

LECCIÓN 17: SUPERBLOQUE DE EXT2

LECCIÓN 17: SUPERBLOQUE DE EXT2	1
17.1 Introducción	2
17.2 Segundo sistema de ficheros extendido (Ext2)	7
17.3 Estructura Física de un SF EXT2	12
17.4 Estructuras de datos	14
El superbloque	14
Estructura ext2_sb_info	21
Descriptores de grupo de bloques	25
17.5 Operaciones vinculadas al superbloque	27
ext2_error	29
ext2_warning	30
ext2_put_super	30
ext2_parse_options	32
ext2_setup_super	35
ext2_check_descriptors	36
ext2_fill_super	38
ext2_commit_super	45
ext2_sync_super	46
ext2_write_super	46
ext2_remount	48
ext2_statfs	50
ext2_init_ext2_fs	51
17.6 Journaling	52
17.7 Tercer sistema de ficheros extendido (Ext3)	54
17.8 Sistema de ficheros ReiserFS	56

17.1 Introducción

En los primeros tiempos de Linux, allá por 1991, éste se desarrolló bajo el sistema operativo Minix. Era más sencillo compartir disquetes entre ambos sistemas que desarrollar un nuevo sistema de ficheros, por ello Linus Torvalds decidió implementar soporte para el Minix FS en Linux. El Minix FS era un software eficiente y relativamente libre de errores. El sistema de ficheros Minix presentaba dos limitaciones importantes:

- Las direcciones de los bloques se guardan en enteros de 16 bits, de modo que el tamaño máximo de todo el sistema de ficheros está restringido a 64 Mb.
- Los directorios contienen entradas de tamaño fijo, siendo la longitud máxima de un nombre de archivo 14 caracteres.

Las restricciones en el diseño del Minix FS eran tan incomodas que la comunidad empezó a pensar y trabajar en la implementación de nuevos FS en Linux.

Para facilitar la incorporación de nuevos FS en el núcleo de Linux se desarrolló la capa VFS (Virtual File System). Ésta fué inicialmente escrita por Cris Provenzano, y posteriormente reescrita por el propio Linus Torvalds antes de integrarla en el núcleo.

Tras la integración del VFS en el núcleo, un nuevo FS denominado Extended File System se introdujo en Abril de 1992, en el núcleo 0.96c. Se eliminaban así dos grandes limitaciones del Minix FS: su tamaño máximo era ahora 2 Gb y la longitud máxima del nombre de un fichero se extendía a 255 caracteres. Era una mejora, pero aún había problemas:

- Ext no soportaba registro separado (timestamps) de acceso, modificación de inodo y modificación de datos.
- Se empleaban listas enlazadas para mantener información de los bloques libres y de los inodos y todo esto provocaba un mal comportamiento: a lo largo del tiempo las listas se iban desordenando y el FS terminaba fragmentado.

Es por esto que surgió el segundo sistema de ficheros extendido (Ext2fs) Remy Card en 1994. Además de incluir varias características nuevas, cabe resaltar la alta eficiencia y robustez.

Durante los últimos años, el Ext2 o Ext2fs (Second EXTended FileSystem, segundo sistema de ficheros extendido) ha sido de hecho el sistema de ficheros más utilizado entre los sistemas Linux. Sin embargo, a medida que Linux ha ido desplazando a Unix y otros sistemas operativos en más servidores y ambientes computacionales, al Ext2 se le ha llevado a su límite. De hecho, muchos de los requisitos más comunes de hoy en día como grandes particiones de discos duros, recuperación rápida de caídas del sistema, rendimiento alto en operaciones de

Entrada / Salida (I/O) y la necesidad de almacenar miles y miles de ficheros representando Terabytes de información, ha superado las posibilidades del Ext2.

En la siguiente tabla se resumen las características fundamentales de varios FS:

	Minix FS	Ext FS	Ext2 FS
Max FS size	64 MB	2 GB	4 TB
Max file size	64 MB	2 GB	2 GB
Max file name	16/30 c	255 c	255 c
3 times support	No	No	Si
Extensible	No	No	Si
Var. block size	No	No	Si
Maintained	Si	No	Si

Afortunadamente, un número variado de otros sistemas de fichero alternativos de Linux han aparecido en escena para intentar solventar las limitaciones del Ext2. Estos son; el Ext3, Ext4 el ReiserFS, el XFS y el JFS. Además de los requisitos especificados más arriba, todos estos sistemas de ficheros soportan también el Journaling (o diario en español), una característica ciertamente demandada por las empresas pero que beneficia a cualquiera que trabaje con Linux. Un sistema de ficheros Journaling puede simplificar los reinicios, reducir los problemas derivados de la fragmentación y acelerar las operaciones I/O. Un sistema con journaling es un sistema de ficheros tolerante a fallos en el cual la integridad de los datos está asegurada porque las modificaciones de la meta-information de los ficheros son primero grabadas en un registro cronológico (log o journal, que simplemente es una lista de transacciones) antes de que los bloques originales sean modificados. En el caso de un fallo del sistema, un sistema con journaling asegura que la consistencia del sistema de ficheros es recuperada.

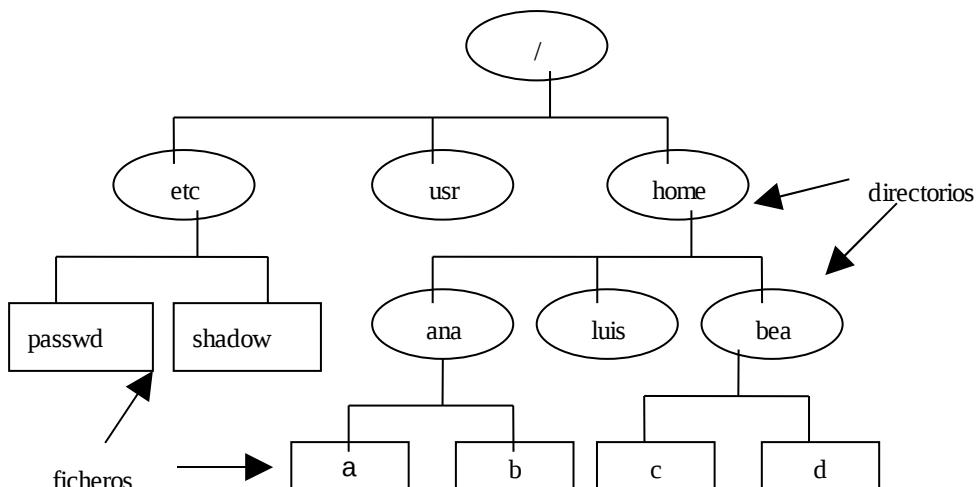
Podemos clasificar los sistemas de ficheros soportados por Linux en 3 categorías: Basados en disco: Estos sistemas son, ext2, ext3, ReiserFX, XFS, JFS, ISO9660, etc. Sistemas remotos (de red): NFS, Coda, Samba, etc. Sistemas especiales: procfs, ramfs y devfs.

Sistema de Ficheros

El sistema de ficheros es una de las partes más importantes de un sistema operativo. El sistema de ficheros almacena y gestiona los datos que los usuarios tienen almacenados en los discos duros, y asegura que los datos que se obtienen son idénticos a los que se almacenaron originalmente. Además de almacenar los datos de usuarios en ficheros (elemento lógico del sistema de ficheros), el sistema de ficheros también crea y gestiona información sobre los ficheros y sobre sí mismo. Por otro lado, además de garantizar la integridad de los datos, los sistemas de ficheros se esperan que sean extremadamente fiables y que tengan un alto nivel de rendimiento.

Desde el punto de vista del sistemas, toda la información de un ordenador existe como bloques de datos dentro de algún dispositivo de almacenaje, organizados utilizando estructuras especiales dentro de particiones (subconjunto lógico del medio de almacenamiento) las cuales se organizan a su vez en ficheros, directorios y espacio no asignado (libre).

Los sistemas de ficheros se crean en particiones de discos para permitir a las aplicaciones almacenar y organizar la información en forma de ficheros y directorios. Linux, como los sistemas basados en Unix, utilizan un sistema de ficheros jerarquizado compuesto como ya hemos dicho por ficheros y directorios, los cuales pueden contener tanto ficheros como otros directorios.



Para que los usuarios tengan acceso a los ficheros y directorios del sistema de ficheros previamente hay que realizar el comando `mount`, el cual se lleva a cabo como parte del proceso de arranque del sistema. El listado de los sistemas de ficheros montados en el arranque se almacenan en el fichero `/etc/fstab` (`fstab – FileSystem TABLE`), mientras que el listado de los sistemas de fichero montados en el sistema se almacenan en el fichero `/etc/mtab` (`mtab – Mount TABLE`). Durante el arranque se montaran aquellos sistemas de ficheros especificados en el fichero '`fstab`'.

Cuando un sistema de ficheros se monta durante el proceso de arranque, un bit en la cabecera del sistema de ficheros (conocido como “Bit Clean” o Bit limpio) permanece a cero indicando que el sistema de ficheros esta en uso (que las estructuras de datos encargadas de la gestión de asignación de espacios disponibles y de la organización de ficheros y directorios están actualmente en uso).

Se dice que un sistema de ficheros es “Consistente” cuando todos los bloques de datos en el sistema de ficheros están o en uso o libres y que cada bloque de datos corresponde a un fichero o directorio accesibles en cualquier momento y lugar. Cuando un sistema Linux es intencionadamente apagado usando su comando específico, todos los sistemas de ficheros de desmontan automáticamente. El desmontado del sistema de ficheros durante un apagado estándar pone a uno el Bit Limpio en la cabecera indicando que el sistema de ficheros fue correctamente desmontado y que por la tanto se supone Consistente.

Años de depuración y rediseño del sistema de ficheros y el uso de algoritmos extremadamente efectivos en la escritura en disco han logrado eliminar las corrupciones causadas por accesos a disco tanto de aplicaciones como del propio núcleo. Pero la eliminación de corrupción de datos debido a caídas de tensión y otras situaciones indebidas es arena de otro costal. Cuando un sistema Linux cae o es simplemente apagado sin seguir los procedimientos estándar de apagado, el Bit Limpio de la cabecera del sistema de ficheros no se actualiza como es debido (no se pondrá a uno). La siguiente vez que el sistema arranque, el proceso de montaje detectara que sistemas de ficheros no tienen a uno el Bit Limpio, y verificará la consistencia de los datos usando la utilidad ‘fsck’ (FileSystem Check, Chequeo del Sistema).

Ejecutar ‘fsck’ en un número de sistemas de ficheros grandes puede llevar bastante tiempo. La razón por la que pueden existir inconsistencias en un sistema de ficheros que no haya sido desmontado como es debido, puede deberse al hecho de que se estuvieran realizando escrituras en disco en el momento del apagado. Puede que ciertas aplicaciones estuvieran actualizando información contenida en ficheros o el sistema podría haber estado actualizando los metadatos (metadata) del sistema de ficheros, los cuales son “datos sobre los datos del sistema de ficheros”, en otras palabras, información sobre que bloques están asignados a que ficheros, que ficheros se encuentran en que directorios. Las inconsistencias en ficheros de datos son bastante perjudiciales, pero las inconsistencias en los metadatos del sistema de ficheros son las que producen perdidas de ficheros y todo tipo de pesadillas operacionales.

Criterios de Selección

Criterios a la hora de elegir un sistema de ficheros:

ESTABILIDAD Y FIABILIDAD – Con respecto a la pérdida de datos

RENDIMIENTO (“lo capaz que es”) – Requisitos de rendimiento

CAPACIDAD (“la capacidad que tiene”) – Los límites del sistema de ficheros

MANTENIMIENTO – El tipo de mantenimiento que necesita

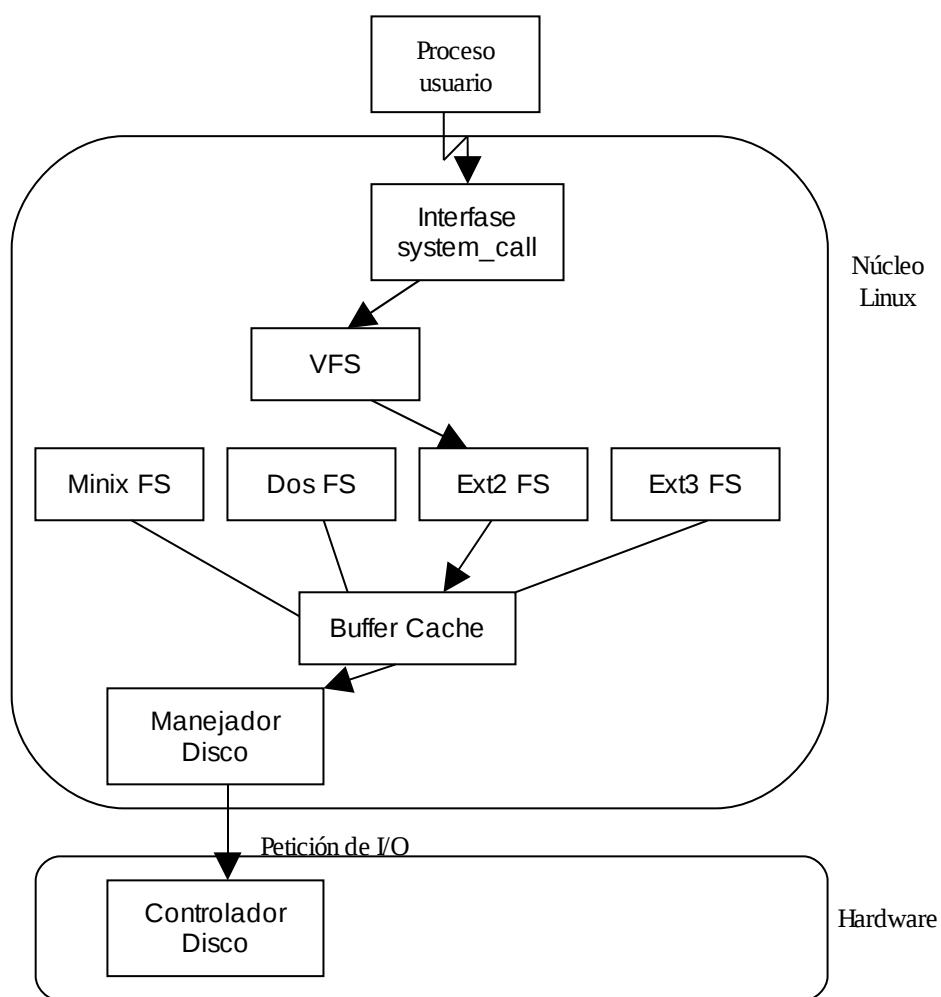
AFINAMIENTO (tuning) – Facilidad de configuración y afinamiento del sistema

SOPORTE – Por parte del grupo de desarrollo

Sistema Virtual de Archivos (VFS)

Los distintos SO suelen usar su propio Sistema de Ficheros, esto complica la compartición de datos en un disco duro entre distintos SO. Linux ofrece soporte para distintos Sistemas de Ficheros como EXT2, Minix, FAT...

Los procesos necesitan de un acceso uniforme a los datos, sin preocuparse de qué Sistema de Ficheros se trata, el VFS es la interfaz entre las llamadas al sistema y la gestión de archivos. Las llamadas se dirigen al VFS, que redirige la petición al módulo que gestiona el archivo.



17.2 Segundo sistema de ficheros extendido (Ext2)

Características de un sistema de ficheros como el Ext2:

Todo sistema de ficheros implementa una serie de conceptos básicos derivados del sistema operativo Unix [Batch 1986]. Los archivos son representados por inodos, los directorios son simplemente archivos que contienen una lista de entradas (que apuntan a otros directorios o a archivos) y los dispositivos de entrada salida pueden ser accedidos mediante ficheros especiales. Veamos algunos de estos conceptos básicos.

BLOQUE lógico es la unidad más pequeña de almacenamiento que puede ser asignado por el sistema de ficheros. Un bloque lógico se mide en bytes, un fichero se almacenara en uno o varios bloques.

VOLUMEN lógico puede ser un disco físico o un subconjunto del espacio de un disco físico. Un volumen lógico se conoce como un **PARTICIÓN** de disco.

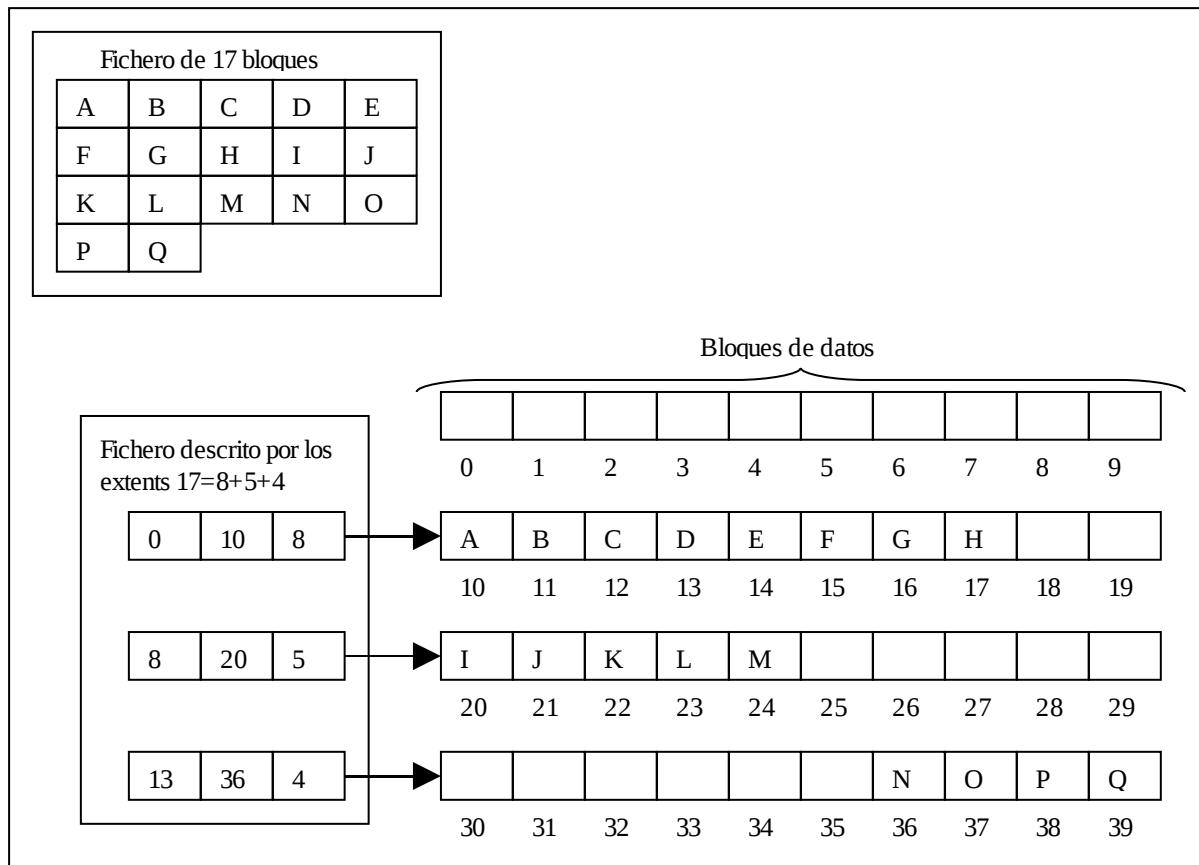
Asignación de bloques es un método donde el sistema de fichero asigna un bloque cada vez. En este método, un puntero a cada bloque se mantiene y almacena.

FRAGMENTACIÓN INTERNA ocurre cuando un fichero no ocupa por completo un bloque. Por ejemplo, si tenemos un fichero de 10K y un tamaño de bloque de 8K, el sistema de ficheros asignara dos bloques para alojar el fichero, pero 6K del segundo bloque se desaprovecharan. Nótese que a mayor tamaño de bloque mayor será el espacio desperdiciado.

FRAGMENTACIÓN EXTERNA ocurre cuando los bloques lógicos que forman un fichero se encuentran esparcidos por todo el disco (no están contiguos). Este tipo de fragmentación produce un bajo rendimiento.

EXTENT es un conjunto de bloques contiguos. Cada Extent se describe como una tripleta, que consiste en un offset del fichero, el número del bloque de comienzo y el tamaño. El offset del fichero es el desplazamiento del primer bloque del extent desde el comienzo del fichero (nos dice a que bloque corresponde dentro del fichero), el numero del bloque de comienzo es el numero del primer bloque del extent y el tamaño es numero de bloques del extent. Los extent se asignan y se monitorizan como una unidad independiente (forman un todo) por lo que un único puntero monitorizara un grupo de bloques. Para ficheros muy grandes, la asignación de extents (o extent allocation) es una técnica mucho más eficiente que la técnica de asignación de bloques. La figura muestra el uso de los extents.

El fichero requiere 17 bloques y el sistema de ficheros puede realizar una asignación de un extent de 8 bloques, un segundo extent de 5 bloques y un tercero de otros 4. El sistema de ficheros será algo como en la figura de arriba. El primer extent tiene un desplazamiento de cero (bloque 'A' del fichero), localización 10 (numero del bloque de comienzo del extent) y un tamaño de 8. El segundo extent tiene un offset de 8 (bloque 'I' del fichero), localización 20 y tamaño 5. El último extent tiene un offset de 13 (bloque 'N' del fichero), localización 35 y tamaño 4.

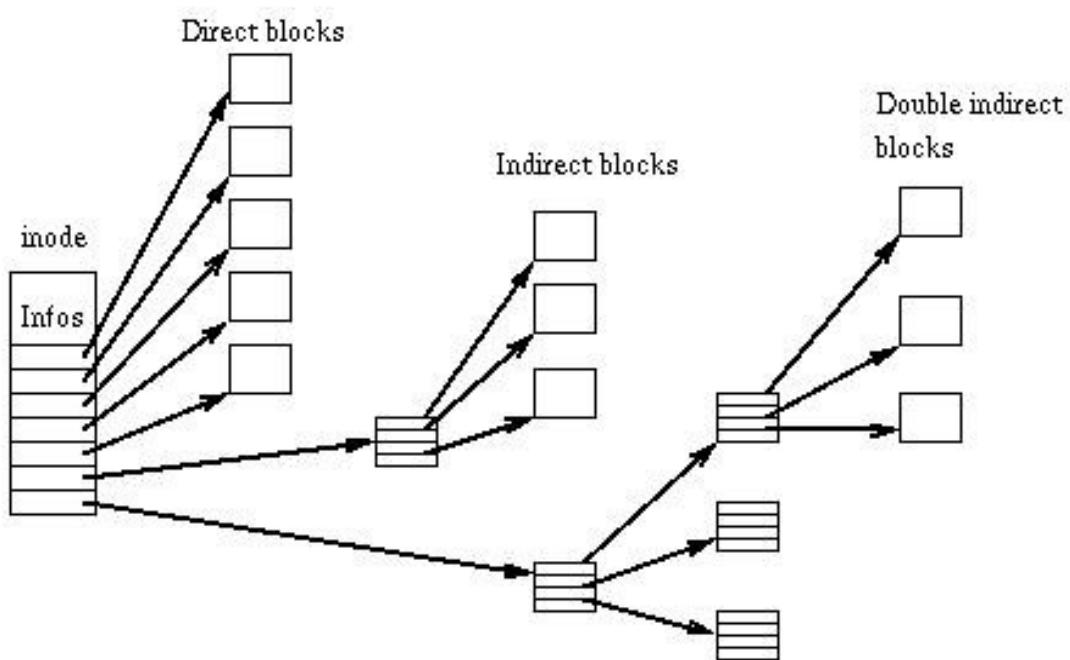


LISTA DE CONTROL DE ACCESO (Access Control List –ACL). En vez de clasificar los usuarios de un fichero en tres clases –propietario, grupo y otros –esta lista se asocia con cada fichero para especificar los derechos de acceso para cualquier usuario específico o combinación de usuarios.

METADATOS del sistema de ficheros son las estructuras de datos internas del sistema de ficheros, información acerca del sistema de fichero excepto la información dentro de los ficheros, es la información necesaria para gestionar el SF y los bloques. Los metadatos incluyen la fecha y hora, la información sobre el propietario, los permisos de acceso de los ficheros, otra tipo de información de seguridad como la lista de control de acceso (ACL) si existe.

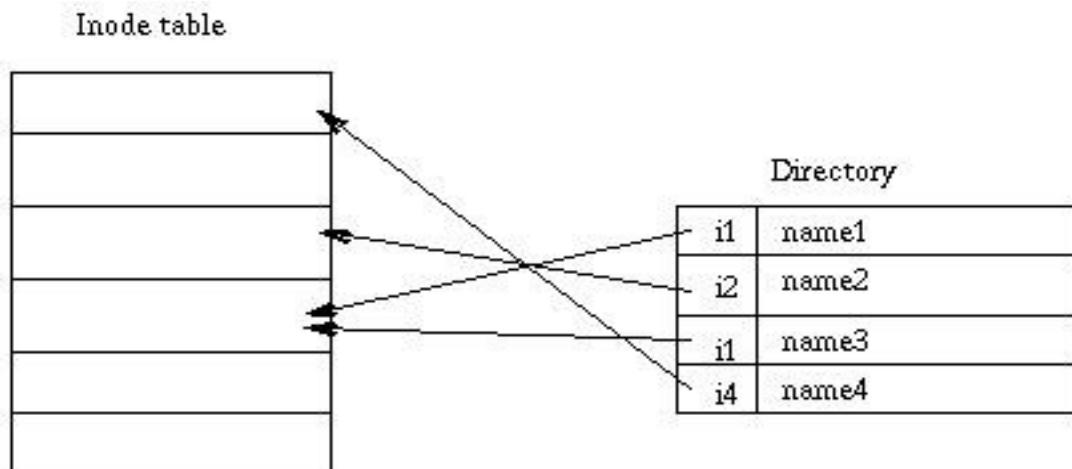
INODE Cada archivo se representa mediante una estructura llamada inodo. Cada inodo contiene la descripción del archivo: tipo, derechos de acceso, propietarios, marcas de tiempo, tamaño y punteros a los bloques de datos. Las direcciones de los bloques de datos asignados al archivos se guardan en su inodo. Cuando un usuario solicita una operación de E/S en un archivo, el núcleo convierte el offset actual (posición dentro del archivo donde se desea leer o escribir) a un número de bloque, emplea este número como un índice en la tabla de direcciones de bloques y lee o escribe el bloque físico.

La siguiente figura representa el campo de direcciones de los bloques de datos dentro de un inodo:



DIRECTORIO Los directorios se estructuran en un árbol jerárquico. Cada directorio puede contener archivos y subdirectorios. Los directorios se implementan como un tipo especial de archivos. Realmente un directorio es un archivo que contiene una lista de entradas. Cada entrada contiene un número de inodo y un nombre de archivo. Cuando un proceso emplea una ruta (path), el núcleo busca en los directorios el correspondiente número de inodo. Una vez que el nombre ha sido convertido en un número de inodo, éste se carga en la memoria y se usa en peticiones posteriores.

La siguiente figura muestra la estructura de un directorio:



ENLACES Los FS Unix implementan el concepto de enlace. Distintos nombres pueden asociarse con un inodo. El inodo contiene un campo que contabiliza el número de enlaces que apuntan al archivo. Añadir un enlace consiste únicamente en crear una nueva entrada de directorio en la que el número de inodo apunta al inodo que se está enlazando, e incrementar el contador de enlaces en el inodo. Cuando se borra un enlace el núcleo decrementa el contador de enlaces y libera el inodo en caso de que éste llegue a cero.

Este tipo de enlaces se denomina **enlace duro** y únicamente se puede emplear dentro de un mismo FS: es imposible crear enlaces duros entre distintos FS. Los enlaces duros pueden apuntar únicamente a ficheros, no a directorios. Esto es así para evitar la aparición de ciclos en el árbol de directorios.

Existe otro tipo de enlace denominado **enlace simbólico**. Los enlaces simbólicos son únicamente archivos que contiene un nombre de archivo. Cuando el núcleo encuentra un enlace simbólico mientras realiza la conversión de ruta a inode, reemplaza el nombre del enlace por su contenido y reinicia la interpretación de la ruta. Como un enlace simbólico no apunta a un inodo es posible crear enlaces simbólicos entre distintos FS. Sin embargo los enlaces simbólicos consumen espacio en disco (inode + bloques de datos), y pueden causar sobrecargas en el sistema debido a que el núcleo debe reiniciar la interpretación cuando encuentra un enlace simbólico.

FICHEROS DE DISPOSITIVO En los sistemas operativos de la familia Unix los dispositivos de E/S se acceden a través de archivos especiales. Un archivo especial de dispositivo no usa espacio en el FS. Es únicamente un punto de acceso al controlador del dispositivo.

Existen dos tipos de archivos de dispositivo: de carácter y de bloque. Los de carácter permiten operaciones E/S en modo carácter, mientras que los de bloque requieren que la información sea escrita en modo bloque mediante el buffer cache. Cuando se realiza una petición E/S en un fichero especial lo que realmente se hace es redireccionar a un (pseudo) controlador de dispositivo. Un archivo especial se referencia por un número mayor, que identifica el dispositivo, y un número menor, que identifica la unidad.

Otras características del Ext2:

Ext2fs soporta los tipos de ficheros estandar de Unix: ficheros regulares, directorios, ficheros especiales de dispositivo y enlaces simbólicos.

Ext2fs puede gestionar FS creados en particiones grandes, hasta 4 Tb.

Ext2fs permite nombres de fichero largos. Emplea entradas de directorio de longitud variable. El tamaño máximo de nombre de fichero es 255 caracteres, aunque este límite puede ser extendido hasta 1012.

Ext2fs reserva algunos bloques para el superusuario (root). Normalmente el 5% de los bloques se reservan para éste. Esto permite al administrador recuperar el sistema fácilmente ante situaciones en las que los procesos de usuario llenen el sistema de ficheros.

Ext2fs soporta algunas extensiones que normalmente no se encuentran en sistemas de ficheros tipo Unix.

Los atributos de archivo permiten a los usuarios modificar el comportamiento del núcleo cuando actua sobre un conjunto de ficheros. Se puede establecer atributos para archivos y directorios. En el caso de un directorio, los archivos nuevos creados en él heredan los atributos.

Ext2fs permite al administrador elegir el tamaño del bloque lógico cuando se crea el FS. Tamaños típicos de bloque son 1, 2 o 4 Kb. Usar tamaños de bloque grandes puede acelerar las operaciones de E/S ya que se requiere una menor cantidad de peticiones, sin embargo puede producir un malgasto de espacio debido a la fragmentación interna (el último bloque de cada archivo puede no estar lleno). Muchas de las ventajas de emplear tamaños de bloque grandes se obtienen empleando técnicas de preasignación implementadas en Ext2fs, pudiendo elegir sin perjuicio del rendimiento tamaños de bloque más razonables.

Ext2fs implementa enlaces simbólicos rápidos. Éstos no utilizan bloques de datos. El nombre destino se almacena en el propio inodo, de este modo se ahorra espacio. Como el espacio disponible en un inodo es limitado el tamaño máximo del destino de un enlace simbólico rápido es de 60 caracteres.

Ext2fs mantiene información sobre el estado del FS. El núcleo emplea un campo en el superbloque (explicado posteriormente) para indicar el estado del FS. Cuando un FS se monta en modo lectura/escritura se marca su estado como "no limpio". Cuando se desmonta o se remonta en modo de sólo lectura su estado se marca como "limpio". Durante el arranque del sistema se comprueba esta información para actuar consecuentemente. El núcleo también guarda errores en este campo. Esta información se comprueba durante el arranque a pesar de que el estado de FS sea "limpio".

No realizar comprobaciones del FS puede ser peligroso, por ello Ext2fs proporciona dos maneras de forzar estas comprobaciones a intervalos regulares. Por un lado tenemos un contador de montajes. Cada vez que el sistema se monta en modo lectura/escritura, se incremente el contador. Cuando el contador alcanza una determinada cifra se fuerza la comprobación. En el superbloque también se almacena el momento de la última comprobación, así como el intervalo máximo entre comprobaciones. Estos campos permiten al administrador fijar comprobaciones periódicas.

El sistema de ficheros preasigna bloques de datos en disco a ficheros regulares antes de ser usados. Así, cuando el fichero aumenta de tamaño, varios bloques ya están reservados en posiciones adyacentes, reduciendo así la fragmentación de los ficheros.

Soporta chequeos automáticos de consistencia del sistema de ficheros en el inicio del sistema. Los chequeos son realizados por un programa llamado e2fsck.

Soporta los llamados ficheros 'inmutables' (ficheros que no pueden ser modificados, borrados o renombrados) y los ficheros de solo agregar (append-only –la información solo se les puede añadir por el final del mismo).

Borrado Lógico. Permite a los usuarios la recuperación sencilla, si es necesario, del contenido de un fichero previamente eliminado.

Compatibilidad tanto con el SVR4 (Unix System V Release 4) y con la semántica BSD.

17.3 Estructura Física de un SF EXT2

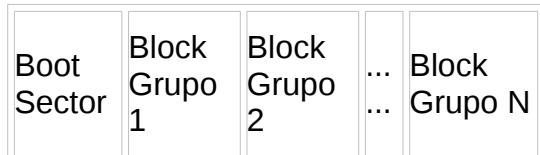
Organización del disco: BLOQUES Y GRUPOS DE BLOQUES

La estructura física de Ext2fs está fuertemente influenciada por la distribución (layout) del sistema de ficheros BSD [McKusick et al. 1984]. Un sistema de archivos se compone de grupos de bloques. Los grupos de bloques son análogos a los grupos de cilindros de los BSD FFS. Sin embargo los grupos de bloques no se encuentran atados a la disposición física de los bloques en el disco.

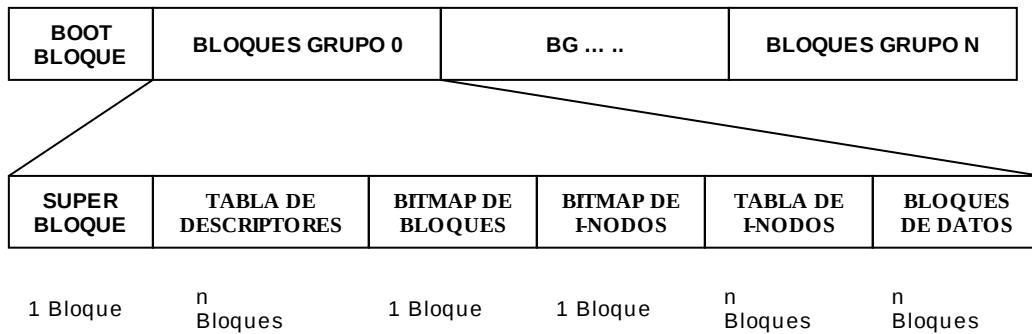
Ext2fs divide el disco en pequeñas unidades lógicas llamadas '**bloques**'. Estas son las unidades mínimas de disco que pueden ser asignadas y su tamaño puede ser escogido (1, 2 o 4 KB) en el momento de creación del sistema de ficheros.

El ext2 divide las particiones lógicas que ocupa en **Grupo de Bloques (BG)**, conjuntos de bloques secuenciales. En realidad, el sistema de ficheros es manejado globalmente como una serie de Grupos de Bloques, lo que mantiene la información relacionada físicamente cercana en el disco y simplifica las tareas de gestión. Como resultado, la mayor parte de la gestión del sistema de ficheros se reduce a la gestión de un sólo grupo de bloques.

La estrcutura física de un sistema de un fichero es como sigue:



Cada grupo contiene una copia redundante de información de control crucial del FS (el superbloque y los descriptores del FS) además de parte del propio FS (block bitmap, inode bitmap, una porción de la tabla de inodos, y bloques de datos). La estructura de un grupo de bloques es como sigue:

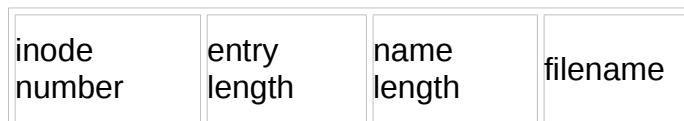


Cada Grupo de Bloques BG contiene:

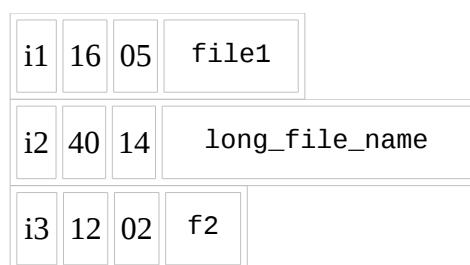
- Una copia del superbloque.
- Tabla con los descriptores del grupo.
- Un bitmap de bloques.
- Un bitmap de inodos.
- Una parte de la tabla de inodos.
- Bloques de datos.

Usar grupos de bloques es un gran avance en términos de fiabilidad: el hecho de guardar una copia de las estructuras de control superbloque y tabal de descriptores en cada grupo facilita la recuperación del FS ante una corrupción del superbloque. También ayuda a alcanzar un buen rendimiento: reduciendo la distancia entre la tabla de inodos y los bloques de datos es posible reducir las búsquedas de las cabezas de los discos.

Los directorios en Ext2fs son listas enlazadas con [entradas de longitud variable](#). Cada entrada contiene el número de inodo, la longitud de la entrada, el nombre de archivo y su longitud. La estructura de un directorio se muestra a continuación:



Como ejemplo se muestra a continuación la estructura de un directorio que contiene 3 archivos: file1, long_file_name, y f2:



Optimizaciones de rendimiento

El sistema de ficheros Ext2fs contiene muchas optimizaciones orientadas a mejorar el rendimiento a la hora de realizar lecturas y escrituras. Aprovechando la gestión del buffer cache realizando lecturas por adelantado: cuando se lee un bloque el código del núcleo solicita varios bloques contiguos. De este modo se pretende asegurar que el siguiente bloque a leer ya se encuentra cargado en el buffer cache. Ext2fs realiza lecturas por adelantado en lecturas secuenciales de archivos y en lecturas de directorios, ya sean explícitas o implícitas.

Así mismo Ext2fs cuenta con numerosas optimizaciones de asignación de bloques. Los grupos de bloques se emplean para reunir inodos y sus datos, de modo que el núcleo siempre intenta situar un inodo y sus bloques de datos en el mismo grupo de bloques.

A la hora de escribir Ext2fs preasigna 8 bloques adjacentes cuando se asigna un nuevo bloque, de este modo se evita solicitar espacio bloque a bloque, además de conseguir que la información de un mismo archivo se encuentre en bloques contiguos.

17.4 Estructuras de datos

El superbloque

El superbloque es un bloque que contiene la información más relevante y describe al sistema de ficheros. Se encuentra en el offset fijo 1024 del disco y ocupa 1024 bytes.

El superbloque contiene una descripción del tamaño y forma del sistema de ficheros. Esta información permite usar y mantener dicho sistema de ficheros. En condiciones normales únicamente el superbloque situado en el grupo de bloques 0 se lee cuando el sistema de ficheros es montado, sin embargo cada grupo de bloques contiene una copia duplicada. Entre otra información el superbloque contiene:

Número Mágico (s_magic): Permite al software que relanza el montaje comprobar que se trata efectivamente del superbloque para un sistema de ficheros Ext2.

Nivel de revisión (s_rev_level): Los números mayor y menor de revisión permiten identificar ciertas características del sistema de archivos que encuentran presentes únicamente en ciertas versiones.

Contador de montajes (s_mnt_count) y máximo número de montajes (s_max_mnt_count): Juntos permiten determinar si se debe realizar una comprobación completa del sistema de ficheros, “e2fsck”.

Número del grupo de bloques (s_block_group_nr): El número del grupo de bloques que contiene la copia del superbloque.

Tamaño de bloque (s_log_block_size): El tamaño del bloque en bytes.

Bloques por grupo (s_blocks_per_group): El número de bloques en un grupo. Igual que el tamaño de bloque, este valor se fija cuando se crea el sistema de ficheros.

Bloques libres (s_free_blocks_count): El número de bloques libres en el sistema de ficheros.

Inodos libres (s_free_inodes_count): El número de inodos libres en el sistema de ficheros.

Primer Inodo (s_first_ino): El número del primer inodo del sistema de ficheros. El primer inodo en un sistema Ext2 raíz debe ser la entrada de directorio para el directorio '/'.

En general el superbloque contiene 3 tipos de información:

Parámetros fijos

Definidos durante la creación del sistema de ficheros, no pueden ser modificados posteriormente. Entre ellos encontramos:

- Tamaño de bloque.
- Número de inodos disponibles
- Número de bloques disponibles
- Número de bloques por grupo
- Número de inodos por grupo
- Sistema operativo que creó el sistema de archivos
- Número de revisión del sistema de ficheros
- Tamaño del fragmento
- Número de fragmentos por grupo

Parámetros modificables

En contraposición a los parámetros fijos, inmutables una vez que el sistema de ficheros ha sido creado, hay varios parámetros que pueden ser modificados durante el funcionamiento del mismo.

- Número de bloques reservados al superusuario
- UID (identificador de usuario) del superusuario por defecto
- GID (identificador de grupo) del superusuario por defecto

Estado del sistema de ficheros

Encontramos información de uso:

- Inodos libres
- Bloques libres
- Directorio donde se montó la última vez
- Estado del sistema de archivos
- Número de montajes
- Marca de tiempo del último montaje
- Marca de tiempo de la última escritura

- Marca de tiempo de la última comprobación

Econtramos información sobre actuaciones:

- Máximo número de montajes sin comprobación
- Máximo tiempo entre comprobaciones
- Comportamiento cuando se detectan errores

Manejo de errores

Ext2 no realiza manejo de errores, se limita a informar al núcleo del sistema operativo de la existencia de los mismos. La comprobación del sistema de ficheros y la corrección de errores es llevada a cabo por herramientas externas como e2fsch o debugfs de Theodore Ts'o, o EXT2ED de Gadi Oxman. Estos programas hacen uso de la información sobre errores y su tratamiento que se encuentra en el superbloque.

El bit 0 del campo s_state del superbloque se pone a 0 durante el montaje de una partición, asignandole un valor de 1 cuando el sistema de archivos es desmontado, de este modo si en el momento del montaje el bit 0 se encuentra a 0 puede deducirse que el sistema no se desmontó o se desmontó incorrectamente y actuar en consecuencia. El bit 1 de s_state será puesto a 1 por el núcleo cuándo detecte algún error.

El campo s_errors define cual ha de ser el comportamiento en caso de detectar un error:

- 1, error ignorado
- 2, se remonta el sistema de archivos en modo de sólo lectura
- 3, se entrará en un "kernel panic"

Estructura ext2_super_bloq

En el archivo <include/linux/ext2_fs.h> se encuentra definida la estructura ext2_super_block.

```
370/*
371 * Structure of the super block
372 */
373 struct ext2_super_block {
374     __le32 s_inodes_count;      /* Inodes count */
375     __le32 s_blocks_count;     /* Blocks count */
376     __le32 s_r_blocks_count;   /* Reserved blocks count */
377     __le32 s_free_blocks_count; /* Free blocks count */
378     __le32 s_free_inodes_count; /* Free inodes count */
379     __le32 s_first_data_block; /* First Data Block */
380     __le32 s_log_block_size;   /* Block size */
381     __le32 s_log_frag_size;    /* Fragment size */
382     __le32 s_blocks_per_group; /* # Blocks per group */
383     __le32 s frags_per_group;  /* # Fragments per group */
384     __le32 s_inodes_per_group; /* # Inodes per group */
385     __le32 s_mtime;           /* Mount time */
386     __le32 s_wtime;           /* Write time */
387     __le16 s_mnt_count;        /* Mount count */
388     __le16 s_max_mnt_count;    /* Maximal mount count */
389     __le16 s_magic;            /* Magic signature */
```

Superbloque en Ext2

```
390     __le16 s_state;          /* File system state */
391     __le16 s_errors;         /* Behaviour when detecting errors */
392     __le16 s_minor_rev_level; /* minor revision level */
393     __le32 s_lastcheck;      /* time of last check */
394     __le32 s_checkinterval;   /* max. time between checks */
395     __le32 s_creator_os;     /* OS */
396     __le32 s_rev_level;      /* Revision level */
397     __le16 s_def_resuid;     /* Default uid for reserved blocks */
398     __le16 s_def_resgid;     /* Default gid for reserved blocks */
399 /*
400 * These fields are for EXT2_DYNAMIC_REV superblocks only.
401 *
402 * Note: the difference between the compatible feature set and
403 * the incompatible feature set is that if there is a bit set
404 * in the incompatible feature set that the kernel doesn't
405 * know about, it should refuse to mount the filesystem.
406 *
407 * e2fsck's requirements are more strict; if it doesn't know
408 * about a feature in either the compatible or incompatible
409 * feature set, it must abort and not try to meddle with
410 * things it doesn't understand...
411 */
412     __le32 s_first_ino;       /* First non-reserved inode */
413     __le16 s_inode_size;     /* size of inode structure */
414     __le16 s_block_group_nr;  /* block group # of this superblock */
415     __le32 s_feature_compat; /* compatible feature set */
416     __le32 s_feature_incompat; /* incompatible feature set */
417     __le32 s_feature_ro_compat; /* readonly-compatible feature set */
418     __u8 s_uuid[16];         /* 128-bit uuid for volume */
419     char s_volume_name[16];   /* volume name */
420     char s_last_mounted[64];  /* directory where last mounted */
421     __le32 s_algorithm_usage_bitmap; /* For compression */
422 /*
423 * Performance hints. Directory preallocation should only
424 * happen if the EXT2_COMPAT_PREALLOC flag is on.
425 */
426     __u8 s_prealloc_blocks;   /* Nr of blocks to try to preallocate*/
427     __u8 s_prealloc_dir_blocks; /* Nr to preallocate for dirs */
428     __u16 s_padding1;
429 /*
430 * Journaling support valid if EXT3_FEATURE_COMPAT_HAS_JOURNAL set.
431 */
432     __u8 s_journal_uuid[16];  /* uuid of journal superblock */
433     __u32 s_journal_inum;    /* inode number of journal file */
434     __u32 s_journal_dev;     /* device number of journal file */
435     __u32 s_last_orphan;     /* start of list of inodes to delete */
436     __u32 s_hash_seed[4];    /* HTREE hash seed */
437     __u8 s_def_hash_version; /* Default hash version to use */
438     __u8 s_reserved_char_pad;
439     __u16 s_reserved_word_pad;
440     __le32 s_default_mount_opts;
441     __le32 s_first_meta_bg;   /* First metablock block group */
442     __u32 s_reserved[190];    /* Padding to the end of the block */
443};
```

Tipo	Campo	Descripción
unsigned int	s_inodes_count	Número de inodos
unsigned int	s_blocks_count	Número de bloques
unsigned int	s_r_blocks_count	Número de bloques reservados
unsigned int	s_free_blocks_count	Número de bloques libres
unsigned int	s_free_inodes_count	Número de inodos libres
unsigned int	s_first_data_block	Primer bloque de datos
unsigned int	s_log_block_size	Tamaño de bloque
unsigned int	s_log_frag_size	Tamaño de fragmento
unsigned int	s_blocks_per_group	Número de bloques por grupo
unsigned int	s_frags_per_group	Número de fragmentos por grupo
unsigned int	s_inodes_per_group	Número de inodos por grupo
unsigned int	s_mtime	Fecha del último montaje
unsigned int	s_wtime	Fecha de la última escritura
unsigned short	s_mnt_count	Número de montajes realizados desde la última comprobación
unsigned short	s_max_mnt_count	Máximo número de montajes entre comprobaciones
unsigned short	s_magic	Número mágico
unsigned short	s_state	Estado del sistema de archivos

Tipo	Campo	Descripción
unsigned short	s_errors	Comportamiento en caso de error
unsigned short	s_minor_rev_level	Número menor de revisión
unsigned int	s_last_check	Fecha de la última coprobación
unsigned int	s_check_interval	Máximo intervalo de tiempo entre comprobaciones
unsigned int	s_creator_os	Sistema operativo que creó el FS
unsigned int	s_rev_level	Número de revisión
unsigned short	s_def_resuid	UID del superusuario por defecto
unsigned short	s_def_resgid	GID del superusuario por defecto

Los siguientes campos son para superbloques EXT2_DYNAMIC_REV sólamente

unsigned int	s_first_ino	Primer inodo no reservado
unsigned short	s_inode_size	Tamaño de la estructura inodo
unsigned short	s_block_group_nr	Número de grupo que contiene éste superbloque
unsigned int	s_feature_compat	Indicador de características compatibles
unsigned int	s_feature_incompat	Indicador de características incompatibles
unsigned int	s_feature_ro_compat	Compatibilidad con sólo lectura
unsigned char	s_uuid[16]	UID de 128 bits, para el volumen
char	s_volume_name[16]	Nombre del volumen

Tipo	Campo	Descripción
char	s_last_mounted`[64]	directorio sobre el que se montó la última vez
unsigned int	s_algorithm_usage_bitmap	Para compresión
Campos relacionados con el rendimiento. Preasignación de directorios únicamente debe realizarse si el flag EXT2_COMPAT_PREALLOC está activo.		
unsigned char	s_prealloc_blocks	Número de bloques que debe intentar preasignarse
unsigned char	s_prealloc_dir_blocks	Número de bloques a preasignar para directorios
unsigned short	s_padding1	Número de bloques de relleno
Campos relacionados con journaling, válidos si EXT3_FEATURE_COMPAT_HAS_JOURNAL está activo.		
unsigned char	s_journal_uuid[16]	UID del superbloque journal
unsigned int	s_journal_inum	Número de inodo del archivo journal
unsigned int	s_journal_dev	Número del dispositivo journal
unsigned int	s_last_orphan	Inicio de la lista de inodos a borrar
unsigned int	s_hash_seed[4]	Semilla hash de HTREE
unsigned char	s_def_hash_version	Versión por defecto de hash a usar
unsigned char	s_reserved_char_pad	Carácter de relleno por defecto
unsigned short	s_reserved_word_pad	Palabra de relleno por defecto
unsigned int	s_default_mount_opts	Opciones de montaje por defecto

Tipo	Campo	Descripción
unsigned int	s_first_meta_bg	Primer grupo de bloques
unsigned int	s_reserved[190]	Reserva de bloques

Estructura ext2_sb_info

Esta estructura representa la manera en la que un superbloque va a ser almacenado y utilizado internamente por el núcleo de Linux, en memoria interna. Se encuentra definido en el fichero `linux/include/linux/ext2_fs_sb.h`

```

68/*
69 * second extended-fs super-block data in memory
70 */
71 struct ext2_sb_info {
72     unsigned long s_frag_size; /* Size of a fragment in bytes */
73     unsigned long s_frags_per_block; /* Number of fragments per block */
74     unsigned long s_inodes_per_block; /* Number of inodes per block */
75     unsigned long s frags_per_group; /* Number of fragments in a group */
76     unsigned long s_blocks_per_group; /* Number of blocks in a group */
77     unsigned long s_inodes_per_group; /* Number of inodes in a group */
78     unsigned long s_itb_per_group; /* Number of inode table blocks per group */
79     unsigned long s_gdb_count; /* Number of group descriptor blocks */
80     unsigned long s_desc_per_block; /* Number of group descriptors per block */
81     unsigned long s_groups_count; /* Number of groups in the fs */
82     unsigned long s_overhead_last; /* Last calculated overhead */
83     unsigned long s_blocks_last; /* Last seen block count */
84     struct buffer_head * s_sbh; /* Buffer containing the super block */
85     struct ext2_super_block * s_es; /* Pointer to the super block in the buffer */
86     struct buffer_head ** s_group_desc;
87     unsigned long s_mount_opt;
88     unsigned long s_sb_block;
89     uid_t s_resuid;
90     gid_t s_resgid;
91     unsigned short s_mount_state;
92     unsigned short s_pad;
93     int s_addr_per_block_bits;
94     int s_desc_per_block_bits;
95     int s_inode_size;
96     int s_first_ino;
97     spinlock_t s_next_gen_lock;
98     u32 s_next_generation;
99     unsigned long s_dir_count;
100    u8 *s_debts;
101    struct percpu_counter s_freeblocks_counter;
102    struct percpu_counter s_freeinodes_counter;
103    struct percpu_counter s_dirs_counter;
104    struct blockgroup_lock *s_blockgroup_lock;
105    /* root of the per fs reservation window tree */
106    spinlock_t s_rsv_window_lock;
107    struct rb_root s_rsv_window_root;

```

Superbloque en Ext2

```

108     struct ext2_reserve_window_node s_rsv_window_head;
109};
110
111static inline spinlock_t *
112sb_bgl_lock(struct ext2_sb_info *sbi, unsigned int block_group)
113{
114     return bgl_lock_ptr(sbi->s_blockgroup_lock, block_group);
115}

```

Tipo	Campo	Descripción
unsigned long	s_frag_size	Tamaño de un fragmento en bytes
unsigned long	s_frags_per_block	Número de fragmentos por bloque
unsigned long	s_inodes_per_block	Número de inodos por bloque
unsigned long	s_frags_per_group	Número de fragmentos en un grupo
unsigned long	s_blocks_per_group	Número de bloques en un grupo
unsigned long	s_inodes_per_group	Número de inodos en un grupo
unsigned long	s_itb_per_group	Nº bloques de la tabla de inodos por grupo
unsigned long	s_gdb_count	Nº bloques del descriptor de grupo
unsigned long	s_desc_per_block	Nº de descriptores de grupo por bloque
unsigned long	s_groups_count	Número de grupos en el fs
unsigned long	s_overhead_last	Último overhead calculado
unsigned long	s_blocks_last	Último bloque contado
struct buffer_head *	s_sbh	Buffer que contiene el superbloque
struct ext2_super_block	s_es	Puntero al buffer superbloque

Tipo	Campo	Descripción
struct buffer head **	s_group_desc	Puntero al descriptor de grupo
unsinged long	s_mount_opt	Opciones de montaje
unsinged long	s_sb_block	Numero de bloque del superbloque
uid_t	s_resuid	Superusuario por defecto
gid_t	s_resgid	Grupo del superusuario por defecto
unsigned short	s_mount_state	Estado del montaje
unsigned short	s_pad	
int	s_addr_per_block_bits	
int	s_desc_per_block_bits	
int	s_inode_size	Tamaño de inodo
int	s_first_ino	Bloque del primer inodo
spinlock_t	s_next_gen_lock	
u32	s_next_generation	
unsigned long	s_dir_count	Número de directorios
u8 *	s_debts	
struct percpu_counter	s_freeblocks_counter	Número de bloques libres
struct percpu_counter	s_freeinodes_counter	Número de inodos libres
struct	s_dirs_counter	Número de directorios

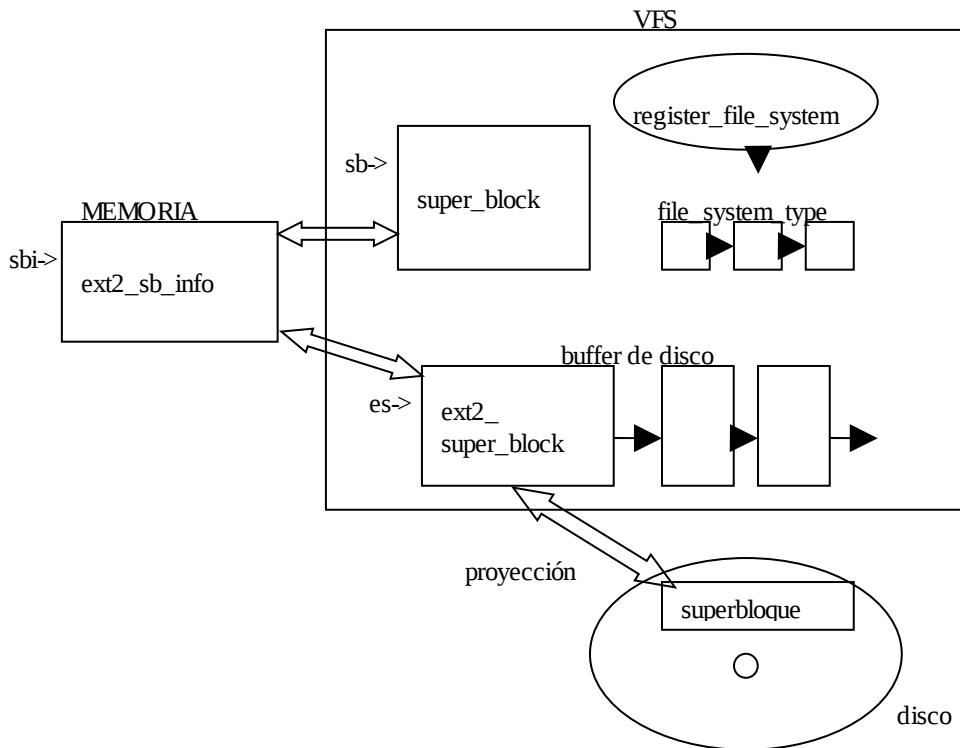
Tipo	Campo	Descripción
percpu_counter		
struct blockgroup_lock	s_blockgroup_lock	
spinlock_t	s_rsv_window_lock	
struct rb_root	s_rsv_window_root	ventana reserva para root
struct ext2_reserve_window_node	s_rsv_window_head	principio de la reserva

Hemos visto tres estructuras relacionadas con el superbloque:

En el capítulo de sistema de ficheros virtual VFS, **super_block**, la variable que lo referencia es “**sb**”.

En este capítulo superbloque para el sistema de ficheros ext2, **ext2_super_block**, esta estructura se proyecta en el buffer de disco, la variable que lo referencia es “**es**”.

Estructura **ext2_sb_info**, superbloque ext2 en memoria, se referencia con la variable “**sbi**”.



Descriptoros de grupo de bloques

(ext2_group_desc)

Los descriptores de grupo se colocan todos juntos, y forman la **tabla de descriptores de grupo**, de la cual se almacena una copia en cada BG, justo detrás de la copia del superbloque. De todas estas copias, sólo se usa la del BG 0. Las demás sólo se emplearán en caso de que el sistema resulte dañado.

Estos descriptores contienen información para gestionar los bloques y los inodos presentes en cada grupo.

En el fichero de cabecera `include/linux/ext2_fs.h` se encuentra la definición de la estructura `ext2_group_desc`, que define la tabla de descriptores de grupo.

```
struct ext2_group_desc
{
    __le32 bg_bitmap;           /* Dirección del Bloque del bitmap de bloques */
    __le32 bg_inode_bitmap;     /* Dirección del Bloque del bitmap de inodos */
    __le32 bg_inode_table;      /* Dirección del Bloque de la tabla de inodos */
    __le16 bg_free_blocks_count; /* número de bloques libres */
    __le16 bg_free_inodes_count; /* número de inodos libres */
    __le16 bg_used_dirs_count;  /* número de directorios */
```

Superbloque en Ext2

```

    __le16 bg_pad;          /* no utilizado */
    __le32 bg_reserved[3];  /* reservado para futura extensión */
};


```

Tipo	Campo	Descripción
unsigned int	bg_block_bitmap	Bloque de inicio del mapa de bloques
unsigned int	bg_inode_bitmap	Bloque de inicio del mapa de inodos
unsigned int	bg_inode_table	Bloque de inicio de la tabla de inodos
unsigned short	bg_free_blocks_count	Número de bloques libres
unsigned short	bg_free_inodes_count	Número de inodos libres
unsigned short	bg_use_dirs_count	Número de directorios
unsigned short	bg_pad;	
unsigned int	bg_reserved[3]	Reservado

Todos estos campos son inicializados el momento de creación del sistema de ficheros y posteriormente actualizados por el sistema de ficheros.

bg_block_bitmap y **bg_inode_bitmap** contienen el número de bloque del bitmap de asignación de bloques y del bitmap de asignación de inodos respectivamente, que son empleado para asignar y desasignar cada bloque o inodo en el Grupo de Bloques.

El sistema de ficheros se vale del **bitmap de asignación de bloques** de cada grupo para guardar la información relativa a la asignación de bloques dentro del BG. Cada bit en el bitmap de bloques representa un bloque del BG y si está libre (bit a 0) o no (bit a 1).

bg_inode_table contiene el número del primer bloque donde comienza la tabla de inodos del Grupo de Bloques actual.

bg_free_blocks_count, **bg_free_inodes_count** y **bg_used_dirs_count** mantienen información estadística sobre el uso de estos recursos en el Grupo de Bloques y son utilizados por el núcleo para equilibrar la carga entre los diferentes grupos de bloques.

Cada grupo de bloques tiene una copia del superbloque así como una copia de los descriptores de grupos. Estos descriptores contienen las coordenadas de las estructuras de control presentes en cada Grupo. Como el superbloque, todos los descriptores de grupo para todos los grupos de bloques se duplican en cada grupo, como medida de seguridad ante posibles errores.

Mapas de bits

El sistema Ext2 emplea, para localizar bloques e inodos libres, mapas de bits. De este modo si una posición contiene el valor 1, entonces el inodo o bloque correspondiente se encuentra libre, en caso contrario se interpreta que está ocupado.

17.5 Operaciones vinculadas al superbloque

En el capítulo de sistema de fichero virtual vimos la estructura `super_operations` (`linux/include/linux/fs.h`) que contiene punteros a funciones que trabajan con la estructura “`super_block`”, que se rellenará con las funciones propias de cada sistema de ficheros real.

```
struct super_operations {
    /*Lee un inode de disco de un sistema de ficheros*/
    struct inode *(*alloc_inode)(struct super_block *sb);
    void (*destroy_inode)(struct inode *);
    void (*dirty_inode)(struct inode *);

    /*escribe el contenido de un inode del VFS en el inode del disco*/
    void (*write_inode)(struct inode *, int);
    /*libera la memoria usada por un inode cuando deja de utilizarse*/
    void (*drop_inode)(struct inode *);
    /*devuelve un inode puesto a cero*/
    void (*delete_inode)(struct inode *);
    /*libera la memoria usada por superbloque cuando el fs se desmonta*/
    void (*put_super)(struct super_block *);
    /*escribe el contenido del superbloque del VFS en disco*/
    void (*write_super)(struct super_block *);
    int (*sync_fs)(struct super_block *sb, int wait);
    int (*freeze_fs)(struct super_block *);
    int (*unfreeze_fs)(struct super_block *);

    /*el VFS lee información de control del sistema de ficheros*/
    int (*statfs)(struct super_block *, struct statfs *);
    /*se varían las condiciones de montaje*/
    int (*remount_fs)(struct super_block *, int *, char *);
    void (*clear_inode)(struct inode *);
    void (*umount_begin)(struct super_block *);
    int (*show_options)(struct seq_file *, struct vfsmount *);
```

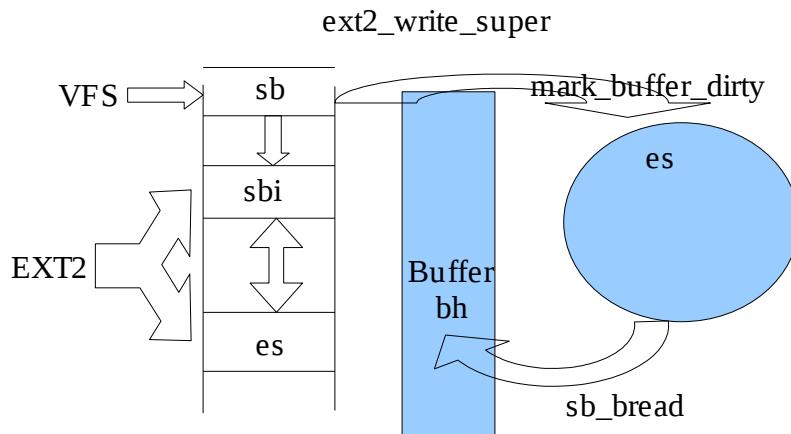
```
int (*show_stats)(struct seq_file *, struct vfsmount *);  
#ifdef CONFIG_QUOTA  
    ssize_t (*quota_read)(struct super_block *, int, char *, size_t, loff_t);  
    ssize_t (*quota_write)(struct super_block *, int, const char *, size_t, loff_t);  
#endif  
};
```

Las operaciones sobre el superbloque para EXT2 se implementan en el archivo fuente fs/ext2/super.c.

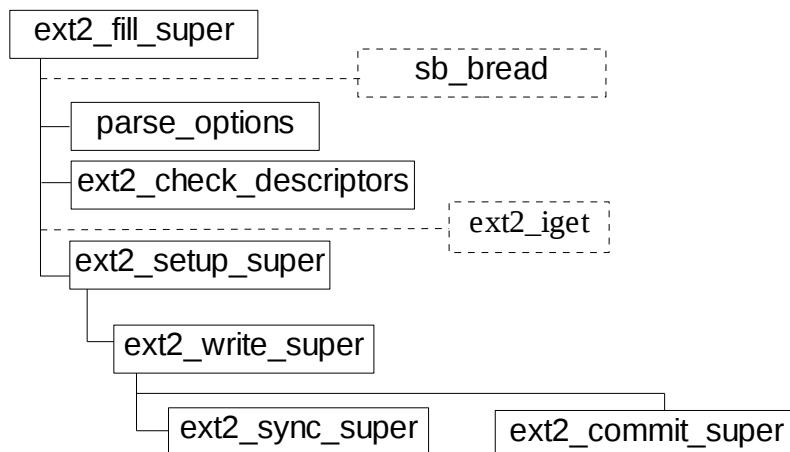
El VFS realiza la correspondencia entre las funciones llamadas por procesos y la específica para ese SF. P. ej.: ext2_write_inode -> write_inode
El siguiente array de punteros a funciones, indica esta correspondencia

```
static struct super_operations ext2_sops = {  
    .alloc_inode    = ext2_alloc_inode,  
    .destroy_inode = ext2_destroy_inode,  
    .write_inode   = ext2_write_inode,  
    .delete_inode  = ext2_delete_inode,  
  
    .put_super     = ext2_put_super,  
    .write_super   = ext2_write_super,  
    .statfs        = ext2_statfs,  
    .remount_fs   = ext2_remount,  
    .clear_inode   = ext2_clear_inode,  
    .show_options  = ext2_show_options,  
#ifdef CONFIG_QUOTA  
    .quota_read    = ext2_quota_read,  
    .quota_write   = ext2_quota_write,  
#endif  
};
```

Las funciones principales relacionadas con el superbloque de un sistema de ficheros ext2 las podemos encontrar en el fichero super.c, vamos a estudiar alguna de ellas relacionadas con leer y escribir el superbloque desde el disco al superbloque del sistema de ficheros virtual en memoria.



Siguiendo la filosofía de Linux, encontramos que unas funciones llaman a otras para realizar funciones más concretas. Podemos ver las siguientes dependencias:



ext2_error

- ¿Qué hace?

Imprime un mensaje de error, mediante la llamada a la función `printk`, durante el montaje de un sistema de archivos y, en función del comportamiento definido en el superbloque, aborta el montaje, o monta en modo sólo lectura.

Código:

```
45void ext2_error (struct super_block * sb, const char * function,
```

```
46             const char * fmt, ...)  
47 {  
48     va_list args;  
49     struct ext2_sb_info *sbi = EXT2_SB(sb);  
50     struct ext2_super_block *es = sbi->s_es;  
51  
52     if (!(sb->s_flags & MS_RDONLY)) {  
53         sbi->s_mount_state |= EXT2_ERROR_FS;  
54         es->s_state =  
55             cpu_to_le16(le16_to_cpu(es->s_state) |  
EXT2_ERROR_FS);  
56         ext2_sync_super(sb, es);  
57     }  
58  
59     va_start(args, fmt);  
60     printk(KERN_CRIT "EXT2-fs error (device %s): %s: ", sb->s_id,  
function);  
61     vprintf(fmt, args);  
62     printf("\n");  
63     va_end(args);  
64  
65     if (test_opt(sb, ERRORS_PANIC))  
66         panic("EXT2-fs panic from previous error\n");  
67     if (test_opt(sb, ERRORS_RO)) {  
68         printf("Remounting filesystem read-only\n");  
69         sb->s_flags |= MS_RDONLY;  
70     }  
71 }
```

ext2_warning

- ¿Qué hace?

Imprime un aviso (la operación se ha llevado a cabo, pero hay aspectos que tener en cuenta) mediante la llamada la función printk.

Código:

```
73 void ext2_warning (struct super_block * sb, const char * function,  
74                     const char * fmt, ...)  
75 {  
76     va_list args;  
77  
78     va_start(args, fmt);  
79     printk(KERN_WARNING "EXT2-fs warning (device %s): %s: ",  
80             sb->s_id, function);  
81     vprintf(fmt, args);  
82     printf("\n");  
83     va_end(args);  
84 }
```

ext2_put_super

- ¿Qué hace?

Implementa la operación sobre sistema de archivos *put_super*. Es llamada por el VFS cuando un sistema de archivos se desmonta. Guarda el superbloque ext2 (es) en disco en caso de haberse modificado, para posteriormente eliminar las memorias ocupadas por los descriptores de grupos de bloques y la memoria intermedia del superbloque (sbi).

Comprueba en primer lugar si se ha modificado el superbloque en disco, en cuyo caso se ha de guardar.

Libera las memorias intermedias que contienen los descriptores del sistema de archivos, llamando a la función *brelse*.

Libera los punteros a esas memorias llamando a *kfree_s*.

Libera las memorias intermedias asociadas a los bloques de *bitmap* cargados en memoria.

Libera la memoria intermedia sbi que contiene el superbloque del sistema de archivos.

Código:

```
111 static void ext2_put_super (struct super_block * sb)
112{
113     int db_count;
114     int i;
115     struct ext2_sb_info *sbi = EXT2_SB(sb);
116
117     ext2_xattr_put_super(sb);
//Se comprueba si hay que actualizar el SB en disco
118     if (!(sb->s_flags & MS_RDONLY)) {
//Se actualiza 'es' con la memoria intermedia sbi
119         struct ext2_super_block *es = sbi->s_es;
120
121         es->s_state = cpu_to_le16(sbi->s_mount_state);
//Se actualiza en disco
122         ext2_sync_super(sb, es);
123     }
//Se liberan las memorias que contienen los descriptores de los grupos
//de bloques mediante la función brelse
124     db_count = sbi->s_gdb_count;
125     for (i = 0; i < db_count; i++)
126         if (sbi->s_group_desc[i])
127             brelse (sbi->s_group_desc[i]);
//Se liberan los punteros a esas memorias
128     kfree(sbi->s_group_desc);
129     kfree(sbi->s_debts);
//Se liberan las memorias asociadas a los bitmaps de bloques
130     percpu_counter_destroy(&sbi->s_freeblocks_counter);
//Se liberan las memorias asociadas a los bitmaps de inodos
131     percpu_counter_destroy(&sbi->s_freeinodes_counter);
132     percpu_counter_destroy(&sbi->s_dirs_counter);
//Se libera la memoria intermedia sbi que contiene el superbloque
```

```
133     brelse (sbi->s_sbh);
134     sb->s_fs_info = NULL;
135     kfree(sbi);
136
137     return;
138}
```

ext2_parse_options

- ¿Qué hace?

Realiza un análisis de las opciones de montaje especificadas. Analiza la cadena de caracteres pasada como parámetro e inicializa las opciones de montaje.

Comprueba si se han pasado opciones de montaje. Si no se le pasa ninguna opción se sale de la función.

Se comprueba cada una de las opciones pasadas como parámetro y va inicializando las opciones de montaje.

La función devuelve 1 si es correcto, 0 en caso contrario.

Código:

```
430 static int parse_options (char * options,
431                           struct ext2_sb_info *sbi)
432{
433     char * p;
434     substring_t args[MAX_OPT_ARGS];
435     int option;
436 //Se comprueba si se han pasado opciones de montaje
437     if (!options)
438         return 1;
439
440     while ((p = strsep (&options, ",")) != NULL) {
441         int token;
442         if (!*p)
443             continue;
444
445         token = match_token(p, tokens, args);
446         switch (token) {
447             case Opt_bsd_df:
448                 clear_opt (sbi->s_mount_opt, MINIX_DF);
449                 break;
450             case Opt_minix_df:
451                 set_opt (sbi->s_mount_opt, MINIX_DF);
452                 break;
453             case Opt_grpid:
454                 set_opt (sbi->s_mount_opt, GRPID);
455                 break;
456             case Opt_nogrpid:
457                 clear_opt (sbi->s_mount_opt, GRPID);
```

```

458         break;
459     case Opt_resuid:
460         if (match_int(&args[0], &option))
461             return 0;
462         sbi->s_resuid = option;
463         break;
464     case Opt_resgid:
465         if (match_int(&args[0], &option))
466             return 0;
467         sbi->s_resgid = option;
468         break;
469     case Opt_sb:
470         /* handled by get_sb_block() instead of here */
471         /* *sb_block = match_int(&args[0]); */
472         break;
473     case Opt_err_panic:
474         clear_opt (sbi->s_mount_opt, ERRORS_CONT);
475         clear_opt (sbi->s_mount_opt, ERRORS_RO);
476         set_opt (sbi->s_mount_opt, ERRORS_PANIC);
477         break;
478     case Opt_err_ro:
479         clear_opt (sbi->s_mount_opt, ERRORS_CONT);
480         clear_opt (sbi->s_mount_opt, ERRORS_PANIC);
481         set_opt (sbi->s_mount_opt, ERRORS_RO);
482         break;
483     case Opt_err_cont:
484         clear_opt (sbi->s_mount_opt, ERRORS_RO);
485         clear_opt (sbi->s_mount_opt, ERRORS_PANIC);
486         set_opt (sbi->s_mount_opt, ERRORS_CONT);
487         break;
488     case Opt_nouid32:
489         set_opt (sbi->s_mount_opt, NO_UID32);
490         break;
491     case Opt_nocheck:
492         clear_opt (sbi->s_mount_opt, CHECK);
493         break;
494     case Opt_debug:
495         set_opt (sbi->s_mount_opt, DEBUG);
496         break;
497     case Opt_oldalloc:
498         set_opt (sbi->s_mount_opt, OLDALLOC);
499         break;
500     case Opt_orlov:
501         clear_opt (sbi->s_mount_opt, OLDALLOC);
502         break;
503     case Opt_nobh:
504         set_opt (sbi->s_mount_opt, NOBH);
505         break;
506 #ifdef CONFIG_EXT2_FS_XATTR
507     case Opt_user_xattr:
508         set_opt (sbi->s_mount_opt, XATTR_USER);
509         break;
510     case Opt_nouser_xattr:
511         clear_opt (sbi->s_mount_opt, XATTR_USER);
512         break;
513 #else
514     case Opt_user_xattr:
515     case Opt_nouser_xattr:

```

```
516                     printk("EXT2 (no)user_xattr options not
supported\n");
517                     break;
518#endif
519#ifndef CONFIG_EXT2_FS_POSIX_ACL
520         case Opt_acl:
521             set_opt(sbi->s_mount_opt, POSIX_ACL);
522             break;
523         case Opt_noacl:
524             clear_opt(sbi->s_mount_opt, POSIX_ACL);
525             break;
526#else
527         case Opt_acl:
528         case Opt_noacl:
529             printk("EXT2 (no)acl options not supported\n");
530             break;
531#endif
532         case Opt_xip:
533#ifndef CONFIG_EXT2_FS_XIP
534             set_opt (sbi->s_mount_opt, XIP);
535#else
536             printk("EXT2 xip option not supported\n");
537#endif
538             break;
539
540#if defined(CONFIG_QUOTA)
541         case Opt_quota:
542         case Opt_usrquota:
543             set_opt(sbi->s_mount_opt, USRQUOTA);
544             break;
545
546         case Opt_grpquota:
547             set_opt(sbi->s_mount_opt, GRPQUOTA);
548             break;
549#else
550         case Opt_quota:
551         case Opt_usrquota:
552         case Opt_grpquota:
553             printk(KERN_ERR
554                     "EXT2-fs: quota operations not
supported.\n");
555             break;
556#endif
557
558         case Opt_reservation:
559             set_opt(sbi->s_mount_opt, RESERVATION);
560             printk("reservations ON\n");
561             break;
562         case Opt_noreservation:
563             clear_opt(sbi->s_mount_opt, RESERVATION);
564             printk("reservations OFF\n");
565             break;
566         case Opt_ignore:
567             break;
568         default:
569             return 0;
570     }
571 }
572 }
```

```
573         return 1;
574 }
575
```

ext2_setup_super

- ¿Qué hace?

Esta función actualiza la estructura superbloque de ext2 (es) incrementando el número de montajes y llama a ext2_write_super para actualizar campos de (es) a partir de (sb) y escribir en el disco. Se llama cuando se monta el sistema de ficheros.

Almacena el "sb" en la memoria intermedia "sbi".

Comprueba que la versión del super bloque no es mayor que la máxima permitida, en cuyo caso se producirá un error.

Si el sistema de fichero se monto de solo lectura se sale de la función, no tiene sentido escribir en disco.

En caso de no haberse montado correctamente el sistema de ficheros la última vez, se mostrará un mensaje con printk y se recomienda ejecutar e2fsck. Se comprueba si el sistema de ficheros ha sido testeado, si tiene errores, si se ha superado el número máximo de montajes, si se ha superado el tiempo de revisión.

Incrementa el número de veces que se ha montado el sistema de ficheros.

Llama a la función ext2_write_super que se encargará de actualizar los campos de "es" a partir de "sb" y posterior escritura en disco.

Código:

```
576 static int ext2_setup_super (struct super_block * sb,
577                               struct ext2_super_block * es,
578                               int read_only)
579 {
580     int res = 0;
//Se almacena el "sb" en la memoria intermedia sbi
581     struct ext2_sb_info *sbi = EXT2_SB(sb);
582 //Si la versión de SB es mayor que la máxima permitida --> ERROR
583     if (le32_to_cpu(es->s_rev_level) > EXT2_MAX_SUPP_REV) {
584         printk ("EXT2-fs warning: revision level too high, "
585                 "forcing read-only mode\n");
586         res = MS_RDONLY;
587     } //Si es de solo lectura
588     if (read_only)
```

```
589             return res;
//Se comprueba que el sistema se montó correctamente la última vez
590     if (!(sbi->s_mount_state & EXT2_VALID_FS))
591         printk ("EXT2-fs warning: mounting unchecked fs, "
592                 "running e2fsck is recommended\n");
593     else if ((sbi->s_mount_state & EXT2_ERROR_FS))
594         printk ("EXT2-fs warning: mounting fs with errors, "
595                 "running e2fsck is recommended\n");
596     else if ((__s16) le16_to_cpu(es->s_max_mnt_count) >= 0 &&
597               le16_to_cpu(es->s_mnt_count) >=
598               (unsigned short) (__s16) le16_to_cpu(es-
599 >s_max_mnt_count))
600         printk ("EXT2-fs warning: maximal mount count reached,
" "
601                 "running e2fsck is recommended\n");
602     else if (le32_to_cpu(es->s_checkinterval) &&
603             (le32_to_cpu(es->s_lastcheck) + le32_to_cpu(es-
604 >s_checkinterval) <= get_seconds()))
605         printk ("EXT2-fs warning: checktime reached, "
606                 "running e2fsck is recommended\n");
607     if (!le16_to_cpu(es->s_max_mnt_count))
//Se incrementa el número de veces que se ha montado el FS
608         es->s_max_mnt_count =
cpu_to_le16(EXT2_DFL_MAX_MNT_COUNT);
609     es->s_mnt_count=cpu_to_le16(le16_to_cpu(es->s_mnt_count) + 1);
//Actualiza los campos de "es" a partir de "sb" y escribe en disco.
610     ext2_write_super(sb);
//Opciones de depuración y chequeo
611     if (test_opt (sb, DEBUG))
612         printk ("[EXT II FS %s, %s, bs=%lu, fs=%lu, gc=%lu, "
613                 "bpg=%lu, ipg=%lu, mo=%04lx]\n",
614                 EXT2FS_VERSION, EXT2FS_DATE, sb->s_blocksize,
615                 sbi->s_frag_size,
616                 sbi->s_groups_count,
617                 EXT2_BLOCKS_PER_GROUP(sb),
618                 EXT2_INODES_PER_GROUP(sb),
619                 sbi->s_mount_opt);
620     return res;
621 }
```

ext2_check_descriptors

· ¿Qué hace?

Verifica la validez de los descriptores de conjuntos leídos desde el disco. Para cada descriptor, verifica que los bloques de bitmap y la tabla de inodos están contenidos en el grupo.

Comprueba si se han pasado opciones de montaje. Si no se le pasa ninguna opción se sale de la función.

Comprueba cada una de las opciones pasadas como parámetro y va inicializando las opciones de montaje.

La función devuelve 1 si es correcto, 0 en caso contrario.

Código:

```

621static int ext2_check_descriptors(struct super_block *sb)
622{
623    int i;
624    struct ext2_sb_info *sbi = EXT2_SB(sb);
625    unsigned long first_block = le32_to_cpu(sbi->s_es-
>s_first_data_block);
626    unsigned long last_block;
627
628    ext2_debug ("Checking group descriptors");
629//Se van recorriendo todos los descriptores de grupo
630    for (i = 0; i < sbi->s_groups_count; i++) {
631        struct ext2_group_desc *gdp = ext2_get_group_desc(sb,
i, NULL);
632//Se selecciona un descriptor de Grupo de Bloques
633        if (i == sbi->s_groups_count - 1)
634            last_block = le32_to_cpu(sbi->s_es-
>s_blocks_count) - 1;
635        else
636            last_block = first_block +
637                         (EXT2_BLOCKS_PER_GROUP(sb) - 1);
638//Si bitmap de bloque no está contenido en el grupo --> ERROR
639        if (le32_to_cpu(gdp->bg_block_bitmap) < first_block ||
640            le32_to_cpu(gdp->bg_block_bitmap) > last_block)
641        {
642            ext2_error (sb, "ext2_check_descriptors",
643                        "Block bitmap for group %d"
644                        " not in group (block %lu)!",
645                        i, (unsigned long) le32_to_cpu(gdp-
>bg_block_bitmap));
646            return 0;
647        }
648//Si bitmap de inodo no está contenido en el grupo --> ERROR
649        if (le32_to_cpu(gdp->bg_inode_bitmap) < first_block ||
650            le32_to_cpu(gdp->bg_inode_bitmap) > last_block)
651        {
652            ext2_error (sb, "ext2_check_descriptors",
653                        "Inode bitmap for group %d"
654                        " not in group (block %lu)!",
655                        i, (unsigned long) le32_to_cpu(gdp-
>bg_inode_bitmap));
656            return 0;
657        }
658//Si tabla de inodo no está contenido en el grupo --> ERROR
659        if (le32_to_cpu(gdp->bg_inode_table) < first_block ||
660            le32_to_cpu(gdp->bg_inode_table) + sbi-
>s_itb_per_group - 1 >
661            last_block)
662        {
663            ext2_error (sb, "ext2_check_descriptors",
664                        "Inode table for group %d"
665                        " not in group (block %lu)!",
666                        i, (unsigned long) le32_to_cpu(gdp-
>bg_inode_table));
667        }
668    }
669    return 0;

```

```
666         }
667         first_block += EXT2_BLOCKS_PER_GROUP(sb);
668     } //Si no se produjo ningún error se devuelve 1
669     return 1;
670 }
671
```

ext2_fill_super

- ¿Qué hace?

Lee del disco el superbloque del sistema de ficheros a montar. Se llama cuando se monta un sistema de ficheros.

Se lee el superbloque desde el disco, se guarda en memoria (en buffer bh, en es y en sbi).

Comprueba su validez mediante el número mágico (*s_magic*).

Comprueba las opciones de montaje con la función *parse_options*.

Comprueba el tamaño de bloque, y en caso de ser incorrecto, se libera y se lee de nuevo el superbloque de disco y se almacena en bh, es y sbi.

Se inicializan campos del superbloque sbi, y se hace una comprobación de que se vaya a montar un sistema de ficheros ext2 mediante su número mágico.

Comprueba que los siguientes campos son correctos: Tamaño de bloque, tamaño de fragmento de bloques por grupo, fragmentos por grupo e inodos por grupo.

Lee de disco, se chequean y almacena en sbi los campos de descriptores de grupo.

Rellena la estructura *sb->s_op* con las operaciones propias del sistema de ficheros ext2 leidas del disco.

Realiza el mount, grabando el directorio raíz del nuevo sistema de ficheros en *sb_root*.

Actualiza el superbloque en disco.

Código:

```
739 static int ext2_fill_super(struct super_block *sb, void *data, int
740   silent)
741 { //bh es un puntero al buffer que contiene el ext2_superblock
742   struct buffer_head * bh;
743   struct ext2_sb_info * sbi;
744   struct ext2_super_block * es;
745   struct inode *root;
746   unsigned long block;
```

```

746     unsigned long sb_block = get_sb_block(&data);
747     unsigned long logic_sb_block;
748     unsigned long offset = 0;
749     unsigned long def_mount_opts;
750     long ret = -EINVAL;
751     int blocksize = BLOCK_SIZE;
752     int db_count;
753     int i, j;
754     le32 features;
755     int err;
756 //Se obtiene memoria para el "sbi"
757     sbi = kzalloc(sizeof(*sbi), GFP_KERNEL);
758     if (!sbi)
759         return -ENOMEM;
760     sb->s_fs_info = sbi;
761     sbi->s_sb_block = sb_block;
762
763 /*
764  * Se calcula el tamaño de bloque (blocksize) para el
765  * dispositivo, y se utiliza como el blocksize. De lo
766  * contrario, (o si el blocksize es menor que el de por
767  * defecto) se usa el de por defecto. Esto es importante
768  * para dispositivos que tienen un tamaño de sector hardware
769  * que es mayor que el valor por defecto
770     blocksize = sb_min_blocksize(sb, BLOCK_SIZE);
771     if (!blocksize) {
772         printk ("EXT2-fs: unable to set blocksize\n");
773         goto failed_sbi;
774     }
775
776 /*
777  * Si el superbloque no comienza en el principio de un
778  * sector hardware, calcula el desplazamiento
779  */
780     if (blocksize != BLOCK_SIZE) {
781         logic_sb_block = (sb_block*BLOCK_SIZE) / blocksize;
782         offset = (sb_block*BLOCK_SIZE) % blocksize;
783     } else {
784         logic_sb_block = sb_block;
785     }
786 //Se lee y almacena el superbloque en una estructura buffer_head "bh"
787     if (!(bh = sb_bread(sb, logic_sb_block))) {
788         printk ("EXT2-fs: unable to read superblock\n");
789         goto failed_sbi;
790     }
791 /* Nota: s_es debe inicializarse tan pronto como sea posible
792  * ya que algunas macro-instrucciones de ext2 dependen de su
793  * valor "es" apunta al buffer bh corregido con el offset que
794  * contiene el superbloque ext2 leido del disco
795     es = (struct ext2_super_block *) (((char *)bh->b_data) +
796 offset);
796 //Se almacena el superbloque ext2 "es" en memoria intermedia "sbi"
797     sbi->s_es = es;
798     sb->s_magic = le16_to_cpu(es->s_magic);
799 //Se verifica la validez del SB comparándolo con el número mágico
800     if (sb->s_magic != EXT2_SUPER_MAGIC)
801         goto cantfind_ext2;
801

```

```

802         /* Se analizan las opciones del mount y se colocan los valores
803         por defecto en "sbi"
804         def_mount_opts = le32_to_cpu(es->s_default_mount_opts);
805         if (def_mount_opts & EXT2_DEF_M_DEBUG)
806             set_opt(sbi->s_mount_opt, DEBUG);
807         if (def_mount_opts & EXT2_DEF_M_BSDGROUPS)
808             set_opt(sbi->s_mount_opt, GRPID);
809         if (def_mount_opts & EXT2_DEF_M_UID16)
810             set_opt(sbi->s_mount_opt, NO_UID32);
811 #ifdef CONFIG_EXT2_FS_XATTR
812     if (def_mount_opts & EXT2_DEF_M_XATTR_USER)
813         set_opt(sbi->s_mount_opt, XATTR_USER);
814 #endif
815 #ifdef CONFIG_EXT2_FS_POSIX_ACL
816     if (def_mount_opts & EXT2_DEF_M_ACL)
817         set_opt(sbi->s_mount_opt, POSIX_ACL);
818 #endif
819         if (le16_to_cpu(sbi->s_es->s_errors) == EXT2_ERRORS_PANIC)
820             set_opt(sbi->s_mount_opt, ERRORS_PANIC);
821         else if (le16_to_cpu(sbi->s_es->s_errors) ==
822             EXT2_ERRORS_CONTINUE)
823             set_opt(sbi->s_mount_opt, ERRORS_CONT);
824         else
825             set_opt(sbi->s_mount_opt, ERRORS_RO);
826         sbi->s_resuid = le16_to_cpu(es->s_def_resuid);
827         sbi->s_resgid = le16_to_cpu(es->s_def_resgid);
828
829         set_opt(sbi->s_mount_opt, RESERVATION);
830 //Se analizan las opciones del montaje con la función parse_options
831     if (!parse_options((char *) data, sbi))
832         goto failed_mount;
833
834     sb->s_flags = (sb->s_flags & ~MS_POSIXACL) |
835         ((EXT2_SB(sb)->s_mount_opt & EXT2_MOUNT_POSIX_ACL) ?
836          MS_POSIXACL : 0);
837
838     ext2_xip_verify_sb(sb); /* see if bdev supports xip, unset
839                           EXT2_MOUNT_XIP if not */
840 //Verificaciones de otras características generales
841     if (le32_to_cpu(es->s_rev_level) == EXT2_GOOD_OLD_REV &&
842         (EXT2_HAS_COMPAT_FEATURE(sb, ~0U) ||
843          EXT2_HAS_RO_COMPAT_FEATURE(sb, ~0U) ||
844          EXT2_HAS_INCOMPAT_FEATURE(sb, ~0U)))
845         printk("EXT2-fs warning: feature flags set on rev 0 fs,
846 "
847             "running e2fsck is recommended\n");
848         /*
849          * Check feature flags regardless of the revision level, since
850          * we
851          * previously didn't change the revision level when setting the
852          * flags,
853          * so there is a chance incompat flags are set on a rev 0
854          * filesystem.
855         */
856         features = EXT2_HAS_INCOMPAT_FEATURE(sb,
857 ~EXT2_FEATURE_INCOMPAT_SUPP);
858         if (features) {

```

```

854         printk("EXT2-fs: %s: couldn't mount because of "
855                 "unsupported optional features (%x).\n",
856                 sb->s_id, le32_to_cpu(features));
857         goto failed_mount;
858     }
859     if (!(sb->s_flags & MS_RDONLY) &&
860         (features = EXT2_HAS_RO_COMPAT_FEATURE(sb,
861 ~EXT2_FEATURE_RO_COMPAT_SUPP))) {
861         printk("EXT2-fs: %s: couldn't mount RDWR because of "
862                 "unsupported optional features (%x).\n",
863                 sb->s_id, le32_to_cpu(features));
864         goto failed_mount;
865     }
866 //Se inicializa el tamaño de bloque
//Se realiza la correspondencia 0->1kB; 1->2kB; 2->4kB
867     blocksize = BLOCK_SIZE << le32_to_cpu(sbi->s_es-
>s_log_block_size);
868
869     if (ext2_use_xip(sb) && blocksize != PAGE_SIZE) {
870         if (!silent)
871             printk("XIP: Unsupported blocksize\n");
872         goto failed_mount;
873     }
874
875     /* Se comprueba que el tamaño del blocksize sea correcto
//Si no se libera memoria y se vuelve a leer el SB
876     if (sb->s_blocksize != blocksize) {
//Se liberan las memorias buffer que contienen los descriptores
//del sistema de ficheros
877         brelse(bh);
878
879         if (!sb_set_blocksize(sb, blocksize)) {
880             printk(KERN_ERR "EXT2-fs: blocksize too small
for device.\n");
881             goto failed_sbi;
882         }
883
884         logic_sb_block = (sb_block*BLOCK_SIZE) / blocksize;
885         offset = (sb_block*BLOCK_SIZE) % blocksize;
886         bh = sb_bread(sb, logic_sb_block);
887         if (!bh) {
888             printk("EXT2-fs: Couldn't read superblock on "
889                     "2nd try.\n");
890             goto failed_sbi;
891         }
//Se vuelve a asignar el superbloque a las variables "es" y "sbi"
892         es = (struct ext2_super_block *) (((char *)bh->b_data)
+ offset);
893         sbi->s_es = es;
//Se comprueba la validez del superbloque
894         if (es->s_magic != cpu_to_le16(EXT2_SUPER_MAGIC)) {
895             printk ("EXT2-fs: Magic mismatch, very
weird !\n");
896             goto failed_mount;
897         }
898     }
899
900     sb->s_maxbytes = ext2_max_size(sb->s_blocksize_bits);
901 //Comprobaciones acerca de los niveles de revisión

```

```

902     if (le32_to_cpu(es->s_rev_level) == EXT2_GOOD_OLD_REV) {
903         sbi->s_inode_size = EXT2_GOOD_OLD_INODE_SIZE;
904         sbi->s_first_ino = EXT2_GOOD_OLD_FIRST_INO;
905     } else {
906         sbi->s_inode_size = le16_to_cpu(es->s_inode_size);
907         sbi->s_first_ino = le32_to_cpu(es->s_first_ino);
908         if ((sbi->s_inode_size < EXT2_GOOD_OLD_INODE_SIZE) ||
909             !is_power_of_2(sbi->s_inode_size) ||
910             (sbi->s_inode_size > blocksize)) {
911             printk ("EXT2-fs: unsupported inode size:
912                     %d\n",
913                     sbi->s_inode_size);
914             goto failed_mount;
915         }
916 //Se rellenan los campos del SB en memoria intermedia "sbi"
917     sbi->s_frag_size = EXT2_MIN_FRAG_SIZE <<
918                         le32_to_cpu(es->s_log_frag_size);
919     if (sbi->s_frag_size == 0)
920         goto cantfind_ext2;
921     sbi->s frags_per_block = sb->s_blocksize / sbi->s_frag_size;
922
923     sbi->s_blocks_per_group = le32_to_cpu(es->s_blocks_per_group);
924     sbi->s frags_per_group = le32_to_cpu(es->s frags_per_group);
925     sbi->s_inodes_per_group = le32_to_cpu(es->s_inodes_per_group);
926
927     if (EXT2_INODE_SIZE(sb) == 0)
928         goto cantfind_ext2;
929     sbi->s_inodes_per_block = sb->s_blocksize /
930 EXT2_INODE_SIZE(sb);
931     if (sbi->s_inodes_per_block == 0 || sbi->s_inodes_per_group == 0)
932         goto cantfind_ext2;
933     sbi->s_itb_per_group = sbi->s_inodes_per_group /
934                         sbi->s_inodes_per_block;
935     sbi->s_desc_per_block = sb->s_blocksize /
936                         sizeof (struct ext2_group_desc);
937     sbi->s_sbh = bh;
938     sbi->s_mount_state = le16_to_cpu(es->s_state);
939     sbi->s_addr_per_block_bits =
940             ilog2 (EXT2_ADDR_PER_BLOCK(sb));
941     sbi->s_desc_per_block_bits =
942             ilog2 (EXT2_DESC_PER_BLOCK(sb));
943 //Si no es SF ext2(número mágico) --> ERROR
944     if (sb->s_magic != EXT2_SUPER_MAGIC)
945         goto cantfind_ext2;
946 //Se comprueba que sea correcto el tamaño de bloque
947     if (sb->s_blocksize != bh->b_size) {
948         if (!silent)
949             printk ("VFS: Unsupported blocksize on dev "
950                     "%s.\n", sb->s_id);
951         goto failed_mount;
952     }
953     if (sb->s_blocksize != sbi->s_frag_size) {
954         printk ("EXT2-fs: fragsize %lu != blocksize %lu (not
supported yet)\n",

```

```

955             sbi->s_frag_size, sb->s_blocksize);
956         goto failed_mount;
957     }
958 //Se comprueba que sea correcto el tamaño de fragmento de bloques de
//grupo
959     if (sbi->s_blocks_per_group > sb->s_blocksize * 8) {
960         printk ("EXT2-fs: #blocks per group too big: %lu\n",
961                 sbi->s_blocks_per_group);
962         goto failed_mount;
963     } //Se comprueba que sea correcto los fragmentos por grupos
964     if (sbi->s frags_per_group > sb->s_blocksize * 8) {
965         printk ("EXT2-fs: #fragments per group too big: %lu\n",
966                 sbi->s frags_per_group);
967         goto failed_mount;
968     } //Se comprueba que sea correcto los inodos por grupos
969     if (sbi->s_inodes_per_group > sb->s_blocksize * 8) {
970         printk ("EXT2-fs: #inodes per group too big: %lu\n",
971                 sbi->s_inodes_per_group);
972         goto failed_mount;
973     }
974
975     if (EXT2_BLOCKS_PER_GROUP(sb) == 0)
976         goto cantfind_ext2;
977     sbi->s_groups_count = ((le32_to_cpu(es->s_blocks_count) -
978                             le32_to_cpu(es->s_first_data_block)) -
1)
979                                         / EXT2_BLOCKS_PER_GROUP(sb)) +
1;
980     db_count = (sbi->s_groups_count + EXT2_DESC_PER_BLOCK(sb) -
1) /
981             EXT2_DESC_PER_BLOCK(sb);
//Se crea memoria para buffer_head para s_group_desc
982     sbi->s_group_desc = kmalloc (db_count * sizeof (struct
buffer_head *), GFP_KERNEL);
983     if (sbi->s_group_desc == NULL) {
984         printk ("EXT2-fs: not enough memory\n");
985         goto failed_mount;
986     }
987     bgl_lock_init(&sbi->s_blockgroup_lock);
//Se crea memoria para s_debts
988     sbi->s_debts = kcalloc(sbi->s_groups_count, sizeof(*sbi-
>s_debts), GFP_KERNEL);
989     if (!sbi->s_debts) {
990         printk ("EXT2-fs: not enough memory\n");
991         goto failed_mount_group_desc;
992     } //Se lee cada uno de los descriptores de grupo desde disco
993     for (i = 0; i < db_count; i++) {
994         block = descriptor_loc(sb, logic_sb_block, i);
995         sbi->s_group_desc[i] = sb_bread(sb, block);
//Se chequean los descriptores de grupo
//Si se produce algun error se libera la memoria asignada
996     if (!sbi->s_group_desc[i]) {
997         for (j = 0; j < i; j++)
998             brelse (sbi->s_group_desc[j]);
999         printk ("EXT2-fs: unable to read group
descriptors\n");
1000    goto failed_mount_group_desc;
1001   }
1002 }
```

```

1003     if (!ext2_check_descriptors (sb)) {
1004         printk ("EXT2-fs: group descriptors corrupted!\n");
1005         goto failed_mount2;
1006     }
1007     sbi->s_gdb_count = db_count;
1008     get_random_bytes(&sbi->s_next_generation, sizeof(u32));
1009     spin_lock_init(&sbi->s_next_gen_lock);
1010
1011     /* per filesystem reservation list head & lock */
1012     spin_lock_init(&sbi->s_rsv_window_lock);
1013     sbi->s_rsv_window_root = RB_ROOT;
1014
1015     /*
1016      * Add a single, static dummy reservation to the start of the
1017      * reservation window list --- it gives us a placeholder for
1018      * append-at-start-of-list which makes the allocation logic
1019      * _much_ simpler.
1020
1021     sbi->s_rsv_window_head.rsv_start =
EXT2_RESERVE_WINDOW_NOT_ALLOCATED;
1022     sbi->s_rsv_window_head.rsv_end =
EXT2_RESERVE_WINDOW_NOT_ALLOCATED;
1023     sbi->s_rsv_window_head.rsv_alloc_hit = 0;
1024     ext2_rsv_window_add(sb, &sbi->s_rsv_window_head);
1025 //Se rellenan más campos del superbloque de memoria intermedia "sbi"
1026     err = percpu_counter_init(&sbi->s_freeblocks_counter,
1027                               ext2_count_free_blocks(sb));
1028     if (!err) {
1029         err = percpu_counter_init(&sbi->s_freeinodes_counter,
1030                               ext2_count_free_inodes(sb));
1031     }
1032     if (!err) {
1033         err = percpu_counter_init(&sbi->s_dirs_counter,
1034                               ext2_count_dirs(sb));
1035     }
1036     if (err) {
1037         printk(KERN_ERR "EXT2-fs: insufficient memory\n");
1038         goto failed_mount3;
1039     }
1040     /*
1041      * Se rellena la estructura "sb" en las operaciones
1042      * relacionadas con el superbloque (sb->s_op) con las
1043      * operaciones propias del sistema de ficheros ext2
1044      sb->s_op = &ext2_sops;
1045      sb->s_export_op = &ext2_export_ops;
1046      sb->s_xattr = ext2_xattr_handlers;
1047 //Lee el nodo raiz del nuevo fs a montar
1048     root = ext2_iget(sb, EXT2_ROOT_INO);
1049     if (IS_ERR(root)) {
1050         ret = PTR_ERR(root);
1051         goto failed_mount3;
1052     }
1053     if (!S_ISDIR(root->i_mode) || !root->i_blocks || !root->i_size)
{
1054         input(root);
1055         printk(KERN_ERR "EXT2-fs: corrupt root inode, run
e2fsck\n");
1056         goto failed_mount3;
}

```

Superbloque en Ext2

```
//Almacena en root el nodo raiz del nuevo fs a montar en root
1057      sb->s_root = d_alloc_root(root);
//Si error --> se elimina el nodo raiz
1058      if (!sb->s_root) {
1059          iput(root);
1060          printk(KERN_ERR "EXT2-fs: get root inode failed\n");
1061          ret = -ENOMEM;
1062          goto failed_mount3;
1063      }
1064      if (EXT2_HAS_COMPAT_FEATURE(sb,
EXT3_FEATURE_COMPAT_HAS_JOURNAL))
1065          ext2_warning(sb, __FUNCTION__,
1066                      "mounting ext3 filesystem as ext2");
//Se llama a ext2_setup_super que incrementará el numero de montajes
//en "es" y guardará "es" en disco
1067      ext2_setup_super (sb, es, sb->s_flags & MS_RDONLY);
1068      return 0;
1069
1070cantfind_ext2:
1071      if (!silent)
1072          printk("VFS: Can't find an ext2 filesystem on dev
% s.\n",
1073                  sb->s_id);
1074      goto failed_mount;
//Etiquetas en caso de error
1075failed_mount3:
1076      percpu_counter_destroy(&sbi->s_freeblocks_counter);
1077      percpu_counter_destroy(&sbi->s_freeinodes_counter);
1078      percpu_counter_destroy(&sbi->s_dirs_counter);
1079failed_mount2:
1080      for (i = 0; i < db_count; i++)
1081          brelse(sbi->s_group_desc[i]);
1082failed_mount_group_desc:
1083      kfree(sbi->s_group_desc);
1084      kfree(sbi->s_debts);
1085failed_mount:
1086      brelse(bh);
1087failed_sbi:
1088      sb->s_fs_info = NULL;
1089      kfree(sbi);
1090      return ret;
1091}
```

ext2_commit_super

- ¿Qué hace?

Esta función es llamada para guardar en disco las modificaciones efectuadas en el superbloque.

Guarda la fecha de la última escritura en el superbloque.

Marca como modificado el buffer que contiene el superbloque, mediante la llamada a *mark_buffer_dirty*. De esta manera, el contenido del buffer será escrito a disco en la siguiente operación de guardar en el buffer cache.

Coloca el campo dirt a limpio.

Código:

```
1093 static void ext2_commit_super (struct super_block * sb,
1094                                     struct ext2_super_block * es)
1095{
//Obtiene la hora de la última escritura en el superbloque
1096     es->s_wtime = cpu_to_le32(get_seconds());
//Se marca como modificado el buffer que contiene el superbloque
//De ello se encarga la función mark_buffer_dirty
1097     mark_buffer_dirty(EXT2_SB(sb)->s_sbh);
1098     sb->s_dirt = 0;
1099}
```

ext2_sync_super

- ¿Qué hace?

Se encarga de actualizar el superbloque desde memoria a disco.

Actualiza campos de "es", número de bloques e inodos libres, fecha de la última escritura (s_wtime).

Llama a las funciones *mark_buffer_dirty* y *sync_dirty_buffer* para escribir en el buffer y luego que se escriba en disco.

Pone sb->s_dirt a 0 a limpio como que se actualizó.

Código:

```
1101 static void ext2_sync_super(struct super_block *sb, struct
ext2_super_block *es)
1102{
1103     es->s_free_blocks_count =
cpu_to_le32(ext2_count_free_blocks(sb));
1104     es->s_free_inodes_count =
cpu_to_le32(ext2_count_free_inodes(sb));
// actualiza fecha de escritura
1105     es->s_wtime = cpu_to_le32(get_seconds());
// marca el buffer como sucio para su escritura en disco
1106     mark_buffer_dirty(EXT2_SB(sb)->s_sbh);
// escribe el buffer en disco
1107     sync_dirty_buffer(EXT2_SB(sb)->s_sbh);
1108     sb->s_dirt = 0;
1109}
```

ext2_write_super

- ¿Qué hace?

Escribe el superbloque en el buffer asignado a disco para su posterior escritura en disco.

Se comprueba si el FS está en modo lectura/escritura.

Si es un FS válido (libre de errores), se actualizan los campos de estado (*s_state*), números de bloques, inodos libres y fecha del último montaje (*s_mtime*).

Se escribe el superbloque en disco llamando a la función `ext2_sync_super`.

Si no es fs valido entonces se llama a la función `ext2_commit_super`, para que se escriba en disco.

Código:

```
/*
1112 * En ext2 no es necesario escribir el superbloque ya que se usa un
1113 * mapeo del superbloque de disco en un buffer
1114 * Sin embargo, esta función todavía es utilizada para establecer el
1115 * flag de validez a 0. Se necesita poner este flag a 0 ya que el FS
1116 * puede haber sido comprobado cuando se montaba y el e2fsck
1117 * puede haber puesto s_state a
1118 * EXT2_VALID_FS después de algunas correcciones.
1119 *
1120 */
1121
1122void ext2_write_super (struct super_block * sb)
1123{
1124    struct ext2_super_block * es;
//Se bloquea el kernel
1125    lock_kernel();
//Se comprueba que el FS no esté en modo de solo lectura
1126    if (!(sb->s_flags & MS_RDONLY)) {
1127        es = EXT2_SB(sb)->s_es;
1128//Se comprueba que sea un sistema de fichero válido
1129        if (le16_to_cpu(es->s_state) & EXT2_VALID_FS) {
1130            ext2_debug ("setting valid to 0\n");
//Se actualiza es->s_state del SF montado
1131            es->s_state = cpu_to_le16(le16_to_cpu(es-
>s_state) &
1132                                ~EXT2_VALID_FS);
//Se actualiza el número de bloques y de inodos libres
1133            es->s_free_blocks_count =
cpu_to_le32(ext2_count_free_blocks(sb));
1134            es->s_free_inodes_count =
cpu_to_le32(ext2_count_free_inodes(sb));
//Se actualiza el s_mtime (fecha de la última modificación del SB
1135            es->s_mtime = cpu_to_le32(get_seconds());
//Se escribe el superbloque "es" en disco
1136            ext2_sync_super(sb, es);
1137        } else
//Si no es un sistema de fichero válido se actualiza el SB
1138            ext2_commit_super (sb, es);
1139    }
1140    sb->s_dirt = 0;
//Se desbloquea el kernel
```

```
1141      unlock_kernel();  
1142}
```

ext2_remount

- ¿Qué hace?

Implementa la operación del sistema de ficheros *remount_fs*. Se monta de nuevo el sistema de ficheros ya montado. Se reconfigura el sistema de ficheros, no lo lee de disco de nuevo.

Decodifica las opciones de montaje con *parse_options*.

Actualizan varios campos del descriptor de superbloque.

Llama a *ext2_setup_super* para inicializar el superbloque.

Código:

```
1144static int ext2_remount (struct super_block * sb, int * flags, char *  
1145 data)  
1146{  
1147     struct ext2_sb_info * sbi = EXT2_SB(sb);  
1148     struct ext2_super_block * es;  
1149     unsigned long old_mount_opt = sbi->s_mount_opt;  
1150     struct ext2_mount_options old_opts;  
1151     unsigned long old_sb_flags;  
1152     int err;  
1153  
1154     /* Store the old options */  
1155     old_sb_flags = sb->s_flags;  
1156     old_opts.s_mount_opt = sbi->s_mount_opt;  
1157     old_opts.s_resuid = sbi->s_resuid;  
1158     old_opts.s_resgid = sbi->s_resgid;  
1159  
1160     /*  
1161      * Allow the "check" option to be passed as a remount option.  
1162      */ /* Se comprueban las opciones de montaje  
1163     if (!parse_options (data, sbi)) {  
1164         err = -EINVAL;  
1165         goto restore_opts;  
1166     }  
1167 //Se actualizan los siguientes campos del descriptor de fichero  
1168     sb->s_flags = (sb->s_flags & ~MS_POSIXACL) |  
1169         ((sbi->s_mount_opt & EXT2_MOUNT_POSIX_ACL) ?  
1170             MS_POSIXACL : 0);  
1171     ext2_xip_verify_sb(sb); /* see if bdev supports xip, unset  
1172                                EXT2_MOUNT_XIP if not */  
1173     if ((ext2_use_xip(sb)) && (sb->s_blocksize != PAGE_SIZE)) {  
1174         printk("XIP: Unsupported blocksize\n");  
1175         err = -EINVAL;  
1176         goto restore_opts;  
1177     }  
1178 }
```

```

1179      es = sbi->s_es;
1180      if (((sbi->s_mount_opt & EXT2_MOUNT_XIP) !=  

1181          (old_mount_opt & EXT2_MOUNT_XIP)) &&  

1182          invalidate_inodes(sb))  

1183          ext2_warning(sb, __FUNCTION__, "busy inodes while  

remounting \"\n"
1184                                "xip remain in cache (no functional  

problem)");
1185      if ((*flags & MS_RDONLY) == (sb->s_flags & MS_RDONLY))
1186          return 0;
1187      if (*flags & MS_RDONLY) {
1188          //Se comprueba que el estado del FS sea válido
1189          if (le16_to_cpu(es->s_state) & EXT2_VALID_FS ||  

1190              !(sbi->s_mount_state & EXT2_VALID_FS))
1191              return 0;
1192          /*
1193             * OK, we are remounting a valid rw partition rdonly,  

so set
1193             * the rdonly flag and then mark the partition as valid  

again.
1194         */
1195         //Se monta de nuevo una partición válida lect/esc como sólo lectura
1196         //Luego se marca de nuevo como una partición válida
1195         es->s_state = cpu_to_le16(sbi->s_mount_state);
1196         es->s_mtime = cpu_to_le32(get_seconds());
1197     } else {
1198         le32 ret = EXT2_HAS_RO_COMPAT_FEATURE(sb,
1199 ~EXT2_FEATURE_RO_COMPAT_SUPP);
1200         if (ret) {
1201             printk("EXT2-fs: %s: couldn't remount RDWR  

because of "
1202                   "unsupported optional features (%x).\n",
1203                   sb->s_id, le32_to_cpu(ret));
1204             err = -EROFS;
1205             goto restore_opts;
1206         }
1207         /*
1208             * Si se va a volver a montar una partición lect/esc a solo  

1208             * lectura RDONLY, se vuelve a leer el flag de validez  

1208             * (puede haber sido cambiado por e2fsck desde que se montó  

1208             * originalmente la partición).
1209         */
1210         /*
1210             * Mounting a RDONLY partition read-write, so reread  

and
1210             * store the current valid flag. (It may have been  

changed
1210             * by e2fsck since we originally mounted the  

partition.)
1211         */
1212         sbi->s_mount_state = le16_to_cpu(es->s_state);
1212     //Se llama a ext2_setup_super para incrementar el número de montajes

```

```
//en "es" y guardar en disco
1213         if (!ext2_setup_super (sb, es, 0))
1214             sb->s_flags &= ~MS_RDONLY;
1215     }
Se actualiza el superbloque en disco con la función ext2_sync_super
1216     ext2_sync_super(sb, es);
1217     return 0;
1218restore_opts:
1219     sbi->s_mount_opt = old_opts.s_mount_opt;
1220     sbi->s_resuid = old_opts.s_resuid;
1221     sbi->s_resgid = old_opts.s_resgid;
1222     sb->s_flags = old_sb_flags;
1223     return err;
1224}
```

ext2_statfs

- ¿Qué hace?

Implementa la operación del sistema de ficheros `statfs`. Copia las estadísticas de uso del sistema de ficheros desde el descriptor del superbloque en la variable pasada por parámetro.

Calcula el tamaño de las cabeceras de un SB.

Lee la información del superbloque (número mágico, tamaño de bloque, número de bloque y número de bloques libres).

Almacena los datos en el buffer pasado por parámetro.

Código:

```
1226static int ext2_statfs (struct dentry * dentry, struct kstatfs * buf)
1227{
1228     struct super_block *sb = dentry->d_sb;
1229     struct ext2_sb_info *sbi = EXT2_SB(sb);
1230     struct ext2_super_block *es = sbi->s_es;
1231     u64 fsid;
1232
1233     if (test_opt (sb, MINIX_DF))
1234         sbi->s_overhead_last = 0;
1235     else if (sbi->s_blocks_last != le32_to_cpu(es->s_blocks_count))
1236     {
1237         unsigned long i, overhead = 0;
1238         smp_rmb();
1239
1240         /*
1241          * Calcula los bloques que ocupan los metadatos
1242          * estructuras del FS
1243          *
1244          */
1245     }
```

```
1246 * Todos los bloques anteriores a first_data_block son
1247 * los metadatos
1248 */
1249 overhead = le32_to_cpu(es->s_first_data_block);
1250 /*
1251 * Añade el superbloque y los grupos de bloques
1252 *
1253 *
1254 */
1255 for (i = 0; i < sbi->s_groups_count; i++)
1256     overhead += ext2_bg_has_super(sb, i) +
1257                 ext2_bg_num_gdb(sb, i);
1258 /*
1259 * Cada grupo de bloques tiene un bitmap de inodo,
1260 * un bitmap de bloque y una tabla de inodo.
1261 */
1262 overhead += (sbi->s_groups_count *
1263             (2 + sbi->s_itb_per_group));
1264 sbi->s_overhead_last = overhead;
1265 smp_wmb();
1266 sbi->s_blocks_last = le32_to_cpu(es->s_blocks_count);
1267 //Se lee información del sistema de ficheros a partir
1268 del superbloque En buf se almacena la salida
1269     buf->f_type = EXT2_SUPER_MAGIC;
1270     buf->f_bsize = sb->s_blocksize;
1271 //Bloque de datos(no metadatos)
1272     buf->f_blocks = le32_to_cpu(es->s_blocks_count) - sbi-
1273 >s_overhead_last;
1274 //Los bloques disponibles, no se cuentan los reservados para el
1275 //superusuario
1276     buf->f_bfree = ext2_count_free_blocks(sb);
1277     es->s_free_blocks_count = cpu_to_le32(buf->f_bfree);
1278     buf->f_bavail = buf->f_bfree - le32_to_cpu(es-
1279 >s_r_blocks_count);
1280     if (buf->f_bfree < le32_to_cpu(es->s_r_blocks_count))
1281         buf->f_bavail = 0;
1282     buf->f_files = le32_to_cpu(es->s_inodes_count);
1283     buf->f_ffree = ext2_count_free_inodes(sb);
1284     es->s_free_inodes_count = cpu_to_le32(buf->f_ffree);
1285     buf->f_nameflen = EXT2_NAME_LEN;
1286     fsid = le64_to_cpup((void *)es->s_uuid) ^
1287             le64_to_cpup((void *)es->s_uuid + sizeof(u64));
1288     buf->f_fsid.val[0] = fsid & 0xFFFFFFFFFUL;
1289     buf->f_fsid.val[1] = (fsid >> 32) & 0xFFFFFFFFFUL;
1290     return 0;
1291 }
```

ext2_init_ext2_fs

- ¿Qué hace?

Registra el sistema de ficheros EXT2.

Llama a la función register_filesystem.

Código:

```
1409 static int __init init_ext2_fs(void)
1410{
1411     int err = __init_ext2_xattr();
1412     if (err)
1413         return err;
1414     err = __init_inodecache();
1415     if (err)
1416         goto out1;
1417     err = register_filesystem(&ext2_fs_type);
1418     if (err)
1419         goto out;
1420     return 0;
1421 out:
1422     destroy_inodecache();
1423 out1:
1424     exit_ext2_xattr();
1425     return err;
1426}
```

17.6 Journaling

Para minimizar las inconsistencias en los sistemas de ficheros y minimizar a su vez el tiempo de arranque, los sistemas de ficheros Journaling mantienen un seguimiento de los cambios que se llevaran a cabo en el sistema de ficheros antes de que realmente se lleven a cabo. Estos registros se almacenan en una parte separada del sistema de ficheros, normalmente conocida como el “journal” (diario) o “log”. Una vez que los registros journal (también conocidos como registros “log”) se han escrito correctamente, el sistema de ficheros aplica esos cambios sobre al sistema de ficheros y después elimina esas entradas del registro journal correspondiente.

Los sistemas de ficheros journaling maximizan la consistencia del sistema de ficheros ya que los logs se escriben antes de que los cambios se vayan a realizar, almacenando esos registros hasta que los cambios hayan sido completados satisfactoriamente sobre el sistema de ficheros. Cuando reiniciamos un ordenador que utiliza un sistema de ficheros journaling, el programa de montaje puede garantizar la consistencia del sistema de ficheros simplemente buscando en el registro journal los cambios pendientes (sin acabar) y finalizarlos sobre el sistema de ficheros. En la mayoría de los casos, el sistema no tiene que comprobar la consistencia del sistema de ficheros, por lo que los ordenadores que utilicen un sistema de ficheros journaling estarán disponibles casi instantáneamente después del retrancarlos. También, la perdida de datos debido a inconsistencias en el sistema de ficheros se reduce drásticamente.

En el sistema Journaling se hace una analogía entre al concepto de base de datos SQL y el sistema de ficheros. El concepto es familiar para cualquiera que conozca como trabaja una base de datos SQL con la lógica de las transacciones. Dentro de esta lógica, “roll forward” se conoce al proceso de volver a ejecutar una operación que fue interrumpida y completarla y “roll back” al proceso de llevar a esa operación a su estado inicial. Esta metodología de trabajo que se desarrollo para prevenir la perdida de datos en las bases de datos SQL, es también extensible a la gestión de los sistemas de ficheros. Podríamos decir sin duda que este es el gran beneficio de los sistemas de ficheros Journaling.

Existen varios sistemas de ficheros journaling disponibles para el sistema operativo Linux. Los más conocidos son; el XFS –desarrollado por Silicon Graphics pero no es open source (código abierto), el ReiserFS –especialmente desarrollado para Linux, el JFS –originalmente desarrollado por IBM del cual se dispone actualmente una versión open source, y el sistema de ficheros ext3 –desarrollado por Stephen Tweedie en Red Hat con la colaboración de otros contribuidores.

17.7 Tercer sistema de ficheros extendido (Ext3)

Este nuevo sistema de ficheros ha sido diseñado con dos conceptos en mente:

Que sea un sistema de ficheros Journaling

Que sea todo lo compatible posible con el Ext2

El Ext3 consigue ambos objetivos muy bien. En particular, esta totalmente basado en el Ext2, por lo que las estructuras de disco son esencialmente idénticas. De hecho, si un sistema de ficheros Ext3 se desmonta limpiamente, puede volver a montarse como un sistema de ficheros Ext2. Al revés se puede hacer lo mismo; crear un sistema Journal a partir de un sistema de ficheros Ext2 remontándolo hasta conseguir un sistema de ficheros Ext3 es una operación sencilla y rápida.

Gracias a la compatibilidad entre el Ext3 y el Ext2, todo lo visto anteriormente para el Ext2 es totalmente aplicable al Ext3. Por lo que ahora simplemente nos vamos a centrar en las características propias del sistema journaling.

Sistema Journal para el Ext3

En un sistema de ficheros Ext2, actualizaciones en los bloques del sistema de ficheros se mantienen durante un tiempo en memoria dinámica antes de ser volcados en el disco. Un evento dramático, como un fallo en la corriente del sistema o un fallo en sí del sistema, puede hacer que el sistema se quede en un estado de inconsistencias. Para sobreponerse a este problema, cada sistema tradicional del Unix es chequeado antes de ser montado; si no es ha sido desmontado correctamente, un programa específico ejecuta un exhaustivo chequeo (que consume mucho tiempo) y corrige todas las posibles inconsistencias que encuentre en el sistema de ficheros a nivel de metadatos.

En el sistema de ficheros Ext2 el estado se almacena en el campo `s_mount_state` del superbloque del disco. La utilidad `e2fsck` es invocada por el script de arranque para chequear el valor almacenado en este campo; si no es igual a `EXT2_VALID_FS`, el sistema de fichero no se desmonta correctamente, y por lo tanto `e2fsck` comienza a chequear todas las estructuras de datos del sistema de ficheros del disco.

Claramente, el tiempo dedicado al chequeo de la consistencia del sistema de ficheros depende en gran medida del número de ficheros y directorios a examinar, y del tamaño del disco. Hoy en día, con sistemas de ficheros alcanzando los cientos de gigabytes, un simple chequeo de consistencia puede llevar horas.

La idea del Journaling Ext3 es realizar cualquier cambio de alto nivel en el sistema de ficheros en dos pasos. Primero, una copia de los bloques que serán escritos se almacena un Journal (diario); entonces, cuando la operación E/S de transferencia de los datos al Journal se completa (realizándose un *commit* sobre el Journal), los bloques se escriben en el sistema de ficheros. Cuando la operación de E/S de transferencia de datos al sistema de ficheros se completa (realizándose un *commit* sobre el sistema de ficheros), la copia de los bloques en el Journal se descartan.

Mientras se recupera de un fallo en el sistema, el programa `e2fsck` distingue dos casos:

El fallo en el sistema ocurrió antes de que se realizara un *commit* en el Journal. Por lo que, o las copias de los bloques relativos a los cambios se han perdido del Journal, o están incompletos; en ambos casos el e2fsck los ignora.

El fallo en el sistema ocurrió después de que se realizara el *commit* en el Journal. La copia de los bloques son válidos y el e2fsck los escribe en el sistema de ficheros.

En el primero de los casos, los cambios sobre el sistema de ficheros se han perdido, pero el estado del mismo es consistente. En el segundo de los casos, el e2fsck aplica todos los cambios previstos sobre el sistema de ficheros, arreglando cualquier inconsistencia debida a operaciones E/S de transferencia de datos inacabadas sobre el sistema de ficheros.

Un sistema de ficheros Journaling no guarda normalmente todos los bloques en el Journal. De hecho, existen dos tipos de bloques: aquellos que contienen los llamados metadatos del sistema de ficheros y los que contienen los datos en sí. De hecho, los registros log de los metadatos son suficientes para recuperar la consistencia de las estructuras del sistema de ficheros. De todas formas, si las operaciones sobre los bloques de un fichero de datos no se almacenan, nada previene que un fallo del sistema corrompa el contenido del mismo.

El Ext3 puede configurarse para que realice un seguimiento tanto en las operaciones que afectan a los metadatos como en aquellas que afectan a los bloques de datos de un fichero. Esto depende de cómo se haya montado el sistema de ficheros. Estos son los diferentes modos de Journal:

Journal

Todos los cambios en los datos y metadatos del sistema de ficheros se “logean” en el Journal. Este modo minimiza la posibilidad de perdida de las actualizaciones hechas sobre cada fichero, pero requiere muchos accesos adicionales a disco. Por ejemplo, cuando un fichero se crea, todos sus bloques de datos tienen que duplicarse como registros de log. Este es el método más seguro pero el más lento de los modos Journaling.

Ordered

Solo los cambios en los metadatos del sistema de ficheros se almacenan el Journal. De todas maneras, el Ext3 agrupa los metadatos y sus bloques de datos relacionados de manera que los bloques de datos sean escritos en disco antes que los metadatos. De esta manera, la posibilidad de tener datos corruptos en un fichero se reducen. Este es el método por defecto del Ext3.

Writeback

Solo los cambios en los metadatos del sistema de ficheros se almacenan el Journal. Este es el método más rápido, pero el más inseguro.

El modo Journaling se especifica en una opción del comando de montaje del sistema. Por ejemplo, para montar un sistema de ficheros Journaling en la partición /dev/hda1 en el punto de montaje /jdisk con el modo *writeback* será:

```
# mount -t ext3 -o data=writeback /dev/hda1 /jdisk
```

Capa del dispositivo de bloque Journaling (Journaling Block Device –JBD)

El Journal del Ext3 normalmente se almacena en el fichero oculto llamado *.journal* que se encuentra en el directorio root del sistema de ficheros.

El Ext3 no maneja el fichero journal por si mismo, si no que utiliza una capa superior del núcleo llamada dispositivo de bloque Journaling, o JBD. El Ext3 invoca a las rutinas del JBC para asegurarse que las sucesivas operaciones no corrompan las estructuras de datos en caso de fallo en el sistema. La interacción entre el JBD y el Ext3 se basa esencialmente en tres unidades principales:

Registros Log.- Describen la actualización sobre un bloque del sistema de ficheros Journaling.

Manejador de Operación Atómica.- Incluye los registros Log relativos a un cambio en el sistema de ficheros. Normalmente cada llamada al sistema que modifica el sistema de ficheros utiliza un único manejador de operación atómica.

Transacción.- Incluye varios manejadores de operación atómica. No es más que un conjunto de operaciones controladas por los manejadores de operación atómica correspondientes.

17.8 Sistema de ficheros ReiserFS

Una vez vistos los distintos tipos de sistemas Journaling, vamos hablar ahora un poco de uno de ellos, el sistema de ficheros ReiserFS. ReiserFS fue diseñado originalmente por Hans Reiser. La primera versión se lanzó a mediados de los 90, llegando a formar parte del núcleo en la versión 2.4.1 del mismo (ReiserFS v3.5). La versión 3.6 es el sistema de ficheros por defecto de las distribuciones SUSE, GENTOO y LINDOWS. La versión actual de prueba (testing) es la v4.

Las características principales del ReiserFS son:

Rápido, pero eficiente en la gestión del espacio.

10 veces más rápido que el Ext2

Sin penalización para ficheros pequeños

Fiable

Soporte Journaling

Compatible con la semántica de UNIX, pero Extensible a través de un sofisticado sistema de Plugins

En esencia, el sistema de ficheros ReiserFS es un sistema Journaling que trata a toda la partición del disco como si fuera una única tabla de una base de datos. Los directorios, ficheros y metadatos se organizan en una eficiente estructura de datos llamada “árbol balanceado”. Esto difiere bastante de la manera tradicional de trabajar de otros sistemas de ficheros, pero ofrece grandes mejoras de velocidad en

muchas aplicaciones, especialmente aquellas que utilizan gran cantidad de ficheros pequeños.

Leer y escribir en ficheros grandes, como imágenes de CDROM, normalmente está limitado por la velocidad del hardware implicado o por el canal de entrada / salida. Pero en cambio, los accesos a pequeños ficheros como los scripts de la shell están normalmente limitados por la eficiencia del sistema de ficheros. Esto es debido a que la apertura de un fichero requiere que primero el sistema localice el fichero, lo que implica la lectura del directorio en el que se encuentra. Despues, el sistema necesita examinar los metadatos para saber si el usuario tiene los permisos de accesos necesarios, lo conlleva una serie de lecturas adicionales del disco. En definitiva, el sistema pierde más tiempo decidiendo si permite el acceso al fichero que el tiempo que finalmente se tarda en obtener la información del mismo.

ReiserFS utiliza los árboles balanceados (Árboles B*) para racionalizar el proceso de la localización de los ficheros y la obtención de la información de los metadatos (y otro tipo de información adicional). Para ficheros extremadamente pequeños, toda la información del fichero puede físicamente almacenarse cerca de los metadatos, de manera que ambos pueden ser accedidos simultáneamente con un poco o nada de movimiento en el mecanismo de búsqueda del disco. Si una aplicación necesita abrir ficheros muy pequeños rápidamente, este planteamiento mejora el rendimiento significativamente.

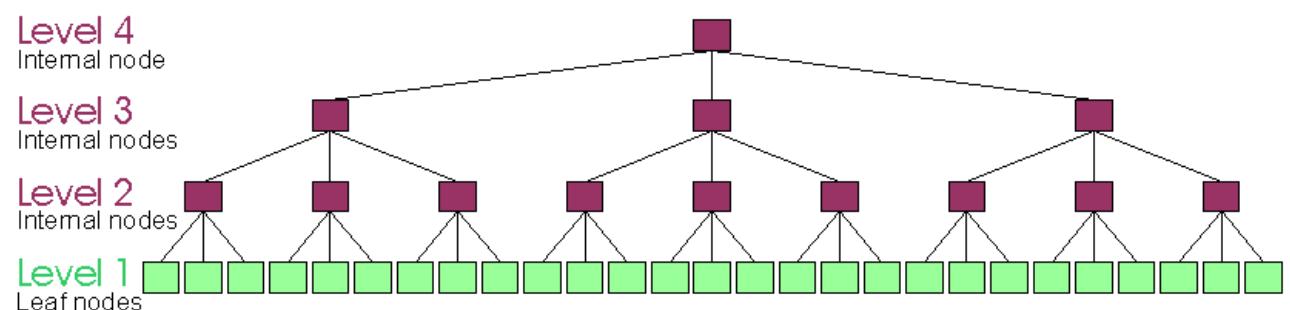


Figura 2 (Ejemplo de un de la estructura de árbol –Árbol B*)

Los nodos hojas (leaf nodes), almacenan los datos en sí, y no tienen hijos. Los nodos que contienen información se dice que están formateados. Solo los nodos hoja pueden estar no formateados. Los punteros se almacenan en nodos formateados por lo que los nodos intermedios (internal nodes) necesariamente tienen que estar formateados. El nodo raíz es de donde nace el árbol.

Otra característica de ReiserFS es que los árboles balanceados no solo almacenan metadatos, si que también almacenan los datos en sí. En un sistema de ficheros tradicional como el ext2, el espacio en disco se reparte en bloques de tamaño desde 512 bytes a 4096 bytes. Si el tamaño de un fichero no es múltiplo del tamaño de bloque habrá cierto espacio que se desperdiciara (fragmentación interna). Por ejemplo, supongamos un tamaño de bloque de 1024 bytes y un espacio requerido de 8195 bytes. 8192 bytes estarán almacenados en 8 bloques (8 x 1024), y los restantes 3 bytes se tendrán que ubicar en un bloque de 1024, desperdiaciéndose de

esta manera 1021 bytes. De los 9 bloques que se han tenido que asignar casi uno por completo se desperdicia, lo que representa un 11% del total solicitado (1 byte / 9 bytes). Ahora imaginemos un fichero de 1025 bytes. Casi cabe por completo en un solo bloque, pero requiere dos. El espacio desperdiciado es del 50% (1/2). El peor de los casos se da con ficheros muy pequeños, como un script muy trivial de una sola línea. Este fichero podría ser de unos 50 bytes, teniendo que ocupar un bloque completo. Si como hemos dicho, el tamaño de bloque es de 1024 bytes, el espacio desperdiciado será de un 95 % del espacio asignado. Como se puede ver, el espacio desperdiciado (en porcentaje) es menor cuanto mayor es el tamaño del fichero.

ReiserFS no utiliza el enfoque clásico de bloques a la hora dividir el espacio de disco, en vez de eso se apoya en la estructura arbórea para mantener un seguimiento de los bytes asignados. En ficheros pequeños, esto puede ahorrar como ya hemos dicho mucho espacio de almacenamiento. Es más, debido a que los ficheros tienden a colocarse cercanos unos de otros, el sistema es capaz de abrir y leer muchos ficheros pequeños con un único acceso físico al disco. Esto conlleva un ahorro de tiempo al disminuir el tiempo de búsqueda de la cabeza lectora del disco.

Algunas aplicaciones se benefician más que otras de este tipo de optimización. Imagínate un directorio con cientos de pequeños ficheros PNG o GIF que son utilizados como iconos en una página Web muy visitada. Esta situación está hecha a la medida del sistema de ficheros ReiserFS. Así como una página Web con miles de ficheros HTML, cada uno de unos poco kilobytes de tamaño, es un excelente candidato. Por otro lado, una partición de disco que almacena imágenes ISO9660 de CDROM, cada una de cientos de megabytes, vera poca mejora en su rendimiento con el ReiserFS. Como con otras muchas cosas en el mundo de la informática, el mejor rendimiento se obtiene a través de la selección de la herramienta que más se ajuste a las necesidades específicas del problema a resolver. (Nota: esto no significa que ReiserFS sea más lento que Ext2 a la hora de gestionar ficheros de gran tamaño, solo que no se notara mucha diferencia de rendimiento en esos casos.)

Para almacenar grandes ficheros, ReiserFS versión 3 utiliza el método BLOB (Binary Large OBject) que desbalanceaba el árbol reduciendo así el rendimiento. En este método se almacenan (en los nodos hoja formateados) punteros a nodos que contienen el fichero en su conjunto (como muestra la imagen). De manera que desbalancea al árbol.

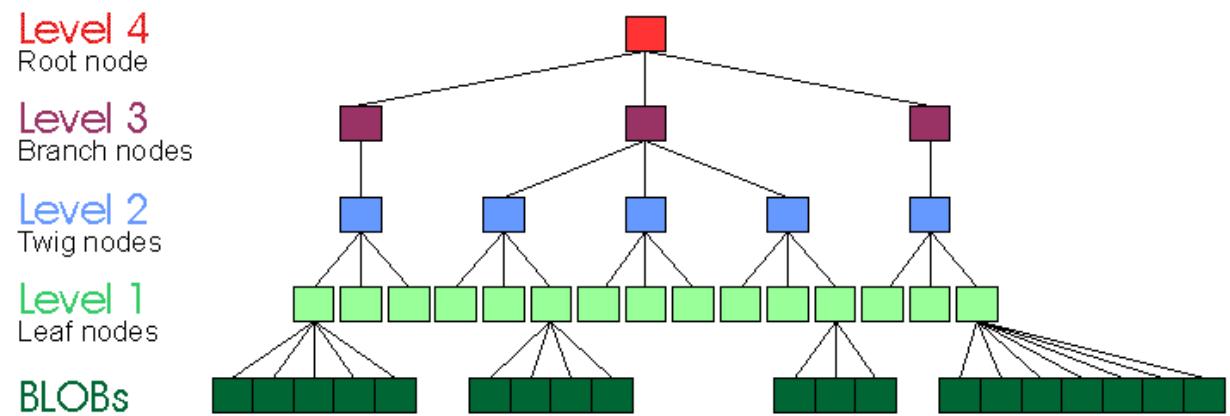


Figura 3 (Árbol B* no balanceado de ReiserFS v3)

En la versión 4 de ReiserFS se intenta solucionar este problema haciendo que todos los punteros a ficheros se almacenen en el mismo nivel.

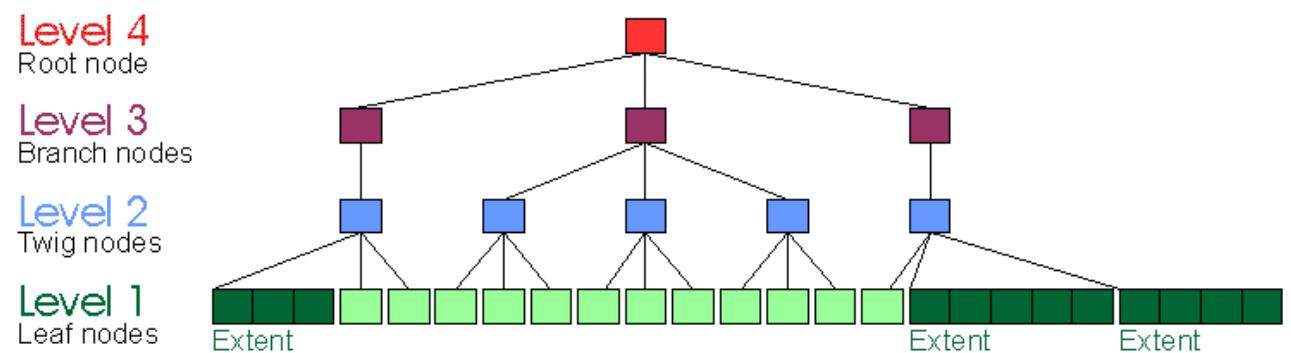


Figura 4 (Árbol B* balanceado de ReiserFS v4, inclusión de nodos Twig, Branch y punteros Extendidos)

Los nodos Twig, son los padres de los nodos hojas. Los nodos Branch son nodos internos que no son Twig. En ReiserFS, los nodos Twig no solo apuntan a nodos hoja, sino que también apuntan a nodos Extendidos (Extended nodes). De esta manera se mantiene al árbol balanceado, almacenando los ficheros pequeños en nodos hoja y los grandes en nodos a través de punteros extendidos.

Otra característica destacable del ReiserFS es la utilización de *Plugins*, lo que permite la adaptación del sistema de ficheros a nuevas características sin la necesidad de formateo. Los *Plugins* trabajan de forma independiente sobre el núcleo del sistema de ficheros. Todas las operaciones se implementan en Plugins, por lo que permite que se modifique la funcionalidad del sistema de ficheros (añadiendo o eliminando Plugins existentes) sin necesidad de modificar el núcleo.

Por encima de todo, ReiserFS es un verdadero sistema de ficheros Journaling como el xfs, el Ext3 y el JFS de IBM. Cada uno de estos sistemas de ficheros implementan a su manera las características Journaling, pero los efectos son los mismos: una

muy buena fiabilidad y una velocidad muy rápida de recuperación después de un apagado inadecuado. Esta es la principal ventaja de un sistema de ficheros Journaling contra otro tradicional.

Bibliografía

The Linux Kernel Book. Rémy Card, Éric Dumas y Frank Mével

[Tanenbaum 1987] A. Tanenbaum. Operating Systems: Design and Implementation. Prentice Hall, 1987.

[Bach 1986] M. Bach. The Design of the UNIX Operating System. Prentice Hall, 1986.

[McKusick et al. 1984] M. McKusick, W. Joy, S. Leffler, and R. Fabry. A Fast File System for UNIX. ACM Transactions on Computer Systems, 2(3):181--197, August 1984.

Arbol de funciones

