

国産数式処理システム GAL におけるパターンマッチング

SASA KI TATEAKI MOTOYOSHI FUMIO
佐々木 建昭, 元吉 文男
(理 研) (電総研)

1. はじめに

現在開発中の国産数式処理システム GAL においては、パターン・マッチングを非常に重視している。パターン・マッチングは数式処理の応用において非常に多用され、利用価値が高い機能であることは REDUCE の LET 文が示すところであるが、将来実用化されるであろう数式データベースの運用を考慮すると、その重要性は我々の予想をはるかに越えるものだと言いなければならない。筆者らを含め、ほとんどの数式処理システム開発者は、パターン・マッチングを数式処理の基本的な機能の一つであると認識している。したがって、パターン・マッチングそのものを目的とすることも当然あるが、それよりも、パターン・マッチングを利用して不定積分の計算や微分方程式の求解を実行することをより重視するのである。数式処理システムにおけるパターン・マッチャーのこの位置づけには留意する必要がある。

数式のパターン・マッチングで我々が最もよくなじんでいるのは REDUCE [1] の LET 文であろうが、REDUCE に限らず、多くの数式処理システムがパターン・マッチング機能を有している。これまでに最も高度なパターン・マッチング機能をレポートしたものは恐らく MACSYMA [2] であり、それに近い機能を有したシステムに SMP [3] がある。GAL のパターン・マッチャーは MACSYMA のそれと同程度のものである(ただし、その細かな点で MACSYMA が、ユーザの使い易さの点で GAL が、それより優る)と考えている。

本稿では、数式パターン・マッチングの(大雑把な)一般論、GAL におけるパターン・マッチャーの紹介に加えて、パターン・マッチングによる数式の単純化が応用上実に有用であることを示す。

2. 数式パターンとパターン変数

数式パターンとは、変数として実変数以外に“パターン変数”を含み得る点を除けば、通常の数式と同様である(ただし、システム・コンパイラ・インタプリタの都合上、振いうるパターンに制限を加えるシステムが多い)。パターン変数とは一般に任意の数式あるいは部分式とマッチし得る変数である。ただし、パターン変数に条件が付けられているときには、その条件を満足する数式としかマッチしない。パターン変数は、通常の変数と区別するため、陽に指定する必要がある。たとえば MACSYMA では A, B, X がパターン変数であることを

```
MATCHDECLARE([A, B, X], pred1, pred2, ...)
```

と指定する。ここで、pred1, pred2, ... は A, B, X を限定する条件文である。この方式ではパターン変数がグローバルに定義されることになる。一方、SMP ではパターン変数は頭に“\$”あるいは“\$”をつけることにより指定する。たとえば \$X, \$X がそうである。ここで、\$X は一つの項とのみマッチし、\$X は複数個の項ともマッチし得る。\$X や \$X に条件が付けられることは MACSYMA と同様であるが、方式は異なる(以下をみよ)。

GALにおけるパターン変数の指定法はSMBにおけるそれと類似である。すなわち“@”を頭につけた変数がパターン変数である。ただし、SMBのように@Xと@@Xを区別せず、どちらも（条件があればそれを満たす）任意の数式とマッチするものとして扱う。SMB方式とGAL方式のどちらがよいかは異論のある所であろうが、たとえば

$$\exp(X+Y+Z) \rightarrow \exp(X) \cdot \exp(Y) \cdot \exp(Z)$$

の変形が、GALにおいては

$$\exp(@X+@Y) \rightarrow \exp(@X) \cdot \exp(@Y)$$

なる公式で実行されるが、SMBでは注意深く

$$\exp($X+$Y) \rightarrow \exp($X) \cdot \exp($Y)$$

としなければならぬ。この複雑さの代償にSMBではもつて変数のマッチングがきめ細かく実行される。

GALでは数式パターンとして、集合式、関係式、論理式、配列、およびベクトルや行列等の構造体数式は許していないが、それ以外の普通に我々が数式と考えるものは何でも許している。さらに、パターン変数は関数名であっても（そのときは関数名とのみマッチする）、変数や関数の添字でも、またベクトルや行列のインデックスであってもよい。

パターン変数には一般に条件がつけられ、MACSYMAではMATCHDECLAREで条件を指定することを述べた。SMBでは数式パターン中に現れたパターン変数の直後に（必要ならば）条件を付ける。たとえば

$$\text{Eul}[\$n_ = \text{Natp}[\$n]]$$

は任意変数（=パターン変数）\$nの関数Eul[\$n]を手で持っているが、変数\$nのあとに続くNatp[\$n]が条件である。一方、GALでは条件を

$$\text{pattern WHERE Conditions}$$

の形で、数式パターンとは分離して与える。ここで、WHEREのかわりにWITHを用いてもよく、条件はANDとORでつなげればよく与えてもよい。たとえば、SMBに対する上例をGALで与えると

$$\text{Eul}(@N) \text{ WHERE ?INT}(@N) \text{ AND } @N >= 0$$

と表現できる。SMB方式では2個以上のパターン変数にまたがる条件は表現しえないが、GALおよびMACSYMAの方式ではそれが可能であることを指摘したい。なお、MACSYMAと異なりGALおよびSMBでは、パターン変数の仕様は局所的である、すなわちパターン変数は一つの数式パターン内でのみ同一視される。したがって、別個のパターン中で同一名のパターン変数が使われても、それらには何の関係もない。

以上を総括すると、MACSYMAとSMBおよびGALで数式パターンの仕様に差はあっても、本質的な機能には大差はないとさえ言う。

3. パターン・マッチングによる簡単化

数式パターン・マッチングの詳細に入る前に、パターン・マッチングを用いた数式の簡単化を述べておくことは、パターン・マッチャーの有用性のみならず、パターン・マッチャーがどのようなものかを理解するのに役立つ。

GALでは数式の簡単化 (simplification) とは、 $left \rightarrow right$ なる書き換え規則による数式の変形であると割り切っている。書き換え規則 (ルール) には

- i) システム組込みのルール,
- ii) ユーザ定義の open ルール,
- iii) ユーザ定義の boxed (packed) ルール,

の3種があるが、ここでは後二者を説明しよう。

open ルールが入力されると、それ以後このルールが消去されるまでに計算されるあらゆる数式 (ただし、計算の最終結果式のみ) にこのルールが適用される (したがって、open ルールが多数あると計算速度はガタ落ちする可能性がある)。右ルールは

$$\begin{aligned} \underline{left} & \longrightarrow \underline{right}; \quad \text{あるいは} \\ \underline{left} & \longrightarrow \underline{right} \quad \text{WHERE } \underline{conditions}; \end{aligned}$$

なる形式で与えられ、RULE 文により

$$\text{RULE } rule1, \dots, rule_n;$$

と定義される。ルールを消去するには UNRULE 文が使える。

一方、boxed ルールとは名前をつけられた一群のルールであり、その名前が呼び出されて初めて有効となる。boxed ルールは RULEBOX 文により

$$\text{RULEBOX } \text{sin} = \{ rule1, \dots, rule_n \};$$

のように定義される。上例では "sin" が boxed ルールの名前であるが、例が示すように名前は関数名、あるいは変数名と同じでもよい。このルールは

$$\text{SIMP}(expr, \text{sin}, \dots);$$

のようにして起動される。ここで、 $expr$ は簡単化の対象となる数式であり、上例では boxed ルール sin, \dots を起動している。boxed ルールは必要の場合にのみ起動されるので、open ルールを用いるよりも効率的であることは言うまでもなからう。その代償に、ユーザは簡単化のために SIMP コマンドを発行しなければならない。

ルールが最も多用されるのは特殊関数を含む数式の計算であろうが、しかし単なる多項式の簡単化においても絶大な威力を発揮するのである。次頁の例1を見よう。この例では、入力形がそのまま保存されていけば式は簡単だが、展開された形式では元の式の明解さは完全に失われてしまっている。応用分野の計算では例1の出力形のような不明解な式が頻繁に出現する。例1の出力形を入力形のように簡単化したいのであるが、因数分解を試みても無駄である。人間がよくやる方法は、うまくまとまりそうだと当りをつけてそれを試すことがある。そこで、 $X+Y-Z$ がまとまりそうだと当りをつけたとしよう。このとき、GALでは $X+Y-Z \rightarrow W$ なるルールを定義すればよい。例2は GAL でそれを実行した

のである(2次元出力ルーチンはまだプログラムされてはいない。ルールにおいて“ \rightarrow ”は“ \Rightarrow ”がも“ $=\Rightarrow$ ”でも“ $=\>$ ”でもよい)。

$$A2 := (X+Y-Z)*(X**2 + Y**2 - Z**2) + X*Y*Z ;$$

$$A2 := X**3 + X**2*Y - X**2*Z + X*Y**2 + X*Y*Z - X*Z**2 + Y**3 - Y**2*Z - Y*Z**2 + Z**3$$

$$A4 := (X+Y-Z)**2*(X**4 + Y**4 - Z**4) + A2 - 2*X*Y*Z ;$$

$$A4 := X**6 + 2*X**5*Y - 2*X**5*Z + X**4*Y**2 - 2*X**4*Y*Z + X**4*Z**2 + X**3 + X**2*Y**4 + X**2*Y - X**2*Z**4 - X**2*Z + 2*X*Y**5 - 2*X*Y**4*Z + X*Y**2 - 2*X*Y*Z**4 - X*Y*Z + 2*X*Z**5 - X*Z**2 + Y**6 - 2*Y**5*Z + Y**4*Z**2 + Y**3 - Y**2*Z**4 - Y**2*Z + 2*Y*Z**5 - Y*Z**2 - Z**6 + Z**3$$

例1. 簡単化の対象となる多項式 $A2$ と $A4$ (展開形)

RULE X+Y-Z ==> W ; (ルールの定義)

"RULE DEFINED"

A2; (A2の通をみる)

$$W*X**2 + W*Y**2 - W*Z**2 + X*Y*Z$$

A4; (A4の通をみる)

$$W**2*X**4 + W**2*Y**4 - W**2*Z**4 + W*X**2 + W*Y**2 - W*Z**2 - X*Y*Z$$

例2. ルールで簡単化した結果(オートリソク: $W > X > Y > Z$)

見てわかるように, $A2$ と $A4$ の入力形がほぼ再現された(入力形を完全に再現するには W についてまとめた形式に変換するだけでよい)。

別の例を見よう(現在入力ルーチンとして REDUCE のそれを借用中なので④の前に!が必要。近く目前の入力ルーチンを組むが、そうすれば!は不要)：

RULEBOX sin = sin(!@X)**2 + cos(!@X)**2 -> 1 ; (ルールボックスの定義)

"RULEBOX DEFINED"

$$B3 := (\sin(X) + \cos(X))**3 ;$$

$$B3 := \sin(X)**3 + 3*\sin(X)**2*\cos(X) + 3*\sin(X)*\cos(X)**2 + \cos(X)**3$$

$$B4 := (\sin(X) + \cos(X))**4 ;$$

$$B4 := \sin(X)**4 + 4*\sin(X)**3*\cos(X) + 6*\sin(X)**2*\cos(X)**2 + 4*\sin(X)*\cos(X)**3 + \cos(X)**4$$

SIMP(B3,sin); (B3を簡単化)

$$2*\sin(X)**2*\cos(X) + 2*\sin(X)*\cos(X)**2 + \sin(X) + \cos(X)$$

SIMP(B4,sin); (B4を簡単化)

$$1 + 4*\sin(X)**2*\cos(X)**2 + 4*\sin(X)*\cos(X)$$

例3. boxed ルールによる簡単化の例

この例では $B3$ と $B4$ を \sin と \cos に関して対称的な数式とした。ルールも同様なので、簡単化した結果も \sin と \cos に関して対称的になっていることに注意されたい。物理や工学の計算、特にベクトル量を含む計算では、対称性を保持し

つつ計算すれば式がうまくなり、結果の物理的・工学的意味が理解し易いが、そうでないればはじめの結果に陥ることはよくある。この点で、GLRの単純化は多項式などの数式計算においても強力な武器になるものと考えられる。

4. 数式パターン・マッチング概論

前節で述べたルールによる単純化では

- ① まず left のパターンとマッチする部分式を探す,
- ② left に条件が付与されていけばその条件をチェックする,
- ③ マッチする部分式が見つかればそれを right で置き換える,

という手順を繰り返している。したがって、その本質はパターン・マッチングであると言える。

パターン・マッチャーには、どの程度の機能をサポートするかによって種々のレベルが存在する。最も簡単なものはシンタクティカル・マッチングであろう。すなわち、数式を表現しているデータ(リストで表現されることが大部分である)を先頭からスキャンして、パターン変数を適当な部分式で置き換えさえすれば同一のデータになるときのみ、マッチングが成立するのみである。この方式は多くの項書き換えシステムで採用されているものであり、Prologなどでユニフィケーションと名付けられているものでもある。SMLでは変数のマッチングはこの方式で実行する。

しかしながら、実用的な数式処理システムにおいては、上述の単純なパターン・マッチャーでは明らかに不十分である。少なくとも項や因子の可換性、省略された因子1と指数0, を考慮したセマンティカル・マッチングが不可欠であり、さらに内部表現の非一意性なども考慮する必要がある。これらの詳細と対策は次節で述べる。

数式パターン・マッチングを一般的に論じる場合、次の2点が重要である。

- (i) 数式パターン・マッチングは一意的ではない(たいてい無限通りのマッチングが可能)。このことは次の算式から目明であろう:

$$\begin{aligned} A + B &= (A+C) + (B-C), \\ A * B &= (A*C) * (B/C). \end{aligned}$$

- (ii) 数式パターン・マッチングは単独ではない(多くの場合、方程式を解くことに帰着)。たとえば次の例がそうである:

$$\begin{aligned} \frac{d^2}{dx^2} @F(x) + @F(x) &\Leftarrow \text{match} \Rightarrow 5. \\ \therefore @F(x) &= a \cdot \sin(x) + b \cdot \cos(x) + 5. \end{aligned}$$

一般的な数式パターン・マッチングにおける代表的な問題点を筆者なりにまとめた(以下のもの以外にもあるかも知れない)。

- (a) combinatorial パターン・マッチング(複数個の項または因子を同時に考えず初めうまくなり深まるマッチング)。

例4 $X^@N Y^@N @Z \Leftarrow \text{match} \Rightarrow X^7 Y^5,$
 答: $\{ @N=5, @Z=X^2 \}$

例5 $@X^4 @Y + @X^2 \Leftarrow \text{match} \Rightarrow X^4 Y^2 + X^4$
 答: $\{ @X = X^2, @Y = X^2 Y^2 \}$.

例4において、左から式をスキャンして $@N=7$ としたのではマッチングは失敗し、同様に例5において $@X=X^4$ としたのではマッチングは失敗することに注意されたい。上例のようなマッチングを実行するには、たとえば例4では $@N$ に対する不等式を作り、数式を全部スキャンし終えた後にそれを解くか、あるいはバックトラッキングにより一度決めたマッチングを修正することが必要である。これらを一般的にサポートするのは容易ではない。

(b) group パターン・マッチング (いくつかの項あるいは因子をまとめて初めてうまく決まるマッチング)。

例6 $2(x+1) \cdot \exp(x^2) \cdot \exp(2x) \Leftarrow \text{match} \Rightarrow @F(x) \cdot @A \text{ WHERE ?FREEOF}(@A, \exp)$
 答 $\{ @F(x) = \exp(x^2) \cdot \exp(2x), @A = 2(x+1) \}$.

この例のようなマッチングを完全に実行するには、項あるいは因子のあらゆる組合せを考慮する必要があり、マッチングに要する時間が大巾に増加する。特に、対象数式が因子に分解されない場合には因数分解しなければならぬが、因数分解は非常に高価な演算である。

(c) equational パターン・マッチング (方程式を解くことにより初めてうまく決まるマッチング)。

例7 $\sin(@X) \cdot \text{DF}(\sin(@X)) \Leftarrow \text{match} \Rightarrow \sin(X) \cdot \cos(X)$,

例8 $2 \sin(@X) \cdot @X \Leftarrow \text{match} \Rightarrow \pi$,
 答: $\{ @X = \pm \pi/2 \}$.

例8のようなマッチングをサポートするには高級な求解ルーチンが必要である。

以上の難しいマッチングをどの程度サポートするかは、システムにおけるパターン・マッチャーの位置付けによるが、「パターン・マッチャーは高度であらねばならない」という認識でよいことを指摘したい。実際、例8のように超越方程式を解いてマッチング結果を出さなくても、ユーザはとまどうだけであらう。

5. GALにおけるパターン・マッチャー

1節に述べたごとく、GALにおいてはパターン・マッチャーは主としてアルゴリズム・インプリメンテーションのための基礎的機能と位置づけられているが、そのためには次の性質が要求されるため機能が制限される:

- (1) 実際の計算時間でパターン・マッチングが実行できること、
- (2) 唯一のマッチング結果を出すこと、
- (3) 人間が出すであろう結果とできる限り一致すること。

これらの要求は相互に矛盾することもあるから、パターン・マッチャーがこれら一意に規定される訳ではないが、プログラミングの指針にはなる。

上述の制約のため、前節に述べた難しいマッチングはそのほとんどが排除される。すなわち、難点 (a) は (1) に反するからサポートしない。難点 (b) は (3) の観点から部分的にはサポートするものの、それは (1) と (2) の観点からごく単純なもの (たとえば除算で分離できる因子とのマッチング) に限られる。難点 (c)

は整数のべき乗根因子を計算することを除いてサポートしない。数式パターンでは一般に多数通りのマッチングが存在することを述べたが、(b) と (h) の観点からそのうち最も妥当らしいものを一つだけ出力することになる。したがって、GALのパターン・マッチャーにはシステム・プログラマの恣意性が不可避的に入り込むことになる。しかしながら、上述の制限を加えることにより、項数 m の多項パターンと項数 n の数式のマッチングに要する時間は $O(m \times n)$ に抑えられている。これは、定数因子を除けば、多項式の乗算と同程度の計算量であり、GALのパターン・マッチャーは十分現実的と言えよう。

上記 (h) について説明を追加しておく。たとえばユーザが $@X * @Y * @Z$ なるパターンを与えたとしよう。これと項 X^2 の間には幾通りものマッチングが考えられるが、GALは $@X = X^2$ なるマッチングをまず決める。そうすると $@Y = @Z = 1$ となる。これを答としてよすが、GALは "FAIL" との答を返す。なぜなら、ユーザが $@X * @Y * @Z$ なるパターンを入力したことは、「ユーザは3個以上の因子をもちいた項を探している」と解釈するのが最も自然だからである。因子のうち1個は数因子 1 であってもよから、GALは X^2 を $@X * @Y$ とはマッチさせず ($@X = X^2, @Y = 1$) が、 $@X * @Y * @Z$ とはマッチさせないのである。同じように、 $@X / @Y$ は分数形の数式とのみマッチさせる。

GALにおけるパターン・マッチャーは、全体パターン・マッチャーと部分パターン・マッチャーに大別され、それぞれ次のように起動される：

- (A) MATCH (expr, pattern),
 (B) PARTMATCH (expr, pattern).

ここで、expr はマッチングの対象となる数式であり、pattern は (一般にパターン変数を含む) パターン数式である。パターンには

pattern-expr WHERE conditions

のように条件を付けることができる。MATCH は pattern が expr 全体とマッチするときのみ、PARTMATCH は pattern が expr の一部あるいは全体とマッチするとき、各パターン変数とマッチする数式の対の集合を答として返す。マッチングが失敗すれば "FAIL" を答として返す。

例 9 MATCH ($X^2 + 2X + 1, @X + @Y$);
 答 { $@X = X^2, @Y = 2X + 1$ },

PARTMATCH ($X^2 + 2X + 1, @X + @Y$);
 答 { $@X = X^2, @Y = 2X$ }.

パターンはシステム内部で単項パターンと多項パターンに大別される。単項パターンは基本的には単項の数式とマッチさせるが、パターンが $@X$ のように単変数のときには数式全体とマッチさせることもある。単項数式と単項パターンをマッチさせるには、パターンの中のパターン変数を含む因子を対象数式から除去し、しかる後にパターン中の残った因子を対象数式の因子と左から順にマッチさせていく。すなわち、項は

$$\text{TERM} = \langle \text{left-FACTOR} \rangle * \langle \text{rest-FACTORS} \rangle$$

と分割することを基本とする。多項パターンは基本的には多項の数式とマッチさせるが、単項数式中の因子に多項のものがあればこれとマッチさせることもある。また、 $\text{TERM} + @X$ の形の二項パターンは $@X=0$ として単項式とマッチさせることもある。多項数式と多項パターンをマッチさせるには、これらの数式を左の項から順にマッチさせていく。すなわち、数式は

$$\text{数式} = \langle \text{left-TERM} \rangle + \langle \text{rest-TERMS} \rangle$$

と分割することを基本とする。項中の因子は

$$\text{因子} = \langle \text{BASE} \rangle ** \langle \text{EXPONENT} \rangle$$

と分解して、底部と指数部を個別にマッチさせる。その際、底部のマッチングを優先することはもちろんである。

最後に、多項パターンのマッチングによる単純化について説明しておく。例として、RULE 文、あるいは RULEBOX 文により

$$\sin(@X)**2 + \cos(@X)**2 \rightarrow 1$$

が入力され、式を単純化する場合は考えよう：

$$(A) \quad 2\sin^2(X) + \sin(X) \cdot \cos^2(X) + \sin^2(X) \cdot \cos(X).$$

多項パターンルールとして入力されると、システムはルールの両辺にシステム用パターン変数がある @EXTRA@ を求める：

$$(B) \quad \sin(@X)^2 \cdot @EXTRA@ + \cos(@X)^2 \cdot @EXTRA@ \rightarrow @EXTRA@.$$

次に (A) と (B) の部分のマッチングを行うが、@EXTRA@ をやや特別に扱う。まず、(A) と (B) の第一項だけのマッチングにより $@X=X$, $@EXTRA@=2\sin(X)$ が得られる。次に、この答を (B) の第二項に代入すると $2\sin(X) \cdot \cos^2(X)$ が得られるから、この項に数因子を除いて一致する項を (A) から探し、第二項を見出すと @EXTRA@ の数因子を 1 に修正する。かくして、(A) は

$$(A') \quad \sin^2(X) + \sin(X) + \sin^2(X) \cdot \cos(X)$$

に書き換えられる。(A') と (B) はもはやマッチしないから (A') が答となる。

参考文献

- [1] Hearn, A. C., "REDUCE user's manual", Version 3.0, The Rand Corporation, 1983.
- [2] The MATHLAB Group, "MACSYMA reference manual", Version 9, Lab. Computer Science, MIT, 1977.
- [3] Cole, C. A., Wolfram, S., et al., "SMP handbook", version 1, CALTEC, 1981.