Современные алгоритмы управления перегрузкой TCP

к.ф.-м.н., м.н.с. Степанов Евгений Павлович

Программа курса

Подходы:

1. ***Управление перегрузкой***
   - Современные протоколы управления перегрузкой TCP
2. ***Демультиплексирование/мультиплексирование***
   - Многопоточные транспортные протоколы
   - Маршрутизация на уровне интернет провайдеров
   - Network Coding
3. ***Сегментация***
   - TCP Proxy
4. ***Балансировка***
   - Балансировка нагрузки и управление трафиком
5. ***Преобразование сообщений***
   - FEC
   - Сжатие

Модели оценки качества сервиса:

- Активные и пассивные измерения
- NS3: моделирование поведения сети с высокой точностью
- Сетевое исчисление: математический подход к качеству сервиса

Примеры:

- Управление сетевыми ресурсами в Центрах Обработки Данных
- Обеспечение качества сервиса в сетях доставки контента
- Пропускная способность по требованию

Перегрузки в сети

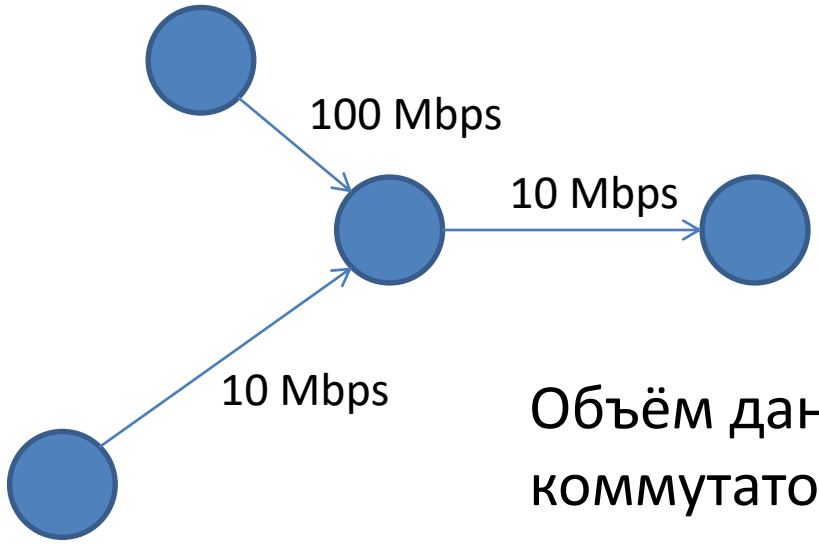

Объём данных, поступающих на коммутатор, превышает объём данных, которые он может передать

Коммутаторы буферизируют проходящий через них трафик:

- При кратковременной перегрузке увеличивается задержка
- При достаточно долгой перегрузке пакеты сбрасываются

Базовое устройство TCP

Алгоритм скользящего окна (sliding window)

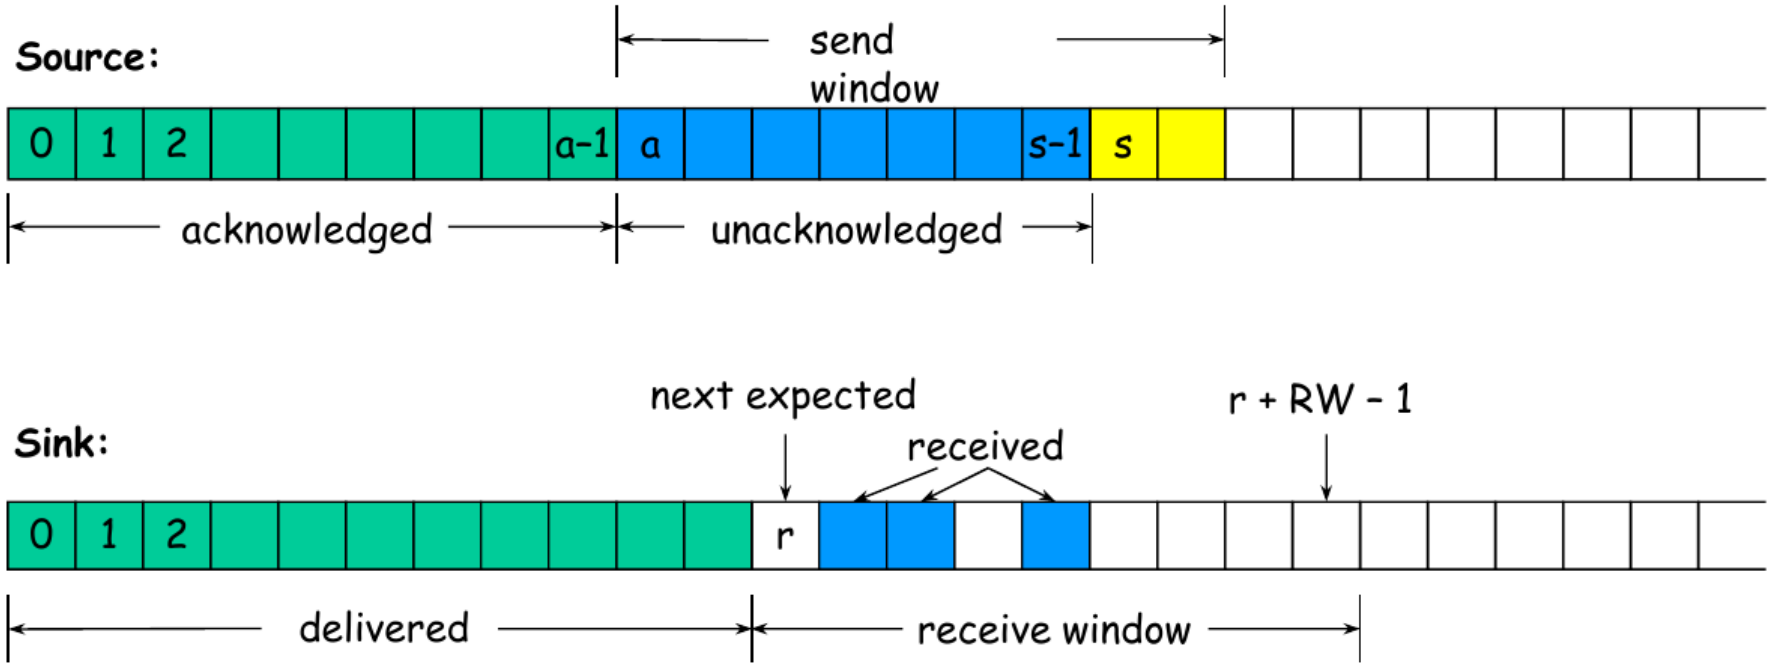

- Позволяет восстанавливать порядок пакетов при отправке множества пакетов с использованием буфера фиксированного размера

Управление TCP трафиком

какими бывают “окна”

- Rate control (traffic policing)
- Receiver-side flow control
  - Цель: избежать перегрузки получателя
  - Параметр: RWND – окно получателя
  - Получатель отправляет свой RWND отправителю
- Network congestion control
  - Цель – избежать перегрузки сети
  - Параметр: CWND – окно перегрузки
  - Отправитель вычисляет свой CWND с помощью алгоритма управления перегрузкой

Cumulative ACK

- Получатель сообщает о последнем успешно полученном пакете – пакеты с меньшими номерами считаются полученными автоматически
- NACK (negative ACK) – получатель явно перечисляет пакеты, которые он не получил
- SACK (selective ACK) – получатель сообщает диапазоны успешно полученных пакетов

Небольшая история Интернет

- 1974 год – первый драфт TCP/IP
- 1983 год – ARPANET переходит на TCP/IP
- 1986 год – ARPANET испытывает сильнейшую перегрузку (congestion collapse)
- 1988 год – появляется управление перегрузкой для TCP

TCP design principles:

- **Van Jacobson** "Congestion avoidance and control“ // Proceedings of SIGCOMM ’88, Stanford, CA. Aug. 1988.

Принцип инвариантности количества отправляемых пакетов

packet conserving principle

Каждое соединение должно стремиться к *устойчивому состоянию*, в котором отправка каждого следующего пакета соединения происходит сразу после того, как завершилась передача одного из его предыдущих пакетов:

- Каналы не должны простаивать
- Передача пакетов должна быть равномерной, а её итоговая скорость должна соответствовать пропускной способности канала

Как найти состояние равновесия?

self-clocking principle

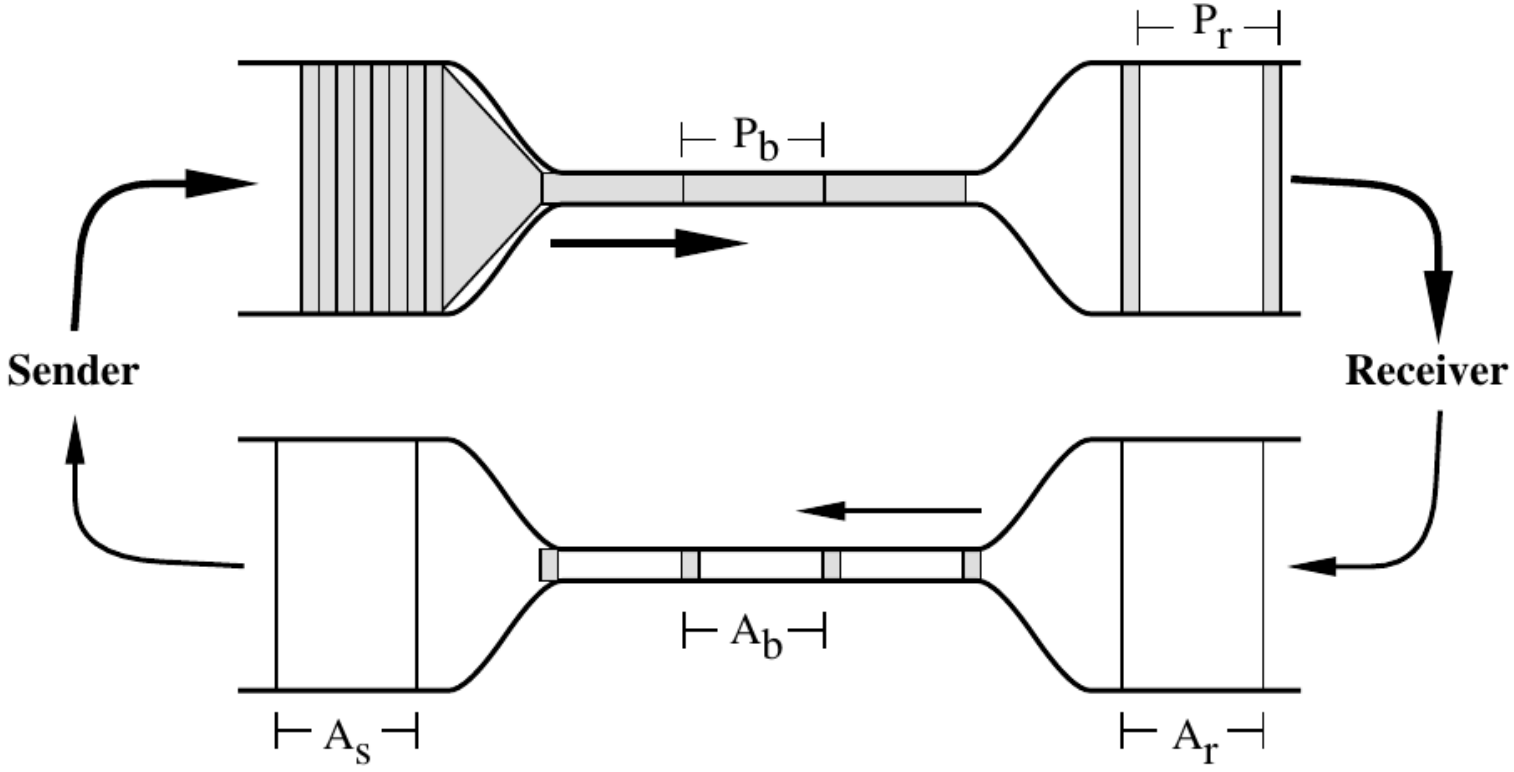

Скорость отправки пакетов должна соответствовать пропускной способности канала в узком месте

Slow start

подгонка часов

- На отправителе появляется новый параметр – congestion window (CWND)
- Значение CWND устанавливается в 1 в начале соединения и при каждой потере
- При получении каждого подтверждения о доставке CWND увеличивается на 1
- Отправитель передаёт max(CWND, RWND) где RWND – окно получателя

Медленный старт совсем не медленный – количество отправленных пакетов растёт в геометрической прогрессии

Как остаться в состоянии равновесия?

Retransmit timer

- Если пакет теряется, то отправитель должен отправить в сеть новый пакет в нужный момент времени
- Нужен надёжный расчёт для RTT и RTO

$$RTT_{avg} = \alpha RTT_{avg} + (1 - \alpha) R_{curr}$$

$$RTO = \beta RTT_{avg}$$

Выбор таймера при повторении ошибок

Перегруженная система обретает стабильность, если нагрузка падает по экспоненциальному закону:

- Exponential Backoff
- RTO, 2RTO, 4RTO, 8RTO, 16RTO, 32RTO

Как остаться в состоянии равновесия?

Congestion avoidance

- Вероятность потери из-за ошибки на физическом уровне обычно мала ($\sim 10^{-10}$)
- Потери возникают из-за перегрузок в сети
- Стратегия:
  - Сеть подаёт сигнал о потере пакета
  - Отправитель снижает нагрузку

If packet loss is (almost) always due to congestion and if a timeout is (almost) always due to a lost packet, we have a good candidate for the 'network is congested' signal.

- Congestion Avoidance and Control

+ Не нужно изменять стек протоколов на устройствах

Как остаться в состоянии равновесия?

Additive Increase Multiple Decrease (AIMD)

Политика изменения окна при перегрузке:

- Пусть L_i – загрузка очередей на интервале i
- В состоянии равновесия $L_i = N$
- В состоянии перегрузки $L_i = N + \gamma L_{i-1}$
- Поскольку загрузка очередей растёт экспоненциально, то размер окна перегрузки тоже должен меняться по экспоннете $W_i = dW_{i-1}$ $(d < 1)$

Как остаться в состоянии равновесия?

Additive Increase Multiple Decrease (AIMD)

Изменение окна при нормальной работе:

- Скорость изменения окна должна быть меньше, чем при перегрузке, иначе система будет нестабильной
- Можно построить такую смесь трафика, что экспоненциальное увеличение (умножение) размера окна приведёт к тому, что пакеты будут отправляться в сеть быстрее, чем она сможет их обрабатывать

$$W_i = W_i + u \; (u \ll W_{max})$$

Управление перегрузкой TCP: задачи

- Соединения должны адаптироваться к качеству предоставленной линии связи и стремиться использовать предоставленные ресурсы максимально *эффективно*
- Соединения должны автоматически распределять пропускную способность разделяемой ими линии связи *справедливым* образом

Алгоритмы управления перегрузкой протокола TCP

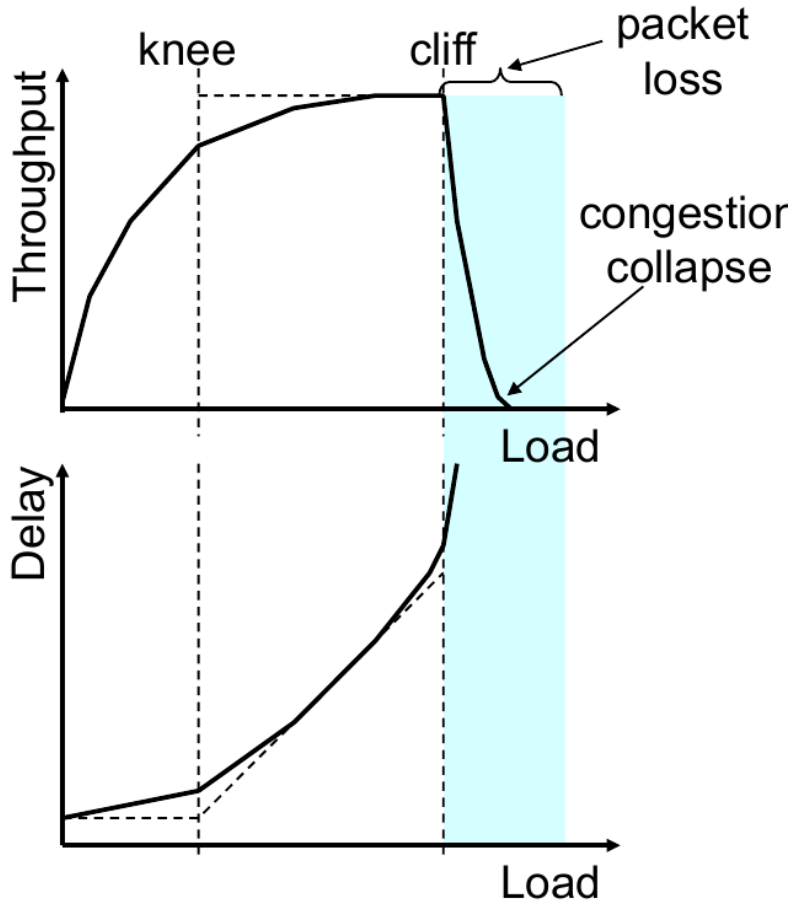

Van Jacobson ***Congestion avoidance and control***
Proceedings of SIGCOMM '88 -- Stanford, CA

TCP Tahoe (Jacobson 1988)

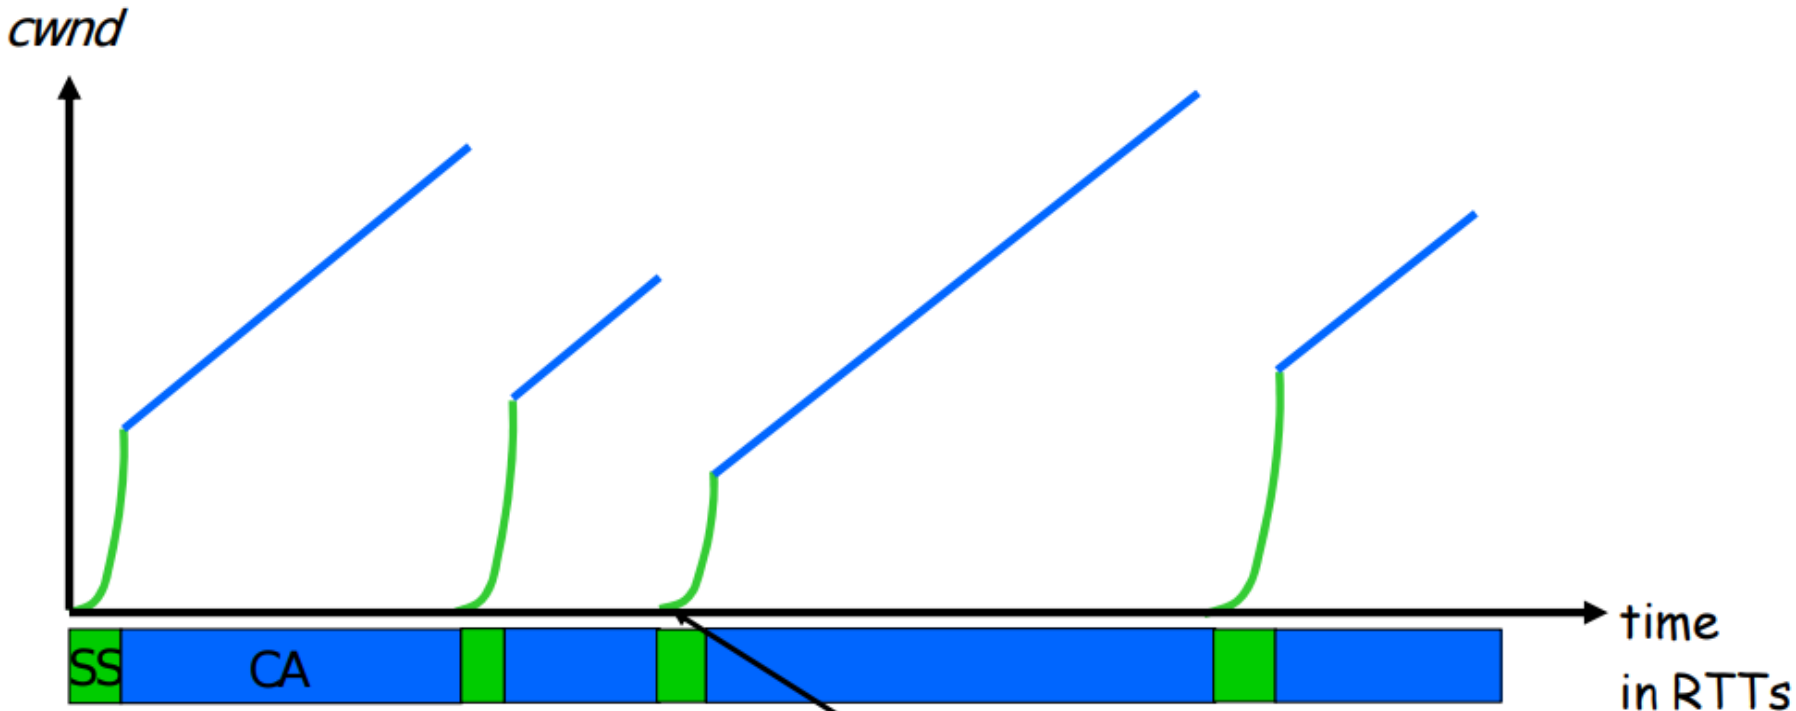

SS: Slow Start
CA: Congestion Avoidance

- Decrease to 1 for either timeout or 3 dupACKs
- Fast retransmit on 3 dupACKs

TCP **Reno** (Jacobson 1990)

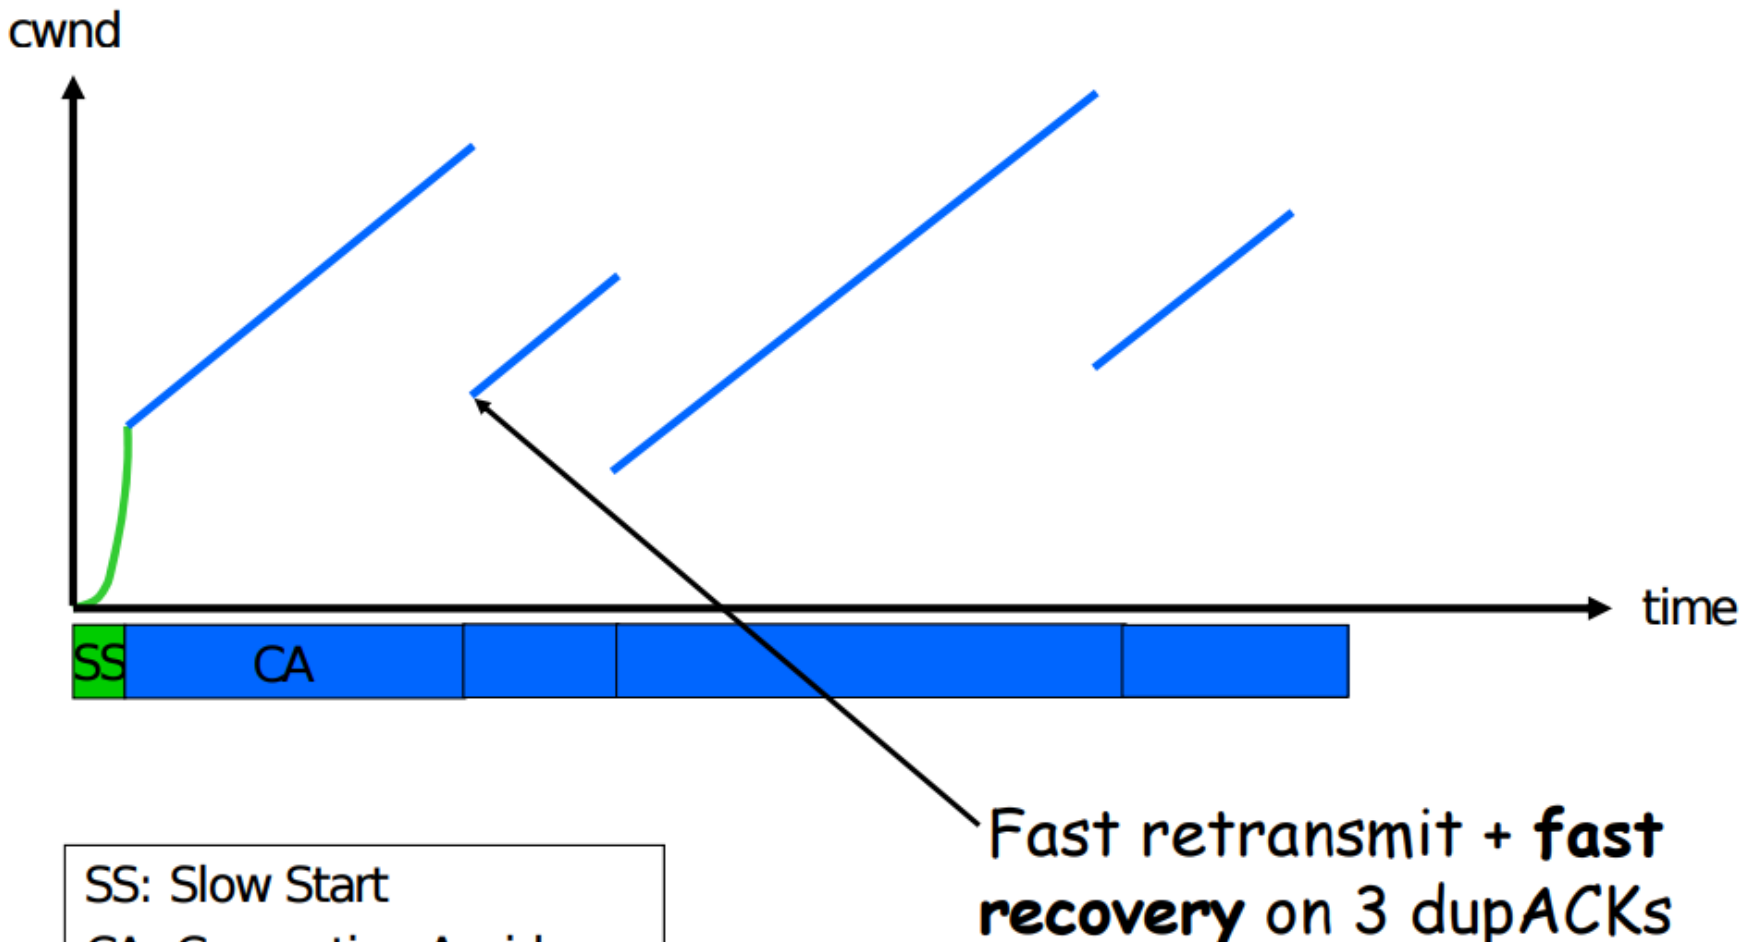

Быстрое восстановление

Какая должна быть реакция на большое количество повторных подтверждений ?

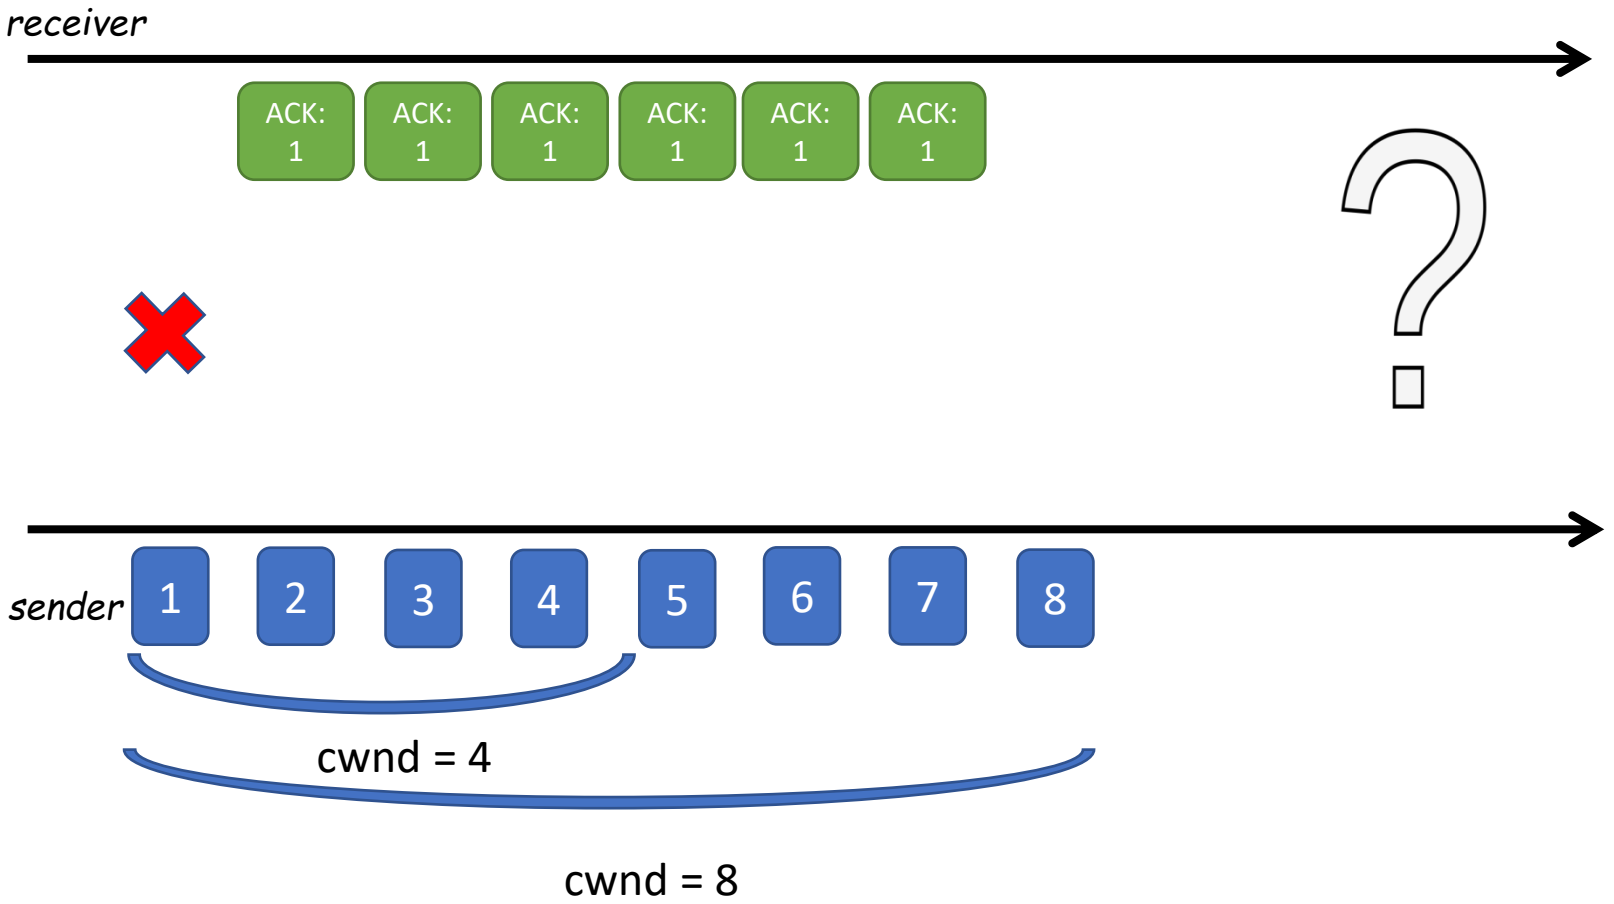

Быстрое восстановление

- *Окно перегрузки определяет количество пакетов, которое может одновременно находиться в сети*
- *Повторное подтверждение означает, что некоторый пакет был доставлен не по порядку -> в сети стало меньше пакетов, чем cwnd*
- *3 повторных подтверждения означают, что 3 пакета покинуло сеть*
- *Проблема: мы не можем сдвинуть sliding window вправо на 3 позиции из-за неподтвержденного пакета*
- *Решение: мы можем сдвигать правую границу sliding window (в данном случае congestion window), увеличивая значение sliding window*

Быстрое восстановление

- В начале фазы быстрого восстановления устанавливаем окно в cwnd/2 + 3
- Каждое последующее повторное подтверждение означает выход еще одного пакета из сети, поэтому на каждый dup ack увеличиваем cwnd на 1: cwnd += 1
- При получении подтверждения на переотправленный пакет мы можем двигать левую границу sliding window, поэтому возвращаем значение cwnd в cwnd/2.

Быстрое восстановление

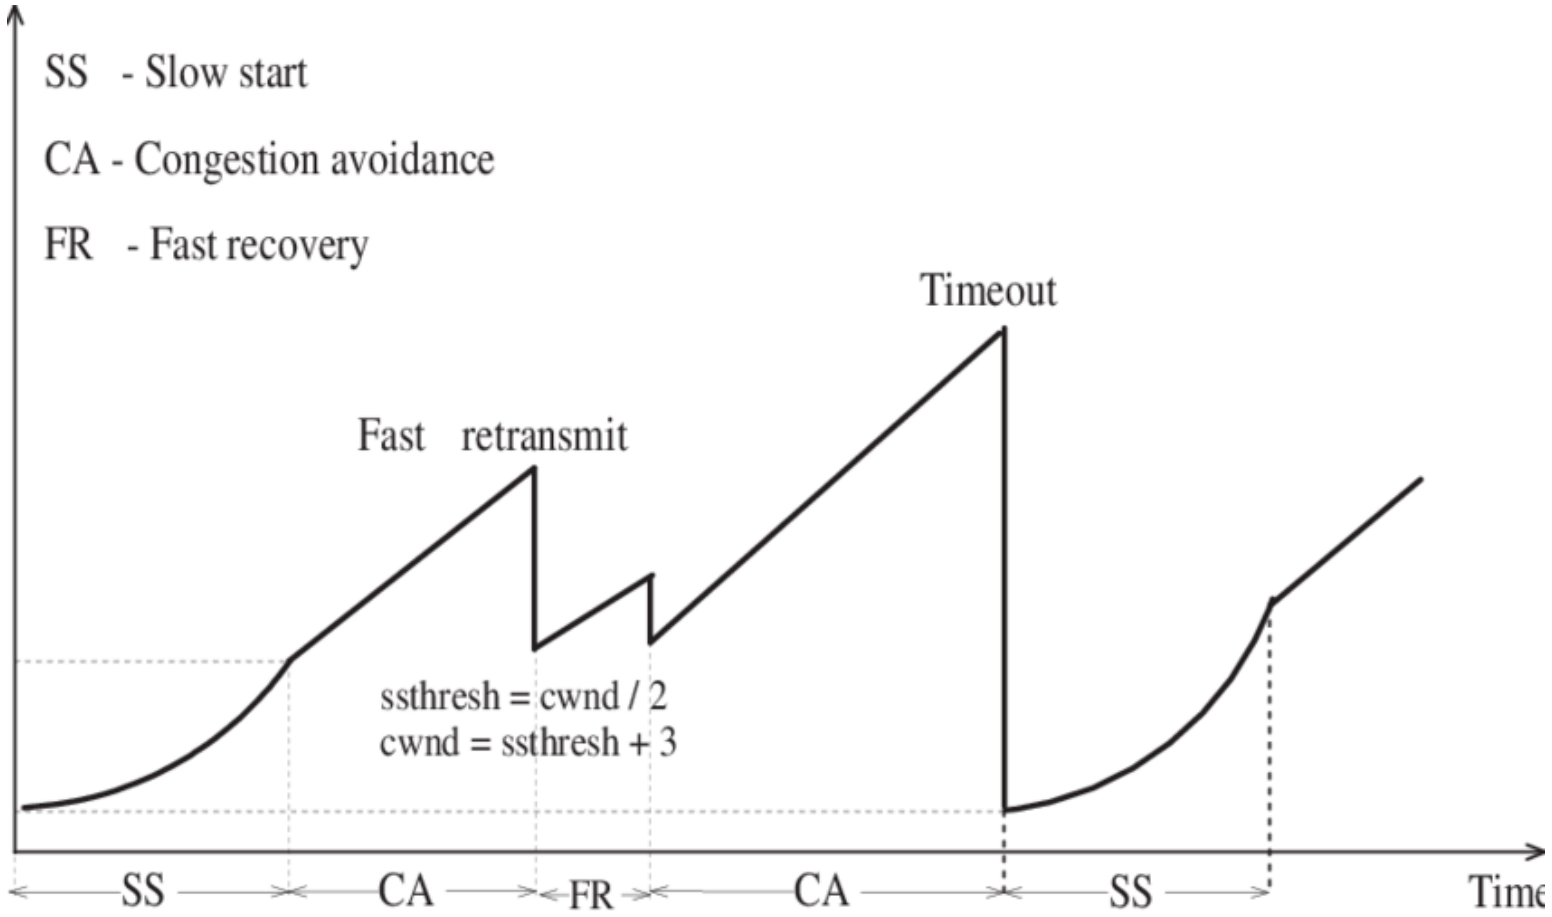

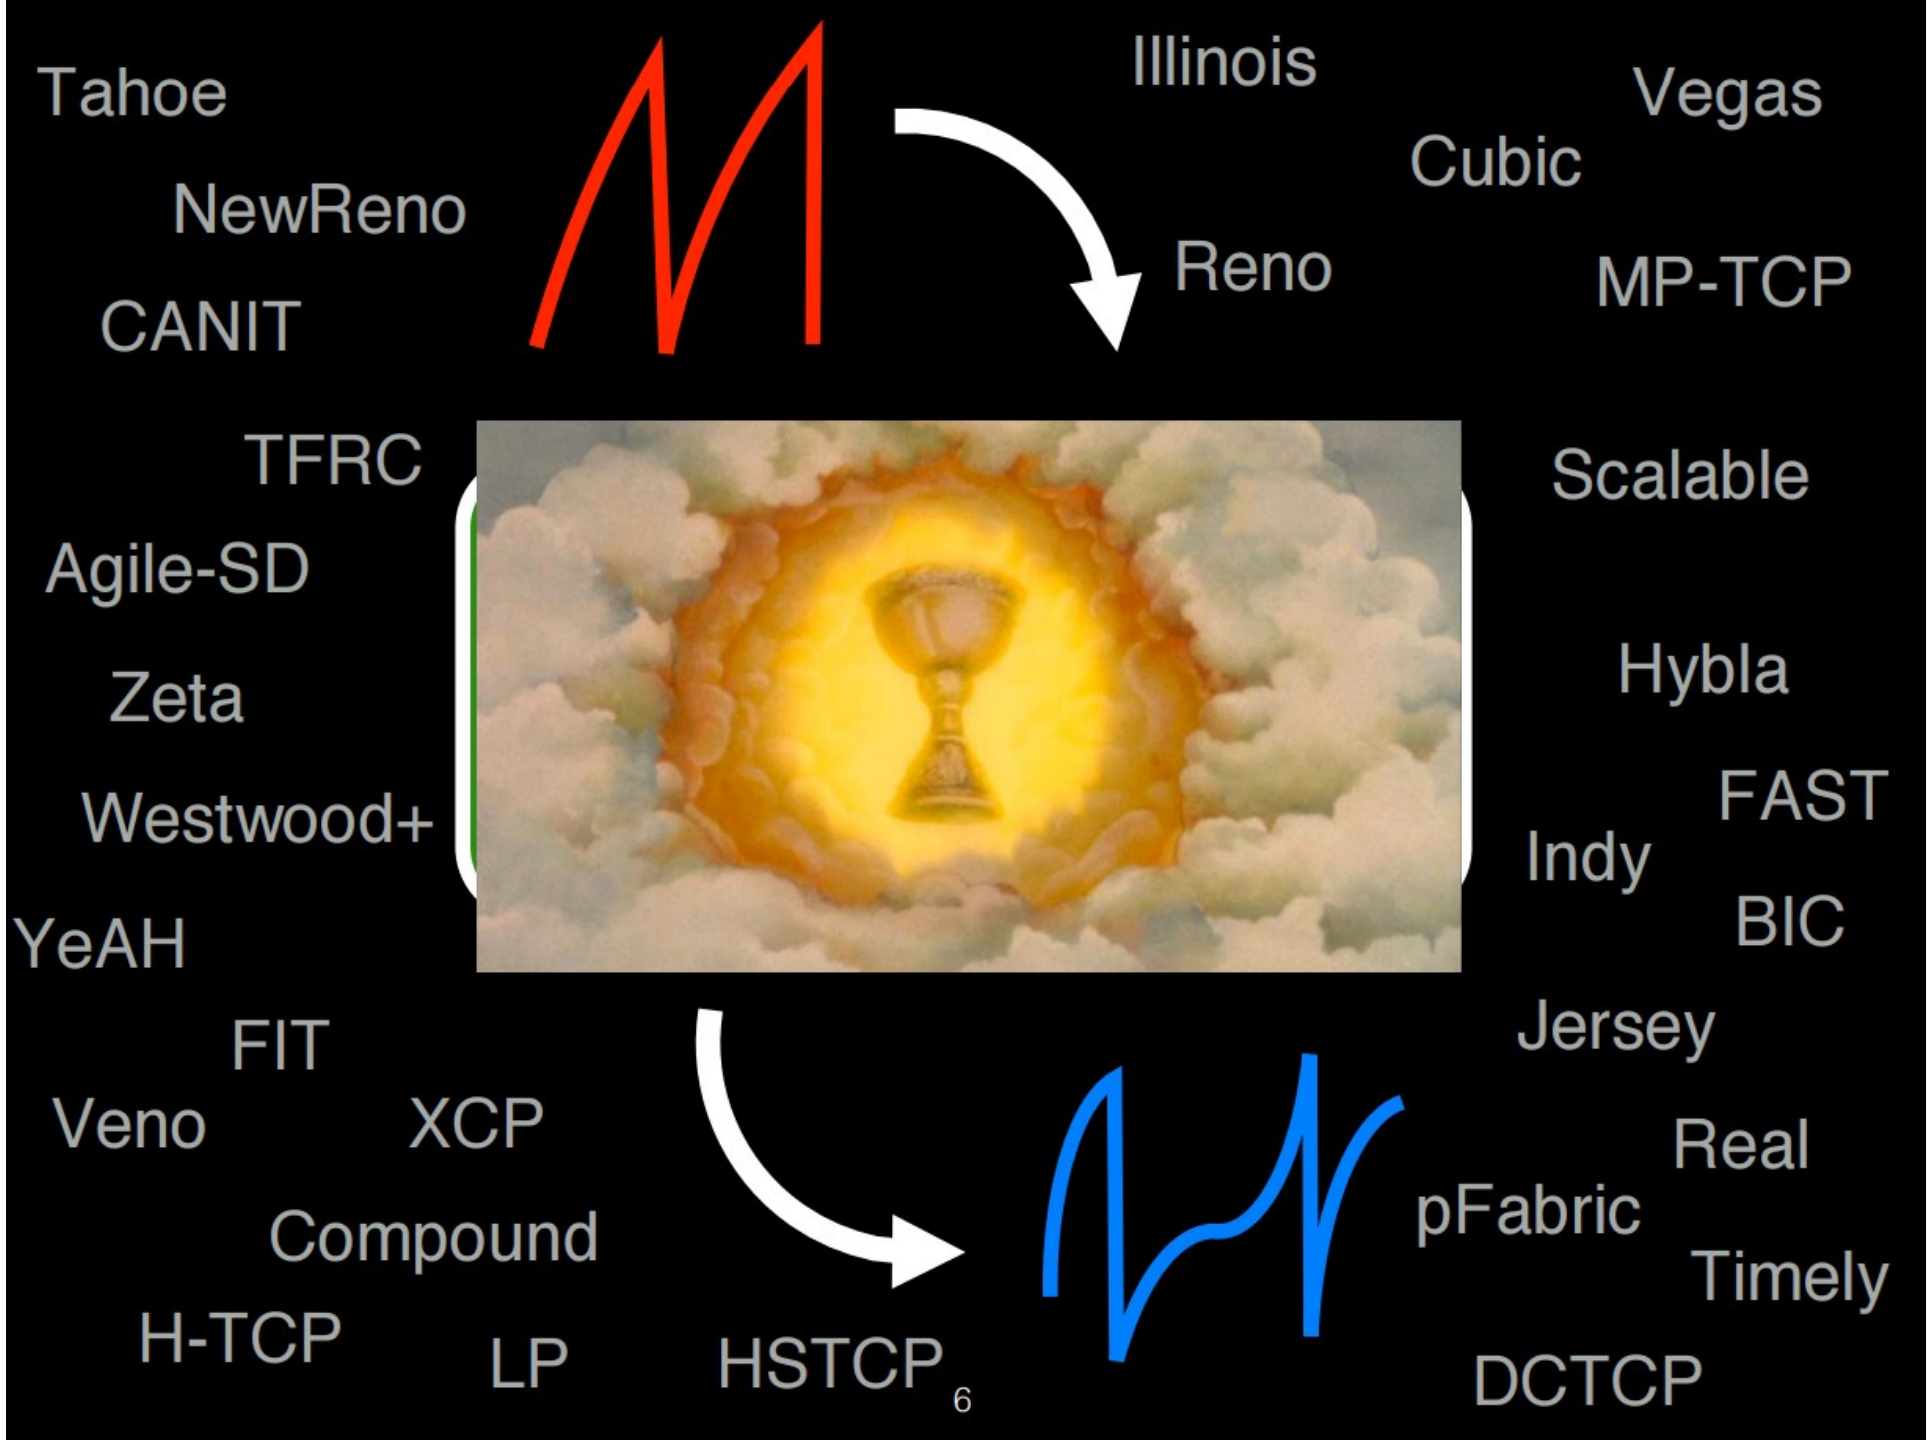
Tahoe
NewReno
CANIT
Illinois
Reno
Vegas
Cubic
MP-TCP
TFRC
Agile-SD
Zeta
Westwood+
YeAH
FIT
Veno
XCP
Compound
H-TCP
LP
HSTCP
Scalable
Hybla
FAST
Indy
BIC
Jersey
Real
pFabric
Timely
DCTCP

Управления перегрузкой TCP: принципы работы

- Взаимодействующие с сетью
  - Сетевые устройства сигнализируют о возникновении перегрузки (TCP/ECN)
- Без взаимодействия с коммутаторами
  - Перегрузка определяется косвенно (по потере пакета, увеличению задержки и т.д.)
- Реактивные (как правило, loss based)
  - Детектируют возниконовение перегрузок по факту
- Проактивные (как правило, delay based)
  - Ограничивают пропускную способность соединения, предчувствуя скорую перегрузку

Управление перегрузкой: скорость реакции

- При отсутствии дополнительных сервисных пакетов отправитель получает информацию из поступающих к нему ACK-сообщений
- ACK-сообщение, соответствующее отправленному пакету, поступает спустя один Round Trip Time (RTT)
- Хосты способны адаптироваться к состоянию сети не быстрее, чем RTT

Additive Increase Multiple Decrease (AIMD)

В устойчивом состоянии график зависимости окна перегрузки (CWND) от времени (t) для алгоритма TCP Reno имеет вид пилы

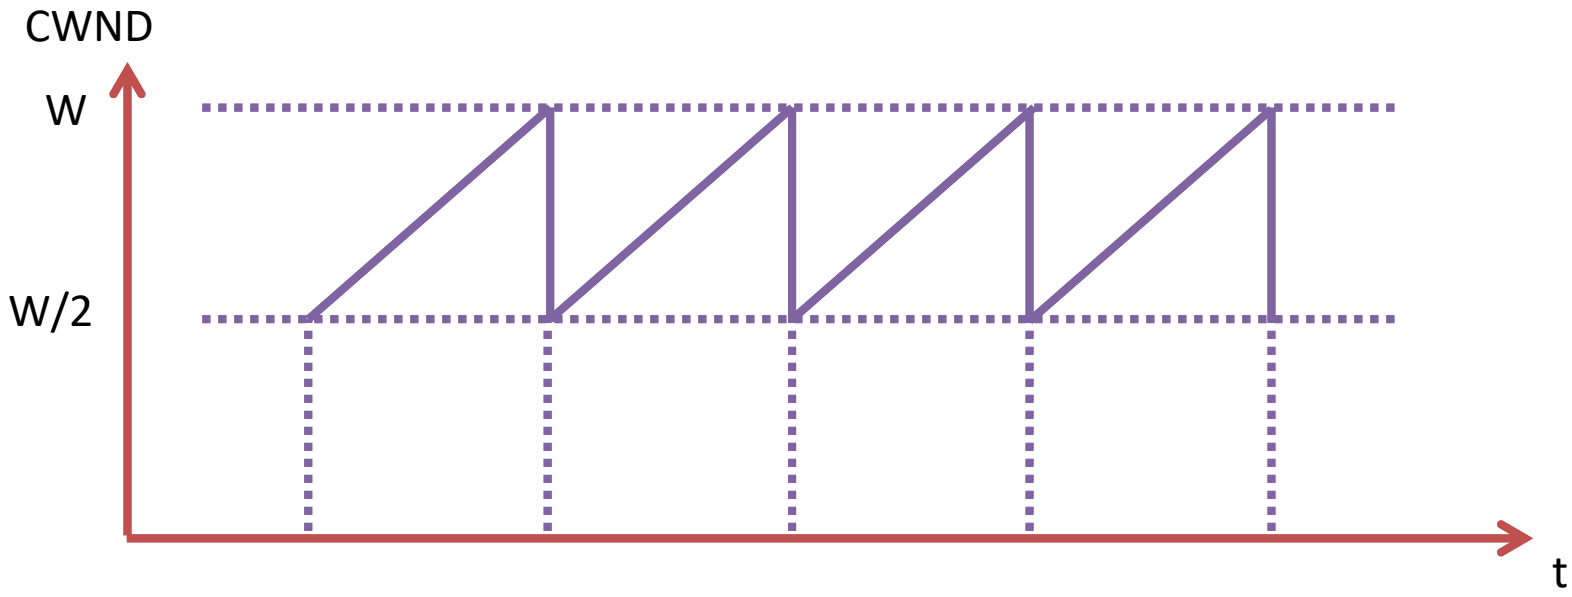

Зависимость размера congestion window от уровня потерь p

- Между последовательными потерями:
  - проходит W/2 раундов алгоритма перегрузки, который увеличивает окно от W/2 до W
  - передаётся 1/p пакетов
- $(W/2 + W)/2 * W/2 = 1/p$
- $W = sqrt(8/3p)$

Проблемы TCP Reno:
1) сети с большим BDP

- ***BDP = Bandwidth Delay Product***
- TCP Reno растёт слишком медленно
  - При использовании канала 10 Gb x 100 ms для увеличения CWND от W/2 до W потребуется 50000 RTT (более часа)
  - При достаточно частых потерях пакетов алгоритм никогда не сможет добраться до максимальной пропускной способности канала

Проблемы TCP Reno:
2) RTT fairness

- Потоки с меньшим RTT адаптируются к пропускной способности канала быстрее, чем потоки с большим RTT
- Более “быстрые” соединения получают преимущество и используют большее количество сетевых ресурсов

Проблемы TCP Reno: 3) TCP friendliness

- В теории delay-based алгоритмы управления перегрузкой, как правило, могут работать более эффективно
  - Алгоритмы могут избегать потерь пакетов
  - Значение задержки содержит больше информации о сетевом окружении
- На практике delay-based соединения имеют плохую производительность, потому что передаются вместе с loss-based соединениями
  - Буферы коммутаторов перегружаются вне зависимости от стратегий delay-based соединений

TCP Cubic

- Идея – предположить, что потери случаются через равные промежутки времени
- Размер окна наращивается таким образом, чтобы он достигал своего максимума в момент следующей потери
  - Размер окна не зависит от RTT!
- Текущий размер окна определяется кубической функцией
  - быстрый рост после перегрузки

TCP Cubic: CWND

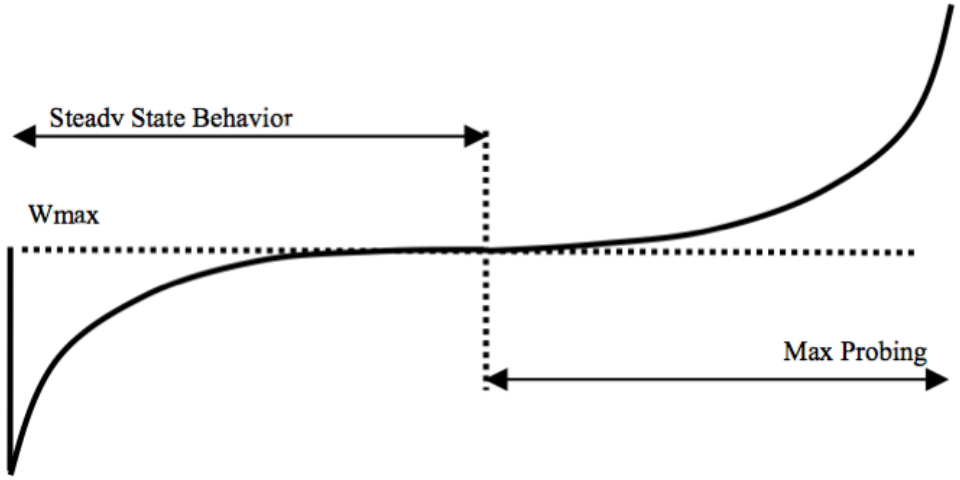

- Изначально CWND растёт быстрее, чем у TCP Reno
- При увеличении вероятности потери рост замедляется
- CWND равен предполагаемому оптимуму максимально долго
- Если потери не происходит – потолок соединения неверен
- Алгоритм начинает быстрый рост, чтобы найти правильную пропускную спсобсность соединения

TCP Compound

- Идея – эффективная комбинация delay-based и loss-based алгоритмов
  - Скорость delay-based соединений
  - Равная борьба с loss-based соединениями
- Окно перегрузки состоит из loss-based и delay based компонент:
  - Loss-based изменяется по аналогии с TCP Reno
  - Delay-based изменяется экспоненциально в зависимости от текущей задержки: может как расти, так и уменьшаться

TCP Compound

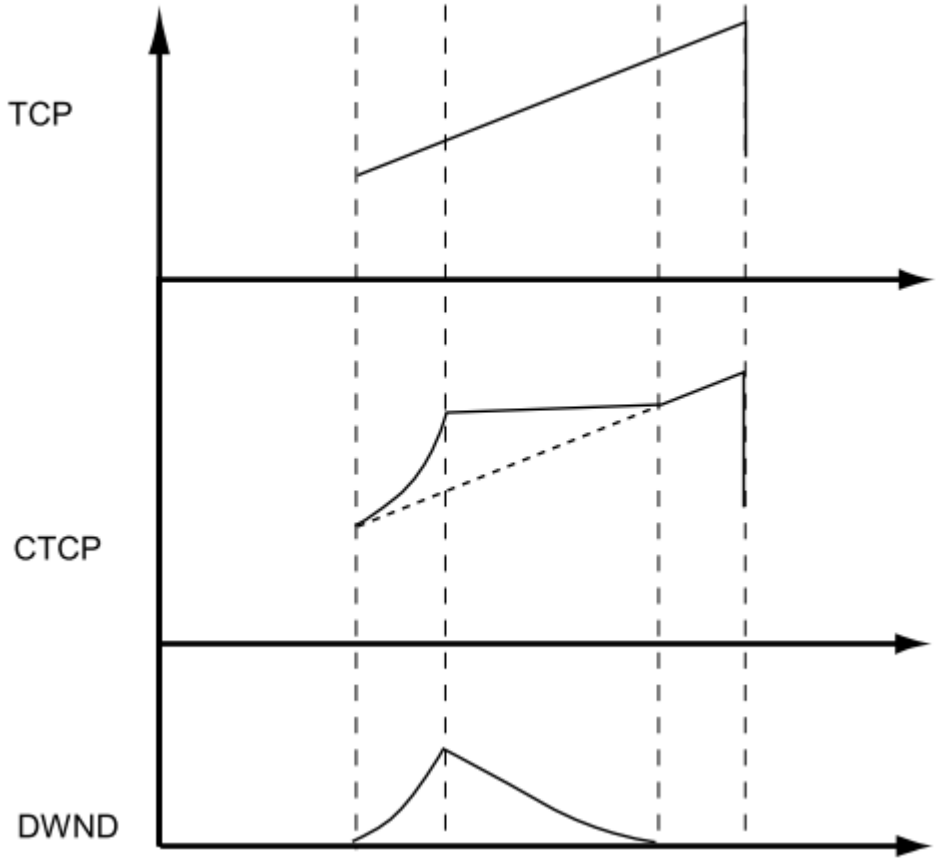

Data Center TCP: специализированный протокол управления перегрузкой для ЦОДов

- Горизонтальное масштабирование сервисов: map-reduce
  - Поступающие на сервер запросы отправляются на вспомогательные сервера
  - Каждый из серверов выполняет обработку запроса в своей области и возвращает результат на центральный сервер
  - Центральный сервер комбинирует результаты и формирует окончательный ответ на запрос

Data Center TCP: специализированный протокол управления перегрузкой для ЦОДов

- Множество “коротких” соединений конкурирует с долго живующими соединения
- Частый сброс пакетов коротких соединений увеличивает латентность системы
  - В буферах коммутаторов не помещается множесто одновременных ответов
  - Буферы коммутаторов заполнены пакетами долго живущих соединений

Data Center TCP: специализированный протокол управления перегрузкой для ЦОДов

- Идея – маркировать пакеты соединений, передающиеся через буферы с высоким уровнем загруженности
- При достаточно частом поступлении маркированных пакетов отправитель уменьшает размер CWND
- При редком поступлении маркированных пакетов размер CWND увеличивается

Сосуществование разных TCP в ЦОД

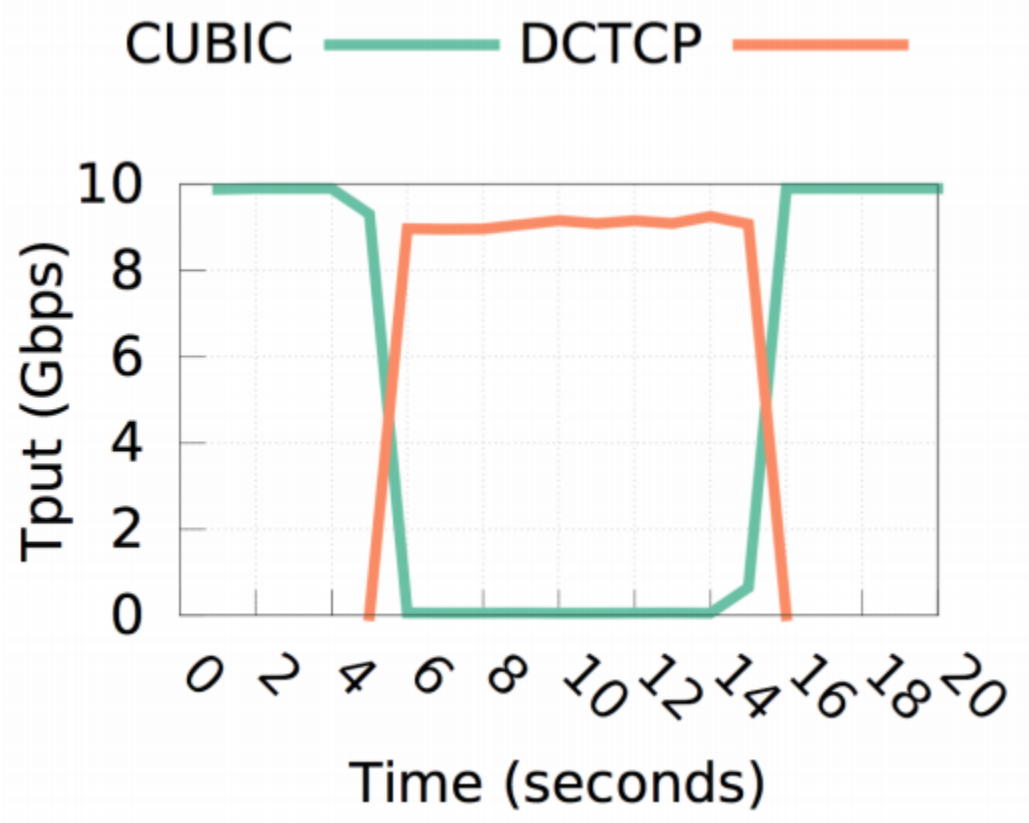

AC⚡DC: High Level View

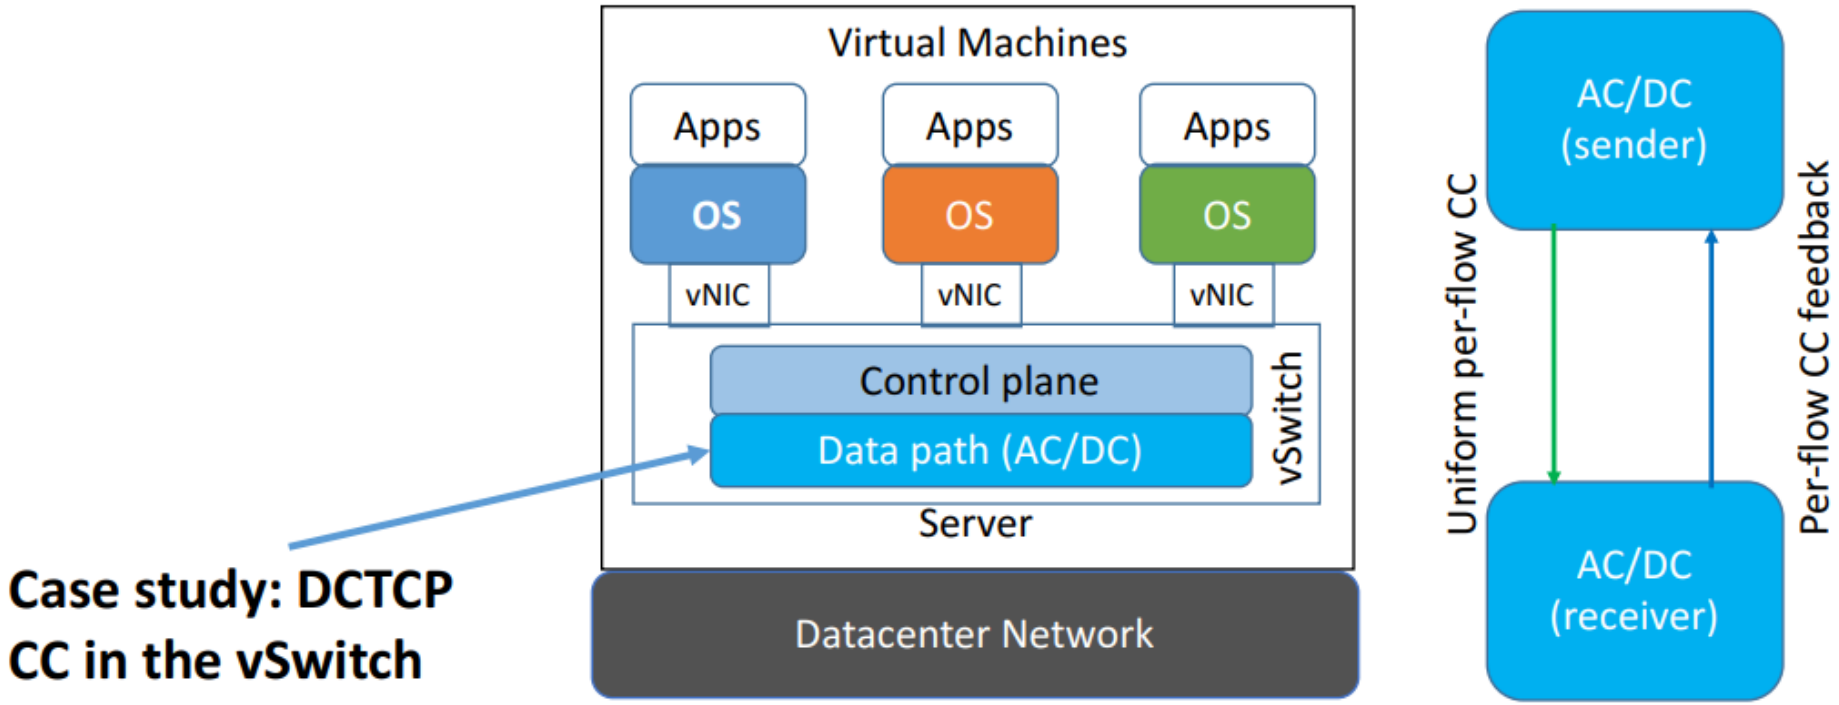

** AC/DC TCP: Virtual Congestion Control Enforcement for Datacenter Networks

Keqiang He, Eric Rozner, Kanak Agarwal, Yu (Jason) Gu, Wes Felter, John Carter, Aditya Akella

Классификация современных алгоритмов управления перегрузкой

1. Loss-based алгоритмы (Reno/NewReno, Cubic)
2. Delay-based алгоритмы (Vegas)
3. Гибридные алгоритмы (Compound TCP)
4. Capacity-based алгоритмы (BBR)
5. Алгоритмы, основанные на машинном обучении (QTCP)

BBR

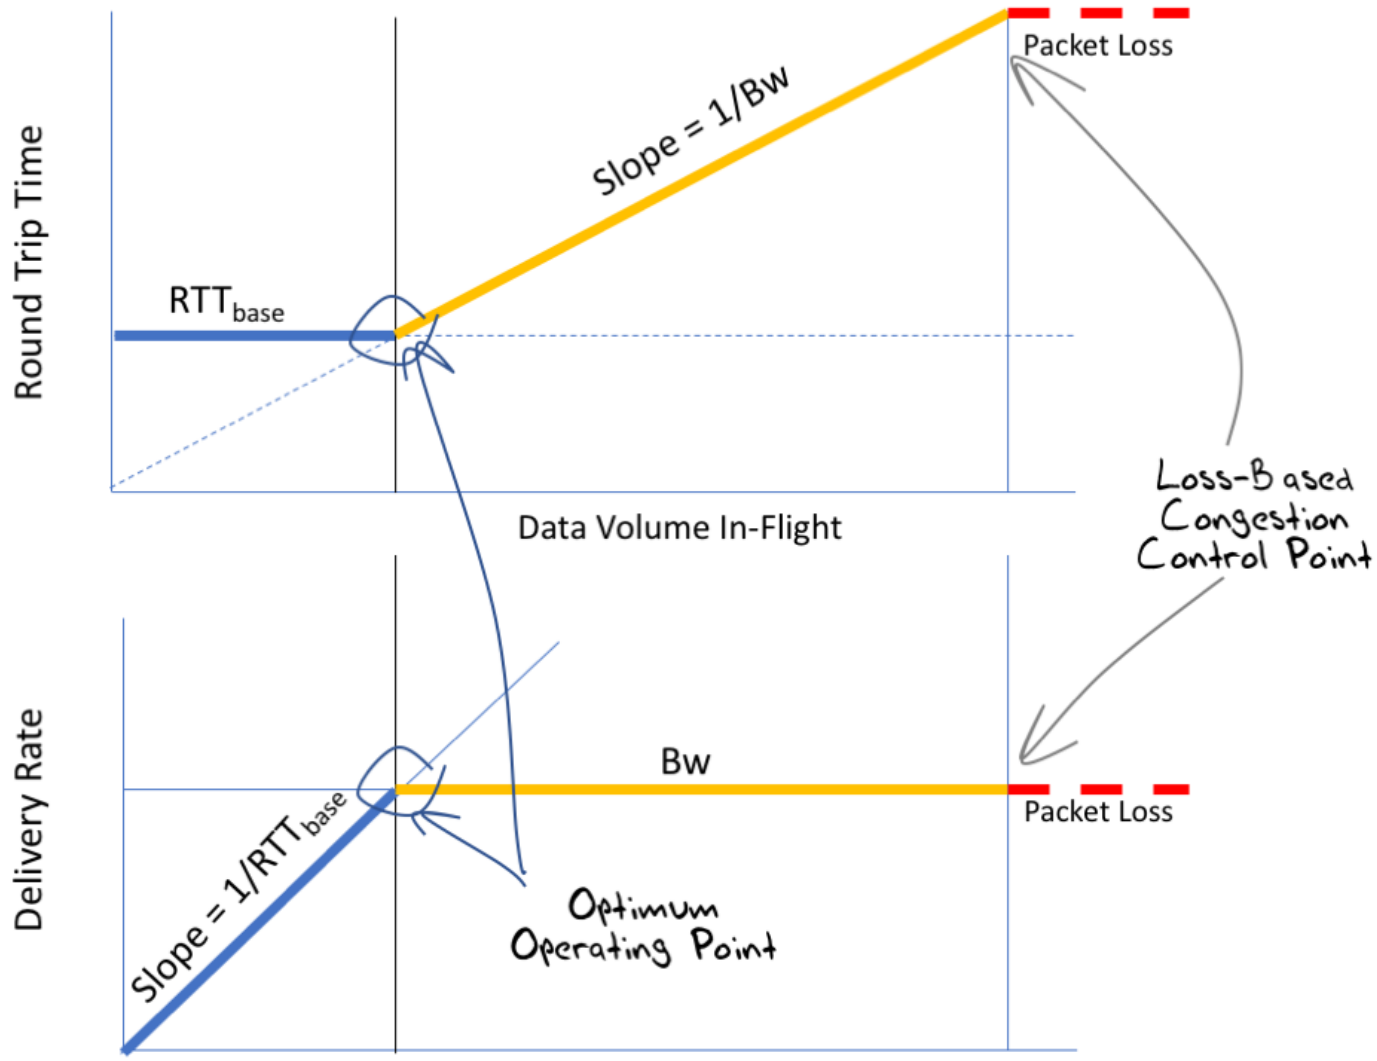
Round Trip Time
Slope = 1/Bw
Packet Loss
RTT$_{base}$
Loss-Based Congestion Control Point
Data Volume In-Flight
Delivery Rate
Bw
Packet Loss
Slope = 1/RTT$_{base}$
Optimum Operating Point

BBR

- Увеличение RTT вызвано
  - Изменением маршрута
  - Изменением пропускной способности узкого места
  - Увеличением задержки очередизации из-за трафика другого соединения
- Измеряем пропускную способность узкого места и минимальный RTT
- Временно увеличиваем скорость отправки:
  - Если измеряемая пропускная способность увеличилась – можем занять больше ресурсов
  - Если увеличилась задержка, то временно замедляем скорость для освобождения буфера
- Не реагируем на потери

BBR vs Cubic

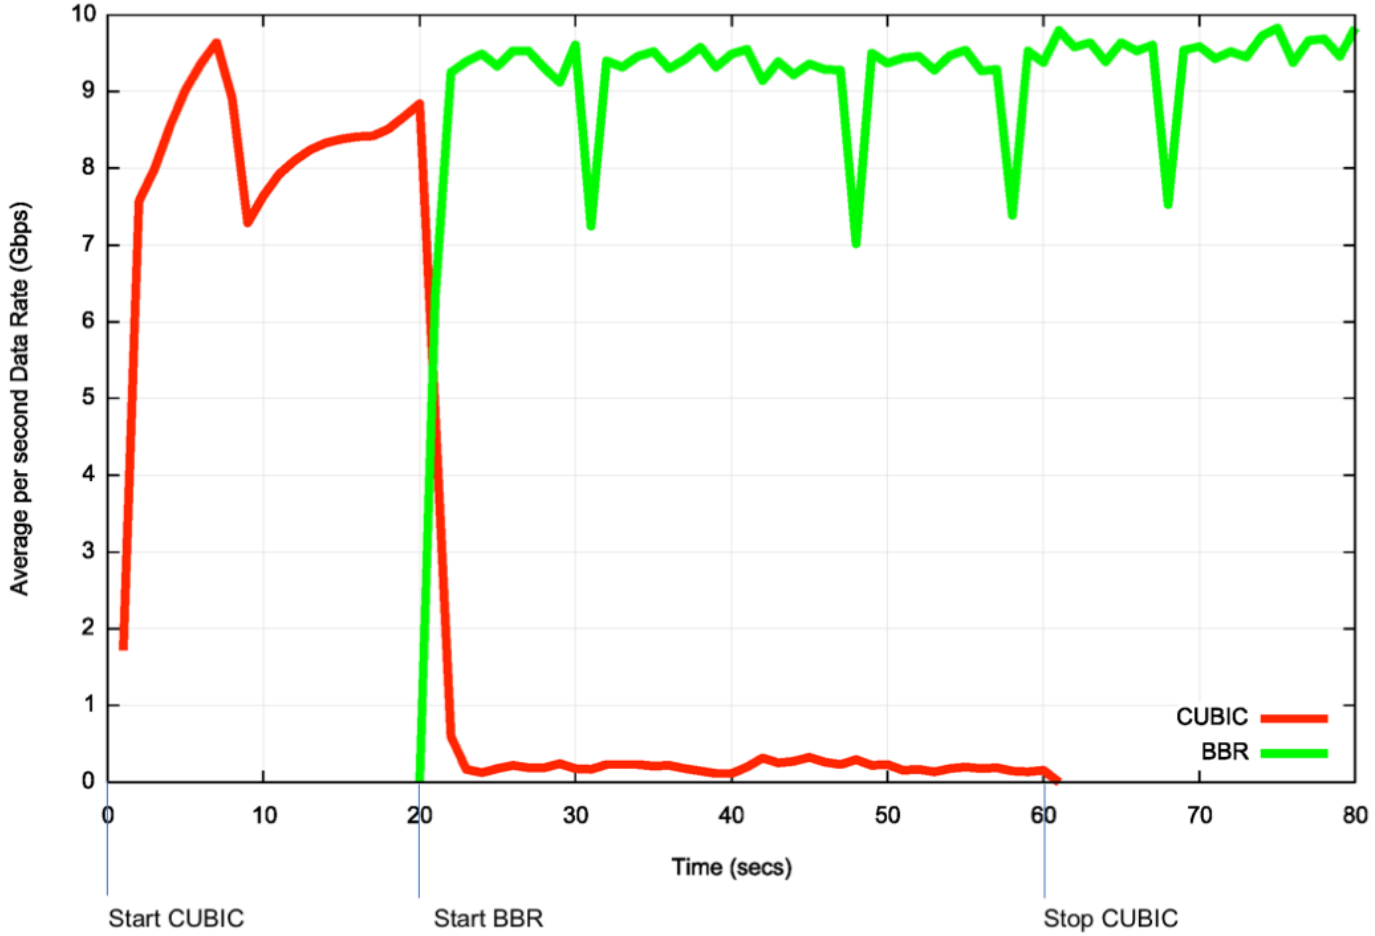
Average per second Data Rate (Gbps)
Time (secs)
CUBIC
BBR
Start CUBIC
Start BBR
Stop CUBIC

BBR vs Cubic vs BBR

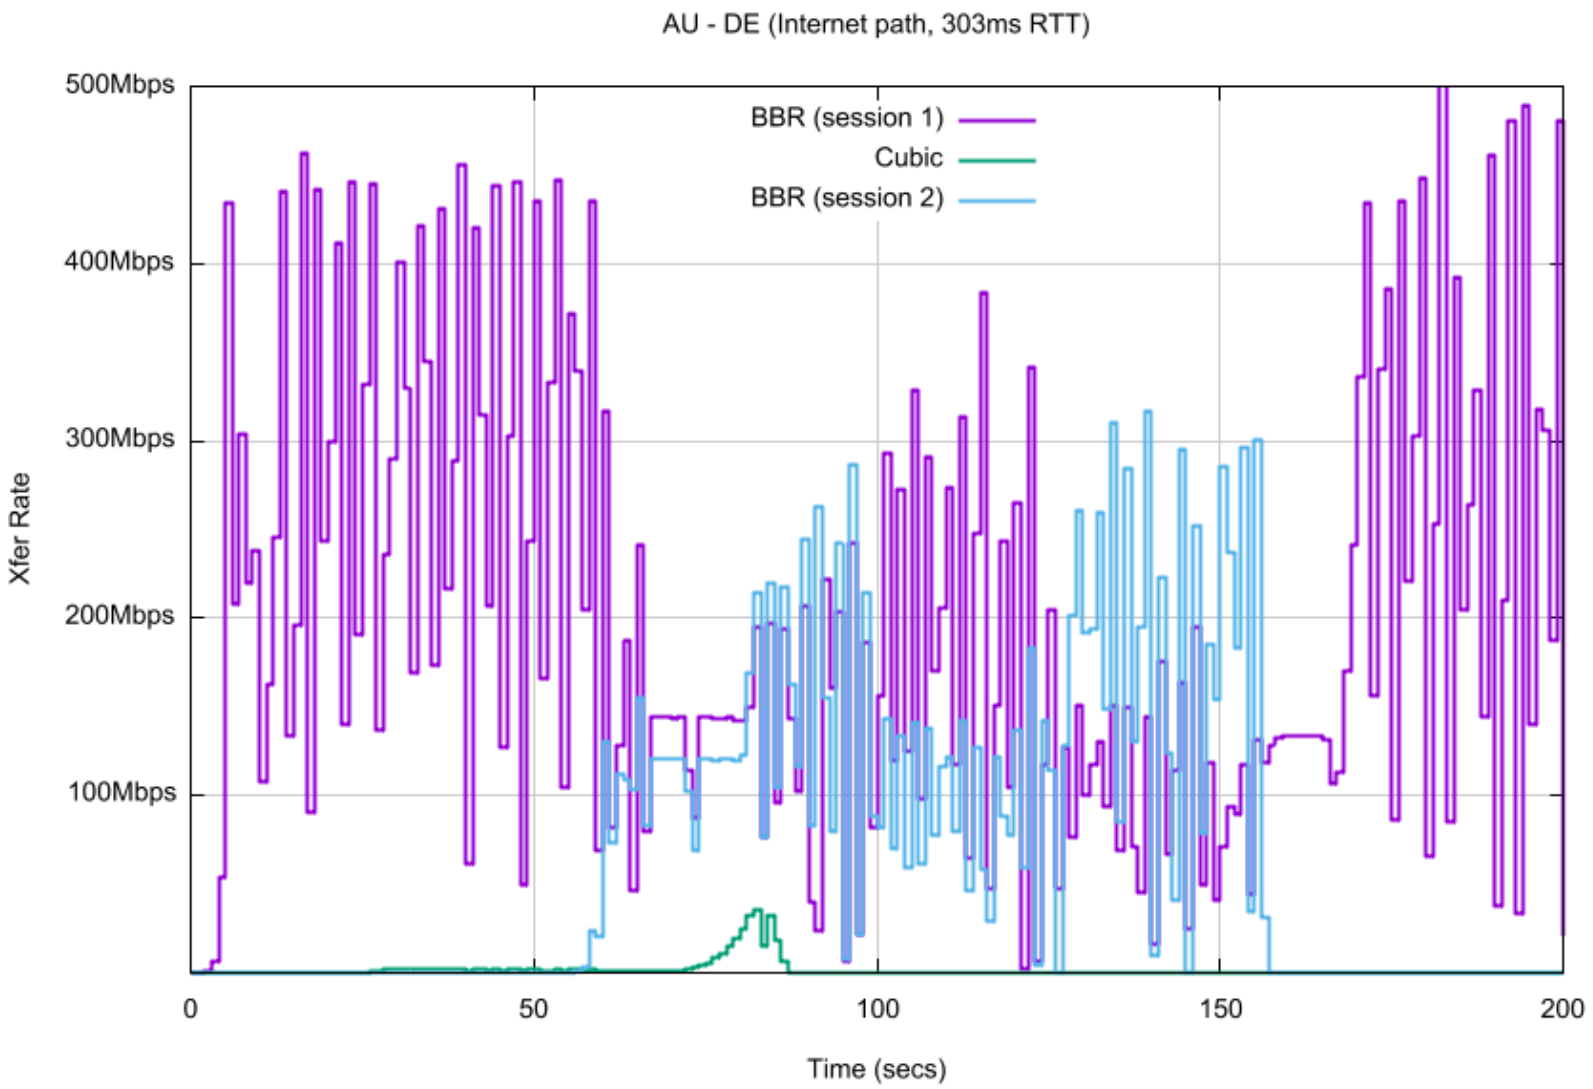

Проблемы BBR

- Aggressive startup operation
- Aggressive bandwidth probing
- RTT unfairness
- Unfairness with loss-based congestion control

BBRv2

	BBRv1	BBRv2

Model Parameters	`BtlBw`, `RTprop`	`BtlBw`
		`RTprop`
		loss_rate
		Aggregation

Packet loss as congestion signal	N/A	loss_rate exceeds loss_threshold
ECN	N/A	DCTCP/L4S style ECN
Exit startup	throughput plateaus	throughput plateaus or loss/ECN rate exceeds threshold
cwnd in ProbeRTT	4 packets	BDP/2

Y. -J. Song, G. -H. Kim, I. Mahmud, W. -K. Seo and Y. -Z. Cho, "Understanding of BBRv2: Evaluation and Comparison With BBRv1 Congestion Control Algorithm," in *IEEE Access*, vol. 9, pp. 37131-37145, 2021

ML в алгоритмах управления перегрузкой

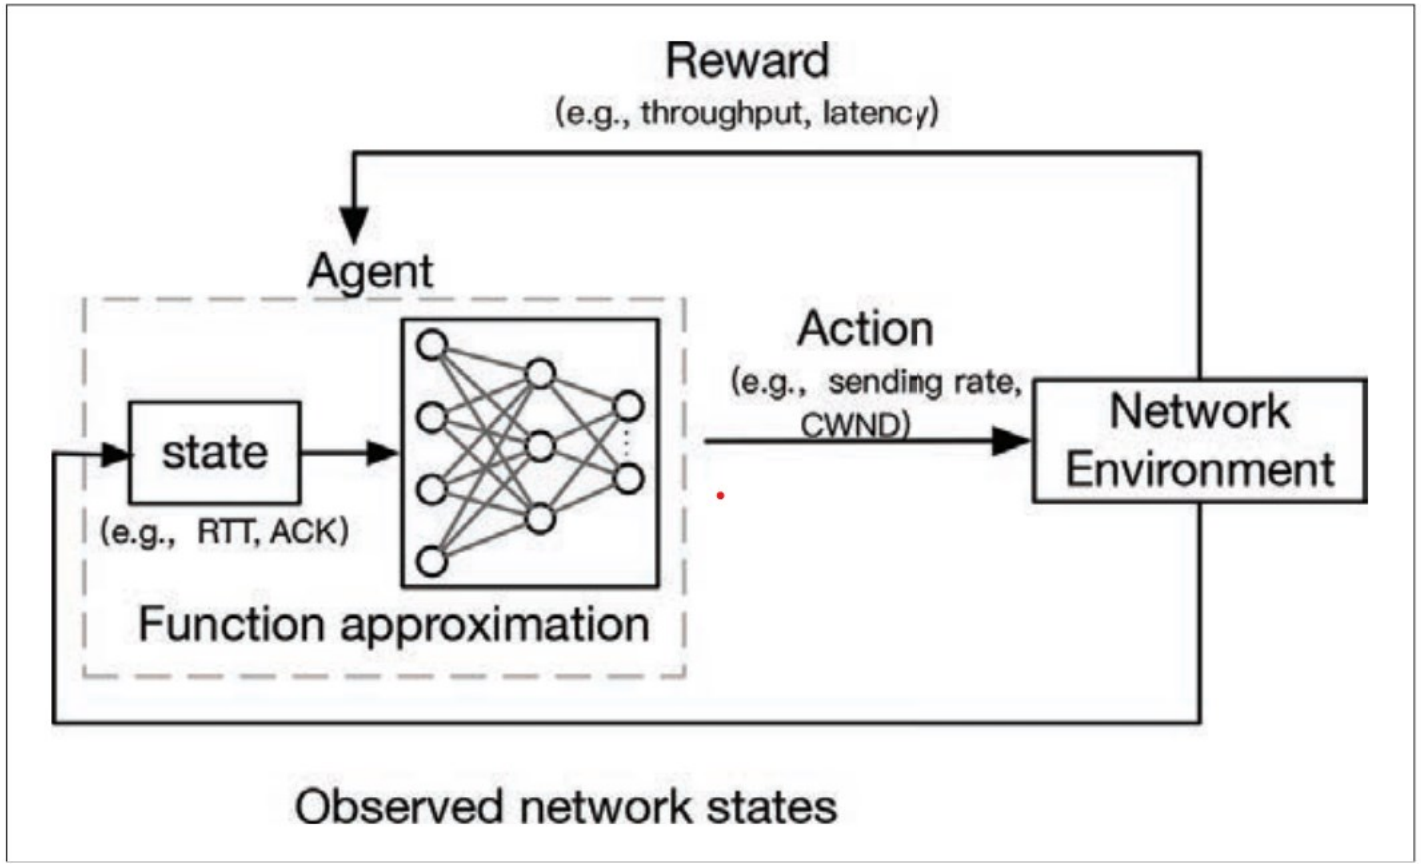

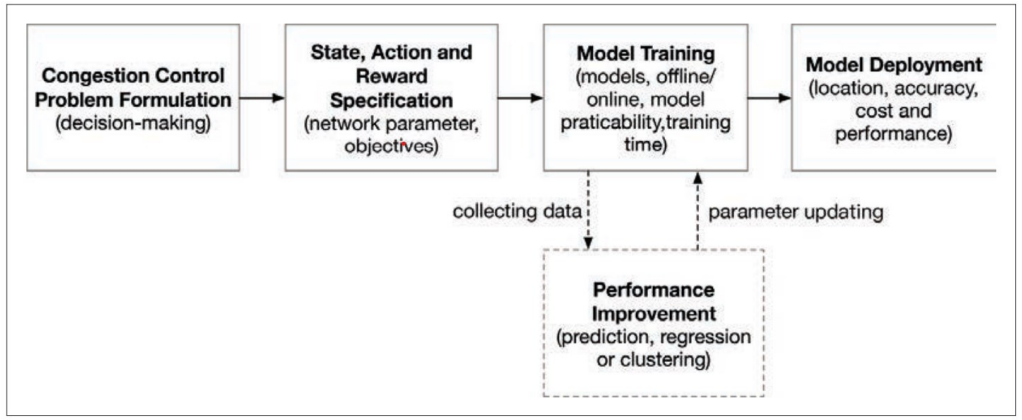

RCP

- Справедливым образом рассчитывается скорость каждого потока
- Уменьшает время завершения потоков

$$R(t) = \frac{C}{N(t)} \Rightarrow R(t) = R(t-d) + \frac{\left(\alpha(C - y(t)) - \beta\frac{q(t)}{d}\right)}{\hat{N}(t)}$$

$$\Downarrow$$

$$R(t) = R(t-T)\left(1 + \frac{\frac{T}{d}\left(\alpha(\eta \cdot C - y(t)) - \beta\frac{q(t)}{d}\right)}{\eta \cdot C}\right)$$

Программа курса

Подходы:

1. ***Управление перегрузкой***
   - Современные протоколы управления перегрузкой TCP
2. ***Демультиплексирование/мультиплексирование***
   - Многопоточные транспортные протоколы
   - Маршрутизация на уровне интернет провайдеров
   - Network Coding
3. ***Сегментация***
   - TCP Proxy
4. ***Балансировка***
   - Балансировка нагрузки и управление трафиком
5. ***Преобразование сообщений***
   - FEC
   - Сжатие

Модели оценки качества сервиса:

- Активные и пассивные измерения
- NS3: моделирование поведения сети с высокой точностью
- Сетевое исчисление: математический подход к качеству сервиса

Примеры:

- Управление сетевыми ресурсами в Центрах Обработки Данных
- Обеспечение качества сервиса в сетях доставки контента
- Пропускная способность по требованию