

Natural Language Processing

Ali Akbar Septiandri

December 29, 2020

Universitas Al Azhar Indonesia

Daftar isi

1. Natural Language Processing

2. NLTK

3. Referensi

Natural Language Processing

Apa Itu NLP?

Salah satu ilmu multidisiplin yang berfokus pada interaksi manusia dan komputer melalui bahasa alami manusia. Beberapa hal yang dibahas di dalamnya antara lain:

- Part-of-Speech (POS) tagging
- Parsing
- Stemming
- Machine translation
- Named entity recognition (NER)
- Question answering
- Sentiment analysis
- Automatic summarisation
- Speech recognition
- Text-to-speech

Kategori Tugas-tugas NLP

- Syntax
 - Part-of-Speech (POS) tagging
 - Parsing
 - Stemming
- Semantics
 - Machine translation
 - Named entity recognition (NER)
 - Question answering
 - Sentiment analysis
- Discourse
 - Automatic summarisation
- Speech
 - Speech recognition
 - Text-to-speech

Start of the line

3 to 15 characters long

`^[a-zA-Z0-9_-]{3,15}$`

↑

End of the line

letters, numbers, underscores, hyphens

Figure 1: Contoh regular expression. Sumber: tajawal

Part-of-Speech (POS) Tagging

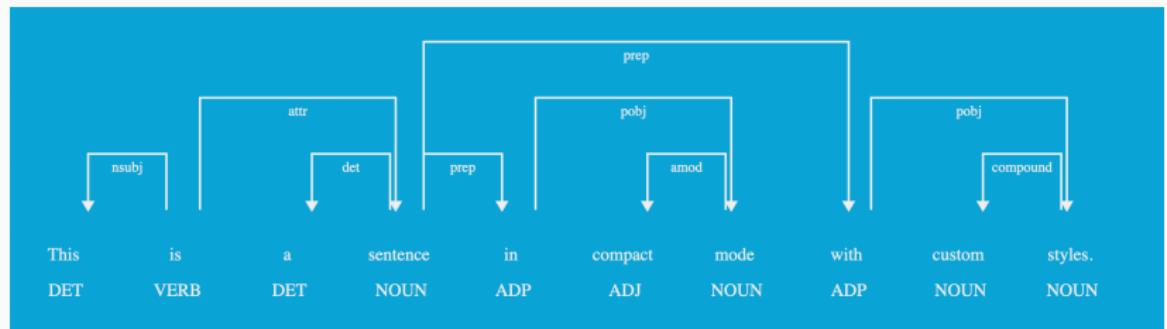


Figure 2: Kategori kata (Sumber: spaCy)

Named Entity Recognition (NER)

When Sebastian Thrun PERSON started working on self-driving cars at Google ORG
in 2007 DATE , few people outside of the company took him seriously.

Figure 3: Menemukan orang, organisasi, dan tanggal dalam teks
(Sumber: spaCy)

SENTIMENT ANALYSIS

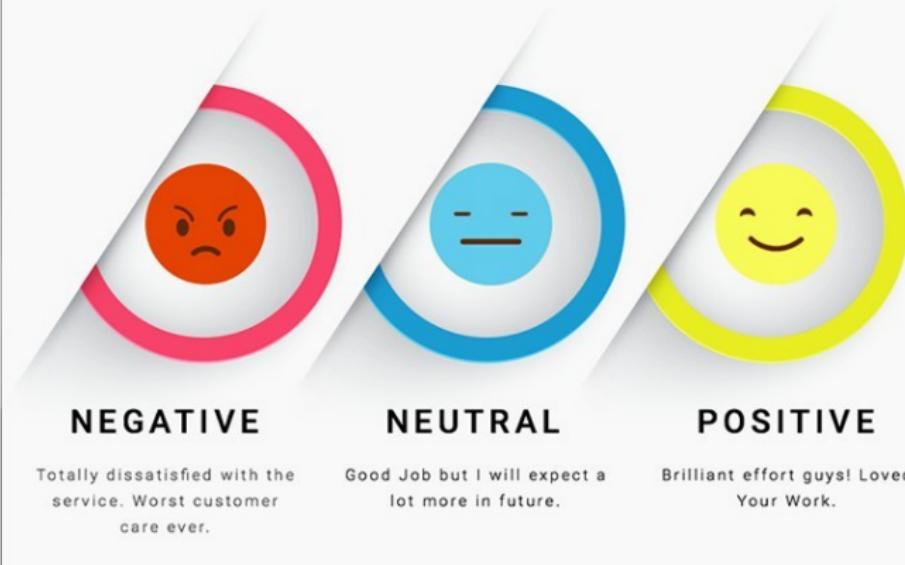


Figure 4: "Apa yang menjadi sentimen dari ulasan ini?" Sumber: KDNNuggets

"[A] fascinating read from beginning to end." —TYLER COWEN,
professor of economics, George Mason University, author of *Average Is Over*

THE
LANGUAGE
OF
FOOD

A LINGUIST
READS THE MENU

DAN
JURAFSKY

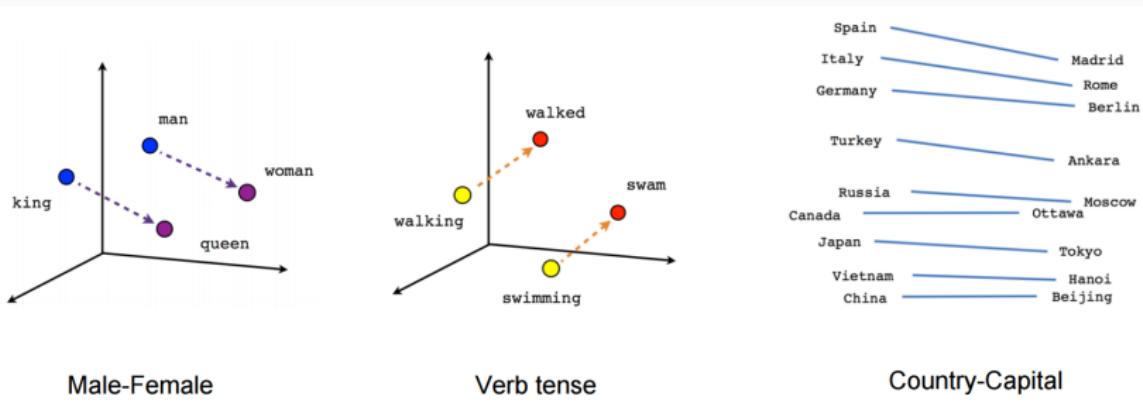


Figure 5: Representasi kata dalam vektor (Mikolov et al., 2013).

Sumber: TensorFlow

Demo word2vec

Sentiment Analysis

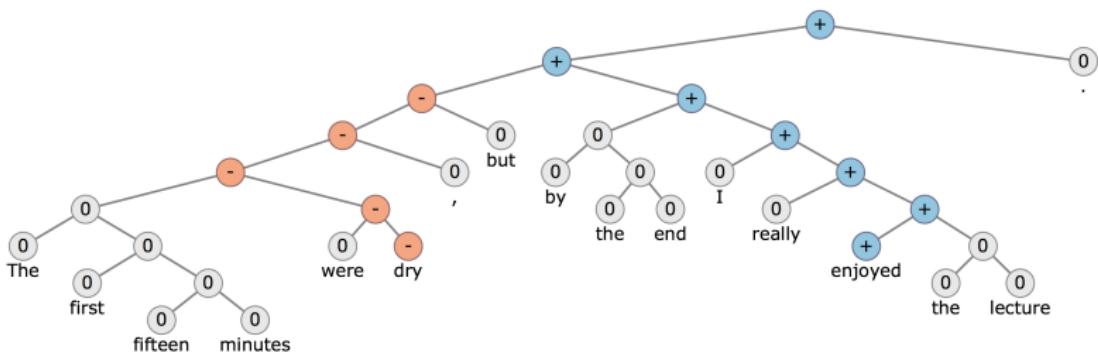


Figure 6: Hasil analisis sentimen dengan *deep learning* [Socher, 2017]

that the most important feature here is the degree centrality. To see this better, we found a Gaussian distribution of degree centrality for each class in the training set. We then plotted the two Gaussians on top of the histograms from the validation set. The plot can be seen in Figure 4.10¹.

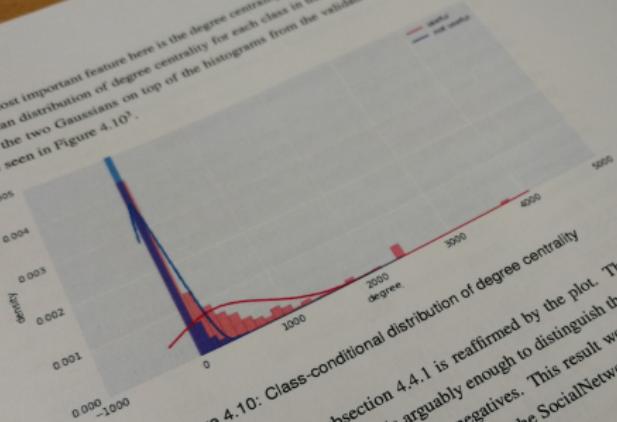


Figure 4.10: Class-conditional distribution of degree centrality

Our suspicion earlier in subsection 4.4.1 is reaffirmed by the plot. The decision boundary from these two Gaussians is arguably enough to distinguish the two classes, this also caused most of the false negatives. This result would also explain why our classifier got better when we introduced the SocialNetwork features.

Classification models

After all these experiments on the prepared test set, we can say that our classifier model is good enough. We can safely say that our classifier could have underfitted or overfitted the problem in the future. This classifier turned the classification problem into a classification con-

Table 4.10: F-score from two different classifiers	
Algorithm	F-score
Baseline	0.5
Naive Bayes	0.75

Figure 7: Deteksi plagiarisme dari makalah

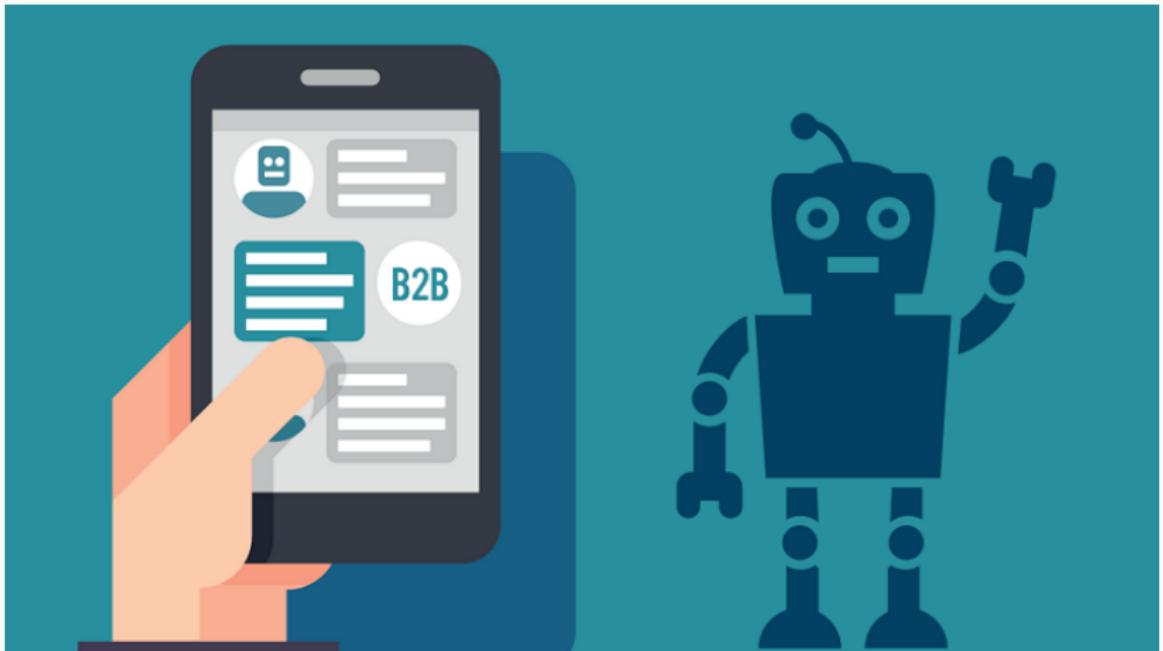


Figure 8: Penggunaan chatbot untuk bisnis. Sumber: Acquire

Computational Linguistics

- NLP juga dikenal dengan nama *computational linguistics*, karena mencoba merepresentasikan makna dari kata, frasa, kalimat, dan dokumen melalui **distribusinya**

Computational Linguistics

- NLP juga dikenal dengan nama *computational linguistics*, karena mencoba merepresentasikan makna dari kata, frasa, kalimat, dan dokumen melalui **distribusinya**
- Distribusi tersebut direpresentasikan dalam **vektor konteks**

Computational Linguistics

- NLP juga dikenal dengan nama *computational linguistics*, karena mencoba merepresentasikan makna dari kata, frasa, kalimat, dan dokumen melalui **distribusinya**
- Distribusi tersebut direpresentasikan dalam **vektor konteks**
- “Dalam suatu dokumen, kata apa saja yang muncul bersamaan?”

Computational Linguistics

- NLP juga dikenal dengan nama *computational linguistics*, karena mencoba merepresentasikan makna dari kata, frasa, kalimat, dan dokumen melalui **distribusinya**
- Distribusi tersebut direpresentasikan dalam **vektor konteks**
- “Dalam suatu dokumen, kata apa saja yang muncul bersamaan?”
- Begitu pula di level semantik → **Bag-of-Words (BoW) model**

Computational Linguistics

- NLP juga dikenal dengan nama *computational linguistics*, karena mencoba merepresentasikan makna dari kata, frasa, kalimat, dan dokumen melalui **distribusinya**
- Distribusi tersebut direpresentasikan dalam **vektor konteks**
- “Dalam suatu dokumen, kata apa saja yang muncul bersamaan?”
- Begitu pula di level semantik → **Bag-of-Words (BoW) model**
- Bahkan, bisa sampai ke level **karakter!**

Bag-of-Words

Dalam representasi ini, urutan atau letak dari kata tersebut tidak relevan

- D1 “send us your password”
- D2 “send us your review”
- D3 “review your password”
- D4 “review us”
- D5 “send your password”
- D6 “send us your account”

Binary Bag-of-Words

Dalam representasi ini, urutan atau letak dari kata tersebut tidak relevan

dokumen	account	password	review	send	us	your
D1	0	1	0	1	1	1
D2	0	0	1	1	1	1
D3	0	1	1	0	0	1
D4	0	0	1	0	1	0
D5	0	1	0	1	0	1
D6	1	0	0	1	1	1

Apa yang menjadi masalah di sini?

- Matriksnya jarang
- Tidak ada informasi urutan
- Ada kata-kata yang sangat sering muncul

$$w_{t,d} = (1 + \log(tf_{t,d})) \log\left(\frac{N}{df_t}\right)$$

- $tf_{t,d}$... frekuensi kata t dalam dokumen d , N ... jumlah dokumen, df_t ... jumlah dokumen yang mempunyai kata t
- Kata yang sering muncul mungkin tidak penting, e.g. kata hubung
- Kata yang langka akan bernilai lebih – lihat posisi df_t !

Menemukan Dokumen yang Mirip

- **Euclidean distance** adalah metode pengukuran jarak yang umum
- Untuk dokumen, jumlah kemunculan kata *mungkin* tidak begitu penting
- Yang penting adalah keberadaan katanya → **cosine similarity**

$$\cos(\mathbf{x}, \mathbf{y}) = \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{x}\| \cdot \|\mathbf{y}\|}$$

Memaknai Kata

- Dengan ide yang serupa dan beberapa tambahan algoritma lainnya, e.g. *Latent Semantic Analysis* (LSA), kita bisa menggunakan kakas ini untuk **tes seperti TOEFL**

Memaknai Kata

- Dengan ide yang serupa dan beberapa tambahan algoritma lainnya, e.g. *Latent Semantic Analysis* (LSA), kita bisa menggunakan kakas ini untuk **tes seperti TOEFL**
- LSA berhasil menjawab 64.4% soal

Memaknai Kata

- Dengan ide yang serupa dan beberapa tambahan algoritma lainnya, e.g. *Latent Semantic Analysis* (LSA), kita bisa menggunakan kakas ini untuk **tes seperti TOEFL**
- LSA berhasil menjawab 64.4% soal
- Pengguna bahasa Inggris non-natif rata-rata berhasil menjawab 64.5% soal

Memaknai Kata

- Dengan ide yang serupa dan beberapa tambahan algoritma lainnya, e.g. *Latent Semantic Analysis* (LSA), kita bisa menggunakan kakas ini untuk **tes seperti TOEFL**
- LSA berhasil menjawab 64.4% soal
- Pengguna bahasa Inggris non-natif rata-rata berhasil menjawab 64.5% soal
- *Cukup untuk masuk banyak universitas di US!*

Beberapa Tantangan

- Homograf, kata yang tulisannya sama tetapi maknanya berbeda, e.g. “**beruang**”

Beberapa Tantangan

- Homograf, kata yang tulisannya sama tetapi maknanya berbeda, e.g. “**beruang**”
- Token yang tidak dikenali, e.g. **salah tik (typo)**, neologisme, **slang**

Beberapa Tantangan

- Homograf, kata yang tulisannya sama tetapi maknanya berbeda, e.g. “**beruang**”
- Token yang tidak dikenali, e.g. **salah tik (typo)**, neologisme, **slang**
- Kata dapat berubah makna dalam frasa, e.g. “**mahasiswa**” itu **netral**, tetapi “**harga mahasiswa**” itu **positif**

Model Bahasa Probabilistik

Manning & Schütze (1999)

$$\begin{aligned} P(\mathbf{w}) &= p(w_1, w_2, \dots, w_{t-1}, w_t) \\ &= p(w_1)p(w_2|w_1)p(w_3|w_2, w_1)\dots p(w_t|w_1, w_2, \dots, w_{t-1}) \end{aligned}$$

Nilai ini bisa diaproksimasi sebagai

$$P(w_1, w_2, \dots, w_{t-1}, w_t) \approx p(w_1) \prod_{i=2}^t p(w_i|w_{i-1})$$

Model Bahasa Probabilistik - Contoh

Diberikan tiga contoh kalimat:

1. Saya mau makan
2. Ali dan saya mau bermain
3. Kamu mau makan

Pertanyaan: “Ali mau ...”

$$p(makan | mau) = 2/3$$

$$p(bermain | mau) = 1/3$$

Model Bahasa Neural

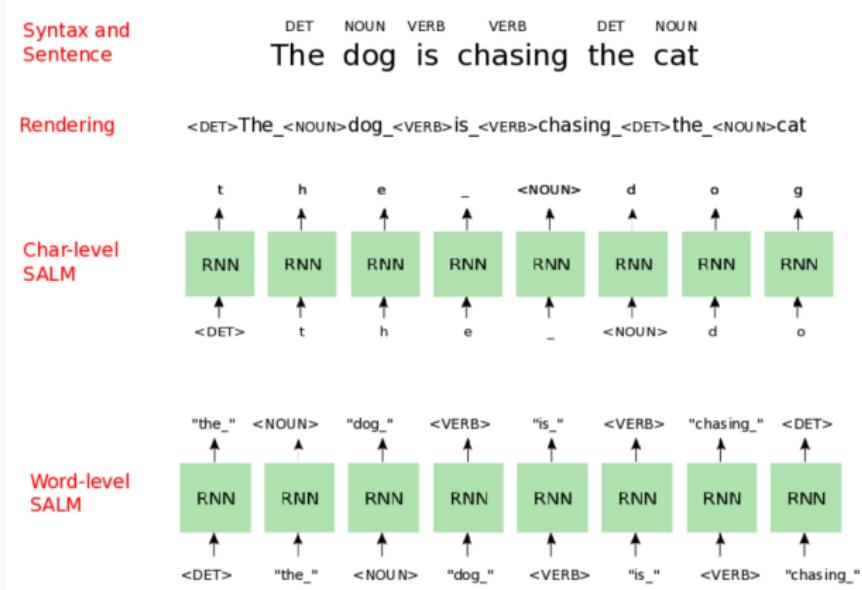


Figure 9: Hubungan antarkata dijelaskan dengan neural network
(Sumber: Zalando Research)

Model Bahasa Neural

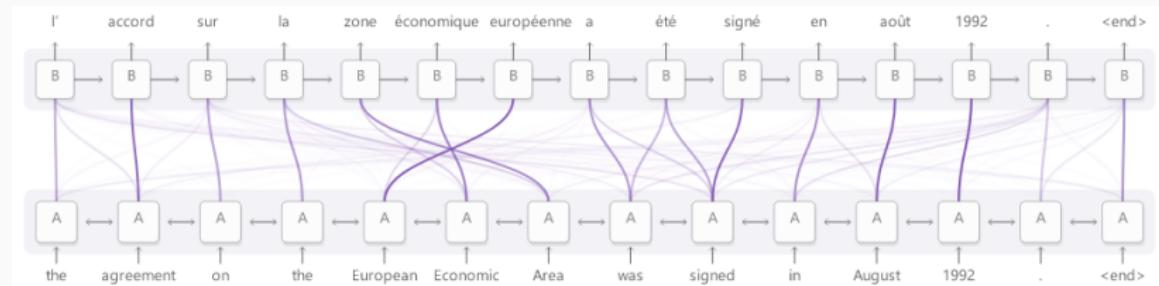


Figure 10: Terjemahan dengan neural network (Sumber: Distill)

Model Bahasa Neural



Figure 11: BERT Transformer (Sumber: Data Folks Indonesia)

NLTK

Natural Language Toolkit

“NLTK is a leading platform for building Python programs to work with human language data. It provides easy-to-use interfaces to over 50 corpora and lexical resources such as WordNet, along with a suite of text processing libraries for classification, **tokenization**, **stemming**, **tagging**, **parsing**, and **semantic reasoning...**”

NER Tagging

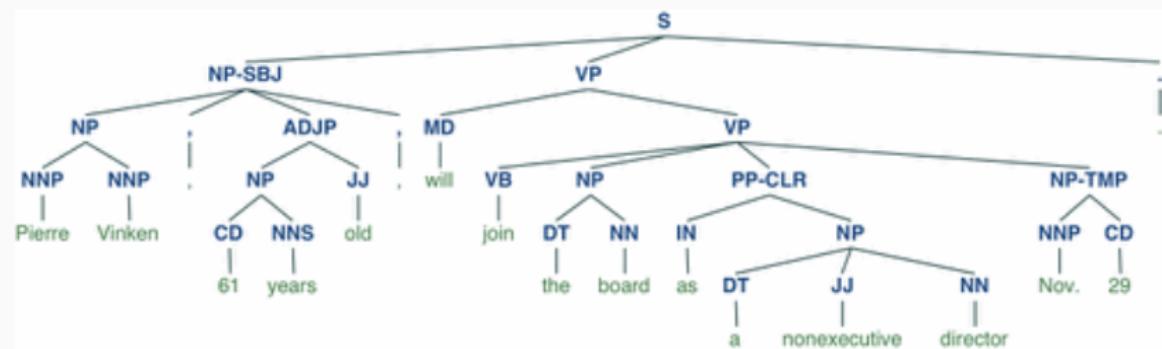


Figure 12: Hasil NER tagging dengan NLTK [NLTK Project, 2017]

Beberapa korpus dan model yang terkenal dari NLTK:

- Project Gutenberg Selections
- Penn Treebank
- SentiWordNet
- Stopwords Corpus
- Porter Stemmer

Everything Data

Document Similarity using NLTK and Scikit-Learn

Alternatif untuk NLTK

Beberapa alternatif untuk tugas-tugas spesifik:

- **spaCy**: Industrial-Strength Natural Language Processing in Python
- **gensim**: topic modelling for humans

	SPACY	NLTK	CORENLP
Programming language	Python	Python	Java / Python
Neural network models	✓	✗	✓
Integrated word vectors	✓	✗	✗
Multi-language support	✓	✓	✓
Tokenization	✓	✓	✓
Part-of-speech tagging	✓	✓	✓
Sentence segmentation	✓	✓	✓
Dependency parsing	✓	✗	✓
Entity recognition	✓	✓	✓
Entity linking	✗	✗	✗
Coreference resolution	✗	✗	✓

Figure 13: Perbandingan fitur (Sumber: spaCy)

	SPACY	NLTK	ALLEN- NLP	STANFORD- NLP	TENSOR- FLOW
I'm a beginner and just getting started with NLP.	✓	✓	✗	✓	✗
I want to build an end-to-end production application.	✓	✗	✗	✗	✓
I want to try out different neural network architectures for NLP.	✗	✗	✓	✗	✓
I want to try the latest models with state-of-the-art accuracy.	✗	✗	✓	✓	✓
I want to train models from my own data.	✓	✓	✓	✓	✓
I want my application to be efficient on CPU.	✓	✓	✗	✗	✗

Figure 14: Mana yang harus dipakai? (Sumber: spaCy)

Referensi

Bahan Bacaan

1. Bird, S., Edward L. & Klein, E. (2009). *Natural Language Processing with Python*. O'Reilly Media Inc.
2. Jurafsky, D. & Martin, J. H. (2018). *Speech and Language Processing* (Vol. 3). Pearson.
3. Manning, C., Raghavan, P., & Schütze, H. (2008). *Introduction to Information Retrieval*. Cambridge University Press.

1. Stanford CS124: From Languages to Information
2. University of Edinburgh: Text Technologies for Data Science
3. Stanford CS276: Information Retrieval and Web Search
(advanced)
4. Stanford CS224n: Natural Language Processing with Deep Learning *(advanced)*

- **Stanford NLP**: Chris Manning, Dan Jurafsky, Percy Liang
- **EdinburghNLP**: Sharon Goldwater, Mirella Lapata, Ivan Titov, Mark Steedman, Shay Cohen, Walid Magdy, etc.
- **UniMelb CIS School**: Tim Baldwin, Trevor Cohn, Karin Verspoor
- **UWNLP**: Noah Smith, Luke Zettlemoyer
- **QCRI**
- Chris Dyer (DeepMind), Sebastian Ruder (DeepMind), Hal Daumé III (UMaryland), Graham Neubig (CMU), Kyunghyun Cho (NYU), Phil Blunsom (Oxford), Richard Socher (Salesforce), Isabelle Augenstein (Copenhagen)

Peneliti Indonesia di NLP

- ITB: Ayu Purwarianti, Masayu Leylia Khodra, Dessi Puji Lestari (speech)
- UI: Mirna Adriani, Rahmad Mahendra
- UGM: Yunita Sari
- Adhiguna Kuncoro (DeepMind), Dani Yogatama (DeepMind), Ruli Manurung (Google Japan), Clara Vania (NYU), Genta Indra Winata (HKUST), Samuel Cahyawijaya (HKUST), Kemal Kurniawan (UniMelb), Yudi Wibisono (UPI)

Referensi

-  NLTK Project (2 Januari 2017)
Natural Language Toolkit
<http://www.nltk.org/>
-  Richard Socher (diakses 15 Mei 2017)
CS224d: Deep Learning for Natural Language Processing
<http://cs224d.stanford.edu/>

Terima kasih