

# 敵対性学習を用いたニューラル機械翻訳

白井 圭佑<sup>†</sup> 二宮 崇<sup>††</sup> 森 信介<sup>†††</sup>

<sup>†</sup> 愛媛大学 工学部 情報工学科

<sup>††</sup> 愛媛大学 大学院理工学研究科 電子情報工学専攻

<sup>†††</sup> 京都大学 学術情報メディアセンター

{shirai@ai, ninomiya@}cs.ehime-u.ac.jp

forest@i.cs.ehime-u.ac.jp

## 1 はじめに

機械翻訳の研究分野では、ルールベース機械翻訳、用例ベース機械翻訳、フレーズベース統計的機械翻訳、統計的同期文法など様々な手法が提案されてきたが、近年ではニューラルネットを用いたニューラル機械翻訳 (Neural Machine Translation; NMT)[1][2] が、従来手法を上回る高い精度を実現し注目を集めている。ニューラル機械翻訳モデルの中でも、入力系列 (原言語文) を全て1つのベクトルにエンコードしてから出力系列 (翻訳先言語文) を生成する Encoder-Decoder モデル [3][2] や、入力系列をエンコードする過程において生成された過去の内部状態に重み付けをして翻訳を行う注意型ニューラル機械翻訳 (Attention NMT; ANMT)[4][5] の研究が特に盛んに行われている。

本稿は、敵対性生成モデル (Generative Adversarial Nets; GAN)[6][7][8] を ANMT に応用した新しい機械翻訳モデルを提案する。GAN は、画像生成の分野において近年注目を集めている画像生成モデルの一つであり、画像を生成する生成モデル (Generator) と、その画像が生成モデルによって作られたのかどうかを判別する識別モデル (Discriminator) を用い、これらの2つのモデルが競い合うように学習を行うことで、より良い生成モデルを学習する手法である。識別モデルは与えられた画像が生成モデルから作られた画像か、データセット中に存在する本物の画像かを正しく見分けるように学習を行い、生成モデルは識別モデルが判別を誤るように学習を行う。本研究では、従来の ANMT の構造を GAN における生成モデルだと捉え、これに新たに識別モデルを追加する。識別モデルは ANMT が入力系列から予測した出力系列と、入力系列に対応する正解データを正しく見分けるように学習を行い、ANMT は従来の学習に加え、識別モデルが判別を誤るように学習を行う。

## 2 ニューラル機械翻訳

### 2.1 Encoder-Decoder モデル

Encoder-Decoder モデルでは、入力系列  $x = x_1x_2\dots x_n$  を受け取り中間表現を生成する Encoder、Encoder から受け取った中間表現から出力系列  $y = y_1y_2\dots y_m$  を生成する Decoder をそれぞれニューラルネットによって実現する。Encoder-Decoder モデルの学習では、下式を用いて入力系列が与えられたときの出力系列の対数尤度を最大化するように学習を行う。

$$\log p(\mathbf{y}|\mathbf{x}) = \sum_{i=1}^m \log p(y_i|y_{j<i}, \mathbf{x}) \quad (1)$$

Encoder, Decoder には時系列データを解析するために LSTM を用いる。全ての入力系列を受け取った後の Encoder 側 LSTM の内部状態を Decoder 側 LSTM の初期内部状態とする。

### 2.2 注意型ニューラル機械翻訳 (ANMT)

注意型ニューラル機械翻訳 (ANMT) は、Encoder-Decoder モデルにおける出力系列の予測時の各ステップにおいて、エンコード時の全てのステップにおける LSTM の内部状態  $\mathbf{h}_s = (h_{s_1}, h_{s_2}, \dots, h_{s_n})$  を参照して出力単語を予測するモデルである。ANMT においては、 $\mathbf{h}_s = (h_{s_1}, h_{s_2}, \dots, h_{s_n})$  に対する重み  $\alpha_i$  を、デコード時のステップ  $i$  における Decoder 側の LSTM の内部状態  $h_{t_i}$  を用いて計算する。ここで、Encoder あるいは Decoder を多層 LSTM によって実現している場合、LSTM の内部状態とは最上位層の LSTM の内部状態を指す。

Luong ら [5] が提案した Global Attention の手法では、デコード時のステップ  $i$  における Decoder 側の隠

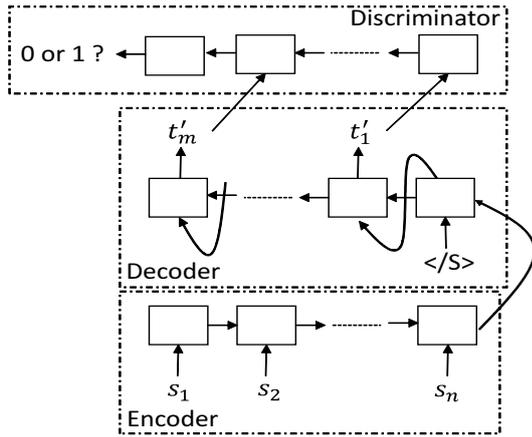


図 1: 提案手法のモデル

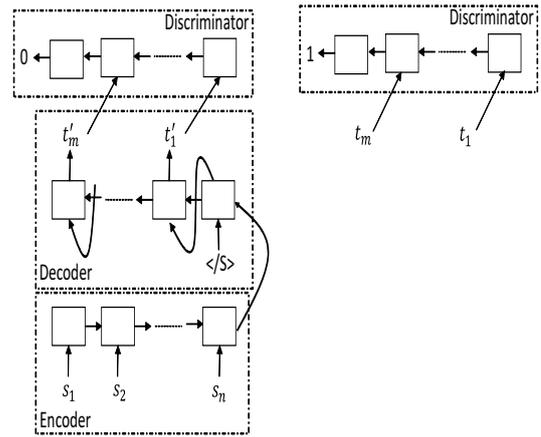


図 2: 識別モデルの学習

れ状態  $h_{t_i}$  と Encoder 側の全ての内部状態  $h_s$  に対する重み  $\alpha_i$  を

$$\alpha_{t_i}(s_j) = \frac{\exp(\text{score}(h_{t_i}, h_{s_j}))}{\sum_{s_k} \exp(\text{score}(h_{t_i}, h_{s_k}))} \quad (2)$$

で計算する .

### 3 ニューラル機械翻訳における敵対性学習

#### 3.1 敵対性生成モデル (GAN) [6]

敵対性生成モデル (GAN) の生成モデルにおいては、ある確率分布  $p_z$  からサンプリングしたサンプル  $z = (z_1, z_2, \dots, z_n)$  を入力として受け取り、画像  $G(z)$  を生成する . 生成モデル  $G$  は識別モデル  $D$  が本物と間違えるような画像を生成することが目的であり、その目的関数は以下のように表される .

$$\min_G \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (3)$$

識別モデルは生成モデルから生成された系列と正解データの系列を正しく見分けることが目的であるため、その目的関数は以下のように表される .

$$\max_D \mathbb{E}_{x \sim p_{data}(x)} [\log(D(x))] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (4)$$

敵対性生成モデルでは 2 つのモデルに関して下式で最適化を行う .

$$\min_G \max_D \mathbb{E}_{x \sim p_{data}(x)} [\log(D(x))] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (5)$$

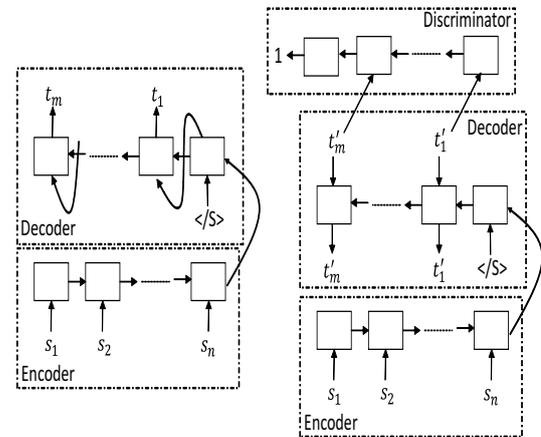


図 3: ANMT の学習

しかし、学習の初期段階では生成モデルは正確な画像を生成出来ず、正解データとは明らかに異なるため、識別モデルは高い確率で正しい判別をすることができる . その場合、式 (3) では生成モデルを最適化するための十分な勾配を得ることが出来ない . そこで実際には、生成モデルの目的関数として下式を用いる .

$$\max_G \mathbb{E}_{z \sim p_z(z)} [\log D(G(z))] \quad (6)$$

#### 3.2 提案手法

画像生成における GAN では、識別モデルは全結合層や畳込みニューラルネットワーク (Convolutional Neural Network; CNN) で実現される . 提案手法では識別モデルに入力として画像ではなく文字列を与えるため、時系列モデルである再帰型ニューラルネット

ワークの一種である LSTM を用いて識別モデルを実現する。

提案モデルの全体像を図 1 に示す。提案モデルは翻訳の生成を行う ANMT と識別モデルから成り、入力として原言語の系列データ  $s_1 \dots s_n$  を Encoder に与え、Decoder は翻訳先言語の系列データ  $t'_1 \dots t'_m$  を生成し、識別モデルは系列データ  $t'_1 \dots t'_m$  を受け取り、その入力が正解データか生成されたデータか識別する。

識別モデルは入力として翻訳先言語の系列データを受け取り、それが入力系列と対の正解データ  $t_1 \dots t_m$  なら 1 を、ANMT が入力系列から予測した出力系列  $t'_1 \dots t'_m$  であれば 0 を返すように学習する (図 2)。ANMT の学習は入力系列と対になる正解データを用いた学習 (図 3 左) と識別モデルを用いた学習 (図 3 右) から成る。識別モデルを用いた学習では ANMT が生成した出力系列を識別モデルが本物と間違えるように ANMT の学習を行う。つまり、識別モデルの出力を 1 として ANMT の学習を行う。

ANMT では語彙の生成に softmax を用いるが、全ての語彙に対するノードをもつネットワークを学習することは、非常に大きな計算コストを要する。そのため本研究では正解データを用いた ANMT の学習には softmax を用い、識別モデルを用いた学習には ANMT により選択された語彙に対してのみ、次式で計算した sigmoid 関数を用いて近似的にスコアを計算する。

$$\sigma(t_i) = \frac{1}{1 + e^{-score(t_i)}} \quad (7)$$

ただし、 $score(t_i)$  はデコード時のステップ  $i$  において単語を予測したときのスコアである。

ミニバッチ内で次の手順を行うことで提案モデルのパラメータ最適化を行う。

- (i) ANMT の学習 式 1 に従って、入力系列から生成した出力系列の対数尤度を最大化するように学習する (図 3 左)。
- (ii) 識別モデルの学習 次に、式 4 に従って、生成された出力系列と正解データの系列を正しく識別する期待値を最大化するように学習する (図 2)。
- (iii) 識別モデルを通した ANMT の学習 最後に、生成した出力系列を識別モデルが本物と間違える期待値を最大化するように学習する (図 3 右)。

## 4 実験

### 4.1 実験設定

#### 4.1.1 対訳コーパス

本実験においては、英日の対訳コーパスとして Asian Scientific Paper Excerpt Corpus (ASPEC)<sup>1</sup> を用いて英日翻訳を行った。コーパスに対する処理としては、和文に対しては京都テキスト解析ツールキット (KyTea)<sup>2</sup> を、英文に対しては mosesdecoder<sup>3</sup> を用いて単語分割を行った後、mosesdecoder を用いて小文字化を行った。また、長さが 1 未満あるいは 50 以上の文を取り除いた。学習用データとしては 100 万文対 (train-1.txt) に上記の処理を行い、上位 50,000 文対を抽出し用いたところ、英語、日本語の語彙は文末記号と未知語のシンボルを含めてそれぞれ 16,416 語、15,051 語であった。開発データと評価データに対しても上記の処理を行った結果、それぞれ 1,658 文対、1,812 文対であった。

#### 4.1.2 ANMT と識別モデル

ANMT としては、Encoder、Decoder がそれぞれ 4 層の LSTM から成る Encoder-Decoder モデルを用いた。注意型のモデルは Luong ら [5] による “Global Attention(dot)” を採用した。また、識別モデルも同様に 4 層の LSTM を用いた。単語埋め込み層、隠れ層の大きさはともに 256 次元とし、LSTM のパラメータは  $[-0.8, 0.8]$  の一様乱数で初期化した。学習には Adam[9] を使用し、パラメータの初期状態は “ $\alpha = 0.01, \beta_1 = 0.9, \beta_2 = 0.999$ ”，ミニバッチサイズは 64 とした。また、本実験でのモデルは全て Chainer[10] を用いて実装した。

### 4.2 結果

英日翻訳の学習を上記の設定で、従来手法 (ANMT) と提案手法 (ANMT + Discriminator) で実験を行った。最終的なモデルとしては各エポック終了後に、開発データに対して計算したパープレキシティが最も低かったものを採用した。

評価データに対して beam 幅 5 の beam search を行い BLEU と RIBES で評価したところ、その結果は表 1 に示す通りになった。

<sup>1</sup><http://lotus.kuee.kyoto-u.ac.jp/ASPEC/>

<sup>2</sup><http://www.phontron.com/kytea/index-ja.html>

<sup>3</sup><https://github.com/moses-smt/mosesdecoder>

表 1: 50,000 文対での学習結果

	BLEU (%)	RIBES
従来手法 (ANMT)	15.86	0.6854
提案手法 (ANMT + Dis)	17.24	0.7036

表 1 より, 提案手法のモデルでは BLEU, RIBES 共に従来手法の ANMT と比較して高い値が得られた.

## 5 おわりに

本研究は, 従来手法である ANMT に GAN の学習方法を取り入れた機械翻訳のモデルを提案した. 本稿で行った実験より従来手法 (ANMT) に対する提案手法の有効性を示すことができた.

今後は, 本稿の実験で用いていない ASPEC の残りの文対を用いて実験を行い, 従来手法と提案手法との比較を行う.

## 謝辞

本研究は JSPS 科研費 25280084, 26540190 の助成を受けたものである. また, PFI の海野氏に Chainer の誤差逆伝搬に関する助言を頂いた. ここに合わせて謝意を表する.

## 参考文献

- [1] Kalchbrenner, N. and Blunsom, P.: Recurrent Continuous Translation Models., *EMNLP*, Vol. 3, No. 39, p. 413 (2013).
- [2] Sutskever, I., Vinyals, O. and Le, Q. V.: Sequence to sequence learning with neural networks, *Advances in neural information processing systems*, pp. 3104–3112 (2014).
- [3] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. and Bengio, Y.: Learning phrase representations using RNN encoder-decoder for statistical machine translation, *arXiv preprint arXiv:1406.1078* (2014).
- [4] Bahdanau, D., Cho, K. and Bengio, Y.: Neural machine translation by jointly learning to align and translate, *arXiv preprint arXiv:1409.0473* (2014).
- [5] Luong, M.-T., Pham, H. and Manning, C. D.: Effective approaches to attention-based neural machine translation, *arXiv preprint arXiv:1508.04025* (2015).
- [6] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y.: Generative adversarial nets, *Advances in Neural Information Processing Systems*, pp. 2672–2680 (2014).
- [7] Radford, A., Metz, L. and Chintala, S.: Unsupervised representation learning with deep convolutional generative adversarial networks, *arXiv preprint arXiv:1511.06434* (2015).
- [8] Mirza, M. and Osindero, S.: Conditional generative adversarial nets, *arXiv preprint arXiv:1411.1784* (2014).
- [9] Kingma, D. and Ba, J.: Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980* (2014).
- [10] Tokui, S., Oono, K., Hido, S. and Clayton, J.: Chainer: a next-generation open source framework for deep learning, *Proceedings of Workshop on Machine Learning Systems (LearningSys) in The Twenty-ninth Annual Conference on Neural Information Processing Systems (NIPS)* (2015).