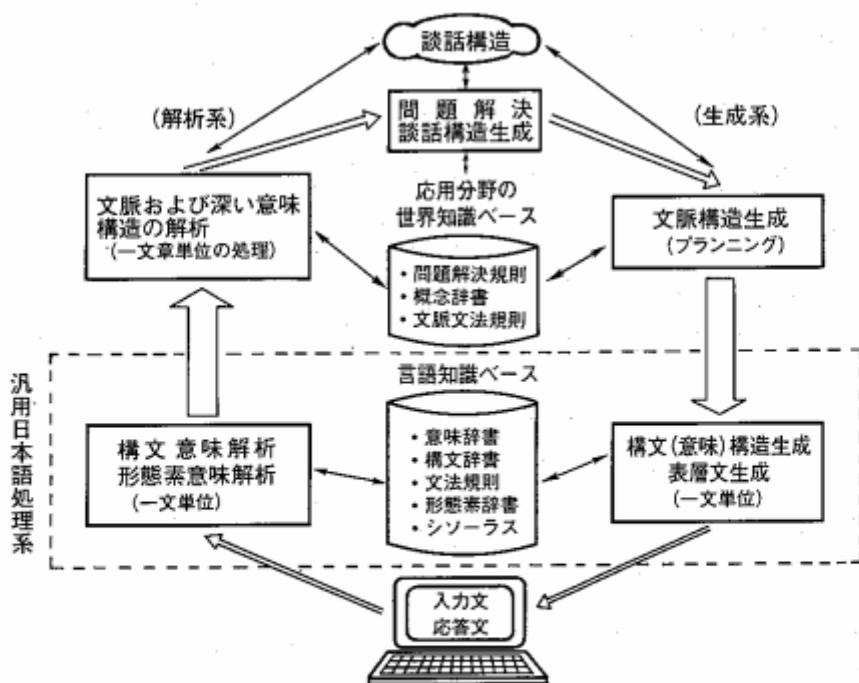


形態素意味解析システムLAX

ICOT
第2研究室

久保幸弘

談話理解実験システムと汎用日本語処理系



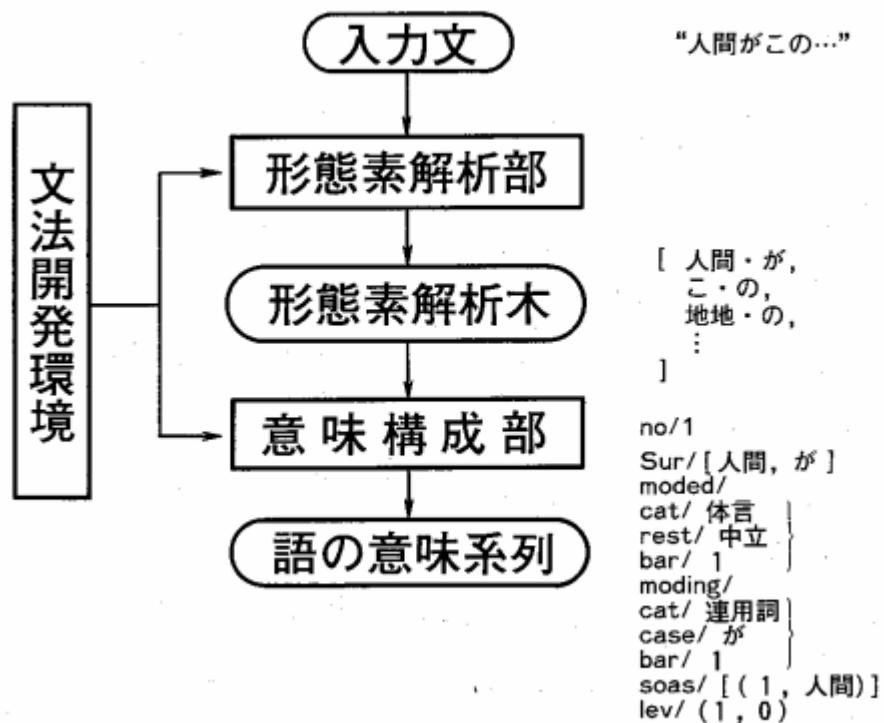
形態素意味解析とは

- 分かち書きされていない日本語の文章から文節(単語)を切りだす
(例)
“人間が地球で生きる。”
→ 人間・が/地球・で/生・き・る・。
- 各形態素の意味から文節の意味を構成する文節の意味
 - 構文的情報
 - 意味的情報

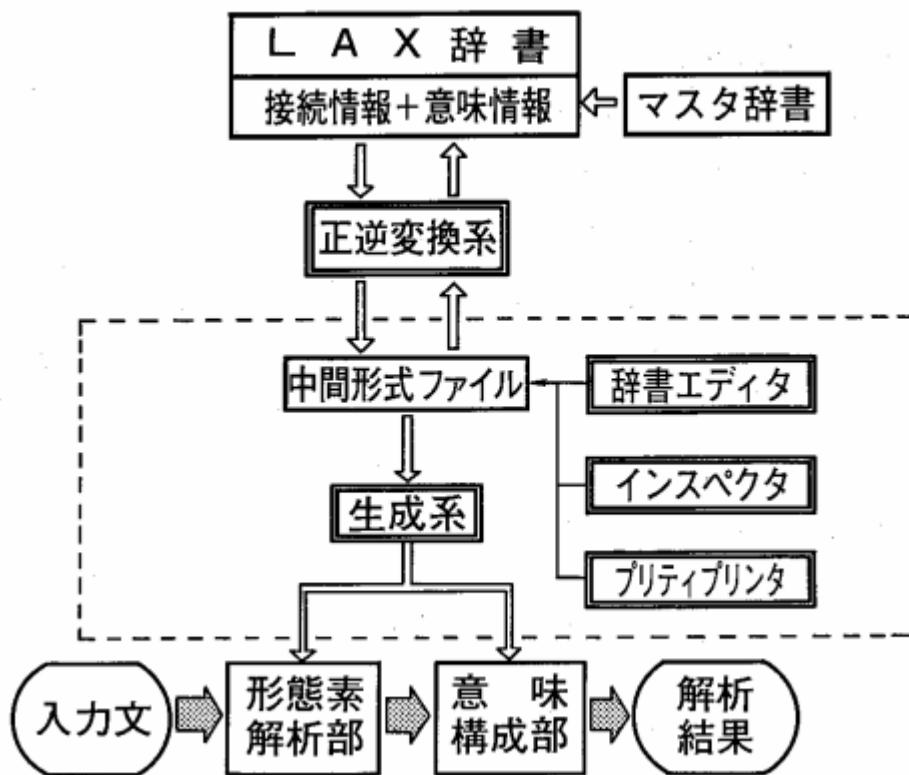
LAX(Lexical Analyzer for Syntax and Semantics)の特徴

- 逐次型推論マシン PSI-II による実行
- 汎用日本語処理 LTB (Language Tool Box) のモジュール
 - 構文意味解析システム SAXとの併用
- 高速な形態素意味解析処理
 - 1 文当たり 100 msec 以下
- レイヤード・ストリーム方式による解探索
 - 決定的な解析処理で全解を算出
 - 並列論理型言語 KL-1 で実装 → 並列化可能
- TRIE 構造による辞書検索
- ローカル・アンビギュイティ・パッキングによる解の縮退
- 未登録語の処理が可能
- 意味の構成が可能

形態素意味解析の流れ



文法開発環境



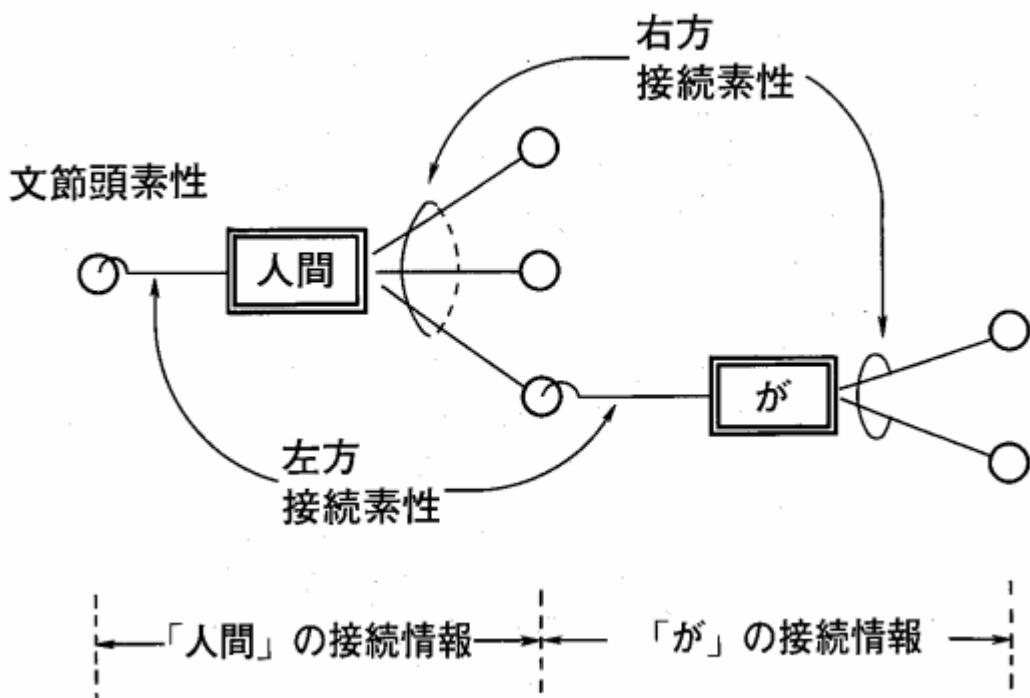
文法開発ツール

- **インスペクタ**
 - 形態素解析結果の簡単な表示
 - 形態素の候補とその辞書記述の表示
 - 連接試験
- **専用辞書エディタ**
 - 形態素文法と意味構成規則の編集
 - エントリの検索, 更新, 削除, 新規登録
 - インスペクタと連携したデバッグ
- **プリティプリンタ**
 - 形態素解析結果のプリティ・プリント

形態素文法記述の特徴

- **森岡文法(構造主義言語学)**
 - 形態素：有意義の最小単位
 - 語(文節)：語基, 接辞, 助辞から構成
- **正規言語に基づく日本語向け形態素文法記述**
 - 各形態素に左方接続素性, 右方接続素性を定義
→ 非決定性有限状態オートマトンの状態遷移関数の定義
 - 複数の状態遷移表
- **ユーザ定義のデータタイプによる意味構成**
 - 形態素の接続状況に応じたきめ細かい処理

形態素の接続可能性の判定



文法記述例－形態素解析部－

人間：： end([文節])
& & [体言派生([接辞, 準体辞, 副接辞]),
体言屈折([格助辞]),
体言準用([準用辞]),
情態派生([ダ系体言])),
屈折([副助辞, 連体助辞, 係助辞,
終助辞]),
句読点([点, マル]),
end([文節])]

文法記述例 一意味構成部一

```
 $$ [ [ no(No), morph(Mor, Cat), out(SEM) ],
      make(SEM),
      role (SEM, [no], No),
      role (SEM, moded, cat], 体言),
      role (SEM, [moded, rest], 中立),
      get_id(ID),
      tail(SEM, [soas], (ID, Mor)),
      cond( { [ 句読点([マル]) ],
              [ role(SEM, [moded, bar], 4)] },
            { [ end([文節]), 句読点([点]) ],
              [ role(SEM, [moded, bar], 1),
                role(SEM, [moding, bar], 1) ] } ) ]
```

形態素解析の評価

○ 使用マシンおよびOS

- PSI-II
- SIMPOS 4. 2 版

○ 対象テキスト

- 『自然を守る』 82文
- 『キュリー夫人』 126文

○ 形態素辞書

- 付属語 500語
 - 自立語 1,230語
- | | |
|----------|------|
| 『自然を守る』 | 450語 |
| 『キュリー夫人』 | 780語 |

課題

- 意味構成部のデバッグ環境
 - LTB標準意味操作モジュールの設計
 - 同インタフェースと意味構成部デバッガの作成
- マスタ辞書へのフィードバックと文生成部との辞書の共通化
- 大語彙の形態素辞書作成と評価
 - 素性の見直しと分類
 - 60,000語の辞書作成
- 各種アプリケーションへの対応
 - DUALS
 - KWIC
- 並列化アルゴリズムの検討
 - マルチPSIへのインプリメント