

**LERNENDE
MASCHINEN**
02.05.2017

**INDUSTRIE
4.0**

**SPRACH-
DIALOGE**
09.05.2017

**KÜNSTLICHE
INTELLIGENZ**

**BIG
DATA**

KI

**TEAM-
ROBOTIK**

**AUTONOME
SYSTEME**

**ALTERS-
ASSISTENZ**

**SMART
SERVICE**

**SICHER-
HEIT**

**EMOTION &
VERHALTEN**

Online-Kurs von DFKI und acatech zum maschinellen Lernen



Im April 2017 waren bereits 4700 Teilnehmer eingeschrieben. In 3 Kurswochen bieten Wissenschaftler, Vertreter aus Unternehmen, Entwickler und Anwender in insgesamt 38 Videos Orientierungswissen für das maschinelle Lernen.

MOOC.HOUSE <https://mooc.house/courses/machinelearning-2016>

Vorlesungsreihe 2017: Künstliche Intelligenz für den Menschen: Digitalisierung mit Verstand

Mainz, 09. Mai 2017



Wie können Computer unsere menschliche Sprache verstehen?

Vom Sprachdialogsystem bis zum Simultandolmetscher

Prof. Dr. rer. nat. Dr. h.c. mult.

Wolfgang Wahlster



Deutsches Forschungszentrum für Künstliche Intelligenz GmbH

Saarbrücken/Kaiserslautern/Bremen/Berlin/Osnabrück

Tel.: (0681) 85775-5252

E-mail: wahlster@dfki.de

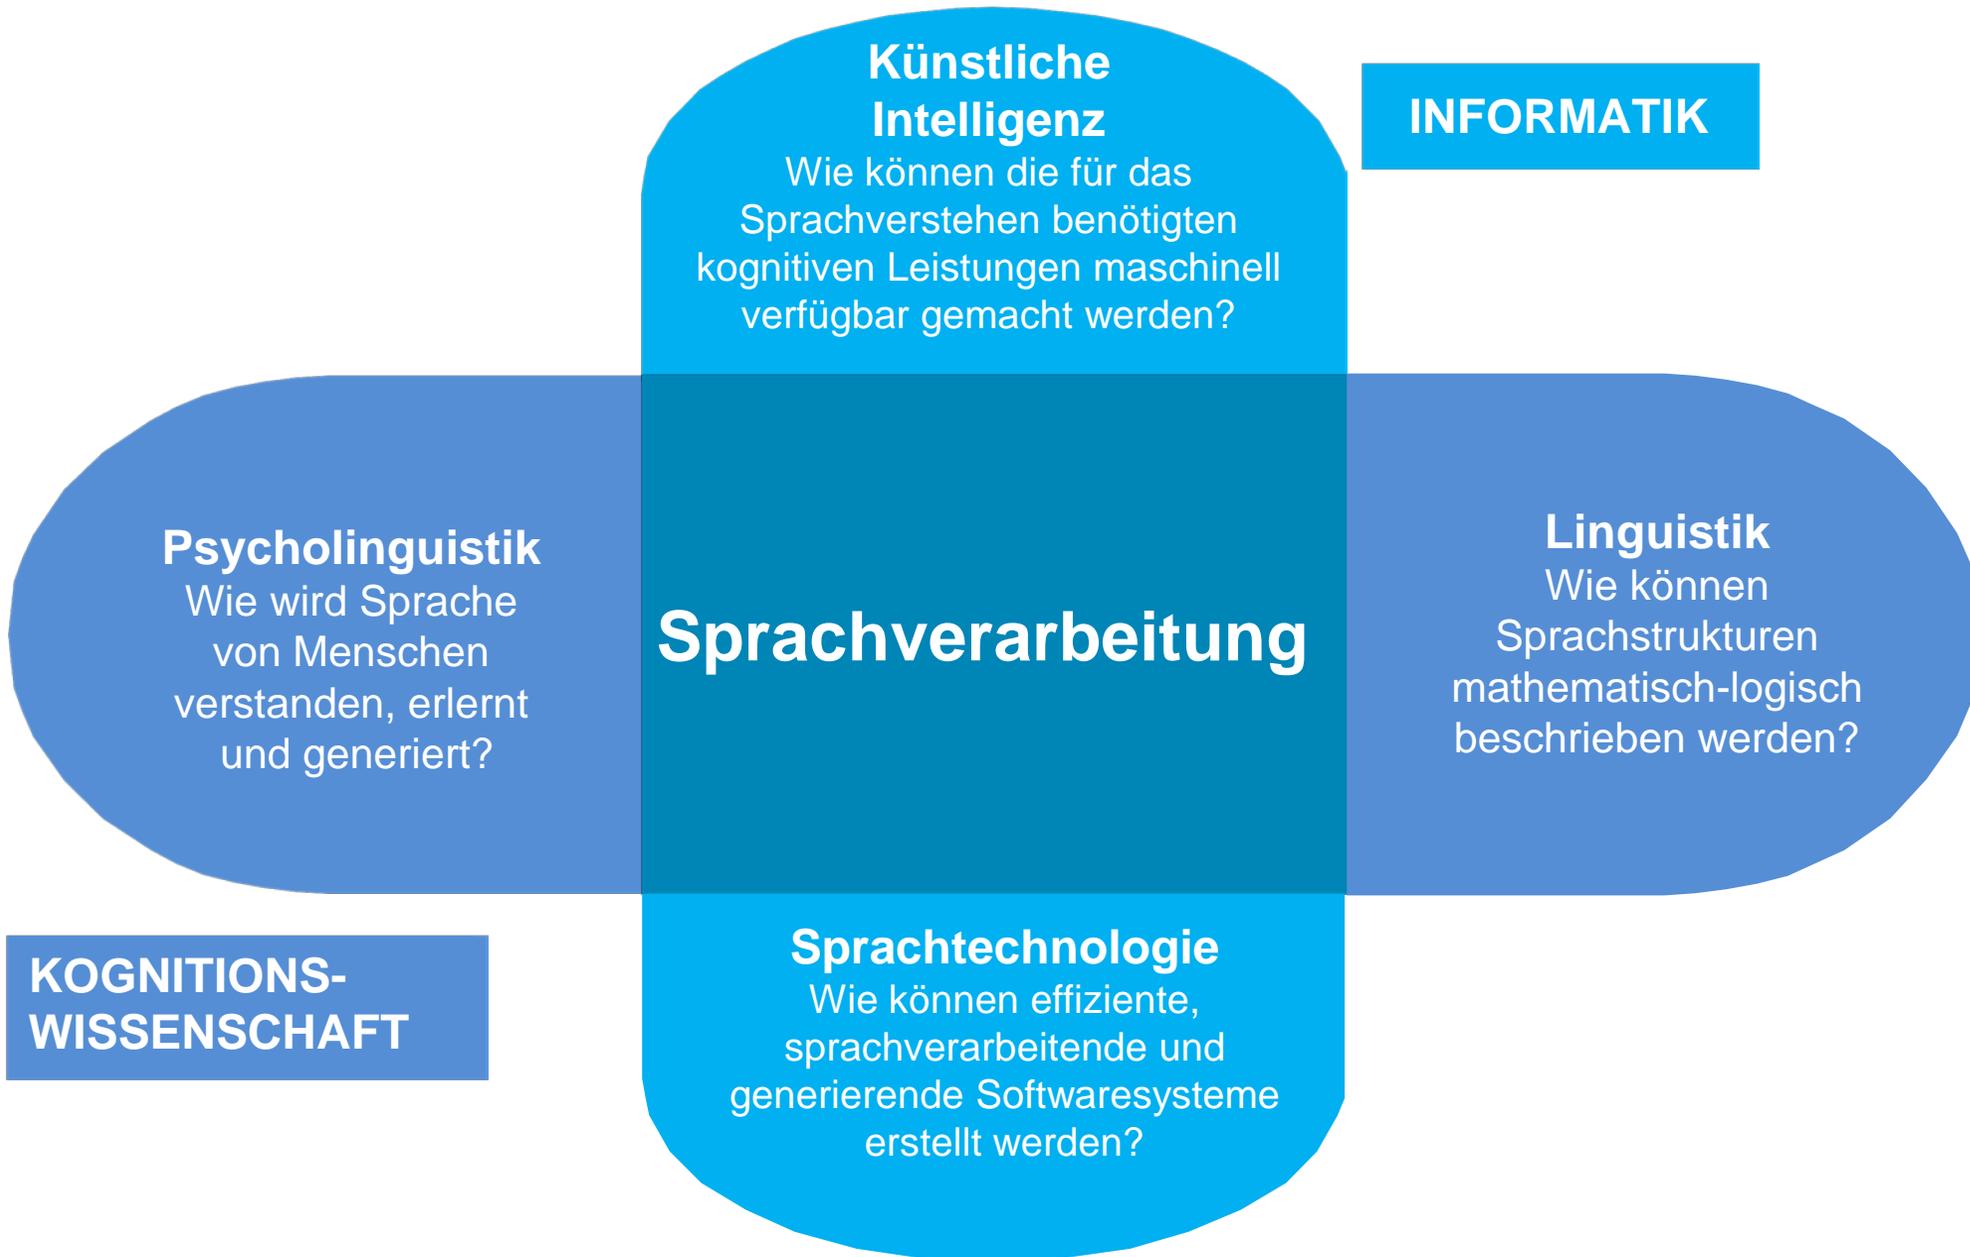
www.dfki.de/~wahlster

Sprachverhalten ist eine definierende Eigenschaft unserer Spezies

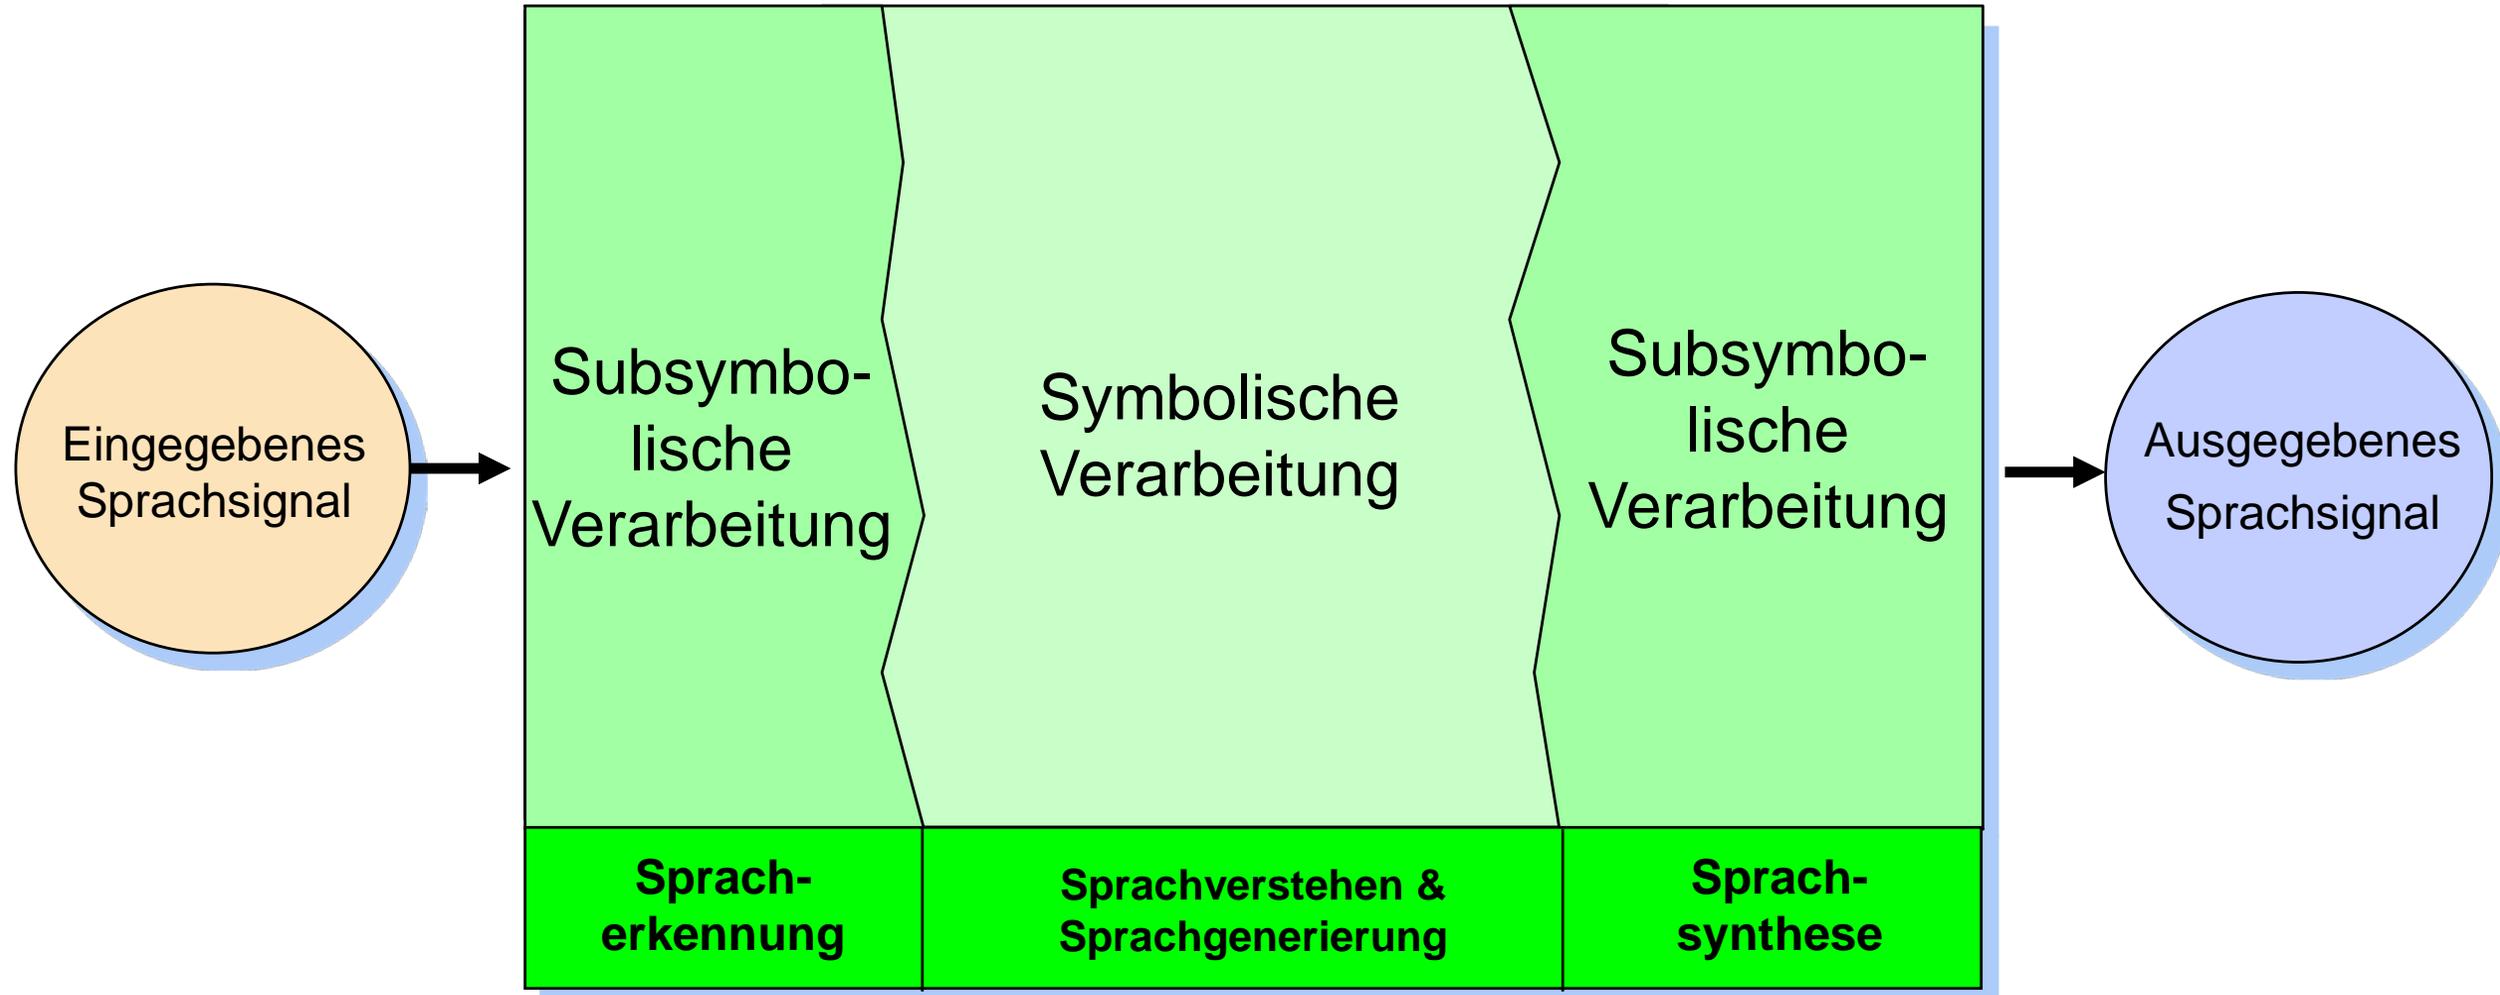
- Können Computermodele natürliches Sprachverhalten analysieren und simulieren?
- Können Computer zu echten Dialogpartnern werden?
- Kann der uralte Menschheitstraum, mit den Dingen sprechen zu können, mit Computern realisiert werden?



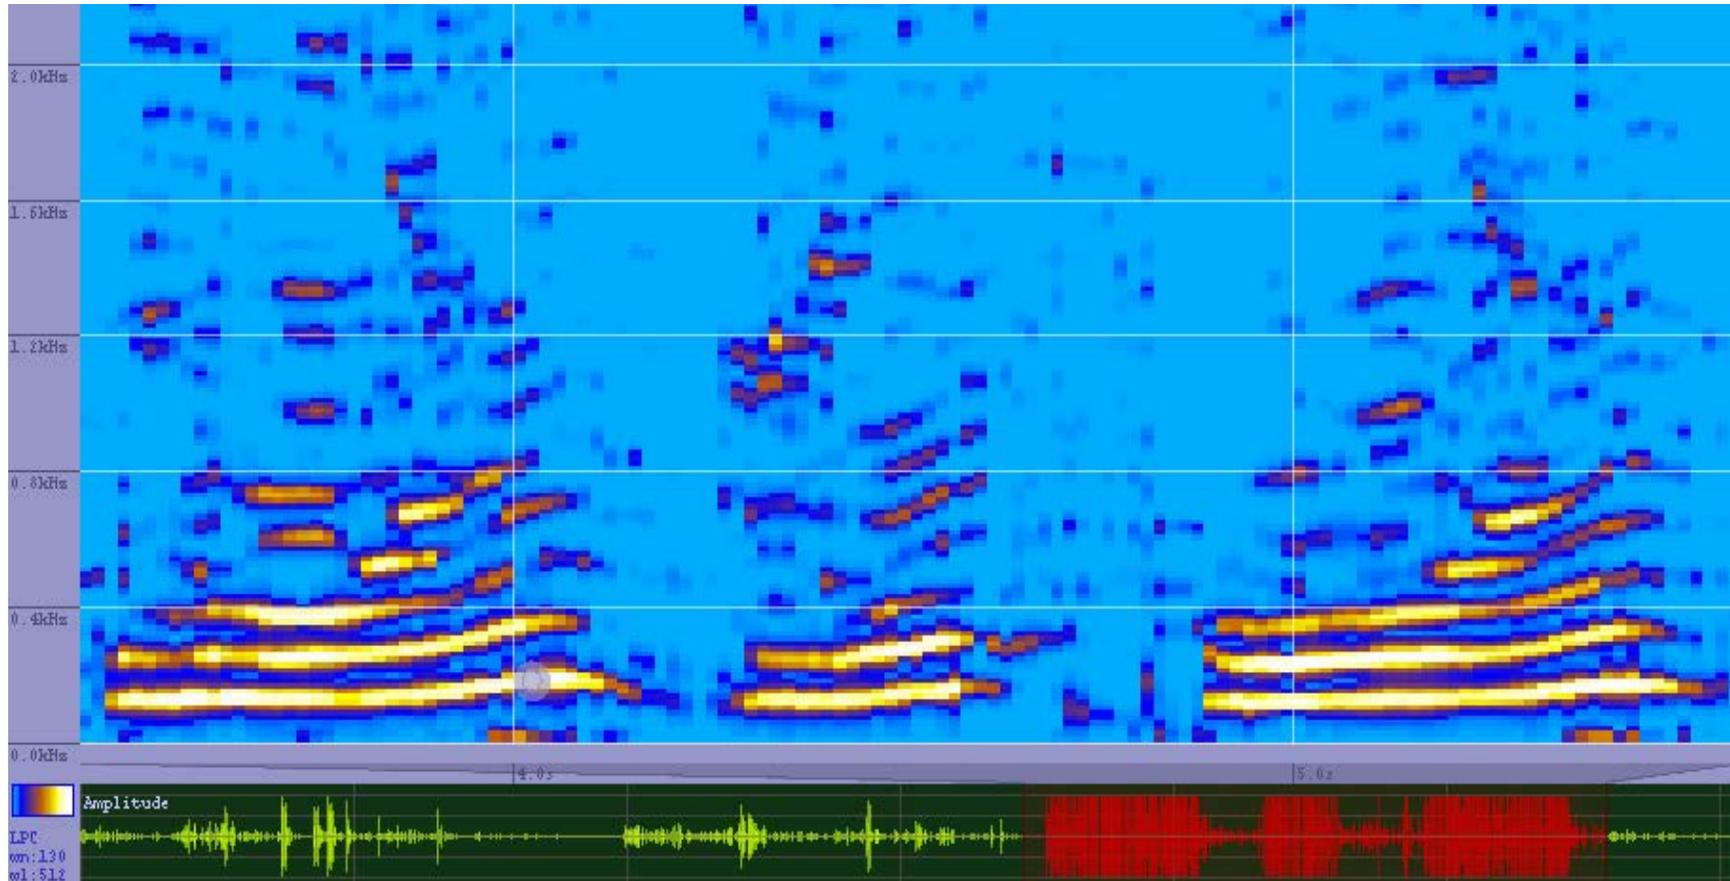
= eines der ehrgeizigsten wissenschaftlichen Ziele unseres Zeitalters



Signal-Symbol-Signal Transformation bei der Computermodellierung von Sprachdialogsystemen



Warum ist Sprachverstehen für den Computer so schwer?



Urlauber wollen wieder me:r ans me:r“

Warum ist Sprachverstehen für den Computer so schwer?

- ☞ **Gleiche Schallwellen werden je nach Kontext zu verschiedenen Wörtern**

Beispiel: „Urlauber wollen wieder me:r ans me:r“

→ Urlauber wollen wieder mehr ans Meer.

- ☞ **Viele Menschen sprechen Dialekt**

Beispiel: „Isch find das nätt“

Bedeutung (1) Ich finde das nett.

oder (2) Ich finde das nicht.

Warum ist Sprachverstehen für den Computer so schwer?

☞ **Wortgrenzen** gehen im Sprachfluß unter:

Beispiel: „amontag“ → „am Montag“

☞ Der Mensch spricht „**ohne Punkt und Komma**“

Beispiel: „So machen wir das vielleicht klappt es“

Bedeutung (1) So machen wir das. Vielleicht klappt es.

oder (2) So machen wir das vielleicht. Klappt es?

Warum ist das Sprachverstehen für den Computer so schwer?

- ➔ **Bei spontaner Rede entstehen viele Versprecher**

Beispiel: „Wir treffen uns dann am Mon, äh, am Dienstag.“

- ➔ **Dialogpartner fallen dem Sprecher oft „ins Wort“**

Beispiel: System: „Können wir dann am Mittwoch zum Essen...“

Sprecher: „Da kann ich nicht.“

Warum ist das Sprachverstehen für den Computer so schwer?

☞ **Der Redefluß leitet häufig in die Irre**

Beispiel: „Die Staatssekretärin lobt... der Ministerpräsident.“

~~Subjekt: Staatssekretärin Prädikat: lobt Objekt: ??~~

Subjekt: Ministerpräsident Prädikat: lobt Objekt: Staatssekretärin

☞ **Viele Formulierungen sind mehrdeutig**

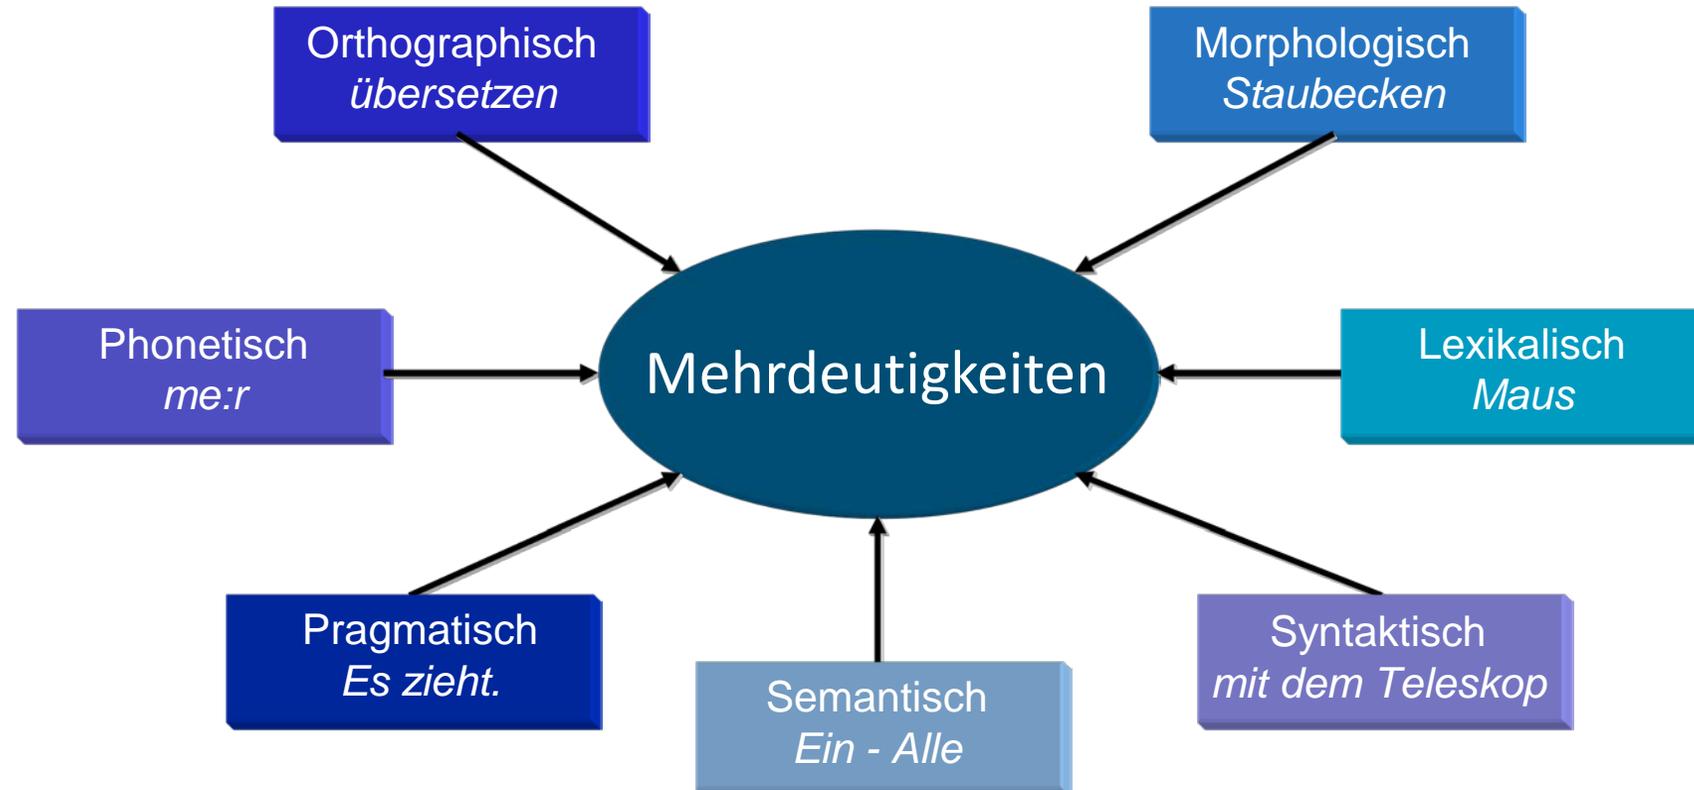
Beispiel: „Wir telefonierten mit Freunden in Japan.“

Bedeutung (1) Wir telefonierten (mit Freunden in Japan).

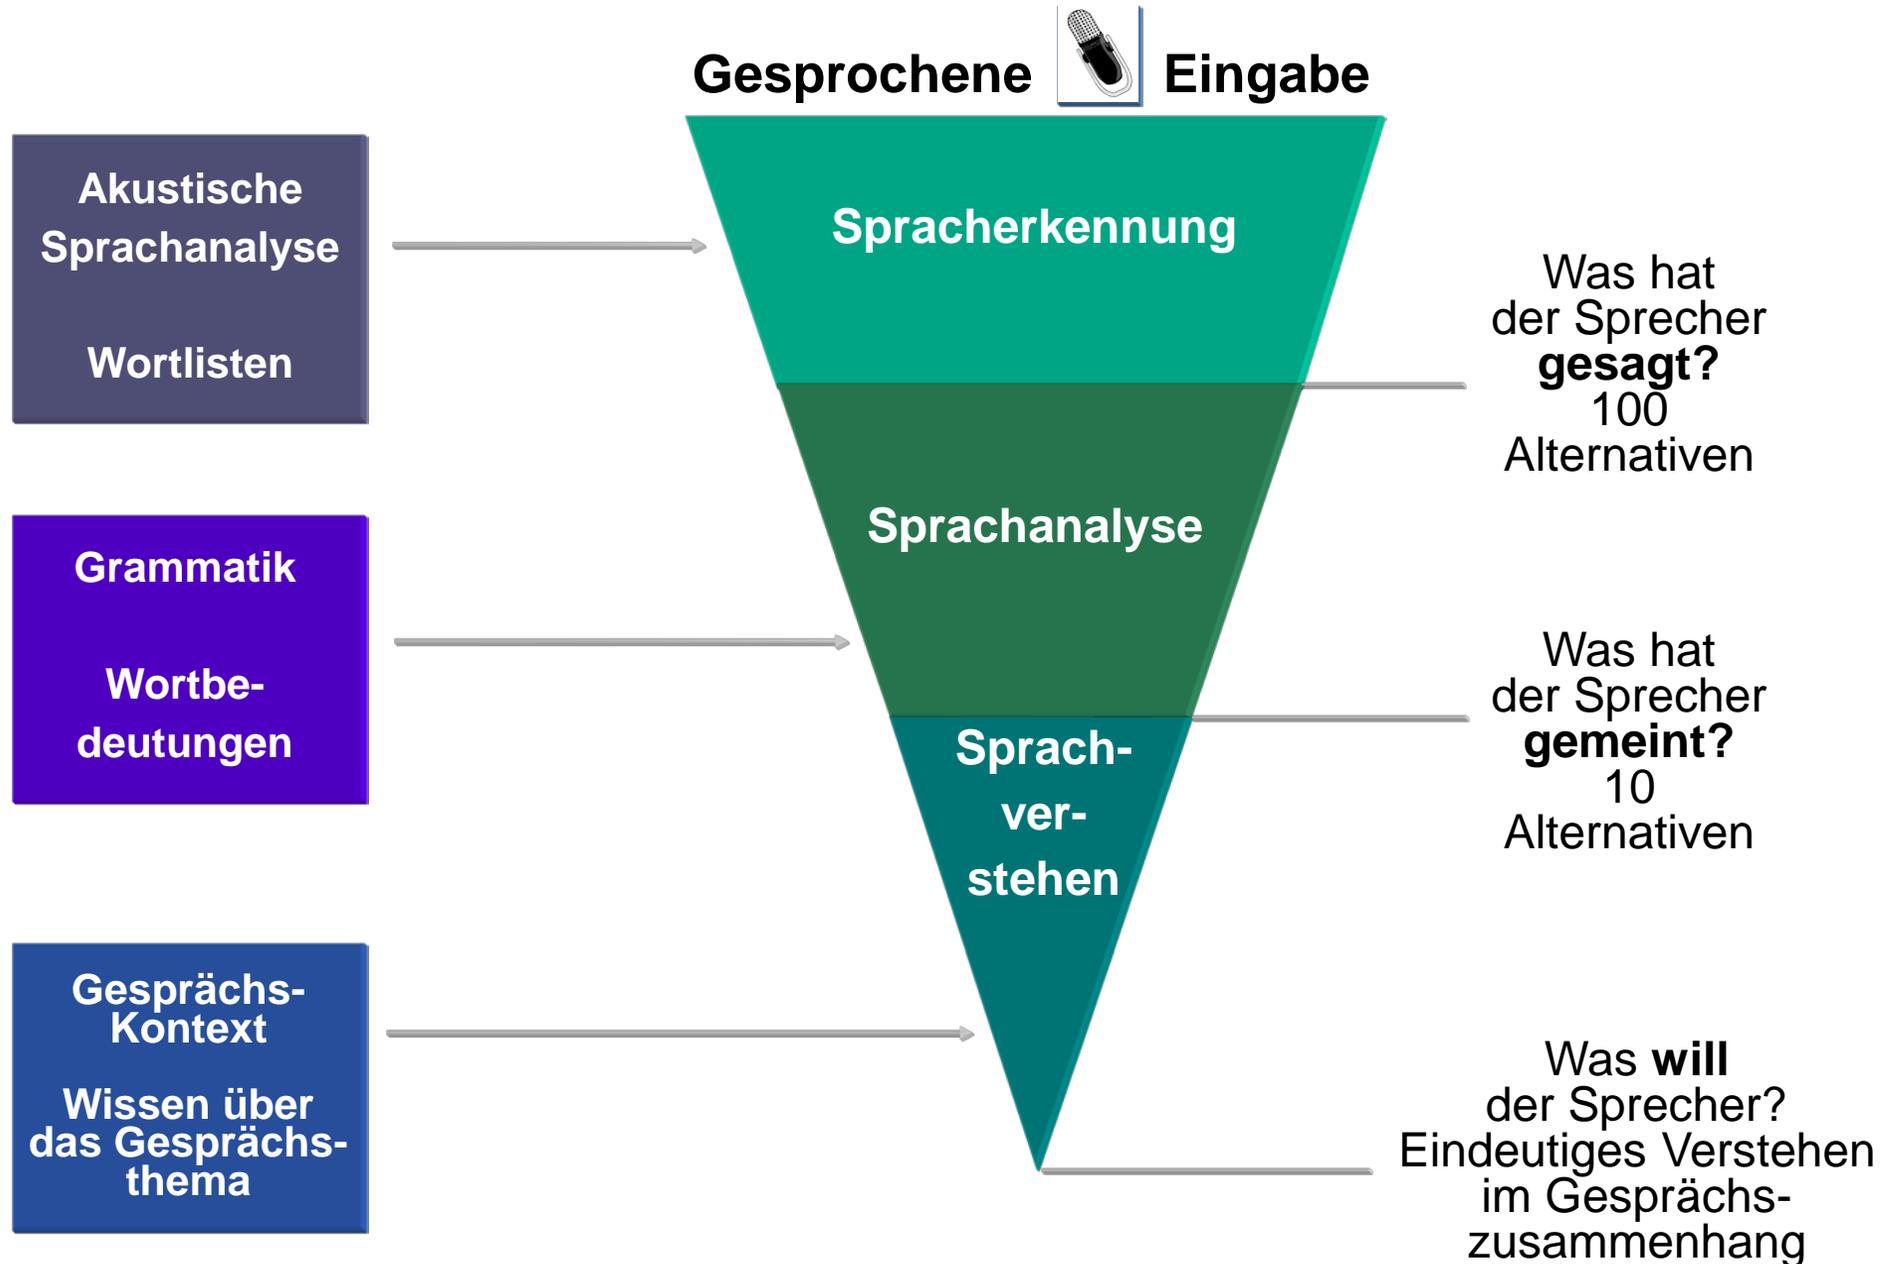
oder (2) (Wir telefonierten mit Freunden) in Japan.

Auflösung mehrdeutiger sprachlicher Äußerungen

- Problem der kombinatorischen Explosion der Lesarten durch Propagierung von Alternativen über alle Verarbeitungsebenen
- Durch die Unsicherheit bei der Spracherkennung entstehen Wörtergitter mit alternativen Hypothesen, welche die Flut von Lesarten noch weiter erhöhen



Drei Stufen der Sprachverarbeitung



Reduktion von Unsicherheit

Von der Eingabeschallwelle zur Ausgabeschallwelle



Verbmobil: Dialogdolmetschen von Spontansprache in der Reisedomäne

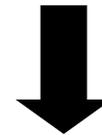


Automatisches Verstehen und Korrigieren von Versprechern in spontanen Telefondialogen



Wir treffen uns in
Mannheim, äh,
in Saarbrücken.

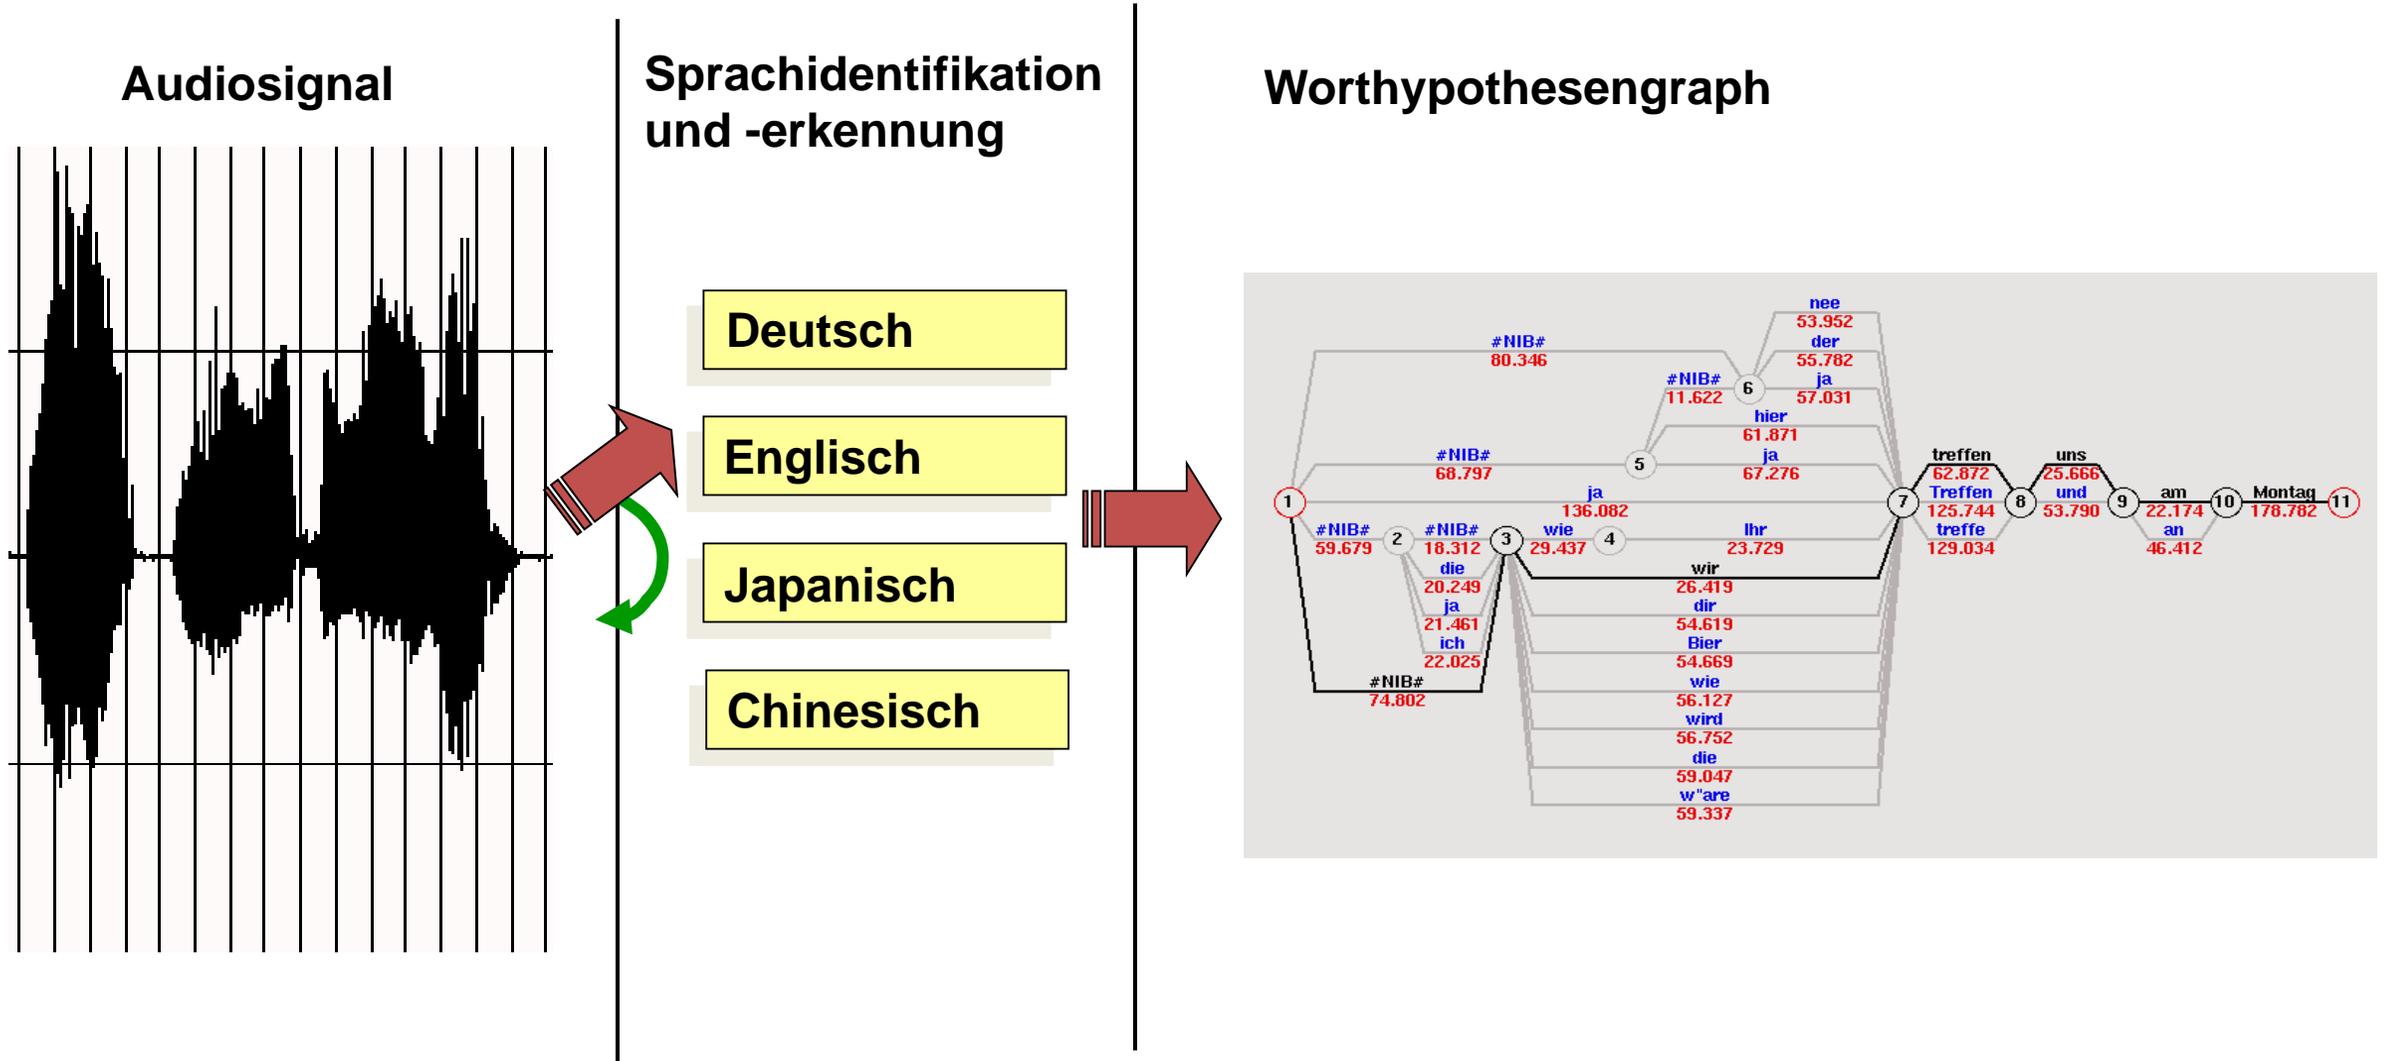
Deutsch



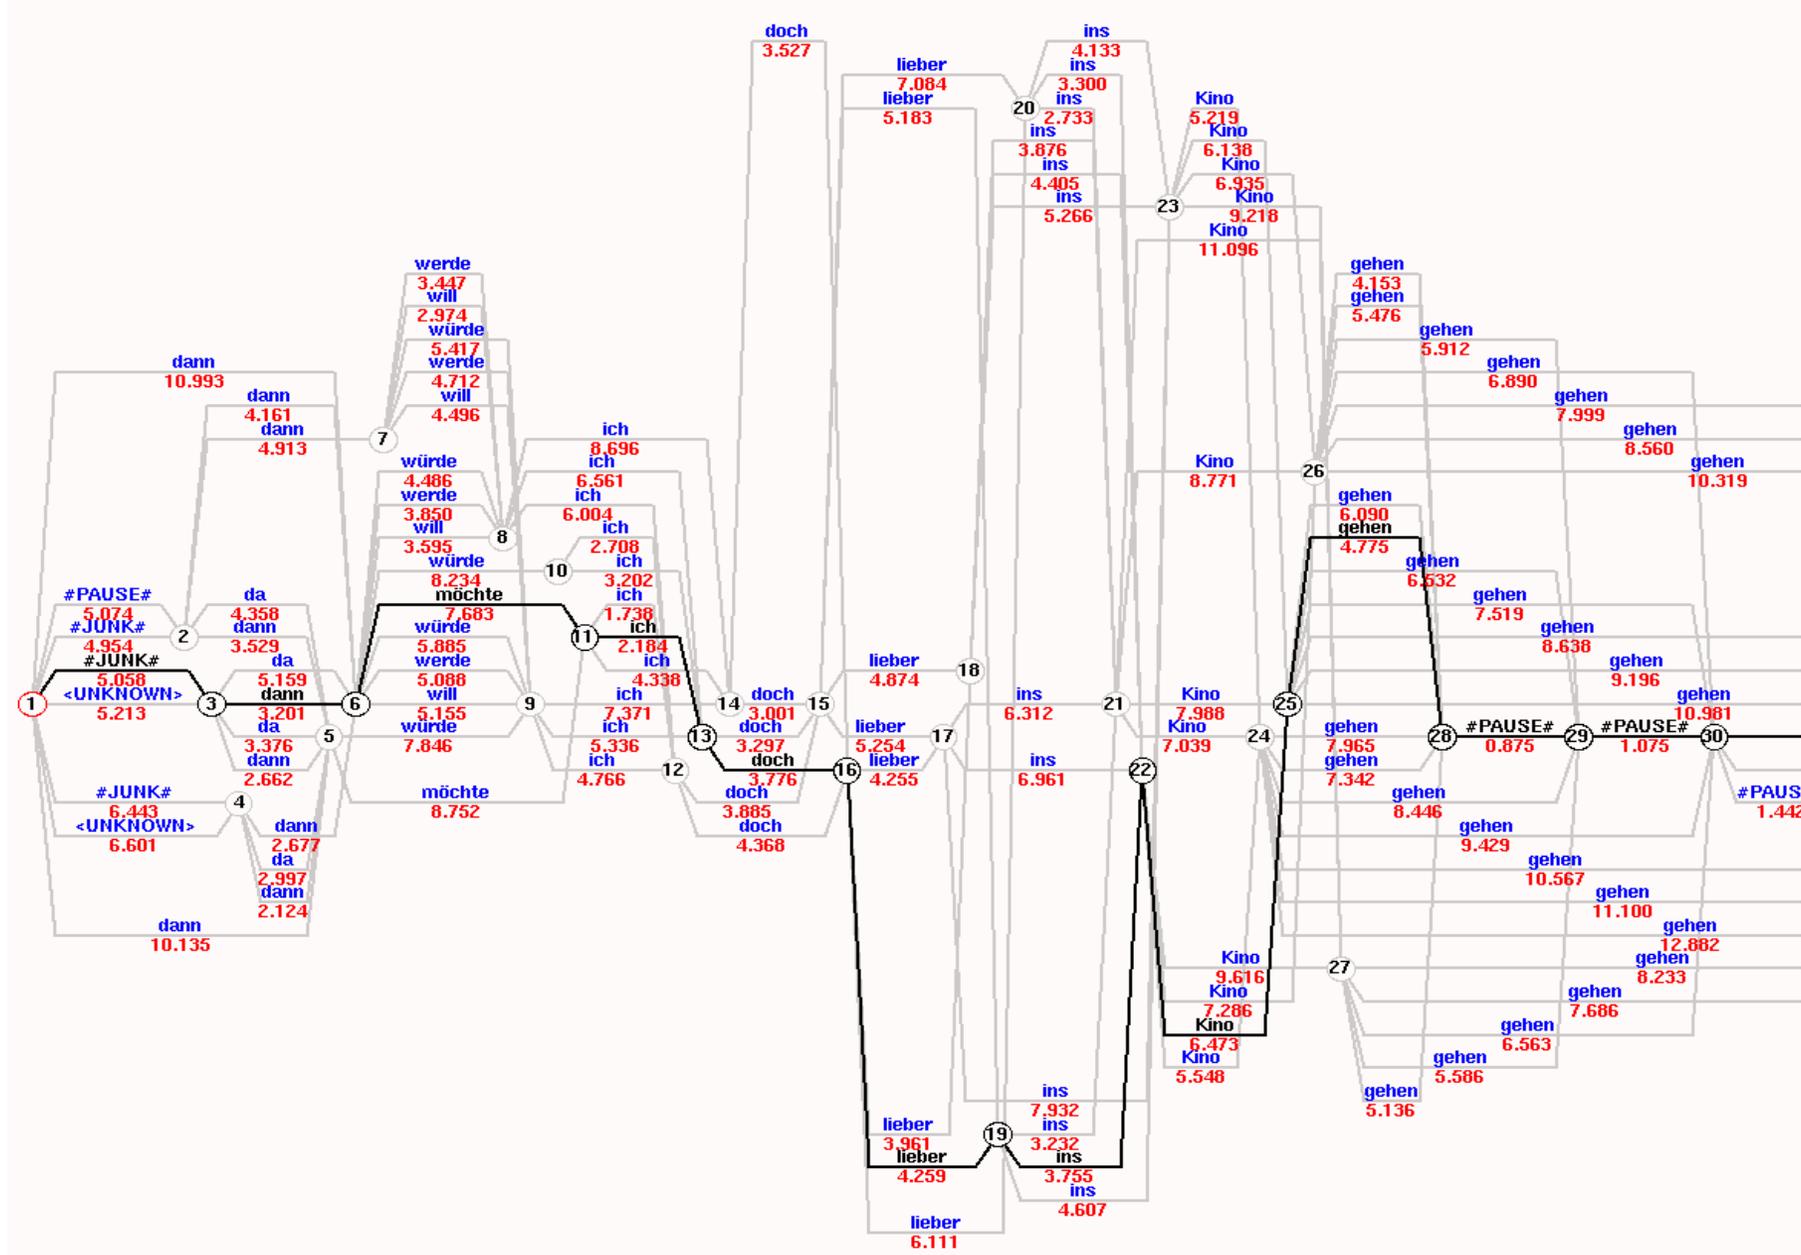
Englisch

We are meeting
in Saarbruecken.

Spracherkennung: Vom Signal zur Worthypothese



Unsicheres Ergebnis der Spracherkennung



Weltwissen im ComputermodeLL für die maschinelle Bedeutungsanalyse

Vater zu einem Service-Roboter im Cyber-Restaurant:

(1) Die **Apfelschorle** trinkt meine **Tochter**, die **Weinschorle** meine **Frau**.

(A) trinkt (Agens: **Apfelschorle**, Objekt: **Tochter**) \wedge
trinkt (Agens: **Weinschorle**, Objekt: **Frau**)

Weltwissen: **Apfelschorle**, **Weinschorle** \sqsubseteq Getränk
Tochter, **Frau** \sqsubseteq Mensch

Selektionsrestriktion: trinkt (Agens: Mensch, Objekt: Getränk)

(B) trinkt (Agens: **Tochter**, Objekt: **Apfelschorle**) \wedge
trinkt (Agens: **Frau**, Objekt: **Weinschorle**)

Semantische Präzisierung durch Situationswissen

Lassen Sie uns zusammen **Essen** gehen!

Referenzzeit:

< 13.00Uhr

> 15.00 Uhr

Let's have **lunch** together!

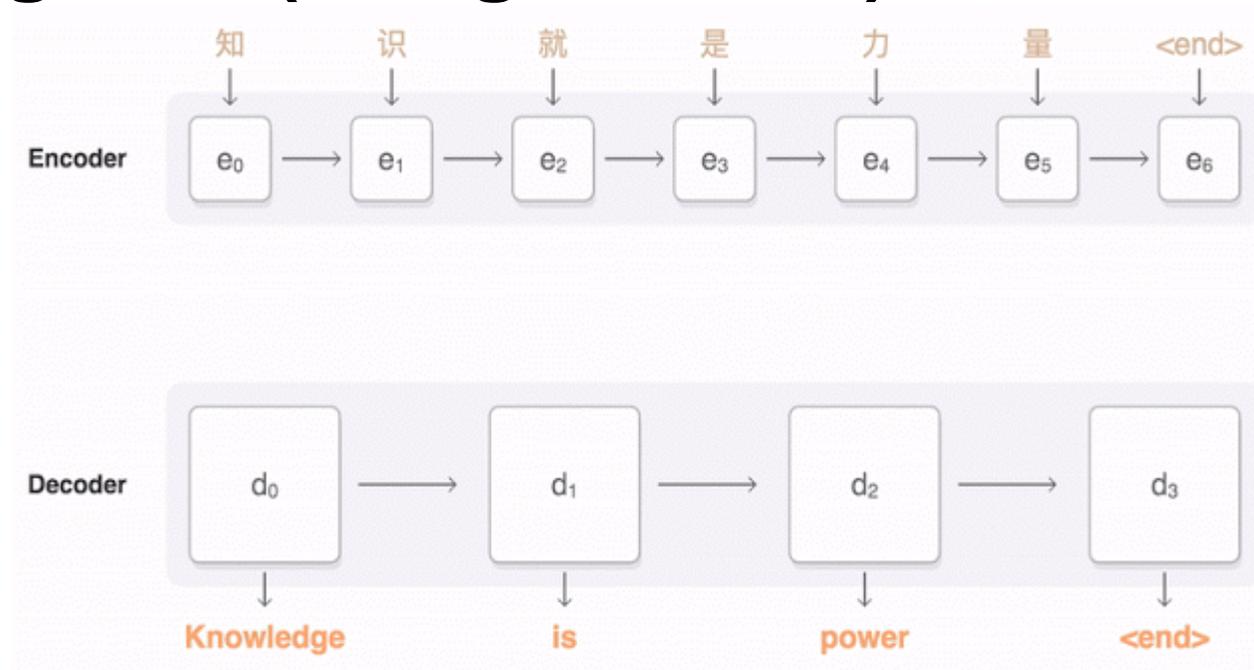
Let's have **dinner** together!

Berücksichtigung des Kontextes und von Weltwissen beim Semantischen Transfer

Beispiel: Platz → room / table / seat

- 1 Nehmen wir dieses Hotel, ja. → Let us take this hotel.
Ich reserviere einen **Platz**. → I will reserve a **room**.
- 2 Machen wir das Abendessen dort. → Let us have dinner there.
Ich reserviere einen **Platz**. → I will reserve a **table**.
- 3 Gehen wir ins Theater. → Let us go to the theater.
Ich möchte **Plätze** reservieren. → I would like to reserve **seats**.

Ende-zu-Ende-Lernen für die neuronale Übersetzung: Chinesisch-Englisch (Google GNMT)



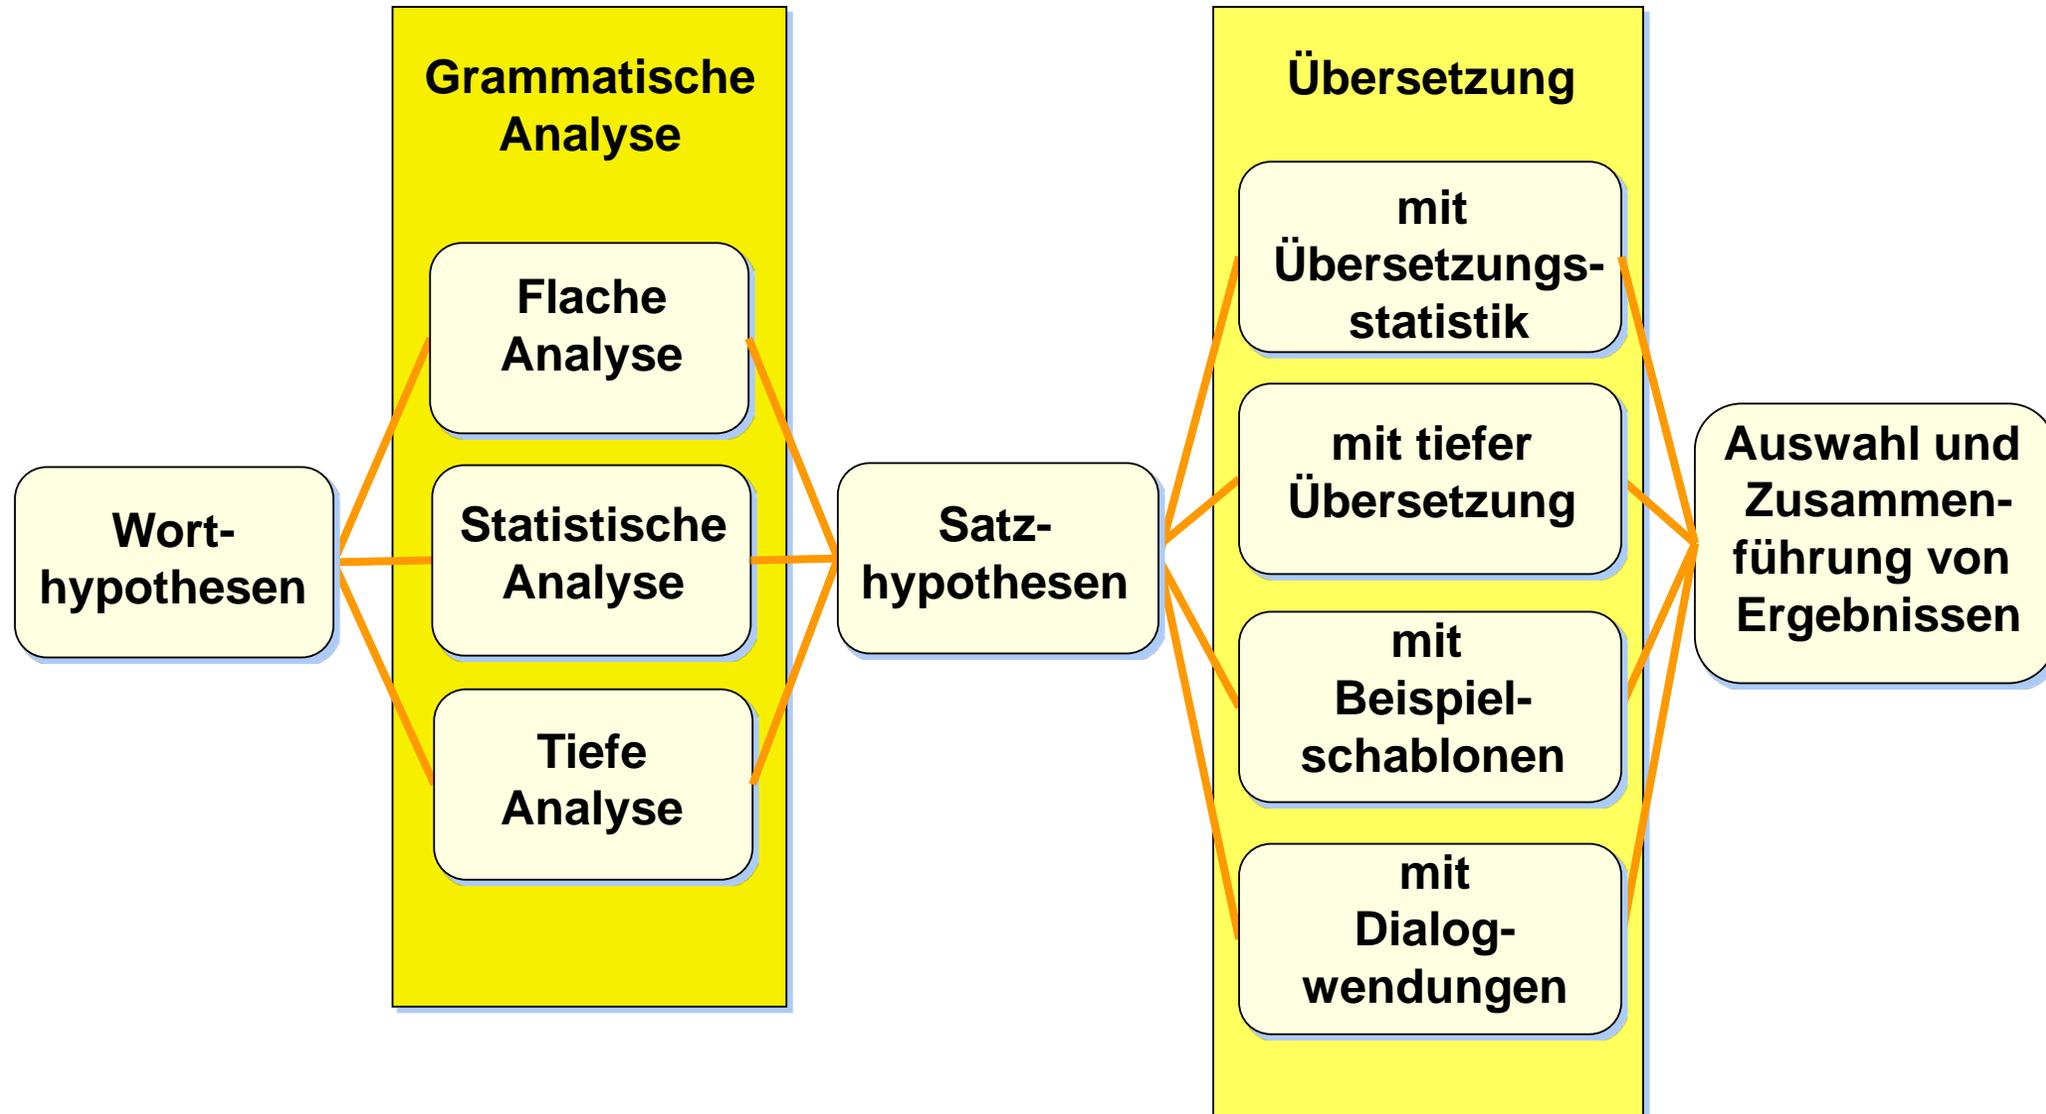
NMT analysiert die Eingabe als Ganzes und behält alle Wörter und Phrasen im Blick.

Dazu kodiert das Übersetzungssystem zuerst die chinesischen Wörter in eine Liste von Vektoren, in der jeder Vektor die Bedeutung aller bis dahin gelesenen Wörter repräsentiert (**Encoder**).

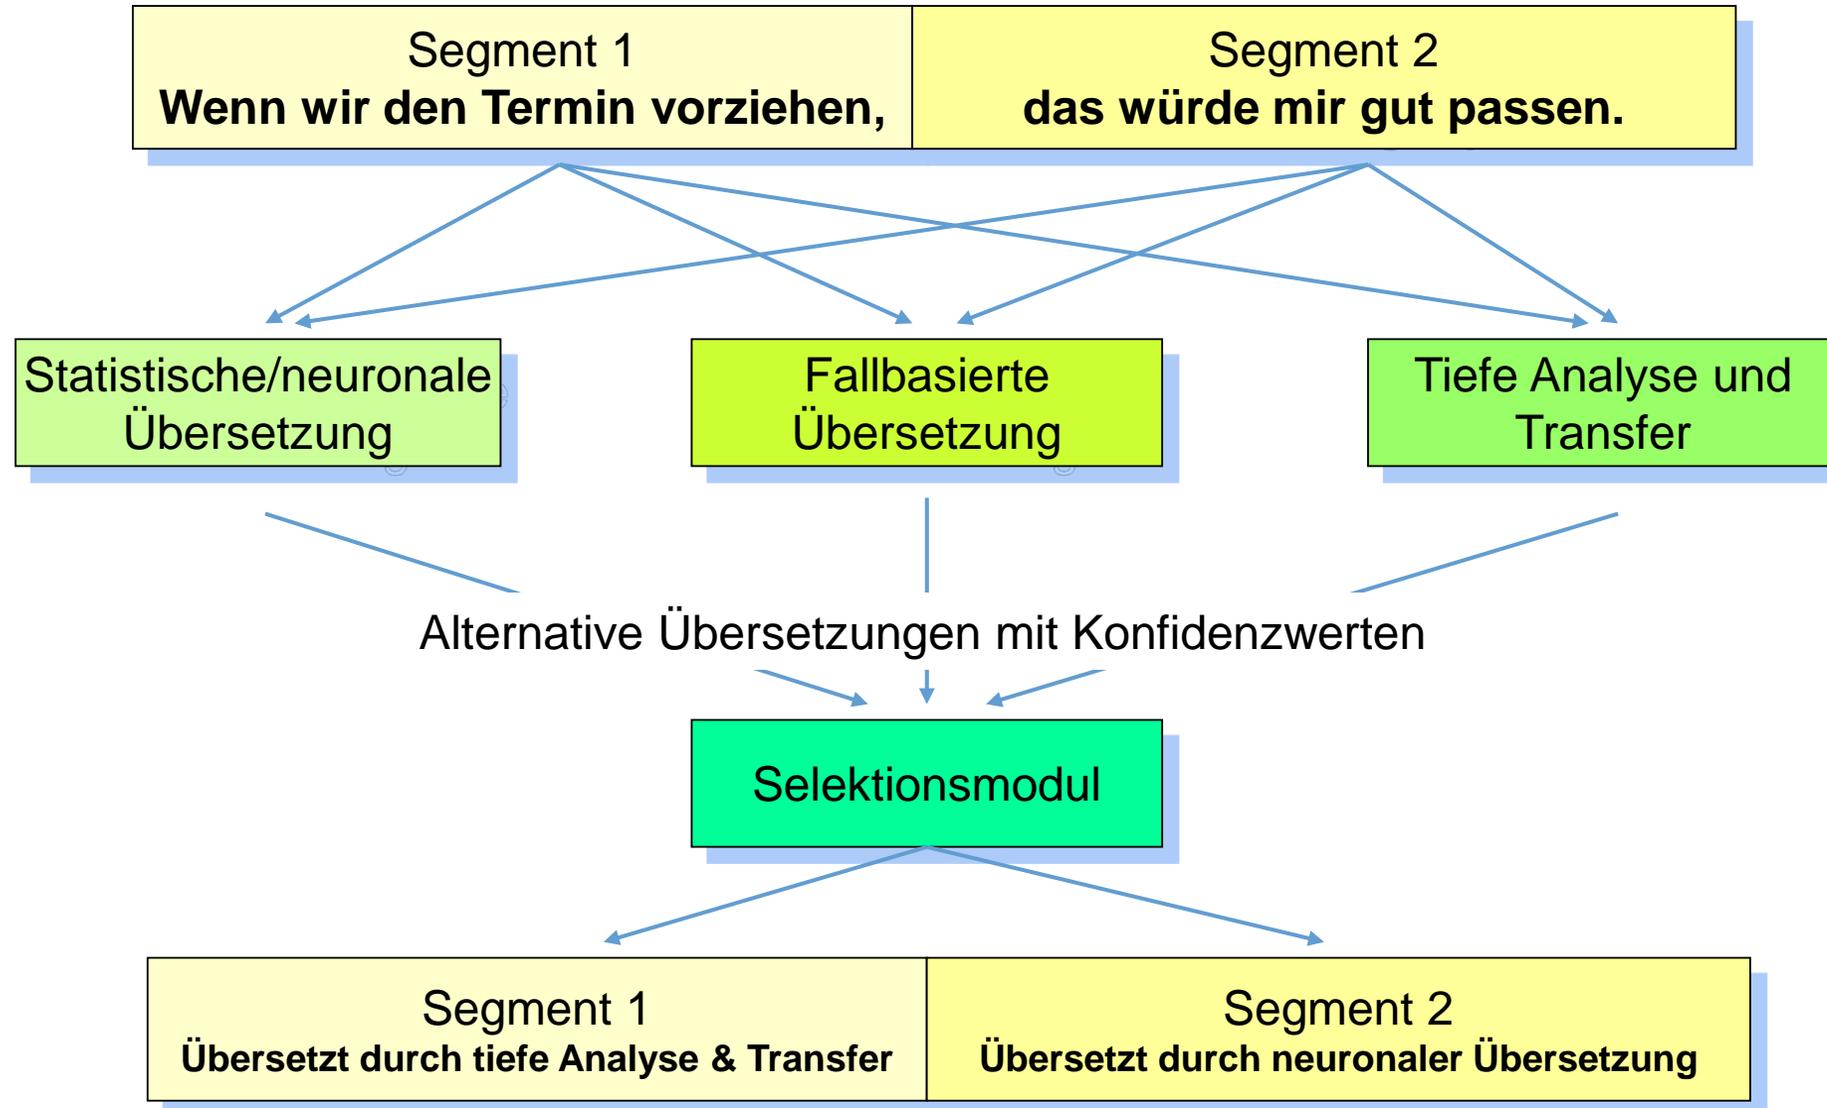
Danach wird der englische Satz wortweise generiert (**Decoder**).

Dabei achtet der Decoder auf eine gewichtete Verteilung der kodierten chinesischen Vektoren, die am wichtigsten zur Generierung der englischen Entsprechung sind (**Attention**).

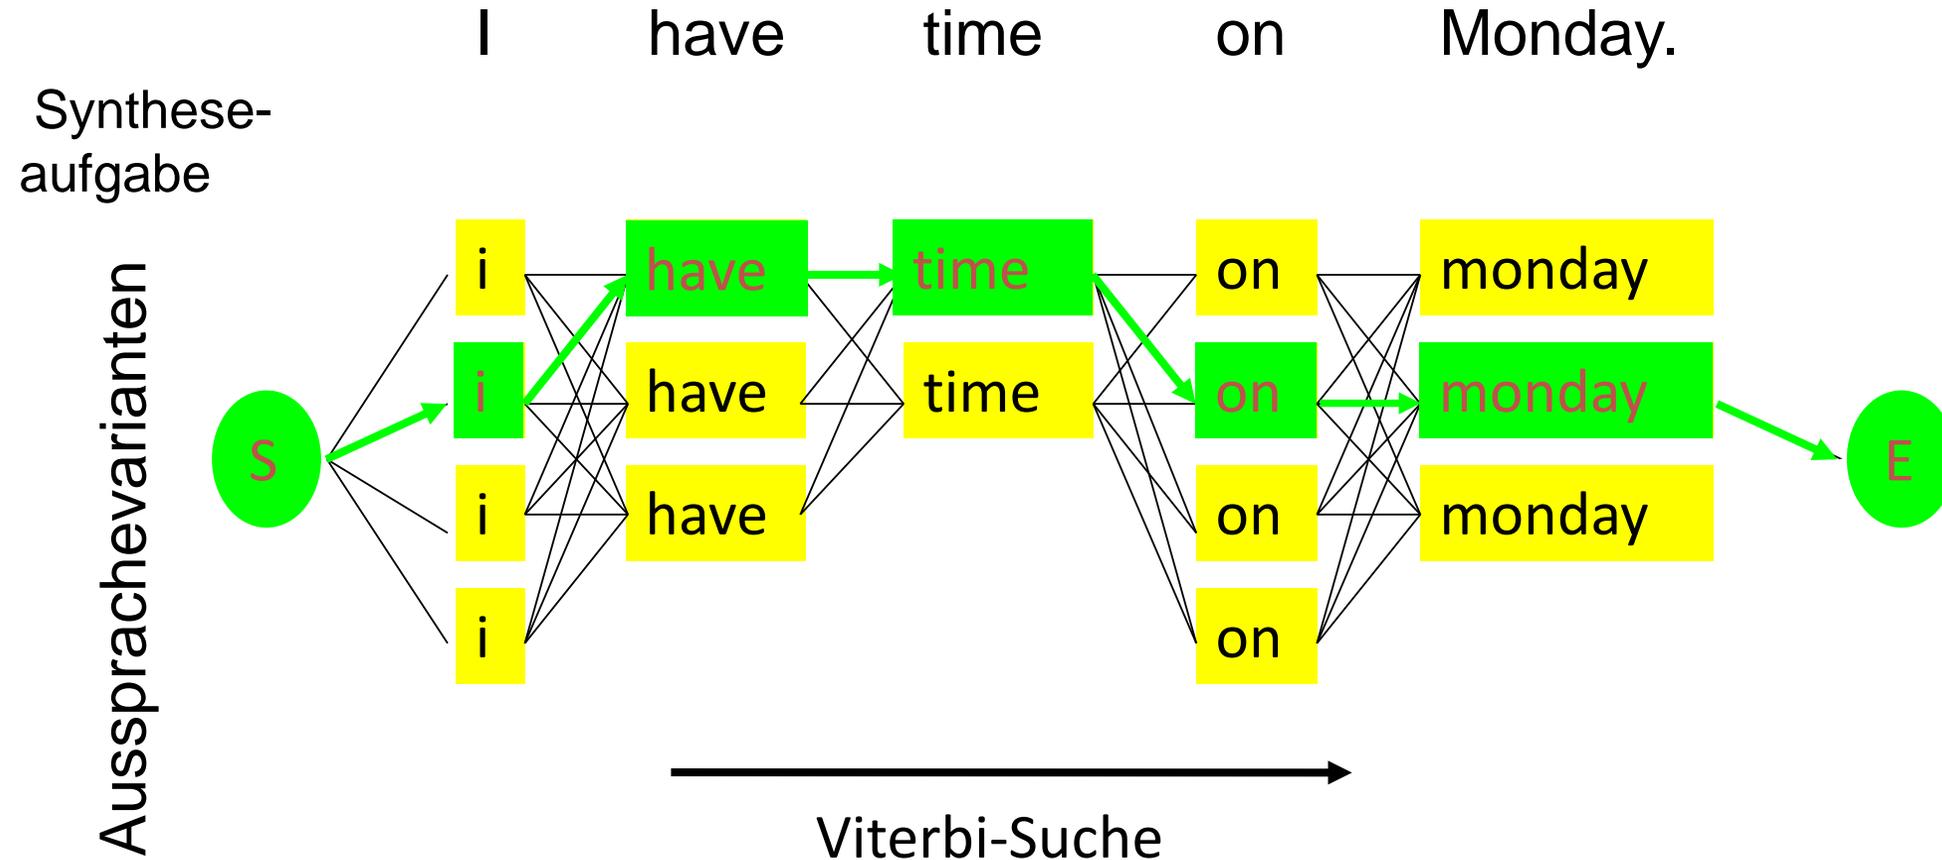
Zusammenführung von flacher und tiefer Sprachverarbeitung in Verbmobil



Die Kombination von Segmentübersetzungen aus einem Mix an Übersetzungsverfahren



Corpus-basierte Sprachsynthese



Dynamische Auswahl von Aussprachevarianten für Wörter je nach Funktion im Satz

Anthropomorphe Objekte: Sprechende Produkte



Durch Künstliche Intelligenz mit allen Sinnen ins Internet



Sprache



Blickbewegung



Gestik



Biometrie



Physische Aktion



Körperhaltung

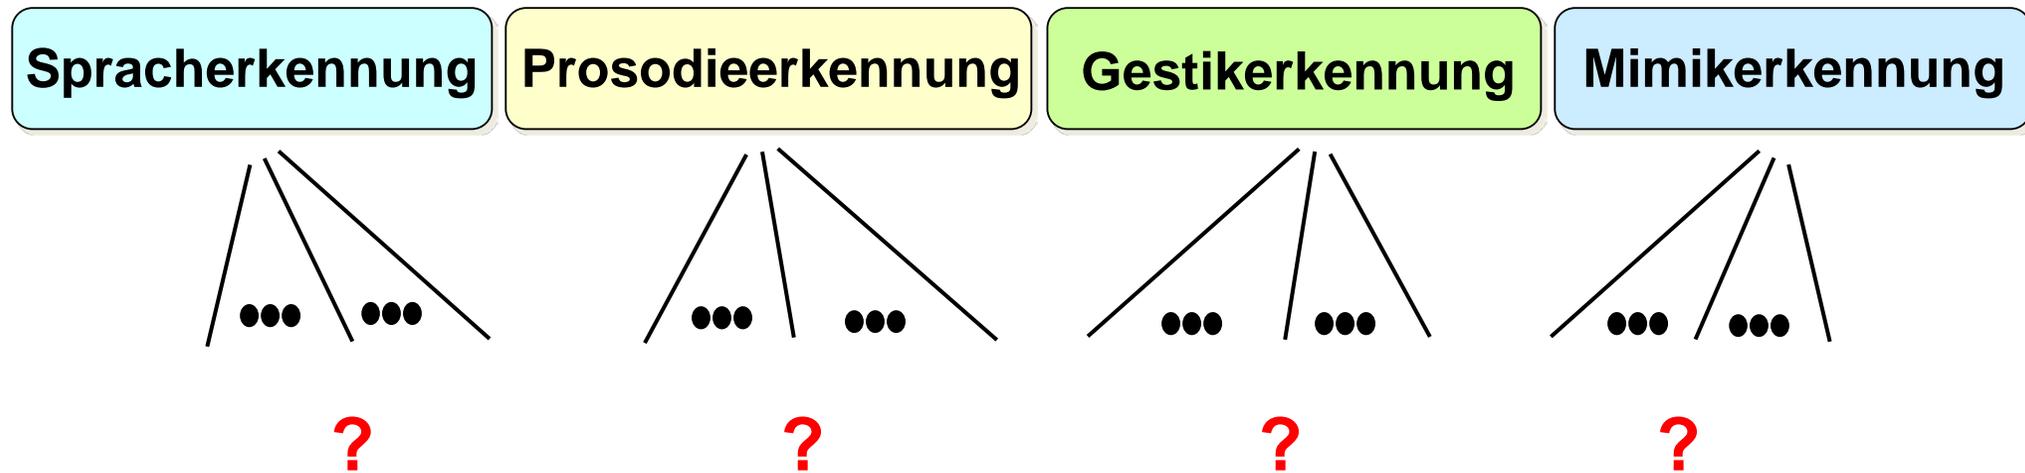


Mimik

Multimodale Interaktion

Die Fusion multimodaler Eingaben

Multiple Modalitäten erhöhen die Interpretationsunsicherheit

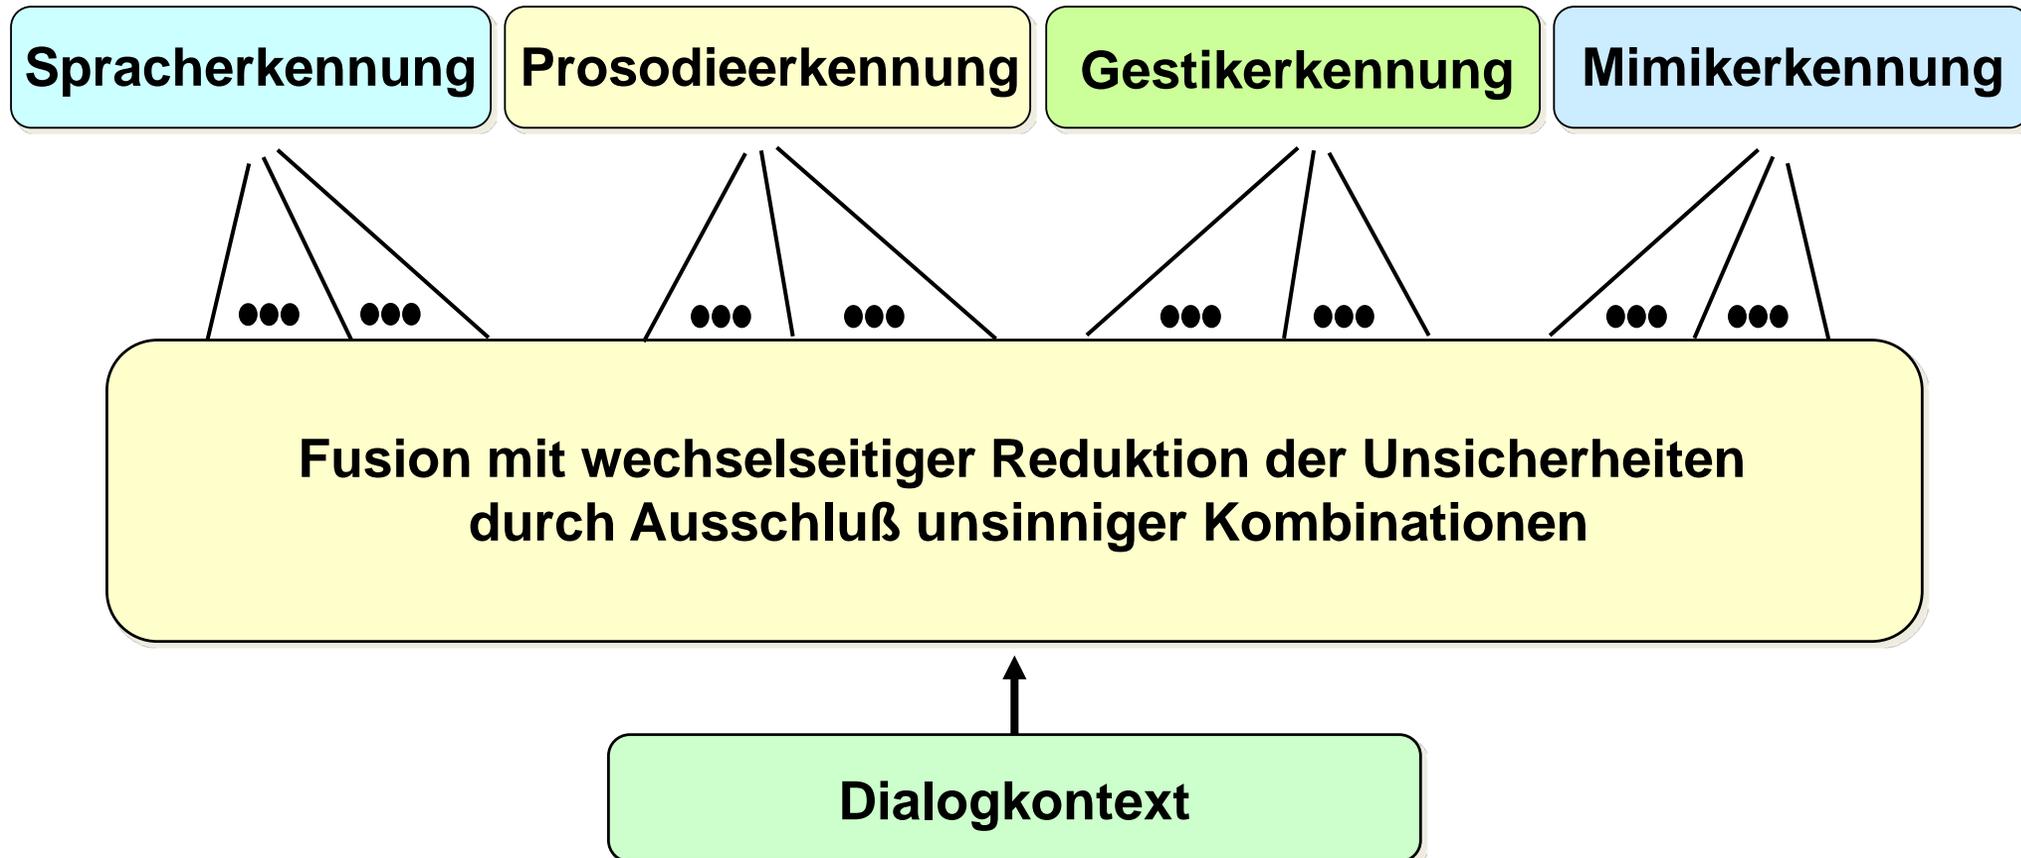


Unsicherheiten bei der Signalinterpretation
in perceptiven Benutzerschnittstellen

Die Fusion multimodaler Eingaben

Multiple Modalitäten erhöhen die Interpretationsunsicherheit

aber: die semantische Fusion multipler Modalitäten macht die Interpretation im Kontext eindeutig

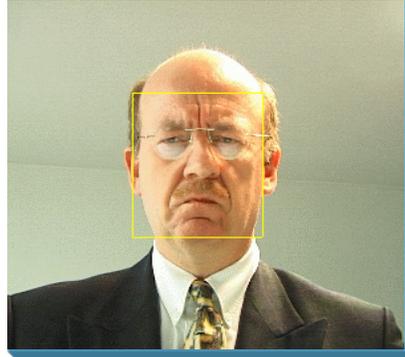


Fusion von Sprach- und Mimikerkennung

Modifikation der Standardsemantik (Ironie, Sarkasmus)

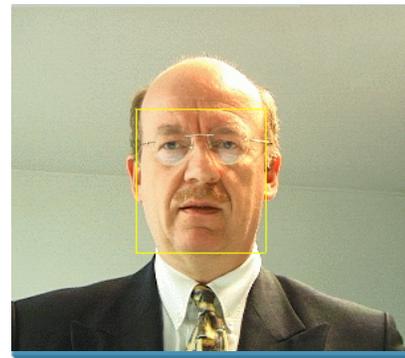
(1) System: : Hier sehen Sie die Übersicht zum heutigen ZDF-Programm.

(2) Benutzer: Echt toll.



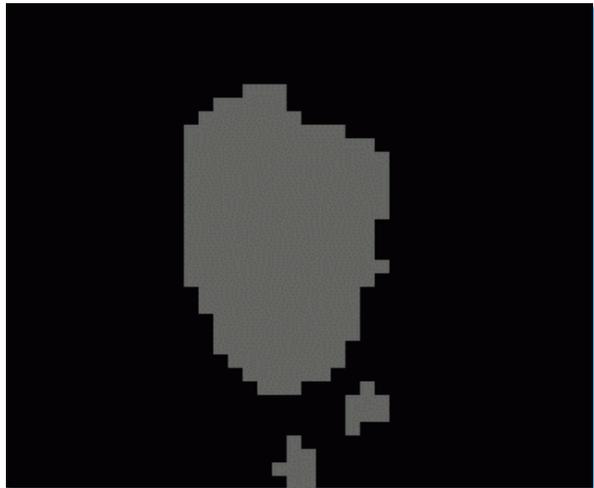
(3) System: Ich zeige Ihnen alternativ das Programm eines anderen Senders.

(2') Benutzer: Echt toll.



(3') System: Welche Sendungen wollen Sie aus dem ZDF-Programm sehen oder aufzeichnen?

Videobasierte Mimikerkennung auf der Basis von Eigenfaces



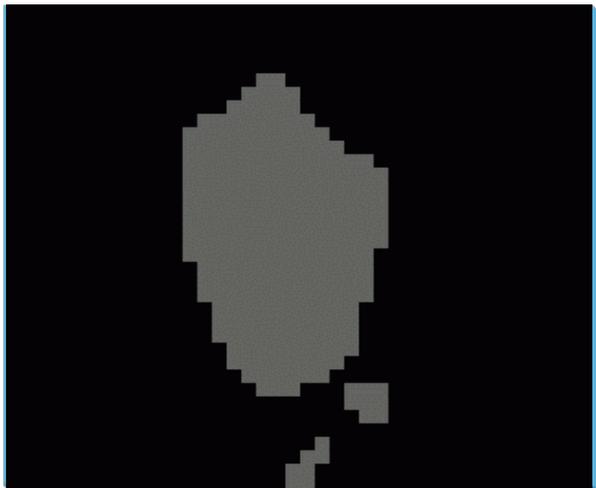
neutral




ärgerlich



Sprecherunabhängige Emotionserkennung



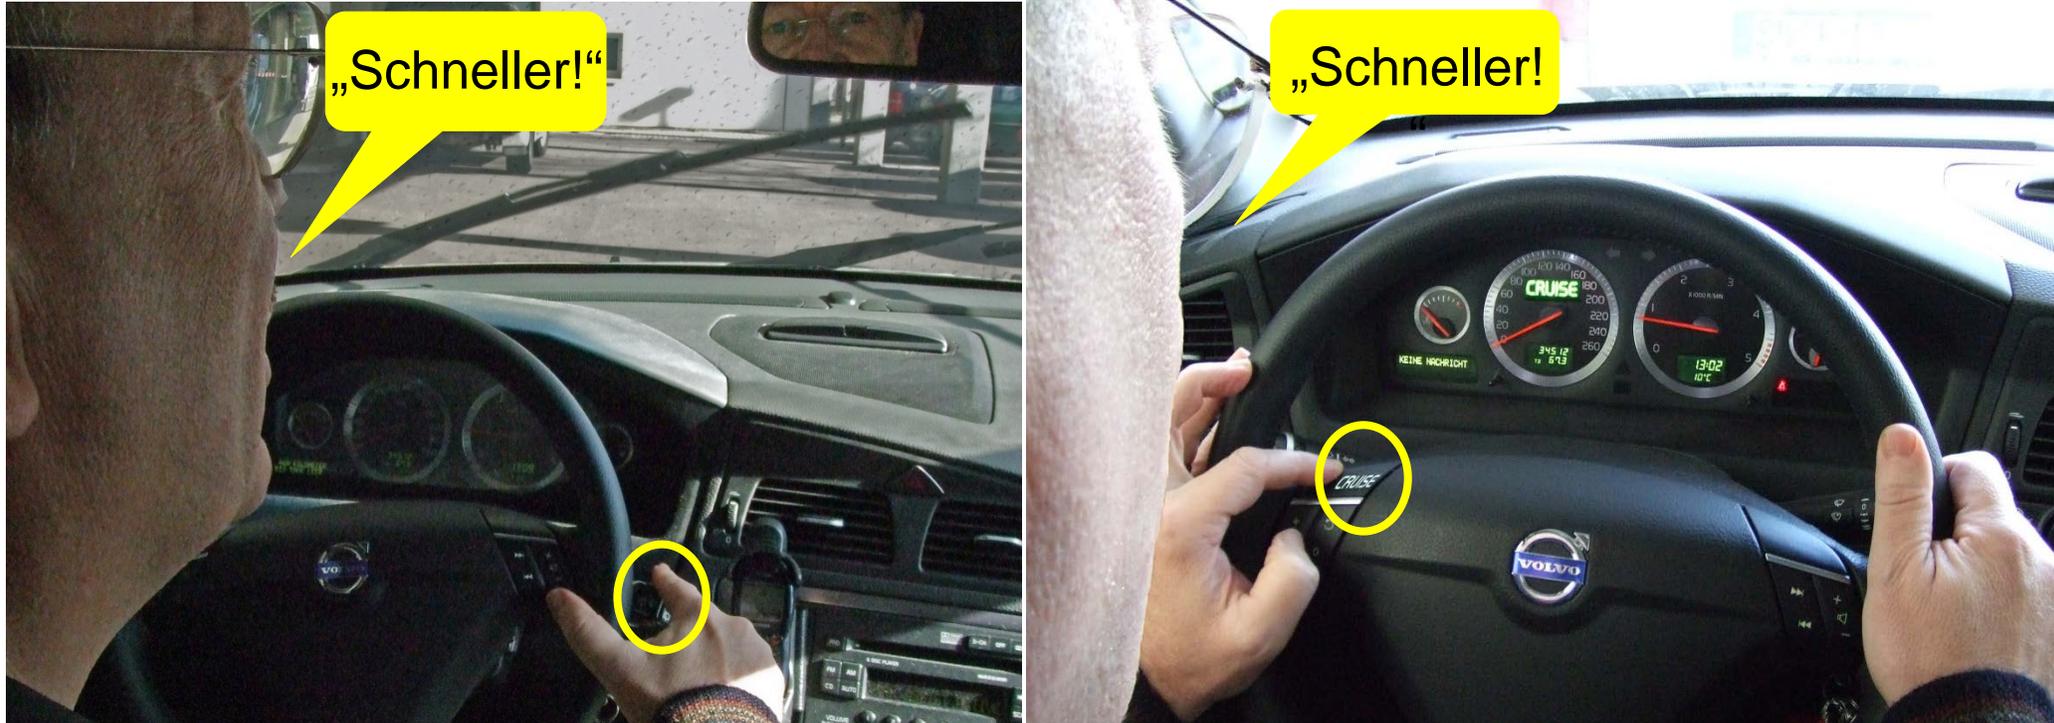
□
neutral



■
ärgerlich



Kombination von Sprache und Aktionskontext



Interpretation und Disambiguierung von multimodalen Äußerungen:
Auswahl der **Scheibenwischer**geschwindigkeit vs. wechseln der
Tempomateeinstellung

Multimodale Fahrereingaben: Sprache und Blickbewegung



**Korrekturdialog während der Fahrt in unserem Twitter4Car
in unserem DFG-Exzellenzcluster
Multimodal Computing and Interaction**

TALK: Robuste Semantische Sprachdialogverarbeitung im BMW



Sprachdialog mit einem iPhone in TEXO-Theseus zur Selektion von Webdiensten



Künstliche Intelligenz für unterwegs: Persönliche digitale Assistenten auf SmartPhones



Apple: Siri



Google: Assistant



Microsoft: Cortana



Samsung: Viv

2007 in Deutschland: Siri-Urversion SmartWeb vom DFKI mit Telekom und Siemens (Ende Handy-Sparte 2005)

Hololens 2016 für freihändige Assistenzfunktionen



Blindtest unserer Antwortmaschine SmartWeb als Super-Siri



Noch nie gehörte Frage: „Wer hat bei den Salzburger Festspielen letztes Jahr die Premiere in La Traviata gesungen?“ wird von SmartWeb verstanden und eine Antwort für 2007 wird aus Dokumenten im Internet gefunden.

Künstliche Intelligenz für die gesamte Familie zuhause



Amazon: Echo - Alexa



Google: Home



Jibo (mit Kamera)

- Funktionen: Steuerung der SmartHome-Funktionen, Einkaufslisten, Bestellungen, Zugriff auf Wissensbank mit Nachfragen, Terminverwaltung, Musik- und Videosuche
- 7 Offene **Fernfeldmikrophone** (abschaltbar), KI-Funktionen über **Cloud-Zugriff**
- Adaption durch **maschinelles Lernen** an die einzelnen Familienmitglieder


VirtualHuman: Mehrpersonenkommunikation mit komplexen Rednerwechselstrategien



QRIO: Sprachdialoge eines Unterhaltungsroboters mit einer Kindergruppe



Sprachbasierte Adaption an die Altersklasse des Benutzers



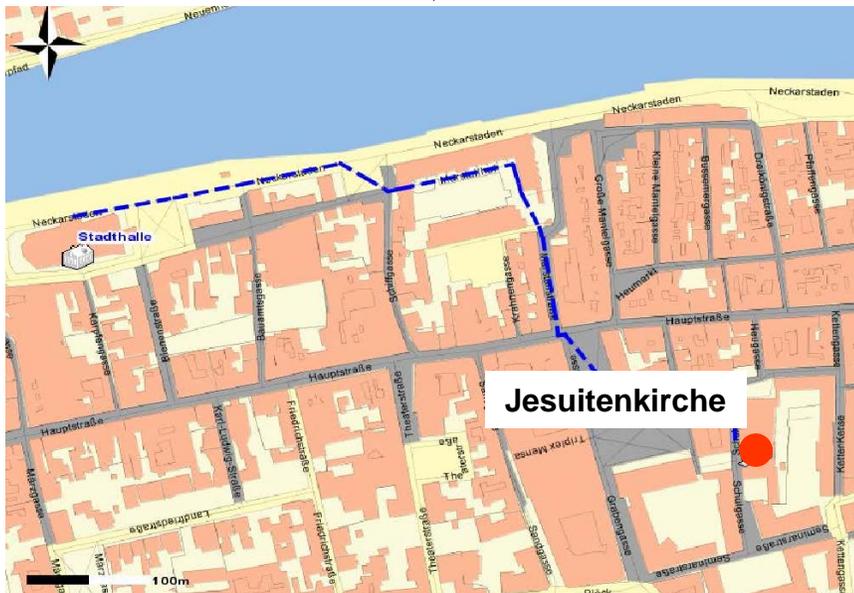
Versteifung des
Stimmlippengewebes
im Alter



Jitter und Shimmer

Erkennung des biologischen
Alters der Stimme durch
akustische Merkmale

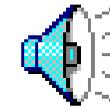
Jitter und Shimmer



Sprachbasierte Adaption an die Altersklasse des Benutzers



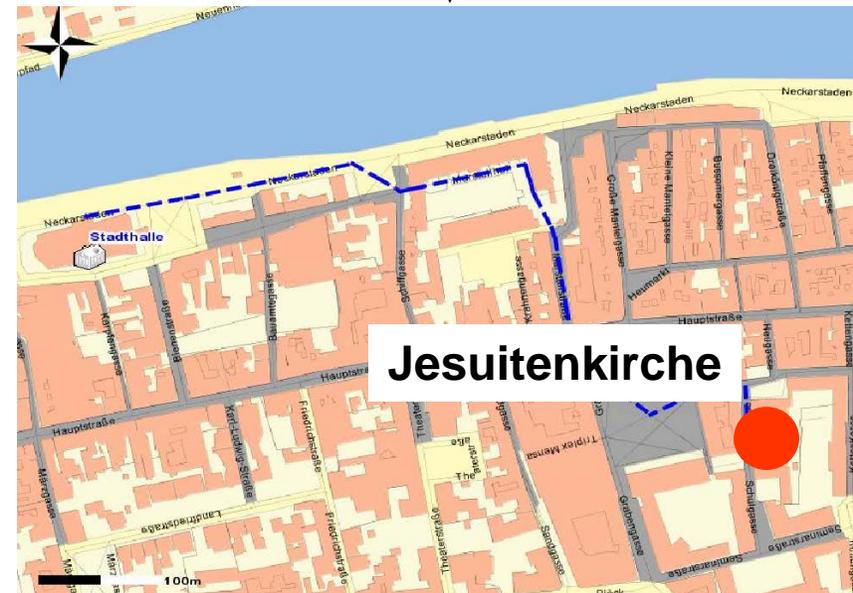
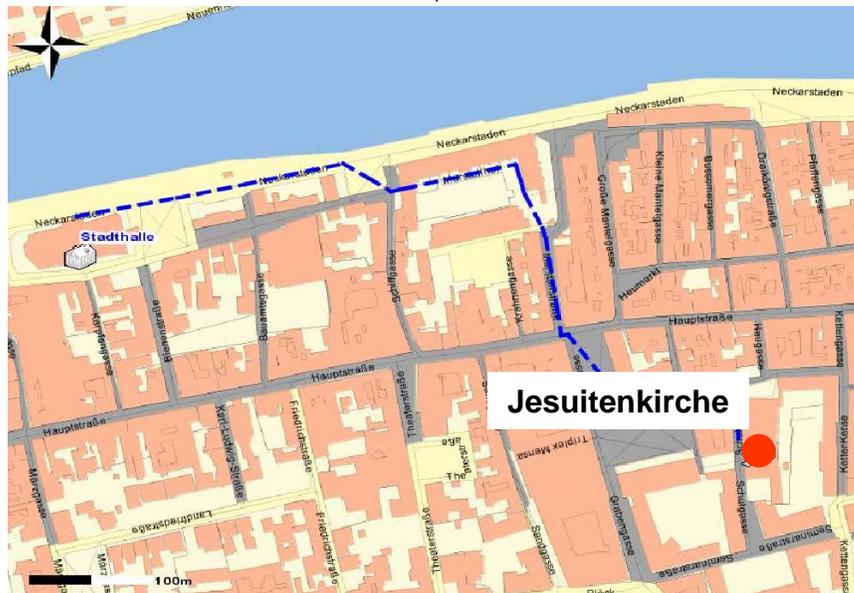
Versteifung des
Stimmlippengewebes
im Alter



Jitter und Shimmer

Erkennung des biologischen
Alters der Stimme durch
akustische Merkmale

Jitter und Shimmer



Auswirkungen des Alterns auf die Sprachproduktion:

zu erwartende Folgen:

Ansteigen der Grundfrequenz F_0 (bei Männern)

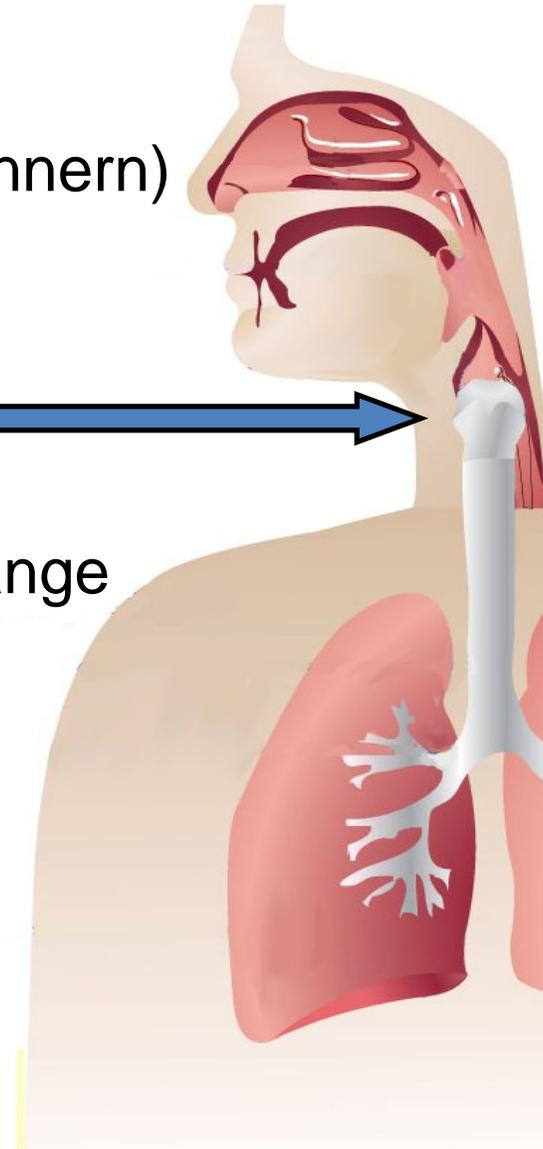
Verminderung der Stimmqualität

Kehlkopf

Verkalkungs- und
Verknöcherungsvorgänge

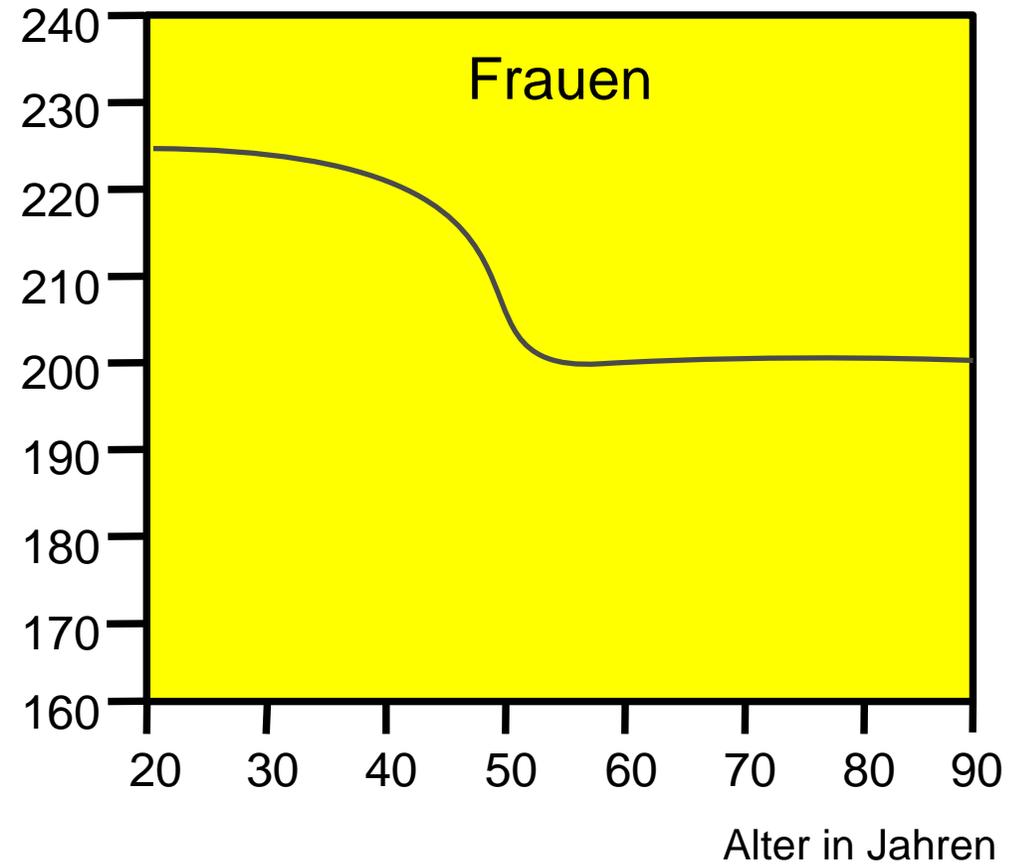
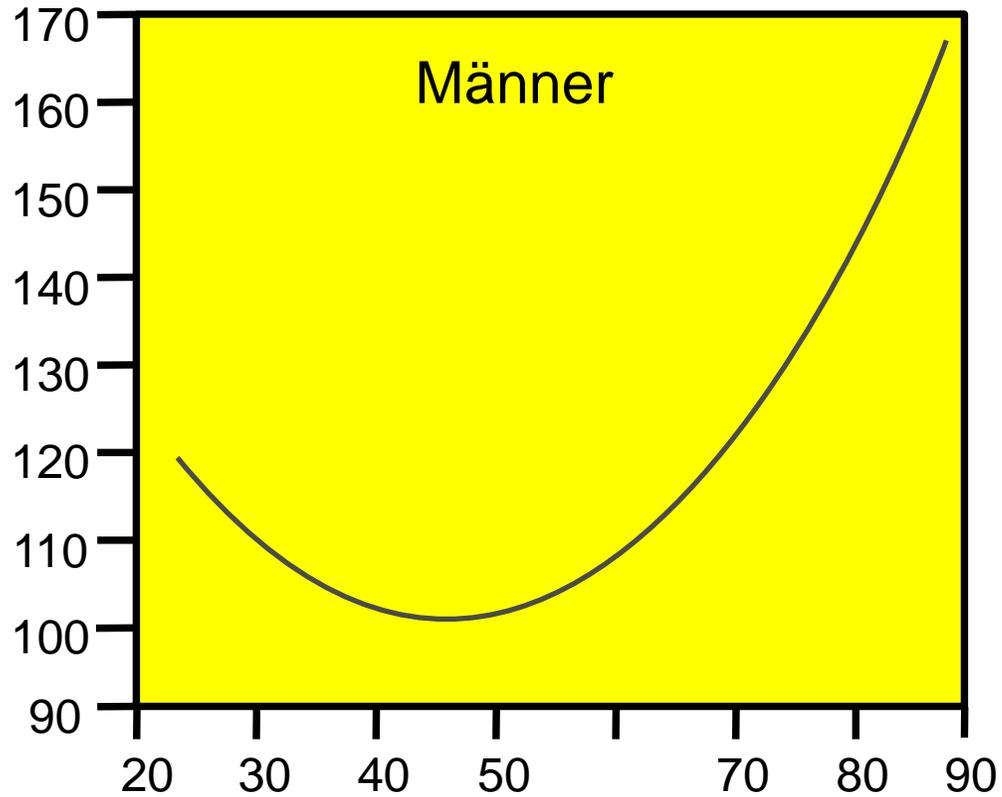
Stimmritzen

Versteifung
Gewebeschwund



Entwicklung der Grundfrequenz der Stimme im Alter

Hz
(idealisiert)



Automatische Anpassung des Dialogverhaltens durch biometrische Sprecherklassifikation



Kooperation der T-Labs der Deutschen Telekom und DFKI

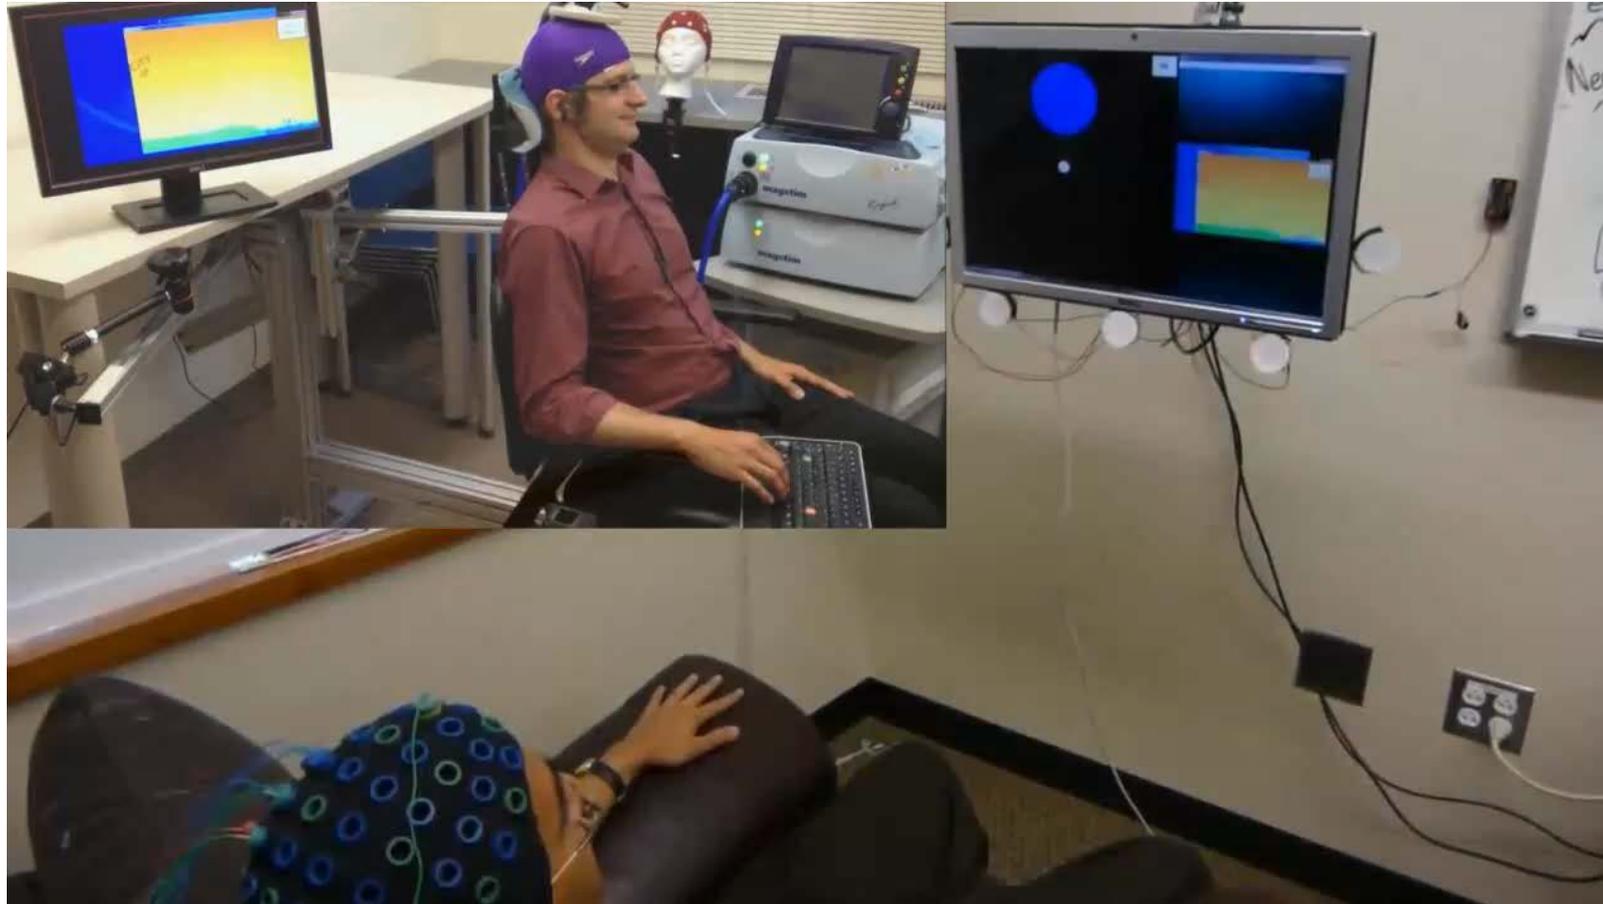
Internet-Uhr zur Innenraumnavigation sowie Fahrstuhlsteuerung des DFKI - M2M Kommunikation und Spracheingabe für Endbenutzer



Skype mit Simultanübersetzung à la Verbmobil des DFKI



Gehirn-zu-Gehirn-Kommunikation



**Gedanke an Tastendruck des Senders (EEG)
löst diesen unwillentlich beim Empfänger aus (TMS)**

Sprachverstehen und –generierung mit Künstlicher Intelligenz ist heute möglich, wenn auch noch nicht mit Qualität menschlicher Dialogpartner

In den 70iger Jahren noch reine Grundlagenforschung, heute gibt eine Sprachindustrie mit über **100 Spezialunternehmen in Deutschland** und z.B. über 200 Sprachdialogsystemen, die in Deutschland über 500 000 Gespräche am Tag automatisiert fallabschliessend führen.

Beispiele für **erfolgreiche Anwendungen** sind:

- **Automatisierte Bestellung, Reservierung und Auskunft**
- **Steuerung von Komfortfunktionen im Auto**
- **Sprachliche Programmierung von Robotern/Rollstühlen/Geräten**
- **Sprachanalyse im Bereich Sicherheit/Terrorismusbekämpfung**
- **Übersetzen und Dolmetschen für Informationsaustausch**

Wettbewerb 2017: Professionelle Übersetzer vs. Google Translate und Systran – 15:25 Sieg über KI

In 50 Minuten mussten Texte zwischen Koreanisch und Englisch übersetzt werden.

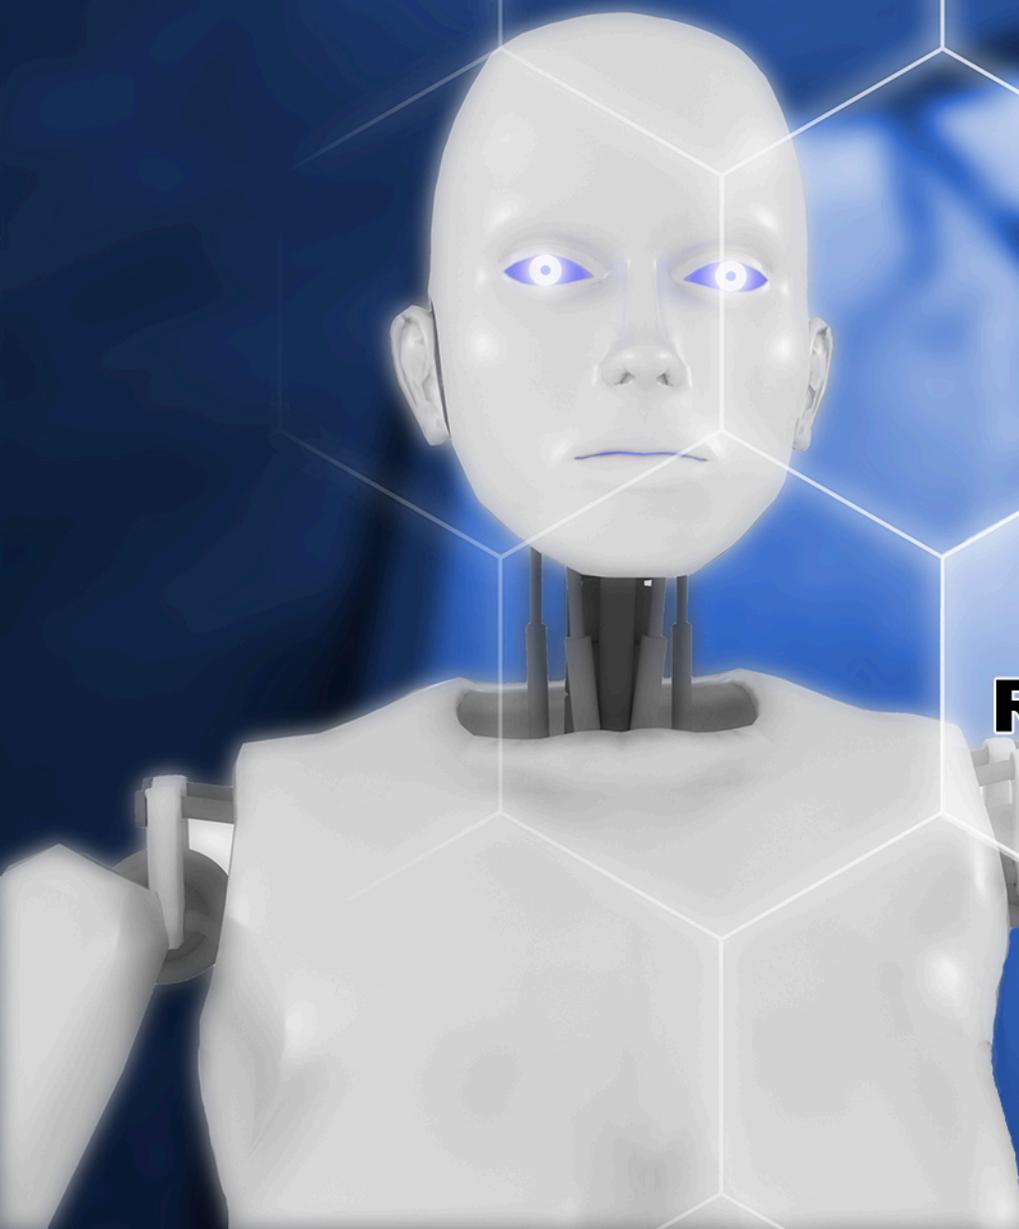
2 Übersetzer bewerteten die Ergebnisse mit 30 als max. Punktzahl



Mangelndes globales Kontextverständnis der neuronalen und statistischen Übersetzung

Heutige Grenzen beim KI-Sprachverstehen

1. Fehlende allgemeine Computermodele für die **Wechselwirkungen** zwischen Sprachverstehen, Bildverstehen, Inferenz, Aktionsplanung und Gedächtnis sowie anderen kognitiven Fähigkeiten.
2. Tiefes und robuste Verstehen derzeit nur **für enge Themenbereiche**, offene Gesprächsthemen erfordern Kombination von flachen und tiefen Verfahren
3. Maschinelles Lernen noch nicht für **komplexe Dialoge** und **Spontansprache** z.B. Verstehen von Wortschöpfungen aufgrund von Hintergrundwissen geeignet. (Prinzipien: “Müll rein – Müll raus” und “Es gibt keine bessere Daten als mehr Daten”)



**LERNENDE
MASCHINEN**
02.05.2017

**INDUSTRIE
4.0**

**SPRACH-
DIALOGE**
09.05.2017

**KÜNSTLICHE
INTELLIGENZ**

**BIG
DATA**

KI

**TEAM-
ROBOTIK**

**AUTONOME
SYSTEME**
16.05.2017

**ALTERS-
ASSISTENZ**

**SMART
SERVICE**

**SICHER-
HEIT**

**EMOTION &
VERHALTEN**

Vielen Dank für Ihre Aufmerksamkeit

