



SPRACHMODELLE IM NATURAL LANGUAGE PROCESSING

VON FRANZISKA MEYER

INHALTE

- Natural Language Processing (NLP)
 - Beispiele
 - Prozess
- Sprachmodelle
- Entwicklung der Anwendungen

The image features a dark blue background with white, stylized circuit-like lines in the corners. These lines consist of vertical and horizontal segments connected by small circles, resembling a network or data flow diagram. The lines are positioned in the top-left, top-right, bottom-left, and bottom-right corners, framing the central text.

NATURAL LANGUAGE PROCESSING

NATURAL LANGUAGE PROCESSING

- zu dt.: Natürliche Sprachverarbeitung
- oft abgekürzt als NLP
- Teilgebiet der Linguistik, Informatik und Artificial Intelligence
 - Aufgabenbewältigung, für welche menschliches Denken erforderlich wäre

NATURAL LANGUAGE PROCESSING

- Definition:

„Natural Language Processing behandelt die Verarbeitung der natürlich gesprochenen Sprache, so dass diese verstanden, interpretiert und darauf reagiert werden kann.“

- Ziel: Einwandfreie Kommunikation zwischen Mensch und Computer

NATURAL LANGUAGE PROCESSING

- **Komplexität:**
 - Wortbedeutungen sind nicht immer eindeutig
 - Kontext muss erfasst werden
 - Erkennbarkeit von Sarkasmus, Ironie, rhetorische Fragen
- **Deshalb: Nutzung von Maschine Learning**

BEISPIELE VON NLP

- E-Mail Filter
- Smart Assistants
- Suchergebnisse
- Predictive Texts
- Übersetzungen

NLP – INPUT UND OUTPUT

- Input: gesprochene Sprache (muss erst in Dokument umgewandelt werden)
- Prozess: ein annotiertes Dokument entsteht
- Output: eine geschriebene oder gesprochene Ausgabe erfolgt (über Sprachgenerierung)

ABLAUF DES NLP

- Tokenisierung
- Lexikalische/Morphologische Analyse (Stemmen/Lemmatisieren)
- Syntaktische Analyse (Parsing)
- Semantische Analyse (Named Entity Recognition)
- Diskursanalyse
- (Pragmatische Analyse)

BEGRIFFLICHKEITEN

- Token
- Morphologie
- Syntax
- Semantik
- Diskurs
- Pragmatik

TOKENISIERUNG

- Tokenisierung entspricht einer Unterteilung in logische Segmente.

Dies ist ein Beispiel

Dies | ist | ein | Beispiel

LEXIKALISCHE/MORPHOLOGISCHE ANALYSE

- Die interne Struktur der Tokens wird analysiert und die lexikalische Klasse zugewiesen
 - Stemming: Wörter werden in ihre Basisform gebracht
„affection“, „affected“, „affecting“, „affects“ - „Affect“
 - Lemmatization: Wörter werden auf ihre Bedeutung zurückgeführt
„besser“ - „gut“

SYNTAKTISCHE ANALYSE

- Ermittlung der Satzstruktur über lexikalische Klasse
 - Ableitung der strukturellen Funktionen (Subjekt, Objekt, etc.)
 - Wie funktioniert ein Wort innerhalb eines Satzes?

SEMANTISCHE ANALYSE

- Überprüfung auf Bedeutung mittels Named-Entity-Recognition
 - Zuweisung von Entitäten zu bestimmten Gruppen

„Microsofts (Organisation) Gründer Bill Gates (Person) war in New York (Ort).“

DISKURSANALYSE

- Beziehung zum vorigen Satz wird erkannt
 - z.B. Frage-Antwort Konstrukt, birgt Bedeutung in nächstem Satz

PRAGMATISCHE ANALYSE

- Reinterpretation der Aussage, sodass eigentliche Bedeutung erkannt wird
- erfordert Wissen aus der realen Welt

SPRACHMODELLE

The image features a dark blue background with the word "SPRACHMODELLE" centered in white, bold, uppercase letters. The corners of the image are decorated with light blue, stylized circuit board traces and nodes, creating a technical or digital aesthetic.

SPRACHMODELLE


- Definition:

„Ein Sprachmodell besteht aus einem Korpus an Textdokumenten mit dem es trainiert wurde, die Sprache zu analysieren.“

- Dient einer Auswertung oder Generation von Sprache hinsichtlich des Inputs
- Betrachtung: Entwicklung von Sprachmodellen

ELIZA - VOR DEN SPRACHMODELLEN

- ELIZA ist kein Sprachmodell, sondern „Simulation eines Psychotherapeuten“ (entspricht eher einem Chatbot)
- Basiert auf Thesaurus und vorgefertigten Antwortkonstrukten



RULE-BASED NLP

- Beginn der 1980er: handgeschriebene Regeln zum Training von Modellen
- Entspricht einer kontextfreien Grammatik
 - Artikel -> Nomen | Adjektiv
- Nutzt reguläre Ausdrücke
 - String „. „ entspricht Satzende

RULE-BASED NLP

- Noch in Benutzung, um Trainingsdaten vorzubereiten
- Nicht unbedingt universell anwendbar

STATISTISCHE SPRACHMODELLE

- Basieren darauf, die Wahrscheinlichkeit eines Wortes auf eine bereits existente Wortfolge zu berechnen

$$P(w_1, \dots, w_m) = \prod_{i=1}^m P(w_i | w_1, \dots, w_{i-1}) \approx \prod_{i=1}^m P(w_i | w_{i-(n-1)}, \dots, w_{i-1})$$

- Es werden Wörter x zu Folgewörtern von Wörtern w , wenn sie häufiger als Nachfolger von w in den Daten in Korpus auftreten

STATISTISCHE SPRACHMODELLE

- Unigram: Ein Unigram betrachtet nur sich selbst, kein Verhältnis zu vorigem Wort, es würden zufällige häufige Wörter gewählt

`that, or, limited, the`

- Bigram/Trigram: Bigramme betrachten ein, Trigramme zwei Wörter vor dem künftigen Input

`outside, new, car, parking, lot, of, the, agreement, reached`

STATISTISCHE SPRACHMODELLE


- N-Gram: beliebig viele Wörter hintereinander ketten für Wahrscheinlichkeitsberechnung
 - Aber:
 - Anspruchsvolle Berechnung
 - Begrenzter Korpus

NEURONALE NETZWERKE

- Deep Learning effektiv für Sprachmodellentwicklung
 - Orientierung am menschlichen Gehirn, welches selbstständig lernt
- Maschine lernt von selbst, kein menschliches Eingreifen von Nöten

NEURONALE NETZWERKE

- Neuronale Netze bestehen aus künstlichen Neuronen, welche mit gewichteten Verbindungen vernetzt sind
- Korrelieren Entscheidungen, so tritt Lernprozess ein
- Mehr Schichten = komplexere Sachverhalte



NEURONALE NETZWERKE

- Clustering: ungelabelte Daten werden nach Ähnlichkeiten geordnet und Unregelmäßigkeiten betrachtet
- Klassifikation: für bereits gelabelte Daten, Zusammenhänge zwischen Daten und Labels soll erkannt werden
- Es lassen sich durch Neuronale Netzwerke ebenfalls Vorhersagen treffen

BERT – MLM/NSP

- Neuerung aus 2018 von Google
- BERT ist kein Sprachmodell, nutzt aber eine Neuerung
- Bidirektionales Verhalten – gesamter Input wird auf einmal erfasst

BERT – MLM/NSP

- Masked Language Modeling (MLM)

„Versteckte“ Wörter können ermittelt werden

Input: The man went to the [MASK]₁ . He bought a [MASK]₂ of milk .
Labels: [MASK]₁ = store; [MASK]₂ = gallon

- Next Sentence Prediction (NSP)

Sätze können auf ihre Abfolge aufeinander geprüft werden

Sentence A = The man went to the store.
Sentence B = He bought a gallon of milk.
Label = IsNextSentence

Sentence A = The man went to the store.
Sentence B = Penguins are flightless.
Label = NotNextSentence

The image features a dark blue background with white, stylized circuit board traces in the corners. These traces form various geometric shapes and paths, some ending in small circles, resembling electronic components or connections. The central text is in a clean, white, sans-serif font.

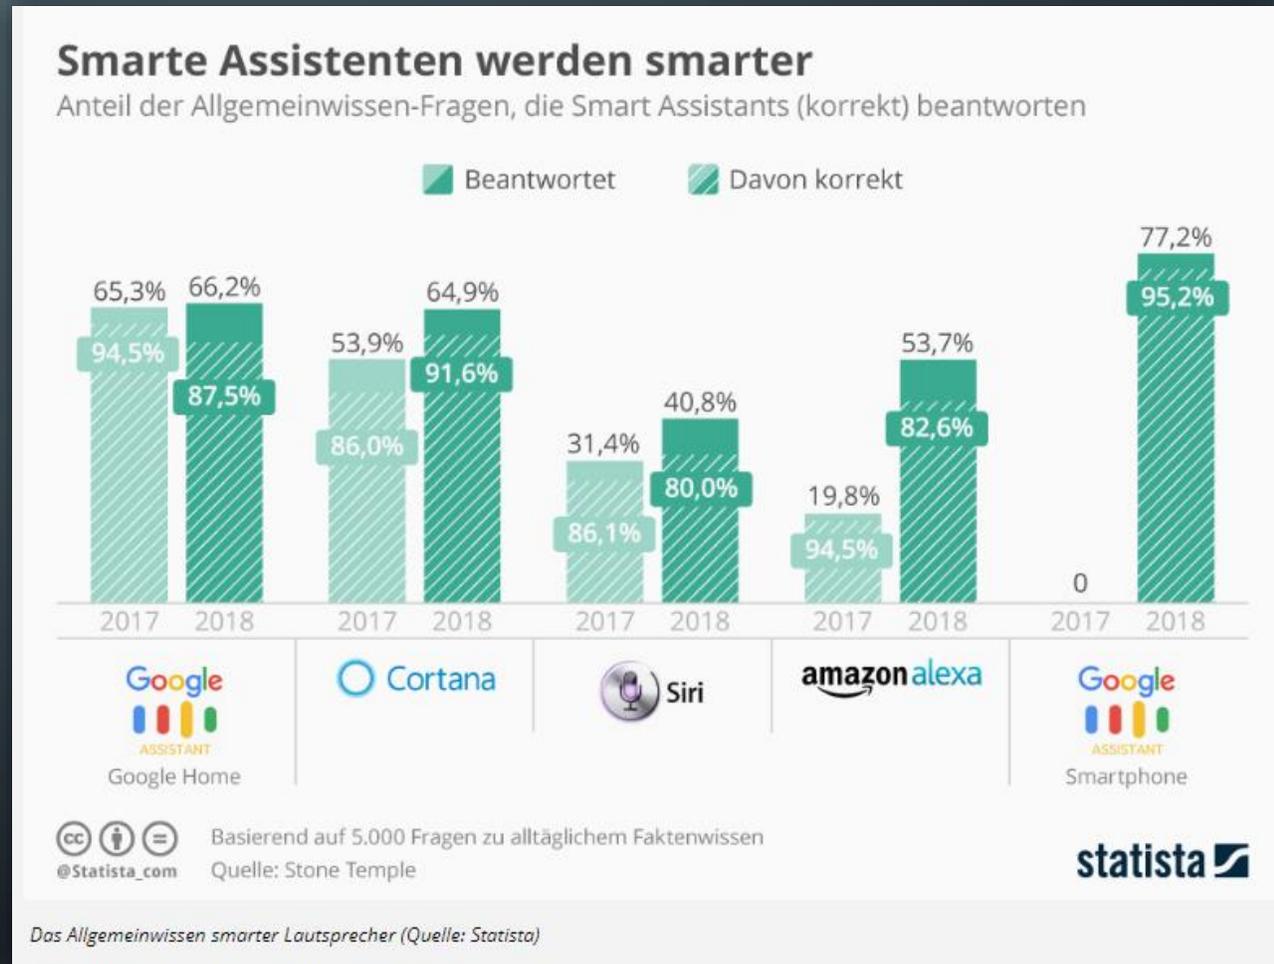
LERNFORTSCHRITT DER ANWENDUNGEN

LERNFORTSCHRITT DER ANWENDUNGEN

- Nicht nur Sprachmodelle entwickeln sich
- NLP Anwendungen lernen konstant weiter



LERNFORTSCHRITT DER ANWENDUNGEN

- Smartassistenten verstehen uns immer besser







LERNFORTSCHRITT DER ANWENDUNGEN

- Predictive Texts von vers. Keyboards lernen unterschiedlich (schnell)



LERNFORTSCHRITT DER ANWENDUNGEN



QUELLEN

- www.bigdata-insider.de/was-ist-natural-language-processing-a-590102/
- www.sem-deutschland.de/inbound-marketing-agentur/online-marketing-glossar/natural-language-processing/
- www.datenbanken-verstehen.de/lexikon/natural-language-processing/
- www.tableau.com/learn/articles/natural-language-processing-examples
- en.wikipedia.org/wiki/Natural_language_processing
- de.wikipedia.org/wiki/Computerlinguistik
- www.digitalconnection.de/connected-customer/das-jahrzehnt-der-digitalen-sprachassistenten/
- www.xenonstack.com/blog/evolution-of-nlp/
- rstudio-pubs-static.s3.amazonaws.com/69717_91e500e66f784451a5126c405ceaa738.html
- lifehacker.com/how-predictive-keyboards-work-and-how-you-can-train-yo-1643795640
- de.wikipedia.org/wiki/ELIZA
- www.youtube.com/watch?v=5ctbvkAMQO4
- www.youtube.com/watch?v=fOvTtapxa9c&

QUELLEN

- www.tutorialspoint.com/artificial_intelligence/artificial_intelligence_natural_language_processing.htm
- de.wikipedia.org/wiki/Computerlinguistik
- web.stanford.edu/class/cs124/lec/languagemodeling.pdf
- www.analyticsvidhya.com/blog/2019/08/comprehensive-guide-language-model-nlp-python-code/
- en.wikipedia.org/wiki/Language_model
- towardsdatascience.com/bert-explained-state-of-the-art-language-model-for-nlp-f8b21a9b6270
- ai.googleblog.com/2018/11/open-sourcing-bert-state-of-art-pre.html
- www.kdnuggets.com/2018/10/main-approaches-natural-language-processing-tasks.html
- www.bigdata-insider.de/was-ist-deep-learning-a-603129/
- www.analyticsvidhya.com/blog/2019/09/demystifying-bert-groundbreaking-nlp-framework/
- pathmind.com/wiki/neural-network
- deeptai.org/machine-learning-glossary-and-terms/attention-models
- www.masswerk.at/elizabot/

The image features a dark blue background with white, stylized circuit board traces in the corners. These traces consist of straight lines of varying lengths and angles, ending in small white circles, resembling a network or data flow diagram. The traces are located in the top-left, top-right, bottom-left, and bottom-right corners, framing the central text.

VIELEN DANK FÜR DIE AUFMERKSAMKEIT!