

Submodular Optimization-based Diverse Paraphrasing and its Effectiveness in Data Augmentation

Ashutosh Kumar*¹ **Satwik Bhattamishra***² † **Manik Bhandari**¹ **Partha Talukdar**¹

¹ Indian Institute of Science, Bangalore, India

² Birla Institute of Technology and Science, Pilani, India


{ashutosh, ppt}@iisc.ac.in, {satwik55, mbbhandarimanik}@gmail.com

読む人：今野 颯人

乾・鈴木研究室 M1

概要

- 入力文sからEnc-Decによりk個の言い換え文を得る



- 応用先：Data augmentation, 対話エージェント
- 目的：従来より多様性のある言い換え文を得たい
- 提案手法：劣モジュラ関数最大化として定式化
- 評価：従来よりも元の文に忠実かつ多様な文を生成することに成功
Data Augmentationでの効果も検証

実際の入出力

SOURCE – how do i increase body height ?
REFERENCE – what do i do to increase my height ?

BEAM – how do i increase my height ?
SEARCH – how do i increase my body height ? 従来よりも多様
 – how do i increase the height ?
 – how would i increase my body height ?

DIPS
(OURS) – how could i increase my height ?
 – what should i do to increase my height ?
 – what are the fastest ways to increase my height ?
 – is there any proven method to increase height ?



モチベーション

- 言い換えの質を決める2つの要素：Fidelity, Diversity
 - Fidelity：元の文に忠実か（意味的類似性）
 - Diversity：語彙的にどのくらい異なるか（多様性）
- 従来の手法：top-k beam search
 - 構文が類似，単語レベルの変化のみ，
 - Diversityが低い
- 目的：Fidelityを落とさずにDiversityを向上させたい
- 提案手法：Fidelity, Diversityを最大化するために劣モジュラ関数最大化として定式化

提案手法

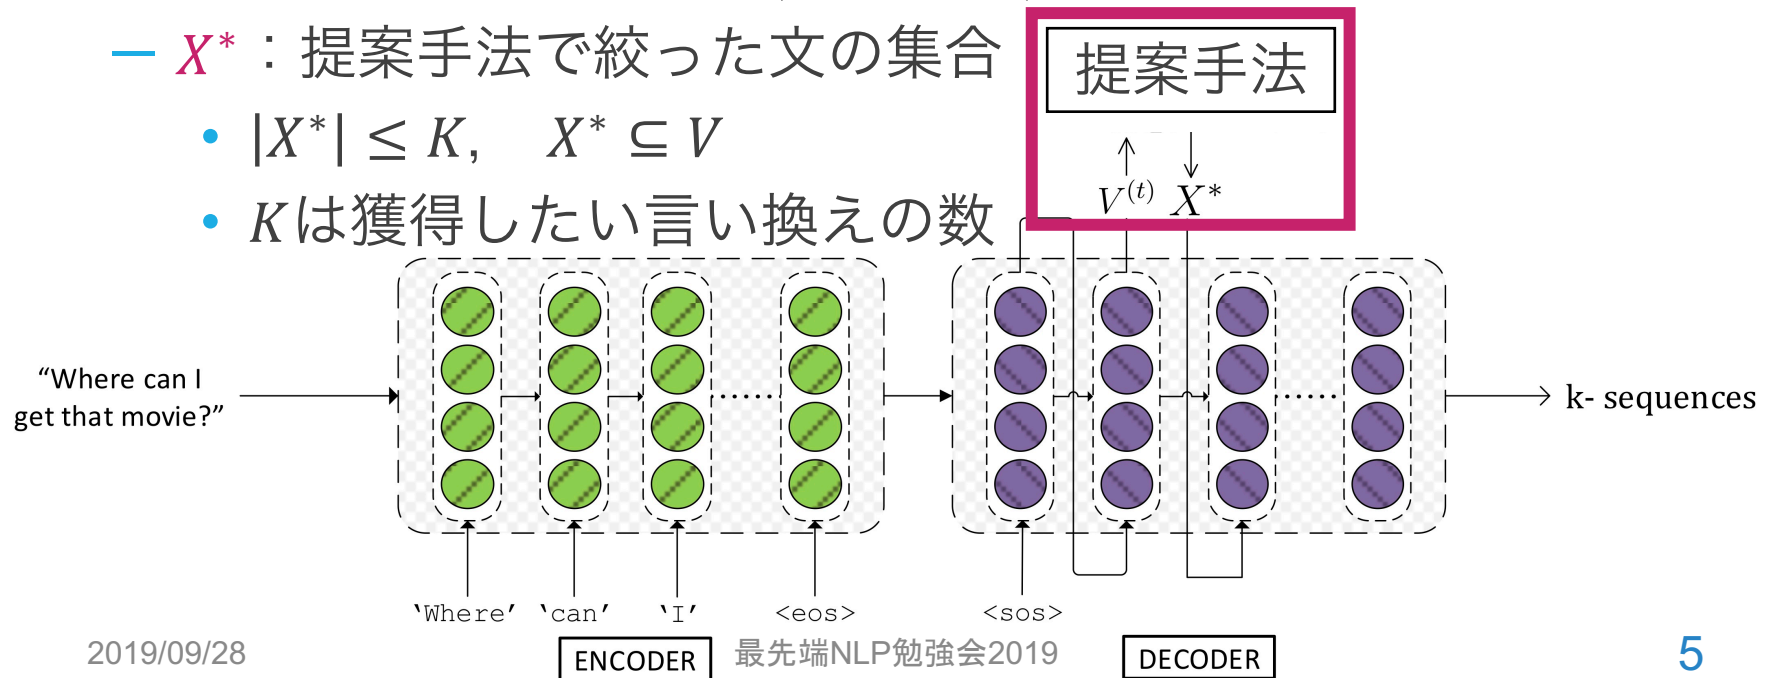
- まずはSEQ2SEQをcross entropy lossで学習
- デコード時のtime-step t ごとに出力文の集合 $V^{(t)}$ からFidelityとDiversityが高い文の部分集合 X^* を選ぶ

— $V^{(t)}$: t 時点での出力文(確率付き)の集合

— X^* : 提案手法で絞った文の集合

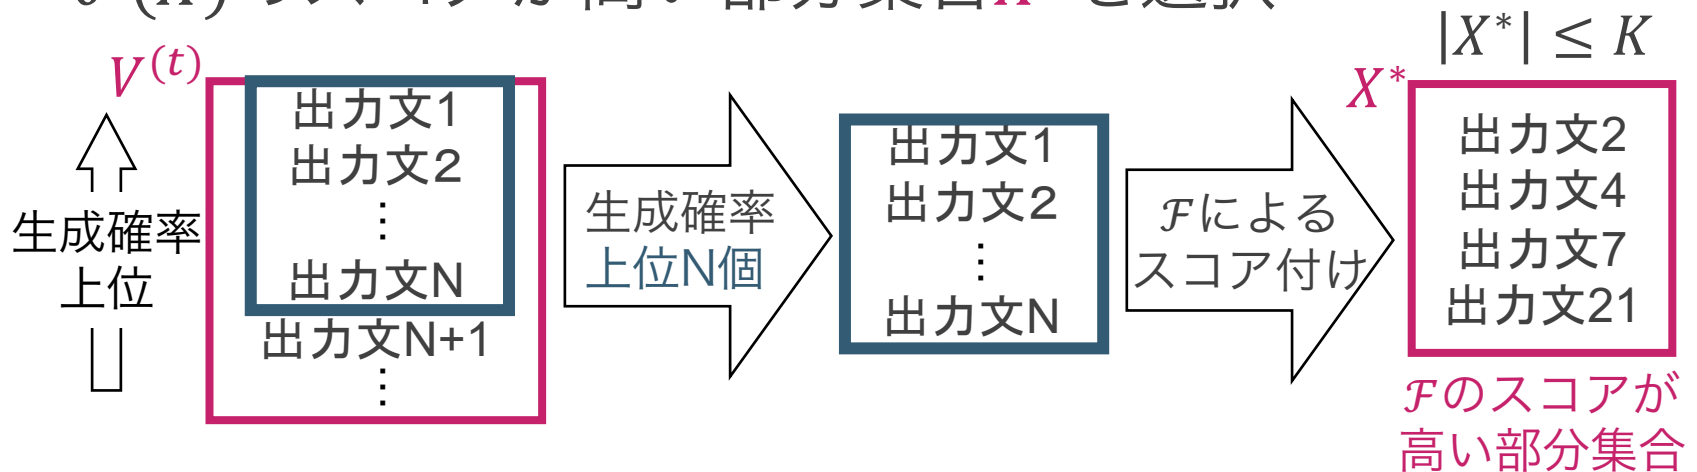
- $|X^*| \leq K, X^* \subseteq V$

- K は獲得したい言い換えの数



提案手法

- $V(t)$ から X^* へ絞りたい
- 集合関数 $\mathcal{F} : 2^V \rightarrow \mathbb{R}$ を作成
 - $\mathcal{F}(X)$: 部分集合 X に対してスコア付けする関数
 - $\mathcal{F}(X)$ のスコアが高い = 文の部分集合 X の **Fidelity** と **Diversity** が高い (ように集合関数 \mathcal{F} を作成)
- $\mathcal{F}(X)$ のスコアが高い部分集合 X^* を選択



- 目的 : $X^* = \operatorname{argmax}_{X \subseteq V} \mathcal{F}(X)$ を求める

組み合わせ爆発の問題

- $X^* = \operatorname{argmax}_{X \subseteq V} \mathcal{F}(X)$ を求めたい
- しかし $\mathcal{F}(X)$ を最大化する部分集合 X^* を選ぶのは困難
 - 冪集合 2^V から最適解となる部分集合を選ぶ
 - NP困難な最適化問題
- 台集合の要素数や $|X|$ の上限値 K が大きくなると解の候補は爆発的に大きくなる
- \mathcal{F} が非負で非単調減少の劣モジュラ関数ならば貪欲法で最適解の $63.2\% (1 - 1/e)$ に近似できる

貪欲法による近似解

Algorithm 1: Greedy selection for submodular optimization (Cardinality constraint)

Input: Ground Set: V

Budget: k

Submodular Function: \mathcal{F}

\mathcal{F} は非負で非単調減少の劣モジュラ関数

```
1  $S \leftarrow \emptyset$ 
2  $N \leftarrow V$ 
3 while  $|S| < k$  do
4    $x^* \leftarrow \operatorname{argmax}_{x \in N} \mathcal{F}(S \cup \{x\})$ 
5    $S \leftarrow S \cup \{x^*\}$ 
6    $N \leftarrow N \setminus \{x^*\}$ 
7 end
8 return  $S$ 
```

$S = \{\}$ からスタートし
 $|S| = k$ となるまで
「貪欲」に要素を
1つずつ増やしていく

$X^* = \operatorname{argmax}_{X \subseteq V} \mathcal{F}(X)$ の近似解を得る

劣モジュラ関数



- 劣モジュラ関数：劣モジュラ性を持った集合関数
- 劣モジュラ性

$$\forall A \subseteq B \subseteq V, \forall j \in V \setminus B:$$

$$\mathcal{F}(A \cup \{j\}) - \mathcal{F}(A) \geq \mathcal{F}(B \cup \{j\}) - \mathcal{F}(B)$$

サイズとともに
増加が緩やかとなる

例) カバー関数



$$f(\{S_1, S_3\}) - f(\{S_1\}) > f(\{S_1, S_2, S_3\}) - f(\{S_1, S_2\})$$
$$10 - 6 = 4 \qquad 11 - 8 = 3$$

劣モジュラ関数の作成

- 文の部分集合 X のFidelityとDiversityが高いと $\mathcal{F}(X)$ のスコアが高いように集合関数 \mathcal{F} を作成
- $\mathcal{F}(X) = \lambda \mathcal{L}(X, s) + (1 - \lambda) \mathcal{D}(X)$
 - $\mathcal{L}(X, s)$: Fidelityの良さを表す集合関数
 $\mathcal{L}(X, s) = \mathcal{L}_1(X, s) + \mathcal{L}_2(X, s)$
 - $\mathcal{D}(X)$: Diversityの良さを表す集合関数
 $\mathcal{D}(X) = \mathcal{D}_1(X) + \mathcal{D}_2(X)$
 - s : 入力文, $\lambda \in [0, 1]$
- $\mathcal{L}_1(X, s), \mathcal{L}_2(X, s), \mathcal{D}_1(X), \mathcal{D}_2(X)$ は全て非負で非単調減少の劣モジュラ関数

劣モジュラ関数の作成①：Fidelity

- $\mathcal{F}(X) = \lambda \mathcal{L}(X, s) + (1 - \lambda) \mathcal{D}(X)$
- Fidelity : $\mathcal{L}(X, s) = \mathcal{L}_1(X, s) + \mathcal{L}_2(X, s)$

- $$\mathcal{L}_1(X, s) = \mu_1 \sqrt{\sum_{x \in X} \sum_{n=1}^N \beta^n |x_{n-gram} \cap s_{n-gram}|}$$

— 元の文と言い換えのN-grams重複度

- $$\mathcal{L}_2(X, s) = \mu_2 \sqrt{\sum_{x \in X} \frac{1}{|x|} \sum_{w_i \in x} \operatorname{argmax} \psi(v_{w_i}, v_{w_j})}$$

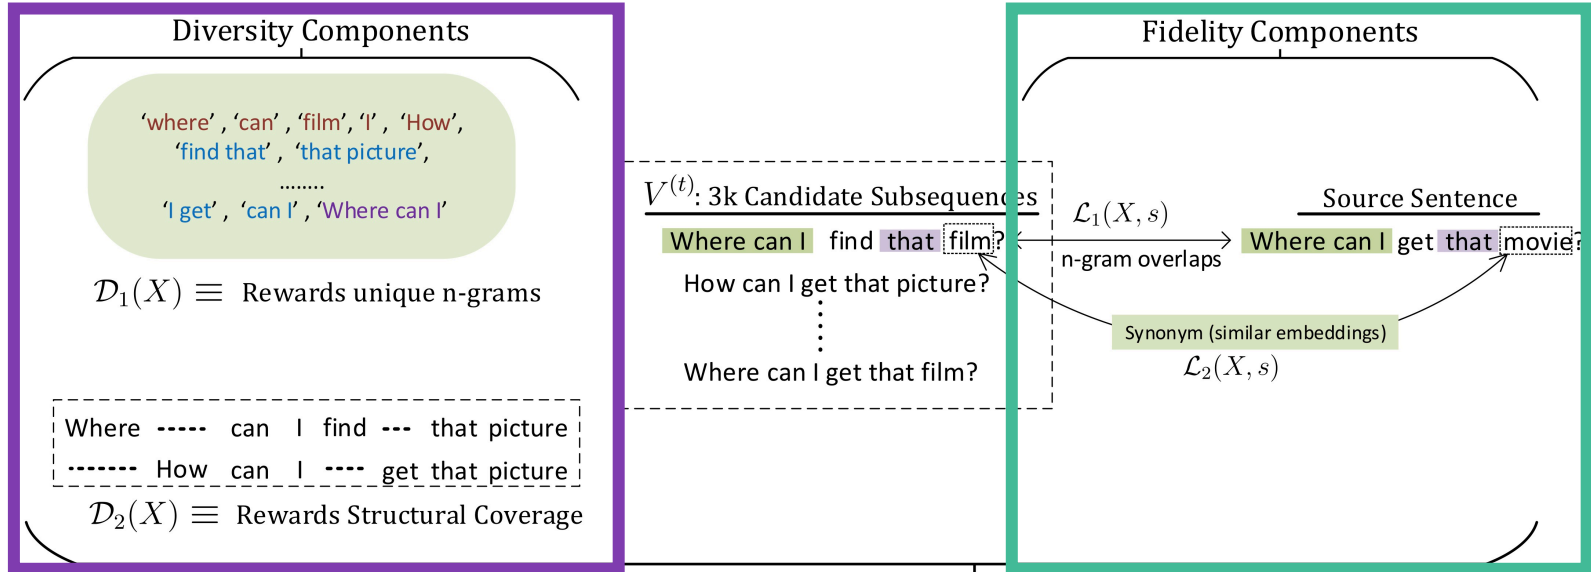
— 元の文と言い換えの単語レベル類似度

劣モジュラ関数の作成② : Diversity

- $\mathcal{F}(X) = \lambda \mathcal{L}(X, s) + (1 - \lambda) \mathcal{D}(X)$
- Diversity : $\mathcal{D}(X) = \mathcal{D}_1(X) + \mathcal{D}_2(X)$
- $\mathcal{D}_1(X) = \mu_3 \sum_{n=1}^N \beta^n \left| \bigcup_{x \in X} x_{n\text{-gram}} \right|$
 - 部分集合 X での N -grams の異なり度合い
- $\mathcal{D}_2(X) = \mu_4 \sum_{x_i \in V^{(t)}} \sum_{x_j \in X} \left(1 - \frac{\text{EditDistance}(x_i, x_j)}{|x_i| + |x_j|} \right)$
 - 部分集合 X での編集距離

提案手法

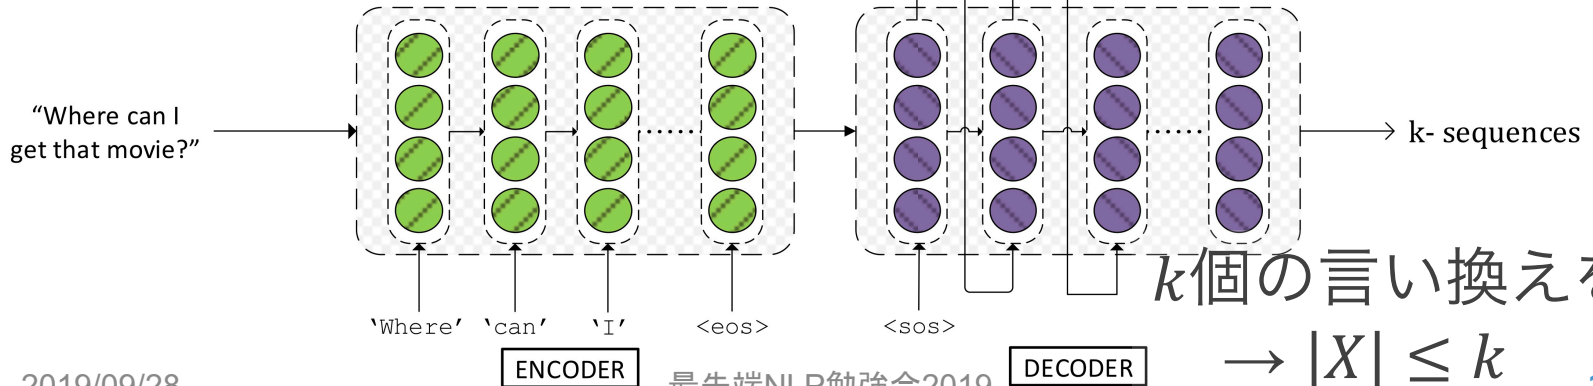
$$\mathcal{F}(X) = (1 - \lambda)\mathcal{D}(X) + \lambda\mathcal{L}(X, s)$$



Diversity

$$\operatorname{argmax}_{X \subset V^{(t)}} \mathcal{F}(X)$$

Fidelity



k個の言い換えを得る
→ $|X| \leq k$

検証

- 1. 言い換え文のQualityは良いか？
 - Fidelityを損なうことなくDiversityを向上させられるか
- 2. Data Augmentationとして有効か？
 - 2つのタスクで検証
 - Intent-Classification
 - Question Classification

検証① 言い換えのQuality : Diversity

- 評価指標 : N-distinct
- Dataset :
 - Quora-question pair dataset
 - Twitter URL paraphrasing dataset

Model	Quora-Div			
	1-distinct	2-distinct	3-distinct	4-distinct
SBS	12.8	24.8	35.3	46.6
VAE-SVG (Gupta et al., 2018)	15.8	22.5	27.6	31.8
DBS (Vijayakumar et al., 2018)	17.9	33.7	44.8	54.9
DPP	17.1	34.4	49.1	62.6
SSR	16.6	32.8	47.1	60.7
DiPS (Ours)	18.1	37.2	52.3	65.3

従来よりも多様性のある文を生成

検証① 言い換えのQuality : Fidelity

- 評価指標 : BLUE, METEOR, TER-plus
- Dataset :
 - Quora-question pair dataset
 - Twitter URL paraphrasing dataset

Model	Quora-Div		
	BLEU↑	METEOR↑	TERp↓
SBS	33.1	28.2	55.6
DBS (Vijayakumar et al., 2018)	30.9	28.3	57.5
VAE-SVG (Gupta et al., 2018)	33.4	25.6	63.2
RbM (Li et al., 2018)	29.4	29.5	62.5
DPP	30.5	27.9	57.3
SSR	28.7	26.8	58.7
DiPS (Ours)	35.1	29.7	53.2

Fidelityを損なわずに文を生成

検証②Data Augmentation:

- Transfer Learningで分類問題のData Augmentationとして使用
 - 言い換え文生成モデルはQuora-Div question pairsで学習
- Intent-classification : YahooL31, SNIPS
- Question Classification : TREC

Model	LogRegDA			LSTM		
	YahooL31	TREC	SNIPS	YahooL31	TREC	SNIPS
NoAug	62.7	82.2	93.4	64.8	94.2	94.7
SBS	63.6	84.6	93.8	65.4	94.4	94.7
DBS	63.3	84.2	94.1	65.6	95.2	96.1
SynRep	63.7	85.2	93.9	65.3	93.6	95.5
ContAug	63.8	86.0	95.3	66.3	95.8	96.4
DiPS(Ours)	64.9	86.6	96.0	66.7	96.4	97.1

Data Augmentationにより精度向上

まとめ

- 言い換え文のクオリティに重要なFidelityとDiversityについて劣モジュラ関数最大化として定式化
- 従来の手法よりも高品質な言い換え文を生成
- Data-AugmentationによりIntent-ClassificationとQuestion Classificationで有用性が示された
- Codeも公開済み：
 - <https://github.com/mallabiisc/DiPS>

感想

- 近似しているにも関わらずdecodeに時間がかかりそう
- Data Augmentationで有効であるかはTransfer Learning次第？
 - 今回の実験設定ではIntent-classificationとQuestion-classificationにquestionが含まれているため、question pairsで学習したのが上手くいった