



Evolución de los sistemas de archivos en Linux

Mario Medina C.

Depto. Ing. Eléctrica, UdeC

mariomedina@udec.cl



Tópicos a tratar




- Sistemas de archivos tradicionales
 - El sistema de archivos Ext2
- Sistemas de archivos basados en bitácoras (journaling)
 - El sistema de archivos Ext3
- Sistema de archivos actuales
 - El sistema de archivos Ext4
 - Otros



Sistemas de archivos



- Sistemas de archivos ven un medio de almacenamiento masivo como un *vector de bloques*
 - Bloques típicamente son de 1, 2 ó 4 KiB
 - Datos se almacenan en sectores de 512 bytes



Vector de bloques





Almacenando un archivo



- Almacenar los datos del archivo y los metadatos
 - Nodo índice contiene índices de los bloques de datos
 - Nombre se almacena en el directorio

Nodo índice (Nodo-i)



Dueño			
Tipo			
Tamaño			
1	11	13	14
17	18	20	5
6	7		

Índice de bloques

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
---	---	---	---	---	---	---	---	---	---	----	----	----	----	----	----	----	----	----	----	----	----

Bloques de disco

- Linus Torvalds
- MINIX
- Andy Tanenbaum





MINIX y Linux




- MINIX
 - Plataforma, guía y fuente de inspiración para desarrollar Linux
- Linux
 - Primera versión del kernel en 1991
 - Inicialmente, utilizaba el sistema de archivos de MINIX
 - ❖ Basado en Berkeley FFS
 - ❖ Simplificado para la enseñanza



MINIX FS



- Sistema de archivos de tamaño máximo 64 MiB
- Archivos de tamaño máximo 64 MiB
- Directorios tienen tamaño fijo
- Nombres de archivos limitados a 14 caracteres
- Bloques de 1 KiB
- Punteros a bloques de 16 bits





Sistema de archivos Ext



- Sistema de archivos extendido (*Extended File System*)
 - Liberado en 1992 para reemplazar MINIX FS
 - Sistema de archivos de tamaño máximo 4 TiB
 - Archivos de tamaño máximo 2 GiB
 - Nombres de archivos de 255 caracteres
 - Ineficiente!
 - ❖ Maneja bloques libres y nodos-I como listas encadenadas



Sistema de archivos Ext2




- Segundo sistema de archivos extendido (*Extended File System 2*)
 - Aparece en 1993
 - Sistema de archivos de tamaño máximo 4 TiB
 - Archivos de tamaño máximo 2 GiB
 - Directorios de tamaño variable
 - Nombres de archivos de 255 caracteres
 - Eficiente y robusto



Sistema de archivos Ext2



- Divide el disco en n grupos de bloques
 - m bloques de datos
 - i nodos- i asociados a los archivos en el grupo





Contenido de un grupo



- m bloques de datos
- i nodos- i
- Bitmap de bloques libres en el grupo
- Bitmap de nodos- i libres en el grupo
- Copia del *superbloque*
- Copia de los descriptores de todos los grupos



Superbloque



- Contiene información de todo el sistema
 - Número total de nodos-i
 - Tamaño total en bloques
 - Tamaño del bloque (1, 2 ó 4 KiB)
 - Tamaño del nodo-i (128 bytes)
 - Número total de bloques libres
 - Número total de nodos-i libres
 - Número de bloques y nodos-i por grupo
 - Contador de operaciones de montaje



Descriptor de grupo



- Cada grupo tiene su propio descriptor
- Replicado en cada grupo (n copias)
 - Número de bloque del bitmap de bloques de datos
 - Número de bloque del bitmap de nodos- i
 - Número de bloque del primer bloque de datos
 - Contador de bloques de datos libres
 - Contador de nodos- i libres
 - Número de directorios en el grupo



Nodo-i



- 128 bytes de longitud
 - Tipo del archivo (archivo, directorio, socket, enlace, etc.)
 - Tamaño del archivo en bytes
 - Tamaño del archivo en bloques
 - Dueño del archivo
 - 3 marcas de tiempo
 - ❖ Fecha y hora de creación
 - ❖ Fecha y hora de última modificación
 - ❖ Fecha y hora de último acceso




Punteros en nodo-i



- 12 punteros directos
 - Contienen número del bloque de datos
- Puntero a tabla de primer nivel
 - Tabla contiene punteros directos
- Puntero a tabla de segundo nivel
 - Tabla de punteros a tablas de primer nivel
- Puntero a tabla de tercer nivel
 - Tabla de punteros a tablas de segundo nivel



Direccionamiento de bloques



I-nodo



Direccionamiento de bloques



- Para bloques de 4 KiB y punteros de 32 bits
 - 12 punteros directos a bloques de datos: 48 KiB
 - Puntero a tabla de primer nivel: 4 MiB
 - ❖ Ocupa un bloque de datos
 - Puntero a tabla de segundo nivel: 4 GiB
 - Puntero a tabla de tercer nivel: 4 TiB
- Máximo tamaño de un archivo
 - 4 TiB + 4 GiB + 4 MiB + 48 KiB



Directorios



- Archivo especial
- Estructura de datos contiene
 - Número del nodo-l
 - Tamaño de esta estructura de datos
 - Longitud del nombre
 - ❖ Máximo 255 caracteres
 - Tipo del archivo
 - Nombre del archivo



Estructura de un directorio



	I-nodo	Largo registro	Largo nombre	Tipo	Nombre del archivo
0		12	1	2	. \0 \0 \0
12	22	12	2	2	. . \0 \0
24	53	16	5	2	h o m e
40	67	28	3	2	u s r \0
52	0	16	7	1	o l d f i l e \0
68	34	12	4	2	s b i n

4 Bytes 2 Bytes 1 1 Largo Variable

- En el ejemplo, archivo `oldfile` está borrado
 - Nodo-i es 0



Límites de Ext2



- Bloques por grupo 32 Ki
 - Bytes por grupo 128 MiB
 - Nodos-i por grupo 32 Ki
 - Número máximo de grupos 128 Ki
 - Tamaño máximo de un disco 16 TiB
 - Bloques por archivo 2 Gi
 - Tamaño máximo de un archivo 4 TiB
-
- Suponiendo bloques de 4 KiB




Problemas de Ext2



- Directorios son listas encadenadas
 - Parche a Ext2 en 2002 implementa directorios como árboles Htree (opción `dir_index`)
 - ❖ Similar a árboles B+
 - Árboles de altura constante (1 ó 2 niveles)
 - Factor de *fanout* alto
 - Función de dispersión (*hash*) aplicada al nombre del archivo
 - Compatible con lista de Ext2 rev. 0



Árboles Htree





Superbloques malos



- Copia del superbloque en todos los grupos
- Modificaciones deben actualizar todas las copias
 - **Ineficiente!**
- Ext2 revisión 1 agrega opción `sparse_super`
 - Copias del superbloque y los descriptores de grupo se almacenan sólo en los grupos 0, 1, y potencias de 3, 5, y 7



Soporte para archivos grandes



- Ext2 rev. 0 limita tamaño máximo de un archivo a 2 GiB
 - Límite fue sobrepasado por evolución de los discos magnéticos
- Ext2 rev.1 agrega opción `large_file`
 - Permite utilizar archivos de tamaño hasta 4 TiB
 - Este límite está siendo sobrepasado hoy en día.



Tamaño máximo de un grupo

- Bitmap de bloques libres debe caber en un bloque
 - Si bloque es 4 KiB, bitmap describe a lo más 32 Ki bloques
 - Cada grupo de bloques puede almacenar a lo más 128 MiB de datos



Número fijo de nodos-i



- Número de nodos-i por grupo se define al momento de crear el sistema de archivos
 - Tamaño de nodo-i: 128 bytes
 - 32 nodos-i en un bloque de 4 KiB
 - Debe haber un nodo-i por cada bloque de datos
 - ❖ 32 Ki bloques → 32 Ki nodos-i
 - Máximo 4 MiB dedicados a almacenar nodos-i



Metadatos en Ext2



- Ext2 mantiene 6 tipos de metadatos
 - Superbloques
 - Descriptores de grupo
 - Nodos-i
 - Tablas de punteros de primer, segundo y tercer nivel
 - Bitmaps de bloques libres
 - Bitmaps de nodos-i libres



Actualizando metadatos



Si un archivo crece de 3 a 5 bloques, actualizar

- Superbloque y todas sus copias
 - Actualizar contador de total de bloques libres
- Descriptor del grupo y todas sus copias
 - Actualizar contador de bloques libres en el grupo
- Grupo
 - Actualizar bitmap de bloques libres
- Nodo-i del archivo
 - Actualizar tamaño, bloques usados, punteros a bloques, tablas de punteros, etc.



Metadatos en memoria



- Información crítica del sistema de archivos se lee a memoria al momento del montaje
- Memoria RAM no puede almacenar todas las estructuras de datos
- Qué hacer?
 - **Guardar datos en cache!**



Metadatos en memoria



- Superbloque y descriptores
 - Siempre en memoria
- Nodos-i
 - En buffer cache
- Bloques de datos
 - En buffer cache
- Bitmaps de bloques y de nodos-i libres
 - En cola FIFO en memoria



Consistencia de metadatos



- Metadatos se almacenan en memoria
 - Mayor desempeño por acceso rápido a metadatos frecuentemente usados
- Copias en disco son actualizadas periódicamente por el proceso `sync`
 - Escribe superbloques, nodos-i, bitmaps modificados desde memoria al disco
- Qué pasa si hay un problema?
 - Inconsistencia en los metadatos!



Reparación usando `fsck`



- `fsck` asegura consistencia del sistema de archivos
 - Corrige errores en metadatos
 - Debe revisar todo el sistema de archivos
- Tiempo de ejecución proporcional al tamaño del disco
 - Puede demorar muchísimo para discos grandes
- Solución: *journaling*



Tercer sistema de archivos extendido (Ext3)



- Compatible con Ext2
 - Partición Ext3 puede ser montada como partición Ext2
 - Conversión in situ entre Ext2 y Ext3 posible
 - Bitácora almacenada como archivo `/.journal`
 - Bitácora se escribe al disco con mayor frecuencia que sync de Ext2
 - Volumen de datos a escribir es menor



La bitácora o *journal*



- Estructura de datos almacenada en disco
 - Bitácora registra cambios a realizar a los metadatos
 - Después se realizan los cambios a los datos
 - Luego, se marcan los cambios como realizados en la bitácora (*commit*)
- Restauración de consistencia
 - Revisar últimas modificaciones a la bitácora
 - Tiempo de ejecución proporcional al tamaño de la bitácora



Modos de operación de Ext3



Journal

- Bitácora guarda cambios a los datos y a los metadatos
- Luego, los datos modificados son escritos a disco y se hace el *commit*
 - Minimiza chances de pérdidas de datos
 - Modo más lento y seguro
 - Alto número de accesos a disco



Modos de operación de Ext3



Ordered

- Bitácora sólo almacena cambios a los metadatos
 - Asegura que los datos son escritos antes que el *commit* en la bitácora
 - Opción por omisión en Ext3
 - Minimiza chances de corrupción



Modos de operación de Ext3



Writeback

- Bitácora sólo almacena cambios a los metadatos
 - No hay reordenamiento de escrituras a disco
 - Es posible que ocurra un *commit* antes que los datos sean escritos al disco
 - Modo más rápido, pero que ofrece menos robustez




Limitaciones de Ext2/Ext3



- Desempeño es muy bueno
 - Ext3 acelera recuperación ante fallas
 - Ext3 aumenta confiabilidad del sistema
- Diseñados para
 - Discos “pequeños”
 - “Bajo” número de archivos
 - Archivos “pequeños”
 - Directorios con “bajo” número de archivos




Tamaños de archivos





Tamaños de archivos






Evolución de los discos duros



IBM RAMAC 305

- Primer disco magnético
- Salió en 1956
- 50 discos en una torre
- Cada disco de 100 KiB
- Costo del arriendo mensual: US\$160000





Evolución de los discos duros



Seagate Barracuda XT modelo ST32000641AS

- SATA 6 Gb/s
- 7200 RPM
- 64 MB cache
- Sólo US\$300





El cuarto sistema de archivos extendido (Ext4)

- Anunciado en 2006
- Soporte para sistemas de archivos de gran tamaño usando secuencias de bloques (*extents*)
- Número de bloque se aumenta a 48 bits
- Permite sistemas de archivos de 1 EiB
- Permite archivos de hasta 16 TiB
- Aumenta número máximo de subdirectorios de 32000 en Ext3 a 640000





Secuencias de bloques



Bloque Físico Bloque Lógico
Largo

Bloque Físico	Largo	Bloque Lógico
4	2	4
7	4	0

Secuencias de Bloques






Secuencias de bloques (*extents*)



- *Extent* representa hasta 128 MiB
 - 4 extents en el nodo-i
 - Raíz de árbol de *extents* en nodo-i
- Nodo-i por omisión tiene 256 bytes





Número de bloque de 48 bits



- Ampliar contadores y punteros a 48 bits
- Superbloque
 - Contadores de bloques totales y libres
- Descriptor de grupo
 - Punteros a bitmaps y tablas de nodos-l
- Bitácora
 - Debe almacenar direcciones de bloques como 48 bits



Asignación multibloques



- Ext3 asigna un nuevo bloque de disco a la vez
 - Implica revisar bitmap de bloques libres
 - Operación costosa
- Ext4 permite realizar asignaciones de múltiples bloques en una operación
 - Reduce uso de CPU
 - Uso más eficiente de bloques libres



Asignación diferida



- Posterga la asignación de bloques libres en disco hasta el tiempo de writeback
- Se usa en conjunto con la asignación multibloque
 - Reduce fragmentación del sistema de archivos
 - Reduce el uso de la CPU
 - Reduce actualizaciones para archivos temporales
 - Escritura puede demorarse hasta 60 s.



Preasignación persistente



- Permite preasignar espacio en disco para un archivo que se sabe va a crecer
 - Asegura asignación contigua de bloques de disco
 - Mejora desempeño
 - Reduce fragmentación
 - Útil para aplicaciones como p2p
 - Importante para operaciones de tiempo real



Otras mejoras



- `fsck` no revisa grupos o nodos-i vacíos
- Marcas de tiempo con granularidad de nanosegundos
- Checksums de la bitácora
- Agranda nodos-i a 256 bytes
- Reserva nodos-l iniciales de un directorio
- Permite deshabilitar bitácoras
- Desfragmentación online



Convirtiendo Ext2/3 a Ext4



- Para convertir Ext3 a Ext4

```
tune2fs -O extents,uninit_bg,dir_index /  
dev/DEV
```

- Ejecutar obligatoriamente `fsck`

```
e2fsck -pDf /dev/DEV
```

- Para convertir Ext2 a Ext4, además es necesario crear una bitácora

```
tune2fs -j /dev/DEV
```



Sistema de archivos XFS



- Desarrollado por SGI para IRIX
- Uso extensivo de árboles B+ y *extents*
 - Bloques libres y ocupados, directorios, etc.
- Sistema de archivos de 64 bits
 - Tamaño máximo teórico: 16 EiB
 - Tamaño máximo de un archivo: 8 EiB
 - Bloques de datos de 512 B a 64 KiB
 - Limitaciones en Linux: 16 TiB



Sistema de archivos XFS



- Disco dividido en grupos de asignación
 - Cada grupo maneja sus bloques libres y nodos-i
 - Punteros internos de 32 bits
- Bitácora de metadatos almacena operaciones lógicas
- Soporte para archivos raros
- Asignación diferida y dinámica de nodos-i



Bitácora física vs lógica



- Bitácora física
 - Bitácora almacena bloques de datos que contienen metadatos modificados
 - Facilita la recuperación de información
 - Desperdicia espacio en la bitácora
- Bitácora lógica
 - Almacena sólo cambios a los metadatos
 - Tamaño de bitácora mucho menor
 - Código más complejo



Ext4 vs XFS



- XFS es full 64-bit
- Código fuente es 100K líneas
- XFS hereda código y compatibilidad con IRIX
- Máximo 16 EiB
- Bitácora lógica
- Ext4 aún no los es
- Código fuente es 25K líneas
- Ext4 hereda robustez y estabilidad de Ext3 y Ext2
- Máximo 1 EiB
- Bitácora física



ReiserFS/Reiser4




- Sistema de archivos con bitácoras
- Árboles almacenan todos los objetos del sistema
- Excelente desempeño para archivos pequeños
- Soporte para archivos ralos
- Desarrollo detenido por arresto de Hans Reiser por asesinar a su mujer



Desempeño



- lozone v.3.322, Disco Seagate 80GiB, 7200RPM





Desempeño en la vida real



- Benchmarks de Phoronix, Dic. 2008
- Comparación de
 - Ext3
 - Ext4
 - XFS
 - ReiserFS
- Resultado: no hay diferencias!
- World of Padman
- Unreal Tournament
- 7-Zip Compression
- Parallel BZip2 Compression
- LZMA Compression
- LAME MP3 Encoding
- FFmpeg
- GnuPG
- OpenSSL
- Bork File Encrypter



Futuro de Ext4



- Soporte para archivos malos
- Soporte para archivos pequeños
- Soporte para archivos muy fragmentados
- Archivos mayores a 16 TiB
- Creación y asignación dinámica de nodos-i
- Nodos-i en el directorio



BTRFS



- Sistema de archivos para Linux en desarrollo por Oracle
 - Copy-On-Write
 - Snapshots
 - Manejo dinámico de dispositivos
 - Compresión transparente
 - Balance de carga
 - Manejo dinámico de volúmenes



Conclusiones



- Ext4 es un sistema de archivos
 - Compatible con sistemas Ext2 y Ext3
 - Robusto, eficiente y de buen desempeño
 - Apto para medios de almacenamiento masivos
- Ventajas se notan en sistemas con gran número de archivos y/o directorios, que ejecutan aplicaciones de alto desempeño