

言語処理学会第21回年次大会

仮名漢字変換ログを用いた 単語分割の精度向上

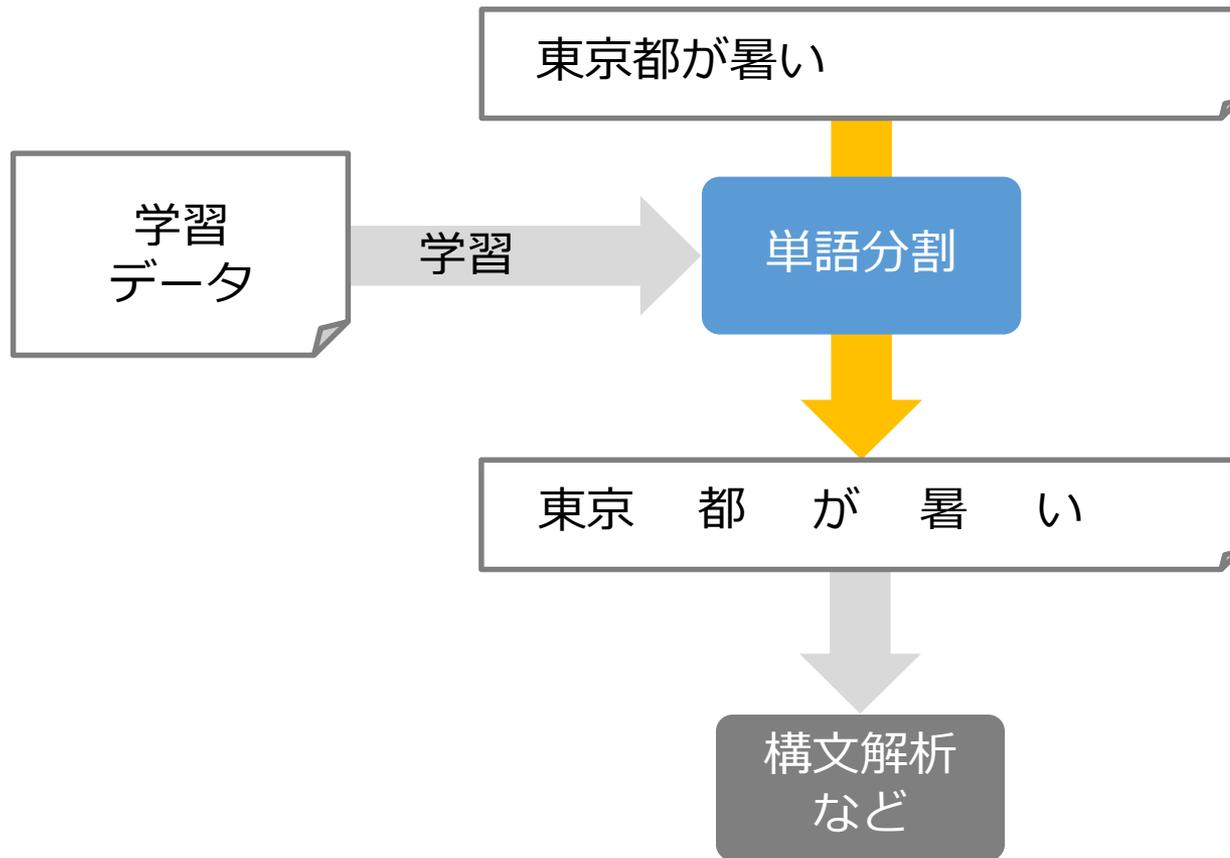


京都大学 大学院

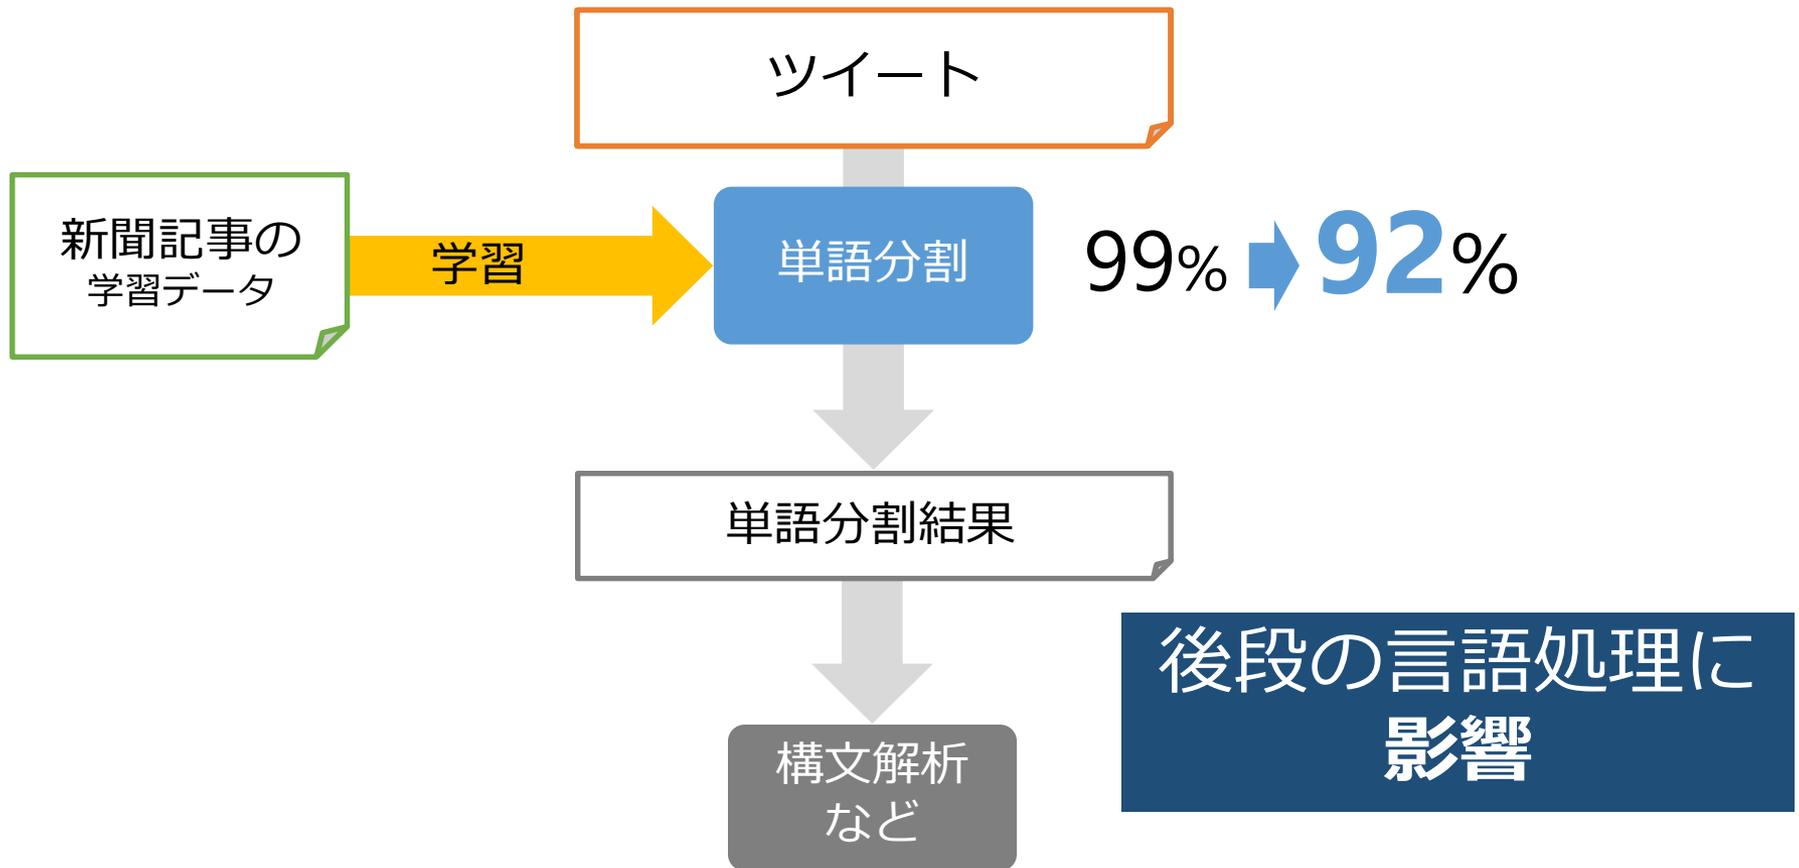
修士二回 高橋 文彦

准教授 森 信介

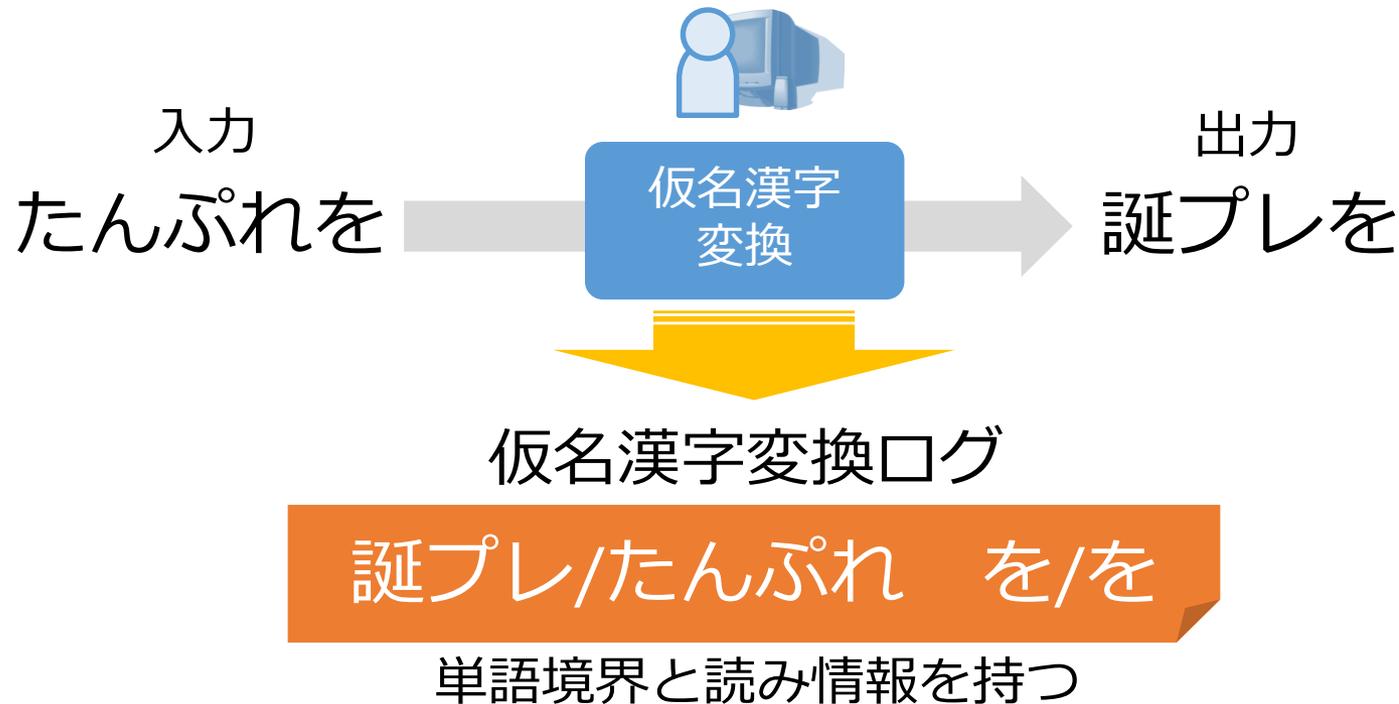
単語分割は様々な言語処理の根源的な処理



学習データのないドメインに対して低い解析精度



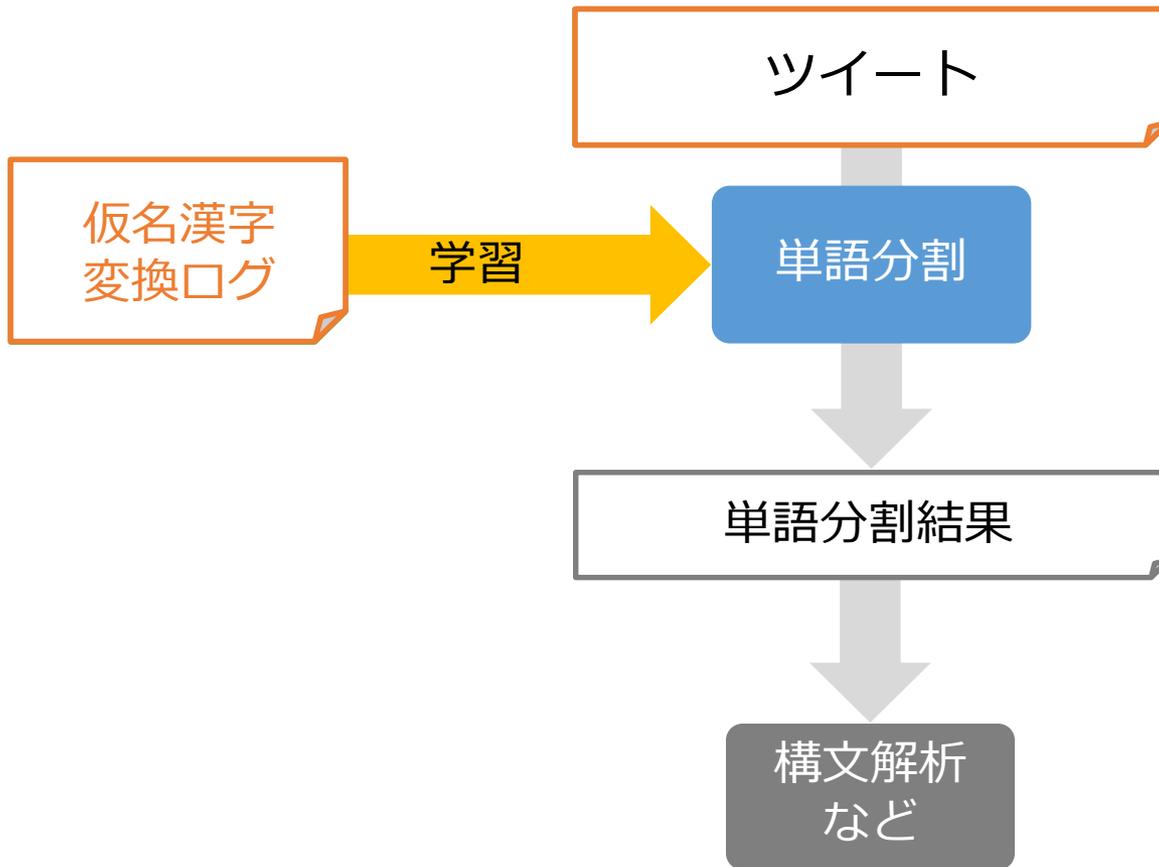
本研究の概要



人が自然に作るデータなので**コストが低い**

➡ **単語分割の学習データに利用**

学習データの無いドメインに対して低い解析精度



- [森+, 1998] [Chen+, 2000]

統計的仮名漢字変換

語彙をコーパスの全部分文字列に拡張 [Mori+, 2006]

- [Tsuboi+, 2008] [Neubig+, 2011]

部分的単語分割からの単語分割器の学習

- [Jiang+, 2013] **自然注釈の利用**

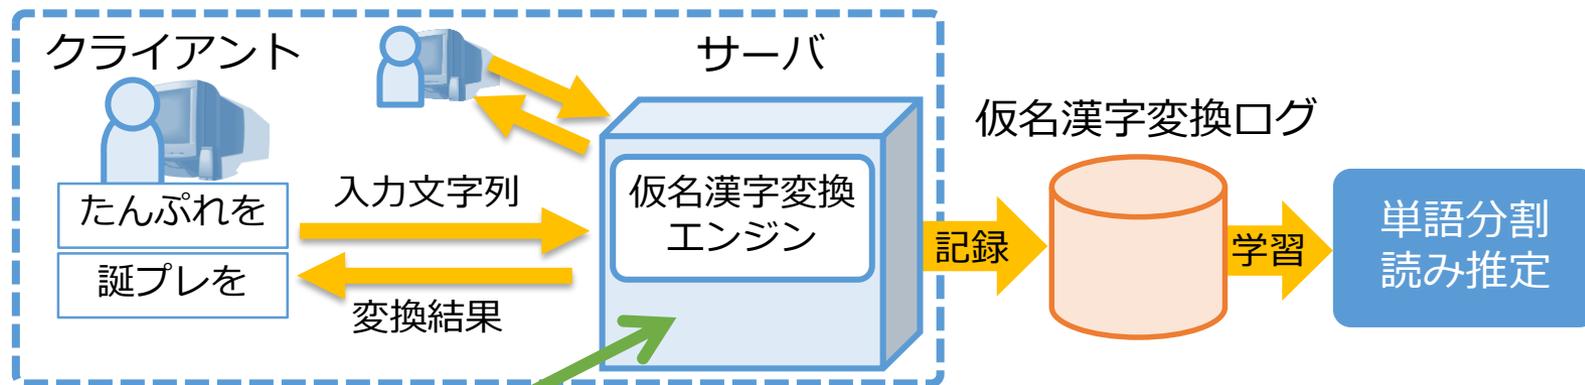
HTMLタグを利用した単語境界情報の獲得

頑 健 な<a>形 態 素解 析 を 行 う



頑 健 な | 形 態 素 | 解 析 を 行 う

ログを収集する仮名漢字変換システム 7



擬似確率的タグ付与コーパス(PSTC)で学習

確率的単語分割 + 確率的読み付与

... の | 誕 ? プ - レ | あ - げ | る ...

単語分割確率 : $p = 0.8$

乱数 $r > p$: 単語境界なし
 $r < p$: 単語境界あり

擬似的に出現率を反映してアノテーション

単語分割確率・読み確率 : ロジスティック回帰により推定

実際には、ツイートのPSTCを作成

昨日 | 誕 | プレ | あげ | た
誕プレ | い | る | ?

「誕プレ」という未知語候補が
仮名漢字変換で提示

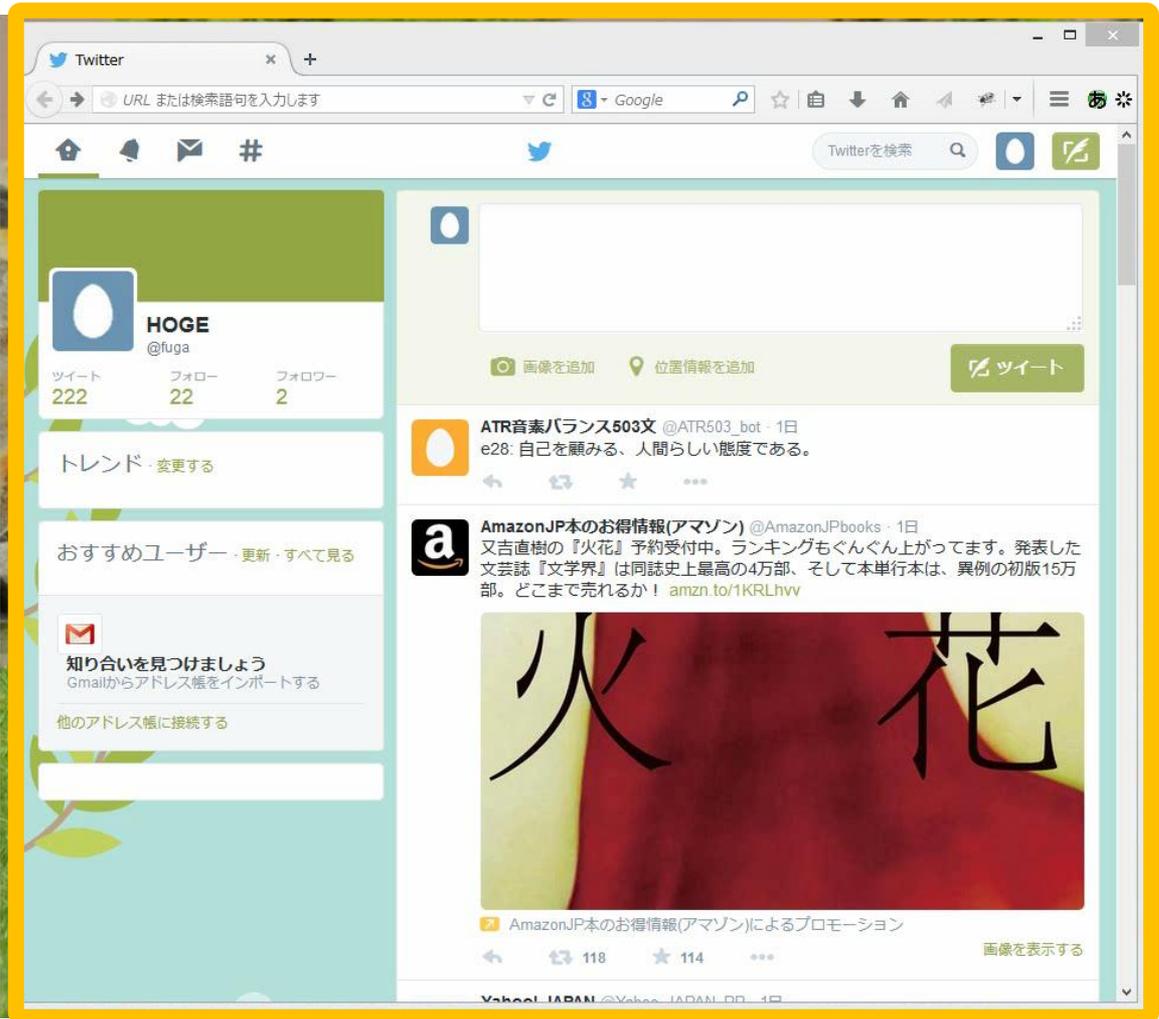
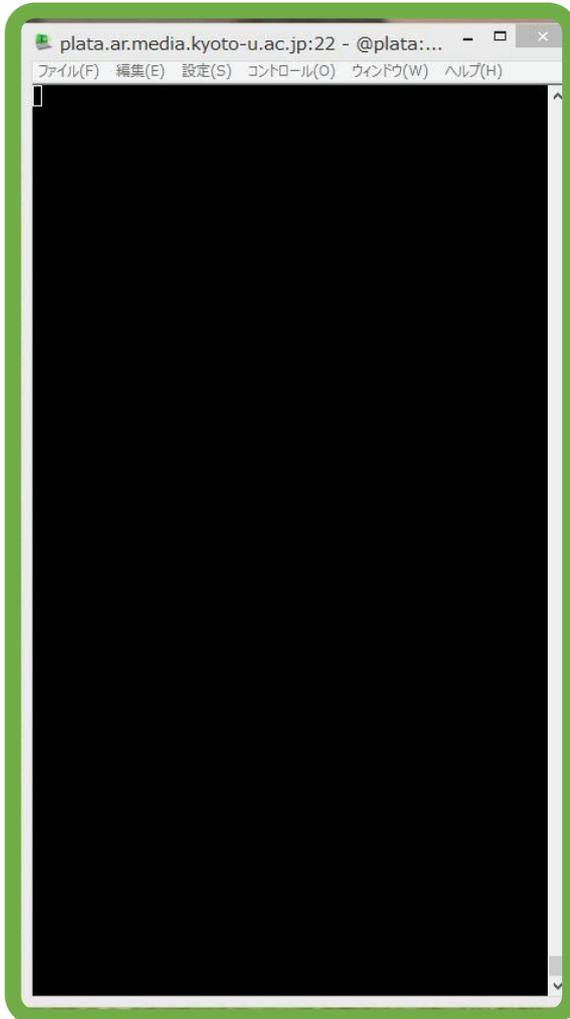
➡ ツイートの
文脈と未知語がログに記録

仮名漢字変換システムのデモ

クライアントが逐次的にサーバにログを送信

サーバ (コンソール)

クライアント (Twitterのページ)



仮名漢字変換を使う工程

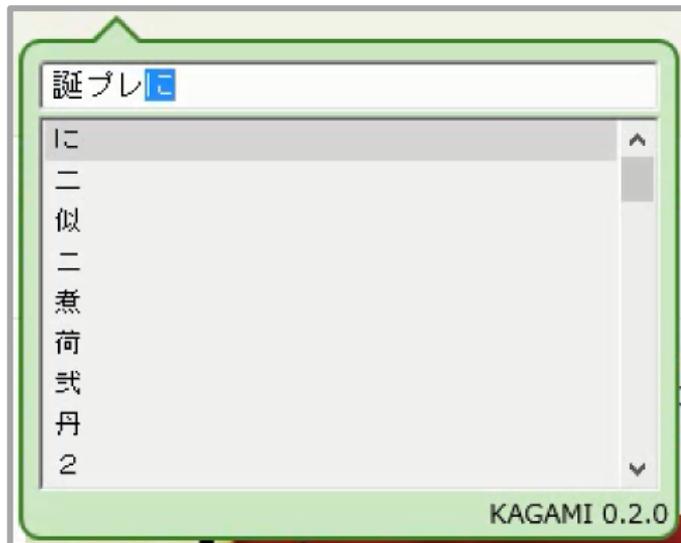
1. 入力文字列の入力

文の読み情報



2. 変換

単語境界と表記の選択



“誕プレに”を入力する過程



確定

ログの確定結果



誕プレ/たんぷれ | に/に

“それを誕プレにしよう”というツイートの
仮名漢字変換ログ

時間	入力文字列	確定結果
18:37:11.22	それを	そ_れ_を
18:37:12.60	たんっぷれに	タンツプレ/たんっぷれ に/に
18:37:14.95	たんぷれに	誕プレ/たんぷれ に/に
18:37:15.33	あげよう	上げ/あげ よう/よう
18:37:19.83	しよう	し_よ_う



確定結果（変換ログの主要な情報）の特徴

- 完全な文でなく **文の断片**
- **誤った確定**を含む
- **単語境界情報がない**場合がある（変換しない場合）

➡ ノイズを含んだ、文断片のアノテーションデータ

AS-IS-log :

確定結果をそのまま用いる

CHUNK-log :

入力の時間差が s 以下の場合、
確定結果をチャンキング ($s = 500[\text{ms}]$)

文断片の問題を回避

MCONV-log :

変換操作が n 回以下のログを除く ($n = 2$)

ユーザーが編集した文は、
確定誤りを含む可能性が低く、
未知語を含む可能性が高い

AS-IS-log
そ_れ_に
タンツ/たんっ プレ/ぷれ に/に
誕プレ/たんぷれ に/に
上げ/あげ よう/よう
し_よ_う

CHUNK-log
そ_れ_に タンツ/たんっ プレ/ぷれ に/に
誕プレ/たんぷれ に/に 上げ/あげ よう/よう
し_よ_う

MCONV-log
誕プレ/たんぷれ に/に
上げ/あげ よう/よう

アノテーションされていない部分のある学習データから推定器を学習

[Neubig+, 2011]

他の推定情報を利用せず周辺文字情報のみを用いる推定手法



素性

文字3-gram : -2/レ, を, あ -1/を, あ, げ
単語辞書 : L(を) R(あげ)

➡ アノテーションされていない部分があっても学習可能

窓幅 $w=3$

素性を**文字3-gram**, **文字種3-gram**, **単語辞書**で実験

・ ログの収集 ユーザー：5～17人

収集期間：2014/04/24 – 2014/12/31(262日間)

人手アノテーションテストコーパス

	ドメイン	文数	単語数
TWI-test	ツイート	588	7,498

人手アノテーション学習コーパス

	ドメイン	文数	単語数
BCCWJ-train	一般分野	56,753	1,324,951

ログ由来の学習コーパス

	エントリー数	単語境界	読み
AS-IS-log	32,119	39,708	34,769
CHUNK-log	8,685	63,144	34,769
MCONV-log	4,610	10,852	8,959
CHUNK-MCONV-log	1,218	14,242	8,956

単語分割の評価

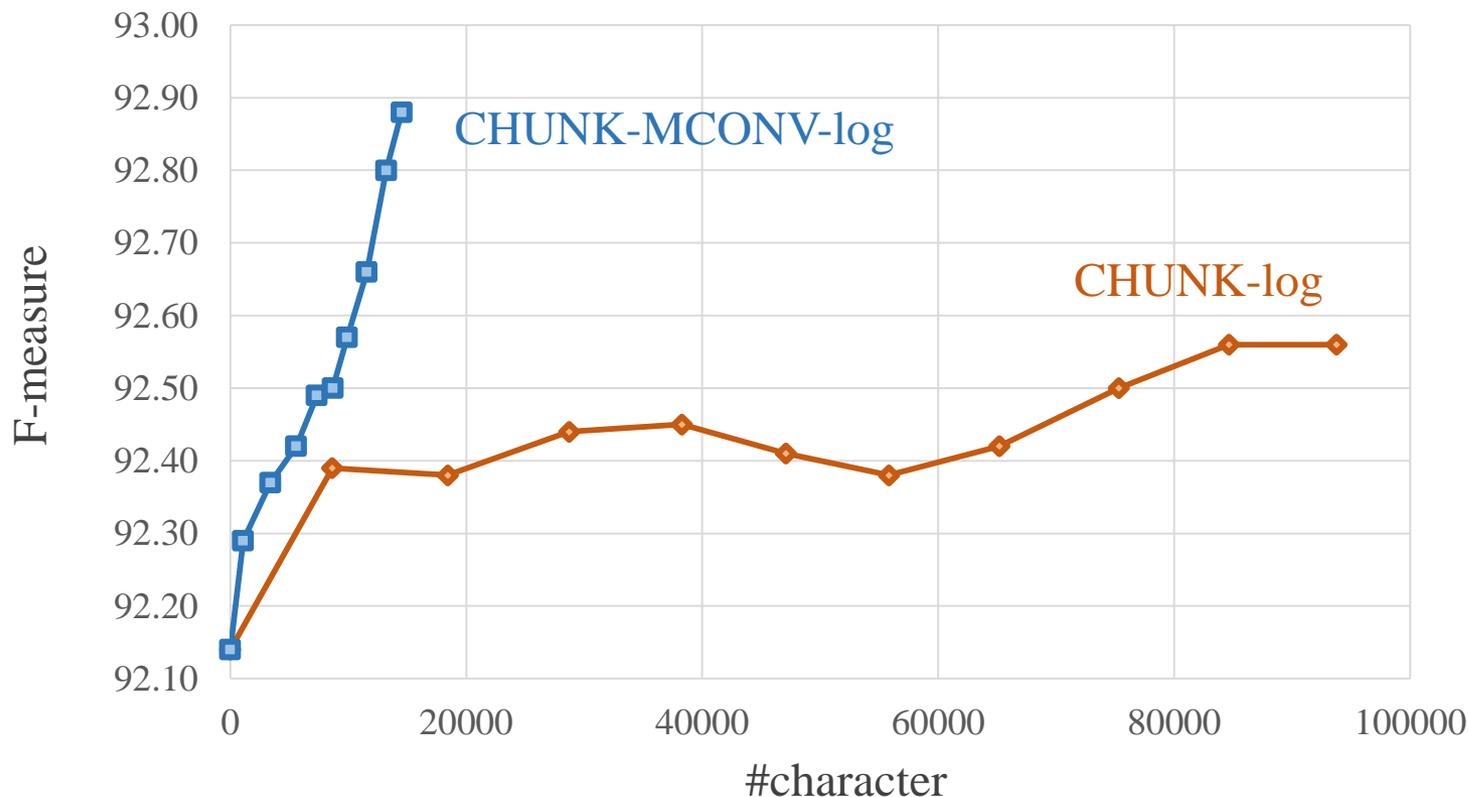
単語分割の評価： **単語**アライメントを取り再現率・適合率・調和平均 (F値)

	再現率	適合率	F値
BCCWJ-train	90.31	94.05	92.14
+ AS-IS-log	90.33	93.77	92.02
+ CHUNK-log	91.04	94.29	92.64
+ MCONV-log	90.62	94.09	92.32
+ CHUNK-MCONV-log	91.40	94.45	92.90

- MCONV-log**によってノイズがフィルタリングされた
- CHUNK-MCONV-log**で最大精度、統計的に優位な差 (p=0.01)
- 再現率 < 適合率 → 過分割

“艦これ” → “艦”, “これ”

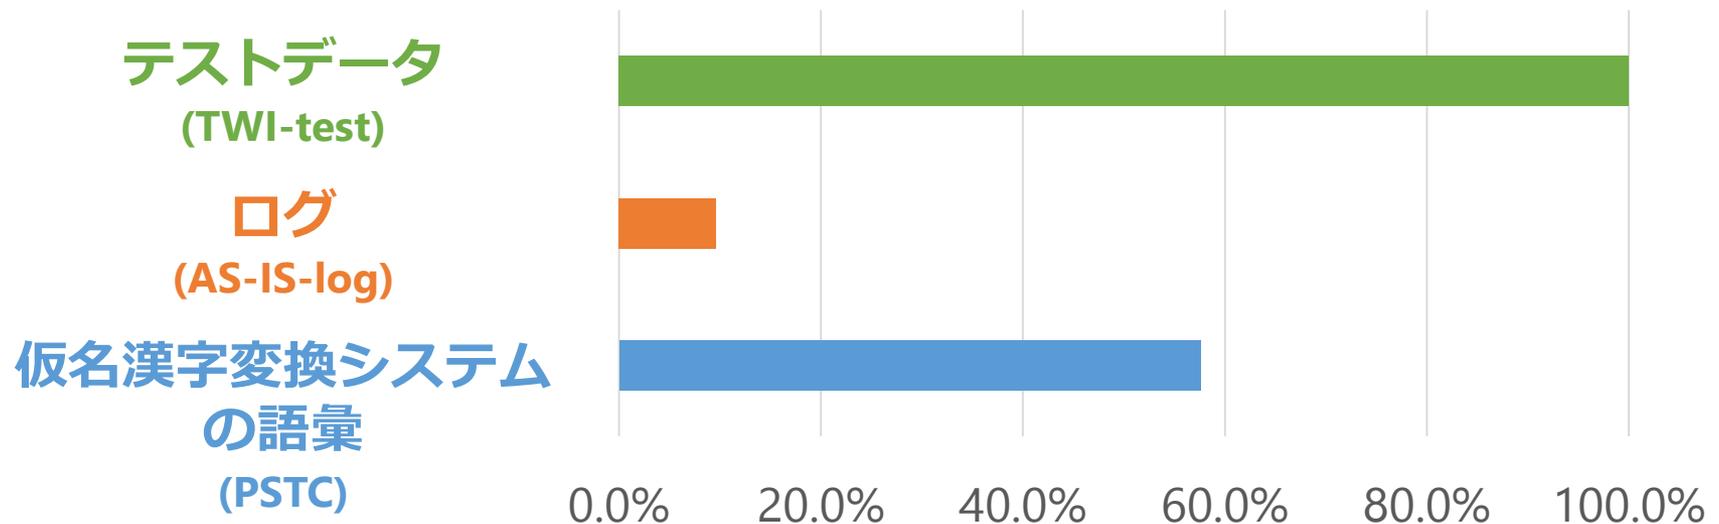
時系列順に並べたログを順次追加した、単語分割精度



- **CHUNK-MCONV-log**は少ない量でより精度が向上
- 人手アノテーションの800文字程度と同等の精度向上
- さらにログを集めることで精度向上が期待

テストデータ中の未知語の適合率

未知語：
BCCWJ, UniDicに含まれない単語
単語単位で扱う



仮名漢字変換システムの語彙中に、ログに未記録の未知語あり

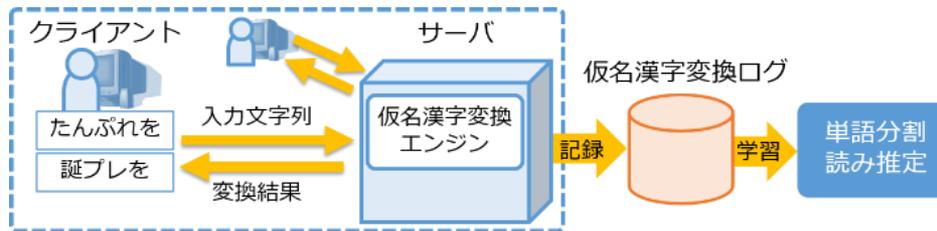
➡ さらにログを集めることで、精度向上が期待

単語分割の精度低下の問題

問題提起

仮名漢字変換ログから 有用な情報を獲得する方法を提案

手法の提案



ログによる精度向上を実現

- テストデータのドメインに合ったログで解析精度が向上
- ログを収集することでさらに精度向上が期待

結論

