Начальный этап исследования стенда передачи Больших Данных по параллельным каналам данных (ПКС подход)

С. Хоружников[1] В. Грудинин[1] О. Садов[1,2] А. Шевель[1,2]
А. Каирканов[1] В. Титов[1,3]

[1]СПб НИУ ИТМО

[2]НИЦ «Курчатовский институт»

[3]СПбГУ

17.07.2014

Обзор

- Источники Больших Данных
- Архитектура Больших Данных
- Технология передачи Больших Данных
- Наши исследования

Источники Больших Данных

- Экспериментальные установки
  - Широкоугольный обзорный телескоп-рефлектор
    (Large Synoptic Survey Telescope, (LSST, $\approx$ 2020)
    `http://www.lsst.org`, 15 ТБ/ночь (10 ПБ/год)
  - Радиоинтерферометр «Квадратная километровая решетка»
    (Square Kilometre Array, SKA, $\approx$ 2019–2024)
    `https://www.skatelescope.org/`, 300-1500 ПБ/год
  - ЦЕРН
    `http://www.cern.ch`, 20 ПБ/год (обрабатывается 1 ПБ/день)
  - Международный экспериментальный термоядерный реактор
    (International Thermonuclear Experimental Reactor, ITER, $\approx$ 2020)
    `http://www.iter.org`, 1 ПБ/год
  - Решетка черенковских телескопов
    Cherenkov Telescope Array, CTA, $\approx$ 2015–2020
    `http://www.cta-observatory.org/`, 20 ПБ/год
  - ГАЙЯ
    Global Astrometric Interferometer for Astrophysics, GAIA 2014
    `http://sci.esa.int/gaia/`, 200 ТБ/год – 1 ПБ/год

Рост сетевого трафика

Тенденция роста трафика ESnet

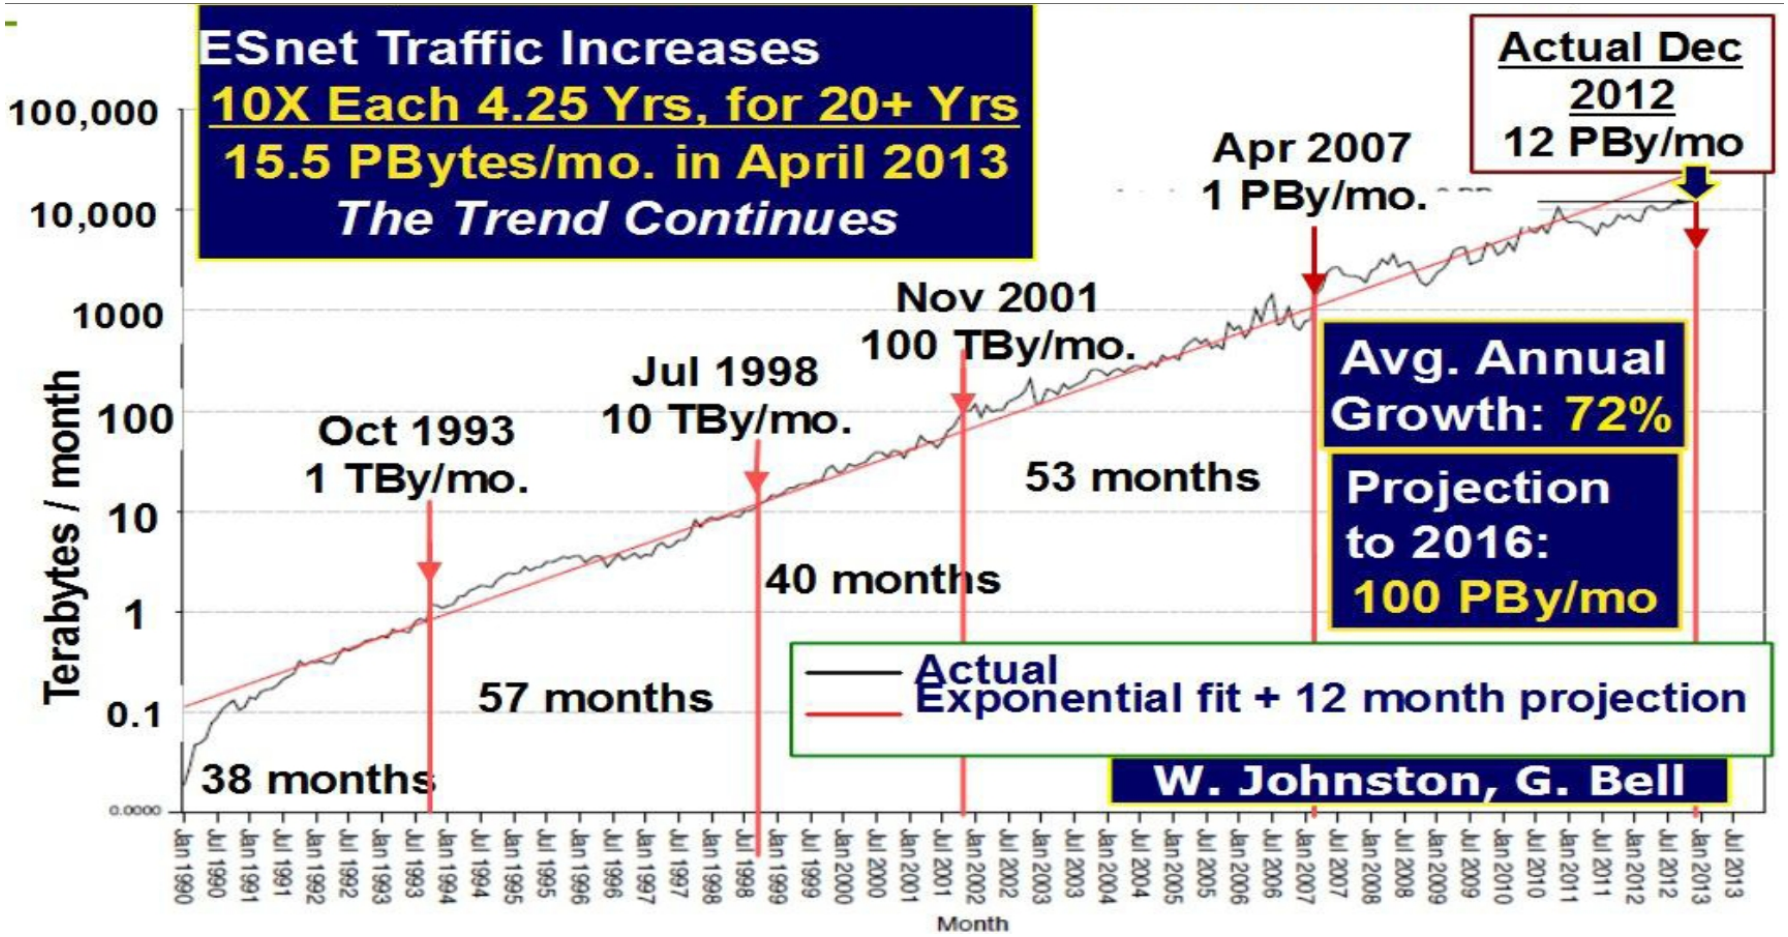

График ежемесячного входного трафика ESnet,
январь 1990 – декабрь 2012

3 V:

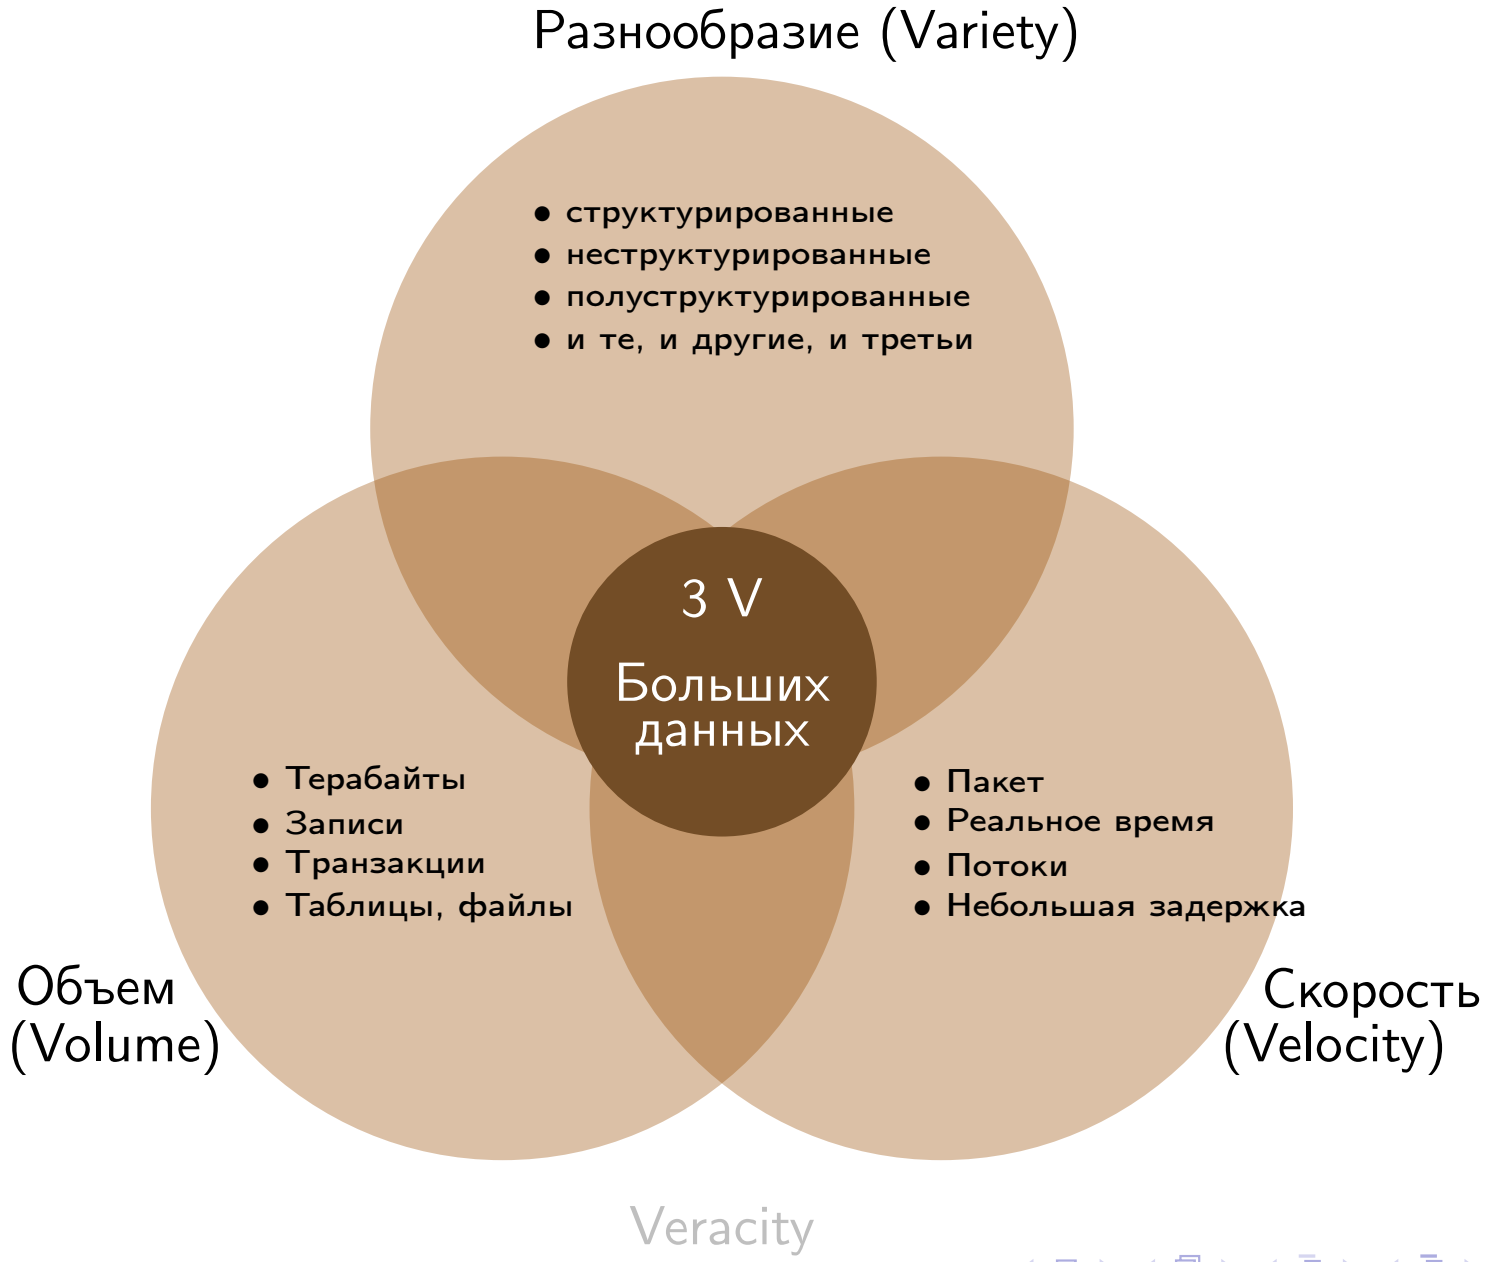
Разнообразие (Variety)
• структурированные
• неструктурированные
• полуструктурированные
• и те, и другие, и третьи
3 V
Больших данных
• Терабайты
• Записи
• Транзакции
• Таблицы, файлы
• Пакет
• Реальное время
• Потоки
• Небольшая задержка
Объем (Volume)
Скорость (Velocity)
Veracity

Архитектура Больших Данных

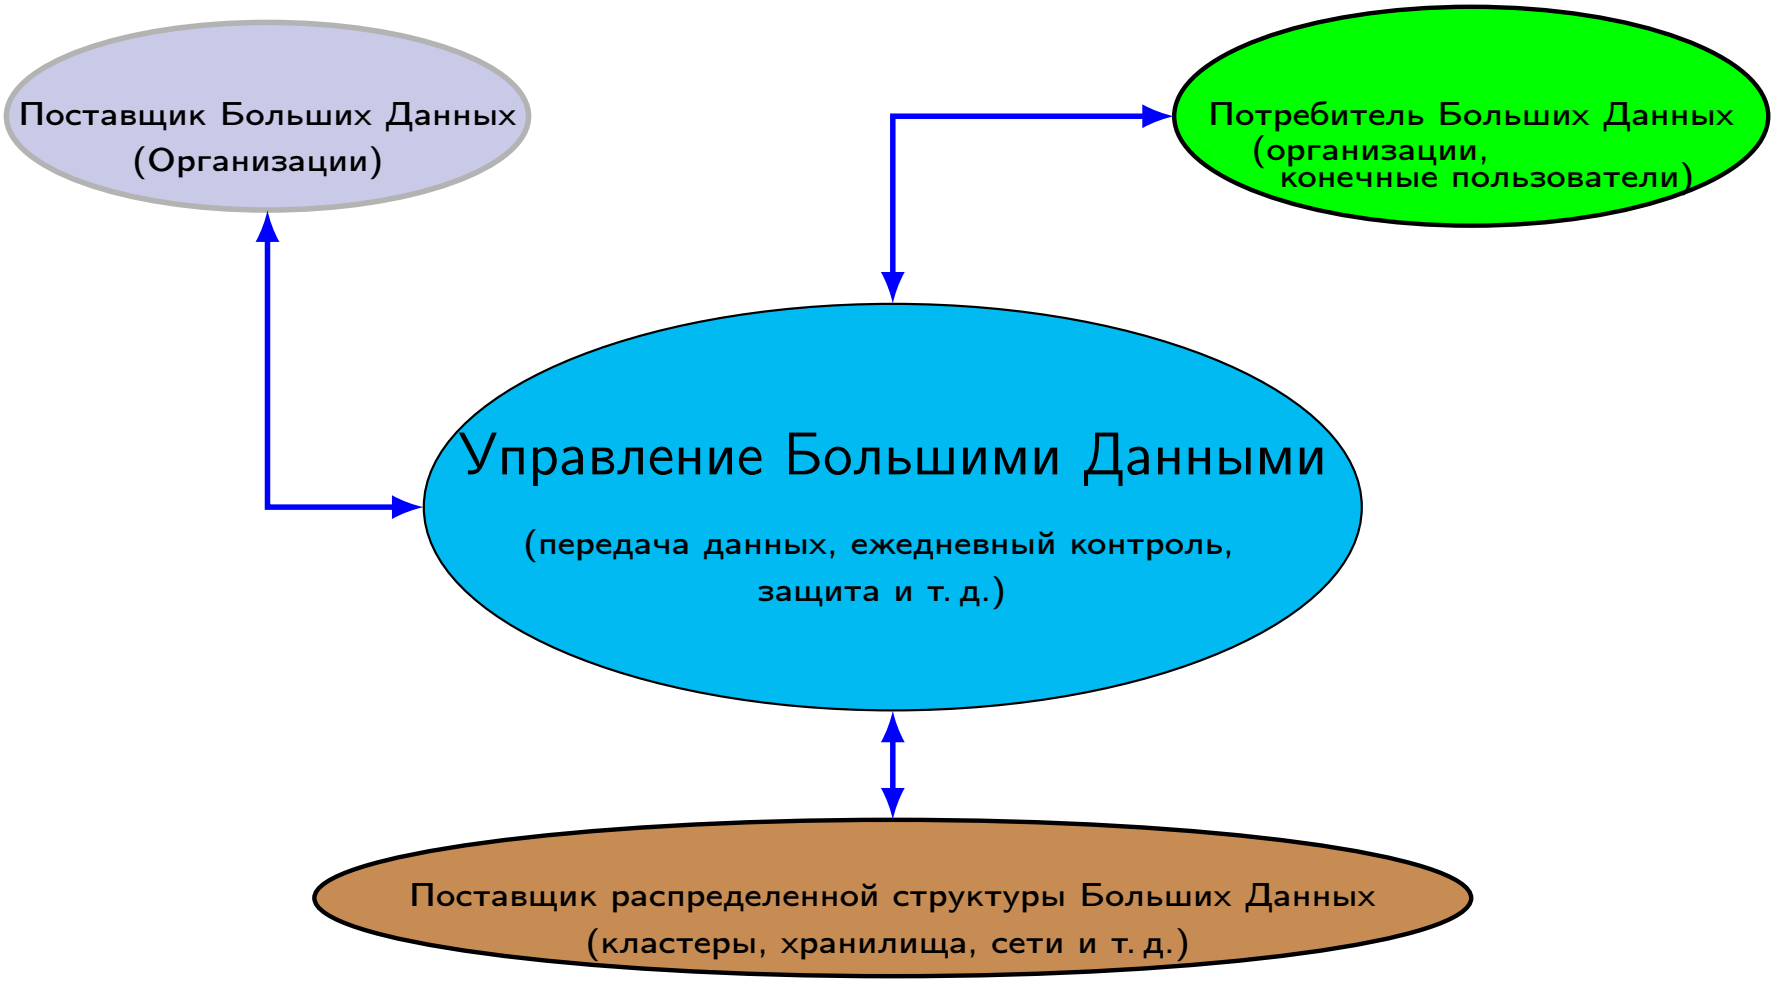

Особенности передачи Больших Данных

- Передача может занять много часов или дней

  (при пропускной способности в 1 Гбит 100 ТБ/100 МБ=1 000 000 секунд или 11.6 дней).
- Обстановка в каналах может измениться: время прохождения сигнала (RTT), % потерянных сетевых пакетов, пропускная способность канала данных.
- Наконец, может случиться сбой в работе канала данных (часы?, дни?).
- Очевидно, полезно иметь доступ к двум или более каналам данных и механизмы динамического распределения потоков передачи по этим каналам.

Технологические особенности передачи Больших Данных

- Основные протоколы: все еще стек TCP/IP.
  - Число сетевых параметров в Linux около 500 (`/proc`)

    ```
    -bash-4.1$ /sbin/sysctl -a | grep "^net\." | wc -l
    ```

    - Важные параметры: размер блока, размер окна TCP и т. д. Основной способ уменьшить время передачи (даже по одному каналу данных) — использовать мультипотоковую передачу.

Тестирование на первой стадии (программные инструменты)

- BBCP, http://www.slac.stanford.edu/~abh/bbcp/
- GridFTP, http://www.globus.org/toolkit/data/gridftp/
- BBFTP, http://doc.in2p3.fr/bbftp/
- FDT, http://monalisa.cern.ch/FDT/
- FTS3, http://fts3-service.web.cern.ch/
- а также технологические компоненты для контроля состояния канала данных, perfSONAR.

Сравнение инструментов передачи данных

- Доступность
- API
- Производительность
- Надежность
- Отслеживание операций
- Возможность предсказать время передачи данных на основе существующих отслеженных записей
- Требуемые ресурсы: память, время ЦПУ и т. д.
- Другое

Характеристики утилит передачи данных

- Режим многопоточной передачи данных.
- Режим многоканальной передачи.
- Возможность устанавливать параметры нижнего уровня (например, размер окна TCP).
- Шифрование данных на лету.
- Сжатие данных на лету.
- Метод обхода сетевых проблем.

Процесс передачи данных

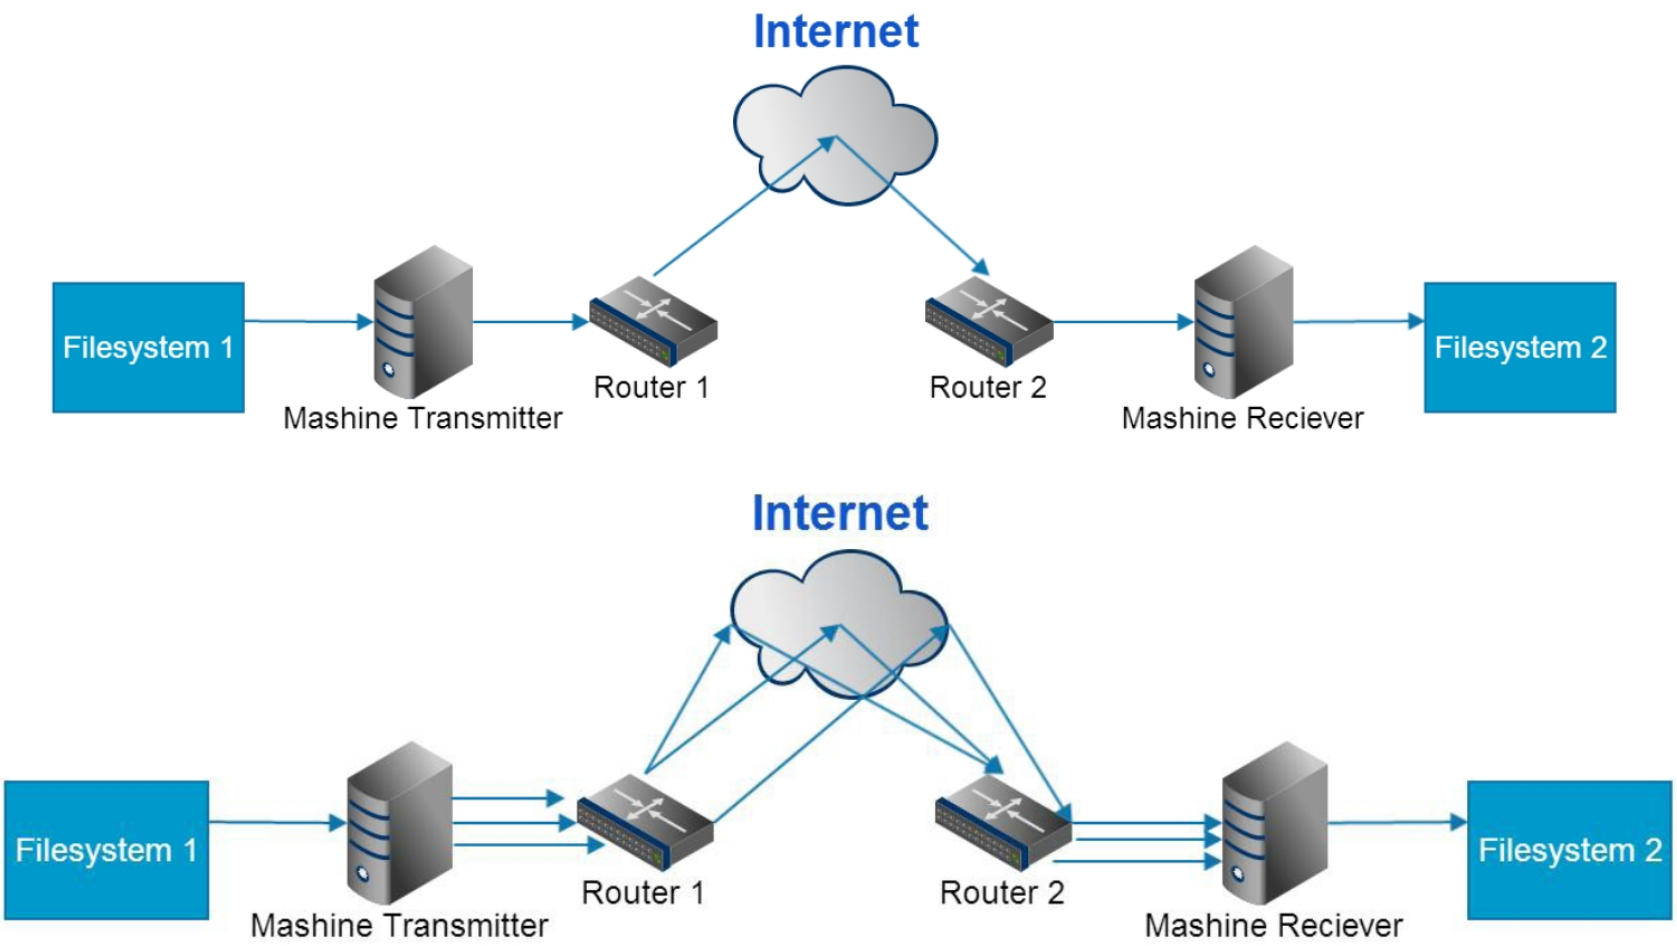

Из нескольких шагов передачи данных (чтение данных из хранилища, передача данных по сети, запись полученных данных) мы концентрируемся на втором, передаче данных по сети.

Тема исследования в НИУ ИТМО: передача Больших Данных

В лаборатории сетевых технологий, `http://sdn.ifmo.ru/`, Университета ИТМО, `http://www.ifmo.ru/`, выполняется новая научно-исследовательская работа «Передача Больших Данных по Интернету».

- Создается распределенный испытательный стенд (100 Тб дисковой памяти + сервер с 96 Гб оперативной памяти под управлением ОС ScientificLinux 6.5 с каждой стороны).
  - Сравнительное изучение существующих инструментов передачи данных (тестирование и измерение).
  - Использование стенда как инструмента для сравнения различных средств (отслеживание для измерений + результаты).
  - Расширенная информация автоматического трекинга об измерениях в процессе разработки.

Планируемые измерения

- Локальные и удаленные сайты с существующими каналами данных (не только самые быстрые каналы).
- Замысел — использовать более, чем один, канал данных в параллель.
- В последнее время мы провели ряд исследовательских работ в области Программно-Конфигурируемых Сетей (ПКС–SDN) OpenFlow и теперь планируем использовать полученный опыт для совершенствования механизмов передачи Больших Данных.

Что сделано

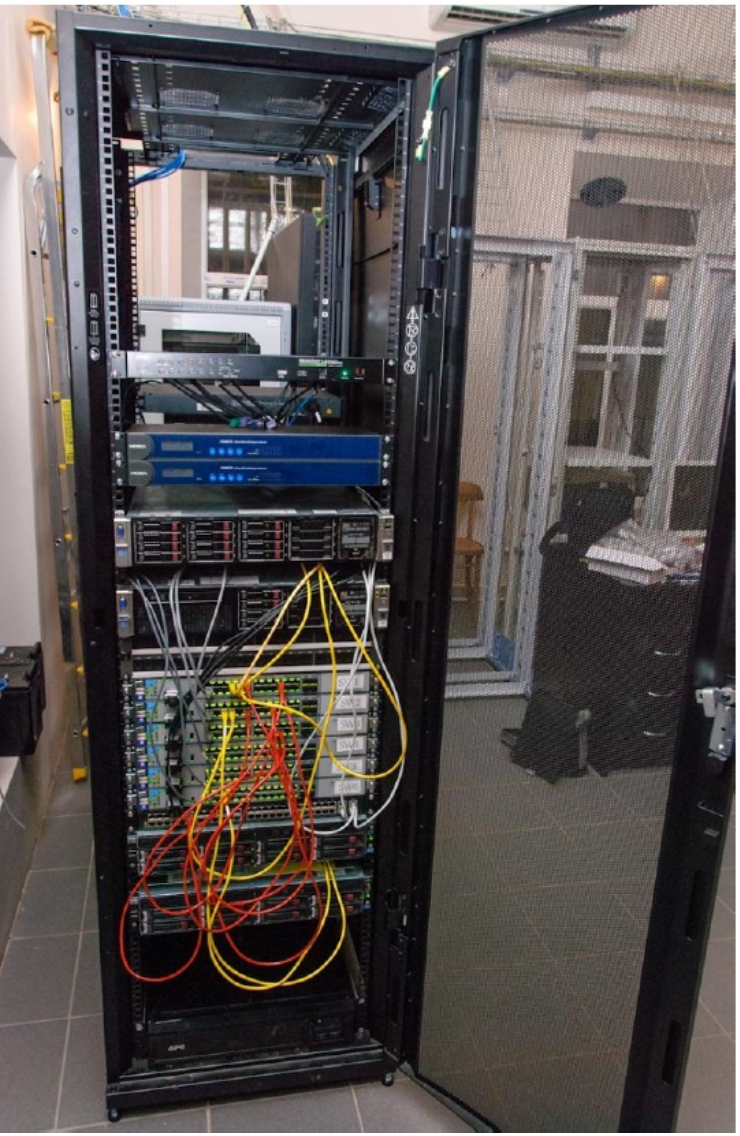

- Используются:
  - Два сервера HP DL380p Gen8 E5-2609, Intel(R) Xeon(R) CPU E5-2640| 2.50GHz, 64
    ScientificLinux 6.5.
  - Шесть коммутаторов HP-3500-24G-PoE yl (OpenFlow 1.0)
  - Pica8 P-3920 (OpenFlow 1.2)
  - Openstack Havana с подходящим набором виртуальных машин для тестирования упомянутых утилит. Openvswitch
  - PerfSonar
  - Скрипты!!! для тестирования: https://github.com/itmo-infocom/BigData

Главные цели

- Объединить разработанные современные компоненты и методы с концепциями, разработками, опытом для достижения максимальной скорости передач Больших Данных на существующих каналах.
- Создать стенд, который использовался бы как место, где исследователи могли бы сравнить свои (новые) инструменты передачи данных с ранее полученными результатами измерений.
- Предложить сотрудничество с . . . (предложения?).
- Пригласить студентов из . . . (предложения?).

Партнеры (обмен замыслами)

- Лаборатория информационных технологий (ЛИТ)
  `http://lit.jinr.ru/index.php?lang=lat`
  Объединенный институт ядерных исследований (`JINR.ru`)
- Центр прикладных исследований компьютерных сетей,
  Московский университет, `http://arccn.ru/`
- Начинаем сотрудничество с GENI, `http://www.geni.net/`

Работа поддержана Санк-Петербургским национальным университетом информационных технологий, механики и оптики (`www.ifmo.ru`).

BBCP

- Размер окна TCP;
- число потоков TCP;
- Размер буфера ввода/вывода;
- сжатие на лету;
- многонаправленное копирование;
- возобновление неудачного копирования;
- аутентификация по ssh;
- использование конвейеров, где источник и/или получатель могут быть конвейерами;
- специальная опция для передачи малых файлов;
- и много других опций, касающиеся многих практических деталей.

BBFTP

- зашифрованные при соединении имя и пароль;
- модули аутентификации SSH и Grid Certificate;
- многопотоковая передача;
- большие окна, как определено в RFC1323;
- сжатие данных на лету;
- автоматическое повторение;
- настраиваемые задержки;
- моделирование передачи;
- интеграция AFS аутентификации.

GridFTP

- две разновидности защиты: Globus GSI и SSH;
- файл с синонимами хостов: каждый следующий поток передачи данных будет использовать следующие синонимы хостов (полезно для вычислительных кластеров);
- конвейеры;
- специальный режим отладки для выяснения узких мест передачи данных;
- имя внутреннего модуля для сайтов источника и получателя;
- число параллельных потоков передачи данных;
- размер буфера;
- перезапуск неудачных операций и число перезапусков.

Другие утилиты

- Xdd — утилита, разработанная для оптимизации передачи данных и процессов ввода/вывода для систем хранения.
- fdp — Java-утилита для многопоточной передачи данных.
- FTS3.
- UDT.
- RDMA.
- MP TCP.

Скрипты

- Нужно рассматривать разные варианты данных для передачи: `/dev/null` (объемом 100 ТБ, без использования дисковой подсистемы), один файл >100 ТБ (с дисковой подсистемы), большое число небольших файлов, суммарным объемом 100 ТБ.
  - Генерация файлов: create-test-file-dispersion.sh, create-test-file-sigma.sh, параметры: директория, размер директории, средний размер файла, дисперсия, образец.
- Тестирование утилит:
  - CopyData.bbcp, параметры: конфигурационный файл bbcp, директория для журналирования, исходная директория с файлом (файлами), удаленный хост, директория на удаленном хосте, комментарии.
- В процессе тестирования необходимо сохранять множества параметров, необходимых для дальнейшего анализа.
- Количественная оценка системы передачи данных включает время, затраченное на передачу данных, объем потребляемых ресурсов.
- Участвующие в испытаниях серверы:
  - Стенд ИТМО • Стенд ПИЯФ • Стенд МГУ

Вопросы?

Спасибо. . .

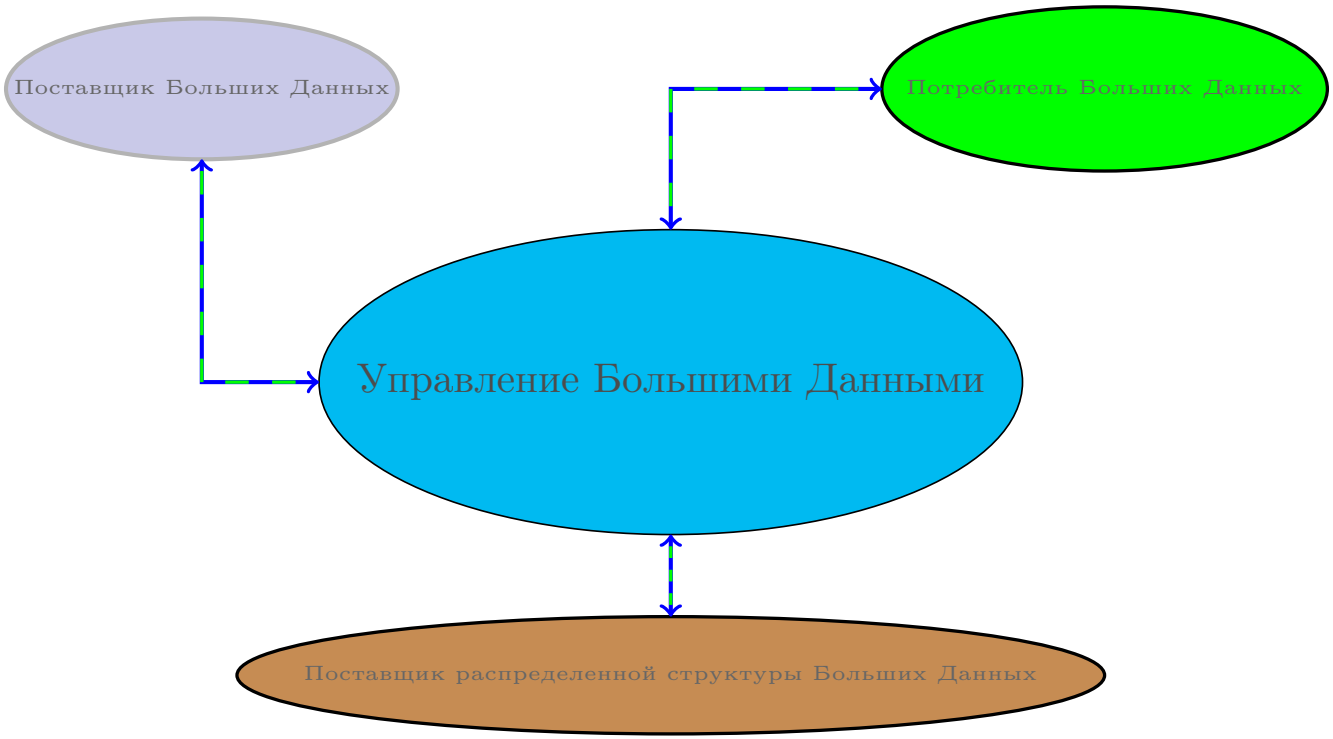

Работа поддержана Санк-Петербургским национальным университетом информационных технологий, механики и оптики (www.ifmo.ru).