

# Scheduled Sampling for Sequence Prediction with Recurrent Neural Networks

Bengio, S., Vinyals, O., Jaitly, N., & Shazeer, N. (2015). In NIPS.

2015/10/29

D1 金子 貴輝

# 選考理由

- NIPS 2015の論文
- Seq2seq, カリキュラム学習に関する
- シンプルなアイデア

# 内容


- 概要
- 導入
- 提案手法
- 関連研究
- 実験
  - 画像キャプションング
  - 構文解析
  - 音声認識
- 結論

# 概要


- トークン系列を生成するためにRNNが使用されている  
(機械翻訳や画像キャプション生成)
- 学習時には過去のトークンと隠れ状態から次のトークンを生成する尤度を最大化する
- 一方, 推論時は過去の不明なトークンは生成されたトークンで置き換える
- この違いは生成される系列に沿ってすぐに溜まっていく誤差を生み出す
- 完全ガイドから少ないガイドへ変化していくカリキュラム学習で大きな改善があった
- MSCOCO image captioning challenge2015で優勝

# 導入

## 学習



## テスト




カリキュラム学習で、段々とテスト時に近い問題にしていく

# 提案手法:カリキュラム学習

## スケジュールドサンプリング


- モデルからの出力を使うか, 目標を使うかを確率 $\epsilon$ で決める,
- 確率はミニバッチ中で一律とする



# 提案手法：詳細

選択率 $\varepsilon$ を3種類のグラフに従って減衰させる

- 線形減衰
- 指数減衰
- 逆シグモイド減衰



モデル

出力は隠れ層にsoftmaxレイヤを載せたもの  
系列長を決定するために<EOS>トークンを追加する

訓練

最尤法をミニバッチSGDで解く

目標の代わりに出力値からの逆伝播は今回行わなかった

# 関連研究

|                    | タスク         | 特色                                |
|--------------------|-------------|-----------------------------------|
| 提案手法               | 系列出力の教師あり学習 | オンラインである                          |
| SEARN[9]           | 強化学習        | メタアルゴリズムであり<br>バッチ法               |
| 構文解析に関する<br>手法[12] | 構文解析        | ビームサーチを使い推論<br>RNNへの適用は難しい        |
| 構文解析に関する<br>手法[13] | 構文解析        | モデルがパーセプトロン<br>選択率 $\epsilon$ が固定 |

[9]:H. Daume III, J. Langford, and D. Marcu. Search-based structured prediction as classification. Machine Learning Journal, 2009.

[12]:M. Collins and B. Roark. Incremental parsing with the perceptron algorithm. In Proceedings of the Association for Computational Linguistics, ACL, 2004.

[13]:Y. Goldberg and J. Nivre. A dynamic oracle for arc-eager dependency parsing. In Proceedings of COLING, 2012



# 実験：画像キャプションニング

- 目的
  - 提案手法の効果を実験的に検証する
- 環境
  - 画像キャプションニングタスクは、再帰構造と単純なデコーダ構造で解かれることが多い
  - キャプションは様々で評価法は確定していない
    - 人間の評価に相関する幾つかの基準があり、MSCOCOチームによって公開されている
  - MSCOCOデータセットで75000枚の画像の訓練データ, 5000枚のテストデータ
  - 1画像につき5つの異なるキャプション
    - 訓練時はランダムに一つ選ぶ
    - 評価時は良いのを選ぶ



The man at bat readies to swing at the pitch while the umpire looks on.



A large bus sitting next to a very tall building.

# 実験：画像キャプションング

- アルゴリズム

- 画像特徴は事前学習した畳込みNN, RNNの初期ワードとして入力される
- RNNはLSTMで512unit, 入力ワードは512次元の埋め込み
- 入力ワードの辞書は8857ページ
- $\epsilon$ は逆シグモイド関数で減衰
- Baselineは現在の最先端手法の再現
- Always Samplingは目標値での教示を全て出力値で置き換え
- Uniform Samplingは目標値での教示をランダムな値で置き換え

- 結果

- dropoutは悪くなる場合もあるが, 提案手法は頑健で全ての基準で向上
- MSCOCO2015優勝

| Approach vs Metric                                                                                     | BLEU-4      | METEOR      | CIDER       |
|--------------------------------------------------------------------------------------------------------|-------------|-------------|-------------|
| Baseline                                                                                               | 28.8        | 24.2        | 89.5        |
| Baseline with Dropout                                                                                  | 28.1        | 23.9        | 87.0        |
| Always Sampling                                                                                        | 11.2        | 15.7        | 49.7        |
|  Scheduled Sampling | <b>30.6</b> | <b>24.3</b> | <b>92.1</b> |
| Uniform Scheduled Sampling                                                                             | 29.2        | 24.2        | 90.9        |
| Baseline ensemble of 10                                                                                | 30.7        | 25.1        | 95.7        |
| Scheduled Sampling ensemble of 5                                                                       | <b>32.3</b> | <b>25.4</b> | <b>98.7</b> |

# 実験：構文解析

- 目的
  - 画像キャプションングに比べ決定的なタスクで、提案手法を評価する
- 環境
  - Constituency Parsingと呼ばれる
  - 構文木を木を構成する線形の「操作」列にすることで、系列出力の枠組みで扱える
  - WSJ 22 development setでのF1スコアを評価
- アルゴリズム
  - LSTM, 512unit, 512入力ベクトル, [22]と同様の注意メカニズム使用
    - 一部の入力に注目するために対応するLSTMセルにsoftmaxを掛けるらしい
  - 入力ワード辞書は90000ページ, 出力辞書は木のための128シンボル
  - $\epsilon$ は逆シグモイドで減衰
- 結果
  - dropoutより効いている
  - 訓練データは40000個だけなので過学習のせいもある
    - 訓練・テスト間のギャップを埋めたことによるかは不明
  - always samplingは悪すぎて有効な木にならなかった

| Approach                        | F1           |
|---------------------------------|--------------|
| Baseline LSTM                   | 86.54        |
| Baseline LSTM with Dropout      | 87.0         |
| Always Sampling                 | -            |
| Scheduled Sampling              | <b>88.08</b> |
| Scheduled Sampling with Dropout | <b>88.68</b> |

[22]: D. Bahdanau, K. Cho, and Y. Bengio. Neural machine translation by jointly learning to align and translate. In International Conference on Learning Representations, ICLR, 2015.

# 実験：音声認識

- 目的
  - 入出力が並列する系列で提案手法を評価する
- 環境
  - 入力はlog Mel filter bank spectraで表現される音響特徴で、出力はその時に対応するHMM状態ラベル
  - HMM状態ラベルはKaldi toolkitのGMM-HMMで生成
  - TIMITコーパスとKaldi toolkitを使って[25]のようにデータ生成
  - 音声特徴は40次元, その1次, 2次時間微分も使用する
  - 180次元の出力をGMM-HMMシステムで作成
  - 訓練, 検証, テストサイズはそれぞれ, 3696, 400, 192個
  - 系列平均長は304フレーム, 検証セットはエポック数とモデルパラメータ決定に使用
  - 10のビーム幅でビームサーチデコードして最適系列を評価してテストを行う,
  - 検証セットで目標のラベルから次のラベルを予測させる評価もする

[25]: N. Jaitly. Exploring Deep Learning Methods for discovering features in speech signals. PhD thesis, University of Toronto, 2014.

# 実験：音声認識

- アルゴリズム

- モデルは、毎時入力と前回の隠れ状態と出力を受け付けるRNN
- 開始状態は0ベクトル、開始出力は特殊トークン
- 2層のLSTM250unitとsoftmaxレイヤのモデル
- baseline(全て目標値), Always Sampling(最後以外は全て出力値)
- 提案手法(3種類, 10epochで減衰した後維持)

- 結果

- baselineはおよそ14epoch後に最小誤差になるのに対し、提案手法はおよそ9epoch後に最小でその後下がる
  - これはサンプリングの逆伝播を省略したせいだろう
- 1ステップ先ではbaselineが、復号では提案手法とAlwaysSamplingが高くなっている
- HMMの状態は前後に関係が強く、そのヒントにbaselineが依存してしまったのでは

| Approach             | $\epsilon_s$ | $\epsilon_e$ | Next Step FER | Decoding FER |
|----------------------|--------------|--------------|---------------|--------------|
| Always Sampling      | 0            | 0            | 34.6          | 35.8         |
| Scheduled Sampling 1 | 0.25         | 0            | 34.3          | <b>34.5</b>  |
| Scheduled Sampling 2 | 0.5          | 0            | 34.1          | 35.0         |
| Scheduled Sampling 3 | 0.9          | 0.5          | 19.8          | 42.0         |
| Baseline LSTM        | 1            | 1            | 15.0          | 46.0         |

# 結論

- RNNでの系列予測では、訓練と推論時の違いが誤差を引き起こしていた
- 目標系列から自身の出力にだんだんと切り替えていくカリキュラム学習を提案
- 幾つかの実験で学習時間を増やさずに精度向上
- 将来の課題は、切り替えた入力からの逆伝播と、より良いサンプリング戦略の探索