動的なコード生成を用いた正規表現エンジンの実装

新 屋 良 磨[†] 河 野 真 治[†]

当研究室では, 与えられた正規表現から, 等価な 有限状態オートマトンに変換し, オートマトンにおける状態遷遷移を C 言語等のコンパイル型言語での関数遷移に変換する正規表現コンパイラを Python で開発している. 本実験では, その正規表現コンパイラを元に, テキストファイルに対しパターンマッチを行いマッチする行を出力するツールである grep に相当するソフトウェアを実装した.

Implimentation of Regular Expression Engine with Dynamic Code Generation.

Ryoma SHINYA[†] and Shinji KONO[†]

上の英訳.

1. はじめに

コンパイラ理論の発展と共に, コンパイルにかかる時間はより短く, また得られるプログラムはアセンブラレベルで最適化が施され, より高速になってきている.

完全に静的なコンパイルが可能な対象として, 正規表現エンジンに着目した. 現在, 正規表現のエンジンは, プログラミング言語の組み込み機能やライブラリ等, さまざまな実装が存在するが, それらの殆どは仮想マシン方式を採用している[2]. 仮想マシンを採用いた実装でも, 正規表現を内部表現に変換する処理を行っており, それらを “コンパイル” と呼ぶことが多い. 本研究で実装したエンジンの “コンパイル” とは, 正規表現を内部形式に変換することではなく, 正規表現から実行バイナリを生成することを指す (3.3 節). 本研究では, 実行バイナリの生成にはコンパイラ基盤である LLVM, GCC を用いており, エンジン生成系は Python で実装した.

本論文では, まず正規表現のコンパイル方法について説明する. さらに, 実装したエンジンの性能調査のために, 正規表現を用いてテキストマッチ処理を行う grep クローンを実装し, GNU grep 等の既存ソフトウェアとの比較を行った.

† 琉球大学
University of the Ryukyu

2. 正規表現

2.1 正規表現によるテキストマッチ

正規表現は与えられた文字列を受理するかどうかを判定できるパターンマッチングの機構であり, sed, grep, awk を始めとするテキスト処理ツールに広く利用されている. 正規表現には定められた文法によって記述され, 例えば, 正規表現 “$a*b$” は”a” の 0 回以上の繰り返し直後, “b” で終わる文字列 (“b” , “ab”, “$aaaab$”) を受理し, “$a(b|c)$” は “a” で始まり, 直後が “b” または “c” で終わる文字列 (“ab”, “ac”) を受理する.

2.2 正規表現の演算

本論文では, 以下に定義された演算をサポートする表現を正規表現として扱う.

(1) 連接 二つの言語 L と M の連接 (LM) は, L に属する列を一つとり, そのあとに M に族する列を連接することによってできる列全体から成る集合である.

(2) 集合和 二つの言語 L と M 集合和 ($L|M$) は, L または M(もしくはその両方) に属する列全体からなる集合である.

(3) 閉包 言語 L の閉包 ($L*$) とは, L の中から有限個の列を重複を許して取り出し, それらを連接してできる列全体の集合である.

正規表現は, この 3 つの演算について閉じており, この 3 つの演算によって定義される表現は, 数学的には正則表現と定義されている. 本論文では, 特に区別のない限り, 正則表現と正規表現を同じものとして扱う.

3. 正規表現エンジンの実装

正規表現は等価な NFA に, また NFA は等価な DFA に変換することが可能である[4]. 以下にその変換手方を説明する.

3.1 正規表現から NFA への変換

NFA(*Non-deterministic Finite Automaton*) は, 入力に対して複数の遷移先持つ状態の集合であり, 遷移先が非決定的 (Non-deterministic) である. ここでは, NFA を 5 個組 $(Q, \Sigma, , \delta, q_0, F)$ で定義する. ただし,

(1) Q は状態の有限集合.
(2) Σ は入力記号の有限集合.
(3) q_0 は Q の要素で, 開始状態と呼ぶ.
(4) F は Q の部分集合で, 受理状態と呼ぶ.
(5) δ は, 状態と入力記号に対して状態の集合を返す遷移関数.(ε 遷移を許す)

正規表現が, 等価な NFA に変換できるということを,2.2 で定義した 3 つの演算について対応する NFA に変換できることから示す.

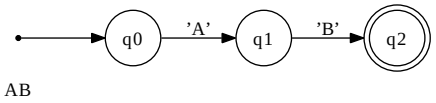

図 1 “A” と “B” の連接

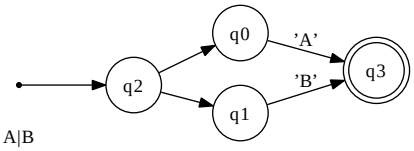

図 2 “A” と “B” の集合和

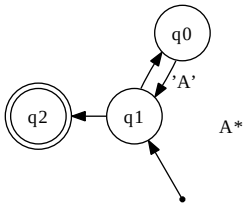

図 3 “A” の閉包

(1) 連接 図 1 は正規表現 “AB” に対応する NFA.
(2) 集合和 図 2 は正規表現 “$A|B$” に対応する NFA.
(3) 閉包 図 3 は正規表現 “A*” に対応する NFA.

図 2, 3 において, ラベルのない矢印は無条件の遷移を現しており,ε 遷移と呼ばれる. また, 二重丸で囲まれた状態は受理状態を現しており, NFA において入力が終了した時点で, 受理状態を保持している場合に限り, その文字列を受理したことになる. なお, NFA は同時に複数の遷移先をもつことがあるので, テキストのマッチング途中で複数の状態を保持することがある.

現在実装されている正規表現エンジンの多くは, 正規表現を内部的に NFA に変換して評価を行っている[1]. NFA による実装は, 後述する後方参照や最長一致に対応しやすいが, 同時に遷移する可能性のある複数の状態を保持する必要があるため, 正規表現の複雑度に多じてマッチングの時間が多くなってしまう場合がある. 文献[1] では, “$a?a?a?aaa$” のような “$a?^n a^n$” のように表現 (“$a?$” は”a“か空文字” “を認識する拡張された正規表現お一つ) の評価において, NFA ベースの正規表現エンジンでは遷移する状態の数が増えてしまうでマッチングにかかる処理時間が n の指数的に増加する問題をベンチマーク結果と共に指摘している. 文献[6] では正規表現から NFA ベースで効率的なマッチング処理を行うエンジンを IBM 7094 機械語で生成する例が紹介されている.

3.2 NFA から DFA への変換

非決定的な遷移を行う NFA から, 決定的な遷移を行う DFA(*Deterministic Finite Automaton*) に変換する手法を説明する. なお, 遷移が決定的であるということは, 1 つの入力に対して, 遷移する状態がただ 1 つであるということを指す. DFA は, NFA と同様な 5 個組で $(Q, \Sigma, , \delta, q_0, F)$ 定義できる. ただし,DFA において δ において ε 遷移は認められず, また任意の状態 q と入力 σ について, $\delta(q, \sigma) = q'$ となる q' は Q の要素となる. つまり, 遷移先が決定的であるということに他ならない.

以下に ε 遷移を許す ε-NFA $E = (Q_E, \Sigma, \delta_E, q_0, F_E)$ から等価な DFA $D = (Q_D, \Sigma, \delta_D, q_D, F_D)$ を構成する手順を示す.

(1) Q_D は Q_E の部分集合全から成る集合であり, おの中で D において到達可能な状態は, ε 遷移に関して閉じている Q_E の部分集合 S に限られる. ここで, 状態 q において ε 遷移に関して閉じている集合全体を $ECLOSE(q)$ と表す. $ECLOSE$ を使って S を定義すると, $S = \bigcup_{q \in S} ECLOSE(q)$ を満たす S.
(2) $q_D = ECLOSE(q_0)$. すなわち, E の開始状態の ε 閉包.

(3) F_D は E の状態の集合で, 受理状態を少なくとも一つ含むもの全体からなる集合である. すなわち,$F_D = \{S | S \in Q_D \wedge S \cap F_E \neq \emptyset\}$

(4) $\delta_D(S, a)$ は Q_D の要素 S と Σ の要素 a に対して次のように計算される.

(a) $S = \{p_1, p_2, ..., p_k\}$ とする.

(b) $\bigcup_{i=1}^{k} \delta(p_i, a)$ を求め, その結果を $\{r_1, r_2, ..., r_m\}$ とする.

(c) このとき, $\delta_D(S, a) = \bigcup_{j=1}^{m} ECLOSE(r_j)$

この方法によって得られた DFA D は NFA E と同等の言語を認識し, また NFA の元となる正規表現と同等である.

3.3 DFA からの実行バイナリ生成

DFA からの実行バイナリ生成には, 生成するコードについて 3 種類の実装を行った.

(1) DFA → Continuation based C → GCC によるコンパイル

(2) DFA → C → GCC によるコンパイル

(3) DFA → LLVM 中間表現 → LLVM によるコンパイル

以下, Continuation based C, LLVM の説明と, それを利用した DFA からの実行バイナリ生成の方法を説明する.

3.3.1 Continuation based C

Continuation based C(以下 CbC) は, プログラミングの基本単位としてコードセグメントを持ち, コードセグメント間の軽量継続を基本とした C の下位言語である. 本研究室での先行研究により CbC コンパイラは, GNU C Compiler 上で実装されており[7], GCC の末尾再帰最適化を強制することで, 関数と同様の記述が可能で, かつ関数呼び出しに伴なうリターンアドレスの保存や, スタックの成長のない, “引数付き goto” として継続を実装している. 本研究では gcc-4.5 上に実装された CbC コンパイラを用いた.

以下に, 正規表現 “$(A|B)*C$” に対応する DFA と, DFA の各状態に対応する CbC のコードセグメントの生成例を示す.

```
__code state_0(unsigned char *s, unsigned
        char* cur, unsigned char* buf, FILE
        *f, char* filename) {
  switch(*s++) {
    case 65: /* match A */
      goto state_0(s, cur, buf, f, filename);
    case 66: /* match B */
      goto state_0(s, cur, buf, f, filename);
    case 67: /* match C */
      goto state_1(s, cur, buf, f, filename);
    default: goto reject(s, cur, buf, f, filename);
  }
}
__code state_1(unsigned char *s, unsigned
        char* cur, unsigned char* buf, FILE
        *f, char* filename) {
  goto accept(s, cur, buf, f, filename);
}
```

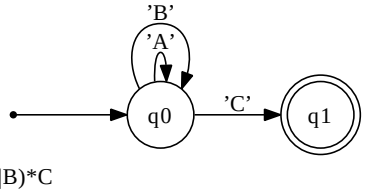

図 4 正規表現 “$(A|B)*C$” に対応する DFA

図 4 の DFA に対応する CbC コードセグメント

DFA の遷移とは直接関係のない引数 (ファイル名やバッファへのポインタ等) が目立が, CbC では環境をコードセグメント間で引数として明示的に持ち運ぶ軽量継続を基盤としたプログラミングスタイルが望ましい. 今回コンパイラによって生成した CbC ソースコードでは, 大域変数は持たず, 必要な変数は全て引数に載せている. CbC の state_1, state_0 から呼ばれている accept, reject はそれぞれ受理と非受理を表す. accept ではテキスト行を出力して次の行へ, reject では次の文字へと処理を移すコードセグメントへ継続を行う.

生成した CbC ソースコードを, GCC 上に実装した CbC コンパイラによってコンパイルすることで実行バイナリを得る.

3.3.2 C

C による実装では, CbC のコードセグメントに代わり関数を用いて DFA を実装した. DFA による遷移を関数呼び出しで行っているため, 実行時のスタックの使用領域や, スタック操作によるオーバーヘッドが予想される.

3.3.3 LLVM

LLVM(Low Level Virtual Machine) は, さまざまなコード最適化/分析機能を備えた, モジュール単位で利用可能なコンパイラ基盤である[5].

CbC/C による実装では,DFA から CbC/C のソースコードに変換し,GCC によってコンパイルを行っている. LLVM による実装では, LLVM の中間表現である LLVM-IR を, 提供されている API を用いて直接操作を行い, コンパイルを経て実行バイナリを得る.

Python から LLVM API の利用は, LLVM API の Python ラッパーである llvm-py☆を使用した.

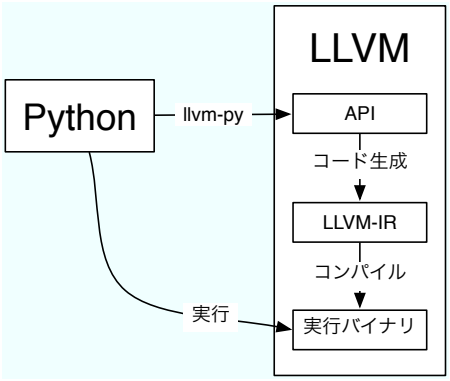

図 5 LLVM を用いた実装

LLVM による実装でも, C による実装と同様に,DFA の状態遷移を switch 文と関数呼び出しによって表現している.

4. grep

正規表現は, テキストのパターンをシンプルに記述できるという利点から, テキストファイルから, 任意のパターンにマッチするテキストを検索するなどの用途に使用される.

GNU grep は, それを実現するソフトウェアの一つであり, 引数として与えられたファイルから, 与えられた正規表現にマッチするテキストを含む行を出力する機能を持っている.

5. 評　　価

5.1 実　　験

本実験で実装した正規表現エンジンの CbC/C/LLVM による三つの実装に対して, コンパイル時間及びマッチングにかかる時間の比較を行った. なお, GCC によるコンパイルには最適化オプション “-O3” を, LLVM のも同様の最適化オプションを用いてコンパイル/マッチングを行っている.

実験環境

- CPU : Core 2 Duo 950 @3.0GHz
- Memory : 16GB
- GCC : 4.5.0
- LLVM: 2.4

コンパイル

☆ http://www.mdevan.org/llvm-py/

n 個の単語を正規表現の和集合演算 “|” で繋げたパターンに対し, 各実装のコンパイル時間の比較を行った.

表 1 ベンチマーク:compile

n (単語数)	1	10	50	100
DFA 変換 [ms]	0.19	3.28	22.2	73.8
DFA の状態数	8	50	187	381
GCC-C [s]	0.34	0.78	2.18	4.27
GCC-CbC[s]	0.75	1.03	9.14	9.43
LLVM [s]	0.044	0.08	0.246	0.472

表 1 から, LLVM によるコンパイルが GCC に比べ 10 倍程高速に行われている. LLVMM による実装では,API を通じて直接 LLVM の中間表現を操作することで, ファイル I/O やパース等のオーバーヘッドもない.

マッチング

マッチング時間の比較では, 様々な正規表現を用いて比較を行った結果, 3 つの実装でマッチング時間にあまり差が見られなかった. 生成されるコードはコードセグメント/関数と, switch 文によるシンプルな実装であることから, コンパイルされたバイナリの性能にあまり差が出ていないものだと思われる.

本実装の中で最もマッチングが高速だった GCC-C で生成した正規表現エンジンを用いて grep に相当するプログラムを実装し, 実際にテキストファイルからのパターンマッチを行い, それぞれの評価を行う. 本実装との比較対象として,

GNU grep　hoge
cgrep　fuga
Google RE2　piyo

実験環境

- CPU : Core i7 950 @3.0GHz
- Memory : 16GB
- GCC : 4.4.1
- Text : Wikipedia 日本語版全記事
  (XML, UTF-8, 4.7GB, 8000 万行)

表 2 に結果を示す.

以下に, それぞれのテストケースのパターン, grep にマッチした行数, および考察を記す. なお, ここで扱う正規表現の “複雑さ” とは, DFA に変換した時点の状態数, 遷移規則の多さを基準としている.

fixed-string　固定文字列によるマッチング
パターン : “*Wikipedia*”
マッチ行数: 348936 行
GNU grep では, 与えられたパターン内に, 確実

表 2 ベンチマーク:grep

テストケース	fixed-string	complex-regex
本実装 (GCC-C)[s]	1.69	4.51
(コンパイル [s])	0.20	0.41
GNU grep 2.6.3[s]	2.93	16.08
GNU grep 2.5.4[s]	2.96	188.51
cgrep 8.15 [s]	1.85	6.48
Google RE2 [s]	30.10	16.92

に含まれる文字列 (固定文字列) が存在する場合は, Boyer-Moore-Horspool 法 等の高速な文字列探索アルゴリズムを用いてフィルタをかけることで, DFA によるマッチングを減らし, 高速化している. 本実装の grep でも, 同様に固定文字列フィルタによる高速化を行っているが, 単純な固定文字列の検索でも, コンパイルすることによる高速化が結果に出ている.

complex-regex 複雑な正規表現でのマッチング
パターン :“$(Python|Perl|Pascall|Prolog|PHP|Ruby|Haskell|Lisp|Scheme)$”
マッチ行数: 15030 行
このパターンは,9 個の単語を和集合演算 “|” で並べたもので, 確実に含まれる文字列は存在せず, fixed-string に比べて GNU grep はマッチングに時間がかかっている.
さらに, GNU grep 2.5.4 は 190 秒と, 本実装及び GNU grep 2.6.3 に対して非常に低速な結果となっているが, これは後述する mbrtowc(3) によるマルチバイト文字の変換処理によるオーバーヘッドによるものである.

2 つのテストケースの結果を見てみると, 本実装はそれぞれ GNU grep と比べて高速な結果となっており, コンパイル時間はマッチングにかかる時間と比べて無視できるほど短い時間である.

5.2 特　　徴

本実験によって実装された正規表現評価器の特徴を, GNU grep との比較をはさみながら説明する.

正規表現からの動的なコード生成

本実装による一番の特徴として, 正規表現から変換を行うことで得られる等価な DFA を, C/CbC/LLVM に変換しコンパイルすることで正規表現に応じた実行バイナリを生成することが挙げられる. またコンパイラ理論におけるさまざまな最適化が期待される. grep による検索のような, 与えられるパターン (正規表現) に対してマッチ対象のテキストファイルが十分に大きい場合, 正規表現のコンパイルにかかる時間はマッチングにかかる時間によって隠される.

GNU grep では, 本実装と同様に DFA ベースのマッチングを行うが, DFA の各状態は構造体よって表され, 状態遷移は各状態毎に保持している遷移先ポインタによる配列を,1Byte 単位でテーブルルックアップを行うことで実装されている.

UTF-8 対応

本実装は, マルチバイト文字の代表的な符号化方式である UTF-8 に内部的に対応しており, 正規表現の演算は 1Byte 単位ではなく,1 文字単位で適用される. マルチバイト文字を含む正規表現のサンプルとして, “(あ | い)*う” を DFA に変換した図 6 を載せる. 図における`'\x'` に始まる文字は 16 進数表記で, `'\x82'` は 16 進数 82 を表す.

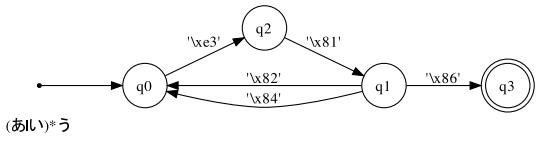

図 6 正規表現 “(あ | い)*う” に対応する DFA

GNU grep 2.5.x では, マルチバイト文字に対応しているものの, プログラム内部で libc mbrtowc(3) を用いて固定サイズであるワイド文字に変換して処理を行っており, テストケース complex-regex ではそのオーバーヘッドが顕著に現れている. 2010 年 3 月にリリースされた GNU grep 2.6 から, UTF-8 に対して本実装と同様に内部的に対応することで, mbrtowc(3) による変換コストが無くなっている.

柔軟な実装

本実験で実装した正規表現評価器は, Python によって実装されており, 全体で 3000 行程度の軽量なプログラムとなっている. 比較対象の GNU grep は, C 言語によって実装されており, プログラム全体は 15000 行程度の規模となっている.

さらに, 本実装から動的に生成されるコードも, コードセグメント/関数と switch を基準としたシンプルな記述で高い可読性を持ちつつ, 細かい最適化を GCC/LLVM の最適化技術を利用することで実行速度も非常に高速であることが実験結果から分かった.

6. 途中報告と課題

本研究では, 現段階で正規表現をコードセグメント/関数による状態遷移を行うコードに変換する手法で正規表現エンジンを実装し, GNU grep との比較を行い, 非常に良好な結果が得られた.

今後の課題として, 正規表現マッチングのデータ並

列な並列アルゴリズムの実装を目指している.

参 考 文 献

1) Cox, R : Regular Expression Matching Can Be Simple And Fast, 2007
2) Cox, R : Regular Expression Matching: the Virtual Machine Approach, 2009
3) Cox, R : Regular Expression Matching in the Wild, 2010
4) Hopcroft, J, E. Motowani, R. Ullman, J : オートマトン言語理論計算論 I (第二版), pp.39–90.
5) Lattner, Chris. Adve, Vikram : The LLVM Compiler Framework and Infrastructure, 2004
6) Thompson, K : Regular Expression Search Algorithm, 1968
7) 与儀 健人 : 組込み向け言語 Continuation based C の GCC 上の実装, 2010

(平成 2010 年 12 月 03 日受付)
(平成　0　年 0 月 0 日採録)

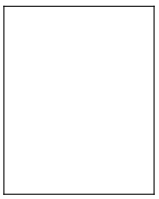

新屋　良磨（正会員）
1988 年生

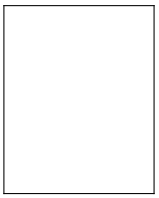

河野　真治（正会員）
1959 年生．1989 年東京大学大学院情報工学課程修了 (工学博士) 同年 Sony Computer Science Laboratory, Inc. 入社．1996 年より琉球大学工学部准教授工学博士． ACM 会員.