



『UniDic』とは

国語研の規定した齊一な言語単位（短単位）と階層的見出し構造に基づく電子化辞書の

■ 設計方針

およびその実装としてのリレーショナルデータベース

■ UniDicデータベース


と、そのデータベースからエクスポートした短単位をエントリとする形態素解析器MeCab用の解析用辞書

■ 解析用UniDic

<http://taku910.github.io/mecab/>

の総称

①設計方針



実装

②UniDicデータベース





エクスポート

③解析用UniDic

書字形 (基本形)	発音形 (基本形)	語形 (基本形)	語彙素 読み	語彙素	...
大きい	オーキー	オオキイ	オオキイ	大きい	...
おおきい	オーキー	オオキイ	オオキイ	大きい	...
おっきい	オッキイ	オッキイ	オオキイ	大きい	...

『UniDic』を使ったコーパス構築の流れ



```
$ echo "青空におおきい雲が浮かんでいる。" | mecab
青空      名詞,普通名詞,一般,,,,アオゾラ,青空,アオゾラ
に        助詞,格助詞,,,,ニ,に,ニ
おおきい 形容詞,一般,形容詞,連体形-一般,オオキイ,大きい,オーキー
雲        名詞,普通名詞,一般,,,,クモ,雲,クモ
が        助詞,格助詞,,,,ガ,が,ガ
浮かん    動詞,非自立可能,,,,五段-バ行,連用形-撥音便,ウカブ,浮かぶ,ウカン
で        助詞,接続助詞,,,,デ,で,デ
いる      動詞,非自立可能,,,,上一段-ア行,終止形-一般,イル,居る,イル
。        補助動詞,句点,,,,,,。 , EOS
```

Point !

コーパス構築の際は、

- 解析用UniDicを使った自動解析結果（精度は100%ではない）を基に①のアノテーション（形態論情報修正）を行う。
- アノテーションの際、UniDic DBに未登録の短単位が見つければ、新たにUniDic DBに登録する。
- 解析用辞書は整備中のコーパスとUniDic DBを基に作成されるので、コーパス構築が進むにつれて、解析用UniDicの解析精度は向上していく。

『UniDic データベース』とコーパスデータベースの関係

UniDicデータベース

書字形 (出現形)	発音形 (出現形)	語形 (出現形)	品詞	語彙素	語彙素 読み	語彙素 類	語種	...
すもも	スモモ	スモモ	名詞 -普通名詞 -一般	李	スモモ	体	和語	
もも	モモ	モモ	名詞 -普通名詞 -一般	桃	モモ	体	和語	
も	モ	モ	助詞 -係助詞	も	モ	係助	和語	

コーパスデータベース (文字列テーブル)

order	文字
10	す
20	も
30	も
40	も
50	も
60	も
70	も
80	も
90	も

UniDicデータベースは、コーパスのデータベースと参照関係にある。

コーパスが完成した際：

コーパスデータベース中の短単位は、

- UniDicデータベースに登録されており、
- UniDicデータベース中の一意のエントリを参照する（リンク付けられた）状態になっている。

参考文献

■ 伝 康晴, 小木曾 智信, 小椋 秀樹, 山田 篤, 峯松 信明, 内元 清貴, 小磯 花絵: 「コーパス日本語学のための言語資源：形態素解析用電子化辞書の開発とその応用」, 日本語科学, Vol.22, pp.101-123 (2007). ■ 伝 康晴. 多様な目的に適した形態素解析システム用電子化辞書, 人工知能学会誌, Vol.24, No.5, pp.640-646 (2009). ■ 伝 康晴, 浅原 正幸: 「リレーショナル・データベースによる統合的言語資源管理環境」, 第1回『話し言葉の科学と工学』ワークショップ講演予稿集, pp.77-84 (2001).