Введение в сетевые технологии для пользователей и администраторов ГРИД

Антон Теслюк

31 января 2006, ИФВЭ Протвино

Введение

- **Цели этого курса:**
  - дать пользователям и администраторам сайтов грид обзор современных сетевых технологий и сервисов, а также тенденций развития сетевых технологий в ближайшем будущем
  - детально рассмотреть вопросы производительности сети при передачи больших объемов данных. Что делать если сеть работает медленно?
  - обзор метрик и средств сетевого мониторинга для грид. Что мерить и чем мерить?
  - обзор способов решения сетевых проблем в распределенных грид-инфраструктурах. Что делать если сеть работает не так как положено?

Содержание

- **Обзор основных сетевых технологий:**
  - Протоколы IP, IPv6
  - IP and QoS (DiffServ, Premium IP)
  - MPLS, LightPath
  - TCP
- **Вопросы производительности при передаче больших массивов данных – TCP Congestion Control**
- **Обзор метрик и средств сетевого мониторинга для грид (EDG E2EMonit tools, NPM by JRA4)**
- **Решение сетевых проблем в глобальных информационных инфраструктурах – EGEE NOC (ENOC)**

IP сети

- **IP protocol**
  - RFC 791, сентябрь 1981 года
  - принцип коммутации пакетов
  - нет гарантий доставки пакета, нет гарантий что пакеты придут в правильном порядке правильному адресату (если вообще придут ☺)
  - нет встроенных средств для поддержки QoS
  - размер заголовка не фиксирован
  - мало адресов, распределение адресов по странам очень неравномерно (особенно мало адресов досталось Японии и Китаю)
  - адресные блоки плохо агрегированы, большие таблицы маршрутизации, большие требования к производительности маршрутизаторов, дорогая маршрутизация

IPv6

- **IPv6 протокол**
  - RFC 2460, декабрь 1998 года
  - 128 бит на адрес. Очень много адресов (~10^38), хватит на каждый компьютер, принтер, холодильник, чайник и.т.д.
  - Фиксированный размер заголовка, заголовок максимально упрощен
  - Агрегирование блоков адресов (RFC 2374)
  - Встроенные механизмы автоконфигурирования (IPv6 stateless autoconfiguration, neighbor discovery), поддержка мобильности (IPv6 multihoming)
  - Реализован в большей части ключевого ПО (в т.ч. и в grid middleware)
  - Тем не менее, реальное распространение IPv6 и полная замена им IPv4 идет с трудом. В IPv6 пока нет killing applications

IP and QoS

- **Обычно IP трафик – best effort traffic. Все IP пакеты эквивалентны, имеют одинаковый приоритет, обслуживаются в одной очереди маршрутизатора**

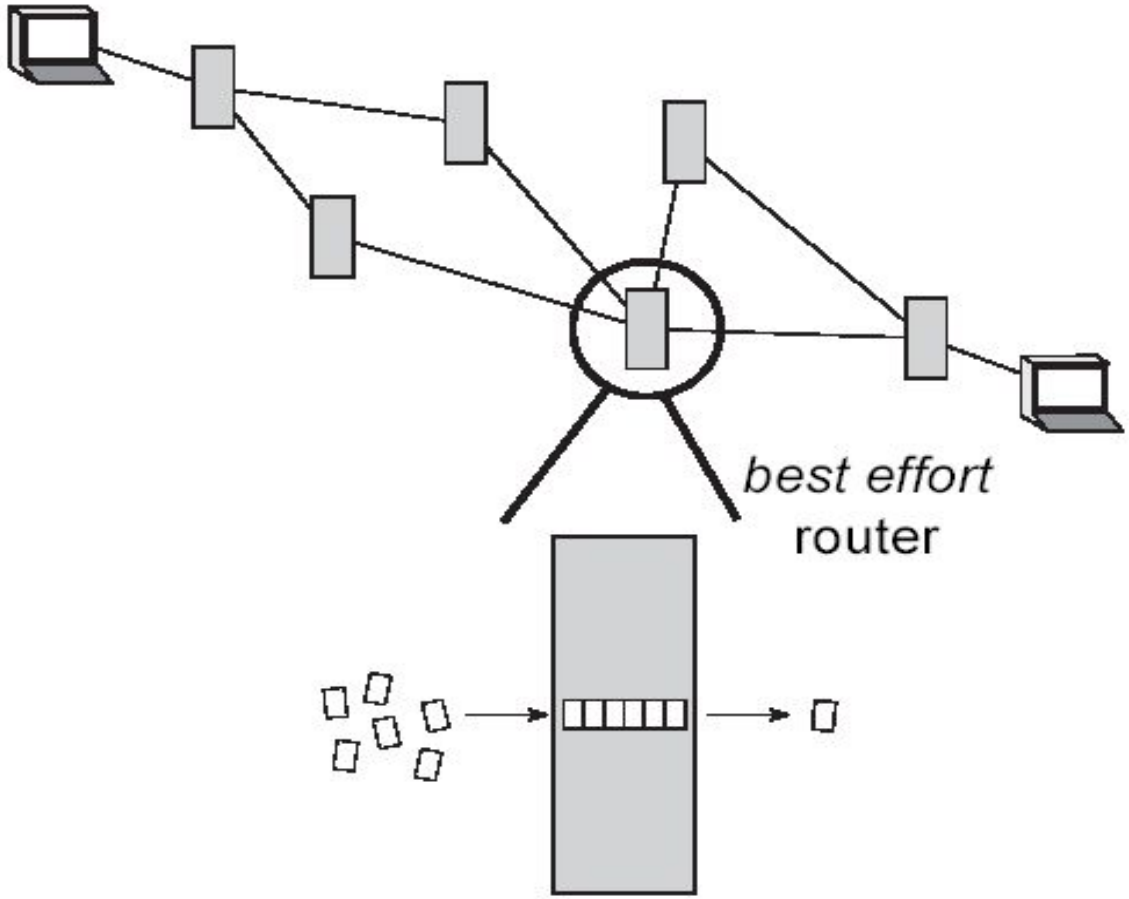

DiffServ

- RFC 2474, декабрь 1998 (заменил RFC 1455 и 1349, 94 и 92 года соответственно)
- Пакеты обрабатываются маршрутизаторами зависимости от значения поля DSCP (младшие 6 бит байта TOS в IP заголовке)

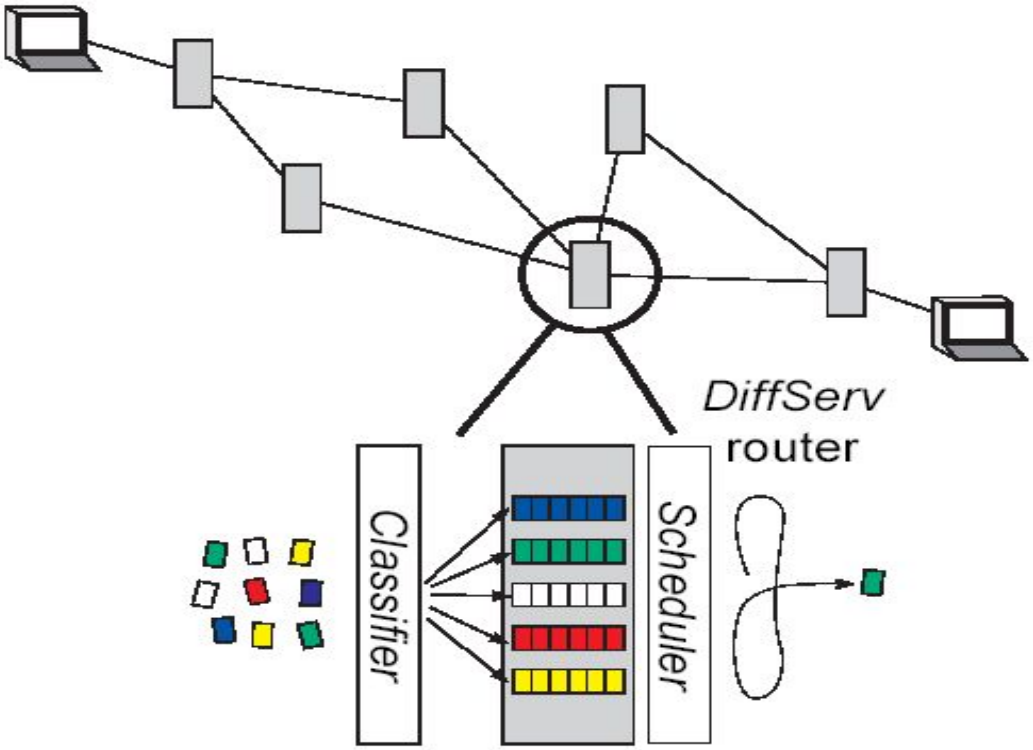

Premium IP

- пример реализации DiffServ – Expedited Forwarding (EF), RFC 2598 (1999 год). Premium IP в GEANT
- пакеты с DSCP = 46 обслуживаются приоритетно по сравнению с остальными
- для надежного функционирования сети объем Premium IP трафика не должен превышать 10% от общего трафика в сети
- необходим контроль за трафиком

- в GEANT помимо приоритетного класса Premium IP существует низкоприоритетный класс трафика – Less than Best Effort (LBE).

QoS на L2 и L1

- **QoS на IP уровне – это достаточно сложно и дорого**
- **Гарантированный сервис можно реализовать и на канальном уровне (с точки зрения IP) – MPLS**
- **Виртуальный канал с требуемым QoS**

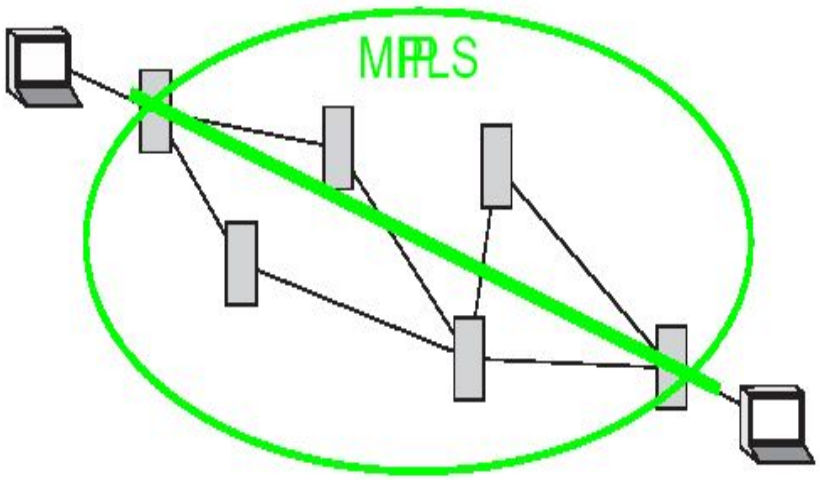

- **LightPath – гарантированный сервис на L1**
  - между двумя узлами выделенный ‘light path’ (например выделенная длина волны в оптическом кабеле), прямое физическое соединение

TCP

- **RFC 791, сентябрь 1981**
- **предоставляет приложениям сервис надежной передачи двунаправленного потока данных**
  - поток данных определяется IP-адресами двух узлов и парой TCP портов: ip1:port1 ↔ ip2:port2
  - TCP порты позволяют разделять трафик разных приложений (и разных потоков одного приложения)
- **e-mail (smtp, pop, imap), ftp, http, gridftp, telnet, ssh и. т.д. используют TCP**
- **каждый пакет имеет свой порядковый номер (sequence number)**
- **получатель отправляет подтверждения отправителю о получении данных**

TCP

- **Пакет может прийти искаженный**
  - TCP Checksum (но всего CRC16)
- **Пакет может не дойти**
  - он будет отправлен заново
- **Пакеты могут задержаться в сети**
  - в TCP используются адаптивные таймеры
- **Пакеты могут прийти в разной последовательности**
  - с помощью порядковых номеров пакетов порядок будет восстановлен
  - в большинстве реализаций TCP частое нарушение порядка пакетов будет воспринято как перегрузку сети
  - это может быть проблемой в случае load balancing

TCP

- **Отправитель может отправлять данные быстрей чем может получить получатель**
  - в каждом TCP-пакете получатель указывает количество информации, которое он готов принять (поле Window)
- **Отправитель может пытаться отправлять больше данных, чем может передать сеть**
  - в TCP реализован механизм устранения заторов сети (end-to-end congestion control)
- **Механизм устранения заторов**
  - позволяет равномерно разделять пропускную способность сети между различными TCP потоками
  - предотвращает перегрузку сети избыточным трафиком

TCP Congestion Control

- **Принцип скользящего окна**
  - в сети не может находится больше пакетов, чем размер текущего окна (congestion window)
  - принцип линейное увеличение, степенное уменьшение
    - при каждом подтверждении о доставки пакета размер окна увеличивается на один пакет (MSS)
    - если пакет теряется, то размер окна уменьшается в два раза

TCP Congestion Control

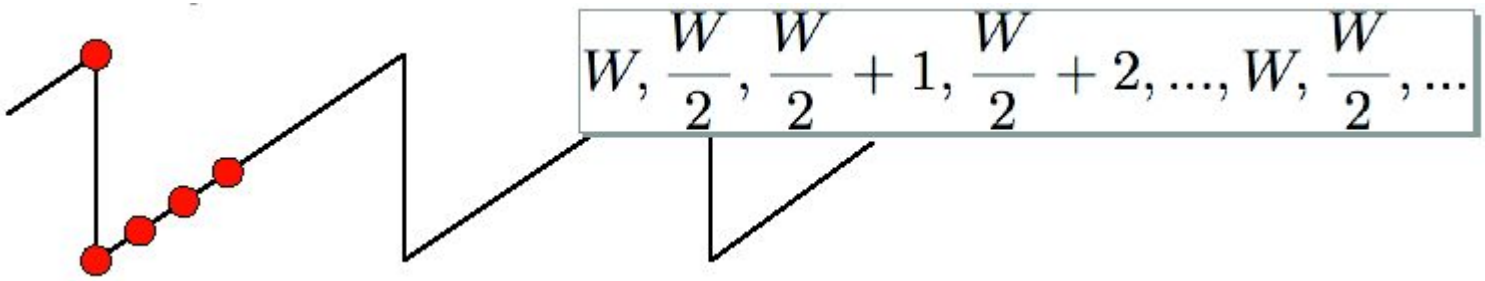

- **Стационарный режим одного TCP потока**
  - W – максимальный размер окна (определяется узким местом в сети) в пакетах, B – размер пакета, R – RTT
  - максимальная скорость передачи: W*B/R, средняя скорость передачи: T = ¾ W*B/R
  - вероятность потери пакета: p = 1/(3/8 W^2)
  - Получаем, что $T = \frac{\sqrt{6}B}{2R\sqrt{p}} = \frac{\sqrt{3/2}B}{R\sqrt{p}}$

Вопросы производительности

- Максимальная пропускная способность Wmax <= CWND_max/RTT
- Максимальный размер окна ограничен размерами TCP буфера отправителя, а также возможностями сети
  - например: BW=1Гбит/с, RTT = 70 ms, BW*RTT = 8.75 Mb – оптимальный размер буфера.
  - по умолчанию TCP буфер в FreeBSD равен 32кб (в Windows XP – 17kb). BW <= 3.74Mbps (для RTT=70ms)
  - в заголовке TCP window size – 16 бит (Wmax=64kb). RFC 1323 – дополнительная TCP option
  - для больших BW*RTT очень критичны потери пакетов (двух и более). RFC 2018 – Selective Acknowledgement.
  - Path MTU discovery (RFC 1191). Необходимо использовать максимальный размер пакета.
  - 32 бита для TCP sequence number может быть мало. Для 1Gbps Twrap= 17s. RFC 1323 – Timestamp TCP Option.
- Увеличение начального размера окна – RFC 2414

Linux Tuning

- **Kernel tuning (начиная с 2.4.xx и 2.6.xx):**
  - maximum receive window: /proc/sys/net/core/rmem_max
  - maximum send window: /proc/sys/net/core/wmem_max
  - TCP send buffers: /proc/sys/net/ipv4/tcp_wmem
  - автонастройка буфера при соединении: /proc/sys/net/ipv4/tcp_moderate_rcvbuf
  - RFC 1323 window scaling: /proc/sys/net/ipv4/tcp_window_scaling
  - RFC 2018 selective acks: /proc/sys/net/ipv4/tcp_sack
- **Настройки отдельного ПО:**
  - Gridftp: можно настроить socket buffer

Сетевой мониторинг в грид

- **Что мерить?**
  - Bandwith:
    - полная полоса пропускания (BW)
    - доступная полоса пропускания (ABW)
    - пропускная способность транспортного уровня (TCP, UDP)
  - Круговые характеристики QoS:
    - круговая задержка (RTT)
    - круговой процент потерь (Packet loss)
    - вариация круговой задержки (Jitter)
  - Односторонние характеристики QoS:
    - односторонняя задержка (OWD)
    - односторонний процент потерь (OWPL)
    - вариация задержки (IPDV)

Мониторинг

- **Как мерить?**
  - Активный мониторинг
    - ICMP ping – packet loss, delay
    - Iperf – available BW
  - Пассивный мониторинг
    - измерения имеющегося сетевого трафика – ntmd
- **Чем мерить?**
  - пакет e2emonit
    - Pinger
    - Iperf
    - UDPmon
  - Интерфейс NPM
    - Веб-интерфейс для пользователя
    - Интерфейс веб-сервисов для агентов

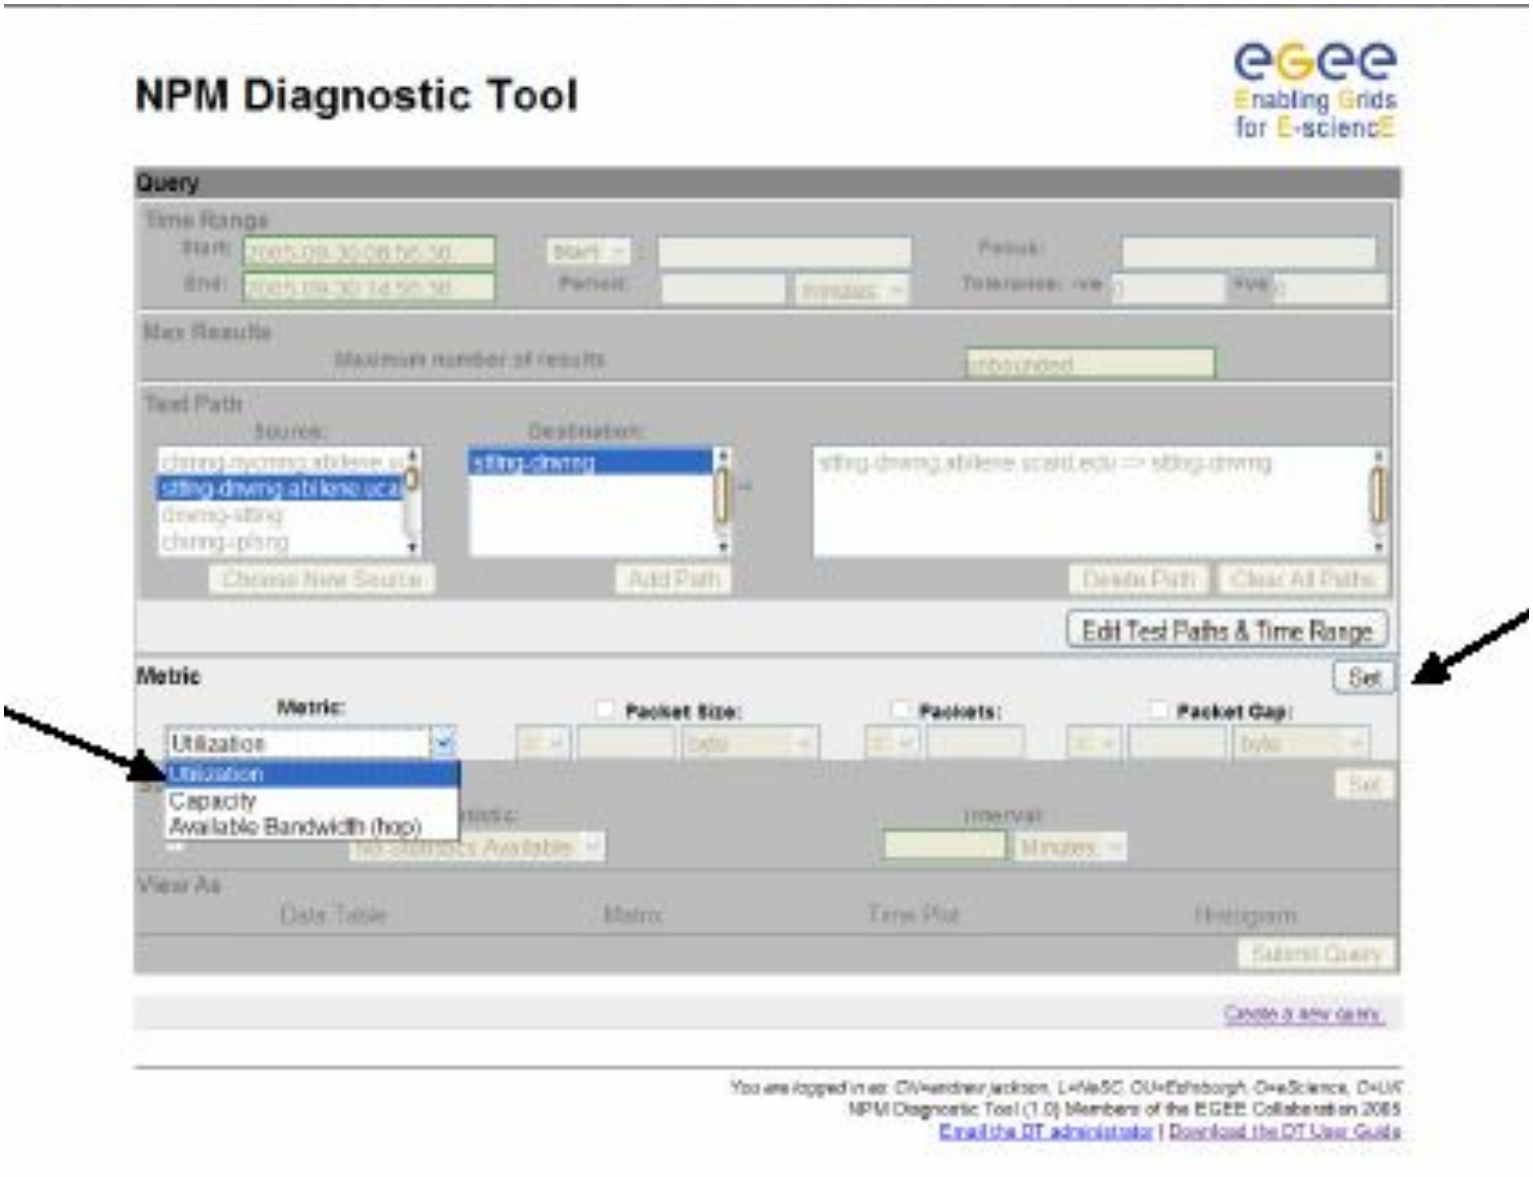
NPM Diagnostic Tool
Enabling Grids for E-sciencE
Query
Time Range
Max Results
Test Path
Source:
Destination:
Edit Test Paths & Time Range
Metric
Set
Metric:
Packet Size:
Packets:
Packet Gap:
Utilization
Capacity
Available Bandwidth (hop)
Interval:
Minutes
View As
Data Table
Metric
Time Plot
Histogram
Submit Query

Что делать если сеть не работает?

- **Network provider user support**
- **EGEE – ENOC**
  - Для пользователя интерфейс тикетов на www.ggus.org (Global Grid User Support)
  - Решение сетевых проблем ENOC (EGEE Network Operation Centre)
    - взаимодействие с провайдерами сетевых услуг
    - сбор и анализ оповещений от сетевых провайдеров
    - решение сетевых проблем
    - инсталляция и мониторинг SLAs

THE END