МГТУ
им. Н.Э. Баумана
ТЕХНОПАРК
Mail.Ru Group

Проектирование высоконагруженных систем

Лекция №2

Быков Александр

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Характеристики линии связи

- **Пропускная способность**
  Измеряется в битах в секунду (бит/с)
  и/или в пакетах в секунду (pps)
- **Задержка передачи**
  Измеряется как Round-Trip Time (мс) + отклонение
- **Максимальный размер пакета (MTU)**
  Предельный размер пропускаемый оборудованием
- **Интенсивность ошибок**
  Вероятность потери пакетов

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Пропускная способность

- **Сетевая карта 1Гбит/с (медь)**
  Реальная пропускная способность 800-900 Мбит/с

- **Сетевая карта 10 Гбит/с (медь)**
  Номинальная пропускная способность 1/2,5/5/10 Гбит/с

- **Сетевая карта 10 Гбит/с (оптика)**
  Требуются дорогие оптические SFP+ коннекторы
  Альтернатива: китайский коннектор + патчинг ядра

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Объединение карт в Bonding

Объединение нескольких физических интерфейсов в один логический интерфейс (агрегация).

Особенности

- Используется хеширование (src, dst) гарантирующее последовательную доставку данных одного соединения

Примеры

- 4 медных интерфейса – 3.6 Гбит/с
- 2 оптических интерфейса – 20 Гбит/с

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

r.mradx.net - исходящий трафик («полка»)

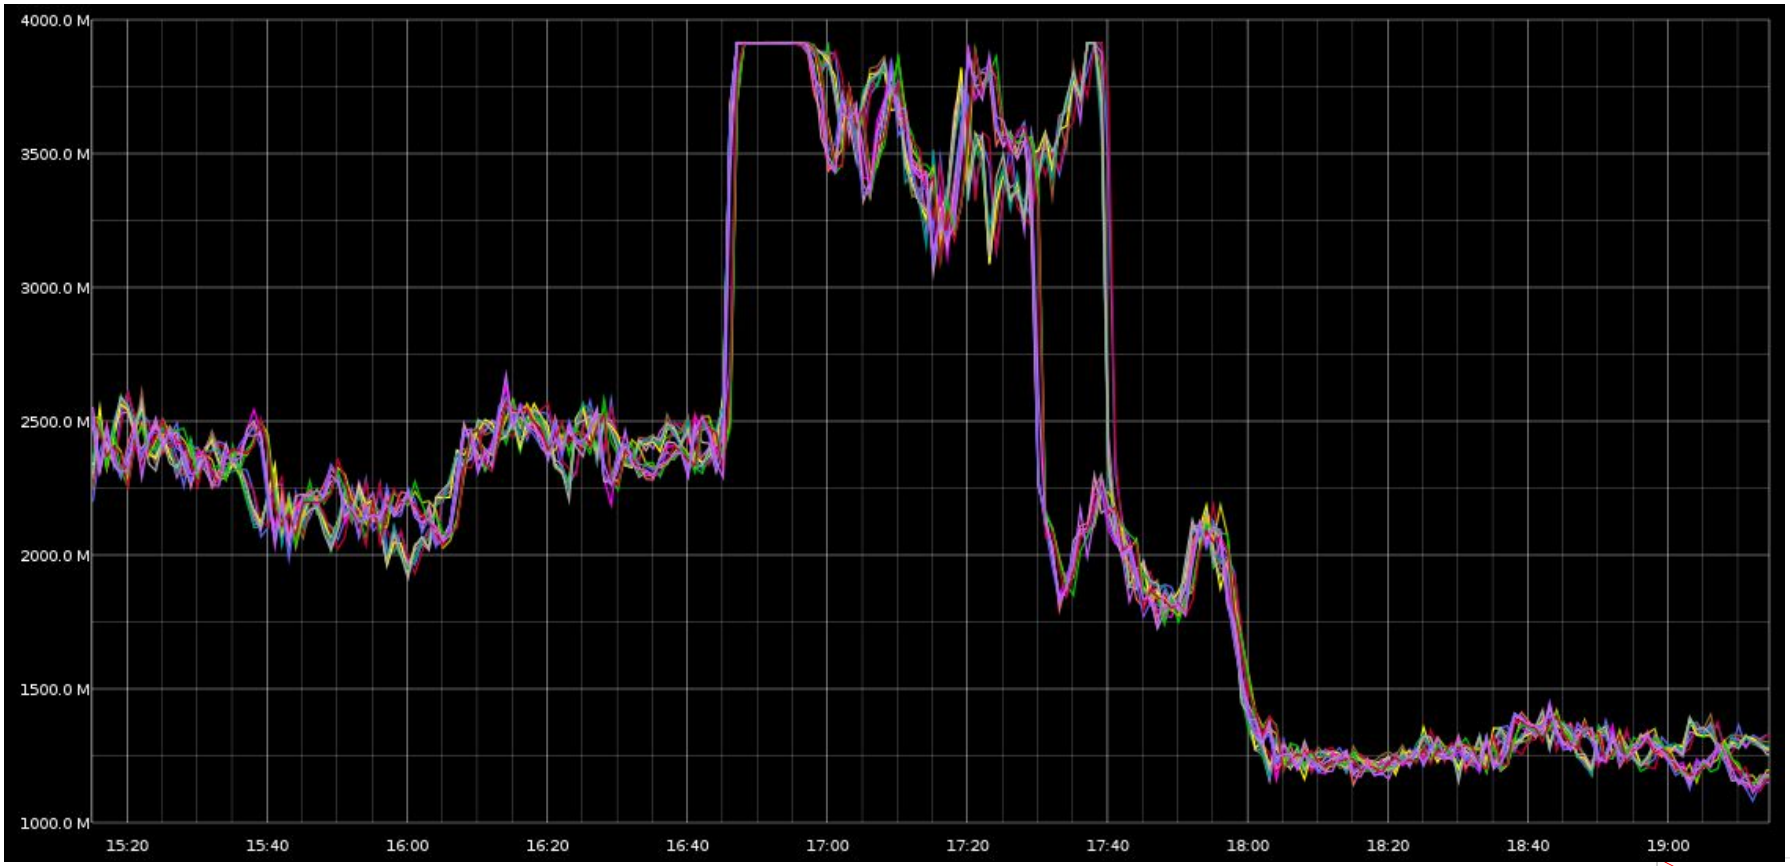

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Сетевой стек ОС

- **Многопоточные сетевые карты (MSI-X)**
  Имеют несколько очередей
  Позволяют разнести обработку на несколько CPU
- **Обычная производительность**
  150 000 – 250 000 PPS
- **Предельная производительность (с тюнингом)**
  до 1 000 000 PPS

HighLoad. Лекция №2


```
CPU0       CPU1       CPU2       CPU3       CPU4       CPU5       CPU6       CPU7       CPU8       CPU9       CPU10      CPU11      CPU12      CPU13      CPU14      CPU15
eth0
  58: 1434978947          0          0          0          0          0          0          0          0          0          0          0          0          0          0   449492   PCI-MSI-edge
eth0-TxRx-0
  59: 1950517087          0          0          0          0          0          0          0          0          0          0          0          0          0     590577          0   PCI-MSI-edge
eth0-TxRx-1
  60: 1823482036          0          0          0          0          0          0          0          0          0          0          0          0     497334          0          0   PCI-MSI-edge
eth0-TxRx-2
  61: 2251074311          0          0          0          0          0          0          0          0          0          0          0     738795          0          0          0   PCI-MSI-edge
eth0-TxRx-3
  62:  765575858          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth0-TxRx-4
  63:  329477757          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth0-TxRx-5
  64: 1517450037          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth0-TxRx-6
  65:  938808932          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth0-TxRx-7
  66:          1          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth1
  67: 1645802435          0          0          0          0          0          0          0          0          0          0     482782          0          0          0          0   PCI-MSI-edge
eth1-TxRx-0
  68: 1688597500          0          0          0          0          0          0          0          0          0     524149          0          0          0          0          0   PCI-MSI-edge
eth1-TxRx-1
  69: 1805458972          0          0          0          0          0          0          0          0     557581          0          0          0          0          0          0   PCI-MSI-edge
eth1-TxRx-2
  70: 2068996833          0          0          0          0          0          0          0     621037          0          0          0          0          0          0          0   PCI-MSI-edge
eth1-TxRx-3
  71:  550403216          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth1-TxRx-4
  72:  559352604          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth1-TxRx-5
  73: 1553486445          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth1-TxRx-6
  74: 1060127510          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth1-TxRx-7
  75:          1          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2
  76: 1632663556          0          0          0          0          0          0     587664          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2-TxRx-0
  77: 1932803994          0          0          0          0          0     598329          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2-TxRx-1
  78: 1890863328          0          0          0          0     559295          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2-TxRx-2
  79: 2135731441          0          0          0     630233          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2-TxRx-3
  80:  564846310          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2-TxRx-4
  81:  586755774          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2-TxRx-5
  82: 1608909743          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2-TxRx-6
  83:  831009992          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
eth2-TxRx-7
  84:          1          0          0          0          0          0          0          0          0          0          0          0          0          0          0          0   PCI-MSI-edge
```

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Полезные утилиты

- **iperf**
  Позволяет создавать нагрузку нужной интенсивности
  TCP и UDP
- **netstat –s**
  Статистика по интерфейсам
- **mpstat –P ALL**
  Статистика по использованию CPU
- **cat /proc/interrupts**
  Распределение обработки по CPU

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Server #1: bytes per second

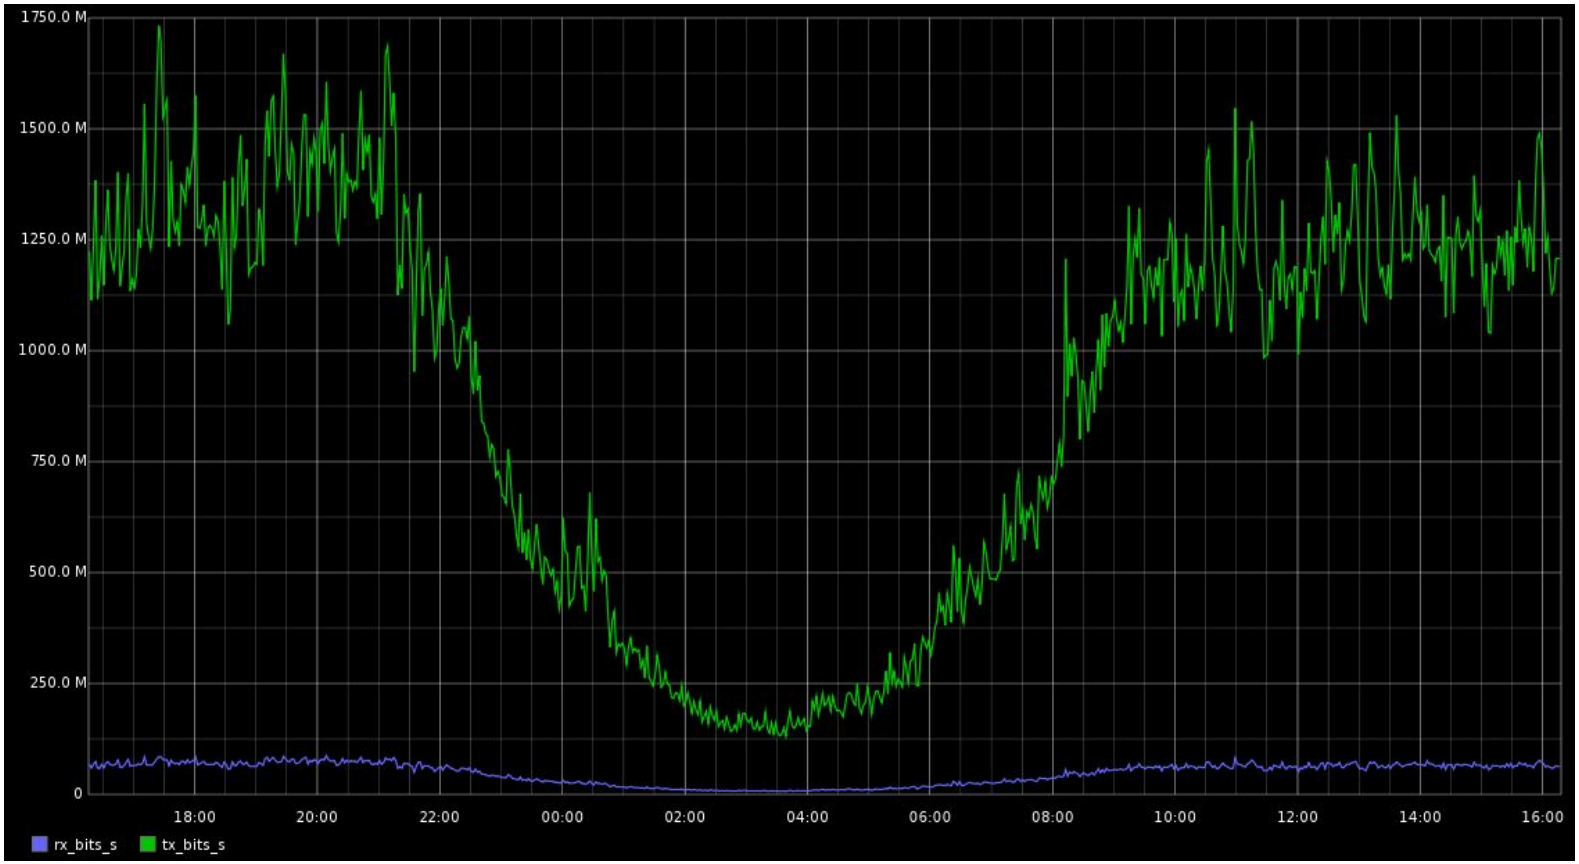

Server #2: bytes per second

Server #1: packets per second

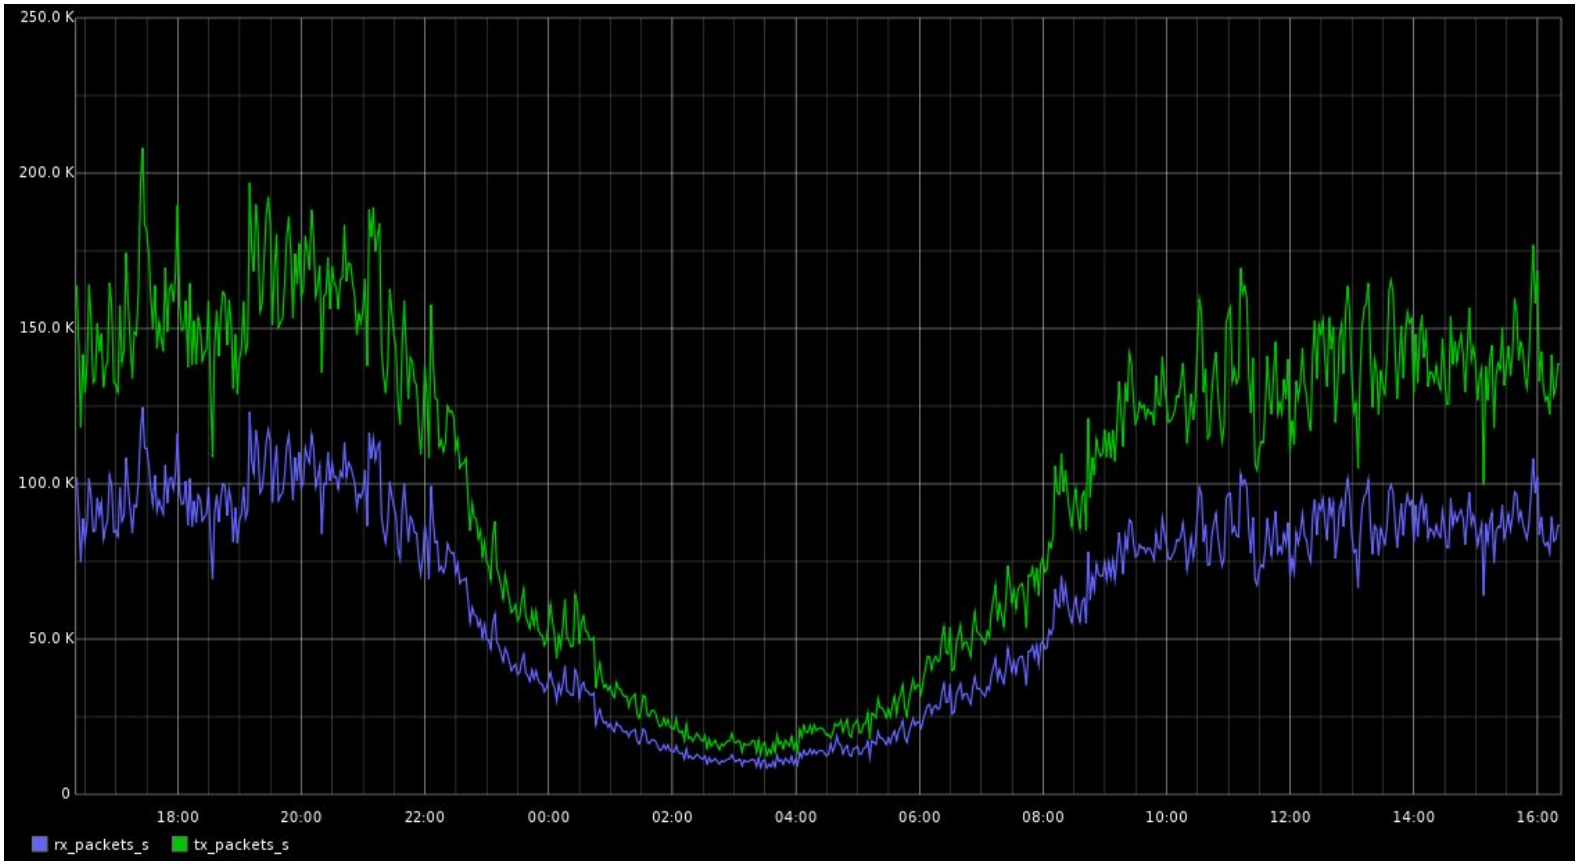

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Server #2: packets per second

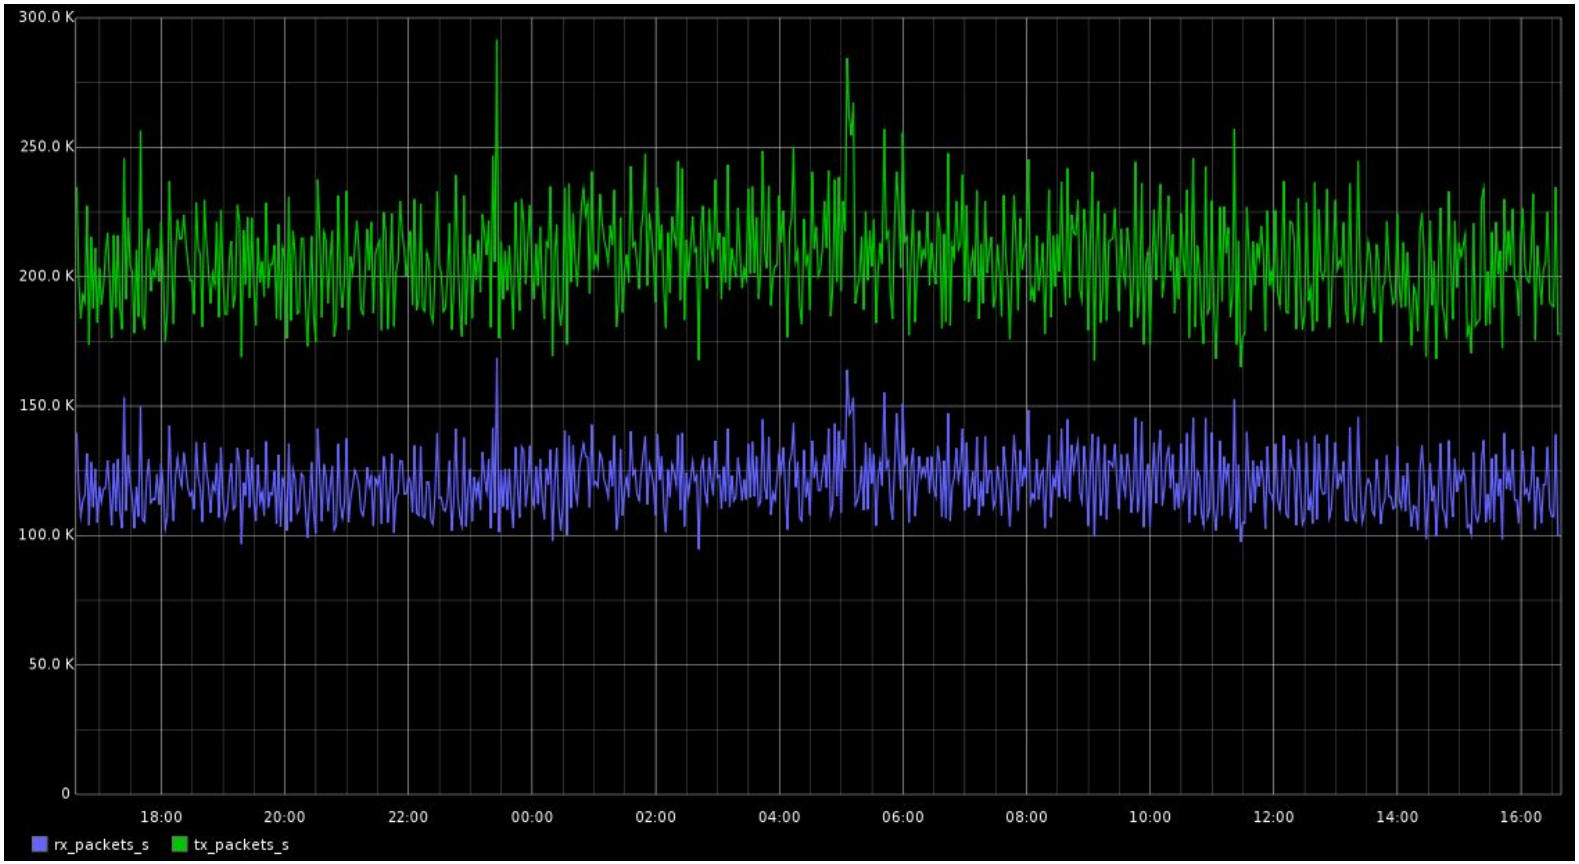

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Сетевой трафик крупных проектов

Проект	Трафик	Данные
Реклама Mail.Ru	45 Гбит/с	2017
Mail.Ru Group	3.4 Тбит/с	2015
Google (с Youtube)	>10% трафика в мире	
CloudFlare	>10% трафика в мире	
Netflix	37% трафика в США	2015

Размер пакета

- **Maximum Transmission Unit (MTU)**
  Значение порядка 1400 байт
- **Jumbo Frames**
  Технология увеличения размера пакета в контролируемой (собственной) сети

HighLoad. Лекция №2

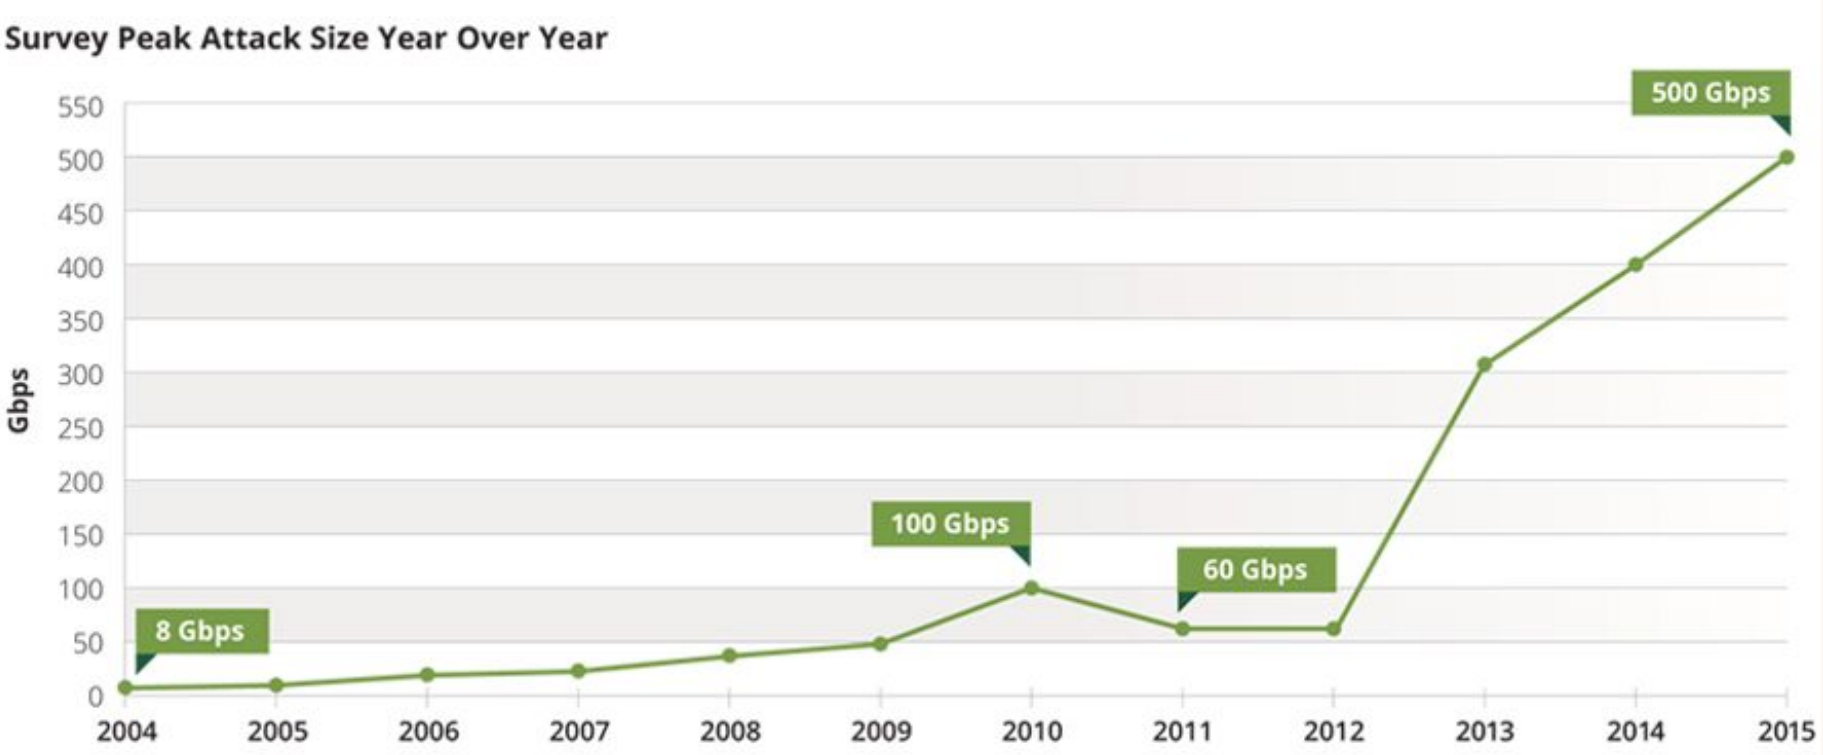

Figure 14 Source: Arbor Networks, Inc.

* 665 Gbps в сентябре 2016 года

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Рекламная система Mail.Ru

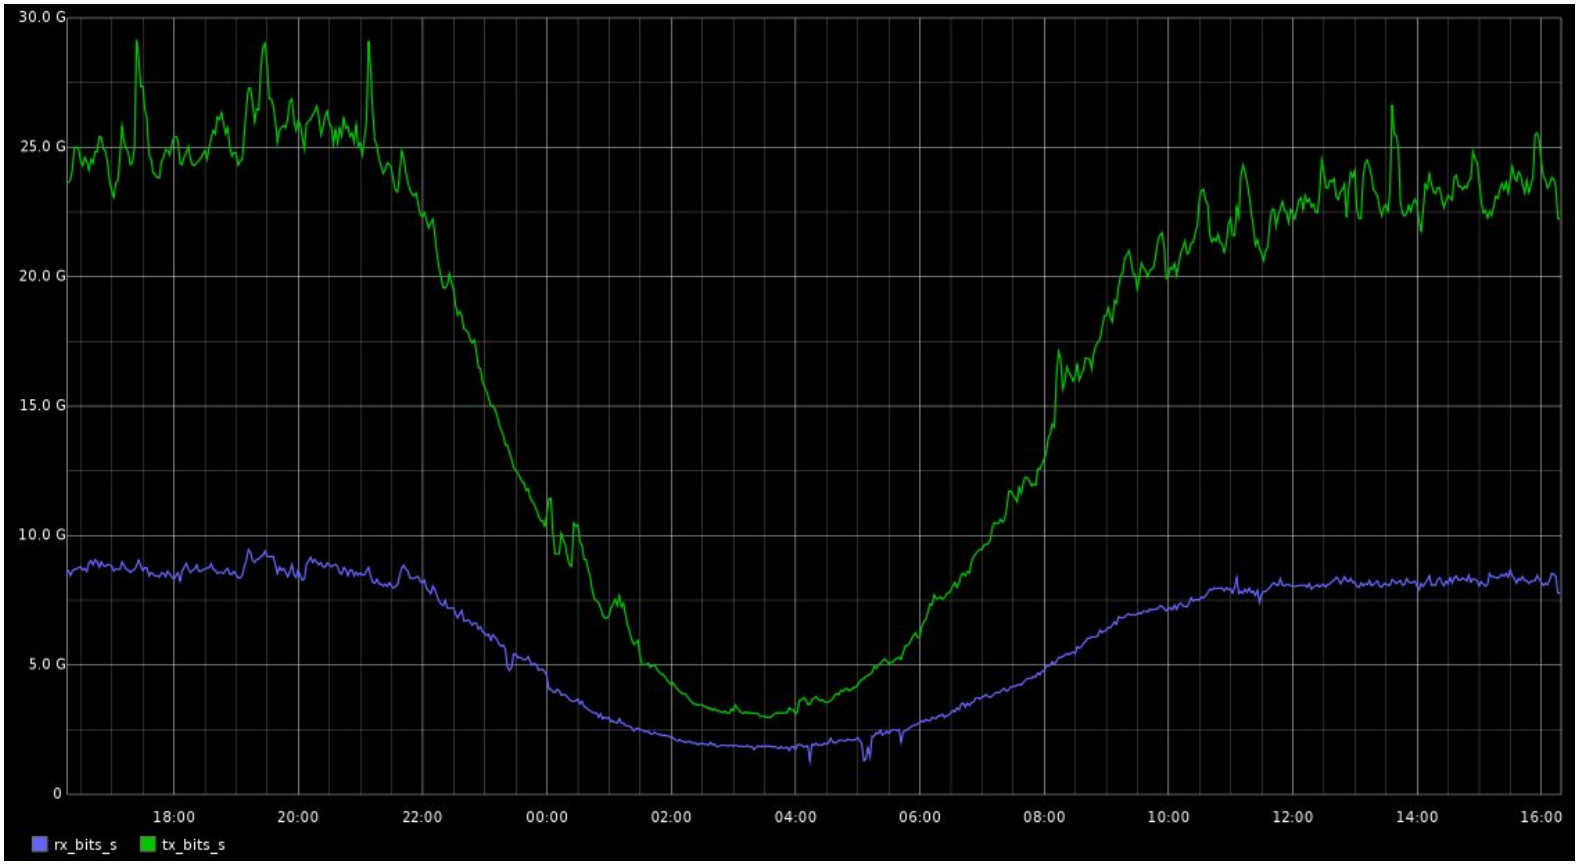

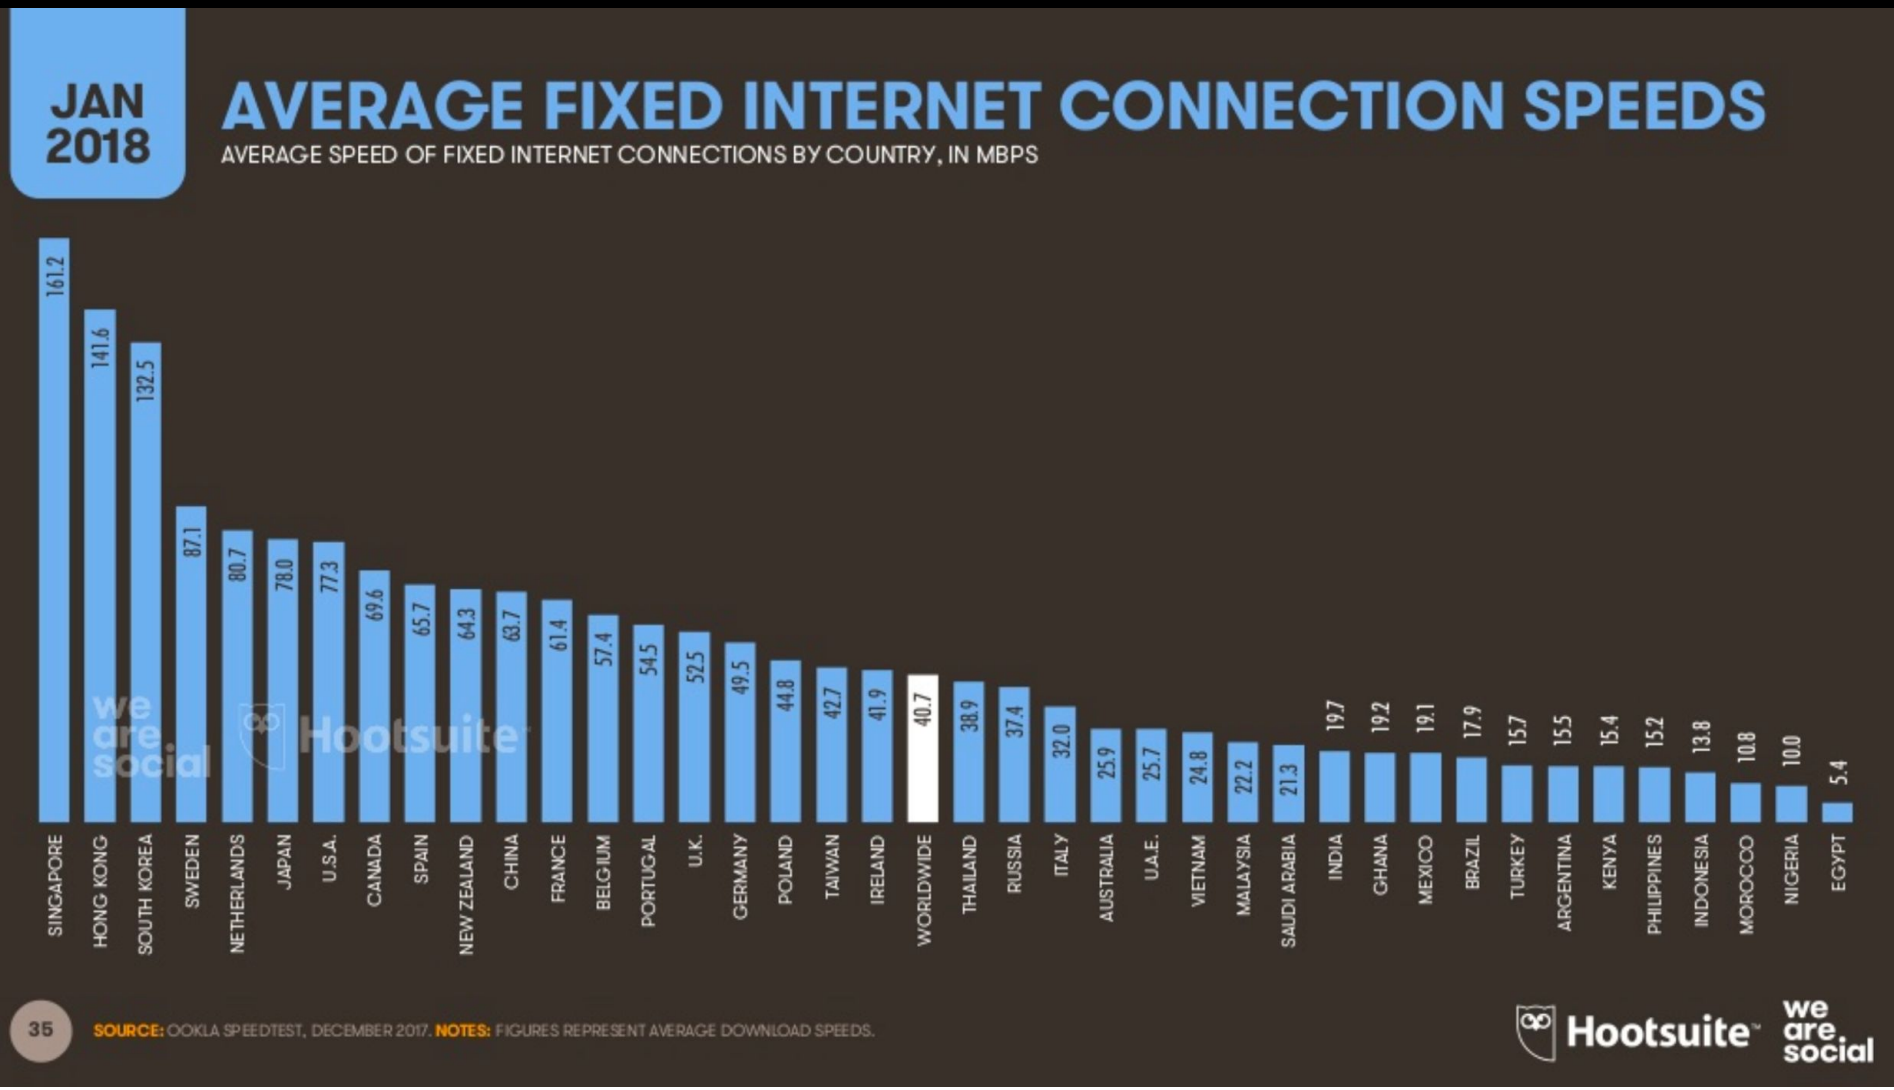
JAN 2018
AVERAGE FIXED INTERNET CONNECTION SPEEDS
AVERAGE SPEED OF FIXED INTERNET CONNECTIONS BY COUNTRY, IN MBPS
SINGAPORE 161.2
HONG KONG 141.6
SOUTH KOREA 132.5
SWEDEN 87.1
NETHERLANDS 80.7
JAPAN 78.0
U.S.A. 77.3
CANADA 69.6
SPAIN 65.7
NEW ZEALAND 64.3
CHINA 63.7
FRANCE 61.4
BELGIUM 57.4
PORTUGAL 54.5
U.K. 52.5
GERMANY 49.5
POLAND 44.8
TAIWAN 42.7
IRELAND 41.9
WORLDWIDE 40.7
THAILAND 38.9
RUSSIA 37.4
ITALY 32.0
AUSTRALIA 25.9
U.A.E. 25.7
VIETNAM 24.8
MALAYSIA 22.2
SAUDI ARABIA 21.3
INDIA 19.7
GHANA 19.2
MEXICO 19.1
BRAZIL 17.9
TURKEY 15.7
ARGENTINA 15.5
KENYA 15.4
PHILIPPINES 15.2
INDONESIA 13.8
MOROCCO 10.8
NIGERIA 10.0
EGYPT 5.4
we are social
Hootsuite
35
SOURCE: OOKLA SPEEDTEST, DECEMBER 2017. NOTES: FIGURES REPRESENT AVERAGE DOWNLOAD SPEEDS.
Hootsuite
we are social

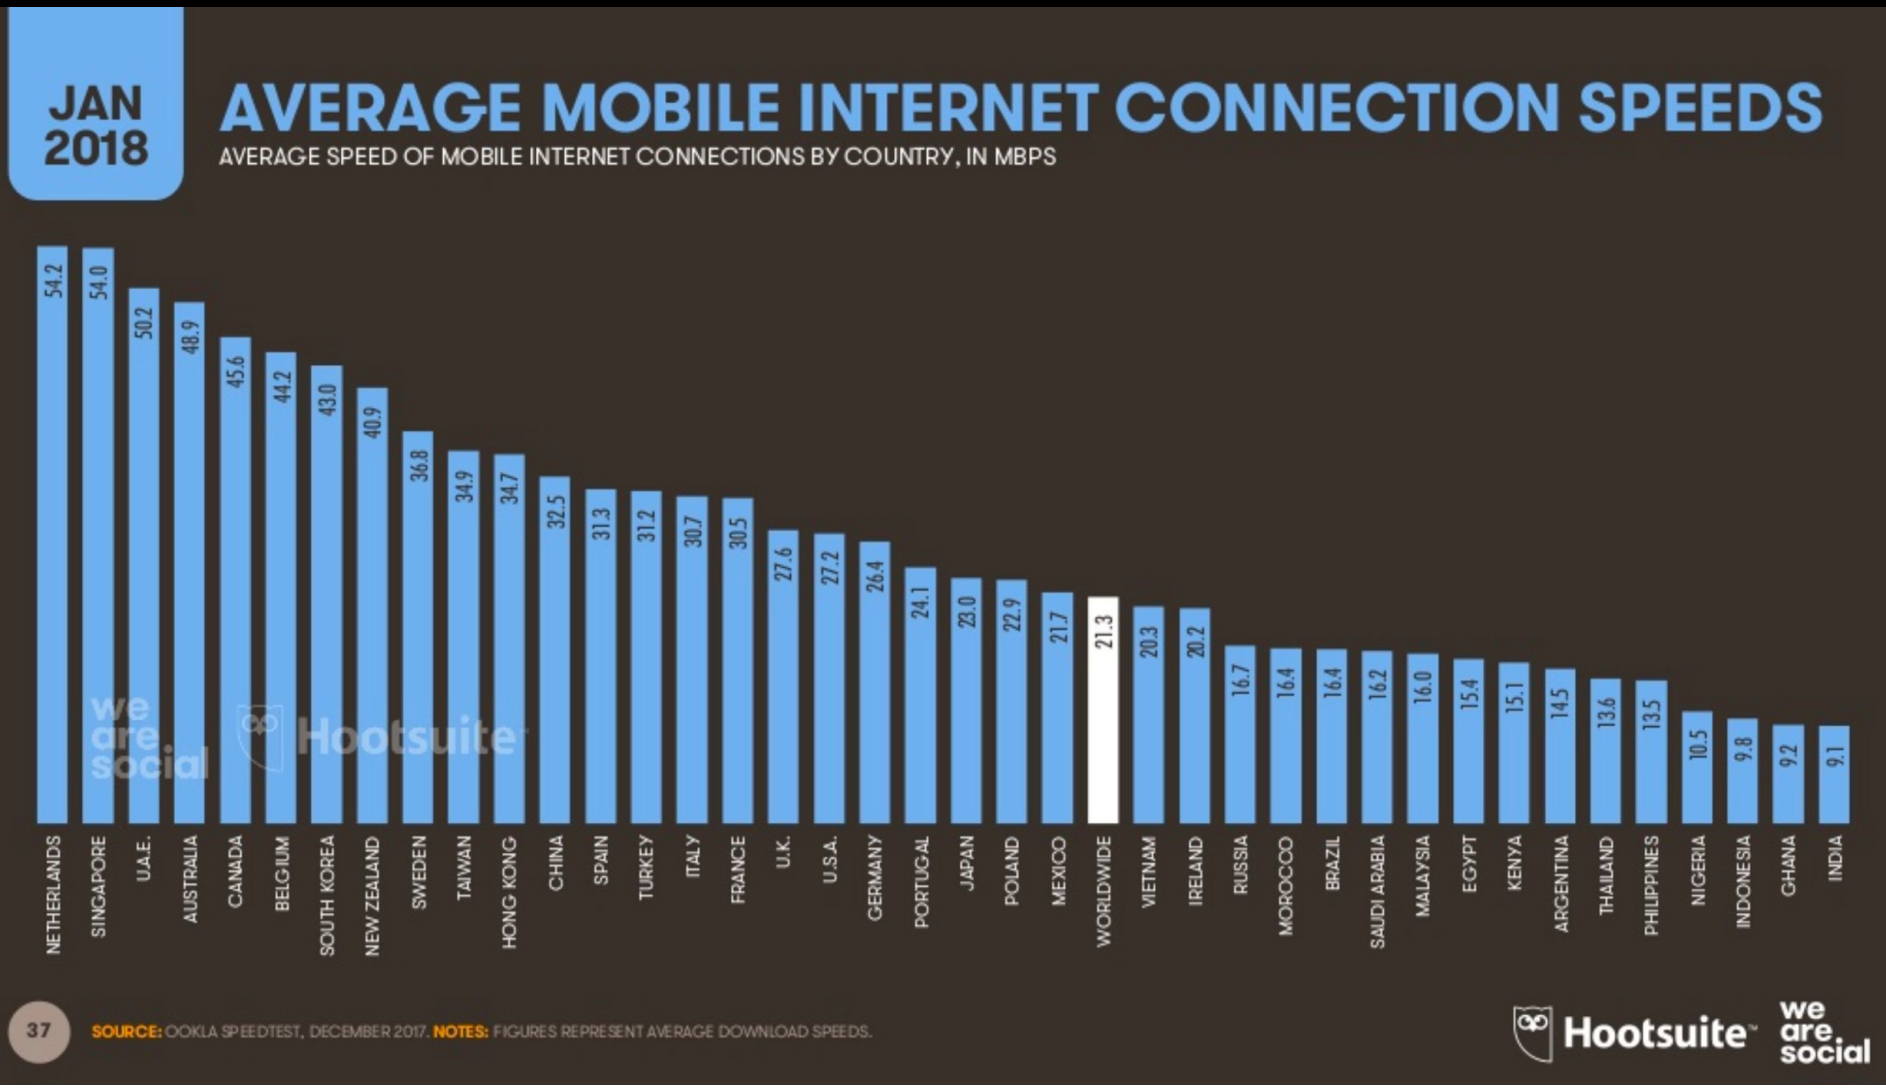
JAN 2018
AVERAGE MOBILE INTERNET CONNECTION SPEEDS
AVERAGE SPEED OF MOBILE INTERNET CONNECTIONS BY COUNTRY, IN MBPS
NETHERLANDS 54.2
SINGAPORE 54.0
U.A.E. 50.2
AUSTRALIA 48.9
CANADA 45.6
BELGIUM 44.2
SOUTH KOREA 43.0
NEW ZEALAND 40.9
SWEDEN 36.8
TAIWAN 34.9
HONG KONG 34.7
CHINA 32.5
SPAIN 31.3
TURKEY 31.2
ITALY 30.7
FRANCE 30.5
U.K. 27.6
U.S.A. 27.2
GERMANY 26.4
PORTUGAL 24.1
JAPAN 23.0
POLAND 22.9
MEXICO 21.7
WORLDWIDE 21.3
VIETNAM 20.3
IRELAND 20.2
RUSSIA 16.7
MOROCCO 16.4
BRAZIL 16.4
SAUDI ARABIA 16.2
MALAYSIA 16.0
EGYPT 15.4
KENYA 15.1
ARGENTINA 14.5
THAILAND 13.6
PHILIPPINES 13.5
NIGERIA 10.5
INDONESIA 9.8
GHANA 9.2
INDIA 9.1
we are social
Hootsuite
37
SOURCE: OOKLA SPEEDTEST, DECEMBER 2017. NOTES: FIGURES REPRESENT AVERAGE DOWNLOAD SPEEDS.
Hootsuite
we are social

Latency numbers every programmer should know (Jeff Dean)

L1 cache reference	0.5 ns	
Branch mispredict	5 ns	
L2 cache reference	7 ns	
Mutex lock/unlock	25 ns	
Main memory reference	100 ns	
Compress 1K bytes with Zippy	3,000 ns	
Send 2K bytes over 1 Gbps network	20,000 ns	
SSD random read	150,000 ns	
Read 1 MB sequentially from memory	250,000 ns	
Round trip within same datacenter	**500,000 ns**	**0.5 ms**
Read 1 MB sequentially from SSD*	1,000,000 ns	1 ms
Disk seek	10,000,000 ns	10 ms
Read 1 MB sequentially from disk	20,000,000 ns	20 ms
Send packet CA->Netherlands->CA	**150,000,000 ns**	**150 ms**

HighLoad. Лекция №2

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Input interpretation:

distance	from	Moscow
	to	San Francisco, California, United States

Result:

9472 km (kilometers)

Unit conversions:

5885 miles

9472 km (kilometers)

9.472×10^6 meters

5114 nmi (nautical miles)

Direct travel times: More

aircraft (550 mph)	10 hours 40 minutes
sound	7 hours 40 minutes
light in fiber	44.3 ms (milliseconds)
light in vacuum	31.6 ms (milliseconds)

(assuming constant-speed great-circle path)

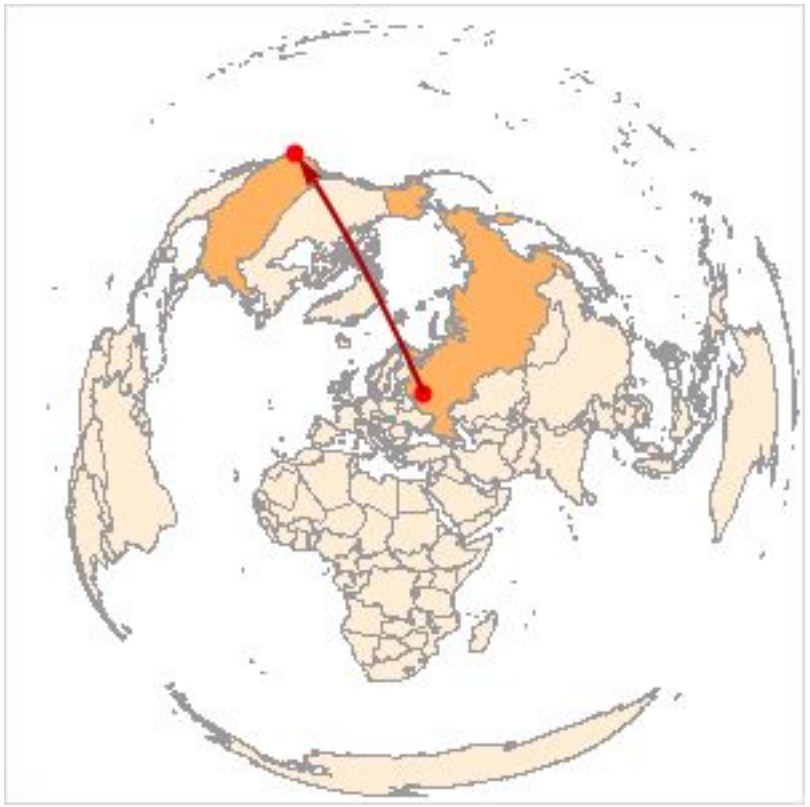

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Submarine Cable Map 2018

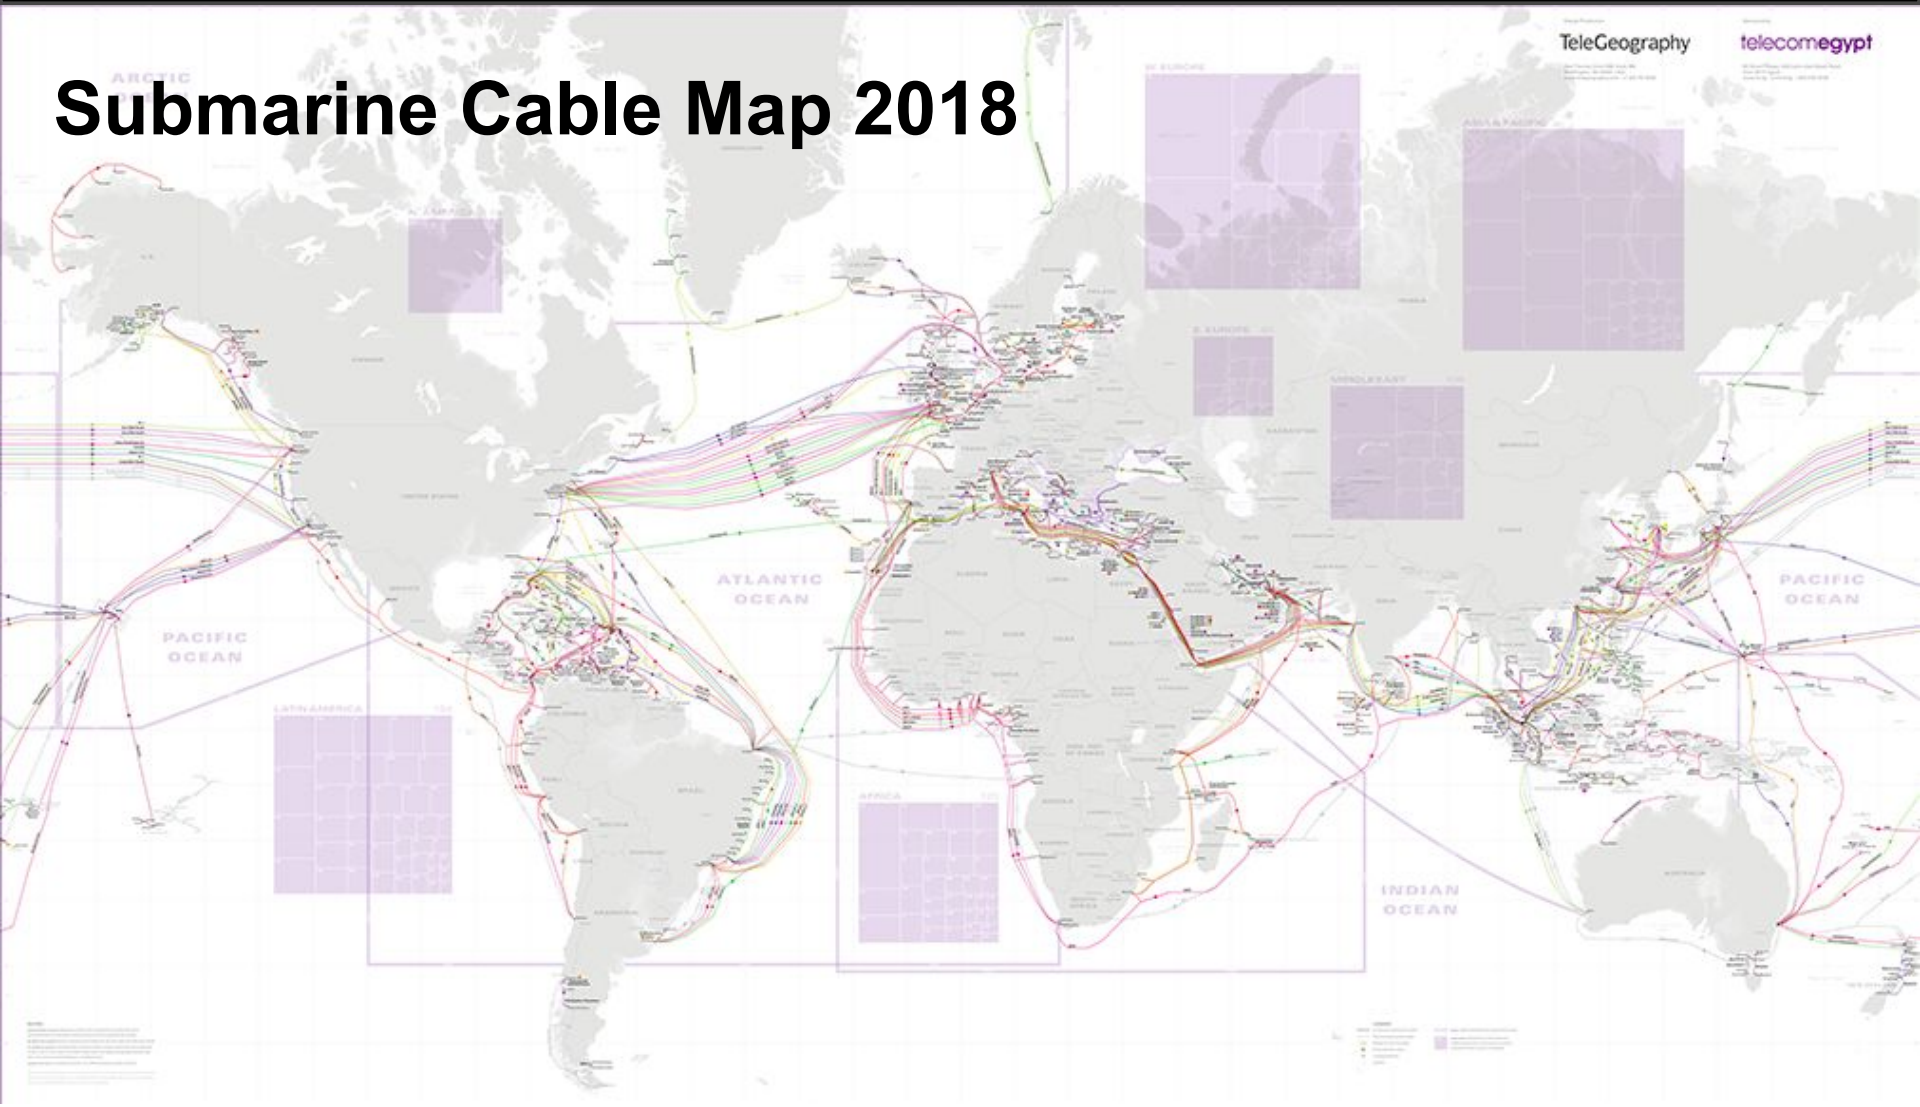

Сетевая задержка

Ping times between cities

	Amsterdam	Copenhagen	Frankfurt	Helsinki	London	Moscow	New York	San Jose	Tokyo
Amsterdam		153.86ms	14.20ms	29.89ms	22.96ms	47.30ms	96.42ms	226.86ms	270.79ms
Copenhagen	82.74ms		112.17ms	52.37ms	40.76ms	60.72ms	115.27ms	162.14ms	275.00ms
Frankfurt	16.50ms	123.25ms		47.21ms	24.63ms	63.82ms	96.70ms	167.43ms	267.34ms
Helsinki	30.06ms	52.32ms	47.16ms		34.95ms	18.31ms	131.37ms	203.62ms	303.50ms
London	22.89ms	90.72ms	25.24ms	34.15ms		62.98ms	77.56ms	142.09ms	270.28ms
Moscow	47.38ms	109.00ms	60.62ms	19.27ms	62.60ms		123.14ms	200.96ms	294.62ms
New York	93.54ms	174.28ms	93.81ms	127.96ms	76.60ms	121.55ms		79.99ms	174.69ms
San Jose	192.61ms	209.72ms	167.60ms	200.84ms	141.93ms	200.95ms	81.45ms		108.03ms
Tokyo	270.55ms	274.68ms	268.34ms	303.05ms	270.80ms	295.01ms	176.68ms	108.09ms	

HighLoad. Лекция №2


```
# host cas.sv.us.criteo.com
cas.sv.us.criteo.com has address 74.119.117.72

# whois 74.119.117.72
NetRange:       74.119.116.0 - 74.119.119.255
CIDR:           74.119.116.0/22
OriginAS:
NetName:        CRITEO-USA
NetHandle:      NET-74-119-116-0-1
Parent:         NET-74-0-0-0-0
NetType:        Direct Assignment
RegDate:        2009-11-05
Updated:        2012-03-02
Ref:            http://whois.arin.net/rest/net/NET-74-119-116-0-1

OrgName:        Criteo Corp.
OrgId:          CRITE-6
Address:        411 High Street
City:           Palo Alto
StateProv:      CA
PostalCode:     94301
Country:        US
RegDate:        2009-10-05
Updated:        2010-07-20
Ref:            http://whois.arin.net/rest/org/CRITE-6
```

Измеряем реальную задержку

```
# ping cas.sv.us.criteo.com

PING cas.sv.us.criteo.com (74.119.117.72) 56(84) bytes of data.
64 bytes from 74.119.117.72: icmp_seq=1 ttl=246 time=196 ms
64 bytes from 74.119.117.72: icmp_seq=2 ttl=246 time=196 ms
64 bytes from 74.119.117.72: icmp_seq=3 ttl=246 time=196 ms
64 bytes from 74.119.117.72: icmp_seq=4 ttl=246 time=196 ms
64 bytes from 74.119.117.72: icmp_seq=5 ttl=246 time=196 ms
64 bytes from 74.119.117.72: icmp_seq=6 ttl=246 time=196 ms

--- cas.sv.us.criteo.com ping statistics ---
7 packets transmitted, 6 received, 14% packet loss, time 6069ms
rtt min/avg/max/mdev = 196.745/196.769/196.806/0.256 ms
```

Анализируем маршрут

```
# traceroute cas.sv.us.criteo.com -q 1

traceroute to cas.sv.us.criteo.com (74.119.117.72), 30 hops max, 60 byte packets
 1  94.100.178.2 (94.100.178.2)  0.408 ms
 2  188.254.103.197 (188.254.103.197)  8.875 ms
 3  46.61.141.133 (46.61.141.133)  51.420 ms
 4  ethernet10-3.ar4.fra4.gblx.net (64.211.193.169)  45.973 ms
 5  ae8.scr4.FRA4.gblx.net (67.16.145.241)  51.687 ms
 6  po3-20G.ar2.SNV2.gblx.net (67.16.139.98)  195.523 ms
 7  CRITEO-CORP.GigabitEthernet4-18.ar2.SNV2.gblx.net (206.41.25.26)  202.311 ms
 8  *
 9  *
10  *
11  *
12  *
13  *
14  *
15  *
```


Traceroutes from Moscow, RU to Yaroslavl, RU
Normal
Abnormal
Stockholm, SE
Yaroslavl, RU
Moscow, RU
Frankfurt, DE
China Telecom
Dyn

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Looking Glass

Каталоги:

- http://www.traceroute.net.ru/
- http://www.lookinglass.org/
- http://www.bgp4.as/looking-glasses
- http://www.bgp4.net/lg

Примеры:

- http://lg.vk.com/
- http://lg.megafon.ru/
- http://lg.transtk.ru/
- http://lg.retn.net/
- http://lg.he.net/
- http://www.msk-ix.ru/network/lookingglass.html
- http://www.ris.ripe.net/cgi-bin/lg/index.cgi

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Задержки внутри ДЦ (города)

- Низкие только на первый взгляд
- Для задач с интенсивным синхронным обменом данными по сети весьма ощутимы

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

IPv6 adoption (Google)

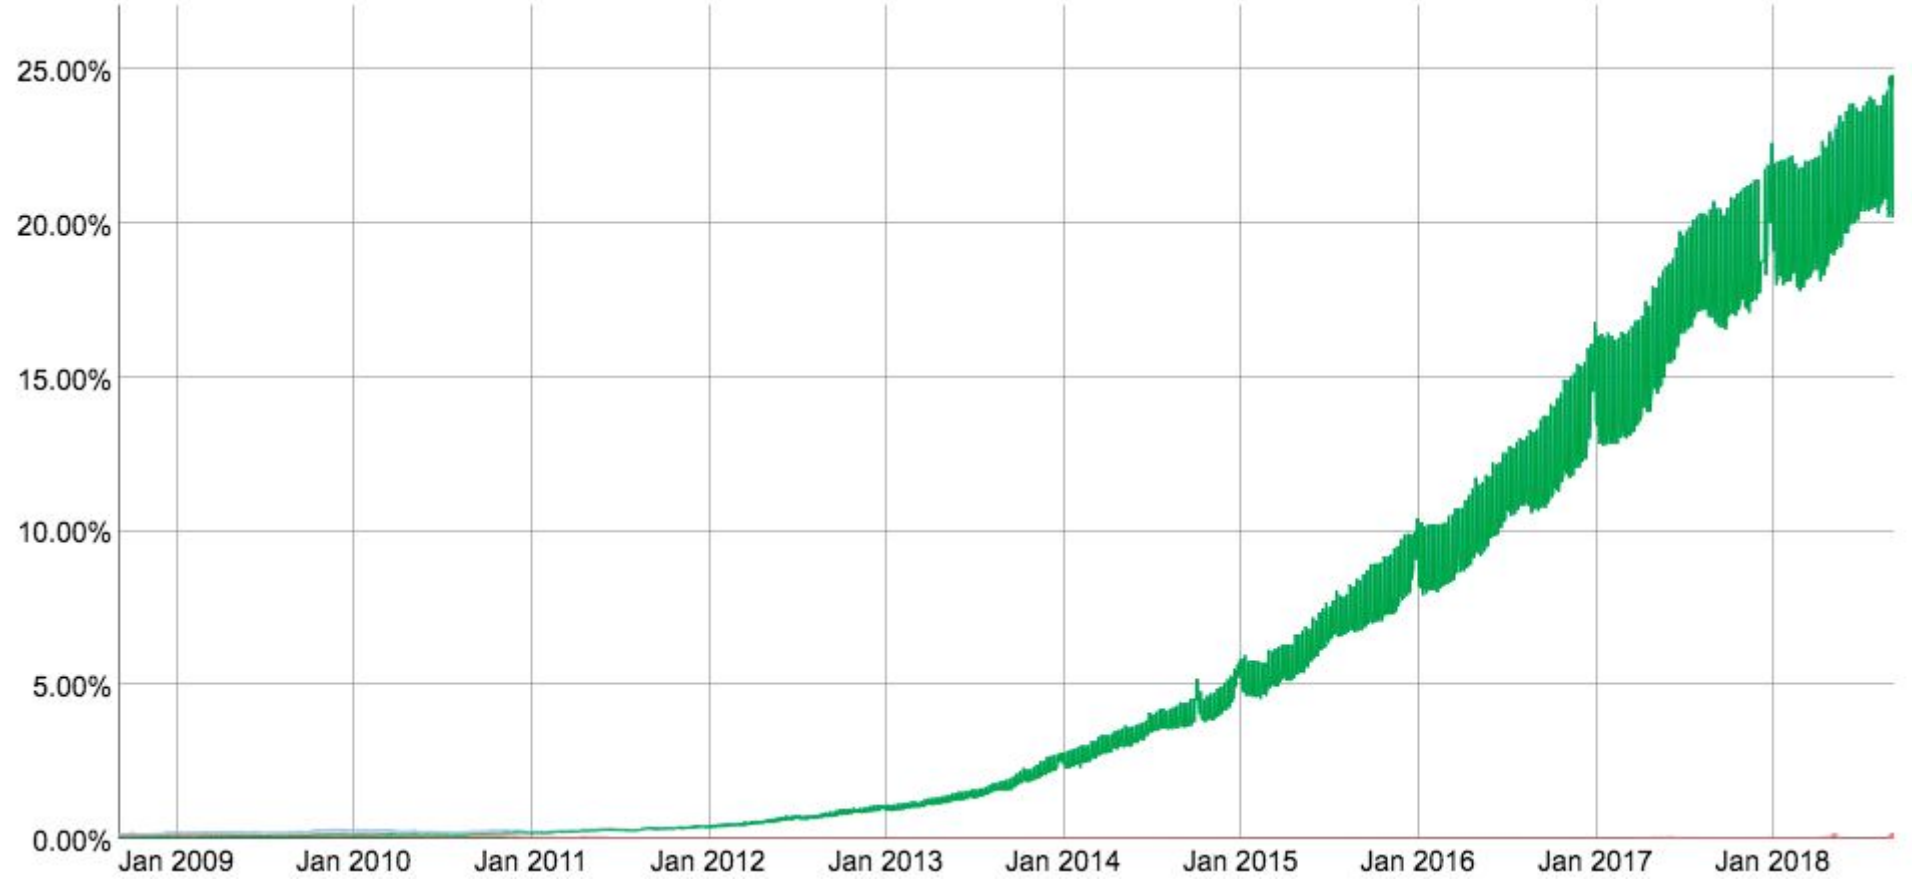

Per Country IPv6 adoption (Google)

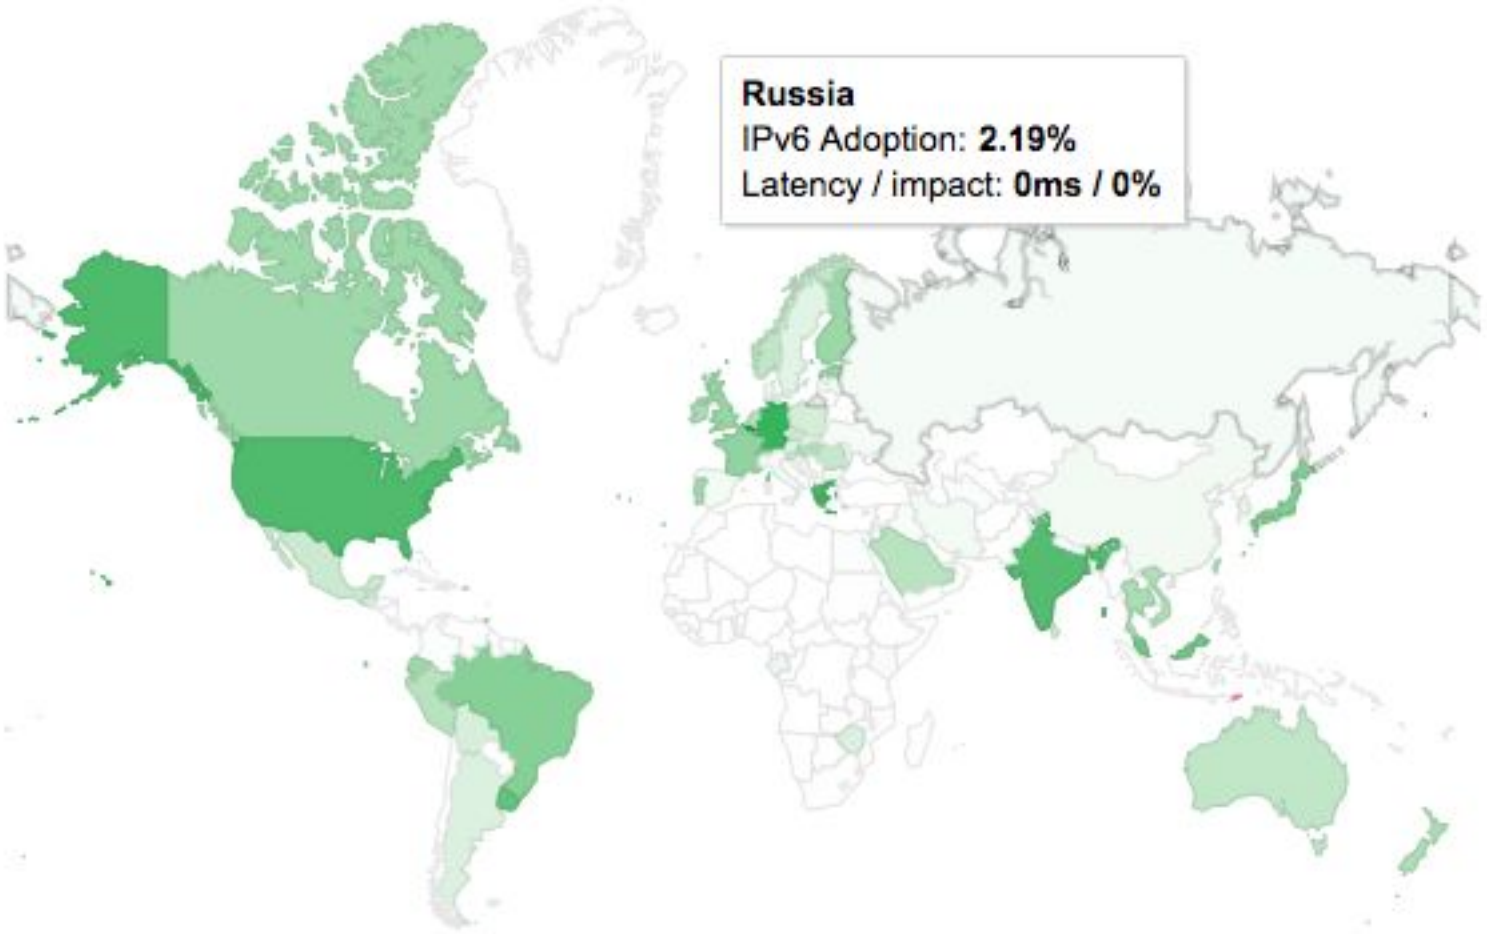

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Протокол TCP/IP (version 4)

Модель OSI
(Open System Interconnection Reference Model)

OSI Model			
	Data unit	Layer	Function
Host layers	Data	7. Application	Network process to application
		6. Presentation	Data representation, encryption and decryption, convert machine dependent data to machine independent data
		5. Session	Interhost communication, managing sessions between applications
	Segments	4. Transport	End-to-end connections, reliability and flow control
Media layers	Packet/Datagram	3. Network	Path determination and logical addressing
	Frame	2. Data link	Physical addressing
	Bit	1. Physical	Media, signal and binary transmission

Модель OSI в применении к TCP/IP

7	**Application**	e.g. HTTP, SMTP, SNMP, FTP, Telnet, SSH and Scp, NFS, RTSP etc.
6	**Presentation**	e.g. XDR, ASN.1, SMB, AFP etc.
5	**Session**	e.g. TLS, SSH, ISO 8327 / CCITT X.225, RPC, NetBIOS, ASP etc.
4	**Transport**	e.g. TCP, UDP, RTP, SCTP, SPX, ATP etc.
3	**Network**	e.g. IP/IPv6, ICMP, IGMP, X.25, CLNP, ARP, RARP, BGP, OSPF, RIP, IPX, DDP etc.
2	**Data Link**	e.g. Ethernet, Token ring, PPP, HDLC, Frame relay, ISDN, ATM, 802.11 Wi-Fi, FDDI etc.
1	**Physical**	e.g. wire, radio, fiber optic etc.

Модель OSI в применении к TCP/IP

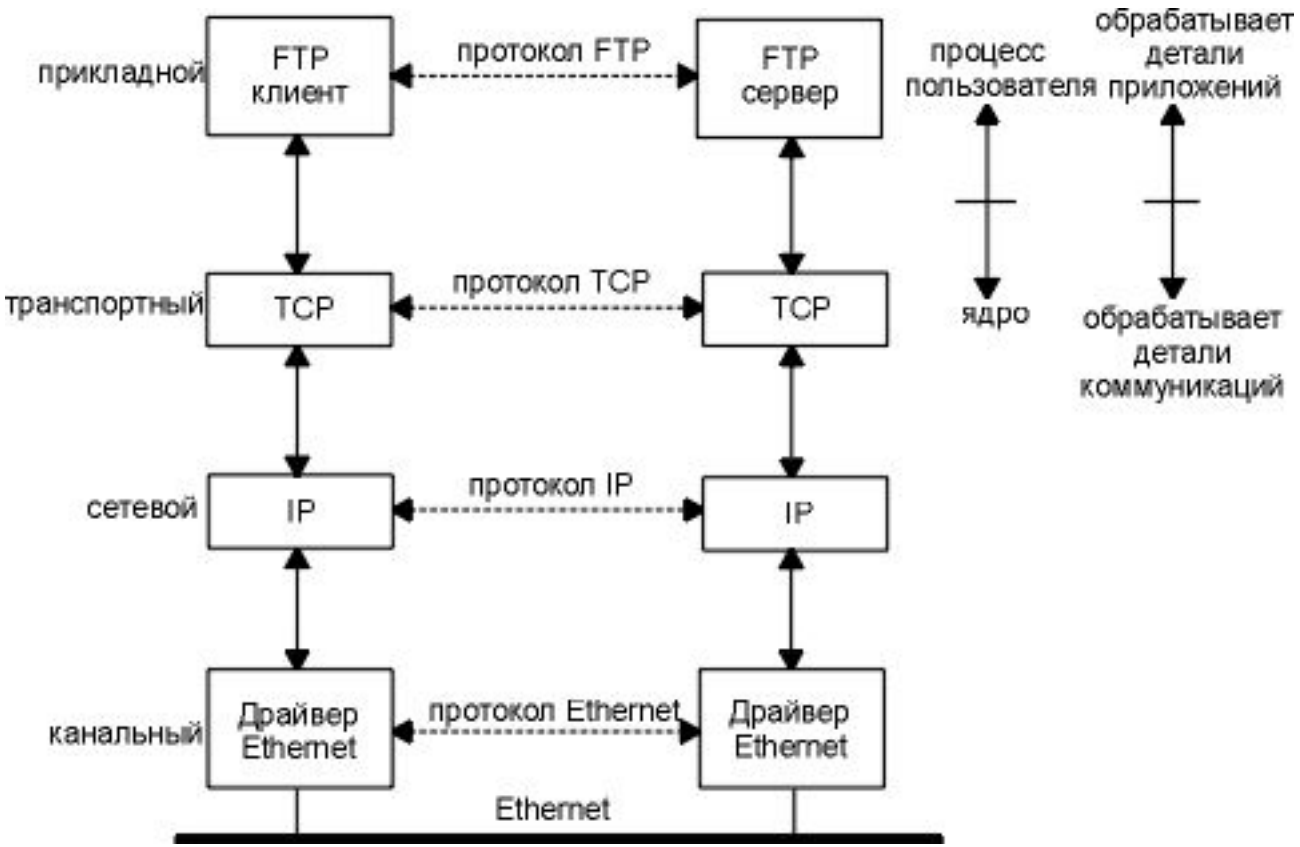

HighLoad. Лекция №2

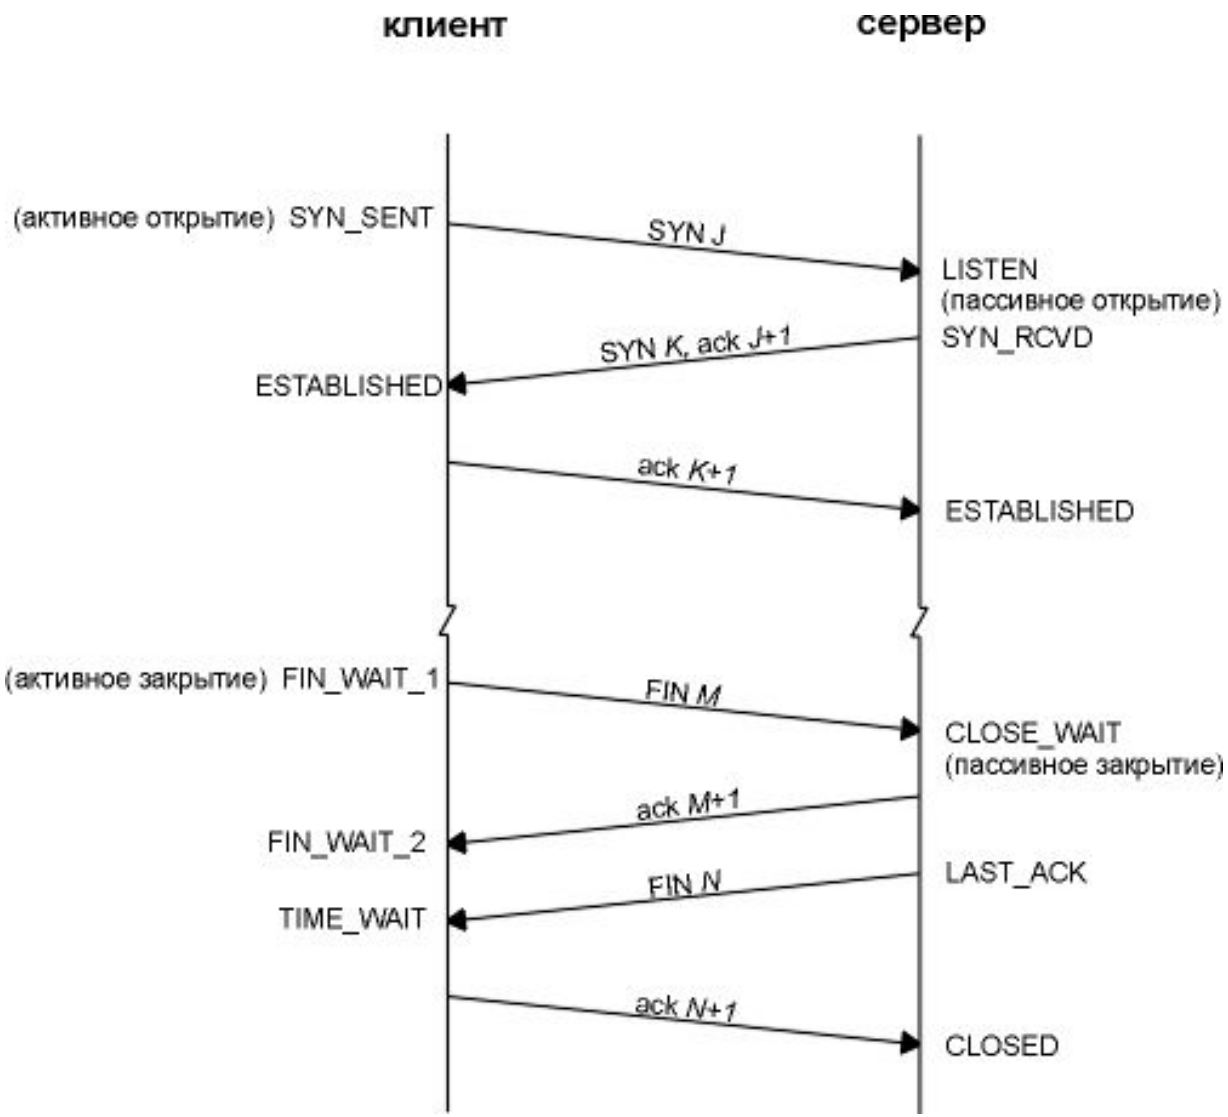

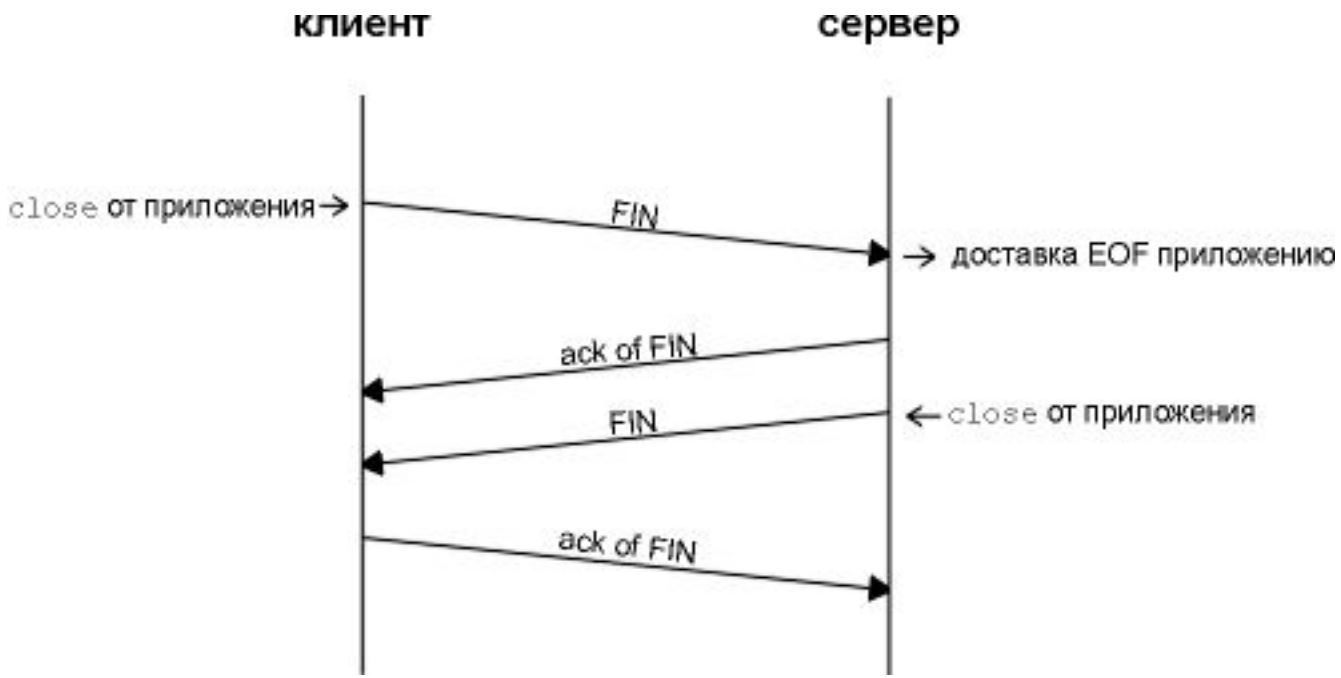
клиент
сервер
close от приложения
FIN
доставка EOF приложению
ack of FIN
close от приложения
FIN
ack of FIN

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

TCP window scaling

Алгоритм Slow Start:

- Размер окна увеличивается на MSS после каждого ACK
- Размер окна удваивается на RTT
- В случае потери пакета начинаем с начала
- Есть верхнее ограничение размера окна с обоих сторон

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

TCP window scaling

Альтернативы:

- BBR - алгоритм учитывающий задержки (Google)

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Потеря пакетов (packet loss)

Повторная отправка пакета:

- TCP: retransmit timeout = 3 s
- DNS: retransmit timeout = 5 s

Последствия:

- Ощутимая задержка для пользователя
- Повышенная нагрузка на сервис

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Потеря пакетов внутри ДЦ

- Рост потребления ресурсов синхронными сервисами
- Каскадное увеличение нагрузки из-за ретрансмиттов

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Проблема медленных соединений

- Занимают ресурсы ОС
- Занимают память в веб-сервере
- Блокируют работу синхронного процесса или потока
- Могут использоваться как метод DDoS-атаки

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Недостатки TCP/IP

- Большое время установления соединения
- Относительно дорогое создание соединения
- Долгая реакция на потерю пакета
- Медленный разгон window size
- Высокая нагрузка на ОС при обработке большого количества активных соединений

Применение UDP

Достоинства:

- Неблокирующая отправка
- Низкая нагрузка на ОС
- Возможность многоадресной передачи

Недостатки:

- Ненадежный
- Неупорядоченный
- Необходимо следить за нагрузкой на сеть

Применения:

- Сбор статистики
- Уведомления
- Специализированные протоколы

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Технология: Point-of-Presence

- Прокси-сервер (NAT) рядом с пользователем
- Прокси-сервер держит постоянное соединение с ДЦ
- Окно передачи разогнанное
- Скорость выше чем при подключении без прокси

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Тюнинг TCP

/etc/sysctl.conf:

```
net.ipv4.tcp_max_syn_backlog = 1024
net.ipv4.tcp_max_orphans = 65536
net.ipv4.tcp_max_tw_buckets = 180000

net.ipv4.tcp_max_syn_backlog = 32768
net.ipv4.tcp_max_orphans = 131072
net.ipv4.tcp_max_tw_buckets = 1800000
```

/usr/src/linux/Documentation/networking/ip-sysctl.txt

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Тюнинг UDP

/etc/sysctl.conf:

```
net.core.rmem_default = 129024
net.core.wmem_default = 129024
net.core.rmem_max = 131071
net.core.wmem_max = 131071
net.ipv4.udp_mem = 387840      517120     775680
```

/usr/src/linux/Documentation/networking/ip-sysctl.txt

МГТУ им. Н.Э. Баумана ТЕХНОПАРК Mail.Ru Group

Список литературы

1. Netflix CDN
   https://events.yandex.ru/lib/talks/2396/
2. How to receive a million packets per second
   https://blog.cloudflare.com/how-to-receive-a-million-packets/
3. Тюнинг сетевого стека в Одноклассниках
   https://habrahabr.ru/company/odnoklassniki/blog/266005/
4. Submarine Cable Map 2018
   https://submarine-cable-map-2018.telegeography.com/

СПАСИБО ЗА ВНИМАНИЕ

Быков Александр

bykov@corp.mail.ru