

# Word Embedding and WordNet Based Metaphor Identification and Interpretation

(Mao et al., 2018)

Rebecca Wilm

PS/HS Figurative Language Resolution  
Institut für Computerlinguistik  
Neuphilologische Fakultät  
Ruprecht-Karls-Universität Heidelberg

June 26, 2019

# Gliederung

1. Hauptbeiträge
2. Ansatz
3. Experimente
  - ▶ Evaluation der Metaphernerkenntung
  - ▶ Evaluation der Metapherninterpretation
4. Vor- und Nachteile
5. Automatische Übersetzung englischer metaphorischer Sätze ins Deutsche

# Hauptbeitrag 1: Metaphernererkennung und -interpretation

## 1. Erkennung von Metaphern

- ▶ Beispiel:

  - “black dress”: wörtlich

  - “black humor”: metaphorisch

## 2. Interpretation von Metaphern

- ▶ Beispiel:

  - “to *kill* a process” → “to *terminate* a process”

Mao et al. (2018) machen beides!

## Hauptbeitrag 2: Anwendung auf Machine Translation

- ▶ Metaphern können zu Problemen bei MT führen  
**Beispiel:** Google Übersetzer übersetzt “devour” in “She devoured his novels” auf Chinesisch zu “吞噬” (“herunterschlucken”)
- ▶ Vermutung: das Ersetzen der Metaphern durch wörtliche Paraphrasen könnte helfen
- ▶ Mao et al. (2018) sind die ersten, die diese Vermutung überprüfen

## Hauptbeitrag 3: Metaphernererkennung auf Wortebene

- ▶ typisch: Metaphernererkennung auf Phrasenebene (z.B. Shutova et al., 2016; Rei et al., 2017)
  - ▶ Extraktion von Phrasen aus Sätzen  
Beispiel: “She devoured his novels” → “devour novel”
  - ▶ Erkennen von “Widersprüchen”
- ▶ Probleme:
  - ▶ unklar, welcher Bestandteil metaphorisch ist
  - ▶ ohne Kontext können metaphorische Phrasen wörtlich wirken  
Beispiel:  
“This young man knows how to climb the social ladder”  
→ “climb ladder”
- ▶ Mao et al. (2018) erkennen Metaphern auf Wortebene
  - ▶ anders als Gao et al. (2018): keine Evaluation auf Sequence Labeling Task

# Ansatz

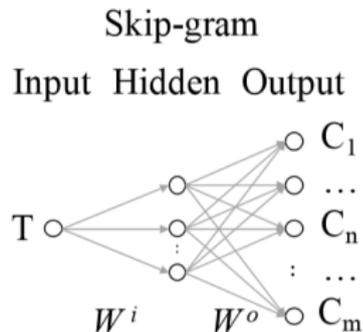
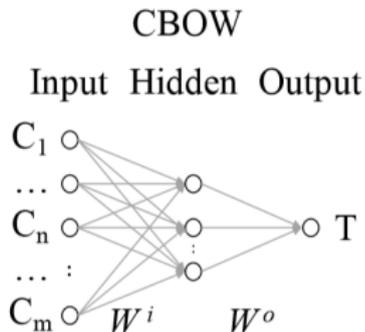
1. Trainieren von Word-Embeddings
2. (a) Trennung des Zielwortes  $w_t$  vom Kontext
  - ▶ *“She devoured his novels”*(b) Extraktion möglicher Bedeutungen des Zielwortes aus WordNet<sup>1</sup>
  - ▶  $W = [“devour”, “destroying”, “enjoyed”, “eats up”, …]$
3. Auffinden des Wortes  $w^*$ , das die wörtliche Bedeutung des Zielwortes im Kontext am besten repräsentiert
  - ▶  $w^* = “enjoyed”$
4. (a) Berechnung der Kosinusähnlichkeit zwischen  $w_t$  und  $w^*$ 
  - ▶  $\cos(“devoured”, “enjoyed”) = ?$(b) Zuweisung eines Labels auf Basis eines Thresholds

---

<sup>1</sup>Fellbaum (1998)

# Schritt 1: Trainieren von Word-Embeddings

- ▶ zwei Varianten<sup>2</sup>:



- ▶ *CBOW*: gegeben Kontext, Wahrscheinlichkeit, ein Zielwort vorauszusagen, maximieren  
"She            his novels"
- ▶ *Skip-gram*: andersherum
- ▶ normalerweise: Verwenden der Input-Vektoren aus  $W^i$ , Verwerfen der Output-Vektoren aus  $W^o$
- ▶ Mao et al. (2018) benutzen beide!

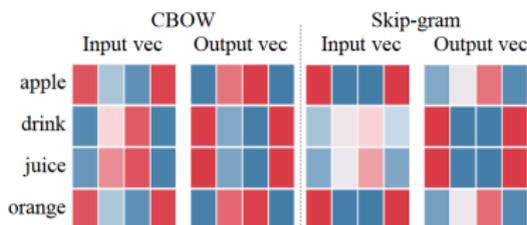
---

<sup>2</sup>Mikolov et al. (2013)

# Warum Input- und Output-Embeddings?

- ▶ die Input-Vektoren von Wörtern, die in ähnlichen Kontexten vorkommen, liegen im Vektorraum nahe beieinander
- ▶ Wörter verschiedener Wortarten kommen in verschiedenen Kontexten vor

→ Problem beim Bestimmen ihrer Ähnlichkeit



- ▶ für häufig kookkurierende Wörter Ähnlichkeit zwischen Input- und Output-Vektoren aussagekräftiger

## Schritt 2

### 1. Trennung des Zielwortes vom Kontext

Beispiel: "She *devoured* his novels"

- ▶ Zielwort:  $w_t = \text{"devoured"}$
- ▶ Kontext:  $\{w_{c1} = \text{"She"}, w_{c2} = \text{"his"}, w_{c3} = \text{"novels"}\}$

### 2. Extraktion möglicher Bedeutungen des Zielwortes aus WordNet

- ▶ die Menge  $W$  der möglichen Bedeutungen enthält:
  - ▶ das Zielwort
  - ▶ alle Synonyme aus WordNet
  - ▶ alle Hyperonyme aus WordNet
  - ▶ alle flektierten Formen dieser Wörter
- ▶  $W = [\text{"devour"}, \text{"destroying"}, \text{"enjoyed"}, \text{"eats up"}, \dots]$

## Schritt 3: Auffinden der passendsten Bedeutung $w^*$

- ▶ Annahme: wörtliche Ausdrücke häufiger als metaphorische

$$w^* = \arg \max_k \text{SIM}(v_k, v_{\text{context}})$$

- ▶  $v_k$ : Vektor eines Kandidaten  $k \in W$
- ▶  $v_{\text{context}}$ : Durchschnitt der Input-Vektoren aller Kontextwörter
  - ▶ Kontextfenster: Satz (bzw. Phrase)

### Experimente mit vier Möglichkeiten für SIM:

$$\text{SIM-CBOW}_I = \cos(v_{k,\text{cbow}}^i, v_{\text{context},\text{cbow}}^i)$$

$$\text{SIM-CBOW}_{I+O} = \cos(v_{k,\text{cbow}}^o, v_{\text{context},\text{cbow}}^i)$$

$$\text{SIM-SG}_I = \cos(v_{k,\text{sg}}^i, v_{\text{context},\text{sg}}^i)$$

$$\text{SIM-SG}_{I+O} = \cos(v_{k,\text{sg}}^o, v_{\text{context},\text{sg}}^i)$$

## Schritt 4: Zuweisung eines Labels

$$S = \cos(v_{w^*}^i, v_{w_t}^i) \begin{cases} \text{wörtlich, falls } S > \textit{Threshold} \\ \text{metaphorisch, sonst} \end{cases}$$

- ▶ hier wird die lemmatisierte Form verwendet

# Experimente auf Satzebene

- ▶ Daten:
  - ▶ jeweils 212 wörtliche und metaphorische Sätze aus dem Datenset von Mohammad et al. (2016)
  - ▶ jeweils 12 Sätze als Development Set
- ▶ empirisch bestimmter Threshold: 0.6
- ▶ Experimente mit anderen Thresholds auf beiden Ebenen
  - ▶ F1 stabil für Threshold zwischen 0.5 und 0.9
- ▶ Baseline: Context2Vec<sup>3</sup>
  - ▶ nicht für Metaphernverarbeitung konzipiert  
→ Einbettung ins Modell (Schritte 3 und 4)
  - ▶ Voraussagen eines Wortes gegeben Kontext mithilfe eines bidirektionalen LSTM
  - ▶ in Schritt 3:  $SIM = \cos(\text{Zielwortvektor}, \text{Kontextvektor})$

---

<sup>3</sup>Melamud et al. (2016)

## Ergebnisse auf Satzebene

Method	Precision	Recall	F1
<i>Context2Vec</i>	0.60	0.80	0.69
<i>SIM-SG<sub>I</sub></i>	0.56	<b>0.95</b>	0.70
<i>SIM-SG<sub>I+O</sub></i>	0.62	0.89	0.73
<i>SIM-CBOW<sub>I</sub></i>	0.59	0.91	0.72
<i>SIM-CBOW<sub>I+O</sub></i>	<b>0.66</b>	0.88	<b>0.75*</b>

- ▶ alle Modelle sind besser als die Baseline
- ▶ Kombination von Input- und Output-Vektoren hilfreich
- ▶ CBOW: bessere Precision; SG: besserer Recall

# Experimente auf Phrasenebene

- ▶ Daten:
  - ▶ 316 metaphorische und 331 wörtliche Phrasen aus dem Datenset von Mohammad et al. (2016)<sup>4</sup>
  - ▶ jeweils 40 Phrasen als Development Set
- ▶ Baselines:
  - ▶ Shutova et al. (2016)
  - ▶ Rei et al. (2017)

---

<sup>4</sup>extrahiert von Shutova et al. (2016)

## Ergebnisse auf Phrasenebene

Methode	Precision	Recall	F1
<i>Shutova et al. (2016)</i>	0.67	0.76	0.71
<i>Rei et al. (2017)</i>	<b>0.74</b>	0.76	<b>0.74</b>
<i>SIM-CBOW<sub>I+O</sub></i>	0.66	0.78	0.72
<i>SIM-SG<sub>I+O</sub></i>	0.68	<b>0.82</b>	<b>0.74*</b>

- ▶ *SIM-SG<sub>I+O</sub>* hier besser als *SIM-CBOW<sub>I+O</sub>*
  - ▶ SG besser bei wenig Kontext
- ▶ der unüberwachte Ansatz von Shutova et al. (2016) wird übertroffen
- ▶ gleicher F1 wie die überwachte Methode von Rei et al. (2017)

# Interpretation von Metaphern für MT

- ▶ Datengrundlage: 100 Sätze

	$\hat{y}=m$	$\hat{y}=w$	gesamt
$y=m$	42	8	50
$y=w$	19	31	50
gesamt	61	39	100

- ▶ Übersetzung ins Chinesische
- ▶ für  $\hat{y}=w$ : Übersetzung des Originals durch Google und Bing
- ▶ für  $\hat{y}=m$ :

Original  
SIM-CBOW<sub>I+O</sub> → Google  
Context2Vec

Original  
SIM-CBOW<sub>I+O</sub> → Bing  
Context2Vec

# Fragebogen

- ▶ Beantwortung eines Fragebogens durch 5 Chinesisch-Muttersprachler\*innen

Sample Questionnaire	
The ex-boxer's job is to <b>bounce</b> people who want to enter this private club.	
bounce: eject from the premises	
Good / Bad	
1. 前拳击手的工作是 <b>反弹</b> 人谁想要进入这个私人俱乐部。	<input type="checkbox"/> <input type="checkbox"/>
2. 前拳击手的工作是让想要进入这个私人俱乐部的人 <b>弹跳</b> 。	<input type="checkbox"/> <input type="checkbox"/>
3. 前拳击手的工作是 <b>拒绝</b> 谁想要进入这个私人俱乐部的人。	<input type="checkbox"/> <input type="checkbox"/>
4. 前拳击手的工作是 <b>拒绝</b> 那些想进入这个私人俱乐部的人。	<input type="checkbox"/> <input type="checkbox"/>
5. 前拳击手的工作是 <b>打人</b> 谁想要进入这个私人俱乐部。	<input type="checkbox"/> <input type="checkbox"/>
6. 前拳击手的工作是 <b>打击</b> 那些想进入这个私人俱乐部的人。	<input type="checkbox"/> <input type="checkbox"/>

- ▶ das mehrheitlich annotierte Label wird ausgewählt

# Ergebnisse

		Acc-m	Acc-w	Acc-ges
Google	<i>Original</i>	0.34	<b>0.68</b>	0.51
	<i>Context2Vec</i>	0.50	0.66	0.58
	<i>SIM-CBOW<sub>I+O</sub></i>	<b>0.60</b>	0.64	<b>0.62</b>
Bing	<i>Original</i>	0.42	<b>0.70</b>	0.56
	<i>Context2Vec</i>	0.60	0.66	0.63
	<i>SIM-CBOW<sub>I+O</sub></i>	<b>0.66</b>	0.64	<b>0.65</b>

- ▶ insgesamt Verbesserung durch Paraphrasieren von Metaphern
  - ▶ für metaphorische Klasse dramatische Verbesserung
  - ▶ für wörtliche Klasse leichte Verschlechterung wegen falscher Zuordnungen

# Vorteile

- ▶ auf Phrasenebene so gut wie Rei et al. (2017) trotz Unüberwachtheit
  - ▶ keine Trainingsdaten nötig
  - ▶ schneller
- ▶ Metaphernererkennung auch auf Wortebene möglich
- ▶ Nutzen von Input- und Output-Vektoren
- ▶ gleichzeitig Erkennung und Interpretation
- ▶ Einsatz in praktischer Anwendung

## Nachteil: Abhängigkeit von WordNet

- ▶ ähnliche Ressourcen nicht für alle Sprachen verfügbar
- ▶ nur für konventionalisierte Metaphern möglich

Beispiel: “the flames of withering injustice”

- ▶ nur ein Synset für “flames”: “the process of combustion of inflammable materials producing heat and light and (often) smoke”
  - ▶ nicht für Funktionswörter möglich
- Beispiel: “involved **in** a row **over** his attack **on** the Pharisees”

# Kritik an Evaluation

- ▶ für Metaphernerkenkung: keine Evaluation auf "Sequence Labeling Task"
- ▶ für Metapherninterpretation:
  - ▶ Performance auf "echten" MT-Korpora wäre interessant
  - ▶ keine Evaluation unabhängig von Metaphernerkenkung
  - ▶ Evaluation nur im Rahmen praktischer Anwendung

# Übersetzung von 10 metaphorischen Sätzen<sup>5</sup> durch Google

- ▶ Übertragung der Metapher komisch:

White wine doesn't **agree** with me.  
Weißwein *stimmt* mir nicht *zu*.

She **stepped** into a life of luxury.  
Sie *betrat* ein luxuriöses Leben.

- ▶ Übertragung der Metapher passt:

The news **leaked** out despite his secrecy.  
Die Nachricht ist trotz seiner Geheimhaltung *durchgesickert*.

This drug will **sharpen** your vision.  
Dieses Medikament wird Ihre Vision *schärfen*.

Stock prices are **drifting** higher.  
Aktienkurse *driften* höher.

Her husband often **abuses** alcohol.  
Ihr Mann *missbraucht* oft Alkohol.

---

<sup>5</sup>aus dem Datenset von Mohammad et al. (2016)

# Übersetzung von 10 metaphorischen Sätzen durch Google

- ▶ Metapher nicht eins zu eins übersetzt:

You can **count** on me to help you any time.

Sie können *sich* jederzeit auf mich *verlassen*.

She had to **juggle** her job and her children.

Sie musste ihren Job und ihre Kinder *unter einen Hut bringen*.

The White House **sits** on Pennsylvania Avenue.

Das Weiße Haus *befindet sich* in der Pennsylvania Avenue.

Life in the camp **drained** him.

Das Leben im Lager *erschöpfte* ihn.

## Literatur (I)

Christiane Fellbaum (Ed.). (1998). *WordNet: An Electronic Lexical Database*. Cambridge, MA: MIT Press.

Gao, G., Choi, E., Choi, Y., & Zettlemoyer, L. (2018). Neural Metaphor Detection in Context. In *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, 607–613.

Mao, R., Lin, C., & Guerin, F. (2018). Word embedding and WordNet based metaphor identification and interpretation. In *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics*, 1222-1231.

Melamud, O., Goldberger, J., & Dagan, I. (2016). context2vec: Learning generic context embedding with bidirectional LSTM. In *Proceedings of The 20th SIGNLL Conference on Computational Natural Language Learning*, 51-61.

## Literatur (II)

Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. In *ICLR Workshop Papers*.

Mohammad, S., Shutova, E., & Turney, P. (2016). Metaphor as a medium for emotion: An empirical study. In *Proceedings of the Fifth Joint Conference on Lexical and Computational Semantics*, 23-33.

Shutova, E., Kiela, D., & Maillard, J. (2016). Black holes and white rabbits: Metaphor identification with visual features. In *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 160-170.

## Literatur (III)

Rei, M., Bulat, L., Kiela, D., & Shutova, E. (2017). Grasping the finer point: A supervised similarity network for metaphor detection. In *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, 1537-1546.