Sistemas Distribuidos

Sistemas de ficheros paralelos

Fernando Pérez Costoya

Índice

- Necesidad de E/S paralela
- Conexión de dispositivos
- Sistemas de ficheros distribuidos versus paralelos
- *General Parallel File System* (GPFS)
- *Google File System* (GFS)

Necesidad de E/S paralela

- Ciertas aplicaciones manejan repositorios masivos de datos
  - Requieren nº enorme de ops. E/S sobre disp. de almacenamiento
- Crecimiento muy significativo de capacidad discos
  - Pero no de sus prestaciones: ancho de banda y latencia
- Crisis E/S: desequilibrio entre capacidad procesamiento y E/S
  - Afecta a aplicaciones con fuerte componente de E/S
- Misma solución que para cómputo: uso de paralelismo
- Entrada/salida paralela
  - Distribución de datos entre múltiples dispositivos de almacenamiento
  - Acceso paralelo a los mismos
  - Debido alta latencia, mejor cuanto mayor sea tamaño accedido
    - Accesos paralelos pequeños mal rendimiento

Conexión de dispos. almacenamiento

- DAS: *Direct-attached storage*
  - Solución “clásica”: disco asociado a nodo
- NAS: *Network-attached storage*
  - Nodo que gestiona un conjunto de discos
- SAN: *Storage Area Networks*
  - Red dedicada al almacenamiento
    - Almacenamiento no vinculado a ningún nodo (“Discos de red”)
  - Redes comunicación separadas para datos de aplicación y ficheros
  - Redes de almacenamiento incluyen *hubs*, *switches*, etc.
    - Tecnología más usada *Fibre Channel*
  - Conectividad total entre nodos y dispositivos:
    - Cualquier nodo accede directamente a cualquier dispositivo
  - Conectividad directa entre dispositivos
    - Copias directas entre dispositivos (agiliza *backups*, replicación, etc.)

Direct-attached storage (DAS)

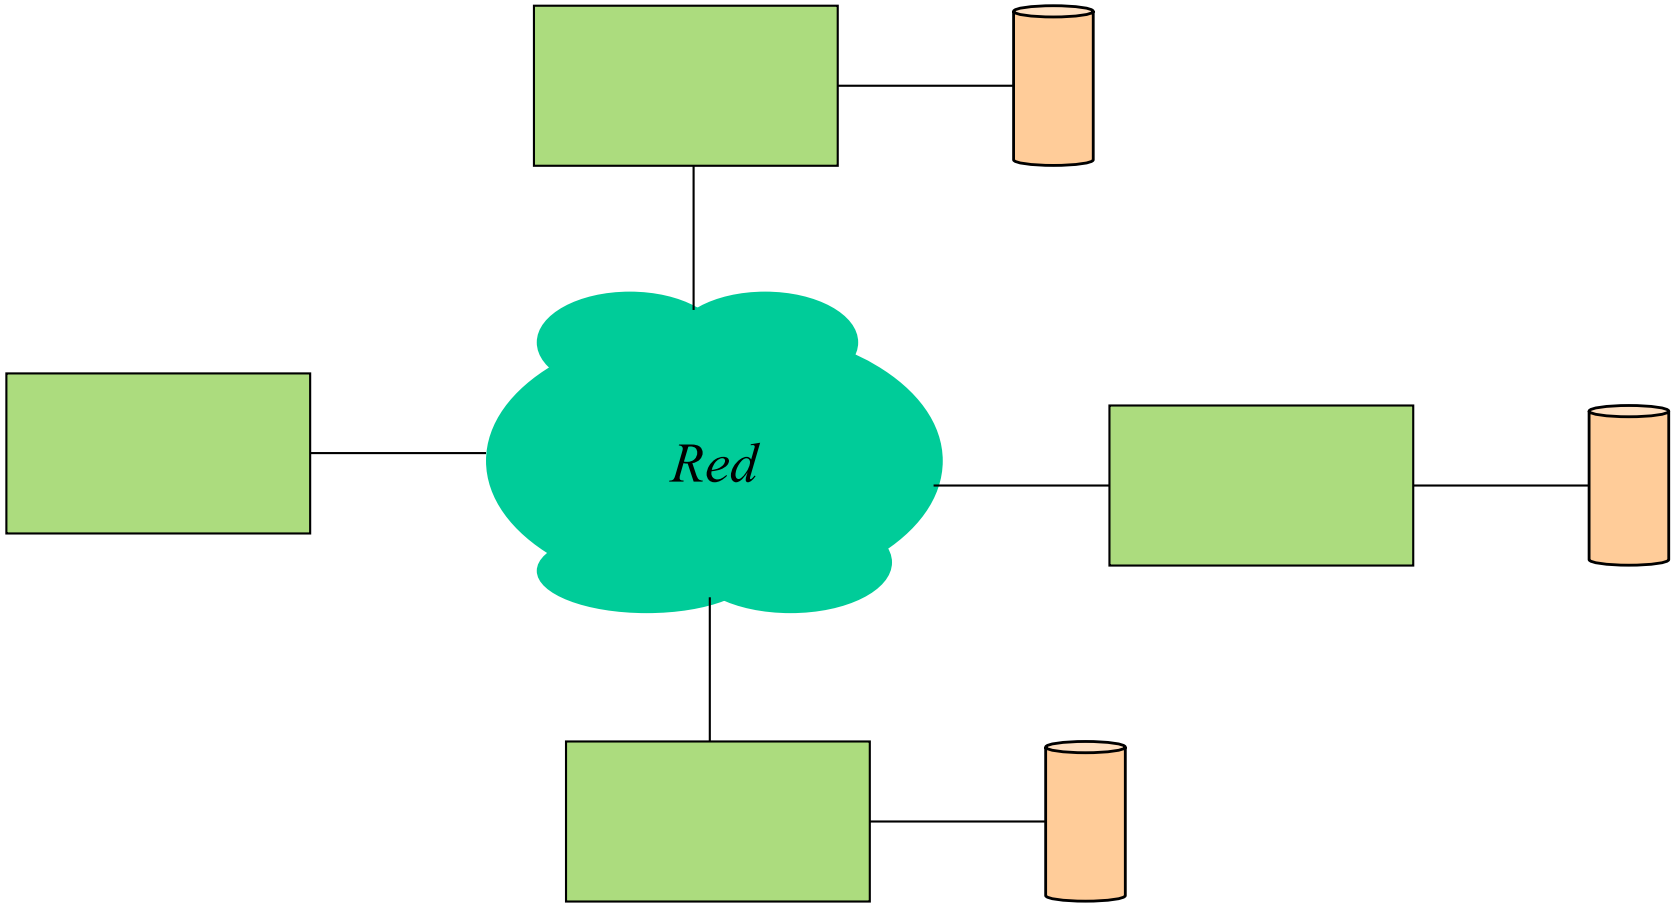

Network-attached storage (NAS)

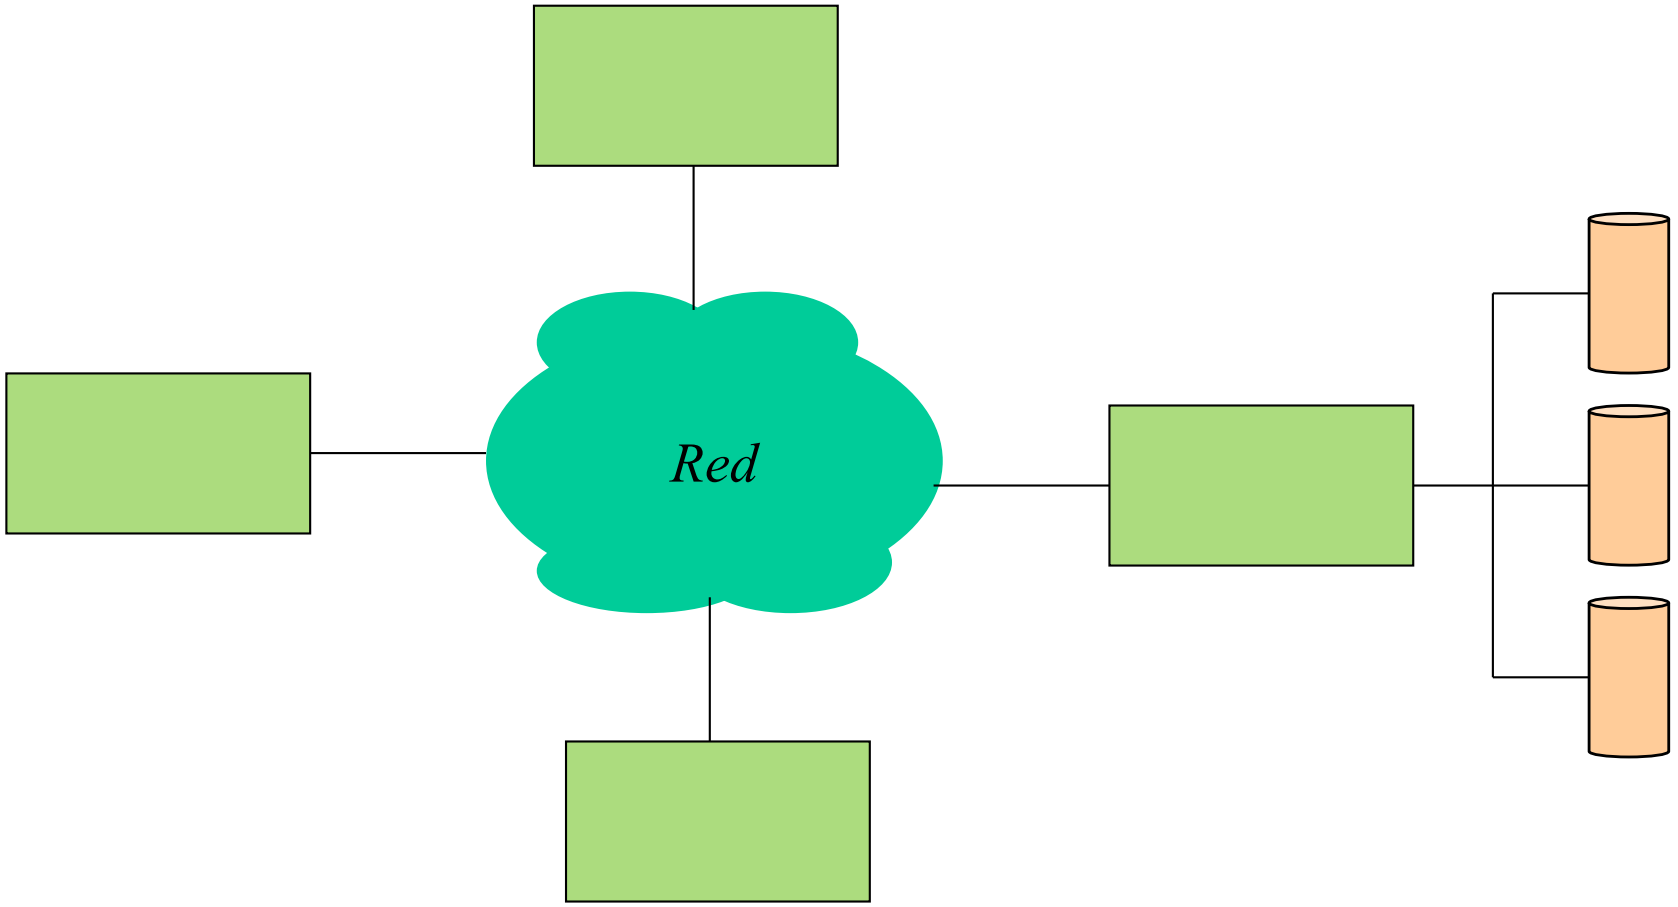

Storage Area Network (SAN)

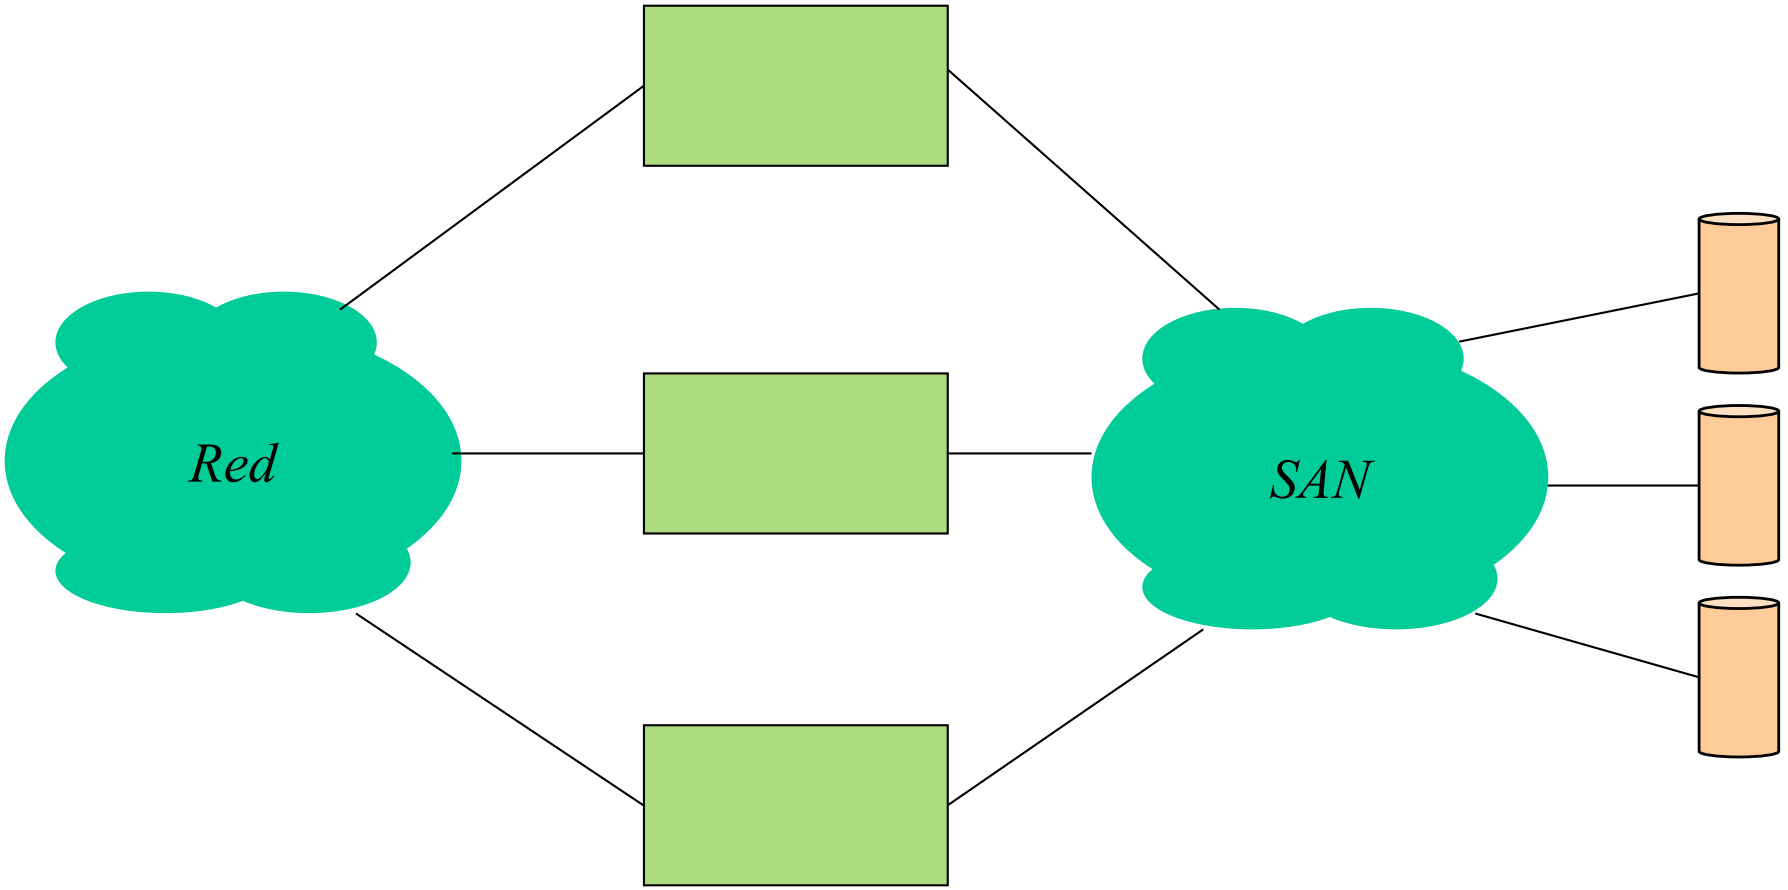

Sistemas de ficheros para E/S paralela

- ¿Por qué no son adecuados sistemas de ficheros distribuidos?
  - Como, por ejemplo, NFS o AFS
- Almacenan cada fichero en un solo servidor:
  - No hay paralelismo en accesos a fichero
  - "Cuello de botella", falta de *escalabilidad* y punto único de fallo
- Demasiadas capas de software en el cliente y en el servidor
  - Separación de funcionalidad poco nítida (incluso redundancia)
- No aprovechan adecuadamente paralelismo de las SAN

Arquitectura SFD

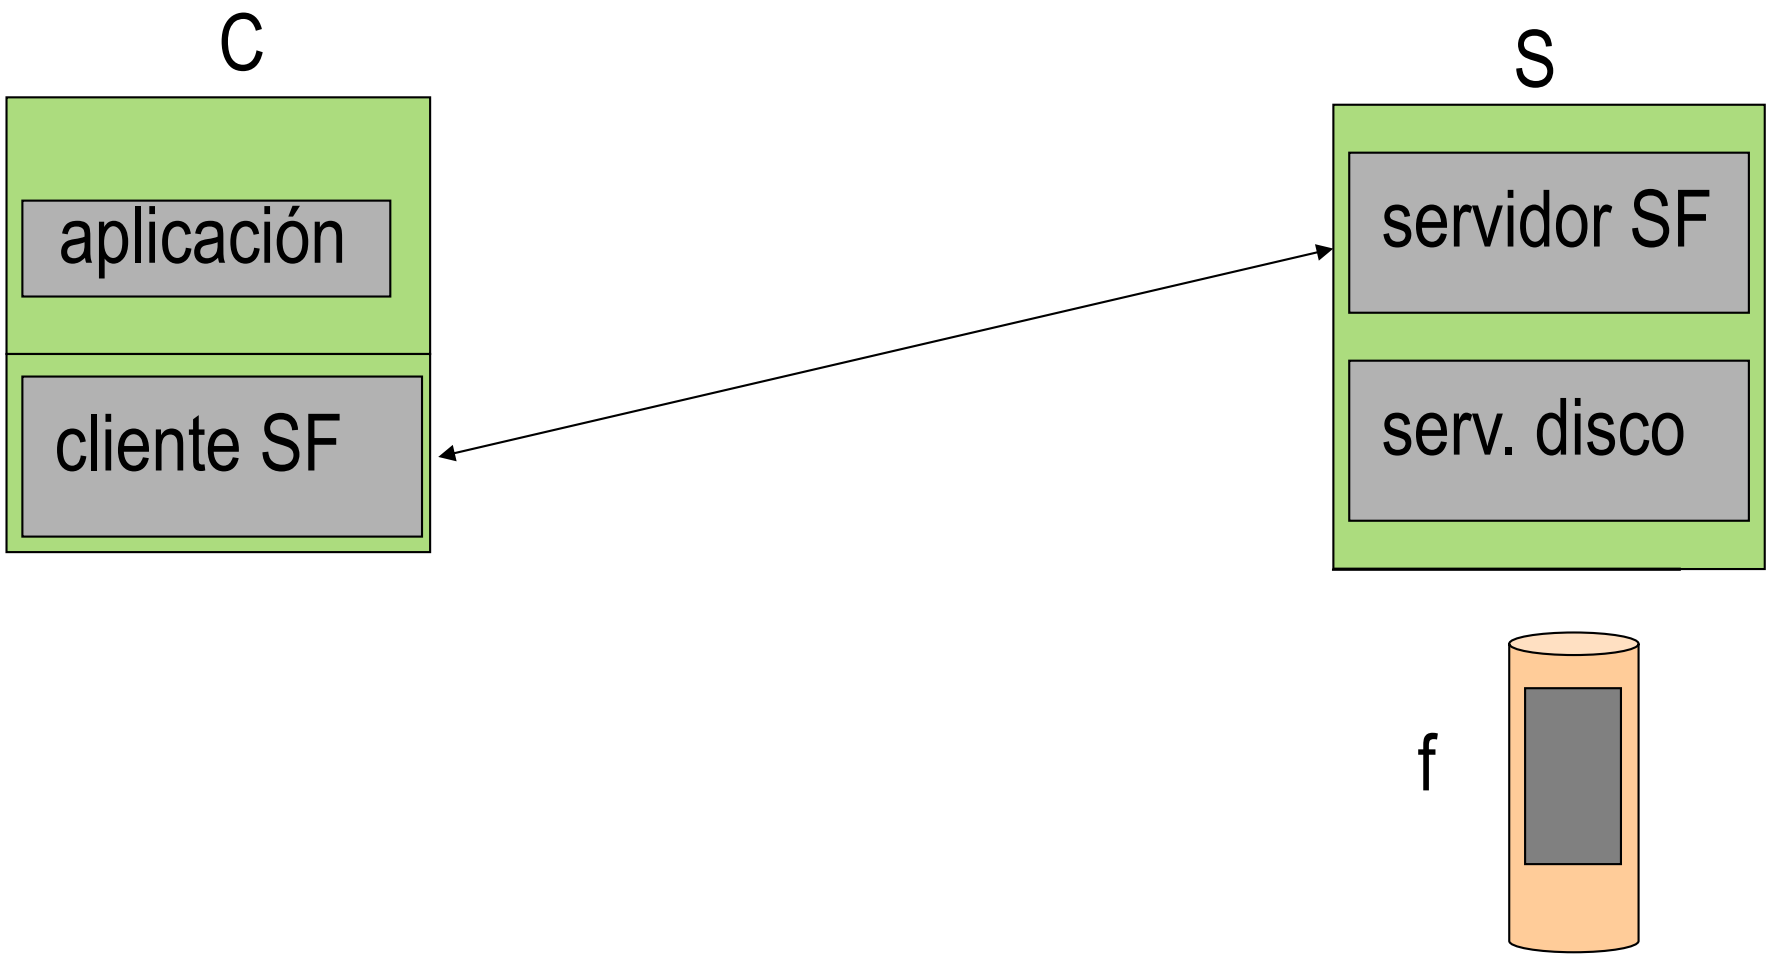

Disposición de datos en SFD

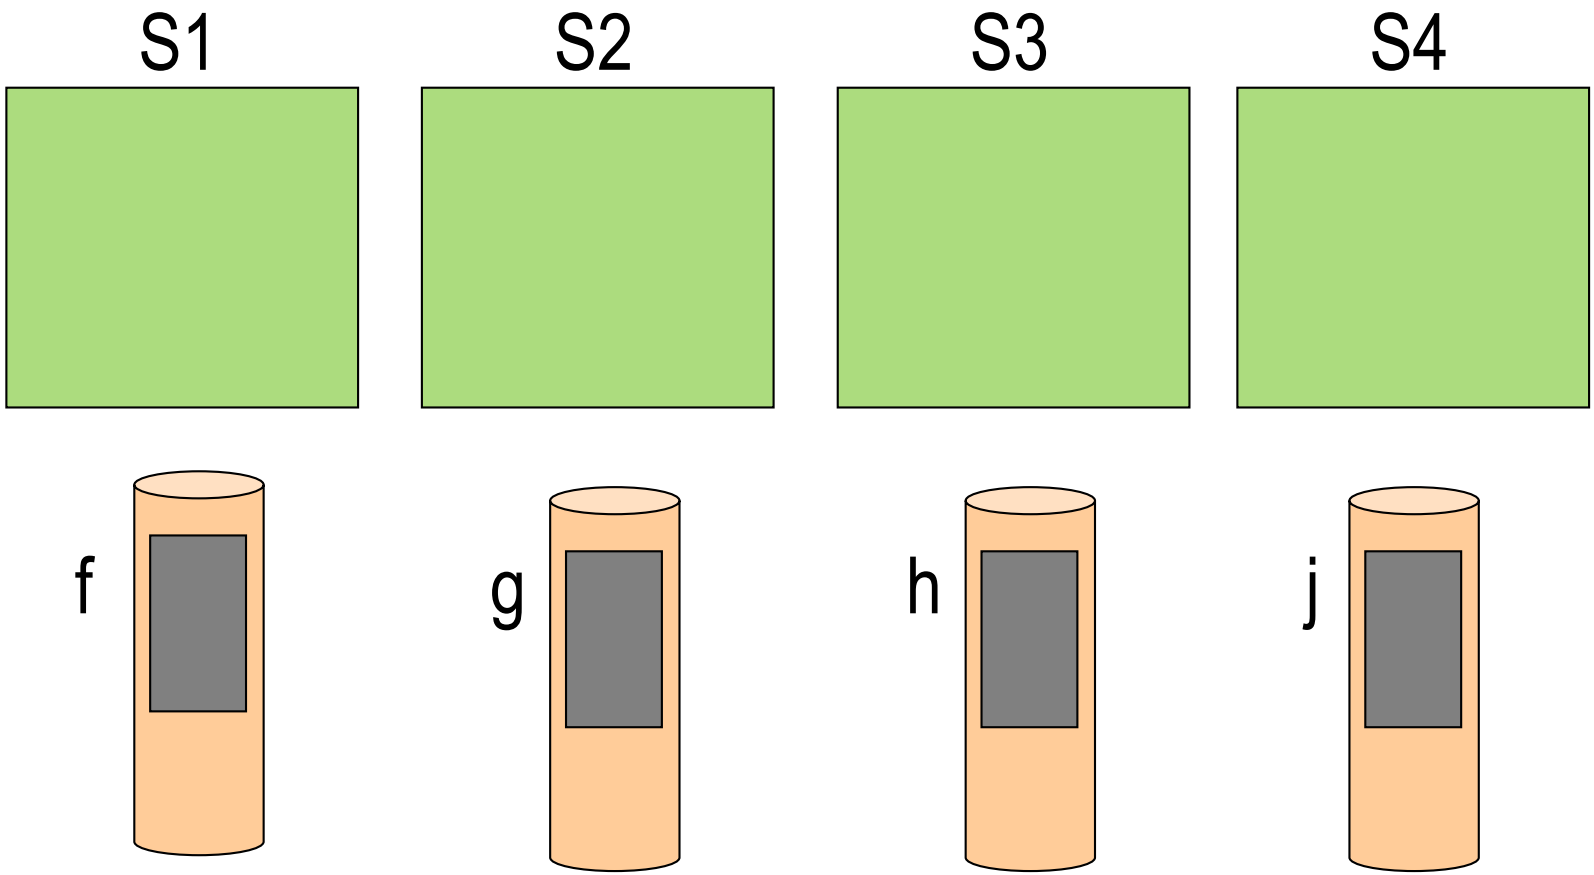

Sistemas de ficheros paralelos

- Uso de *stripping*:
  - Datos de fichero distribuidos entre discos del sistema
  - Similar a RAID 0 pero por software y entre varios nodos
- *Shared disk file systems*
  - Nuevo reparto de funcionalidad de SF en 2 niveles
- Nivel inferior: servicio de almacenamiento distribuido
  - Proporcionado por la SAN
  - Si no SAN, módulo de servicio de disco en cada nodo E/S (NES)
- Nivel superior: sist. ficheros en cada nodo de cómputo (NC)
  - Cada NC accede a los discos como si fueran locales
  - Cada NC gestiona la metainfo. de los datos que accede
  - Se requiere un mecanismo de cerrojos distribuido
- Ejemplos: GPFS, PVFS, Lustre o Google File System

Disposición de datos en SFP: *stripping*

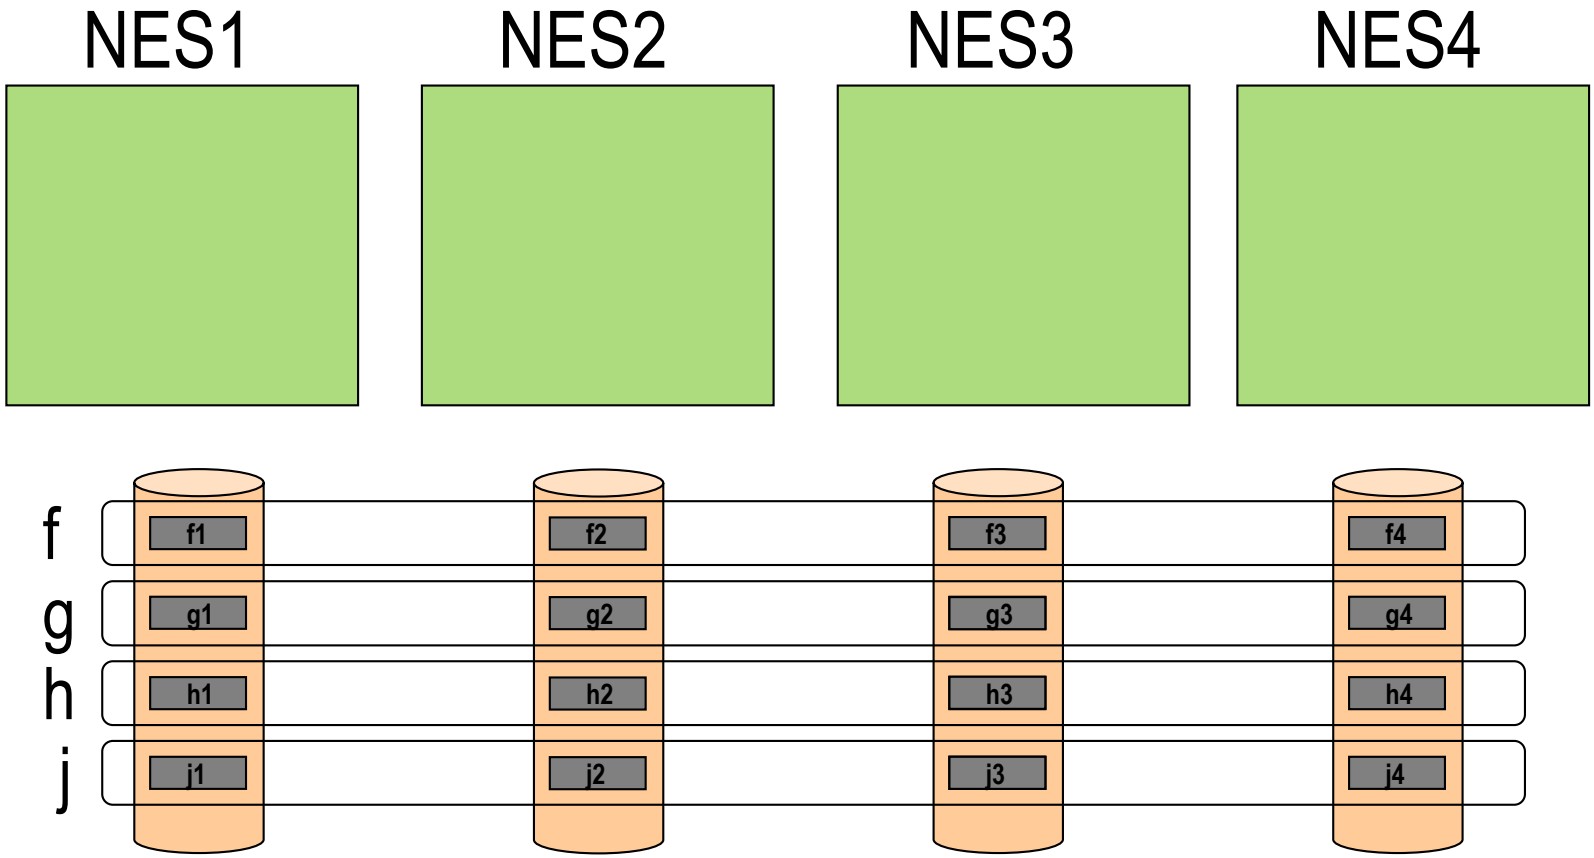

Arquitectura SFP

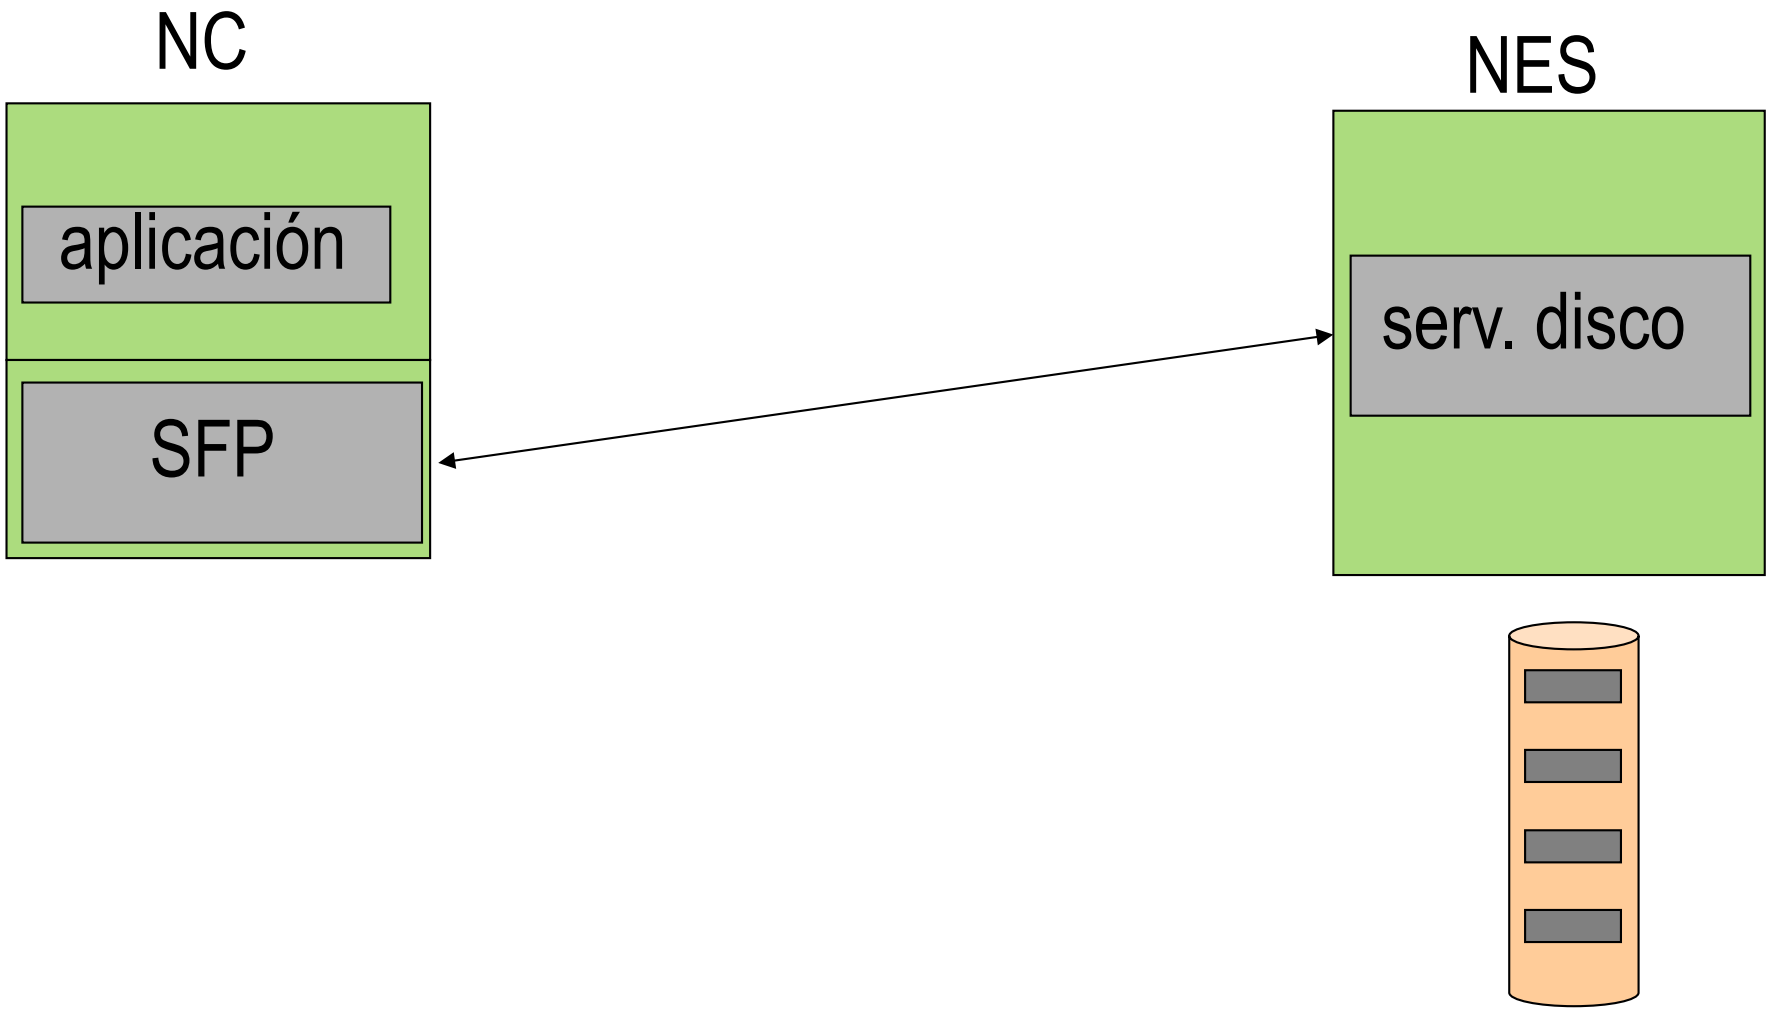

Configuración basada en SAN

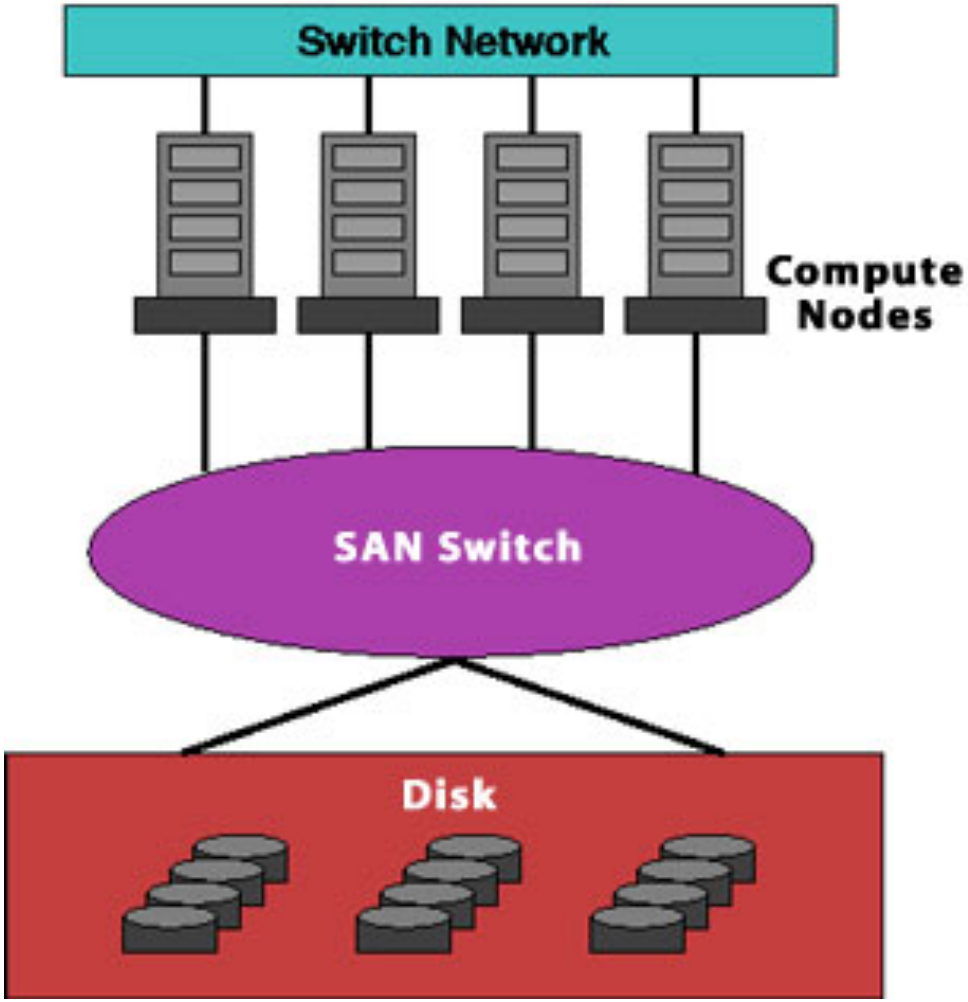

http://www.ncsa.illinois.edu/UserInfo/Data/filesystems/

Configuración basada en nodos de E/S

Nodos E/S: sólo servicio de disco

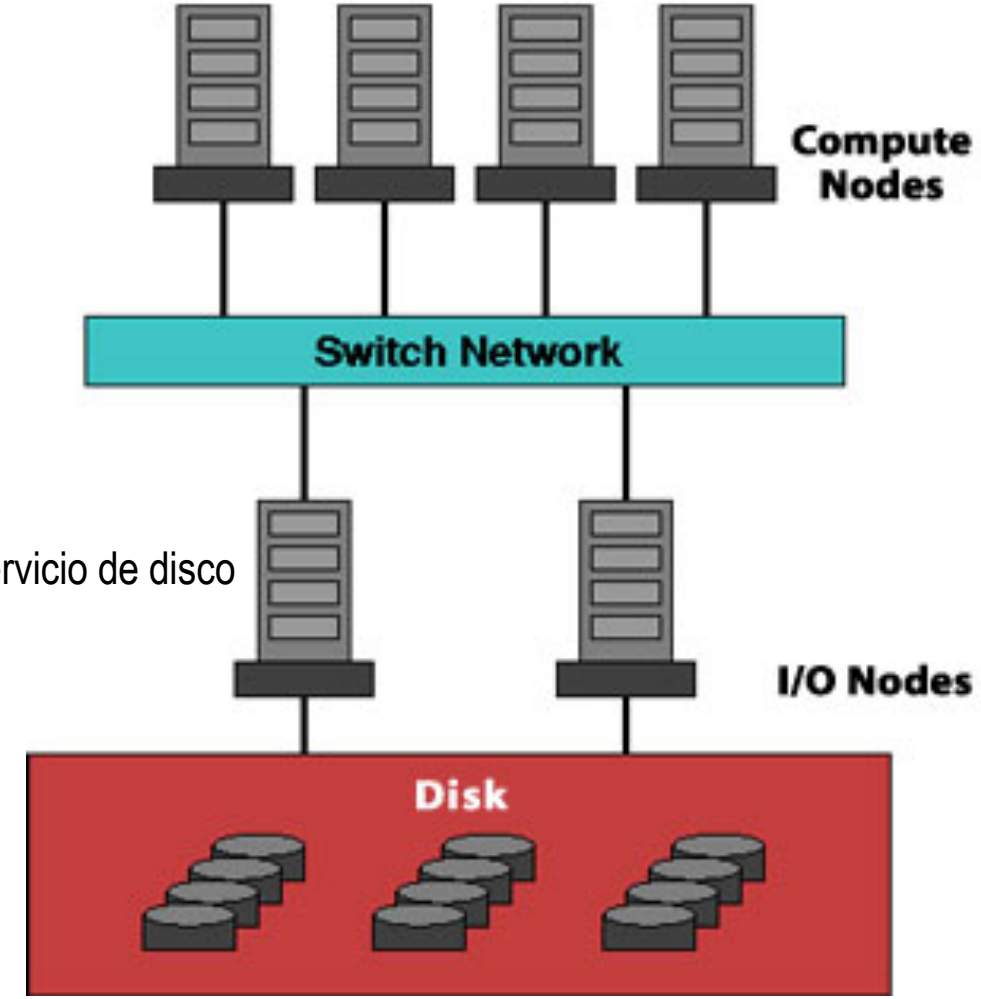

http://www.ncsa.illinois.edu/UserInfo/Data/filesystems/

General Parallel File System de IBM

- Sistema de ficheros para clusters
  - Gran escala: decenas de miles de discos
    - Soporte grandes volúmenes, ficheros y directorios (*hashing* extensible)
  - Presente en la mayoría de los Top 500
- Soporte para SAN y nodos con discos: *Shared disk file system*
- Sistemas heterogéneos (versiones para AIX, Linux, Windows)
- Semántica POSIX (excepto *atime*)
  - Escrituras atómicas incluso aunque POSIX actual no lo requiera
- Facilidades para implementar biblioteca MPI-IO
- Paralelismo en gestión de datos y metadatos
  - Optimiza acceso para 1 fichero/N procesos y N ficheros/1 proceso
  - Ops. administración también con paralelismo y "en caliente"
- Tolerancia a fallos en discos, nodos y comunicación

Arquitectura *Shared disk file system*

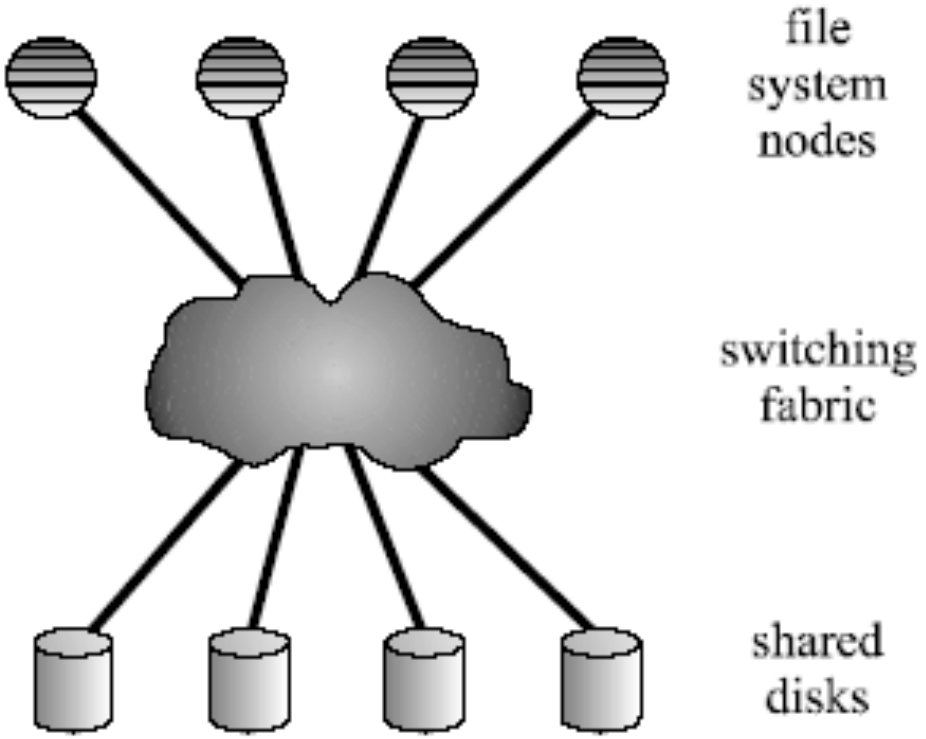

GPFS: A Shared-Disk File System for Large Computing Clusters

Frank Schmuck and Roger Haskin; *FAST '02. USENIX*

Striping

- Bloques de fichero repartidos *round-robin* en discos de un SF
- Tamaño bloque *T* entre 16K y 1M: típico 256K
  - Si SF formado por RAIDs: *T* múltiplo de tamaño franja de RAID
  - Ficheros pequeños y colas de ficheros: subbloques de hasta *T*/32
- Lecturas y escrituras de un nodo aprovechan paralelismo
  - Uso de *prefetching* en lecturas con detección de patrones de acceso:
    - secuencial directo e inverso y con saltos regulares
    - En caso de patrón de acceso irregular: aplicación puede especificarlo
  - Uso de *write-behind* para escrituras paralelas en discos
- Si discos de un SF no uniformes en tamaño y/o prestaciones
  - Configuración maximizando rendimiento o prestaciones
    - Reparto de bloques no uniforme

Paralelismo y control de coherencia

- SF gestiona diversos tipos de “objetos”
  - Datos de los ficheros
  - Metadatos del fichero: inodo y bloques indirectos
  - Metadatos del sistema de ficheros: información de espacio libre, etc.
- SF usa caché de “objetos” en nodo de cómputo (como en SFD)
  - Necesidad de coherencia en gestión de cachés
- Si “objeto” se extiende por varios dispositivos (no en SFD):
  - Necesidad de coherencia si se requiere actualización atómica
  - NOTA: si un SFP no usa caché ni requiere actualización atómica
    - No sería necesario esquema para mantener coherencia
- Solución basada en gestor de cerrojos distribuidos
  - NOTA: se trata de cerrojos internos del SF; No cerrojos de aplicación

Gestor de cerrojos distribuidos

- Gestor de *tokens* (GT) único en sistema ejecutando en un NC
  - Posible problema de escalabilidad y punto único de fallo
- Gestiona *tokens* lectura/escritura para distintos tipos de objetos
  - Rangos de bytes, inodos, mapas de reservas de bloques e inodos, ...
- Doble rol del *token*:
  - Control acceso paralelo a objeto + control de caché del objeto
    - Caché válida si se posee el token; volcado de cambios al perderlo
- Operación en NC requiere *token* para cierto objeto
  - Lo solicita a GT y lo mantiene para posteriores ops. en ese NC
    - Hasta que operación conflictiva en otro NC causa su revocación
- Escalabilidad GT: minimizar su intervención
  - Solicitud múltiples *tokens* en una sola petición
  - NC que requiere *token* solicita directamente revocación a NCs
  - Nuevo fichero reutiliza inodo manteniendo *tokens* asociados al mismo

Coherencia en acceso a datos

- Protocolo basado en *tokens* asociados a rangos de bytes
  - Solución similar a la usada en algunos SFD (*Prot2*)
- Optimización en la gestión de *tokens*
  1. Proceso lee/escribe fichero usando *N* llamadas: 1 único *token*
     - En *Prot2*: *N* peticiones de *token* para rangos correspondientes
  2. *M* proc. escriben fich. (1/*M* cada uno) con *N* llamadas/pr.: *M* tokens
     - En *Prot2*: *M*N* peticiones de *token* para rangos correspondientes
- Solicitud de *token* incluye dos rangos:
  - Rango requerido: el especificado en operación *read/write*
  - Rango deseado: al que podría querer acceder en el futuro
    - Si acceso secuencial directo, hasta el infinito
- Resolución de solicitud:
  - Se revocan *tokens* que entran en conflicto con rango requerido
  - Se concede rango $\subset$ deseado que no entre en conflicto

Optimización en gestión de *tokens*

1. En primera escritura/lectura a F, rango deseado [0,∞]
   - Si ningún otro cliente accede a F, no más peticiones de *tokens*
   - Por tanto, el proceso sólo pide un *token*
2. Aplicación con *M* procesos crea fichero: 1/*M* parte cada uno
   - P1: *d=open(F); write(d,b,TAM_BLOQ)*
     - P1 obtiene *token* [0,∞]
   - P2: *d=open(F); lseek(d,SEEK_SET,1/N);write(d,b,TAM_BLOQ)*
     - P2 obtiene *token* [1/N,∞]; P1 ajusta su *token* [0,1/N-1]
   - P3: *d=open(F); lseek(d,SEEK_SET,2/N);write(d,b,TAM_BLOQ)*
     - P3 obtiene *token* [2/N,∞]; P2 ajusta [1/N,2/N-1]; P1 *token* [0,1/N-1]
   - Y así sucesivamente.
   - Por tanto, cada proceso sólo pide un *token*

Coherencia acceso metadatos fichero

- Modificaciones concurrentes a metadatos de fichero
  - Directas (*chmod*)
  - Indirectas: *write* → fecha modificación, tamaño y punteros a bloques
- Uso de *token* de acceso exclusivo por inodo no es eficiente
  - Solicitud *token* de inodo por cada escritura aunque no solapadas
- Idea: actualización de inodo en paralelo y mezcla de cambios
- Solución: *token* de escritura compartida y exclusiva
  - Escrituras usan *token* de escritura compartida
    - Cada nodo modifica su copia del inodo (fecha mod., tamaño y punteros)
  - Ciertas ops. requieren *token* escritura exclusiva (*stat*,*utime*,*ftruncate*,..)
    - Se revocan *tokens* de escritura compartida
    - Cada NC afectado vuelca su copia del inodo y se mezclan
    - ¿Quién se encarga de esta operación de mezcla?
      - **Metanodo del fichero**

Metanodo de un fichero

- NC elegido como metanodo (MN) de un fichero
  - Es el único que lee/escribe su inodo al disco
- Primer acceso a fichero F en un NC contacta con GT
  - Además de pedirle *tokens* de bytes de rangos y de inodo
  - Le solicita *token* de metanodo (se ofrece como MN para F)
    - Si todavía no hay MN para F, GT lo asigna a solicitante
      - Primer nodo que accede a fichero actúa como MN
    - Si ya lo hay, GT le informa de su identidad
  - NOTA: Se piden todos los *tokens* con un único mensaje a GT
- Periódicamente y cuando se revoca *token*, envía su copia a MN
  - MN mezcla cambios concurrentes a inodos:
    - *Fecha mod* = *máx(Fecha mod copias)* (igual para tamaño y punteros)
- NC deja rol de MN para F cuando deja de usar ese inodo
  - Rechaza volcados para ese inodo → elección de nuevo MN para F

Google File System

- Caldo de cultivo (≈2000)
- Almacenamiento datos en Google crítico: ¿usar SFP existente?
  - NO: por características de plataforma y de aplicaciones previstas
- Plataforma basada en *commodity* HW
  - Fallos HW/SW son norma y no excepción: Tolerancia a fallos SW
  - No altas prestaciones pero gran paralelismo (>1000 nodos almacen.)
    - 1 op. no es muy rápida pero se pueden hacer muchas en paralelo
- Perfil de aplicaciones previstas:
  - Modo de operación *batch* (ancho de banda importa más que latencia)
  - Millones de ficheros grandes (>100MB) y muy grandes (>1GB)
  - Patrones de acceso típicos
    - Escritor genera fichero completo inmutable
    - Múltiples escritores añaden datos a un fichero en paralelo
  - Con gran paralelismo, que no debe "estropear" el SF

Por la especialización hacia el éxito

- ¿SFP especializado para aplicaciones/plataforma Google?
  - Generalización de componentes clave en desarrollo informática
  - Tensión entre especialización y generalización
- Google juega con ventaja
  - Controla desarrollo de SFP y de aplicaciones
  - SFP no ideado para usarse fuera de Google
    - GFS → NFS (*Not For Sale*)
  - Reparto de funcionalidad SFP y aplicaciones ajustable a discreción
  - Puede imponer API, modelos coherencia,... "extraños", no estándar
- Especialización: sí pero no demasiada
  - Cobertura a mayoría de aplicaciones en Google
  - Prueba de éxito: numerosos clones de libre distribución (Hadoop FS)

Carga de trabajo prevista y API

- Perfil de aplicaciones previsto implica:
  - Mayoría lecturas grandes (>1MB) y secuenciales
  - Algunas lecturas pequeñas aleatorias
  - Mayoría escrituras grandes (>1MB) y secuenciales
    - Agregando datos y no sobrescribiendo (ficheros inmutables)
  - Habitual escrituras pequeñas simultáneas al final del fichero
  - Escrituras pequeñas aleatorias no previstas (pero soportadas)
- API, y modelo de coherencia, no estándar
  - Afectará a productividad pero Google manda...
  - Además de clásicas *create*, *open*, *read*, *write*, *close* y *delete*
    - *record append*
    - *snapshot*: Copia perezosa de fichero usando COW

Una primera aproximación a GFS

- Receta para diseñar de una manera simple un nuevo SFP:
  - Tomar como base un SF convencional (nodo maestro)
  - Añadir: cada trozo de fichero almacenado en nodo distinto
    - Nodo Linux convencional: trozo fichero GFS → fichero local
  - Datos repartidos en discos: problema de fiabilidad → réplicas
  - No usar caché en nodos cliente: no algoritmos de coherencia
    - Carga típica de Google (≈*read/write once*) apoya esta simplificación
- ¡Único nodo maestro gestiona toda la información del SF!
  - Ha primado sencillez sobre escalabilidad y tolerancia a fallos
    - Con el tiempo lo pagaremos...
- Escalabilidad del SF: la del nodo maestro
  - Minimizar trabajo y gasto de memoria de maestro
  - Nodo maestro más potente y con más memoria
  - ¡Ambas soluciones contrarias a la filosofía Google!

Striping

- Trozos fichero repartidos entre nodos de almacenamiento (NA)
- Tamaño de trozo/*chunk*/*stripe*: ¡64MB!
  - Respaldado por patrón típico de aplicaciones:
    - Grandes ficheros accedidos con lecturas/escrituras grandes
- Ventajas:
  - Clásicas: mejor aprovechamiento discos y red
  - Escalabilidad del maestro:
    - Menos gasto de memoria
    - Menos trabajo
- Desventajas:
  - Clásicas: relacionadas con fragmentación
    - Aunque fichero que representa *chunk* en NA puede tener tamaño justo
  - Menos paralelismo (fichero de 64MB en un único NA)
    - Pero mayoría ficheros previstos son muy grandes

Arquitectura de GFS

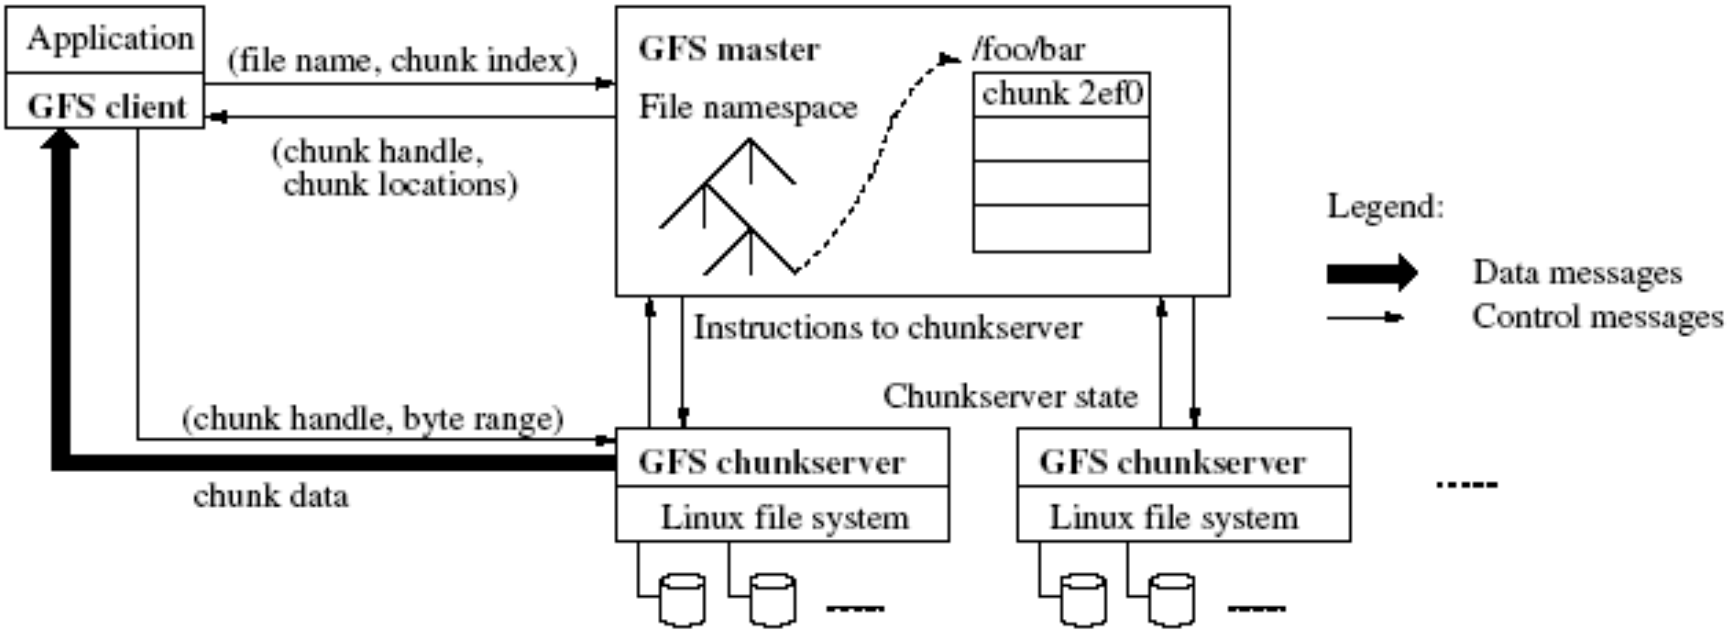

The Google File System

Sanjay Ghemawat, Howard Gobioff, and Shun-Tak Leung; *SOSP '03*

Finalmente se nos ha quedado pequeño

- Charla esclarecedora de Quinlan (Google) y McKusick (BSD)
  - http://queue.acm.org/detail.cfm?id=1594206
- Evolución de las necesidades
  1. Almacenamiento de centenares TB a decenas de PB
  2. Aumento proporcional de número de clientes
  3. Nuevas aplicaciones que manejan ficheros pequeños
  4. Nuevas aplicaciones donde latencia es importante
- Problemas (relación directa/indirecta con maestro único)
  1. Más metadatos en maestro: requiere más proceso y memoria
  2. Maestro recibe más operaciones (*open*, *close*, ...)
  3. Tamaño bloque (TB) menor (¿1MB?): más metadatos en maestro
  4. GFS usa TB grande y agrupa todo tipo de ops. siempre que puede
     - Además, tiempo de recuperación fallo maestro del orden de minutos

GFS II/Colossus

- GFS entra en la era de los “múltiples maestros”
  - *Sharding* de metadatos entre maestros
- GFS II/Colossus: reescritura completa
- Todavía poca información: se han filtrado aspectos adicionales
  - Tamaño de bloque 1MB
  - Tiempo de recuperación de pocos segundos
  - Uso de códigos correctores vs. replicación
  - Más especialización: soporte de Google Caffeine
    - Diseñado para trabajar conjuntamente con Bigtable
    - Almacenamiento de metadatos de Colossus en Bigtable