

# Митап Альфа-Банка Backend Stories 4.0

9 августа в 19:00

# ОТКАЗОУСТОЙЧИВОСТЬ В БОЛЬШОМ ИНТЕРНЕТЕ

---

A

# ABOUT ME

---

- Руководитель Центра компетенций Java в Альфа-Банке
- Был разработчиком и системным администратором
- Очень много занимаюсь наймом
- Считаю, хороший разработчик должен отвечать не только за код (devops и все такое :)

# DISCLAIMER

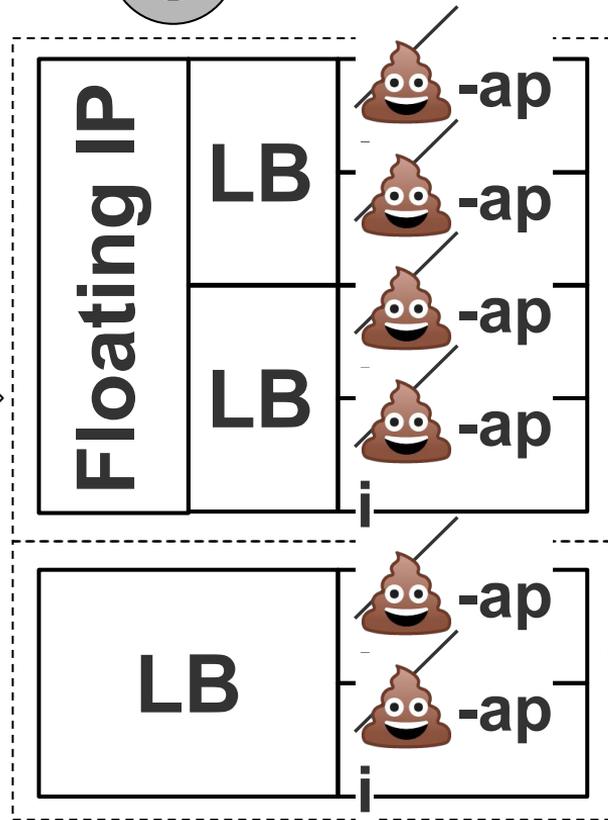
---

- Доклад совсем не про dev
- И не про формулы, девятки, SLA и т.д.
- Будет много капитанства про сети и протоколы
- Language is смешанный
- Не все термины взяты из RFC
- Надо знать про IP-адреса, маски и сети

# THE PROBLEM



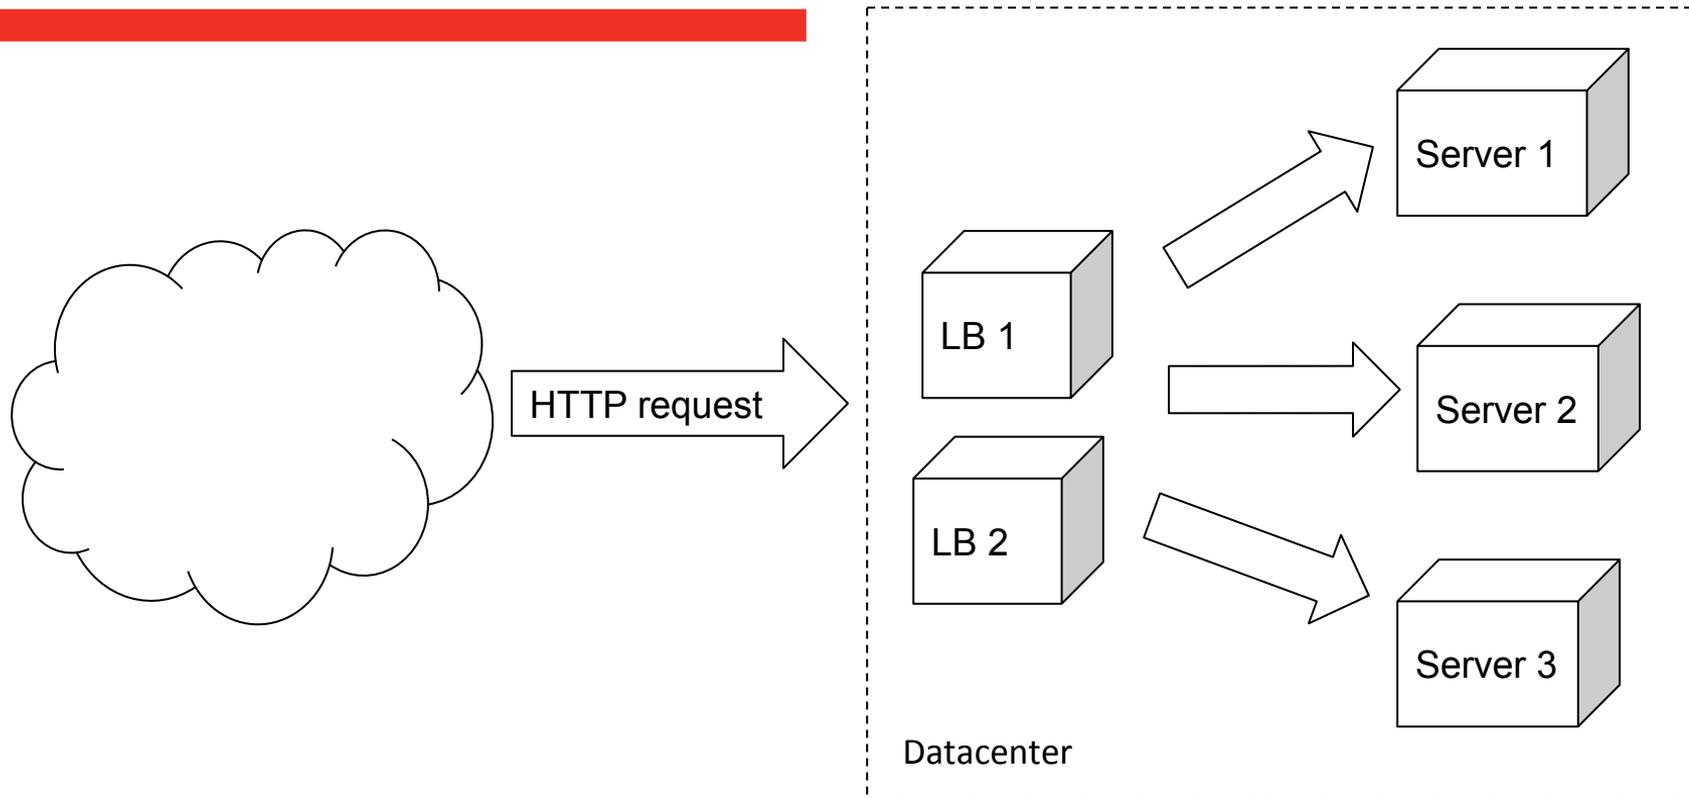
happy dev/ops



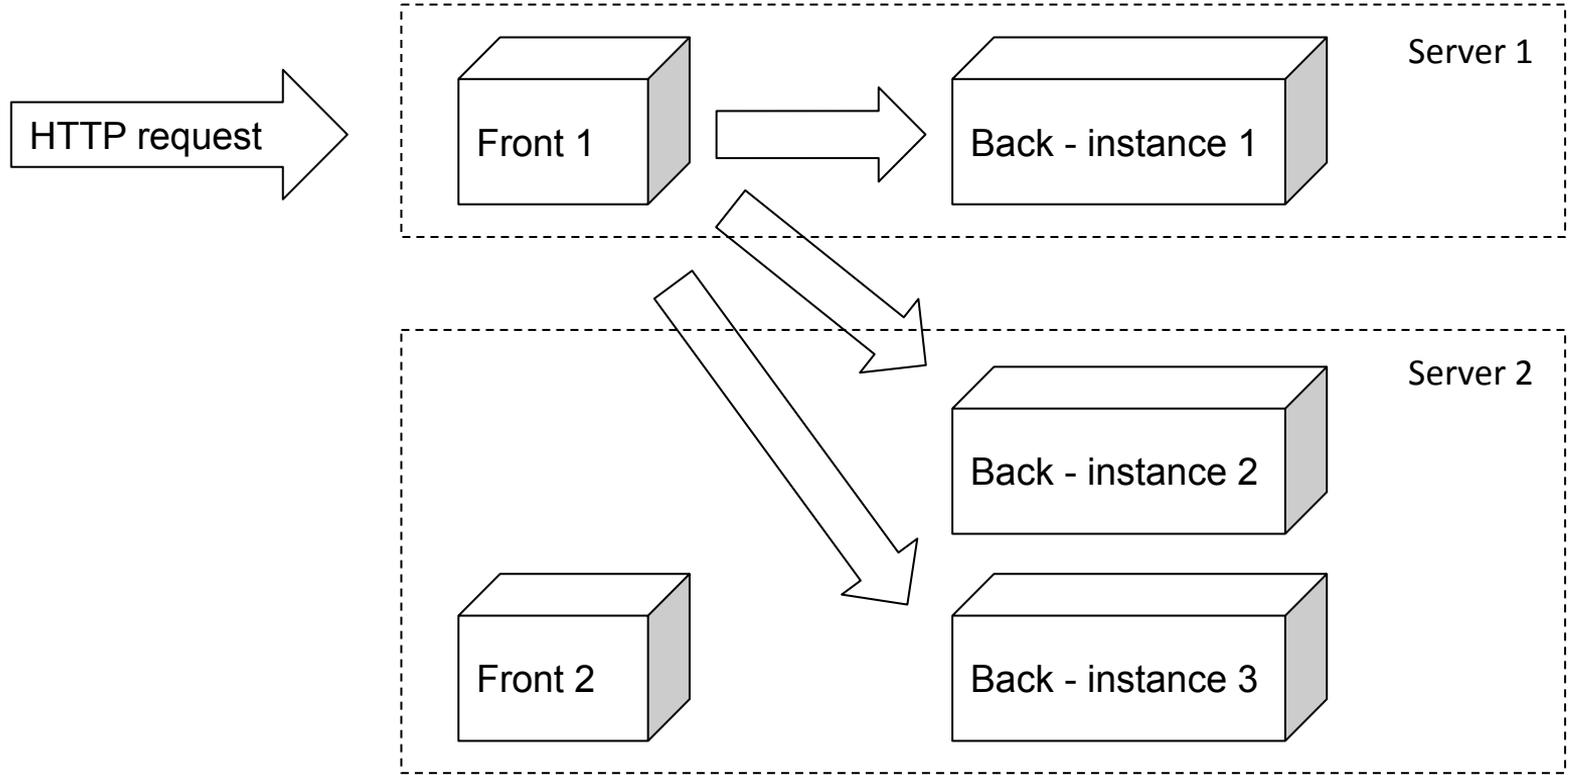
# О ЧЕМ МЫ НЕ БУДЕМ ГОВОРИТЬ

---

# SERVER BALANCING



# SERVICE DISCOVERY



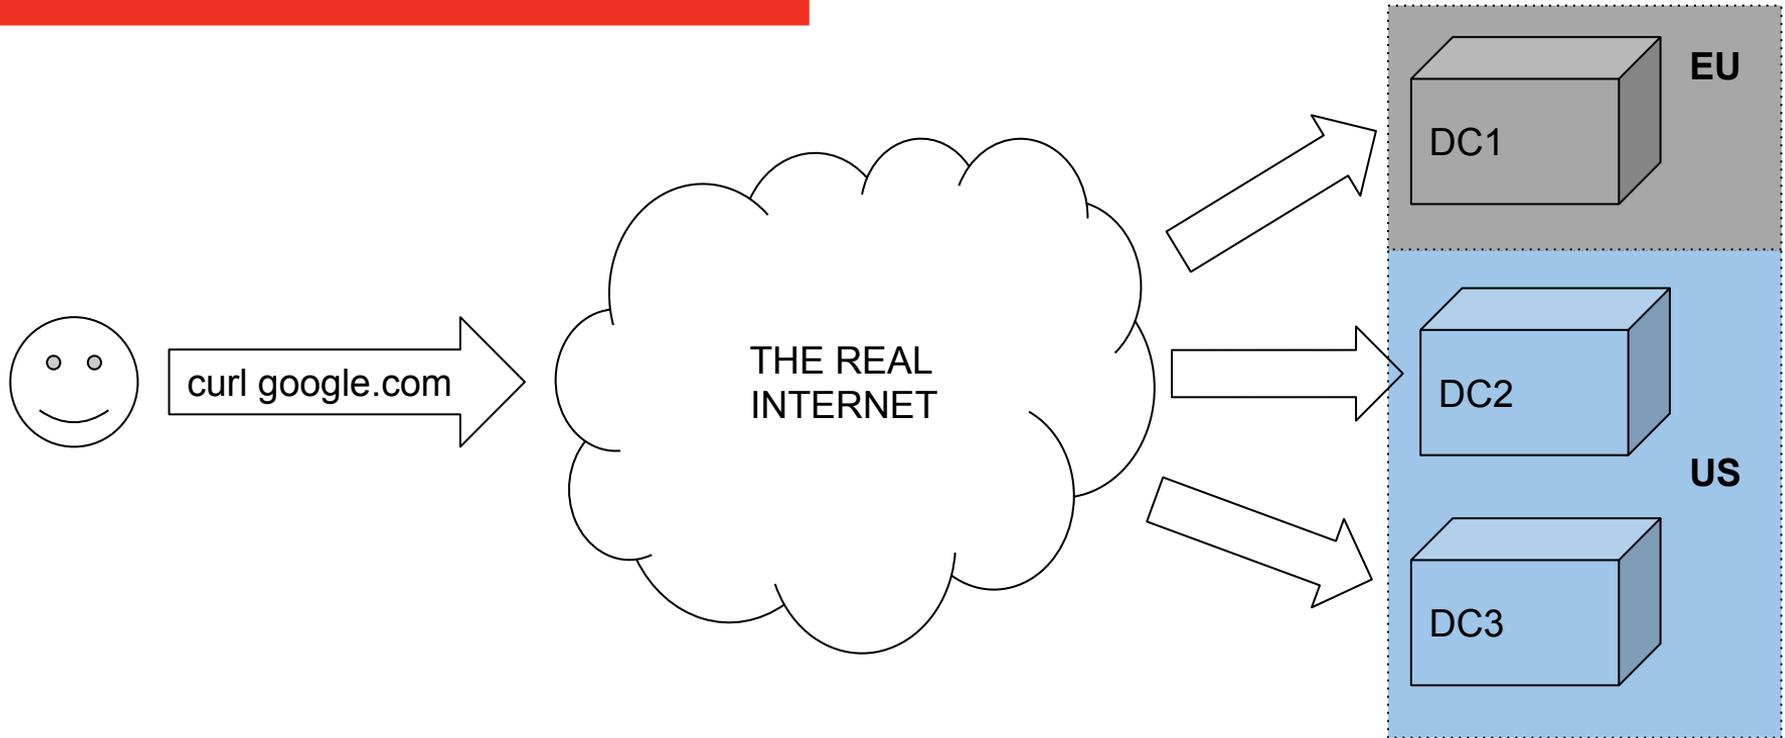
**А БУДЕМ ПРО**

---

**A**

---

# INTERNET ROUTING & BALANCING



# INTERNET ROUTING & BALANCING

---

- Round robin DNS
- Geo DNS
- BGP Anycast routing
- Multihome BGP
- Всякое разное

# ОГЛАВЛЕНИЕ

---

1. DNS WTF
2. Round robin DNS
3. Geo DNS
4. BGP WTF
5. BGP Anycast routing
6. Multihome BGP
7. Всякое разное

# Зачем нужен DNS

drive.google.com

- symbol name
- server name
- host name
- domain name
- fully qualified domain name

резолвинг

173.194.220.194

- IP-address

2a00:1450:4010:c09::c2

- IPv6-address



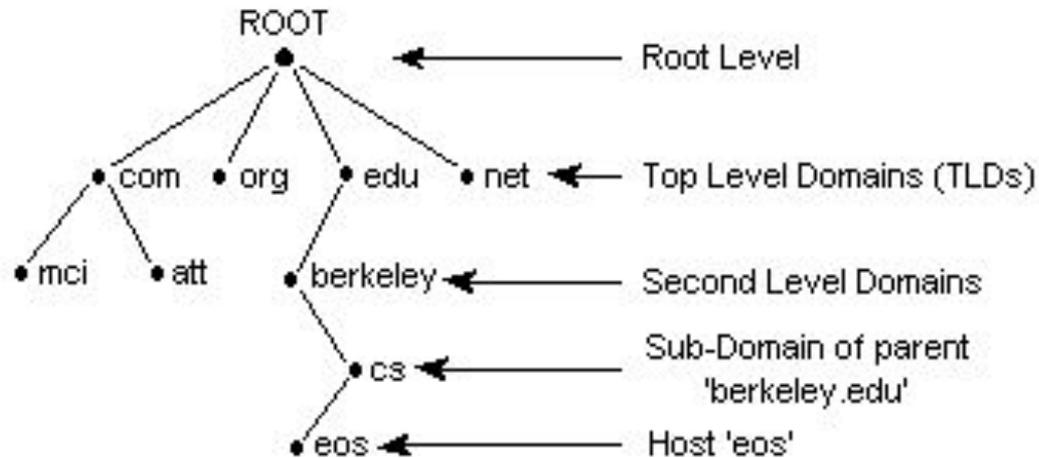
drive.google.com?

173.194.220.194

DNS server  
DNS resolver

# DNS is a tree

DNS Hierarchy



<https://www.inetdaemon.com/tutorials/internet/dns/operation/hierarchy.shtml>

# DNS entities

---

1. domain
2. zone
3. host

Вопрос: **google.com** - это что?

Ответ: все сразу

# DNS entities

---

1. google.com domain = google.com + drive.google.com + ...
2. google.com zone = google.com only
3. google.com host = zone record (type A), just IP-address

Вопрос: **www.google.com** - это что?

Ответ: просто хост

# DNS zone & records

- DNS-зона, обычно, хранится в файле и состоит из записей
- Файл зоны **google.com** - **/etc/named/master/google.com**
- Запись **drive.google.com** состоит из:

drive	CNAME	300	wide-docs.l.google.com.
-------	-------	-----	-------------------------

Name	Type	TTL	Value
------	------	-----	-------

wide-docs	A	300	185.143.173.149
-----------	---	-----	-----------------

Name	Type	TTL	Value
------	------	-----	-------

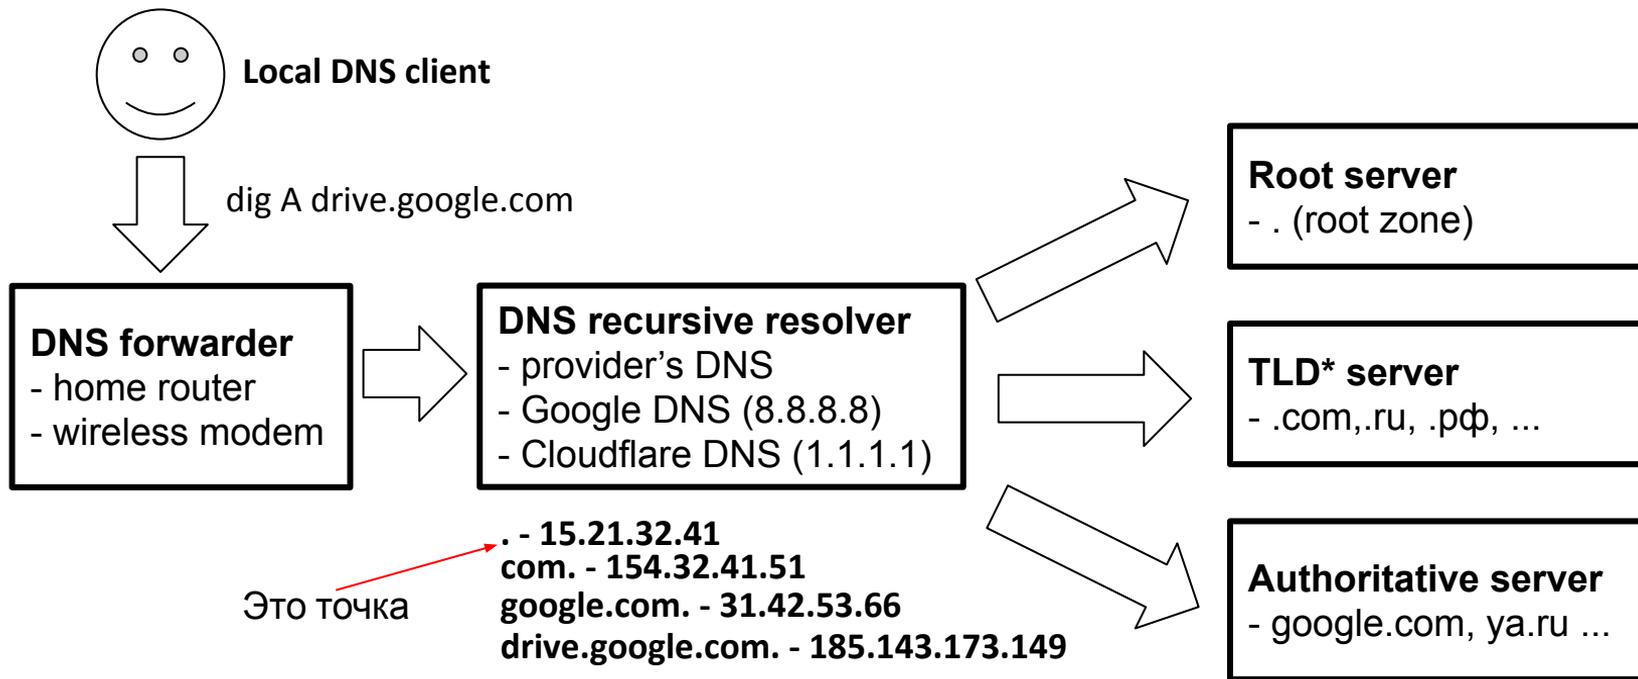
# DNS record types

---

Types:

- **A - IP-address (host)**
- CNAME - Alias
- NS - Authoritative name server
- MX - Mail receiver
- TXT - text comment
- ...

# DNS resolving and server types



\* TLD - top level domain

<https://www.cloudflare.com/learning/dns/dns-server-types/>

# DNS root servers

- **13** root nameservers total (A-Root ... M-Root)
- As of 2019-07-14, the root server system consists of **997** instances operated by the **12** independent root server operators
- Thanks to BGP Anycast :)
- No roots - no Internet
- И в России есть нюансы

<https://root-servers.org/>

[https://en.wikipedia.org/wiki/Root\\_name\\_server](https://en.wikipedia.org/wiki/Root_name_server)

Картинка с <http://casinoyay.com/kak-uskolznut-ot-vsevidyashhego-ok-a-roskomnadzora/>



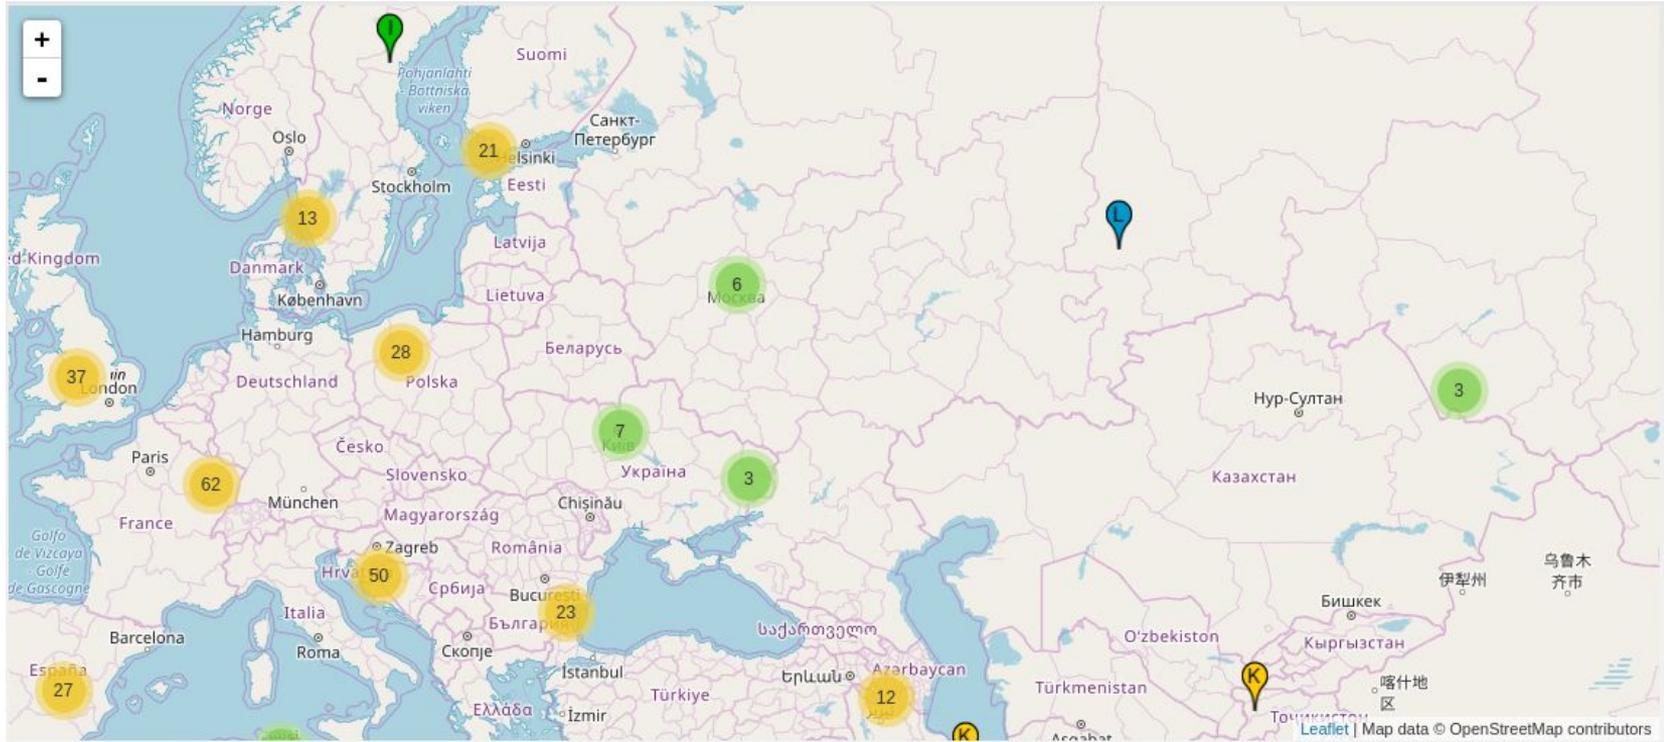
# DNS root servers

---

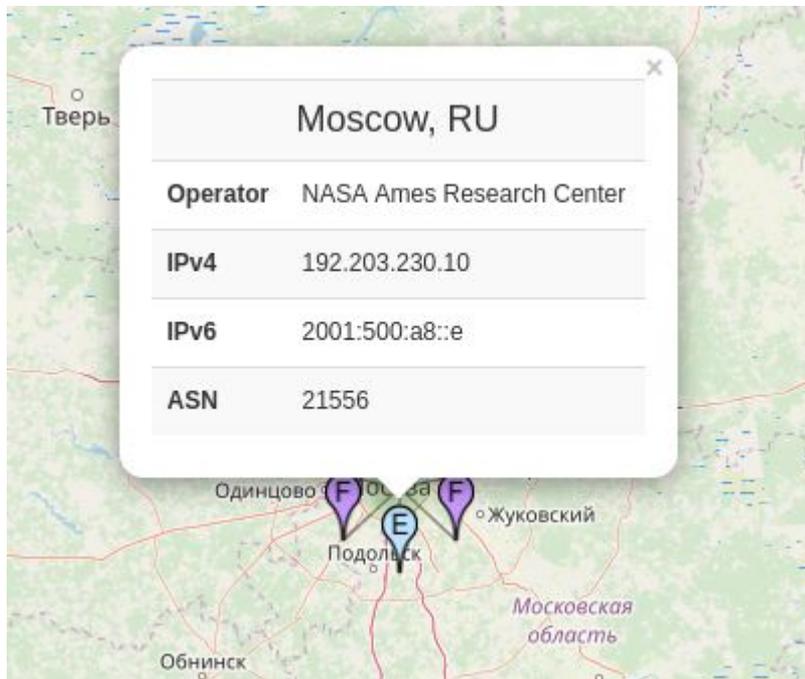
На 22.05.2018 в России размещено 11 реплик корневых серверов DNS, в том числе:

- f.root (Москва — 2 шт.);
- i.root (Санкт-Петербург);
- j.root (Москва, Санкт-Петербург);
- k.root (Москва, Санкт-Петербург, Новосибирск);
- l.root (Москва, Ростов-на-Дону, Екатеринбург).

# DNS root servers



# DNS root servers



Картинка с <https://roskomsvoboda.org/33839/>



И это тоже влияет на  
отказоустойчивость

# ОГЛАВЛЕНИЕ

---

1. DNS WTF
2. Round robin DNS
3. Geo DNS
4. BGP WTF
5. BGP Anycast routing
6. Multihome BGP
7. Всякое разное

# Round robin DNS

---

alfaconf.pro zone:

- alfaconf.pro A 3600 185.143.173.130
- alfaconf.pro A 3600 185.143.173.149
- alfaconf.pro A 3600 185.143.173.151

# Round robin DNS demo

---

1. Настройка round-robin в DNS-зоне
2. Резолвинг всех хостов, TTL (dig)
3. Выбор одного из хостов (ping)
4. Системный локальный кэш MacOS
5. Chrome & Firefox
6. Особенности кэшей :)

# Local DNS resolver caching

---

DNS-записи кэшируются на клиенте и промежуточных DNS-резолверах

Сброс локального кэша для macOS:

```
sudo killall -HUP mDNSResponder  
sudo killall -INFO mDNSResponder
```

Java DNS resolving - работает как надо:

```
InetAddress address = InetAddress.getByName("alfaconf.pro");
```

# Browser DNS caching

---

Настройки в Chrome

- `chrome://net-internals/#dns`

Настройки в Firefox

- `about:config`
  - `network.dnsCache*`

Не забываем про чистку браузерных кэшей

# Особенности Round robin DNS

---

- Пользователь ходит на один IP в течение TTL
- Если этот IP вылетел, то сервис не доступен в течение TTL
- Нет инвалидации DNS кэшей :)
- Нет гарантии решения проблемы при обновлении кэша
- Это в целом проблемы DNS (к Geo DNS тоже относится)
- RR DNS в чистом виде не дает availability

# Плюшки RR DNS

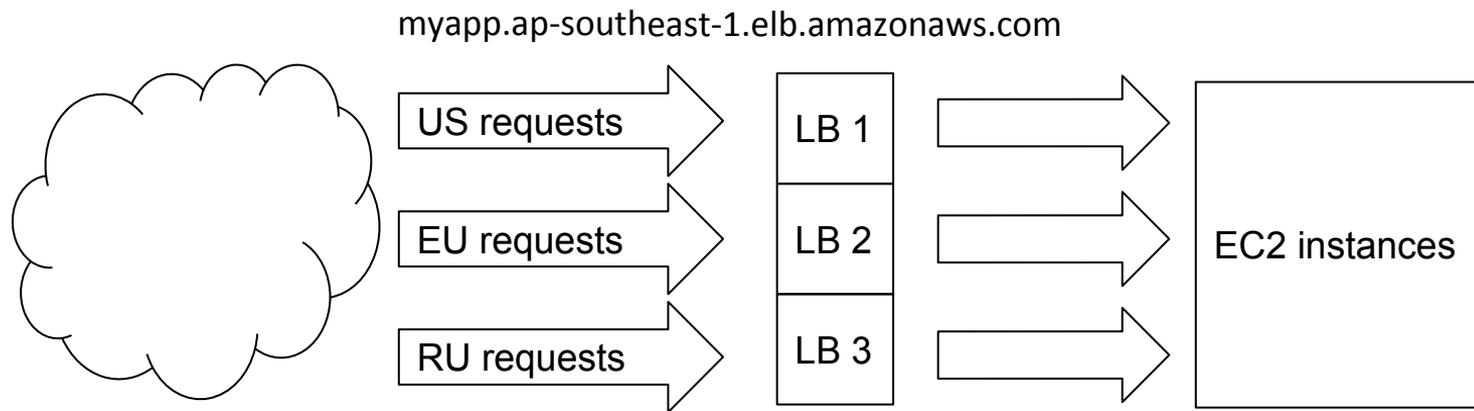
---

- Простота
- RR DNS + алертинг + API у DNS-провайдера = ~availability
- RR DNS + алертинг + быстрый ввод IP = ~availability
- RR DNS хорош для масштабирования нагрузки на LB
- Elastic Load Balancer (ELB - AWS) - использует именно RR DNS

# RR DNS - ELB

TTL у ELB = 60 секунд

## Scalability, not Availability



# When RR DNS is not enough

---

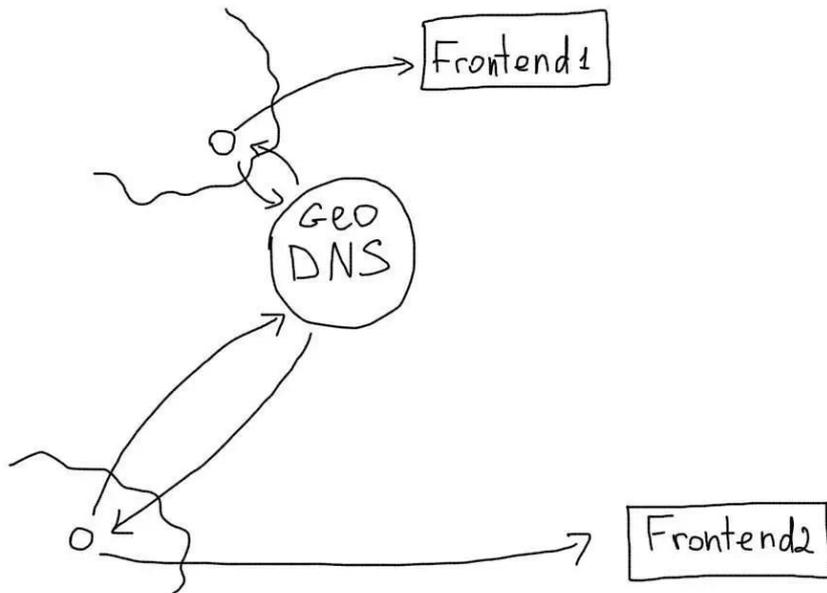
- round robin is too simple

# ОГЛАВЛЕНИЕ

---

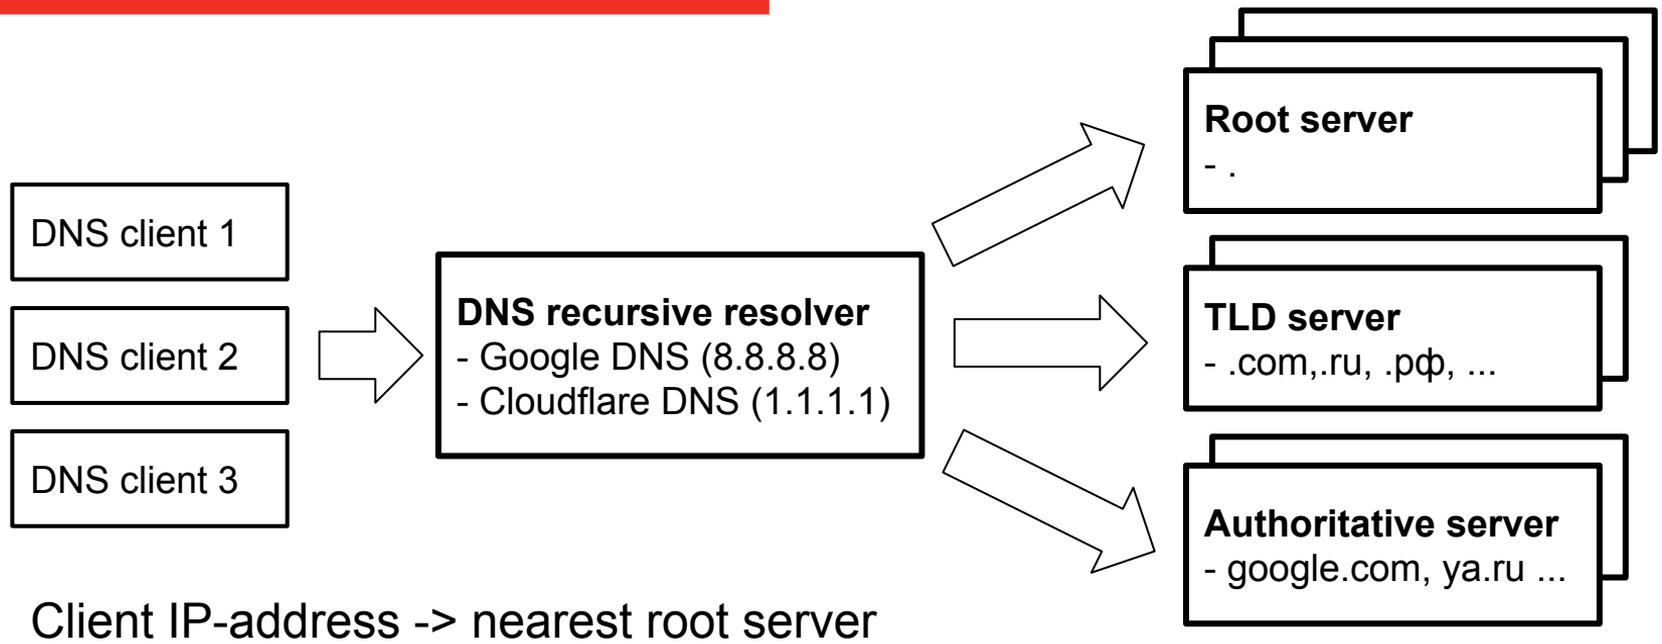
1. DNS WTF
2. Round robin DNS
3. **Geo DNS**
4. BGP WTF
5. BGP Anycast routing
6. Multihome BGP
7. Всякое разное

# GEO DNS



Картинка с <https://ruhighload.com/dns+балансировка+>

# GEO DNS resolving



[https://en.wikipedia.org/wiki/EDNS\\_Client\\_Subnet](https://en.wikipedia.org/wiki/EDNS_Client_Subnet)  
<https://developers.google.com/speed/public-dns/faq>

# When DNS is not enough



Public DNS servers:

- Google 8.8.8.8, 8.8.4.4
- Cloudflare 1.1.1.1
- OpenDNS
- root servers

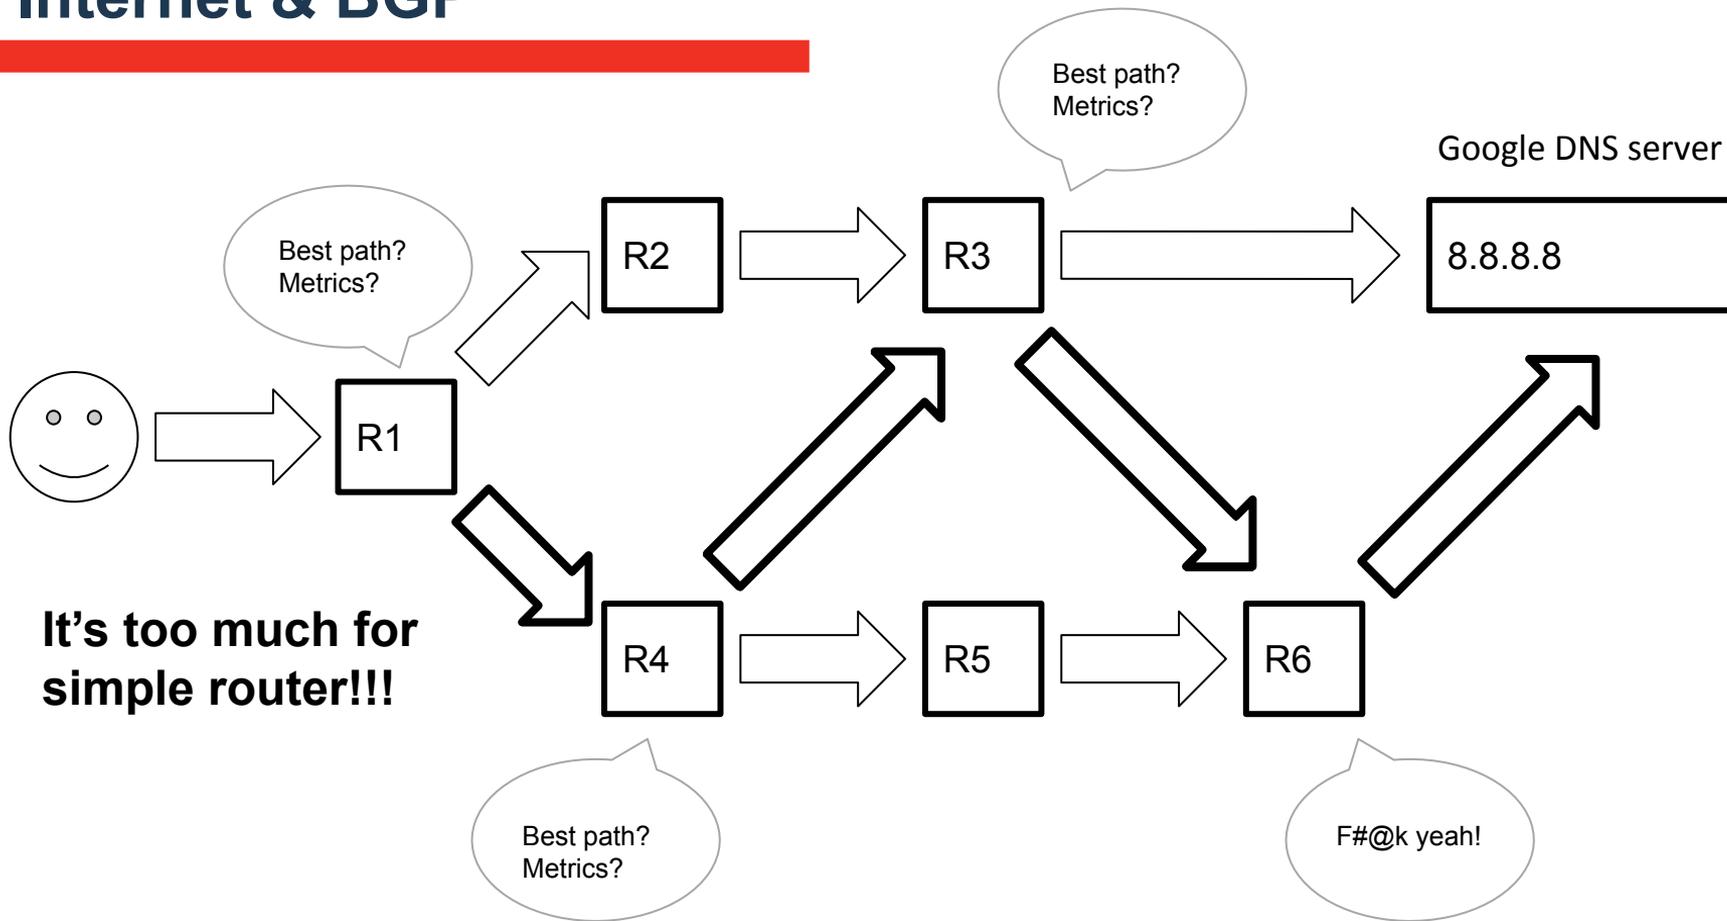
Мы не можем ходить к DNS-серверу по domain name

# ОГЛАВЛЕНИЕ

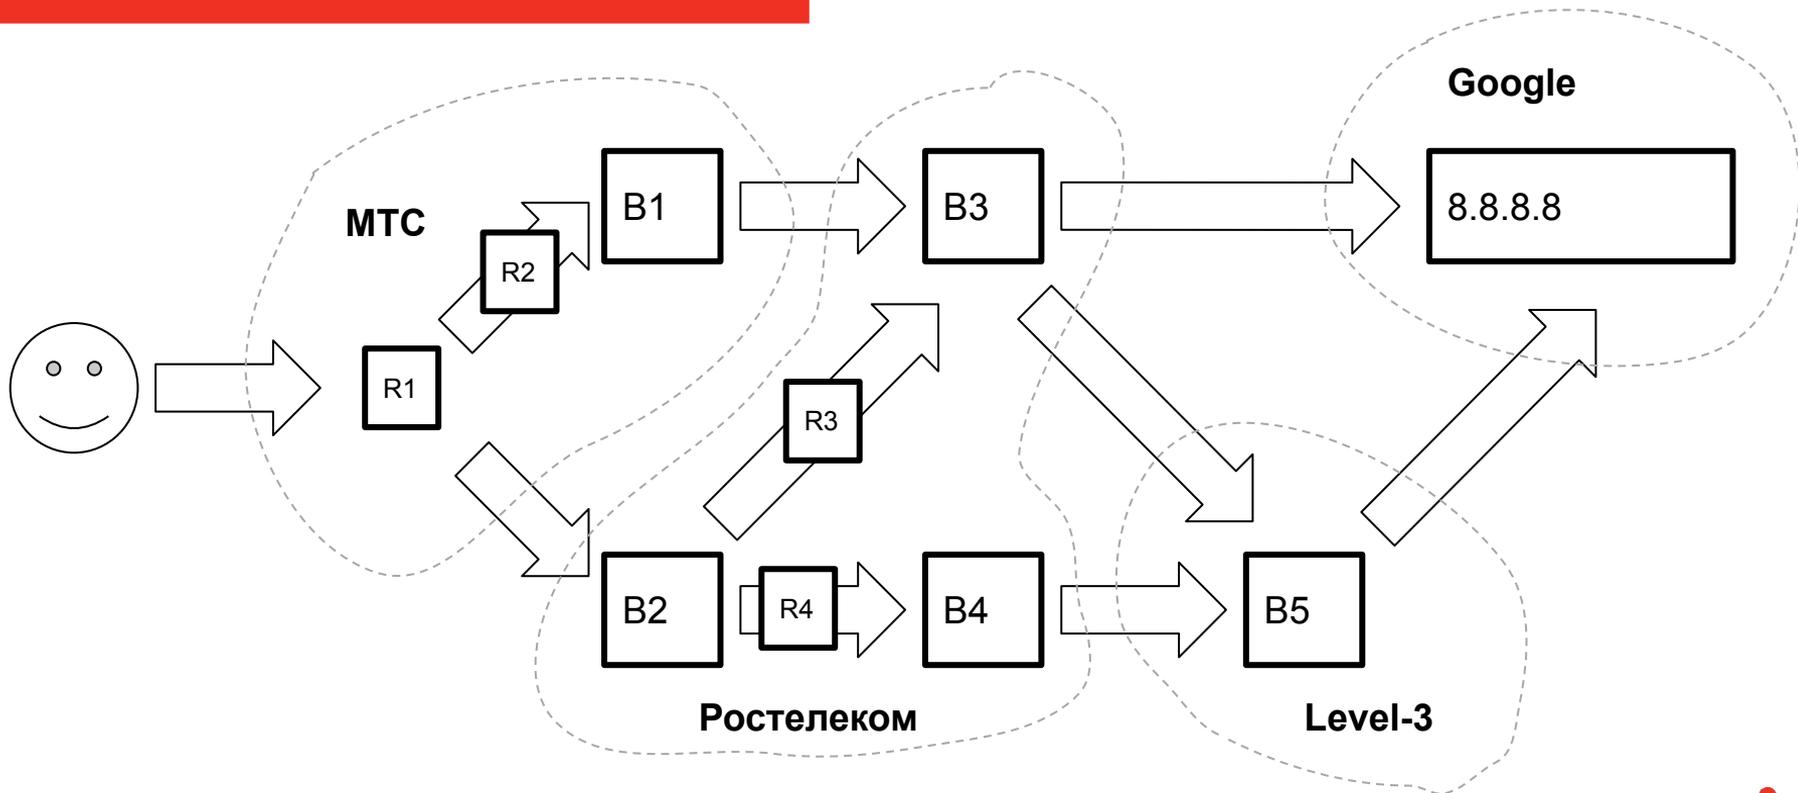
---

1. DNS WTF
2. Round robin DNS
3. Geo DNS
4. **BGP WTF**
5. BGP Anycast routing
6. Multihome BGP
7. Всякое разное

# Internet & BGP



# Autonomous systems

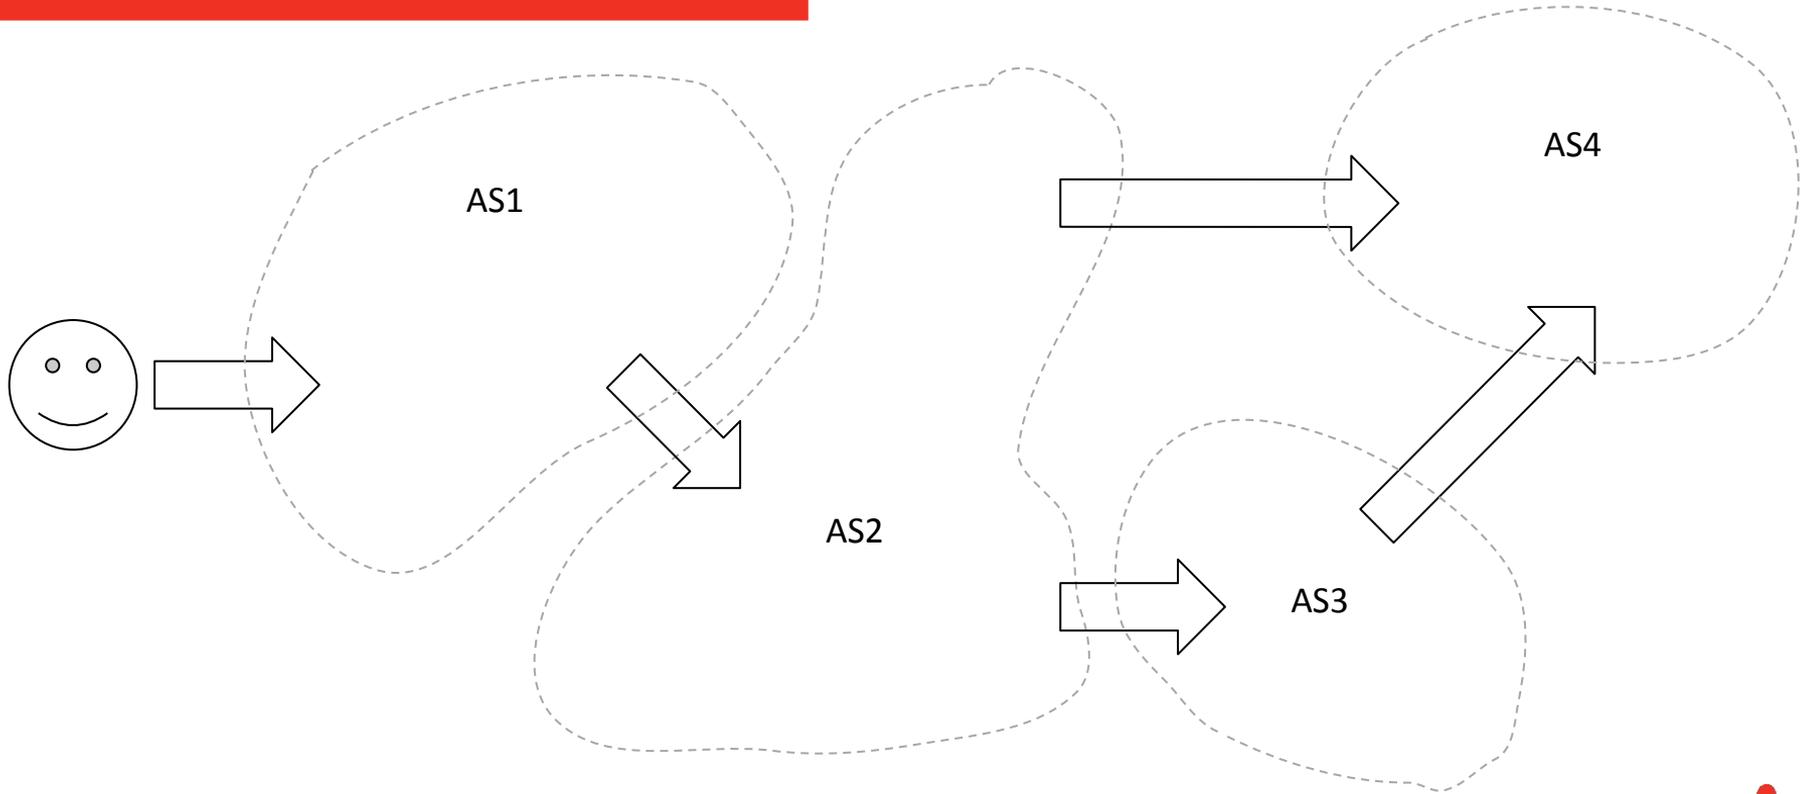


# Автономная система

---

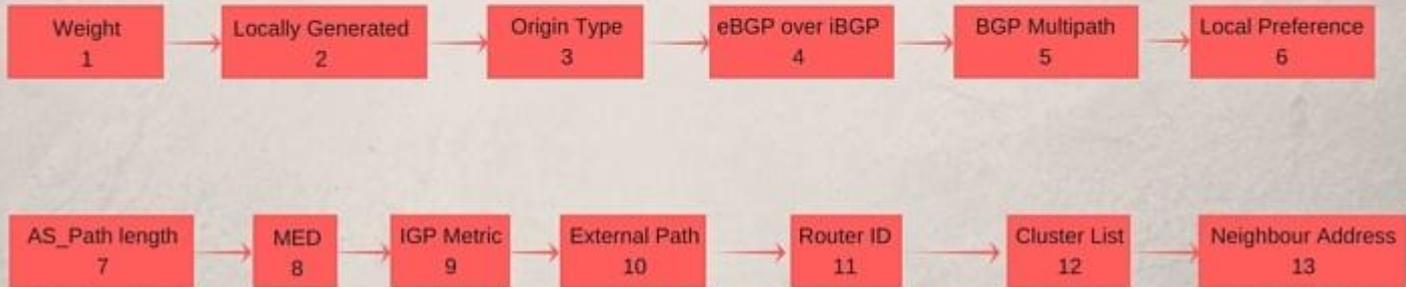
- набор внутренних и внешних (border) маршрутизаторов
- набор IP-сетей (префиксов)
- ограничена одним владельцем (administrative management)
- роутинг внутри AS - её внутреннее дело
- роутинг между AS - BGP
- связанные посредством бордеров AS - соседи (neighbors)

# Autonomous systems

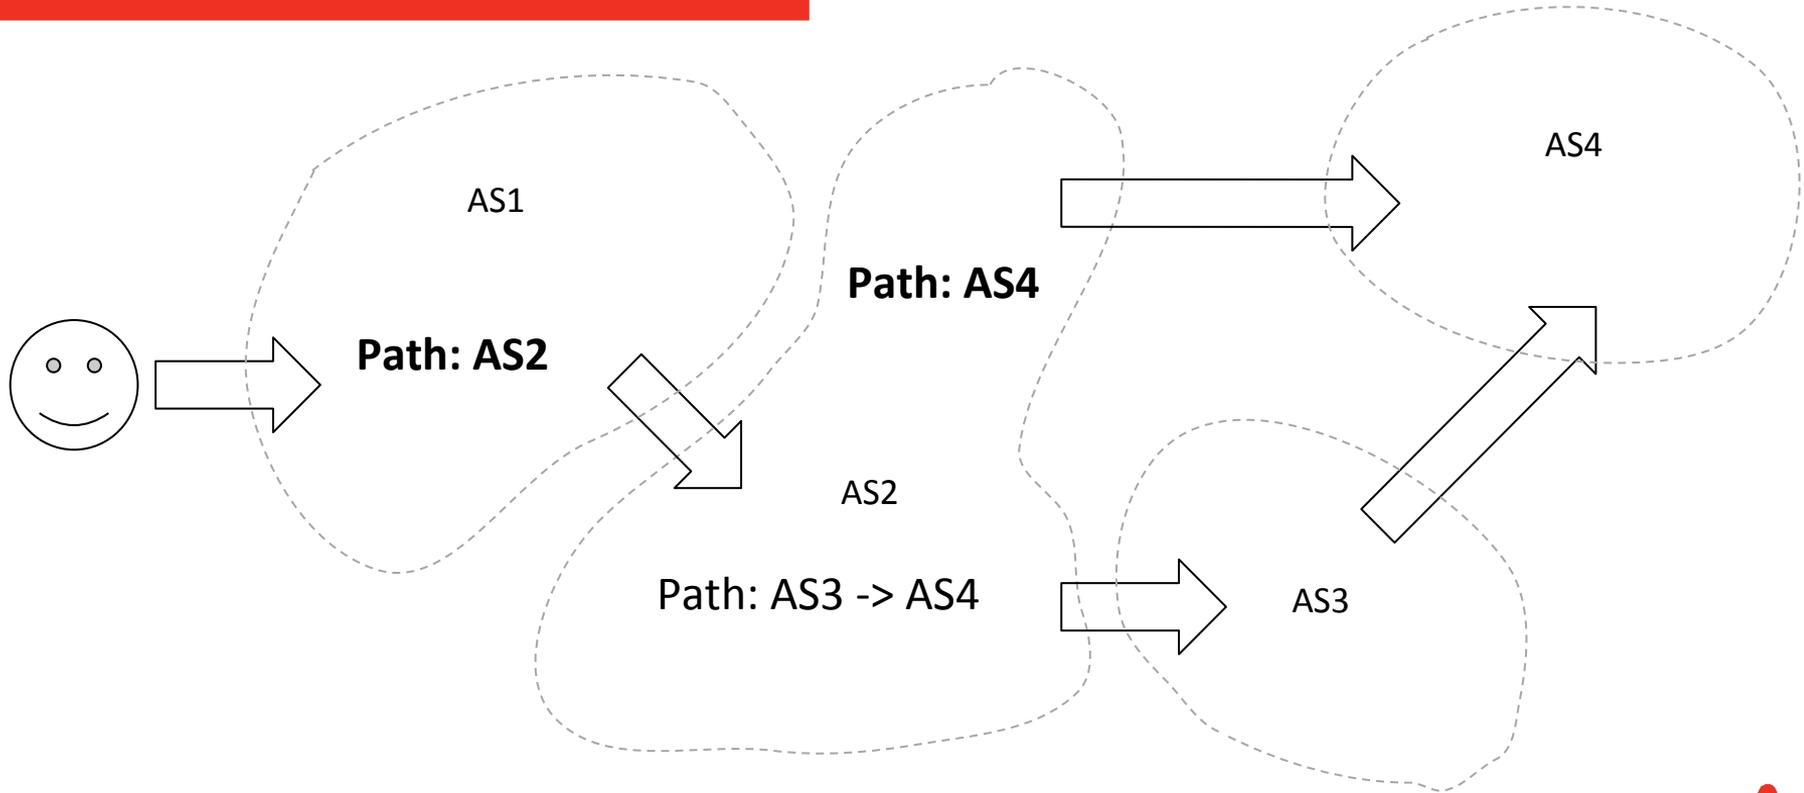


# BGP best path

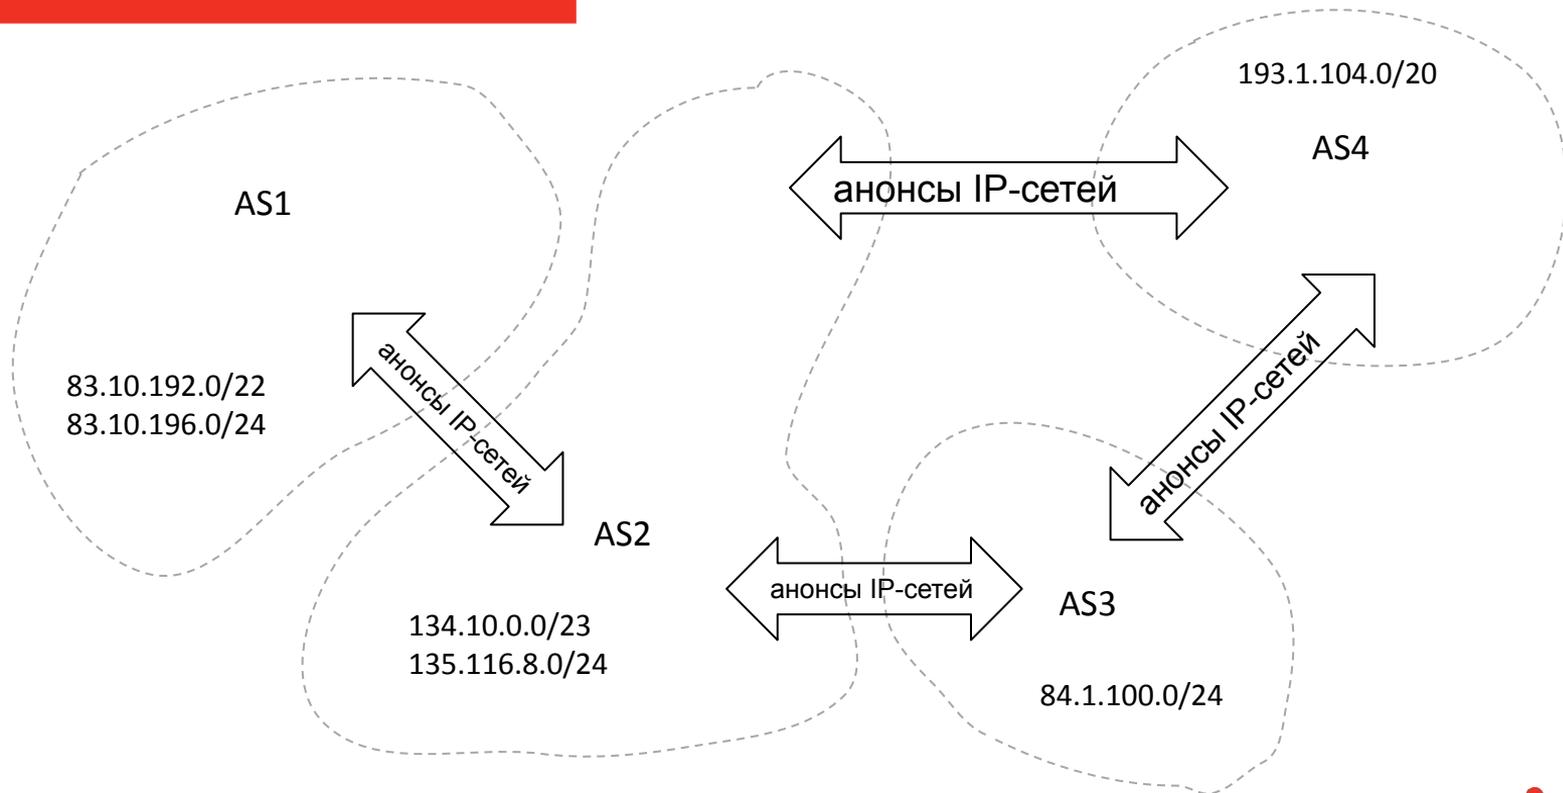
## BGP Best Path Selection Algorithm



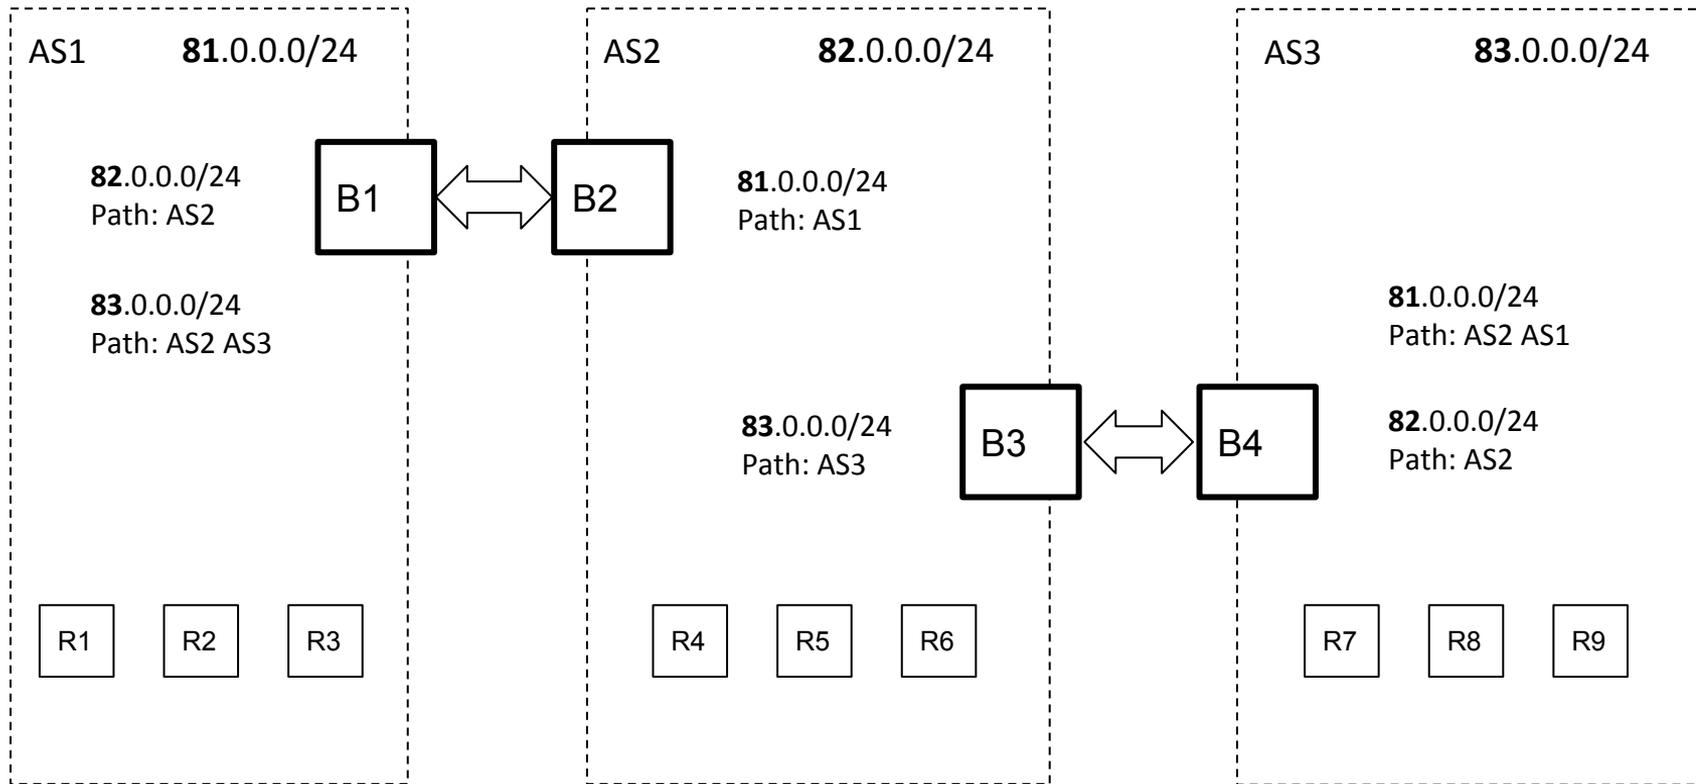
# AS path length



# BGP peering



# BGP peering in details



# BGP stats

---

- ~ 65k AS
- ~ 800k IP-сетей (префиксов)
- ~ 10k изменений анонсов в неделю
- <http://as2914.net> (galaxy)

# BGP - это протокол доверия

---

- **Нет аутентификации соседа.** Формально есть MD5 :)
- **Нет фильтрации.** У BGP есть фильтры и они описаны, но ими не пользуются, либо пользуются неправильно.
- **Очень просто установить соседство.** Настройка — пара строчек конфига.
- **Не требуются права на управление BGP.** Никто не отберет права за настройку BGP в пьяном виде.

# Можно анонсить чужие сети

- **Пакистан против YouTube.** В 2008 году ребята из Пакистана решили заблокировать у себя YouTube. Сделали они это настолько хорошо, что без котиков осталось полмира.
- **DV LINK захватил префиксы Google, Apple, Facebook, Microsoft.** В том же 2017 российский провайдер DV LINK начал зачем-то анонсировать сети Google, Apple, Facebook, Microsoft и некоторых других крупных игроков.
- **eNet из США захватил префиксы AWS Route53 и MyEtherwallet.** В 2018 году провайдер из Огайо или кто-то из его клиентов проанонсировал сети Amazon Route53 и криптокошелек MyEtherwallet.
- **Как Verizon и BGP Optimizer устроили большой оффлайн.** 24.06.2019 на небольшую компанию в Пенсильвании хлынул поток трафика из множества маршрутов, проходящих через крупного провайдера Verizon (пострадали Amazon, Linode, Cloudflare)

<https://habr.com/en/company/oleg-bunin/blog/456582/>



# ОГЛАВЛЕНИЕ

---

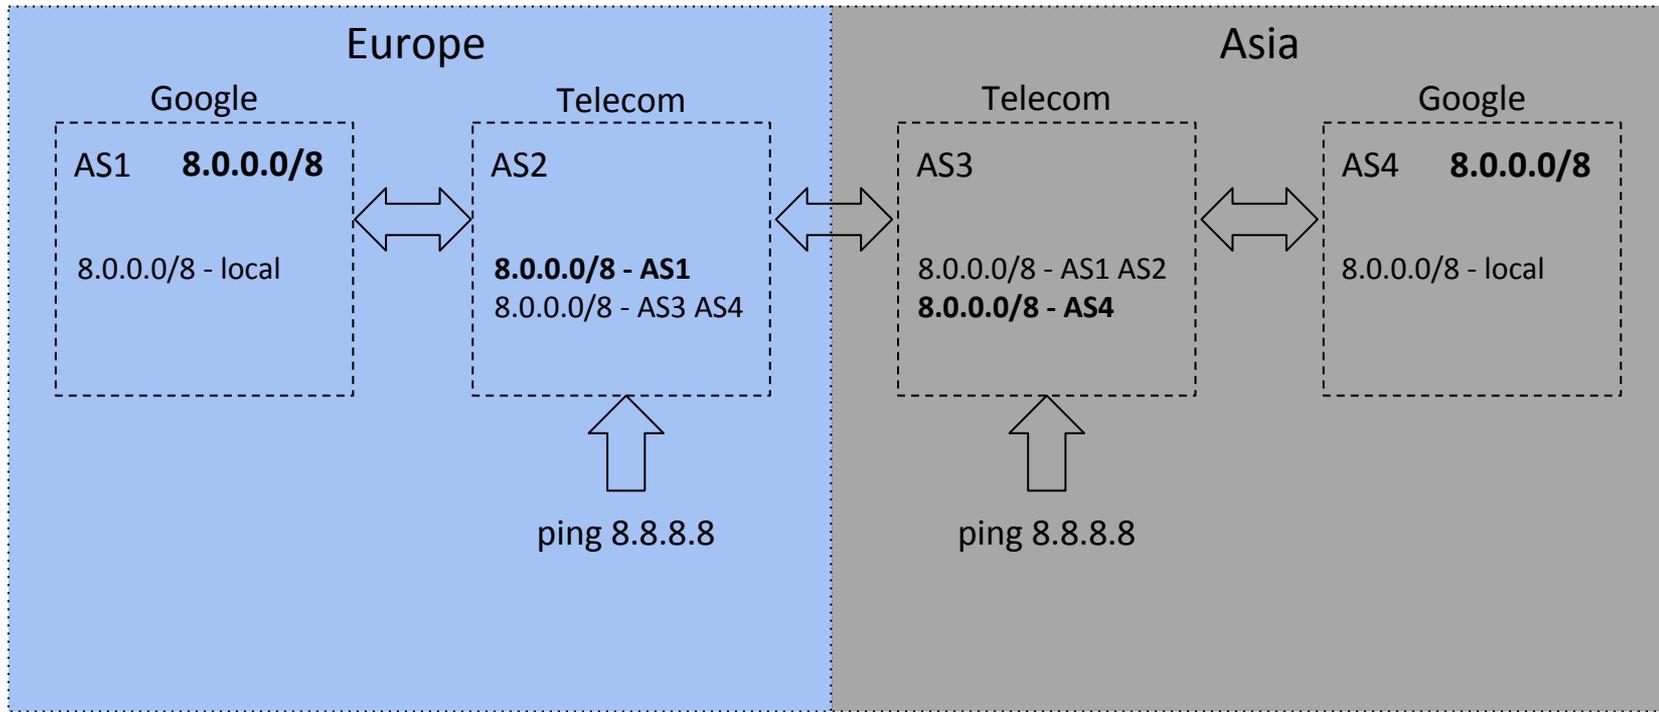
1. DNS WTF
2. Round robin DNS
3. Geo DNS
4. BGP WTF
5. **BGP Anycast routing**
6. Multihome BGP
7. Всякое разное

# BGP Anycast

---

- Но если анонсить свои сети с разных AS ...
- Получим BGP Anycast

# BGP Anycast



# Chicken or egg problem solved



## Anycast BGP:

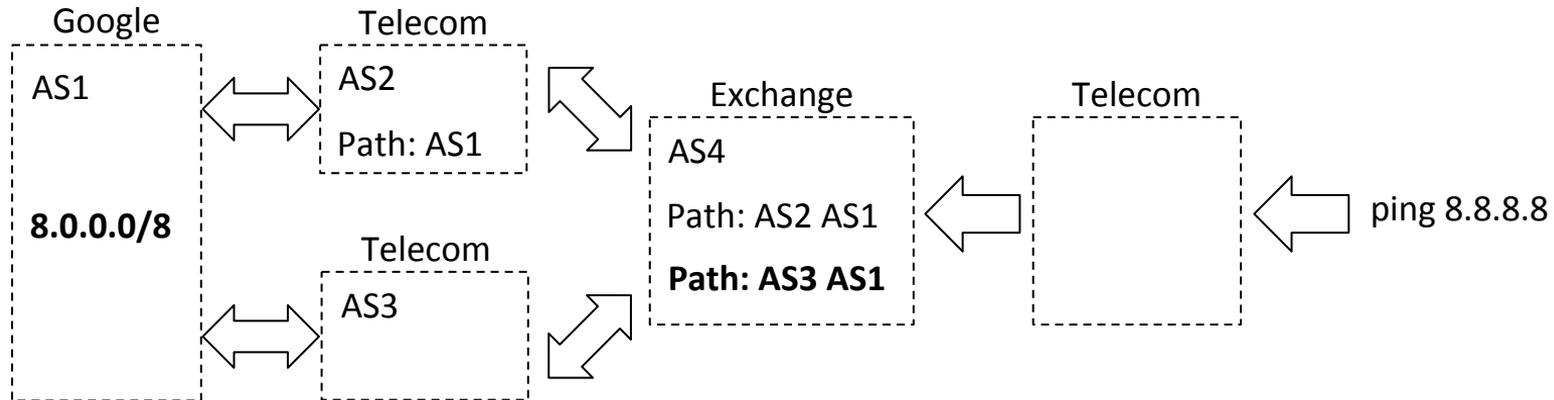
- достаточно просто
- нужны географически разнесенные точки присутствия

# ОГЛАВЛЕНИЕ

---

1. DNS WTF
2. Round robin DNS
3. Geo DNS
4. BGP WTF
5. BGP Anycast routing
6. **Multihome BGP**
7. Всякое разное

# Multihome BGP



# Multihome BGP

---

- Не нужны разные точки присутствия
- Нужны лишь подключения к разным телеком-провайдерам
- Используют почти все крупные сервисы
- alfabank.ru точно :)

# Особенности BGP

---

- Легко отстрелить себе ногу и пол-интернета
- Во время переключения best path могут быть потери
- Нужны AS, IP-сети, свое железо, каналы связи

# Плюшки BGP

---

- Маршрутная информация обновляется асинхронно, никаких кэшей, время недоступности минимально
- Дает отказоустойчивость на IP-уровне
- Изначально в BGP заложены возможности гибкого управления входящим трафиком (веса, предпочтения, балансировка)

# ОГЛАВЛЕНИЕ

---

1. DNS WTF
2. Round robin DNS
3. Geo DNS
4. BGP WTF
5. BGP Anycast routing
6. Multihome BGP
7. Всякое разное

# ВСЯКОЕ РАЗНОЕ

---

- HTTP redirects, типа google.com -> google.ru
- да хватит уже

# Выводы



- Нельзя ограничиваться приложением / сервером / датацентром
- Даже AWS / GCE / DO / Azure не панацея
- Нужно использовать правильные инструменты

# DNS links

---

- <https://www.inetdaemon.com/tutorials/internet/dns/operation/hierarchy.shtml>
- [https://en.wikipedia.org/wiki/List\\_of\\_DNS\\_record\\_types](https://en.wikipedia.org/wiki/List_of_DNS_record_types)
- <https://www.cloudflare.com/learning/dns/dns-server-types/>
- [https://en.wikipedia.org/wiki/Root\\_name\\_server](https://en.wikipedia.org/wiki/Root_name_server)
- <https://root-servers.org/>
- <https://ruhighload.com/dns+балансировка+>
- [https://en.wikipedia.org/wiki/EDNS\\_Client\\_Subnet](https://en.wikipedia.org/wiki/EDNS_Client_Subnet)
- <https://developers.google.com/speed/public-dns/faq>

# BGP links

---

- <http://as2914.net>
- <https://www.cidr-report.org/as2.0/>
- <https://ru.wikipedia.org/wiki/Anycast>
- <https://habr.com/en/company/oleg-bunin/blog/456582/>
- <https://habr.com/ru/company/qrator/blog/457446/>
- <http://noc.runnet.ru/lg/> or <http://lg.rinet.ru/> (looking glasses)

**СПАСИБО**



**А**