

TR-I-0282

機能分割とパイプラインによる  
機械翻訳システムの並列処理手法

大橋 弘嗣

Hiroshi Ohashi

1992. 9

概要

自然言語処理における並列手法が色々提案されているが、そのほとんどがパーサーの並列化手法である。機械翻訳システムの並列処理の報告は少ない。本報告では変換主導型機械翻訳システムの並列化手法を並列手法のデータ並列、機能分割、パイプラインの内、機能分割とパイプライン処理の組み合わせによる並列効果を述べる。また、この並列効果についてプロトタイプシステムによる実験結果を示す。プロトタイプシステムは密結合並列マシン-Sequent S2000 <intel 80486 (25MHz) 16cpu>上で並列Lisp言語 allegro Clipで記述されている。なお、本報告で説明する変換主導型機械翻訳システムは現在文構造の解析処理が付け加えられており、翻訳処理の完成度はプロトタイプよりも高い。

ATR自動翻訳電話研究所

ATR Interpreting Telephony Research Laboratories

© ATR Interpreting Telephony Research Laboratories

## 1. 目的

自然言語処理における並列化手法が色々提案されているが、そのほとんどがパーサーの並列化手法である。機械翻訳システムの並列処理の報告は少ない。本報告では変換主導型機械翻訳システムの並列化手法を並列手法のデータ並列、機能分割、パイプラインの内、機能分割とパイプライン処理の組み合わせによる並列効果を述べる。また、この並列効果についてプロトタイプシステムによる実験結果を示す。プロトタイプシステムは密結合並列マシン—Sequent S2000 <intel 80486 (25MHz) 16cpu>上で並列Lisp言語 allegro Clipで記述されている。なお、本報告で説明する変換主導型機械翻訳システムは現在文構造の解析処理が付け加えられており、翻訳処理の完成度はプロトタイプよりも高い。

## 2. 並列処理の概要

本報告での並列化手法は機能分割とパイプラインの併用により構築されている。機能分割とはある機能を持った処理別に処理構造を分割し、処理データを機能単位に分割して処理することである。パイプラインは機能処理を単位処理データの時間差により時分割に処理が可能になる。以下に逐次及び並列変換主導型機械翻訳システムの処理形態、及び並列処理形態の詳細を示す。

### a. 逐次変換主導型機械翻訳システムの処理形態

変換主導型機械翻訳システムでは形態素解析で形態素切りされた日本語のストリングと形態素情報をもとに、変換知識情報から有効な変換知識を探索し複数の日本語構造候補を生成する。生成された日本語構造候補は変換知識に記述されている用例により角川類語辞典による用例距離計算を施され、英語変換されて用例距離を付加された英語文として出力される。

- ア. 形態素解析
- イ. 日本語構造生成
- ウ. 英語変換、用例計算
- エ. 英語文生成

逐次処理はア→イ→ウ→エの順に全解候補単位で処理される。

### b. 並列変換主導型機械翻訳システムの処理形態

並列処理では形態素解析は逐次で、そこで処理された情報をもとに日本語構造生成、英語変換及び用例計算、英語文生成ごとに機能分割しパイプラインで時分割処理を行う。実験では処理形態を機能分割の方法、並列実行の方法等、数種類行っている。詳細は次項で説明する。

- ア. 形態素解析 (逐次)
- イ. 日本語構造生成 (機能分割)
- ウ. 英語変換、用例計算 (機能分割)
- エ. 英語文生成 (機能分割)

並列処理ではア→イ→ウ→エの順に解候補単位で処理される。

c. 並列処理における日本語構造の機能分割の詳細

日本語構造生成時に経験則により優先順位の高い変換知識を選び出すことにより、数種類の日本語構造を生成する。この処理において優先順位の高い変換知識の候補を、機能分割でライトウェイトプロセス（以下LWPと記す）化された上記変換知識から生成される日本語構造を生成プロセスにメールアドレスを通して送り、複数のLWPを生成し並列処理を行う。日本語構造生成時に助詞（に、の、を）、補助動詞（下さい、ます）から構造を生成しようとした場合、日本語構造探索が多数発生し処理時間が増加する。変換知識（は～ています）の場合処理時間は少なく済む。

以下で示す処理形態は” [形態素解析] - [日本語構造生成] - [英語変換、用例計算] - [英語文生成] ”を示す。

ア. 1-1-1-1形態

機能分割によりLWP化されるプロセスは機能ごとに1プロセスとし、メールアドレスで機能をパイプライン化する。この形態はメールアドレスでの処理待ちにより並列効率は良くない。

イ. 1-1-N-N形態

日本語構造生成プロセスでの生成処理は逐次で実行し、分割された日本語構造が生成されるごとにメールアドレスを通して下流の英語変換、英語文生成LWPへ分割された日本語構造を受け渡す。下流プロセスが分割され並列効率は良くなるが日本語構造生成処理が逐次のため、優先変換知識が多くなると、この処理に処理時間が片寄ることになり、全体処理時間の半分以上を占めることになった。

ウ. 1-N-N-N形態

日本語構造生成プロセスをLWP化し、並列に生成された複数の日本語構造候補は、各々これも機能分割でLWP化された英語変換処理にメールアドレスを通して送られる。この処理において日本語構造生成プロセスがCPU数でパイプラインとなり、各々の日本語構造生成の処理時間に差異が生じる。以下、英語変換、英語文生成LWPに分割された日本語構造がメールアドレスを通して送られ時間差で各々の日本語構造が処理される。

ウー1. N-N-N個のLWPの動的生成

日本語構造、英語変換、英語文生成プロセスを日本語例文ごとの変換知識に応じて、日本語構造が生成されるごとに、以降のLWPを動的生成し、日本語構造をメールアドレスに受け渡す。

ウー2. N-N-N個のLWPの静的生成

処理実行前に必要個の機能別LWPを生成しておき、各々のLWPをプロセス間の相互通信により協調動作（起動、停止）させることで、生成オーバーヘッドを短縮する。

エ. 1-N-N形態

1-N-N-N形態の下流プロセスをN-N → Nプロセスにまとめ下流プロセスのLWP生成、割り当てオーバーヘッドを低減する。

d. 部分的な並列処理

- ア. 分割された日本語構造の用例計算を下位の日本語構造でLWP化し、フォークジョインでループ分割処理する。
- イ. ループ分割では実際の処理の分割と処理結果の回収の分割に分け、処理を並列化する。
- ウ. ループ分割の問題点としてループ内list処理別ループではループ内のlistがlistごとに処理数が異なり処理粒度が一定にならない場合最大listの処理時間に処理速度が左右される。

e. globalメモリのlocalメモリへの変換

並列処理を行う場合にLISPにおいて関数と関数のデータの受渡しにglobalメモリを使用することもあるが、メールアドレスを使用してローカルメモリへコピーし、LWPへデータを受け渡すことで並列処理の処理結果をLWP各々が独立して処理可能になる。処理が終了後、各々のLWPより処理結果をメールアドレスを通して回収し、独立処理で得られたデータを一つにまとめる処理が必要となる。

globalメモリ上で処理すべき場合はメモリにロックを掛け排他制御を必要とする。

f. allegro CLipの機能

主な機能を以下に示す。

- ア. QLISP、PARALLEL LISP、SPURLISP、MULTILISP各々の並列処理機能を組み合わせて使用可能である。

- イ. LWPの生成、消去、停止、起動

LWPとはlight weight processの略で機能別に並列処理を行う処理単位。

- ウ. メールボックスの生成、メッセージの送付、回収、カウント

メールアドレスはLWPごとに独立に処理しようとするデータをLWPに受渡したり、LWPから処理したデータを回収するための通信路。

- エ. メモリロック機能（スリーブロック、スピブロック）

LWP同士が処理のやり取りをするためにメールアドレス以外に共有メモリを使用するときに、LWP同士のアクセスによるデータの整合性を保護するために排他制御を行う機能。

### 3. 並列処理の実験結果


- ア. LWP別実行時間グラフ（形態 1-N-N）

この例文では優先変換知識による日本語構造候補が16候補作成され、そのうち7候補が構造的に可能であるため、英語変換、英語文生成（TR3）の処理が行われている。上記の優先変換知識16候補は、以下に記す。

|      |            |    |                     |
|------|------------|----|---------------------|
| NO1  | : ますと      | ×× | ○: 日本語構造候補生成成功      |
| NO2  | : ます       | ×  | ×: " 失敗             |
| NO3  | : ています     | ○  | ××: 初期段階失敗          |
| NO4  | : が～れています  | ×  | (変換知識初期段階候補の条件選択削除) |
| NO5  | : が        | ×  |                     |
| NO6  | : と～ます     | ×  |                     |
| NO7  | : は～ています   | ×  |                     |
| NO8  | : は～れています  | ×  |                     |
| NO9  | : は～れます    | ×  |                     |
| NO10 | : は～と～ます   | ×  |                     |
| NO11 | : には～れています | ○  |                     |
| NO12 | : 助詞ーが     | ○  |                     |
| NO13 | : 助詞ーと     | ○  |                     |
| NO14 | : 助詞ーは     | ×  |                     |
| NO15 | : 助詞ーに     | ○  |                     |
| NO16 | : 助詞ーには    | ○  |                     |

この例文では処理時間がNO3の“ ています” の処理に制約されている。TR2及びTR3の両処理とも他の処理の倍～5倍ほど掛かっている。TR2では構造探索の多さ、TR3では構造及び用例計算の多さに起因している。TR2の処理時間が増しても、生成構造が多いとは言えず、TR3の処理時間増に必ずしも結び付かない訳である。例えば、CPUを8個使っても“ が～れています” と“ には～れています” の処理は速く処理されるが、全体的には“ ています” が終了しなければ全体の処理時間は速くならない。

(図1)



\* 例文：参加料には予稿集代と歓迎会費が含まれています（CPU数：7）

\* Xは日本語構造生成が失敗したことを示す。

\* x軸の単位：msec、y軸はLWPを示す。

\* LWP別用例距離値

日本語構造候補16候補の内構造生成成功の7候補の用例距離値を以下に示す。

NO11 : 19  
 NO4 : 1.6  
 NO12 : 0.83  
 NO13 : 19  
 NO3 : 7.77  
 NO16 : 6.16  
 NO15 : 7.34

#### イ. 例文別CPU数別処理時間

例文により並列度が異なるため、短い文で適用される優先変換知識が少ない場合、並列度は小さく、長い文で適用される変換知識が多い場合、並列度は大きくなる。また、助詞などは他種類の構造が探索されるため処理時間が長くなる。逆に、助詞+変換知識の場合構造が特定され処理時間は短くなる。

（表1）

| CPU数／例文     | 例文1              | 例文2             | 例文3            | 例文4            |
|-------------|------------------|-----------------|----------------|----------------|
| 1 real-time | 29.530           | 16.100          | 1.470          | 2.030          |
| non-gc-time | 27.334           | 15.517          | 1.066          | 2.000          |
| 2           | 17.480<br>16.800 | 10.070<br>9.230 | 0.830<br>0.800 | 1.390<br>1.316 |
| 3           | 12.980<br>11.867 | 8.710<br>7.766  | 0.730<br>0.717 | 1.150<br>1.170 |
| 4           | 12.000<br>10.483 | 8.450<br>7.283  | 0.730<br>0.700 | 1.170<br>1.083 |
| 5           | 12.100<br>9.899  | 7.200<br>6.834  | 0.750<br>0.750 | 1.110<br>1.083 |
| 6           | 12.900<br>9.950  | 6.980<br>6.433  | 0.740<br>0.733 | 1.100<br>1.100 |

\* 例文1：発表を希望されるのでしたら3月20日までに要約を提出して下さい

例文2：参加料には予稿集代と歓迎会費が含まれています

例文3：そちらは会議事務局ですか

例文4：登録用紙で手続きをして下さい

\* 例文別優先変換知識候補

例文1：たら、れるのでしたら、下さい、助詞ーに、助詞ーまで、助詞ーまでに、れる、助詞ーを、  
助詞ーの (10候補)

例文2：前記参照

例文3：です、ですか、は～です、は～ですか、助詞ーは (5候補)

例文4：下さい、て下さい、で下さい、助詞ーを、助詞ーで (5候補)



\* 例文別日本語構造生成時 (TR2) の並列度、及び英語変換、英語文生成時 (TR3 (TR4、TR5)) の並列度

|        |             |          |            |
|--------|-------------|----------|------------|
| [1-N-N | 例文1： 10/6 文 | [1-N-N-N | 10/6/6/6 文 |
| 形態]    | 例文2： 16/7 文 | 形態]      | 16/7/7/7 文 |
|        | 例文3： 5/3 文  |          | 5/3/3/3 文  |
|        | 例文4： 5/3 文  |          | 5/3/3/3 文  |

\*. 処理単位 (s)

(図2)

(図3)



\* 例文1：□ real-time  
× non-gc-time  
例文2：△ real-time  
▽ non-gc-time

例文3：□ real-time  
× non-gc-time  
例文4：△ real-time  
▽ non-gc-time

\* 処理単位 y 軸: (s) x 軸: CPU 数

#### 4. まとめ

ア. 処理形態別に実験を行ったが密結合並列マシンでは処理粒度を細かくするよりも、処理粒度は粗い処理の方がメールボックスでの通信処理時間に左右されにくい、処理粒度を細かくしマイクロ秒単位に同時通信を行うとバス競合が起こり通信処理時間に処理時間が左右されるが、1-N-N-N 形態でも 1-N-N 形態でも粗粒度であるため通信処理時間に左右されていない。

イ. 助詞優先変換知識など処理時間の掛かる変換知識が含まれる文ではその処理に処理時間が制約を受け他の処理時間の短い処理の並列度増を阻害している。また処理時間の掛かる失敗構造生成が行われる文においても、その処理に処理時間が制約を受ける。

#### ウ. 先行制約制御依存

形態素解析→日本語構造生成→英語変換→英語文生成の処理プロセスにおいて、各々の処理プロセスが先行制約を受け、先行プロセスの終了を待って後続プロセスの処理が行われる。後続プロセスは先行プロセスの加工したデータを再度加工し、最終プロセスで結果を生成する。

解候補を分割することで日本語構造生成プロセス、英語変換プロセス、英語生成プロセスが同時並列に解候補別に並列処理されている。処理単位が解候補単位であり、粗粒度で他情報の制約を受けない構造であるため、処理待ちによる処理順序の制約は受けない。

後続プロセスが先行制約制御依存を受けなければ処理順序を入れ換える処理構造も考えられる。

#### エ. 先行制約データ依存

逐次処理では各々のプロセスで処理された解候補データをグローバルメモリに蓄え後続プロセスで処理していた。このため全解候補が生成されることが必要となり、解候補データの先行制約データ依存により後続処理は全解候補生成の処理時間の制約を受ける。

並列処理では解候補データを解候補単位に分割することにより、先行制約データ依存の処理時間制約を短縮するように LWP に振り分けている。

細粒度並列を行おうとすると処理待ちによる処理順序制約による先行制約データ依存が発生し、データの処理単位別整合性を保つ必要が出て処理構造は複雑になり、スケジューリング、バリア同期等が必要になる。

#### オ. 並列実行による成功可能性探索の早期発見と失敗可能性及び未処理探索の処理中止の問題

用例距離計算結果の決定値により、並行処理中または待ち行列中の未処理及び処理途中ライトウェイトプロセスを処理中止することで同時進行過程の処理時間の掛かる失敗探索や成功探索を処理しない方法を考察する。

用例距離計算の確からしさの許容範囲を 0~3 とすれば、"0" は、EXACT MATCH でそれ以上は近似値による構造生成であり、0~3 までの結果が出力されれば、他の解候補は必要ではないといえる。よって、並列処理中に 0~3 までの英語文が生成されれば、他の処理中の解候補はもはや必要とはいえない。この方法で処理時間の掛かる探索及び未処理の探索を処理中止すれば、大幅な処理時間の短縮となる。この方法は並列実行以外でも可能であるが、そのトリガーを発見するには並列処理が有効である。なぜなら、トリガーが最も最後に実行されることも起こりえるからであり、並列処理すれば同時に実行され早期発見に結び付く。

上記例文では許容範囲"0~3"では2番目に終了した NO4 を正解とすると real-time で約 3.02 秒で他処理を中止でき、許容範囲"0~1"では3番目に終了した NO12 を正解とすると約 3.21 秒で他処理を中止することが可能である。処理時間は NO4 では 5.0 倍、NO12 では 5.



0倍にすることができる。CPU 8個ではNO4で約2.66秒で終了し6.0倍、NO12は変らなかった。この処理はデータのみでありインプリメントはしていない。

#### 参考文献

- [1] 松本「並列構文解析」 自然言語処理 53-2 (1986)
- [2] 寿崎、佐藤他「マルチPSIにおける並列構文解析プログラムPAXの実現及び評価」  
並列処理シンポジウム JSPP'89
- [3] 加藤「素性構造の単一化に基づくパーサの並列化手法の効率」 ATR Technical Report
- [4] Hideto Tomabechi「Quasi-Destructive Graph Unification」 ATR Technical Report
- [5] 藤岡、苫米地、古瀬、飯田「並列時間差準破壊型単一化アルゴリズムの実現手法」 ATR Technical Report
- [6] 古瀬、飯田「変換主導型機械翻訳の実現A」 ATR Technical Report
- [7] 佐々木、神余、笠原、成田「原子カプラント状態予測シミュレータへの並列処理の適用」 並列処理シンポジウム JSPP'89
- [8] 笠原、藤井、本多、成田「スタテック、マルチプロセッサ、スケジューリング、アルゴリズムを用いた常微分方程式求解の並列処理」 情報処理学会論文誌 vol. 28 No. 10 (1987)
- [9] 坂井「並列計算機におけるスケジューリングと負荷分散」 情報処理 vol. 27 No. 9 (1986)
- [10] 喜連川、大城「共有メモリ型並列マシン (Symmetry S81) とSIMD型超並列マシン (MasPar MP-1) の連続鑄造設備モールド部温度計算への適用並びにその評価」
- [11] 宮野「並列化とその限界ー理論的側面から」 コンピュータソフトウェア vol. 7 No. 1 (1990)
- [12] 「Symmetry Technical Summary」 Sequent社
- [13] 「Allegro CLiP User Guide」 Franz社
- [14] 笠原「並列処理技術」 コロナ社
- [15] 高橋「並列処理機構」 丸善

## xx. 並列変換主導型機械翻訳システムの起動方法

0. シークエントS-2000 に ログイン する。

1. NEMACSを起動する。

2. M-x clipを入力する。

clip file の load  
パラレル file の load  
漢字テーブル の load

<initial lwp> が 表示される。

3. 形態素解析プログラムのロード

:ld /usr2/ohashi/ppatran/morph/setup

4. 並列patran の ロード

:ld /usr2/ohashi/ppatran/setup

5. パッケージの指定

(in-package 'ppatran)

6. TRANSLATEの方法

(translate " 会議に申し込みたいのですが" )

.  
. .  
.

\* 国際会議予約の例文は /usr2/ohashi/ppatran/a-text を参照。

7. 結果の表示

(pprint \*output\*)

8. lwp別プロセスreal-timeの表示

(lwp-run-time)

## 9. 機能処理別プロセス数の表示

(lwp-count)

## 10. CPU数のset

(set-numproc CPU数) : CPU数 1~15

## 11. エラーの対処

lwpの途中でエラーになったとき

エラー表示

<lwp32> . . . エラーの原因のlwp

:res reset

:loc ローカルエリアパラメータ表示

:zo ゾーンエリアパラメータ表示

反応が返ってこない時

c-c c-c lisp interrupt

c-x c-c 強制終了

## 12. CLIPプロセスが ps ux コマンドで表示されkillされていないとき

KILL-CLIP

## 13. monitorの表示

cd /usr/etc ディレクトリーで monitor を起動する。

## 14. compileの方法

:cl ファイル名