

## Herausforderung: Gesprochene Sprache

Die größte Herausforderung bei der Verarbeitung von gesprochener Sprache ist die **große Variabilität des Sprachsignals**:

- dasselbe Wort wird nie zweimal wirklich *identisch* ausgesprochen
- Buchstaben werden je nach Kontext ganz unterschiedlich gesprochen („der nasse Hase schläft nachts“)  
• unser Gefühl täuscht uns oft: zum Beispiel wird im Deutschen das „r“ eigentlich nie gesprochen
- auch die Bedeutung von Wörtern ist je nach Kontext verschieden

„Nur weil Menschen es können, heißt es leider nicht, dass es einfach ist!“

**Wäre es nicht besser, wenn Sprache viel einfacher wäre?**

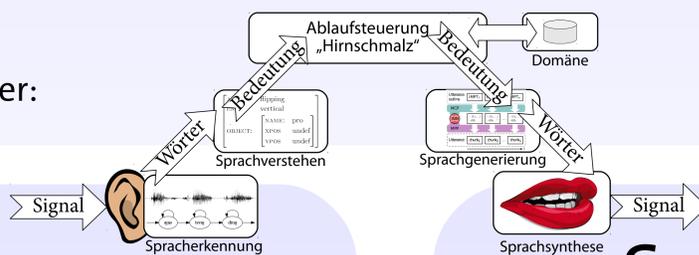
- dann wäre sie sicher leichter zu verstehen (gerade für Computer), aber
- unsere Sprache ist sehr *ausdrucksstark*: was immer wir sagen wollen, wir können es mit Sprache tun!

## Aufbau von sprachverarbeitenden Systemen

Sprache ist vielschichtig und wird von unterschiedlichen Teildisziplinen der Linguistik erforscht:

- Phonetik → Sprachlaute
- Morphologie → Worte und Wortbildung
- Syntax → Kombination von Wörtern zu Sätzen
- Semantik → Bedeutung von ganzen Äußerungen

Die Vielschichtigkeit spiegelt sich in sprachverarbeitenden Systemen wider:



vielschichtiges Problem  
→ komplexe Systeme

### Spracherkennung

Ziel: im Audiosignal die gesprochenen Wörter erkennen

Formal: Gegeben einen Sinneseindruck **O** gilt es, die Wortfolge **W** zu finden, die am wahrscheinlichsten zu diesem Sinneseindruck passt:  $\hat{W} = \arg \max W : P(W|O)$ .

Es können nur bekannte Wörter berücksichtigt werden, d.h. „neue“ Wörter sind in der Regel nicht erlaubt.

Spracherkennungsqualität ist *nie perfekt*, aber heute für viele Anwendungen „gut genug“ (Siri, ...)

- Menschen gleichen Fehler durch Integration von Weltwissen aus, was Computer nur schlecht können

### Sprachsynthese

Ziel: aus Wortfolge „lebendige“ Sprache erzeugen, dabei muss die *natürliche Variabilität* hinzugefügt werden

Problem: Schriftsprache ist oft mehrdeutig, korrekte Aussprache erschließt sich erst aus dem Kontext

Die Satzmelodie entspricht der Informationsstruktur.  
Gutes Vorlesen setzt daher Verständnis voraus!

“I didn't say we should kill him.”  
• someone else said we should kill him  
• I am denying that I said we should kill him  
• I wrote it down or implied it, but I didn't say it  
• I said someone else should do the job  
• I said that we absolutely must kill him  
• scaring him a little would've been enough  
• we got the wrong guy!

**Spontane Sprache** zeichnet sich durch Füllwörter, Lachen, und Feedback aus – dies ist für Sprachsynthesysteme noch schwieriger als reines Vorlesen

## Unsere Forschung: Schritthaltende Verarbeitung

Menschen fallen sich ins Wort, korrigieren sich, helfen sich, kurz: **Menschen verstehen während der Verarbeitung**. Die meisten Systeme interpretieren Äußerungen erst als ganzen Satz, und sprechen selbst immer ganze Sätze.

Probleme:

- keine Systemreaktionen während der Nutzer spricht
  - keine Anpassung von laufenden Sprachausgaben
- keine natürliche Interaktion im Dialog

Lösungen:

- sofortige Weitergabe von vorläufigen Ergebnissen
  - spätere Korrektur und Ergänzung der Hypothesen
- ermöglicht natürlicheres Verhalten