

# 日本語形態素解析

内山将夫@NICT

mutiyama@nict.go.jp

# 日本語形態素解析

- 入力文を形態素に分割し，各種の情報をつけること  
例

「今日は良い天気だ。」を茶筌で解析すると以下のようになる。

今日	キヨウ	今日	名詞-副詞可能
は	ハ	は	助詞-係助詞
良い	ヨイ	良い	形容詞-自立 形容詞・
アウオ段		基本形	
天氣	テンキ	天氣	名詞-一般
だ	ダ	だ	助 動 詞 特 殊・
ダ		基本形	
.	.	.	記号-句点

## 日本語形態素解析の重要性

- 日本語形態素解析は，日本語処理の最初の方のステップである。
- 機械翻訳においても，入力文は，単語に分割されていることを仮定している。
- Web検索においても，入力質問やWebページは，形態素解析される。

## 形態素解析の難しさ

- 入力文には，区切の曖昧さがある
- 入力文には，辞書にない単語がある .

## 問題：区切の曖昧さの例（15分）

辞書に

- す
- すもも
- も
- もも
- の
- うち

という7個の単語があるとき、

- すももももももものうち

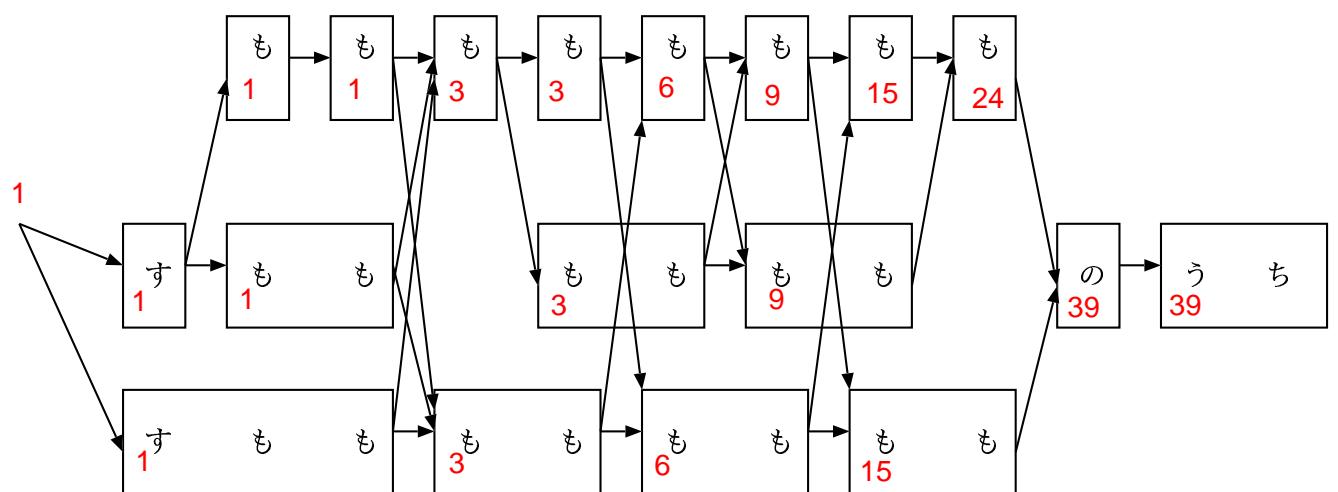
の区切の曖昧さにはどのようなものがあるかを、あげて下さい。たとえば、

- すもも | も | もも | も | もも | の | うち
- す | も | もも | も | もも | もも | の | うち

などがありますが、他にも色々あります。

全部で何通りの区切り方があるでしょうか。

## 形態素解析の曖昧さの例



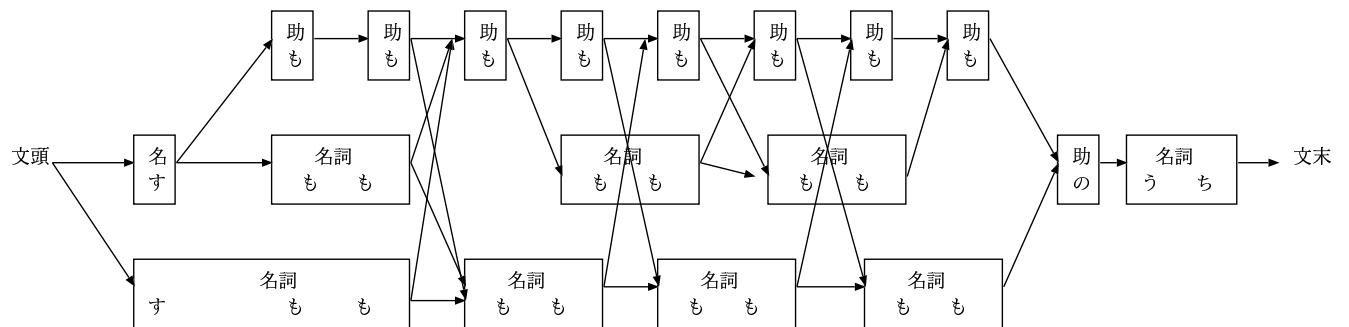
全部で 39 通りの区切の曖昧性があります。(実は 47 でした。上図では「もも」が一個ありません)

最初の時点では、区切の曖昧さは 1 通りです。枝わかれするにつれて、区切の曖昧さは増加します。区切の曖昧さを後の方に伝播していくことにより、区切の曖昧さの数を計算できます。

## 茶筌による解析結果

すもも	スモモ	すもも	名詞-一般
も	モ	も	助詞-係助詞
もも	モモ	もも	名詞-一般
も	モ	も	助詞-係助詞
もも	モモ	もも	名詞-一般
の	ノ	の	助詞-連体化
うち	ウチ	うち	名詞-非自立-副詞可能

## 区切の曖昧性の解消法



上図のパスのうちで，もっとも確からしいパスを通過することにより，最適な分割ができる．

パスの確からしさは，上図のノードとエッジにコストを与えることにより，パスのコストを，ノードのコストとエッジのコストの和で表現し，そのパスのコストが最小のパスを選択する．

## スコアの例

### ノードのコスト

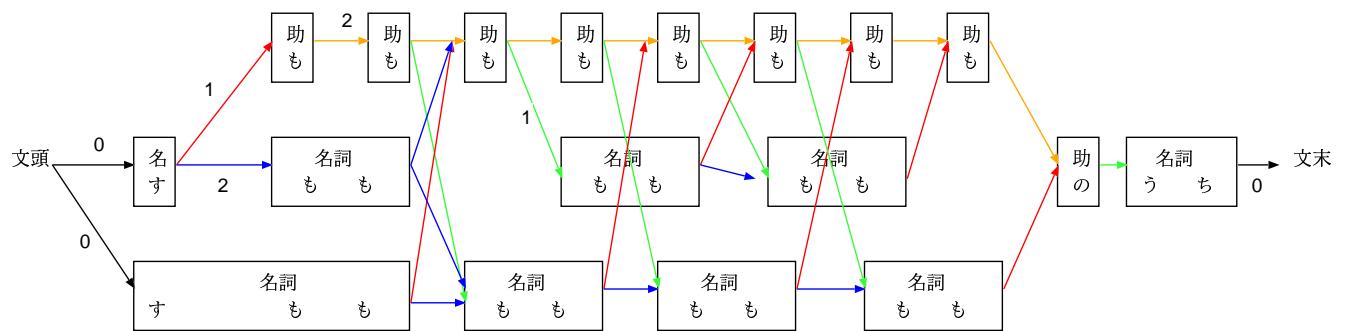
- も (助詞) = 1
- の (助詞) = 1
- もも (名詞) = 1
- うち (名詞) = 1
- す (名詞) = 1
- すもも (名詞) = 1

単純に，どのコストも1と考える。

### エッジのコスト

- 文頭に名詞が接続するとき = 0 (とてもよくある)
- 名詞に文末が接続するとき = 0 (あまりないが簡単のため)
- 名詞に助詞が接続するとき = 1 (よくある)
- 助詞に名詞が接続するとき = 1 (よくある)
- 名詞に名詞が接続するとき = 2 (やや少ない)
- 助詞に助詞が接続するとき = 2 (やや少ない)

## 問題：区切の曖昧さの例 (15分)



名詞=>名詞 (2)、助詞=>助詞 (2)、名詞=>助詞 (1)、助詞=>名詞 (1)

最小コストパスはどれでしょうか。そのコストはいくらですか。最小コストパスを求める一般的な方法についても考えて下さい。

# 回答

- 最小コストパス  
すもも(名詞) も(助詞) もも(名詞) も(助詞) もも(名詞) の(助詞) うち(名詞)
- 合計コスト = 13
- 最小コストパスを求める一般的な方法(課題とします)  
動的計画法により求めることができる。フレーズベースのSMTのデコーダーと類似のアルゴリズムを利用できる。

# どのようにコストを決めるか

- コーパスベースでコストを決めることができる

$$\begin{aligned} & \arg \max_{\text{形態素列}} P(\text{形態素列} | \text{文字列}) \\ &= \arg \max_{\text{形態素の文字列} = \text{文字列}} P(\text{形態素列}) \end{aligned}$$

$$\begin{aligned} P(\text{形態素列}) &= P((w_1, t_1), (w_2, t_2), \dots) \\ &= P(w_1, w_2, \dots, w_n | t_1, t_2, \dots, t_n) P(t_1, t_2, \dots, t_n) \\ &= \prod_i P(w_i | t_i) P(t_i | t_{i-1}) \end{aligned}$$

ただし， $w_i$ は単語で， $t_i$ は品詞とする．これより

$$\begin{aligned} & \arg \max_{w_1^n, t_1^n} \prod_i P(w_i | t_i) P(t_i | t_{i-1}) \\ &= \arg \min_{w_1^n, t_1^n} \sum_i (-\log P(w_i | t_i)) + \sum_i (-\log P(t_i | t_{i-1})) \end{aligned}$$

つまり，

- 単語コスト  $= -\log P(w_i | t_i)$
- 接続コスト  $= -\log P(t_i | t_{i-1})$

とすれば，コストを学習できる．ただし，そのためには，形態素に区切られ，かつ，品詞が付けられたコーパスが必要である．

## どのようなコーパスがあるか

- 代表的な形態素解析済みコーパスとしては，京都テキストコーパスがある

これは，京都大学黒橋研究室が，作成したものである。良質な形態素解析済みのコーパスを作成するのは，非常に大変である。

また，辞書を作成するのも非常に大変である。

## どのような形態素解析器があるか

ChaSen, Juman, Mecab

## まとめ

- 形態素解析における区切の曖昧性を取り扱う方法を述べた

## 残された問題

- 辞書にない語(未知語)をどう扱うか
- コーパスをどう作るか
- 辞書をどう作るか

どれも難しい問題である。