Распределенные иерархические системы хранения данных (HSM)

А.Н. Мойбенко
МЛИТ, ОИЯИ

Требования пользователей

- Побольше места (лучше неограниченно)
- Побыстрее скорость передачи
- Минимализация времени доступа к данным
- Легкая доступность к данным
- Надежность хранения
- Защита
- Разрешение / ограничение доступа

Немного истории

- ЭВМ коллективного пользования.(< ~1980)
- Пользователи используют одну ЭВМ
- Данные хранятся на диске (дисках) ЭВМ
- Данные архивируются на магнитных лентах (16 мм)
- ЭВМ индивидуального пользования (PC) (late 1980)
- Данные хранятся на диске (дисках) ЭВМ
- Данные архивируются на магнитных кассетах (8 мм)
- PC соединяются в кластеры для (> 1990):
- Увеличения скорости сбора и обработки данных
- Увеличения объема доступных данных (пользователю доступны данные с многих PC)
- Архивирование на магнитных кассетах через магнитофоны, расположенные в автоматических ленточных библиотеках

Продолжительность и стоимость хранения информации

- Hard Disk Drive (HDD) – 4 – 7 years
  - active (require power)
  - Max capacity 20 TB
  - Cost $16/TB
- Solid State Drives (SSD) – 5 – 10 years
  - Active, require power
  - Max capacity 4 TB
    - Cost $60 / TB
- Flash - 10 years with average use
  - passive
  - Max capacity 1 TB
  - Cost $90 / TB
- Magnetic Tape – 15 – 30 years
  - Max capacity 20 TB
  - Passive, but require tape drive, tape library
  - 20000 load / unload cycles
  - $5 / TB ($2.5 / TB - compresssed)

  Consider:
  - Acquisition cost
  - Operational cost
  - Power and cooling
  - Warranty

  Tape system cost ~ 1/3 disk system cost per PB not considering lifespan

Структура иерархической системы хранения данных

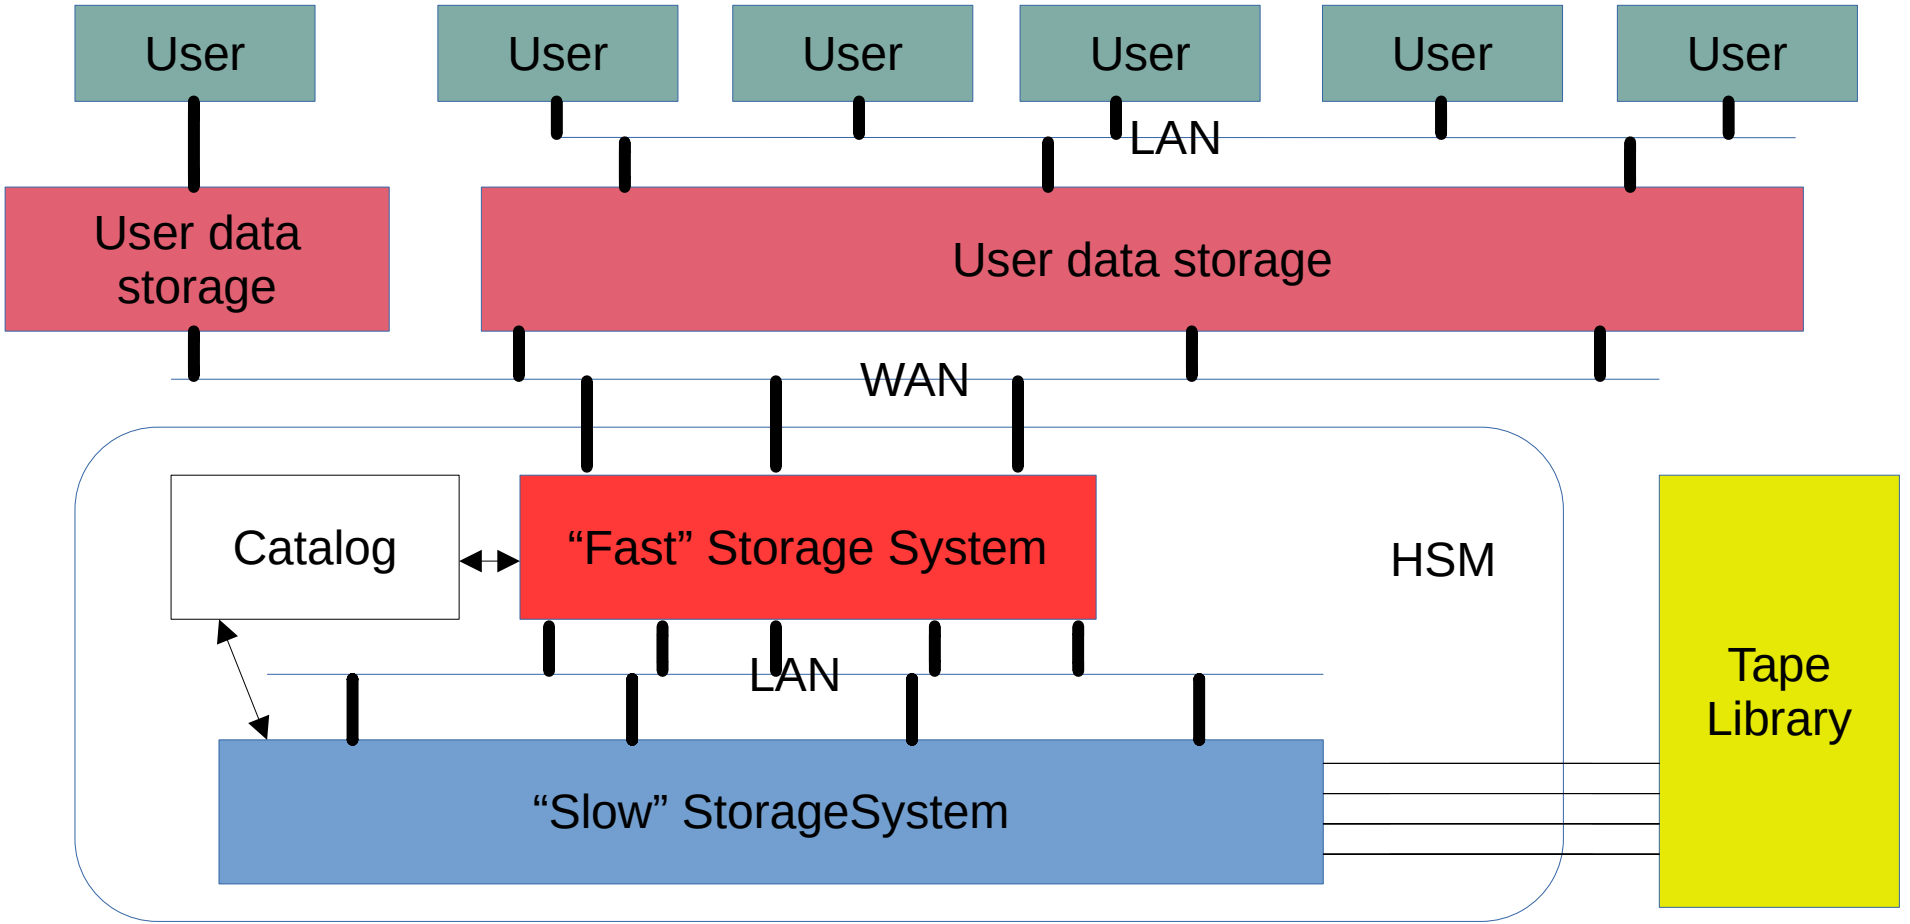

Потребность в иерархических распределенных системах хранения данных

- Возрастание объемов даных (> 10 PB) и числа compute nodes.
  - Распределение данных
  - Распределение ресурсов хранения
  - добавление элементов хранения
  - Определение неисправных элементов и их замена
- Увеличение скорости передачи данных
- Автоматизация архивирования, освобождения /восстановления / и репликации “быстрого” хранилища данных в “медленном” хранилище
- Обеспечение надежного долговременного хранения

Способы доступа к данным в иерархических системах хранения

- Кэширование
  - Если данных нет в быстром хранилище они копируются из более медленного.
  - Если быстрое хранилище переполняется менее ценные данные удаляются
- Tiering (передача между уровнями) – данные копируются с более медленного уровня на более быстрый. После чтения данные не остаются на более быстром уровне (backup подход).

Иерархические системы в HEP

- HPSS – High perfomance Strorage System (DOE, NSF, IN2P3) (~1992)
- CASTOR – CERN Avanced STORage manager (CERN) (1998)
- Dcache + Enstore (FNAL, PIC, JINR, KIAE) (1998)
- EOS + CTA – CERN Tape Archive (CERN) (2021)
- Dcache+HPSS – BNL (~2004 Atlas)

Как требования пользователей удовлетворяются в HSM

- Побольше места (лучше неограниченно)
  - Высокоскоростная, расширяемая централизованная система управления метаданными, доступная на каждом уровне системы хранения и транспортировки
  - Расширяемость за счет добавления элементов хранения (horizontal scalability)
- Побыстрее скорость передачи
  - Распараллеливание процессов передачи данных
  - Репликация данных на первом (user facing) уровне

Как требования пользователей удовлетворяются в HSM

- Минимализация времени доступа к данным
  - Кэширование данных на “быстром” (1) уровне
  - Massive data prestaging from “slow” (2nd) (Tape) to “fast” (1st) layer
- Легкая доступность к данным
  - Каталог данных
  - Средства доставки
- Надежность хранения
  - Магнитные ленты (можно положить на полку)
  - Автоматизация копирования по запросу на магнитных лентах

Как требования пользователей удовлетворяются в HSM

- Защита данных
  - Аутентикация пользователя
  - Данные на магнитной ленте трудно переписать
  - Автоматизация переключения клавиши “запрет записи” на магнитной кассете
- Разрешение / ограничение доступа
  - Авторизация доступа

Пример: JINR CMS T1 dCahe + Enstore

- 2 Layer HSM
- Dcache – “fast” data storage layer (distributed disk system)
- Current capacity – 2.4 PB
- Enstore – “slow” layer (distributed tape system)
- Current capacity ~ 5000 20 GB tapes
- Occupied – 11 PB
- In production since 2016

JINR CMS T1 dcache + enstore data transfers