

構文木付きコーパス作成支援統合環境: eBonsai

市川 宙[†] 野口 正樹[‡] 吉田 恭祐[‡]

橋本 泰一[‡] 徳永 健伸[‡] 田中 穂積[‡]

[†] 東京工業大学 工学部 情報工学科

[‡] 東京工業大学大学院 情報理工学研究科 計算工学専攻

{ichikawa,mnoguchi,rincho,taiichi,take,tanaka}@cl.cs.titech.ac.jp

1 概要

近年、自然言語処理の分野では、大規模な言語資源に基づく統計的手法が研究の中心となっている。言語資源の中でも、構文木付きコーパスは、特に統計的構文解析手法における重要な言語資源である。しかし、構文木付きコーパスは、人手により作成するため、多大な労力を必要とする。そのため、このようなコーパスの作成支援ツールの研究が行われるようになった[1, 2]。このようなツールの1つとして、構文木付きコーパス作成支援統合環境 eBonsai (図1)を開発した。

eBonsai は、統合環境 Eclipse 上に、以下の2つのプラグインを実装したものである。

- アノテーションプラグイン。このプラグインは、ユーザが正しい構文木の候補から、正しい構文木を視覚的に選択する作業を支援する。
- 構文構造検索プラグイン。このプラグインは、構文木をクエリとし、クエリと同じ構造を含む文をコーパスから検索するために利用する。このプラグインにより、ユーザは、構文構造を付与する際に、参考となる文をコーパスから容易に検索できるようになる。

この2つのプラグインは、Eclipse 上で連携して動作する(例えば、アノテーションプラグインから構文構造検索プラグインに木構造をコピー&ペーストできる)。また、Eclipse が持つプロジェクト管理機能や、その他のプラグイン(CVS 機能など)と組み合わせる事で、Eclipse をコーパス作成の統合環境として利用できるようになった。

2 構文木付きコーパスの作成方法

eBonsai を使った構文木付きコーパス作成の流れは、以下のとおりである(図2)。

1. 平文コーパスから文を取り出す。
2. その文を MSLR パーザ [3] で構文解析する。




図2: eBonsai を使った構文木付きコーパス作成の流れ

3. 得られた構文木の集合の中から、アノテーションプラグインを使って、正しい構文木を選ぶ。この時、構文構造検索プラグインを使って、他の文の構文木を参考にする事ができる。
4. 選んだ構文木を構文木付きコーパスに加える。

MSLR パーザでは、多様な日本語の文をカバーするため、適用範囲の広い文法が用いられる。そのため、2の段階で構文木が一意に決まる事は減多になく、2では構文木の候補の集合が(圧縮統語森の形式で)出力される。その候補の中から正しい構文木を選ぶのが3の作業であり、ここで eBonsai が使用される。

3 アノテーションプラグイン

3.1 アノテーションプラグインの概要

アノテーションプラグインは、MSLR パーザの出力である圧縮統語森(構文木の候補の集合)から正しい構文木を選択するためのツールである。

構文木の候補は、場合によっては数万にもなるため、それらを1つ1つ見て正しいものを探すのは時間を要する。そこで、候補の1つを視覚的に表示し、正しい構文木が満たすべき制約をユーザが繰り返し指定することで、候補を絞り込み、正しい構文木を容易に選択




図 1: eBonsai

できるようになっている。「満たすべき制約の指定」には、以下の2種類がある。

1. 係り受けの指定. どの節（連体節，連用節など）がどの句（名詞句，動詞句など）に係るのかを指定する。
2. 非終端記号の指定. ノードが動詞句なのか名詞句なのか，などを指定する。


このプラグインは、岡崎 [4] のツールを Eclipse プラグインとして再実装したものである。

3.2 アノテーションプラグインの操作方法

以下の文を例にとって、アノテーションプラグインの使い方を説明する。


警告の黄色の用紙を郵便受けに入れておいたが、まだ支払われていない。

1. Eclipse の「Navigator」上で、この文の圧縮統語森ファイル (RWC0003441-00.csv) をダブルクリックする。
2. 新しくウィンドウが開き、木構造の候補の1つが視覚的に表示される。




このウィンドウをアノテーションエディタと呼ぶ。左上には候補の総数 9 が表示されている。

3. ”< 動詞句-用-無 >”のノードが赤くなっている。これは、「非終端記号の候補が複数ある」という意味である。
4. ”< 動詞句-用-無 >”を右クリックすると、ポップアップメニューに非終端記号の候補一覧が表示される。




5. ここの「警告」は明らかに名詞句なので、「<名詞句-サ変-無>」を選ぶ。
6. すると、「<動詞句-用-無>」が「<名詞句-サ変-無>」に変わって黒くなり、このノードの曖昧性が解消された事が分かる。




左上の候補総数も3に減少している。

7. 次に、「<補足節-を-無-無>」のノードが緑になっている。これは、「係り先の候補が複数ある」という意味である。
8. 「<補足節-を-無-無>」を右クリックすると、ポップアップメニューに係り先の候補一覧が表示される。



9. 「警告の黄色の用紙を まだ支払われていない」というのは変なので、ここでは上の候補を選ぶ。
10. ノードが全て黒くなり、候補総数が1になった。



これでこの文のアノテーションは終了である。

3.3 アノテーションプラグインのその他の機能

他にも以下の機能が実装されている。



図 3: アノテーションエディタの右クリックメニュー

- 回数無制限のUndo/Redo. 結果を保存して終了したあとも、Undo/Redoが可能. アノテーションエディタの右クリックメニュー（図3）から行う。
- 他の木構造候補の表示. アノテーションエディタの右クリックメニューの [Previous tree] [Next tree] で行う。
- 枝の畳み込み. ノードを右クリックして [Switch folding] を選ぶと、そのノード以下の枝を畳み込んで表示する。
- 木構造の一部を、構文構造検索プラグインにコピーする. アノテーションエディタの右クリックメニューの [Copy to search] で行う. 後述。

4 構文構造検索プラグイン

4.1 構文構造検索プラグインの概要

アノテーションプラグインを使った作業で、ユーザは係り先や非終端記号の選択を求められる。多くの場合、文意を考えれば、これらの選択は容易である。しかし、選択に迷うような微妙なケースも存在する。そのような時にヒントを提供するのが、構文構造検索プラグインである。

構文構造検索プラグインは、クエリとして木構造を与え、その木構造を含む文をコーパスから検索し、表示する。

構文構造の検索には、吉田 [5] の手法を用いている。

4.2 構文構造検索プラグインの操作

1. クエリ入力ウィンドウ（図4左上）でクエリとなる木構造を作る。

- ノードのラベルを変更するには、ノードを左クリックして選択し、下の入力欄に入力する。ラベル名にはワイルドカード % も使える。
- 子ノードを追加するには、ノードを右クリックして [子の追加] を選ぶ。




図 4: 構文構造検索プラグイン

2. クエリ入力ウィンドウを右クリックし, [Search] を選ぶ.
 - [Partial search] を選ぶと, 子の数がクエリと一致しなくてもヒットするようになる.
 - [Narrow search] を選ぶと, 前回の検索結果から絞り込む事ができる.
 - [Partial narrow search] は Partial search と Narrow search の組み合わせである.
3. 検索結果一覧ウィンドウ (図 4 左下) にヒットした文が一覧表示される.
4. 一覧中の文をクリックすると, 検索結果詳細ウィンドウ (図 4 右) に選んだ文の木構造が表示される. ヒットした部分は中央に青く表示される.
5. 同じ文の複数箇所ヒットした場合は, 検索結果詳細ウィンドウに 1/2 などと表示されるので, 右クリックメニューで [Previous match] [Next match] を選んで, 他のヒット箇所を表示できる.

5 アノテーションプラグインと構文構造検索プラグインの連携

以下の手順で, アノテーションプラグインで表示されている木構造の一部を, 構文構造検索プラグインのクエリ入力ウィンドウにコピーできる.

1. アノテーションプラグイン上で左ドラッグし, 木

構造の一部を選択する (ノードが青くなる).

2. アノテーションプラグイン上で右クリックし, [Copy to search] を選ぶ. クエリ入力ウィンドウに, 選択中の木構造がコピーされる.
3. 必要なら, クエリを修正する.
4. クエリ入力ウィンドウを右クリックし, [Search] などを選んで検索する.

先ほどの例なら, この機能を使って, どのような場合に「動詞句+助詞」の”になるのかを調べる事ができる.

6 まとめと今後の課題

本論文では, 構文木付きコーパスの作成を支援する統合環境 eBonsai を紹介した. eBonsai によって, 構文木付きコーパスの作成作業を, 統合環境の中でシームレスに行えるようになった.

今後の課題として, 以下のようなものが挙げられる.

- 本格的な構文付きコーパス作成作業に適用.
- CVS などを利用した共同作業の方針を確立.
- インタフェースを改善.
- ヒントとなる情報 (参考になる文の木構造, 特例的な作業方針など) を自動表示.

参考文献

- [1] Oliver Plaehn, Thorsten Brants. Annotate – An Efficient Interactive Annotation Tool. Proceedings of the Sixth Conference on Applied Natural Language Processing ANLP-2000, Seattle, WA, 2000
- [2] Proceedings of the Third International Conference on Language Resources and Evaluation, Paris: European Language Resources Association, 2002
- [3] 白井清昭, 植木正裕, 橋本泰一, 徳永健伸, 田中 穂積. 自然言語解析のための MSLR パーザ・ツールキット. 自然言語処理. Vol.7. No.5. pp.93 – 112. 2000. Nov
- [4] 岡崎篤, 白井清昭, 徳永健伸, 田中穂積. 正しい構文木の選択を支援する構文木付きコーパス作成ツール. 人工知能学会 第 15 回全国大会, 2001
- [5] Kyosuke Yoshida, Taiichi Hashimoto, Takenobu Tokunaga, Hozumi Tanaka. Retrieving Annotated Corpora for Corpus Annotation. Proceedings of the Fourth International Conference on Language Resources and Evaluation (LREC 2004), 2004