

簡易ジャーナリング機能付き ファイルシステムの自作

演習 III 第 2 期 — 最終発表

内容

ファイルシステムとは	3
ファイルシステムの処理	8
ジャーナリングの仕組み	17
デモ	26

演習 III で取り組んだこと

- 簡易的ジャーナリング付きファイルシステムの自作
 - CTF の Linux カーネル問で頻出のカーネルモジュールを触ってみたかった。
 - ファイルのバイナリ構造を見るのが好き
 - 今まで解読したことがあるもの：BMP, GIF, EXT4(少し)

ファイルシステムとは


ファイルシステムの役割

- ストレージデバイス上のデータレイアウトを管理する。
 - ▶ ディレクトリの木構造とストレージの直列構造を効率良く変換する
 - ▶ デバイスへの書き込み途中でエラーが発生しても、データの整合性を保つ (→ ジャーナリング)
 - ▶ 例) EXT4, NTFS, BTRFS, FAT32, ...

ファイルシステムの実現方法

- 主要なファイルシステムは OS に組み込まれている。
 - ▶ `$ cat /proc/filesystems` で使用可能なファイルシステム一覧を確認できる。
 - ▶ Linux ではカーネルモジュールとして動的に追加することもできる。

ファイルシステムの階層



何を作ったか

ブロックデバイス上に構築する、Unix 風の小さなファイルシステム **LLFS** を実装した。

実装した機能


- inode での管理をベースとしたファイル/ディレクトリ構造
 - ▶ lookup, create, read/write など簡単なもののみ
- ビットマップによる空きブロック・空き inode の管理
- ジャーナリング（2 段階書き込み）
- クラッシュ後の自動回復

目標は、書き込みの途中で電源が落ちても **ファイルシステムが壊れない** こと。これをジャーナル（先行書き込みログ）で保証する。

ファイルシステムの処理

ディスクレイアウト

ディスク先頭から、メタ情報・ジャーナル・データの順に領域を固定配置する。



通常書き込みは、まず Journal 領域に記録してから本来の位置へ反映する。ここが今回の肝になる。

スーパーブロック：構造体の定義

ファイルシステム全体の情報が格納される領域。

```
1  struct llfs_super_block {
2      __le32 magic;           // Magic number ("LLFS")
3      __le32 block_size;      // Size of one block
4      __le32 itable_block;    // Block number of inode table
5      __le32 inode_bitmap_block; // Block number of inode bitmap
6      __le32 block_bitmap_block; // Block number of block bitmap
7      __le16 inode_size;      // Inode size (64 in llfs)
8      __le16 pad;
9      __le32 journal_block;    // [JOURNAL] Top block number of journal area
10     __le32 journal_blocks;    // [JOURNAL] Number of blocks of journal area
11 };
```



inode：ファイル 1 個のメタデータ

ファイルやディレクトリのメタデータを格納する。本演習では直接ブロックのみ対応した。

```
1  #define LLFS_N_BLOCKS 13
2
3  struct llfs_inode {
4      __le16 mode;           // File mode
5      __le16 uid;           // Owner Uid
6      __le32 size;          // File size in bytes
7      __le32 blocks;        // Blocks count
8      __le32 block[LLFS_N_BLOCKS]; // Pointers to blocks
9  };
10
11 struct llfs_itable {
12     struct llfs_inode table[];
13 };
```

dir_entry

ディレクトリの中身。子ファイルや子ディレクトリの一覧を保持

```
1 struct llfs_dir_entry {
2     __le32 inode;    // Inode number
3     __le16 rec_len;  // Entry length
4     __u8 name_len;   // Filename length
5     __u8 file_type;  // File type
6     char name[];     // File name
7 };
```

```
1 // $ hexdump -C vdisk.img
2 // ルートディレクトリデータ
3 ...
4 00007000  01 00 00 00 0c 00 01 02  2e 00 00 00 01 00 00 00  |.....|
5 00007010  0c 00 02 02 2e 2e 00 00  02 00 00 00 14 00 0a 01  |.....|
6 00007020  65 6d 70 74 79 2d 66 69  6c 65 00 00 03 00 00 00  |empty-file.....|
7 00007030  10 00 05 01 68 65 6c 6c  6f 00 00 00 00 00 00 00  |...hello.....|
8 00007040  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |.....|
9 ...
```

mount 時の処理

- モジュールロード時
 - ▶ `register_filesystem()`: 自身をファイルシステムとして登録
- mount 時
 1. ルート i ノードの情報を VFS に渡す
 2. ジャーナルログ領域を見て必要があれば回復

lookup 時の処理

VFS からパスが与えられて、ファイルが存在するかしないか、存在するならその情報を返す。

0. 親ディレクトリの i ノードと、探したいファイル名が渡される
1. 親ディレクトリの `dir_entry` を見に行って、探索
 - 探索アルゴリズムが重要(LLFS では線形探索)
2. ファイル名に合致するエントリが見つかったら、対応する i ノードを見に行って情報を VFS に返す

create 時の処理

0. 親ディレクトリと、作りたいファイルのファイル名やその他の情報(ファイル権限など)が渡される
1. 新規ファイルに割り当てるための空き i ノード番号を取得する
2. i ノードテーブルに書き込み
3. 親ディレクトリの dirent を更新

(open)/read/write 時の処理

iomap という API を使って処理：i ノード情報と論理ブロック番号をもらって、物理ブロック番号を返すような関数を設定する。

1. i ノードテーブルのブロックテーブルを見に行く
2. すでにブロックが割り当てられていたら、その物理ブロック番号を返す
3. ブロックが割り当てられていなかったら、
 - read の場合は穴(HOLE)として報告する
 - write の場合は、空きブロックを確保して、それを返す。同時に i ノードブロックも更新

iomap のうれしいところ：

論理ブロックや物理ブロックの対応関係を VFS に渡してあげれば、読み書きは VFS が勝手に制御してくれる。

ジャーナリングの仕組み

なぜジャーナルが要るのか

1 回のファイル操作は、複数ブロックの更新に分解される。

更新の途中でクラッシュすると…

ブロックは確保してある(ブロックビットマップを更新済み)なのに、iノードテーブルが更新されていないため、使われないブロックが生まれる可能性

解決策：Write-Ahead Logging (WAL)

本来の場所を書き換える前に、「これからやる更新一式」をジャーナルへ先に書いておき、途中で落ちても再起動時にジャーナルを見ればやり直せる。

トランザクションの処理

1. ログ領域に書き込み
2. 最後に書き込み完了フラグを立てる
3. 本物の領域に書き込み
4. 書き込みが終わったらログを無効にする

境界は「コミット」

書き込み完了フラグが書けた瞬間に、その更新を「確定」とみなす。2.未満で落ちた更新は捨て、2.以上で落ちた更新は次回の mount 時に 3.をやり直す。

コミット処理(create 編)

変更ログを保持しておき、最後に書き込みをする。

```
1  /* A. 旧 commit ブロックを無効化(seq 再利用による torn-commit 誤検出を防ぐ)。  
2  *   これ以降クラッシュしても commit magic は無効なので「未コミット」と判定される。 */  
3  bh = sb_bread(sb, commit_off);  
4  if (!bh)  
5      goto fail;  
6  memset(bh->b_data, 0, sb->s_blocksize);  
7  jwrite_sync(bh);  
8  brelse(bh);  
9  jbarrier(sb);
```



```
1  /* B. descriptor を書く(magic, seq, n, target[]) */
2  bh = sb_bread(sb, jb);
3  if (!bh) goto fail;
4  memset(bh->b_data, 0, sb->s_blocksize);
5  desc = (struct llfs_jrnl_desc *)bh->b_data;
6  desc->magic = cpu_to_le32(LLFS_JRNL_DESC_MAGIC);
7  desc->sequence = cpu_to_le32(seq);
8  desc->n_blocks = cpu_to_le32(n);
9  for (i = 0; i < n; i++)
10     desc->target[i] = cpu_to_le32(t->target[i]);
11  jwrite_sync(bh);
12  brelse(bh);
13
14  /* C. data ブロック(変更後のメタを丸ごとジャーナルへコピー) */
15  for (i = 0; i < n; i++) {
16     struct buffer_head *jbh = sb_bread(sb, jb + 1 + i);
17     if (!jbh)
18         goto fail;
19     memcpy(jbh->b_data, t->bh[i]->b_data, sb->s_blocksize);
20     jwrite_sync(jbh);
21     brelse(jbh);
22 }
```



```
1      /* D. — BARRIER — descriptor + data を確実に永続化 */
2      jbarrier(sb);
3
4      /* E. commit ブロックを書く ← ★コミット点★ */
5      bh = sb_bread(sb, commit_off);
6      if (!bh)
7          goto fail;
8      cmt = (struct llfs_jrnl_commit *)bh->b_data;
9      cmt->magic = cpu_to_le32(LLFS_JRNL_COMMIT_MAGIC);
10     cmt->sequence = cpu_to_le32(seq);
11     jwrite_sync(bh);
12     brelse(bh);
13     jbarrier(sb);
14
15     /* F. チェックポイント: ここで初めて最終位置(in-place)へ反映する */
16     for (i = 0; i < n; i++) {
17         mark_buffer_dirty(t->bh[i]);
18         sync_dirty_buffer(t->bh[i]);
19     }
20     jbarrier(sb);
```



```
1      /* G. ジャーナルをクリア(次回マウントで replay されないように) */
2      bh = sb_bread(sb, jb);
3      if (!bh)
4          goto fail;
5      desc = (struct llfs_jrnl_desc *)bh->b_data;
6      desc->magic = 0;
7      jwrite_sync(bh);
8      brelse(bh);
9      jbarrier(sb);
10
11     /* H. pin を解放してトランザクションを破棄 */
12     for (i = 0; i < n; i++)
13         brelse(t->bh[i]);
14     sbi->cur_txn = NULL;
15     kfree(t);
16     return 0;
```



クラッシュからの回復

mount 時にジャーナルを走査し、フラグが立っているトランザクションだけを再適用する。

```
1 // マウント時に必ず呼ぶ
2 int llfs_journal_recover(struct super_block *sb) {
3     ...
4     n = le32_to_cpu(desc->n_blocks);
5     seq = le32_to_cpu(desc->sequence);
6
7     if (le32_to_cpu(cmt->magic) != LLFS_JRNL_COMMIT_MAGIC ||
8         le32_to_cpu(cmt->sequence) != seq) {
9         /* 未コミット(torn write)→ 破棄。in-place は手付かずなので旧状態で一貫。 */
10        ...
11        return 0;
12    }
```



```
1  /* コミット済み → redo(同一内容の上書きなので幂等) */
2  for (i = 0; i < n; i++) {
3      u32 target = le32_to_cpu(desc->target[i]);
4      struct buffer_head *src = sb_bread(sb, jb + 1 + i);
5      struct buffer_head *dst;
6
7      ...
8
9      memcpy(dst->b_data, src->b_data, sb->s_blocksize);
10     mark_buffer_dirty(dst);
11     sync_dirty_buffer(dst);
12     brelse(dst);
13     brelse(src);
14 }
15 jbarrier(sb);
```



デモ

まとめ

できたこと

- inode ベースの小さなファイルシステム
- 簡易的なジャーナリングシステム

今後の課題

- ls, remove, mkdir などへの対応
- B 木ベースのファイルシステム
 - Copy on Write をやりたかった
- FUSE (Filesystem in Userspace)
 - ファイルシステムが落ちるとカーネル全体が落ちるのは危ない