

ICOT Technical Memorandum: TM-0765他

TM-0765他

第39回情報処理学会全国大会論文集
(2研関連)

July, 1989

©1989, ICOT

ICOT

Mita Kokusai Bldg. 21F
4-28 Mita 1-Chome
Minato-ku Tokyo 108 Japan

(03) 456-3191~5
Telex ICOT J32964

Institute for New Generation Computer Technology

TM-0765 LAX—インタプリンタと意味構成部のデバッグ環境
の実現

米田順美、久保幸弘、白石智子、妙泉正隆

TM-0772 日本語述部の分析

佐野 洋、田中裕一

TM-0773 構文意味解析システムSAXにおける係り受け

福本文代、杉村領一(松下電産)

TM-0774 形態素意味解析システムLAXによる語の意味構成

久保幸弘

LAX- インタプリタと 意味構成部のデバッグ環境の実現

米田順美 久保幸弘 † 白石智子 妙泉正隆
(財)日本情報処理開発協会 †(財)新世代コンピュータ技術開発機構

1 はじめに

ICOTでは、日本語処理システムの構築に必要な解析・生成などのモジュールの統合開発環境をLTB(Language Tool Box)[5]としてまとめている。形態素意味解析システムLAX[1]はこのLTBのツールの一つで、分かち書きされていない通常の日本語の文章から、文節の並びとその意味構造を解析するプログラムの開発環境である。

従来のLAXの開発環境[2]では、形態素解析部のデバッグのみをサポートしていたが、今回意味構成部のデバッグ環境を作成したので報告する。また、従来版では形態素意味解析を行うためにはエントリの修正毎に辞書をコンパイルする必要があり、大きな辞書の開発には不向きであったが、これも改善したので報告する。

2 LAX の構成

図1にLAXのシステム構成を示す。

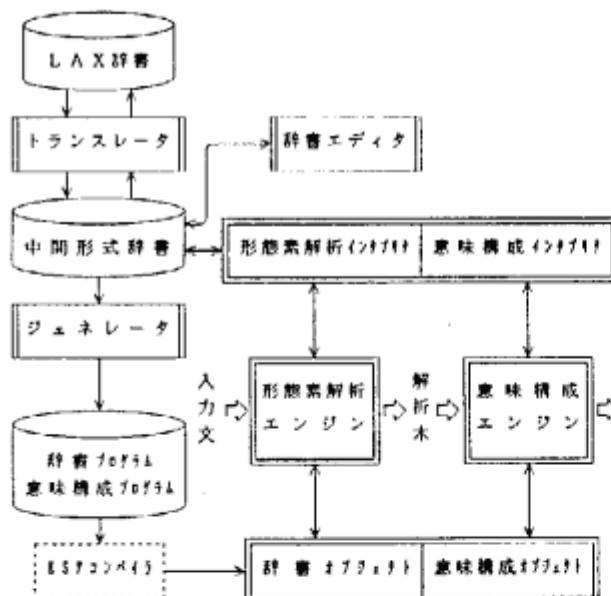


図1: LAX システム構成

LAXでは、LAX辞書と呼ばれる辞書を作成し、トランスレーターにより中間形式辞書ファイルを得る。以後LAXでの辞書の開発はこの中間形式辞書ファイルに対して行う。さらにジェネレーターにより辞書プログラムと意味構成プログラムを得る。これらはESP[6]により記

Implementation of the LAX-interpreter and the debugging environment for the semantic construction part.

Junmi YONEDA Yukihiko KUBO† Tomoko SHIRAISHI
Masataka YOSHIZUMI JIPDEC †ICOT

述されており、ESPコンパイラを用いてコンパイルすることにより辞書オブジェクトと意味構成オブジェクトを得る。従来の形態素意味解析プログラムでは、解析エンジンがこの辞書オブジェクトと意味構成オブジェクトを参照し、形態素解析と意味の構成を行う。今回開発した解析インタプリタでは、オブジェクトの代わりに中間形式辞書ファイルを参照する。LAX辞書へは逆トランスレータにより変換される。表1に従来のLAXの機能と今回実現した機能を示す。以下では、改良した点について

表1: LAX の機能

| モジュール名 | 形態素解析部 | 意味構成部 |
|--------|--------|-------|
| コンパイラ | ○ | ○ |
| インタプリタ | ○ | ○ |
| エディタ | ○ | ○ |
| デバッガ | ○ | ○ |

○: 従来の機能 ○: 今回実現した機能

説明する。ただし、意味構成部のコンパイラ機能と構成の詳細については別途[3]発表するので省略する。

3 中間形式辞書を用いた形態素解析インタプリタ

形態素解析インタプリタは辞書オブジェクトの代わりに中間形式辞書ファイルを用いる。中間形式辞書ファイルではTRIE構造を常にファイル内に有し、辞書エントリファイルへのポインタを参照しながら辞書引きを行う。

中間形式辞書ファイルは図2が示すようにTRIE構造、意味辞書エントリファイル、左(右)方接続素性ファイル、接続素性ファイルおよび意味構成規則ファイルで構成され、それぞれは矢印が示すような参照関係にある。

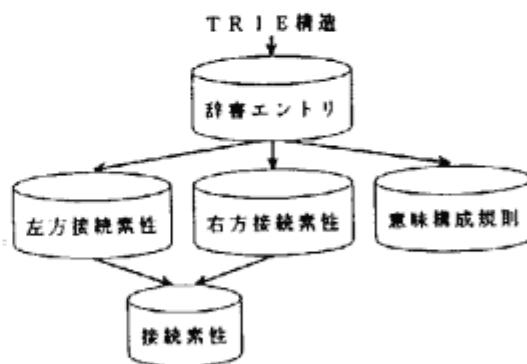


図2: 中間形式辞書ファイルの構成

表2にコンパイルされた辞書オブジェクトと、中間形式辞書ファイルを用いた解析速度の比較を示す。これは、約1000語の形態素を有する辞書に対しいくつかの例文を解析させたものである。

表2: 解析時間の比較

| 入力文 | | 解析時間 (ms) | | |
|-----|------|-----------|---------|-----|
| 文字数 | 解析本数 | インタプリタ i | コンパイラ c | i/c |
| 16 | 8 | 517 | 62 | 8.3 |
| 45 | 3 | 366 | 42 | 8.7 |
| 64 | 16 | 730 | 97 | 7.5 |
| 83 | 32 | 700 | 126 | 5.5 |
| 88 | 96 | 1188 | 291 | 4.1 |

インタプリタ・モードではコンパイラ・モードの10倍程度の解析時間で結果を得る。1文当たり1秒またはそれ未満で解析できることから辞書のデバッグに対しては十分実用に適する。

これにより、辞書の変更にともなうオブジェクト生成およびコンパイル作業が不要となり、辞書開発速度を向上することができた。

4 意味構成規則のデバッグ環境の作成

従来の意味構成部の機能は意味構成オブジェクトの生成のみであったが、今回以下の機能を追加した。

1. エディット機能

従来の形態素接続情報の修正を行う辞書エディタに、意味構成規則の修正機能を追加した。これにより辞書エディタの機能は、意味構成規則を含む形態素の検索、追加、置換、および辞書環境値の変更となった。意味規則は中間形式辞書ファイルの構成要素である意味構成規則ファイルに格納され、後述の意味構成インタプリタにより参照される。

図3に辞書エディタのウインドウを示す。

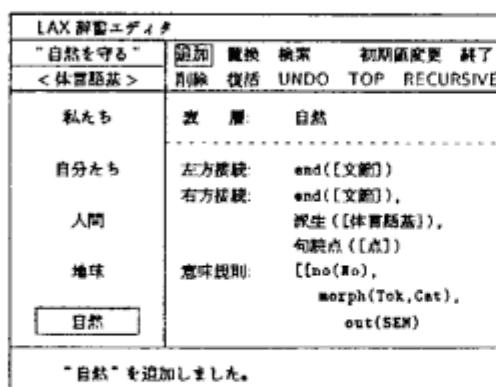


図3: LAX 辞書エディタ

2. 意味構成インタプリタ

意味構成エンジンは形態素解析エンジンの出力結果である形態素解析木をもとに各形態素が持つ意

味規則を順に適用し文節の意味を構成する。意味構成規則は変数宣言と意味処理記述から構成される。意味構造とそれに対する操作はデータ型としてあらかじめ定義しておく。意味処理記述部に記述される操作は全てデータ型に定義されているものである。インタプリタは、各形態素の意味規則を意味構成規則ファイルから取り出し、変数宣言に記述されている変数を形態素解析木から得られる値で束縛する。次に、意味処理記述の処理をインタプリティブに実行する。

3. トレース機能

意味構成部のデバッグツールとしてデータ型のメソッドレベルでインタラクティブに実行を行うトレース機能を提供した。

図4に意味構成部のモジュール構成を示す。

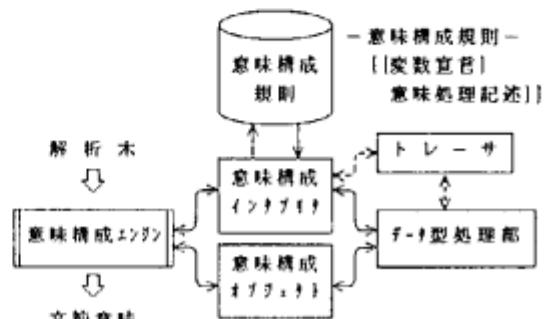


図4: LAX 意味構成部

5 おわりに

本稿では、LAX の解析インタプリタ、意味構成部のエディット機能、同トレース機能について報告した。これらのデバック機能を追加することにより、辞書記述の変更後にそれをコンパイルすることなく解析試験が行えるようになった。これにより辞書開発速度を向上することができた。

今後の課題として意味構成部のインタプリタの高速化がある。

参考文献

- [1] 久保: 形態素意味解析システム LAX, 第7回第五世代コンピュータに関するシンポジウム予稿集, 1989年6月
- [2] 久保, 妙泉, 佐野, 赤坂, 杉村: LTB-形態素解析システム LAX の開発環境, 情報処理学会第37回全国大会, 1988
- [3] 久保: 形態素意味解析システム LAX による文節の意味構成, 情報処理学会第39回全国大会, 1989
- [4] 杉村, 赤坂, 久保, 松本, 佐野: 論理型形態素解析 LAX, Proc. of the Logic Programming Conf.'88, pp213-222, 1988
- [5] Sugimura, et al.: A Software Environment for Research into Discourse Understanding Systems, Proc. of the International Conf. on Fifth Generation Computer Systems, pp285-295, 1988
- [6] 小型化 PSI/ESP 説明書 (simpos 3.1版), ICOT, 1988年1月