

ストリングパターンのユニフィケーション

松山 隆司 張 汝濤

東北大学工学部情報工学科

ストリング処理における基本演算であるパターンマッチングを拡張し、ユニフィケーションを導入することにより、処理機能の向上を図ることができると考えられる。本論文では、定数記号、一文字列変数、任意文字列変数の並びとして定義されるストリングパターンのユニフィケーション・アルゴリズムを提案し、その完全性を証明する。論文では、まず正規ストリングパターンという限定されたストリングパターンに対する完全なアルゴリズムを示し、それに基づいて一般のストリングパターンのユニフィケーション・アルゴリズムが構成できることを示す。この拡張における基本思想は、一般のストリングパターンを制約条件付き正規ストリングパターンとして表現するというもので、ストリング処理における制約条件プログラミングを目指したものとなっている。

STRING PATTERN UNIFICATION

Takashi MATSUYAMA Ru-tao ZHANG

Dept. of Information Eng.

Tohoku University

Sendai, Miyagi 980

Pattern matching is an important fundamental function in string processing. The introduction of unification will realize versatile string processing functions. This paper proposes a complete algorithm of string pattern unification, where a string pattern is defined as an ordered sequence of constant symbols, unit-length variables, and arbitrary-length variables. We first confine ourselves to the regular string pattern, which is a subclass of string patterns, and prove the completeness of the unification algorithm. Then based on this simplified algorithm, we formulate a unification algorithm for general string patterns. In this formulation, we describe a general string pattern in terms of a regular string pattern with constraints. Extending this idea, we will be able to formulate the constraint programming in string processing.

1. はじめに

ストリングやリスト処理における重要な演算の1つにパターンマッチングがあり、テキストエディタやデータベース検索、自然言語処理、パターンによる関数呼び出しなど様々な分野で利用されている。一方、パターンマッチングの拡張であるユニフィケーションはPROLOGなどの論理型言語の基本演算機能として、その能力の高さが広く知られている。本論文では、ストリングを対象としたユニフィケーションアルゴリズムを提案し、その完全性を証明する。ストリングに対するユニフィケーションを基本演算として利用することにより、従来パターンマッチングを用いて行われていた各種演算の機能が大幅に向上するものと考えられる。

ストリングパターン(変数を含む文字列)のユニフィケーションとは、与えられた2つのストリングパターン中の変数に相互に文字列を代入することにより、両者を一致させる操作である。通常のユニフィケーションと異なり、ストリングパターンのユニフィケーションでは、任意長の文字列と照合する任意文字列変数があるため、完全なアルゴリズムを考えるのは難しい[1]。ここでは、まず制限されたストリングパターンを対象として、完全なユニフィケーションアルゴリズムを与える。その後、このアルゴリズムに基づいて一般のストリングパターンのユニフィケーションアルゴリズムを構成する。

以下では、まず2において、ストリングパターン及びそのユニフィケーションを定義し、2つのストリングパターンのMGCCIS (most general complete common instance set) の概念を導入する。3では、正規ストリングパターンという制限されたストリングパターンに対するユニフィケーションアルゴリズムを与え、その完全性を証明する。4では、3のアルゴリズムを拡張することにより、一般のストリングパターンに対するユニフィケーションアルゴリズムが構成できることを示す。

2. ストリングパターンのユニフィケーション

2.1 ストリングパターン

【定義1】 Σ を有限アルファベット、 Σv 、 Σu をそれぞれ可算無限個の記号集合とし、 Σ 、 Σv 、 Σu は互いに素であるとする。 Σ 、 Σv 、 Σu の要素をそれぞれ定数記号、一文字列変数、任意文字列変数と呼ぶ。ストリングパターンとは、 $\Sigma \cup \Sigma v \cup \Sigma u$ 中の要素の有限個(1個以上)の並びで、要素の個数をストリングパターンの長さと呼ぶ。特に、 Σ の要素だけからなるストリングパターンを定数ストリングと呼ぶ。(ストリングパターンの定義を長さ0以上の要素の並びとし、空文字列を導入した場合の議論は5で述べる。)

以下では a 、 b 、 c 等の文字で定数記号を表し、 $*x$ 等の $*$ から始まる文字列で一文字列変数を、 $\$x$ 等の $\$$ から始まる文字列で任意文字列変数を表す。また、ストリングパターンは、 a b c や a $\$x$ b のように、要素である定数記号や変数を空白で区切って表現する。

このことから明らかなように、ここで考えるストリングパターンのユニフィケーションアルゴリズムは、 $(a$ b $c)$ や $(a$ $\$x$ $b)$ 等のアトムリストに対してもそのまま適用できる。より一般的には、ストリングパターンのユニフィケーションの問題は、結合則を満たす関数 $f(x, y)$ によって作られる項—たとえば

$f(a, f(b, c)) = f(f(a, b), c)$ —に対する意味的ユニフィケーションを考える問題といえる[2]。

【定義2】代入 f とは全てのストリングパターンの集合 P 上の関数で、対 \langle 変数, ストリングパターン \rangle の有限集合として表現される。

$$f = \{ \langle vi, ei \rangle \mid vi \in \Sigma \cup \Sigma v, ei \in P, 1 \leq i \leq n \}$$

ここで、 n は有限の正数、 ei を vi に対する束縛と呼び、 f は以下の条件を満たす。

① $i \neq j \Rightarrow vi \neq vj$ (全ての vi は異なる)

② $vi \in \Sigma v$ の時、 $ei \in \Sigma \cup \Sigma v$ (一文字列変数には長さ1の定数文字列あるいは1つの一文字列変数しか束縛できない)

③ $vi \in \Sigma u$ の時、 $ei \in P$ (任意文字列変数にはどのようなストリングパターンでも束縛できる)

また、次の①、②、③、④を満たすパターン p に対する代入を p の改名と呼ぶ。

① $\forall i, ei \in \Sigma v \cup \Sigma u$ (全ての束縛は変数である)

② $i \neq j \Rightarrow ei \neq ej$ (変数が異なれば、対応する束縛も異なる)

③ $vi \in \Sigma u \Rightarrow ei \in \Sigma u$ (任意文字列変数には任意文字列変数が束縛される)

④ $\forall i, ei \in Vp \quad \forall p: p$ 中の変数の集合

ストリングパターン p に代入 $f = \{ \langle v1, e1 \rangle, \dots, \langle vn, en \rangle \}$ を適用した結果 $f(p)$ は、 p 中の各 vi を同時に ei ($1 \leq i \leq n$)に書き換えて得られたストリングパターンである。たとえば、代入 $f = \{ \langle *x, a \rangle, \langle \$x, \$y \$z \rangle, \langle \$y, a \$b \rangle \}$ をストリングパターン

$$p = a \$x *x b \$y$$

に対して適用すると

$$f(p) = a \$y \$z a b a b$$

以下では、ストリングパターンのことを単にパターンと略記する。

【定義3】パターン p の規定する Σ 上の言語 $L(p)$ とは、パターン p 中の各変数を任意の定数ストリングに書き換えることによって得られる定数ストリングの集合である。ここでの書き換えには次の2種類がある。

①一文字列変数を長さ1の定数ストリングに書き換える。

②任意文字列変数を長さ1以上の定数ストリングに書き換える。

パターン言語と文脈自由言語とは互いに包含関係が成り立たない。たとえば、パターン $\$x a \x によって規定される言語は、 $\{$ 中央が a で、 a の左右のストリングが等しい定数ストリング $\}$ で、文脈自由文法では表せない。また、正規文法 $A \rightarrow a \mid a A$ が表す言語は $\{ a^n \mid 1 \leq n \}$ で、1つのパターンでは表現できない。

【定義4】パターン p の間の等価関係と包含関係

①等価関係 \equiv

$$p1 \equiv p2 \text{ iff } \exists f \quad p1 = f(p2) \quad f \text{ は } p2 \text{ の改名}$$

②包含関係 \leq

$$p1 \leq p2 \text{ iff } \exists f \quad p1 = f(p2) \quad f \text{ は } 1 \text{ つの代入}$$

明らかに、 $p1 \equiv p2$ は $L(p1) = L(p2)$ を意味し、 $p1 \leq p2$ であれば $L(p1) \subseteq L(p2)$ 。また、 \leq は推移律を満たす。

パターンには次のようなクラスがある[3][4]。

①正規パターン: 全ての変数が高々1回しか現れないパターン

②一変数パターン：変数が1種類しかないパターン

③非交差パターン：任意の変数xの最左出現と最右出現の間に他の変数がないパターン

たとえば、

① $p_1 = a \$x b \$y c \$z d$

は正規パターン

② $p_2 = a \$x b \$x c \$x d$

は一変数パターン

③ $p_3 = a \$x b \$x c \$z d$

は非交差パターンである。

P_r, P_o, P_n をそれぞれ正規パターン、一変数パターン、非交差パターンの集合とすると、明らかに、 $P_r \subseteq P_n, P_o \subseteq P_n$ 。しかし、パターンが表す言語という観点からは、正規パターンが最も一般的である。つまり、一般のパターン（一変数パターン、非交差パターン等）によって規定される言語は、ある正規パターンによって規定される言語の部分集合となる。たとえば、上の p_1, p_2, p_3 に対して、 $L(p_2) \subseteq L(p_3) \subseteq L(p_1)$ 。このことは、4において一般のパターンのユニフィケーションを考えるとときに重要な役割を果たす。

2.2 スtringパターンのユニフィケーション

【定義5】2つのパターン p_1 と p_2 の共通インスタンスとは、次の①と②を満たすようなパターン p' である。

① $p' \leq p_1$

② $p' \leq p_2$

【定義6】パターンのユニフィケーションとは、2つのパターン p_1 と p_2 が与えられたとき、それぞれに代入を施すことにより、与えられた2つのパターンを同一化する操作である。すなわち、パターン p_1 と p_2 に対して $p = f_1(p_1) = f_2(p_2) \dots\dots\dots (1)$ を満たすような代入 f_1, f_2 および両者の共通インスタンス p を求める操作である。

一般に p_1 と p_2 には、 $a \$x b$ と $a \$x$ のように共通する変数が含まれているが、以下ではそのような共通変数がない場合のユニフィケーションをまず考える。このことは、 p_1 と p_2 のユニフィケーションを、2つのパターンによってそれぞれ独立に規定された言語 $L(p_1)$ と $L(p_2)$ の積集合を求める操作と考えることを意味する。こう仮定することにより、(1)の代入 f_1, f_2 の間に共通変数がなくなり、 $f = f_1 \cup f_2$ とすると、明らかに f は1つの代入で、 $p = f(p_1) = f(p_2) \dots\dots\dots (1)'$ この代入 f を p_1 と p_2 のユニファイアと呼ぶ。 $(p_1$ と p_2 に共通変数が含まれる場合のユニフィケーションは4で述べる。)

【定義7】2つのパターン p_1 と p_2 の MGCI (most general common instance) とは、

$$L(p) = L(p_1) \cap L(p_2)$$

を満たすようなパターン p である。このとき、ユニファイア $f (f(p_1) = f(p_2) = p)$ を p_1 と p_2 の MGU (most general unifier) と呼ぶ。

【定理1】(most general common instance の非存在性) 一般に、2つのパターンの全ての共通インスタンスの集合は1つのパターンで表すことができない。

【証明】2つのパターン

$$p_1 = \$x a \quad p_2 = a \$y$$

の共通インスタンスである $a a$ と $a \$z a$ は1つのパターンでは表現できない ($\$z$ にいかなる空でないパターンを代入しても $a a$ にはならない)。

(注意：任意文字列変数に空文字列の束縛を許した場合でも、 p_1 と p_2 の共通インスタンス a と $a \$z a$ は1つのパターンで表現できない。)

この定理から、いくつかのパターンの集合によって、2つのパターンの全ての共通インスタンスの集合 (common instance set) を表すことが考えられる。すなわち、2つのパターン p_1 と p_2 の共通インスタンスの集合を次の条件を満たす k 個のパターン $\{p'_1, \dots, p'_k\}$ によって表現することを考える。(一般に k は有限とは限らない)

$$L(p_1) \cap L(p_2) = L(p'_1) \cup \dots \cup L(p'_k)$$

【定義8】2つのパターン p_1 と p_2 の完全共通インスタンス集合 CCIS (Complete Common Instance Set)

$\Sigma(p_1, p_2)$ とは、 p_1 と p_2 の全ての共通インスタンスからなる集合である。すなわち

$$\Sigma(p_1, p_2) = \{p' \mid p' \leq p_1 \text{ and } p' \leq p_2\}$$

明らかに、 $\Sigma(p_1, p_2)$ は p_1 と p_2 のユニフィケーションの結果を表すが、 $\Sigma(p_1, p_2)$ 中の要素の間に等価あるいは包含関係が成り立つかもしれない。したがって、より簡潔な表現である MGCCIS (most general complete common instance set) を考える。

【定義9】2つのパターン p_1 と p_2 の most general complete common instance set (以下 MGCCIS と略記する) $\mu\Sigma(p_1, p_2)$ とは、次の①、②、③を同時に満たすようなパターンの集合である。

① $\mu\Sigma(p_1, p_2) \subseteq \Sigma(p_1, p_2)$ (consistency)

② $\forall p' \in \Sigma(p_1, p_2)$ に対し、
 $\exists p \in \mu\Sigma(p_1, p_2) \quad p' \leq p$ (completeness)

③ $\forall p, p' \in \mu\Sigma(p_1, p_2)$ に対し、
 $p \not\leq p' (p \leq p' \text{ ではない})$ (non-redundancy)

明らかに、 $\mu\Sigma(p_1, p_2)$ と $\Sigma(p_1, p_2)$ の表している言語 (要素である各パターンの表現している言語の和) は同じである。従って、 $\mu\Sigma(p_1, p_2)$ によって p_1 と p_2 のユニフィケーションの結果を表すことにすれば、完全に冗長性のない記述が得られる。

以下では、正規パターンに対象を限定し、MGCCIS の性質と、ユニフィケーションアルゴリズムを述べる。

3. 正規パターンのユニフィケーションアルゴリズム

3.1 正規パターンの MGCCIS の性質

【定理2】正規パターン p_1 と p_2 の $\mu\Sigma(p_1, p_2)$ は正規パターンだけからなる集合である。

【証明】正規パターンでない $p \in \mu\Sigma(p_1, p_2)$ が存在すると仮定する。すなわち、 p は

$$p = \alpha \$x \beta \$x \gamma$$

のような任意文字列変数 $\$x$ (一文字列変数の場合も同じ) が含まれるとする。ここで、 α, β, γ はそれぞれパターンである。

$\mu\Sigma(p_1, p_2)$ の定義および p_1, p_2 に共通変数がないことより、

$$\exists f_1, f_2 \quad f_1(p_1) = f_2(p_2) = p \\ = \alpha \$x \beta \$x \gamma$$

f_1, f_2 における $\$x$ を含む束縛の種類によって次の4つの場合に分けて考える (もし、元の p_1 (あるいは p_2) に $\$x$ が (ただ1個) 存在する場合は、代入 f_1 (あるいは f_2) に対 $\langle \$x, \$x \rangle$ があると考える。)

$$\textcircled{1} f_1 = f_1 \cup \{ \langle \$i_1, \alpha e \$x \beta b \rangle \}$$

$\langle \$i_2, \beta_e \$x \gamma_b \rangle$
 $f_2 = f_2 1U \{ \langle \$j_1, \alpha_e' \$x \beta_b' \rangle, \langle \$j_2, \beta_e' \$x \gamma_b' \rangle \}$ のとき。
 ここで、 $\$i_1, \i_2 は p_1 中の変数、 $\$j_1, \j_2 は p_2 中の変数を表す (図 1 (a))。すなわち、 p に含まれる前の $\$x$ と後ろの $\$x$ がそれぞれ異なった変数 $\$i_1$ ($\$j_1$)、 $\$i_2$ ($\$j_2$) に対する束縛によって生成されたものである場合。ここで

$$\begin{aligned} \alpha &= \alpha_b & \alpha_e &= \alpha_b' & \alpha_e' \\ \beta &= \beta_b & \beta_m &= \beta_b' & \beta_m' & \beta_e \\ \gamma &= \gamma_b & \gamma_e &= \gamma_b' & \gamma_e' \end{aligned}$$

とする。このとき、これまでに現れていない新たな変数 $\$x'$ を用いて、新たな代入

$$\begin{aligned} f_1' &= f_1 1U \{ \langle \$i_1, \alpha_e \$x \beta_b \rangle, \langle \$i_2, \beta_e \$x' \gamma_b \rangle \} \\ f_2' &= f_2 1U \{ \langle \$j_1, \alpha_e' \$x \beta_b' \rangle, \langle \$j_2, \beta_e' \$x' \gamma_b' \rangle \} \end{aligned}$$

を考えると、

$$\begin{aligned} p_1' &= f_1'(p_1) = \alpha_b \alpha_e \$x \beta_b \beta_m \beta_e \$x' \gamma_b \gamma_e \\ &= \alpha \$x \beta \$x' \gamma \\ p_2' &= f_2'(p_2) = \alpha_b' \alpha_e' \$x \beta_b' \beta_m' \beta_e' \beta_e' \$x' \gamma_b' \gamma_e' \\ &= \alpha \$x \beta \$x' \gamma \end{aligned}$$

明らかに $p_1' = p_2' = p'$ かつ $p = f(p')$ 、 $f = \{ \langle \$x', \$x \rangle \}$ となる p' が存在する。

② $f_1 = f_1 1U \{ \langle \$i, \alpha_e \$x \beta \$x \gamma_b \rangle \}$
 $f_2 = f_2 1U \{ \langle \$j_1, \alpha_e' \$x \beta_b' \rangle, \langle \$j_2, \beta_e' \$x \gamma_b' \rangle \}$

のとき。ここで、 $\$i$ は p_1 中の変数で、 $\$j_1$ と $\$j_2$ は p_2 中の変数である (図 1 (b))。すなわち、 p に含まれる 2 つの $\$x$ は、 f_1 では $\$i$ に対する束縛によって生成され、 f_2 では $\$j_1$ と $\$j_2$ に対する束縛によって生成されたものである場合。ここで

$$\begin{aligned} \alpha &= \alpha_b & \alpha_e &= \alpha_b' & \alpha_e' \\ \beta &= \beta_b & \beta_m &= \beta_b' & \beta_m' & \beta_e \\ \gamma &= \gamma_b & \gamma_e &= \gamma_b' & \gamma_e' \end{aligned}$$

とする。このとき、これまでに現れていない新たな変数 $\$x'$ を用いて、新たな代入

$$\begin{aligned} f_1' &= f_1 1U \{ \langle \$i, \alpha_e \$x \beta \$x' \gamma_b \rangle \} \\ f_2' &= f_2 1U \{ \langle \$j_1, \alpha_e' \$x \beta_b' \rangle, \langle \$j_2, \beta_e' \$x' \gamma_b' \rangle \} \end{aligned}$$

を考えると、

$$\begin{aligned} p_1' &= f_1'(p_1) = \alpha_b \alpha_e \$x \beta \$x' \gamma_b \gamma_e \\ &= \alpha \$x \beta \$x' \gamma \\ p_2' &= f_2'(p_2) = \alpha_b' \alpha_e' \$x \beta_b' \beta_m' \beta_e' \beta_e' \$x' \gamma_b' \gamma_e' \\ &= \alpha \$x \beta \$x' \gamma \end{aligned}$$

明らかに、 $p_1' = p_2' = p'$ かつ $p = f(p')$ 、 $f = \{ \langle \$x', \$x \rangle \}$ となる p' が存在する。

③ $f_1 = f_1 1U \{ \langle \$i_1, \alpha_e \$x \beta_b \rangle, \langle \$i_2, \beta_e \$x \gamma_b \rangle \}$
 $f_2 = f_2 21U \{ \langle \$j_1, \alpha_e' \$x \beta_b' \rangle \}$
 ④ $f_1 = f_1 1U \{ \langle \$i, \alpha_e \$x \beta \$x \gamma_b \rangle \}$
 $f_2 = f_2 21U \{ \langle \$j, \alpha_e' \$x \beta \$x \gamma_b' \rangle \}$
 の場合も同じように、 $p = f(p')$ かつ $f_1'(p_1) = f_2'(p_2) = p'$ を満たすような p' が求められる。




図 1 正規パターン p_1 と p_2 の共通インスタンス

明らかに $p' \in \Sigma(p_1, p_2)$ であり、
 (a) $p' \in \mu \Sigma(p_1, p_2)$ ならば、 $p \leq p'$ ($p = f(p')$ から) なので、定義 9 の条件 ③ によって $p \in \mu \Sigma(p_1, p_2)$
 (b) $p' \in \mu \Sigma(p_1, p_2)$ ならば、定義 9 の ② より、 $\exists p'' \in \mu \Sigma(p_1, p_2)$ かつ $p' \leq p''$ 。また、 $p \leq p''$ および \leq は推移律を満たすことから $p \leq p''$ となり、 $p \in \mu \Sigma(p_1, p_2)$
 (a)、(b) いずれの場合でも $p \in \mu \Sigma(p_1, p_2)$ になる。これは最初の仮定に矛盾する。■

以上のことから、正規パターン p_1 と p_2 の $\mu \Sigma(p_1, p_2)$ は正規パターンの集合であることが証明された。

以下では正規パターンの完全なユニフィケーションアルゴリズムについて述べる。ここでの完全性とは、(共通変数のない) 2 つの正規パターン p_1 と p_2 に対して、有限時間で、 $\mu \Sigma(p_1, p_2)$ が求められることをいう。

3. 2 アルゴリズム R

2 つの正規パターン p_1 と p_2 があり、それぞれの長さを m, n とする。 p_{1i} を p_1 の i 番目の要素、 p_{2j} を p_2 の j 番目の要素とする。 ($1 \leq i \leq m, 1 \leq j \leq n$)
 ① $m * n$ の大きさの配列 A を作る。

② for $i = 1$ to m do
 if p_{1i} が任意文字列変数
 then A ($i, 1$), ..., A (i, n) に印を付け、
 A ($i, 1$) から A ($i, 2$) へ

 A ($i, n-1$) から A (i, n) へ
 リンクを付ける。

```

elseif p1iが一文字列変数
then A(i,1), ..., A(i,n)に印を付け
る(図2(a))
③for j=1 to n do
if p2jが任意文字列変数
then A(1,j), ..., A(m,j)に印を付け、
A(1,j)からA(2,j)へ
.....
A(m-1,j)からA(m,j)へ
リンクを付ける。
elseif p2jが一文字列変数
then A(1,j), ..., A(m,j)に印を付
ける(図2(b))

```

```

④for i=1 to m do
for j=1 to n do
if p1i, p2jが共に定数記号かつp1i=p2j
then A(i,j)に印を付ける(図2(c))
⑤for i=1 to m do
for j=1 to n do
if A(i,j)とA(i+1,j+1)に印が存在する
then A(i,j)からA(i+1,j+1)へリンク
を付ける。(図2(d))

```

⑥ A(1,1) から A(m,n) までの全ての道(連続する有向のリンクの並び)を求める。

以上のアルゴリズムにおいて、各道は2つの正規パターンの共通インスタンスと対応する。もし1つの道もなければ、2つのパターンのユニフィケーションは失敗となる。このアルゴリズムによる2つの正規パターン

$p1 = \$x1 \ b \ c \ \$y1 \ f \ g \ h$
 $p2 = \$x \ a \ b \ \$y \ e \ f \ \$z$

のユニフィケーションの例を図3に示す。

【道が表す共通インスタンスの計算法】

道の上の全ての点 A(i, j) に対して

```

①if p1i, p2jのいずれかが定数記号
then その定数を採る。
②elseif p1i, p2jのいずれかが一文字列変数
then 新たな一文字列変数(*ij)を生成する。
③else 新たな任意文字列変数($ij)を生成する。
道に対応する共通インスタンスは、上の①②③で得られた記号をA(1,1)からA(m,n)まで道を辿った順に並べたものである。上の②と③で生成された一文字列変数、任意文字列変数は全て互いに異なり、p1あるいはp2に含まれないものとする。

```

【道が表すユニファエアの計算法】

①任意文字列変数の束縛

p1iを任意文字列変数とする(p2jが任意文字列変数の場合も同様)。道の上に必ず A(i, j1) から A(i, j2) までの連続した水平リンクの並びがある(極端な場合 j1=j2)。その道が表す共通インスタンスの中で、A(i, j1) から A(i, j2) までに対応する部分パターンを p1i の束縛とする。

②一文字列変数の束縛

p1iを一文字列変数とする(p2jが一文字列変数である場合も同様)。道の上に A(i, j) があり、その道の表す共通インスタンスにおいて、A(i, j) に対応する部分パターン(長さ1)を p1i の束縛とする。

上の①と②で求めた変数の束縛の集合が p1 と p2 のユニファエアである。

アルゴリズムRで求めた道 i に対応する共通インスタ







図2 アルゴリズムR(本文参照)




図3 ユニフィケーションの例




図4 任意文字列変数のみからなるパターンのユニフィケーション

ンス、ユニファエアを r_i, f_i とすると、明らかに $f_i(p1) = f_i(p2) = r_i \dots (2)$

たとえば、図3中の破線で示した道に対応する共通インスタンスとユニファエアはそれぞれ

$r = \$1 \ a \ b \ c \ \$2 \ e \ f \ g \ h$
 $f = \{ \langle \$x, \$1 \rangle, \langle \$y, c \ \$2 \rangle, \langle \$z, g \ h \rangle, \langle \$x1, \$1 \ a \rangle, \langle \$y1, \$2 \ e \rangle \}$

となる。

3.3 アルゴリズムRの計算量

アルゴリズムRには6つのステップがあり、最も計算量が多いのはステップ6の道の探索過程である。このステップの計算量は道の数に依存する。また、道の数は $p1, p2$ に含まれる任意文字列変数の数に依存する。最悪の場合は、 $p1$ も $p2$ も任意文字列変数のみからなるときで、図4に示すように、

$N(i, j)$ を A(1,1) から A(i, j) までの道の数とすると、

$$N(i, 1) = 1 \quad (1 \leq i \leq m) \quad \dots (3.1)$$

$$N(1, j) = 1 \quad (1 \leq j \leq n) \quad \dots (3.2)$$

$$N(i, j) = N(i-1, j) + N(i, j-1) + N(i-1, j-1) \quad (1 < i \leq m, 1 < j \leq n) \dots (3.3)$$

が成り立つ。(3.1)、(3.2)、(3.3)を解くと、

$$N(m, n) = \frac{(m+n)!}{m!n!}$$

$$\text{また、} \frac{(m+n)!}{m!n!} \leq \frac{(m+n)!}{((m+n)/2)!((m+n)/2)!}$$

$$\doteq \frac{(m+n)^{m+n}}{((m+n)/2)^{(m+n)/2} ((m+n)/2)^{(m+n)/2}}$$

$$= \frac{(m+n)^{m+n}}{((m+n)/2)^{m+n}} \doteq 2^{m+n}$$

従って、ステップ6 (アルゴリズムR) の計算量の最悪値は $O(2^{m+n})$ となる。

3.4 MGCCISの計算

アルゴリズムRから、 $\mu \Sigma(p_1, p_2)$ が求められることは次の定理3、4によって証明される。

【定理3】正規パターン p_1 と p_2 に対して、アルゴリズムRで求められた共通インスタンスの集合を $\{r_1, r_2, \dots, r_k\}$ とし、 p' を p_1 と p_2 の任意の共通インスタンスとすると、 $\exists k, 1 \leq k \leq K, p' \leq r_k \dots (4)$

【証明】 p_1 と p_2 の任意の共通インスタンス p' が、アルゴリズムRで求めた配列A中の1つの道と対応付けられることを証明すればよい。

p_1, p_2 の長さをそれぞれ m, n とする。

まず、 p' は p_1 と p_2 の共通インスタンスなので、

$$\exists f_1, f_2, p' = f_1(p_1) = f_2(p_2)$$

ここで f_1 と f_2 は代入である。このとき、 p' 中の $p'_t \dots p'_{t+x}$ ($0 \leq x$) という部分パターンに対して、 p_1, p_2 中の変数の束縛の重なり方を考えると、次の4つの場合がある (図5(a))

① $p'_t \dots p'_{t+x}$ が p_1, p_2 中の定数ストリングに対応する場合。すなわち、

$$\exists i, j, p_{1i} \dots p_{1i+x} = p_{2j} \dots p_{2j+x} = p'_t \dots p'_{t+x}$$

かつ p'_t, \dots, p'_{t+x} が全て定数記号である。このとき、配列Aには $A(i, j)$ から $A(i+x, j+x)$ への連続する斜めリンクの並びがある。

② $p'_t \dots p'_{t+x}$ が p_1 中の定数ストリング、 p_2 中の変数と対応する (変数が一文字列変数の時は $x=0$) 場合。すなわち、

$$\exists i, j, p'_t \dots p'_{t+x} = p_{1j} \dots p_{1i+x}, < p_{2j}, \dots, p'_{t+x} > \in f_2$$

かつ p'_t, \dots, p'_{t+x} が全て定数記号である。このとき、配列Aには $A(i, j)$ から $A(i+x, j)$ への連続する縦リンクがある。

③ $p'_t \dots p'_{t+x}$ が p_2 の定数ストリング、 p_1 の変数と対応する場合。これは②と同様。

④ $p'_t \dots p'_{t+x}$ が p_1 と p_2 の変数と対応する場合。すなわち、

$$\exists i, j, < p_{1i}, \dots, p'_t \dots p'_{t+x} \dots > \in f_1 < p_{2j}, \dots, p'_t \dots p'_{t+x} \dots > \in f_2$$

このとき、配列A中の $A(i, j)$ に印が付けられる。これは、 p_{1j}, p_{2j} がそれぞれ任意文字列変数あるいは一文字列変数であるからである。

次に、共通インスタンス p' 上において、上で考えた4つの場合の部分パターンの並び方を考える。





図5 定理3の証明図

①の後ろに②が続く場合。すなわち、図5(b)に示すように、 p_1 中の $p_{1i} \dots p_{1i+x}, p_2$ 中の $p_{2j} \dots p_{2j+x}$ が p' 中の定数部分パターン $p'_t \dots p'_{t+x}$ と対応し、 p_1 中の $p_{1i+x+1} \dots p_{1i+x+y}, p_2$ 中の変数 p_{2j+x+1} が $p'_t \dots p'_{t+x+y}$ と対応する。 p_{2j+x+1} は変数なので、 $A(1, j+x+1), \dots, A(m, j+x+1)$ には印が付けられており、 $A(i+x, j+x)$ から $A(i+x+1, j+x+1)$ へのリンクが付けられる。すると、①と②の場合に求まる2つの部分連続リンクが1つの連続リンクになり、この連続リンクが p' 中の $p'_t \dots p'_{t+x+y}$ と対応する。

同様に、①②③④の任意の2つの場合の組み合わせに対して、それぞれの対応する部分連続リンクの間にリンクが付けられ、1つの連続リンクとなり、最後に、 p' 全体がA中の1つの道と対応する。また、①②③④のどの場合が一番初め、あるいは一番終りにあっても $A(1, 1)$ と $A(m, n)$ は道に入る。

以上のことから、 p_1 と p_2 の任意の共通インスタンスを配列A中の道に対応付けることができ、その道が表す共通インスタンスを r_k とすると $p' = f(r_k)$ が成り立つ。ここで、 f は $\{ < \$ij, p'_t \dots p'_{t+x} > \}$ と表せ、 $\$ij$ は上の④の場合における p_{1i}, p_{2j} に対応する変数、 $p'_t \dots p'_{t+x}$ はそのときの p' 中の部分パターンである。

この定理から、アルゴリズムRは

- ①全ての解が求められる。
 - ②有限時間で止まる。(配列Aが有限であるから)
- また、このアルゴリズムで求めた全ての r_k は $r_k \in \Sigma(p_1, p_2) \dots (5)$

であるから、 $\{r_1, r_2, \dots, r_k\}$ はMGCCISの条件の①と②を満たす(式(4)、式(5)より)。したがって、 $R = \{r_1, r_2, \dots, r_k\}$ から $r_i \leq r_j$ を満たすような r_i を除去すれば、残ったものが $\mu \Sigma(p_1, p_2)$ となる。

以下ではこのような ri の除去法について述べる。

【定理4】 $p1 \leq p2$ iff $\mu \Sigma (p1, p2) = \{p1\}$

【証明】 \Rightarrow $p1 \leq p2$ と仮定する。 $p1 \leq p1$ なので、 $p1 \in \Sigma (p1, p2)$ 。また、 $\Sigma (p1, p2)$ の定義より、 $\forall p' \in \Sigma (p1, p2) p' \leq p1$

したがって、 $\mu \Sigma (p1, p2) = \{p1\}$

\Leftarrow $\mu \Sigma (p1, p2) = \{p1\}$ と仮定すると、

$\mu \Sigma (p1, p2)$ の定義より、 $p1 \leq p2$ 。■

定理3、4より、 $p1 \leq p2$ ならば改名を除き $p1 \in R = \{r1, \dots, rk\}$ となる。このことから、2つのパターン $p1, p2$ に対してアルゴリズム R を適用して得られた $R =$

$\{r1, \dots, rk\}$ に含まれる任意の ri, rj に対して再びアルゴリズム R を適用し、その結果を R' とすると、(改名を除き) $ri \in R'$ (あるいは $rj \in R'$) であれば、 $ri \leq rj$ (あるいは $rj \leq ri$) となり、 R から ri (あるいは rj) を除去する。($ri \in R'$ の判定は ri, rj のユニフィケーションに用いた配列中の道の形から容易に判断できる)。このようにして、 R から $ri \leq rj$ を満たす ri を除去することにより $\mu \Sigma (p1, p2)$ が求められる。

以上のことから、アルゴリズム R によって、正規パターン $p1, p2$ の $MGCCIS \mu \Sigma (p1, p2)$ が有限時間で計算できることが示された。

3.5 MGCCUS の計算

ここでは、2つの正規パターンの most general complete unifier set を定義し、その求め方を示す。

【定義10】 2つの代入 $f1$ と $f2$ があるとする。

$$f1 = \{ \langle v1i, e1i \rangle \mid 1 \leq i \leq m \}$$

$$f2 = \{ \langle v2j, e2j \rangle \mid 1 \leq j \leq n \}$$

このとき、 $f1$ と $f2$ の合成 $f1 \circ f2$ とは、

$$\{ \langle v2j, f1(e2j) \rangle \mid 1 \leq j \leq n \} \cup$$

$$\{ \langle v1i, e1i \rangle \mid 1 \leq i \leq n \}$$

から次の①あるいは②を満たすような対を除いたものである。

① $\langle x, x \rangle$ のような対 (x は変数)

② $\exists 1 \leq j \leq n v2j = v1i$ を満たす対 $\langle v1i, e1i \rangle$

代入 f を $f = f1 \circ f2$ 、 p をパターンとしたとき、

$$f(p) = f1(f2(p)) \leq f2(p)$$

が成り立つ。

【定義11】 2つのパターン $p1$ と $p2$ の完全ユニファイア集合、 $U \Sigma (p1, p2)$ を

$$U \Sigma (p1, p2) = \{ f \mid f(p1) = f(p2) \}$$

とする。

明らかに、2つのパターンの完全ユニファイア集合の要素は無数個ある可能性がある。また、完全ユニファイア集合には幾つかの冗長なものが含まれるかもしれない。したがって、完全ユニファイア集合より簡潔な $MGCCUS$ (most general complete unifier set) を考える。

【定義12】 2つのパターン $p1$ と $p2$ の Most General Complete Unifier Set (以下では $MGCCUS$ と略記する) $\mu U \Sigma (p1, p2)$ は同時に次の①、②、③を満たすようなものである。

① $\mu U \Sigma (p1, p2) \subseteq U \Sigma (p1, p2)$

② $\forall f \in U \Sigma (p1, p2)$ に対して

$$\exists f' \in \mu U \Sigma (p1, p2) \exists \theta \theta \circ f' = f$$

③ $\forall f1, f2 \in \mu U \Sigma (p1, p2)$ 、 $f1 \neq f2$ に対して $\forall \theta \theta \circ f1 \neq f2 \wedge \theta \circ f2$

一般のパターンに対して、 $\mu U \Sigma (p1, p2)$ が有限




図6 定理5の証明図

かどうかは分からないが、次の定理より正規パターンに対しては、 $\mu U \Sigma (p1, p2)$ は有限で、かつアルゴリズム R で求めたユニファイア集合は $MGCCUS$ であることが示される。

【定理5】 アルゴリズム R で求めたユニファイアの集合は $p1$ と $p2$ の $MGCCUS \mu U \Sigma (p1, p2)$ である。

【証明】 2つの正規パターン $p1$ と $p2$ に対して、アルゴリズム R で求めたユニファイアの集合を $F = \{f1, f2, \dots, fk\}$ とする。 $fi(p1) = fi(p2)$ ($1 \leq i \leq k$) から、 $F \subseteq U \Sigma (p1, p2)$ 。また、定理3および代入の合成の定義より $\forall f' \in U \Sigma (p1, p2)$ に対して、 $\exists \theta \exists i, \theta \circ fi = f'$ 。

次に $\forall 1 \leq i, j \leq k i \neq j \Rightarrow \forall \theta fi \neq \theta \circ fj$ (あるいは $fj \neq \theta \circ fi$) であることを証明する。

$i \neq j$ なので、アルゴリズム R で求めた fi と fj に対応する配列 A 中の道も異なる。その2つの道をそれぞれ li, lj とする。 li, lj の作り方から、 li と lj は必ずどこかで交わる。この分岐点からの2つの道の出方は図6 (a)の①と②、または①と③、②と③の3つの可能性がある。

(a) 分岐点からの2つの道の出方が①と②である場合 (図6 (b))

分岐点 a の位置を $A(x, y)$ とすると、パターン $p1$ 中の x 番目の記号 $p1x$ は任意文字列変数である。 a を含む li と lj に共通する道のうち、 a および a の前の水平部分に対応する共通インスタンスの部分パターンを $S1$ 、 a の後ろの水平部分に対応する部分パターンを $S2$ とする。

(a.1) 分岐点 a から水平へ行く道を li 、斜めへ行く道を lj とする。明らかに、

$$\langle p1x, S1 \rangle \in f1 \text{ かつ } \langle p1x, S1S2 \rangle \in fi.$$

$fi = \theta \circ fj$ が成り立つためには、 θ は次の等式を満たさなければならない。

$$\theta(S1) = S1S2$$

① $S1$ に任意文字列変数が含まれていなければ

$$\theta(S1) \neq S1S2$$

となり、 $fi = \theta \circ fj$ を満たすような θ は存在しない (両辺のパターンの表すストリングの長さが異なる)。

② $S1$ に任意文字列変数が含まれているとき (この場合、 $p2$ 中の $S1$ と対応する部分にも任意文字列変数がある図6 (c))、 $\theta(S1) = S1S2$ が成り立つためには、 $S1$ 中の任意文字列変数に別のパターンを代入しなければならない。今、 $S1$ 中の任意文字列変数 $\$xy'$ にパターン Sxy' を代入することを考える。すなわち、

$$\langle \$xy', Sxy' \rangle \in \theta \text{ かつ } \$xy' \neq Sxy'$$

一方、 $p2$ 中の $\$xy'$ と対応する任意文字列変数を $p2y'$ とすると、 fi には $\langle p2y', \$xy' \rangle$ が含まれ、 fj にも

$\langle p_2y', \$xy' \rangle$ が含まれる。すると、
 $\langle p_2y', \$xy' \rangle \in \theta \circ f_j$
 $\langle p_2y', \$xy' \rangle \in f_i$
 となり、 $\theta \circ f_j \ni f_i$ 。
 したがって $f_i = \theta \circ f_j$ を満たすような θ は存在しない。
 (a.2) 分岐点から水平へ行く道を l_j 、斜めへ行く道を l_i とする。明らかに、
 $\langle p_1x, S1 \rangle \in f_i$ かつ $\langle p_1x, S1S2 \rangle \in f_j$
 $f_i = \theta \circ f_j$ が成り立つためには、 θ は次の等式を満たさなければならない。

$$S1 = \theta(S1S2)$$

上式を満たす θ は存在しないから (両辺の長さが異なる)、
 $f_i = \theta \circ f_j$ を満たす θ は存在しない。

②と③、①と③の場合も同じように、 $\theta \circ f_j = f_i$ を満たすような θ は存在しないことが証明される。従って、アルゴリズムRによって求められたユニファイアの集合 $\{f_1, \dots, f_k\}$ は、2つの正規パターンのMGCUSである。■

定理5から、MGCCISの場合と同じように、2つの正規パターンのMGCUSは有限個であり、アルゴリズムRでそれら全てが求められる。アルゴリズムRで求まる共通インスタンスの集合の中には冗長なものが含まれており、それを除去したものが $\mu \Sigma(p_1, p_2)$ となっていたのに対し、アルゴリズムRで求めたユニファイアの集合はそのまま $\mu U \Sigma(p_1, p_2)$ となる。

4. 一般パターンのユニフィケーション

アルゴリズムRでは、2つのパターン p_1, p_2 に次の制限を設けていた。

- ① p_1, p_2 は共に正規パターンである。
 - ② p_1, p_2 には共通する変数が存在しない。
- ここでは、これらの制限を除いた一般のパターンのユニフィケーションについて述べる。

正規パターンのユニフィケーションの結果 (MGCCISあるいはMGCUS) は有限集合であったが、一般パターンのMGCCISとMGCUSは有限とは限らない。たとえば、2つのパターン

$$p_1 = \$x \ a \ \$x$$

$$p_2 = a \ \$y \ a \ \$y \ a$$

の完全共通インスタンス集合 $\Sigma(p_1, p_2)$ を考えてみよう。まず、 p_1 が a を中心として左右対称であるから、 p_2 が p_1 と等しいのは、 $a \ \$y = \$y \ a$ が成り立つ時だけである。また、 $a \ \$y = \$y \ a$ は、 $\$y = a, a a, a a a, \dots$ に対してのみ成り立つ。

以上のことから、 p_1 と p_2 の完全共通インスタンス $\Sigma(p_1, p_2)$ は $\{a^{3+2n} \mid 1 \leq n\}$ となり、有限個のパターンで表せない。また、この集合がMGCCISの3つの条件を満たしているから、上の、2つのパターンのMGCCIS $\mu \Sigma(p_1, p_2)$ も $\{a^{3+2n} \mid 1 \leq n\}$ となり、無限集合となる。同様に、上の2つのパターンのMGCUSも無限集合となる。

以下では、一般パターンを正規パターンに制約条件を付けたものとして表現し、アルゴリズムRを用いて一般パターンのユニフィケーションを行うことを考える。また、MGCCIS、MGCUSについても制約条件を用いることにより、無限集合を間接的に表現するという方法を用いる。

4.1 制約付き正規パターンによる一般パターンの表現

2で述べたように、正規パターンが表現しているパターン言語は最も一般的である。逆にいうと、正規パターンに制約を付けたものとして一般パターンを表すことができる。たとえば、パターン

$p_1 = \$x \ a \ \x $p_2 = \$x_1 \ a \ \x_2
 に対して、明らかに $p_1 \leq p_2$ なので、 $L(p_1) \subseteq L(p_2)$ 。すなわち、 $L(p_2)$ を生成するとき、 $\$x_1$ に束縛される定数文字列と $\$x_2$ に束縛される定数文字列が等しい代入によって生成された定数文字列の集合が $L(p_1)$ となる。このことから、正規パターン p_2 に $\$x_1 = \x_2 という制約を付けたものとして一般パターン p_1 を表すことにする。

一般パターンを制約条件付き正規パターンに変換するには、

①パターン中の同一変数を互いに異なる新たな変数に書き換える。

②①で導入された同一変数を表す新たな変数の対を "==" で結ぶ。

たとえば、パターン

$$\$x \ a \ \$y \ b \ \$x \ \$y \ a \ \$x$$

$$\$x_1 \ a \ \$y_1 \ b \ \$x_2 \ \$y_2 \ a \ \$x_3$$

where $\$x_1 = \$x_2 \ \& \ \$x_2 = \$x_3 \ \& \ \$y_1 = \y_2 と変換される。ここで、whereはそれ以降が制約条件であることを示す特殊記号である。

制約条件を利用することにより、

① $\{a^n\} = \{a, aa, aaaa, \dots\}$ など、これまで1つのパターンで表現できなかった言語が、制約条件付きパターン $\$x \ where \ \$x \ a = a \ \$x$ によって記述できる。

② $p_1 = a \ \$x$ と $p_2 = \$x \ a$ のユニフィケーションといった、ユニファイする2つのパターンに共通変数がある場合、まず $p_1' = a \ \$x_1$ と $p_2' = \$x_2 \ a$ のユニフィケーションを行い、その共通インスタンスであるパターンに $\$x_1 = \x_2 という制約条件を加えればよいことになる。

4.2 一般パターンのユニフィケーション

ここでは、正規パターンのユニフィケーションアルゴリズムRに基いて一般パターンのユニフィケーションアルゴリズムを構築することを考える。

一般パターン p_1 と p_2 に対応する正規パターンをそれぞれ p'_1, p'_2 とし、 $p_1 = p'_1$ where C_1 、 $p_2 = p'_2$ where C_2 とする。ここで C_1, C_2 は == 式の AND 結合による制約条件を表す。また、 p_1 と p_2 の共通変数に対応する p'_1, p'_2 中の変数を == で結んだ式の AND 結合による制約条件を C_3 とする。 p_1 と p_2 のユニフィケーションの結果を Q 、 p'_1 と p'_2 のユニフィケーションの結果を Q' ($Q' = L(p'_1) \cap L(p'_2)$) とすると、 Q は Q' の部分集合で、 Q' に含まれるパターンの内、制約条件 C_1, C_2, C_3 を同時に満たすものの集合である。

以上の考察から、一般パターン p_1 と p_2 とのユニフィケーションは次のように行う。

① p_1 と p_2 を制約付き正規パターンに変換する。

$$p_1 = p'_1 \ where \ A_{11} = B_{11}, \dots, \ A_{1m} = B_{1m}$$

$$p_2 = p'_2 \ where \ A_{21} = B_{21}, \dots, \ A_{2n} = B_{2n}$$

また、 p_1, p_2 の共通変数に対応する p'_1, p'_2 中の変

数を == で結び

where $A_{31} == B_{31}, \dots, A_{3k} == B_{3k}$
とする。ここで A_{ij}, B_{ij} はパターンを表す。
② アルゴリズム R によって、 p_1 と p_2 のユニフィケーションを行う。このときの MGCUS を $\mu \cup \Sigma (p_1, p_2) := \{f_1, f_2, \dots, f_k\}$ とする。
③ 各 f_i に対して、where の後の全ての == 式 ($A_{11} == B_{11}, \dots, A_{1m} == B_{1m}, A_{21} == B_{21}, \dots, A_{2n} == B_{2n}, A_{31} == B_{31}, \dots, A_{3k} == B_{3k}$) の両辺に代入 f_i を施し、制約条件の簡約化を行う。簡約化は次の手続き simplify によって行う。

【制約条件の簡約化】

まず、代入 f_i の下で、1つの式 $A == B$ を簡約化する手続き simplify-1 を示す。以下において、 m, n をそれぞれパターン A、B の長さ、 A_i を A の i 番目の要素、 B_j を B の j 番目の要素とする ($1 \leq i \leq m, 1 \leq j \leq n$)。empty は空ストリング、\$variable は任意文字列変数、*variable は一文字列変数を表す。

```
simplify-1(A, B, fi)
begin
  A=fi(A) ; m=length(A)
  B=fi(B) ; n=length(B)
1> if A=B then return(nil, fi)
2> elseif A is empty then return("fail")
3> elseif B is empty then return("fail")
4> elseif A1=B1
   then simplify-1(A2... Am, B2... Bn, fi)
5> elseif Am=Bn
   then simplify-1(A1... Am-1, B1... Bn-1, fi)
6> elseif A1 and B1 are constant and A1≐B1
   then return("fail")
7> elseif Am and Bn are constant and Am≐Bn
   then return("fail")
8> elseif A1 is a *variable and B1 is not a
   $variable
   then let f'i= {<A1, B1>} • fi
   simplify-1(A2... Am, B2... Bn, f'i)
9> elseif B1 is a *variable and A1 is not a
   $variable
   then let f'i= {<B1, A1>} • fi
   simplify-1(A2... Am, B2... Bn, f'i)
10> elseif Am is a *variable and Bn is not a
   $variable
   then let f'i={<Am, Bn>} • fi
   simplify-1(A1... Am-1, B2... Bn-1, f'i)
11> elseif Bn is a *variable and Am is not a
   $variable
   then let f'i={<Bn, Am>} • fi
   simplify-1(A1... Am-1, B1... Bn-1, f'i)
12> elseif A is a string consisting of only
   one $variable
   then if A1 is a member of B
   then return("fail")
   else let f'i={<A1, B>} • fi
   return((nil f'i))
13> elseif B is a string consisting of only
   one $variable
   then if B1 is a member of A
   then return("fail")
```

```
else let f'i={<B1, A>} • fi
return((nil f'i))
14> else return((A, B) fi)
end
次に、simplify-1を用いて、リストとして表現された
==式の集合 {A1==B1, ..., Ar==Br} に対する、代入
fiの下での簡約化アルゴリズムsimplifyを与える。
simplify(((A1, B1), ..., (Ar, Br)), fi)
begin
  n=1
  m=length((A1, B1), ..., (Ar, Br))
  store=()
  loop1
  M=simplify-1(An, Bn, fi)
  if M="fail" then return("fail")
  else f'i=second(M)
  n=n+1
  append first(M) to store
  if fi≐f'i
  then append (An, Bn), ..., (Ar, Br) to store
  simplify(store, f'i)
  elseif n<=m then go loop1
  else return((store, f'i))
end
```

【手続き simplify の停止性】

① simplify-1 は $k \leq \min \{ \text{length}(f_i(A)), \text{length}(f_i(B)) \}$ 回の再帰適用で止まる。(1> 2> 3> 6> 7> 13> 14> の場合 simplifyはすぐに止まり、他の場合はAとBの長さを1減らす。)

② simplifyの再帰呼び出しの条件 $f_i \neq f'i$ は simplify-1中で新しい束縛が生成された場合にのみ成り立つ。しかし、制約条件の集合を表すリスト $((A1, B1), \dots, (Ar, Br))$ に現れる変数の個数は有限であり、simplify-1における $f'i$ の生成では新たな変数は導入されない。したがって、simplifyの再帰適用で変数の数は減少するのみである。このため、simplifyの再帰適用も有限回しか生じない。

【simplifyの適用結果】

① simplifyを適用した結果が "fail" であれば、 f_i は p_1 と p_2 のユニファイアではない。

② simplifyを適用した結果が $((A'1, B'1), \dots, (A'r', B'r'))$ 、 $f'i$ であれば、 $f'i$ where $A'1 == B'1, \dots, A'r' == B'r'$ が p_1 と p_2 のユニファイアの候補となる。ここで、ユニファイアに対する == 式による制約条件の意味は制約付きパターンの場合と同じである。

③ simplifyを適用した結果が $(nil, f'i)$ であれば、 $f'i$ は p_1 と p_2 のユニファイアである。

上の②と③で得られたユニファイア(候補)からなる集合 $\{f'c1, f'c2, \dots, f'ck'\}$ が p_1 と p_2 のユニファイア(候補)集合である。

以上の議論から、一般パターンのユニフィケーションにおけるユニファイア集合は有限集合で表せるようになる。ただし、ユニファイアにも == 式を含む可能性があり、そうしたユニファイアの候補が真のユニファイアであるかどうか(全ての制約条件を満たす解が存在するかどうか)は判定できない。

【共通インスタンスの求め方】

各ユニファイア（候補） $fci(f_i \text{ あるいは } f_i \text{ where } A1==B1, \dots, Ar==Br)$ の形式）に対応する共通インスタンスは $fci(p1)$ あるいは $fci(p2)$ である。 fci が制約条件付きのユニファイアであるときは、 $fci(p1) = f_i(p1) \text{ where } A1==B1, \dots, Ar==Br$ となり、2つのパターンの共通インスタンスにも $==$ が含まれる可能性がある。たとえば、パターン $\$x \ a \ \x と $a \ \$y \ a \ \$y \ a$ のユニフィケーション結果は

①ユニファイア $\{ \langle \$x, a \ \$z \rangle, \langle \$y, \$z \rangle \}$
where $a \ \$z == \$z \ a$

②共通インスタンス

$a \ \$z \ a \ \$z \ a$ where $a \ \$z == \$z \ a$
となる。

5. まとめ

本論文では、ストリングパターンのユニフィケーションについて検討し、正規パターンに対する完全なユニフィケーションアルゴリズムを与え、それに基づいて一般パターンのユニフィケーションアルゴリズムを構成した。その際、制約条件付き正規パターンによる一般パターンの表現と、制約条件の簡約化手続きを与えた。

制約条件を用いることにより、全ての解を求め、有限時間で停止する一般パターンのユニフィケーション・アルゴリズムが構成できたが、得られた共通インスタンスやユニファイアにも制約条件が付けられることになり、今のところ制約条件を満たす解が存在するかどうかを決定する手続きはない。この問題は、CLP [5]などの制約条件プログラミング言語に共通した問題であり、より強力な制約条件の簡約化手続きを開発する必要がある。

本論文では、任意文字列変数に空ストリングを束縛できないとしたが、空ストリングが束縛できる変数 $\$x$ を含む拡張パターン $p = \alpha \ \$x \ \beta$ を $\{ \alpha \ \beta, \alpha \ \$x \ \beta \}$ のように $\$x$ が空の場合とそうでない場合を表す2つのパターンの集合として表現することにより、アルゴリズムRで拡張パターンのユニフィケーションを行うことができる。ここで α, β はパターンを表す。また、アルゴリズムRの⑤における斜めリンクの設定法を改良することにより任意文字列変数に空ストリングの束縛を許したユニフィケーション・アルゴリズムが容易に構成できる [6]。

本論文で述べたストリングパターンのユニフィケーションを基本演算とすることにより、ストリングを対象とした制約条件プログラミングを実現することができる。我々は、その1つの試みとしてユニフィケーションと制約条件に基づくストリング、リスト処理言語を開発した [6]。この言語については稿を改めて報告する。

最後に本研究を行うにあたり、有益なコメントと熱心な議論をして頂いた伊藤貴康教授に感謝します。また、本研究は、文部省科学研究費一般研究A (60420035)の補助を受けて行われた。

【参考文献】

- [1]赤間 清(1986): 文字列領域における一般化と統一化のアルゴリズム, 情報処理学会知識工学と人工知能研究会資料, 86-AI-45
- [2]Plotkin, G.D. (1972): Building-in Equational Theories, Machine Intelligence Vol.7, pp.73-90
- [3]Shinohara, T. (1982): Polynomial Time Inference of Pattern Language and its Application, Proc. of 7th IBM Symposium on Mathematical Foundation of Computer Science, pp.193-209
- [4]Angluin, D. (1979): Finding Patterns Common to a Set of Strings, Proc. of 11th Annual ACM Symposium on Theory of Computing, pp.130-141
- [5]Jaffar, J. and Michaylov, S.: Methodology and Implementation of a CLP System, 4th Int'n. Logic Conf., pp.196-218
- [6]張汝涛(1988): ユニフィケーションに基づくストリング処理に関する研究、東北大学修士論文