HighLoad++

Некоторые аспекты влияния сходимости протокола BGP на доступность сетевых ресурсов

Александр Азимов

aa@highloadlab.com

Автономные системы

Многоинтерфейсные	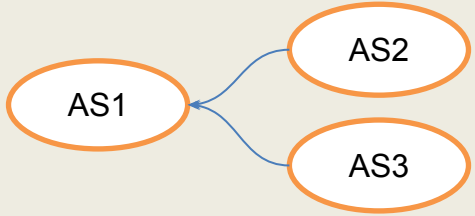
Транзитные	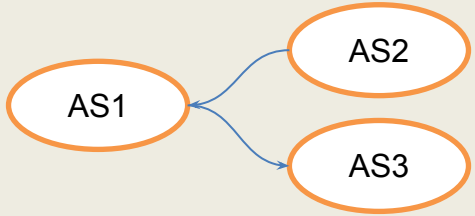
Ограниченные	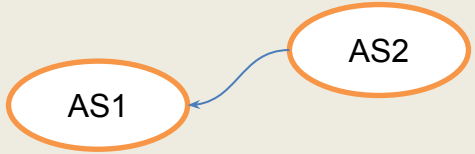

Протокол BGP

- Border Gateway Protocol (RFC 1771, 4271)
- Де-факто стандартный протокол внешней маршрутизации
- Дистанционно-векторный протокол
- Политика маршрутизации
- Набор атрибутов маршрутов
  - LOCAL_PREF
  - AS_PATH
  - …

Политика маршрутизации

LOCAL_PREF	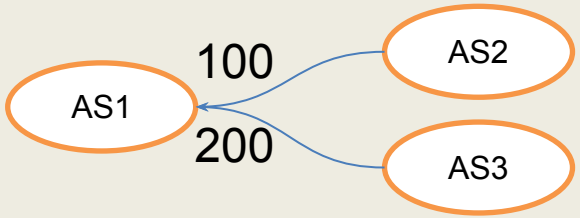
AS_PATH prepend	

Формальная модель

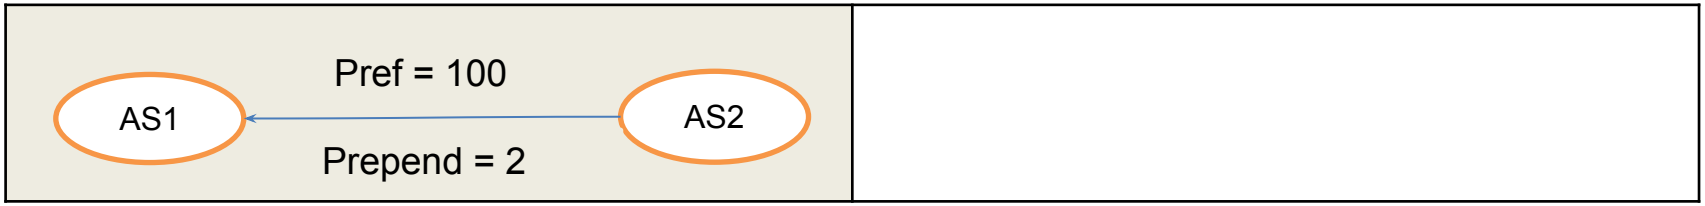

Представим модель сети автономных систем, как ориентированный граф $G(V, E)$:

- V – автономные системы
- $(as_1, as_2) \in E$ тогда и только тогда, когда АС as_1 будет анонсировать маршрут к префиксу I BGP АС as_2
- Вес дуги состоит из двух частей:
  - Prepend – политика AS_PATH АС as_1
  - Pref – политика LOCAL_PREF as_2

Транзитные АС

Пусть $ASPath$ – множество, состоящие из всех существующих значений атрибута маршрута BGP AS_PATH в текущий момент времени.

Тогда признаком транзитной автономной системы будет:

$$x \in ASTransit \leftrightarrow \exists path \in ASPath, \exists i < |path|: x = path_i$$

«Ядро» Интернета

Множество транзитных АС неоднородно:

- Пропускают только трафик клиентов
- Имеют пиринговые отношения с соседями

1. $Peers(0) = Transit$
2. $Peers(i+1) = \left\{x \in Peers(i) \mid \exists path \in ASPath, \exists i < j < |path| : x = path_i \& path_j \in Peers(i)\right\}$
3. $\lim_{i \to \infty} Peers(i) = \text{CORE}$

Пример нахождения CORE

- $Transit = \{AS_2, AS_3, AS_4, AS_5, AS_6\}$
- $Peer(1) = \{AS_3, AS_4, AS_5\}$
- $Peer(2) = \{AS_3, AS_4\} = CORE$

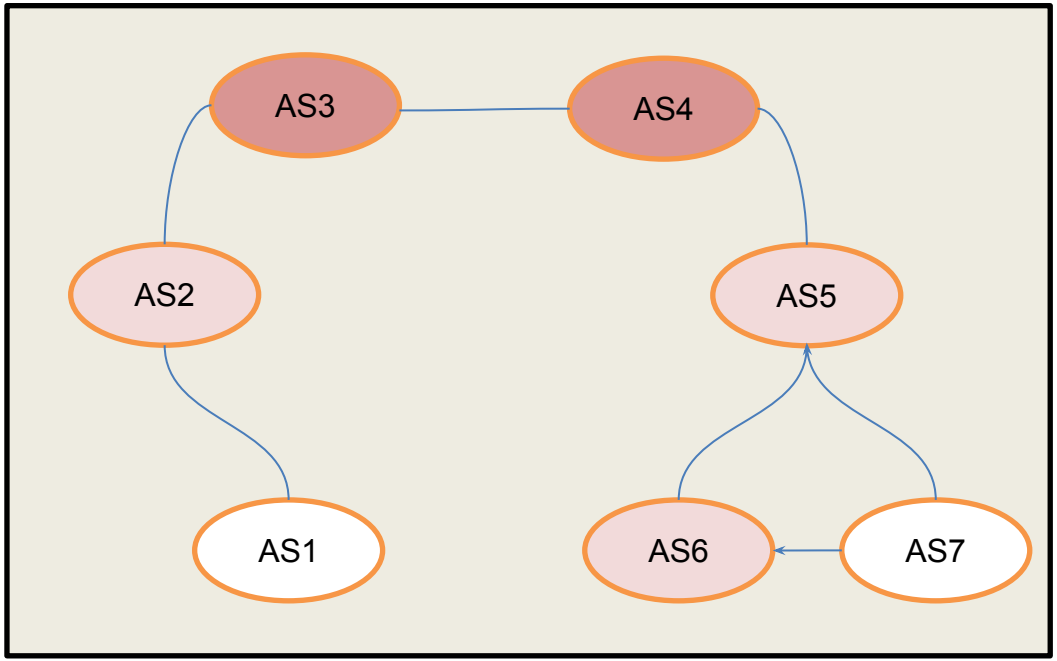

Свойства CORE

Лемма

Предел $\lim_{i \to \infty} Peers(i)$ существует и отличен от пустого множества.

- $G'(E', V') \leq G(E, V)$:
- $\forall v \in V' \to v \in Core,$
- $\forall (v_1, v_2) \in E' \to \max\big(pref(v_i, v_2)\big) = pref(v_1, v_2)$

Теорема

Прикладное применение

- Хостингам: выбор сервис провайдера
- Reverse Traceroute
- Обнаружение LOCAL_PREF циклов
- Определение времени сходимости
- Моделирование механизмов самого BGP

Время сходимости

10 AC до CORE

=

До 5 минут задержки

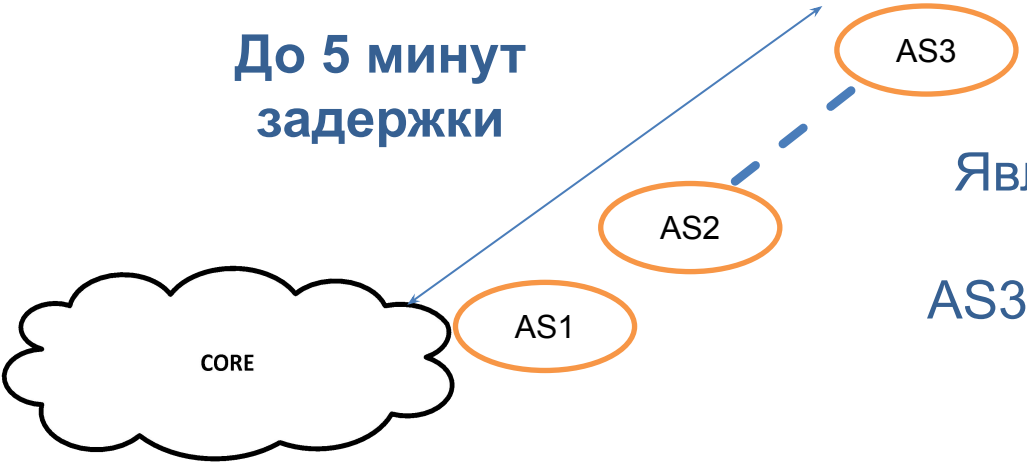

Псевдо-транзитные AC

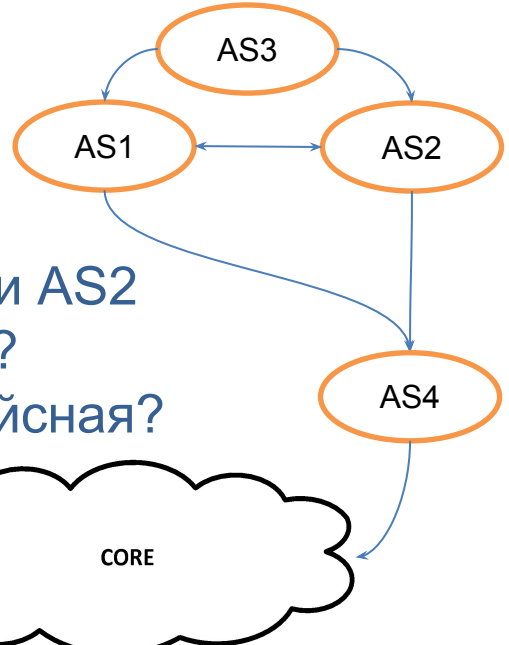

Являются ли AS1 и AS2 транзитными?
AS3 многоинтерфейсная?

Reverse Traceroute

- AC – единая политика маршрутизации
- Reverse Traceroute – знание, как к тебе идет трафик от других AC
- Если знать, как идет трафик, можно его балансировать – profit!

LOCAL_PREF циклы

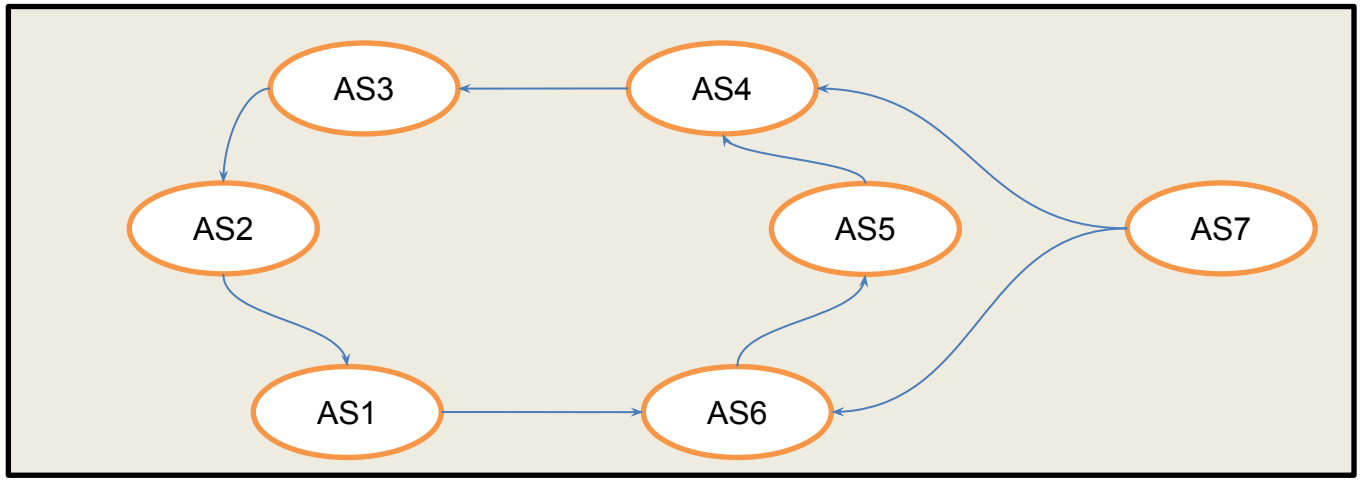

- Причина сетевой нестабильности для целевого префикса
- Создание постоянного «шума» из BGP сообщений
- Замедление времени сходимости по всей сети AC

Время сходимости

Рассматриваемые события:

- Объявление маршрута к префиксу I автономной системой X
- Удаление маршрута к префиксу I автономной системой

- $ET_{up} = \theta(d \times Et_{wait})$, где d – диаметр относительно вершины X в графе G
- $ET_{down} = \theta(D \times Et_{wait})$, где D – длина гамильтонова пути относительно вершины X в графе G

Система моделирования

Критерии сравнения	SSFNet	NS-2	PRIME	CBGP	Разработанная система
Реализация политик маршрутизации	-	-	+	+	+
Полнота стека BGP-решений	+/-	+/-	+	+	+
Модель передачи BGP сообщений	Пакетный уровень	Пакетный уровень	Пакетный уровень	В виде объектов	В виде объектов
Возможность моделирования сходимости BGP маршрутизации	+	+	+	-	+
Возможность распределенных вычислений	+	-	+	-	+
Масштабируемость	+	+	-	+	+

Проверка распределений

$$d^{\max}(X) \times E(t_{wait}) \leq ET_{up} \leq d^{\max}(X) \times E(t_{wait}) + s$$

$$D_{\frac{1}{2}}^{max}(x) \times E(t_{wait}) \leq ET_{down} \leq D^{max}(x) \times E(t_{wait}) + s$$

Объявление маршрута

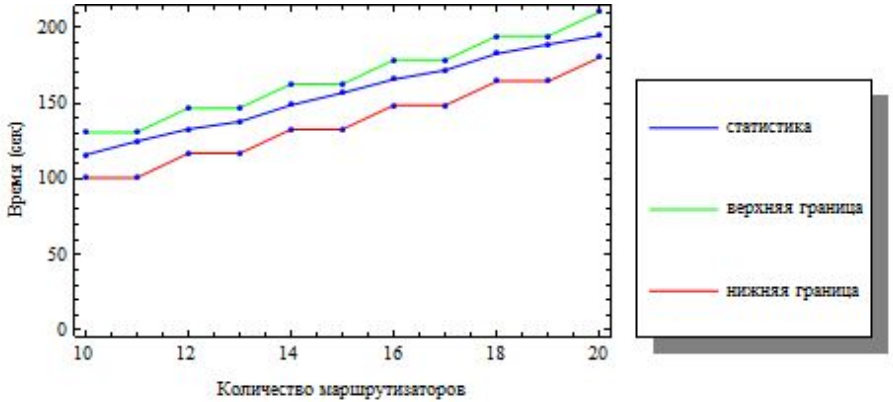

Удаление

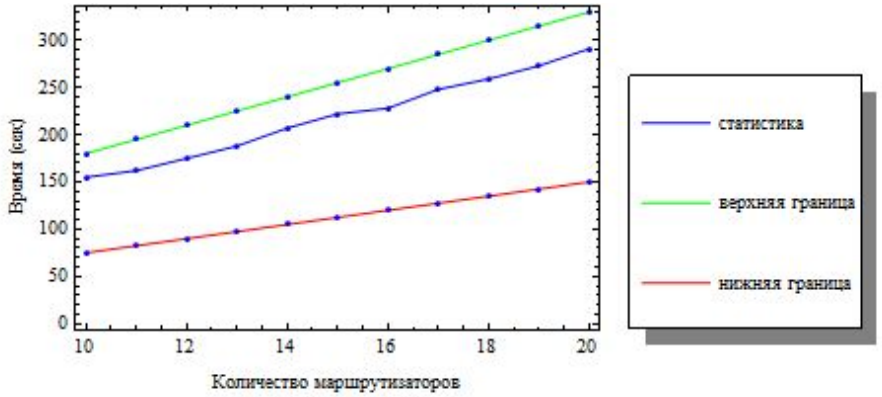

Flap Damping

Зачем?

Снижение нагрузки на сеть BGP маршрутизаторов от нестабильных маршрутов, не оказывая влияния на время сходимости в стабильных участках сети.

Flap Damping

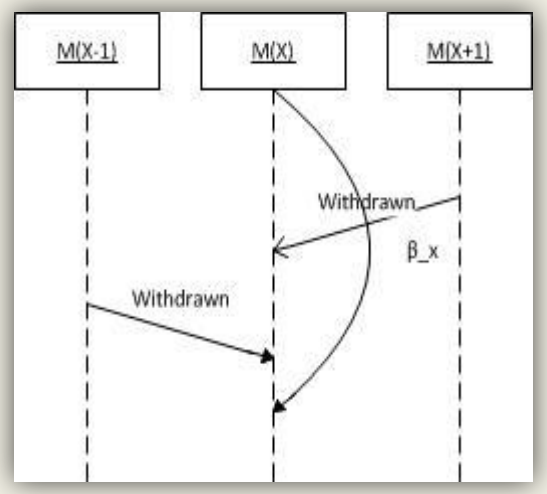

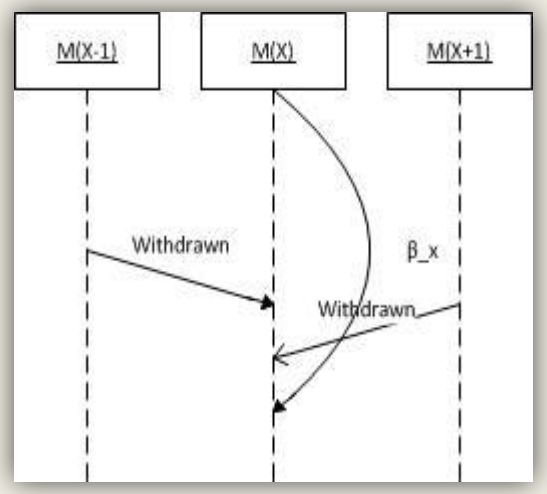

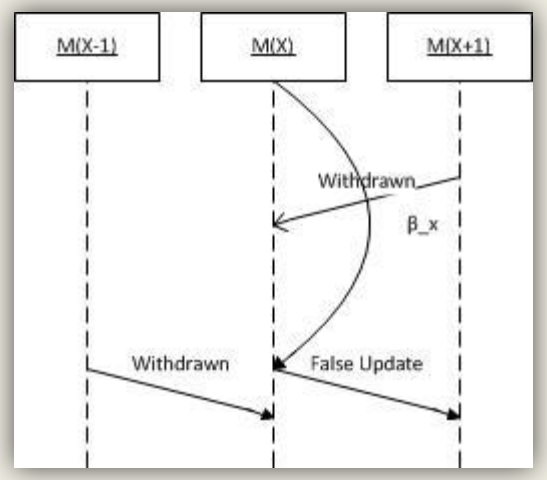

Flap Damping

Вероятность появления мигающего маршрута в кольце маршрутизаторов длины n:

$$2 \times \left(\Phi\left(7 \times \sqrt{\frac{3}{n+1}}\right) - \Phi\left(2 \times \sqrt{\frac{3}{n+1}}\right)\right), \text{при } n \text{ четном}, 2 \times \left(\Phi\left(6 \times \sqrt{\frac{3}{n+1}}\right) - \Phi\left(\sqrt{\frac{3}{n+1}}\right)\right), \text{при } n \text{ нечетном}$$

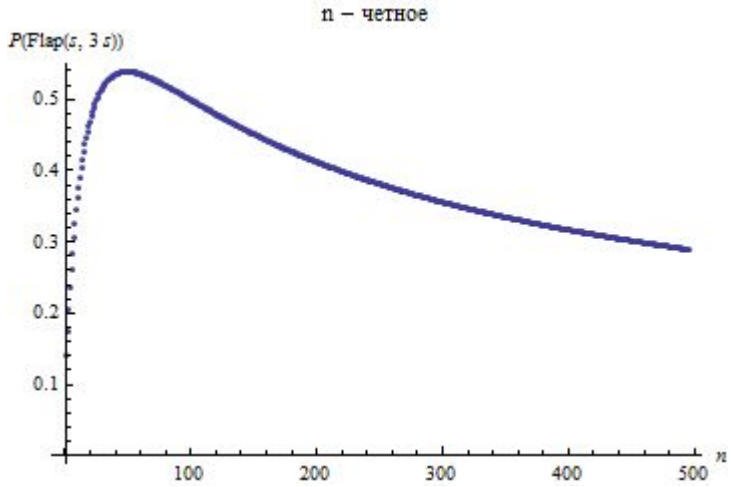

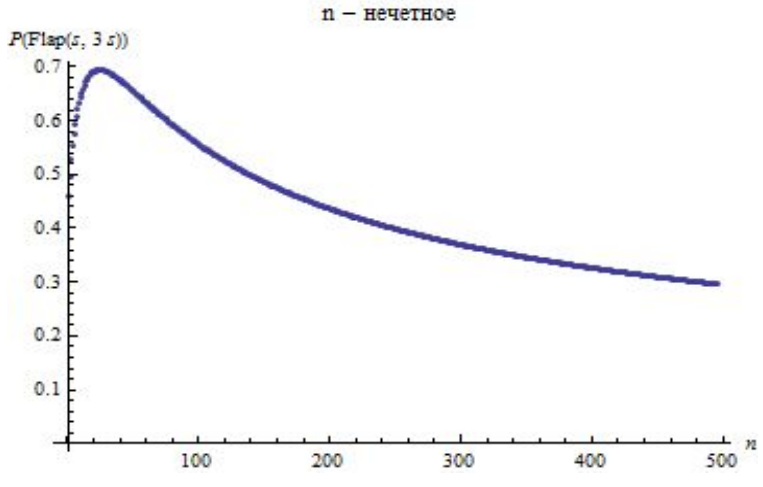

Flap Damping DoS?

- Yes!
- Не блокируется ни одним существующим расширением BGP S-BGP

Данные для экспериментов

- List of router registries
- http://www.irr.net/docs/list.html
- BGP dumps
- http://www.ripe.net/projects/ris/rawdata.html

Автономных систем: 36200
Транзитных систем: 5876
CORE: 1757
Prepends:

Результаты

- Разработана модель BGP маршрутизации
- Сформулированы оценки времени сходимости протокола BGP
- Разработана система моделирования для проверки теоретических оценок
- Рассмотрены механизмы BGP LOCAL_PREF и Flap Damping и их влияние на доступность сетевых ресурсов
- Предложен метод для построения Reverse Traceroute

HighLoad++

Спасибо за внимание!

Вопросы?