

Aktueller Stand der Forschung in Neuronaler Maschineller Übersetzung

Christopher Brix

christopher.brix@rwth-aachen.de

January 14th, 2020

www.christopher-brix.de

Inhalt

Über Mich

Neural Machine Translation (NMT)
Alte und Neue Architekturen

2D LSTM

Weitere Forschung
Data Cleaning/Augmentation/Fairness
Document Level Translations
Sparsity

Über Mich

Studium:

- ▶ 2014 - 2018: B.Sc. Informatik, RWTH Aachen
- ▶ 2018 - 2020: M.Sc. Informatik, RWTH Aachen

Forschung:

- ▶ Wissenschaftliche Hilfskraft seit 2016
 - ▷ i6: Human Language Technology and Pattern Recognition (Prof. Dr.-Ing. Ney)
 - ▷ Betreuer: Parnia Bahar
- ▶ Co-Autor von "Empirical Investigation of Optimization Algorithms in Neural Machine Translation", veröffentlicht im PBML
- ▶ Co-Autor paper "Towards Two-Dimensional Sequence to Sequence Model in Neural Machine Translation", veröffentlicht in EMNLP

Highlights:

- ▶ LxMLS, Teilnehmer & Tutor
- ▶ Google NLP Summit 2019
- ▶ Google Research Intern 2020

Neural Machine Translation (NMT)

Maschinelle Übersetzung:

- ▶ Übersetzung eines Quellsatzes f_1^J in die Ziel-Hypothese \hat{e}_1^I
- ▶ $\hat{e}_1^I = \operatorname{argmax}_{I, e_1^I} \{\Pr(e_1^I | f_1^J)\}$

SMT:

- ▶ Zerlegung mittels Bayes Theorem
- ▶ $\hat{e}_1^I = \operatorname{argmax}_{I, e_1^I} \{\Pr(f_1^J | e_1^I) \cdot \Pr(e_1^I)\}$

NMT:

- ▶ Direkte Modellierung von $\Pr(e_1^I | f_1^J)$
- ▶ Wörter werden von neuronalem Netz generiert

Encoder-Decoder

Idee: Erst Zusammenfassen, dann Übersetzen [Sutskever⁺ 14]

- ▶ Zusammenfassen des Quell-Satzes in einem Vektor fester Größe
- ▶ Ausgeben der übersetzten Zusammenfassung




Figure: Architektur eines Encoder-Decoder NMT Systems

Attention

Idee: Fokus auf einzelnen Wörtern [Bahdanau⁺ 15]:

- ▶ Zusammenfassen eines Satzteils
- ▶ Ausgeben des nächsten Wortes
- ▶ Wiederholen, bis Übersetzung komplett ist

Online: <https://jalammar.github.io/visualizing-neural-machine-translation-mechanics-of-seq2seq-models-with-attention>

Attention

Encoder:

$$f_1^J \rightarrow \vec{h}_j = LSTM(f_j, \vec{h}_{j-1})$$

$$f_1^J \rightarrow \overleftarrow{h}_j = LSTM(f_j, \overleftarrow{h}_{j+1})$$

$$h_j = \begin{bmatrix} \vec{h}_j \\ \overleftarrow{h}_j \end{bmatrix}$$

Attention:

$$\alpha(j|i) = A_j(s_{i-1}, h_1^J)$$

$$c_i = \sum_{j=1}^J \alpha(j|i) \cdot h_j$$

Decoder:

$$e_i \leftarrow t_i = Y(e_{i-1}, s_{i-1}, c_i)$$

$$s_i = LSTM([e_i, c_i], s_{i-1})$$

$$p_i(e_i = w | e_1^{i-1}, f_1^J) \\ = softmax(t_i)_w$$




Figure: Architektur eines Attention NMT Systems

Transformer

Idee: Self-Attention für hohe Parallelisierbarkeit nutzen [Vaswani⁺ 17]:

- ▶ Jedes Wort bestimmt den Einfluss aller anderen Wörter auf sich selbst
- ▶ Verschiedene Indizes sind unabhängig
- ▶ $\alpha(j|j') = A_j(h_{j'}, h_1^J)$

$$\hat{h}_{j'} = \sum_{j=1}^J \alpha(j|j') \cdot h_j$$




Figure: Self-Attention

Online: <http://jalammar.github.io/illustrated-transformer>

Transformer

Positional Encoding:

- ▶ Sine/Cosine Kodierung des Wortposition

6 Encoder Layer:

- ▶ Multi-Head Attention
- ▶ Feed Forward Layer

6 Decoding Layer:

- ▶ Masked Multi-Head Attention (über den Ziel-Satz)
- ▶ Multi-Head Attention (über den letzten Encoder Layer)
- ▶ Feed Forward Layer




Figure: Architektur eines Transformer NMT Systems

2D LSTM

- ▶ 1D LSTM verarbeitet 1D Daten
- ▶ Viele Daten haben mehr als 1 Dimension, z.B. Bilder
- ▶ LSTMs können entsprechend erweitert werden [Graves⁺ 07]




Figure: Erweiterung eines LSTMs für 2D Daten

2D LSTM





Figure: 2DLSTM cell

Parallele Berechnung

- ▶ 1D LSTM für n Daten: $\mathcal{O}(n)$ Operationen



(a) Dependencies

1	2	3
4	5	6
7	8	9

(b) Ordered processing

1	2	3
2	3	4
3	4	5

(c) Parallel processing

- ▶ 2DLSTM kann innerhalb von $\mathcal{O}(n + m)$ Operationen berechnet werden [Voigtlaender⁺ 16]

2D Sequence to Sequence (2D seq2seq)

Neue Architektur [Bahar⁺ 18]:

- ▶ Kein expliziter encoder
- ▶ Kein expliziter decoder
- ▶ Komplexität: $\mathcal{O}(I + J)$

2D LSTM:

$$a_{0,0} = 0$$

$$a_{j,i} = 2DLSTM([f_j, e_{i-1}], \\ a_{j-1,i}, a_{j,i-1})$$

Decoding:

$$\hat{e}_i \leftarrow \text{softmax}(a_{J,i})$$




Figure: 2D seq2seq Architektur

2D seq2seq - Ergebnisse


Table: WMT 2016/17, Encoder/Attention/Decoder/2DLSTM Größe von 1000.

	Deutsch→Englisch				Englisch→Deutsch			
	BLEU [%]		TER [%]		BLEU [%]		TER [%]	
	2016	2017	2016	2017	2016	2017	2016	2017
Baseline	33.1	29.0	47.5	51.9	27.4	22.9	53.9	60.2
2D seq2seq	33.7	29.3	46.9	51.9	28.9	23.2	52.6	59.5


Table: Trainings- und Übersetzungs-Geschwindigkeit.

	Training [Token/s]	Übersetzung [Token/s]
Baseline	2,944	48
2D seq2seq	791	0.7

2D seq2seq - Performanz bei langen Sätzen



(a) BLEU



(b) TER

Figure: WMT 2017 newstest2015, newstest2016 and newstest2017 Deutsch→Englisch

- ▶ Gruppengröße: 1455, 3081, 2133, 990, 344 und 169 Satzpaare
- ▶ 2D seq2seq kann längere Sätze besser übersetzen

Data Cleaning/Augmentation/Fairness

Data Cleaning:

- ▶ Paracrawl Korpus: 5.000.000.000 Deutsch-Englisch Satzpaare
- ▶ Viele schlechte Paare

Data Augmentation:

- ▶ Nützlich bei kleinen Korpora
- ▶ Monolinguale Daten mit Model A übersetzen, um Model B zu trainieren

Data Fairness:

- ▶ Bias im Datensatz => Bias im Model (Geschlecht, Höflichkeit, etc.)
- ▶ Schaffung von Datensätzen ohne Bias
- ▶ Model steuerbar machen

Document Level Translations

Problem:

- ▶ Satzweise Übersetzung kann inkonsistent sein
 - ▷ Geschlecht
 - ▷ Technische Begriffe
 - ▷ Fehlender Kontext

Mögliche Ansätze:

- ▶ Attention über vorherigen Satz
- ▶ Zusätzliche Zusammenfassungen des Dokuments

Sparsity

Idee:

- ▶ Teile des Netzwerks werden entfernt, um Zeit/Platz zu sparen

Verschiedene Typen:

- ▶ Structured sparsity
 - ▷ Ganze Layer/Module
 - ▷ Einzelne Neuronen
 - ▷ Blöcke von Verbindungen
- ▶ Unstructured sparsity
 - ▷ Einzelne Verbindungen

Vielen Dank für Ihre Aufmerksamkeit!

Christopher Brix

Christopher.Brix@rwth-aachen.de

www.christopher-brix.de

References