
編集距離に基づくカリキュラム学習 を用いたスタイル変換

門谷宙* 梶原智之** 荒瀬由紀* 鬼塚真*

*大阪大学大学院情報科学研究科 **愛媛大学大学院理工学研究科



OSAKA UNIVERSITY

もくじ

- 1 背景
- 2 関連研究: Platanios et al. [1]
- 3 提案手法
- 4 評価実験
- 5 分析
- 6 まとめ

もくじ

1 背景

2 関連研究: Platanios et al. [1]

3 提案手法

4 評価実験

5 分析

6 まとめ

スタイル変換

- 入力文の意味を保持したまま表現を変更するタスク
- 単言語パラレルコーパス上で機械翻訳と同様の手法を使用
- 応用事例: 文章読解支援, 機械翻訳の前処理

! LOOOOOVVVVVVVEEE this song SOOO Much!!!!!!

カジュアル → **フォーマル**
スタイル変換モデル

I love this song very much.

カリキュラム学習

- 簡単な問題から学習を始め, 徐々に難しい問題を学習
- 機械学習モデルの性能向上
- 適用事例: 物体認識 [2], マルチメディア検索 [3]

Easy

Thank you.

Medium

Thank you very much.

Difficult

Thank you for your
helping me with my work.



Training Time

[2] Xiao et al. (ACMMM 19) Error-Driven Incremental Learning in Deep Convolution Neural Network for Large-Scale Image classification

[3] Jiang et al. (NIPS 14) Self-Paced Learning with Diversity

自然言語処理におけるカリキュラム学習

- **機械翻訳**におけるカリキュラム学習
 - 訓練サンプルの難易度のみを考慮する手法 [4]
→ 学習の収束は早くなるが, 翻訳品質は向上せず
 - モデルの能力を考慮する手法 [1]
→ 収束後においても翻訳品質が向上
- **スタイル変換**におけるカリキュラム学習の先行研究はなし

もくじ

1 背景

2 関連研究: Platanios et al. [1]

3 提案手法

4 評価実験

5 分析

6 まとめ

Platanios et al. [1]: 手法概要

- 機械翻訳におけるカリキュラム学習手法
- 2つの指標を導入
 - 訓練サンプル s_i の難易度 $\bar{d}(s_i) \in [0, 1]$
 - 訓練ステップ t におけるモデルの能力 $c(t) \in [0, 1]$
- 各ステップで $\bar{d}(s_i) \leq c(t)$ を満たす訓練サンプルのみを使用
→ 訓練時間の経過に伴って使用できる訓練サンプルが増加

Platanios et al. [1]: 難易度の基準 $d(s_i)$

- 訓練サンプル s_i の入力文は単語列 $\{w_1, \dots, w_{N_i}\}$ で構成される
- 難易度の基準 $d_{length}(s_i)$
 - 長文は難しい → **文長** が難易度の指標
 - $d_{length}(s_i) \triangleq N_i$
- 難易度の基準 $d_{rarity}(s_i)$
 - 低頻度語は難しい → **単語の出現頻度** が難易度の指標
 - $d_{rarity}(s_i) \triangleq -\sum_{j=1}^{N_i} \log \hat{p}(w_j)$ ($\hat{p}(w_j)$: 単語 w_j の出現確率)
- 既存の難易度の基準は、正解文を考慮していない

もくじ

- 1 背景
- 2 関連研究: Platanios et al. [1]
- 3 提案手法
- 4 評価実験
- 5 分析
- 6 まとめ

スタイル変換における難易度

- ほとんど変換を必要としない訓練サンプル:
入力文をコピーするだけで, 正解文とほぼ一致 (簡単)
- 多くの変換が必要な訓練サンプル:
複雑な書き換え操作が必要 (難しい)
- 入力文を正解文に変換するために必要な変換コストと仮定
→ カリキュラム学習に**編集距離**を導入

入力文

正解文

Their first two albums were **pretty** good. Their first two albums were **very** good.

no where there is no such thing

That does not existst.

編集距離

- 単語列 X を単語列 Y に変換するために必要な編集操作の回数
 - 挿入 単語を1つ加える
 - 削除 単語を1つ消す
 - 置換 単語を1つ別の単語に変える
- 簡単な訓練サンプルは小さく, 難しい訓練サンプルは大きい

入力文	正解文	編集距離
Their first two albums were pretty good.	Their first two albums were very good.	1
no where there is no such thing	That does not existst.	7



提案手法: 編集距離に基づくカリキュラム学習

- スタイル変換に初めてカリキュラム学習を適用
- カリキュラム学習の枠組みは Platanios et al. [1] に従う
- 難易度の基準 $d_{distance}(s_i)$
 - 難易度の指標: 編集距離
 - $d_{distance}(s_i) \triangleq E_i$
 E_i : 訓練サンプル s_i の入力文と正解文の編集距離
 - 入力文と正解文の両方を考慮

カリキュラム学習の枠組み: Platanios et al. [1]

難易度 $\bar{d}(s_i)$

- 難易度の基準 $d(s_i)$ から難易度 $\bar{d}(s_i)$ への変換手順
 1. $d(s_i)$ に従って累積分布関数を作成
 2. 累積分布関数上で $d(s_i)$ に対応する値を $\bar{d}(s_i)$ とする
- $\bar{d}(s_i)$ が小さいほど簡単, 大きいほど難しい



カリキュラム学習の枠組み: Platanios et al. [1]


モデルの能力 $c(t)$

- $c(t) = \min(1, \sqrt{t \frac{1-c_0^2}{T} + c_0^2})$

c_0 : モデルの能力の初期値

T : モデルの能力が完全に備わると予想されるステップ数

- $c(t)$ は訓練開始時は小さく, 訓練の経過に伴い単調増加



もくじ

- 1 背景
- 2 関連研究: Platanios et al. [1]
- 3 提案手法
- 4 評価実験
- 5 分析
- 6 まとめ

実験設定

フォーマルさに関するスタイル変換の性能を評価

- データセット: GYAFC [5]
- スタイル変換モデル: Transformer [6]
- 評価指標: BLEU [7]

	Train	Dev	Test
E&M	209,124	2,877	1,416
F&R	209,124	2,788	1,332

[5] Rao and Tetreault (NAACL 18) Dear Sir or Madam, May I Introduce the GYAFC Dataset: Corpus, Benchmarks and Metrics for Formality Style Transfer

[6] Vaswani et al. (NIPS 17) Attention is All you Need

[7] Papineni et al. (ACL 02) Bleu: a Method for Automatic Evaluation of Machine Translation

比較手法

- ベースライン カリキュラム学習を用いない手法
- CL-SL **文の長さ**に基づくカリキュラム学習
- CL-SR **単語の出現頻度**に基づくカリキュラム学習
- CL-ED **編集距離**に基づくカリキュラム学習

実験結果

- 両ドメインで、提案手法がベースラインを上回る性能を達成
- 既存のカリキュラム学習は有効でないが、提案手法は有効

	カジュアル → フォーマル	
	E&M	F&R
入力文	49.19	50.94
正解文	100.0	100.0
ベースライン	69.81	75.02
CL-SL	69.83	74.90
CL-SR	70.05	74.62
CL-ED	70.34	75.41

もくじ

1 背景

2 関連研究: Platanios et al. [1]

3 提案手法

4 評価実験

5 分析

6 まとめ

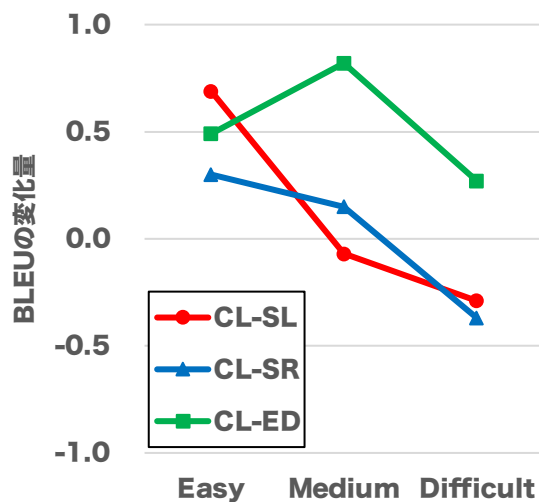
分析手順

どのような特性を持つ事例に対する性能が向上するか分析


- 評価データを難易度の指標に従って、3つのビンに振り分け
- 比較手法を用いて、ビン毎にBLEUを測定
 - ベースライン カリキュラム学習を用いない手法
 - CL-SL **文の長さ**に基づくカリキュラム学習
 - CL-SR **単語の出現頻度**に基づくカリキュラム学習
 - CL-ED **編集距離**に基づくカリキュラム学習
- ベースラインからのBLUEの変化量を調べる

分析結果

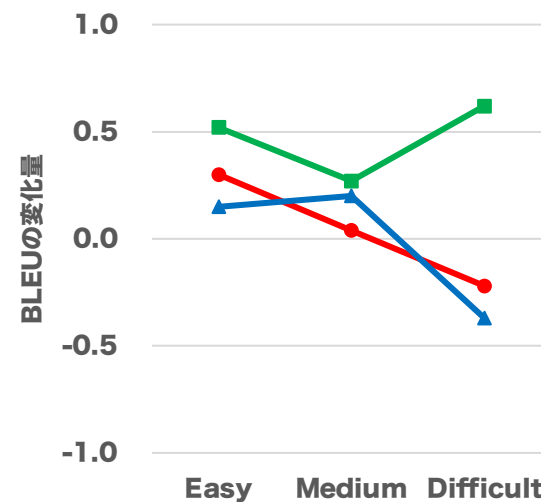
- 全体的に簡単な事例に対する性能の向上が大きい
- 既存のカリキュラム学習は難しい事例に対する性能が悪化
- 提案手法は難しい事例に対する性能を改善



(a) 文長



(b) 単語の出現頻度



(c) 編集距離

もくじ

- 1 背景
- 2 関連研究: Platanios et al. [1]
- 3 提案手法
- 4 評価実験
- 5 分析
- 6 まとめ

まとめ

- 提案手法: 編集距離に基づくカリキュラム学習
 - スタイル変換に初めてカリキュラム学習を適用
 - 難易度の指標として編集距離を導入
- 評価実験の結果, 提案手法の有効性を確認
- 提案手法は難しい事例に対する性能改善に貢献