

GearsOS の分散ファイルシステムの設計

一木貴裕^{a)} 河野 真治^{b)}

概要: 本研究室では gear というプログラミング概念を持つ、分散フレームワーク Christie を開発している。Christie はノード同士が Datagear と呼ばれる変数データを送信しあうことにより、簡潔に分散プログラムの記述を行うことができる。この Christie の仕組みを、同様に本研究室が開発している GearsOS に組み込み、ファイルシステムを構築したい。GearsOS はノーマルレベルとメタレベルを分けて記述できる Continuation based C(CbC) で構成されており、Christie と近い仕様をもつ。

Designing a Distributed File System for GearsOS

1. GearsOS のファイルシステムの開発

当研究室では OS の信頼性の検証を目的とした OS である GearsOS を開発している。GearsOS はユーザレベルとメタレベルを分離して記述が行える言語である Continuation based C(以下 CbC) で記述されており、Gear というプログラミング概念を持つ。

GearsOS は現在開発途上であるため、現在は言語フレームワークとしてしか動作しない。OS として起動するためにこれから実装が必要な機能が多く存在しており、その中の一つとして分散ファイルシステムが挙げられる。GearsOS の分散ファイルシステムを構成するために、当研究室が開発している分散フレームワーク Christie の仕組みを用いようと考えた。

Christie は GearsOS のもつ Gear という概念とよく似た、別の Gear というプログラミング概念を持っており、DataGear と呼ばれる変数データを接続されたノード同士が送信しあうことで分散処理を簡潔に記述することができる。DataGear は指定された型と名前を持つ key に対応しており、プログラムが必要な key にデータが揃ってから初めてプログラムが処理される。また、Christie は Topology-Manager と呼ばれる機能を持っており、任意の形でノード同士の配線を行い Topology を形成する機能を持っている。

GearsOS の分散処理の記述方式として Christie の仕組みを取り入れることにより、分散ファイルシステムを構成したい。

2. UNIX ファイルシステムについて

UNIX ファイルシステムは UNIX 系 OS を始めとした多くの OS のファイルシステムの大元となっている。

UNIX ファイルシステムではファイルに構造を持たず、カーネルがファイルを単純なバイト配列とみなして処理が行われ、ファイルの実際の取り扱いはプログラムが判断する。ユーザの視点ではファイルを取り扱う際に、OS レベルの観点からファイルを構成する必要がなく、ファイルの拡張子を任意のアプリケーションに適したものにすれば良い。全てのファイルは i-node と呼ばれるユニークな番号をもち、ファイルのメタデータは全て i-node 内に格納されている。i-node はファイルの探索の際などに用いられ、ユーザは stat() と呼ばれるシステムコールにより共通的にファイル情報を得ることができる。

また、UNIX は階層型の仮想ファイルシステムを搭載している。ネットワークを経由してファイルシステムにアクセスする際は、木構造に構成されたディレクトリ Tree にリモート先のファイルシステムをマウントすることにより参照することができる。

UNIXbase のファイルシステムを比較・検討をしながら GearsOS を構成していく。

¹ 情報処理学会
IPSI, Chiyoda, Tokyo 101-0062, Japan

¹¹ 現在、琉球大学理工学研究科情報工学専攻
Presently with Johoshori University

^{a)} ikki-tkhr@cr.ie.u-ryukyu.ac.jp

^{b)} kono@ie.u-ryukyu.ac.jp

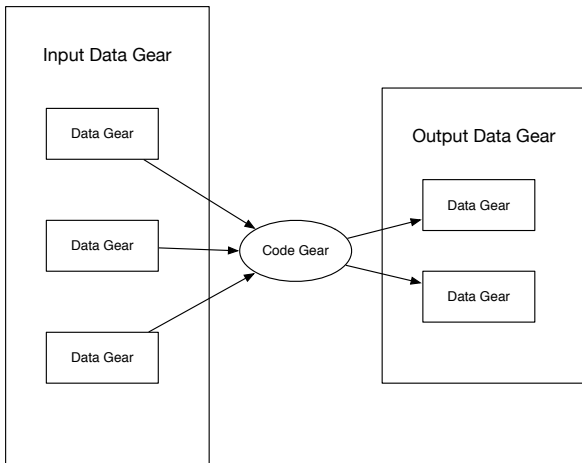


図 1: CodeGear と入出力の関係図




図 2: CodeGear と MetaCodeGear の関係図

```

proc->cbc_arg.cbc_console_arg.num = num;
goto (cbccodes[num])(cbc_ret);
}
    
```

Code 1: CbC を利用したシステムコールのディスパッチ

Code1 の状態遷移図を図 1 に示す。図中の `cbc_read` などは、`read` システムコールを実装している CodeGear の集合である。

3. Continuation based C

GearsOS は C 言語の下位言語である Continuation based C を用いて記述されている。CbC は関数呼び出しでなく、継続を導入しており、スタック領域を用いず `jmp` 命令でコード間を移動することにより軽量な継続を実現している。CbC ではこの継続を用いて `for` 文などのループの代わりに再起呼び出しを行う。実際の OS やアプリケーションを記述する際には GCC または LLVM/clang の CbC 実装を用いる。

CbC では関数の代わりに CodeGear という単位でプログラミングを行う。CodeGear は `_code` で宣言を行い、各 CodeGear は DataGear と呼ばれる変数データを入力として受け取り、その結果を別の DataGear に書き込む。特に入力の DataGear を InputDataGear、出力される DataGear を OutputDataGear と呼ぶ。CodeGear と DataGear の関係図を図 1 に示す。CodeGear は関数呼び出しのスタックを持たないため、一度 CodeGear を遷移すると元の処理に戻ってくることができない。

CbC コードの例をソースコード 1 に示す。この例題では特定のシステムコールの場合、CbC で実装された処理に `goto` 文をつかって継続する。例題では CodeGear へのアドレスが配列 `cbccodes` に格納されている。引数として渡している `cbc_ret` は、システムコールの戻り値の数値をレジスタへ代入する CodeGear である。実際に `cbc_ret` に継続が行われるのは、`read` などのシステムコールの一連の処理の継続が終わったタイミングである。

```

void syscall(void)
{
    int num;
    int ret;

    if((num >= NELEM(syscalls)) && (num <= NELEM(
        cbccodes)) && cbccodes[num]) {
    
```

4. CbC を用いた OS の記述

CodeGear の遷移はノーマルレベルから見ると単純に CodeGear が DataGear を Input, Output を繰り返し、コードブロックを移動しているように見える。CodeGear が別の DataGear に遷移する際の DataGear との関係性を図 2 に示す。ノーマルレベルでは DataGear を受け取った CodeGear を実行、実行結果を DataGear に書き込み別の CodeGear に継続していると見える。

しかし、実際には CodeGear から別の CodeGear への遷移にはデータの整合性の確認などのメタ計算が必要となる。コード間の遷移に必要なメタ計算は、MetaCodeGear と呼ばれる CodeGear ごとの実装された CodeGear で行う。MetaCodeGear で参照される DataGear を MetaDataGear と呼び、また、CodeGear の直前に実行される MetaCodeGear を StubCodeGear と呼ぶ。これらメタ計算部分を含めた CodeGear の遷移と DataGear の関係性を図示すると図 2 の下段の形に表せる。CodeGear の実行前後に実行される MetaCodeGear や入出力の DataGear を MetaDataGear から取り出すなどのメタ計算が加わる。

MetaCodeGear は詳細な処理の変更や、スクリプトに問題がある場合を除き、プログラマが直接実装する必要がなく、GearsOS が持つ Perl スクリプトにより、GearsOS がビルドされる際に生成される。

CodeGear の遷移に重要な役割を持つ MetaDataGear として context が存在する。context は遷移先の CodeGear と MetaDataGear の紐付けや、計算に必要な DataGear の保存や管理を行う。加えて context は処理に必要な CodeGear の番号と MetaCodeGear の対応表や、DataGear の格納場所を持つ。context と各データ構造の役割を図 3 に示す。計算に必要なデータ構造と処理を持つデータ構造であることから、context は従来の OS のプロセスに相当し、ユーザープログラムごとに context が存在している。




図 3: Context を介した CodeGear の継続




図 4: RemoteDataGear と接続ノードの関係図

5. 分散フレームワーク Christie

Christie は当研究室で開発されている java 言語で記述された、分散フレームワークである。Christie は CbC と似ているが異なる仕様を持つ Gear というプログラミング概念を持つ。

- CodeGear (以下 CG)
- DataGear (以下 DG)
- CodeGearManager (以下 CGM)
- DataGearManager (以下 DGM)

CodeGear はクラスやスレッドに相当する。DataGear は変数データであり、CodeGear 内で java のアノテーションを用いて記述する。DataGear は Key と必ず対応しており、put という処理により CG 内の全ての Key に DataGear が揃った際に初めて CG が動作するという仕組みになっている。

CodeGearManager はいわゆるノードに相当し、CodeGear, DataGear, DataGearManager を管理する。複数の CodeGearManager 同士が配線され、DG を送信し合うことで分散処理を実現している。

DataGearManager は DG を管理しているもので変数プールに相当し、CGM が利用する CG の key と put されたデータの組み合わせを所持している。DataGearManager は Local と Remote に区別することができ、LocalDGM は CGM 自身が所持する DG のプールであり、Local に put することにより自身の持つ key に DG を送ることができる。対する RemoteDataGearManager は CGM が配線されている別の CGM が持つ DG のプールである。つまり、任意の接続された RemoteDGM に DG を put すると、対応した CGM(ノード) が持つ DGM の pool に DG が送信される。RemoteDGM に DG を put する処理が分散処理の肝となっている。RemoteDataGearManager の仕組みを図 4 に示す。

Christie の要となる DataGear の key は java のアノテーション機能が使われている。アノテーションには以下の 4 つが存在する。

Take 先頭の DG を読み込み、その DG を削除する。DG が複数ある場合、この動作を用いる。

Peek 先頭の DG を読み込むが、DG が削除されない。そ

のため、特に操作をしない場合は同じデータを参照し続ける。

TakeFrom(Remote DGM name) Take と似ているが、Remote DGM name を指定することで、その接続先 (Remote) の DGM から Take 操作を行える。

PeekFrom(Remote DGM name) Peek と似ているが、Remote DGM name を指定することで、その接続先 (Remote) の DGM から Peek 操作を行える。

5.1 Christie のサンプルコード

コード 2, 3 は Christie で記述した Hello World のプログラムである。ユーザープログラムは StartCodeGear クラスを継承したクラス (コード 2) から開始する。CodeGearManager はポート番号を指定した上で creatCGM メソッドを呼び出すことにより生成される。生成された CodeGearManager は CGM 名.setup にて CGM に処理させたいスレッド、つまり CodeGear を持たせることができる。

コード 3 は HeloWorldCodeGear の記述である。HelloWorldCodeGear では key: helloWorld に put された文字列を print 出力するという単純な処理を記述している。CGM 名.getLocalDGM().put("Keyname", 変数データ) にて key に変数データを紐付け (put し)、CodeGear に設定されている全ての key がデータを受け取った際に初めて CodeGear は処理される。HelloWorldCodeGear では String 型の helloWorld という key が Take 型で設定されている。

```
public class StartHelloWorld extends StartCodeGear {

    public StartHelloWorld(CodeGearManager cgm) {
        super(cgm);
    }

    public static void main(String[] args){
        CodeGearManager cgm = createCGM(10000);
        cgm.setup(new HelloWorldCodeGear());
        cgm.getLocalDGM().put("helloWorld","hello");
        cgm.getLocalDGM().put("helloWorld","world");
    }
}
```

Code 2: Christie における CGM と CG の setup

```
public class HelloWorldCodeGear extends CodeGear {
    @Take
    String helloWorld;

    @Override
    protected void run(CodeGearManager cgm) {
        System.out.print(helloWorld + "\n");
        cgm.setup(new HelloWorldCodeGear());
    }
}
```

Code 3: HelloWorldCodeGear

5.2 TopologyManager

Christie には Topology を形成するための機能 Topology-Manager が備わっている。Topology に参加するノードに対して名前を与え、必要とあればノード間の配線を行う。

TopologyManager の Topology 形成方法として静的 Topology と動的 Topology がある。静的 Topology はプログラマが任意の形の Topology とノードの配線を dot ファイルに記述し、TopologyManager に参照させることで自由な形の Topology が形成できる。現時点では静的 Topology での Topology 形成は dot ファイルに記述した参加ノード数に実際に参加するノードの数が達していない場合、動作しないという制約が存在している。動的 Topology は参加を表明したノードに対し、自動的にノード同士の配線を行う。例えば Tree を構成する場合、参加したノードから順番に root から近い役割を与える。

6. Gear を用いたファイルシステムの構成

Christie の分散ファイルシステムを WordCount 例題を通して構築する。WordCount 例題とは指定したファイルの中身の文字列を読み取り、文字数と行列数、加えて文字列を出力するという例題である。CbC で記述した場合の WordCount プログラムの遷移図を示した図を図??に示す。WordCount の例題は大きく分けて、指定した名前のファイルを File 構造体として Open する FileOpen スレッド、ファイル構造体を受け取り文字列 (word) を表示し文字数 (bytes) と行数 (lines) を CountUp する WordCount スレッドの二つの CodeGear で記述することができる。図??で示した WordCount の遷移図は File をオープンした CG と WordCount の CG を巡回することにより、

3 5 6

```
#include <stdio.h>
#impl UnixFileImp as "UnixFileImpl.h"

File* createUnixFileImpl(struct Context* context) {
```




図 5: WordCount with CbC

```
File *file = new File();
file->FileImpl = (union Data*)new FileImpl();
return file;
}

readBlock(UnixFileImpl* file) {
    Block *block = new Block();
    int len = read(fd, BUFSIZE, block->data);
    block->eof &= ~BLOCK_FLAG_EOF;
    if (len <= 0) {
        block->eof |= BLOCK_FLAG_EOF;
        close(file->fd);
    }
    return block ;
}

__code unixOpen(UnixFileImpl* file,Key *key, __code
next(Block *block,...));
file->fd = open(key->path,unix_mode(key->modde));
if (fd < 0) {
    goto error("can't open");
}
goto next(readBlock(file), ...);
}

__code uniAck(UnixFileImpl* file,Ack *ack, __code
next(Block *block,...));
if (!ack->isOk) {
    close(file->fd);
    goto next(...);
}
goto next(readBlock(file), ...); // file is
automatically put into local dataGearManger/
input
}
```

Code 4: UnixFileImpl.cbc

```
#include ".././././context.h"
#include <stdio.h>
#impl "Wc.h" as "WcImpl.h"
#interface "WcResult.h"

Wc* createWcImpl(struct Context* context) {
    Wc *wc = new Wc();
    wc->wc = (union Data*)new WcImpl();
    wc->bytes = 0;
    wc->words = 0;
    wc->lines = 0;
    return wc;
}

__code take(Impl* wc, Block *block,__code next(Ack *
ack, ...),__code finish(StdData *result,...) {
    if (isEof(block->eof)) {
        result.buffer = new Buffer(1);
```

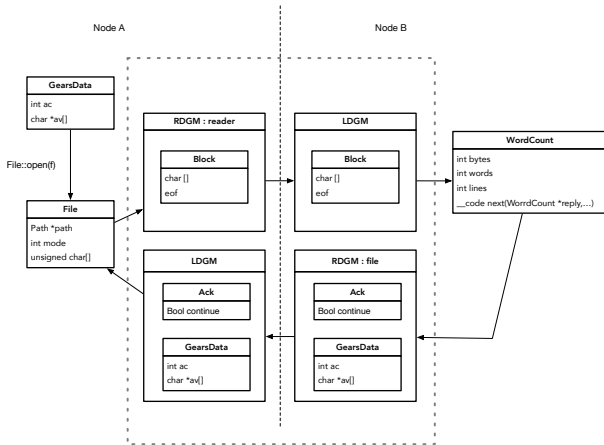
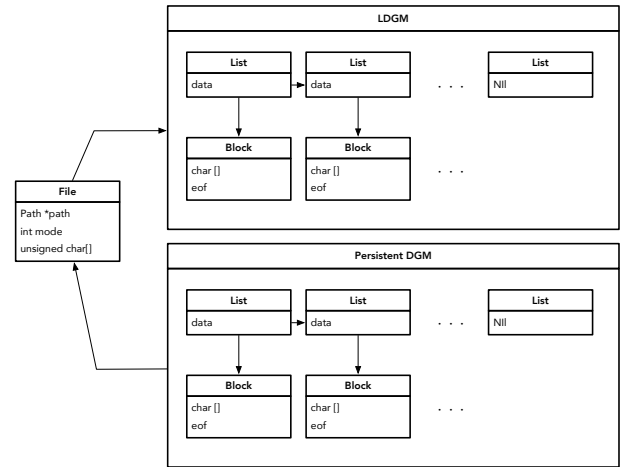


図 6: WordCountDGM with Christie



SSD/NVme/MRAM/HDD

図 8: file Persistenceency

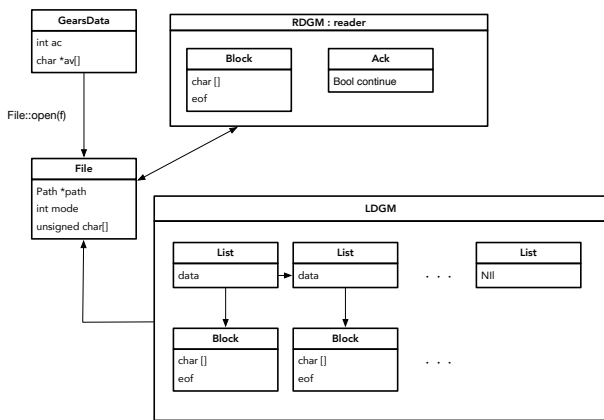


図 7: file Implementation

参考文献

- [1] 赤堀 貴一, 河野真治: Christie によるブロックチェーンの実装. 琉球大学工学部情報工学科卒業論文 2019.
- [2] 照屋 のぞみ, 河野真治: 分散フレームワーク Christie の設計. 琉球大学理工学研究科修士論文 2018.
- [3] 清水 隆博, 河野真治: xv6 の構成要素の継続の分析. OS 研究会 2019.
- [4] 清水 隆博, 河野真治: 継続を基本とした言語による OS のモジュール化. 琉球大学理工学研究科修士論文 2020.
- [5] 清水 隆博, 河野真治: 継続を基本とした言語による OS のモジュール化. 琉球大学理工学研究科修士論文 2020.

```

result.buffer->data = new Byte(BUSIZE);
result.size = 1;
result.buffer->size =
    sprintf(result.buffer[0]->data, "%d_%d_%d
    \n", wc->bytes, wc->words, wc->lines);
goto finish(resut);
}
for(size_t i = 0 ; i<block->size; i++) {
    if (block->data[i] == '\n') wc->lines++;
    if (block->data[i] == ' ') {
        wc->words++;
        while(block->data[i] == ' ') {
            if(i>=block->size)
                goto next(ack,take);
            i++;
            wc->bytes++;
        }
    }
    wc->bytes++;
}
goto next(ack,take);
}
}

```

Code 5: WcImpl.cbc