

COLING2012 参加報告（その7）

渡邊 陽太郎[†]

1 はじめに

本稿では、2012 年 12 月 8 日～15 日にインド・ムンバイの IIT Bombay にて開催された自然言語処理の国際会議である COLING 2012 (24th International Conference on Computational Linguistics) について報告する。会議の概要については他の参加者から報告があるため、本稿では、筆者が特に関心を持った発表 2 件と、インドの食に関する話題として、会議中に提供された昼食およびバンケットの内容について報告する。

2 Richard Billingsley and James Curran: Improvements to Training an RNN parser

(Billingsley and Curran 2012) は、Socher らによって提案された Deep Learning のフレームワークである、Recurrent Neural Networks (RNN) に基づく構文解析手法 (Socher and Manning 2010) に関して、解析性能のさらなる向上のために、以下の二つの手法を提案している。(1) 構文解析時に使用する句のスコアリング方法に Restricted Boltzmann Machines (RBM) を導入することによって、スコア関数の表現能力を高める。(2) 解析の途中で得られる構文木の質を向上させるため、得られた句の信頼性を与える関数を定義し、CKY Parsing を適用する際にその関数の勾配を葉ノードまで伝播させ、更新されたベクトルを用いて構文解析しなおす。また、RNN のようなボトムアップの構文解析手法と、トップダウンな構文木の解析方法との関連性について、Deep Belief Networks (DBN) (Hinton, Osindero, and Teh 2006) と RNN の二つのモデルを比較・議論している。

RNN による構文解析において、単語の情報は要素が連続値を持つ固定長のベクトルを用いて表現される。また、構文木は子が二つのノードに限定される binarized tree が用いられる。RNN では、単語のベクトルとパラメータとなる行列を用いて句のノードのベクトルを計算することによって、句の特徴量を表現する。この特徴量から計算できるスコアが、最適な binarized tree

[†] 東北大学大学院情報科学研究科, Graduate School of Information Sciences, Tohoku University

の探索に用いられる。まずはじめに、現在の単語 t_i 、その直前の単語 t_{i-1} 、直後の単語 t_{i+1} のベクトルを、 $v_i = \sigma(Y_1 t_{i-1} + Y_2 t_i + Y_3 t_{i+1})$ という式で計算することで、周辺文脈を考慮した単語ベクトルを得る。ここで、行列 Y_1, Y_2, Y_3 は学習されるパラメータ、 σ には、sigmoid 関数、または $\tanh$ が用いられる。句のノードに対応するベクトル p は、その子となる二つのベクトル c_1, c_2 と、それらに隣接する単語のベクトル v_1, v_2 を、パラメータベクトル W_1, W_2, W_3, W_4 から、 $p = \sigma(W_1 c_1 + W_2 c_2 + W_3 v_1 + W_4 v_2)$ という計算によって得られる。それぞれのノード p のスコアは、パラメータ R を用いて、 $s = \sigma(Rp)$ という計算によって得る。

スコアリング関数への RBM の導入 Socher らは、句 p のスコアリングのために、パラメータベクトル W_{score} を導入し、 $s = W_{score}p$ という計算によりスコアを得ていた。それに対して、著者らは、discriminative RBM を導入することによって、スコア関数の表現能力を高める方法を提案している。句 p 、隠れ層 h 、句であるかどうかを判断するクラスラベルに相当するベクトル s を用いて、RBM のエネルギー関数を $E = hMp + hVs$ と定義し、パラメータ M と V の最適化をおこなっている。

ノードの信頼度の伝播によるベクトルの修正 RNN による構文解析では、木の構造が少しでも異なると、得られる親のベクトルは大幅に異なってくる。その場合、ビーム幅の狭い探索では、正しい木を表す句がビームから外れてしまう可能性が出てくる。そこで、正しい句が可能な限り候補に含まれるように、親から子へ句の信頼度を伝播させる方法を提案している。具体的には、構文解析時の各ノードのスコア s_i を計算し、それらの平均 $\hat{s} = \frac{1}{N} \sum_{i=1}^N s_i$ から、句の信頼性 $g_i = \max(0, s_i - \hat{s})$ を計算する。この値から勾配 $kg_i \frac{ds_i}{dp}$ を計算し、葉ノードまで伝達させる。 k は事前に規定されるパラメータである。この勾配の値を葉ノードのベクトルに加えて再度構文解析をおこない、元々の解析結果よりも高いスコアの構文解析結果が得られれば、それを採用する。

評価実験では、Socher らの設定と同様に、15 単語以下の文のみを対象とした実験と、全ての文を対象とした実験の 2 種類を実施している。全ての文を対象とした実験の結果、RNN を用いた場合の F 値 83.95 から、勾配計算によるフィードバックを与えた場合に F 値 84.32(+0.38)、スコア関数に RBN を導入した場合に F 値 84.77(+0.83) と性能が改善したことを報告している。

RNN は構文木をボトムアップに構成するが、これは既存手法の生成モデルによる構文解析アルゴリズムのような、トップダウンの性質を持っていない。著者らは、構文木が root から文の単語を生成するような性質を持たせるため、生成モデルの一つである、DBN を用いた構文解析のモデル化に関して議論している。しかし、著者らは DBN を用いた構文解析手法の実装には至っておらず、Deep Learning でよく用いられている Contrastive Divergence による最適化を用いた DBN による構文解析の実現を、今後の課題としている。

3 Yoav Goldberg and Joakim Nivre: A Dynamic Oracle for Arc-Eager Dependency Parsing

(Goldberg and Nivre 2012) では、遷移ベースの依存構造解析アルゴリズムの一つである Arc-Eager Dependency Parsing (Nivre 2012) の学習時における欠点を改善した、新たな学習方法を提案している。これまでの手法は、正しい依存構造木を導く遷移系列が複数存在する場合に、ある特定の遷移系列のみを正解とみなし (*Static Oracle*)、その他の系列は正解として扱うことができないという問題があった。また、学習時には、正しい遷移系列を用いて学習がおこなわれるため、テスト時に一旦解析ミスが起こると、スタック (Σ)、バッファ (B)、決定された依存構造の集合 (A) から構成される configuration $c = \langle \Sigma, B, A \rangle$ が、学習時には全く出現しないという状況が容易に起こり、これがエラーを引き起こす原因になっていた。

著者らは、これらの問題を、*Dynamic Oracle* という概念を導入することによって解決した。*Dynamic Oracle* は、ある configuration c に対して、ある特定の遷移 t を適用した後に得られる可能な依存構造木の中で、損失 (loss) が最小となる依存構造木の loss の値と、 t を適用する前、つまり c から可能な遷移を適用した後に得られる依存構造木の中で、損失が最小となる依存構造木の loss の値の差によって定義されるコストに基づいて定義される。*Dynamic Oracle* は、 c が与えられた時にコストがゼロになるような遷移 t に対してのみ true を返す関数である。

Dynamic Oracle を用いた学習では、初期状態となる configuration から、一つずつ状態を選択していき、コストがゼロでなくなるような遷移が選択された場合にパラメータが更新される。多様な configuration を学習時に考慮できるよう、学習時の configuration の選択方法として、評価実験では下記の 3 種類の関数を比較している。

CHOOSE_NEXT: *Static Oracle* を学習に用いる。既存手法。

CHOOSE_NEXT_AMB: argmax の遷移 t_p のコストがゼロであれば、 t_p を選択し、そうでなければコストがゼロとなる遷移の中からランダムに一つ選択する。

CHOOSE_NEXT_EXP: argmax の遷移 t_p が正解かどうかに関わらず、90% の確率でその遷移を選択し、10% の確率で CHOOSE_NEXT_AMB を実行する。このように遷移を選択することで、最適でない configuration が、学習時に考慮されることになる。

評価実験では、Penn Treebank, British National Corpus, English Web Treebank, CoNLL-2007 Shared Task データなど、様々なデータを用いて手法の有効性を評価しており、提案手法の一つである CHOOSE_NEXT_EXP では、*Static Oracle* を用いて学習する場合と比較して、高い解析性能が得られたことを報告している。

本手法は、遷移ベースの依存構造解析手法だけでなく、正解の系列が一つに定まらないような一般的な構造予測問題において有用であると考えられる。

4 会議中に提供された食事

会議のランチはビュッフェ形式で提供され、その構成は、ライスまたは炊き込みご飯（プラオ）、豆のカレー（ダル）、野菜のカレー、チャパティ、デザート、サラダ、ピクル等であった。また、バンケットも同様にビュッフェ形式で提供され、数多くのインド料理が提供された。

日程		メニュー
12/8	Lunch	ペンネ (Penne Pasta), ダル・タドゥカ (Dal Tadka), クミンライス (Jeera Rice), ベジタブル・カダイ (Vegetable Kadai), チャパティ (Chapati), ムング豆のハルワ (Moong Dal Halwa), サラダ, ピクル, その他
12/9	Lunch	ベジタブル・プラオ (Vegetable Pulao), ダル・マカニ (Dal Makhani), グリーン・グジャラート (Green Gujarat), チャパティ, チキンのコックローヴァン* (Chicken Coq Au Vin), ウリのハルワ (Doodhi Halwa), サラダ, ピクル, その他
12/10	Lunch	ライス, マハラシュトラ州のダル (Varan, Maharashtra Dal), コールハプール (マハラシュトラ州の町名) の野菜カレー (Veg Kolhapuri), チャパティ, タイチキンカレー*, グラブジャムン (Gulab Jamun), サラダ, ピクル, その他
12/11	Lunch	グリーンピースのプラオ (Pea Pulao), マサラ・ダル (Masala Dal), パニール・カスリメティ・グリーンピースのクリームカレー (Paneer Methi Mutter Malai), チキン・ストロガノフ* (Chicken Stroganoff), ラスグラ (Rasgulla, 粉乳と砂糖のスイーツ), サラダ, ピクル, その他
	Banquet	ヤギとひよこ豆のケバブ* (Shammi Kebab), 骨なしゴマチキン* (Sesame Chicken Finger), パニールの胡椒揚げ (Paneer Pepper Fry), ポテト・グリーンピース・カスリメティのشناック (Aloo Mutter Methi Ki Tikki), グリーンピース・カスリメティ・パニールのカレー (Mutter Paneer Ka Nukta), コールハプールサブジ (Subz Kolhapuri), 3 種の炒め (Three Treasure Stir Fry), ナン・チャパティ, ライス, 5 種類の豆を使ったダル (Dal Panchratan), チキンのブラックペッパーソース* (Chicken Black Pepper Source), バターチキン* (Butter Chicken), その他
12/13	Lunch	ライス, ダル・フライ (Dal Fry), ベジタブル・コルマ (Vegetable Korma), バターチキン*, チャパティ, カラ・ジャムン (Kala Jamun), サラダ, ピクル, その他
12/14	Lunch	ベジタブル・プラオ, マサラ・ダル, ベジタブル・ジャルフレジ (Vegetable Jalfrezi), 人参のハルワ (Gajar Halwa), サラダ, ピクル, その他

表 1 COLING 2012 期間中に提供された食事一覧。*はノン・ベジタリアン向けである。

チュートリアル、本会議期間中のランチ、およびバンケットにて提供された料理を表 1 に示す¹。インドはヒンドゥー教徒が 80% 程度を占めており、彼らの多くはベジタリアンである。このような背景からか、基本的にインドの食事はベジタリアン用、ノン・ベジタリアン用に分けられている。会議中に提供された食事も、肉が含まれるものには *Non Veg* の記載があった。

インド料理の名前は、用いられている食材、食材の形状、グレービー、調理法、地名などの組み合わせで決まる。例えば、Dal Tadka は食材＋調理法の組み合わせで、豆 (Dal) を Tadka (タドゥカ) という方法²で調理したという意味である。グレービーの特徴を表すものとしては、表 1 中では、バターを使う Makhani, スパイスを多く使用する Masala (マサラ), カダイという鍋で作る汁気の少ない Kadai (カダイ), クリーム状の Malai (マライ), 汁気が少なく辛口のジャル

¹ 会議期間中に提供された食事のうち主要なものは記録したが、名前の記載が無かった一部に関しては予測で記載している。ご了承ください。

² 仕上げにテンパリンをおこなう。テンパリングとは、スパイスの香りを油に移して、その香りが移った油をカレーにかけて仕上げる方法。

フレジ (Jalfrezi), ヨーグルトやココナッツミルクを使ったクリーミーなコルマ (Korma) などが該当する。Green Gujarat, Veg Kolhapuri, Maharashtrian Dal は、地名が含まれる名前であるが、これは地域特有の味付けを意味する。例えば、Gujarat 州は甘い味付けが特徴的、Kolhapur は胡椒、新鮮なコリアンダーの葉、トマト、ココナッツを入れるのが特徴的である³。名前に複数の食材を並べることもあり、例えば Paneer Methi Mutter Malai は、牛乳から作られるパニール (Paneer)、フェヌグリークの葉 (Methi)、Mutter (グリーンピース) のマライという意味である。

ランチには、全ての日で豆のカレー (ダル) が含まれていた。ダルとは、ムング豆やレンズ豆などの豆カレーのことを指し、インドでは日常的に食される極めて一般的なものである (日本における味噌汁に相当するものと考えられる)。ベジタリアンにとって、ダルはタンパク質を摂取するための重要な栄養源となる。会議中には、テンパリングで仕上げる Dal Tadka, 通常よりスパイスを多く使用する Masala Dal, バターを使う濃厚な Dal Makhani, 5 種類の豆 (トゥール豆, ムング豆, ウラド豆, ひよこ豆, マスール豆) で作る Dal Panchratan, 地域特有のダルの調理法が用いられた Varan (Maharashtrian Dal) などが提供された。これらの様々なバリエーションを通じて、ダルの魅力を実感することができた。デザートには牛乳を使って作られるハルワ (Halwa), グラブ・ジャムン (Gulab Jamun), ラスグラ (Rasgula) などとも供された。これらは強い甘さが特徴的であるが、多くのスパイスを口にした後に舌をリセットするには最適である。

会議中の食事は殆どが北インド料理に属するものであったが、滞在していたホテルでは南インド料理が提供されていた。南インドは基本的に米が主食で、カレーは水分を多く含み、用いられるスパイスは異なってくる。ダルを使った野菜カレーのサンバル (Sambar), 米粉を発酵させ蒸したパンのイドゥリ (Idli), 豆から作るドーナツのワダ (Vada), 平らな米から作られる軽食ポハ (Poha), インドのお好み焼きウツパム (Uttapam), 味付けのアクセントとなるチャートニなどを口にすることができた。ムンバイは南インドには属さないため地域は異なるものの、インドの地でこれらの料理に触れられたのは、筆者にとって大きな喜びであった。

5 おわりに

COLING 2012 は、インド・ムンバイにおいて 12 月の過ごしやすい時期に開催された。ビザ取得までの道のりの長さ、会議の運営における様々な新しい試み、現地で体験したインドという国の環境や食事などを思い返すと、筆者にとって、これまで参加した国際会議の中で特に印象に残る会議であった。

³<http://www.ecurry.com/blog/indian/curries/gravies/chicken-kolhapuri/>



(a) プラオ, ダル, カダイ (ランチ)

(b) サラダ (ランチ)

(c) バンケット

図1 ランチ, バンケットの様子

参考文献

- Billingsley, R. and Curran, J. (2012). “Improvements to Training an RNN parser.” In *Proceedings of COLING 2012: Technical Papers*, pp. 279–294.
- Goldberg, Y. and Nivre, J. (2012). “A Dynamic Oracle for Arc-Eager Dependency Parsing.” In *Proceedings of COLING 2012: Technical Papers*, pp. 959–976.
- Hinton, G. E., Osindero, S., and Teh, Y.-W. (2006). “A fast learning algorithm for deep belief nets.” In *Neural computation*.
- Nivre, J. (2012). “An Efficient Algorithm for Projective Dependency Parsing.” In *Proceedings of the 8th International Workshop on Parsing Technologies (IWPT)*, pp. 149–160.
- Socher, R. and Manning, C. D. (2010). “Learning Continuous Phrase Representations and Syntactic Parsing with Recursive Neural Networks.” In *Proceedings of Deep Learning and Un-supervised Feature Learning Workshop*, pp. 1–9.

略歴

渡邊 陽太郎 (正会員) : 2004 年信州大学工学部情報工学科卒業. 2007 年奈良先端科学技術大学院大学情報科学研究科博士前期課程修了. 2010 年同大学院大学情報科学研究科博士後期課程修了. 同年より東北大学大学院情報科学研究科助教. 現在に至る. 博士 (工学). 自然言語処理, 主に含意関係認識, 意味解析の研究に従事. ACL, 情報処理学会, 言語処理学会, 人工知能学会各会員.

(2012 年 11 月 30 日依頼)

(2013 年 1 月 24 日受付)