive/p/namebench/downloads`), архив проекта:

```
$ ls -l namebench-1.3.1-source.tgz
-rw-rw-r-- 1 olej olej 1118505 апр 26 12:36 namebench-1.3.1-source.tgz
```

После разархивирования:

```
$ ls -l namebench-1.3.1
итого 272
-rw-r--r-- 1 olej olej 197383 июн  6  2010 ChangeLog.txt
drwxr-xr-x 4 olej olej   4096 июн  6  2010 cocoa
drwxr-xr-x 2 olej olej   4096 июн  6  2010 config
-rw-r--r-- 1 olej olej  11358 июн  6  2010 COPYING
drwxr-xr-x 2 olej olej   4096 июн  6  2010 data
-rw-r--r-- 1 olej olej   8601 июн  6  2010 JSON.txt
drwxr-xr-x 2 olej olej   4096 июн  6  2010 libnamebench
-rwxr-xr-x 1 olej olej   2477 июн  6  2010 namebench.py
drwxr-xr-x 8 olej olej   4096 июн  6  2010 nb_third_party
-rw-r--r-- 1 olej olej  12152 июн  6  2010 README.txt
-rw-r--r-- 1 olej olej   5268 июн  6  2010 setup.py
drwxr-xr-x 2 olej olej   4096 июн  6  2010 templates
drwxr-xr-x 2 olej olej   4096 июн  6  2010 tools
```

Программа написана на Python, поэтому не требует никакой сборки, а поэтому сразу готова к запуску. Программа может запускаться в консольном режиме и в графическом. Но, чтобы не разбираться с недокументированным консольным режимом и использовать GUI нужно в системе иметь установленной (или установить) языковую систему Tcl/Tk, 2 небольших пакета:

```
$ aptitude search tcl | grep ' tcl ' | grep ^i
i  tcl - Tool Command Language (default version) — shell
$ aptitude search python-tk | grep ^i
i  python-tk - Tkinter - Writing Tk applications with Python2
```

Программа достаточно старая (последняя версия 1.3.1 — середина 2010 года), но это не умаляет её достоинств и применимости. Единственная особенность, что написана она под Python2, что при запуске нужно теперь указывать явно:

```
$ python2 namebench.py
Starting Tk interface for namebench...
...
```

(Почему для тестирования были выбраны именно эти конкретно 3 сервера DNS? Потому что это сервера OpenNIC поддерживающие альтернативные DNS, о чём речь впереди, в последней части книги. Вы можете указать произвольное число тестируемых серверов, более того, включить в анализ крупнейших глобальных и региональных провайдеров DNS … но нужно учитывать, что время

тестирования значительное, при большом числе серверов может составлять несколько часов.)

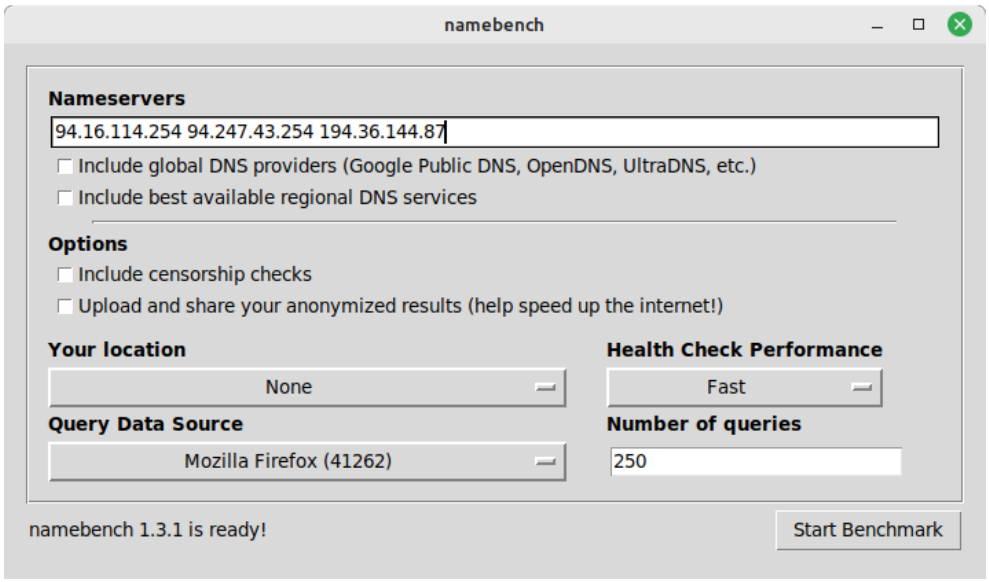

После завершения тестирования (достаточно продолжительного — в это время можно чем-то заняться) во вкладку открытого браузера отображается ранжированный список серверов по предпочтительности, и графики их временных откликов:

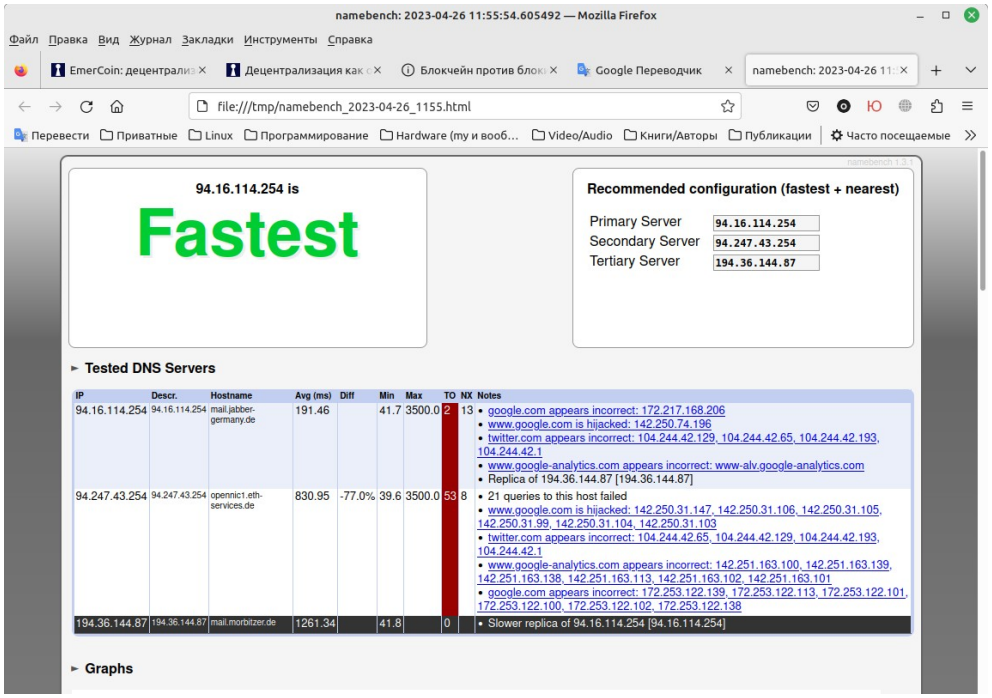

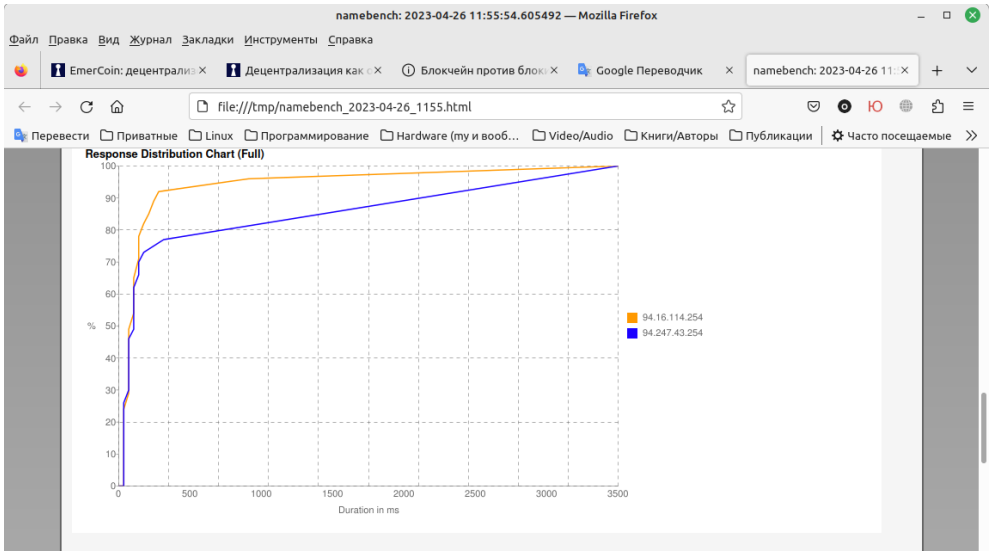

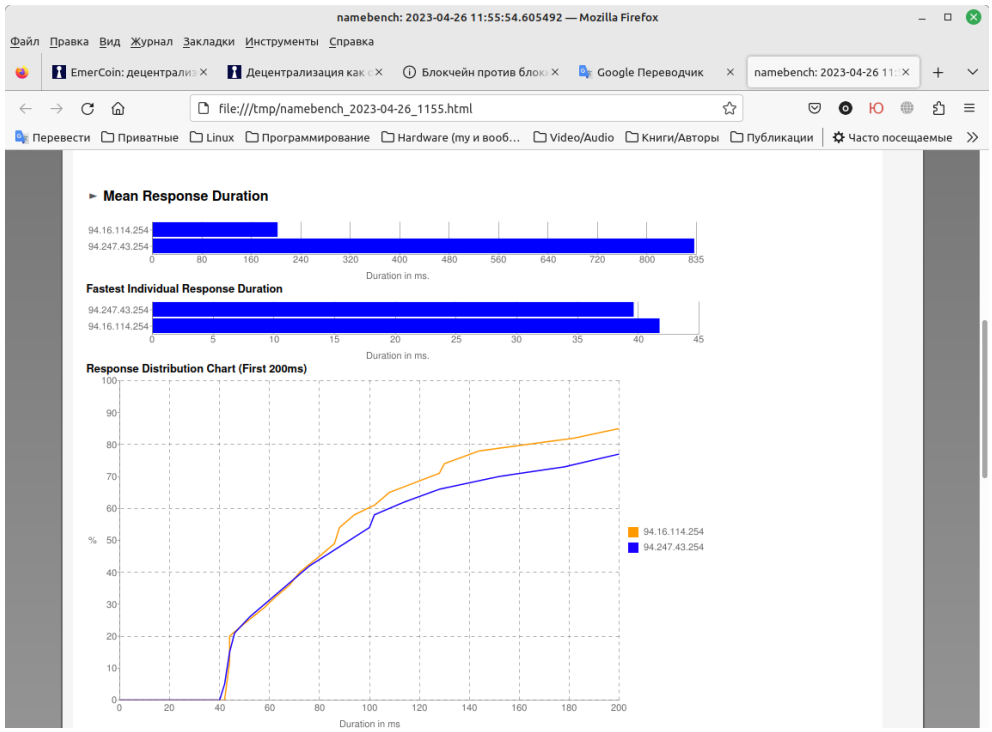

Защищённость сети, файервол

Здесь мы говорим о защищённости сети в смысле доступа к серверам или хостам локальной снаружи, из глобальной сети. Для локальных сетей IPv4 (традиционных и привычных на протяжении нескольких десятилетий) проблема смягчается использованием NAT: хосты локальной сети имеют частные IPv4 не маршрутизируемые адреса, и недоступны по этим адресам извне.

Но с переходом к IPv6 исчезает разделение адресов на «серые» и «белые», и локальные хосты могут быть доступны по IPv6 из любой точки мира. И, тем более, остро всегда стояла задача максимально ограничить доступ к отдельно стоящим серверам Интернет (кроме тех протоколов, для обслуживания которых и выделен сервер).

Управление доступностью адресов и портов на сегодня обеспечивается подсистемой ядра Linux `netfilter`, и его правил, для управления которыми используются утилита `iptables` (в разные времена в Linux для таких целей использовались подобные подсистемы под разными названиями: `ipchains`, `ipfw`, `ipfilter` — само обилие реализаций говорит о важности проблемы!). Утилита `iptables` устанавливается в системе автоматически, в составе инсталляции, даже если вы её не используете:

```
$ aptitude search iptables | grep ^i
i A iptables - утилита для фильтрации сетевых пакетов и NAT
```

Правила netfilter распределены по 4-м таблицам (filter, nat, mangle, raw), в целях файервола применяются манипуляции с таблицей filter. Каждая таблица состоит из цепочек (chain) правил, каждая таблица имеет свой предопределённый набор цепочек. Но сверх предопределённых цепочек могут создаваться и дополнительные. Для интересующей нас сейчас таблицы filter предопределённые цепочки — это INPUT (входящие пакеты), OUTPUT (исходящие) и FORWARD (транзитные).

Правила в цепочках применяются последовательно ко всем сетевым пакетам и могут запрещать или разрешать прохождение пакетов фильтруя их по разным признакам: IP адресата, порт и другим признакам.

Важно помнить, что правила netfilter выполняются в ядре Linux, и даже если мы удалим вообще из системы пакет iptables (или любой другой пакет управления netfilter, такие например, как firewall или это ufw), то правила фильтрации будут всё-равно выполняться, а для того чтобы правило или правила отменить нужно а). правило удалить, б). всю цепочку правил очистить, в). таблицу целиком очистить.

Правила цепочки и правила в цепочки можно добавлять (удалять, перемещать, управлять, диагностировать…) непосредственно самой утилитой iptables:

```
$ iptables --help
iptables v1.8.7

Usage: iptables -[ACD] chain rule-specification [options]
       iptables -I chain [rulenum] rule-specification [options]
       iptables -R chain rulenum rule-specification [options]
       iptables -D chain rulenum [options]
       iptables -[LS] [chain [rulenum]] [options]
       iptables -[FZ] [chain] [options]
       iptables -[NX] chain
       iptables -E old-chain-name new-chain-name
       iptables -P chain target [options]
       iptables -h (print this help information)
...
```

Понятно, что в силу своей важности для работоспособности сети вообще, все операции с правилами netfilter, даже просто просмотр правил, могут выполняться только с правами root.

Добавление правил посредством утилиты iptables — это подробное, тщательное (низкоуровневое), весьма трудоёмкое и требующее кропотливого (и достаточно сложного) тестирования функционирования. Изначально предопределённый цепочки правил пусты (не накладывается запретов):

```
$ sudo iptables -L -v -n
Chain INPUT (policy ACCEPT 0 packets, 0 bytes)
 pkts bytes target     prot opt in     out     source               destination

Chain FORWARD (policy ACCEPT 0 packets, 0 bytes)
 pkts bytes target     prot opt in     out     source               destination

Chain OUTPUT (policy ACCEPT 0 packets, 0 bytes)
 pkts bytes target     prot opt in     out     source               destination
```

Вот как, только в качестве нескольких примеров внешнего вида, могут выглядеть операции iptables над правилами netfilter:

- Просмотр правил трансляции адресов NAT:

```
# iptables -t nat -L –line-numbers
```

- Разрешить все исходящие пакеты (таблицу filter можно не указывать, она дефаутная):

```
# iptables -t filter -I OUTPUT 1 -j ACCEPT
```

- Запретить все входящие пакеты из подсети 10.10.10.0/24:

```
# iptables -t filter -A INPUT -s 10.10.10.0/24 -j DROP
```

- Разрешить SSH:

```
# iptables -A INPUT -p tcp --dport 22 -j ACCEPT
```

- Разрешить диапазон входящих портов TCP:

```
# iptables -A INPUT -p tcp --dport 3000:4000 -j ACCEPT
```

- Разрешаем ICMP (для выполнения команды ping):

```
# iptables -A INPUT -p icmp -j ACCEPT
```

Из показанного понятно, что команды `iptables` очень детализированы и подробны. Правила действуют до перезагрузки, должны сохраняться (предусмотрено несколько способов) и восстанавливаться при загрузке. Мы не будем детально углубляться в синтаксис и написание правил `iptables` потому как они многократно и полно документированы и описаны.

Отдельные дистрибутивы Linux вводят дополнительно свои, более высокоуровневые механизмы **управления** правилами (которые, сами правила, так и продолжают называться правилами `iptables`, и могут просматриваться утилитой `iptables`). Из таких подсистем в Fedora, RedHat, CentOS — это `firewall`, а в Debian, Ubuntu, Mint, LMDE — это `ufw`.

Файервол ufw

UFW (**U**ncomplicated **F**ire**W**all — несложный брандмауэр) — удобный интерфейс для управления политиками безопасности межсетевого экрана. Он выполняет, собственно, то что и `iptables`: формирует и загружает правила для `netfilter` в ядре.

```
$ aptitude search ufw
p   gufw                                        - графический интерфейс пользователя для ufw
p   ufw                                         - program for managing a Netfilter firewall

$ sudo apt install ufw
Чтение списков пакетов… Готово
Построение дерева зависимостей… Готово
Чтение информации о состоянии… Готово
Следующие НОВЫЕ пакеты будут установлены:
  ufw
...
```

При установке пакета создаётся сервис:

```
$ systemctl status ufw
● ufw.service - Uncomplicated firewall
     Loaded: loaded (/lib/systemd/system/ufw.service; enabled; vendor preset: enabled)
     Active: inactive (dead)
       Docs: man:ufw(8)
```

Именно он будет запускаться при загрузке системы и загружать составленные нами правила для `netfilter` (после загрузки правил этот сервис останавливается, в работающей системе он не нужен):

```
$ systemctl is-enabled ufw
enabled
```

Файервол может обслуживать как протокол IPv4 так и IPv4:

```
# grep IPV6 /etc/default/ufw
IPV6=yes
```

А для управления самими правилами используется утилита `ufw` (должна выполняться, естественно, от `root`), она же используется для активизации (поднятия) файервола и его отключения:

```
# ufw status
Status: inactive
# ufw enable
Command may disrupt existing ssh connections. Proceed with operation (y|n)? y
Firewall is active and enabled on system startup
# ufw status verbose
```

```
Status: active
Logging: on (low)
Default: deny (incoming), allow (outgoing), disabled (routed)
New profiles: skip
```

Это политики (изначальные) ufw по умолчанию: все выходные соединения разрешены, все входные соединения и форвардинг запрещены.

Посмотрим как работает файервол на примере протокола SSH, выполняем с соседнего хоста LAN (я специально использую адреса IPv6):

```
$ ssh -l olej fe80::921b:eff:fe2b:fe3a%eno1
ssh: connect to host fe80::921b:eff:fe2b:fe3a%eno1 port 22: Connection timed out
```

Теперь остановим файервол:

```
# ufw disable
Firewall stopped and disabled on system startup
```

И повторим сеанс SSH, теперь:

```
$ ssh -l olej fe80::921b:eff:fe2b:fe3a%eno1
olej@fe80::921b:eff:fe2b:fe3a%eno1's password:
Linux esprimop420 5.10.0-21-amd64 #1 SMP Debian 5.10.162-1 (2023-01-21) x86_64
Last login: Thu Apr 27 11:16:02 2023 from fe80::13f5:9fe2:6393:bf4a%enp3s0
olej@esprimop420:~$ exit
выход
Connection to fe80::921b:eff:fe2b:fe3a%eno1 closed.
```

Теперь о том как определяются правила, например, SSH:

```
# ufw allow OpenSSH
Rules updated
Rules updated (v6)
# ufw status numbered
Status: active

     To                         Action      From
     --                         ------      ----
[ 1] OpenSSH                    ALLOW IN    Anywhere
[ 2] OpenSSH (v6)               ALLOW IN    Anywhere (v6)
```

Добавлять можно указанием как числовых портов (TCP и/или UDP), так по именам стандартных сетевых служб, большой список которых предопределён в приложении:

```
# ufw app list
Available applications:
  AIM
  Bonjour
  CIFS
  CUPS
  DNS
  Deluge
  IMAP
  IMAPS
  IPP
  KTorrent
  Kerberos Admin
  Kerberos Full
  Kerberos KDC
  Kerberos Password
  LDAP
  LDAPS
  LPD
  MSN
  MSN SSL
  Mail submission
```

```
  NFS
  OpenSSH
  POP3
  POP3S
  PeopleNearby
  SMTP
  SSH
  Socks
  Telnet
  Transmission
  Transparent Proxy
  VNC
  WWW
  WWW Cache
  WWW Full
  WWW Secure
  XMPP
  Yahoo
  qBittorrent
  svnserve
```

Добавим ещё HTTP/HTTPS доступ:

```
# ufw allow in from any to any port 80,443,8080:8090 comment 'web app' proto tcp
Rule added
Rule added (v6)
# ufw status numbered
Status: active

     To                         Action      From
     --                         ------      ----
[ 1] OpenSSH                    ALLOW IN    Anywhere
[ 2] 80,443,8080:8090/tcp       ALLOW IN    Anywhere                   # web app
[ 3] OpenSSH (v6)               ALLOW IN    Anywhere (v6)
[ 4] 80,443,8080:8090/tcp (v6)  ALLOW IN    Anywhere (v6)              # web app
```

А вот так удаляем выбранное правило:

```
# ufw delete 4
Deleting:
 allow 80,443,8080:8090/tcp comment 'web app'
Proceed with operation (y|n)? y
Rule deleted (v6)
# ufw status
Status: active

To                         Action      From
--                         ------      ----
OpenSSH                    ALLOW       Anywhere
80,443,8080:8090/tcp       ALLOW       Anywhere                   # web app
OpenSSH (v6)               ALLOW       Anywhere (v6)
```

Синтаксис хорошо описан (man ufw) и допускает очень тонкое управление правилами. Запуск команды с опцией `--dry-run` не производит фактических изменений правил `netfilter`, но моделирует изменения и выводит на терминал набор создаваемых командой правил в терминологии `iptables`.

Наконец, отметим что `ufw` не модифицирует предопределённые цепочки (INPUT, OUTPUT, FORWARD) таблицы filter, а добавляет свои, новые цепочки в таблицу, и довольно много:

```
# iptables -t filter -L | grep ^"Chain ufw-" | wc -l
32
```

Для удобства конфигурирования, если вы предпочитаете такую форму, можно установить и графический (GUI) инструмент:

```
# apt install gufw
Чтение списков пакетов… Готово
Построение дерева зависимостей… Готово
Чтение информации о состоянии… Готово
Следующие НОВЫЕ пакеты будут установлены:
  gufw
Обновлено 0 пакетов, установлено 1 новых пакетов, для удаления отмечено 0 пакетов, и 0 пакетов не обновлено.
Необходимо скачать 876 kB архивов.
После данной операции объём занятого дискового пространства возрастёт на 3.538 kB.
Пол:1 http://deb.debian.org/debian bullseye/main amd64 gufw all 20.04.1-1 [876 kB]
Получено 876 kB за 0с (2.559 kB/s)
Выбор ранее не выбранного пакета gufw.
(Чтение базы данных … на данный момент установлено 351300 файлов и каталогов.)
Подготовка к распаковке …/gufw_20.04.1-1_all.deb …
Распаковывается gufw (20.04.1-1) …
Настраивается пакет gufw (20.04.1-1) …
Обрабатываются триггеры для mailcap (3.69) …
Обрабатываются триггеры для desktop-file-utils (0.26-1) …
Обрабатываются триггеры для hicolor-icon-theme (0.17-2) …
Обрабатываются триггеры для man-db (2.9.4-2) …
```

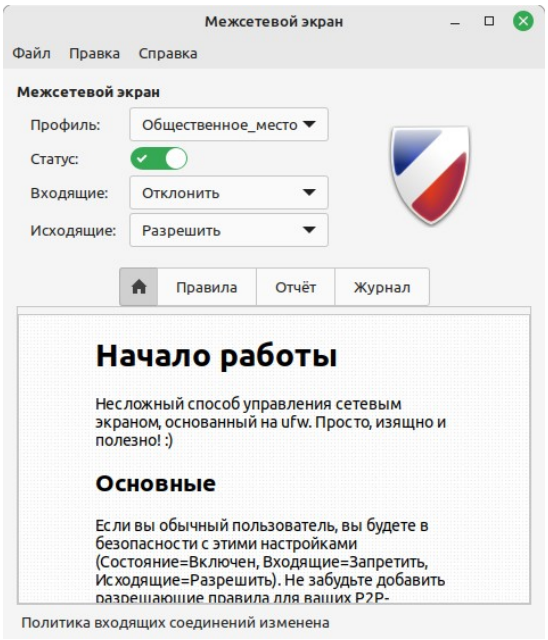

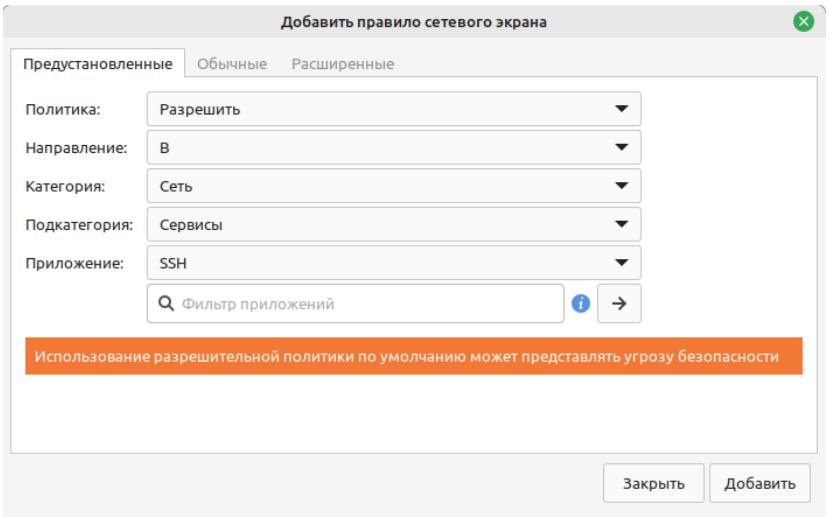

В результате последовательно формируется набор правил, что, вообще то говоря, эквивалентно тому, как мы генерировали эти же правила консольной утилитой `ufw`:

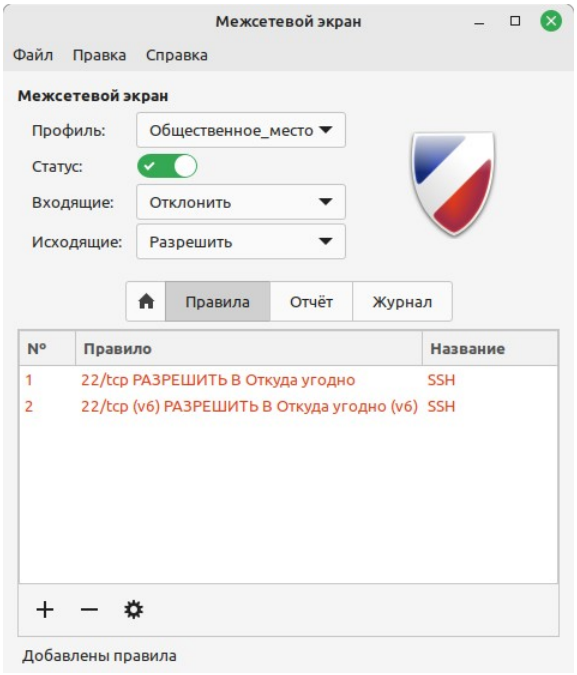

Суперсервер inetd

Ещё с самых ранних UNIX (практически с 80-х годов) сложилась практика для предоставления ряда сетевых сервисов с помощью суперсервера. Идея состоит в том, что, вместо запуска многих серверов разных сервисов и на разных портах, одна программа-демон ожидает одновременно запросы на соединения с множеством адресов портов. Когда клиент подключается к прослушивающему сервису, программа-демон запускает соответствующий сервер как дочерний процесс, и продолжает прослушивание запросов дальше. При таком подходе серверам не нужно работать постоянно и потреблять ресурсы, они могут запускаться по требованию.

Такая программа-демон получила название суперсервер (сервер запускающий другие сервера). В качестве суперсерверов используется более давний проект `inetd` (Internet Service Daemon) или его более позднее развитие `xinetd` (Extended Internet Service Daemon) … для наших целей сейчас это не имеет значения, и я покажу использование на примере `inetd` (дистрибутив LMDE5):

```
$ cat /etc/debian_version
11.2
$ aptitude search inetd | grep ^i
i A openbsd-inetd - OpenBSD Internet Superserver
i  update-inetd - программа обновления файла настройки inetd
$ aptitude search xinetd | grep -v xinetd$
p  xinetd - replacement for inetd with many enhancements
p  xinetd:i386 - replacement for inetd with many enhancements
```

То какие порты прослушивать (быть в готовности) и какие действия на них выполнять определяется в конфигурационном файле суперсервера: для `inetd` это `/etc/inetd.conf`, а для `xinetd`, соответственно, `/etc/xinetd.conf` — форматы конфигурационных файлов `inetd.conf` и `xinetd.conf` радикально отличаются, хотя, по сути, служат одной цели. В `inetd.conf` каждой службе соответствует одна строка записи, и формат такой строки (взято непосредственно из комментария `inetd.conf`):

```
# <service_name> <sock_type> <proto> <flags> <user> <server_path> <args>
```

Здесь:

`<service_name>` - имя сервиса;

`<sock_type>` - тип сокета, это `stream` для TCP или `dgram` для UDP;

<proto> - протокол … это может быть, например: tcp, tcp4, tcp6;

<flags> - это wait или nowait;

<user> - имя пользователя от лица которого запускается сервер;

<server_path> - путевое имя запускаемого сервера;

<args> - параметры которые нужно (возможно) передать серверу при запуске:

Имена имя сервисов (<service_name>) — это то, что мы уже видели раньше в большом файле /etc/services — имена сервисоа известные системе, например:

```
$ cat /etc/services | grep telnet
telnet          23/tcp
telnets         992/tcp                         # Telnet over SSL
tfido           60177/tcp                       # fidonet EMSI over telnet
```

Раньше, достаточно много лет назад, в поле <server_path> (или в публикациях тех лет) вы прочитали бы: /usr/sbin/in.proftpd или /usr/sbin/in.telnetd, и это были прямые путевые имена программ серверов (или ссылки на них). Но сейчас в качестве сервера записывают /usr/sbin/tcpd — это демон tcpd (система TCP-Wrappers)[4]. Его смысл в аутентификации доступа к сервисам через файлы /etc/hosts.allow и /etc/hosts.deny:

```
$ ls -l /etc/hosts.*
-rw-r--r-- 1 root root 411 мар 11  2022 /etc/hosts.allow
-rw-r--r-- 1 root root 711 мар 11  2022 /etc/hosts.deny
```

А вот последний параметр <args> и будет полным путевым именем сервера службы, он передаётся демону tcpd в качестве параметра «кого запускать».

Теперь у нас готово всё чтобы проверить это в деле...

Сервер telnet

В качестве образца для экспериментов мы выберем сервис telnet. Это, пожалуй, старейший протокол удалённого доступа не только в UNIX, но вообще в IT, возникший ещё в этоху связи по сериальным линиям скорости 9600 бит/сек. Со временем telnet, как не шифрованный протокол, заменил SSH. Кто-то может удивиться: «Почему telnet?», или даже: «Фу, telnet!». Но:

- telnet вполне применим и уместен при административных операциях внутри локальной сети;

- telnet замечательный тестер для проверки открытых портов в сети и коннекта к ним (например, все TCP порты WEB-серверов, что мы уже неоднократно делали по тексту);

- telnet, и это самое главное, предельно прост и проверка сокетной активации на нём ничем не замутнена и максимально понятна;

Установим интересующие нас пакеты, клиент и сервер протокола telnet (хотя клиент, скорее всего, уже установлен в системе совсем для других нужд):

```
$ sudo apt install telnet telnetd
Чтение списков пакетов… Готово
Построение дерева зависимостей… Готово
Чтение информации о состоянии… Готово
Будут установлены следующие дополнительные пакеты:
  openbsd-inetd tcpd
Следующие НОВЫЕ пакеты будут установлены:
  openbsd-inetd tcpd telnet telnetd
Обновлено 0 пакетов, установлено 4 новых пакетов, для удаления отмечено 0 пакетов, и 0 пакетов не обновлено.
Необходимо скачать 177 kB архивов.
После данной операции объём занятого дискового пространства возрастёт на 497 kB.
Хотите продолжить? [Д/н] y
Пол:1 http://deb.debian.org/debian bullseye/main amd64 tcpd amd64 7.6.q-31 [23,8 kB]
Пол:2 http://deb.debian.org/debian bullseye/main amd64 openbsd-inetd amd64 0.20160825-5 [36,8 kB]
Пол:3 http://deb.debian.org/debian bullseye/main amd64 telnet amd64 0.17-42 [71,1 kB]
```

4 Хотя во внутренней надёжной сети вполне работоспособен и старый способ с прямым указанием путевых имён серверов.

```
Пол:4 http://deb.debian.org/debian bullseye/main amd64 telnetd amd64 0.17-42 [45,4 kB]
Получено 177 kB за 0с (747 kB/s)
Выбор ранее не выбранного пакета tcpd.
(Чтение базы данных … на данный момент установлено 351726 файлов и каталогов.)
Подготовка к распаковке …/tcpd_7.6.q-31_amd64.deb …
Распаковывается tcpd (7.6.q-31) …
Выбор ранее не выбранного пакета openbsd-inetd.
Подготовка к распаковке …/openbsd-inetd_0.20160825-5_amd64.deb …
Распаковывается openbsd-inetd (0.20160825-5) …
Выбор ранее не выбранного пакета telnet.
Подготовка к распаковке …/telnet_0.17-42_amd64.deb …
Распаковывается telnet (0.17-42) …
Выбор ранее не выбранного пакета telnetd.
Подготовка к распаковке …/telnetd_0.17-42_amd64.deb …
Распаковывается telnetd (0.17-42) …
Настраивается пакет telnet (0.17-42) …
update-alternatives: используется /usr/bin/telnet.netkit для предоставления /usr/bin/telnet
(telnet) в автоматическом режиме
Настраивается пакет tcpd (7.6.q-31) …
Настраивается пакет openbsd-inetd (0.20160825-5) …
invoke-rc.d: policy-rc.d denied execution of start.
Created symlink /etc/systemd/system/multi-user.target.wants/inetd.service →
/lib/systemd/system/inetd.service.
/usr/sbin/policy-rc.d returned 101, not running 'start inetd.service'
Настраивается пакет telnetd (0.17-42) …
Добавление пользователя telnetd в группу utmp
invoke-rc.d: policy-rc.d denied execution of start.
Обрабатываются триггеры для man-db (2.9.4-2) …
```

Очень характерно, что в этой инсталляции устанавливаются, по зависимостям, и суперсервер `openbsd-inetd` и TCP-wraper `tcpd` (это значит, что в этой системе мы ещё не пользовали сервисов активируемых через суперсервер). Кроме того, автоматически создался пользователь `telnetd`.

```
$ cat /etc/passwd | grep telnet
telnetd:x:120:130::/nonexistent:/usr/sbin/nologin
```

Сразу же создадим нужные нам записи в конфигурационный файл:

```
$ grep -v ^# /etc/inetd.conf | grep -v ^$
telnet          stream  tcp4    nowait  telnetd /usr/sbin/tcpd  /usr/sbin/in.telnetd
telnet          stream  tcp6    nowait  telnetd /usr/sbin/tcpd  /usr/sbin/in.telnetd
```

Старт суперсервера:

```
# systemctl start inetd
# systemctl status inetd
● inetd.service - Internet superserver
     Loaded: loaded (/lib/systemd/system/inetd.service; enabled; vendor preset: enabled)
     Active: active (running) since Thu 2023-04-27 19:40:57 EEST; 5s ago
       Docs: man:inetd(8)
   Main PID: 6382 (inetd)
      Tasks: 1 (limit: 14232)
     Memory: 704.0K
        CPU: 3ms
     CGroup: /system.slice/inetd.service
             └─6382 /usr/sbin/inetd

апр 27 19:40:57 esprimop420 systemd[1]: Starting Internet superserver...
апр 27 19:40:57 esprimop420 systemd[1]: Started Internet superserver.
```

Наш сетевой интерфейс, контролируемый со стороны суперсервера `inetd`:

```
$ ip a s dev enp3s0
```

```
2: enp3s0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP group default qlen
1000
    link/ether 90:1b:0e:2b:fe:3a brd ff:ff:ff:ff:ff:ff
    inet 192.168.1.138/24 brd 192.168.1.255 scope global dynamic noprefixroute enp3s0
       valid_lft 96177sec preferred_lft 96177sec
    inet6 fe80::921b:eff:fe2b:fe3a/64 scope link
       valid_lft forever preferred_lft forever
```

Вот взгляд со стороны серверного хоста на прослушиваемые (ожидающие) порты `telnet`:

```
# netstat -lptu | grep telnet
tcp        0      0 0.0.0.0:telnet          0.0.0.0:*               LISTEN      6382/inetd
tcp6       0      0 [::]:telnet             [::]:*                  LISTEN      6382/inetd
```

Теперь взглянем на это интерфейс со стороны любого другого хоста этой локальной сети:

```
$ nmap 192.168.1.138
Starting Nmap 7.80 ( https://nmap.org ) at 2023-04-27 18:45 EEST
Nmap scan report for 192.168.1.138
Host is up (0.011s latency).
Not shown: 997 closed ports
PORT   STATE SERVICE
22/tcp open  ssh
23/tcp open  telnet
53/tcp open  domain

Nmap done: 1 IP address (1 host up) scanned in 0.25 seconds
```

Или вот так:

```
$ nmap -6 fe80::921b:eff:fe2b:fe3a%eno1
Starting Nmap 7.80 ( https://nmap.org ) at 2023-04-27 18:49 EEST
Nmap scan report for fe80::921b:eff:fe2b:fe3a
Host is up (0.0064s latency).
Not shown: 997 closed ports
PORT   STATE SERVICE
22/tcp open  ssh
23/tcp open  telnet
53/tcp open  domain

Nmap done: 1 IP address (1 host up) scanned in 1.51 seconds
```

И, наконец, с этого же хоста LAN — долгожданная удалённая терминальная сессия по `telnet`, из-за которой мы всё это и городили. И проведём мы её умышленно в протоколе IPv6 (назло недоброжелателям, утверждающим что `inetd` не работает с протоколами IPv6):

```
$ telnet -6 fe80::921b:eff:fe2b:fe3a%eno1
Trying fe80::921b:eff:fe2b:fe3a%eno1...
Connected to fe80::921b:eff:fe2b:fe3a%eno1.
Escape character is '^]'.
Debian GNU/Linux 11
esprimop420 login: olej
Password:
Linux esprimop420 5.10.0-21-amd64 #1 SMP Debian 5.10.162-1 (2023-01-21) x86_64

The programs included with the Debian GNU/Linux system are free software;
the exact distribution terms for each program are described in the
individual files in /usr/share/doc/*/copyright.

Debian GNU/Linux comes with ABSOLUTELY NO WARRANTY, to the extent
permitted by applicable law.
Last login: Thu Apr 27 11:27:20 EEST 2023 from fe80::13f5:9fe2:6393:bf4a%enp3s0 on pts/2
olej@esprimop420:~$ who
```

```
olej     tty7         2023-04-26 22:25 (:0)
olej     pts/0        2023-04-27 08:33 (192.168.1.13)
olej     pts/1        2023-04-27 10:31 (192.168.1.13)
olej     pts/3        2023-04-27 20:01 (fe80::13f5:9fe2:6393:bf4a%enp3s0)
olej@esprimop420:~$ exit
выход
Connection closed by foreign host.
```

P.S. Я умышленно выполнил на удалённом хосте команду `who`: здесь 1-я строка — это графическая сессия, окружение рабочего стола Cinnamon с которым загрузился компьютер, следующие 2 строки — это 2 SSH терминальные сессии, в которых я правлю конфиги, запускаю программы и копирую их результаты, а вот 4-я строка — это и есть `telnet` сессия в протоколе IPv6.

Сокетная активация в systemd

Точно так же, как и с кэширующим сервером DNS, разработчики `systemd` (Lennart Poettering с сотоварищи) не могли пройти мимо 40-летней истории успеха суперсерверов и запуска сервисов по сетевым запросам. В `systemd` этот способ запуска серверов получил название сокет-активации и его описание занимает в документации целую большую главу.

В каталоге сервисов systemd есть несколько сценариев запуска сокетной активации. В принципе, мы могли бы рассматривать и использовать сценарии для SSH:

```
$ pwd
/usr/lib/systemd/system
$ ls ssh*
ssh.service  ssh@.service  ssh.socket
```

(Здесь 1-й сценарий `ssh.service` мы уже встречали раньше — это традиционный сценарий запуска SSH сервера, а вот 2 следующих: `ssh@.service` и `ssh.socket` — именно относятся к сокетной активации.)

Но для чистоты эксперимента мы создадим схему сокетной активации совсем другого сервера, которого не по умолчанию под управлением `systemd`, а именно — сервера протокола FTP (попутно вспомним ещё один из популярных протоколов Интернет, которому незаслуженно не уделили внимания раньше).

О признанной популярности протокола FTP говорит хотя бы просто перечень пакетов в репозиториях дистрибутивов:

```
$ aptitude search ftpd | grep -v tftp
p  ftpd - FTP-сервер
p  ftpd-ssl - FTP-сервер с поддержкой SSL
p  fusiondirectory-plugin-pureftpd - pureftpd plugin for FusionDirectory
p  fusiondirectory-plugin-pureftpd-schema - LDAP schema for FusionDirectory pureftpd plugin
p  gosa-plugin-pureftpd - pureftpd plugin for GOsa²
p  gosa-plugin-pureftpd-schema - LDAP schema for GOsa² pureftpd plugin
p  inetutils-ftpd - Сервер FTP
p  inetutils-ftpd:i386 - Сервер FTP
p  mysqmail-pure-ftpd-logger - real-time logging system in MySQL - Pure-FTPd traffic-logger
p  nordugrid-arc-gridftpd - ARC GridFTP server
p  owftpd - FTP daemon providing access to 1-Wire networks
v  proftpd -
v  proftpd-abi-1.3.7c -
p  proftpd-basic - Transitional dummy package for ProFTPD
p  proftpd-core - Versatile, virtual-hosting FTP daemon - binaries
p  proftpd-dev - Versatile, virtual-hosting FTP daemon - development files
p  proftpd-doc - Versatile, virtual-hosting FTP daemon - documentation
p  proftpd-mod-autohost - ProFTPD module mod_autohost
p  proftpd-mod-case - ProFTPD module mod_case
p  proftpd-mod-clamav - ProFTPD module mod_clamav
p  proftpd-mod-counter - ProFTPD module mod_counter
p  proftpd-mod-crypto - Versatile, virtual-hosting FTP daemon - TLS/SSL/SFTP modules
v  proftpd-mod-dnsbl -
p  proftpd-mod-fsync - ProFTPD module mod_fsync
```

```
p  proftpd-mod-geoip - Versatile, virtual-hosting FTP daemon - GeoIP module
p  proftpd-mod-geoip2 - ProFTPD module mod_geoip2
p  proftpd-mod-ldap - Versatile, virtual-hosting FTP daemon - LDAP module
p  proftpd-mod-msg - ProFTPD module mod_msg
p  proftpd-mod-mysql - Versatile, virtual-hosting FTP daemon - MySQL module
p  proftpd-mod-odbc - Versatile, virtual-hosting FTP daemon - ODBC module
p  proftpd-mod-pgsql - Versatile, virtual-hosting FTP daemon - PostgreSQL module
p  proftpd-mod-proxy - ProFTPD module mod_proxy
p  proftpd-mod-snmp - Versatile, virtual-hosting FTP daemon - SNMP module
p  proftpd-mod-sqlite - Versatile, virtual-hosting FTP daemon - SQLite3 module
p  proftpd-mod-statsd - ProFTPD module mod_statsd
p  proftpd-mod-tar - ProFTPD module mod_tar
p  proftpd-mod-vroot - ProFTPD module mod_vroot
p  proftpd-mod-wrap - Versatile, virtual-hosting FTP daemon - tcpwrapper module
p  pure-ftpd - защищённый и эффективный FTP сервер
p  pure-ftpd-common - Pure-FTPd FTP server (Common Files)
p  pure-ftpd-ldap - защищённый и эффективный FTP-сервер с идентификацией пользователей через LDAP
p  pure-ftpd-mysql - Secure and efficient FTP server with MySQL user authentication
p  pure-ftpd-postgresql - Secure and efficient FTP server with PostgreSQL user authentication
p  python-pyftpdlib-doc - documentation for Python FTP server library
p  python3-pyftpdlib - Python FTP server library (Python 3)
p  twoftpd - простой и защищённый FTP-сервер (программы)
p  twoftpd-run - a simple secure efficient FTP server
p  vsftpd - легковесный, эффективный FTP-сервер, написанный с упором на безопасность
p  vsftpd-dbg - lightweight, efficient FTP server written for security (debug)
```

Как видим, представлено на выбор множество разных FTP серверов, можете выбрать для экспериментов любой (мне хорошо известны в разные годы `proftpd`, `vsftpd`, `pure-ftpd`, поэтому во избежание сюрпризов можете выбрать что-то из них):

```
$ sudo apt install pure-ftpd
Чтение списков пакетов… Готово
Построение дерева зависимостей… Готово
Чтение информации о состоянии… Готово
Следующие пакеты устанавливались автоматически и больше не требуются:
  libhiredis0.14 libmemcached11 libmemcachedutil2 proftpd-doc
Для их удаления используйте «sudo apt autoremove».
Будут установлены следующие дополнительные пакеты:
  openbsd-inetd pure-ftpd-common tcpd
Следующие пакеты будут УДАЛЕНЫ:
  proftpd-core
Следующие НОВЫЕ пакеты будут установлены:
  openbsd-inetd pure-ftpd pure-ftpd-common tcpd
...
```

Для организации сокетной активации этого сервера создадим 2 файла в каталоге сценариев `systemd` (всё это делаем с правами `root`):

```
# pwd
/usr/lib/systemd/system
# touch pure-ftpd.socket
# touch pure-ftpd@.service
```

И заполняем их следующим содержимым (сервис `proftpd` сам устанавливает при инсталляции свои сценарии сокетной активации, поэтому можете их взять за основу):

```
$ cat /usr/lib/systemd/system/pure-ftpd.socket
[Unit]
Description=pure-ftp FTP Server Activation Socket
Conflicts=pure-ftpd.service

[Socket]
```

```
ListenStream=21
Accept=true

[Install]
WantedBy=sockets.target
```

```
$ cat /usr/lib/systemd/system/pure-ftpd@.service
[Unit]
Description=pure-ftpd FTP Server
After=network-online.target

[Service]
ExecStart=-/usr/sbin/pure-ftpd
StandardInput=socket
```

Собственно, на этом всё! Но для таких экспериментов, или тестирования результатов своей работы, нужно тщательно **убедиться**, что никакой другой сервер FTP статически не конфигурирован в системе:

```
# systemctl status pure-ftpd
● pure-ftpd.service
     Loaded: loaded (/etc/init.d/pure-ftpd; generated)
     Active: active (exited) since Fri 2023-04-28 15:36:57 EEST; 1h 32min ago
       Docs: man:systemd-sysv-generator(8)
    Process: 19009 ExecStart=/etc/init.d/pure-ftpd start (code=exited, status=0/SUCCESS)
        CPU: 59ms

апр 28 15:36:57 R420 systemd[1]: Starting pure-ftpd.service...
апр 28 15:36:57 R420 pure-ftpd[19009]: Starting ftp server:
апр 28 15:36:57 R420 pure-ftpd[19019]: Running: /usr/sbin/pure-ftpd -l pam -E -J HIGH -u 1000 -O
clf:/var/log/pure-ftpd/transfer.log -B
апр 28 15:36:57 R420 systemd[1]: Started pure-ftpd.service.
апр 28 15:36:57 R420 pure-ftpd[19020]: (?@?) [ERROR] Unable to start a standalone server: [Address
already in use]
```

Это не должно быть сюрпризом: **все** проекты FTP стартуют сразу при инсталляции пакетов, в отличие от многих сервисов которые мы разбирали раньше!

```
# systemctl stop pure-ftpd
# systemctl status pure-ftpd
○ pure-ftpd.service
     Loaded: loaded (/etc/init.d/pure-ftpd; generated)
     Active: inactive (dead) since Fri 2023-04-28 17:10:20 EEST; 2s ago
       Docs: man:systemd-sysv-generator(8)
    Process: 19009 ExecStart=/etc/init.d/pure-ftpd start (code=exited, status=0/SUCCESS)
    Process: 22165 ExecStop=/etc/init.d/pure-ftpd stop (code=exited, status=0/SUCCESS)
        CPU: 26ms
...
```

P.S. Не ищите сценарии запуска и установки в привычном каталоге `/usr/lib/systemd/system` — серверы FTP помещают свои скрипты управления «в старом стиле» в каталог `/etc/init.d` (команды `systemd`, к счастью, умеют так же хорошо находить и работать с сервисами конфигурированными «в старом стиле»).

```
$ ls -l /etc/init.d/ | grep ftp
-rwxr-xr-x 1 root root 5322 сен 19  2021 proftpd
-rwxr-xr-x 1 root root 3172 янв 31  2022 pure-ftpd
```

Кроме непосредственно самих сервисов FTP нужно остановить и `inetd` (`xinetd`) чтобы избежать маскирующего запуска FTP средствами суперсервера:

```
# systemctl status inetd
● inetd.service - Internet superserver
```

```
     Loaded: loaded (/lib/systemd/system/inetd.service; enabled; vendor preset: enabled)
     Active: active (running) since Fri 2023-04-28 15:36:56 EEST; 1h 38min ago
       Docs: man:inetd(8)
   Main PID: 18954 (inetd)
      Tasks: 1 (limit: 115786)
     Memory: 548.0K
        CPU: 401ms
     CGroup: /system.slice/inetd.service
             └─18954 /usr/sbin/inetd

апр 28 15:36:56 R420 systemd[1]: Starting Internet superserver...
апр 28 15:36:56 R420 systemd[1]: Started Internet superserver.
# systemctl stop inetd
# systemctl status inetd
○ inetd.service - Internet superserver
     Loaded: loaded (/lib/systemd/system/inetd.service; enabled; vendor preset: enabled)
     Active: inactive (dead) since Fri 2023-04-28 17:15:25 EEST; 1s ago
       Docs: man:inetd(8)
    Process: 18954 ExecStart=/usr/sbin/inetd (code=exited, status=0/SUCCESS)
   Main PID: 18954 (code=exited, status=0/SUCCESS)
        CPU: 402ms
...
```

Окончательная проверка на чистоту эксперимента перед запуском созданного сервиса — здесь ничего не должно быть (в ответ):

```
# systemctl --full | grep ftp
# ps -A | grep ftp
```

Теперь запускаем свой сконфигурированный для FTP сервис (сокетной активации):

```
# systemctl start pure-ftpd.socket
# systemctl status pure-ftpd.socket
● pure-ftpd.socket - pure-ftp FTP Server Activation Socket
     Loaded: loaded (/lib/systemd/system/pure-ftpd.socket; disabled; vendor preset: enabled)
     Active: active (listening) since Fri 2023-04-28 17:14:27 EEST; 5s ago
     Listen: [::]:21 (Stream)
   Accepted: 0; Connected: 0;
      Tasks: 0 (limit: 115786)
     Memory: 8.0K
        CPU: 845us
     CGroup: /system.slice/pure-ftpd.socket

апр 28 17:14:27 R420 systemd[1]: Listening on pure-ftp FTP Server Activation Socket.
```

Всё! Сервер FTP в готовности и ожидании. Что мы и проверим с любого иного хоста LAN:

```
$ ftp 192.168.1.13
Connected to 192.168.1.13.
220---------- Welcome to Pure-FTPd [privsep] [TLS] ----------
220-You are user number 1 of 50 allowed.
220-Local time is now 17:19. Server port: 21.
220-IPv6 connections are also welcome on this server.
220 You will be disconnected after 15 minutes of inactivity.
Name (192.168.1.13:olej): olej
331 User olej OK. Password required
Password:
230 OK. Current directory is /home/olej
Remote system type is UNIX.
Using binary mode to transfer files.
ftp> pwd
257 "/home/olej" is your current location
ftp> system
```

```
215 UNIX Type: L8
ftp> exit
221-Goodbye. You uploaded 0 and downloaded 0 kbytes.
221 Logout.
```

Здесь показана полная FTP-сессия в режиме диалога, от её начала до конца, как она происходила на клиентском компьютере. А на сервере во время этой сессии посмотрим:

```
$ systemctl --full | grep ftp
   pure-ftpd@0-192.168.1.13:21-192.168.1.241:48136.service  loaded active running   pure-ftpd FTP
Server (192.168.1.241:48136)
   system-pure\x2dftpd.slice                                loaded active active    Slice
/system/pure-ftpd
   pure-ftpd.socket                                         loaded active listening pure-ftp FTP
Server Activation Socket
```

И наконец … «как вишенка на торте», я зайду по SSH на сервер `linux-ru.ru`, базирующийся за тысячи километров в Казахстане … как легко видеть, это арендуемый виртуальный сервер крупного регионального провайдера:

```
$ sudo inxi -Mxxx
Machine:   Type: Kvm System: QEMU product: Standard PC (i440FX + PIIX, 1996) v: pc-i440fx-bionic
serial: N/A Chassis: type: 1
           v: pc-i440fx-bionic serial: N/A
           Mobo: N/A model: N/A serial: N/A BIOS: SeaBIOS v: 1.13.0-1ubuntu1.1 date: 04/01/2014
$ ip -6 a s dev tun0
3: tun0: <POINTOPOINT,MULTICAST,NOARP,UP,LOWER_UP> mtu 53049 state UNKNOWN qlen 500
    inet6 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771/7 scope global
       valid_lft forever preferred_lft forever
    inet6 fe80::d86f:9577:d828:cb4d/64 scope link stable-privacy
       valid_lft forever preferred_lft forever
```

Это вот `ping` ICMPv6 к хосту локальной сети на которой я веду отработку FTP (через тысячи километров, местного провайдера Интернет, роутер-шлюз выхода из локальной сети в Интернет — это к вопросу грядущей «прозрачности» IPv6):

```
$ ping -c3 21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f
PING 21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f(21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f) 56 data bytes
64 bytes from 21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f: icmp_seq=1 ttl=64 time=426 ms
64 bytes from 21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f: icmp_seq=2 ttl=64 time=118 ms
64 bytes from 21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f: icmp_seq=3 ttl=64 time=118 ms

--- 21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 3ms
rtt min/avg/max/mdev = 117.950/220.699/426.072/145.220 ms
```

А вот клиентская сессия FTP в IPv6 из этого удалённого хоста к только что созданному серверу FTP с сокетной активацией:

```
$ ftp 21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f
Connected to 21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f.
220---------- Welcome to Pure-FTPd [privsep] [TLS] ----------
220-You are user number 1 of 50 allowed.
220-Local time is now 18:30. Server port: 21.
220 You will be disconnected after 15 minutes of inactivity.
Name (21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f:olej): olej
331 User olej OK. Password required
Password:
230 OK. Current directory is /home/olej
Remote system type is UNIX.
Using binary mode to transfer files.
ftp> exit
221-Goodbye. You uploaded 0 and downloaded 0 kbytes.
221 Logout.
```

Прокси-сервера

Дословно термин `proxy` — доверенное лицо. Принцип состоит в том, что клиент осуществляет запросы к целевому ресурсу не непосредственно, а как косвенные запросы через некоторый промежуточный прокси-сервер. Делается это с различными целями:

- Клиент может физически не иметь прямого доступа в Интернет, как это имеет место массово в локальных сетях (корпоративных, ведомственных), компьютеры которых имеют частные IPv4 адреса, не маршрутизируемые в сети. В такой архитектуре запросы направляются через прокси-сервер, являющийся для клиентов шлюзом в Интернет.
- Проксирование во внешней сети может использоваться для преодоления территориальных ограничений накладываемых организационно. Особенно возрастает такое использование в последнее время с разрушением цельности Интернет в результате военных действий, когда одни страны ограничивают трафик в или из других стран. В таких случаях прокси-сервер, расположенный в нейтральной зоне позволяет восстановить цельность.
- Прокси-сервер позволяет защищать компьютер клиента от некоторых сетевых атак снаружи.
- Прокси-сервер в некоторой (минимальной) степени помогает сохранять анонимность клиента.
- Очень часто прокси-сервер используют разнообразные мошенники и недоброжелатели для скрытия своего IP адреса (и, как следствие, средствами геолокации выяснения местоположения). Поэтому обнаружения факта проксирования, используемого клиентом, уже должно вызывать повышенную настороженность.

Проксирование (передача полномочий) может производится на разных уровнях протокола TCP/IP, в связи с этим и различают группы широко используемых прокси-серверов:

- Проксирование на уровне протоколов прикладных уровней. Здесь массово используемыми являются HTTP/HTTPS прокси-сервера (HTTPS требует аутентификацию клиента в отличие от HTTP) — это самая известная и самая древняя категория. Понятно, что с такими прокси-серверами может работать только ограниченная группа клиенты, работающих в протоколах HTTP/HTTPS, но это и самая массовая группа: браузеры, передача файлов, утилиты `wget`, `curl`, некоторые формы DNS протоколов... Самый известный проект этой группы `squid`, из малых реализаций — например, `polipo`, рекомендуемый к использованию в проекте TOR, но последние релизы `polipo` относятся к 2014 году.
- Проксирование на уровне протоколов транспортных (L3) протоколов TCP и, иногда UDP. Здесь самая известная категория — это SOCKS4 и SOCKS5 прокси-сервера (различие между ними в том, что SOCKS5 допускает настройками возможность аутентификации и поддерживает UDP протокол). Из числа самых известных проектов можно назвать `Dante` и `3proxy`.

- Сервер `3proxy` умеет, в зависимости от конфигурации, осуществлять проксирование как SOCKS, так и HTTP/HTTPS.
- По существу, повсеместно используемая в LAN IPv4 трансляция адресов NAT, осуществляемая на сетевом (L2) уровне протокола IP механизмом ядра `netfilter` (о нём говорили раньше), что работает на шлюзах LAN в Интернет по умолчанию — также является прокси (использование посредника). Но его в этом качестве прокси не называют.

Создание собственного прокси-сервера (SOCKS5), скажем на небольшом арендуемом VDS (виртуальном сервере провайдера), посмотрим на примере `Dante`:

```
$ aptitude search Dante
p   dante-client                                - SOCKS wrapper for users behind a firewall
p   dante-server                                - SOCKS (v4 and v5) proxy daemon (danted)
```

В этой паре `dante-client` это средство «научить» любое приложение работать через SOCKS5 (из числа тех кто не умеют это делать), и ещё как некоторое средство в ограниченных функциях файервола. Мы к нему ещё вернёмся в пару слов позже…

А сейчас нас интересует именно сервер:

```
$ sudo apt install dante-server
Чтение списков пакетов… Готово
Построение дерева зависимостей
Чтение информации о состоянии… Готово
Следующие НОВЫЕ пакеты будут установлены:
  dante-server
Обновлено 0 пакетов, установлено 1 новых пакетов, для удаления отмечено 0 пакетов, и 6 пакетов не обновлено.
Необходимо скачать 375 kB архивов.
После данной операции объём занятого дискового пространства возрастёт на 1.013 kB.
Пол:1 http://mirror.timeweb.ru/debian buster/main amd64 dante-server amd64 1.4.2+dfsg-6 [375 kB]
Получено 375 kB за 1с (519 kB/s)
Выбор ранее не выбранного пакета dante-server.
(Чтение базы данных … на данный момент установлено 47759 файлов и каталогов.)
Подготовка к распаковке …/dante-server_1.4.2+dfsg-6_amd64.deb …
Распаковывается dante-server (1.4.2+dfsg-6) …
Настраивается пакет dante-server (1.4.2+dfsg-6) …
Created symlink /etc/systemd/system/multi-user.target.wants/danted.service → /lib/systemd/system/danted.service.
Обрабатываются триггеры для man-db (2.8.5-2) …
Mar 19 20:00:01 R420 kernel: [38065.020377] EXT4-fs (sdc1): mounted filesystem with ordered data mode. Opts: (null)
. Quota mode: none.
                    Обрабатываются триггеры для systemd (241-7~deb10u8) …
$ sudo danted -v
Dante v1.4.2.  Copyright (c) 1997 - 2014 Inferno Nettverk A/S, Norway
```

После установки `danted` попытается средствами `systemd` стартовать, но это ему не удастся и завершится ошибкой, поскольку его нужно конфигурировать для нормальной работы. Его конфигурационный файл:

```
$ ls -l /etc/danted.conf
-rw-r--r-- 1 root root 8134 янв  5  2019 /etc/danted.conf
```

В первом приближении, без авторизации, это может выглядеть так (файл конфигурации тщательнейшим образом прокомментирован):

```
$ grep -v '^$\|^#' danted.conf
logoutput: stderr
internal: eth0 port = 1080
external: eth0
socksmethod: none
user.privileged: proxy
user.unprivileged: nobody
user.libwrap: nobody
```

```
client pass {
        from: 0/0 to: 0/0
        log: connect disconnect error ioop
}
socks pass {
        from: 0/0 to: 0/0
        log: connect disconnect error ioop
}
```

Здесь (из самого важного):

- `internal` и `external` — это входящий и исходящий интерфейсы, могут быть заданы как именами, там и указанием их IP адресов;

- `port` — это прослушиваемый (проксируемый) порт SOCKS4/5;

- `socksmethod` — собственно, и определяет способ авторизации, `none` — без авторизации;

Теперь мы можем производить запуск, в общем обычным для серверов путём, но мы должны добиться безошибочный старт (более-менее правильный файл конфигурации):

```
# systemctl start danted
# systemctl status --no-pager --full danted
● danted.service - SOCKS (v4 and v5) proxy daemon (danted)
   Loaded: loaded (/lib/systemd/system/danted.service; enabled; vendor preset: enabled)
   Active: active (running) since Sun 2023-03-19 22:11:32 MSK; 3s ago
     Docs: man:danted(8)
           man:danted.conf(5)
  Process: 9542 ExecStartPre=/bin/sh -c        uid=`sed -n -e "s/[[:space:]]//g" -e "s/#.*//" -e
"/^user\.privileged/{s/[^:]*://p;q;}" /etc/danted.conf`;  if [ -n "$uid" ]; then
        touch /var/run/danted.pid;             chown $uid /var/run/danted.pid;        fi
(code=exited, status=0/SUCCESS)
  Main PID: 9546 (danted)
     Tasks: 20 (limit: 1149)
   Memory: 20.4M
   CGroup: /system.slice/danted.service
           ├─9546 /usr/sbin/danted
           ├─9547 danted: monitor
           ├─9548 danted: negotia
           ├─9549 danted: request
           ├─9550 danted: request
           ├─9551 danted: request
           ├─9552 danted: request
           ├─9553 danted: request
           ├─9554 danted: request
           ├─9555 danted: request
           ├─9556 danted: request
           ├─9557 danted: request
           ├─9558 danted: request
           ├─9559 danted: request
           ├─9560 danted: request
           ├─9561 danted: request
           ├─9562 danted: request
           ├─9563 danted: request
           ├─9564 danted: request
           └─9565 danted: io-chil

map 19 22:11:32 277938.local systemd[1]: Starting SOCKS (v4 and v5) proxy daemon (danted)...
map 19 22:11:32 277938.local systemd[1]: Started SOCKS (v4 and v5) proxy daemon (danted).
map 19 22:11:33 277938.local danted[9546]: Mar 19 22:11:33 (1679253093.602826) danted[9546]: info:
Dante/server[1/1] v1.4.2 running
```

Но для того, чтобы убедиться в работоспособности сервера, мы должны прежде разрешить на файерволе (если он работает на этом хосте) разрешить заказанный входной порт, или приостановить (временно) работу файервола:

```
# ufw allow 1080
Rule added
```

И теперь с хоста, возможно весьма удалённого, возможно в локальной сети с NAT и ограниченным числом разрешённоых портов внаружу, можем проверить работоспособность SOCKS прокси:

```
$ curl -x socks5://90.156.230.27:1080 ifconfig.co
90.156.230.27
```

Здесь, как должно быть понятно, 90.156.230.27 — это и есть IP удалённого сервера с «белым» адресом, для которого я и проделываю настройку. И контрольный запрос с того же места, но без задействования прокси:

```
$ curl ifconfig.co
193.28.177.124
```

Здесь в качестве ответа я получаю совсем другой IP 193.28.177.124 — это динамический адрес, который за счёт динамической трансляции NAT мой **провайдер** Интернет присваивает всем компьютерам в моей локальной сети.

Сервер работоспособен … Но оставить его в такой конфигурации нельзя. Опыт проводимых отладочных работ показал (файлы системных журналов), что только за пару часов отладки сервера на его использование набежали до сотни незваных мерзавцев, непрерывно барражирующих в Интернет и сканирующих не закрытые порты и прокси-сервера. И если завтра через ваш прокси-сервер взломают и разденут на миллион долларов Bank of America, то засвечен будет IP вашего прокси-сервера и претензии будут предъявляться вам. Поэтому нужно сразу конфигурировать аутентификацию пользователей на прокси-сервере … и, возможно, сменить типовой порт 1080 на другой (на практике приходится видеть 5555, 1085 ...). Кроме того, хотелось бы добавить и обслуживание адресов IPv6. В конечном итоге (после целого ряда изменений и перезапуска `danted`) файл конфигурации может принять вид подобный следующему:

```
$ grep -v "^$\|^#" /etc/danted.conf
logoutput: stderr
internal: 90.156.230.27 port = 1085
internal: 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771 port = 1085
external: 90.156.230.27
external: 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
socksmethod: username
user.privileged: root
user.unprivileged: nobody
user.libwrap: nobody
client pass {
        from: 0/0 to: 0/0
        log: error ioop
}
socks pass {
        from: 0/0 to: 0/0
        log: error ioop
        group: proxy
}
```

Для сетевых интерфейсов сервера:

```
$ ip a s
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue state UNKNOWN group default qlen 1000
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
    inet 127.0.0.1/8 scope host lo
       valid_lft forever preferred_lft forever
    inet6 ::1/128 scope host
       valid_lft forever preferred_lft forever
2: eth0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP group default qlen
1000
    link/ether 2e:49:10:b4:b2:02 brd ff:ff:ff:ff:ff:ff
    inet 90.156.230.27/24 brd 90.156.230.255 scope global dynamic eth0
       valid_lft 63386sec preferred_lft 63386sec
    inet6 fe80::2c49:10ff:feb4:b202/64 scope link
```

```
        valid_lft forever preferred_lft forever
  3: tun0: <POINTOPOINT,MULTICAST,NOARP,UP,LOWER_UP> mtu 53049 qdisc pfifo_fast state UNKNOWN group
 default qlen 500
      link/none
      inet6 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771/7 scope global
         valid_lft forever preferred_lft forever
      inet6 fe80::d86f:9577:d828:cb4d/64 scope link stable-privacy
         valid_lft forever preferred_lft forever
```

В файле конфигурации мы теперь поменяли тип аутентификации на `username`, а сетевые интерфейсы (и входные и выходные) определяем не именами, а их адресами (и IPv4 и IPv6). Но теперь нам нужно:

- создать (если она не создалась при инсталляции пакета) группу пользователей `proxy`:
- создать (одного или нескольких) имён пользователей для пользования прокси, без возможности логирования в терминальной сессии:

  ```
  # useradd --shell /usr/sbin/nologin proxy_user_02
  ```
- добавить пользователям пароли использования проксирования:

  ```
  # passwd proxy_user_02
  Новый пароль :
  Повторите ввод нового пароля :
  passwd: пароль успешно обновлён
  ```
- добавить таких пользователей в группу `proxy`:

  ```
  # sudo usermod -a -G proxy proxy_user_02
  ```

В итоге, только пользователи с этими именами могут авторизоваться на прокси-сервере:

```
$ cat /etc/group | grep proxy
proxy:x:13:proxy_user_01,proxy_user_02
$ cat /etc/passwd | grep proxy
proxy:x:13:13:proxy:/bin:/usr/sbin/nologin
proxy_user_01:x:1003:1003::/home/proxy_user_01:/usr/sbin/nologin
proxy_user_02:x:1004:1004::/home/proxy_user_02:/usr/sbin/nologin
```

Вот теперь можно испытывать и далее использовать SOCKS5 прокси … и увидеть запаздывание которое вносить проксирование:

```
$ time curl -x socks5://proxy_user_02:xxxxxx@90.156.230.27:1085 check-host.net/ip
90.156.230.27
real    0m0,940s
user    0m0,008s
sys     0m0,009s
$ time curl --noproxy '*' check-host.net/ip
193.28.177.119
real    0m0,125s
user    0m0,004s
sys     0m0,010s
```

А вот так выглядит обращение к HTTP серверу по его IPv6 адресу:

```
$ curl -x socks5://proxy_user_02:xxxxxx@90.156.230.27:1085 \
[221:58c9:9a6:99be:f3d:c1ac:2b5b:9771] > /dev/null
  % Total    % Received % Xferd  Average Speed   Time    Time     Time  Current
                                 Dload  Upload   Total   Spent    Left  Speed
100 52727    0 52727    0     0  42897      0 --:--:--  0:00:01 --:--:-- 42902
```

Последнее действие, полезное в использовании прокси — это определить на клиентских компьютерах системными переменными параметры используемых прокси по умолчанию, чтобы в каждой команде не набирать эти непростые параметры. Для того чтобы эти значения восстанавливались после перезагрузки системы (клиента) пропишем их в файл `/etc/environment`:

```
$ cat /etc/environment
PATH="/usr/local/sbin:/usr/local/bin:/usr/sbin:/usr/bin:/sbin:/bin"
```

```
export all_proxy=socks5://proxy_user_02:xxxxxx@90.156.230.27:1085/
export ALL_PROXY=socks5://proxy_user_02:xxxxxx@90.156.230.27:1085/
export no_proxy="localhost,127.0.0.0/8,192.168.1.0/24,::1"
```

Тогда программы, которые умеют использовать прокси (а далеко не все умеют) будут использовать определения в переменных окружения:

```
$ env | grep proxy
no_proxy=localhost,127.0.0.0/8,192.168.1.0/24,::1
ALL_PROXY=socks5://proxy_user_02:xxxxxx@90.156.230.27:1085/
all_proxy=socks5://proxy_user_02:xxxxxx@90.156.230.27:1085/
```

В том что прокси подхватывается по умолчанию можно убедиться по времени отклика команды `curl` без явного указания ему использовать прокси:

```
$ time curl check-host.net/ip
90.156.230.27
real    0m0,940s
user    0m0,008s
sys     0m0,009s
```

Прокси сквозь SSH

Как уже упоминалось, протокол SSH может туннелировать множество других сетевых протоколов. Таким способом среди множества других возможностей представляется возможность организовать SOCKS-проксирование сквозь такой туннель. Организуем его вот таким SSH подключением к любому серверу в Интернет, к которому у вас есть доступ:

```
$ ssh -N -D 5555 90.156.230.27
olej@90.156.230.27's password:
...
```

Обратите внимание! Мы хотим создать прокси через удалённый сервер через произвольный порт 5555, который, естественно, не открыт как входной на файерволе `ufw` сервера. В этом случае трафик прокси будет туннелироваться через порт 22 протокола SSH.

Если вы на эту команду `ssh` создания прокси получите в ответ: Permission denied, please try again. — то с **другого** терминала **этого** же хоста от имени **этого** пользователя вы можете выполнять:

```
$ curl -s -x socks4://127.0.0.1:5555 ifconfig.co
90.156.230.27
$ curl -s -x socks5://127.0.0.1:5555 ifconfig.co
90.156.230.27
```

P.S. Оговорка об ошибках команды установления туннеля здесь не случайная и не лишняя! В ней имя пользователя **явно** нельзя указывать, неявно предполагается текущее имя логина на запрашиваемом клиенте. А пароль, затем, запрашивается на сервере SSH для этого же имени. Для подтверждения того как это происходит можете выполнить команду в терминале от `root`:

```
$ sudo ssh -N -D 5555 90.156.230.27
[sudo] пароль для olej:
root@90.156.230.27's password:
```

Здесь запрашивается 2 разных пароля: 1-й для sudo на локальном клиенте, второй — на удалённом сервере. Если вы будете упорствовать в вводе «не того» пароля, то после нескольких попыток (обычно 2) сервер оборвёт все текущие и новые SSH подключения чтобы воспрепятствовать дальнейшим попыткам. Этот «молчание» будет продолжаться несколько минут, значение определяется настройками параметров логирования на сервере.

Клиенты прокси

Многие сетевые клиенты сами умеют работать с проксированием. Некоторым программам использование прокси нужно указать явно: опциями командной строки, как, например, `curl`, другим — в настроечных параметрах, как браузер FireFox. Другие программы вообще не имеют возможностей индивидуальной настройки (например все браузеры производные от Chromium), а используют переменные окружения из числа тех что были показаны выше: `all_proxy`, `http_proxy`, `socks_proxy`.

Но встречаются программы, которые принципиально не умеют использовать прокси (как пример прграмма управления версиями cvs). А иногда и для программ названных абзацем выше (то есть так или иначе умеют использовать прокси) из-за конкретики задачи неудобно использовать настроечные параметры. Для таких случаев предусмотрены пакет (проект) dante-client и его программа (команда) :

```
# aptitude install dante-client
Следующие НОВЫЕ пакеты будут установлены:
  dante-client libdsocksd0{a} libfile-which-perl{a}
0 пакетов обновлено, 3 установлено новых, 0 пакетов отмечено для удаления, и 2 пакетов не обновлено.
Необходимо получить 207 kБ архивов. После распаковки 578 kБ будет занято.
Хотите продолжить? [Y/n/?] y
Получить: 1 http://mirror.mirohost.net/ubuntu jammy/universe amd64 libdsocksd0 amd64 1.4.2+dfsg-7build4 [179 kB]
Получить: 2 http://mirror.mirohost.net/ubuntu jammy/main amd64 libfile-which-perl all 1.23-1 [13,8 kB]
Получить: 3 http://mirror.mirohost.net/ubuntu jammy/universe amd64 dante-client all 1.4.2+dfsg-7build4 [14,3 kB]
Получено 207 kБ в 1с (390 kБ/с)
Выбор ранее не выбранного пакета libdsocksd0:amd64.
(Чтение базы данных … на данный момент установлено 551432 файла и каталога.)
Подготовка к распаковке …/libdsocksd0_1.4.2+dfsg-7build4_amd64.deb …
Распаковывается libdsocksd0:amd64 (1.4.2+dfsg-7build4) …
Выбор ранее не выбранного пакета libfile-which-perl.
Подготовка к распаковке …/libfile-which-perl_1.23-1_all.deb …
Распаковывается libfile-which-perl (1.23-1) …
Выбор ранее не выбранного пакета dante-client.
Подготовка к распаковке …/dante-client_1.4.2+dfsg-7build4_all.deb …
Распаковывается dante-client (1.4.2+dfsg-7build4) …
Настраивается пакет libfile-which-perl (1.23-1) …
Настраивается пакет libdsocksd0:amd64 (1.4.2+dfsg-7build4) …
Настраивается пакет dante-client (1.4.2+dfsg-7build4) …
Обрабатываются триггеры для man-db (2.10.2-1) …
Обрабатываются триггеры для libc-bin (2.35-0ubuntu3.1) …
$ which socksify
/usr/bin/socksify
```

Программа socksify умеет работать с прокси как HTTP так и SOCKS. Но для её успешного использования нам предстоит настроить конфигурацию /etc/dante.conf.

Для этого, прежде, создадим временный туннель SOCKS средствами SSH без авторизации, как было показано ранее, который иногда называют как «VPN для бедных»:

```
$ ssh -N -D 5555 90.156.230.27
olej@90.156.230.27's password:
```

Почему «выскочило» такое имя пользователя мы уже выясняли, но ещё подробно вернёмся к этому вопросу. А для использования такого прокси-туннеля пропишем в конфигурацию dante (всё остальное в этом достаточно большом файле — это комментированные строки примеров применения для различных случаев):

```
$ grep -v "#\|^$" /etc/dante.conf
route {
    from: 0.0.0.0/0  to: 0.0.0.0/0  via: 127.0.0.1 port = 5555
    protocol: tcp udp
    proxyprotocol: socks_v5
    method: none
}
```

И испытываем полученный SOCKS-прокси на работоспособность:

```
$ curl -s -x socks4://127.0.0.1:5555 ifconfig.co
90.156.230.27
```

```
$ curl --noproxy '*' ifconfig.co
193.28.177.119
$ socksify curl --noproxy '*' ifconfig.co
90.156.230.27
```

Дальше перейдём к использованию стационарного сервера `danted`, который мы оставили работающим постоянно на удалённом сервере `90.156.230.27` 2-мя главами ранее… Он требует, нашими стараниями, авторизации пользователя именем и паролем. Для этого перепишем конфигурационный файл клиента так:

```
$ grep -v "#\|^$" /etc/dante.conf
route {
    from: 0.0.0.0/0  to: 0.0.0.0/0  via: 90.156.230.27 port = 1085
    protocol: tcp udp
    proxyprotocol: socks_v4 socks_v5
    method: username
}
```

Здесь, попутно, заметим, что программа `dante` это не сервер, и не потребует рестарта или посылки сигнала (`kill ...`) перечтения конфигурации — он перечитает конфигурацию сразу же при выполнении клиентского запроса.

Первая попытка так использовать прокси-сервер «с налёта» завершится неудачей:

```
$ socksify curl --noproxy '*' check-host.net/ip
olej@90.156.230.27.1080 socks password:
olej@90.156.230.27.1080 socks password:
curl: (7) Failed to connect to check-host.net port 80 after 33901 ms: В соединении отказано
```

Это связано с тем, что в качестве имени авторизации на SOCKS-прокси отправляется текущее имя пользователя, в чьём сеансе отправляется запрос. А на прокси-сервере сервера мы специально создали имена новых пользователей, которым разрешено авторизоваться для использования прокси, и поместили их там в группу пользователей `proxy` (см. 2-мя главами выше). Но на клиентском компьютере у меня (и на многих других компьютерах) нет **таких** пользователей, даже если я попытаюсь проделать команду от такого имени, что-то типа:

```
$ su proxy_user_02 -c "socksify curl --noproxy '*' check-host.net/ip"
su: user proxy_user_02 does not exist or the user entry does not contain all the required fields
```

Синтаксически верно, но с точки зрения операционной системы бессмысленно!

Разнообразные перепробованные варианты заставить `socksify` выполняться от имени произвольного пользователя, как и поиск по Интернет такой возможности, не увенчались успехом. Команда `socksify` не допускает опций подсказки (`--help` или `-h`), но помощь пришла из `man` страницы в виде списка предопредегённых переменных (этой и многих других) окружения программы:

```
$ man socksify
...
       SOCKS_USERNAME
              Use the value of SOCKS_USERNAME as the username when doing username authentication.
```

Теперь (и успешно!) команду использования прокси через `socksify` выполняем так (2-я форма показана для сравнения):

```
$ export SOCKS_USERNAME=proxy_user_02; socksify curl --noproxy '*' ifconfig.co
proxy_user_02@90.156.230.27.1080 socks password:
90.156.230.27
$ curl -x socks5://proxy_user_02:xxxxxx@90.156.230.27 ifconfig.co
90.156.230.27
```

Кто и как использует прокси?

С ростом возможностей использования разнообразных прокси (и окольных путей запросов) можно легко запутаться кто из программ умеет использовать и кто использует проксирование, … в каком направлении и протоколе? Для этого установите такую простую утилиту:

```
$ sudo apt install sockstat
Чтение списков пакетов… Готово
Построение дерева зависимостей… Готово
```

```
Чтение информации о состоянии… Готово
Следующие НОВЫЕ пакеты будут установлены:
  sockstat
Обновлено 0 пакетов, установлено 1 новых пакетов, для удаления отмечено 0 пакетов, и 0 пакетов не обновлено.
Необходимо скачать 12,5 kB архивов.
После данной операции объём занятого дискового пространства возрастёт на 37,9 kB.
Пол:1 http://ftp.bme.hu/debian bullseye/main amd64 sockstat amd64 0.4.1-1 [12,5 kB]
Получено 12,5 kB за 0с (45,5 kB/s)
Выбор ранее не выбранного пакета sockstat.
(Чтение базы данных … на данный момент установлен 367121 файл и каталог.)
Подготовка к распаковке …/sockstat_0.4.1-1_amd64.deb …
Распаковывается sockstat (0.4.1-1) …
Настраивается пакет sockstat (0.4.1-1) …
Обрабатываются триггеры для man-db (2.9.4-2) …

$ sockstat -h
usage: sockstat [-46clhu] [-p ports] [-U uid|user] [-G gid|group] [-P pid|process] [-R protocol]
       protocol = 'tcp' or 'udp' or 'raw' or 'unix'
```

Вот возможный вид использования прокси-серверов в (специально) весьма нагруженной системе:

```
$ sockstat -4
USER     PROCESS         PID      PROTO  SOURCE ADDRESS       FOREIGN ADDRESS         STATE
olej     firefox-bin     4480     tcp4   192.168.1.14:60232   198.16.66.101:436       ESTABLISHED
olej     firefox-bin     4480     tcp4   192.168.1.14:44514   198.16.66.101:436       ESTABLISHED
olej     firefox-bin     4480     tcp4   192.168.1.14:37994   198.16.66.101:436       ESTABLISHED
...
olej     firefox-bin     4480     tcp4   192.168.1.14:54268   198.16.66.101:436       ESTABLISHED
olej     Telegram        5479     tcp4   127.0.0.1:54978      127.0.0.1:9050          ESTABLISHED
olej     thunderbird     6127     tcp4   127.0.0.1:36602      127.0.0.1:9050          ESTABLISHED
olej     thunderbird     6127     tcp4   127.0.0.1:44294      127.0.0.1:9050          ESTABLISHED
olej     thunderbird     6127     tcp4   127.0.0.1:59310      127.0.0.1:9050          ESTABLISHED
olej     thunderbird     6127     tcp4   127.0.0.1:55596      127.0.0.1:9050          ESTABLISHED
olej     thunderbird     6127     tcp4   127.0.0.1:58848      127.0.0.1:9050          ESTABLISHED
olej     Viber           27304    tcp4   127.0.0.1:30666      *:*                     LISTEN
olej     Viber           27304    tcp4   127.0.0.1:45112      *:*                     LISTEN
olej     Viber           27304    tcp4   192.168.1.14:37880   44.192.201.149:4244     ESTABLISHED
olej     ssh             36721    tcp4   192.168.1.14:47460   192.168.1.138:22        ESTABLISHED
olej     ssh             36837    tcp4   192.168.1.14:43592   192.168.1.241:22        ESTABLISHED
olej     chrome          39461    udp4   224.0.0.251:5353     *:*                     CLOSED
olej     chrome          39461    udp4   224.0.0.251:5353     *:*                     CLOSED
olej     chrome          39510    tcp4   127.0.0.1:55572      127.0.0.1:9050          ESTABLISHED
olej     opera           40562    udp4   224.0.0.251:5353     *:*                     CLOSED
olej     opera           40562    udp4   224.0.0.251:5353     *:*                     CLOSED
olej     opera           40598    tcp4   127.0.0.1:50608      127.0.0.1:9050          ESTABLISHED
olej     opera           40598    udp4   224.0.0.251:5353     *:*                     CLOSED
olej     opera           40598    udp4   224.0.0.251:5353     *:*                     CLOSED
olej     opera           40598    udp4   *:40987              *:*                     CLOSED
olej     chromium        42821    udp4   224.0.0.251:5353     *:*                     CLOSED
olej     chromium        42821    udp4   224.0.0.251:5353     *:*                     CLOSED
olej     chromium        42857    tcp4   127.0.0.1:54148      127.0.0.1:9050          ESTABLISHED
olej     chromium        42857    tcp4   127.0.0.1:40240      127.0.0.1:9050          ESTABLISHED
olej     chromium        42857    tcp4   127.0.0.1:44706      127.0.0.1:9050          ESTABLISHED
olej     chromium        42857    tcp4   127.0.0.1:60058      127.0.0.1:9050          ESTABLISHED
olej     chromium        42857    tcp4   127.0.0.1:44728      127.0.0.1:9050          ESTABLISHED
olej     chromium        42857    tcp4   127.0.0.1:60138      127.0.0.1:9050          ESTABLISHED
```

Изучить, даже такие обширные «простыни», в высшей степени полезно, здесь мы всё видим: FireFox (множество его вкладок) работает через браузерное дополнение Browsec через VPN в Нидерландах (198.16.66.101:436), Thunderbird, Telegram, Google Chrome, Opera и Chromium — черезлокальный SOCKS-прокси системы TOR (о которой будет дальше), но это ничем принципиально

не отличает этот прокси от рассмотренного ранее SOCKS5.

Источники использованной информации

[1] systemd для администраторов — http://www2.kangran.su/~nnz/pub/s4a/s4a_latest.pdf

[2] Памятка пользователям ssh — https://habr.com/ru/articles/122445/

[3] Магия SSH — https://habr.com/ru/articles/331348/

[4] Настройка DHCP-сервера в Linux — https://itproffi.ru/nastrojka-dhcp-servera-v-linux/

[5] Установка и базовая настройка DHCP сервера на Ubuntu — https://www.dmosk.ru/miniinstruktions.php?mini=dhcp-ubuntu

[6] Как это работает: Пара слов о DNS — https://habr.com/ru/companies/1cloud/articles/309018/

[7] Кэширующий DNS сервер на BIND — https://линуксблог.рф/keshiruyushhij-dns-server-na-bind

[8] Настройка DNS на Ubuntu Server 18.04 LTS — https://tokmakov.msk.ru/blog/item/522

[9] Настройка systemd-resolved для локального кэширования DNS в Debian 10 — https://zevilz.dev/posts/496/

[10] Настройка netfilter с помощью iptables — https://www.dmosk.ru/instruktions.php?object=iptables-settings

[11] Настройка iptables для чайников — https://losst.pro/nastrojka-iptables-dlya-chajnikov

[12] Конфигурирование сервера. Суперсерверы inetd и xinetd — http://www.redov.ru/kompyutery_i_internet/linux_server_svoimi_rukami/p8.php#metkadoc9

[13] Интернет-демон (xinetd/inetd) — https://wm-help.net/lib/b/book/1696396857/364

[14] Поднимаем SOCKS5 прокси в шесть шагов — https://fckrkn.github.io/dante_proxy/

[15] Создание и настройка SOCKS5 прокси сервера в Ubuntu — https://la2ha.ru/dev-seo-diy/unix/socks5-proxy-server-ubuntu

[16] Установка и настройка Dante SOCKS5 Proxy сервера на Ubuntu 18.04 LTS — https://blog.xenot.ru/ustanovka-i-nastrojka-dante-socks5-proxy-servera-na-ubuntu-18-04-lts-godnaya-instruktsiya-po-obhodu-blokirovki-messendzhera-telegram-i-dr-sajtov-roskomnadzorom.fuck

[17] Dante, учим любой софт работать через socks proxy — https://habr.com/ru/articles/82727/

[18] SOCKS через SSH — не только для ICQ — https://habr.com/ru/articles/49801/

Следующие 2 части являются разбором того как сетевой трафик обеспечивается в терминологии программного кода: сначала в пользовательских приложения, а затем и в коде ядра Linux. Только таким образом можно с исчерпывающей полнотой проследить полный путь информации от того момента когда вы, например, набираете текстовую строку на терминале, и до того момента, когда эта строка попадёт на обработку программе сервера, стоящего за много тысяч километров от вашего терминала.

Естественно, что эти части предполагают некоторое, хотя бы начальное знакомство с языком программирования C, на котором написана основная часть системного программного обеспечения операционной системы Linux. Но если вы не располагаете такими знаниями, или просто не расположены вникать в программный код — то эти 2 части можно совершенно безболезненно для всего остального изложения.

4. Программирование сетевых приложений

Общие принципы

Сетевые проекты могут иметь самую разнообразную архитектуру и использовать любые протоколы пользовательского уровня. Но при этом все они подчиняются некоторому набору общих принципов, неизменных для всех сетевых проектов.

Клиент и сервер

В сетевом взаимодействии **всегда** присутствуют две **несимметричные** стороны взаимодействия: клиент и сервер.

- Сервер находится непрерывно в **пассивном** ожидании запросов от клиентов. Получив запрос, сервер активируется, осуществляет требуемую обработку запроса (иногда, зачастую, эта обработка состоит в возврате клиенту некоторого ответа, но это совершенно не обязательно).

- Клиент **активно** (по своей инициативе) запрашивает обслуживание у сервера.

Из-за этого сетевые приложения принципиально несимметричные, то и используют разные API для клиентской и серверной стороны. Поэтому сетевые проекты именуют клиент-серверными. Даже в случаях симметричного по функциям взаимодействия сторон (pear-to-pear сети) каждая из сторон периодически меняясь выступает то как клиент, то как сервер.

Сети датаграммные и потоковые

На уровне **физической** среды передачи (уровни L1 и L2 в терминологии Linux), сетевой обмен **всегда** организуется пакетами ограниченной длины (MTU параметр — максимальная длина пакета для данного **сетевого интерфейса**).

Но на уровне транспортных механизмов сети (уровень L3) делятся на 2 большие категории по логике своего взаимодействия: датаграммные и потоковые.

- Датаграммные транспортные механизмы обеспечивают обмен дейтаграммами, логическими пакетами (имеющими начало и конец). Длина датаграммы (сообщения) может совпадать (так чаще всего и бывает), но может и не совпадать с длиной пакета, передаваемого в физическую среду — тогда происходит сегментация датаграммы на несколько пакетов сетевого, канального или физического уровня. Или наоборот, пакет физической среды с короткой датаграммой уходит в «укороченном» виде, длиной заметно ниже MTU. Самым известным из датаграммных транспортных протоколов в сети IP является UDP. При передаче последовательности 5-ти сообщений длинами, соответственно, 10, 10, 10, 10, 10 байт, на приёмном конце будет **обязательно** считано последовательными чтениями в цикле 5 сообщений длинами 10, 10, 10, 10, 10 байт.

- Потоковые транспортные механизмы логически представляют обмен на уровне сокета как непрерывный поток байт (труба, в один конец которого втекает, а из другого вытекает некоторый поток). При обмене посредством потокового механизма не может быть никаких «пакетов»: поток отдельных байт передаётся в поток, и поток отдельных байт считывается из потока. Самым известным из потоковых транспортных протоколов в сети IP является TCP. При последовательной передаче в потоковый сокет порций (сообщений), соответственно, 10, 10, 10, 10, 10 байт, на приёмном конце в цикле чтений может быть считано, с равным успехом, любое произвольное число байт в каждом чтении, например, 5, 20, 15, 5, 5, более того, этот объём информации (50 байт) может быть считан за отличающееся число считываний, например 4 а не 5: 15, 15, 15, 5 или 6 считываний: 8, 8, 8, 8, 8, 10 (тут срабатывают различные дополнительные механизмы оптимизации, такие как отсроченная отправка, алгоритм Нэйгла и другие).

Предположение каких-либо «пакетов» на приёмном конце при TCP обмене является самой частой грубейшей ошибкой начинающих программистов.

Ещё одним заблуждением является представление, что UDP и TCP протоколы являются двумя альтернативами в IP сети **соизмеримой сложности** функционирования. И исходящее отсюда желание построить на UDP (чвой) протокол надёжной доставки, например, отправкой подтверждений приёма. На самом деле протокол TCP **на порядок** сложнее в функционировании, включающий в логику своей работы много дополнительных механизмов, таких как: адаптивное согласование окон приёма и передачи, медленные старт, алгоритм Нэйгла, отсроченные подтверждения, адаптивное управление размерами окон приёма и передачи и другие. Другими словами, реализовать на UDP

механизм надёжной доставки — это значит в собственном коде вручную реализовать протокол TCP … только «плохой протокол TCP».

Из предыдущего заблуждения вытекает (неоднократно приходилось слышать) ещё одна красивая народная легенда о том, что, якобы, для одних и тех же действий реализация на UDP будет заметно быстрее чем на TCP. Это полная ерунда!

Каждый из транспортных механизмов предназначен для своих целей. В дальнейшем тексте везде, чтоб не создавать многословности, там где мы хотим говорить о датаграммной передаче, мы будем называть это UDP. А там, где речь идёт о потоковой передаче — TCP.

Датаграммный протокол UDP ориентирован на быструю передачу информации, ничем не гарантирующую доставку. Вплоть до того, что приёмная сторона (её сетевой стек) имеет право просто успешно принимать UDP сообщения, но, если она перегружена, то по собственной инициативе просто сбрасывать в мусор уже принятые пакеты, никак не уведомляя о том ни приёмную, ни передающую сторону.

Потоковый протокол TCP ориентирован на **надёжную доставку** информации. В случае потери пакетов или их искажения на тракте передающая сторона делает многократные попытки повторной передачи.

Протокол UDP определён в RFC 768. Протоколу TCP посвящены RFC 790, 791, 793, 1025, 1323. Это базовые RFC, в последующие годы они дополнялись и расширялись.

Примечание в порядке предупреждения: не обольщайтесь кажущейся простотой и **понятностью** протокола UDP для реализации **надёжного** взаимодействия в создаваемом проекте. Надстраивание над UDP средств контроля и резервирования — это ловушка, в которую попадают многие разработчики, впервые начинающие сетевое проектирование. При этом вы только повторяете путь развития TCP, который занял не одно десятилетие.

Фазы соединения TCP

В формате каждого пакета транспортного уровня TCP предусмотрено несколько битовых флагов, определяющие предназначение пакета. Поэтому в публикациях пакеты часто называют по имени установленных в них флагов. Некоторые из этих флагов могут быть установлены одновременно (но не в любых комбинациях). Вот эти флаги:

URG - указатель срочности (urgent pointer) данных (другие названия: внеполосовые данные, приоритетные данные).

ACK - Номер подтверждения необходимо принять в рассмотрение (acknowledgment).

PSH - Получатель должен передать эти данные приложению как можно скорее.

RST - Сбросить соединение.

YN - Синхронизирующий номер последовательности для установления соединения.

FIN - Отправитель заканчивает посылку данных.

TCP это протокол, ориентированный на соединение. Перед тем как какая-либо сторона может послать данные другой, между ними должно быть **установлено** соединение. Чтобы установить TCP соединение пересылаются 3 сегмента:

1. Запрашивающая сторона (клиент) отправляет SYN (флаг) сегмент, указывая **номер порта** сервера, к которому клиент хочет подсоединиться, и **исходный номер последовательности** клиента (ISN).

2. Сервер отвечает своим сегментом SYN, содержащим **исходный номер последовательности** сервера. Сервер также **подтверждает** приход SYN от клиента с использованием ACK флаг (указывая номер ISN клиента плюс один).

3. Клиент должен подтвердить приход SYN от сервера с использованием ACK флага (ISN сервера плюс один).

Этих трех сегментов достаточно для установления соединения. Часто это называется трехразовым рукопожатием (three-way handshake).

Этих трех сегментов достаточно для установления соединения. Часто это называется трехразовым рукопожатием (three-way handshake).

При пересылке данных передающая сторона пересылает **сегмент данных**, а приёмная сторона должна **подтвердить** его получение сегментом ACK с инкрементированным номером последовательности. Если подтверждение не приходит в установленный тайм-аут, производятся попытки повторной передачи. Первый тайм-аут устанавливается обычно в 1,5 секунды после первой

передачи. После этого величина тайм-аута удваивается для каждой передачи, причем верхний предел составляет 64 секунды. После 12 неудачных повторов (с увеличивающимся интервалом) TCP осуществляет сброс и возвращает ошибку канала.

После полного завершения обмена соединение нужно **разорвать**. Соединения обычно устанавливаются клиентом, то есть первый SYN двигается от клиента к серверу. Однако любая сторона может активно закрыть соединение (послать первый FIN). Часто, однако, именно клиент определяет, когда соединение должно быть разорвано, так как процесс клиента в основном управляется пользователем.

Когда сервер получает FIN от клиента, он отправляет назад ACK с принятым номером последовательности плюс один (сегмент 5). На FIN тратится один номер последовательности, так же как на SYN. В этот момент TCP сервер также доставляет приложению признак конца файла (end-of-file) чтобы выключить сервер. Затем сервер закрывает свое соединение, что заставляет его TCP послать FIN (сегмент 6), который клиент должен подтвердить (ACK), увеличив на единицу номер принятой последовательности (сегмент 7).

Так как TCP соединение полнодуплексное (данные могут передвигаться в каждом направлении независимо от другого направления), каждое направление должно быть закрыто независимо от другого. Можно сказать, что та сторона, которая первой закрывает соединение (отправляет первый FIN), осуществляет активное закрытие, а другая сторона (которая приняла этот FIN) осуществляет пассивное закрытие. Правило заключается в том, что каждая сторона должна послать FIN, когда передача данных завершена. Когда TCP принимает FIN, он должен уведомить приложение, что удаленная сторона разрывает соединение и прекращает передачу данных в этом направлении.

Получение FIN означает только, что в этом направлении прекращается движение потока данных. TCP, получивший FIN, может все еще посылать данные в своём направлении. Несмотря на то, что приложение все еще может посылать данные при наполовину закрытом TCP соединении, на практике только некоторые (совсем немного) TCP приложения используют это.

Для того чтобы установить соединение, необходимо 3 сегмента, а для того чтобы разорвать — нужно 4. Это объясняется тем, что TCP соединение может быть в наполовину закрытом состоянии.

Адаптивные механизмы TCP

Протокол TCP годами проходил многократную модернизацию (разными RFC) и предполагает на сегодня в своём функционировании ряд **адаптивных механизмов**. Главным образом эти механизмы направлены а). на повышение пропускной способности протокола и б). обеспечение объявленной надёжной передачи TCP меньшими затратами. Вот только некоторые (их больше) из таких адаптивных механизмов, которые можно **отключить**, или **изменить** численные характеристики их функционирования есть:

1. Задержанные подтверждения (delayed ACK). Обычно TCP не отправляет ACK сразу по приему данных. Вместо этого он осуществляет задержку подтверждений в надежде на то, что в том же направлении им будут отправлены данные (ответ), таким образом ACK может быть отправлено вместе с данными (присоединено). Большинство реализаций используют задержку равную 200 миллисекунд — таким образом, TCP задерживает ACK на время до 200 миллисекунд, чтобы посмотреть, не направляются ли данные в том же направлении, что и ACK.
2. Алгоритм Нэйгла (Nagle). При передаче коротких сегментов (скажем, длины L) от клиента к серверу генерируются пакеты размером (обычно) 40+L байт: 20 байт - IP заголовок, 20 байт - TCP заголовок и L байт данных. Короткие сегменты (тиниграммы, от tiny - крошечный) обычно не проблема для LAN, так как большинство LAN не излишне перегружены, однако они могут привести к серьёзной перегрузке WAN. Простое и элегантное решение было предложено в RFC 896, которое сейчас называется алгоритмом Нэйгла. Из алгоритма следует, что в TCP соединении может присутствовать только один исходящий маленький сегмент, который еще не был подтвержден. Следующие маленькие сегменты могут быть посланы только после того, как было получено подтверждение уже ранее отправленного. Вместо того чтобы отправляться последовательно, маленькие порции данных накапливаются и отправляются одним TCP сегментом, когда прибывает подтверждение на первый пакет. Красота этого алгоритма заключается в том, что он сам настраивает временные характеристики: чем быстрее придет подтверждение, тем быстрее будут отправлены данные. В медленных глобальных сетях, где необходимо уменьшить количество маленьких пакетов, отправляется меньше сегментов. При последовательных передачах от клиента 1, 1, 2, 1, 2, 2, 3, 1 и 3 байт, на сервере длины возвращаемые операцией чтения вполне, таким образом, могут быть: 1 и 14.

3. Контроль потока данных TCP осуществляется на каждом конце с использованием размера окна (window size). Это количество байт, начинающееся с указанного в поле номера подтверждения, которое приложение собирается принять. Это 16-битовое поле ограничивает размер окна в 65535 байт. Принимающая сторона, если она не успевает обрабатывать передаваемые данные, может запросить изменение размера окна.

4. Медленный старт. Отправитель начинает свою работу, отправив несколько сегментов в сеть. Размер сегментов может достигать размера окна, объявленного получателем. При этом всё будет в порядке, если два хоста находятся в одной и той же локальной сети, однако если между отправителем и получателем присутствуют маршрутизаторы или медленные каналы, могут возникнуть проблемы. Некоторые промежуточные маршрутизаторы должны будут поместить пакеты в очередь, которая может переполниться. Поэтому от TCP требуется, чтобы он поддерживал алгоритм, который называется медленный старт. Он заключается в том, что отправитель начинает работу, отправив один небольшой сегмент и ожидая ACK на этот сегмент. Когда ACK получен, могут быть отправлены 2 сегмента. Когда каждый из этих двух сегментов подтвержден, окно переполнения увеличивается до 4. Таким образом, осуществляется экспоненциальное увеличение.

Про адаптивные механизмы TCP нужно знать хотя бы о их существовании и их перечень, с тем, что их можно либо отключить при необходимости (алгоритм Нэйгла), либо изменить параметры их функционирования (окна приёма-передачи).

Сообщения прикладного уровня в TCP

А что делать, если посредством TCP протокола необходимо передавать определённый порции данных, разграниченные сообщения прикладного уровня? Тогда эти сообщения в **потоке** TCP нужно **форматировать** на уровне **содержания** самих сообщений. На то существует несколько основных способов:

1. Концевые ограничители. Для потока информации формулируют некоторые логические разграничители сообщений в потоке (признак EOF). Для символьного потока, например, это может быть символ '\0' так же для формата ASCIIZ строк языка C (хотя это и не лучшее решение). Один из самых распространённых способов — использование в **текстовом** потоке строк одной пустой строки в качестве разграничителя, 2 идущих подряд символов перевода строки '\n' считаются завершением сообщения. Это использовано во многих протоколах прикладного уровня: HTTP в WEB (запрос GET), SIP в IP-телефонии и другие случаи. Этого способа **недостаток** состоит в том, что он неприменим к произвольным **бинарным** потокам данных, в которых значащими являются любые (все возможные) значения байта данных. Но и это решается (некоторыми дополнительными затратами) путём **экранирования** отдельных символов (байт). Большим **достоинством** такого способа является то, что он **восстанавливает синхронизацию** (границу сообщения) при временном нарушении структуры потока в результате искажений в канале, помех, потери связи, ...

2. Сообщения самоопределённой длины. Это означает, например, что первыми N (1,2,4,...) байтами сообщения передаётся его **длина** в байтах, а затем следует непосредственно само тело сообщения. Длина обычно передаётся в бинарном виде фиксированной длины, но интересным вариантом может быть передача длины и в символьном формате с разделителем. Вариантом использования этого способа есть реализация запроса POST протокола HTTP в WEB, способ достаточно широко используется в проектах промышленной автоматики. Для этого способа **достоинством** будет возможность передачи любого рода **бинарной** информации. А недостатком — невозможность (или сложность) восстановления синхронизации (границы сообщения) при нарушении структуры потока (потере границы сообщений).

3. Наконец, в некоторых целевых системах прикладного свойства может быть заложен обмен сообщениями вообще заранее фиксированной длины L: если передаваемое сообщение не умещается в эту длину — оно сегментируется на 2 или некколько последовательных сообщений, если сообщение короче L — оно дополняется до этой длины «пустым» (фиктивным) содержимым. Такая схема часто применяется в протоколах и проектах промышленной автоматики. Не следует впадать в заблуждение, что такая схема (а она к тому подталкивает!) упрощает приём сообщений: передача сообщений длины L в **поток** нисколько не гарантирует что на приёмный конец будут приходить «пакеты» длины L. Приходить могут фрагменты любой длины (как меньше, так и больше L), как уже отмечалось выше, и принимать их нужно в кольцевой буфер достаточного объёма для последующего разбора.

Иногда, в проектах требующих экстремальной надёжности, используют и комбинацию этих двух методов. Это может быть связано, например, с требованием восстановления синхронизации при нарушении структуры потока. Например: длина сообщения, за которой следует тело сообщения, которое, возможно, завершается повтором значения длины (дублирование для страховки) и всё это

ограничивается разделителем сообщения.

Весьма часто в системах не очень высокой нагруженности (например интерактивных) **клиент** открывает соединение TCP только на передачу **одного единственного** сообщения прикладного уровня, после чего сразу же закрывает сокет. При необходимости передачи следующих сообщений, **клиент** откроет новые соединения, опять же для передачи каждого единичного сообщения. Так работает, например, прикладной протокол HTTP. При этом естественным образом решается проблема разграничения сообщений прикладного уровня.

Присоединённый UDP

Протокол UDP, как уже подчёркивалось, никак не гарантирует надёжность доставки датаграмм. Получатель (например сервер) датаграмм, его сетевой стек, если он перегружен имеет право вообще сбросить (уничтожить) приходящую датаграмму, никак на неё не реагируя, и не извещая даже об ошибке посылкой ICMP пакета.

Клиент протокола UDP, который мы увидим далее, может отсылать датаграммы серверу даже на не существующий IP или порт (когда на хосте не выполняется подходящий сервер UDP). В последнем случае хост получателя ответит сообщением ICMP об ошибке «недоступный порт». Но отправитель (клиент) не получит это уведомление как код завершения отправки, это уведомление ICMP является **асинхронным**. Операция записи в сокет `sendto()` сообщает только о возможных **синхронных** ошибках в момент отправки сообщений.

Иногда используются (например в сети DNS) такой малоизвестный вариант, как **присоединённый** UDP, когда для сокета UDP (в коде клиента) вызывается функция `connect()`. Но при этом не происходит ничего похожего на соединение TCP: ядро просто записывает адрес и порт удалённого корреспондента в сокет. После этого клиент уже не может использовать вызовы `sendto()` и `recvfrom()`, а пользуется вызовами `send()`, `write()`, `recv()`, `read()`. Естественно, такой клиент не может рассылать широковещательные сообщения.

Такой клиент не сможет отправлять сообщения на ошибочный адрес IP (сокет связан с адресом). Но самое главное, что такой сокет будет возвращать асинхронные сообщения ICMP об ошибках от удалённого хоста.

Сетевые сокеты и операции

В конкурсе на лучшую компьютерную идею всех времен и народов сокеты, без сомнения, могли бы рассчитывать на призовое место.
Андрей Боровский, «Программирование для Linux»

Вся мощность и многообразие сетевых возможностей обеспечивается концепцией сетевого сокета, введенного операционной системой BSD и некоторым количеством вызовов API вокруг этого понятия (показываемые прототипы функций полностью **скопированы** из заголовочных файлов определений, вплоть до оригинальных имён в записи параметров).

Создание сокета производится вызовом:

```
#include <sys/socket.h>
/* Create a new socket of type TYPE in domain DOMAIN, using
   protocol PROTOCOL.  If PROTOCOL is zero, one is chosen automatically.
   Returns a file descriptor for the new socket, or -1 for errors.  */
extern int socket( int __domain, int __type, int __protocol ) __THROW;
```

Здесь:

- `__domain` — семейство протоколов, которое может быть:

```
#include <bits/socket.h>
/* Address families.  */
#define AF_UNSPEC       PF_UNSPEC
#define AF_LOCAL        PF_LOCAL
#define AF_UNIX         PF_UNIX
#define AF_FILE         PF_FILE
#define AF_INET         PF_INET
#define AF_AX25         PF_AX25
#define AF_IPX          PF_IPX
```

```
#define AF_APPLETALK    PF_APPLETALK
#define AF_NETROM       PF_NETROM
#define AF_BRIDGE       PF_BRIDGE
#define AF_ATMPVC       PF_ATMPVC
#define AF_X25          PF_X25
#define AF_INET6        PF_INET6
#define AF_ROSE         PF_ROSE
#define AF_DECnet       PF_DECnet
#define AF_NETBEUI      PF_NETBEUI
#define AF_SECURITY     PF_SECURITY
#define AF_KEY          PF_KEY
#define AF_NETLINK      PF_NETLINK
#define AF_ROUTE        PF_ROUTE
#define AF_PACKET       PF_PACKET
#define AF_ASH          PF_ASH
#define AF_ECONET       PF_ECONET
#define AF_ATMSVC       PF_ATMSVC
#define AF_RDS          PF_RDS
#define AF_SNA          PF_SNA
#define AF_IRDA         PF_IRDA
#define AF_PPPOX        PF_PPPOX
#define AF_WANPIPE      PF_WANPIPE
#define AF_LLC          PF_LLC
#define AF_CAN          PF_CAN
#define AF_TIPC         PF_TIPC
#define AF_BLUETOOTH    PF_BLUETOOTH
#define AF_IUCV         PF_IUCV
#define AF_RXRPC        PF_RXRPC
#define AF_ISDN         PF_ISDN
#define AF_PHONET       PF_PHONET
#define AF_IEEE802154   PF_IEEE802154
#define AF_CAIF         PF_CAIF
#define AF_ALG          PF_ALG
#define AF_NFC          PF_NFC
#define AF_VSOCK        PF_VSOCK
#define AF_MAX          PF_MAX
```

- `__type` — тип протокола (не все типы допускаются во всех семействах):

```
#include <bits/socket_type.h>
/* Types of sockets.  */
enum __socket_type
{
  SOCK_STREAM = 1,              /* Sequenced, reliable, connection-based
                                   byte streams.  */
  SOCK_DGRAM = 2,               /* Connectionless, unreliable datagrams
                                   of fixed maximum length.  */
  SOCK_RAW = 3,                 /* Raw protocol interface.  */
  SOCK_RDM = 4,                 /* Reliably-delivered messages.  */
  SOCK_SEQPACKET = 5,           /* Sequenced, reliable, connection-based,
                                   datagrams of fixed maximum length.  */
  SOCK_DCCP = 6,                /* Datagram Congestion Control Protocol.  */
  SOCK_PACKET = 10,             /* Linux specific way of getting packets
                                   at the dev level.  For writing rarp and
                                   other similar things on the user level. */
  SOCK_CLOEXEC = 02000000,      /* Atomically set close-on-exec flag for the
                                   new descriptor(s).  */
  SOCK_NONBLOCK = 00004000      /* Atomically mark descriptor(s) as
                                   non-blocking.  */
};
```

- `__protocol` — имя протокола, обычно оно указывается только для символьных сокетов `SOCK_RAW`, для остальных здесь можно указать 0 и имя протокола будет выбрано автоматически:

```
#include <netinet/in.h>
/* Standard well-defined IP protocols.  */
enum
  {
    IPPROTO_IP = 0,           /* Dummy protocol for TCP.  */
    IPPROTO_HOPOPTS = 0,    /* IPv6 Hop-by-Hop options.  */
    IPPROTO_ICMP = 1,         /* Internet Control Message Protocol.  */
    IPPROTO_IGMP = 2,         /* Internet Group Management Protocol. */
    IPPROTO_IPIP = 4,         /* IPIP tunnels (older KA9Q tunnels use 94).  */
    IPPROTO_TCP = 6,          /* Transmission Control Protocol.  */
    IPPROTO_EGP = 8,          /* Exterior Gateway Protocol.  */
    IPPROTO_PUP = 12,         /* PUP protocol.  */
    IPPROTO_UDP = 17,         /* User Datagram Protocol.  */
    IPPROTO_IDP = 22,         /* XNS IDP protocol.  */
    IPPROTO_TP = 29,          /* SO Transport Protocol Class 4.  */
    IPPROTO_DCCP = 33,        /* Datagram Congestion Control Protocol.  */
    IPPROTO_IPV6 = 41,      /* IPv6 header.  */
    IPPROTO_ROUTING = 43,   /* IPv6 routing header.  */
    IPPROTO_FRAGMENT = 44,  /* IPv6 fragmentation header.  */
    IPPROTO_RSVP = 46,        /* Reservation Protocol.  */
    IPPROTO_GRE = 47,         /* General Routing Encapsulation.  */
    IPPROTO_ESP = 50,       /* encapsulating security payload.  */
    IPPROTO_AH = 51,        /* authentication header.  */
    IPPROTO_ICMPV6 = 58,    /* ICMPv6.  */
    IPPROTO_NONE = 59,      /* IPv6 no next header.  */
    IPPROTO_DSTOPTS = 60,   /* IPv6 destination options.  */
    IPPROTO_MTP = 92,       /* Multicast Transport Protocol.  */
    IPPROTO_ENCAP = 98,     /* Encapsulation Header.  */
    IPPROTO_PIM = 103,      /* Protocol Independent Multicast.  */
    IPPROTO_COMP = 108,     /* Compression Header Protocol.  */
    IPPROTO_SCTP = 132,     /* Stream Control Transmission Protocol.  */
    IPPROTO_UDPLITE = 136,  /* UDP-Lite protocol.  */
    IPPROTO_RAW = 255,      /* Raw IP packets.  */
    IPPROTO_MAX
  };
```

Отметим, что все перечисленные здесь константы вида `AF_*`, `SOCK_*`, `IPPROTO_*` — это не просто символьные препроцессорные константы, а численные значения, которые будут непосредственно **вписываться** в различные поля сетевых пакетов, передаваемых по сети.

Для созданного сокета определяется (`<sys/socket.h>`) целый ряд API операций над сокетом (показаны далеко не все, с полным перечнем крайне полезно познакомиться). Объект сокет в высшей степени подобен файловому дескриптору (а иногда и просто совпадает с ним), поэтому в вызовах (в прототипах в заголовочных файлах `.h`) он и указывается как файловый дескриптор.

```
/* Give the socket FD the local address ADDR (which is LEN bytes long).  */
extern int bind( int __fd, __CONST_SOCKADDR_ARG __addr, socklen_t __len ) __THROW;
```

Функция `bind()` задаёт сокету локальный адрес (связывает) для выбранного семейства протокола. То, что конкретно представляет из себя этот адрес, зависит от самого протокола:

```
# define __CONST_SOCKADDR_ARG   const struct sockaddr*
```

Структура `sockaddr` может конкретизироваться совершенно по-разному для разных семейств протоколов, при вызове указатель преобразовывается к его типу, а 3-й параметр указывает длину адресной структуры для этого семейства протоколов. Например, для нескольких семейств:

```
#include <netinet/in.h>
struct sockaddr_in {
    __SOCKADDR_COMMON (sin_);
    in_port_t sin_port;                 /* Port number.  */
    struct in_addr sin_addr;            /* Internet address.  */
   /* Pad to size of `struct sockaddr'.  */
    unsigned char sin_zero[sizeof (struct sockaddr) -
                           __SOCKADDR_COMMON_SIZE -
                           sizeof (in_port_t) -
```

```
                            sizeof (struct in_addr)];
  };
  ...
  struct sockaddr_in6 {
      __SOCKADDR_COMMON (sin6_);
      in_port_t sin6_port;        /* Transport layer port # */
      uint32_t sin6_flowinfo;     /* IPv6 flow information */
      struct in6_addr sin6_addr;  /* IPv6 address */
      uint32_t sin6_scope_id;     /* IPv6 scope-id */
  };

  #include <linux/netlink.h>
  struct sockaddr_nl {
          __kernel_sa_family_t    nl_family;      /* AF_NETLINK   */
          unsigned short  nl_pad;         /* zero         */
          __u32           nl_pid;         /* port ID      */
          __u32           nl_groups;      /* multicast groups mask */
  };

  #include <linux/un.h>
  struct sockaddr_un {
          __kernel_sa_family_t sun_family; /* AF_UNIX */
          char sun_path[UNIX_PATH_MAX];    /* pathname */
  };
```

В случае **клиента**, в структуре адреса протоколов IP указывается тот **конкретный** хост (адрес и порт), к которому мы хотим получить связь. В случае **сервера**, для IPv4 сервер устанавливает в `bind()` **универсальный адрес**, указываемый константой `INADDR_IN`, что означает: принимать запросы от любого IP. После успешного выполнения `bind()` сокет инициализирован готов к использованию.

Обычный вид кода, который производит создание и инициализацию сокета, имеет достаточно неизменный вид, подобный следующему (показан сервер UDP, но все прочие сервера и клиенты будут делать то же самое):

```
        if( ( sockfd = socket( AF_INET, SOCK_DGRAM, 0 ) ) < 0 )
           error( "server: can't open datagram socket" );
        // Bind our local address so that the client can send to us.
        struct sockaddr_in serv_addr;
        bzero( (char*)&serv_addr, sizeof( serv_addr ) );
        serv_addr.sin_family      = AF_INET;
        serv_addr.sin_addr.s_addr = htonl( INADDR_ANY );
        serv_addr.sin_port        = htons( SERV_UDP_PORT );
        if( bind( sockfd, (struct sockaddr*)&serv_addr, sizeof( serv_addr ) ) < 0 )
           error( "server: can't bind local address" );
        ...

  /* Prepare to accept connections on socket FD.
     N connection requests will be queued before further requests are refused.
     Returns 0 on success, -1 for errors.  */
  extern int listen (int __fd, int __n) __THROW;
```

Функция `listen()` вызывается только **сервером** TCP, и выполняет 2 действия:

- преобразует неприсоединённый сокет (клиентский) в **пассивный**, запросы к которому начинают приниматься ядром;

- вторым аргументом этой функции задаётся максимальное число соединений, которые ядро может помещать в очередь этого сокета;

Функция `listen()` вызывается после `socket()` и `bind()`, перед `accept()`.

```
/* Await a connection on socket FD.
   When a connection arrives, open a new socket to communicate with it,
   set *ADDR (which is *ADDR_LEN bytes long) to the address of the connecting
   peer and *ADDR_LEN to the address's actual length, and return the
   new socket's descriptor, or -1 for errors.
   This function is a cancellation point and therefore not marked with
   __THROW.  */
extern int accept (int __fd, __SOCKADDR_ARG __addr,
                   socklen_t *__restrict __addr_len);
```

Функция `accept()` вызывается **сервером** TCP после для возвращения следующего полностью **установленного** соединения из очереди устанавливаемых соединений (пассивный сокет превращается в **присоединённый**).

```
/* Open a connection on socket FD to peer at ADDR (which LEN bytes long).
   For connectionless socket types, just set the default address to send to
   and the only address from which to accept transmissions.
   Return 0 on success, -1 for errors.
  This function is a cancellation point and therefore not marked with
   __THROW.  */
extern int connect (int __fd, __CONST_SOCKADDR_ARG __addr, socklen_t __len);
```

Функция `connect()` используется **клиентом** TCP для установления **соединения** с TCP сервером.

После завершения работы с соединённым сокетом соединение нужно разорвать, для чего сокет закрыть. Для разрыва TCP соединения, если не быть слишком придирчивым, вполне годится стандартная функция `close()`:

```
#include <unistd.h>
/* Close the file descriptor FD.
  This function is a cancellation point and therefore not marked with
   __THROW.  */
extern int close (int __fd);
```

Но API сокетов предоставляет нам и другую альтернативу, которая позволяет более тонко управлять разрывом соединения:

```
/* Shut down all or part of the connection open on socket FD.
   HOW determines what to shut down:
     SHUT_RD   = No more receptions;
     SHUT_WR   = No more transmissions;
     SHUT_RDWR = No more receptions or transmissions.
   Returns 0 on success, -1 for errors.  */
extern int shutdown( int __fd, int __how ) __THROW;
```

Здесь мы можем раздельно закрывать только считывающую или только записывающую половину соединения.

Обменные операции

После выполнения всяких подготовительных мероприятий с сокетом, сокет готов к записи в него данных, и считывания из него данных (сокет, обычно, полнодуплексный канал, позволяющий двунаправленные операции). Для чтения-записи данных сокета вполне достаточно, особенно для TCP (потокового) сокета, использовать традиционные POSIX обменные функции файловых дескрипторов:

```
#include <unistd.h>
/* Read NBYTES into BUF from FD.  Return the
   number read, -1 for errors or 0 for EOF.
  This function is a cancellation point and therefore not marked with
   __THROW.  */
extern ssize_t read( int __fd, void *__buf, size_t __nbytes ) __wur;
/* Write N bytes of BUF to FD.  Return the number written, or -1.
```

```
     This function is a cancellation point and therefore not marked with
     __THROW.  */
  extern ssize_t write( int __fd, const void *__buf, size_t __n ) __wur;
```

Более того, функция будет так же возвращать нулевое значение как признак EOF по закрытию сокета противоположным концом соединения.

Точно так же (как на файловых дескрипторах) на сокетах можно организовать мультиплексное ожидание ввода используя `select()` или `poll()`.

И точно так же, можно (и нужно!) организовывать **тайм-ауты** ожидания на сокетах в операциях `connect()`, `read()`, `select()` и `poll()`, `recvfrom()`, `recv()`, ... : POSIX вызовом `alarm()` или использованием асинхронных таймеров.

Если же этих традиционных способов вам окажется не достаточно, то API сокетов предоставляет ещё много специфических вариантов обменных функций:

```
  #include <sys/socket.h>
  /* Send N bytes of BUF to socket FD.  Returns the number sent or -1.
     This function is a cancellation point and therefore not marked with
     __THROW.  */
  extern ssize_t send( int __fd, const void *__buf, size_t __n, int __flags );
  /* Read N bytes into BUF from socket FD.
     Returns the number read or -1 for errors.
     This function is a cancellation point and therefore not marked with
     __THROW.  */
  extern ssize_t recv( int __fd, void *__buf, size_t __n, int __flags );
```

Эта пара обменных операций (все они симметричные) предполагает дополнительный, 4-й параметр: `__flags` — нулевое значение, или формируемая в результате логического OR битовая маска флагов, уточняющая характер операции:

```
  #include <bits/socket.h>
  /* Bits in the FLAGS argument to `send', `recv', et al.  */
  enum {
      MSG_OOB             = 0x01,       /* Process out-of-band data.  */
      MSG_PEEK            = 0x02,       /* Peek at incoming messages.  */
      MSG_DONTROUTE       = 0x04,       /* Don't use local routing.  */
  #ifdef __USE_GNU
      /* DECnet uses a different name.  */
      MSG_TRYHARD         = MSG_DONTROUTE,
  # define MSG_TRYHARD    MSG_DONTROUTE
  #endif
      MSG_CTRUNC          = 0x08,       /* Control data lost before delivery.  */
      MSG_PROXY           = 0x10,       /* Supply or ask second address.  */
      MSG_TRUNC           = 0x20,
      MSG_DONTWAIT        = 0x40,       /* Nonblocking IO.  */
      MSG_EOR             = 0x80,       /* End of record.  */
      MSG_WAITALL         = 0x100,      /* Wait for a full request.  */
      MSG_FIN             = 0x200,
      MSG_SYN             = 0x400,
      MSG_CONFIRM         = 0x800,      /* Confirm path validity.  */
      MSG_RST             = 0x1000,
      MSG_ERRQUEUE        = 0x2000,     /* Fetch message from error queue.  */
      MSG_NOSIGNAL        = 0x4000,     /* Do not generate SIGPIPE.  */
      MSG_MORE            = 0x8000,     /* Sender will send more.  */
      MSG_WAITFORONE      = 0x10000,    /* Wait for at least one packet to return.*/
      MSG_FASTOPEN        = 0x20000000, /* Send data in TCP SYN.  */
      MSG_CMSG_CLOEXEC    = 0x40000000  /* Set close_on_exit for file
                                           descriptor received through
                                           SCM_RIGHTS.  */
    };
```

Из них особое внимание стоит обратить на MSG_OOB: отправка или получение **приоритетных** (внеполосовых) данных в TCP соединении.

```
  #include <sys/socket.h>
  /* Send N bytes of BUF on socket FD to peer at address ADDR (which is
```

```
   ADDR_LEN bytes long).  Returns the number sent, or -1 for errors.
   This function is a cancellation point and therefore not marked with
   __THROW.  */
extern ssize_t sendto( int __fd, const void *__buf, size_t __n,
                       int __flags, __CONST_SOCKADDR_ARG __addr,
                       socklen_t __addr_len );
/* Read N bytes into BUF through socket FD.
   If ADDR is not NULL, fill in *ADDR_LEN bytes of it with tha address of
   the sender, and store the actual size of the address in *ADDR_LEN.
   Returns the number of bytes read or -1 for errors.
   This function is a cancellation point and therefore not marked with
   __THROW.  */
extern ssize_t recvfrom( int __fd, void *__restrict __buf, size_t __n,
                         int __flags, __SOCKADDR_ARG __addr,
                         socklen_t *__restrict __addr_len );
```

Эта пара операций ввода-вывода **аналогичны** стандартным операциям `read()` и `write()`, но требуют 3-х дополнительных параметров:

- `__flags` — битовые флаги, которые объяснены выше;

- `__addr` — struct sockaddr, адрес получателя или отправителя, с кем происходит обмен;

- `__addr_len` — размер этой адресной структуры;

Последние 2 аргумента `recvfrom()` аналогичны последним аргументам `accept()`: кто отправил датаграмму (при UDP), или кто инициировал соединение (при TCP). Последние 2 аргумента `sendto()` аналогичны последним аргументам connect(): структура адреса заполняется адресом протокола того места куда отправляется датаграмма (при UDP), или с которым будет устанавливаться соединение (при TCP).

Такие прототипы операций `recvfrom()` и `sendto()` делают их **удобными** для использования в UDP, но все обменные операции в равной мере применимы **ко всем видам сокетов**.

Ещё один вид операций ввода-вывода — векторные операции:

```
#include <sys/uio.h>
/* Read data from file descriptor FD, and put the result in the
   buffers described by IOVEC, which is a vector of COUNT 'struct iovec's.
   The buffers are filled in the order specified.
   Operates just like 'read' (see <unistd.h>) except that data are
   put in IOVEC instead of a contiguous buffer.
  This function is a cancellation point and therefore not marked with
   __THROW.  */
extern ssize_t readv( int __fd, const struct iovec *__iovec, int __count ) __wur;
/* Write data pointed by the buffers described by IOVEC, which
   is a vector of COUNT 'struct iovec's, to file descriptor FD.
   The data is written in the order specified.
   Operates just like 'write' (see <unistd.h>) except that the data
   are taken from IOVEC instead of a contiguous buffer.
  This function is a cancellation point and therefore not marked with
   __THROW.  */
extern ssize_t writev( int __fd, const struct iovec *__iovec, int __count ) __wur;
```

Они позволяют использовать для чтения или записи один или **более** (вектор) буферов с помощью одного вызова функции. Такие операции называются операциями распределяющего чтения (scatter read) и объединяющей записи (gather write).

Второй параметр этих функций — указатель на массив структур `iovec`:

```
#include <bits/uio.h>
/* Structure for scatter/gather I/O.  */
struct iovec {
    void *iov_base;     /* Pointer to data.  */
    size_t iov_len;     /* Length of data.  */
  };
```

А последний параметр `readv()` и `writev()` — это размерность этого массива. Максимально

допустимый размер вектора зависит от типа операционной системы (POSIX 1.g) и её версии, и определяется там же:

```
/* Size of object which can be written atomically.
   This macro has different values in different kernel versions.  The
   latest versions of the kernel use 1024 and this is good choice.  Since
   the C library implementation of readv/writev is able to emulate the
   functionality even if the currently running kernel does not support
   this large value the readv/writev call will not fail because of this.  */
#define UIO_MAXIOV      1024
```

Ну и наконец, самая общая (но как всегда и сложная) форма обменных операций — на случай, если предыдущие не обеспечивают желаемое поведение в тонких деталях:

```
#include <sys/socket.h>
/* Send a VLEN messages as described by VMESSAGES to socket FD.
   Returns the number of datagrams successfully written or -1 for errors.
   This function is a cancellation point and therefore not marked with
   __THROW.  */
extern int sendmmsg (int __fd, struct mmsghdr *__vmessages,
                     unsigned int __vlen, int __flags);
/* Receive a message as described by MESSAGE from socket FD.
   Returns the number of bytes read or -1 for errors.
  This function is a cancellation point and therefore not marked with
   __THROW.  */
extern ssize_t recvmsg (int __fd, struct msghdr *__message, int __flags);
```

Большинство аргументов этих функций скрыто в структуре:

```
#include <bits/socket.h>
/* Structure describing messages sent by `sendmsg' and received by `recvmsg'.  */
struct msghdr {
    void *msg_name;             /* Address to send to/receive from.  */
    socklen_t msg_namelen;      /* Length of address data.  */
    struct iovec *msg_iov;      /* Vector of data to send/receive into.  */
    size_t msg_iovlen;          /* Number of elements in the vector.  */
   void *msg_control;          /* Ancillary data (eg BSD filedesc passing). */
    size_t msg_controllen;      /* Ancillary data buffer length.
                                   !! The type should be socklen_t but the
                                   definition of the kernel is incompatible
                                   with this.  */
   int msg_flags;              /* Flags on received message.  */
  };
```

Параметры сокета

API сокетов включает ряд функций, дающих уточнённую информацию о сокете, или управляющих особенностями поведения сокета. Важнейшей из этих возможностей есть:

```
/* Put the current value for socket FD's option OPTNAME at protocol level LEVEL
   into OPTVAL (which is *OPTLEN bytes long), and set *OPTLEN to the value's
   actual length.  Returns 0 on success, -1 for errors.  */
extern int getsockopt( int __fd, int __level, int __optname,
                       void *__restrict __optval,
                       socklen_t *__restrict __optlen ) __THROW;
/* Set socket FD's option OPTNAME at protocol level LEVEL
   to *OPTVAL (which is OPTLEN bytes long).
   Returns 0 on success, -1 for errors.  */
extern int setsockopt( int __fd, int __level, int __optname,
                       const void *__optval, socklen_t __optlen ) __THROW;
```

Функциями `getsockopt()` и `setsockopt()` считываются и устанавливаются значения многочисленных свойств сокета. Параметр `__fd` должен быть открытым дескриптором сокета.

Параметр `__level` указывает каким протокольным уровнем должен интерпретироваться параметр (`SOL_SOCKET`, `IPPROTO_IP`, `IPPROTO_IPV6`, `IPPROTO_TCP`, ... см. выше):

```
#define SOL_SOCKET      1
...
```

Параметр `__optname` указывает имя параметра к которому относится вызов:

```
#include <asm-generic/socket.h>
#define SO_DEBUG        1
#define SO_REUSEADDR    2
#define SO_TYPE         3
#define SO_ERROR        4
#define SO_DONTROUTE    5
#define SO_BROADCAST    6
#define SO_SNDBUF       7
#define SO_RCVBUF       8
#define SO_SNDBUFFORCE  32
#define SO_RCVBUFFORCE  33
#define SO_KEEPALIVE    9
...
```

Параметр `__optval` указывает адрес переменной, куда помещается считанное значение (`getsockopt()`) или которая содержит новое значение (`setsockopt()`). Тип этой переменной может быть различным, в зависимости от `__optname`, но для многих параметров это `int`.

Примеры изменения использования `setsockopt()` для изменений свойств сокета или изменения адаптационных механизмов TCP:

1. Разрешить быстрый перезапуск сервера (или восстановление упавшего), не ожидая истечения состояния TIME-WAIT (порядка 2-х минут):

```
const int on = 1;
setsockopt( fd, SOL_SOCKET, SO_REUSEADDR, &on, sizeof( on ) );
```

Такой вызов должен предшествовать вызову `bind()` (привязке сокета).

2. Отключение алгоритма Нэйгла (объединения коротких последовательных сегментов в один более длинный), что допустимо для LAN:

```
const int on = 1;
setsockopt( fd, IPPROTO_TCP, TCP_NODELAY, &on, sizeof( on ) );
```

Вспомогательные Функции того же (информационного) предназначения:

```
#include <sys/socket.h>
/* Put the local address of FD into *ADDR and its length in *LEN.  */
extern int getsockname( int __fd, __SOCKADDR_ARG __addr,
                        socklen_t *__restrict __len ) __THROW;
/* Put the address of the peer connected to socket FD into *ADDR
   (which is *LEN bytes long), and its actual length into *LEN.  */
extern int getpeername( int __fd, __SOCKADDR_ARG __addr,
                        socklen_t *__restrict __len ) __THROW;
```

Первая из них (`getsockname()`) возвращает локальный, а вторая (`getpeername()`) — удалённый адресную структуру протокола, связанный на данный момент с сокетом.

Использование сокетного API

Базовые схемы построения обмена в клиентских и серверных кодах, и для UDP и для TCP остаются практически постоянными от проекта к проекту, хотя в деталях могут существенно различаться[5]. Рассмотрим эти базовые схемы (все примеры кодов находятся в каталоге архива под именем `echo-cli-serv`)...

Общие определения:

`common.h :`

```
#ifndef __common_h
#define  __common_h
```

5 За основу примеров этой главы взяты примеры из книги У.Р.Стивенса [3].

```
#include <errno.h>
#include <stdio.h>
#include <stdlib.h>
#include <string.h>
#include <unistd.h>

#include <netdb.h>
#include <sys/socket.h>    /* basic socket definitions */
#include <netinet/in.h>
#include <arpa/inet.h>

#define MAXLINE 4096                /* max text line length */
static char sendline[MAXLINE],     /* write buffer */
            recvline[MAXLINE + 1]; /* reaad buffer */

void  err_dump(const char *, ...);
void  err_sys(const char *, ...);

void str_cli(register FILE*, register int sockfd);
void str_echo(int sockfd);

void dg_cli(FILE* fp, int sockfd,
            struct sockaddr* pserv_addr,
            int servlen);
void dg_echo(int sockfd,
             struct sockaddr* pcli_addr,
             int maxclilen);
#endif
```

Здесь вы можете определить IP (и порты) адрес используемого сервера, локального или удалённого в глобальной сети … но для тестирования работоспособности всех клиент-серверных приложений вполне достаточно, в большинстве случаев, и петлевого интерфейса:

inet.h :

```
/* Definitions for TCP and UDP client/server programs. */
#include "common.h"

#define SERV_UDP_PORT 60000
#define SERV_TCP_PORT 60000
//#define SERV_HOST_ADDR "192.168.1.13" /* host addr for server */
#define SERV_HOST_ADDR "127.0.0.1"      /* host addr for server */

ssize_t readline(int fd, void *vptr, size_t maxlen);
ssize_t writen(int fd, const void *vptr, size_t n);
```

Все показанные дальше 4 вариант (включая UNIX сокеты) сделаны предельно просто, так чтобы они могли быть использованы как базовые шаблоны для расширения в конкретные приложения. Везде в них:

- Клиент ожидает ввода строки с терминала;
- Получив строку он пересылает её серверу…
- Сервер получив строку молча ретранслирует её назад клиенту…
- Клиент выводит полученное на терминал для сравнения на адекватность;
- После чего весь цикл повторяется до бесконечности…

P.S. Обратите внимание, что для портов TCP и UDP здесь выбрано одно и то же численное значение, для того чтобы лишний раз подтвердить что это совершенно разные вещи, и они не мешают взаимно работе друг друга.

Каждое приложение ниже (клиент и сервер каждого типа) разделены на части: часть

формирующая сокет (вызывающая) и часть выполняющая цикл операций ввода-вывода. Так листинги короче и обозримее.

UDP клиент-сервер

Клиент посылающий UDP запросы и диагностирующий ретранслируемые ответы:

dgcli.c :

```
void dg_cli(FILE* fp, int sockfd,
            struct sockaddr* pserv_addr, // ptr to appropriate sockaddr_XX structure
            int servlen) {               // actual sizeof(*pserv_addr)
   int n;
   while (fgets(sendline, MAXLINE, fp) != NULL) {
      n = strlen(sendline);
      if (sendto(sockfd, sendline, n, 0, pserv_addr, servlen) != n)
         err_dump("dg_cli: sendto error on socket");
      // Now read a message from the socket and
      // write it to our standard output.
      n = recvfrom(sockfd, recvline, MAXLINE, 0,
                   (struct sockaddr*)0, (socklen_t*)0);
      if (n < 0)
         err_dump("dg_cli: recvfrom error");
      recvline[n] = 0;    /* null terminate */
      fputs(recvline, stdout);
   }
   if (ferror(fp))
      err_dump("dg_cli: error reading file");
}
```

udpcli.c :

```
#include "inet.h"

int main(int argc, char* argv[]) {
   int sockfd;
   /* Open a UDP socket (an Internet datagram socket). */
   if((sockfd = socket(AF_INET, SOCK_DGRAM, 0)) < 0)
      err_dump("client: can't open datagram socket");
   struct sockaddr_in serv_addr;
   /* Fill in the structure "serv_addr" with the address
    * of the server that we want to send to. */
   bzero((char*)&serv_addr, sizeof(serv_addr));
   serv_addr.sin_family      = AF_INET;
   serv_addr.sin_addr.s_addr = inet_addr(SERV_HOST_ADDR);
   serv_addr.sin_port        = htons(SERV_UDP_PORT);
   dg_cli(stdin, sockfd, (struct sockaddr*)&serv_addr, sizeof(serv_addr));
   close(sockfd);
   exit(0);
}
```

Эхо-сервер UDP, ретранслирующий запросы клиента:

dgecho.c :

```
#include "inet.h"

void dg_echo(int sockfd,
             struct sockaddr* pcli_addr,  /* ptr to appropriate sockaddr_XX structure */
             int maxclilen) {             /* sizeof(*pcli_addr) */
   for (;;) {
      socklen_t clilen = maxclilen;
      int n = recvfrom(sockfd, recvline, MAXLINE, 0, pcli_addr, &clilen);
      if (n < 0) err_dump("dg_echo: recvfrom error");
      if (sendto(sockfd, recvline, n, 0, pcli_addr, clilen) != n)
```

```
         err_dump("dg_echo: sendto error");
   }
}
```

udpserv.c :

```
#include "inet.h"

int main(int argc, char* argv[]) {
   int sockfd;
   /* Open a UDP socket (an Internet datagram socket). */
   if((sockfd = socket(AF_INET, SOCK_DGRAM, 0)) < 0)
      err_dump("client: can't open datagram socket");
   struct sockaddr_in serv_addr;
   /* Fill in the structure "serv_addr" with the address
    * of the server that we want to send to. */
   bzero((char*)&serv_addr, sizeof(serv_addr));
   serv_addr.sin_family      = AF_INET;
   serv_addr.sin_addr.s_addr = inet_addr(SERV_HOST_ADDR);
   serv_addr.sin_port        = htons(SERV_UDP_PORT);
   dg_cli(stdin, sockfd, (struct sockaddr*)&serv_addr, sizeof(serv_addr));
   close(sockfd);
   exit(0);
}
```

Эта пара в работе:

```
$ ./udpserv
...
$ ./udpcli
UDP клиент послает
UDP клиент послает
...
```

Важно! … И очень поучительно для понимания: измените в файле `inet.h` значение IP адреса сервере SERV_HOST_ADDR на адрес отсутствующий (недоступный) в вашей локальной сети, или вообще бессмысленный IPv4, лишь бы он был синтаксически верно записан… При этом UDP-клиент будет бодро отсылать датаграммы «в небо» и бесконечно ожидать оттуда ретрансляции, а приложение никак не будет фиксировать ошибки в происходящем. В противоположность, показанный далее TCP-клиент сразу же заявит о недостижимости сервера. Об этому уже упоминалось ранее, но то было на словах, а здесь — возможность простой живой иллюстрации.

TCP клиент-сервер

Поскольку TCP — потоковый протокол, то полезно предварительно написать функции записи в поток и чтения из потока (именно потому, что в TCP нет «пакетов» и размер чтения-записи за одну операцию может быть произвольным):

writen.c :

```
#include "common.h"

/* Write "n" bytes to a descriptor */
ssize_t writen(int fd, const void *vptr, size_t n) {
   size_t nleft;
   ssize_t nwritten;
   nleft = n;
   while (nleft > 0) {
      if ((nwritten = write(fd, vptr, nleft)) <= 0) {
         if (errno == EINTR) nwritten = 0;     /* and call write() again */
         else return(-1);                     /* error */
      }
      nleft -= nwritten;
      vptr  += nwritten;
```

```
   }
   return(n);
}
```

readln.c :

```
#include "common.h"

static ssize_t my_read(int fd, char *ptr) {
   static int read_cnt = 0;
   static char *read_ptr;
   static char read_buf[MAXLINE];
   if (read_cnt <= 0) {
again:
      if ((read_cnt = read(fd, read_buf, sizeof(read_buf))) < 0) {
         if (errno == EINTR) goto again;
         return(-1);
      } else if (read_cnt == 0)
         return(0);
      read_ptr = read_buf;
   }
   read_cnt--;
   *ptr = *read_ptr++;
   return(1);
}

ssize_t readline(int fd, void *vptr, size_t maxlen) {
   int n, rc;
   char c, *ptr;
   ptr = vptr;
   for (n = 1; n < maxlen; n++) {
      if ((rc = my_read(fd, &c)) == 1) {
         *ptr++ = c;
         if (c == '\n') break;   /* newline is stored, like fgets() */
      } else if (rc == 0) {
         if(n == 1) return(0);   /* EOF, no data read */
         else break;             /* EOF, some data was read */
      } else return(-1);         /* error, errno set by read() */
   }
   *ptr = 0;                     /* null terminate like fgets() */
   return(n);
}
```

Клиент посылающий TCP запросы и диагностирующий получаемые ответы:

strcli.c :

```
#include "common.h"

void str_cli(register FILE* fp, register int sockfd) {
   int n;
   while (fgets(sendline, MAXLINE, fp) != NULL) {
      n = strlen(sendline);
      if (writen(sockfd, sendline, n) != n)
         err_sys("str_cli: writen error on socket");
      /* Now read a line from the socket and
       * write it to our standard output. */
      n = readline(sockfd, recvline, MAXLINE);
      if (n < 0) err_dump("str_cli: readline error");
      recvline[n] = 0;    /* null terminate */
      fputs(recvline, stdout);
   }
   if (ferror(fp))
```

```
      err_sys("str_cli: error reading file");
}
```

tcpcli.c :

```
#include "inet.h"

int main(int argc, char* argv[]) {
   int sockfd;                    // TCP сокет
   struct sockaddr_in serv_addr;  // заполнить структуру адреса сервера
   bzero((char*)&serv_addr, sizeof(serv_addr));
   serv_addr.sin_family      = AF_INET;
   serv_addr.sin_addr.s_addr = inet_addr(SERV_HOST_ADDR);
   serv_addr.sin_port        = htons(SERV_TCP_PORT);
   /* Open a TCP socket (an Internet stream socket). */
   if ((sockfd = socket(AF_INET, SOCK_STREAM, 0)) < 0)
      err_sys("client: can't open stream socket");
   /* Connect to the server. */
   if (connect(sockfd, (struct sockaddr*)&serv_addr, sizeof(serv_addr)) < 0)
      err_sys("client: can't connect to server");
   str_cli(stdin, sockfd);        // цикл обменов с сервером
   close(sockfd);
   exit(0);
}
```

Эхо-сервер TCP, ретранслирующий запросы клиента (присутствующий в архиве сервер реализован как параллельный, обслуживающий много запросов, здесь же он показан в схематичном последовательном виде):

strecho.c :

```
#include "common.h"

void str_echo(int sockfd) {
   int n;
   for (;;) {
      n = readline(sockfd, recvline, MAXLINE);
      if (n == 0) return;      /* connection terminated */
      else if (n < 0) err_dump("str_echo: readline error");
      if (writen(sockfd, recvline, n) != n)
         err_dump("str_echo: writen error");
   }
}
```

tcpserv.c :

```
#include "inet.h"

int main(int argc, char* argv[]) {
   int sockfd;                   // TCP сокет
   if ((sockfd = socket(AF_INET, SOCK_STREAM, 0)) < 0)
      err_dump("server: can't open stream socket");
   struct sockaddr_in serv_addr; // инициализировать униадресом
   bzero((char*)&serv_addr, sizeof(serv_addr));
   serv_addr.sin_family      = AF_INET;
   serv_addr.sin_addr.s_addr = htonl(INADDR_ANY);
   serv_addr.sin_port        = htons(SERV_TCP_PORT);
   if (bind(sockfd, (struct sockaddr*)&serv_addr, sizeof(serv_addr)) < 0)
      err_dump("server: can't bind local address");
   listen(sockfd, 5);
   for (;;) {                    // цикл по подключения
      socklen_t clilen = sizeof(serv_addr);
      int childpid, newsockfd;
      newsockfd = accept(sockfd, (struct sockaddr*)&serv_addr, &clilen);
      if (newsockfd < 0)         // ожидать соединения
```

```
            err_dump("server: accept error");
         if ((childpid = fork()) < 0)
            err_dump("server: fork error");
         else if (childpid == 0) {  // обрабатывать в дочернем процессе
            close(sockfd);          // закрыть копию прослушивающего сокета
            str_echo(newsockfd);    // ретранслировать полученные данные
            exit(0);                // завершить дочерний процесс
         }
         close(newsockfd);          // в роительском процессе
      }
   }
```

Смотрим эту пару в работе:

```
$ ./tcpserv
...
$ ./tcpcli
TCP клиент посылает
TCP клиент посылает
...
```

Взаимодействие запрос-ответ

Чаще всего (но это не всегда так) клиент-серверное взаимодействие в TCP реализует схему запрос-ответ, когда клиент отправляет серверу запрос, и ожидает на него ответа, а сервер обслуживает этот запрос, подготавливает на него ответ и возвращает ответ ожидающему клиенту.

В примере выше показано именно такое взаимодействие. TCP взаимодействие запрос-ответ может реализовываться в двух вариантах:

1. Когда клиент открывает соединение (`connect()` со стороны клиента и `accept()` со стороны сервера), а затем **периодически** отправляет через это соединение (соединённый сокет) запросы, и через это же соединение сервер последовательно возвращает клиенту ответы на запросы. Это ровно та схема, которая показана выше. По этой схеме работают множество сетевых служб, примерами могут быть протоколы: Telnet, FTP и др. Эта схема хоть и очевидна, но чаще всё же используется другая схема...

2. Другая схема состоит в том, что клиент открывает **новое** соединение на каждый запрос. Через это установленное соединение клиент пересылает запрос, и через него же сервер возвращает результат. Возвратив результат на запрос сервер немедленно **закрывает** соединение (как вариант, соединение может закрывать клиент **после** получения ответа от сервера). Эта схема используется в Интернет ещё чаще, чем предыдущая, примером её использования есть HTTP (запросы клиента GET или POST). В такой схеме фрагмент кода сервера, показанный выше, трансформируется в ещё более простой код:

```
   ...
   while(1) {                                          // цикл по подключения
      int len = sizeof(serv_addr),
          newsockfd = accept(sockfd, (struct sockaddr*)&serv_addr, &len);
      if(newsockfd < 0) err_dump( ... );               // ожидать соединения
      int n = readline(newsockfd, recvline, MAXLINE);  // чтение от клиента
      if(n < 0) err_dump( ... );
      if(writen(newsockfd, recvline, n) != n)          // ретрансляция
         err_dump( ... );
      close(newsockfd);                                // закрыть после ответа
   }
```

Главное отличие здесь состоит в исключении цикла по поступающим запросам клиента — каждый запрос-ответ является **законченным** актом взаимодействия, и завершается закрытием соединения.

Клиент-сервер в UNIX домене

Для сравнения, в архиве примеров приведены клиент и эхо-сервер, работающие в семействе протоколов UNIX домена — это взаимодействие в пределах локального компьютера. Такое сравнение

способствует гораздо более глубокому пониманию вопросов сетевого программирования. Подобным образом взаимодействуют графические (GUI) пользовательские приложения Linux с сервером графической подсистемы X11 и оконными менеджерами (вообще то говоря, сетевыми приложениями и протолом). Показаны пары приложений (клиент и сервер) как для UDP (`unixdgcli.c` и `unixdgserv.c`), так и для TCP (`unixstrcli.c` и `unixstrserv.c`).

Их работа (тестирование) будет выглядеть аналогично показаннриу выше:

```
$ ./unixstrserv
...
$ ./unixdgserv
...
$ ./unixstrcli
UNIX сокет поток
UNIX сокет поток
...
$ ./unixdgcli
UNIX датаграмм поток
UNIX датаграмм поток
...
```

Управляющие операции

Функции `ioctl()` традиционно являлись системным интерфейсом управления для всего, что не попадало в какую-либо другую чётко определённую категорию. Стандарт POSIX постепенно избавляется от вызова `ioctl()` в различных ситуациях, заменяя её функциями-обёртками с стандартизованной функциональностью.

Тем не менее, `ioctl()` может использоваться во многих случаях получения информации от сетевого стека, или управлением функциональностью сокета. Функция определена как:

```
int ioctl(int fd, int request, void* arg);
```

Функция всегда применяется к файловому дескриптору или сокету. Вид 3-го арумента полностью определяется целочисленным кодом операции `request` (часто это указатель на числовое значение, но может быть и сложная структура). Для считывания и изменения значения одного и того же параметра используются разные кода `ioctl()` (код определяет направление передачи данных). Определения некоторых кодов, относящиеся к области сокетов, можно найти в файле `<linux/sockios.h>` :

```
...
/* Socket configuration controls. */
#define SIOCGIFNAME     0x8910          /* get iface name               */
#define SIOCSIFLINK     0x8911          /* set iface channel            */
#define SIOCGIFCONF     0x8912          /* get iface list               */
#define SIOCGIFFLAGS    0x8913          /* get flags                    */
#define SIOCSIFFLAGS    0x8914          /* set flags                    */
...
```

Работающие примеры использования операций `ioctl()` можно видеть в подкаталоге `ioctl` каталога `ufd` архива примеров кода:

```
$ ip link
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue state UNKNOWN mode DEFAULT group default
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
2: enp2s14: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc mq state UP mode DEFAULT group
default qlen 1000
    link/ether 00:15:60:c4:ee:02 brd ff:ff:ff:ff:ff:ff
3: wlp8s0: <BROADCAST,MULTICAST> mtu 1500 qdisc noop state DOWN mode DEFAULT group default qlen
1000
    link/ether 00:13:02:69:70:9b brd ff:ff:ff:ff:ff:ff

$ ./prifinfo inet4 0
lo: <UP LOOP >
  IP addr: 127.0.0.1
enp2s14: <UP BCAST MCAST >
```

```
IP addr: 192.168.1.5
broadcast addr: 192.168.1.255
```

Классы обслуживания сервером

Системам UNIX свойственна клиент-серверная архитектура, эта архитектура имеет в UNIX много десятилетий историю, и многие крупные проекты построены именно по этой архитектуре. Именно поэтому, для клиент-серверной архитектуры изучено много вариантов того, как работает обслуживающий сервер. Эти варианты рассмотрены ниже.

Рассмотрение сосредоточено вокруг TCP серверов, так как они наиболее часто используют какие-либо формы распараллеливания обслуживания, для серверов TCP это особенно актуально, так как именно на этом протоколе строятся, главным образом, высоконагруженные сервера массового обслуживания. Но и для сервера UDP могут быть также реализованы параллельные формы обслуживания.

Различные варианты показаны в каталоге архива `xservers`. В проекте реализован специализированный TCP клиент (файл `cli.cc`), который посылает требуемое число раз[6] запросы к нужному серверу (определяется выбором порта), принимает от него ответ, и тут же разрывает соединение (по такой примерно схеме обрабатываются запросы в HTTP протоколе). Сервера представляют собой простые ретрансляторы, но выполненные в различной технике.

Клиент измеряет время (точнее – **число тактов** частоты процессора, это высокая точность наносекундного диапазона[7]) между отправкой запроса серверу и приходом ответа от него. Для фиксации числа тактов с момента старта процессора используется измерение аппаратного счётчика RDTSC, присутствующего во всех современных моделях процессоров семейства x86. Код записан с использованием инлайного ассемблера проекта GCC:

rdtsc.c :

```
uint64_t rdtsc(void) {
   union sc {
      struct { uint32_t lo, hi; } r;
      uint64_t f;
   } sc;
   __asm__ __volatile__ ("rdtsc" : "=a"(sc.r.lo), "=d"(sc.r.hi));
   return sc.f;
}

// вариант для старых GCC:
// __asm__ __volatile__ (".byte 0x0f, 0x31" : "=a"(sc.r.lo), "=d"(sc.r.hi));

// вариант но только для 32-бит i686:
// asm volatile ("rdtsc" : "=A" (x));
```

Каждый запрос к серверу представляет собой случайное число, генерируемое клиентом, в символьной форме. Ретранслированный сервером ответ сверяется с запросом для дополнительного контроля. Все показанные программы показаны в упрощённых вариантах: не везде сделана полная обработка ошибочных ситуаций, и сознательно не включена обработка сигнала `SIGCHLD`, которая должна препятствовать появлению «зомби» процессов.

Код клиента мы не обсуждаем (он приведен в архиве), но относительно его опций запуска: `-a` — IP адрес сервера (по умолчанию это `localhost`), `-p` — значение TCP порта подключения (по умолчанию это 51000, что соответствует простому последовательному серверу) и `-n` — число запросов к серверу в серии (по умолчанию 10).

Программный код выполнен в нотации языка C++ (хотя специфические объектные особенности C++, за исключением потокового ввода-вывода C++ и не использованы — всё то же легко выписать на классическом C, но оно выглядит несколько более объёмным, и это одна из причин выбора языка иллюстраций). Я собираю и показываю иллюстрации с компилятором и библиотекой:

```
$ gcc --version
```

6 Серия запросов от клиента делается для усреднения результата и для того (как будет видно далее), чтобы исключить (или наоборот учесть, выделить) эффекты кэширования памяти.

7 Инструмент для такого хронометража собран в статически компонуемую библиотеку `libdiag.a`, все коды для неё представлены в архиве, но здесь они обсуждаться не будут.

```
gcc (Ubuntu 11.3.0-1ubuntu1~22.04) 11.3.0
Copyright (C) 2021 Free Software Foundation, Inc.
This is free software; see the source for copying conditions.  There is NO
warranty; not even for MERCHANTABILITY or FITNESS FOR A PARTICULAR PURPOSE.
```

(В заметно более ранних версиях GCC были отличия в путевых именах заголовочных файлов, но это легко решаемые проблемы.)

Часть общих определений и функций этой иллюстрации вынесены в общие файлы, они используются всеми вариантами серверов, и их общее использование сильно упрощает сравнительное изучение собственно кодов серверов:

common.h :

```
#if !defined(__COMMON_H)
#define __COMMON_H

#include <iostream>
#include <iomanip>
using namespace std;
#include <stdlib.h>
#include <stdio.h>
#include <errno.h>
#include <string.h>
#include <netdb.h>
#include "libdiag.h"

#define EOK 0

const int PORT = 51000,
          SINGLE_PORT = PORT,        // 51001
          FORK_PORT = PORT + 1,
          FORK_LARGE_PORT = PORT + 2,
          PREFORK_PORT = PORT + 3,
          XINETD_PORT = PORT + 4,    // 51004
          THREAD_PORT = PORT + 5,
          THREAD_POOL_PORT = PORT + 6,
          PRETHREAD_PORT = PORT + 7,
          QUEUE_PORT = PORT + 8;     // 51008
const int MAXLINE = 40;

// критическая ошибка ...
void errx(const char *msg, int err = EOK);
// ретранслятор тестовых пакетов TCP
void retrans(int sc);
// создание и подготовка прослушивающего сокета
int getsocket(in_port_t);
extern int debug; // уровень отладочного вывода сервера
// параметры строки запуска сервера
void setv(int argc, char *argv[]);
#endif
```

common.c :

```
#include "common.h"

// диагностика ошибки ...
void errx(const char *msg, int err) {
    perror(msg);
    if (err != EOK) errno = err;
    exit(EXIT_FAILURE);
}

// ретранслятор тестовых пакетов TCP
static char chdata[MAXLINE];
```

```
void retrans(int sc) {
   int rc = read(sc, chdata, MAXLINE);
   if (rc > 0) {
      rc = write(sc, chdata, strlen(chdata) + 1);
      if (rc < 0) perror("write data failed");
   }
   else if (rc < 0) { perror("read data failed"); return; }
   else if (rc == 0) { cout << "client closed connection" << endl; return; };
   return;
}

// создание и подготовка прослушивающего сокета
static struct sockaddr_in addr;
int getsocket(in_port_t p) {
   int rc = 1, ls;
   if (-1 == (ls = socket(AF_INET, SOCK_STREAM, 0)))
      errx("create stream socket failed");
   if (setsockopt(ls, SOL_SOCKET, SO_REUSEADDR, &rc, sizeof(rc)) != 0)
      errx("set socket option failed");
   memset(&addr, 0, sizeof(addr));
   addr.sin_family = AF_INET;
   addr.sin_port = htons(p);
   addr.sin_addr.s_addr = htonl(INADDR_ANY);
   if (bind(ls, (struct sockaddr*)&addr, sizeof(sockaddr)) != 0)
      errx("bind socket address failed");
   if (listen(ls, 25) != 0)
      errx("put socket in listen state failed");
   cout << "waiting on port " << p << " ..." << endl;
   return ls;
}

// уровень отладочного вывода сервера
int debug = 0;
void setv(int argc, char *argv[]) {
   debug = (argc > 1 && 0 == strcmp(argv[1], "-v")) ? 1 : 0;
   if (debug) cout << "verbose mode" << endl;
}
```

При тестировании можно запускать клиент и сервера на одном хосте (сервер `localhost` по умолчанию), на раздельных хостах LAN (чтобы клиент и сервер не разделяли производительность одних и тех же процессоров при временных замерах), или удалённо в глобальной сети. Но временные задержки реакции сервера намного ниже, чем фремя распространения по физической сети, поэтому сравнения проведём именно на петлевом интерфейсе.

Последовательный сервер

Код простейшего последовательного сервера:

ech0.cc :

```
// последовательный ретранслятор тестовых пакетов TCP
int main(int argc, char *argv[]) {
   int ls = getsocket(SINGLE_PORT), rs;
   setv(argc, argv);
   while (true) {
      if((rs = accept(ls, NULL, NULL)) < 0)
         errx("accept error");
      retrans(rs);
      close(rs);
      if(debug) cout << "*" << flush;
   }
   exit(EXIT_SUCCESS);
```

```
}
```

Выполнение:

```
$ sudo nice -n-19 ./ech0
waiting on port 51000 ...
^C
$ sudo nice -n-19 ./cli -p 51000 -n25
host: localhost, TCP port = 51000, number of echoes = 25
time of reply - Cycles [usec.] :
201615[84]      68259[28]       61590[25]       58374[24]       56883[23]
58092[24]       57909[24]       57522[23]       57519[23]       58440[24]
57117[23]       56571[23]       57057[23]       55872[23]       59031[24]
56148[23]       56808[23]       51144[21]       53736[22]       52761[21]
52398[21]       52269[21]       50538[21]       52053[21]       51636[21]
Mean: 22.875 | Mean square deviation: 1.61536
```

Параллельный сервер

Следующий вариант - это сервер, который на протяжении нескольких десятилетий считается классической реализацией параллельного сервера: когда по поступлению очередног запроса (`accept()`) порождается (вызовом `fork()`) новый обслуживающий процесс (клон родительского процесса), который и занимается обслуживанием поступившего запрос. Родительский же процесс при этом возвращается в режим прослушивания следующих поступающих запросов:

ech1.cc :

```
// ретранслятор с fork
int main(int argc, char *argv[]) {
   int ls = getsocket(FORK_PORT), rs;
   setv(argc, argv);
   while (true) {
      if ((rs = accept(ls, NULL, NULL)) < 0)
         errx("accept error");
      pid_t pid = fork();
      if (pid < 0)
         errx("fork error");
      if (pid == 0) {
         close(ls);
         retrans(rs);
         close(rs);
         if(debug) cout << "*" << flush;
         exit(EXIT_SUCCESS);
      }
      else close(rs);
   }
   exit(EXIT_SUCCESS);
}
```

Выполнение:

```
$ sudo nice -n-19 ./ech1
waiting on port 51001 ...
^C
$ sudo nice -n-19 ./cli -p 51001 -n25
host: localhost, TCP port = 51001, number of echoes = 25
time of reply - Cycles [usec.] :
754818[314]     538815[224]     656835[273]     568614[236]     506487[211]
438210[182]     636324[265]     426072[177]     556410[231]     479442[199]
631098[262]     461304[192]     480411[200]     599235[249]     476529[198]
395757[164]     387363[161]     415428[173]     485223[202]     764427[318]
521814[217]     783915[326]     406083[169]     556893[232]     534963[222]
Mean: 220.125 | Mean square deviation: 43.8095
```

Такой сервер может обслуживать достаточно много запросов одновременно (при условии, что у него остаётся на то достаточно ресурсов процессоров и памяти). Но, как и следовало ожидать, реактивность (пауза перед обслуживанием) у него значительно хуже.

Предварительное клонирование процесса

Получается, что для серверов, работающих на высоко интенсивных потоках запросов, с традиционным fork-методом всё не так хорошо со скоростью реакции... Но можно поменять порядок вызовов `fork()` и `accept()` местами – создать заранее некоторый **пул** обслуживающих процессов, каждый из которых до прихода клиентского запроса будет заблокирован на `accept()` (все `accept()` на одном и том же пассивном сокете, что не предусмотрено спецификацией, но это работает!). А после отработки очередного клиентского запроса заблаговременно создать новый обслуживающий процесс. Эта техника описана в литературе как «предварительный fork» или pre-fork. Меняем код сервера:

ech11.cc :

```
const int NUMPROC = 3;
// ретранслятор с предварительным fork (prefork)
int main(int argc, char *argv[]) {
   int ls = getsocket(PREFORK_PORT), rs;
   setv(argc, argv);
   for (int i = 0; i < NUMPROC; i++) {
      if (fork() == 0) {
         int rs;
         while(true) {
            if ((rs = accept(ls, NULL, NULL)) < 0)
               errx("accept error");
            retrans(rs);
            close(rs);
            if (debug)
               cout << i << flush;
            delay(250); // пауза 250 usec.
         }
      }
   }
   for (int i = 0; i < NUMPROC; i++)
      wait(NULL);
   exit(EXIT_SUCCESS);
}
```

Выполнение:

```
$ sudo nice -n-19 ./ech11
waiting on port 51003 ...
^C
$ sudo nice -n-19 ./cli -p 51003 -n25
host: localhost, TCP port = 51003, number of echoes = 25
time of reply - Cycles [usec.] :
121971[50]      100428[41]      96906[40]       64575[26]       72657[30]
62886[26]       61074[25]       59622[24]       56355[23]       56481[23]
58227[24]       55269[23]       54381[22]       58335[24]       55287[23]
67938[28]       56145[23]       53421[22]       63234[26]       58638[24]
55389[23]       57414[23]       55443[23]       54297[22]       54039[22]
Mean: 25.4167 | Mean square deviation: 4.94062
```

Здесь цифры весьма близкие в к простому последовательному серверу.

Создание потока по запросу

Строим параллельный сервер (файл `ech2.cc`), но вместо параллельных клонов процессов теперь будем порождать параллельные потоки в том же адресном пространстве:

ech2.cc :

```
void* echo(void* ps) {
    int sc = *(int*)ps;
    sched_yield();
    retrans(sc);
    close(sc);
    if (debug)
       cout << "*" << flush;
    return NULL;
}

// ретранслятор с pthread_create по запросу
int main(int argc, char *argv[]) {
   int ls = getsocket(THREAD_PORT), rs;
   setv(argc, argv);
   while (true) {
      pthread_t tid;
      if ((rs = accept(ls, NULL, NULL)) < 0)
         errx("accept error");
      if (pthread_create(&tid, NULL, &echo, &rs) != EOK)
         errx("thread create error");
      sched_yield();
   }
   exit(EXIT_SUCCESS);
}
```

Выполнение:

```
$ sudo nice -n-19 ./ech2
waiting on port 51005 ...
^C
$ sudo nice -n-19 ./cli -p 51005 -n25
host: localhost, TCP port = 51005, number of echoes = 25
time of reply - Cycles [usec.] :
1015857[423]    222273[92]      309009[128]     208569[86]      220194[91]
326541[136]     196122[81]      189402[78]      189324[78]      183285[76]
182238[75]      184515[76]      184845[77]      191820[79]      197787[82]
259284[108]     217791[90]      194625[81]      215502[89]      193584[80]
188184[78]      209352[87]      192684[80]      198282[82]      320907[133]
Mean: 89.2917 | Mean square deviation: 17.7728
```

Пул потоков

Точно так, как мы это делали с предварительным созданием клона процесса (`ech11.cc`), мы можем создать сервер, который будет предварительно создавать несколько поток, которые будет заблокирован на `accept()` в ожидании запросов на обслуживание. Мы, фактически, поменяли местами вызовы `pthread_create()` и `accept()` в предыдущей схеме:

ech22.cc :

```
static int ntr = 3;
static pthread_mutex_t mutex = PTHREAD_MUTEX_INITIALIZER;
static pthread_cond_t condvar = PTHREAD_COND_INITIALIZER;

void* echo(void* ps) {
    int sc = *(int*)ps, rs;
    sched_yield();
    if ((rs = accept(sc, NULL, NULL)) < 0)
       errx("accept error");
    retrans(rs);
    close(rs);
    pthread_mutex_lock(&mutex);
```

```
    ntr++;
    pthread_cond_signal(&condvar);
    pthread_mutex_unlock(&mutex);
    if (debug)
       cout << pthread_self() << '.' << flush;
    delay(250);  // пауза 250 usec.
    return NULL;
}

// ретранслятор с предварительным pthread_create()
int main(int argc, char *argv[]) {
   int ls = getsocket(PRETHREAD_PORT), rs;
   setv(argc, argv);
   while(true) {
      pthread_t tid;
      if (pthread_create(&tid, NULL, &echo, &ls) != EOK)
         errx("thread create error");
      sched_yield();
      pthread_mutex_lock(&mutex);
      ntr--;
      while (ntr <= 0)
         pthread_cond_wait(&condvar, &mutex);
      pthread_mutex_unlock(&mutex);
   }
   exit(EXIT_SUCCESS);
}
```

Здесь `accept()` перенесен в обрабатывающий поток. Какой конкретно из потоков будет разблокирован для обработки при получении запроса — непредсказуемо! Для синхронизации использована условная переменную, но могут применяться любые из синхронизирующих примитивов.

Выполнение:

```
$ sudo nice -n-19 ./ech22
waiting on port 51007 ...
^C
$ sudo nice -n-19 ./cli -p 51007 -n25
host: localhost, TCP port = 51007, number of echoes = 25
time of reply - Cycles [usec.] :
221172[92]      79551[33]       83268[34]       70563[29]       96792[40]
61968[25]       69990[29]       68184[28]       69705[29]       69486[28]
68427[28]       69159[28]       60072[25]       60039[25]       60069[25]
59787[24]       79071[32]       67590[28]       59730[24]       58710[24]
68250[28]       67662[28]       58119[24]       81150[33]       167340[69]
Mean: 30 | Mean square deviation: 8.97682
```

Последовательный сервер с очередью обслуживания

Есть ещё один класс серверов, который при определённых условиях может оказаться оптимальнее параллельных. Это последовательный сервер с очередью обслуживания.

ech4.cc :

```
static queue<int> events;
static pthread_mutex_t mutex = PTHREAD_MUTEX_INITIALIZER;

void* reply(void*) {
   int rsq;
   while (true) {
      if (events.empty())
         continue;
      pthread_mutex_lock(&mutex);
      rsq = events.front();
      events.pop();
```

```
      if (debug)
         cout << '-' << rsq << '.' << flush;
      pthread_mutex_unlock(&mutex);
      retrans(rsq);
      close(rsq);
   }
}

// последовательный ретранслятор с очередью обслуживания
int main(int argc, char *argv[]) {
   int ls = getsocket(QUEUE_PORT);
   setv(argc, argv);
   pthread_t tid;
   if (pthread_create(&tid, NULL, &reply, NULL) != EOK)
      errx("thread create error");
   while (true) {
      int rs = accept(ls, NULL, NULL);
      if (rs < 0) errx("accept error");
      pthread_mutex_lock(&mutex);
      events.push(rs);
      if (debug)
         cout << '+' << rs << '.' << flush;
      pthread_mutex_unlock(&mutex);
   }
   exit(EXIT_SUCCESS);
}
```

Выполнение:

```
$ sudo nice -n-19 ./ech4
waiting on port 51008 ...
^C
$ sudo nice -n-19 ./cli -p 51008 -n25
host: localhost, TCP port = 51008, number of echoes = 25
time of reply - Cycles [usec.] :
140265[58]      101799[42]      56643[23]       58818[24]       58521[24]
55710[23]       56742[23]       52230[21]       55062[22]       60906[25]
62130[25]       56286[23]       56343[23]       56433[23]       42876[17]
51561[21]       50826[21]       52536[21]       48429[20]       53763[22]
52680[21]       50244[20]       49935[20]       48507[20]       53337[22]
Mean: 22.75 | Mean square deviation: 4.39934
```

Как понятно при внимательном рассмотрении, архитектура с входной очередью обслуживания может быть расширена также на **любую параллельную** реализацию сервера. Это может быть очень перспективным направлением развития для малых, экономных и встраиваемых систем, где нужно препятствовать интенсивному разбазариванию ресурсов (за счёт бесконтрольного создания дочерних процессов или потоков).

Суперсервер и сокетная активация

Есть ещё один способ построения и запуска сетевых серверов, сочетающий простоту кодирования с экономичностью решения для бюджетных архитектур. Поскольку в нагруженной системе может быть достаточно большое число (несколько десятков) различных серверов, ожидающих подключений на разных портах, находящихся в пассивном ожидании и потребляющих при этом ресурсы (память), то в UNIX была давно была предложена другая техника активации серверов — по запросу. Это реализуется использованием суперсервера и сокетной активации[8]. Философия сокетной активации состоит в том:

- Запущенный суперсервер пассивно **прослушивает весь** поддерживаемый (конфигурированный) диапазон портов UDP и TCP.
- При появлении активности (запросе от клиента) на каком либо из этих портов, суперсервер

8 Это способ очень в духе UNIX и очень широко используемый в UNIX различными проектами.

запускает программу, приписанную (в конфигурационных файлах) в качестве сервера для этого протокола. Этой программой сервера может быть как штатная реализация, так и ваше собственное приложение.

- Весь ввод-вывод из сети при этом продолжает приниматься и отправляться суперсервером, но он перенаправляет сетевой ввод-вывод на **стандартные потоки** ввода-вывода (SYSIN и SYSOUT) запущенной программы сервера.

Первым исторически из суперсерверов, наиболее известными, и используемым до сегодня на малых и встраиваемых архитектурах являются `inetd`. В десктопных и серверных архитектурах более часто используется следующее поколение `xinetd`. Большинство функциональности сокетной активации включено также в поддержку новой системы управления загрузкой и сервисами `systemd`, пришедшей на смену традиционной системе `init`.

Все из суперсерверов опираются на перечисление **зарегистрированные** сетевых служб (протоколов, серверов) в системном файле `/etc/services`:

```
$ cat /etc/services | wc -l
11176
$ cat /etc/services
...
echo            7/tcp
echo            7/udp
...
daytime         13/tcp
daytime         13/udp
...
ftp             21/tcp
ftp             21/udp          fsp fspd
ssh             22/tcp                          # The Secure Shell (SSH) Protocol
ssh             22/udp                          # The Secure Shell (SSH) Protocol
telnet          23/tcp
telnet          23/udp
...
```

Различие суперсерверов проявляется в их конфигурировании.

- Непосредственно **прослушиваемые** `inetd` порты записаны в его конфигурационном файле `/etc/inetd.conf`, по принципу: один сервис — одна строка конфигурации. В этой строке от 6-ти до 11-ти **позиционных** параметров, в строго предопределённом порядке, разделённых пробелами, никакие переносы строки не допускаются.
- Конфигурации `xinetd` более обстоятельны, описываются не одной строкой **позиционных** параметров на сервис, как для `inetd`, а целым блок **ключевых** параметров. Используемых параметров довольно много, большинство из них — опциональные, а основные очень похожи и соответствуют полям строки конфигурации `inetd`. Эти конфигурации записываются файлами в каталоге `/etc/xinetd.d` (чаще по одному сервису на файл, но может быть и по несколько сервисов одним файлом — все файлы этого каталога читаются **последовательно** как одно целое). Здесь каждый сервис конфигурируется одной **записью** (заключённой в блок скобками `{...}`).
- Управляющие файлы systemd (управляющие стартом и остановом всех служб Linux) размещаются в каталоге `/usr/lib/systemd/system/`. Для сокетной активации службы создаются 2 стартовых файла, на примере SSH это `sshd.socket` и `sshd@.service`: первый содержит описание сокета и порта, а второй — правил старта сервера. Формат параметров этих файлов подобен `xinetd`.

Рассмотрим запуск посредством сокетной активации сервера (ретранслятора), аналогичного рассматриваемым выше. Большим достоинством этого метода есть то, что сервер может быть выполнен быстро, на **любых** языках, компилирующих или скриптовых (ниже показаны несколько реализаций: C, C++, bash, JavaScript). Вот несколько примеров, любой из которых мы можем использовать (всё тот же каталог архива `xservers`):

ech3c.c :

```
int main(int argc, char *argv[]) {
   char data[MAXLINE];
   while (1)
      write(STDOUT_FILENO, data, read(STDIN_FILENO, data, MAXLINE));
   exit(EXIT_SUCCESS);
}
```

ech3cc.cc :

```
int main(void) {
   char buf[MAXLINE];
   // простейшая ретрансляция ...
   while (true) {
      if ((cin >> buf).eof()) break;
      cout << buf << endl;
   }
   return EXIT_SUCCESS;
}
```

ech3.sh :

```
#!/bin/bash
while [TRUE]
do
   read buf
   if [[${#buf} -eq 0]]   # ^D - конец ввода
   then break
   fi
   echo $buf
done
```

ech3.js :

```
#!/usr/bin/js
while(true) {
   var buf = readline();
   if(buf === null) {       // ^D - конец ввода
      break;
   }
   print( buf );
}
```

Как легко видеть, сервер в этом варианте приобретает простейший вид, и его (любой) легко оттестировать в локальном запуске:

```
$ ~/ech3
1
1
12
12
123
123
^D
```

За простоту программного кода сервера нужно платить некоторой усложнённостью системной конфигурации для его запуска, для этого нужно:

1. При запуске сервера должно указываться **абсолютное путевое имя** программы сервера, поэтому копируем программу куда-то в легкодоступное место (в экспериментах — в домашний каталог пользователя):

```
$ cp ech3.sh $HOME
$ ls ~/ech*
/home/Olej/ech3.sh
```

2. Добавить запись конфигурации `xinetd` в каталог `/etc/xinetd.d` отдельным файлом (в

примере используем `xinetd`, остальные суперсервера конфигурируюся подобно):

```
# cat /etc/xinetd.d/ech3
service ech3
{
    disable = no
    protocol = tcp
    wait = no               # параллельный сервер
    user = Olej             # имя от которого запускать
    server = /home/Olej/ech3 # путь к программе
}
```

3. При каждой правке конфигураций заставить перечитать новые конфигурации. Это можно сделать либо послав запущенному серверу сигнал `SIGHUP`:

```
# ps -A | grep inetd
 7408 ?        00:00:00 xinetd
# kill -SIGHUP 7408
```

Либо это можно сделать полностью перезапустив суперсервер:

```
# systemctl restart xinetd.service
# systemctl status xinetd.service
xinetd.service - Xinetd A Powerful Replacement For Inetd
   Loaded: loaded (/usr/lib/systemd/system/xinetd.service; enabled)
   Active: active (running) since Вс 2014-06-15 23:33:41 EEST; 42min ago
...
```

Теперь у нас всё готово к испытаниям полученного сервера:

```
# sudo nice -n19 ./cli -a 192.168.1.5 -p51004 -n20
host: 192.168.1.5, TCP port = 51004, number of echoes = 20
time of reply - Cycles [usec.] :
11242486[4333]  15039250[5797]  10533778[4060]  10174720[3922]  21456950[8271]
14830070[5716]  10340546[3986]  12170304[4691]  16235328[6258]  46813980[18046]
10834944[4176]  42702314[16461] 9714874[3745]   9897594[3815]   8937908[3445]
10455986[4030]  10009446[3858]  35143576[13547] 24846692[9578]  13429070[5176]
```

Здесь задержки, естественно, гораздо больше (1-2 порядка), чем у рассмотренных ранее «нативных» реализаций, но для очень многих проектов это не является критическим фактором, а простота и **гибкость** перенастроек (через конфигурационные файлы) перекрывают этот недостаток.

На что хотелось бы обратить внимание в завершение рассмотрения сокетной активации? **Во-первых**, на то, что хотя ваша собственная программа **сервера** и работает (как обычная консольная программа-фильтр) с входным потоком SYSIN (дескриптор 0) и выходным потоком SYSOUT (дескриптор 1), но программа здесь может применять к этим **потокам** также весь API, применяемый для работы с сетевыми сокетами: `getpeerbyname(0,...)`, `getsockopt(1,...)`, `setsockopt(1,...)`, `send(1,...)`, `reqv(0,...)`, `sendto(1,...)`, `reqvfrom(0,...)`, ...

Ниже показано как, достаточно необычно, может выглядеть **многопоточный** UDP-сервер, работающий с запуском по сокетной активации: в обычной конфигурации UDP сервер обрабатывает датаграммы последовательно, что препятствует дальнейшему прослушиванию порта до завершения обработки текущего запроса (архив `xinetd` подкаталог `udp-connected`). Здесь запускаемый `xinetd` экземпляр сервера создаёт соединённый UDP-сокет (упоминался ранее) по поступившему запросу, обработка (сколь угодно продолжительная) и ответ в этот сокет осуществляются в отдельном дочернем процессе:

`common.h :`

```
#ifndef _COMMON_H
#define _COMMON_H

#include  <stdio.h>
#include  <stdlib.h>
#include  <unistd.h>
#include  <string.h>
#include  <errno.h>
#include  <netdb.h>
```

```
#define MAXLEN 1500
#define SDELIM " > "

#endif
```

udpsocserv.c :

```
#include  <syslog.h>
#include <sys/wait.h>

#include  "common.h"

// добавить запись UDP порта в /etc/services и в конфигурацию в /etc/xinetd.d
int main( void ) {
   char rbuf[ MAXLEN ];
   openlog( NULL, LOG_NDELAY, LOG_USER );
   syslog( LOG_NOTICE, "server [%d] start", getpid() );
   while( 1 ) {
      struct sockaddr_in adr;
      socklen_t len = sizeof( struct sockaddr_in );
      int n = recvfrom( STDIN_FILENO, rbuf, MAXLEN, 0,  // чтение пакета из SYSIN для xinetd:
                        (struct sockaddr*)&adr, &len );
      if( n >= 0 ) syslog( LOG_NOTICE, "server read %d byte", n );
      if( n <= 0 ) {
         if( n < 0 ) syslog( LOG_ERR, "recvfrom error: %m" ), exit( EXIT_FAILURE );
         break;
      }
      rbuf[ n ] = '\0';
      int sc = socket( AF_INET, SOCK_DGRAM, 0 );        // open a UDP socket
      if( sc < 0 ) syslog( LOG_ERR, "socket error: %m" ), exit( EXIT_FAILURE );
      if( connect( sc, (struct sockaddr*)&adr, sizeof( struct sockaddr_in ) ) < 0 )
         syslog( LOG_ERR, "connect error: %m" ), exit( EXIT_FAILURE );
      pid_t pid = fork();
      if( 0 == pid ) {                                  // обработка в дочернем процессе
         close( STDIN_FILENO );
         close( STDOUT_FILENO );
         sleep( 1 );                                    // имитация времени обработки
         char wbuf[ MAXLEN + 8 ];
         sprintf( wbuf, "[%d]%s%s", getpid(), SDELIM, rbuf );
         if( write( sc, wbuf, strlen( wbuf ) ) < 0 )    // ретрансляция данных
            syslog( LOG_ERR, "write error: %m" ), exit( EXIT_FAILURE );
         exit( EXIT_SUCCESS );                          // завершение обрабатывающего процесса
      }
      else if( pid > 0 ) {
         if( n != 1 ) waitpid( -1, NULL, WNOHANG );     // продолжение работы
         else {                                         // пустая "\n" строка от клиента
            wait( NULL );
            exit( EXIT_SUCCESS );
         }
      }
      else syslog( LOG_ERR, "fork error: %m" ), exit( EXIT_FAILURE );
   }
   syslog( LOG_NOTICE, "server [%d] exit", getpid() );
   closelog();
   exit( EXIT_SUCCESS );
}
```

Клиент для экспериментов с такими серверами (в архиве их несколько) — мы не можем использовать в качестве тестового клиента программу `telnet` как для TCP, потому что это UDP и в этом случае для каждого проекта нужно писать свою клиентскую часть:

udpcli.c :

```
#include <arpa/inet.h>
#include  "common.h"

void dg_cli( FILE* fp, int sockfd,
             struct sockaddr* pserv_addr, // ptr to appropriate sockaddr structure
             int servlen ) {               // actual sizeof(*pserv_addr)
   int n;
   char line[ MAXLEN ];
   while( fgets( line, MAXLEN, fp ) != NULL ) {
      n = strlen( line );
      if( sendto( sockfd, line, n, 0, pserv_addr, servlen ) != n )
         printf( "send: %m\n" ), exit( EXIT_FAILURE );
      if( ( n = recvfrom( sockfd, line, MAXLEN, 0,
                          (struct sockaddr*)NULL, (socklen_t*)NULL ) ) < 0 )
         printf( "recv: %m\n" ), exit( EXIT_FAILURE );
      line[ n ] = '\0';                  // null terminate
      fputs( line, stdout );
      if( strstr( line, SDELIM ) == NULL ) continue;
      if( strlen( strstr( line, SDELIM ) ) == strlen( SDELIM ) + 1 )
         printf( "server exit\n" );
   }
}

int main( int argc, char* argv[] ) {
   char serv_host_addr[ 16 ] = "127.0.0.1";                // host addr for server
   int serv_udp_port = 50010;                              // server UDP port
   if( argc > 1 ) strcpy( serv_host_addr, argv[ 1 ] );
   if( argc > 2 ) serv_udp_port = atoi( argv[ 2 ] );
   printf( "UDP server: %s:%d\n", serv_host_addr, serv_udp_port );
   int sockfd;
   if( ( sockfd = socket( AF_INET, SOCK_DGRAM, 0 ) ) < 0 )  // open a UDP socket
      printf( "socket: %m\n" ), exit( EXIT_FAILURE );
   struct sockaddr_in serv_addr;
   bzero( (char*)&serv_addr, sizeof( serv_addr ) );         // fill address structure
   serv_addr.sin_family      = AF_INET;
   serv_addr.sin_addr.s_addr = inet_addr( serv_host_addr );
   serv_addr.sin_port        = htons( serv_udp_port );
   dg_cli( stdin, sockfd, (struct sockaddr*)&serv_addr, sizeof( struct sockaddr_in ) );
   close( sockfd );
   exit( EXIT_SUCCESS );
}
```

Здесь принятый пакет суперсервер передал серверу через STDIN_FILENO (fd = 0), но тут же по сокетному адресу принятого сообщения создаётся дубликат соединённого сокета `sc`, и вся работа с этим сокетом и подготовка ответа на запрос производится в копии процесса (`fork()`):

```
$ ./udpcli 127.0.0.1 50011
UDP server: 127.0.0.1:50011
1
[11489] > 1
12
[11490] > 12
123
[11491] > 123

[11492] >
server exit
1234
[11494] > 1234
```

```
[11495] >
server exit
^C
```

Сервер в ретранслируемом сообщении от клиента (в заголовке) сообщает свой PID. Пример сделан так, что при вводе в клиенте (для передачи серверу) пустой строки (Enter), текущий экземпляр сервера завершается. Но по следующему сообщению от клиента `xinetd` запустит новый экземпляр сервера.

Что можно в заключение сказать о сокетной активации?

Что **во-первых**, поскольку программа сервер в этой схеме работает как фильтр (вход-выход), то в качестве сервера под управлением суперсервера может исполняться (через транзитный запускающий уровень, как дочернее приложение) практически любая утилита из набора штатных программ Linux, например консольные клиенты запросов PostgreSQL или MySQL. (такое решение приведено в архиве примера `child`).

А **во-вторых**, что запуск сервера посредством сокетной активации требует кропотливой конфигурации и настройки, достаточно сложны в отладке. Но такой способ того стоит! Особо обратите внимание при отработке такого способа на то, чтобы контролируемые суперсервером порты не были закрыты сетевым файерволом хоста — в данной технологии это сложно диагностируемая ситуация.

Расширенные операции ввода-вывода

В качестве **расширенных** (по сравнению с блокирующими `read()`, `write()` и всех из их многочисленных вариаций) операций обычно в обсуждениях обобщённо называют: расширенные операции ввода-вывода. К этой части обычно относят рассмотрение: `select()`, `pselect()`, `poll()`, `epoll()`, асинхронного ввода-вывода и подобных вопросов. Пожалуй, самую ясную и строгую классификацию моделей ввода-вывода в UNIX дал У. Р. Стивенс в:

*Прежде чем начать описание функций `select` и `poll`, мы должны вернуться назад и уяснить основные различия между **пятью** моделями ввода-вывода, доступными нам в Unix:*

- блокируемый ввод-вывод;

- неблокируемый ввод-вывод;

- мультиплексирование ввода-вывода (функции `select` и `poll`);

- ввод-вывод, управляемый сигналом (сигнал `SIGIO`);

- асинхронный ввод-вывод (функции POSIX.1 `aio_`).

Все эти возможные модели осуществления обменных операций, что часто упускается из виду, относятся к операциям **над любыми** обменными объектами в программном коде: символьными потоками терминального ввода-вывода, файловыми дескрипторами, сетевыми сокетами... Но только на сетевых сокетах наиболее отчётливо проявляются отличительные стороны всех режимов, и для сетевых сокетов расширенные режимы ввода-ввывода наиболее часто используются на практике. Так, на файловых дескрипторах или дескрипторах символьных устройств мы можем часто наблюдать блокирование на операциях `read()`, но гораздо реже — на операциях `write()` (в частности, и из-за операций кэширования записи на диск). Но на сокетах операция `write()` столь же часто может переходить в блокированное состояние, когда сетевой стек ещё не готов отправить передаваемые данные.

Блокируемый ввод — это самый часто используемый, и самый известный вариант, когда выполняется операция `read()`. Все рассматривавшиеся раньше операции обмена на сокетах были блокирующими. Эта модель ввода-вывода не нуждается в детальных комментариях. А все прочие перечисленные модели реализации операций ввода вывода последовательно рассмотрены далее.

Примеры реализации

Далее будут рассматриваться все оставшиеся (помимо блокируемых операций) модели ввода-вывода. Все примеры, относящиеся к расширенным моделям обмена находятся в каталоге примеров `ufd`. Большинство из примеров заимствованных из книги У. Р. Стивенс [3], но претерпели некоторые изменения в связи с прошедшим временем со времени написания книги (больше 25 лет).

Все подкаталоги этого архива содержат образцы и клиентов и серверов, демонстрирующих

рассматриваемую модель. Сервера представляют собой ретрансляторы строк получаемых от клиента (эхо-сервера) на порт (по умолчанию) 9877, определяемый в заголовочном файле `unp.h` :

```
/* Define some port number that can be used for client-servers */
#define SERV_PORT        9877                   /* TCP and UDP client-servers */
#define SERV_PORT_STR   "9877"                  /* TCP and UDP client-servers */
```

Такой порт выбран автором примеров произвольно (из области приватных портов), и может быть изменён, при желании, на любой другой приемлемый.

Неблокируемый ввод-вывод

При неблокируемом вводе-выводе не ожидает обязательно наличия данных (или возможности вывода) — результат выполнения операции, либо невозможность её выполнения в данный момент определяется по анализу кода возврата. Перевод сокета в режим неблокирующего чтения выполняется вызовом `fcntl()` с соответствующими параметрами (дескриптор всегда создаётся вызовами `open()`, `socket()`, `accept()` в **блокируемом** режиме операций).

Схематично обработка происходит следующим образом:

```
int fdi = open( ... );                      // открыли: фаловый дескриптор, сокет, pipe, ...
int cur_flg = fcntl(fo[0], F_GETFL);        // чтение должно быть в режиме O_NONBLOCK
if (-1 == fcntl(fo[0], F_SETFL, cur_flg | O_NONBLOCK))
   error( ... ), exit(EXIT_FAILURE);
...
while (1) {
   int n = read(fdi, buf, buflen);
   if (n > 0) {
      ...                                   // считаны данные ... обработка
   }
   else if (0 == n)                         // EOF – конец данных
      break;
   else if (-1 == n) {
      if (EAGAIN == errno) {                // данные не готовы
         printf("not ready!\n");
         usleep(300);
         continue;                          // после паузы повторить
      }
      else
         error( ... ), exit(EXIT_FAILURE);  // невосстановимая ошибка
   }
}
close(fdi);
```

Замечания к примерам

Большая подборка примеров, относящихся к неблокирующему вводу-выводу применительно к сетевым сокетам находится в каталог `ufd/nonblock`.

На одном из хостов LAN запускаем ретранслирующий сервер:

```
$ ./tcpservselect03
listening socket readable
^C
```

На другом хосте LAN выполняем программу клиента, который отправляет строки, полученные из входного потока (которым может быть, например, и файл), серверу, и затем воспроизводит ответ, ретранслированный сервером:

```
$ ./tcpcli01 192.168.1.5
12345
12345
qwer
qwer
www
www
```

```
^D
Завершено
```

Всё, относящееся к неблокируемому вводу, реализовано в исходном файле `strclinonb.c`. В файле `strclifork.c` приведена ещё одна, альтернативная, более простая реализация клиента. За подробными объяснениями кода, если он непонятен, следует обратиться к [3].

Особенно полезно наблюдать работу подобных клиент-серверных приложений, анализируя параллельно дамп сетевого трафика, захватываемый сетевым снифером `tcpdump`. Это можно делать как на хосте сервера, так и клиента:

```
$ ip link
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue state UNKNOWN mode DEFAULT group default
    link/loopback 00:00:00:00:00:00 brd 00:00:00:00:00:00
2: em1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP mode DEFAULT group default qlen 1000
    link/ether a0:1d:48:f4:93:5c brd ff:ff:ff:ff:ff:ff
3: wlo1: <NO-CARRIER,BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state DORMANT mode DORMANT group default qlen 1000
    link/ether 34:23:87:d6:85:0d brd ff:ff:ff:ff:ff:ff
$ sudo tcpdump -i em1 tcp and port 9877
tcpdump: verbose output suppressed, use -v or -vv for full protocol decode
listening on em1, link-type EN10MB (Ethernet), capture size 65535 bytes
12:56:23.568017 IP modules.52421 > notebook.9877: Flags [S], seq 269087598, win 29200, options [mss 1460,sackOK,TS val 19530115 ecr 0,nop,wscale 7], length 0
12:56:23.568292 IP notebook.9877 > modules.52421: Flags [S.], seq 894792783, ack 269087599, win 28960, options [mss 1460,sackOK,TS val 19525763 ecr 19530115,nop,wscale 7], length 0
12:56:23.568355 IP modules.52421 > notebook.9877: Flags [.], ack 1, win 229, options [nop,nop,TS val 19530115 ecr 19525763], length 0
12:56:27.878584 IP modules.52421 > notebook.9877: Flags [P.], seq 1:7, ack 1, win 229, options [nop,nop,TS val 19534425 ecr 19525763], length 6
12:56:27.878842 IP notebook.9877 > modules.52421: Flags [.], ack 7, win 227, options [nop,nop,TS val 19530074 ecr 19534425], length 0
12:56:28.569058 IP notebook.9877 > modules.52421: Flags [P.], seq 1:7, ack 7, win 227, options [nop,nop,TS val 19530764 ecr 19534425], length 6
12:56:28.569157 IP modules.52421 > notebook.9877: Flags [.], ack 7, win 229, options [nop,nop,TS val 19535116 ecr 19530764], length 0
12:56:38.990624 IP modules.52421 > notebook.9877: Flags [P.], seq 7:12, ack 7, win 229, options [nop,nop,TS val 19545537 ecr 19530764], length 5
12:56:38.990859 IP notebook.9877 > modules.52421: Flags [.], ack 12, win 227, options [nop,nop,TS val 19541186 ecr 19545537], length 0
12:56:38.991150 IP notebook.9877 > modules.52421: Flags [P.], seq 7:12, ack 12, win 227, options [nop,nop,TS val 19541186 ecr 19545537], length 5
12:56:38.991208 IP modules.52421 > notebook.9877: Flags [.], ack 12, win 229, options [nop,nop,TS val 19545538 ecr 19541186], length 0
12:56:42.414878 IP modules.52421 > notebook.9877: Flags [P.], seq 12:16, ack 12, win 229, options [nop,nop,TS val 19548962 ecr 19541186], length 4
12:56:42.415136 IP notebook.9877 > modules.52421: Flags [P.], seq 12:16, ack 16, win 227, options [nop,nop,TS val 19544610 ecr 19548962], length 4
12:56:42.415189 IP modules.52421 > notebook.9877: Flags [.], ack 16, win 229, options [nop,nop,TS val 19548962 ecr 19544610], length 0
12:56:44.014763 IP modules.52421 > notebook.9877: Flags [F.], seq 16, ack 16, win 229, options [nop,nop,TS val 19550562 ecr 19544610], length 0
12:56:44.015015 IP notebook.9877 > modules.52421: Flags [F.], seq 16, ack 17, win 227, options [nop,nop,TS val 19546210 ecr 19550562], length 0
12:56:44.015073 IP modules.52421 > notebook.9877: Flags [.], ack 17, win 229, options [nop,nop,TS val 19550562 ecr 19546210], length 0
^C
17 packets captured
17 packets received by filter
0 packets dropped by kernel
```

Обратите внимание на соответствие длин передаваемых строк (в терминале ввода) и на указание длины передаваемых данных в пакетах, перехватываемых снифером.

Конечно, можно изучать выполнение клиента и локально, на том же хосте, на котором выполняется и сервер:

```
$ ./tcpcli01 127.255.255.254
```

```
это петлевой интерфейс
это петлевой интерфейс
^D
Завершено
```

Однако, такое изучение поведения предлагаемых примеров может быть менее информативно.

Мультиплексирование ввода-вывода

Один из самых старых API POSIX:

```
int select(int n, fd_set *readfds, fd_set *writefds, fd_set *exceptfds,
           struct timeval *timeout);
```

И его более поздний эквивалент:

```
int pselect(int n, fd_set *readfds, fd_set *writefds, fd_set *exceptfds,
            const struct timespec *timeout, sigset_t *sigmask);
```

Различия:

- `select()` использует тайм-аут в виде `struct timeval` (с секундами и микросекундами), а `pselect()` использует `struct timespec` (с секундами и наносекундами);

- `select()` может обновить параметр `timeout`, чтобы сообщить, сколько времени осталось. Функция `pselect()` не изменяет этот параметр ;

- `select()` не содержит параметра `sigmask`, и ведет себя как `pselect()` с параметром `sigmask`, равным `NULL`. Если этот параметр `pselect()` не равен `NULL`, то `pselect()` сначала замещает текущую маску сигналов на ту, на которую указывает `sigmask`, затем выполняет `select()`, после чего восстанавливает исходную маску сигналов.

Параметр тайм-аута может задаваться несколькими способами:

- NULL, что означает ожидать вечно;

- ожидать инициированное структурой значение времени;

- не ожидать вообще (программный опрос — pooling), когда структура инициализируется значением {0, 0}.

Функции возвращают значение больше нуля — число готовых к операции дескрипторов, ноль — в случае истечения тайм-аута, и отрицательное значение при ошибке.

Примечание: Готовность дескриптора функция `select()` возвращает по поступлению на дескриптор **первого** доступного байта. Если вы ожидаете **блок** данных некоторого размера, то функция чтения, непосредственно следующая за `select()`, может возвратить число считанных байт **меньше**, чем вы можете ожидать.

Вводится понятие набора дескрипторов, и макросы для работы с набором дескрипторов:

```
FD_CLR( int fd, fd_set *set );
FD_ISSET( int fd, fd_set *set );
FD_SET( int fd, fd_set *set );
FD_ZERO( fd_set *set );
```

С готовностью дескрипторов чтения и записи `readfds`, `writefds` — относительно ясно интуитивно. Очень важно, что вариантом срабатывания исключительной ситуации `exceptfds` на дескрипторе сетевых сокетов — является получение внеполосовых (**приоритетных**) данных TCP, что очень широко используется в реализациях (конечных автоматов) сетевых протоколов (например SIP, VoIP сигнализаций PRI, SS7 — на линиях E1/T1, ...).

Примечание: Большинство UNIX систем имеют определение численной константы с именем `FD_SETSIZE` — максимального размера набора дескрипторов, но её численное значение сильно зависит от констант периода компиляции совместимости с стандартами (такими, например, как `__USE_XOPEN2K`, ...).

Ещё один вариант мультиплексирования ввода-вывода вывода — функция `poll()`. Представление набора дескрипторов заменено на массив структур вида:

```
struct pollfd {
```

```
    int fd;          /* файловый дескриптор  */
    short events;    /* запрошенные события  */
    short revents;   /* возвращенные события */
};
```

Здесь: `fd` — открытый файловый дескриптор, `events` — набор битовых флагов запрошенных событий для этого дескриптора, `revents` — набор битовых флагов возвращенные событий для этого дескриптора (из числа запрошенных, или `POLLERR, POLLHUP, POLLNVAL`). Часть возможных битов, описаны в `<sys/poll.h>`:

```
#define POLLIN      0x0001    /* Можно читать данные */
#define POLLPRI     0x0002    /* Есть срочные данные */
#define POLLOUT     0x0004    /* Запись не будет блокирована */
#define POLLERR     0x0008    /* Произошла ошибка */
#define POLLHUP     0x0010    /* Разрыв соединения */
#define POLLNVAL    0x0020    /* Неверный запрос: fd не открыт */
```

Ещё некоторая часть относящихся констант описаны в `<asm/poll.h>`: `POLLRDNORM, POLLRDBAND, POLLWRNORM, POLLWRBAND` и `POLLMSG`.

Сам вызов оперирует с массивом таких структур, по одному элементу на каждый интересующий дескриптор:

```
#include <sys/poll.h>
int poll( struct pollfd *ufds, unsigned int nfds, int timeout );
```

Здесь: `ufds` - сам массив структур, `nfds` - его размерность, `timeout` - тайм-аут в миллисекундах (ожидание при положительном значении, немедленный возврат при нулевом, бесконечное ожидание при значении, заданном специальной константой `INFTIM`, которая определена просто как отрицательное значение).

Пример того, как используются (и работают) вызовы `select()` и `poll()` - позаимствованы из [3] (каталог `ufd`), оригиналы кодов У. Стивенса несколько изменены (оригиналы относятся к 1998г. и проверялись на совершенно других UNIX того периода). Примеры достаточно объёмные (это полные версии программ TCP клиентов и серверов), поэтому ниже показаны только фрагменты примеров, непосредственно относящиеся к вызовам `select()` и `poll()`, а также примеры того, что реально эти примеры выполняются и как это происходит (вызовы функций в коде показаны как у У. Стивенса — с большой буквы, вызов этот — это полный аналог соответствующего вызова API, но обрамлённый выводом сообщения о роде ошибки, если она возникнет):

tcpservselect01.c (TCP ретранслирующий сервер на `select()`):

```
...
    int                             nready, client[ FD_SETSIZE ];
    fd_set                          rset, allset;
    socklen_t                       clilen;
    struct sockaddr_in      cliaddr, servaddr;
    ...
    listenfd = Socket( AF_INET, SOCK_STREAM, 0 );
    bzero( &servaddr, sizeof(servaddr) );
    servaddr.sin_family      = AF_INET;
    servaddr.sin_addr.s_addr = htonl(INADDR_ANY);
    servaddr.sin_port        = htons(SERV_PORT);
    Bind( listenfd, (SA*)&servaddr, sizeof(servaddr) );
    Listen( listenfd, LISTENQ );
    maxfd = listenfd;                           /* initialize */
    maxi = -1;                                  /* index into client[] array */
    for( i = 0; i < FD_SETSIZE; i++ )
       client[i] = -1;                          /* -1 indicates available entry */
       FD_ZERO( &allset );
       FD_SET( listenfd, &allset );
       for ( ; ; ) {
          rset = allset;                        /* structure assignment */
          nready = Select( maxfd + 1, &rset, NULL, NULL, NULL );
          if( FD_ISSET( listenfd, &rset ) ) {   /* new client connection */
          connfd = Accept(listenfd, (SA *) &cliaddr, &clilen);
...
```

tcpservpoll01.c (TCP ретранслирующий сервер на `poll()`):

```
...
   struct pollfd           client[ OPEN_MAX ];
   struct sockaddr_in      cliaddr, servaddr;
...
   listenfd = Socket( AF_INET, SOCK_STREAM, 0 );
   bzero( &servaddr, sizeof(servaddr) );
   servaddr.sin_family      = AF_INET;
   servaddr.sin_addr.s_addr = htonl( INADDR_ANY );
   servaddr.sin_port        = htons( SERV_PORT );
   Bind( listenfd, (SA*)&servaddr, sizeof(servaddr) );
   Listen( listenfd, LISTENQ );
   client[0].fd = listenfd;
   client[0].events = POLLRDNORM;
   for( i = 1; i < OPEN_MAX; i++ )
      client[i].fd = -1;                        /* -1 indicates available entry */
      maxi = 0;                                 /* max index into client[] array */
      for ( ; ; ) {
         nready = Poll( client, maxi + 1, INFTIM );
         if( client[0].revents & POLLRDNORM ) {   /* new client connection */
            for( i = 1; i < OPEN_MAX; i++ )
               if( client[i].fd < 0 ) {
                  client[i].fd = connfd;  /* save descriptor */
                  break;
               }
...
               client[i].events = POLLRDNORM;
               if( i > maxi )
                  maxi = i;
...
```

Замечания к примерам

Как выполнять эти примеры и на что обратить внимание? Запускаем выбранный нами сервер (позже мы остановим его по `Ctrl+C`), все сервера этого раздела прослушивают фиксированный порт 9877, и являются для клиента ретрансляторами данных, получаемых на этот порт:

```
$ ./tcpservselect01
...
^C
```

или

```
$ ./tcpservpoll01
...
^C
```

В том, что сервер прослушивает порт и готов к работе, убеждаемся, например, так:

```
$ netstat -a | grep :9877
tcp        0      0 *:9877                  *:*                         LISTEN
```

К серверу подключаемся клиентом (из того же архива примеров), и вводим строки, которые будут передаваться на сервер и ретранслироваться обратно:

```
$ ./tcpcli01 192.168.1.5
1 строка
1 строка
2 строка
2 строка
последняя
последняя
```

```
^C
```

Указание IP адреса сервера (не имени!) в качестве параметра запуска клиента — обязательно. Клиентов одновременно может быть много — сервера параллельные. Во время выполнения клиента можно увидеть состояние сокетов — клиентского и серверных, прослушивающего и присоединённого (клиент не закрывает соединение после обслуживания каждого запроса, как, например, сервер HTTP):

```
$ netstat -a | grep :9877
tcp        0      0 *:9877                  *:*                       LISTEN
tcp        0      0 localhost:46783         localhost:9877            ESTABLISHED
tcp        0      0 localhost:9877          localhost:46783           ESTABLISHED
```

Ввод-вывод управляемый сигналом

В этом случае на сетевом сокете включается режим управляемого сигналом ввода-вывода, и устанавливается обработчик сигнала при помощи `sigaction()`. Когда UDP дейтаграмма готова для чтения, генерируется сигнал `SIGIO`. Обработать данные можно в обработчике сигнала вызовом `recvfrom()`. Пример того, как это работает, заимствован из [3], и находится в каталоге архива `ufd/sigio`, он слишком громоздкий для детального обсуждения, но может быть изучен и в коде и в работе. Краткая сводка о запуске примера:

Запуск ретранслирующего сервера UDP (в конце выполнения останавливаем его по `Ctrl+C`):

```
$ ./udpserv01
^C
```

Убедиться, что сервер готов и прослушивает порт, можно так:

```
$ netstat -a | grep :9877
udp        0      0 *:9877                  *:*
```

Запуск клиента:

```
$ ./udpcli01 192.168.1.5
qweqert
qweqert
134534256
134534256
^D
```

Примечание: Особо интересен запуск (например из скрипта) нескольких одновременно (6) клиентов, которые плотным потоком шлют серверу на ретрансляцию большое число строк (у У. Стивенса — 3645 строк). После этого серверу можно послать сигнал `SIGHUP`, по которому он выведет гистограмму, которая складывалась по числу одновременно читаемых дейтаграмм:

```
$ ps -A | grep udp
 2692 pts/12   00:00:00 udpserv01
$ kill -HUP 2692
$ ./udpserv01
cntread[0] = 0
cntread[1] = 8
cntread[2] = 0
cntread[3] = 0
cntread[4] = 0
cntread[5] = 0
cntread[6] = 0
cntread[7] = 0
cntread[8] = 0
^C
```

Асинхронный ввод-вывод

Асинхронный ввод-вывод добавлен только в редакции стандарта POSIX.1g (1993г., одно из расширений реального времени). В вызове `aio_read()` даётся указание ядру начать операцию ввод-вывода, и указывается, каким сигналом уведомить процесс о завершении операции (включая копирование данных в пользовательский буфер). Вызывающий процесс не блокируется. Результат операции (например, полученная UDP дейтаграмма) может быть обработан, например, в обработчике

сигнала. Разница с предыдущей моделью, управляемой сигналом, состоит в том, что в той модели сигнал уведомлял о возможности начала операции (вызове операции чтения), а в асинхронной модели сигнал уведомляет уже о завершении операции чтения в буфер пользователя.

Всё, что относится к асинхронному вводу-выводу в Linux описано в <aio.h>. Управляющий блок асинхронного ввода-вывода — видны все поля, которые обсуждались выше:

```
struct aiocb {                  /* Asynchronous I/O control block.  */
   int aio_fildes;              /* File desriptor.  */
   int aio_lio_opcode;          /* Operation to be performed.  */
   int aio_reqprio;             /* Request priority offset.  */
   volatile void *aio_buf;      /* Location of buffer.  */
   size_t aio_nbytes;           /* Length of transfer.  */
   struct sigevent aio_sigevent; /* Signal number and value.  */
...
}
```

Того же назначения блок для 64-битных операций:

```
struct aiocb64 {
...
}
```

И некоторые операции (в качестве примера):

```
int aio_read(struct aiocb *__aiocbp);
int aio_write(struct aiocb *__aiocbp);
```

Может быть инициализировано выполнение целой **цепочки** асинхронных операций (длиной __nent) :

```
int lio_listio(int __mode,
               struct aiocb* const list[__restrict_arr],
               int __nent, struct sigevent *__restrict __sig);
```

Как и для потоков pthread_t, асинхронные операции значительно легче породить, чем позже остановить... для чего также потребовался отдельный API:

```
int aio_cancel(int __fildes, struct aiocb *__aiocbp);
```

Можно предположить, что каждая асинхронная операция выполняется как отдельный поток, у которого не циклическая функция потока.

Символьный сокет[9]

Символьный сокеты (raw sosckets) используются для обеспечения обмена на уровне протоколов, которые не поддерживаются транспортным уровнем (TCP, UDP, SCTP, ...). Средствами такого сокета можно работать с протоколами ICMP, IGMP, или даже организовывать обмен IPv4 датаграммами с собственным полем протокола IPv4, которое не обрабатывается ядром Linux (8-битовое поле пакета, характерные значения которого 1 — ICMP, 2 — IGMP, 6 — TCP, 17 — UDP: константы из <netinet/in.h> вида IPPROTO_*, которые мы уже встречали раньше). С помощью символьного сокета вообще можно построить свой собственный заголовок IPv4 при помощи параметра сокета IP_HDRINCL:

```
...
int on = 1, fd = socket( AF_INET, SOCK_RAW, 0 );
setsockopt( fd, IPPROTO_IP, IP_HDRINCL, &on, sizeof( on ) );
...
```

Только **привилегированный** пользователь (root) может создавать символьные сокеты. Сокет создаётся вызовом такого типа:

```
int fd = socket( AF_INET, SOCK_RAW, IPPROTO_ICMP );
```

Третьим параметром указано протокол сетевого уровня, константы которых указаны в <netinet/in.h> (выше уже показывался их полный перечень).

9 Ещё для символьного сокета разные авторы используют названия неструктурированные сокет и сырой сокет.

Вывод в символьный сокет может производиться всё теми же вызовами `sendto(), sendmsg()`, или `write(), writev()` и `send()`, если сокет уже присоединён.

Ввод из символьного сокета производится теми же, уже рассмотренными, функциями чтения из сокета. Но есть достаточно много исключений и особенностей в том, какие IP датаграммы и как передаются символьному сокету, например:

- Пакеты UDP и TCP **никогда** не передаются на символьный сокет;

- Все IGMP пакеты и большинство ICMP пакетов передаются на символьный пакет только **после того**, как ядро заканчивает обработку этих сообщений;

- Все IP датаграммы с таким значением поля протокола, которое не понимается ядром, передаются на символьный сокет;

Подобных особенностей довольно много и они, порой, могут привести в замешательство.

Детально работа с символьными сокетами описана в [3, 4], где приведены коды иллюстрационных приложений для программ `ping` и `traceroute`, работающих с символьными сокетами.

Канальный уровень

Возможен даже доступ к пакетам канального (MAC) уровня, но это уже совершенно возможность Linux, не предусмотренная какими-либо стандартами и не представленная в других системах UNIX — сокет :

```
int fd = socket(AF_INET, SOCK_PACKET, htons(ETH_P_ALL));
```

В результате такого вызова будут из такого сокета возвращаться кадры для всех протоколов, получаемых канальным уровнем.

Третьим параметром вызова должна быть не нулевая константа, задающая тип кадра Ethernet, который будет отбираться фильтром. Если нужны все кадры IPv4, определяем сокет так:

```
int fd = socket(AF_INET, SOCK_PACKET, htons(ETH_P_IP));
```

Могут быть полезными в качестве последнего параметра такие константы как: `ETH_P_ARP`, `ETH_P_IPV6`.

Другим, более универсальным, средством перехвата и фильтрации пакетов канального уровня является свободно доступная библиотека BPF (BSD Packet Filter) — `libpcap`:

```
$ yum list all libpcap*
Установленные пакеты
libpcap.x86_64                       14:1.5.3-1.fc20               @fedora-updates/$releasever
Доступные пакеты
libpcap.i686                         14:1.5.3-1.fc20               updates
libpcap-devel.i686                   14:1.5.3-1.fc20               updates
libpcap-devel.x86_64                 14:1.5.3-1.fc20               updates
...
$ ls -l /lib64/libpcap*
lrwxrwxrwx. 1 root root     16 янв 17 16:37 /lib64/libpcap.so.1 -> libpcap.so.1.5.3
-rwxr-xr-x. 1 root root 267368 янв 15 16:23 /lib64/libpcap.so.1.5.3
```

Библиотека `libpcap` присутствует практически во всех POSIX системах. На ней работает такой известный сетевой снифер как `tcpdump`. Библиотека резует достаточно обширный API таких вызовов как `pcap_open_live()`, `pcap_open_live()`, `pcap_compile()`, `pcap_setfilter()`, `pcap_datalink()` и др.

Для более детального изложения доступа к кадрам канального уровня можно обратиться к [3, 4].

Источники использованной информации

[1] **Йон Снайдерс, «Эффективное программирование TCP/IP»**, «ДМК Пресс», 2009
Йон Снайдерс, «Эффективное программирование TCP/IP. Библиотека программиста» - СПб.: «Питер», 2001, 320 стр., ISBN 5-318-00453-9
Йон Снайдерс, «Эффективное программирование TCP/IP», «ДМК Пресс», 2009
Книгу можно скачать здесь:
- http://www.proklondike.com/var/file/codingproch_snader_effective_tcp_ip.rar (потребуется установить один из многочисленных просмотровщиков .chm форматов)

- http://padabum.com/d.php?id=35216 — в формате .pdf

[2] **У. Р. Стивенс, «UNIX: Разработка сетевых приложений»**, СПб.: «Питер», 2003, ISBN 5-318-00535-7, стр. 1088

http://www.books.ru/books/unix-razrabotka-setevykh-prilozhenii-82359/?show=1

Полный архив примеров кодов к этой книге может быть взят здесь:
http://www.kohala.com/start/unp.tar.Z

[3] **У. Стивенс, Б. Феннер, Э. Рудофф, «UNIX: Разработка сетевых приложений»**, СПб.: «Питер», 2006, ISBN: 5-94723-991-4, стр. 1040
http://www.books.ru/books/unix-razrabotka-setevykh-prilozhenii-460327/?show=1

[4] **У. Р. Стивенс, «UNIX: взаимодействие процессов»**, СПб.: «Питер», 2003, ISBN: 5-318-00534-9, стр. 576.
http://www.books.ru/books/unix-vzaimodeistvie-protsessov-23626/?show=1

[5] **W. Richard Stevens' Home Page** (ресурс полного собрания книг и публикаций У. Р. Стивенса):
http://www.kohala.com/start/

5. Драйверы сетевых устройств в Linux (ядро)

Linux — операционная система с **монолитным** ядром. Альтернативой монолитному ядру являются **микроядерные** операционные системы (которых создано достаточно мало). Проблемой всех моноядерных операционных систем является: как расширять функциональность ядра, динамически подгружая к нему новые компоненты? В Linux такие компоненты ядра называются модулями, и загружаясь они связываются с API ядра и его структурами данных **по абсолютным адресам** размещения. Все **драйверы** Linux являются модулями. Все имена (функции API, переменные, ...) ядра, можно видеть в псевдофайле `/proc/kallsyms`:

```
$ cat /proc/kallsyms | wc -l
88304
```

Как видно, число имён (объектов) ядра составляет несколько десятков тысяч (это число определяется **версией ядра**). Функции API ядра (которые в наибольшей мере интересуют разработчика) отмечены в этом списке `'T'`: сегмент текста (то есть кода) и экспортируемое имя (большая литера `'T'`— внешнее имя):

```
$ cat /proc/kallsyms | head -n 100 | tail -n 10
c0401a30 T start_thread
c0401a80 T thread_saved_pc
c0401aa0 T __show_regs
c0401cc0 T release_thread
c0401ce0 T copy_thread
c0401f60 T __switch_to
c04022b0 T get_wchan
c0402350 T restore_sigcontext
c0402460 T setup_sigcontext
c0402530 t do_signal
```

Число, стоящее в начале каждой строке — это **абсолютный** адрес для вызова этой функции ядра. Но и число доступных функций API ядра впечатляет:

```
$ cat /proc/kallsyms | grep T | wc -l
15341
```

Введение в модули ядра

Для простейшего знакомства с техникой написания модулей ядра Linux проще не вдаваться в пространные объяснения, но создать простейший модуль (код такого модуля интуитивно понятен всякому программисту), собрать его и наблюдать исполнение. Вот с такого образца простейшего модуля ядра (архив `first_hello.tgz`) мы и начнём рассмотрение:

hello_printk.c :

```
#include <linux/init.h>
#include <linux/module.h>

MODULE_LICENSE( "GPL" );
MODULE_AUTHOR( "Oleg Tsiliuric <olej@front.ru>" );

static int __init hello_init( void ) {
   printk( "Hello, world!" );
   return 0;
}

static void __exit hello_exit( void ) {
   printk( "Goodbye, world!" );
}

module_init( hello_init );
module_exit( hello_exit );
```

Сборка модуля

Для сборки созданного модуля используем скрипт сборки `Makefile`, который будет с

минимальными изменениями повторятся при сборке **любых** модулей ядра (он использует макросы подготовленные разработчиками ядра):

Makefile :

```
CURRENT = $(shell uname -r)
KDIR = /lib/modules/$(CURRENT)/build
PWD = $(shell pwd)
DEST = /lib/modules/$(CURRENT)/misc

TARGET = hello_printk
obj-m      := $(TARGET).o

default:
	$(MAKE) -C $(KDIR) M=$(PWD) modules

clean:
	@rm -f *.o .*.cmd .*.flags *.mod.c *.order
	@rm -f .*.*.cmd *.symvers *~ *.*~ TODO.*
	@rm -fR .tmp*
	@rm -rf .tmp_versions
```

От модуля к модуля в различных проектах будет меняться только переменная скрипта: `hello_printk` — это имя собираемого модуля и имя исходного файла кода `hello_printk.c`. Делаем сборку модуля ядра, выполняя команду :

```
$ make
make -C /lib/modules/2.6.32.9-70.fc12.i686.PAE/build M=/home/olej/2011_WORK/Linux-kernel/examples
make[1]: Entering directory `/usr/src/kernels/2.6.32.9-70.fc12.i686.PAE'
  CC [M]  /home/olej/2011_WORK/Linux-kernel/examples/own-modules/1/hello_printk.o
  Building modules, stage 2.
  MODPOST 1 modules
  CC      /home/olej/2011_WORK/Linux-kernel/examples/own-modules/1/hello_printk.mod.o
  LD [M]  /home/olej/2011_WORK/Linux-kernel/examples/own-modules/1/hello_printk.ko
make[1]: Leaving directory `/usr/src/kernels/2.6.32.9-70.fc12.i686.PAE'
```

На этом модуль создан. Начиная с ядер 2.6 расширение файлов модулей сменено с `*.o` на `*.ko`:

```
$ ls *.ko
hello_printk.ko
```

Форматом **файла** модуля является обычный **объектный** ELF формат (`.o`), но дополненный в таблице внешних имён некоторыми дополнительными именами, такими как : `__mod_author5`, `__mod_license4`, `__mod_srcversion23`, `__module_depends`, `__mod_vermagic5`, `...` которые определяются специальными модульными макросами. Изучаем **файл** модуля командой:

```
$ modinfo ./hello_printk.ko
filename:       hello_printk.ko
author:         Oleg Tsiliuric <olej@front.ru>
license:        GPL
srcversion:     83915F228EC39FFCBAF99FD
depends:
vermagic:       2.6.32.9-70.fc12.i686.PAE SMP mod_unload 686
```

Точки входа и завершения

Любой модуль должен иметь объявленные функции **входа** (инициализации) модуля и его **завершения** (не обязательно, может отсутствовать). Функция инициализации будет вызываться (после проверки и соблюдения всех достаточных условий) при выполнении команды `insmod` для модуля. Точно так же, функция завершения будет вызываться при выполнении команды `rmmod`.

Функция инициализации имеет прототип и объявляется именно как функция инициализации макросом `module_init()`, как это было сделано с только-что рассмотренном примере:

```
static int __init hello_init( void ) {
   ...
}
```

```
module_init( hello_init );
```

Функция завершения, совершенно симметрично, имеет прототип, и объявляется макросом `module_exit()`, как было показано:

```
static void __exit hello_exit( void ) {
   ...
}
module_exit( hello_exit );
```

Примечание: Обратите внимание: функция завершения по своему прототипу не имеет возвращаемого значения, и, поэтому, она даже не может сообщить о невозможности каких-либо действий, когда она уже начала выполняться. Идея состоит в том, что система при `rmmod` сама проверит допустимость вызова функции завершения, и если они не соблюдены, просто не вызовет эту функцию.

Показанные выше соглашения по объявлению функций инициализации и завершения являются общепринятыми. Но существует ещё один не документированный способ описания этих функций: воспользоваться непосредственно их **предопределёнными** именами, а именно `init_module()` и `cleanup_module()`. Это может быть записано так:

```
int init_module( void ) {
   ...
}
void cleanup_module( void ) {
   ...
}
```

При такой записи необходимость в использовании макросов `module_init()` и `module_exit()` отпадает, а использовать квалификатор `static` с этими функциями нельзя (они должны быть известными внешними именами при связывании модуля с ядром).

Конечно, такая запись никак не способствует улучшению читаемости текста, но иногда может существенно сократить рутину записи, особенно в коротких иллюстративных примерах.

Вывод диагностики модуля

Для диагностического вывода из модуля используем вызов `printk()`. Он настолько подобен по своим правилам и формату общеизвестному из пользовательского пространства `printf()`, что даже не требует дополнительного описания. Отметим только некоторые тонкие особенности `printk()` относительно `printf()`:

Сам вызов `printk()` и все сопутствующие ему константы и определения найдёте в файле определений `/lib/modules/`uname -r`/build/include/linux/kernel.h`:

```
asmlinkage int printk( const char * fmt, ... )
```

Первому параметру (форматной строке) **может** предшествовать (а может и не предшествовать) константа квалификатор, определяющая уровень сообщений. Определения констант для 8 уровней сообщений, записываемых в вызове `printk()` вы найдёте в файле `printk.h`:

```
#define KERN_EMERG      "<0>"   /* system is unusable                   */
#define KERN_ALERT      "<1>"   /* action must be taken immediately     */
#define KERN_CRIT       "<2>"   /* critical conditions                  */
#define KERN_ERR        "<3>"   /* error conditions                     */
#define KERN_WARNING    "<4>"   /* warning conditions                   */
#define KERN_NOTICE     "<5>"   /* normal but significant condition     */
#define KERN_INFO       "<6>"   /* informational                        */
#define KERN_DEBUG      "<7>"   /* debug-level messages                 */
```

Предшествующая константа не является отдельным параметром (не отделяется запятой), и (как видно из определений) представляет собой символьную строку определённого вида, которая **конкатенируется** с первым параметром (являющимся, в общем случае, **форматной** строкой). Если такая константа не записана, то устанавливается уровень вывода этого сообщения по умолчанию.

Загрузка модулей

Наш модуль при загрузке/выгрузке выводит сообщение посредством вызова `printk()`. Этот вывод направляется на **текстовую консоль**. При работе в **терминале** (в графической системе X11)

вывод не попадает в терминал, но его можно видеть в файле системного журнала /var/log/messages.

```
$ sudo insmod hello_printk.ko
$ lsmod | head -n2
Module                  Size  Used by
hello_printk             557  0
$ sudo rmmod hello_printk
$ lsmod | head -n2
Module                  Size  Used by
vfat                    6740  2
$ dmesg | tail -n2
Hello, world!
Goodbye, world!
$ sudo cat /var/log/messages | tail -n3
Mar  8 01:44:14 notebook ntpd[1735]: synchronized to 193.33.236.211, stratum 2
Mar  8 02:18:54 notebook kernel: Hello, world!
Mar  8 02:19:13 notebook kernel: Goodbye, world!
```

Последними 2-мя командами показаны 2 основных метода визуализации сообщений ядра (занесенных в системный журнал): утилита dmesg и прямое чтение файла журнала /var/log/messages. Они имеют несколько отличающийся формат: файл журнала содержит метки времени поступления сообщений, что иногда бывает нужно. Кроме того, прямое чтение файла журнала требует, в некоторых дистрибутивах, наличия прав root.

Утилита insmod получает **имя файла модуля**, и пытается загрузить его без проверок взаимосвязей. Утилита modprobe сложнее: ей передаётся или **универсальный идентификатор**, или непосредственно **имя модуля**. Если modprobe получает универсальный идентификатор, то она сначала пытается найти соответствующее имя модуля в файле /etc/modprobe.conf (устаревшее), или в файлах *.conf каталога /etc/modprobe.d, где каждому универсальному идентификатору поставлено в соответствие имя модуля (в строке alias ... , смотри modprobe.conf(5)).

Далее, по имени модуля утилита modprobe, по содержимому файла :

```
$ ls -l /lib/modules/`uname -r`/*.dep
-rw-r--r-- 1 root root 206131 Map  6 13:14 /lib/modules/2.6.32.9-70.fc12.i686.PAE/modules.dep
```

- пытается установить зависимости запрошенного модуля: модули, от которых зависит запрошенный, будут загружаться утилитой прежде него. Сам файл зависимостей modules.dep формируется командой :

```
# depmod -a
```

Той же командой (время от времени) мы обновляем и большинство других файлов modules.* этого каталога:

```
$ ls /lib/modules/`uname -r`
build              modules.block        modules.inputmap     modules.pcimap       updates
extra              modules.ccwmap       modules.isapnpmap    modules.seriomap     vdso
kernel             modules.dep          modules.modesetting  modules.symbols      weak-updates
misc               modules.dep.bin      modules.networking   modules.symbols.bin
modules.alias      modules.drm          modules.ofmap        modules.usbmap
modules.alias.bin  modules.ieee1394map  modules.order        source
```

Интересующий нас файл содержит строки вида:

```
$ cat /lib/modules/`uname -r`/modules.dep
...
kernel/fs/ubifs/ubifs.ko: kernel/drivers/mtd/ubi/ubi.ko kernel/drivers/mtd/mtd.ko
...
```

Каждая строка файла зависимостей (modules.dep) содержит: а). модули, от которых зависит данный (например, модуль ubifs зависим от 2-х модулей ubi и mtd), и б). полные пути к файлам всех модулей. После этого загрузить модули не представляет труда, и непосредственно для этой работы включается (по каждому модулю последовательно) утилита insmod.

Примечание: если загрузка модуля производится непосредственно утилитой insmod, указанием ей **имени файла модуля**, то утилита никакие зависимости не проверяет, и, если обнаруживает неразрешённое имя — завершает загрузку аварийно.

Утилита `rmmod` выгружает ранее загруженный модуль, в качестве параметра утилита должна получать **имя модуля** (не **имя файла модуля).** Если в системе есть модули, зависимые от выгружаемого (счётчик ссылок использования модуля больше нуля), то выгрузка модуля не произойдёт, и утилита `rmmod` завершится аварийно.

Совершенно естественно, что все утилиты `insmod, modprobe, depmod, rmmod` слишком кардинально влияют на поведение системы, и для своего выполнения, естественно, требуют права `root`.

Параметры загрузки модуля

Модулю при его загрузке могут быть переданы значения параметров — здесь наблюдается полная аналогия (по смыслу, но не по формату) с передачей параметров пользовательскому процессу из командной строки через массив `argv[]`.

Для каждого параметра определяется переменная-параметр, далее имя этой переменной указывается в макросе `module_param()`. Подобный макрос должен быть записан **для каждого** предусмотренного параметра, и должен последовательно определить: а). имя (параметра и переменной), б). тип значения этой переменной, в). права доступа к параметру, отображаемому как путевое имя в системе `/sys`.

Значения параметрам могут быть установлены **во время загрузки** модуля через `insmod` или `modprobe`, последняя команда также может прочитать значение параметров из своего файла конфигурации (`/etc/modprobe.conf`) для загрузки модулей.

Обработка входных параметров модуля обеспечивается макросами (описаны в `<linux/moduleparam.h>`), вот основные (там же есть ещё ряд мало употребляемых), два из них приводятся с полным определением через другие макросы (что добавляет понимания):

```
module_param_named( name, value, type, perm )
#define module_param(name, type, perm)  \
      module_param_named(name, name, type, perm)
module_param_string( name, string, len, perm )
module_param_array_named( name, array, type, nump, perm )
#define module_param_array( name, type, nump, perm ) \
      module_param_array_named( name, name, type, nump, perm )
```

Но даже из этого подмножества употребляются чаще всего только два: `module_param()` и `module_param_array()` (детально понять работу макросов можно реально выполняя обсуждаемый ниже пример).

Примечание: Последним параметром perm указаны права доступа (например, `S_IRUGO | S_IWUSR`), относящиеся к имени параметра, отображаемому в подсистеме `/sys`, если нас не интересует имя параметра отображаемое в `/sys`, то хорошим значением для параметра `perm` будет 0.

Для параметров модуля в макросе `module_param()` могут быть указаны следующие типы:

- `bool, invbool` - булева величина (`true` или `false`) - связанная переменная должна быть типа `int`. Тип `invbool` инвертирует значение, так что значение `true` приходит как `false` и наоборот.

- `charp` - значение указателя на `char` - выделяется память для строки, заданной пользователем (не нужно предварительно распределять место для строки), и указатель устанавливается соответствующим образом.

- `int, long, short, uint, ulong, ushort` - базовые целые величины разной размерности; версии, начинающиеся с u, являются беззнаковыми величинами.

В качестве входного параметра может быть определён и массив выше перечисленных типов (макрос `module_param_array()`).

Пример, показывающий большинство приёмов использования параметров загрузки модуля (архив `params.tgz`) показан ниже:

mod_params.c :

```
#include <linux/module.h>
#include <linux/moduleparam.h>
#include <linux/string.h>

MODULE_LICENSE( "GPL" );
```

```
MODULE_AUTHOR( "Oleg Tsiliuric <olej@front.ru>" );

static int iparam = 0;        // целочисленный парамер
module_param( iparam, int, 0 );

static int k = 0;             // имена параметра и переменной различаются
module_param_named( nparam, k, int, 0 );

static bool bparam = true;    // логический инверсный парамер
module_param( bparam, invbool, 0 );

static char* sparam;          // строчный параметр
module_param( sparam, charp, 0 );

#define FIXLEN 5
static char s[ FIXLEN ] = ""; // имена параметра и переменной различаются
module_param_string( cparam, s, sizeof( s ), 0 ); // копируемая строка

static int aparam[] = { 0, 0, 0, 0, 0 };          // параметр - целочисленный массив
static int arnum = sizeof( aparam ) / sizeof( aparam[ 0 ] );
module_param_array( aparam, int, &arnum, S_IRUGO | S_IWUSR );

static int __init mod_init( void ) {
   int j;
   char msg[ 40 ] = "";
   printk( "======================================\n" );
   printk( "iparam = %d\n", iparam );
   printk( "nparam = %d\n", k );
   printk( "bparam = %d\n", bparam );
   printk( "sparam = %s\n", sparam );
   printk( "cparam = %s {%d}\n", s, strlen( s ) );
   sprintf( msg, "aparam [ %d ] = ", arnum );
   for( j = 0; j < arnum; j++ ) sprintf( msg + strlen( msg ), " %d ", aparam[ j ] );
   printk( "%s\n", msg );
   printk( "======================================\n" );
   return -1;
}

module_init( mod_init );
```

В коде этого модуля присутствуют две вещи, которые могут показаться непривычными программисту на языке C, нарушающие стереотипы этого языка, и поначалу именно в этом порождающие ошибки программирования в собственных модулях:

– отсутствие резервирования памяти для символьного параметра `sparam`[10];
– и динамический размер параметра-массива `aparam`. (динамически изменяющийся после загрузки модуля);
– при этом этот динамический размер **не может** превысить статически зарезервированную максимальную размерность массива (такая попытка вызывает ошибку).

Но и то, и другое, хотелось бы надеяться, достаточно разъясняется демонстрируемым кодом примера.

Для сравнения - выполнение загрузки модуля с параметрами по умолчанию (без указания параметров), а затем с переопределением значений всех параметров:

```
# sudo insmod mod_params.ko
insmod: ERROR: could not insert module ./mod_params.ko: Operation not permitted
$ dmesg | tail -n8
[14562.245812] ======================================
```

10 Объявленный в коде указатель просто устанавливается на строку, размещённую где-то в параметрах запуска программы загрузки. При этом остаётся открытым вопрос: а если **после** отработки инсталляционной функции, **резидентный** код модуля обратится к такой строке, к чему это приведёт? Я могу предположить, что к критической ошибке, а вы можете проверить это экспериментально.

```
[14562.245816] iparam = 0
[14562.245818] nparam = 0
[14562.245820] bparam = 1
[14562.245822] sparam = (null)
[14562.245824] cparam =  {0}
[14562.245828] aparam [ 5 ] =  0  0  0  0  0
[14562.245830] ========================================

# insmod mod_params.ko iparam=3 nparam=4 bparam=1 sparam=str1 cparam=str2 aparam=5,4,3
insmod: ERROR: could not insert module mod_params.ko: Operation not permitted
$ dmesg | tail -n8
[15049.389328] ========================================
[15049.389336] iparam = 3
[15049.389338] nparam = 4
[15049.389340] bparam = 0
[15049.389342] sparam = str1
[15049.389345] cparam = str2 {4}
[15049.389348] aparam [ 3 ] =  5  4  3
[15049.389350] ========================================
```

При этом массив `aparam` получил и новую размерность `arnum`, и его элементам присвоены новые значения.

Вводимые параметры загрузки и их значения в команде `insmod` жесточайшим образом контролируются (хотя, естественно, всё проконтролировать абсолютно невозможно), потому как модуль, загруженный с ошибочными значениями параметров, который становится составной частью ядра — это угроза целостности системы. Если **хотя бы один** из параметров признан некорректным, загрузка модуля не производится. Вот как происходит контроль для некоторых случаев:

```
# insmod mod_params.ko aparam=5,4,3,2,1,0
insmod: ERROR: could not insert module mod_params.ko: Invalid parameters
# echo $?
1
$ dmesg | tail -n2
[15583.285554] aparam: can only take 5 arguments
[15583.285561] mod_params: `5' invalid for parameter `aparam'
```

Здесь имела место попытка заполнить в массиве `aparam` число элементов большее, чем его зарезервированная размерность (5).

Попытка загрузки модуля с указанием параметра с именем, не предусмотренным в коде модуля, в некоторых конфигурациях (Fedora 14) приведёт к ошибке не распознанного параметра, и модуль не будет загружен:

```
$ sudo /sbin/insmod ./mod_params.ko zparam=3
insmod: error inserting './mod_params.ko': -1 Unknown symbol in module
$ dmesg | tail -n1
mod_params: Unknown parameter `zparam'
```

Но в других случаях (Fedora 20) такой параметр будет просто проигнорирован, а модуль будет нормально загружен:

```
# insmod mod_params.ko ZZparam=3
insmod: ERROR: could not insert module mod_params.ko: Operation not permitted
$ dmesg | tail -n8
[15966.050023] ========================================
[15966.050026] iparam = 0
[15966.050029] nparam = 0
[15966.050031] bparam = 1
[15966.050033] sparam = (null)
[15966.050035] cparam =  {0}
[15966.050039] aparam [ 5 ] =  0  0  0  0  0
[15966.050041] ========================================
```

К таким (волатильным) возможностям нужно относиться с большой осторожностью!

```
# insmod mod_params.ko iparam=qwerty
insmod: ERROR: could not insert module ./mod_params.ko: Invalid parameters
```

```
$ dmesg | tail -n1
[16625.270285] mod_params: `qwerty' invalid for parameter `iparam'
```

Так выглядит попытка присвоения не числового значения числовому типу.

```
# insmod mod_params.ko cparam=123456789
insmod: ERROR: could not insert module mod_params.ko: No space left on device
$ dmesg | tail -n2
[16960.871302] cparam: string doesn't fit in 4 chars.
[16960.871309] mod_params: `123456789' too large for parameter `cparam'
```

А здесь была превышена максимальная длина для строки-параметра, передаваемой копированием.

Подсчёт ссылок использования

Одним из важных (и очень путанных по описаниям) понятий из сферы модулей есть подсчёт ссылок использования модуля. Счётчик ссылок является внутренним полем структуры описания модуля и, вообще то говоря, является слабо доступным пользователю непосредственно. При загрузке модуля начальное значение счётчика ссылок нулевое. При загрузке любого следующего модуля, который использует имена (импортирует), экспортируемые данным модулем, счётчик ссылок данного модуля инкрементируется. Модуль, счётчик ссылок использования которого не нулевой, **не может быть выгружен** командой `rmmod`. Такая тщательность отслеживания сделана из-за критичности модулей в системе: некорректное обращение к несуществующему модулю **гарантирует** крах всей системы.

Смотрим такую простейшую команду:

```
$ lsmod | grep i2c_core
i2c_core               21732  5 videodev,i915,drm_kms_helper,drm,i2c_algo_bit
```

Здесь модуль, зарегистрированный в системе под именем (не имя файла!) `i2c_core` (имя выбрано произвольно из числа загруженных модулей системы), имеет текущее значение счётчика ссылок 5, и далее следует перечисление имён 5-ти модулей на него ссылающихся. До тех пор, пока эти 5 модулей не будут удалены из системы, удалить модуль `i2c_core` будет невозможно.

В чём состоит отмеченная выше путаность всего, что относится к числу ссылок модуля? В том, что в области этого понятия происходят постоянные изменения от ядра к ядру, и происходят они с такой скоростью, что литература и обсуждения не поспевают за этими изменениями, а поэтому часто описывают какие-то несуществующие механизмы. До сих пор в описаниях часто можно встретить ссылки на макросы `MOD_INC_USE_COUNT()` и `MOD_DEC_USE_COUNT()`, которые увеличивают и уменьшают счётчик ссылок. Но эти макросы остались в ядрах 2.4. В ядре 2.6 их место заняли функциональные вызовы (определённые в `<linux/module.h>`):

- `int try_module_get( struct module *module )` - увеличить счётчик ссылок для модуля (возвращается признак успешности операции);
- `void module_put( struct module *module )` - уменьшить счётчик ссылок для модуля;
- `unsigned int module_refcount( struct module *mod )` - возвратить значение счётчика ссылок для модуля;

В качестве параметра всех этих вызовов, как правило, передаётся константный указатель `THIS_MODULE`, так что вызовы, в конечном итоге, выглядят подобно следующему:

```
try_module_get( THIS_MODULE );
```

Таким образом, видно, что имеется возможность управлять значением счётчика ссылок из собственного модуля. Делать это нужно крайне обдуманно, поскольку если мы увеличим счётчик и симметрично его позже не уменьшим, то мы вообще не сможем выгрузить модуль (до перезагрузки системы), это один из путей возникновения в системе «перманентных» модулей, другая возможность их возникновения: модуль не имеющий в коде функции завершения. В некоторых случаях может оказаться нужным динамически изменять счётчик ссылок, препятствуя на время возможности выгрузки модуля. Это актуально, например, в функциях, реализующих операции `open()` (увеличиваем счётчик обращений) и `close()` (уменьшаем, восстанавливаем счётчик обращений) для драйверов устройств — иначе станет возможна выгрузка модуля, обслуживающего открытое устройство, а следующие обращения (из процесса пользовательского пространства) к открытому дескриптору устройства будут направлены в не инициированную память!

И здесь возникает очередная путаница (которую можно наблюдать и по коду некоторых модулей):

во многих источниках рекомендуется инкрементировать из собственного кода модуля счётчик использований при открытии устройства, и декрементировать при его закрытии. Это было актуально, но с некоторой версии ядра (я не смог отследить с какой) это отслеживание делается автоматически при выполнении открытия/закрытия.

Структуры данных сетевого стека

Сетевая реализация построена так, чтобы не зависеть от конкретики протоколов. Основной структурой данных описывающей **сетевой интерфейс** (устройство) является `struct net_device`, к ней мы вернёмся позже, описывая устройство.

А вот **основной** структурой обмениваемых **данных** (между сетевыми уровнями), на движении экземпляров данных которой между сетевыми уровнями построена работа всей подсистемы — это есть буферы сокетов (определения в `<linux/skbuff.h>`). Буфер сокетов состоит их двух частей: данные управления `struct sk_buff`, и данные пакета (указываемые в `struct sk_buff` указателями `head` и `data`). Буферы сокетов всегда увязываются в очереди (`struct sk_queue_head`) посредством своих двух первых полей `next` и `prev`. Вот некоторые поля структуры, которые позволяют представить её структуру:

```
typedef unsigned char *sk_buff_data_t;
struct sk_buff {
   struct sk_buff *next; /* These two members must be first. */
   struct sk_buff *prev;
...
   sk_buff_data_t  transport_header;
   sk_buff_data_t  network_header;
   sk_buff_data_t  mac_header;
...
   unsigned char *head,
                 *data;
...
};
```

Структура вложенности заголовков сетевых уровней в точности соответствует структуре инкапсуляции сетевых протоколов протоколов внутри друг друга, это позволяет обрабатывающему слою получать доступ к информации, относящейся только к нужному ему слою.

Экземпляры данных типа `struct sk_buff` :

– Возникают при поступлении очередного сетевого пакета (здесь нужно принимать во внимание возможность сегментации пакетов) из внешней физической среды распространения данных. Об этом событии извещает прерывание (IRQ), генерируемое сетевым адаптером. При этом создаётся (чаще извлекается из пула использованных) экземпляр буфера сокета, заполняется данными из поступившего пакета и далее этот экземпляр передаётся **вверх** от сетевого слоя к слою, до приложения **прикладного уровня**, которое является получателем пакета. На этом экземпляр данных буфера сокета уничтожается (утилизируется).

– Возникают в среде приложения **прикладного уровня**, которое является отправителем пакета данных. Пакет отправляемых данных помещается в созданный буфер сокета, который начинает перемещаться вниз от сетевого слоя к слою, до достижения канального уровня L2. На этом уровне осуществляется физическая передача данных пакета через сетевой адаптер в среду распространения. В случае успешного завершения передачи (что подтверждается прерыванием, генерируемым сетевым адаптером, часто по той же линии IRQ, что и при приёме пакета) буфер сокета уничтожается (утилизируется). При отсутствии подтверждения отправки (IRQ) обычно делается несколько повторных попыток, прежде, чем принять решение об ошибке канала.

Прохождение экземпляра данных буфера сокета сквозь стек сетевых протоколов будет детально проанализировано далее.

Путь пакета сквозь стек протоколов

Теперь у нас достаточно деталей, чтобы проследить путь пакетов (буферов сокетов) сквозь сетевой стек, проследить то, как буфера сокетов возникают в системе, и когда они её покидают, а также ответить на вопрос, почему вышележащие протокольные уровни (будут рассмотрены чуть ниже) никогда не порождают и не уничтожают буферов сокетов, а только обрабатывают (или

модифицируют) содержащуюся в них информацию (работают как фильтры). Итак, последовательность связей мы можем разложить в таком порядке:

Приём: традиционный подход

Традиционный подход состоит в том, что каждый приходящий сетевой пакет порождает аппаратное прерывание по линии IRQ адаптера, что и служит сигналом на приём очередного сетевого пакета и создание буфера сокета для его сохранения и обработки принятых данных. Порядок действий модуля сетевого интерфейса при этом следующий:

1. Читая конфигурационную область PCI адартера сети при инициализации модуля, определяем линию прерывания IRQ, которая будет обслуживать сетевой обмен:

```
char irq;
pci_read_config_byte( pdev, PCI_INTERRUPT_LINE, &byte );
```

Точно таким же манером будет определена и область адресов ввода-адресов адаптера, скорее всего, через DMA ... - всё это рассматривается позже, при рассмотрении аппаратных шин.

2. При инициализации сетевого интерфейса, для этой линии IRQ устанавливается обработчик прерывания `my_interrupt()` :

```
request_irq( (int)irq, my_interrupt, IRQF_SHARED, "my_interrupt", &my_dev_id );
```

3. В обработчике прерывания, по приёму нового пакета из сети (то же прерывание может происходить и при завершении отправки пакета в сеть, здесь нужен анализ причины), создаётся (или запрашивается из пула используемых) новый экземпляр буфера сокетов:

```
static irqreturn_t my_interrupt( int irq, void *dev_id ) {
   ...
   struct sk_buff *skb = kmalloc( sizeof( struct sk_buff ), ... );
   // заполнение данных *skb чтением из портов сетевого адаптера
   netif_rx( skb );
   return IRQ_HANDLED;
}
```

Все эти действия выполняются не в самом обработчике верхней половины прерываний от сетевого адаптера, а в обработчике отложенного прерывания `NET_RX_SOFTIRQ` для этой линии. Последним действием является передача заполненного сокетного буфера вызову `netif_rx()` (или `netif_receive_skb()`) который и запустит процесс движения его (буфера) вверх по структуре сетевого стека (отметит отложенное программное прерывание `NET_RX_SOFTIRQ` для исполнения).

Приём: высокоскоростной интерфейс

Особенность природы сетевых интерфейсов состоит в том, что их активность носит взрывной характер: после весьма продолжительных периодов молчания возникают интервалы пиковой активности, когда сетевые пакеты (сегментированные на IP пакеты объёмы передаваемых данных) следуют сплошной плотной чередой. После такого пика активности могут снова наступать значительные промежутки полного отсутствия активности, или вялой активности на интерфейсе (обмен ARP пакетами для обновления информации разрешения локальных адресов и подобные виды активности). Современные Ethernet сетевые карты используют скорости обмена до 10Gbit/s, но уже даже при значительно ниже интенсивностях традиционный подход становится нецелесообразным: в периоды высокой плотности поступления пакетов:

- новые приходящие пакеты создают вложенные запросы IRQ нескольких уровней при ещё не обслуженном приёме текущего IRQ;
- асинхронное обслуживание каждого IRQ в плотном потоке создаёт слишком большие накладные расходы;

Поэтому был добавлен набор API для обработки таких плотных потоков пакетов, поступающих с высокоскоростных интерфейсов, который и получил название NAPI (New API[11]). Идея состоит в том, чтобы приём пакетов осуществлять не методом аппаратного прерывания, а методом **программного опроса** (polling), точнее, комбинацией этих двух возможностей:

- при поступлении **первого** пакета «пачки» инициируется прерывание IRQ адаптера (всё начинается как в традиционном методе)...
- в обработчике прерывания **запрещается** поступление дальнейших запросов прерывания с этой линии IRQ по приёму пакетов, IRQ с этой же линии по отправке пактов могут продолжать

11 Естественно, до какого времени он будет «новым» неизвестно — до появления ещё более нового.

поступать, таким образом, этот запрет происходит не программным запретом линии IRQ со стороны процессора, а записью управляющей информации в **аппаратные регистры** сетевого адаптера, адаптер должен предусматривать такое раздельное управление поступлением прерываний по приёму и передаче, но для современных высокоскоростных адаптеров это, обычно, соблюдается;

– после прекращения прерываний по приёму обработчик переходит в режим циклического считывания и обработки принятых из сети пакетов, сетевой адаптер при этом накапливает поступающие пакеты во внутреннем кольцевом буфере приёма, а считывание производится либо до полного исчерпания кольцевого буфера, либо до опередёлённого порогового числа считанных пакетов (10, 20, ...), называемого бюджетом функции полинга;
– естественно, это считывание и обработка пакетов происходит не в собственно обработчике прерывания (верхней половине), а в его отсроченной части;
– по каждому принятому в опросе пакету генерируется сокетный буфер для продвижения его по стеку сетевыз протоколов вверх;
– после **завершения цикла** программного опроса, по его результатам устанавливается состояние завершения `NAPI_STATE_DISABLE` (если не осталось больше не сосчитанных пакетов в кольцевом буфере адаптера), или `NAPI_STATE_SCHED` (что говорит, что устройство адаптера должно продолжать опрашиваться когда ядро следующий раз перейдёт к циклу опросов в отложенном обработчике прерываний).
– если результатом является `NAPI_STATE_DISABLE`, то после завершения цикла программного опроса восстанавливается разрешение генерации прерываний по линии IRQ приёма пакетов (записью в порты сетевого адаптера);

В реализующем коде модуля это укрупнённо должно выглядеть подобно следующему (при условии, что линия IRQ связана с аппаратным адаптером, как это описано для традиционного метода):

1. Реализатор обязан предварительно создать и зарегистрировать специфичную для модуля функцию опроса (poll-функцию), используя вызов (`<netdevice.h>`):

```
static inline void netif_napi_add( struct net_device *dev,
                                   struct napi_struct *napi,
                                   int (*poll)( struct napi_struct *, int ),
                                   int weight );
```

– где:

`dev` — это рассмотренная раньше структура зарегистрированного сетевого интерфейса;

`poll` — регистрируемая функция программного опроса, о которой ниже;

`weight` — относительный вес, приоритет, который придаёт разработчик этому интерфейсу, для 10Mb и 100Mb адаптеров здесь часто указано значение 16, а для 10Gb и 100Gb — значение 64;

`napi` — дополнительный параметр, указатель на специальную структуру, которая будет передаваться в каждый вызов функции `poll`, и где будет, по результату выполнения этой функции, заполняться поле `state` значениями `NAPI_STATE_DISABLE` или `NAPI_STATE_SCHED`, вид этой структуры должен быть (`<netdevice.h>`):

```
struct napi_struct {
   struct list_head poll_list;
   unsigned long state;
   int weight;
   int (*poll)( struct napi_struct *, int );
};
```

2. Зарегистрированная функция программного опроса (полностью зависимая от задачи и реализуемая в коде модуля) имеет подобный вид:

```
static int my_card_poll( struct napi_struct *napi, int budget ) {
   int work_done; // число реально обработанных в цикле опроса сетевых пакетов
   work_done = my_card_input( budget, ... ); // реализационно специфический приём пакетов
   if( work_done < budget ) {
      netif_rx_complete( netdev, napi );
      my_card_enable_irq( ... );             // разрешить IRQ приёма
   }
```

```
    return work_done;
}
```

Здесь пользовательская функция `my_card_input()` в цикле пытается аппаратно сосчитать `budget` сетевых пакетов, и для каждого считанного сетевого пакета создаёт сокетный буфер и вызывает `netif_receive_skb()`, после чего этот буфер начинает движение по стеку протоколов вверх. Если кольцевой буфер сетевого адаптера исчерпался ранее `budget` пакетов (нет более наличных пакетов), то адаптеру разрешается возбуждать прерывания по приёму, а ядро вызовом `netif_rx_complete()` уведомляется, что отменяется отложенное программное прерывание `NET_RX_SOFTIRQ` для дальнейшего вызова функции опроса. Если же удалось сосчитать `budget` пакетов (в буфере адаптера, видимо, есть ещё не обработанные пакеты), то опрос продолжится при следующем цикле обработки отложенного программного прерывания `NET_RX_SOFTIRQ`.

3. Обработчик аппаратного прерывания линии IRQ сетевого адаптера (активирующий при приходе **первого** сетевого пакета «пачки» активности) должен выполнять примерно следующее:

```
static irqreturn_t my_interrupt( int irq, void *dev_id ) {
   struct net_device *netdev = dev_id;
   if( likely( netif_rx_schedule_prep( netdev, ... ) ) ) {
      my_card_disable_irq( ... );             // запретить IRQ приёма
      __netif_rx_schedule( netdev, ... );
   }
   return IRQ_HANDLED;
}
```

Здесь ядро должно быть уведомлено, что новая порция сетевых пакетов готова для обработки. Для этого

– вызов `netif_rx_schedule_prep()` подготавливает устройство для помещение в список для программного опроса, устанавливая состояние в `NAPI_STATE_SCHED`;
– если предыдущий вызов успешен (а противное возникает только если NAPI уже активен), то вызовом `__netif_rx_schedule()` устройство помещается в список для программного опроса, в цикле обработки отложенного программного прерывания `NET_RX_SOFTIRQ`.

Вот, собственно, и всё относительно новой модели приёма сетевых пакетов. Здесь нужно держать в виду, что бюджет, разово устанавливаемый в функции опроса (локальный бюджет), не должен быть чрезмерно большим. По крайней мере:

– Опрос не должен должен потреблять более одного системного тика (глобальная переменная `jiffies`), иначе это будет искажать диспетчеризацию потоков ядра;

– Бюджет не должен быть больше глобально установленного ограничения:

```
$
300
```

После каждого цикла опроса число обработанных пакетов (возвращаемых функцией опроса) вычитается из этого глобального бюджета, и если остаток меньше нуля, то обработчик программного прерывания `NET_RX_SOFTIRQ` останавливается.

Передача пакетов

Описанными выше действиями инициируется создание и движение сокетного буфера вверх по стеку. Движение же вниз (при отправке в сеть) обеспечивается по другой цепочке:

1. При инициализации сетевого интерфейса (это момент, который уже был назван выше в п.2), создаётся таблица операций сетевого интерфейса, одно из полей которой `ndo_start_xmit` определяет функцию передачи пакета в сеть:

```
struct net_device_ops ndo = {
   .ndo_open = my_open,
   .ndo_stop = my_close,
   .ndo_start_xmit = stub_start_xmit,
};
```

2. При вызове `stub_start_xmit()` должна обеспечить аппаратную передачу полученного сокета в сеть, после чего уничтожает (возвращает в пул) буфер сокета:

```
static int stub_start_xmit( struct sk_buff *skb, struct net_device *dev ) {
   // ... аппартное обслуживание передачи
   dev_kfree_skb( skb );
```

```
    return 0;
}
```

Реально чаще уничтожение отправляемого буфера будет происходить не при инициализации операции, а при её (успешном) завершении, что отслеживается **по той же линии IRQ**, что и приём пакетов из сети.

Часто задаваемый вопрос: а где же в этом процессе место (код), где реально создаётся содержательная информация, **помещаемая** в сокетный буфер, или где **потребляется** информация из принимаемых сокетных буферов? Ответ: не ищите такого места в пределах сетевого стека ядра — любая информация для отправки в сеть, или потребляемая из сети, возникает в поле зрения только на прикладных уровнях, в приложениях пространства пользователя, таких, например, как `ping, ssh, telnet` и великое множество других. Интерфейс из этого прикладного уровня в стек протоколов ядра обеспечивается известным POSIX API сокетов прикладного уровня.

Драйверы: сетевой интерфейс

Задача сетевого интерфейса — быть тем местом, в котором:

- создаются экземпляры структуры `struct sk_buff`, по каждому принятому из интерфейса пакету (здесь нужно принимать во внимание возможность сегментации IP пакетов), далее созданный экземпляр структуры продвигается по стеку протоколов вверх, до получателя пользовательского пространства, где он и уничтожается;
- исходящие экземпляры структуры `struct sk_buff`, порождённые где-то на верхних уровнях протоколов пользовательского пространства, должны отправляться (чаще всего каким-то аппаратным механизмом), а сами экземпляры структуры после этого — уничтожаться.

Более детально эти вопросы рассмотрены, при обсуждении прохождения пакетов сквозь стек сетевых протоколов. А пока наша задача — создание той концевой точки (интерфейса), где эти последовательности действий начинаются и завершаются.

Ниже показан пример простого создания и регистрации в системе нового сетевого интерфейса (примеры этого раздела заимствованы из [6] и находятся в архиве `net.tgz`):

network.c :

```
#include <linux/module.h>
#include <linux/netdevice.h>

static struct net_device *dev;

static int my_open( struct net_device *dev ) {
   printk( KERN_INFO "Hit: my_open(%s)\n", dev->name );
   /* start up the transmission queue */
   netif_start_queue( dev );
   return 0;
}

static int my_close( struct net_device *dev ) {
   printk( KERN_INFO "Hit: my_close(%s)\n", dev->name );
   /* shutdown the transmission queue */
   netif_stop_queue( dev );
   return 0;
}

/* Note this method is only needed on some; without it
   module will fail upon removal or use. At any rate there is a memory
   leak whenever you try to send a packet through in any case*/
static int stub_start_xmit( struct sk_buff *skb, struct net_device *dev ) {
   dev_kfree_skb( skb );
   return 0;
}

static struct net_device_ops ndo = {
   .ndo_open = my_open,
   .ndo_stop = my_close,
```

```
   .ndo_start_xmit = stub_start_xmit,
};

static void my_setup( struct net_device *dev ) {
   int j;
   printk( KERN_INFO "my_setup(%s)\n", dev->name );
   /* Fill in the MAC address with a phoney */
   for( j = 0; j < ETH_ALEN; ++j )
      dev->dev_addr[ j ] = (char)j;
   ether_setup( dev );
   dev->netdev_ops = &ndo;
}

static int __init my_init( void ) {
   printk( KERN_INFO "Loading stub network module:...." );
   dev = alloc_netdev( 0, "fict%d", my_setup );
   if( register_netdev( dev ) ) {
      printk( KERN_INFO " Failed to register\n" );
      free_netdev( dev );
      return -1;
   }
   printk( KERN_INFO "Succeeded in loading %s!\n", dev_name( &dev->dev ) );
   return 0;
}

static void __exit my_exit( void ) {
   printk( KERN_INFO "Unloading stub network module\n" );
   unregister_netdev( dev );
   free_netdev( dev );
}

module_init( my_init );
module_exit( my_exit );

MODULE_AUTHOR( "Bill Shubert" );
MODULE_AUTHOR( "Jerry Cooperstein" );
MODULE_AUTHOR( "Tatsuo Kawasaki" );
MODULE_DESCRIPTION( "LDD:1.0 s_24/lab1_network.c" );
MODULE_LICENSE( "GPL v2" );
```

Здесь нужно обратить внимание на вызов `alloc_netdev()`, который в качестве параметра получает шаблон (`%d`) имени нового интерфейса: мы задаём префикс имени интерфейса (`fict`), а система присваивает сама первый свободный номер интерфейса с таким префиксом. Обратите также внимание как в цикле заполнился фиктивным значением `00:01:02:03:04:05` MAC-адрес интерфейса, что мы увидим вскоре в диагностике.

Вся связь сетевого интерфейса с выполняемыми на нём операциями осуществляется через таблицу функций операций сетевого интерфейса (**n**et **d**evice **o**perations):

```
struct net_device_ops {
        int                     (*ndo_init)(struct net_device *dev);
        void                    (*ndo_uninit)(struct net_device *dev);
        int                     (*ndo_open)(struct net_device *dev);
        int                     (*ndo_stop)(struct net_device *dev);
        netdev_tx_t             (*ndo_start_xmit) (struct sk_buff *skb,
                                                   struct net_device *dev);
        ...
        struct net_device_stats* (*ndo_get_stats)(struct net_device *dev);
        ...
}
```

В ядре 3.09, например, определено 39 операций в `struct net_device_ops`, (и около 50-ти операций в ядре 3.14), но реально разрабатываемые модули реализуют только некоторую малую часть из них.

Характерно, что в таблице операций интерфейса присутствует операция **передачи** сокетного буфера `ndo_start_xmit` в физическую среду, но вовсе нет операции **приёма** пакетов (сокетных буферов). Это совершенно естественно, как мы увидим вскоре: принятые пакеты (например в обработчике аппаратеного прерывания IRQ) тут же передаются в очередь (ядра) принимаемых пакетов, и далее уже обрабатываются сетевым стеком. А вот выполнять операцию `ndo_start_xmit` — обязательно, хотя бы, как минимум, для вызова API ядра `dev_kfree_skb()`, который утилизирует (уничтожает) сокетный буфер после успешной (да и безуспешной тоже) операции передачи пакета. Если этого не делать, в системе возникнет слабо выраженная утечка памяти (с каждым пакетом), которая, в конечном итоге, рано или поздно приведёт к краху системы.

Теперь созданное нами выше (пока фиктивное) сетевое устройство уже можно установить в системе:

```
$ sudo insmod ./network.ko
$ dmesg | tail -n4
[ 7355.005588] Loading stub network module:....
[ 7355.005597] my_setup()
[ 7355.006703] Succeeded in loading fict0!
$ ip link show dev fict0
5: fict0: <BROADCAST,MULTICAST> mtu 1500 qdisc noop state DOWN qlen 1000
    link/ether 00:01:02:03:04:05 brd ff:ff:ff:ff:ff:ff
$ sudo ifconfig fict0 192.168.56.50
$ dmesg | tail -n6
[ 7355.005588] Loading stub network module:....
[ 7355.005597] my_setup()
[ 7355.006703] Succeeded in loading fict0!
[ 7562.604588] Hit: my_open(fict0)
[ 7573.442094] fict0: no IPv6 routers present
$ ping 192.168.56.50
PING 192.168.56.50 (192.168.56.50) 56(84) bytes of data.
64 bytes from 192.168.56.50: icmp_req=1 ttl=64 time=0.253 ms
64 bytes from 192.168.56.50: icmp_req=2 ttl=64 time=0.056 ms
64 bytes from 192.168.56.50: icmp_req=3 ttl=64 time=0.057 ms
64 bytes from 192.168.56.50: icmp_req=4 ttl=64 time=0.056 ms
^C
--- 192.168.56.50 ping statistics ---
4 packets transmitted, 4 received, 0% packet loss, time 3000ms
rtt min/avg/max/mdev = 0.056/0.105/0.253/0.085 ms
$ ifconfig fict0
fict0     Link encap:Ethernet  HWaddr 00:01:02:03:04:05
          inet addr:192.168.56.50  Bcast:192.168.56.255  Mask:255.255.255.0
          inet6 addr: fe80::201:2ff:fe03:405/64 Scope:Link
          UP BROADCAST RUNNING MULTICAST  MTU:1500  Metric:1
          RX packets:0 errors:0 dropped:0 overruns:0 frame:0
          TX packets:0 errors:0 dropped:0 overruns:0 carrier:0
          collisions:0 txqueuelen:1000
          RX bytes:0 (0.0 b)  TX bytes:0 (0.0 b)
```

Обратите внимание, как совершенно **произвольное значение** заполняется в структуре `net_device`, и устанавливается в качестве MAC (аппаратного) адреса созданного интерфейса (в функции `my_setup()`).

Как уже отмечалось выше, основу структуры описания сетевого интерфейса составляет структура `struct net_device`, описанная в `<linux/netdevice.h>`. При работе с сетевыми интерфейсами эту структуру стоит изучить весьма тщательно. Это очень крупная структура, содержащая не только описание аппаратных средств, но и конфигурационные параметры сетевого интерфейса по отношению к выше лежащим протоколам (пример взят из ядра 3.09):

```
struct net_device {
   char  name[ IFNAMSIZ ] ;
...
   unsigned long  mem_end;   /* shared mem end     */
   unsigned long  mem_start; /* shared mem start   */
   unsigned long  base_addr; /* device I/O address */
   unsigned int   irq;       /* device IRQ number  */
```

```
...
   unsigned       mtu;       /* interface MTU value     */
   unsigned short type;      /* interface hardware type */
...
   struct net_device_stats stats;
   struct list_head dev_list;
...
   /* Interface address info. */
   unsigned char  perm_addr[ MAX_ADDR_LEN ]; /* permanent hw address    */
   unsigned char  addr_len;                  /* hardware address length */
...
}
```

Здесь поле `type`, например, определяет тип аппаратного адаптера с точки зрения ARP-механизма разрешения MAC адресов (`<linux/if_arp.h>`):

```
...
#define ARPHRD_ETHER       1    /* Ethernet 10Mbps           */
...
#define ARPHRD_IEEE802     6    /* IEEE 802.2 Ethernet/TR/TB */
#define ARPHRD_ARCNET      7    /* ARCnet                    */
...
#define ARPHRD_IEEE1394   24    /* IEEE 1394 IPv4 - RFC 2734 */
...
#define ARPHRD_IEEE80211 801    /* IEEE 802.11               */
```

Здесь же заносятся такие совершенно аппаратные характеристики интерфейса (реализующего его физического адаптера), как, например, адрес базовой области ввода-вывода (`base_addr`), используемая линия аппаратного прерывания (`irq`), максимальная длина пакета для данного интерфейса (`mtu`)...

Детальный разбор огромного числа полей `struct net_device` (этой и любой другой сопутствующей) или их возможных значений — бессмысленный, хотя бы потому, что эта структура радикально изменяется от подверсии к подверсии ядра; такой разбор должен проводиться «по месту» на основе изучения названных выше заголовочных файлов.

Со структурой сетевого интерфейса обычно создаётся и связывается (кодом модуля) **приватная структура данных**, в которой пользователь может размещать произвольные собственные данные любой сложности, ассоциированные с интерфейсом. Это обычная практика ядра Linux, и не только сетевой подсистемы. Указатель такой приватной структуры помещается в структуру сетевого интерфейса. Это особо актуально, если предполагается, что драйвер может создавать несколько сетевых интерфейсов (например, несколько идентичных сетевых адаптеров). Доступ к приватной структуре данных должен определяться **исключительно** специально определённой для того функцией `netdev_priv()`. Ниже показан возможный вид функции — это определение из ядра 3.09, но никто не даст гарантий, что в другом ядре оно радикально не поменяется:

```
/*     netdev_priv - access network device private data
 * Get network device private data
 */
static inline void *netdev_priv( const struct net_device *dev ) {
        return (char *)dev + ALIGN( sizeof( struct net_device ), NETDEV_ALIGN );
}
```

Примечание: Как легко видеть из определения, приватная структура данных дописывается **непосредственно в хвост** `struct net_device` - это обычная практика создания структур переменного размера, принятая в языке C начиная с стандарта C89 (и в C99). Но именно из-за этого, за счёт эффектов **выравнивания** данных (и его возможного изменения в будущем), не следует адресоваться к приватным данным непосредственно, а следует использовать `netdev_priv()`.

При начальном размещении интерфейса размер определённой пользователем приватной структуры передаётся первым параметром функции размещения, например так:

```
child = alloc_netdev( sizeof( struct priv ), "fict%d", &setup );
```

После успешного выполнения размещения интерфейса приватная структура также будет размещена («в хвост» структуре `struct net_device`), и будет доступна по вызову `netdev_priv()`.

Все структуры `struct net_device`, описывающие доступные сетевые интерфейсы в системе, увязаны в единый связный список.

Примечание: В ядре Linux **все и любые** списочные связные структуры строятся на основе API кольцевых двухсвязных списков, структур данных `struct list_head` (поле `dev_list` в `struct net_device`). Техника связных списков в ядре Linux будет подробно рассмотрена позже, в части API ядра.

Следующий пример визуализирует содержимого списка сетевых интерфейсов:

devices.c :

```
#include <linux/module.h>
#include <linux/init.h>
#include <linux/netdevice.h>

static int __init my_init( void ) {
   struct net_device *dev;
   printk( KERN_INFO "Hello: module loaded at 0x%p\n", my_init );
   dev = first_net_device( &init_net );
   printk( KERN_INFO "Hello: dev_base address=0x%p\n", dev );
   while ( dev ) {
      printk( KERN_INFO
              "name = %6s irq=%4d trans_start=%12lu last_rx=%12lu\n",
              dev->name, dev->irq, dev->trans_start, dev->last_rx );
      dev = next_net_device( dev );
   }
   return -1;
}

module_init( my_init );
```

Выполнение (предварительно для убедительности загрузим ранее созданный модуль `network.ko`):

```
$ sudo insmod network.ko
$ sudo insmod devices.ko
insmod: error inserting 'devices.ko': -1 Operation not permitted
$ dmesg | tail -n8
Hello: module loaded at 0xf8853000
Hello: dev_base address=0xf719c400
name =     lo  irq=   0  trans_start=           0  last_rx=           0
name =   eth0  irq=  16  trans_start=  4294693516  last_rx=           0
name =  wlan0  irq=   0  trans_start=  4294693412  last_rx=           0
name =   pan0  irq=   0  trans_start=           0  last_rx=           0
name = cipsec0 irq=   0  trans_start=     2459232  last_rx=           0
name = mynet0  irq=   0  trans_start=           0  last_rx=           0
```

Статистики интерфейса

Процессы, происходящие на сетевом интерфейс, сложно явно наблюдать (в сравнении, скажем, с интерфейсами `/dev` или `/proc`). Поэтому очень важной характеристикой интерфейса становится накопленная статистика происходящих на нём процессов. Для накопления статистики работы сетевого интерфейса описана специальная структура (достаточно большая, определена там же в `<linux/netdevice.h>`, показано только начало структуры) :

```
struct net_device_stats {
   unsigned long  rx_packets;     /* total packets received    */
   unsigned long  tx_packets;     /* total packets transmitted */
   unsigned long  rx_bytes;       /* total bytes received      */
   unsigned long  tx_bytes;       /* total bytes transmitted   */
   unsigned long  rx_errors;      /* bad packets received      */
   unsigned long  tx_errors;      /* packet transmit problems  */
...
}
```

Поля такой структуры структура должны заполняться кодом модуля статистическими данными проходящих пакетов (при передаче пакета, например, инкрементируя `tx_packets`).

В пространство пользователя эту структуру возвращает функция `ndo_get_stats` в таблице операций `struct net_device_ops` (выше эти поля были специально показаны). Модуль должен реализовать такую собственную функцию и поместить её в `struct net_device_ops`. Это делается, если вы хотите получать статистики сетевого интерфейса пользователем вызовом `ifconfig`, или через интерфейс файловой системы `/proc`, как это ожидаемо и происходит для всех других сетевых интерфейсов:

```
$ ifconfig wlan0
wlan0     Link encap:Ethernet  HWaddr 00:13:02:69:70:9B
          inet addr:192.168.1.22  Bcast:192.168.1.255  Mask:255.255.255.0
          inet6 addr: fe80::213:2ff:fe69:709b/64 Scope:Link
          UP BROADCAST RUNNING MULTICAST  MTU:1500  Metric:1
          RX packets:8658 errors:0 dropped:0 overruns:0 frame:0
          TX packets:9070 errors:0 dropped:0 overruns:0 carrier:0
          collisions:0 txqueuelen:1000
          RX bytes:4240425 (4.0 MiB)  TX bytes:1318733 (1.2 MiB)
```

Где обычно размещается структура `net_device_stats`, которую мы предполагаем возвращать пользователю? Часто встречаются несколько вариантов:

1. Если модуль обслуживает только один конкретный сетевой интерфейс, то структура может размещаться на глобальном уровне кода модуля.

```
static struct net_device_stats stats;
...
static struct net_device_stats *my_get_stats( struct net_device *dev ) {
   return &stats;
}
...
static struct net_device_ops ndo = {
   ...
   .ndo_get_stats = my_get_stats,
};
```

2. Часто структура статистики размещается как составная часть структуры **приватных данных** (о которой была речь выше), которую разработчик связывает с сетевым интерфейсом.

```
static struct net_device *my_dev = NULL;
struct my_private {
   struct net_device_stats stats;
   ...
};
...
static struct net_device_stats *my_get_stats( struct net_device *dev ) {
   struct my_private *priv = (my_private*)netdev_priv( dev );
   return &priv->stats;
}
...
static struct net_device_ops ndo = {
   ...
   .ndo_get_stats = my_get_stats,
}
...
void my_setup( struct net_device *dev ) {
   memset( netdev_priv( dev ), 0, sizeof( struct my_private ) );
   dev->netdev_ops = &ndo;
}
int __init my_init( void ) {
    my_dev = alloc_netdev( sizeof( struct my_private ), "my_if%d", my_setup );
}
```

3. Наконец, может использоваться структура, включённая (имплементированная) непосредственно **в состав** определения интерфейса `struct net_device`.

```
...
```

```
static struct net_device_stats *my_get_stats( struct net_device *dev ) {
   return &dev->stats;
}
```

Все эти три варианта использования показаны (для сравнения: файлы `virt.c`, `virt1.c` и `virt2.c` в архиве `virt.tgz`).

Виртуальный сетевой интерфейс

В предыдущих примерах мы создавали сетевые интерфейсы, но они не осуществляли реально с физической средой передачи и приёма. Для выполнения такого уровня проработки нужно бы иметь реальное коммуникационное оборудование на PCI шине, что не всегда доступно. Но мы можем создать интерфейс, который будет перехватывать трафик сетевого ввода-вывода с другого, реально существующего в системе, интерфейса, и обеспечивать обработку этих потоков (архив `virt.tgz`).

virt.c :

```
#include <linux/module.h>
#include <linux/netdevice.h>
#include <linux/etherdevice.h>
#include <linux/moduleparam.h>
#include <net/arp.h>

#define ERR(...) printk( KERN_ERR "! "__VA_ARGS__ )
#define LOG(...) printk( KERN_INFO "! "__VA_ARGS__ )

static char* link = "eth0";
module_param( link, charp, 0 );

static char* ifname = "virt";
module_param( ifname, charp, 0 );

static struct net_device *child = NULL;

struct priv {
   struct net_device_stats stats;
   struct net_device *parent;
};

static rx_handler_result_t handle_frame( struct sk_buff **pskb ) {
   struct sk_buff *skb = *pskb;
   if( child ) {
      struct priv *priv = netdev_priv( child );
      priv->stats.rx_packets++;
      priv->stats.rx_bytes += skb->len;
      LOG( "rx: injecting frame from %s to %s", skb->dev->name, child->name );
      skb->dev = child;
      return RX_HANDLER_ANOTHER;
   }
   return RX_HANDLER_PASS;
}

static int open( struct net_device *dev ) {
   netif_start_queue( dev );
   LOG( "%s: device opened", dev->name );
   return 0;
}

static int stop( struct net_device *dev ) {
   netif_stop_queue( dev );
   LOG( "%s: device closed", dev->name );
   return 0;
```

```
}

static netdev_tx_t start_xmit( struct sk_buff *skb, struct net_device *dev ) {
   struct priv *priv = netdev_priv( dev );
   priv->stats.tx_packets++;
   priv->stats.tx_bytes += skb->len;
   if( priv->parent ) {
      skb->dev = priv->parent;
      skb->priority = 1;
      dev_queue_xmit( skb );
      LOG( "tx: injecting frame from %s to %s", dev->name, skb->dev->name );
      return 0;
   }
   return NETDEV_TX_OK;
}

static struct net_device_stats *get_stats( struct net_device *dev ) {
   return &( (struct priv*)netdev_priv( dev ) )->stats;
}

static struct net_device_ops crypto_net_device_ops = {
   .ndo_open = open,
   .ndo_stop = stop,
   .ndo_get_stats = get_stats,
   .ndo_start_xmit = start_xmit,
};

static void setup( struct net_device *dev ) {
   int j;
   ether_setup( dev );
   memset( netdev_priv(dev), 0, sizeof( struct priv ) );
   dev->netdev_ops = &crypto_net_device_ops;
   for( j = 0; j < ETH_ALEN; ++j ) // fill in the MAC address with a phoney
      dev->dev_addr[ j ] = (char)j;
}

int __init init( void ) {
   int err = 0;
   struct priv *priv;
   char ifstr[ 40 ];
   sprintf( ifstr, "%s%s", ifname, "%d" );
   child = alloc_netdev( sizeof( struct priv ), ifstr, setup );
   if( child == NULL ) {
      ERR( "%s: allocate error", THIS_MODULE->name ); return -ENOMEM;
   }
   priv = netdev_priv( child );
   priv->parent = __dev_get_by_name( &init_net, link ); // parent interface
   if( !priv->parent ) {
      ERR( "%s: no such net: %s", THIS_MODULE->name, link );
      err = -ENODEV; goto err;
   }
   if( priv->parent->type != ARPHRD_ETHER && priv->parent->type != ARPHRD_LOOPBACK ) {
      ERR( "%s: illegal net type", THIS_MODULE->name );
      err = -EINVAL; goto err;
   }
   /* also, and clone its IP, MAC and other information */
   memcpy( child->dev_addr, priv->parent->dev_addr, ETH_ALEN );
   memcpy( child->broadcast, priv->parent->broadcast, ETH_ALEN );
   if( ( err = dev_alloc_name( child, child->name ) ) ) {
      ERR( "%s: allocate name, error %i", THIS_MODULE->name, err );
      err = -EIO; goto err;
```

```
    }
    register_netdev( child );
    rtnl_lock();
    netdev_rx_handler_register( priv->parent, &handle_frame, NULL );
    rtnl_unlock();
    LOG( "module %s loaded", THIS_MODULE->name );
    LOG( "%s: create link %s", THIS_MODULE->name, child->name );
    LOG( "%s: registered rx handler for %s", THIS_MODULE->name, priv->parent->name );
    return 0;
err:
    free_netdev( child );
    return err;
}

void __exit exit( void ) {
    struct priv *priv = netdev_priv( child );
    if( priv->parent ) {
        rtnl_lock();
        netdev_rx_handler_unregister( priv->parent );
        rtnl_unlock();
        LOG( "unregister rx handler for %s\n", priv->parent->name );
    }
    unregister_netdev( child );
    free_netdev( child );
    LOG( "module %s unloaded", THIS_MODULE->name );
}

module_init( init );
module_exit( exit );

MODULE_AUTHOR( "Oleg Tsiliuric" );
MODULE_AUTHOR( "Nikita Dorokhin" );
MODULE_LICENSE( "GPL v2" );
MODULE_VERSION( "2.1" );
```

Перехват **входящего** трафика родительского интерфейса здесь осуществляется установкой нового обработчика (функция `handle_frame()`) входящих пакетов для созданного интерфейса, вызовом `netdev_rx_handler_unregister()`, который появился в API ядра начиная с 2.6.36 (ранее это приходилось делать другими способами). При передаче **исходящего** сокетного буфера в сеть (функция `start_xmit()`) мы просто подменяем в структуре сокетного буфера интерфейс, через который физически должна производиться отправка.

Работа с таким интерфейсом выглядит примерно следующим образом:

- на **любой** существующий и работоспособный сетевой интерфейс:

```
$ ip addr show dev p7p1
3: p7p1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP qlen 1000
    link/ether 08:00:27:9e:02:02 brd ff:ff:ff:ff:ff:ff
    inet 192.168.56.101/24 brd 192.168.56.255 scope global p7p1
    inet6 fe80::a00:27ff:fe9e:202/64 scope link
    valid_lft forever preferred_lft forever
```

- устанавливаем новый виртуальный интерфейс и конфигурируем его (на IP подсеть, отличную от исходной подсети интерфейса `p7p1`):

```
$ sudo insmod virt2.ko link=p7p1
$ sudo ifconfig virt0 192.168.50.2
$ ifconfig virt0
virt0     Link encap:Ethernet  HWaddr 08:00:27:9E:02:02
          inet addr:192.168.50.2  Bcast:192.168.50.255  Mask:255.255.255.0
          inet6 addr: fe80::a00:27ff:fe9e:202/64 Scope:Link
          UP BROADCAST RUNNING MULTICAST  MTU:1500  Metric:1
          RX packets:0 errors:0 dropped:0 overruns:0 frame:0
          TX packets:27 errors:0 dropped:0 overruns:0 carrier:0
          collisions:0 txqueuelen:1000
          RX bytes:0 (0.0 b)  TX bytes:5027 (4.9 KiB)
```

- самый простой способ создать **ответный** конец (вам ведь нужно как-то тестировать свою работу?) для такой (192.168.50.2/24) подсети **на другом хосте** LAN, это создать **алиасный IP** для сетевого интерфейса этого удалённого хоста, по типу:

```
$ sudo ifconfig vboxnet0:1 192.168.50.1
$ ifconfig
...
vboxnet0  Link encap:Ethernet  HWaddr 0A:00:27:00:00:00
          inet addr:192.168.56.1  Bcast:192.168.56.255  Mask:255.255.255.0
          inet6 addr: fe80::800:27ff:fe00:0/64 Scope:Link
          UP BROADCAST RUNNING MULTICAST  MTU:1500  Metric:1
          RX packets:0 errors:0 dropped:0 overruns:0 frame:0
          TX packets:223 errors:0 dropped:0 overruns:0 carrier:0
          collisions:0 txqueuelen:1000
          RX bytes:0 (0.0 b)  TX bytes:36730 (35.8 KiB)
vboxnet0:1 Link encap:Ethernet  HWaddr 0A:00:27:00:00:00
          inet addr:192.168.50.1  Bcast:192.168.50.255  Mask:255.255.255.0
          UP BROADCAST RUNNING MULTICAST  MTU:1500  Metric:1
```

(Здесь показан сетевой интерфейс гипервизора виртуальных машин VirtualBox, но точно то же можно проделать и с интерфейсом любого физического устройства).

- теперь из вновь созданного виртуального интерфейса мы можем проверить прозрачность сети посылкой ICMP:

```
$ ping 192.168.50.1
PING 192.168.50.1 (192.168.50.1) 56(84) bytes of data.
64 bytes from 192.168.50.1: icmp_req=1 ttl=64 time=0.371 ms
64 bytes from 192.168.50.1: icmp_req=2 ttl=64 time=0.210 ms
64 bytes from 192.168.50.1: icmp_req=3 ttl=64 time=0.184 ms
64 bytes from 192.168.50.1: icmp_req=4 ttl=64 time=0.242 ms
^C
--- 192.168.50.1 ping statistics ---
4 packets transmitted, 4 received, 0% packet loss, time 3001ms
rtt min/avg/max/mdev = 0.184/0.251/0.371/0.074 ms
```

- и далее создать для удалённого хоста сессию `ssh` (по протоколу TCP) через новый виртуальный интерфейс:

```
$ ssh 192.168.50.2
Nasty PTR record "192.168.50.2" is set up for 192.168.50.2, ignoring
olej@192.168.50.2's password:
Last login: Tue Apr  3 10:21:28 2012 from 192.168.1.5
[olej@fedora16vm ~]$ uname -a
Linux fedora16vm.localdomain 3.3.0-8.fc16.i686 #1 SMP Thu Mar 29 18:33:55 UTC 2012 i686 i686 i386
GNU/Linux
[olej@fedora16vm ~]$ exit
logout
Connection to 192.168.50.2 closed.
$
```

Примечание: Чтобы не увеличивать сложность обсуждения, выше показан упрощённый пример модуля, который полностью **перехватывает** трафик родительского интерфейса, при этом он **замещает** родительский интерфейс (для этого нужно раздельно обрабатывать пакеты IP и пакеты разрешения адресов ARP). Среди архива примеров размещён и архив (`virt-full.tgz`), который корректно анализирует адреса получателей.

Виртуальный сетевой интерфейс (созданный тем или иным способом) это очень мощный инструмент периода создания и отладки сетевых модулей, поэтому он заслуживает отдельного рассмотрения.

Протокол сетевого уровня

На этом уровне (L2) обеспечивается обработка таких протоколов, как: IP/IPv4/IPv6, IPX, ICMP, RIP, OSPF, ARP, или добавление оригинальных пользовательских протоколов. Для установки обработчиков сетевого уровня предоставляется API сетевого уровня (`<linux/netdevice.h>`):

```
struct packet_type {
```

```
    __be16  type; /* This is really htons(ether_type). */
    struct net_device *dev; /* NULL is wildcarded here    */
    int (*func)( struct sk_buff*, struct net_device*, struct packet_type*, struct net_device* );
...
    struct list_head list;
};
extern void dev_add_pack( struct packet_type *pt );
extern void dev_remove_pack( struct packet_type *pt );
```

Фактически, в протокольных модулях, как здесь, так и далее на транспортном уровне — мы должны **добавить фильтр**, через который проходят буфера сокетов **из входящего потока** интерфейса (исходящий поток реализуется проще, как показано в примерах ранее). Функция `dev_add_pack()` добавляет ещё один новый обработчик для пакетов заданного типа и выбранного интерфейса, реализуемый функцией `func()`. Функция **добавляет, но не замещает** существующий обработчик (в том числе и обработчик по умолчанию сетевой системы Linux). На обработку в функцию отбираются (попадают) те буфера сокетов, которые удовлетворяют критерием, заложенным в структуре `struct packet_type` (по типу протокола `type`, сетевому интерфейсу `dev`)

Примеры добавления собственных обработчиков сетевых протоколов находятся в архиве `netproto.tgz`. Вот так может быть добавлен обработчик нового протокола сетевого уровня:

net_proto.c :

```
#include <linux/module.h>
#include <linux/init.h>
#include <linux/netdevice.h>

#define ERR(...) printk( KERN_ERR "! "__VA_ARGS__ )
#define LOG(...) printk( KERN_INFO "! "__VA_ARGS__ )

int test_pack_rcv( struct sk_buff *skb, struct net_device *dev,
                   struct packet_type *pt, struct net_device *odev ) {
    LOG( "packet received with length: %u\n", skb->len );
    kfree_skb( skb );
    return skb->len;
};

#define TEST_PROTO_ID 0x1234
static struct packet_type test_proto = {
    __constant_htons( ETH_P_ALL ),  // may be: __constant_htons( TEST_PROTO_ID ),
    NULL,
    test_pack_rcv,
    (void*)1,
    NULL
};

static int __init my_init( void ) {
    dev_add_pack( &test_proto );
    LOG( "module loaded\n" );
    return 0;
}

static void __exit my_exit( void ) {
    dev_remove_pack( &test_proto );
    LOG( KERN_INFO "module unloaded\n" );
}

module_init( my_init );
module_exit( my_exit );

MODULE_AUTHOR( "Oleg Tsiliuric" );
MODULE_LICENSE( "GPL v2" );
```

Примечание: Самая большая сложность с подобными примерами — это то, какими средствами

вы будете его тестировать для нестандартного протокола, когда операционная система, возможно, не знает такого сетевого протокола, и не имеет утилит обмена в таком протоколе...

Выполнение такого примера:

```
$ sudo insmod net_proto.ko
$ dmesg | tail -n6
module loaded
packet received with length: 74
packet received with length: 60
packet received with length: 66
packet received with length: 241
packet received with length: 52
$ sudo rmmod net_proto
```

В этом примере обработчик протокола перехватывает (фильтрует) **все** пакеты (константа `ETH_P_ALL`) на всех сетевых интерфейсах. В случае собственного протокола здесь должна бы быть константа `TEST_PROTO_ID` (но для такого случая нам нечем оттестировать модуль). Очень большое число идентификаторов протоколов (Ethernet Protocol ID's) находим в `<linux/if_ether.h>`, некоторые наиболее интересные из них, для примера:

```
#define ETH_P_LOOP   0x0060  /* Ethernet Loopback packet  */
...
#define ETH_P_IP     0x0800  /* Internet Protocol packet  */
...
#define ETH_P_ARP    0x0806  /* Address Resolution packet */
...
#define ETH_P_PAE    0x888E  /* Port Access Entity (IEEE 802.1X) */
...
#define ETH_P_ALL    0x0003  /* Every packet (be careful!!!) */
...
```

Здесь же находим описание заголовка Ethernet пакета, который помогает в заполнении структуры `struct packet_type` :

```
struct ethhdr {
   unsigned char h_dest[ETH_ALEN];   /* destination eth addr */
   unsigned char h_source[ETH_ALEN]; /* source ether addr    */
   __be16       h_proto;             /* packet type ID field */
} __attribute__((packed));
```

Написанный нами пример модуля порождает ряд вопросов:

- Можно ли установить несколько обработчиков потока пакетов (для одного или различающихся типов протоколов `type`)?
- В каком порядке будут вызываться функции-обработчики при поступлении пакета?
- Как специфицировать один отдельный сетевой интерфейс, к которому должен применяться фильтр?
- Какую роль играет вызов `kfree_skb()` (в функции-фильтре обработки протокола `test_pack_rcv()`), и какой сокетный буфер (или его копия) при этом освобождается?

Для уяснения этих вопросов нам необходимо собрать на базе предыдущего другой пример (показаны только отличающиеся фрагменты кода):

net_proto2.c :

```
...
static int debug = 0;
module_param( debug, int, 0 );

static char* link = NULL;
module_param( link, charp, 0 );

int test_pack_rcv_1( struct sk_buff *skb, struct net_device *dev,
                     struct packet_type *pt, struct net_device *odev ) {
   int s = atomic_read( &skb->users );
```

```
   kfree_skb( skb );
   if( debug > 0 )
      LOG( "function #1 - %p => users: %d->%d\n", skb, s, atomic_read( &skb->users ) );
   return skb->len;
};

int test_pack_rcv_2( struct sk_buff *skb, struct net_device *dev,
                     struct packet_type *pt, struct net_device *odev ) {
   int s = atomic_read( &skb->users );
   kfree_skb( skb );
   if( debug > 0 )
      LOG( "function #2 - %p => users: %d->%d\n", skb, s, atomic_read( &skb->users ) );
   return skb->len;
};

static struct packet_type
test_proto1 = {
   __constant_htons( ETH_P_IP ),
   NULL,
   test_pack_rcv_1,
   (void*)1,
   NULL
},
test_proto2 = {
   __constant_htons( ETH_P_IP ),
   NULL,
   test_pack_rcv_2,
   (void*)1,
   NULL
};

static int __init my_init( void ) {
   if( link != NULL ) {
      struct net_device *dev = __dev_get_by_name( &init_net, link );
      if( NULL == dev ) {
         ERR( "%s: illegal link", link );
         return -EINVAL;
      }
      test_proto1.dev = test_proto2.dev = dev;
   }
   dev_add_pack( &test_proto1 );
   dev_add_pack( &test_proto2 );
   if( NULL == test_proto1.dev ) LOG( "module %s loaded for all links\n", THIS_MODULE->name );
   else LOG( "module %s loaded for link %s\n", THIS_MODULE->name, link );
   return 0;
}

static void __exit my_exit( void ) {
   if( test_proto2.dev != NULL ) dev_put( test_proto2.dev );
   if( test_proto1.dev != NULL ) dev_put( test_proto1.dev );
   dev_remove_pack( &test_proto2 );
   dev_remove_pack( &test_proto1 );
   LOG( "module %s unloaded\n", THIS_MODULE->name );
}
```

Здесь, собственно, выполняется абсолютно то же, что и в предыдущем варианте, но мы устанавливаем одновременно **два** новых дополнительных обработчика для пакетов IPv4 (`ETH_P_IP`), причём устанавливаем именно в последовательности: `test_pack_rcv_1()`, а затем `test_pack_rcv_2()`. Смотрим что из этого получается... Загружаем модуль:

```
$ sudo insmod net_proto2.ko link=p7p1
```

```
$ dmesg | tail -n1
[  403.339591] ! module net_proto2 loaded for link p7p1
```

И далее (конфигурировав интерфейс на адрес 192.168.56.3) с другого хоста выполняем:

```
$ ping -c3 192.168.56.3
PING 192.168.56.3 (192.168.56.3) 56(84) bytes of data.
64 bytes from 192.168.56.3: icmp_req=1 ttl=64 time=0.668 ms
64 bytes from 192.168.56.3: icmp_req=2 ttl=64 time=0.402 ms
64 bytes from 192.168.56.3: icmp_req=3 ttl=64 time=0.330 ms
--- 192.168.56.3 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2000ms
rtt min/avg/max/mdev = 0.330/0.466/0.668/0.147 ms
```

В системном журнале мы найдём:

```
$ dmesg | tail -n7
[  403.339591] ! module net_proto2 loaded for link p7p1
[  420.305824] ! function #2 - eb6873c0 => users: 2->1
[  420.305829] ! function #1 - eb6873c0 => users: 2->1
[  421.306302] ! function #2 - eb687c00 => users: 2->1
[  421.306308] ! function #1 - eb687c00 => users: 2->1
[  422.306289] ! function #2 - eb687180 => users: 2->1
[  422.306294] ! function #1 - eb687180 => users: 2->1
```

Отсюда видно, что обработчики срабатывают в порядке обратном их установке (установленный позже - срабатывает раньше), но срабатывают **все**. Они получают в качестве аргумента адрес одной и той же копии буфера сокета. Относительно `kfree_skb()` мы должны обратиться к исходному коду реализации ядра (файл `net/core/skbuff.c`):

```
void kfree_skb(struct sk_buff *skb) {
   if (unlikely(!skb))
      return;
   if (likely(atomic_read(&skb->users) == 1))
      smp_rmb();
   else if (likely(!atomic_dec_and_test(&skb->users)))
      return;
   trace_kfree_skb(skb, __builtin_return_address(0));
   __kfree_skb(skb);
}
```

Вызов `kfree_skb()` будет реально освобождать буфер сокета только в случае `skb->users == 1`, при всех остальных значениях он будет только декрементировать `skb->users` (счётчик использования). Для уточнения происходящего мы можем закомментировать вызовы `kfree_skb()` в двух обработчиках выше, и наблюдать при этом:

```
$ dmesg | tail -n7
[11373.754524] ! module net_proto2 loaded for link p7p1
[11398.930057] ! function #2 - ed3dfc00 => users: 2->2
[11398.930061] ! function #1 - ed3dfc00 => users: 3->3
[11399.929838] ! function #2 - ed3dfb40 => users: 2->2
[11399.929843] ! function #1 - ed3dfb40 => users: 3->3
[11400.929522] ! function #2 - ed3df480 => users: 2->2
[11400.929527] ! function #1 - ed3df480 => users: 3->3
```

Если функция обработчик не декрементирует `skb->users` по завершению вызовом `kfree_skb()`, то, после окончательного вызова обработки по умолчанию, буфер сокета не будет уничтожен, и в системе будет наблюдаться **утечка памяти**. Она незначительная, но неумолимая, и, в конце концов, приведёт к краху системы. Проверку на отсутствие утечки памяти (по этой причине, или по любой иной) предлагается проверить приёмом по сетевому каналу значительного объёма данных (несколько гигабайт), с фиксацией состояния памяти командой `free`. Для этого можно с успехом использовать утилиту `nc` (network cat):

– на тестируемом узле запустить скрипт `./client`:

```
LIMIT=1000000
for ((a=1; a <= LIMIT ; a++))
do
   rm -a z.txt
   nc 192.168.56.1 12345 > z.txt
   sleep 1
done
```

– на стороннем узле сети запустить скрипт `./server`

```
dd if=/dev/zero of=z.txt bs=1M count=1
LIMIT=1000000
for ((a=1; a <= LIMIT ; a++))
do
   cat z.txt | nc -l 12345
done
```

(здесь в скриптах: 192.168.56.1 — IP адрес узла где работает `server`, 12345 — номер TCP порта, через который `nc` предписывается передавать данные, при желании, можно использовать и UDP, добавив к `nc` опцию `-u`)

– и подождать некоторое время, порядка 10-20 минут:

```
$ free
             total       used       free     shared    buffers     cached
Mem:        768084     260636     507448          0      23392     129108
-/+ buffers/cache:     108136     659948
Swap:      1540092          0    1540092

$ ifconfig p7p1
p7p1: flags=4163<UP,BROADCAST,RUNNING,MULTICAST>  mtu 1500
        inet 192.168.56.3  netmask 255.255.255.255  broadcast 192.168.56.3
        inet6 fe80::a00:27ff:fe08:9abd  prefixlen 64  scopeid 0x20<link>
        ether 08:00:27:08:9a:bd  txqueuelen 1000  (Ethernet)
        RX packets 2017560  bytes 3048762624 (2.8 GiB)
        RX errors 0  dropped 0  overruns 0  frame 0
        TX packets 398156  bytes 26283474 (25.0 MiB)
        TX errors 0  dropped 0 overruns 0  carrier 0  collisions 0
```

Ещё раз о виртуальном интерфейсе

Ранее рассматривалось создание виртуального сетевого интерфейса (использующего трафик реального физического, родительского) средствами `netdev_rx_handler_register()`. Но такой способ не свободен от некоторых недостатков: он появился хронологически достаточно поздно, в API ядра начиная с версии 2.6.36, не со всяким ядром он может быть использован, кроме того, он в некоторой степени громоздкий и путанный. Но это же можно сделать и другим способом, не зависящим от версий используемого ядра, используя протокольные механизмы сетевого уровня (L3). Кроме того, это хороший реалистичный пример использования протокольных фильтров. Пример подобной реализации расположен в архиве `virt-proto.tgz`.

Примечание: В названном архиве представлены два варианта модуля: упрощённый модуль `virtl.ko` (lite вариант), интерфейс (`virt0`) которого **замещает** родительский сетевой интерфейс, и полный вариант `virt.ko`, который анализирует сетевые фреймы (и ARP и IP4 протоколов), и затрагивает только трафик, к его интерфейсу относящийся. Разница состоит в том, что на время загрузки упрощённого модуля работа родительского интерфейса прекращается, а при загрузке полного варианта оба интерфейса работают одновременно и независимо. Но код полного модуля гораздо более громоздкий, а для понимания принципов он ничего не добавляет. Ниже детально рассмотрен упрощённый вариант, не скрывающий принципы, и только позже мы в пару слов коснёмся полного варианта: код его и протокол испытаний приведены в архиве, поэтому его детализация не вызывает сложностей.

virtl.c :

```
#include <linux/module.h>
#include <linux/netdevice.h>
#include <linux/etherdevice.h>
#include <linux/inetdevice.h>
```

```
#include <linux/moduleparam.h>
#include <net/arp.h>
#include <linux/ip.h>

#define ERR(...) printk( KERN_ERR "! "__VA_ARGS__ )
#define LOG(...) printk( KERN_INFO "! "__VA_ARGS__ )
#define DBG(...) if( debug != 0 ) printk( KERN_INFO "! "__VA_ARGS__ )

static char* link = "eth0";
module_param( link, charp, 0 );

static char* ifname = "virt";
module_param( ifname, charp, 0 );

static int debug = 0;
module_param( debug, int, 0 );

static struct net_device *child = NULL;
static struct net_device_stats stats;  // статическая таблица статистики интерфейса
static u32 child_ip;

struct priv {
   struct net_device *parent;
};

static char* strIP( u32 addr ) {      // диагностика IP в точечной нотации
   static char saddr[ MAX_ADDR_LEN ];
   sprintf( saddr, "%d.%d.%d.%d",
            ( addr ) & 0xFF, ( addr >> 8 ) & 0xFF,
            ( addr >> 16 ) & 0xFF, ( addr >> 24 ) & 0xFF
          );
   return saddr;
}

static int open( struct net_device *dev ) {
   struct in_device *in_dev = dev->ip_ptr;
   struct in_ifaddr *ifa = in_dev->ifa_list;      /* IP ifaddr chain */
   LOG( "%s: device opened", dev->name );
   child_ip = ifa->ifa_address;
   netif_start_queue( dev );
   if( debug != 0 ) {
      char sdebg[ 40 ] = "";
      sprintf( sdebg, "%s:", strIP( ifa->ifa_address ) );
      strcat( sdebg, strIP( ifa->ifa_mask ) );
      DBG( "%s: %s", dev->name, sdebg );
   }
   return 0;
}

static int stop( struct net_device *dev ) {
   LOG( "%s: device closed", dev->name );
   netif_stop_queue( dev );
   return 0;
}

static struct net_device_stats *get_stats( struct net_device *dev ) {
   return &stats;
}

// передача фрейма
static netdev_tx_t start_xmit( struct sk_buff *skb, struct net_device *dev ) {
```

```
   struct priv *priv = netdev_priv( dev );
   stats.tx_packets++;
   stats.tx_bytes += skb->len;
   skb->dev = priv->parent;   // передача в родительский (физический) интерфейс
   skb->priority = 1;
   dev_queue_xmit( skb );
   DBG( "tx: injecting frame from %s to %s with length: %u",
        dev->name, skb->dev->name, skb->len );
   return 0;
}

static struct net_device_ops net_device_ops = {
   .ndo_open = open,
   .ndo_stop = stop,
   .ndo_get_stats = get_stats,
   .ndo_start_xmit = start_xmit,
};

// приём фрейма
int pack_parent( struct sk_buff *skb, struct net_device *dev,
                 struct packet_type *pt, struct net_device *odev ) {
   skb->dev = child;          // передача фрейма в виртуальный интерфейс
   stats.rx_packets++;
   stats.rx_bytes += skb->len;
   DBG( "tx: injecting frame from %s to %s with length: %u",
        dev->name, skb->dev->name, skb->len );
   kfree_skb( skb );
   return skb->len;
};

static struct packet_type proto_parent = {
   __constant_htons( ETH_P_ALL ), // перехватывать все пакеты: ETH_P_ARP & ETH_P_IP
   NULL,
   pack_parent,
   (void*)1,
   NULL
};

int __init init( void ) {
   void setup( struct net_device *dev ) { // вложенная функция (GCC)
      int j;
      ether_setup( dev );
      memset( netdev_priv( dev ), 0, sizeof( struct priv ) );
      dev->netdev_ops = &net_device_ops;
      for( j = 0; j < ETH_ALEN; ++j )     // заполнить MAC фиктивным адресом
         dev->dev_addr[ j ] = (char)j;
   }
   int err = 0;
   struct priv *priv;
   char ifstr[ 40 ];
   sprintf( ifstr, "%s%s", ifname, "%d" );
   child = alloc_netdev( sizeof( struct priv ), ifstr, setup );
   if( child == NULL ) {
      ERR( "%s: allocate error", THIS_MODULE->name ); return -ENOMEM;
   }
   priv = netdev_priv( child );
   priv->parent = __dev_get_by_name( &init_net, link ); // родительский интерфейс
   if( !priv->parent ) {
      ERR( "%s: no such net: %s", THIS_MODULE->name, link );
      err = -ENODEV; goto err;
   }
```

```
   if( priv->parent->type != ARPHRD_ETHER && priv->parent->type != ARPHRD_LOOPBACK ) {
      ERR( "%s: illegal net type", THIS_MODULE->name );
      err = -EINVAL; goto err;
   }
   memcpy( child->dev_addr, priv->parent->dev_addr, ETH_ALEN );
   memcpy( child->broadcast, priv->parent->broadcast, ETH_ALEN );
   if( ( err = dev_alloc_name( child, child->name ) ) ) {
      ERR( "%s: allocate name, error %i", THIS_MODULE->name, err );
      err = -EIO; goto err;
   }
   register_netdev( child );         // зарегистрировать новый интерфейс
   proto_parent.dev = priv->parent;
   dev_add_pack( &proto_parent );    // установить обработчик фреймов для родителя
   LOG( "module %s loaded", THIS_MODULE->name );
   LOG( "%s: create link %s", THIS_MODULE->name, child->name );
   return 0;
err:
   free_netdev( child );
   return err;
}

void __exit exit( void ) {
   dev_remove_pack( &proto_parent ); // удалить обработчик фреймов
   unregister_netdev( child );
   free_netdev( child );
   LOG( "module %s unloaded", THIS_MODULE->name );
   LOG( "============================================" );
}

module_init( init );
module_exit( exit );

MODULE_AUTHOR( "Oleg Tsiliuric" );
MODULE_LICENSE( "GPL v2" );
MODULE_VERSION( "3.6" );
```

От рассмотренных уже ранее примеров код отличается только тем, что после регистрации нового сетевого интерфейса (`virt0`) он выполняет вызов `dev_add_pack()`, предварительно установив в структуре `packet_type` поле `dev` на указатель родительского интерфейса: только с этого интерфейса входящий трафик будет перехватываться определённой в структуре функцией `pack_parent()`. Эта функция фиксирует статистику интерфейса и, самое главное, **подменяет** в сокетном буфере указатель родительского интерфейса на виртуальный. Обратная подмена (виртуального на физический) происходит в функции отправки фрейма `start_xmit()`, но это не отличается от того, что мы видели ранее. Вот как это работает:

- на тестируемом компьютере загружаем модуль и конфигурируем его:

```
$ ip address
...
2: eth0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP qlen 1000
    link/ether 08:00:27:52:b9:e0 brd ff:ff:ff:ff:ff:ff
    inet 192.168.1.21/24 brd 192.168.1.255 scope global eth0
    inet6 fe80::a00:27ff:fe52:b9e0/64 scope link
       valid_lft forever preferred_lft forever
3: eth1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP qlen 1000
    link/ether 08:00:27:0f:13:6d brd ff:ff:ff:ff:ff:ff
    inet 192.168.56.102/24 brd 192.168.56.255 scope global eth1
    inet6 fe80::a00:27ff:fe0f:136d/64 scope link
       valid_lft forever preferred_lft forever
$ sudo insmod ./virt.ko link=eth1 debug=1
$ sudo ifconfig virt0 192.168.50.19
```

```
$ sudo ifconfig virt0
virt0     Link encap:Ethernet  HWaddr 08:00:27:0f:13:6d
          inet addr:192.168.50.19  Bcast:192.168.50.255  Mask:255.255.255.0
          inet6 addr: fe80::a00:27ff:fe0f:136d/64 Scope:Link
          UP BROADCAST RUNNING MULTICAST  MTU:1500  Metric:1
          RX packets:0 errors:0 dropped:0 overruns:0 frame:0
          TX packets:46 errors:0 dropped:0 overruns:0 carrier:0
          collisions:0 txqueuelen:1000
          RX bytes:0 (0.0 B)  TX bytes:8373 (8.1 KiB)
```

(показана статистика с нулевым числом принятых байт на интерфейсе).

- на тестирующем компьютере создаём алиасный IP для тестируемой подсети (192.168.50.0/24) и можем осуществлять трафик на созданный интерфейс:

```
$ sudo ifconfig vboxnet0:1 192.168.50.1
$ ping 192.168.50.19
PING 192.168.50.19 (192.168.50.19) 56(84) bytes of data.
64 bytes from 192.168.50.19: icmp_req=1 ttl=64 time=0.627 ms
64 bytes from 192.168.50.19: icmp_req=2 ttl=64 time=0.305 ms
64 bytes from 192.168.50.19: icmp_req=3 ttl=64 time=0.326 ms
^C
--- 192.168.50.19 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2000ms
rtt min/avg/max/mdev = 0.305/0.419/0.627/0.148 ms
```

- на этом же (тестирующем) компьютере (ответной стороне) очень содержательно наблюдать трафик (в отдельном терминале), фиксируемый `tcpdump`:

```
$ sudo tcpdump -i vboxnet0
tcpdump: verbose output suppressed, use -v or -vv for full protocol decode
listening on vboxnet0, link-type EN10MB (Ethernet), capture size 65535 bytes
...
18:41:01.740607 ARP, Request who-has 192.168.50.19 tell 192.168.50.1, length 28
18:41:01.741104 ARP, Reply 192.168.50.19 is-at 08:00:27:0f:13:6d (oui Unknown), length 28
18:41:01.741116 IP 192.168.50.1 > 192.168.50.19: ICMP echo request, id 8402, seq 1, length 64
18:41:01.741211 IP 192.168.50.19 > 192.168.50.1: ICMP echo reply, id 8402, seq 1, length 64
18:41:02.741164 IP 192.168.50.1 > 192.168.50.19: ICMP echo request, id 8402, seq 2, length 64
18:41:02.741451 IP 192.168.50.19 > 192.168.50.1: ICMP echo reply, id 8402, seq 2, length 64
18:41:03.741163 IP 192.168.50.1 > 192.168.50.19: ICMP echo request, id 8402, seq 3, length 64
18:41:03.741471 IP 192.168.50.19 > 192.168.50.1: ICMP echo reply, id 8402, seq 3, length 64
18:41:06.747701 ARP, Request who-has 192.168.50.1 tell 192.168.50.19, length 28
18:41:06.747715 ARP, Reply 192.168.50.1 is-at 0a:00:27:00:00:00 (oui Unknown), length 28
```

Теперь коротко, в два слова, о том, как сделать полновесный виртуальный интерфейс, работающий только со своим трафиком, и не нарушающий работу родительского интерфейса (то, что делает полная версия модуля в архиве). Для этого необходимо:

- объявить **два** раздельных обработчика протоколов (для протоколов разрешения имён ARP и собственно для протокола IP):

```
// обработчик фреймов ETH_P_ARP
int arp_pack_rcv( struct sk_buff *skb, struct net_device *dev,
                  struct packet_type *pt, struct net_device *odev ) {
   ...
   return skb->len;
}

static struct packet_type arp_proto = {
   __constant_htons( ETH_P_ARP ),
   NULL,
   arp_pack_rcv,  // фильтр пртокола ETH_P_ARP
   (void*)1,
```

```
   NULL
};

// обработчик фреймов ETH_P_IP
int ip4_pack_rcv( struct sk_buff *skb, struct net_device *dev,
                  struct packet_type *pt, struct net_device *odev ) {
   ...
   return skb->len;
}

static struct packet_type ip4_proto = {
   __constant_htons( ETH_P_IP ),
   NULL,
   ip4_pack_rcv,    // фильтр пртокола ETH_P_IP
   (void*)1,
   NULL
};
```

- и оба их зарегистрировать в функции инициализации модуля:

```
   arp_proto.dev = ip4_proto.dev = priv->parent; // перехват только с родительского интерфейса
   dev_add_pack( &arp_proto );
   dev_add_pack( &ip4_proto );
```

- каждый из обработчиков должен осуществлять **подмену** интерфейса только для тех фреймов, IP получателя которых совпадает с IP интерфейса ...

- а два раздельных обработчика удобны тем, что заголовки фреймов ARP и IP имеют совершенно разный формат, и выделять IP назначения в них приходится по-разному (весь полный код показан в архиве примера).

Используя такой полновесный модуль, можно открыть к хосту, например, одновременно две параллельные сессии SSH на разные интерфейсы, родительский и виртуальный (использующие разные IP), которые будут в параллель реально использовать единый общий физический интерфейс:

```
$ ssh olej@192.168.50.17
olej@192.168.50.17's password:
Last login: Mon Jul 16 15:52:16 2012 from 192.168.1.9
...
$ ssh olej@192.168.56.101
olej@192.168.56.101's password:
Last login: Mon Jul 16 17:29:57 2012 from 192.168.50.1
...
$ who
olej     tty1         2012-07-16 09:29 (:0)
olej     pts/0        2012-07-16 09:33 (:0.0)
olej     pts/1        2012-07-16 12:22 (192.168.1.9)
olej     pts/4        2012-07-16 15:52 (192.168.1.9)
olej     pts/6        2012-07-16 17:29 (192.168.50.1)
olej     pts/7        2012-07-16 17:31 (192.168.56.1)
```

Последняя показанная команда (`who`) выполняется уже в сессии SSH, то есть на том самом удалённом хосте, к которому и фиксируется командой два **независимых** подключения из двух различных подсетей (последние две строки вывода), которые на самом деле представляют один хост.

Протокол транспортного уровня

На этом уровне (L4) обеспечивается обработка таких протоколов, как: UDP, TCP, SCTP, DCCP ... их число возрастает. Протоколы транспортного уровня (протоколы IP) описаны в `<linux/in.h>` :

```
/* Standard well-defined IP protocols.  */
enum {
  IPPROTO_IP =     0,   /* Dummy protocol for TCP               */
```

```
  IPPROTO_ICMP =   1,   /* Internet Control Message Protocol    */
  IPPROTO_IGMP =   2,   /* Internet Group Management Protocol   */
...
  IPPROTO_TCP =    6,   /* Transmission Control Protocol        */
...
  IPPROTO_UDP =   17,   /* User Datagram Protocol               */
...
  IPPROTO_SCTP = 132,   /* Stream Control Transport Protocol    */
...
  IPPROTO_RAW  = 255,   /* Raw IP packets                       */
}
```

Для установки обработчика протоколов транспортного уровня существует API `<net/protocol.h>` :

```
struct net_protocol {                 // This is used to register protocols
   int  (*handler)( struct sk_buff *skb );
   void (*err_handler)( struct sk_buff *skb, u32 info );
   int  (*gso_send_check)( struct sk_buff *skb );
   struct sk_buff *(*gso_segment)( struct sk_buff *skb, int features );
   struct sk_buff **(*gro_receive)( struct sk_buff **head, struct sk_buff *skb );
   int (*gro_complete)( struct sk_buff *skb );
   unsigned int no_policy:1,
                netns_ok:1;
};
int inet_add_protocol( const struct net_protocol *prot, unsigned char num );
int inet_del_protocol( const struct net_protocol *prot, unsigned char num );
```

Здесь 2-й параметр вызова функций (`num`) как раз и есть константа набора констант вида `IPPROTO_*`.

Эта схема в общих чертах напоминает то, как это же делалось на сетевом уровне: каждый пакет проходит через функцию-фильтр, где мы можем анализировать или изменять отдельные поля сокетного буфера, отображающего пакет.

Пример модуля, устанавливающего протокол:

trn proto.c :

```
#include <linux/module.h>
#include <linux/init.h>
#include <net/protocol.h>

int test_proto_rcv( struct sk_buff *skb ) {
   printk( KERN_INFO "Packet received with length: %u\n", skb->len );
   return skb->len;
};

static struct net_protocol test_proto = {
   .handler = test_proto_rcv,
   .err_handler = 0,
   .no_policy = 0,
};

//#define PROTO IPPROTO_ICMP
//#define PROTO IPPROTO_TCP
#define PROTO IPPROTO_RAW
static int __init my_init( void ) {
   int ret;
   if( ( ret = inet_add_protocol( &test_proto, PROTO ) ) < 0 ) {
      printk( KERN_INFO "proto init: can't add protocol\n");
      return ret;
   };
   printk( KERN_INFO "proto module loaded\n" );
   return 0;
```

```
}

static void __exit my_exit( void ) {
   inet_del_protocol( &test_proto, PROTO );
   printk( KERN_INFO "proto module unloaded\n" );
}

module_init( my_init );
module_exit( my_exit );

MODULE_AUTHOR( "Oleg Tsiliuric" );
MODULE_LICENSE( "GPL v2" );
```

Вот как будет выглядеть работа модуля для протокола `IPPROTO_RAW`:

```
$ sudo insmod trn_proto.ko
$ lsmod | head  -n2
Module                  Size  Used by
trn_proto               780  0
$ cat /proc/modules | grep proto
trn_proto 780 0 - Live 0xf9a26000
$ ls -R /sys/module/trn_proto
/sys/module/trn_proto:
holders  initstate  notes  refcnt  sections  srcversion
...
$ sudo rmmod trn_proto
$ dmesg | tail -n60 | grep -v ^audit
proto module loaded
proto module unloaded
```

Но если вы попытаетесь установить (добавить!) обработчик для уже **обрабатываемого** (установленного) протокола (например, `IPPROTO_TCP`), то получите ошибку:

```
$ sudo insmod trn_proto.ko
insmod: error inserting 'trn_proto.ko': -1 Operation not permitted
$ dmesg | tail -n60 | grep -v ^audit
proto init: can't add protocol
$ lsmod | grep proto
$
```

Здесь возникает уже названная раньше сложность:

– Если вы планируете отрабатывать новый (или не использующийся в системе) протокол, то для его тестирования в системе нет инструментов, и прежде нужно подумать о том, чтобы создать тестовые приложения прикладного уровня.

– Если пытаться моделировать работу нового протокола под видом уже существующего (например, `IPPROTO_UDP`), то вам прежде понадобится удалить существующий обработчик, чем можно радикально нарушить работоспособность системы (например, для `IPPROTO_UDP` разрушить систему разрешения доменных имён DNS).

Источники использованной информации

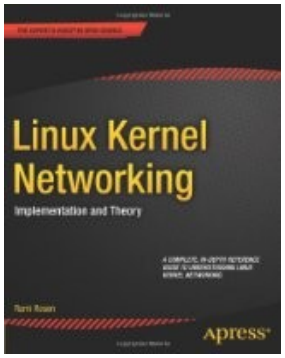

[1] **Rami Rosen, «Linux Kernel Networking: Implementation and Theory»**, New York, «Apress», 2014, ISBN: 978-1-4302-6196-4, p. 612
http://www.foxebook.net/linux-kernel-networking-implementation-and-theory/
(там же книгу можно свободно скачать)

[2] **С. Сэтчэлл, Х. Клиффорд, «Linux IP Stacks в комментариях»**, К.:, «ДиаСофт», 2001, ISBN: 966-7393-83-6, 288 стр.
http://www.books.ru/books/linux-ip-stacks-v-kommentariyakh-11155/?show=1

[3] **«Linux Network Configuration»** :
http://www.yolinux.com/TUTORIALS/LinuxTutorialNetworking.html#CONFIGFILES

[4] Олег Цилюрик, статьи в редакциях разных лет (различающихся):
- «Сеть IP - когда писать программы лень»
http://smartbox.jinr.ru/qnx.org.ru/article10.html, 2002
http://rus-linux.net/MyLDP/algol/Simple-TCP-programming.html, 2012
- «Сервер TCP / IP … много серверов хороших и разных»
http://www.cta.ru/online/online_progr-nets.htm — журнал «СТА» («Современные Технологии Автоматизации»), Москва, 2003
http://rus-linux.net/MyLDP/algol/analiz-variantov-realizacii-TCP-IP-servera-01.html, 2012

В книге: **Д.Алексеев, Е.Видревич, А.Волков, Е.Горошко, М.Горчак, Р.Жавнис, Д.Сошин, О.Цилюрик, А.Чиликин, «Практика работы с QNX»** - М.: «КомБук», 2004, 432 стр., ISBN: 5-94740-009-X
http://www.books.ru/books/praktika-raboty-s-qnx-179608/?show=1

Книгу можно скачать здесь: http://9knig.ru/os/19431-praktika-raboty-s-qnx..html

[5] LXR (Linux Cross-Referencer) ресурсы перекрёстного анализа **исходных кодов ядра** Linux:
http://lxr.free-electrons.com/source/
http://lxr.linux.no/
http://lxr.missinglinkelectronics.com/linux
http://lxr.oss.org.cn/

6. За границами Интернет

Классический Интернет представляет собой мощную организованную систему. Но некоторые пользователи и разработчики считают что он заорганизован, управляемый разнообразными комитетами и комиссиями, с ограничениями которые начинают накладывать государственные законодательные органы в рамках своих территориальных компетенций.

Обширный управленческий аппарат, помимо всего прочего, несёт в себе потенциал мелких но частых сбоев в работе за счёт несогласованности и ошибочности действий.

Но развивается целый ряд альтернативных проектов, использующих только его транспортный механизм TCP/IP, но не требующих его централизованного управления и его управляющих органов (комиссий и комитетов). Они функционируют **над** транспортным механизмом сети TCP/IP, используя этот транспортный механизм Интернет, но выходя где-то за рамки и соглашения Интернет. Поэтому я в этой части назвал их условно «надсистемы».

Альтернативные проекты апробируют модели «самонастраивающихся» механизмов конфигурирования и функционирования сети.

Альтернативные проекты носят характер экспериментальных разработок, но они концентрируются вокруг совсем не такого большого числа направлений. Поэтому их интересно и полезно знать, хотя бы в форме отдельных конкретных реализаций. При множестве экспериментальных проектов, которые постоянно возникают новые и угасают существующие, их тематики группируются вокруг относительно немногочисленных целей:

- Охрана приватности. Такие проекты направлены не только на защищённость самого содержимого сетевых обменов, но и на анонимизацию получателя, целевых ресурсов, и сокрытие направлений и самого факта осуществления трафика. Эту деятельность некоторые рассматривают как расширение сферы охранения персональной информации.
- Децентрализация. За долгие годы развития Интернет сложилась развитая инфраструктура учреждений, организаций и комитетов, обеспечивающих деятельность сети: провайдеры, хостеры, регистраторы… Они обеспечивают слаженное функционирование разных сторон сети, но, иногда, и вносят избыточную заорганизованность. Кроме того, их деятельность коммерческая и часто услуги довольно дорого стоят потребителям. В этой части экспериментальные проекты пытаются исключить избыточные регламентирующие звенья.
- Живучесть. Во многом, из-за определённой централизованности организации Интернет, при нарушении согласованности действий различных организующих сторон, возможны перебои работы сети, или даже полное нарушение её работоспособности, на отдельных территориальных, государственных, ведомственных или других сегментах сети. Эксперименты в части адаптивных изменений топологии сети и направлены на уменьшение подобных рисков.
- Упрощение настроек. Много десятилетнее постоянное усложнение фрагментов сети (локальных сетей в составе Интернет) привело к большой сложности их конфигураций, и требует на сегодня даже в средней руки организациях содержать сетевых администраторов как отдельную профессиональную группу. Экспериментальные проекты пытаются двигаться в строну самоорганизующихся архитектур, которые гибко подключаются к существующим участникам сети, выбирают оптимальные маршруты и самонастраиваются внутри сети.

Далее рассмотрены выборочно только несколько альтернативных направлений развития, для того, чтобы составить поверхностное представление о **тенденциях** движения. Проекты для рассмотрения выбраны достаточно произвольно, но то что показано, кроме других критериев их отбора — это не уровень сырых экспериментов, а вполне работоспособные на сегодня реализации

TOR

Проект TOR (**T**he **O**nion **R**outer) — свободное и открытое программное обеспечениедля реализации второго (V2) и третьего (V3) поколения так называемой луковичной маршрутизации: ваши данные — это сердцевина луковицы, а их защита — слои вокруг. Это такая адаптивная система прокси-серверов, которая позволяющая устанавливать анонимное сетевое соединение, защищённое от прослушивания.

Разработка системы началась в 1995 году. К началу 2000-х исходный код был опубликован свободной лицензией. Написана преимущественно на языке C. В октябре 2002 года впервые была

развёрнута сеть маршрутизаторов, которая к концу 2003 года насчитывала около десяти сетевых узлов. По состоянию на 2016 год, по оценкам, число участников сети (включая ботов), превысило 2 миллиона.

Для анонимизации Tor, также как прокси и VPN, пропускает трафик через промежуточные серверы. Но Только в случае с Tor их не один, а три, и называется они узлами. Каждый пакет данных, передаваемый системой узлов TOR, проходит через три различных — узла, которые выбираются случайным образом в начале сеанса, и могут быть изменены по ходу прохождения сеанса. Перед отправкой пакет последовательно шифруется тремя ключами: сначала — для третьего узла, потом — для второго и в конце — для первого. Когда первый узел получает пакет, он расшифровывает «верхний» слой шифра (аналогия с тем, как чистят луковицу) и узнаёт, куда отправить пакет дальше. Второй и третий сервер поступают также. После 3-го прокси-сервера пакет поступает получателю в открытом виде.

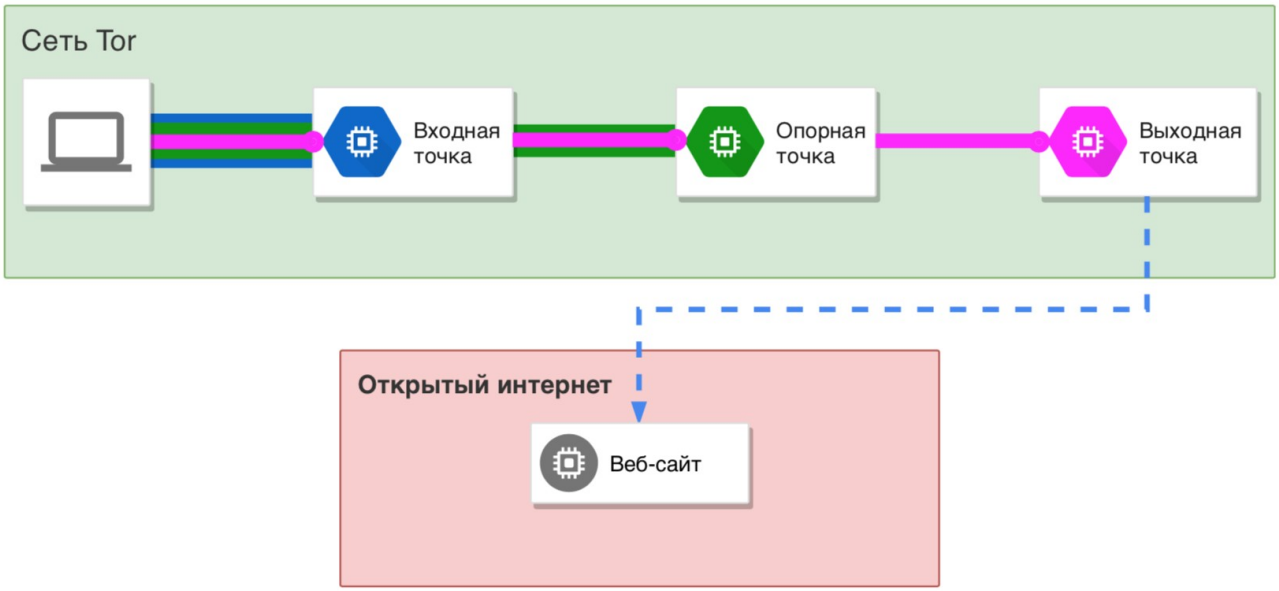

TOR как прокси для всей сети

Для большинства конечных пользователей проект TOR представляет TOR-браузер, который производится на базе FireFox как отдельное изделие с 2008 года. Но нас интересует техническая сторона вопроса, а именно TOR как SOCKS-прокси:

```
$ aptitude show tor
Пакет: tor
Версия: 0.4.6.10-1
Новый: да
Состояние: установлен
Установлен автоматически: да
Приоритет: необязательный
Раздел: universe/net
Сопровождающий: Ubuntu Developers <ubuntu-devel-discuss@lists.ubuntu.com>
Архитектура: amd64
Размер в распакованном виде: 5.400 k
Зависит: libc6 (>= 2.34), libcap2 (>= 1:2.10), libevent-2.1-7 (>= 2.1.8-stable), liblzma5 (>=
5.1.1alpha+20120614), libseccomp2 (>= 0.0.0~20120605), libssl3 (>= 3.0.0~~alpha1), libsystemd0,
libzstd1 (>= 1.4.0), zlib1g (>= 1:1.1.4), adduser, lsb-base
Рекомендует: logrotate, tor-geoipdb, torsocks
Предлагает: mixmaster, torbrowser-launcher, socat, apparmor-utils, nyx, obfs4proxy
Конфликтует: libssl0.9.8 (< 0.9.8g-9)
Описание: анонимизирующая сеть работающая поверх TCP
 Tor — система анонимного взаимодействия с установкой соединений и малым временем задержки.

 Пользователи выбирают начало пути по сети узлов, и согласовывают «виртуальные цепи» через сеть, в
которых каждому узлу известен предыдущий и следующий узел, а все остальные — не известны. Трафик,
передаваемый по цепи, расшифровывается симметричным ключом в каждом узле, из которого получается
```

информация о следующем узле.

Фактически, Tor позволяет создавать распределённую сеть ретранслирующих узлов. Пользователи пропускают свои TCP-данные (веб-трафик, ftp, ssh и т. д.) через цепь таких узлов-ретрансляторов, так что получателям, наблюдателям и самим маршрутизаторам становится трудно отследить источник и цель потока данных.

Этот пакет по умолчанию включает только клиентскую часть, но его можно настроить также для работы в качестве узла передачи и/или скрытого сервера.

Клиентские приложения могут использовать сеть Tor путём подключения к локальному прокси-серверу SOCKS. Если само приложение не имеет поддержки SOCKS, вы можете использовать клиент socks, такой как torsocks.

Обратите внимание, что Tor не занимается очисткой протоколов. Это значит, что существует опасность воздействия на протоколы приложений и связанные с ними программы, так что они выдадут информацию об источнике. Для решения этой проблемы Tor полагается на Torbutton и аналогичные очистители протоколов. Самый простой вариант работы с веб-сайтами через Tor - Tor Browser Bundle, самодостаточный пакет, состоящий из статической сборки Tor, Torbutton и Firefox с изменениями, устраняющими различные проблемы, связанные с защитой персональных данных.

Домашняя страница: https://www.torproject.org/

Установка пакета:

```
$ sudo apt install tor
Чтение списков пакетов… Готово
Построение дерева зависимостей
...
ureadahead will be reprofiled on next reboot
Обрабатываются триггеры для systemd (237-3ubuntu10.41) …
```

Обращаем внимание на последнюю строку, упоминающую systemd — это показывает, что стек TOR устанавливается как сервис. Сразу после установки:

```
$ systemctl status tor
● tor.service - Anonymizing overlay network for TCP (multi-instance-master)
     Loaded: loaded (/lib/systemd/system/tor.service; enabled; vendor preset: enabled)
     Active: active (exited) since Thu 2023-04-27 11:58:14 EEST; 5 days ago
   Main PID: 545 (code=exited, status=0/SUCCESS)
      Tasks: 0 (limit: 18948)
     Memory: 0B
        CPU: 0
     CGroup: /system.slice/tor.service

апр 27 11:58:14 nvme systemd[1]: Starting Anonymizing overlay network for TCP (multi-instance-
master)...
апр 27 11:58:14 nvme systemd[1]: Finished Anonymizing overlay network for TCP (multi-instance-
master).
$ ps -A | grep tor
    623 ?        00:00:16 tor
```

И вот SOCKS прокси, через котрый работают приложения TOR, прокси устанавливается на TCP порт 9050 (заметим, что установка TOR-браузера устанавливает прокси независимо на порт 9060, таким образом они могут работать независимо не вредя друг другу):

```
$ netstat -l -t | grep 9050
tcp        0      0 localhost:9050          0.0.0.0:*               LISTEN
```

Проверить можем простейшим образом (1-я строка — это прямой запрос, IP адрес который динамически выделяет мой провайдер, а следующий — через SOCKS TOR):

```
$ curl check-host.net/ip
193.28.177.119
$ curl -x socks4://127.0.0.1:9050 check-host.net/ip
107.189.31.134
$ whois 107.189.31.134 | grep -i Country:
```

```
Country:        US
Country:        LU
```

И я оказываюсь где-то там … в Луизиане, кажется… Но через некоторое время, без всякого вмешательства с нашей стороны, с того же компьютера, это может стать … Германия:

```
$ curl -x socks4://127.0.0.1:9050 check-host.net/ip
212.21.66.6
$ whois 212.21.66.6 | grep -i Country:
country:        DE
country:        DE
```

Это TOR стек самопроизвольно сменил цепочку 3-х узлов (3-й из которых мы и видим в команде). Это ещё одна особенность TOR.

Но совершенно не обязательно дожидаться пока стек TOR сам сменит цепочку узлов через которые вы используете сеть TOR — достаточно послать сервису TOR сигнал HUP чтобы он принудительно «подбросил» новую цепочку узлов. Путешествуем со своим хостом по всему миру:

```
$ sudo killall -HUP tor
$ curl -x socks4://127.0.0.1:9050 check-host.net/ip && echo
178.218.144.99
$ whois 178.218.144.99 | grep  -i Country:
country:        IT
$ sudo killall -HUP tor
$ curl -x socks4://127.0.0.1:9050 check-host.net/ip && echo
192.42.116.216
$ whois 192.42.116.216 | grep  -i Country:
Country:        NL
country:        NL
country:        NL
$ sudo killall -HUP tor
$ curl -x socks4://127.0.0.1:9050 check-host.net/ip && echo
103.251.167.10
$ whois 103.251.167.10 | grep  -i Country:
country:        ZZ
country:        ZZ
```

Мы проверили и продемонстрировали работу TOR SOCKS прокси на примере простейшей, даже тривиальной утилиты `curl`. Но точно таким же способом (используя локально работающий SOCKS прокси) вы можете организовать работу через сеть анонимизации TOR практически **любого** приложения вашего компьютера (о технике использования прокси было рассказано раньше, но она в полной мере относится и к этому случаю).

Mesh-сети

Mesh-сети, которые до того неспешно обсуждались в академических кругах, привлекли к себе пристальное внимание после 2013-2014 годов, когда они неожиданно массово были использованы участниками протестных настроений, «цветных революций», в массовых уличных акциях. Из новостных лент тех дней:

В Гонконге, участники "революции зонтиков" используют программу FireChat, что позволяет им быстро установить связь друг с другом по сети, поддерживаемой устройствами отдельных пользователей (не внешнего оборудования) - mesh networking. … Бесплатное приложение FireChat для устройств на Android и iOS позволяет людям общаться между собой даже там, где не работает сотовая связь. Мессенджер устанавливает прямое соединение между двумя телефонами на расстоянии до 70 м. Но при большом скоплении подключенных к сети пользователей FireChat радиус действия мессенджера может быть намного больше: в пределах стадиона, парка или везде, где минимальное расстояние между двумя пользователями меньше 70 метров.

Ячеистая топология (mesh-сеть) — это распределенная, одноранговая, ячеистая сеть. Каждый узел в такой сети обладает такими же полномочиями как и все остальные, грубо говоря — все узлы в сети равны. Сети бывают самоорганизующиеся и настраиваемые, первый тип сетей при включении оборудования, которое его поддерживает, автоматически подключаются к существующим участникам, выбирают оптимальные маршруты и самонастраиваются внутри сети.

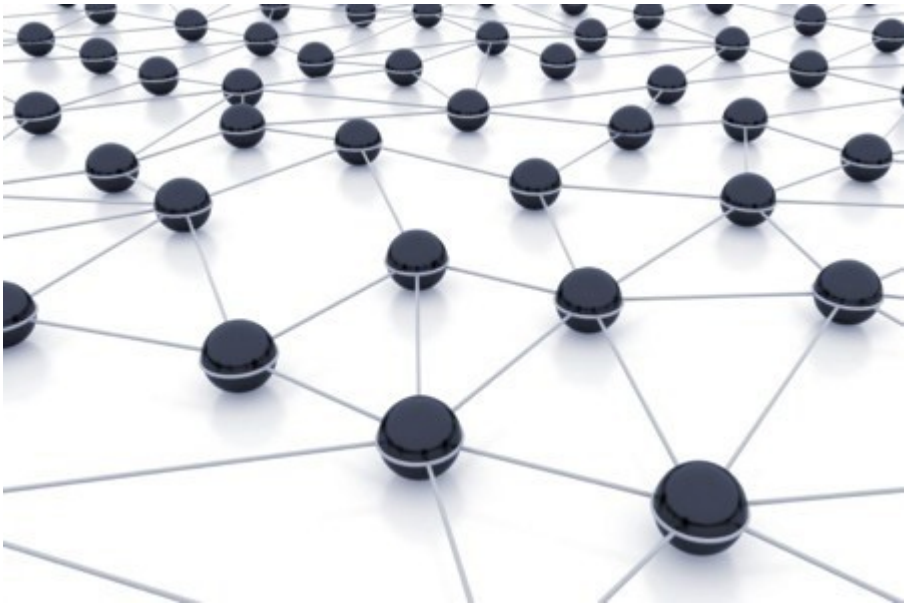

Такая организация сети, является достаточно сложной в реализации и, если она не является самоорганизующиеся, то и в настройке, однако, как предполагается, при такой топологии реализуется максимально высокая отказоустойчивость сети.

Первоначально, именно сеть мобильных, перемещающихся, гаджетов с беспроводной связью (WiFi) привлекла внимание к этой идее. Но позже оказалось что она отлично расширяется на ячеистую сеть узлов любой топологии, независимо от природы самих узлов, в том числе и на уже существующую транспортную сеть Интернет, в том числе и стационарных хостов в его составе.

Основной принцип, обеспечивающий высокую живучесть такой сети, состоит в её самоконфигурируемости: при потере отдельных узлов, или даже целых значительных фрагментов сети, сеть динамически (на ходу) меняет свою топологию, и изменяются траектории распространения IP пактов даже в пределах одного сеанса связи. Большое количество связей обеспечивает широкий выбор маршрута трафика внутри сети — следовательно, обрыв одного соединения не нарушит функционирования сети в целом. (В какой-то мере, это, не по существу но качественно, напоминает переход от стационарных сетей коммутации каналов в проводной телефонии к той же коммутации каналов, но уже в сети мобильных сотовых станций).

В качестве иллюстрации конкретной реализации mesh-сети, но уровня проекта уже пригодного для практического применения, мы рассмотрим частный пример IPv6 сети `Yggdrasil`. Помимо деталей конкретной сети это даёт возможность вообще взглянуть на особенности ячеистых сетей.

Сеть Yggdrasil

Yggdrasil — это пиринговая сеть, использующая IPv6 адресацию, весь трафик в которой шифруется несимметричным кодированием (с приватными и публичными ключами). (Пиринговая — это ещё одно название ячеистых одноранговых сетей, в которых каждый хост связывается с несколькими известными ему пирами, соседями по сети, через которые хост организует свой адаптивный роутинг в сеть.)

Пара ключей шифрования (приватный и публичный) устанавливаются для хоста либо автоматически в момент инсталляции, либо могут быть изменены пользователем ручной записью их значений в конфигурационный файл. Адрес IPv6 хоста формируется как функция от этой пары ключей, и никем глобально не регламентируется.

Проект Yggdrasil свободный и с открытыми исходными кодами, написан и развивается на языке Go (что является его дополнительным достоинством). Некоторые дополнительные сервисные утилиты к нему написаны сообществом пользователей на C и Python, и будут показаны далее. Установку системы можно произвести, таким образом, сборкой из исходных кодов, но ещё проще установить из .deb пакетов Linux, предоставляемых в каждом релизе для нескольких аппаратных архитектур вместе с исходными кодами (все ссылки на ресурсы показаны в конце этой части). Мы рассмотрим весь процесс для минимальной архитектуры ARM (для x86 всё то же самое, и ещё даже проще):

```
$ inxi -Mxxx
Machine:   Type: ARM Device System: Raspberry Pi 2 Model B Rev 1.1 details: BCM2835 rev: a21041
           serial: 00000000f57e2ca8
```

```
$ inxi -Sxxx
System:    Host: raspberrypi Kernel: 5.15.84-v7+ armv7l bits: 32 compiler: gcc v: 10.2.1
           Desktop: Openbox 3.6.1
           info: lxpanel dm: LightDM 1.26.0 Distro: Raspbian GNU/Linux 11 (bullseye)
```

Даже такой, более чем скромной (игрушечной), архитектуры достаточно будет для полноценного использования как роутер сети Yggdrasil:

```
$ wget https://github.com/yggdrasil-network/yggdrasil-go/releases/download/v0.4.7/yggdrasil-0.4.7-armhf.deb
--2023-04-11 14:34:28--  https://github.com/yggdrasil-network/yggdrasil-go/releases/download/v0.4.7/yggdrasil-0.4.7-armhf.deb
Распознаётся github.com (github.com)… 140.82.121.4
Подключение к github.com (github.com)|140.82.121.4|:443... соединение установлено.
...
$ ls -l yggdrasil-0.4.7-armhf.deb
-rw-r--r-- 1 olej olej 3431402 ноя 20 23:26 yggdrasil-0.4.7-armhf.deb
...
```

Установка:

```
$ sudo dpkg -i yggdrasil-0.4.7-armhf.deb
Выбор ранее не выбранного пакета yggdrasil.
(Чтение базы данных … на данный момент установлен 269631 файл и каталог.)
Подготовка к распаковке yggdrasil-0.4.7-armhf.deb …
Распаковывается yggdrasil (0.4.7) …
Настраивается пакет yggdrasil (0.4.7) …
Generating initial configuration file /etc/yggdrasil.conf
Please familiarise yourself with this file before starting Yggdrasil
$ dpkg -c yggdrasil-0.4.7-armhf.deb
-rwxr-xr-x runner/docker 5308416 2022-11-20 23:22 usr/bin/yggdrasil
-rwxr-xr-x runner/docker 3145728 2022-11-20 23:22 usr/bin/yggdrasilctl
-rw-r--r-- runner/docker     511 2022-11-20 23:22 etc/systemd/system/yggdrasil.service
-rw-r--r-- runner/docker     356 2022-11-20 23:22 etc/systemd/system/yggdrasil-default-config.service
```

Вот, собственно, и всё что нужно для того, чтобы получить работающую Yggdrasil сеть, как видно из состава устанавливаемого, устанавливается сервис для запуска средствами systemd, утилиты `yggdrasil` и `yggdrasilctl`, и генерируется шаблон который будет использоваться в качестве конфигурационного файла `/etc/yggdrasil.conf`. Прежде чем запускать сервис, нам нужно будет подготовить этот конфигурационный файл. Как минимум, первое, что мы должны сделать перед первичным запуском — это вписать адреса нескольких пиров (соседей) с которыми будет взаимодействовать хост, эти адреса вписывается в секцию Peers (как и откуда берутся эти адреса и как выбираются пиры мы поговорим позже):

```
# grep -v '^$\|#' /etc/yggdrasil/yggdrasil.conf | grep " Peers:" -A7
  Peers: [
     tcp://193.111.114.28:8080
     tls://193.111.114.28:1443
     tls://pl1.servers.devices.cwinfo.net:11129
     tcp://195.123.245.146:7743
     tls://yggdrasil.su:62586
     tcp://yggdrasil.su:62486
  ]
```

Как уже было сказано, уникальная пара ключей несимметричного шифрования генерируется при инсталляции пакета, они записываются в конфигурационный файл, именно они определяют сгенерированный IPv6 адрес хоста (и пока мы не будем отвлекаться на значения этих ключей):

```
# grep -v '^$\|#' /etc/yggdrasil/yggdrasil.conf | grep Key:
  PublicKey: 3cb7c934a4852779885762bb59781f9f54d771206460ca0d1c9f72311a7729f6
  PrivateKey: fa9f8209f5fe184a4632513676eef8e3d0b7ee798af11cb37d7ee8873eef37883cb7c934a4852779885762bb59781f9f54d771206460ca0d1c9f72311a7729f6
```

Всё! В этой позиции мы можем запустить, если ещё, скажем, и не оптимизированную, но уже полноценно работающую пиринговую сеть Yggdrasil:

```
# systemctl status yggdrasil
● yggdrasil.service - yggdrasil
     Loaded: loaded (/lib/systemd/system/yggdrasil.service; disabled; vendor preset: enabled)
     Active: active (running) since Tue 2023-03-28 23:54:35 EEST; 19s ago
    Process: 43199 ExecStartPre=/sbin/modprobe tun (code=exited, status=0/SUCCESS)
   Main PID: 43200 (yggdrasil)
      Tasks: 16 (limit: 115786)
     Memory: 6.1M
        CPU: 93ms
     CGroup: /system.slice/yggdrasil.service
             └─43200 /usr/sbin/yggdrasil -useconffile /etc/yggdrasil/yggdrasil.conf

map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Interface MTU: 53049
map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Your public key is
3cb7c934a4852779885762bb59781f9f54d771206460ca0d1c9f72311a7729f6
map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Your IPv6 address is
202:1a41:b65a:dbd6:c433:bd44:ea25:343f
map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Your IPv6 subnet is
302:1a41:b65a:dbd6::/64
map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Connected TCP:
203:63fc:667d:b16c:8e78:a899:8d54:a5e4@193.111.114.28, source 192.168.1.14
map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Connected TLS:
203:63fc:667d:b16c:8e78:a899:8d54:a5e4@193.111.114.28, source 192.168.1.14
map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Connected TCP:
202:db60::9ce0:a73d:7498:d7ae@195.123.245.146, source 192.168.1.14
map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Connected TLS:
200:4ac1:2516:a78:b43e:51e1:ab90:e2a2@54.37.137.221, source 192.168.1.14
map 28 23:54:35 R420 yggdrasil[43200]: 2023/03/28 23:54:35 Connected TCP:
218:71e5:78e4:8989:b71:db7f:7bf1:f1e1@94.130.176.250, source 192.168.1.14
map 28 23:54:36 R420 yggdrasil[43200]: 2023/03/28 23:54:36 Connected TLS:
218:71e5:78e4:8989:b71:db7f:7bf1:f1e1@94.130.176.250, source 192.168.1.14
```

В сообщениях старта сервиса нам уже указан адрес IPv6 который сгенерирован из пары ключей для этого хоста: 202:1a41:b65a:dbd6:c433:bd44:ea25:343f и адрес нашей подсети: 302:1a41:b65a:dbd6::/64. В нашей системе появится новый сетевой интерфейс `tun0` с соответствующими параметрами:

```
$ ip a s dev tun0
4: tun0: <POINTOPOINT,MULTICAST,NOARP,UP,LOWER_UP> mtu 53049 qdisc fq_codel state UNKNOWN group
default qlen 500
    link/none
    inet6 202:1a41:b65a:dbd6:c433:bd44:ea25:343f/7 scope global
       valid_lft forever preferred_lft forever
    inet6 fe80::4268:4330:6890:e026/64 scope link stable-privacy
       valid_lft forever preferred_lft forever
```

Теперь мы можем оперировать с новым интерфейсом IPv6 привычными сетевыми утилитами:

```
$ host howto.ygg.lib
howto.ygg.lib has IPv6 address 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c
$ ping -c5 -6 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c
PING 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c(222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c) 56 data bytes
64 bytes from 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c: icmp_seq=1 ttl=64 time=1310 ms
64 bytes from 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c: icmp_seq=2 ttl=64 time=387 ms
64 bytes from 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c: icmp_seq=3 ttl=64 time=175 ms
64 bytes from 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c: icmp_seq=4 ttl=64 time=173 ms
64 bytes from 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c: icmp_seq=5 ttl=64 time=228 ms

--- 222:a8e4:50cd:55c:788e:b0a5:4e2f:a92c ping statistics ---
5 packets transmitted, 5 received, 0% packet loss, time 4024ms
rtt min/avg/max/mdev = 172.586/454.564/1310.016/434.823 ms, pipe 2
```

К этому месту мы же имеем полновесный хост сети Yggdrasil со всеми возможностями этой сети: IPv6 адресация со сплошным шифрованием трафика внутри сети. Всё дальнейшее описание будет касаться только **оптимизации** функционирования хоста, но никак не его работоспособности — работоспособность мы уже обеспечили. Обратите внимание, что нам не пришлось заниматься трудоёмкими настройками этой сети: маршрутизация и другие параметры… И сколько бы велик ни был размер нашей локальной сети, работу которой мы захотим распространить на пиринговую сеть, нам не придётся заниматься её администрированием.

Внимание: Сразу внесём ясность, что Yggdrasil использует IPv6 адресацию в диапазоне 0200::/7, который не рекомендуется IETF к использованию с 2004 года. Таким образом этот диапазон не вызовет никаких конфликтов с IPv6 адресами, распределяемых для Интернет IANA. Но в Интернет не будут маршрутизироваться адреса Yggdrasil, так же как и Yggdrasil не маршрутизирует адреса не из своего диапазона. В этом легко убедится в вашей сети для которой провайдер не предоставляет IPv6 маршрутизацию: трафик прозрачно идёт, как в примере выше, на howto.ygg.lib — адрес Yggdrasil, но вот противоположный пример:

```
$ host ya.ru
ya.ru has address 5.255.255.242
ya.ru has address 77.88.55.242
ya.ru has IPv6 address 2a02:6b8::2:242
ya.ru mail is handled by 10 mx.yandex.ru.
$ ping -6 2a02:6b8::2:242
ping: connect: Сеть недоступна
$ traceroute 2a02:6b8::2:242
traceroute to 2a02:6b8::2:242 (2a02:6b8::2:242), 30 hops max, 80 byte packets
connect: Сеть недоступна
```

Выбор пиров для хоста

Первый вопрос который просится: откуда мы взяли адреса пиров (соседей), которые прописали в секции Peers конфигурации, и через которые хост и осуществляет свой роутинг? И как и какие пиры выбирать?

Понятно, что должны быть записаны несколько пиров наиболее доступных, самых быстрых, с конфигурируемого хоста. А поэтому, понятно, что нет никакого универсального набора, а выбор зависит от вашей конкретно геолокации (местоположения хоста), и должен производиться индивидуально.

Хорошо… но из какого набора производить выбор? Наверное, из-за важности этого выбора, сложилось несколько источников набора адресов пиров.

1. Фиксированный список. Это статический список, который сформирован и обновляется участниками проекта с некоторой периодичностью:

```
$ git clone https://github.com/yggdrasil-network/public-peers.git
Клонирование в «public-peers»...
remote: Enumerating objects: 2963, done.
remote: Counting objects: 100% (363/363), done.
remote: Compressing objects: 100% (235/235), done.
remote: Total 2963 (delta 217), reused 240 (delta 123), pack-reused 2600
Получение объектов: 100% (2963/2963), 695.92 КиБ | 595.00 КиБ/с, готово.
Определение изменений: 100% (1711/1711), готово.
$ ls -l ./public-peers/
итого 32
drwxrwxr-x 2 olej olej 4096 мар 28 21:23 africa
drwxrwxr-x 2 olej olej 4096 мар 28 21:23 asia
drwxrwxr-x 2 olej olej 4096 мар 28 21:23 europe
drwxrwxr-x 2 olej olej 4096 мар 28 21:23 mena
drwxrwxr-x 2 olej olej 4096 мар 28 21:23 north-america
drwxrwxr-x 2 olej olej 4096 мар 28 21:23 other
-rw-rw-r-- 1 olej olej 1621 мар 28 21:23 README.md
drwxrwxr-x 2 olej olej 4096 мар 28 21:23 south-america
$ tree ./public-peers/europe
/home/olej/2023/own.WORK/Yggdrasil/public-peers/europe
```

```
├── czechia.md
├── finland.md
├── france.md
├── germany.md
├── netherlands.md
├── poland.md
├── romania.md
├── russia.md
├── slovakia.md
├── sweden.md
├── switzerland.md
├── ukraine.md
└── united-kingdom.md

0 directories, 13 files

$ cat ./public-peers/europe/ukraine.md
# Ukraine peers

Add connection strings from the below list to the `Peers: []` section of your
Yggdrasil configuration file to peer with these nodes.

* Bila Tserkva, operated by [ufm](ufm@ufm.lol)
  * `tcp://193.111.114.28:8080`
  * `tls://193.111.114.28:1443`

* Kiev, operated by [mvvpt](mvvpt0@bigmir.net)
  * `tcp://78.27.153.163:33165`
  * `tls://78.27.153.163:33166`
  * `tls://78.27.153.163:3785`
  * `tls://78.27.153.163:3784`
  * `tls://78.27.153.163:179`
```

Думаю, что логика использования этого источника понятна: для наиболее близкого территориального расположения выбираем несколько адресов. Адреса, как увидим, могут быть в нескольких протоколах, IPv4 и IPv6, с указанием порта. Именно в таком виде адрес и записывается в секцию конфигурации Peers: один адрес — одна строка.

Каждый адрес из фиксированного списка должен быть **обязательно** проверен на доступность (и время доступа), например ping-ом — вчера адрес был доступен, а сегодня его владелец передумал: всё это частные инициативы участников.

2. Проверочная утилита пригодности пиров на Python:

```
$ git clone https://github.com/zhoreeq/peer_checker.py.git
Клонирование в «peer_checker.py»...
remote: Enumerating objects: 10, done.
remote: Counting objects: 100% (10/10), done.
remote: Compressing objects: 100% (9/9), done.
Получение объектов: 100% (10/10), готово.
Определение изменений: 100% (3/3), готово.
remote: Total 10 (delta 3), reused 4 (delta 0), pack-reused 0
```

Скачанная утилита не требует никакой сборки (Python). Запуская просто без параметров получим подсказку по использованию:

```
$ python ./peer_checker.py/peer_checker.py
Usage: ./peer_checker.py/peer_checker.py [path to public_peers repository on a disk]
I.e.:  ./peer_checker.py/peer_checker.py ~/Projects/yggdrasil/public_peers
```

Запускаем утилиту, «напустив её» натот фиксированный список, который получили ранее:

```
$ python ./peer_checker.py/peer_checker.py ./public-peers/
Report date: Wed May  3 11:14:30 2023
Dead peers:
```

```
tls://[2603:c023:8001:1600:35e0:acde:2c6e:b27f]:17001    mena/saudi-arabia.md
tcp://[2603:c023:8001:1600:35e0:acde:2c6e:b27f]:17002    mena/saudi-arabia.md
tls://[2001:41d0:304:200::ace3]:23108          europe/france.md
tls://[2001:41d0:2:c44a:51:255:223:60]:54232    europe/france.md
tcp://[2001:470:1f13:e56::64]:39565   europe/france.md
...
tls://x-ams-1.sergeysedoy97.ru:65535     europe/netherlands.md
tls://79.137.194.94:65535        europe/netherlands.md
tls://[2001:41d0:601:1100::cf2]:11129    europe/poland.md
tcp://ipv4.campina-grande.paraiba.brazil.yggdrasil.iasylum.net:40000     south-america/brazil.md
...

Alive peers (sorted by latency):

URI     Latency (ms)       Location
tls://s-msk-0.sergeysedoy97.ru:65535           11.848    europe/russia.md
tls://s-fra-0.sergeysedoy97.ru:65535           12.085    europe/germany.md
tls://s-ams-0.sergeysedoy97.ru:65535           12.452    europe/netherlands.md
tls://s-ams-1.sergeysedoy97.ru:65535           14.252    europe/netherlands.md
tls://s-msk-2.sergeysedoy97.ru:65535           17.061    europe/russia.md
tls://pl1.servers.devices.cwinfo.net:11129     25.775    europe/poland.md
tcp://78.27.153.163:33165   26.017    europe/ukraine.md
tcp://193.111.114.28:8080   26.022    europe/ukraine.md
tls://78.27.153.163:3784    26.128    europe/ukraine.md
tls://78.27.153.163:179     26.144    europe/ukraine.md
tls://78.27.153.163:3785    26.178    europe/ukraine.md
tls://78.27.153.163:33166   26.231    europe/ukraine.md
tls://193.111.114.28:1443   26.469    europe/ukraine.md
tls://s-msk-1.sergeysedoy97.ru:65535           35.013    europe/russia.md
...
```

Утилита требует на выполнение некоторое время (умеренное). Она отсортировала «мёртвые» адреса от «живых», а последние, пригодные к использованию, отсортировала по времени латентности как она видится из вашего местоположения.

Внимание: Множество адресов IPv6 в списке «мёртвых» может быть связано не только с их недоступностью, а с тем (скорее), что ваш собственный **провайдер** Интернет не обеспечивает для вас трафик в протоколе IPv6… А для русскоязычных территорий на сегодня большинство провайдеров не спешит предоставлять клиентам IPv6 трафик.

3. Ещё один, свежий, инструмент получения списка пиров:

```
$ git clone https://github.com/ygguser/peers_updater.git
Клонирование в «peers_updater»...
remote: Enumerating objects: 707, done.
remote: Counting objects: 100% (193/193), done.
remote: Compressing objects: 100% (115/115), done.
remote: Total 707 (delta 118), reused 128 (delta 78), pack-reused 514
Получение объектов: 100% (707/707), 132.99 КиБ | 599.00 КиБ/с, готово.
Определение изменений: 100% (417/417), готово.
$ cd peers_updater
```

Теперь это выписано на языке Rust:

```
$ tree -L 2
.
├── build.rs
├── Cargo.toml
├── CHANGELOG.md
├── LICENSE
├── README.md
├── README_ru.md
└── src
```

```
    ├── cfg_file_read_write.rs
    ├── clap_args.rs
    ├── defaults.rs
    ├── download_file.rs
    ├── main.rs
    ├── parsing_peers.rs
    ├── peer.rs
    ├── self_updating.rs
    ├── tmpdir.rs
    ├── unpack.rs
    └── using_api.rs

1 directory, 17 files
```

Если у вас установлена среда разработки языка Rust (типовым образом, из стандартного репозитория дистрибутива), то сборка утилиты должна проходить «без сучка без задоренки» (с подтягиванием всего необходимого, крейтов для сборки):

```
$ cargo build --release
    Updating crates.io index
  Downloaded foreign-types v0.3.2
  Downloaded proc-macro2 v1.0.56
  Downloaded untrusted v0.7.1
  Downloaded spin v0.5.2
  Downloaded autocfg v1.1.0
...
  Downloaded 41 crates (8.5 MB) in 7.22s (largest was `ring` at 5.1 MB)
   Compiling cc v1.0.79
   Compiling libc v0.2.141
   Compiling untrusted v0.7.1
   Compiling cfg-if v1.0.0
   Compiling spin v0.5.2
...
    Finished release [optimized] target(s) in 2m 12s

$ ls -l target/release/peers_updater
-rwxrwxr-x 2 olej olej 1735160 апр 16 22:47 target/release/peers_updater
$ cd target/release
```

Выполнение:

```
$ time ./peers_updater -p > peers.txt
real    0m35,944s
user    0m0,019s
sys     0m0,059s
$ head peers.txt
URI                                                     |Region         |Country        |Latency
--------------------------------------------------------------------------------------------------
tls://s-ams-1.sergeysedoy97.ru:65535                    |europe         |netherlands    |11
tls://s-fra-0.sergeysedoy97.ru:65535                    |europe         |germany        |12
tls://s-msk-1.sergeysedoy97.ru:65535                    |europe         |russia         |12
tls://s-msk-2.sergeysedoy97.ru:65535                    |europe         |russia         |12
tls://s-ams-0.sergeysedoy97.ru:65535                    |europe         |netherlands    |12
tls://78.27.153.163:33166                               |europe         |ukraine        |13
tls://78.27.153.163:3785                                |europe         |ukraine        |13
tls://78.27.153.163:179                                 |europe         |ukraine        |13
...
$ cat peers.txt | wc -l
119
```

Найдено 119 свежих пиров. Совсем неплохо!

4. Проверка того какие пиры реально использует ваш хост, после того как вы их прописали в конфигурации и перезапустили сервис. (Здесь каждый Port, как он назван в заголовке, представляется

на терминале одной длинной строкой, но отобразить это в тексте невозможно.):

```
$ sudo yggdrasilctl getPeers
 Port                              Public Key                                                  IP
Address                       Uptime    RX        TX       Pr                                 URI
 1       2493ffffffffec63eb18516ce50a3dc2667e29d49fb8b9bd7b39ffe94a32c882
         202:db60::9ce0:a73d:7498:d7ae           4h54m39s  199kb      2mb      0
         tcp://195.123.245.146:7743
 2       000000c70d438dbb3b7a4712404207070f34e500cd47cef73f26dd54e8f5d591
         218:71e5:78e4:8989:b71:db7f:7bf1:f1e1   4h54m39s  162kb     64kb      0
         tcp://yggdrasil.su:62486
 3       91deffffffffe01abab3514ca4cfc27ec04dc261c801d285f0ce06e3314f8b6e
         200:dc42::3fca:8a99:5d66:b660           3h0m19s   51kb      11kb      0
         tcp://y.zbin.eu:7743
 4       0000000230d4e2faac3a016ed5a5541a1e89bf6640ffd1e083be71e8dae575db
         21e:e795:8e82:a9e2:ff48:952d:55f2:f0bb  4h54m39s  350kb     49kb      0
         tcp://51.15.204.214:12345
 5       00000017d79dda4d057c2e0ddaf8d0ea85cd8d169e34fd881a4825a6a97da964
         21b:8286:225b:2fa8:3d1f:2250:72f1:57a3  20m39s    25kb       2kb      0
         tcp://45.95.202.21:12403
 6       82340324e39a7b1e03d5b389c682e5d803f7884ac4dab8e7854b77260dd3dab8
         200:fb97:f9b6:38cb:9c3:f854:98ec:72fa   3h5m39s   12kb      16kb      0
         tcp://212.154.86.134:8800
 7       4d758aceabcdd2431559468a27a4cda8d46a3899e27a2d41c26ed599a0b902f0
         201:ca29:d4c5:50c8:b6f3:aa9a:e5d7:616c  4h54m39s  116kb     22kb      0
         tcp://158.101.229.219:17002
 8       000002692ce4bca396c7b037b6fab696dddb076b566fca5e43339fc2cc116f23
         216:cb69:8da1:ae34:9c27:e424:82a4:b491  3m39s     10kb       1kb      0
         tcp://45.147.200.202:12402
 9       0000000d9a030fa6b7de7f1f1c2b4754e9fb66086cf971f7997576e842902ef4
         21c:4cbf:9e0b:2904:301c:1c7a:9715:62c0  4h54m37s  78kb      60kb      0
         tls://[fe80::522d:d0bd:b221:a526]:39655
 10      0000000d9a030fa6b7de7f1f1c2b4754e9fb66086cf971f7997576e842902ef4
         21c:4cbf:9e0b:2904:301c:1c7a:9715:62c0  4h54m37s  43kb      54kb      0
         tls://[fe80::522d:d0bd:b221:a526%eno2]:48877
```

Майнинг IPv6 адресов

С точки зрения защищённости, потенциально существует возможность, путём грандиозного перебора, подобрать такие значения PublicKey и PrivateKey, которые будут производить известный адрес, и тем создавать угрозу сетевого спуфинга (подмена, фальсификация адресата).

В Yggdrasil, где адрес IPv6 выводится математически, а топология не является ответственностью уполномоченных лиц, единственный сценарий спуфинга – подбор злоумышленником пары ключей PublicKey и PrivateKey, которые образуют известный адрес. Из логики алгоритма образования адреса (которая описана в приведенных в конце части источниках, но не входит в цель наших обсуждений) получается, что 2-й байт адреса (первый байт это ведущие «0x02») это число первых непрерывно идущих нулевые бит PublicKey — повышенное число таких нулевых бит создают дополнительный фактор уникальности адреса, увеличивают численное значение 2-го байта адреса, и усложняют задачу подбора.

Для рядовых рабочих станций это не имеет существенного значения. А вот для серверов стараются подобрать (а позже занести в конфиг) такую пару ключей, чтобы они давали максимальное число ведущих нулей в PublicKey. Процесс поиска таких значений достижим только путём случайного перебора, по логике вычислений соответствует поиску следующего блока для криптовалюты с хэшем меньше порога, а поэтому также называется майнингом. Процесс подбора ключей является крайне трудоёмким, на самом высоко производительном оборудовании может продолжаться непрерывно часами, а возможно и сутками. Для выполнения этой работы в Yggdrasil предложено несколько вариантов утилит.

Первая из таких утилит это `SimpleYggGen-CPP`:

```
$ git clone https://notabug.org/acetone/SimpleYggGen-CPP.git
Клонирование в «SimpleYggGen-CPP»...
remote: Counting objects: 1293, done.
remote: Compressing objects: 100% (527/527), done.
remote: Total 1293 (delta 748), reused 1281 (delta 740)
Получение объектов: 100% (1293/1293), 1.23 МиБ | 999.00 КиБ/с, готово.
```

```
Определение изменений: 100% (748/748), готово.
$ ls -l SimpleYggGen-CPP
итого 56
-rw-rw-r-- 1 olej olej    81 апр  3 21:19 CMakeLists.txt
-rw-rw-r-- 1 olej olej 34570 апр  3 21:19 LICENSE
-rw-rw-r-- 1 olej olej  2838 апр  3 21:19 README.md
drwxrwxr-x 4 olej olej  4096 апр  3 21:19 src
drwxrwxr-x 2 olej olej  4096 апр  3 21:19 src-qt
drwxrwxr-x 3 olej olej  4096 апр  3 21:19 test
```

Как следует и из названия, утилита написана на C++ и собирается с помощью Cmake, обычным для Cmake способом:

```
$ cd SimpleYggGen-CPP
$ mkdir _build && cd _build
$ cmake -G "Unix Makefiles" ..
-- The C compiler identification is GNU 11.3.0
-- The CXX compiler identification is GNU 11.3.0
-- Detecting C compiler ABI info
-- Detecting C compiler ABI info - done
-- Check for working C compiler: /usr/bin/cc - skipped
-- Detecting C compile features
-- Detecting C compile features - done
-- Detecting CXX compiler ABI info
-- Detecting CXX compiler ABI info - done
-- Check for working CXX compiler: /usr/bin/c++ - skipped
-- Detecting CXX compile features
-- Detecting CXX compile features - done
-- Configuring done
-- Generating done
-- Build files have been written to: /home/olej/2023/Yggdrasil/SimpleYggGen-CPP/_build
$ make -j
[ 66%] Building CXX object src/CMakeFiles/sygcpp.dir/main.cpp.o
[ 66%] Building CXX object src/CMakeFiles/sygcpp.dir/parameters.cpp.o
[100%] Linking CXX executable sygcpp
[100%] Built target sygcpp
$ ls -l src/sygcpp
-rwxrwxr-x 1 olej olej 290464 апр  3 21:40 src/sygcpp
olej@R420:~/2023/Yggdrasil/SimpleYggGen-CPP/_build$ ls -l src/sygcpp
-rwxrwxr-x 1 olej olej 290464 апр  3 21:40 src/sygcpp
$ src/sygcpp --version
 +-------------------------------------------------------------------------+
 |                   [    SimpleYggGen C++  5.1-flow    ]                  |
 |                   EdDSA public key -> IPv6 -> Meshname                  |
 |                   notabug.org/acetone/SimpleYggGen-CPP                  |
 |                                                                         |
 |                              GPLv3 (c) 2021                             |
 +-------------------------------------------------------------------------+
$ src/sygcpp --help
 +-------------------------------------------------------------------------+
 |            Simple Yggdrasil address miner usage:  --help or -h          |
 +-------------------------------------------------------------------------+
 [Mining modes]
   High addresses                                    BY DEFAULT |
   IPv6 by pattern                                         --ip | -i
   IPv6 by pattern + height                             --ip-high | -ih
   IPv6 by regular expression                           --regexp | -r
   IPv6 by regular expression + height               --regexp-high | -rh
   Meshname by pattern                                    --mesh | -m
   Meshname by regular expression                   --mesh-regexp | -mr
   Subnet brute force (300::/64)                    --brute-force | -b
 [Main parameters]
```

```
  Threads count (maximum by default)                --threads | -t  <value>
  String for pattern or regular expression          --pattern | -p  <value>
  Start position for high addresses (14 by default) --altitude | -a  <value>
[Extra options]
  Disable auto-increase in high mode          --increase-none | -in
  Disable logging to text file, stdout only    --logging-none | -ln
  Force display meshname domains               --display-mesh | -dm
  Show PrivateKeys in full format in console        --full-pk | -fp
  Show the version of the miner                     --version | -v
[Meshname convertation]
  Convert IP to Meshname                             --tomesh | -tm <value>
  Convert Meshname to IP                               --toip | -ti <value>
[Notes]
  Meshname domains use base32 (RFC4648) alphabet symbols.
  In meshname domain mining should use "=" instead ".meship" or ".meshname".
  Subnet brute force mode understand "3xx:" and "2xx:" patterns.
+-------------------------------------------------------------------------+
```

Запуск на майнинг — сначала результативные строки идут довольно часто, потом всё реже и реже, продолжаем до тех пор, пока нас устроит ведущее число нолей в PublicKey:

```
$ time src/sygcpp
SimpleYggGen was started without parameters.
The mining mode for high addresses will be launched automatically.
Use --help for usage information.
+-------------------------------------------------------------------------+
|                   [    SimpleYggGen C++  5.1-flow    ]                  |
|                   EdDSA public key -> IPv6 -> Meshname                  |
|                   notabug.org/acetone/SimpleYggGen-CPP                  |
|                                                                         |
|                              GPLv3 (c) 2021                             |
+-------------------------------------------------------------------------+
Threads: 40, high addresses (214++), logging to text file.

Address:    216:813f:6186:1ced:92bb:9571:4780:936f
PublicKey:  000002fd813cf3c624da88d51d70fed920ae9c4687d188719176a9b3c98a276a
PrivateKey: 95660c4077f8dfb1c7ac04860ad0acfae400833be3a17b86b81b0cc8b521410c

kH/s: [____564] Total: [_____________3200008] Found: [__1] Time: [0:00:00:07]
kH/s: [____570] Total: [_____________6400012] Found: [__1] Time: [0:00:00:12]

Address:    218:47de:1d18:13ae:e5a5:c8f9:50b2:af76
PublicKey:  000000dc10f173f6288d2d1b8357a6a844fb0e6ce9a3910b05cd5178ec295ea3
PrivateKey: f93d3c5f9bd856b3101fb8d3e63ae84d5ad37bcc0744e7f0ee11a54fcab26f39

kH/s: [____567] Total: [_____________9600007] Found: [__2] Time: [0:00:00:18]

Address:    21a:cdd9:136c:5e0e:25e9:3fcf:848d:e3cd
PublicKey:  0000002644dd92743e3b42d8060f6e43865b7835618c97b144130f943819a3be
PrivateKey: b7ab2dc8e4e3e5f335388a5e04f85422d399cb75c8c584b0aa318d1c7d5934ca

kH/s: [____569] Total: [____________12800004] Found: [__3] Time: [0:00:00:24]
kH/s: [____569] Total: [____________16000005] Found: [__3] Time: [0:00:00:29]
kH/s: [____567] Total: [____________19200007] Found: [__3] Time: [0:00:00:35]
kH/s: [____569] Total: [____________22400019] Found: [__3] Time: [0:00:00:41]
kH/s: [____569] Total: [____________25600022] Found: [__3] Time: [0:00:00:47]
kH/s: [____570] Total: [____________28800005] Found: [__3] Time: [0:00:00:52]
kH/s: [____570] Total: [____________32000006] Found: [__3] Time: [0:00:00:58]
kH/s: [____568] Total: [____________35200001] Found: [__3] Time: [0:00:01:04]
kH/s: [____571] Total: [____________38400005] Found: [__3] Time: [0:00:01:09]
kH/s: [____570] Total: [____________41600006] Found: [__3] Time: [0:00:01:15]
kH/s: [____569] Total: [____________44800027] Found: [__3] Time: [0:00:01:21]
```

```
 Address:    21b:83ff:70cf:8a69:90d5:5a1f:7d6:339
 PublicKey:  00000017c008f3075966f2aa5e0f829fcc68e06ebc7fcc38fb3c3bf6d8a4b939
 PrivateKey: 9313b0cc394be3c108ad05886442d630fdc81539d475b804d5f42d9d7abf3815
...
```

Вторая, альтернативная, реализациях для тех же целей, более поздняя — это `syg_go`, написана на языке Go (утверждается что она может быть при определённых условиях производительнее … но я ничего такого не наблюдал):

```
$ git clone http://github.com/tdemin/syg_go
Клонирование в «syg_go»...
warning: переадресация на https://github.com/tdemin/syg_go/
remote: Enumerating objects: 140, done.
remote: Counting objects: 100% (140/140), done.
remote: Compressing objects: 100% (63/63), done.
remote: Total 140 (delta 75), reused 138 (delta 73), pack-reused 0
Получение объектов: 100% (140/140), 35.32 КиБ | 168.00 КиБ/с, готово.
Определение изменений: 100% (75/75), готово.
```

Построение утилиты, если у вас установлена типовая среда разработки Go, не представляет особых проблем, а можно просто воспользоваться готовым релизом: https://git.tdem.in/tdemin/syg_go/releases.

```
$ ls -l syg_go_0.2.0_Linux_x86_64.tar.gz
-rw-rw-r-- 1 olej olej 937653 апр  9 16:11 syg_go_0.2.0_Linux_x86_64.tar.gz
```

После разархивировния:

```
$ ls -l
итого 2176
-rw-r--r-- 1 olej olej    8747 июл  5  2021 LICENSE
-rw-r--r-- 1 olej olej    3097 июл  5  2021 README.md
-rwxr-xr-x 1 olej olej 2207744 июл  5  2021 syg_go
-rw-rw-r-- 1 olej olej    3912 апр  9 18:43 syg-ipv6-high.txt
$ ./syg_go -help
Usage of ./syg_go:
  -highaddr
        high address mining mode, excludes regex
  -iter uint
        per how many iterations to output status (default 100000)
  -original
        use original Yggdrasil code
  -regex string
        regex to match addresses against (default "::")
  -threads int
        how many threads to use for mining (default 40)
  -version
        display version
$ ./syg_go --version
syg_go 0.2.0
Copyright (c) 2021 Timur Demin
```

Запуск майнинга, или как его ещё называют «поиск высоких адресов» — картина та же: сначала достаточно частые результаты, потом они всё реже и реже:

```
$ time ./syg_go -highaddr
2023/04/09 16:13:57 using syg_go vendored code
2023/04/09 16:13:57 starting mining higher addresses with 40 threads
2023/04/09 16:13:57 priv:
0156acc54893f6aa915ea4286bd74afaf07013066281d71a9625686da1548caff4a2742937f38b9a05dd6a3f5a31f86ce0a
816ad60b3e02bc1fd2002c3ba2758 | pub:
f4a2742937f38b9a05dd6a3f5a31f86ce0a816ad60b3e02bc1fd2002c3ba2758 | ip:
200:16bb:17ad:9018:e8cb:f445:2b81:4b9c
2023/04/09 16:13:57 priv:
a71c18f9705e580105d5822809a9ba3972865fc0d9189dc60132d5bf2c015b49152ef90e31d460139ac8a0f6efac85db241
8b4c3b9b0b85e5c8f9c3fe121c19e | pub:
152ef90e31d460139ac8a0f6efac85db2418b4c3b9b0b85e5c8f9c3fe121c19e | ip:
```

```
203:ad10:6f1c:e2b9:fec6:5375:f091:537
 2023/04/09 16:13:57 priv:
45a258a60db77043fe9cc8e1d50e58404f2c11ca08af4875d0aad01d03fafdf3137ed3a4ce5b8ec7b2409e594281a7565eb
88906a80d67ceb64d3b7d47c0dfd4 | pub:
137ed3a4ce5b8ec7b2409e594281a7565eb88906a80d67ceb64d3b7d47c0dfd4 | ip:
203:c812:c5b3:1a47:1384:dbf6:1a6b:d7e5
 2023/04/09 16:13:57 priv:
d1c0ea03b1029412f179e97426514f3e6f20d68ee9e2ff24cd14fcacb4c284d108bd227921b0a914d6597e04572485cfa82
6123a33f30bb4821b80b29275aa82 | pub:
08bd227921b0a914d6597e04572485cfa826123a33f30bb4821b80b29275aa82 | ip:
204:e85b:b0db:c9ea:dd65:34d0:3f75:1b6f
 2023/04/09 16:13:57 priv:
19faba30534a7e7825caa56754b49be7f18851410ae6f0d1b479c2867a27a87206eff8c6da8aa60e1e88ca9632439a844e9
5ad60237b2ac4aa711c872d73eaf4 | pub:
06eff8c6da8aa60e1e88ca9632439a844e95ad60237b2ac4aa711c872d73eaf4 | ip:
205:4401:ce49:5d56:7c78:5dcd:5a73:6f19
 2023/04/09 16:13:57 priv:
beca64b2bdc2448d547a7a3c660b8c60df2f92798a215afcc00a7cfee240d9a602d1bfc034113170237aac93c8c49a783e2
a3407c01f57112378aab6941cce78 | pub:
02d1bfc034113170237aac93c8c49a783e2a3407c01f57112378aab6941cce78 | ip:
206:9720:1fe5:f767:47ee:42a9:b61b:9db2
 2023/04/09 16:13:57 priv:
8e273aa1c0e0657d554a3b6e2f4ffd8d44b214dbf5a297315824c775694b094b01417dda33aecf03bbba15038cff7bb87b7
d80d4540e78520fadbd7f3c80360f | pub:
01417dda33aecf03bbba15038cff7bb87b7d80d4540e78520fadbd7f3c80360f | ip:
207:be82:25cc:5130:fc44:45ea:fc73:84
 2023/04/09 16:13:57 priv:
7d08cac7a607a9fee1dc933cce5fc17d67d03e8d50f6e5f134325e9d44967594009e84646ac803dd7a5bb57fd53229ee8f2
61ea4b9446690154052e7697fa1f5 | pub:
009e84646ac803dd7a5bb57fd53229ee8f261ea4b9446690154052e7697fa1f5 | ip:
208:c2f7:372a:6ff8:450b:4895:55:9bac
 2023/04/09 16:13:57 priv:
43d5662db521c5c3ae77058d7e63ff1e7ae72b911d29decaf64bebd04e0a61d00067dedd84de5357895bb86d5cbeb759e51
de174fedc4918b5aa0a1b6d2143f8 | pub:
0067dedd84de5357895bb86d5cbeb759e51de174fedc4918b5aa0a1b6d2143f8 | ip:
209:6084:89ec:86b2:a1da:911e:4a8d:522
 2023/04/09 16:13:57 priv:
9fb43928c805846fb76bdae35b9d8447378aa7c6358ae27fbc133611ee90d338001babb5412bb0ba6edd5367fb63610fe8c
a7b90983d610b340cccb831e3f50f | pub:
001babb5412bb0ba6edd5367fb63610fe8ca7b90983d610b340cccb831e3f50f | ip:
20b:4544:abed:44f4:5912:2ac9:8049:c9ef
 2023/04/09 16:13:57 priv:
58a98238e2cc4d8f15bdebfd2df09efc19d5878d9b909606b688d45c36ef0e3b000b28e81127a32c9d7b37349631992c227
906721923a94a39097f326f41c559 | pub:
000b28e81127a32c9d7b37349631992c227906721923a94a39097f326f41c559 | ip:
20c:9ae2:fddb:b9a:6c50:9919:6d39:ccda
 2023/04/09 16:13:57 priv:
c4401abdd63c73a44c66272c942358cc3427ff4ca5212ca8b25408aa93f8524d0000059274f225183a3600648a3a80f22bb
df86ee9dcc33e876b946ae78b605c | pub:
0000059274f225183a3600648a3a80f22bbdf86ee9dcc33e876b946ae78b605c | ip:
215:9b62:c376:b9f1:727f:e6dd:715f:c375
 2023/04/09 16:13:58 reached 100000 iterations
 2023/04/09 16:13:58 reached 200000 iterations
 2023/04/09 16:13:58 reached 300000 iterations
 2023/04/09 16:13:59 reached 400000 iterations
 2023/04/09 16:13:59 reached 500000 iterations
 2023/04/09 16:14:00 reached 600000 iterations
 2023/04/09 16:14:00 reached 700000 iterations
 2023/04/09 16:14:01 reached 800000 iterations
 2023/04/09 16:14:01 reached 900000 iterations
 2023/04/09 16:14:01 reached 1000000 iterations
 2023/04/09 16:14:02 reached 1100000 iterations
 2023/04/09 16:14:02 reached 1200000 iterations
 2023/04/09 16:14:02 priv:
afa07b2542645d585a9d842bd6b9bfa36cd1c1123e8aec29ba4381daaf4fd7230000020566de41a835e8c269010b632a0f7
a66b9a413f9b8f666cf0ac2350d90 | pub:
0000020566de41a835e8c269010b632a0f7a66b9a413f9b8f666cf0ac2350d90 | ip:
216:fd4c:90df:2be5:b9e:cb7f:7a4e:6af8
 2023/04/09 16:14:03 reached 1300000 iterations
 2023/04/09 16:14:03 reached 1400000 iterations
 2023/04/09 16:14:04 reached 1500000 iterations
```

```
2023/04/09 16:14:04 reached 1600000 iterations
2023/04/09 16:14:04 reached 1700000 iterations
...
```

Чтобы не погрязнуть в этих миллионах пустых итераций, запускать можно так:

```
$ time ./syg_go -highaddr 2>/dev/null | tee syg-ipv6-high.txt
2023/04/09 18:02:43 using syg_go vendored code
2023/04/09 18:02:43 starting mining higher addresses with 40 threads
2023/04/09 18:02:43 priv:
0d5c209a915d47d263ca0aec484e991a2bc06c1a8284705c3b4e45a6fa8b4d0213007587070fad1192879f1310ddbf6ef95
bc0ffd5ccdb3b4f8215abc67945dc | pub:
13007587070fad1192879f1310ddbf6ef95bc0ffd5ccdb3b4f8215abc67945dc | ip:
203:cff8:a78f:8f05:2ee6:d786:ece:f224
2023/04/09 18:02:43 priv:
e8446b97716fda08d135242934a2fee694162ff531d4bf4c3112cf3f9aa3118900934873b39eccb13981b7a798882e30143
ead7a6d62605f34d120f2432bf6b8 | pub:
00934873b39eccb13981b7a798882e30143ead7a6d62605f34d120f2432bf6b8 | ip:
208:d96f:1898:c266:9d8c:fc90:b0ce:efa3
2023/04/09 18:02:43 priv:
9566f018fdee58eb807bd1117c10cb52897f588b6fd86383881e448326b177c3004344bf6ae5ebcad7721a77e19b00fc5b8
338148366da5a7c995eb690cf01bd | pub:
004344bf6ae5ebcad7721a77e19b00fc5b8338148366da5a7c995eb690cf01bd | ip:
209:f2ed:254:6850:d4a2:3796:2079:93fc
2023/04/09 18:02:43 priv:
dcd95c0c1761bf627e3a7db58af95d66422dd7f4cd5e29400f1c1deccef365f700223d49177bbda8af1fcd64ad04151cf33
2e0562c6b20065342d7ad4907d535 | pub:
00223d49177bbda8af1fcd64ad04151cf332e0562c6b20065342d7ad4907d535 | ip:
20a:ee15:b744:2212:ba87:194:da97:df57
2023/04/09 18:02:43 priv:
88a3b8e2a950ab0998a26d5f3846c08010e0b84c9cecb1174b90e6394e122bdc00020fcdfb850a3d066ba674783db660e6c
8cc66d86ccaeaace4c641fc274c35 | pub:
00020fcdfb850a3d066ba674783db660e6c8cc66d86ccaeaace4c641fc274c35 | ip:
20e:f819:23d:7ae1:7cca:2cc5:c3e1:24cf
2023/04/09 18:02:43 priv:
b7c63456cb51f7230b8a14ec207aef57811c5287523f7da7d46411630e78881c0001331c9bd3ca4b598be2117c377fe2298
bd98789812bc5096849574166 64d4 | pub:
0001331c9bd3ca4b598be2117c377fe2298bd98789812bc5096849574166 64d4 | ip:
20f:cce3:642c:35b4:a674:1dee:83c8:801d
2023/04/09 18:02:43 priv:
5dc1f633f9c5f98e5844bca676a4ca084ba73839f8f7a63649dd4751974a42ac00007f0dfa34c5c1c700ff0fb832d676d3f
27d95591fffe7efab78cc721bbd76 | pub:
00007f0dfa34c5c1c700ff0fb832d676d3f27d95591fffe7efab78cc721bbd76 | ip:
211:3c8:172c:e8f8:e3fc:3c1:1f34:a624
2023/04/09 18:02:43 priv:
4525c551d30b9630d828bdf97123c836c3b6547e7eba8827805ccd99a7bcb4c800006dce5b8b28b69fcbbf7689ca585d3b4
03aa6c0f73ad4a84efa3ec0c15338 | pub:
00006dce5b8b28b69fcbbf7689ca585d3b403aa6c0f73ad4a84efa3ec0c15338 | ip:
211:48c6:91d3:5d25:80d1:225:d8d6:9e8b
2023/04/09 18:02:45 priv:
893ebeac1086b55c641a173e734ec95d510380d8be58414e9ed3915c4e549fd200006c0747664d74427440a20f05af13861
8188bf870ec369f92a3cafc373d42 | pub:
00006c0747664d74427440a20f05af138618188bf870ec369f92a3cafc373d42 | ip:
211:4fe2:e266:ca2e:f62e:fd77:c3e9:43b1
2023/04/09 18:02:45 priv:
5a2aec4bc93b126e51a1602859bbbb91cca57c318ec5c5795c2070886d77ceba00001c6fa8d15428155d100a97bd3d4ecd5
9a4f84cf2b40d4dae3b57302b108c | pub:
00001c6fa8d15428155d100a97bd3d4ecd59a4f84cf2b40d4dae3b57302b108c | ip:
213:3905:72ea:bd7e:aa2e:ff56:842c:2b13
2023/04/09 18:02:50 priv:
d559d3ed28ba5c9f69b33f8eeff9aa162e136f7d01ac949f3c7120d263c1d6440000007a723d3e94063f7a384416a2edaf2
11744f2e29fe77ffedf1be3434288 | pub:
0000007a723d3e94063f7a384416a2edaf211744f2e29fe77ffedf1be3434288 | ip:
219:1637:b05:afe7:217:1eef:a574:4943
2023/04/09 18:04:08 priv:
2e63d58b5c37acaa3d0ce2cd05531f6e692df12d28dafa50fbd3548f70d31c6800000016544de8bc80c739b38de7bcd77fc
1dc98c892dd48f62e510b90cd64da | pub:
00000016544de8bc80c739b38de7bcd77fc1dc98c892dd48f62e510b90cd64da | ip:
21b:9abb:2174:37f3:8c64:c721:8432:8803
2023/04/09 18:27:23 priv:
076e23435b8c361818e6c7776e4a410d9e6c4a65ed98367ca7df8d8be1afc2c800000005d60d541432e5fbabad558d6cca0
2aaddbb3363fcd3a8421934e4d575 | pub:
00000005d60d541432e5fbabad558d6cca02aaddbb3363fcd3a8421934e4d575 | ip:
21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f
2023/04/09 18:43:17 priv:
```

```
8469aaef0296fb7d2c9a97008593c83d9b64b04a9b99f759eb105153ddafcd2f00000002a1150bb1ff15e07bb758c468f31
e75cbf8d17bc246364377cf18eae3 | pub:
00000002a1150bb1ff15e07bb758c468f31e75cbf8d17bc246364377cf18eae3 | ip:
21e:af75:7a27:75:fc2:2453:9dcb:8670
 ^C
 real    98m15,868s
 user    2980m53,540s
 sys     67m51,329s
```

Как и было обещано — наблюдаем: с каждым найденным результатом число ведущих нолей в pub становися всё больше и больше, а соответствующий ему ip всё выше и выше.

Найденные значения приватного и публичного ключ записываем в конфигурационный файл, заменяем в нём соответствующие строки:

```
$ sudo grep "Key:" /etc/yggdrasil/yggdrasil.conf | grep -v ^$
  PublicKey: 00001c6fa8d15428155d100a97bd3d4ecd59a4f84cf2b40d4dae3b57302b108c
  PrivateKey:
5a2aec4bc93b126e51a1602859bbbb91cca57c318ec5c5795c2070886d77ceba00001c6fa8d15428155d100a97bd3d4ecd5
9a4f84cf2b40d4dae3b57302b108c
```

Соответствующий им IPv6 адрес нам показан в майнинге только для справки, для сверки — он должен быть установлен автоматически после перезапуска сервиса (если только где-то в конфигурации не допущена ошибка).

Yggdrasil в локальной сети

В LAN, где один из хостов уже подключен по IPv4 через внешние пиры, как показано было выше, для подключения следующих хостов Yggdrasil к P2P роумингу вовсе им не обязательно прописывать внешние пиры в секции Peers. В локальной сети хосты обнаруживают друг друга за счёт механизма Multicast Peer Discovery (MPL) — технология автоматического обнаружения пиров Yggdrasil в локальной сети.

Когда в локальной сети Yggdrasil запущено на одном или нескольких устройствах, то благодаря этой технологии все эти узлы обнаружат друг друга и автоматически установят соединение между собой, прописывать их в секции `Peers` нет необходимости. Multicast Peer Discovery включено по-умолчанию. Открывает UDP порт 9001 (для прослушивания сигналов о существовании от других узлов).

Важно (и это часто является предметом неработоспособности и беспокойства): Multicast Peer Discovery в Yggdrasil работает только с link-local IPv6 адресами устройств в локальной сети (диапазон `fe80::/10`), с IPv4 это не работает! Таким образом вы должны проследить что на интерфейсах вашей локальной сети должна быть включена поддержка IPv6 и устройства должны иметь IPv6 link-local адреса в локальной сети (между ними должен работать `ping`). Поддержка IPv6 может быть запрещена, например, настройками Network Manager.

Проверяем что поддержка IPv6 на интерфейсе хоста включена:

```
$ ip a s dev enp3s0
 2: enp3s0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP group default qlen
1000
     link/ether 10:7b:44:47:a2:47 brd ff:ff:ff:ff:ff:ff
     inet 192.168.1.241/24 brd 192.168.1.255 scope global dynamic noprefixroute enp3s0
        valid_lft 106770sec preferred_lft 106770sec
     inet6 fe80::522d:d0bd:b221:a526/64 scope link noprefixroute
        valid_lft forever preferred_lft forever
```

Теперь мы можем запускать хост Yggdrasil в такой вот конфигурации, без внешних пиров:

```
$ sudo grep "Peers:" /etc/yggdrasil/yggdrasil.conf
  Peers: []
  InterfacePeers: {}
$ systemctl status --no-pager --full yggdrasil
● yggdrasil.service - yggdrasil
     Loaded: loaded (/etc/systemd/system/yggdrasil.service; enabled; vendor preset: enabled)
     Active: active (running) since Thu 2023-04-27 11:58:18 EEST; 6 days ago
   Main PID: 1302 (yggdrasil)
```

```
       Tasks: 12 (limit: 18948)
      Memory: 28.4M
         CPU: 23min 42.051s
      CGroup: /system.slice/yggdrasil.service
              └─1302 /usr/bin/yggdrasil -useconffile /etc/yggdrasil.conf
...
$ sudo yggdrasilctl getPeers
 Port                              Public Key                                                IP
Address                       Uptime    RX        TX       Pr                              URI
 1       00000005d60d541432e5fbabad558d6cca02aaddbb3363fcd3a8421934e4d575
         21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f  9h29m48s  113kb     157kb     0
         tls://[fe80::13f5:9fe2:6393:bf4a%enp3s0]:42099
 2       00000005d60d541432e5fbabad558d6cca02aaddbb3363fcd3a8421934e4d575
         21d:8a7c:aafa:f346:8115:14aa:9ca4:cd7f  9h29m47s  106kb     74kb      0
         tls://[fe80::9bac:3791:1b79:7237]:45769
```

Здесь видно, что в качестве пиров для этого хоста в LAN использованы только link-local IPv6 адреса его соседей по LAN. Но вот с него коннект к глобальному Yggdrasil хосту, находящемуся за тысячи километров, и здесь трафик маршрутизируется транзитом через 2 соседние хосты в LAN (fe80::13f5:9fe2:6393:bf4a%enp3s0 и fe80::9bac:3791:1b79:7237):

```
$ host ygg.linux-ru.lib
ygg.linux-ru.lib has IPv6 address 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
$ ping -6 -c3 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
PING 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771(221:58c9:9a6:99be:f3d:c1ac:2b5b:9771) 56 data bytes
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=2 ttl=64 time=122 ms
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=3 ttl=64 time=122 ms

--- 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771 ping statistics ---
3 packets transmitted, 2 received, 33.3333% packet loss, time 2004ms
rtt min/avg/max/mdev = 121.583/121.758/121.933/0.175 ms
```

Это и есть автоконфигурация достаточно сложной сети, о чём говорилось ранее.

Работа в Yggdrasil без установки клиента

Но показанное выше это ещё не всё. Если в локальной сети есть хост уже увязанный в Yggdrasil, то для других хостов этой LAN можно организовать роутинг в Yggdrasil даже не устанавливая там никакого специального программного обеспечения, клиента. Более того, это можно сделать даже несколькими способами (точная ссылка в источниках информации). Но мне из этих способов кажется наиболее интересным способ организации роутинга нативным способом сети, вообще без использования каких-либо дополнительных программных инструментов. Что мы сейчас и проделаем…

Если устройство поддерживает протокол IPv6 в LAM, оно может быть подключено к сети Yggdrasil путем присвоения ему IPv6 адреса из подсети 300::/64 и указания адреса шлюза в сеть Yggdrasil.

Сначала проделаем подготовительную работу на хосте Yggdrasil:

```
$ ip a s tun0
3: tun0: <POINTOPOINT,MULTICAST,NOARP,UP,LOWER_UP> mtu 53049 qdisc pfifo_fast state UNKNOWN group
default qlen 500
    link/none
    inet6 21e:af75:7a27:75:fc2:2453:9dcb:8670/7 scope global
       valid_lft forever preferred_lft forever
    inet6 fe80::eeec:dd70:b702:96bd/64 scope link stable-privacy
       valid_lft forever preferred_lft forever
```

Адрес этого интерфейса в Yggdrasil 21e:af75:7a27:75:fc2:2453:9dcb:8670/7, тогда для подключения других устройств к этой подсети необходимо им назначить адреса такого вида: 31e:af75:7a27:75::/64. Это могут быть адреса с любыми младшими позициями: 31e:af75:7a27:75::1, 31e:af75:7a27:75::2 … и так далее. Обращаем внимание, что первая цифра 2 изменена на 3, далее 3 секции с разделителем «:» - это обязательная часть префикса. Остальные 64 бита (4 последние секции) - произвольные числа от 0000 до ffff.

Итак, на хосте Yggdrasil присвоим интерфейсу глядящему в LAN произвольный адрес из этой

подсети (алиас), скажем так:

```
# ip address add 31e:af75:7a27:75::1/64 dev eth0
# ip a s dev eth0
2: eth0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc pfifo_fast state UP group default qlen
1000
    link/ether b8:27:eb:7e:2c:a8 brd ff:ff:ff:ff:ff:ff
    inet 192.168.1.142/24 brd 192.168.1.255 scope global dynamic noprefixroute eth0
       valid_lft 107400sec preferred_lft 78260sec
    inet6 31e:af75:7a27:75::1/64 scope global
       valid_lft forever preferred_lft forever
    inet6 fe80::5b06:3ef5:5b91:15d3/64 scope link
       valid_lft forever preferred_lft forever
```

(Хорошей идеей здесь было бы присвоение требуемого IPv6 петлевому интерфейсу `lo` 127.0.0.1)

На этом же хосте (роутер в Yggdrasil) проверяем и при необходимости разрешаем форвардинг IPv6 между всеми интерфейсами хоста, у меня это:

```
$ cat /proc/sys/net/ipv6/conf/all/forwarding
0
# sysctl -w net.ipv6.conf.all.forwarding=1
net.ipv6.conf.all.forwarding = 1
# cat /proc/sys/net/ipv6/conf/all/forwarding
1
```

Для того, чтобы эта установка сохранялась постоянно, после перезагрузки, проверим и при необходимости уберём комментарий (или допишем такую строку):

```
# grep net.ipv6.conf.all.forwarding /etc/sysctl.conf
#net.ipv6.conf.all.forwarding=1
# grep -v ^# /etc/sysctl.conf | grep -v ^$
net.ipv6.conf.all.forwarding=1
```

На этом подготовку роутера Yggdrasil заканчивает. Теперь на любом другом хосте LAN присваиваем произвольный IPv6 из той же подсети 31e:af75:7a27:75::/64:

```
$ ip a s dev eno1
2: eno1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
    link/ether 70:71:bc:a3:c5:c0 brd ff:ff:ff:ff:ff:ff
    altname enp0s25
    inet 192.168.1.11/24 brd 192.168.1.255 scope global noprefixroute eno1
       valid_lft forever preferred_lft forever
    inet6 fe80::762:c6bf:9eaa:93a9/64 scope link noprefixroute
       valid_lft forever preferred_lft forever
# ip address add 31e:af75:7a27:75::5/64 dev eno1
$ ip a s dev eno1
2: eno1: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 1500 qdisc fq_codel state UP group default qlen
1000
    link/ether 70:71:bc:a3:c5:c0 brd ff:ff:ff:ff:ff:ff
    altname enp0s25
    inet 192.168.1.11/24 brd 192.168.1.255 scope global noprefixroute eno1
       valid_lft forever preferred_lft forever
    inet6 31e:af75:7a27:75::5/64 scope global
       valid_lft forever preferred_lft forever
    inet6 fe80::762:c6bf:9eaa:93a9/64 scope link noprefixroute
       valid_lft forever preferred_lft forever
```

И прописываем здесь для этого нового адреса маршрут:

```
# ip -6 route add 0200::/7 via 31e:af75:7a27:75::1
# route -6 | grep eno1
Таблица маршрутизация ядра IPv6
Destination                    Next Hop                   Flag Met Ref Use If
31e:af75:7a27:75::/64          [::]                       U    256 1     0 eno1
200::/7                        31e:af75:7a27:75::1        UG   1024 1     0 eno1
fe80::/64                      [::]                       U    1024 4     0 eno1
```

```
nvidia/128                    [::]                    Un   0   3     0 eno1
nvidia/128                    [::]                    Un   0   6     0 eno1
ip6-mcastprefix/8             [::]                    U    256 5     0 eno1
[::]/0                        [::]                    !n   -1  1     0 lo
```

(Нас в этой таблице роутинга интересует 2-я строка.)

Всё! Проверяем ping на хост-роутер Yggdrasil:

```
$ ping -c3 31e:af75:7a27:75::1 -I eno1
PING 31e:af75:7a27:75::1(31e:af75:7a27:75::1) from 31e:af75:7a27:75::5 eno1: 56 data bytes
64 bytes from 31e:af75:7a27:75::1: icmp_seq=1 ttl=64 time=0.779 ms
64 bytes from 31e:af75:7a27:75::1: icmp_seq=2 ttl=64 time=0.834 ms
64 bytes from 31e:af75:7a27:75::1: icmp_seq=3 ttl=64 time=0.751 ms

--- 31e:af75:7a27:75::1 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2052ms
rtt min/avg/max/mdev = 0.751/0.788/0.834/0.034 ms
```

И, наконец, ping на IPv6 хост Yggdrasil далеко в глобальной сети:

```
$ host ygg.linux-ru.lib
ygg.linux-ru.lib has IPv6 address 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
$ ping -c3 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771
PING 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771(221:58c9:9a6:99be:f3d:c1ac:2b5b:9771) 56 data bytes
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=1 ttl=64 time=901 ms
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=2 ttl=64 time=149 ms
64 bytes from 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771: icmp_seq=3 ttl=64 time=150 ms

--- 221:58c9:9a6:99be:f3d:c1ac:2b5b:9771 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 2001ms
rtt min/avg/max/mdev = 148.929/399.765/900.526/354.091 ms
```

Альтернативные DNS

Источники использованной информации

[1] Что такое VPN, Proxy, Tor? Разбор — https://habr.com/ru/companies/droider/articles/549212/

[2] Децентрализация как ответ беспределу: система доменных имен, которые невозможно разделегировать — https://roskomsvoboda.org/13508/

[3] Wi-Fi Mesh сети для самых маленьких — https://habr.com/ru/articles/196562/

[4] Yggdrasil Network: Заря бытовых меш-сетей, или Интернет будущего, 2021 —

https://habr.com/ru/articles/547250/

[5] Добро пожаловать на wiki пользователей сети Yggdrasil — https://howto.yggno.de/

[6] Yggdrasil Network — https://yggdrasil-network.github.io/

[7] Релизы пакетов Yggdrasil для разных архитектур, для загрузок —

https://github.com/yggdrasil-network/yggdrasil-go/releases

[8] GIT репозиторий Yggdrasil для сборки из исходных кодов —

https://github.com/yggdrasil-network/yggdrasil-go.git

[9] Multicast Peer Discovery — https://howto.yggno.de/yggdrasil:mpd

[10]Как подключиться к Yggdrasil, не устанавливая его клиент на устройство —

https://howto.yggno.de/yggdrasil:network_connection_variants

[11] EmerCoin: децентрализованный альтернативный DNS на основе криптовалюты —

https://roskomsvoboda.org/12118/

[12] Блокчейн против блокировок —

https://dzen.ru/media/olegarch/blokchein-protiv-blokirovok-61367c945a15184a849007e8

[13] Emercoin, 2023г. (рус.) — https://rtfm.emercoin.com/

Некоторые краткие итоги

В результате проделанного совмещённого рассмотрения программирования сетевых потоков в **приложениях** и прохождения их сквозь уровни сетевого стека **ядра**, удаётся цельно проследить весь тракт прохождения сетевой информации пользователя. Были последовательно рассмотрены элементы такого тракта:

- Порождение пользовательской информации в приложениях прикладного уровня (telnet, ssh, http, ...);

- Создание сокета (`socket()`) в приложениях пользователя как модели канала передачи;

- Все фазы предварительной подготовки созданного сокета (`bind()`) для его использования в несимметричной модели клиент-сервер (`listen()`, `accept()`);

- Осуществление операций ввода-вывода на этом сокете в режиме датаграммной или потоковой модели обмена для передачи в сетевую среду (`write()`, `send()`, `sendto()`, `sendmsg()`, ...);

- Создание и структура сетевого интерфейса (`struct net_device`), и его конфигурирование к работе (`ifconfig`, `route`, ...);

- Передача потока сокетных буферов, представляющих вывод в сокет, в функцию-член `ndo_start_xmit` структуры `struct net_device_ops` сетевого интерфейса;

- Дальнейшая передача сокетного сегмента в физическую среду обмена, и подтверждение завершения успешности этой передачи пакета возбуждением прерывания на линии IRQ;

- Возбуждение прерывания на линии IRQ приёмной стороны по поступлению сетевого пакета, и стратегии обслуживания потока пакетов (NAPI и др.);

- Формирование сокетного буфера из принятого сетевого пакета, и передача его функцией `netif_rx()` в очередь сетевого стека на восходящую обработку;

- Прохождение восходящего сокетного буфера сквозь фильтры сетевого (структура `struct packet_type`) и транспортного (структура `struct net_protocol`) уровней, возможность вмешательства и ручной модификации сокетного буфера в коде протокольных фильтров;

- Формирование из потока сокетных буферов потока чтения из сетевого сокета на пользовательском уровне (`read()`, `recv()`, `recvfrom()`, `recvmsg()`, ...);

- Передача переданной сквозь сеть потребительской информации приложению получателя (telnet, ssh, http, ...).

Вся последовательность работы сети и для любых протоколов укладывается в описанную схему, хотя и обрастает при этом массой рутинных подробностей, которые, тем не менее, не должны заслонять простую и ясную основную схему.