Sistemas de ficheros distribuidos

Índice

- Introducción
- Estructura de un SFD
- Resolución de nombres
- Acceso a los datos
- Gestión de cache
- Gestión de cerrojos
- Estudio de ejemplos: NFS, AFS y Coda
- Sistemas de ficheros paralelos
  - *General Parallel File System* (GPFS)
  - *Google File System* (GFS)

Conceptos básicos

- Sistema de ficheros distribuido (SFD)
  - Sistema de ficheros para sistema distribuido
  - Gestiona distintos dispositivos en diferentes nodos ofreciendo a usuarios la misma visión que un SF centralizado
  - Permite que usuarios compartan información de forma transparente
  - Misma visión desde cualquier máquina
- Numerosos aspectos similares a SF centralizados
- Algunos aspectos específicos como por ejemplo:
  - Traducción de nombres involucra a varios nodos
  - Uso de cache afecta a múltiples nodos
  - Aspectos de tolerancia a fallos

Características deseables del SFD

- Aplicables las correspondientes al SD global:
  - Transparencia, fiabilidad, rendimiento, escalabilidad, seguridad.
- Específicamente:
  - Espacio de nombres único
  - Soporte de migración de ficheros
  - Soporte para replicación
  - Capacidad para operar en sistemas “desconectados”
    - Una red “partida” o un cliente que usa un sistema portátil
  - Soporte de heterogeneidad en hardware y S.O.
  - Integración de nuevos esquemas de almacenamiento (SAN)
  - Paralelismo en acceso a datos de un fichero

Estructura del SFD

- Cliente (nodo con aplicación) – Servidor (nodo con disco)
- ¿Cómo repartir funcionalidad de SF entre cliente y servidor?
- Arquitectura “tradicional”
  - servidor: proporciona acceso a ficheros almacenados en sus discos
  - cliente: pasarela entre aplicación y servidor
    - con más o menos funcionalidad (clientes *fat* o *thin*)
- Arquitectura “alternativa”
  - servidor: proporciona acceso a bloques de disco
  - cliente: toda la funcionalidad del SF
  - Utilizada en sistemas de ficheros para *clusters*
    - se estudiará más adelante

Arquitectura del SFD

- Solución basada en arquitectura tradicional parece sencilla:
  - SF convencional en servidor
  - Exporta servicios locales para abrir, cerrar, leer, escribir, cerrojos,...
- ¿Asunto zanjado? No todo está resuelto:
  - Resolución de nombre de fichero:
    - Cliente y varios servidores involucrados. ¿Cómo se reparten trabajo?
  - Acceso a los datos:
    - ¿se transfiere sólo lo pedido? ¿más cantidad? ¿todo el fichero?
    - Uso de cache en el cliente. Coherencia entre múltiples caches.
  - Gestión de cerrojos:
    - ¿Qué hacer si se cae un cliente en posesión de un cerrojo?
  - Otros: migración, replicación, heterogeneidad, ...

Operaciones sobre los ficheros

- Apertura del fichero: Traducción del nombre
  - Gestión de nombres
- Lecturas/escrituras sobre el fichero
  - Acceso a datos
  - Uso de cache
- Establecimiento de cerrojos sobre el fichero

Gestión de nombres

- Similar a SF convencionales:
  - Espacio de nombres jerárquico basado en directorios
  - Esquema de nombres con dos niveles:
    - Nombres de usuario (*pathname*) y Nombres internos
  - Directorio: Relaciona nombres de usuario con internos
- Nombres de usuario
  - Deben proporcionar transparencia de la posición
    - Nombre no debe incluir identificación del nodo donde está

      triqui.fi.upm.es:/home/fichero.txt
- Nombres internos
  - Identificador único de fichero (UFID) utilizado por el sistema
    - Puede ser una extensión del usado en SF convencionales.
    - Por ejemplo:

      id. de máquina + id. disco + id. partición + id. inodo

Espacio de nombres

- Similar a SF convencionales:
  - Espacio de nombres dividido en volúmenes (o particiones, o ...)
    - Cada volumen gestionado por un servidor
  - Espacio único mediante composición de volúmenes:
    - Extensión distribuida de operación de montaje de UNIX
- Alternativas en la composición:
  - Montar sistema de ficheros remoto sobre la jerarquía local (NFS)
    - Montaje en cliente: información de montaje se almacena en cliente
    - Espacio de nombres diferente en cada máquina
  - Único espacio de nombres en todas las máquinas (AFS)
    - Montaje en servidor: información de montaje se almacena en servidor
    - Espacio de nombres común para el SD

Resolución de nombres

- Traducir una ruta que se extiende por varios servidores
- ¿Quién busca cada componente de la ruta?
  - cliente: solicita contenido del directorio al servidor y busca (AFS)
  - servidor: realiza parte de la búsqueda que le concierne
- Alternativas en la resolución dirigida por los servidores
  - iterativa, transitiva y recursiva
- "Cache de nombres" en clientes
  - Almacén de relaciones entre rutas y nombres internos
    - También existe en SF convencional
  - Evita repetir proceso de resolución
    - Operación más rápida y menor consumo de red (*escalabilidad*)
  - Necesidad de coherencia
    - Fichero borrado y nombre interno reutilizado
    - Uso de contador de versión del inodo

      id. de máquina + id. disco + id. partición + id. inodo + nº versión

Resolución iterativa

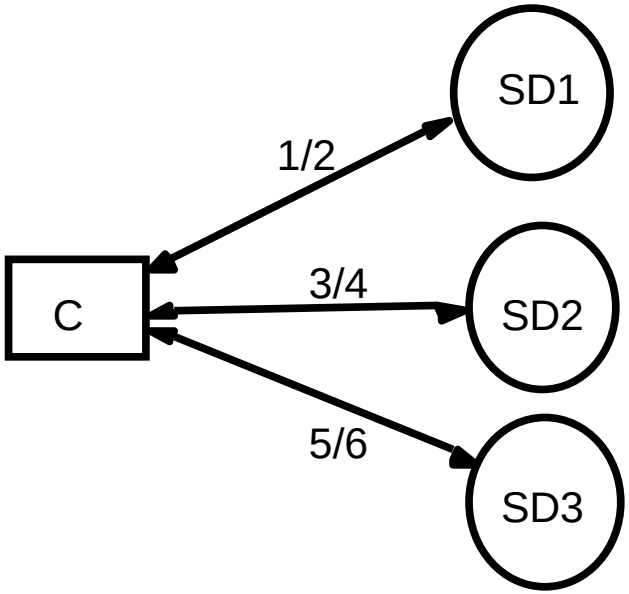

Resolución transitiva

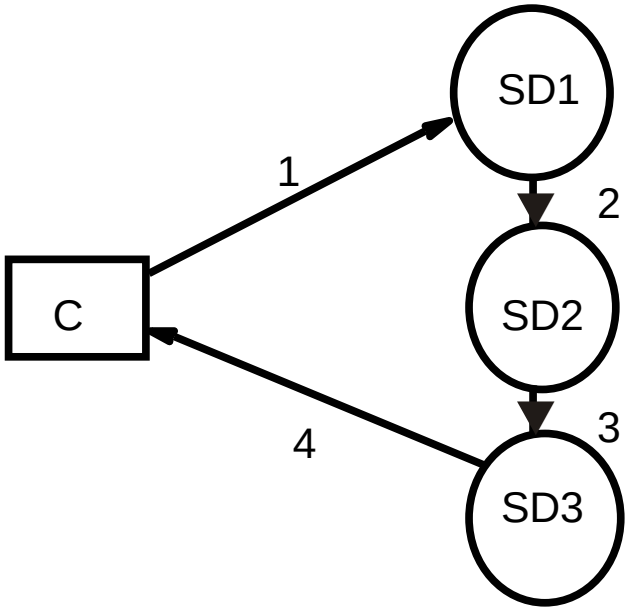

Resolución recursiva

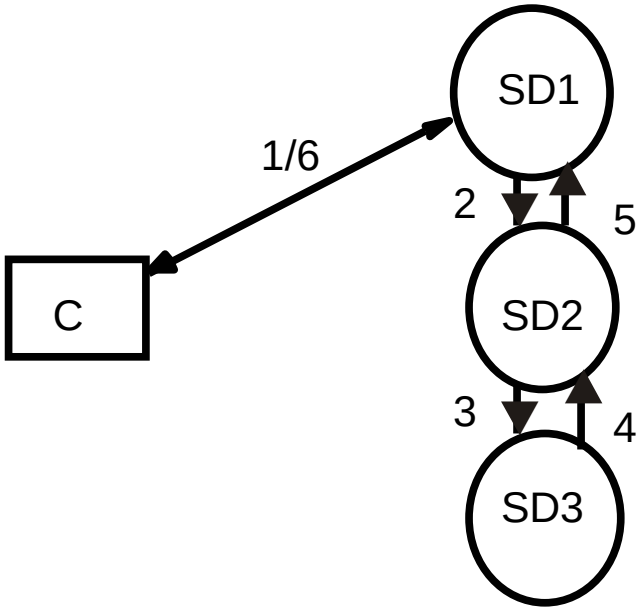

Localización de ficheros

- Resolución obtiene nombre interno (UFID)
- Uso de UFID con dir. máquina donde fichero está localizado
  - No proporciona, en principio, independencia de la posición
    - Nombre de fichero cambia cuando éste migra
- Uso de UFID que no contenga información de máquina:
  - Por ejemplo (AFS):

    id. único de volumen + *id. inodo* + *nº versión*
  - Permite migración de volúmenes
  - Requiere esquema de localización: Volumen → Máquina
- Posibles esquemas de localización:
  - Tablas que mantengan la información de ubicación (AFS)
  - Uso de *broadcast* para localizar nodo
- Uso de "cache de localizaciones" en clientes

Acceso a datos del fichero

- Una vez abierto el fichero, se tiene info. para acceder al mismo
- Aspectos de diseño vinculados con acceso a datos:
  - ¿Qué se garantiza ante accesos concurrentes?
    - Semántica de uso concurrente
  - ¿Qué información se transfiere entre cliente y servidor?
    - Modelo de acceso
  - ¿Qué info. se guarda en cache y cómo se gestiona?
    - Gestión de cache

Semánticas de uso concurrente

- Sesión: serie de accesos que realiza cliente entre *open* y *close*
- La semántica especifica el efecto de varios procesos accediendo de forma simultánea al mismo fichero
- Semántica UNIX
  - Una lectura *ve* los efectos de todas las escrituras previas
  - El efecto de dos escrituras sucesivas es el de la última
- Semántica de sesión (AFS)
  - Cambios a fichero abierto, visibles sólo en nodo que lo modificó
  - Una vez cerrado, cambios visibles sólo en sesiones posteriores
  - Múltiples imágenes simultáneas del fichero
  - Dos sesiones sobre mismo fichero que terminan concurrentemente:
    - La última deja el resultado final
  - No adecuada para procesos con acceso concurrente a un fichero

Modelo de acceso

- Modelo carga/descarga
  - Transferencias completas del fichero
  - Localmente se almacena en memoria o discos locales
  - Normalmente utiliza semántica de sesión
  - Eficiencia en las transferencias
  - Llamada `open` con mucha latencia

- Modelo de servicio remoto
  - Servidor debe proporcionar todas las operaciones sobre el fichero
  - Acceso por bloques
  - Modelo cliente/servidor

Modelo carga/descarga

- Correspondencia petic. de aplicación y mens. de protocolo:
  - *open* → mensaje de descarga (*download*)
    - se realiza traducción y servidor envía fichero completo
    - cliente almacena fichero en cache local
  - *read*/*write*/*lseek* → no implica mensajes de protocolo
    - lecturas y escrituras sobre copia local
  - *close* → mensaje de carga (*upload*)
    - si se ha modificado, se envía fichero completo al servidor

Modelo de serv. remoto: con estado

- Correspondencia petic. de aplicación y mens. de protocolo:
  - *open* → mensaje de apertura
    - se realiza traducción
    - servidor habilita zona de memoria para info. de la sesión
    - retorna id. específico para esa sesión
  - *read*/*write*/*lseek* → mensaje de protocolo correspondiente
    - mensaje incluye id. sesión
    - mensaje lectura y escritura incluye tamaño pero no posición
    - uso de información sobre la sesión almacenada en servidor (posición)
  - *close* → mensaje de cierre
    - servidor libera zona de memoria de la sesión
- Ventajas servicio con estado (frente a sin estado):
  - Mensajes más pequeños, posibilidad de realizar políticas "inteligentes" en servidor (p.ej. lectura anticipada), procesamiento de peticiones posiblemente un poco más eficiente

Modelo de serv. remoto: sin estado

- Correspondencia petic. de aplicación y mens. de protocolo:
  - *open* → mensaje de apertura
    - se realiza traducción
    - servidor **no** habilita zona de memoria para info. de sesión (cliente sí)
    - retorna id. interno del fichero UFID
  - *read*/*write* → mensaje de protocolo correspondiente
    - mensaje autocontenido
    - mensaje incluye UFID, tamaño y posición
  - *lseek* → no implica mensaje de protocolo
  - *close* → no implica mensaje de protocolo
    - cliente libera zona de memoria de la sesión
- Ventajas servicio sin estado (frente a con estado):
  - Tolerancia a fallos ante rearranque del servidor, posiblemente menos mensajes, no hay gastos de recursos en servidor por cada cliente (*escalabilidad*)

Gestión de cache

- El empleo de cache permite mejorar el rendimiento
- Caches en múltiples niveles de un SD:
  - Cache en los servidores
    - Reducen los accesos a disco
  - Cache en los clientes
    - Reduce el tráfico por la red
    - Reduce la carga en los servidores
    - Puede situarse en discos locales (no permite nodos sin disco)
      - Más capacidad pero más lento
      - No volátil, facilita la recuperación
    - y/o en memoria principal
      - Menor capacidad pero más rápido
      - Memoria volátil

Uso de cache en clientes

- Empleo de cache de datos en clientes
  - Mejora rendimiento y capacidad de crecimiento
  - Introduce problemas de coherencia
- Otros tipos de cache
  - Cache de nombres
  - Cache de metadatos del sistema de ficheros
- Políticas de gestión de cache de datos:
  - Política de actualización
  - Política de coherencia
- Enfoque alternativo: Cache colaborativa (xFS)
  - Si bloque solicitado está en la cache de otro cliente, se copia de ésta

Política de actualización

- Escritura inmediata (*write-through*)
  - Buena fiabilidad
  - Las escrituras son más lentas
  - Mayor fragmentación en la información transferida por la red
- Escritura diferida (*delayed-write*)
  - Escrituras más rápidas
  - Se reduce el tráfico en la red
  - Los datos pueden borrarse antes de ser enviados al servidor
  - Menor fiabilidad
  - ¿Cuándo volcar los datos?
    - Volcado periódico
    - Volcado al cerrar (*Write-on-close*)

Coherencia de cache

- El uso de cache en clientes produce problema de coherencia
  - ¿es coherente una copia en cache con el dato en el servidor?
- Estrategia de validación iniciada por el cliente
  - cliente contacta con servidor para determinar validez
    - en cada acceso, al abrir el fichero o periódicamente
- Estrategia de validación iniciada por el servidor
  - servidor avisa a cliente (*callback*) al detectar que su copia es inválida
    - generalmente se usa *write-invalidate* (no *write-update*)
  - servidor almacena por cada cliente info. sobre qué ficheros guarda
    - implica un servicio con estado

C. de cache: semántica de sesión

- Validación iniciada por el cliente (usada en AFS versión 1):
  - En apertura se contacta con servidor enviando nº de versión (o fecha modificación) del fichero almacenado en cache local (si lo hay)
  - Servidor comprueba si corresponde con versión actual:
    - En caso contrario, se envia la nueva copia
- Validación iniciada por el servidor (usada en AFS versión 2):
  - Si hay copia en cache local, en apertura no se contacta con servidor
  - Servidor almacena información de qué clientes tienen copia local
  - Cuando cliente vuelca nueva versión del fichero al servidor:
    - servidor envía invalidaciones a clientes con copia
  - Disminuye nº de mensajes entre cliente y servidor
    - Mejor rendimiento y *escalabilidad*
  - Dificultad en la gestión de *callbacks*
    - No encajan fácilmente en modelo cliente-servidor clásico

C. de cache: semántica UNIX

- Validación iniciada por el cliente
  - Inaplicable
    - Hay que contactar con servidor en cada acceso para validar info.
- Validación iniciada por el servidor. 2 ejemplos de protocolos:
  - *Prot1*: control en la apertura con desactivación de cache
    - Basado en Sprite: SOD desarrollado en Berkeley en los 80
  - *Prot2*: uso de *tokens*
    - Basado en DFS, sistema de ficheros distribuido de DCE (*Open Group*)

C. de cache: semántica UNIX. *Prot1*

- Servidor guarda info. de qué clientes tienen abierto un fichero
- Si acceso concurrente conflictivo (1escritor + otro(s) cliente(s))
  - se anula cache y se usa acceso remoto en nodos implicados
- En *open* cliente contacta con servidor especificando:
  - modo de acceso + nº de versión de copia en cache (si la hay)
  - Si no hay conflicto de acceso:
    - Si versión del cliente en cache es más antigua, se indica que la invalide
  - Si la petición produce un conflicto de acceso:
    - Se le envía a los clientes con el fichero abierto una orden de invalidación y desactivación de la cache para ese fichero
      - Si era un escritor se le pide un volcado previo
    - Se indica al cliente que invalide y desactive la cache para ese fichero
  - Si la petición se encuentra que ya hay conflicto
    - Se indica al cliente que invalide y desactive la cache para ese fichero

C. de cache: semántica UNIX. *Prot2*

- Para realizar operación se requiere *token* correspondiente
  - *Token* (de lectura o escritura) asociado a un rango de bytes
- Si cliente solicita operación y no está presente *token* requerido en su nodo, se solicita al servidor de ficheros
- Para una zona de un fichero, el servidor puede generar múltiples *tokens* de lectura pero sólo uno de escritura
- Si existen múltiples *tokens* de lectura y llega solicitud de escritura, servidor reclama los *tokens*
  - Cliente devuelve *token* e invalida bloques de cache afectados
  - Cuando todos devueltos, servidor manda *token* de escritura
- Si hay un *token* de escritura y llega solicitud de lectura o escritura, servidor reclama el *token*:
  - Cliente vuelca e invalida bloques de cache afectados

Servicio con estado basado en *leases*

- Semántica UNIX requiere servicio con estado
  - ¿Cómo lograr servicio con estado pero con buena recuperación?
- *Lease*: concesión con plazo de expiración
  - Necesita renovarse
  - Aplicable a otros servicios además de la coherencia
- *Prot2* ampliado: *token* tiene un plazo de expiración
  - Pasado el plazo cliente considera que *token* ya no es válido
  - Tiene que volver a solicitarlo
  - Permite tener servidor con estado pero fácil recuperación:
    - Cuando rearranca servidor no entrega *tokens* hasta que haya pasado plazo de expiración con lo que todos los *tokens* están caducados

Gestión de cerrojos

- SFD ofrecen cerrojos de lectura/escritura
  - múltiples lectores y un solo escritor
- Peticiones *lock*/*unlock* generan mensajes correspondientes
  - *lock*: si factible retorna OK; sino no responde
  - *unlock*: envía a OK a cliente(s) en espera
- Requiere un servicio con estado:
  - servidor almacena qué cliente(s) tienen un cerrojo de un fichero y cuáles están en espera
- Problema: cliente con cerrojo puede caerse
  - Solución habitual: uso de *leases*
  - Cliente con cerrojo debe renovarlo periódicamente

Network File System (NFS) de Sun

- Especificación de un protocolo para acceso a ficheros remotos
- Estándar diseñado para entornos heterogéneos
  - Versión 3: RFC-1813 (descrita en esta presentación)
  - Versión 4: RFC-3010 (última versión; cambios en arquitectura)
- Independencia gracias al uso de RPC/XDR de ONC
- Seguridad basada en “RPC segura”
- Compartición: máquina monta directorio remoto en SF local
  - Espacio de nombres es diferente en cada máquina
- No da soporte a migración ni replicación
- Comprende dos protocolos: montaje y acceso a ficheros

Protocolo de montaje

- Establece una conexión lógica entre el servidor y el cliente
- Cada máquina incluye una “lista de exportación”
  - qué “árboles” exporta y quién puede montarlos
- Petición de montaje incluye máquina y directorio remotos
  - Se convierte en RPC al servidor de montaje remoto
  - Si permiso en lista, devuelve un identificador “opaco” (*handle*)
    - Cliente no conoce su estructura interna
- La operación de montaje sólo afecta al cliente no al servidor
  - se permiten montajes NFS anidados, pero no “transitivos”
- Aspectos proporcionados por algunas implementaciones:
  - montajes *hard* o *soft*: en montaje, si servidor no responde...
    - espera ilimitada (*hard*) o plazo máximo de espera (*soft*)
  - automontaje: no solicita montaje hasta acceso a ficheros

Ejemplo de montado en NFS

- La máquina A exporta */usr* y */bin*
- En la máquina B:
  - *mount máquinaA:/usr /usr*

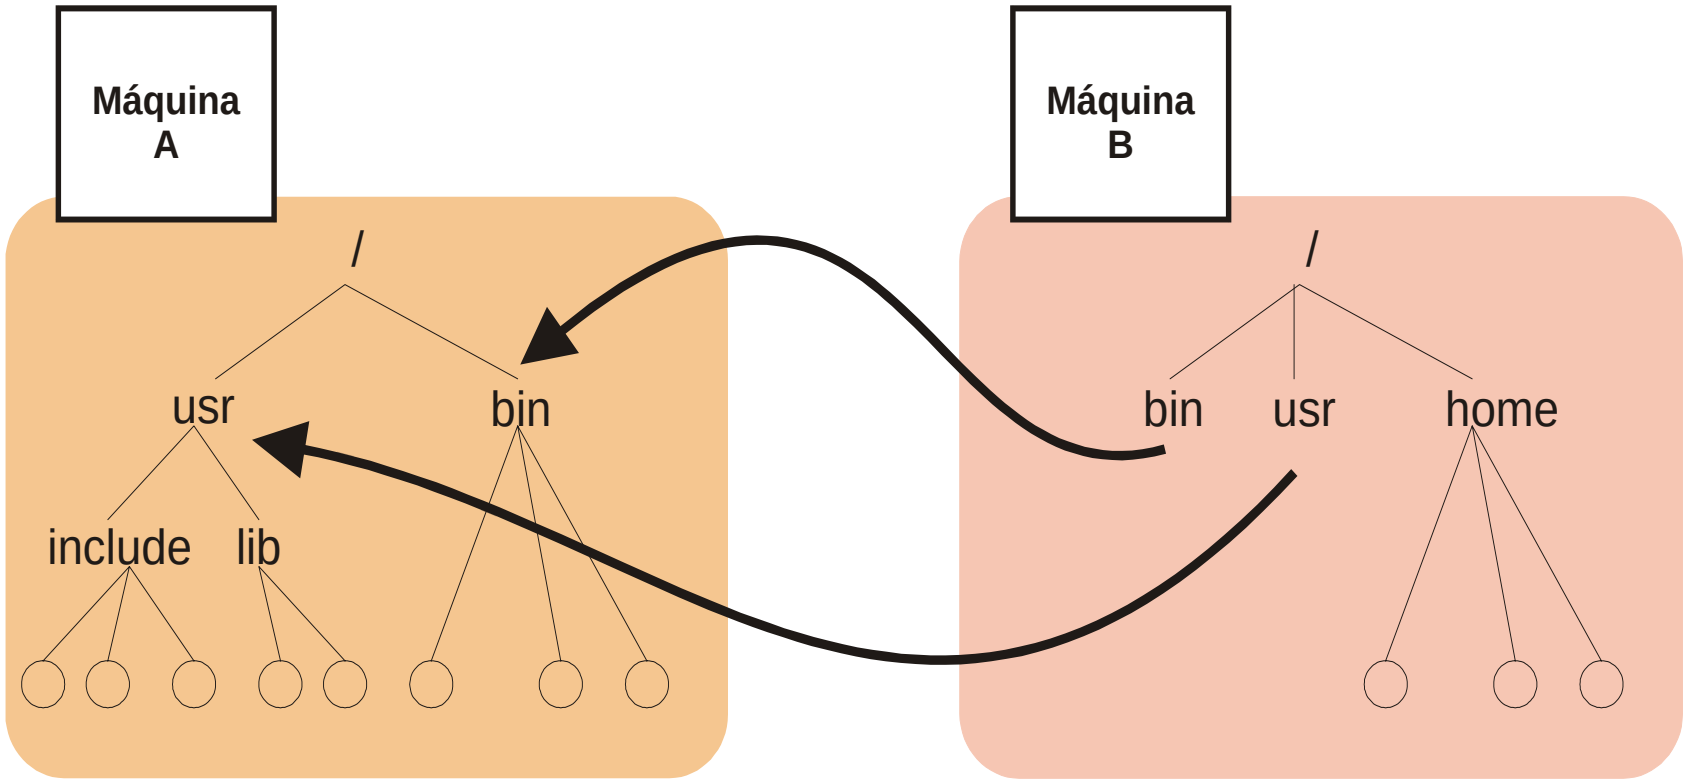

Ejemplo de montado en NFS

- Imagen diferente del sistema de ficheros

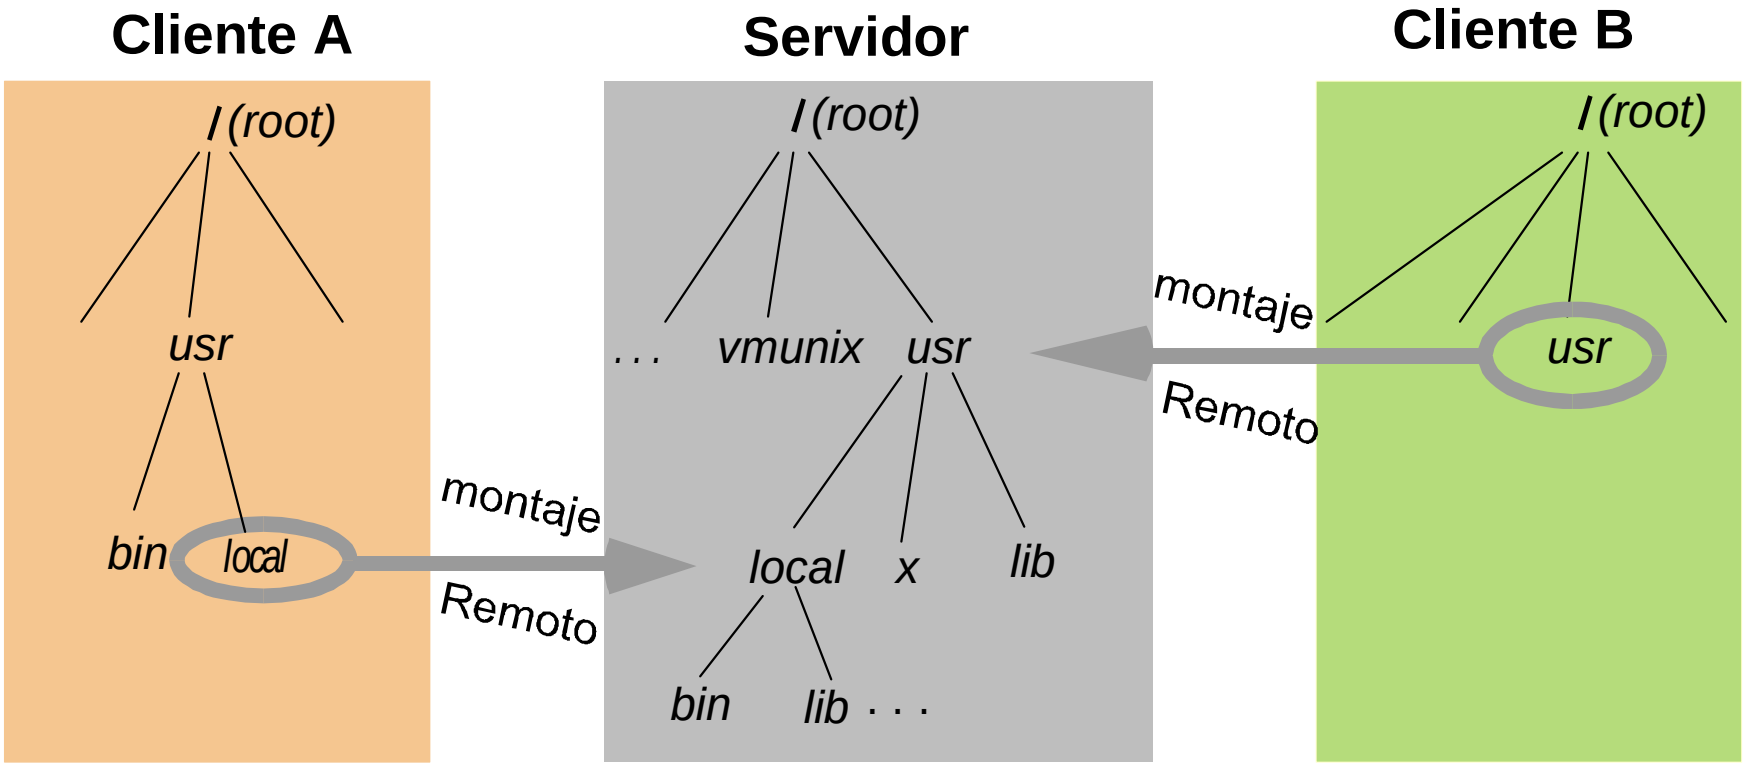

Protocolo NFS

- Ofrece RPCs para realizar operaciones sobre ficheros remotos
  - Búsqueda de un fichero en un directorio (LOOKUP)
  - Lectura de entradas de directorio
  - Manipulación de enlaces y directorios
  - Acceso a los atributos de un fichero
  - Lectura y escritura. En vers. 2 escritura síncrona en disco de servidor
    - Versión 3 permite asíncrona (COMMIT fuerza escritura en disco)
- Servidores NFS sin estado (no en versión 4)
  - Operaciones autocontenidas
- OPEN reemplazado por LOOKUP (no hay CLOSE)
  - traducción iterativa componente a componente
    - LOOKUP(*handle* de directorio, fichero) $\rightarrow$ *handle* de fichero
- El protocolo no ofrece mecanismos de control de concurrencia
  - Procolo independiente de NFS: *Network Lock Manager*

Implementación Sun/NFS

- Arquitectura basada en sistema de ficheros virtual (VFS)
- *Vnodo* apunta a un nodo-i local o a uno remoto (*Rnodo*)
- Cada *Rnode* contiene *handle* del fichero remoto
- Contenido del *handle* depende de sistema remoto
- En sistemas UNIX se usa un *handle* con tres campos:
  - id. del sistema de ficheros
  - número de inodo
  - número del versión del inodo (se incrementa en cada reutilización)
- En montaje se obtiene *handle* de la raíz del subárbol montado
- Posteriores operaciones *lookup* obtienen sucesivos *handles*

Arquitectura de Sun/NFS

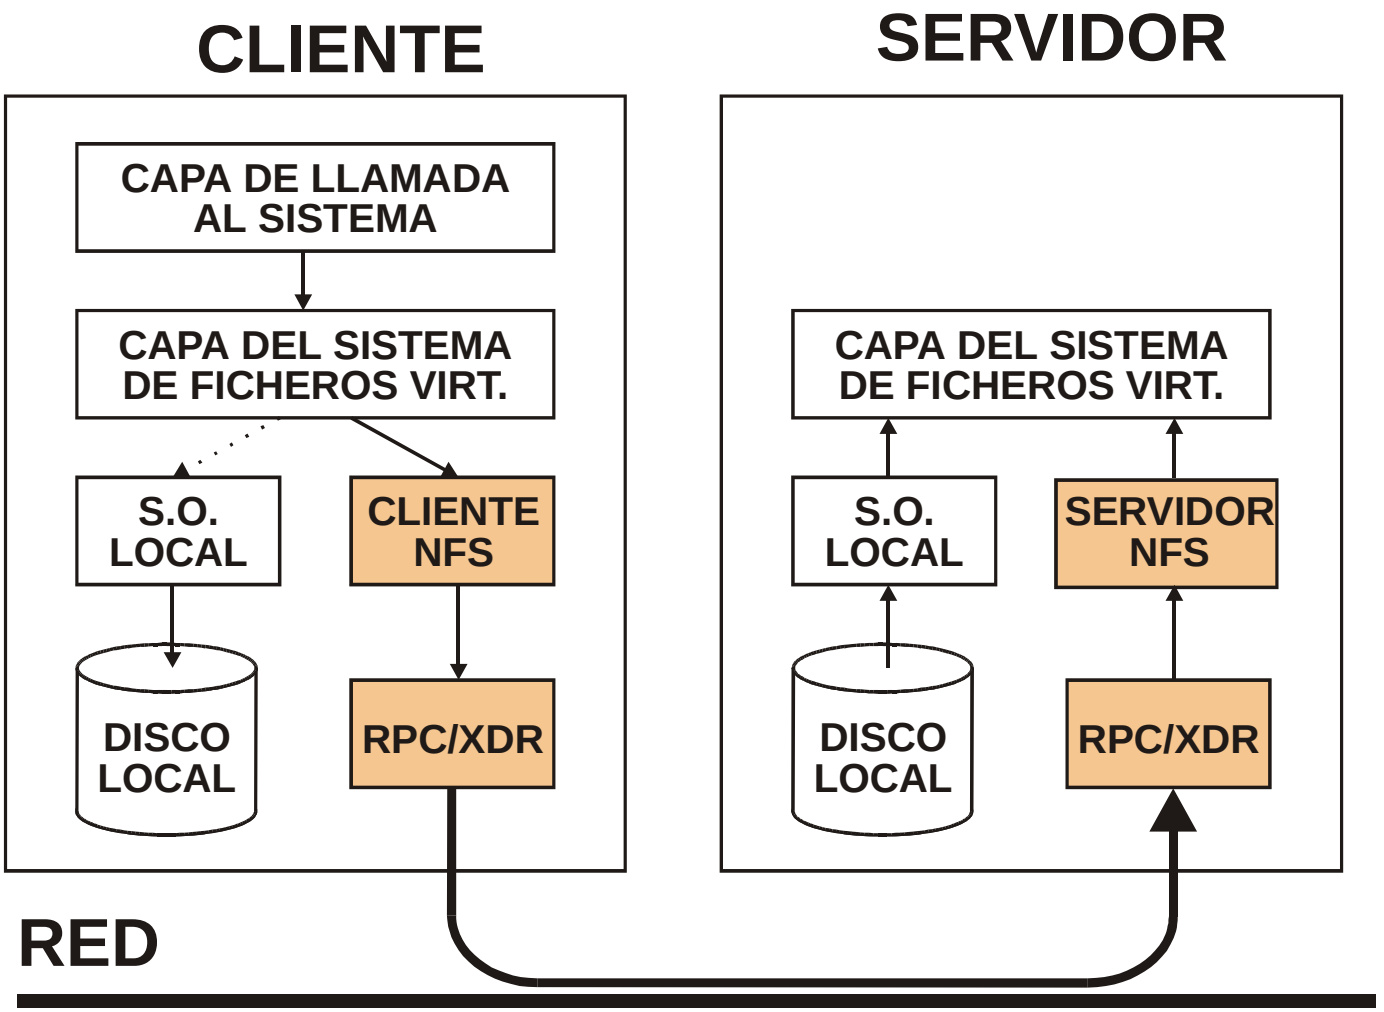

Acceso a ficheros en Sun/NFS

- Las transferencias se realizan en bloques de 8 KB
- Los bloques se almacenan en la cache de los clientes
- Los clientes realizan lecturas adelantadas de un bloque
- Las escrituras se realizan localmente.
- Los bloques se envían al servidor cuando se completan o se cierra el fichero
- Cache del servidor:
  - escritura síncrona o asíncrona según lo indicado por el cliente
- 3 tipos de cache en el cliente:
  - cache de nombres para acelerar las traducciones
  - cache de atributos de ficheros y directorios (fechas, dueño, ...)
  - cache de bloques de ficheros y directorios

Coherencia de cache en Sun/NFS

- No asegura ninguna semántica
- Validación dirigida por el cliente:
  - Toda operación sobre un fichero devuelve sus atributos
  - Si los atributos indican que el fichero se ha modificado
    - se invalidan los datos del fichero en cache de bloques
  - Entradas de cache de bloques y atributos tienen un tiempo de vida
  - Si no se acceden es ese periodo se descartan
  - Valores típicos:
    - 3 segundos para ficheros
    - 30 para directorios

Novedades de la versión 4 de NFS

- Servicio con estado basado en *leases* (hay OPEN y CLOSE)
- Diseñado para ser usado en Internet
- Integra protocolo de montaje y de cerrojos
  - Un solo puerto fijo (2049): facilita atravesar cortafuegos
- Empaquetamiento de operaciones:
  - Una llamada RPC (COMPOUND) con múltiples operaciones
- Operación LOOKUP puede resolver el camino completo
  - Montajes en el servidor visibles por el cliente
- Uso de listas de control de acceso (ACL)
- Atributos del fichero incluye un mecanismo de extensibilidad

Andrew File System (AFS)

- SFD desarrollado en Carnegie-Mellon (desde 1983)
  - Se presenta la versión AFS-2
- Actualmente producto de Transarc (incluida en IBM)
  - OpenAFS: versión de libre distribución para UNIX y Windows
- Sistemas distribuidos a gran escala (5000 - 10000 nodos)
- Distingue entre nodos cliente y servidores dedicados
  - Los nodos cliente tienen que tener disco
- Ofrece a clientes dos espacios de nombres:
  - local y compartido (directorio `/afs`)
  - espacio local sólo para ficheros temporales o de arranque
- Servidores gestionan el espacio compartido
- Visión única en todos los clientes del espacio compartido

Estructura de AFS

- Dos componentes que ejecutan como procesos de usuario
- *Venus*:
  - ejecuta en los clientes
  - SO le redirecciona peticiones sobre ficheros compartidos
  - realiza las traducciones de nombres de fichero
    - resolución dirigida por el cliente
    - cliente lee directorios: requiere formato homogéneo en el sistema
- *Vice*:
  - ejecuta en los servidores
  - procesa solicitudes remotas de clientes
- Usan sistema de ficheros UNIX como almacén de bajo nivel

Estructura de AFS

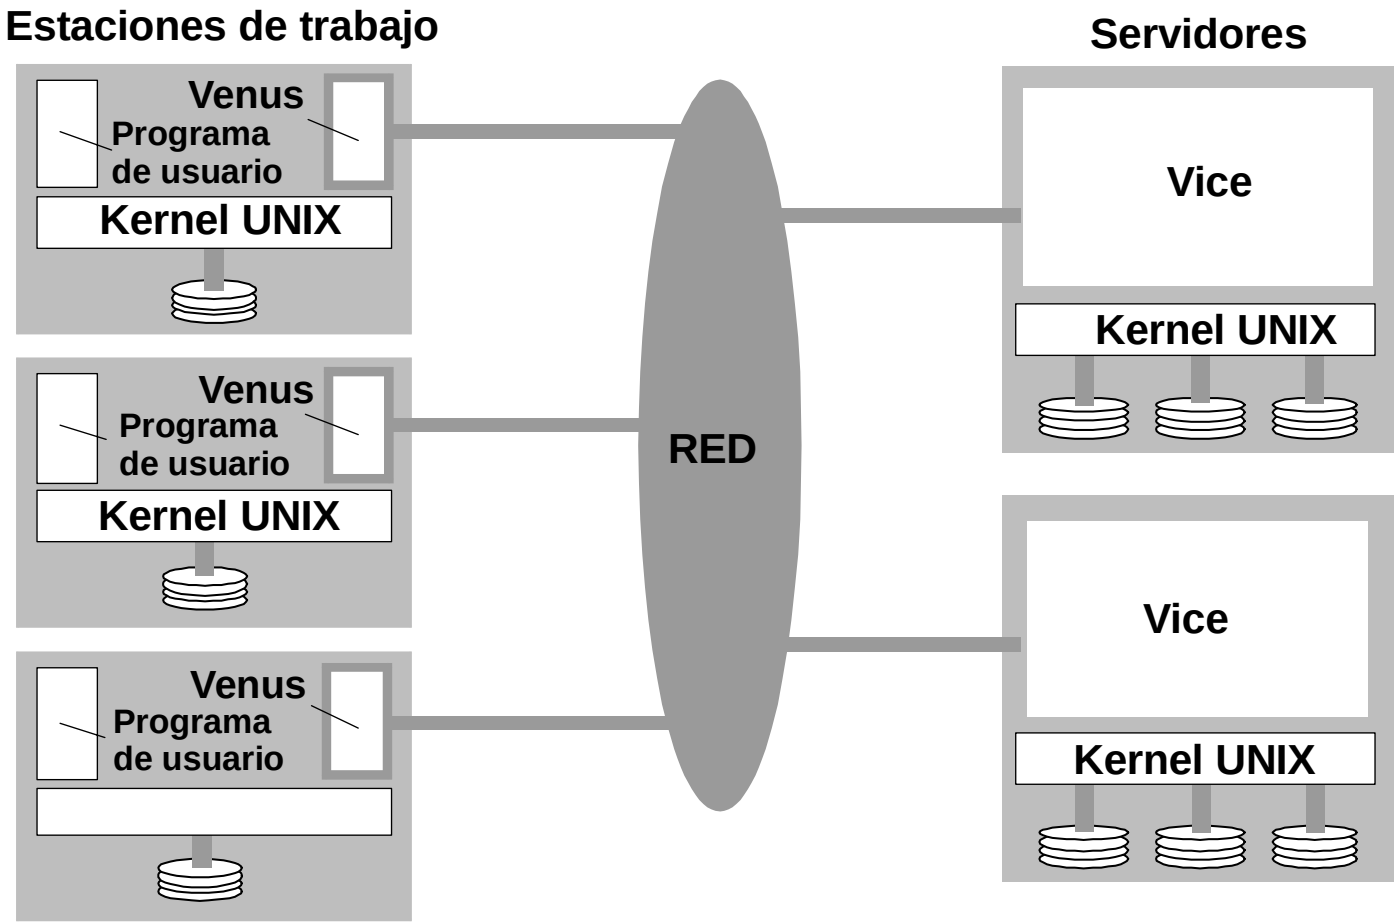

Espacio de nombres compartido

- Los ficheros se agrupan en *volúmenes*
  - Unidad más pequeña que un sistema de ficheros UNIX
- Cada fichero tiene identificador único (UFID: 96 bits)
  - Número de volumen
  - Número de *vnodo* (dentro del volumen)
  - Número único: permite reutilizar números de vnodo
- Los UFID son transparentes de la posición
  - un volumen pueden cambiar de un servidor a otro.
- Soporte a la migración de volúmenes
- Estrategia de localización
  - número de volumen $\rightarrow$ servidor que lo gestiona
  - tabla replicada en cada servidor
  - cliente mantiene una cache de localización
    - si falla repite proceso de localización

Acceso a ficheros

- Modelo de carga/descarga
  - En `open` servidor transfiere fichero completo al cliente
  - Versión actual: fragmentos de 64Kbytes
- *Venus* almacena el fichero en la cache local de los clientes
  - Se utiliza el disco local (la cache es no volátil)
- Lecturas/escrituras localmente sin intervenir *Venus*
  - Cache de UNIX opera aunque de manera transparente a AFS
- Cuando un proceso cierra un fichero (*close*)
  - Si se ha modificado se envía al servidor (*write-on-close*)
  - Se mantiene en cache local para futuras sesiones
- Modificaciones de directorios y atributos directamente al servidor

Coherencia de cache (1/2)

- Semántica de sesión
- Validación iniciada por servidor basada en *callbacks*
- Cuando cliente abre fichero del que no tiene copia local (o no es válida), contacta con el servidor
  - el servidor “anota” que el fichero tiene un *callback* para ese cliente
- Siguientes aperturas del fichero no contactan con servidor
- Cuando cliente cierra un fichero que ha modificado:
  - Lo notifica y lo vuelca al servidor
  - Servidor avisa a los nodos con copia local para que la invaliden:
    - Eevoca el *callback*
  - Solicitud en paralelo usando una multiRPC

Coherencia de cache (2/2)

- Cuando llega una revocación a un nodo:
  - procesos con fichero abierto continúan accediendo a copia anterior
  - nueva apertura cargará el nuevo contenido desde el servidor
- Los clientes de AFS asumen que los datos en su cache son válidos mientras no se notifique lo contrario
- El servidor almacena por cada fichero una lista de clientes que tienen copia del fichero en su cache:
  - la lista incluye a todos los clientes que tienen copia y no sólo a los que tienen abierto el fichero

Coda

- Descendiente de AFS orientado a proporcionar alta disponibilidad mediante replicación de volúmenes
- Lectura de cualquier copia – Escritura en todas
- Si red "partida": cliente sólo actualiza copias accesibles
  - Se mantienen contadores de versión en cada copia de fichero
- En reconexión: se comparan contadores de las copias
  - Si no conflicto → se propaga a todas las copias la última versión
  - Si conflicto → reconciliación automática o manual
    - Ejemplo de automática: reconciliación de directorio
- Permite operación desconectada del cliente
  - Usuario puede sugerir qué ficheros deberían estar en cache
  - En reconexión: conciliación entre cache del cliente y servidores
  - Aunque no concebido para ello, es aplicable a computación móvil

Sistemas Operativos Distribuidos

Sistemas de ficheros paralelos

Fernando Pérez Costoya

Índice

- Necesidad de E/S paralela
- Conexión de dispositivos
- Sistemas de ficheros distribuidos versus paralelos
- Técnicas de optimización de E/S
- *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)

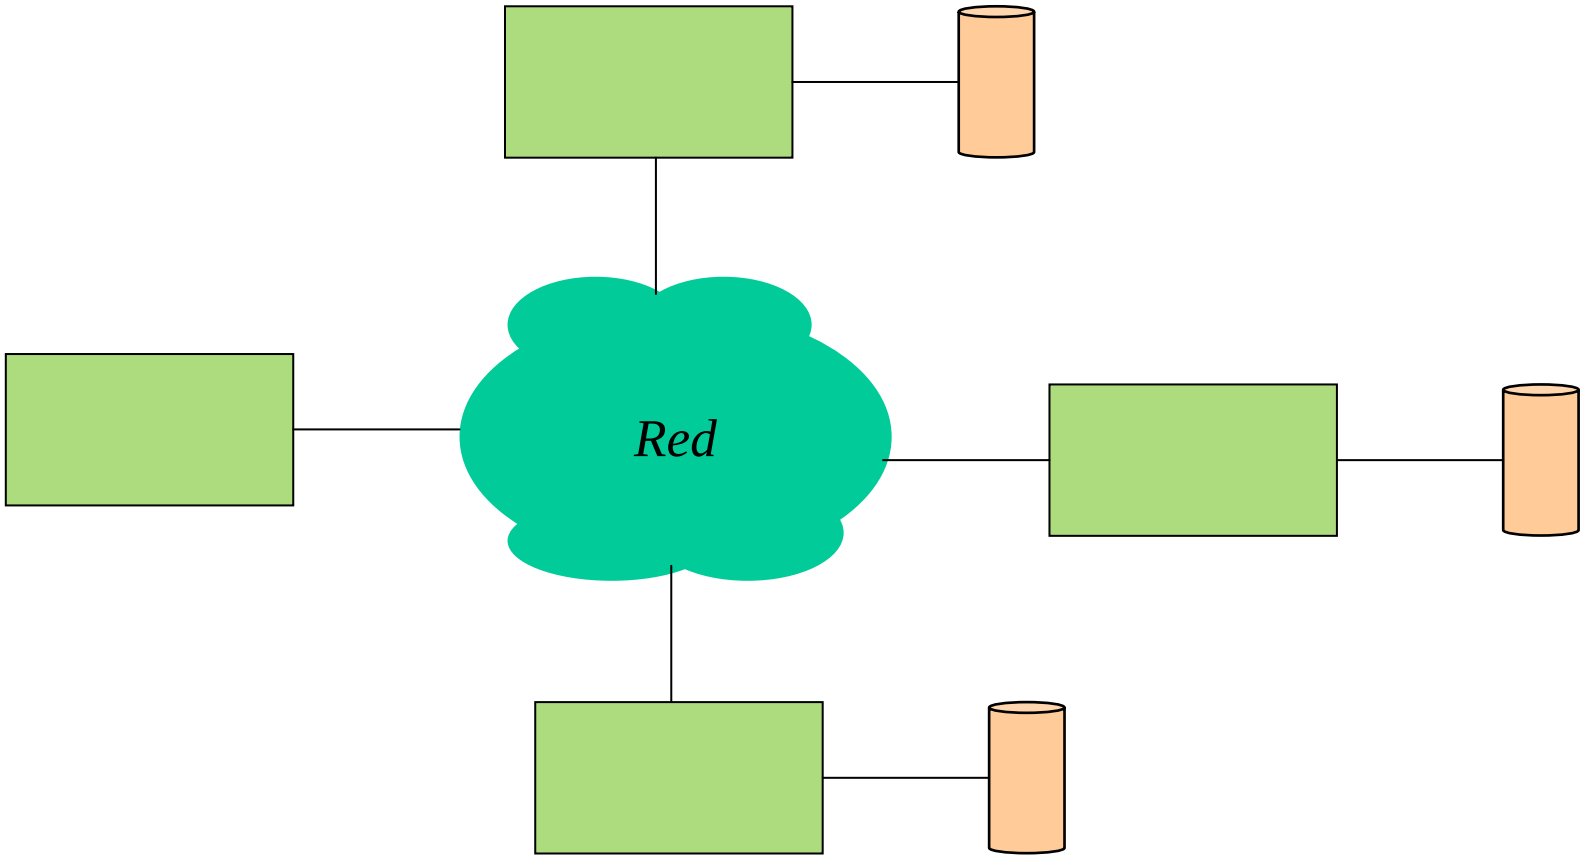

Network-attached storage (NAS)

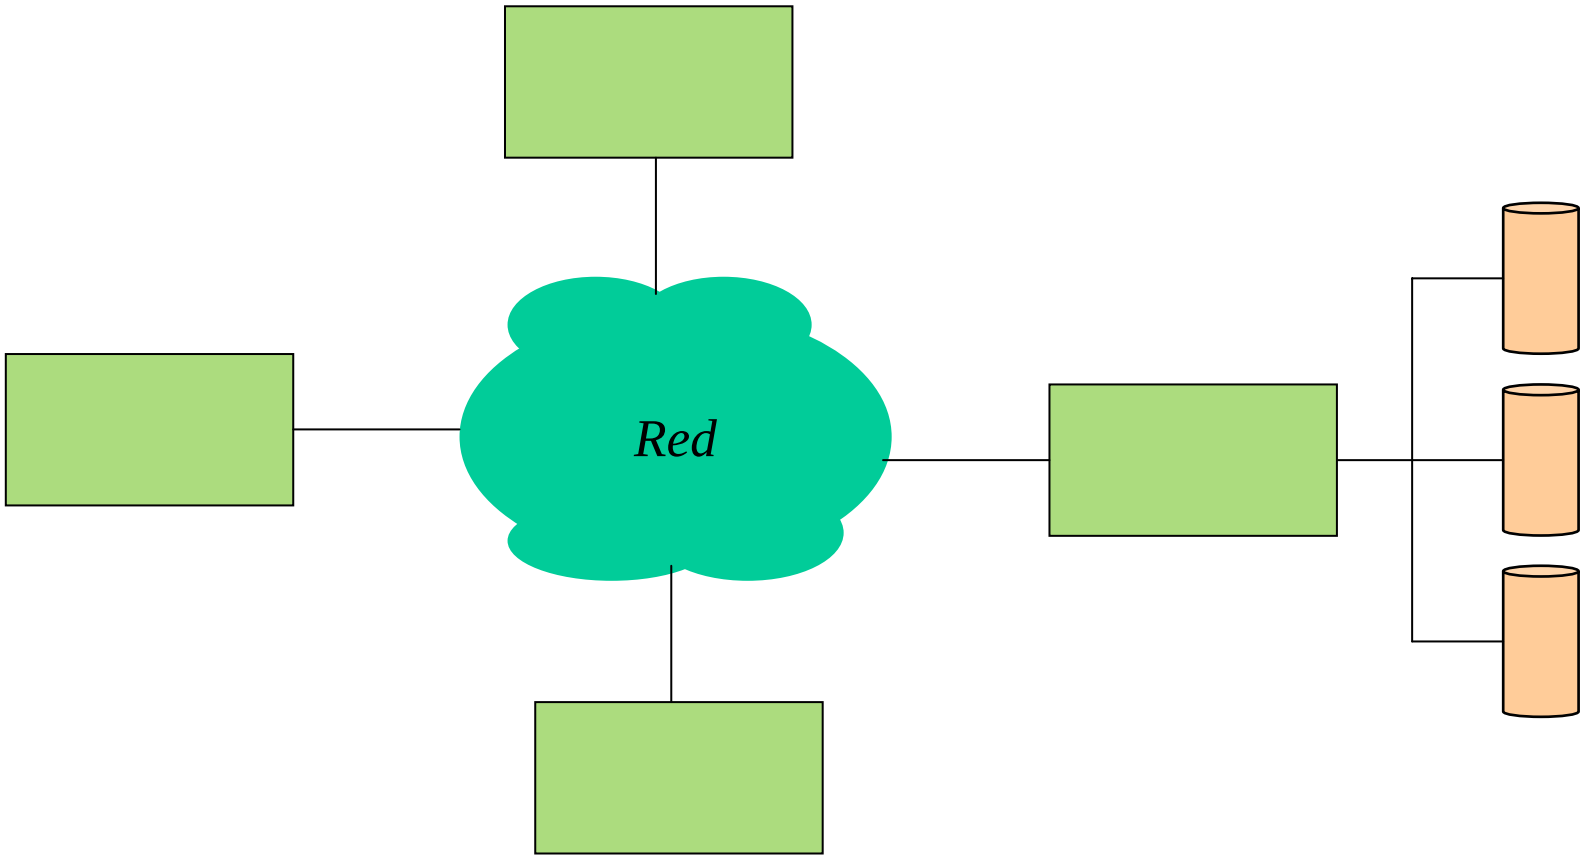

Storage Area Network (SAN)

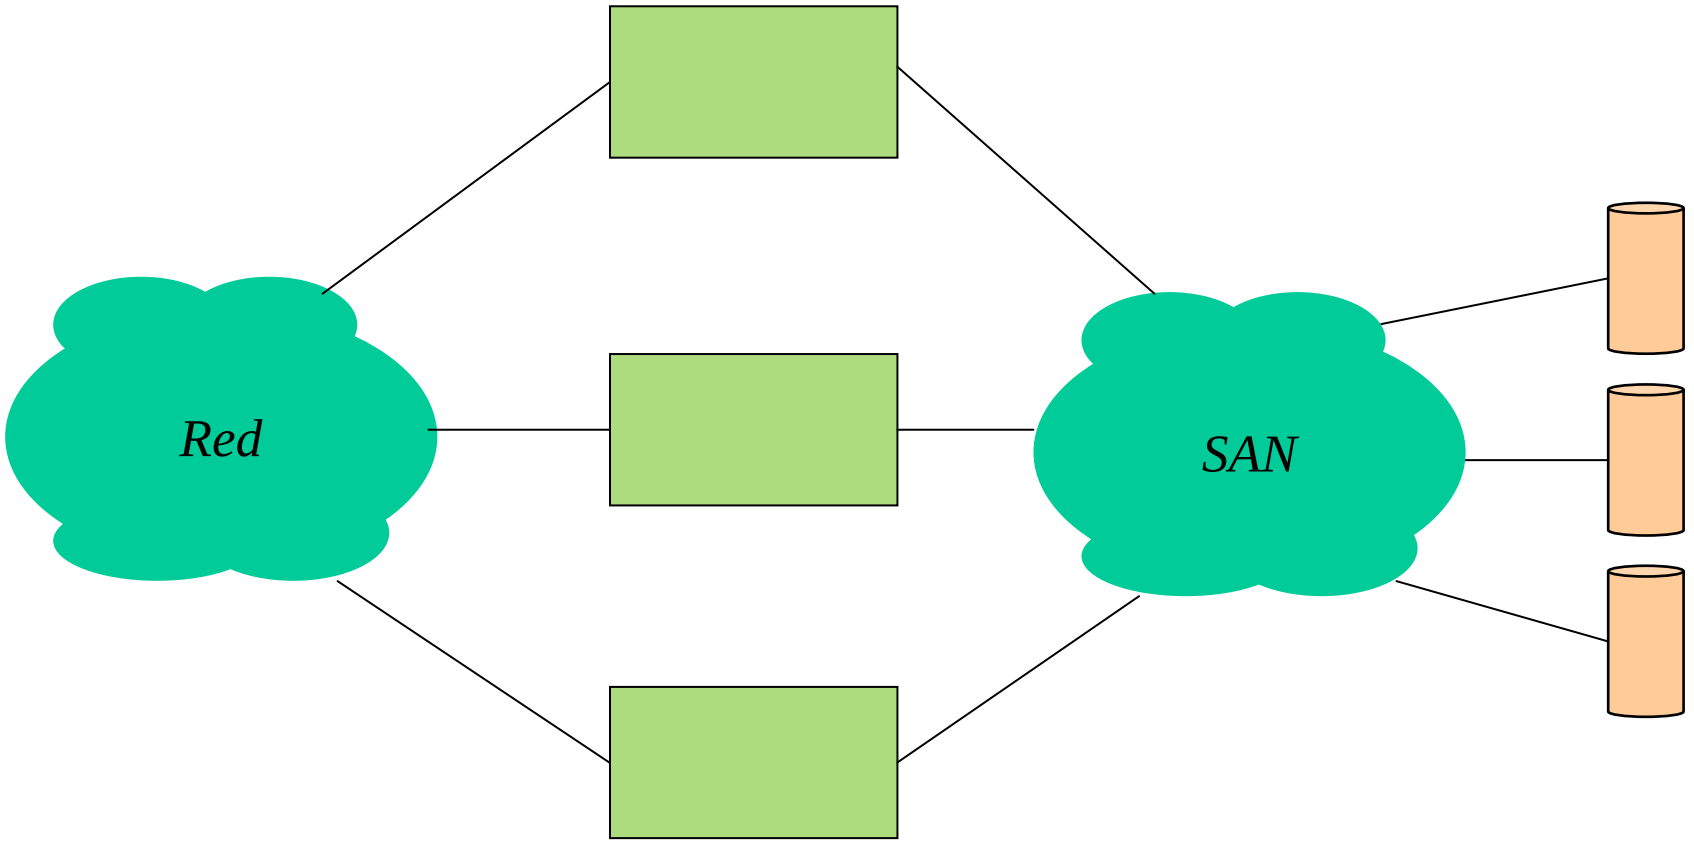

Sistemas de ficheros para E/S paralela

- ¿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

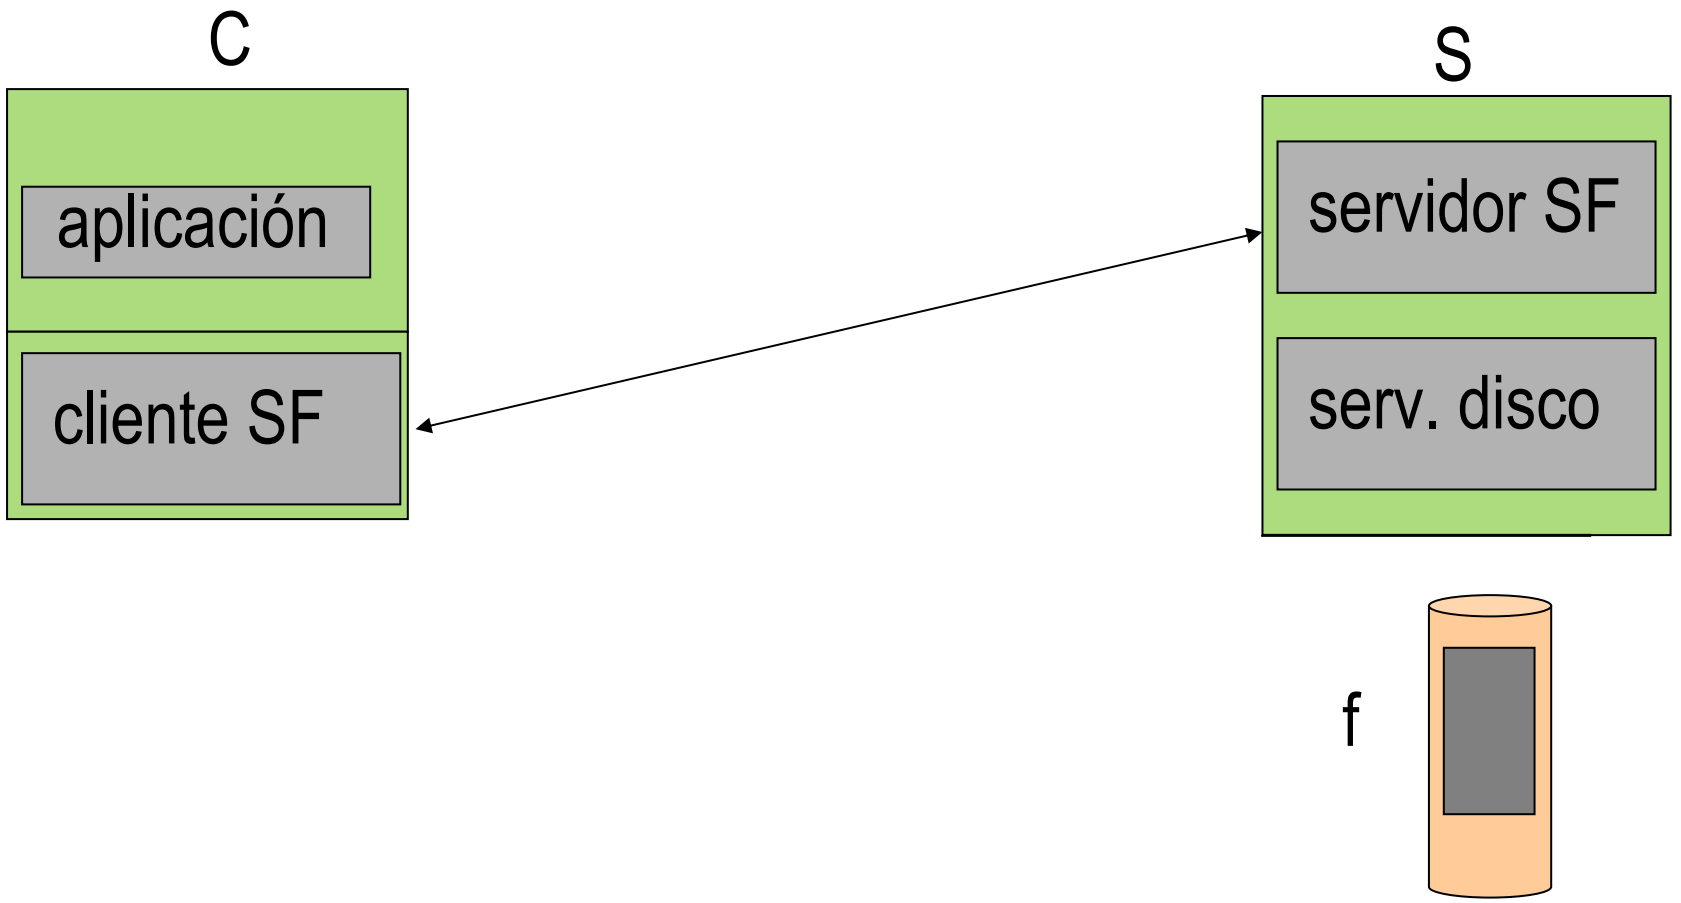

Disposición de datos en SFD

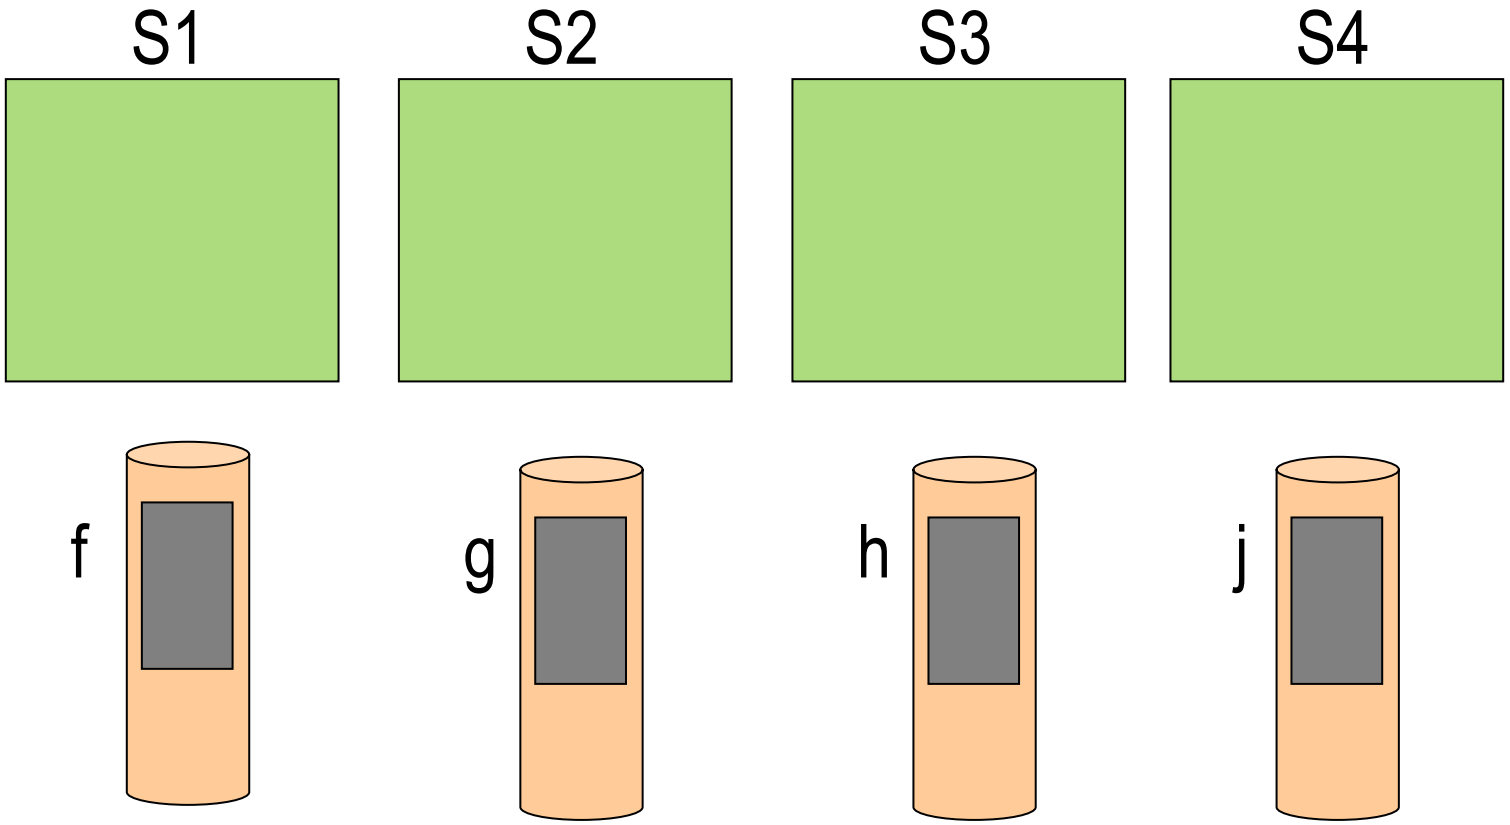

Sistemas de ficheros paralelos

- 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*

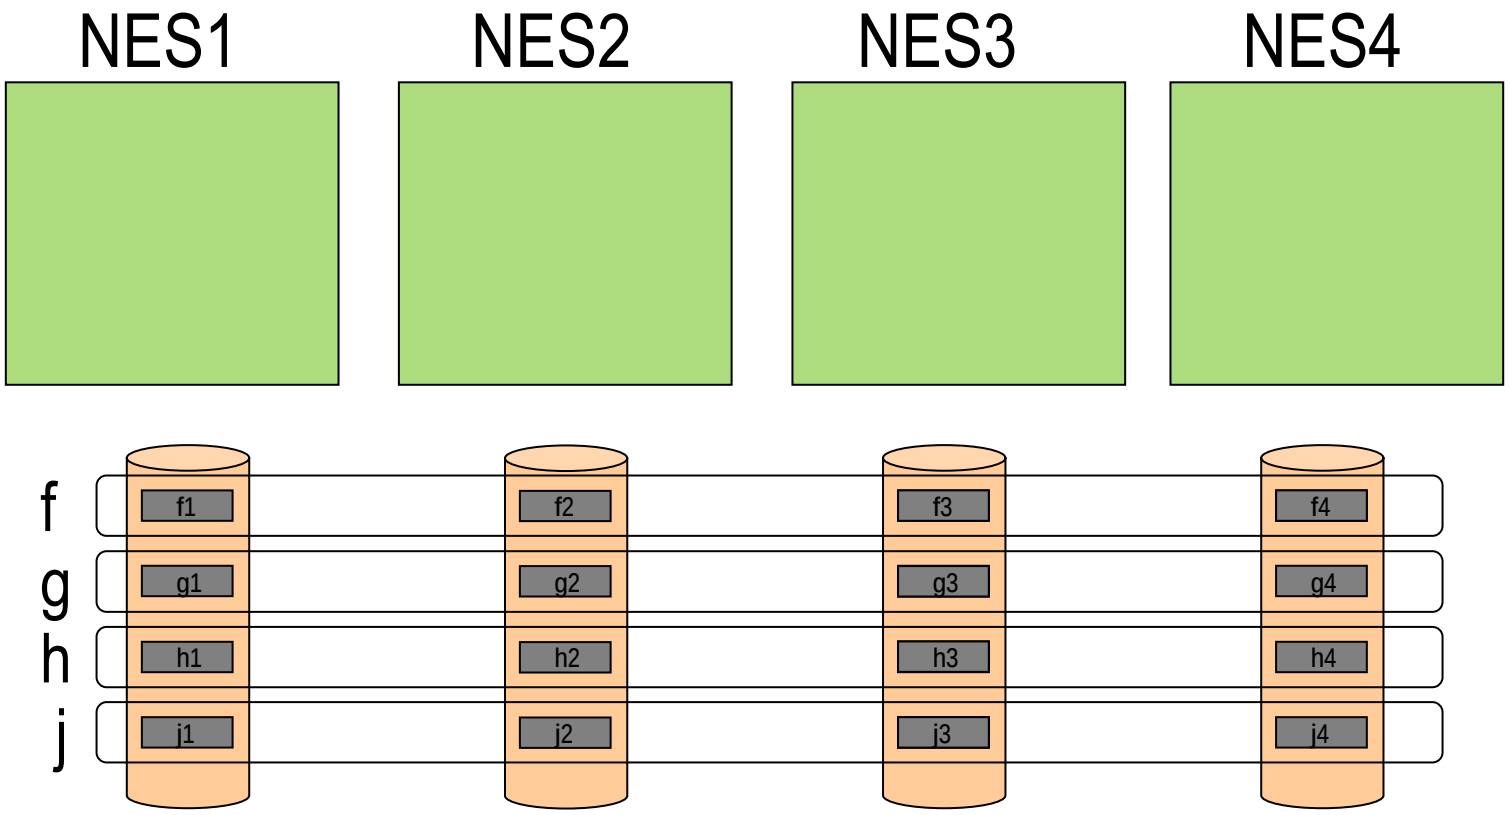

Arquitectura SFP

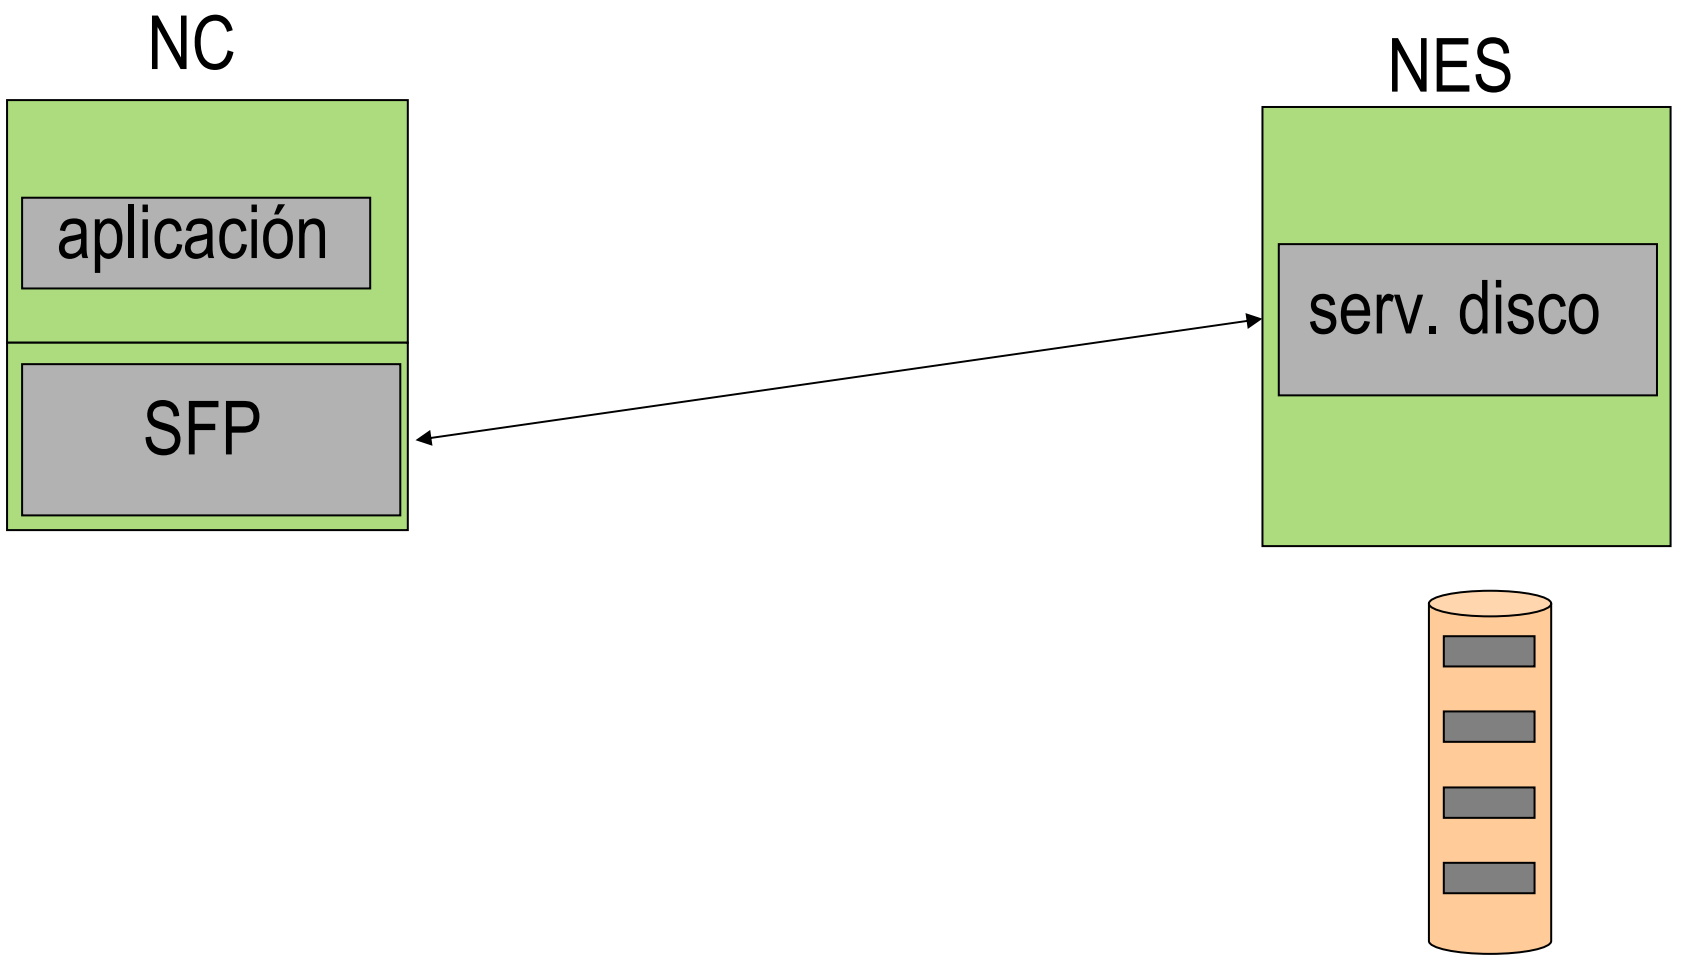

Configuración basada en SAN

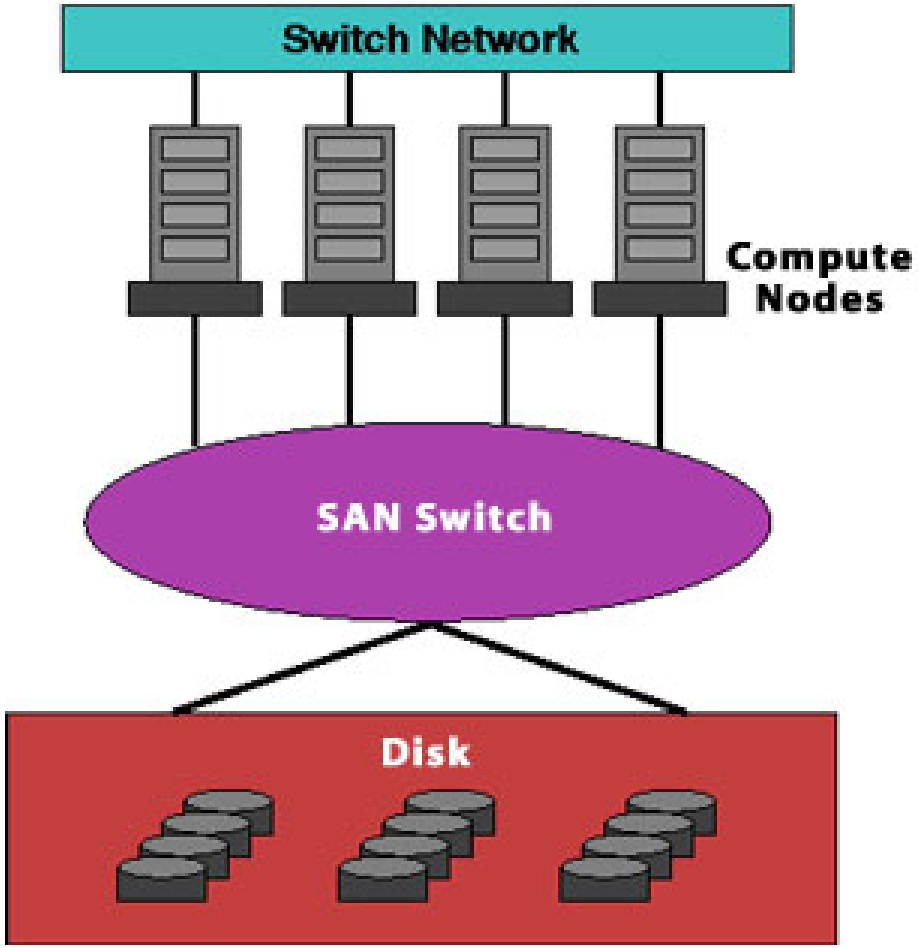

http://www.ncsa.illinois.edu/UserInfo/Data/filesystems/

Configuración basada en nodos de E/S

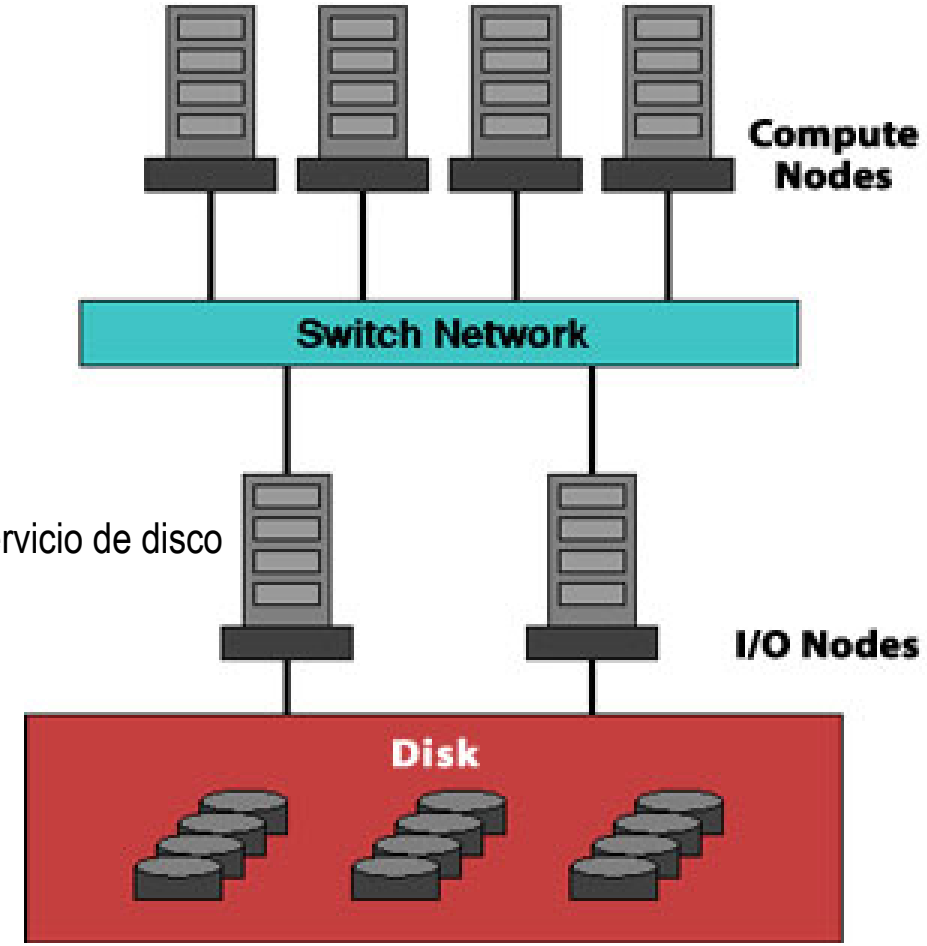

http://www.ncsa.illinois.edu/UserInfo/Data/filesystems/

Redundancia de datos

- *Stripping* aumenta probabilidad de fallo al acceder a fichero
- Necesidad de redundancia para mejorar disponibilidad
- 2 alternativas:
  - Replicación ($\approx$ RAID 1)
  - Códigos correctores ($\approx$ RAID 5)
- Comparativa:
  - Redundancia ocupa más espacio pero requiere menos cómputo
- Códigos correctores: problema de las “escrituras pequeñas”
  - Escritura no abarca todos datos controlados por un código corrector
    - Lectura de datos a sobrescribir y código corrector previo
    - Cálculo del nuevo código corrector
    - Escritura de nuevos datos y nuevo código corrector
  - Hay que evitarlas
    - Tamaño escritura múltiplo tamaño zona controlada por código corrector

SFP con replicación

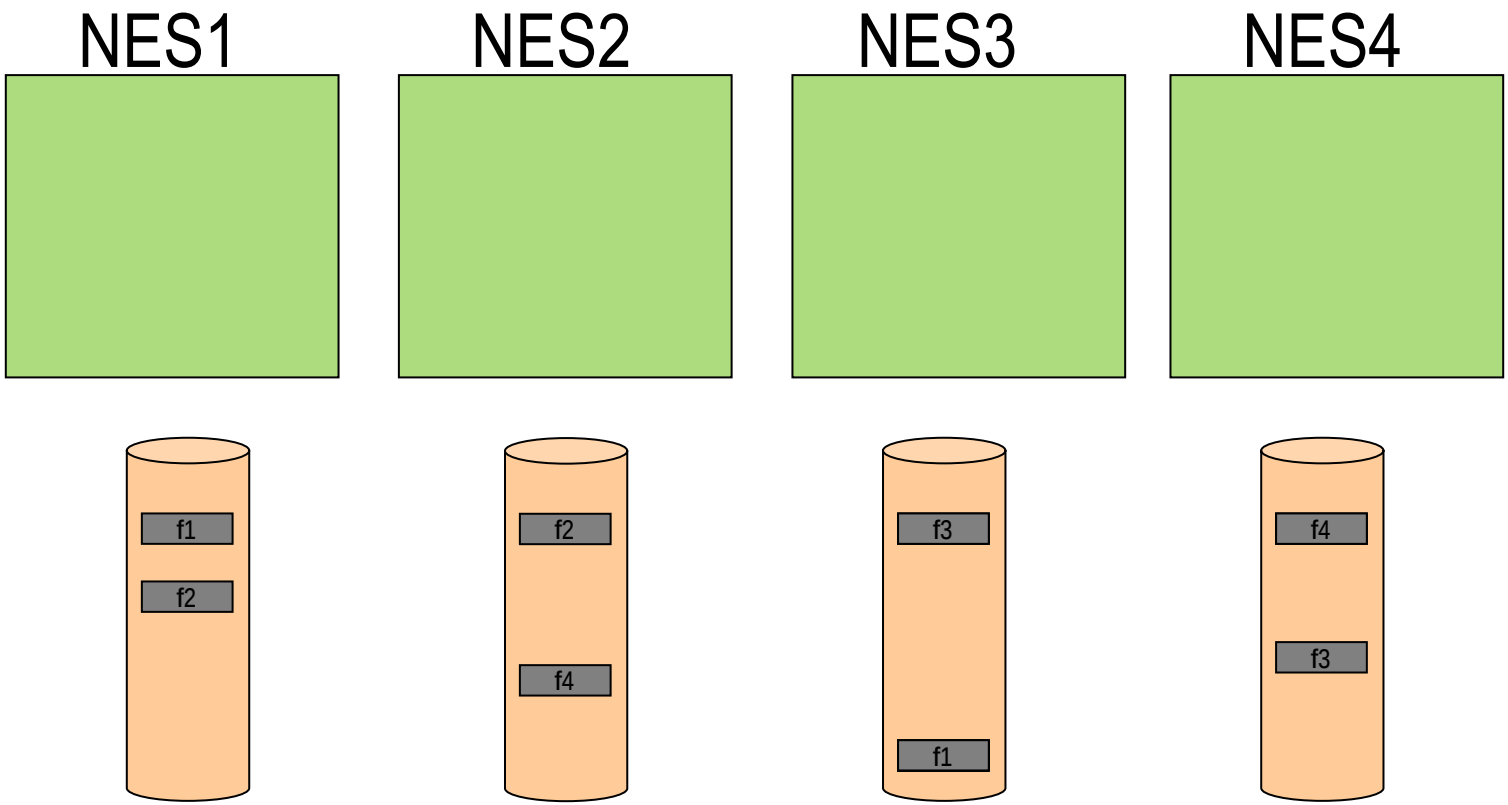

SFP con códigos correctores

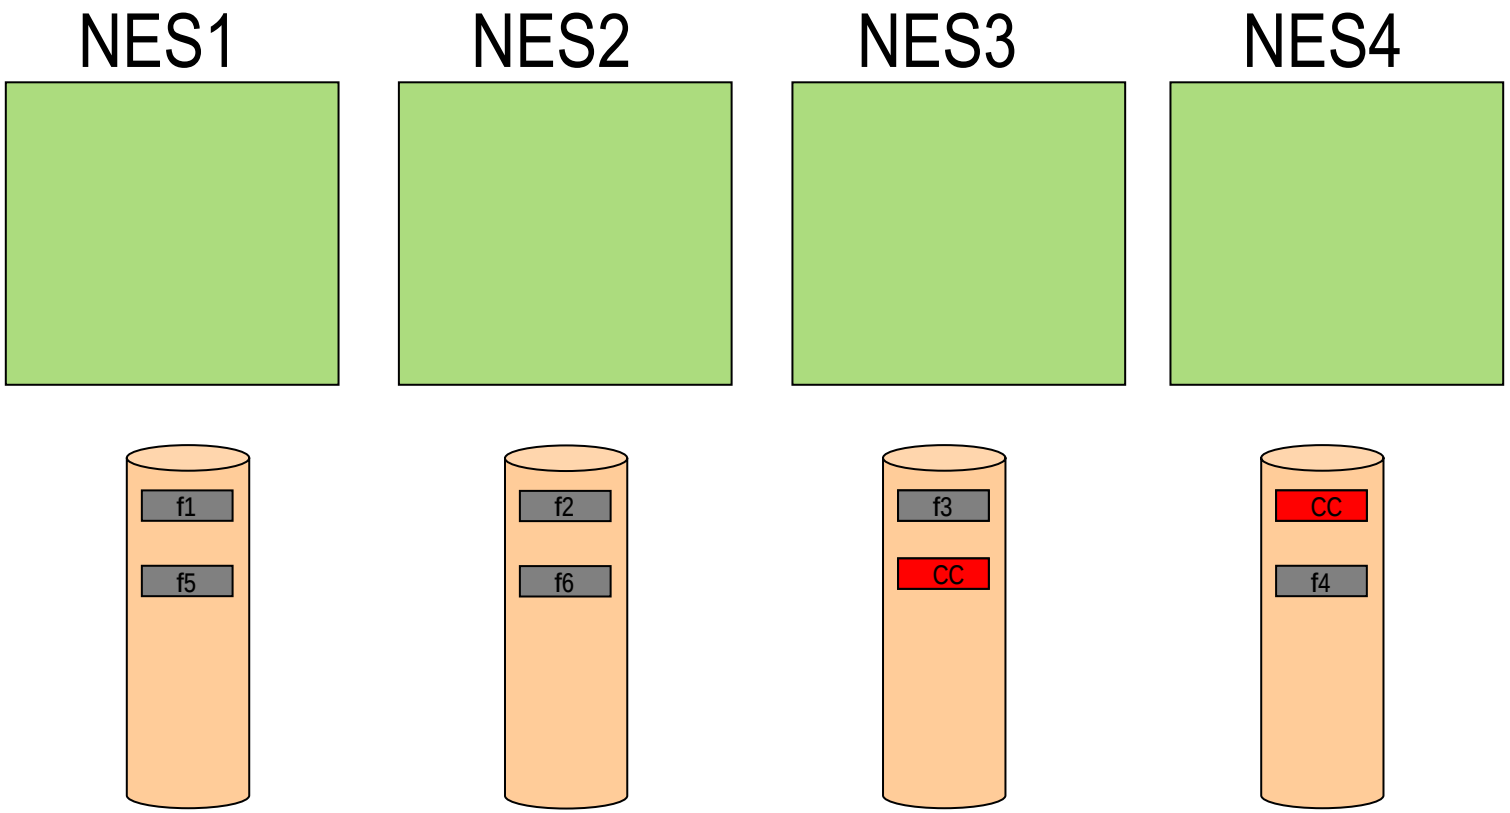

Técnicas de optimización de E/S

- Objetivo: Maximizar tamaño de accesos a dispositivo
- Optimización de:
  - Operaciones de un proceso
  - Operaciones independientes de varios procesos
  - Operaciones colectivas
- Diversas técnicas
  - Uso de caché de datos
  - Operaciones no contiguas
  - Operaciones colectivas

Caché de datos

- Permite nodos clientes soliciten/vuelquen múltiples bloques
- Uso de *prefetching* en lecturas
  - Se piden por anticipado más bloques de los solicitados por lectura
  - SF detecta patrón de acceso de la aplicación:
    - P. ej. secuencial directo e inverso, con saltos regulares, ...
  - En caso de patrón de acceso irregular: aplicación puede especificarlo
- Uso de *write-behind* (escritura diferida)
  - Nodo cliente vuelca simultáneamente múltiples bloques de datos
- Caché requiere algoritmo de coherencia
- Caché cooperativa:
  - Nodo cliente puede pedir datos a otro cliente en vez de a nodo E/S

Accesos no contiguos

- Op. E/S implica dos zonas de almacenamiento
  - *Buffer* de usuario y zona del fichero afectada
  - Ambas pueden ser no contiguas
- No contigüidad más frecuente en aplicaciones paralelas
  - Ej. Proceso lee filas pares de matriz almacenada en fichero
- Si SF no da soporte a accesos no contiguos:
  - múltiples operaciones de E/S $\rightarrow$ peor rendimiento
- Soporte accesos no contiguos: *list I/O* vs. *datatypes I/O*
- *List I/O*: Op. con lista de *buffers* y zonas del fichero
- *Datatype I/O*: Definición de tipos de datos con posibles huecos
  - Para especificar no contigüidad en fichero y/o en *buffers*
  - Solución usada en MPI-IO

Accesos no contiguos

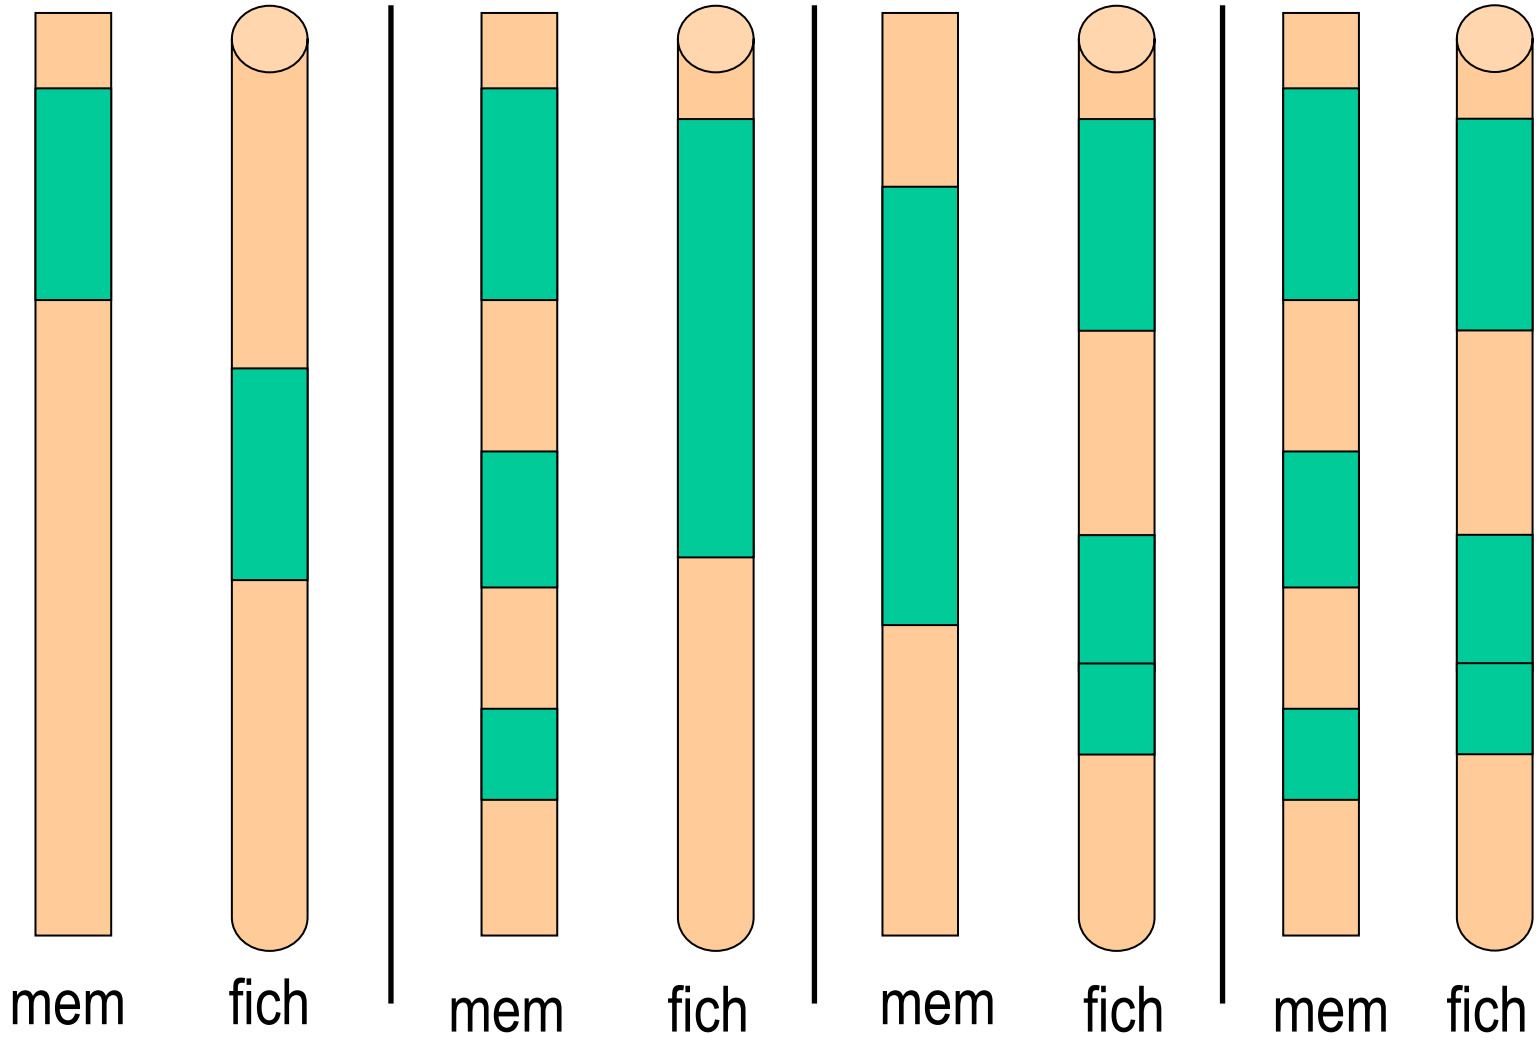

Accesos no contiguos con *List I/O*

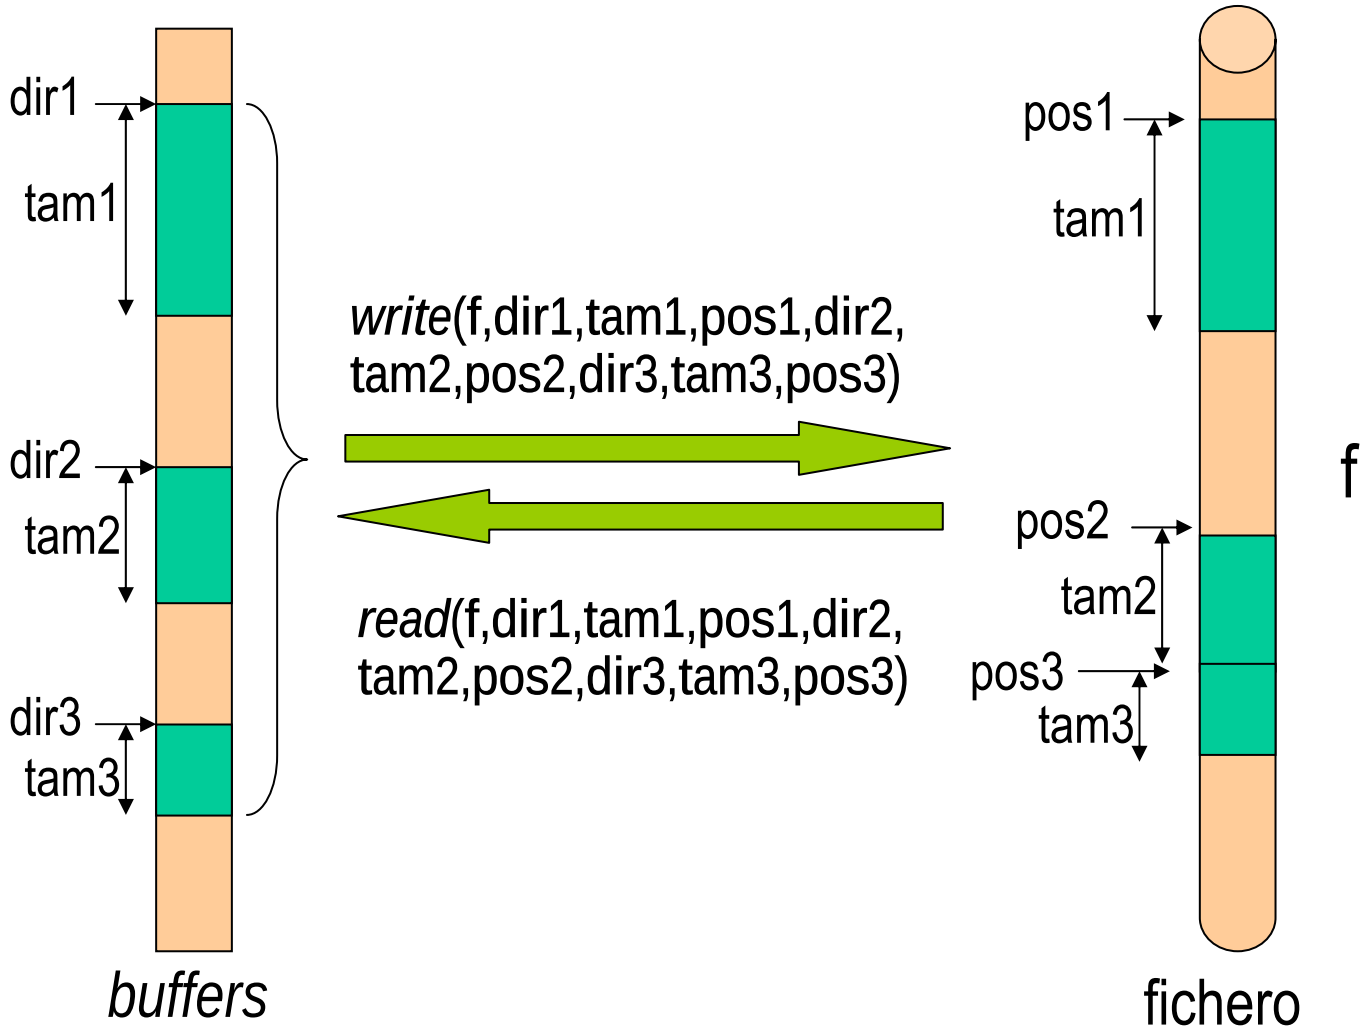

Operaciones de E/S en sistemas UNIX

- Contiguas con posición de acceso implícita o explícita
  - *read/write* y *pread/pwrite*
- No contiguas en memoria (posición implícita o explícita)
  - *readv/writev* y *preadv/pwritev*
- No contiguas en memoria y fichero (posición explícita)
  - *lio_listio*
  - Especificadas en la extensión de tiempo real de POSIX
  - Pueden ser síncronas o asíncronas

Ejemplo de uso de POSIX *List I/O*

```
#include <aio.h>....
    char buf1[3], buf2[9];
    int f = open("/etc/passwd", O_RDONLY);
    struct aiocb * desc[2];
    desc[0] = malloc(sizeof(struct aiocb));
    desc[0]->aio_lio_opcode = LIO_READ;
    desc[0]->aio_fildes = f;
    desc[0]->aio_buf = buf1;
    desc[0]->aio_nbytes = sizeof(buf1);
    desc[0]->aio_offset = 7;
    desc[1] = malloc(sizeof(struct aiocb));
    desc[1]->aio_lio_opcode = LIO_READ;
    desc[1]->aio_fildes = f;
    desc[1]->aio_buf = buf2;
    desc[1]->aio_nbytes = sizeof(buf2);
    desc[1]->aio_offset = 22;
    lio_listio(LIO_WAIT, desc, 2, NULL); ...
```

MPI-IO

- Desarrollado 1994 en laboratorio Watson de IBM
- Objetivo: dar soporte para E/S paralela en MPI
- Incorporado en MPI-2
- Integración uniforme en modelo de paso de mensajes de MPI
  - Escribir/leer en un fichero: enviar/recibir un mensaje
  - Operaciones con posición de acceso implícita o explícita
  - Soporte de varios procesos compartiendo puntero de posición
  - Soporte de operaciones asíncronas
  - Operaciones de E/S independientes y colectivas
  - Uso de tipos de datos de MPI, con posibles huecos, para
    - definir vistas (contiguas o no) sobre un fichero
    - definir *buffers* (contiguos o no) de una lectura/escritura

---

int MPI_Send(void *buf, int count, MPI_Datatype datatype, int dest, int tag, MPI_Comm comm)

int MPI_File_write(MPI_File fh, void *buf, int count, MPI_Datatype datatype, MPI_Status *status)

Operaciones de E/S en MPI-IO

- Lectura/escritura con posición de acceso implícita
  - Síncronas: *MPI_File_read, MPI_File_write*
  - Asíncronas: *MPI_File_iread, MPI_File_iwrite*
  - Cambio de puntero de posición de acceso: *MPI_File_seek*
- Lectura/escritura con posición de acceso explícita
  - Síncronas: *MPI_File_read_at, MPI_File_write_at*
  - Asíncronas: *MPI_File_iread_at, MPI_File_iwrite_at*
- Lectura/escritura con posición de acceso compartida
  - Síncronas: *MPI_File_read_shared, MPI_File_write_shared*
  - Asíncronas: *MPI_File_iread_shared, MPI_File_iwrite_shared*
- Operaciones colectivas
  - Posición implícita: *MPI_File_read_all, MPI_File_write_all*
  - Posición explícita: *MPI_File_read_at_all, MPI_File_write_at_all*

Ejemplo tipo no contiguo en MPI

```
MPI_Aint base, extension;
MPI_Datatype tipo_cont, tipo_nocont;
MPI_Type_contiguous(2, MPI_INT, &tipo_cont);
base = 0; extension = 6 * sizeof(int);
MPI_Type_create_resized(tipo_cont, base, extension, &tipo_nocont);
MPI_Type_commit(&tipo_nocont);
```

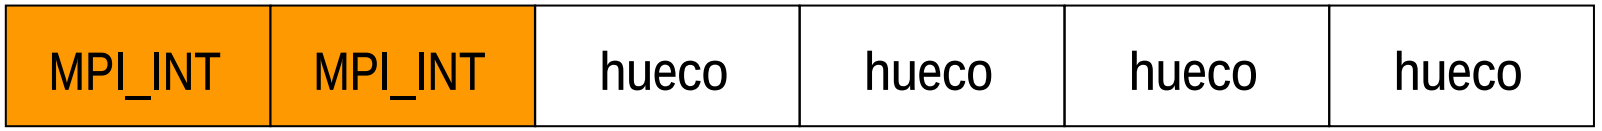

Operaciones no contiguas en MPI-IO

- No contigüidad en *buffer*:
  - En op. lectura/escritura uso de un tipo de datos MPI que la refleje
    - Igual que con envío y recepción
- No contigüidad en fichero:
  - Proceso especifica vista del fichero que refleja su patrón de acceso
  - Para ello usa un tipo de datos MPI que defina patrón
  - Proceso sólo ve la parte del fichero que permite el patrón
  - *MPI_File_set_view (fh, disp, etype, filetype, datarep, info)*
    - Desplazamiento (*disp*)
    - Tipo de dato leído (*etype*)
    - Patrón de acceso (*filetype*)

Ejemplo de vista

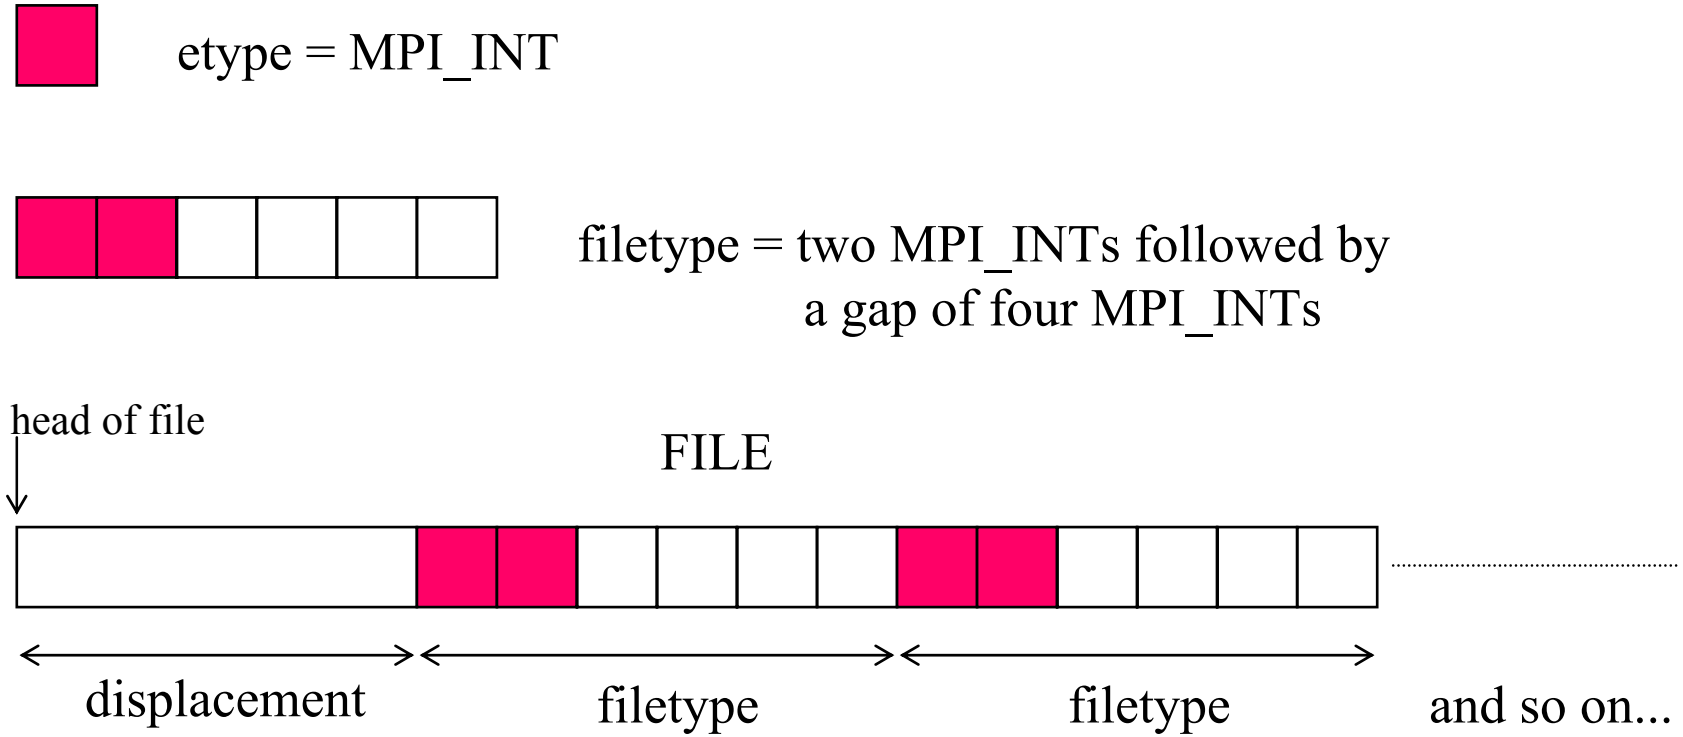

Introduction to Parallel I/O and MPI-IO. Rajeev Thakur

Ejemplo de vista (código)

```
MPI_Aint lb, extent;
MPI_Datatype etype, filetype, contig;
MPI_Offset disp;
MPI_Type_contiguous(2, MPI_INT, &contig);
lb = 0; extent = 6 * sizeof(int);
MPI_Type_create_resized(contig, lb, extent, &filetype);
MPI_Type_commit(&filetype);
```

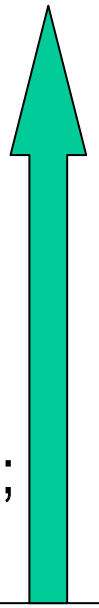

Como en ejemplo previo

```
disp = 5 * sizeof(int); etype = MPI_INT;
MPI_File_open(MPI_COMM_WORLD, "/pfs/datafile",
    MPI_MODE_CREATE | MPI_MODE_RDWR, MPI_INFO_NULL, &fh);
MPI_File_set_view(fh, disp, etype, filetype, "native",  MPI_INFO_NULL);
MPI_File_write(fh, buf, 1000, MPI_INT, MPI_STATUS_IGNORE);
```

Vistas no solapadas para varios procesos

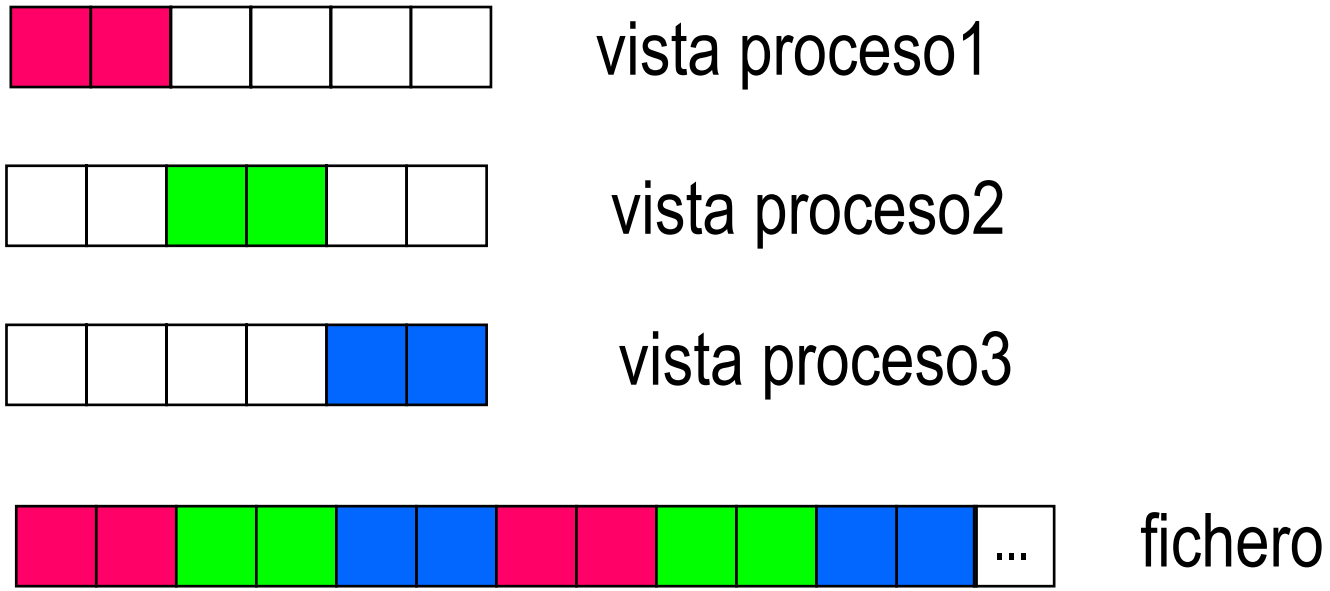

Data Sieving

- Algunos SFP: todos los datos → *buffer* y de ahí se copian los pedidos
  - Acceso contiguo al fichero pero inútil si datos superfluos no se usan

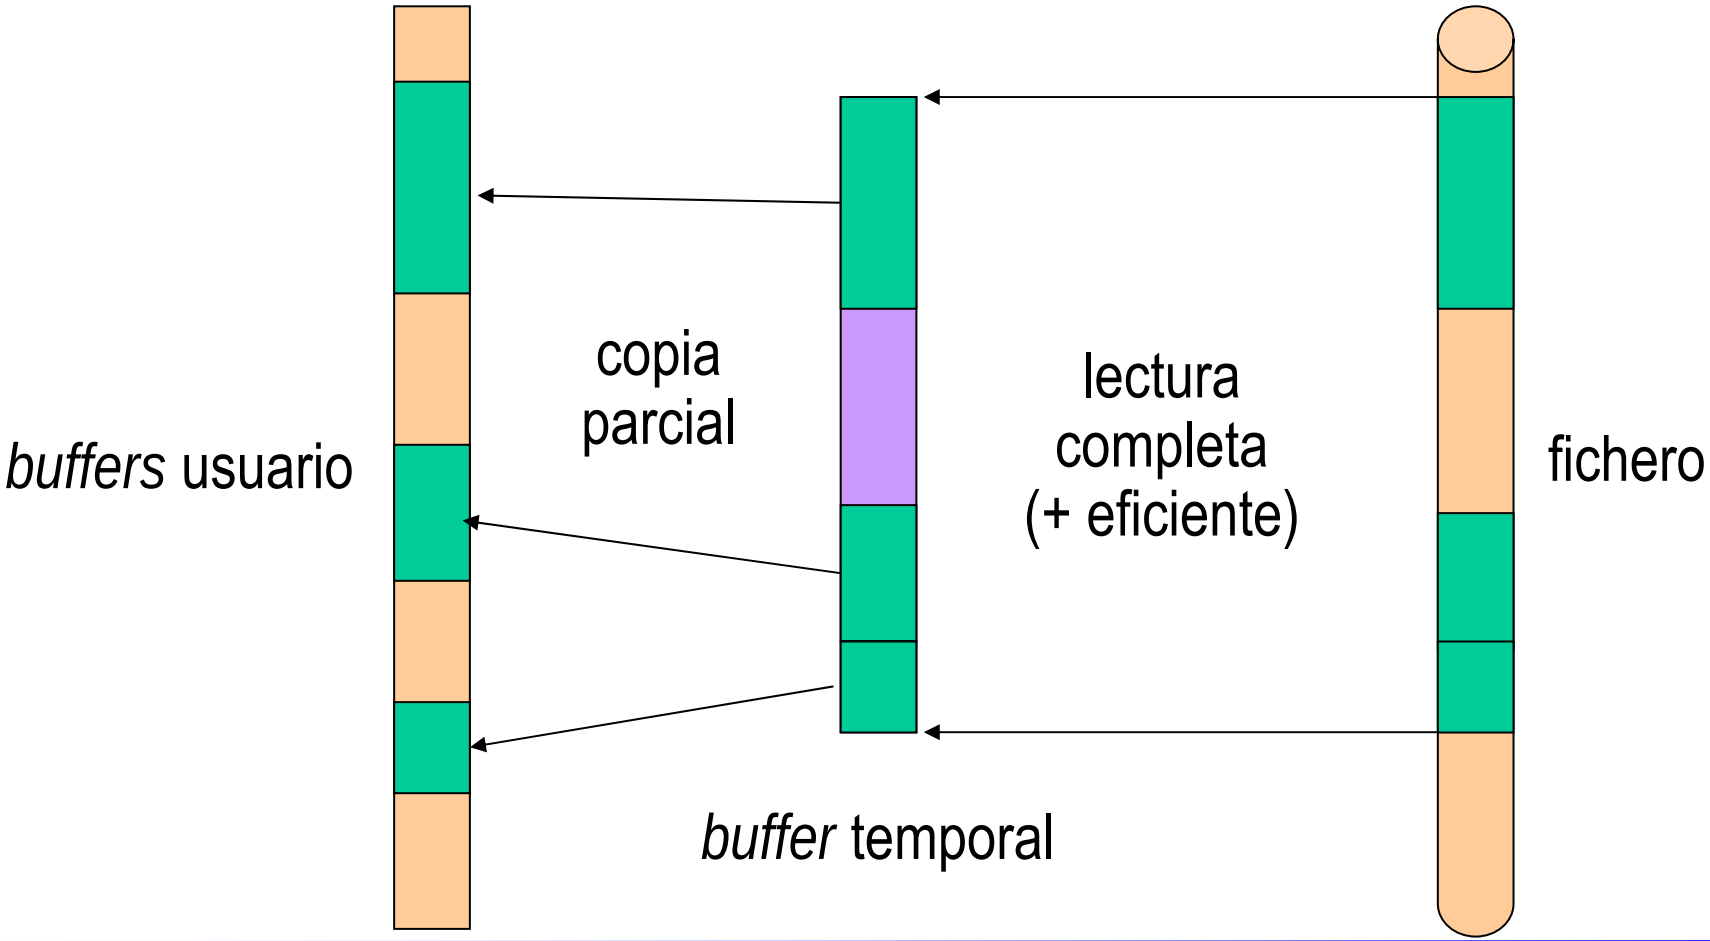

Operaciones colectivas de E/S

- Invocadas simultáneamente por todos los procesos
  - Similar a operaciones colectivas de paso de mensajes (MPI)
  - Todos los procesos especifican misma op. lectura/escritura colectiva
- SF conoce zonas de fichero y *buffers* de procesos afectados
  - Permite optimización y agrupamiento de accesos
  - Implementación con > rendimiento que usando ops. independientes
- 2 estrategias típicas: *server-directed I/O* vs. *two-phase I/O*
- *Server-directed I/O (SDIO) [Disk-directed I/O]*
  - Cada NES recibe petición colectiva y realiza la parte que le afecta
  - Datos a *buffer* temporal y de ahí se distribuyen a nodos de cómputo
- *Two-phase I/O (TPIO)*
  - 1ª fase: Cada NC se ocupa de una parte contigua (*data sieving*)
  - 2ª fase: NCs se redistribuyen los datos
- SDIO más eficiente pero requiere NES más inteligentes

SDIO (lectura)

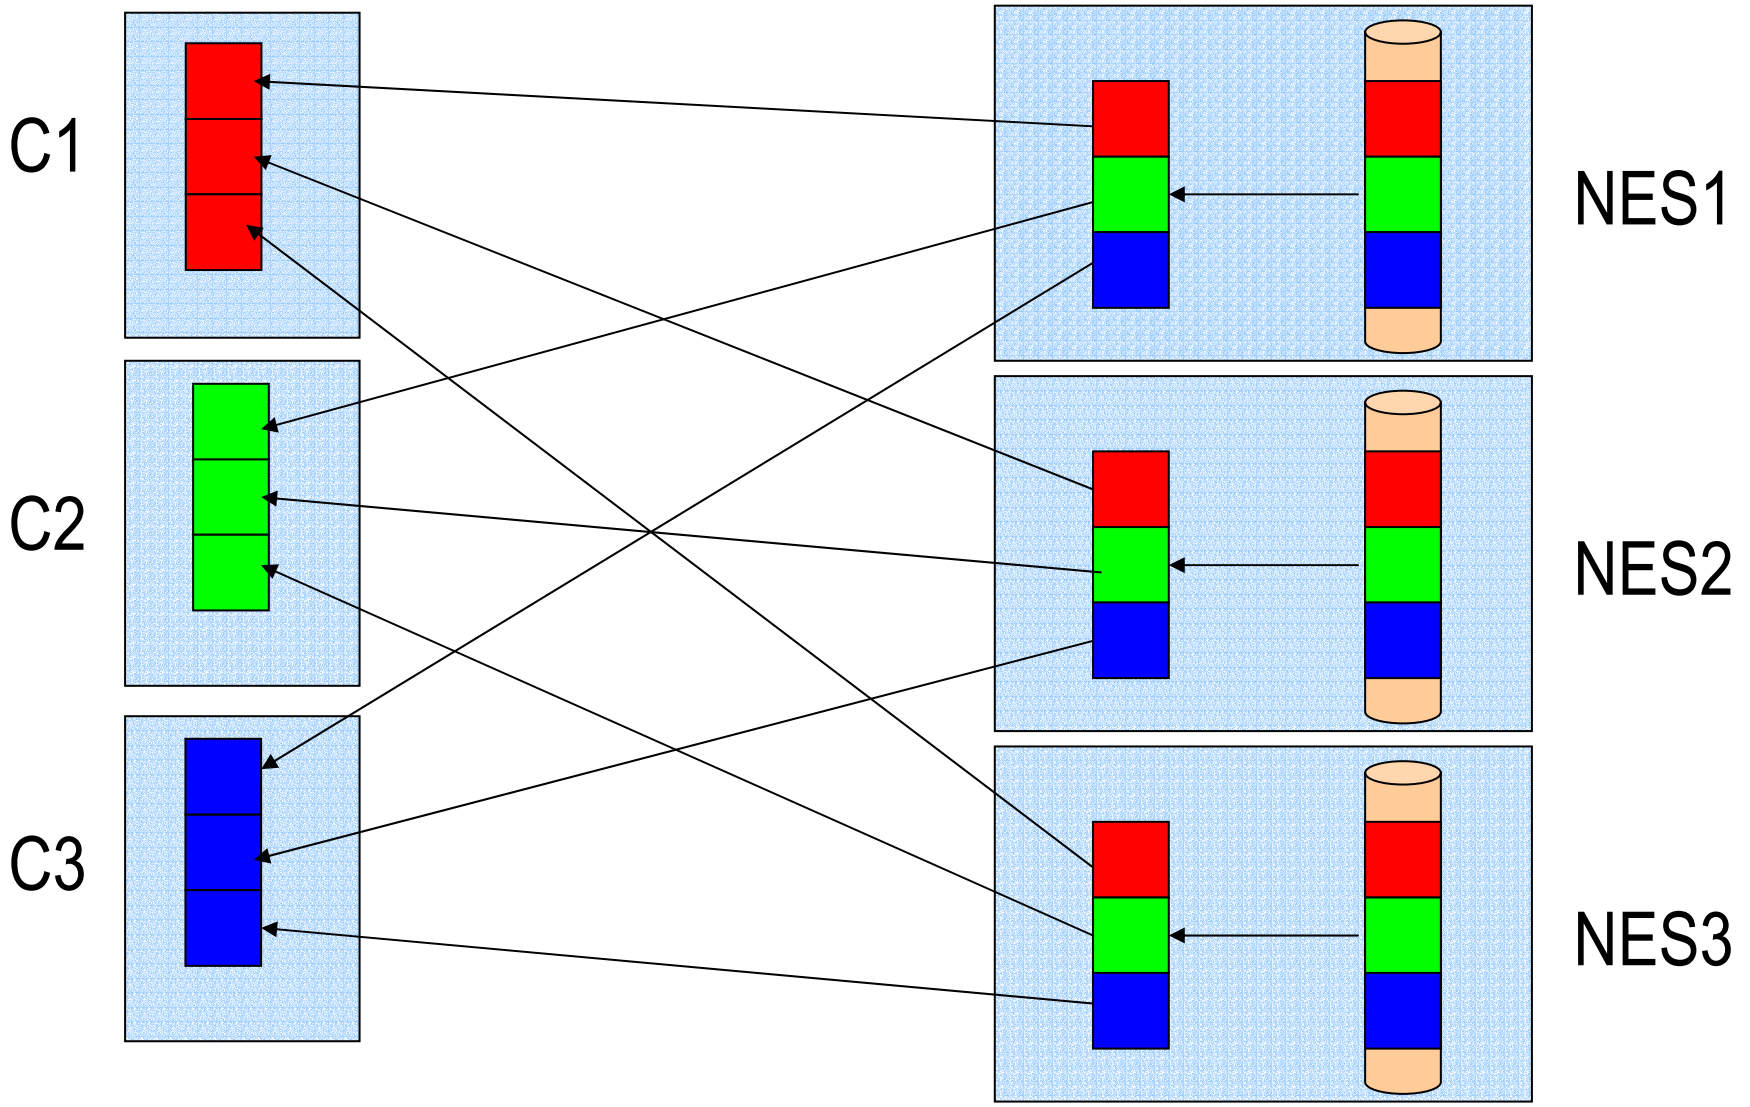

TPIO (lectura)

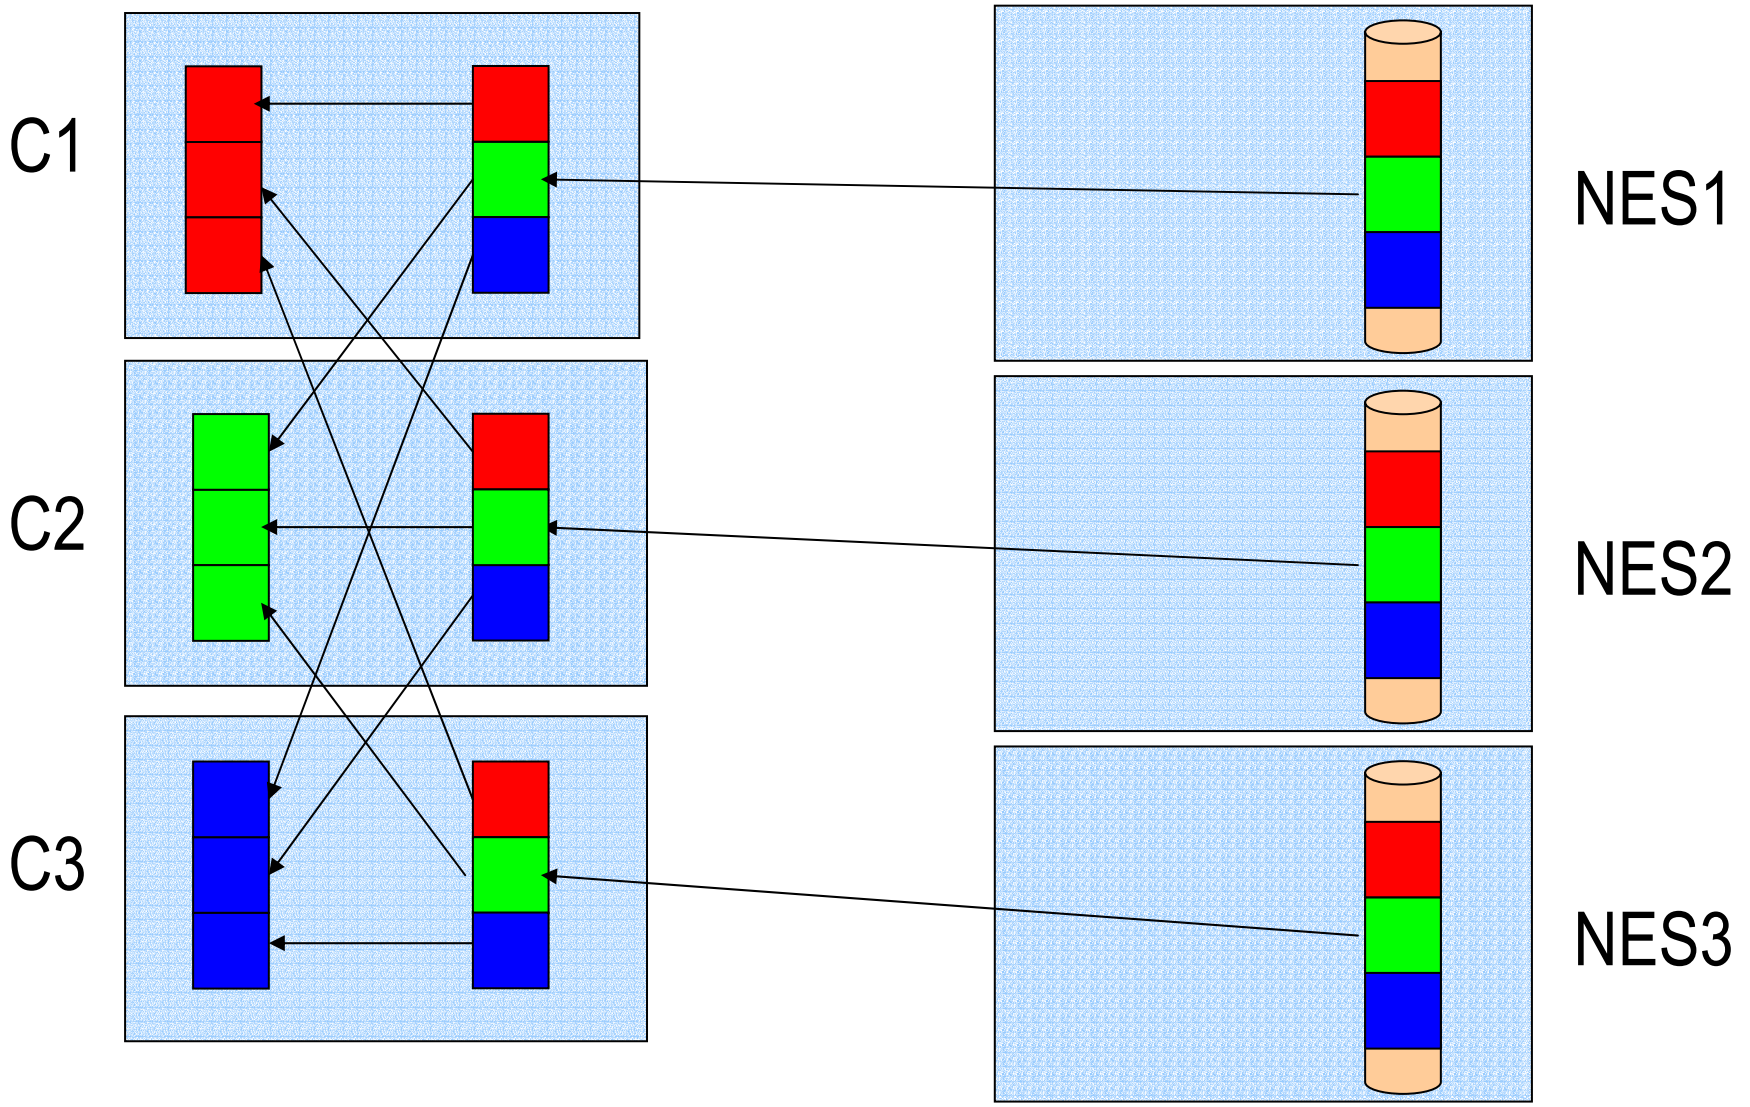

General Parallel File System de IBM

- 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*

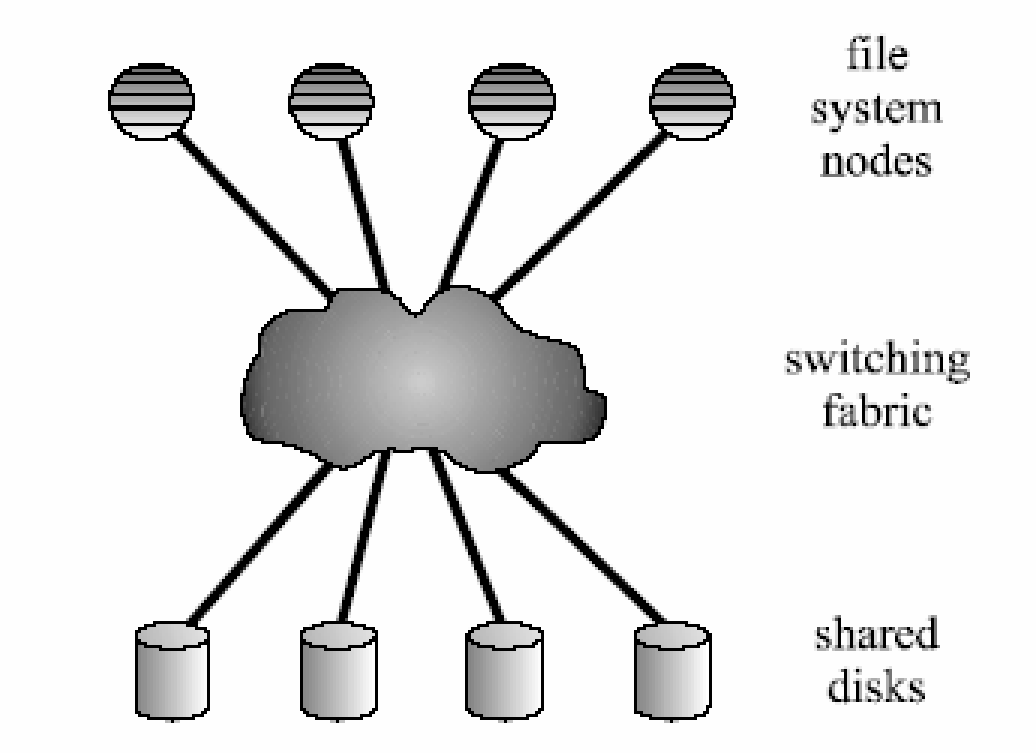

GPFS: A Shared-Disk File System for Large Computing Clusters

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

Configuración basada en SAN

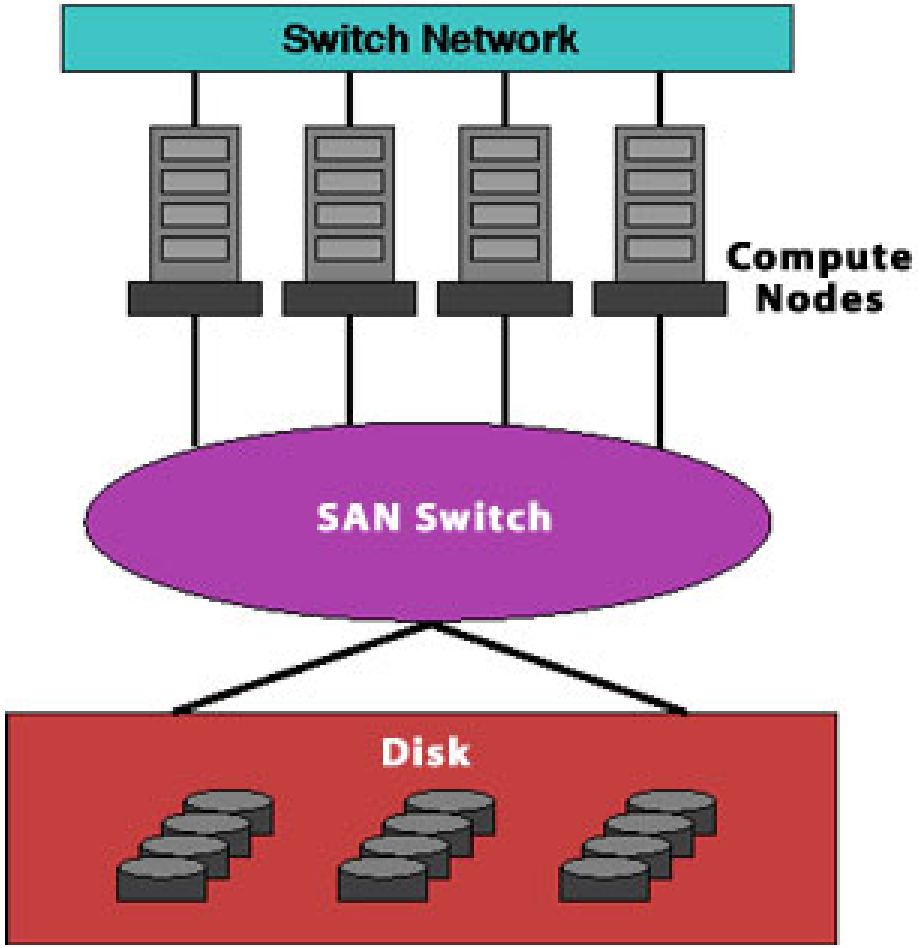

http://www.ncsa.illinois.edu/UserInfo/Data/filesystems/

Configuración basada en nodos de E/S

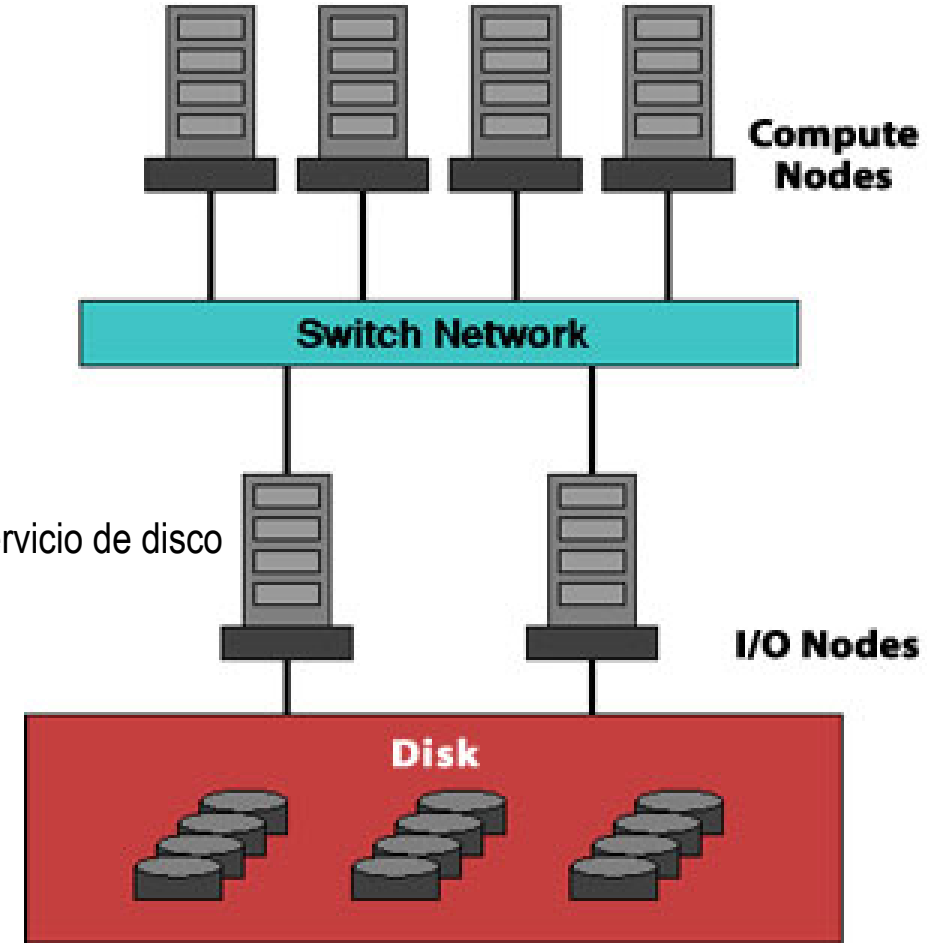

Nodos E/S: sólo servicio de disco

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

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*

Data shipping

- *Tokens* rangos de bytes: OK si accesos alineados a bloques
- Si accesos de grano fino (sub-bloque):
  - Tráfico elevado por coherencia de caché
    - Sobrecarga de gestión de *tokens*
    - Volcados a disco frecuentes y de poco volumen al perder el *token*
  - Conflictos incluso aunque operaciones no solapadas (*False sharing*)
- Alternativa: *data shipping* (DS)
  - Activación DS sobre fichero F: especifica conjunto de NC
  - Bloques de F asignados *round-robin* a NC del conjunto
  - Lectura/escritura de bloque se redirige a NC asociado a ese bloque
    - Sólo ese NC lee y escribe ese bloque del disco
  - Cada NC encargado de DS vuelca periódicamente datos a discos
  - Desventajas: No uso de caché y no atomicidad en escrituras
  - Biblioteca MPI-IO usa DS (disponible para cualquier aplicación)

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 $\rightarrow$ elección de nuevo MN para F

Coherencia acceso metadatos sistema

- Modificación concurrentes de información de espacio libre
  - Uso de cerrojo sobre metadatos de sistema no es eficiente
  - Cada *write* sobre fichero nuevo consulta y modifica esa información
- Solución: se divide espacio libre de un SF en R regiones
  - Cada región controlada por un cerrojo
  - Región guarda información de 1/R estado de cada disco
- Cada SF tiene un gestor de asignación (GA)
  - Mantiene estadísticas aproximadas de uso de cada región
  - NC pide región a GA y la usa para asignar espacio
  - Cuando se agota espacio, pide otra
  - GA asigna regiones intentando evitar conflictos
- Operaciones intentan evitar conflictos en uso de regiones
  - Borrado de fichero en NC: no hace directamente liberación espacio
  - La retransmite a NC que tienen asignadas las regiones afectadas

Administración escalable y en línea

- Algunas operaciones de administración son “pesadas”
  - Redistribución de datos al incluir nuevos dispositivos
    - GPFS permite añadir y eliminar discos “en caliente”
  - Desfragmentación de discos
  - Comprobación/reparación del SF
- Deberían aprovechar el paralelismo del sistema
  - Y hacerse en línea (si procede: no para una reparación de SF)
- Solución: Gestor del sistema de ficheros (GSF)
  - Cada SF tiene un GSF
  - Actúa de iniciador y coordinador de ops. de administración
    - Modelo maestro-trabajador
  - Va asignando a cada NC un rango de inodos que debe procesar
    - Cuando ese NC termina trabajo, le envía un nuevo rango

Tolerancia a fallos en nodos

- Monitorización de estado de los nodos
- Cada nodo usa un *log* de metadatos por cada SF que usa
- Cuando se detecta caída de un nodo *N*
  - Otro NC procesa el *log*
    - No posible conflicto pues *N* tenía *tokens* requeridos
  - Fin de procesado de log, GT libera *tokens* que *tenía* N
- Si cae GT, se asigna función a otro nodo
  - Recupera estado preguntando a otros nodos qué *tokens* poseen
- Tratamiento similar para caída de otros gestores (p.e. GA)

Tolerancia a fallos en comunicación

- Infraestructura gestiona protocolo de pertenencia a grupo
- Partición de la red:
  - Sólo grupo mayoritario puede seguir accediendo al SF
    - En caso contrario, se puede corromper SF
  - Para evitar NC fuera de grupo mayoritario tengan acceso a SF
    - Se notifica a SF que les impida acceso (se “vallan” esos nodos)

Tolerancia a fallos en almacenamiento

- Distribución de datos/metadatos entre varios dispositivos
  - Fallo de un disco puede afectar gravemente a un SF
    - Especialmente si hay pérdida de metadatos
- Configuración de GPFS típica:
  - Uso de múltiples RAID con conexión dual
- Además (o en su lugar) se puede activar replicación
  - SF se encarga de gestionar dos copias
  - Tanto de datos como de metadatos
    - Mayor sobrecarga pero mejor tolerancia a fallos
  - O sólo de metadatos
    - Pérdida de algunos datos de ficheros pero no ficheros inaccesibles

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

El nodo maestro

- Gestiona el SF: todo excepto accesos a trozos en NA
  - Además de información habitual de SF almacena:
    - *ChunkID* de cada trozo de un fichero
    - Datos asociados a *ChunkID*: localización actual de réplicas y nº versión
  - Por escalabilidad, SF "peculiar": en memoria y basado en prefijos
- SF en memoria
  - Escalabilidad: bueno por rendimiento; malo por gasto de memoria
    - Minimiza metainformación por fichero y por trozo (64 bits/trozo)
  - Persistencia: *log* de ops. replicado con *checkpoints* periódicos
    - *checkpoints* diseñados para poca sobrecarga y re-arranques rápidos
- SF basado en prefijos (similar a SO Sprite)
  - No inodos, ni ficheros directorio, ni enlaces, ...
  - Tabla *hash*: ruta $\rightarrow$ metadatos del fichero (usa compresión)
- *Shadow master* (maestro replicado): acceso sólo lectura a SF

Lectura

1. C: fichero+nºtrozo→ M: *ChunkID*+versión+ubicación réplicas
   - C: guarda esa información hasta expiración o reapertura
   - M: puede enviar información de trozos siguientes
2. C: Pide directamente trozo a réplica más cercana

- Minimiza intervención de maestro en operación de lectura

Arquitectura + operación de lectura

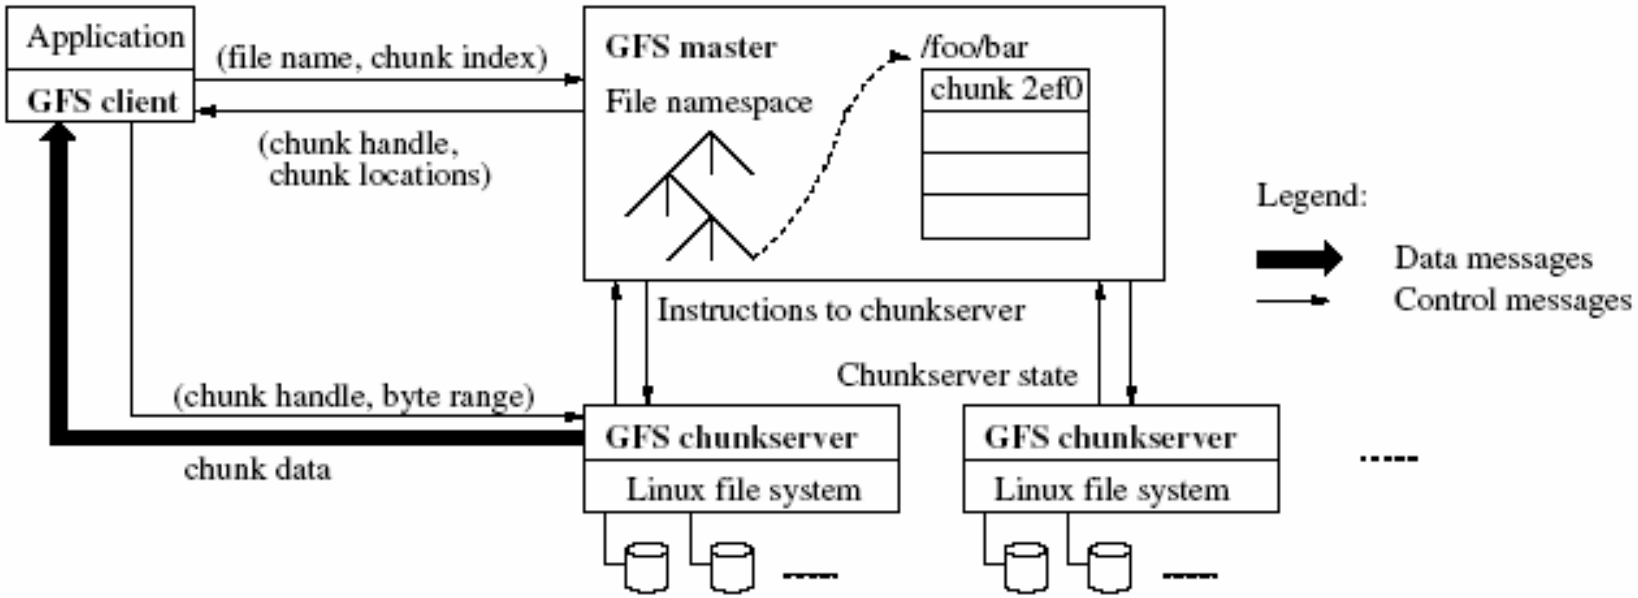

The Google File System

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

Escritura

- Debe mantener coherencia de réplicas (3 por defecto)
  - Clientes deben leer misma información de réplicas
  - Pero pueden estar mezclados datos de escrituras (no atómicas)
- Uso de *leases* para controlar qué réplica actúa como primaria

1. (2) Igual que en lectura pero con info. propietario del *lease*
   - Si no lo hay, maestro lo selecciona en ese instante
3. Propagación de datos a réplicas (*pipeline* de datos)
4. Primaria: asigna orden a escritura, escribe y versión++
5. Secundaria: escribe siguiendo orden asignado por primario
6. Réplicas secundarias confirman escritura a primaria
7. Respuesta a cli.: error si falló alguna escritura $\rightarrow$ reintento

- Escrituras *multi-chunk* no atómicas

Operación de escritura

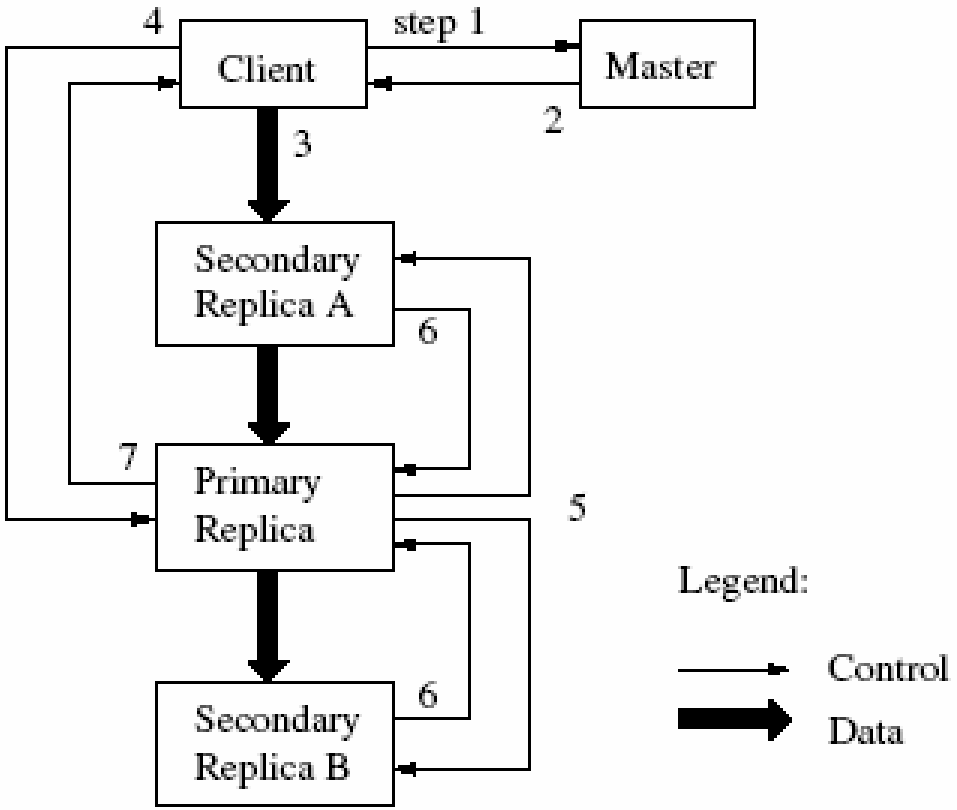

The Google File System

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

Record append

- Agrega datos (registro) sin necesidad de sincronización
- *Offset* lo elige GFS
- Limitado a tamaños ≤ ¼ tamaño trozo
- Operación similar a escritura excepto en:
  - Si registro no cabe en trozo, primaria/secundarias rellenan resto
    - Informan a cliente de que reintente en siguiente trozo
  - Si cabe y no errores de escritura, similar a escritura
    - Pero *offset* lo selecciona el primario
  - Si error escritura en alguna réplica, cliente repite operación hasta OK
    - Pero en cada reintento datos se escriben a continuación
    - Contenido de réplicas distinto (escrituras erróneas, regs. duplicados)
    - Sólo asegura que se ha escrito bien al menos una vez en cada réplica
- ¡Aplicación maneja huecos, registros erróneos y duplicados!

Gestión de réplicas

- Maestro no mantiene info. persistente de ubicación de réplicas
  - En arranque interroga a NA
- Maestro responsable de crear réplicas:
  - Cuando se crea el trozo, política de ubicación guiada por
    - Uso de discos y NA, y aspectos geográficos (rack-aware)
  - Cuando nº réplicas debajo de umbral
    - Por nodos caídos: *Heartbeats* entre maestro y NA con info. de estado
    - Errores de disco: uso de *checksums* en NA
  - Para equilibrar la carga entre NA
- Liberación de réplicas mediante *garbage collection*
  - En *Heartbeats* maestro detecta réplicas huérfanas y obsoletas

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