

Compositional Vector Space Models for Knowledge Base Completion

最先端 NLP 勉強会 2015

Saku Sugawara

東京大学相澤研究室

August 29, 2015

Compositional Vector Space Models for Knowledge Base Completion
Arvind Neelakantan, Benjamin Roth, Andrew McCallum
Univ. Massachusetts
ACL2015

要点

- Knowledge Base Completion の論文
- relation の含意関係の合成計算を Reccurent NN で行う
- multi-hop relations(=path) の推論を non-atomically に行う
- 既存手法よりも 7-10%程度高い精度を達成

Overview

- 1 Introduction
- 2 Recurrent Neural Networks for KB Completion
- 3 Zero-shot KB Completion
- 4 Experiments
- 5 Conclusion

Knowledge Base における知識とは

- (Barack Obama, presidentOf, USA)
- (Brad Pitt, marriedTo, Angelina Jolie)

のように、

(entity1, relation, entity2)

の形をしているもの

Knowledge Base Completion

- 既存の知識を使って新しい知識を補完するタスク
- 既存の知識ベースは不完全であり、必要な情報が欠けている
 - 個人の情報の国籍が欠けている
 - ⇒ 出生地や居住地から推測できるのでは？
 - ベンガルトラはしっぽを持つか？
 - ⇒ ベンガルトラはトラ、トラはネコ科、ネコ科は.....
- 必要に応じて推論して補完してあげる必要がある

単純には.....

- relation でグラフを作りパスをたどるだけで新しい知識になる

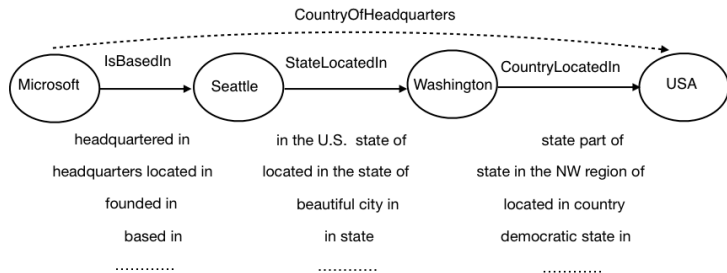


Figure 1: Semantically similar paths connecting entity pair (Microsoft, USA).

- 膨大な数になってしまう

先行研究 1 - Path Ranking Algorithm (PRA)

- Lao et al., 2010-2012
- パスを全列挙せず、
- ランダムウォークで探索して、
- スコア付けして学習（雰囲気です）
⇒ 計算が早くても、結局は特徴の数が多くなってしまふ

先行研究 2 - Vector representations of relations

- (Bordes+, 2013), (Nickel+, 2011), (Socher+, 2013) など
- relation をベクトル表現にして、類似度を測れるようにする
⇒ ただし、推論の一単位が個々の relation のみ
- 行列やテンソルを使ったものもある

先行研究 3 - Cluster PRA

- Gardner et al., 2013-2014
- 訓練済みのベクトル表現を用いる
- しかし relation type のクラスタリングは atomic なパスの特徴で済ませている
 - ⇒ relation type に依存しない汎用的なモデルに到達できない

本研究の貢献

手法として：

- パスである relation のつながりを推論する
- ベクトル表現を用いて一般化
- non-atomically かつ compositionally な推論でさらに一般化

さらに：

- 新しいデータセットを構築 (52 million triples)
<http://iesl.cs.umass.edu/downloads/inferencerules/release.tar.gz>

とのこと

Recurrent Neural Networks for KB Completion

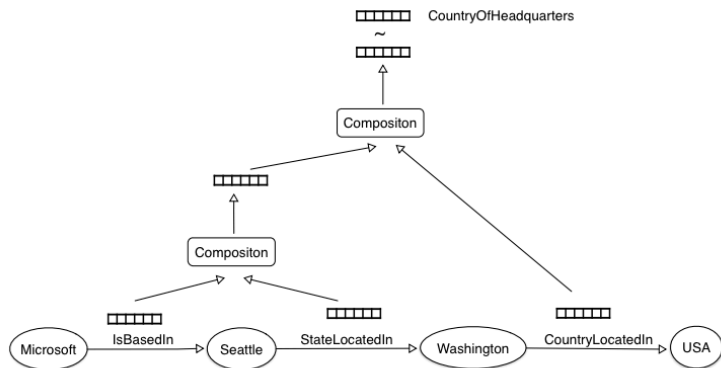


Figure 2: Vector Representations of the paths are computed by applying the composition function recursively.

Composition

relation $\delta = r_1 \rightarrow r_2 \rightarrow \dots \rightarrow r_n$ に対して、次のように計算する

$$v(r_{1\dots i}) = f(W_\delta[v(r_{1\dots i-1}); v(r_i)])$$

- $v(_) \in \mathbb{R}^d$ は relation のベクトル表現
- f はシグモイド関数
- $W_\delta \in \mathbb{R}^{d \times (2d+1)}$ は relation δ の合成行列 (to be trained)
- semicolon = concatenation^{2d} + bias feature

Model Training

ひとつの relation δ に対して、次のパラメータを学習する：

$$\Theta = \{W_\delta, v_r(\omega) \forall \omega \in \Delta\}$$

目的関数は、対数尤度に L2 正則化項を加えて、

$$\Theta^* = \arg \max_{\Theta} \sum_{\lambda=(\gamma,\delta) \in \Lambda_\delta^+} P(y_\lambda = 1; \Theta) + \sum_{\lambda=(\gamma,\delta) \in \Lambda_\delta^-} P(y_\lambda = 0; \Theta) - \rho \|\Theta\|^2$$

ここで、 y_λ は λ が正しいとき 1、そうでないとき 0
AdaGrad (Duchi et al., 2011) で更新

Model Training

また、 λ の確率を表す P は、

$$P(y_\lambda = 1; \Theta) = \text{sigmoid}(v_p(\mu_\lambda) \cdot v_r(\delta))$$

$$P(y_\lambda = 0; \Theta) = 1 - P(y_\lambda = 1; \Theta)$$

$$\text{where } \mu_\lambda = \arg \max_{\pi \in \Phi_\delta(\gamma)} (v_p(\mu_\pi) \cdot v_r(\delta))$$

Φ_δ は、entity pair γ に対して δ に等しいパスの集合 (PRA で与えられる)

Zero-shot KB Completion

- relation vectors を訓練済みのものに固定する
 - from (Riedel et al., 2013)
- 一般化された合成行列のみを学習する
- すなわち、すべての relation を同一の行列で学習

Task

- PRA で重みのないパスを事前に列挙しておく
- 与えられた relation と entity の片割れに対して、適切なパスを推測する
- 欲しい答えが出せれば正解

Data

- ClueWeb dataset(Orr+, 2013) で Freebase の relation を拡張
- entity は Freebase にあるもののみを利用し、entity のペアを含む文章を ClueWeb から抜き出して新しい知識とする
- relation は次のような形式で表現される ;
 - /people/person/place_of_birth
 - /government/pollled_entity/poll_scores
 - /music/artist/genre

Data

Entities	18M
Freebase triples	40M
ClueWeb triples	12M
Relations	25,994
Relation types tested	46
Avg. paths/relation	2.3M
Avg. training facts/relation	6638
Avg. positive test instances/relation	3492
Avg. negative test instances/relation	43,160

Results - example1

Relation: /book/written_work/original_language/ (*book “x” written in language “y”*)

Seen paths:

/book/written_work/previous_in_series → /book/written_work/author → /people/person/nationality → /people/person/nationality⁻¹
→ /people/person/languages

/book/written_work/author → /people/ethnicity/people⁻¹ → /people/ethnicity/languages_spoken

Unseen paths:

“in”⁻¹ - “writer”⁻¹ → /people/person/nationality⁻¹ → /people/person/languages

/book/written_work/author → addresses → /people/person/nationality⁻¹ → /people/person/languages

Relation: /people/person/place_of_birth/ (*person “x” born in place “y”*)

Seen paths:

“was,born,in” → /location/ mailing_address/citytown⁻¹ → /location/ mailing_address/state_province_region

“from” → /location/location/contains⁻¹

Unseen paths:

“born,in” → /location/location/contains → “near”⁻¹

“was,born,in” → commonly_known_as⁻¹

Results - example2

Relation: /geography/river/cities/ (*river “x” flows through or borders “y”*)

Seen paths:

“at” → /location/location/contains⁻¹

“meets,the” → /transportation/bridge/body_of_water_spanned⁻¹ → /location/location/contains⁻¹ → “in”

Unseen paths:

/geography/lake/outflow⁻¹ → /location/location/contains⁻¹

/geography/lake/outflow⁻¹ → /location/location/contains⁻¹ → “near”

Relation: /people/family/members/ (*person “y” part of family “x”*)

Seen paths:

/royalty/monarch/royal_line⁻¹ → /people/person/children → /royalty/monarch/royal_line

→ /royalty/royal_line/monarchs_from_this_line

/royalty/royal_line/monarchs_from_this_line → /people/person/parents⁻¹ → /people/person/parents⁻¹ → /people/person/parents⁻¹

Unseen paths:

/royalty/monarch/royal_line⁻¹ → “leader”⁻¹ → “king” → “was,married,to”⁻¹

“of,the”⁻¹ → “but,also,of” → “married” → “defended”⁻¹

Results - separate RNN

	train with top 1000 paths	train with all paths
Method	MAP	MAP
<i>PRA Classifier</i>	43.46	51.31
<i>Cluster PRA Classifier</i>	46.26	53.23
<i>Composition-Add</i>	40.23	45.37
<i>RNN-random</i>	45.52	56.91
<i>RNN</i>	46.61	56.95
<i>PRA Classifier-b</i>	48.09	58.13
<i>Cluster PRA Classifier-b</i>	48.72	58.02
<i>RNN + PRA Classifier</i>	49.92	58.42
<i>RNN + PRA Classifier-b</i>	51.94	61.17

-b では、PRA で bigram features を用いている

Results - Zero-shot

	train with top 1000 paths	train with all paths
Method	MAP	MAP
RNN	43.82	50.10
zero-shot	19.28	20.61
Random	7.59	

Table 4: Results comparing the zero-shot model with supervised RNN and a random baseline on 10 types. RNN is the fully supervised model described in section 3 while zero-shot is the model described in section 4. The zero-shot model without explicitly training for the target relation types achieves impressive results by performing significantly ($p < 0.05$) better than a random baseline.

問題点と今後

- RNN が、局所的な特徴を保持できていない
 - PRA の bigram features でスコアが上がったのと同じように記憶の保持が要る
- ⇒ memory module の実装
- entity にもベクトル表現を導入し、動詞句の多義性 (polysemy) の問題に取り組む

まとめ (要点)

- relation の含意関係の合成計算を Recurrent NN で行う
- multi-hop relations(=path) の推論を non-atomically に行う
- 既存手法よりも 7-10%程度高い精度を達成