

I441 2013/07/30
ネットワークプログラミング
ー システムコール中心に ー

知念

北陸先端科学技術大学院大学 高信頼ネットワークイノベーションセンター
Dependable Network Innovation Center,
Japan Advanced Institute of Science and Technology

アウトライン

前回

- システムコールの流れ
- 並行サーバ
 - ◇ マルチプロセス
 - ◇ 非同期 I/O

今回

- 非同期コネクション
- エラーハンドリング
- 共有メモリ、等々

性能向上のヒント

- コンテキストスイッチを削減
 - ◇ 繰り返しサーバと並行サーバの混合
fork/pthread_create の発生を軽減する
- 潜在的な待ち時間を削減 — ブロック回避・軽減
 - ◇ 非同期 I/O
ブロックするシステムコールを呼ぶ前に受信・送信可能かどうか確認
 - ◇ 非同期コネクション（次ページ）
システムコールでブロックしないようにする

非同期コネクション、ノンブロッキング

- ブロックしない、即座に返ってくる技法
- ノンブロッキングでは戻り値で成否確認できない
 - ◇ 成否の確定を待たないのだから当然
 - ◇ `errno` に `EAGAIN` や `EINPROGRESS` が入る
- 具体的な切り替えは `fcntl` で

```
fd = socket(...);  
opt = O_NONBLOCK;  
ik = fcntl(fd, F_SETFL, opt);
```

非同期コネクション、ノンブロッキング (*cont.*)

現在値を引き継いで切り替えると無難
他の属性を破壊しない

```
fd = socket(...);  
opt = fcntl(fd, F_GETFL, 0);  
opt |= O_NONBLOCK;  
ik = fcntl(fd, F_SETFL, opt);
```

XOR で戻す

```
opt = fcntl(fd, F_GETFL, 0);  
opt ^= O_NONBLOCK;  
ik = fcntl(fd, F_SETFL, opt);
```

空回り防止・回避

システムコールでブロックしなくなると...

- 無闇に空回りするプログラムになることも

```
while(1) {  
    nr = read(fd, buf, BUFSIZ);  
}
```

通称 *busy loop*、CPU を浪費するので極力避ける
対策

- スリープを入れる
- select/poll で読み込めるか確認する（前回）
- タイムアウトつき select/poll が有効

空回り防止・回避 (*cont.*)

スリープ例

```
while(1) {  
    nr = read(fd, buf, BUFSIZ);  
    sleep(1);  
}
```

- 複数の単位が用意されている

- ◇ sleep は秒[s]
- ◇ usleep はマイクロ秒[us]
- ◇ nanosleep はナノ秒[ns]

精度は OS やライブラリによる、盲信・過信しない

タイムアウト付き select

タイムアウト(1.5秒)つき select 例

```
FD_ZERO(&fds)
FD_SET(fd, &fds)
tw.tv_sec = 1;
tw.tv_usec = 500*1000;
while(1) {
    memset(&rfd, &fds, sizeof(fds));
    ik = select(fd+1, &rfd, NULL,
                NULL, &tw);
    if(ik>0) {
        nr = read(fd, BUF, BUFSIZ);
    }
}
```

読込監視を1.5秒続ける

タイムアウト付き **select** (*cont.*)

read ブロックの select ブロック置換ともみなせる


- 受信あれば読み込み可能を検出して即座に返る
- 受信なければ指定時間経過後に返る

したがって、ループ全体的には

- 受信があれば即座に受信を処理
 - 受信が続く場合も即座に次の受信を処理
スリープの方は必ず待つ、レート制御に近い
 - 受信が無ければスリープにほぼ等価
- レート制御は `setitimer` を参照

connect の待ち時間削減

- 非同期コネクションの主な用途の一つ
- connect の待ち時間は比較的長い
 - ◇ TCP のレベルで考える



- ◇ この時間（数十ms～数百ms）も節約したい
- ◇ 待っている間に他の処理がしたい

connect の待ち時間削減 (cont.)


```
fd = socket(...)  
ik = enable_nonblock(fd)  
ik = connect(fd, ...)  
if (ik < 0 && errno != EINPROGRESS) {  
    << connect 開始失敗時の処理 >>  
}  
    << 他の処理 >>  
if (iswritable(fd)) {  
    ik = scanerror(fd, &err)  
    if (err) {  
        << connect 失敗時の処理 >>  
    }  
    disable_nonblock(fd)  
}
```

connect の待ち時間削減 (*cont.*)

- `enable_noblock`: ノンブロッキングに変更
- `disable_noblock`: ブロッキングに変更
- `iswritable`: 書き込み可能か確認
非同期コネクションの `connect` は成否確定すると
書き込み可能になる 書き込み可能のみ検出例

```
ik = select (nfd, NULL, wfds, NULL, NULL)
```
- `scanerror`: `getsockopt` でエラーを確認（前回）
通常の `errno` と同様な値を得る

クライアント connect 前後





- 実は connect の前にも処理がある
 - ◇ gethostbyname/getaddrinfo 等の問い合わせ（次ページに詳細）
- write は待ち時間ほぼなし
 - ◇ バッファリングされているから（前回登場）

gethostbyname 類の待ち時間


ホスト名から IP アドレスへ変換

- 主に DNS の通信
主に UDP で実現
ここでも待ち時間が存在
- resolver は DNS client を指す
- ライブラリ内の処理なので容易には短縮できない




gethostbyname 類の待ち時間 (*cont.*)

基本形のプログラム関係図



gethostbyname 類の待ち時間 (*cont.*)

基本形のタイミング図




gethostbyname 類の待ち時間 (*cont.*)

対策


- 1) resolver を別プロセスにする
resolver 作業を TCP で応答するサーバに
隠蔽された resolver の待ち時間を
待ち時間制御可能な connect, read に読み換え
- 2) キャッシュを設ける
問い合わせ回数を減らす
- 3) 別 resolver 関数
待ち時間のない関数があれば良い

対策1: resolver 別プロセス

- resolver が gethostbyname 呼び出し
- クライアントは TCP のみ扱う
- TCP なら待ち時間制御可能に



対策1: resolver 別プロセス (*cont.*)



対策2: キャッシュ

gethostbyname 呼び出し回数軽減

自作

- gethostbyname 結果を記録
- gethostbyname 呼出前に記録を走査

他実装

- unbound 等

繰り返しが多ければ効果大きい

対策3: 別 resolver 関数

待ち時間のない / 短い関数を使う

待ち時間中に別処理できる関数 / 機構を使う

自作

- UDP で DNS 問い合わせ
- 一定時間でタイムアウト

他実装

- UDNS, adns, libdns 等
- light weight resolver 等

他実装注意点

- 他人のバグに引きずられる可能性
 - libc内蔵 gethostbyname のバグ可能性極小
- 望みのプラットフォームで動かない可能性
 - ◇ 組み込み環境
 - ◇ 古い OS
- 各種内蔵・関連機構への影響
 - ◇ resolv.conf
 - ◇ NetManager

エラーハンドリング

- システムコール返り値を確認する（再掲！）
- エラーでも、一時的な場合がある

考慮しなければならないエラー値（代表的）

EINTR	割り込み発生
EAGAIN	もう一回
EINPROGRESS	進行中
ECONNRESET	相手が解放・切断した
EPIPE	相手が切断した

エラーハンドリング: EINTR

システムコール処理中に各種割り込みが発生すると、
処理が中断して EINTR を返す

```
try_accept:
    sfd = accept(lfd, ...)
    if (sfd < 0) {
        if (errno == EINTR) {
            goto try_accept:
        }
        ...
    }
```

EINTR が出てきたら、繰り返す
EAGAIN も同様

発生度合いは OS に依存する

エラーハンドリング: EPIPE

書き込み時に通信が切断すると EPIPE が発生

```
nw = write(sfd, ...)
if (nw < 0) {
    if (errno == EPIPE) {
        return -1
    }
    ...
}
```

EPIPE を見つけたらそれ以降の処理は無理

- return か exit で対処

PIPE 設定

- EPIPE 発生処置は原則プロセス停止となる
 - ◇ 小さなプログラムはその方が無難
- プロセス停止の無効化は signal 使う


```
signal(SIGPIPE, SIG_IGN);
```

POSIX に合わせるなら sigaction がおすすめ

- 無効にしないと簡単に終了するプログラムになってしまう
サーバでは使い物にならない

共有メモリ

複数のプロセスでメモリを共有する



親子関係にないプロセス間で同じデータ扱える
プロセスが終了しても保持される点に注意

共有メモリ (*cont.*)

システムコールやライブラリ関数は 2 系統存在


- shm: shmget, shmat, shmdt
 - ◇ key や id で管理したメモリ領域を扱う
- mmap
 - ◇ ファイルをメモリ上に投影する

注意点

- サイズ上限等 OS によって異なる
 - ◇ shm は古い OS では領域が小さい
- semaphore 等で同時書き込みを回避する

共有メモリを使った通信

- 一方からデータを共有メモリに書き込む
- 他方でデータを共有メモリから読み込む



- 固定長なら実装容易
- 可変長は長さに十分注意

ネットワークスタックを介さないので高速

ソケットその他

アドレス再利用

- 同じ IP アドレスを複数のコネクションで使う
- サーバの多くではこの設定が必要

```
flag = 1;  
setsockopt (fd, SOL_SOCKET, SO_REUSEADDR,  
            &flag, sizeof(flag));
```

ソケットその他 (*cont.*)

fd パッシング

- sendmsg, recvmsg で fd を交換できる



- msghdr, iovec 等データ構造が少し複雑
- 親子関係ないプロセス間でも可能

応用システム: 代理サーバ

代理サーバ (proxy server)

- クライアントとサーバの間で通信を中継




- キャッシングやデータ変換等を装備する場合も
 - ◇ キャッシュ持つと応答が短くなる
 - ◇ キャッシュ持つとサーバへのトラフィック減る
- クライアントとサーバの両方の機能を持つ
 - ◇ プログラムの難易度高い

応用システム：代理サーバ (*cont.*)

- forward proxy // 特に指定なければこれ

- ◇ クライアント側に設置

- ◇ キャッシュがあるといわば読み込みキャッシュ



- reverse proxy

- ◇ サーバ側に設置

- ◇ キャッシュがあるといわば書き込みキャッシュ




応用システム：マルチサービス

プログラムは一つのサービス（アプリケーションプロトコル）に限定されない

ここまでは簡単にするために触れなかった


- 複数サービス利用するクライアント
- 複数サービス提供するサーバ



応用システム: マルチサービス (cont.)

クライアントでは出力が混ざらないよう注意

- CUI ならコンソール
- GUI ならウィンドウ




このまま出力すると、BBABABBACCACACC


応用システム: マルチサービス (*cont.*)

サーバは複数 listen fd を持つ

port A



port B



内容に応じてコンテキスト等を決める

参考実装

- サーバ
 - ◇ Apache, nginx
- 代理サーバ
 - ◇ Squid
- ベンチマーク
 - ◇ ab(Apache 内蔵), httpperf, JMeter
 - ◇ WebPolygraph

プラットフォームの差異と対策

差異

- ヘッドファイルやライブラリの有無
- 型定義有無や内容、関数定義の有無や引数

対策

- 小さな差異は同等品を用意する
- 大きな差異
 - ◇ 足りないだけならインストールを促す
 - ◇ 使わずに済む回避策をとる
 - ◇ 諦める

configure

configure と make だけでコンパイルを可能に

```
% gtar ztvf some.tar.gz  
% cd some  
% ./configure  
% make
```

様々なプラットフォームで、これだけでコンパイル

- OS 由来の差異を吸収 UNIX 中心
 - ◇ BSD, Linux, Solaris, MacOS
 - ◇ Linux の様々なディストリビューション
- ヘッダ・ライブラリの差異を吸収

configure (cont.)

configure は

- autoconf で生成されるシェルスクリプト

configure.in → autoconf → configure

- Makefile や config.h 等を生成する

Makefile.in → configure → Makefile
config.h.in → configure → config.h

- config.h に差異や処理方針、その内容を記録

configure (cont.)

- ファイルシステムからヘッダやライブラリを把握
- config.h 上では把握結果はマクロとして残る

```
#define HAVE_SELECT
```

- .c や .h ではマクロに応じたコードを書く

```
#ifndef HAVE_SELECT  
#define isreadable isreadable_select  
#else  
#define isreadable isreadable_poll  
#endif
```

Makefile を作る関連プログラム automake もある