

テキストアナリティクスと
音声解析と
認知科学と
検索エンジン



日英対訳コーパス CORPORA

田淵 龍二（ミント音声教育研究所）
E-mail: tabuchiryuji@nifty.ne.jp

2018年9月6日 13:35-14:00
第13回 テキストアナリティクス・シンポジウム
成蹊大学（東京都武蔵野市吉祥寺）

あらまし

1 はじめに アメリカのリーダビリティ公式を**音声解析**による認知科学的視点から再評価し、**作動記憶**（ワーキングメモリ）との関連が極めて濃いこと示してきた。




図 1. 連續音声の視覚化と呼気段落 [1]




図 5. 句数で数えた文長ごとの累積 [6]




図 4. 読解プロセスの概要
(長期記憶は省略) [5]を改変

2 基礎研究 : テキスト読解過程の認知科学的基盤、およびテキストから音声情報を抽出する方法。

音韻符号化時間予測式

$$D = 120 \times Sy + 80 \times Cn \quad \dots \quad (1)$$

where

D: 時間 (ミリ秒)

Sy: 音節数

Cn: 子音数




図 10. 読解プロセスとテキストアナリティクス




図 6. 字幕表示実測時間と字幕默読予測時間の度数分布 (n=54,253) [7]

3 応用 適応学年ごとに学習に最適なテキストや動画を選ぶ検索エンジン開発。

日英対訳コーパス
CORPORA（左）と
TED ビデオコーパス
selected360



4まとめ 基礎研究から応用までの流れを紹介することで、単語や形態素以外の要素（音声）に注目したテキストアナリティクスの多様な一面を明らかにする。

キーワード テキストアナリティクス, 音声解析, 認知科学, 検索エンジン, リーダビリティ公式

日英対訳コーパス CORPORA



図 7. get away で検索した様子と QR コード

URL : <http://www.mintap.com/talkies/pac/corpora.html>

TED ビデオコーパス selected360



図 8. 文レベルを高 2 としたときの様子と QR コード

URL : <http://www.mintap.com/talkies/?selected360>

音声言語に埋め込まれていた法則の方程式

BG 長分布は対数正規分布に従う

$$f(x, \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma x} e^{-\frac{1}{2}\left(\frac{\ln(x)-\mu}{\sigma}\right)^2}$$

平均発話速度は対数分布に従う

$$wps = a \cdot \ln(w) + b$$




図 2. 呼気段落長の度数分布
(n=19,551) [3] を改変





図 3. 単語数ごと発話速度の分布
と平均値[3] を改変

読解プロセスとテキストアナリティクス



A 読みやすさ指標

B 形態素・構文解析
と単語処理

C AI (人工知能)、
アノテーション