

日本語学習者コーパス検索ツールの開発

Development of a search tool for Japanese-learner corpora

淺尾 仁彦 李 在鎬
(京都大学大学院) (情報通信研究機構)

asaokitan@ling.bun.kyoto-u.ac.jp



背景

- 学習者コーパスの需要の高まり
 - 文字列ベースの検索では不十分
 - 形態素解析のコスト

- KY コーパス(鎌田・山内 1999)に基づくタグ付き学習者コーパスの作成(李ほか 2008)
 - 品詞情報(茶筌)
 - 意味分類(分類語彙表)
 - 誤用や言い直し(手作業)
- 検索ツールの必要性

開発

「E-KWIC KY コーパス用」

- Excel 上で実行できる
 - 広い層の研究者が利用できる
- 検索機能
 - 基本形による単語の検索
 - 品詞/意味分類による検索
 - 正用/誤用別の検索
 - 学習者母語の絞り込み
 - 学習者レベルの絞り込み
- 検索結果を Excel のワークシートとして保存できる
- 発表者ウェブサイトで公開、フィードバックを得て継続的に改善

<http://www30.atwiki.jp/corpus-ling/pages/55.html>

利用例

- 「の」の誤用
 - 古いの切手」「小さいの弟」

母語	正用	誤用
韓国語	1,602	58
中国語	2,018	117
英語	1,634	35

- 中国人学習者に有意に多い($p < .001$)
- 学習者レベルが上がると改善
 - 初級…誤用 10 件 (15.6%)
 - 中級…誤用 102 件 (13.8%)
 - 上級…誤用 77 件 (6.5%)

KY コーパス(オリジナル)

T: 町の感じとかどうですか、人の感じとか
S: はい、ここ、大阪の、人はたいへん親切だし、物価はちょっと高いんですけど、便利、交通も便利だし、はい、そんなに寒くないだし、私ここが好きです、〈あーそうですか〉はい

KY コーパス(加工済み)

寒く	サムク	寒い	助動詞
ない	ナイ	ない	助動詞
だし	ダ	だ	助動詞-誤用
、私	、	、	助詞-接続助詞
	ワタシ	私	記号
			名詞-代名詞



図 2 E-KWIC KY コーパス用

茶まめ用

- 「茶まめ」(小木曾ほか 2007)
 - 簡単な形態素解析ツール
 - 辞書「UniDic」を利用
 - 解析結果を Excel に出力できる
- 解析結果を利用した検索ツールがない

「E-KWIC 茶まめ用」

- 「E-KWIC KY コーパス用」から学習者コーパス向け機能を除いたもの
- 手持ちのデータに自由に適用できる



図 4 E-KWIC 茶まめ用




図 3 検索結果の出力

文献

- 李在鎬・浅尾仁彦・濱野寛子・佐野香織・井佐原均(2008).「タグ付き日本語学習者コーパスの開発」.『言語処理学会第14回年次大会発表論文集』pp. 658-661.
- 鎌田修・山内博之(1999).「KY コーパス」.Ver 1.1. (http://opi.jp/shiryo/ky_corpus.html)
- 小木曾智信・小椋秀樹・伝康晴(2007).「日本語研究に適した形態素解析ソフトウェア—「UniDic」と「茶まめ」—」.『日本語学会 2007 年度秋季大会予稿集』pp.255-262. (<http://www.tokuteicorpus.jp/dist/>)

