

# Kommunikation mit gesprochener Sprache ...

... ist mehr als Hören und Sprechen:

# Kommunikation mit gesprochener Sprache ...

... ist mehr als Hören und Sprechen:



Hören

*Kikala brint tovoluti?*

# Kommunikation mit gesprochener Sprache ...

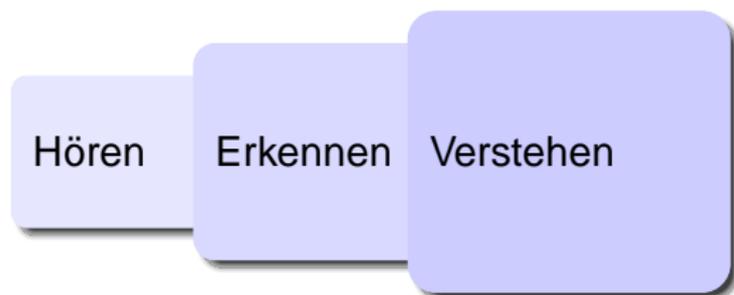
... ist mehr als Hören und Sprechen:



*Winter kochtest ganz Blatt?*

# Kommunikation mit gesprochener Sprache ...

... ist mehr als Hören und Sprechen:



*Wann steigt die Party?*

# Kommunikation mit gesprochener Sprache ...

... ist mehr als Hören und Sprechen:



*Wann steigt die Party?*

*Sintu högafi notsi!*

# Kommunikation mit gesprochener Sprache ...

... ist mehr als Hören und Sprechen:



*Wann steigt die Party?*

*Sonderbar werfen die Wellen hinab!*

# Kommunikation mit gesprochener Sprache ...

... ist mehr als Hören und Sprechen:

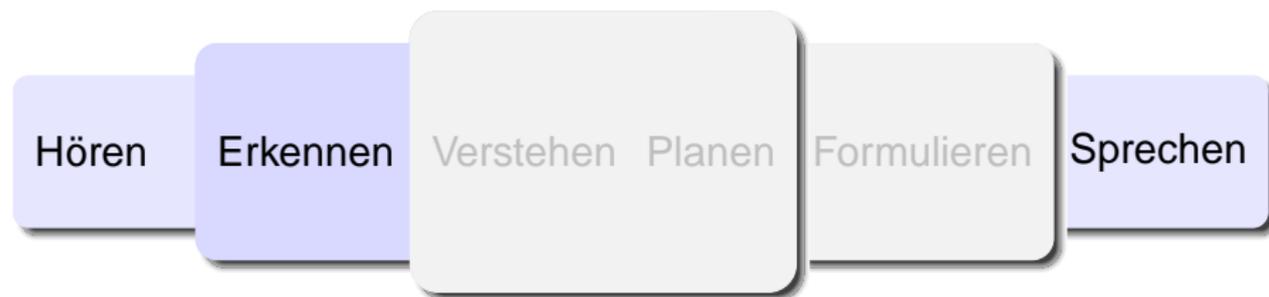


*Wann steigt die Party?*

*Am Freitag, im Hirsch!*

# Kommunikation mit gesprochener Sprache ...

... ist mehr als Hören und Sprechen:



*Wann steigt die Party?*

*Am Freitag, im Hirsch!*

# Gesprochene Sprache

## Segmentstruktur

**Äußerungen** Und wie wäre es am Mittwoch?

# Gesprochene Sprache

## Segmentstruktur

<b>Äußerungen</b>	Und	wie	wäre	es	am	Mittwoch?
		⋮		⋮	⋮	⋮
<b>Phrasen</b>		wie	wäre	es	am	Mittwoch?

# Gesprochene Sprache

## Segmentstruktur

<b>Äußerungen</b>	Und	wie	wäre	es	am	Mittwoch?
<b>Phrasen</b>		wie	wäre	es	am	Mittwoch?
<b>Wörter</b>		wie	wäre	es		

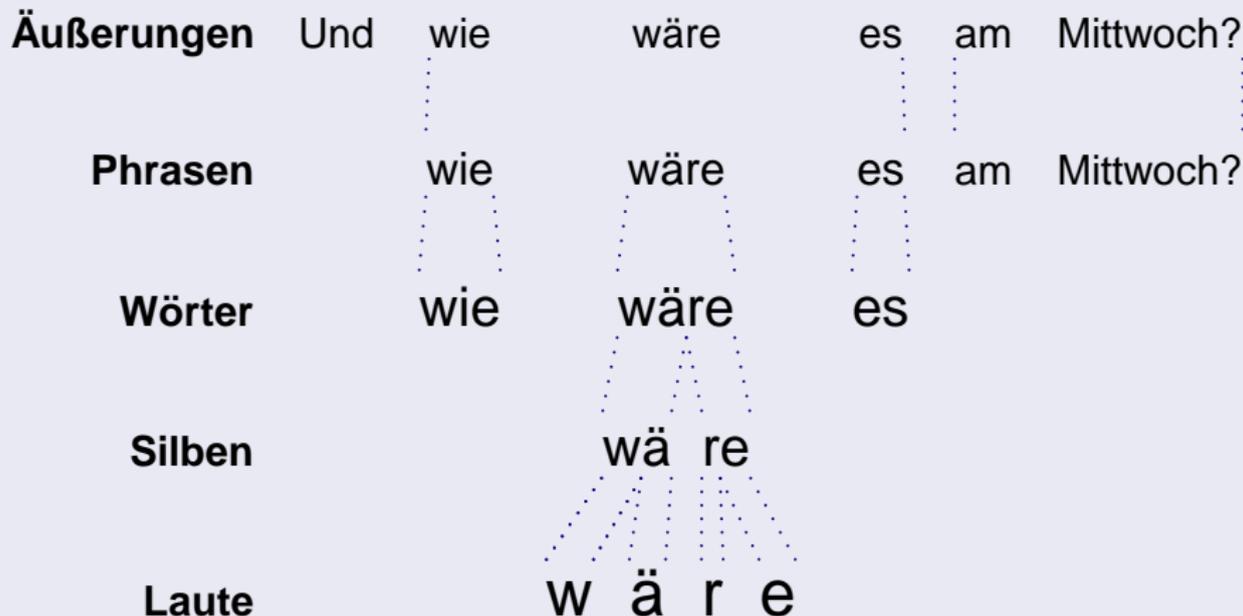
# Gesprochene Sprache

## Segmentstruktur

<b>Äußerungen</b>	Und	wie	wäre	es	am	Mittwoch?
<b>Phrasen</b>		wie	wäre	es	am	Mittwoch?
<b>Wörter</b>		wie	wäre	es		
<b>Silben</b>			wä re			

# Gesprochene Sprache

## Segmentstruktur



# Gesprochene Sprache

## Segmentübergreifende Information (Prosodie)

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz

# Gesprochene Sprache

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz
- Rhythmus

# Gesprochene Sprache

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz
- Rhythmus
- Lautstärke

# Gesprochene Sprache

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz
- Rhythmus
- Lautstärke

wird verwendet ...

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz
- Rhythmus
- Lautstärke

wird verwendet ...

- ... für Hervorhebungen (Neues, Wichtiges, Unerwartetes, ...)

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz
- Rhythmus
- Lautstärke

wird verwendet ...

- ... für Hervorhebungen (Neues, Wichtiges, Unerwartetes, ...)
- ... zur Gliederung (Phrasen, Sätze)

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz
- Rhythmus
- Lautstärke

wird verwendet ...

- ... für Hervorhebungen (Neues, Wichtiges, Unerwartetes, ...)
- ... zur Gliederung (Phrasen, Sätze)
- ... zur Moduskennzeichnung (Aussage, Frage, ...)

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz
- Rhythmus
- Lautstärke

wird verwendet ...

- ... für Hervorhebungen (Neues, Wichtiges, Unerwartetes, ...)
- ... zur Gliederung (Phrasen, Sätze)
- ... zur Moduskennzeichnung (Aussage, Frage, ...)
- ... zur Dialogsteuerung (Vergabe der Initiative)

## Segmentübergreifende Information (Prosodie)

- Grundfrequenz
- Rhythmus
- Lautstärke

wird verwendet ...

- ... für Hervorhebungen (Neues, Wichtiges, Unerwartetes, ...)
- ... zur Gliederung (Phrasen, Sätze)
- ... zur Moduskennzeichnung (Aussage, Frage, ...)
- ... zur Dialogsteuerung (Vergabe der Initiative)
- ... zum Ausdruck von Emotionen (Freude, Angst, Überraschung, Verlegenheit, ...)

# Sprachsynthese

Zwei Herangehensweisen:

# Sprachsynthese

Zwei Herangehensweisen:

## Vollsynthese

- Erzeugen des Sprachsignals durch Ton- und Rauschgeneratoren
- akzeptable Verständlichkeit
- geringe Natürlichkeit

# Sprachsynthese

Zwei Herangehensweisen:

## Vollsynthese

- Erzeugen des Sprachsignals durch Ton- und Rauschgeneratoren
- akzeptable Verständlichkeit
- geringe Natürlichkeit

## reproduktive Synthese

- Aufnehmen und Wiedergeben menschlicher Sprachsignale
- hohe Verständlichkeit
- gute bis hohe Natürlichkeit

## reproduktive Synthese

Was sind geeignete Basiseinheiten?

- ganze Phrasen: nur für Spezialanwendungen
- Laute: schlechte Qualität
- Kompromiss: flexible Ermittlung der Basiselemente aus Korpusdaten

## reproduktive Synthese

Was sind geeignete Basiseinheiten?

- ganze Phrasen: nur für Spezialanwendungen
- Laute: schlechte Qualität
- Kompromiss: flexible Ermittlung der Basiselemente aus Korpusdaten

Wie werden die Basiselemente verkettet?

- harter Schnitt erzeugt Knackgeräusche
- "weiche" Übergänge erforderlich
- prosodische Variation durch spezielle Transformationsverfahren

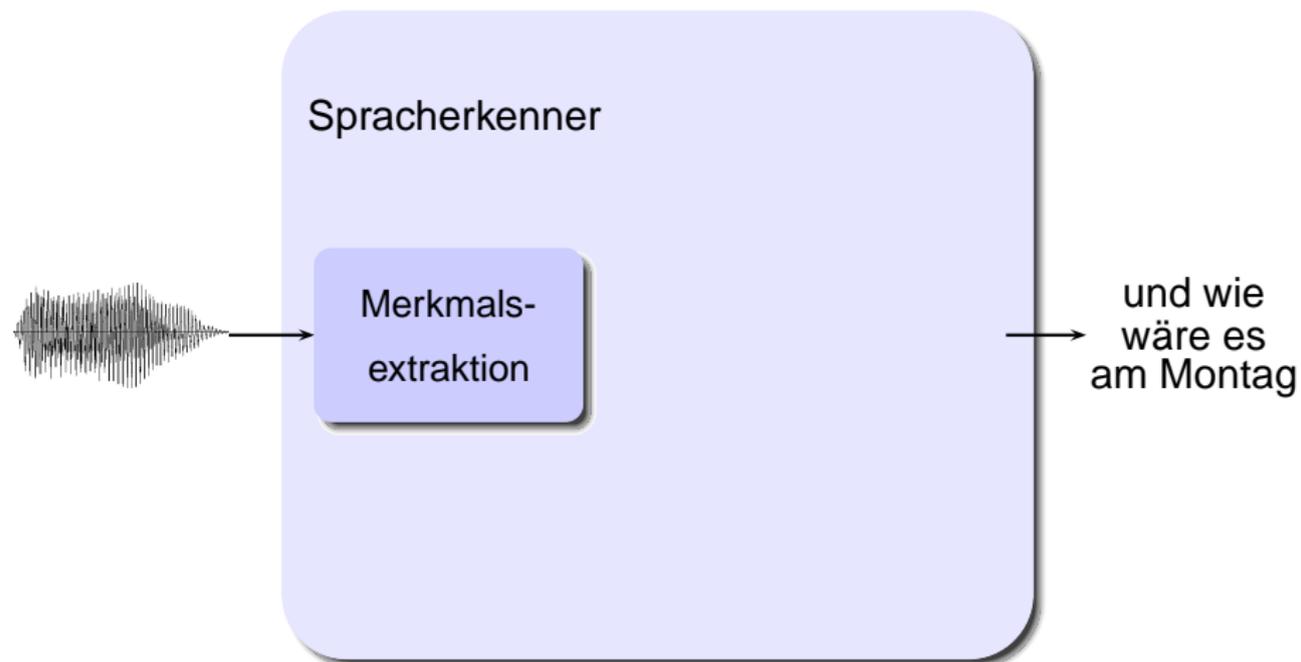
# Spracherkennung

- nur Berücksichtigung von Lautcharakteristika
- "Training" von Modellen auf großen Sprachdatensammlungen
- Vernachlässigung der Prosodie
- nur Erkennung, kein Sprachverstehen!

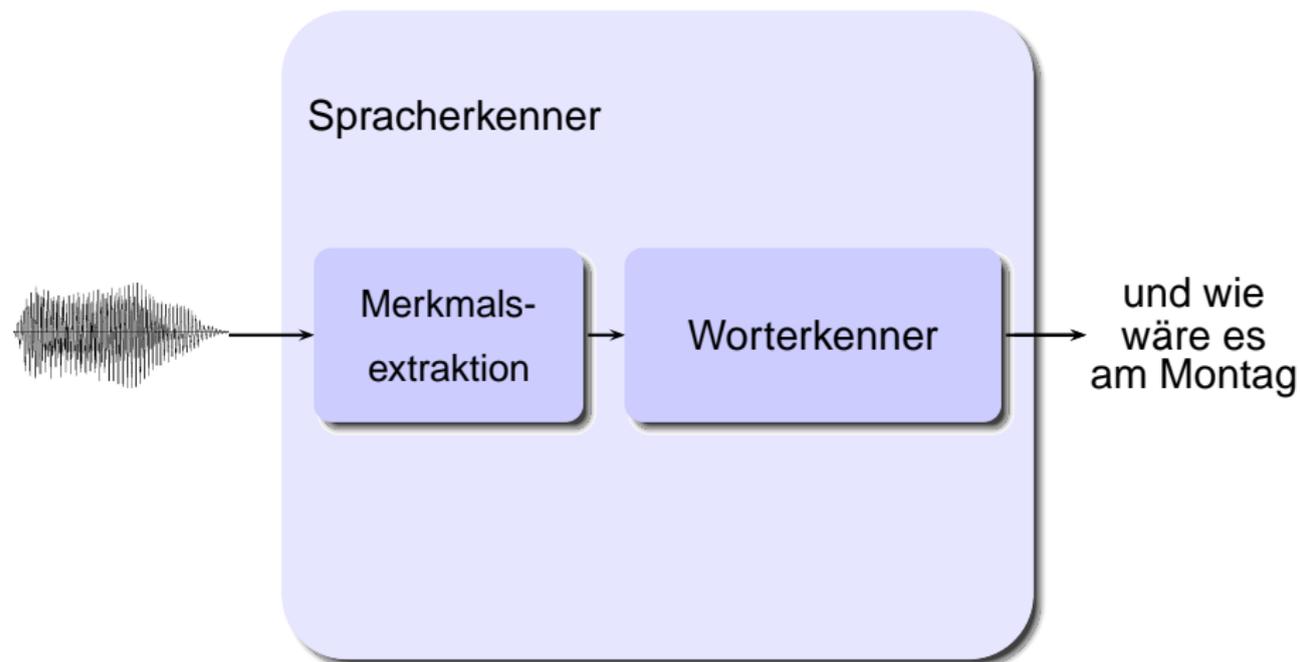
# Spracherkennung



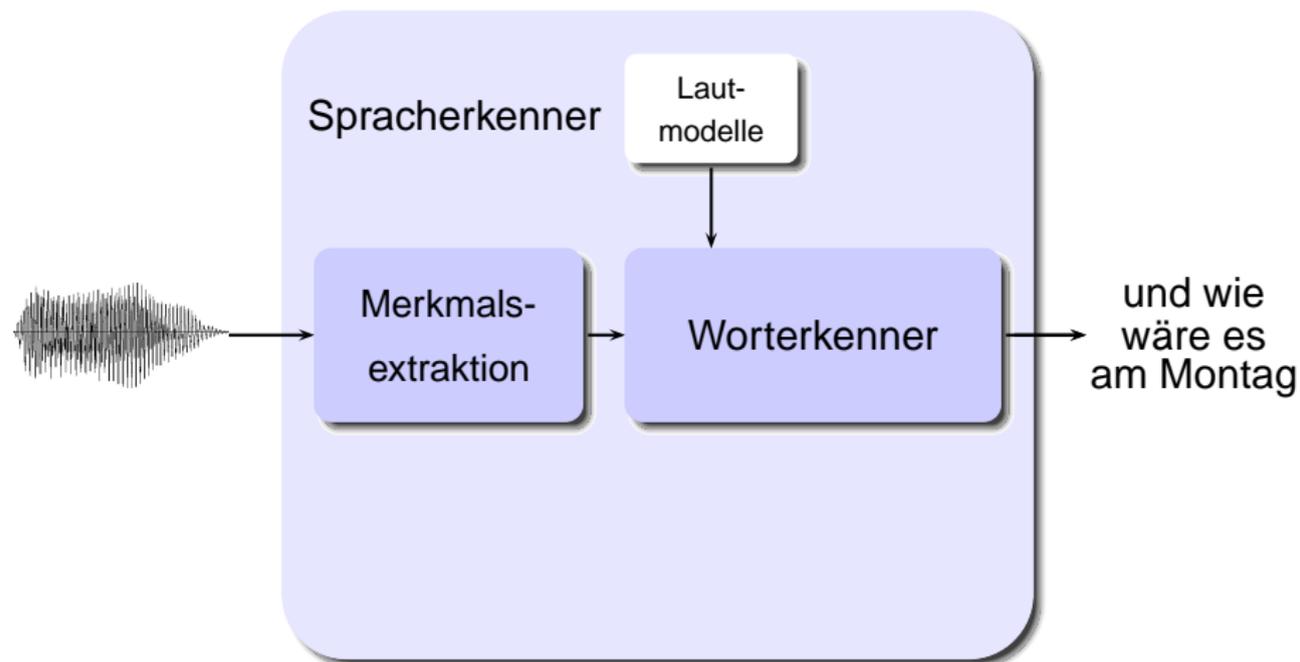
# Spracherkennung



# Spracherkennung



# Spracherkennung



# Spracherkennung

Spracherkennung

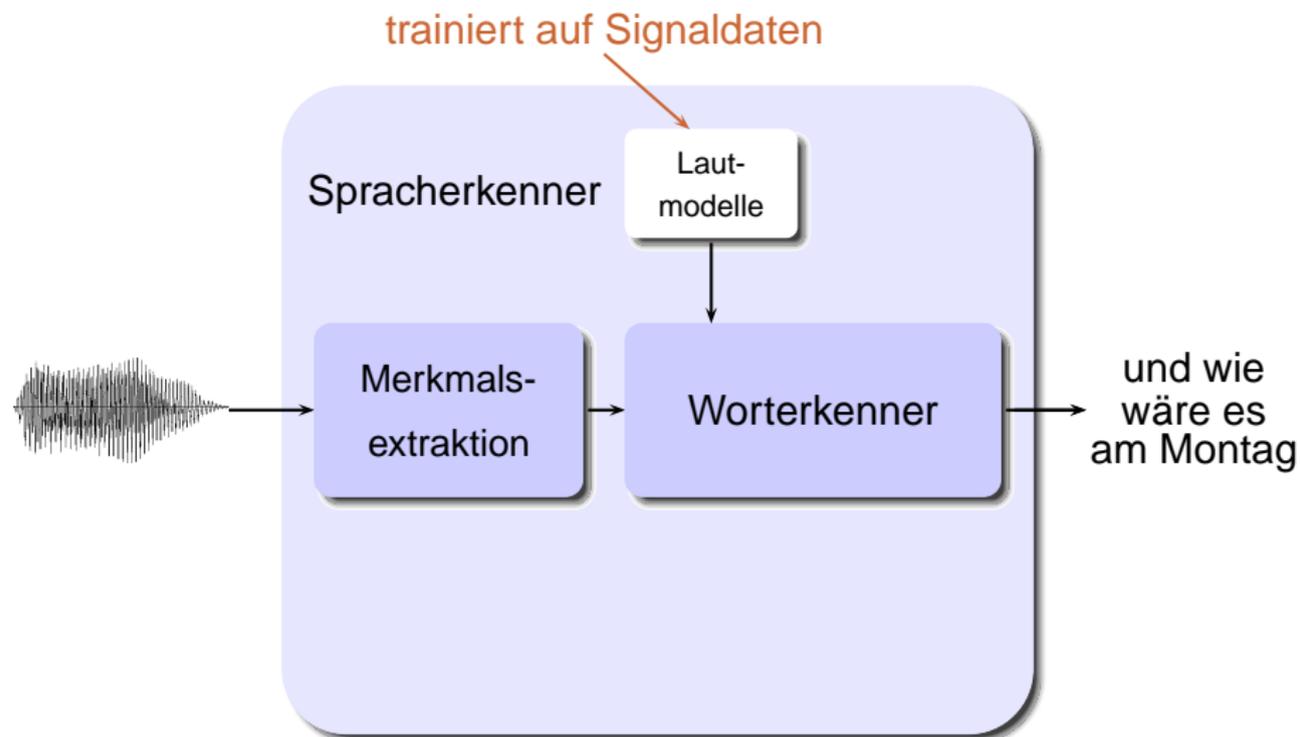
Laut-  
modelle

- Modelle für jeden Laut im Kontext seiner Nachbarlaute  
 $m-a+m$ ,  $m-a+n$ ,  $d-a+n$ , ...
- Berechnung der Wahrscheinlichkeit, dass das Sprachsignal durch das Modell erzeugt wurde
- Zustände, Zustandsübergänge
- Transitionswahrscheinlichkeiten
- Emissionswahrscheinlichkeiten

erkenner

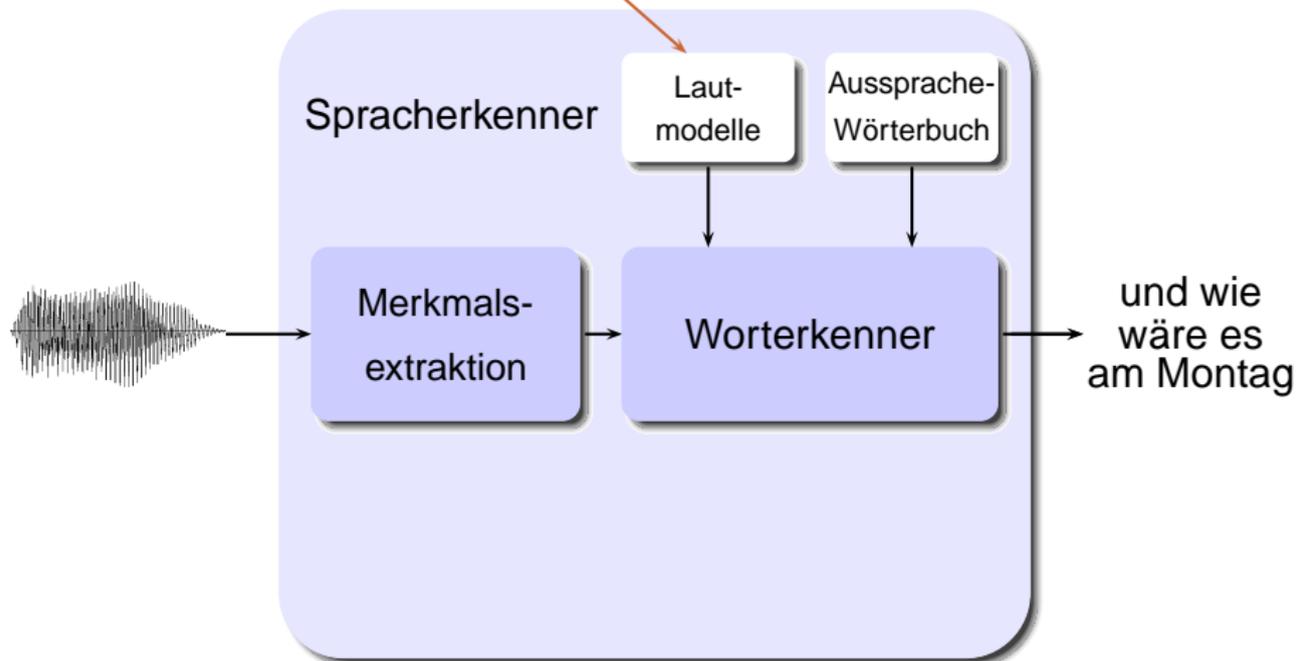
und wie  
wäre es  
am Montag

# Spracherkennung



# Spracherkennung

trainiert auf Signaldaten



# Spracherkennung

trainiert auf Signaldaten

- eine oder mehrere Lautfolgen für jede Wortform

Mittwoch m i t v o x sp  
wäre v e h r 2 sp

- Verkettung von Lautmodellen zu Wortmodellen

Mittwoch:

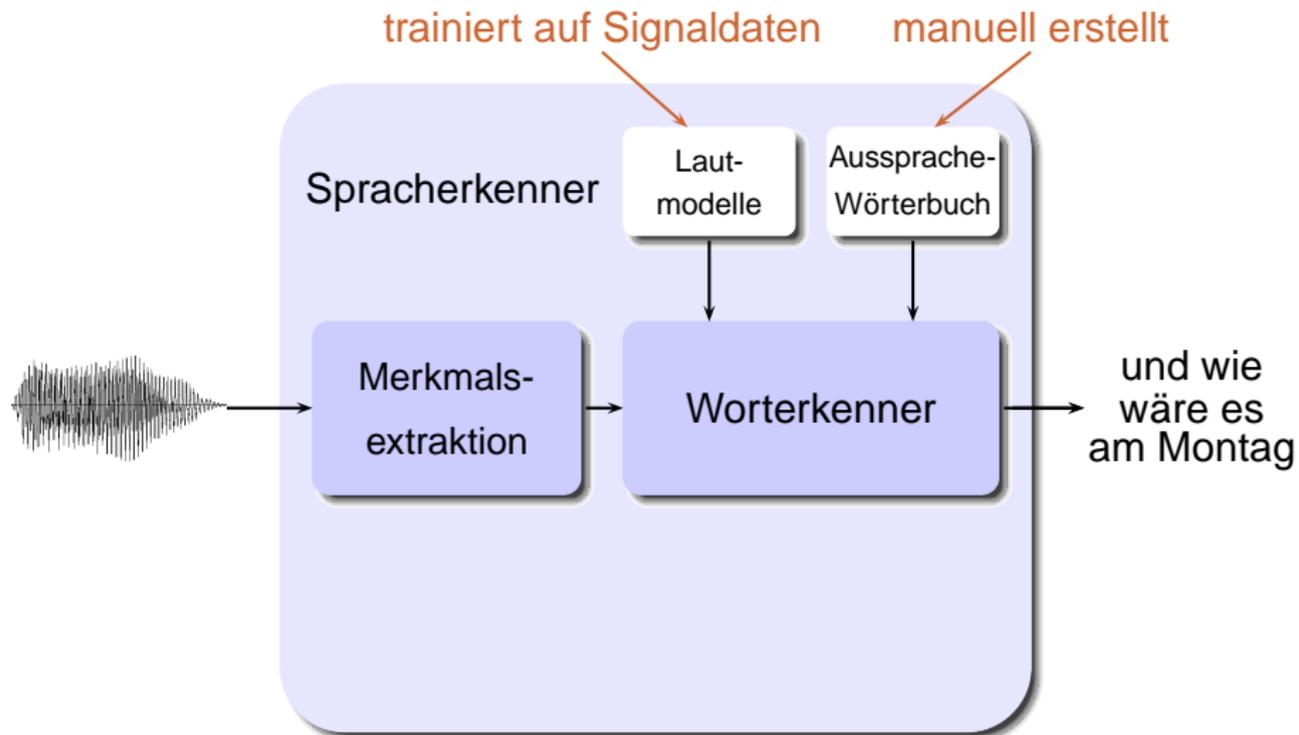
sp-m+i m-i+t i-t+v t-v+o ...

Aussprache-  
Wörterbuch

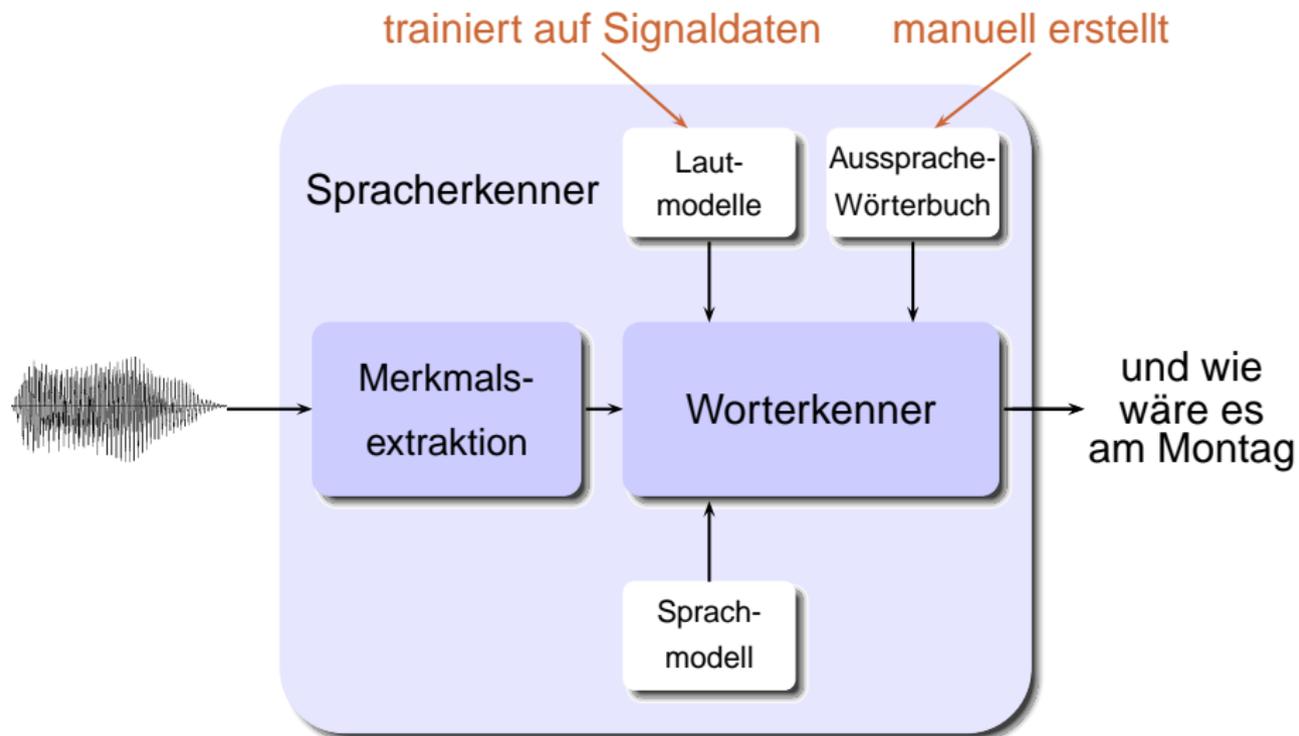
Wörterkennner

und wie  
wäre es  
am Montag

# Spracherkennung



# Spracherkennung



# Spracherkennung

trainiert auf Signaldaten

manuell erstellt

- Berechnung der Wahrscheinlichkeit für komplette Äußerungen
- Wahrscheinlichkeiten für Wortpaare, -tripel oder -quadrupel
  - $p(\text{wir}|\text{dann wollen})$
  - $p(\text{Mittwoch}|\text{dann wollen})$
- wenig geeignet für Dialogsysteme

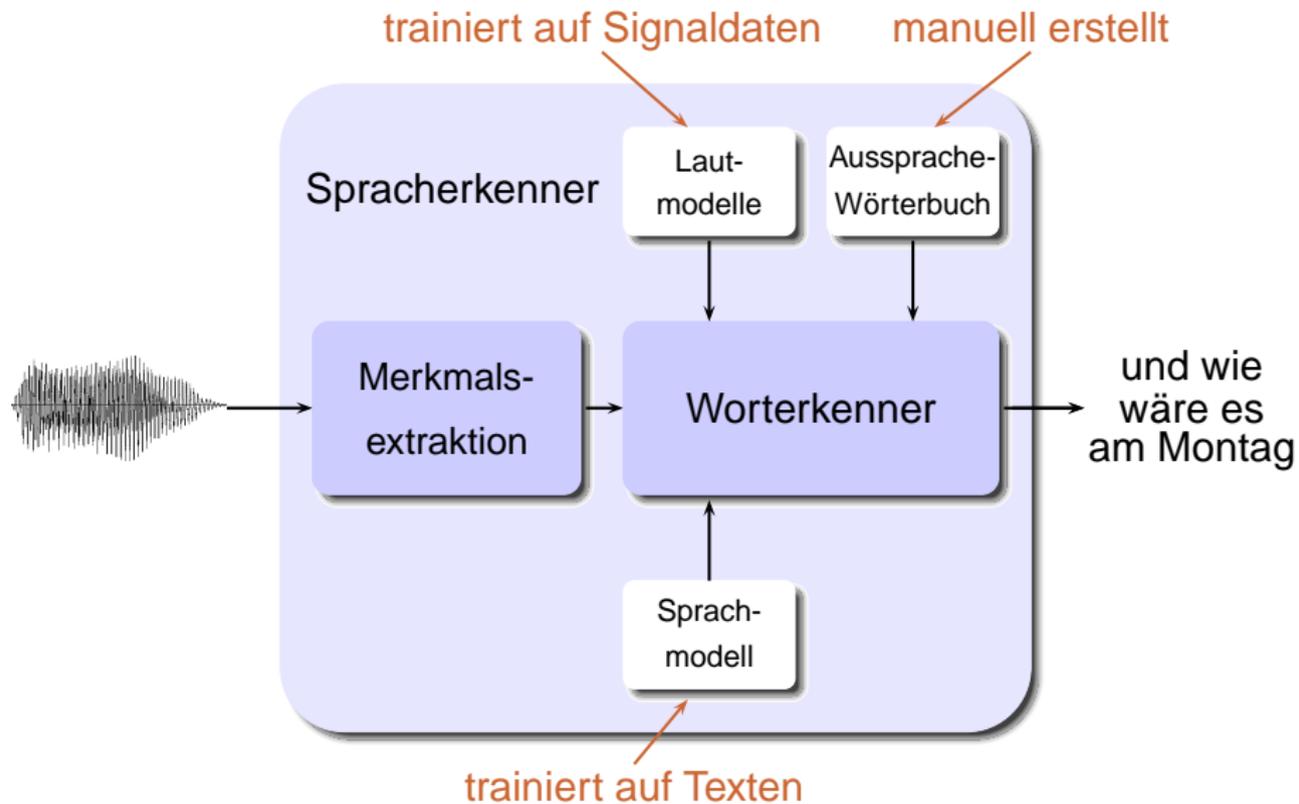
Aussprache-  
Wörterbuch

erkenner

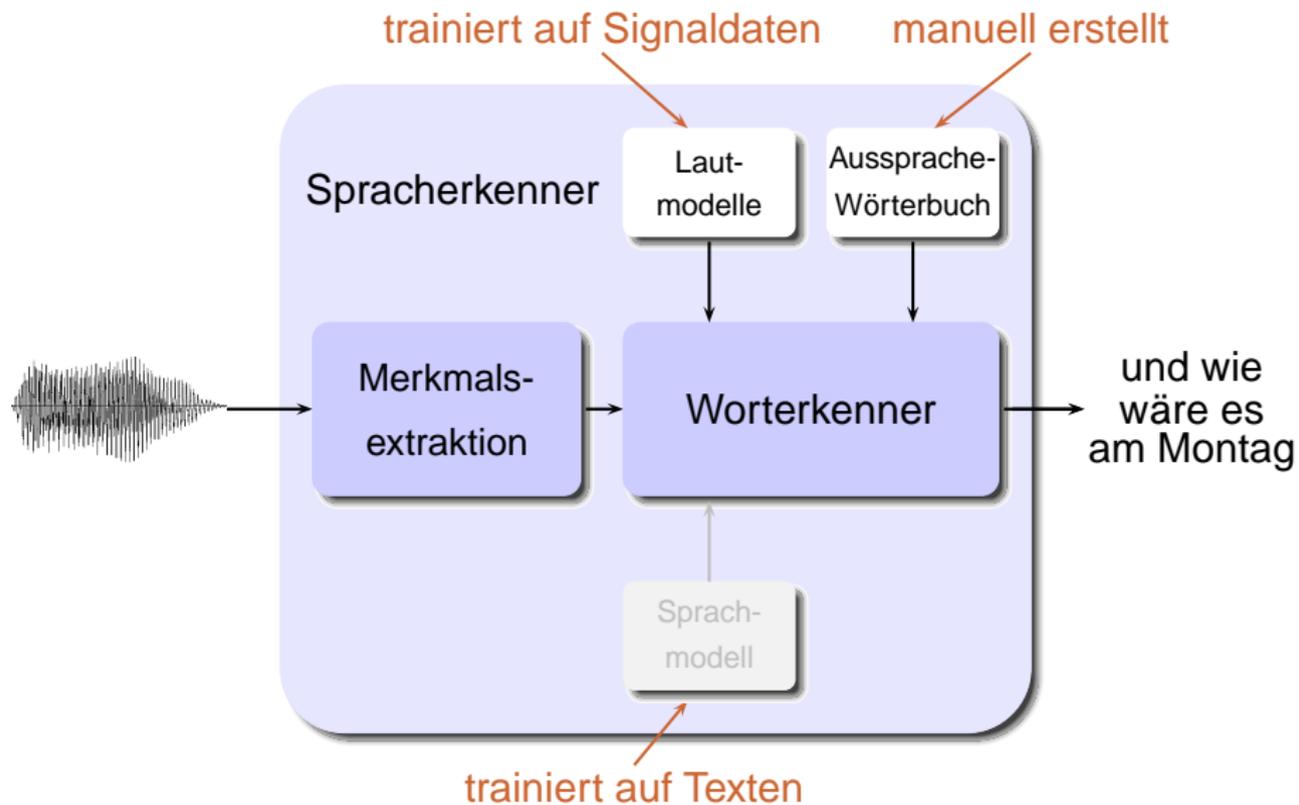
und wie  
wäre es  
am Montag

Sprach-  
modell

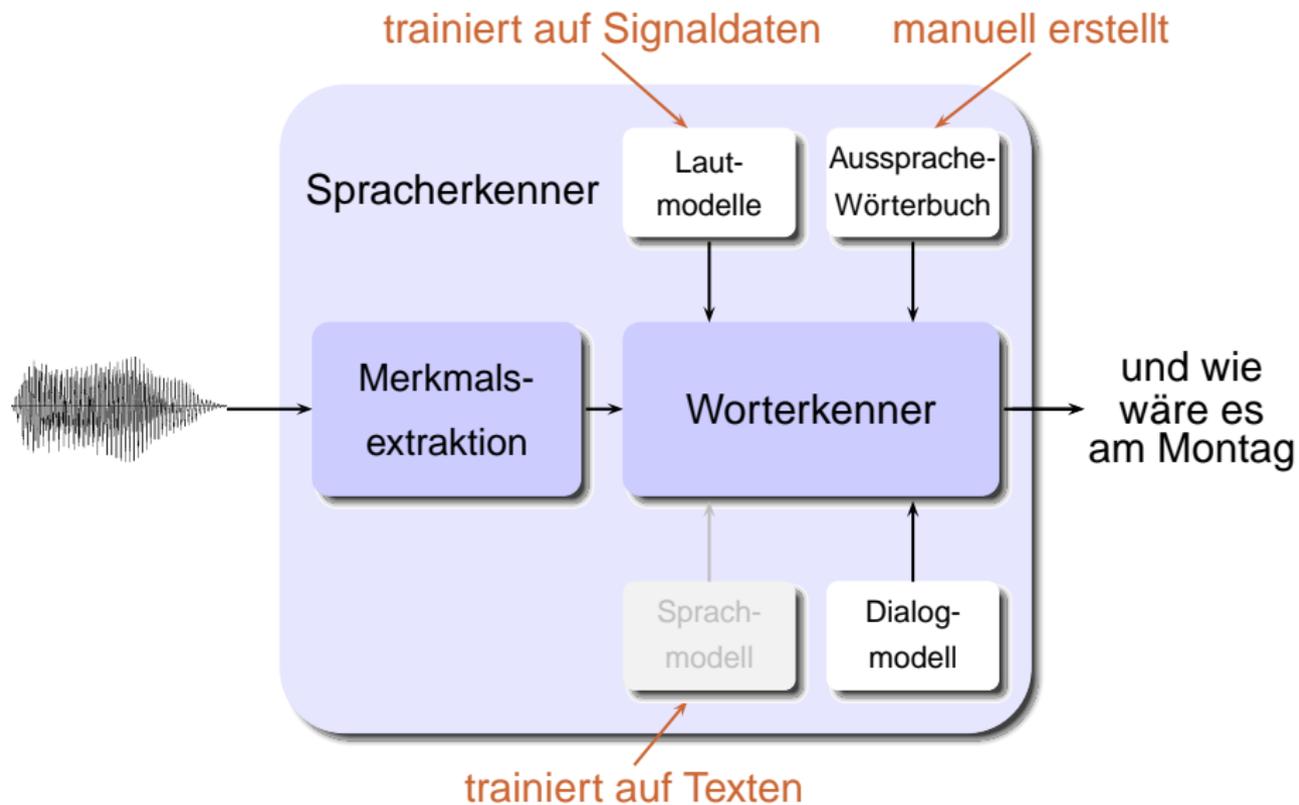
# Spracherkennung



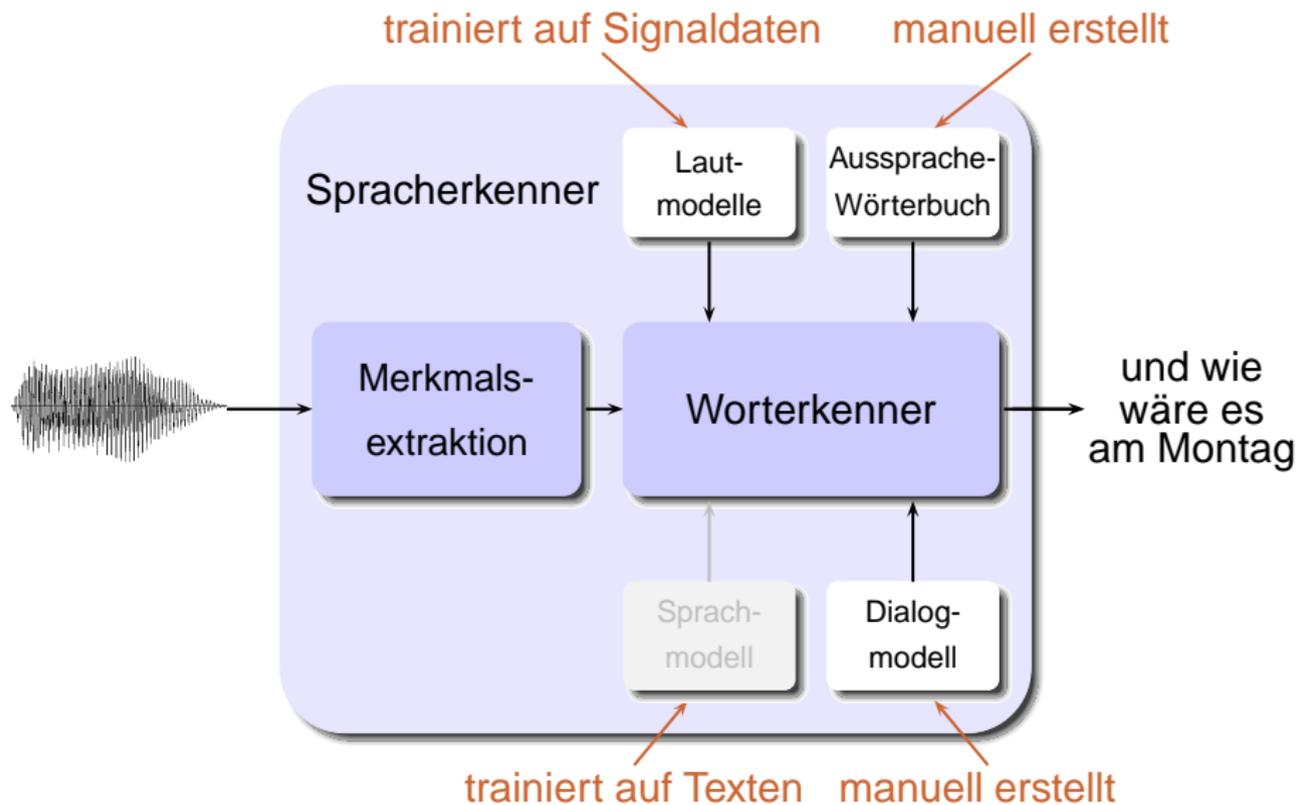
# Spracherkennung



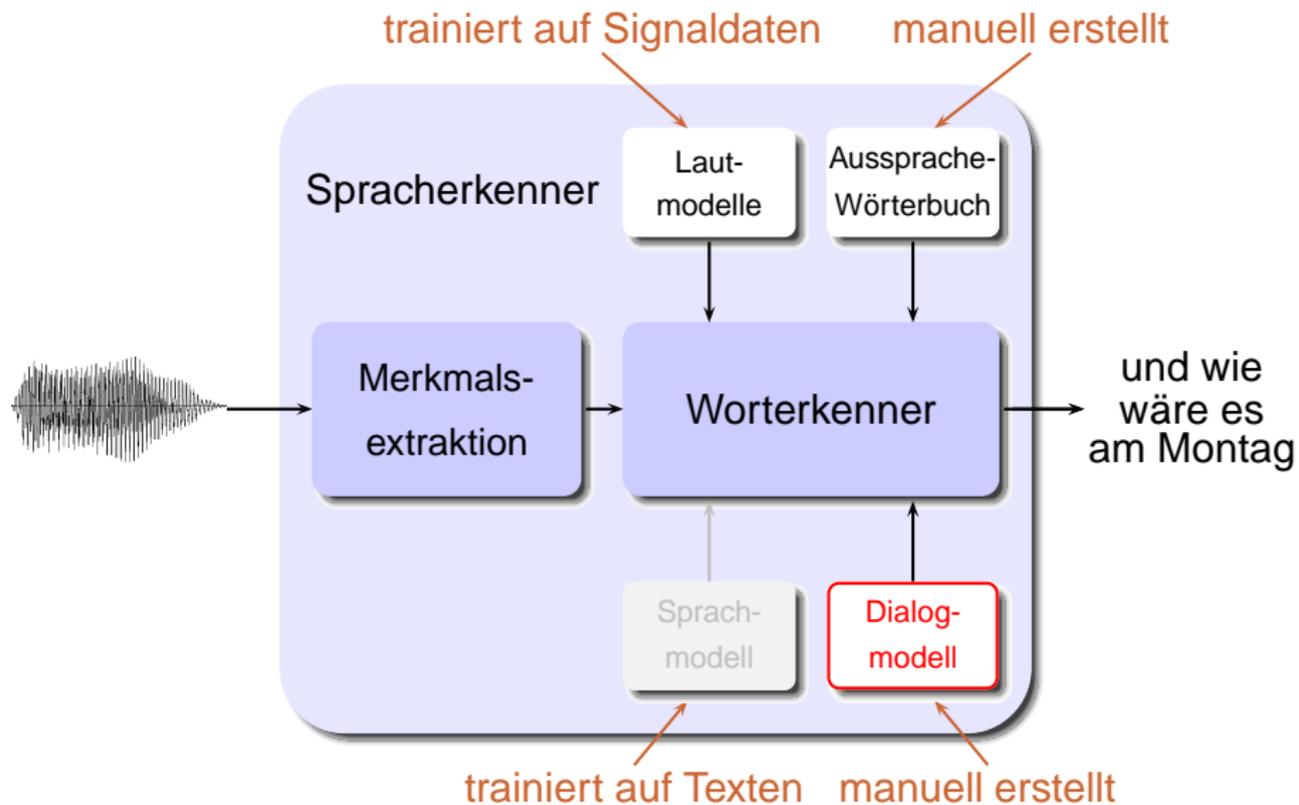
# Spracherkennung



# Spracherkennung



# Spracherkennung



# Dialogmodellierung

- dynamische Einschränkung des Erkennerwortschatzes in Abhängigkeit vom Dialogzustand

# Dialogmodellierung

- dynamische Einschränkung des Erkennerwortschatzes in Abhängigkeit vom Dialogzustand
- Wozu braucht man das?

# Dialogmodellierung

- dynamische Einschränkung des Erkennerwortschatzes in Abhängigkeit vom Dialogzustand
- Wozu braucht man das?
  - Erkennungssicherheit erhöhen  
→ Was wurde gesagt?

# Dialogmodellierung

- dynamische Einschränkung des Erkennerswortschatzes in Abhängigkeit vom Dialogzustand
- Wozu braucht man das?
  - Erkennungssicherheit erhöhen
    - Was wurde gesagt?
      - ähnliche Aussprache: *Mai* oder *drei*?
      - verschiedene Sprecher
      - schlechte Übertragungsqualität

# Dialogmodellierung

- dynamische Einschränkung des Erkennerswortschatzes in Abhängigkeit vom Dialogzustand
- Wozu braucht man das?
  - Erkennungssicherheit erhöhen
    - Was wurde gesagt?
      - ähnliche Aussprache: *Mai* oder *drei*?
      - verschiedene Sprecher
      - schlechte Übertragungsqualität
  - semantische Interpretation erleichtern
    - Was wird von der Maschine erwartet?

# Dialogmodellierung

- dynamische Einschränkung des Erkennerswortschatzes in Abhängigkeit vom Dialogzustand
- Wozu braucht man das?
  - Erkennungssicherheit erhöhen
    - Was wurde gesagt?
      - ähnliche Aussprache: *Mai* oder *drei*?
      - verschiedene Sprecher
      - schlechte Übertragungsqualität
  - semantische Interpretation erleichtern
    - Was wird von der Maschine erwartet?
      - Zahl → Geldbetrag, Uhrzeit, Datum, Kontonummer, ...
      - Mehrdeutigkeit: *Wann werden S/sie kommen?*
      - Referenzauflösung: Was wird durch *sie* bezeichnet?

# Dialogmodellierung

- dynamische Einschränkung des Erkennerwortschatzes in Abhängigkeit vom Dialogzustand
- Wozu braucht man das?
  - Erkennungssicherheit erhöhen
    - Was wurde gesagt?
      - ähnliche Aussprache: *Mai* oder *drei*?
      - verschiedene Sprecher
      - schlechte Übertragungsqualität
  - semantische Interpretation erleichtern
    - Was wird von der Maschine erwartet?
      - Zahl → Geldbetrag, Uhrzeit, Datum, Kontonummer, ...
      - Mehrdeutigkeit: *Wann werden S/sie kommen?*
      - Referenzauflösung: Was wird durch *sie* bezeichnet?
- eine Maschine hat keinen gesunden Menschenverstand!

# Dialogmodellierung

- Dialogzustände: Aufforderung zur Eingabe (Prompt)
- Übergänge zwischen Dialogzuständen: Erkennung von Nutzeräußerungen

# Dialogmodellierung

- Dialogzustände: Aufforderung zur Eingabe (Prompt)
- Übergänge zwischen Dialogzuständen: Erkennung von Nutzeräußerungen



Bitte  
geben Sie  
Ihren Ab-  
fahrtsort  
ein!

# Dialogmodellierung

- Dialogzustände: Aufforderung zur Eingabe (Prompt)
- Übergänge zwischen Dialogzuständen: Erkennung von Nutzeräußerungen



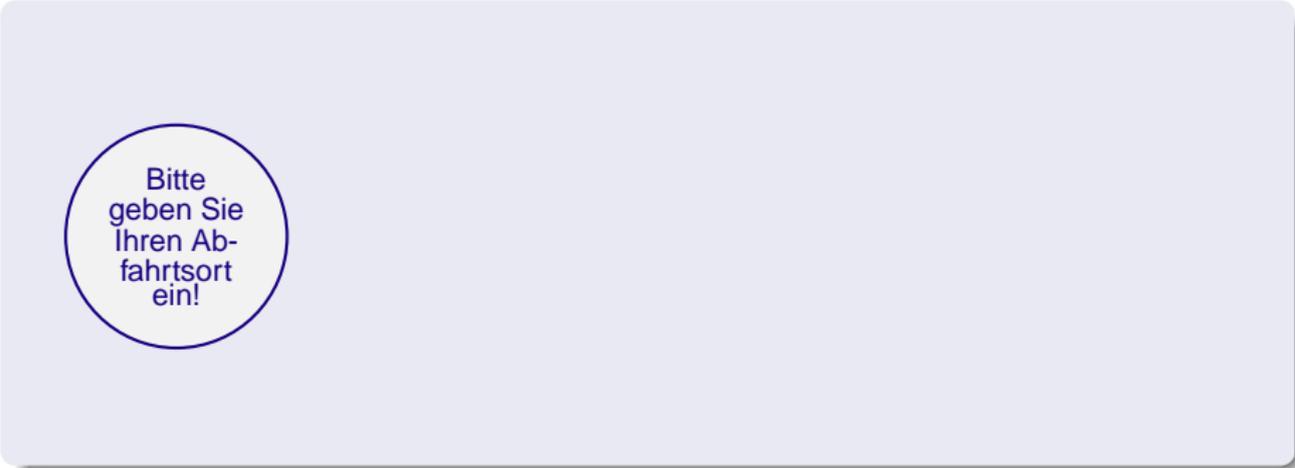
# Dialogmodellierung

- Dialogzustände: Aufforderung zur Eingabe (Prompt)
- Übergänge zwischen Dialogzuständen: Erkennung von Nutzeräußerungen



# Dialogmodellierung

- Mehrfachverwendung von Teilnetzen



Bitte  
geben Sie  
Ihren Ab-  
fahrtsort  
ein!

# Dialogmodellierung

- Mehrfachverwendung von Teilnetzen



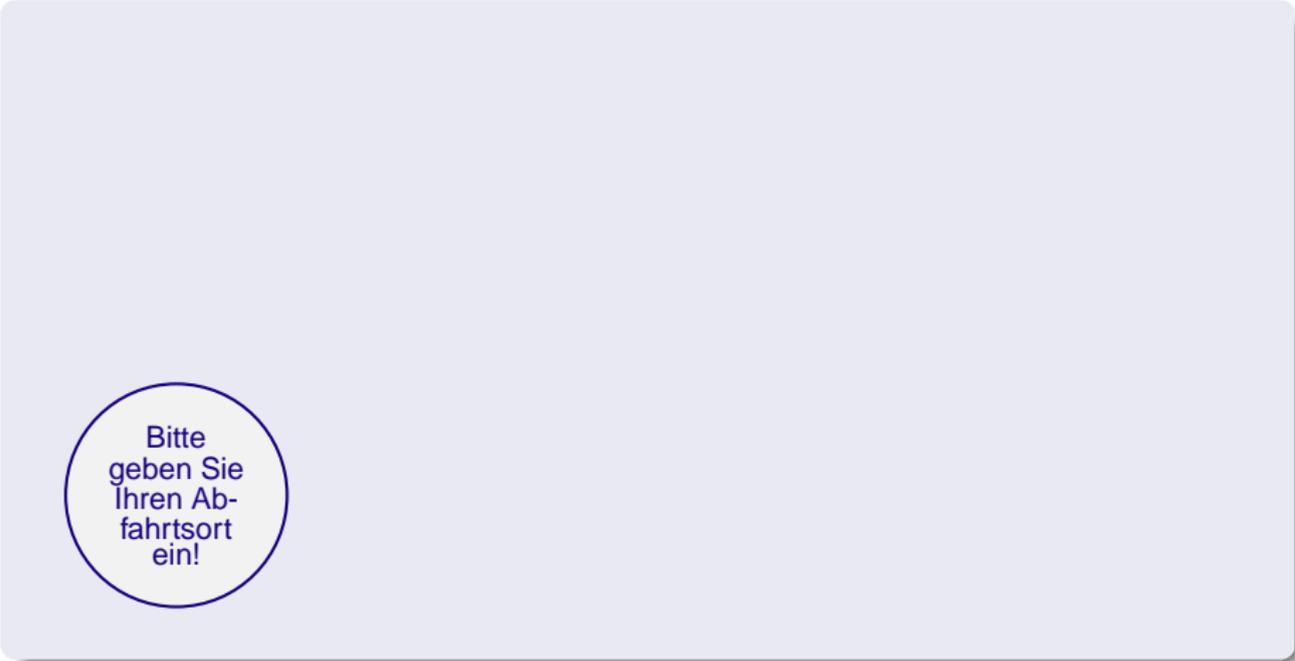
# Dialogmodellierung

- Mehrfachverwendung von Teilnetzen



# Dialogmodellierung

- sprecherunabhängige Spracherkennung ist unsicher
- insbesondere bei Telefoneingabe
- Erhöhen der Zuverlässigkeit durch Rückfragen



Bitte  
geben Sie  
Ihren Ab-  
fahrtsort  
ein!

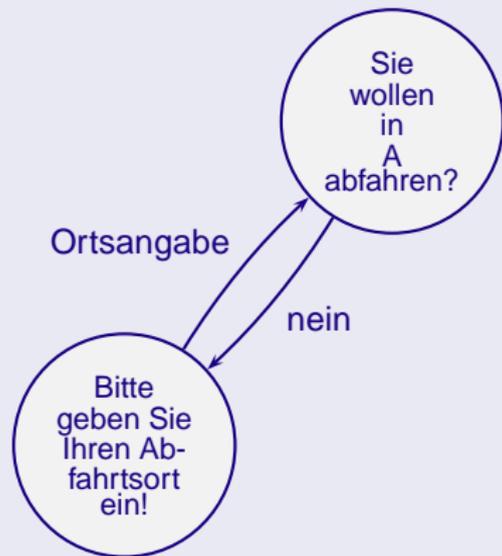
# Dialogmodellierung

- sprecherunabhängige Spracherkennung ist unsicher
- insbesondere bei Telefoneingabe
- Erhöhen der Zuverlässigkeit durch Rückfragen



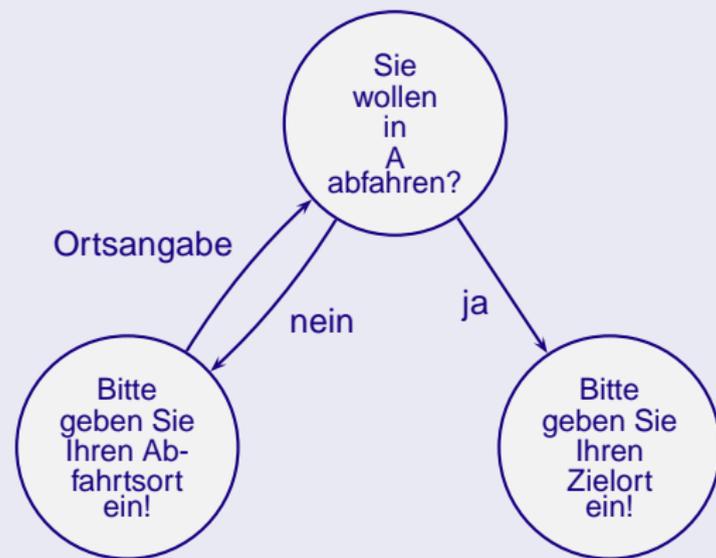
# Dialogmodellierung

- sprecherunabhängige Spracherkennung ist unsicher
- insbesondere bei Telefoneingabe
- Erhöhen der Zuverlässigkeit durch Rückfragen



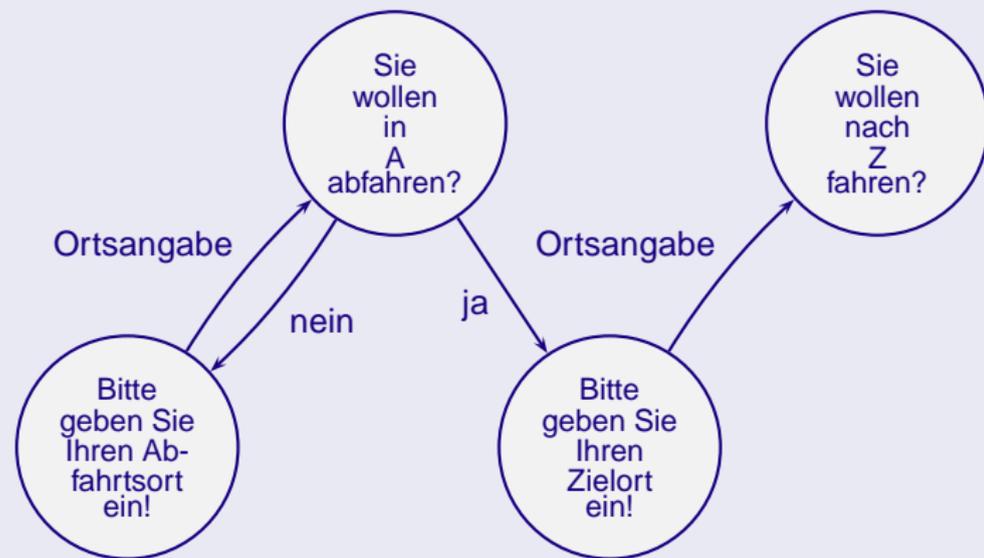
# Dialogmodellierung

- sprecherunabhängige Spracherkennung ist unsicher
- insbesondere bei Telefoneingabe
- Erhöhen der Zuverlässigkeit durch Rückfragen



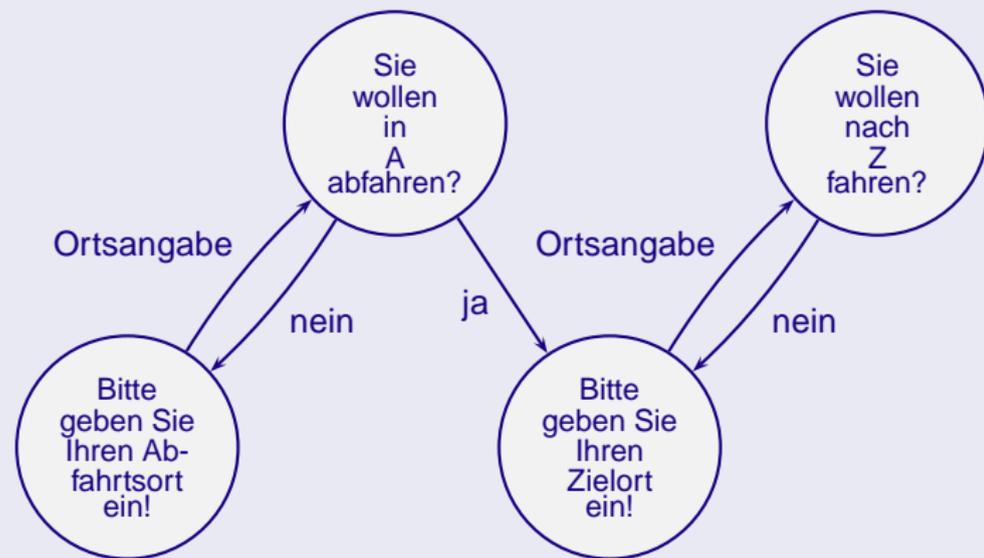
# Dialogmodellierung

- sprecherunabhängige Spracherkennung ist unsicher
- insbesondere bei Telefoneingabe
- Erhöhen der Zuverlässigkeit durch Rückfragen



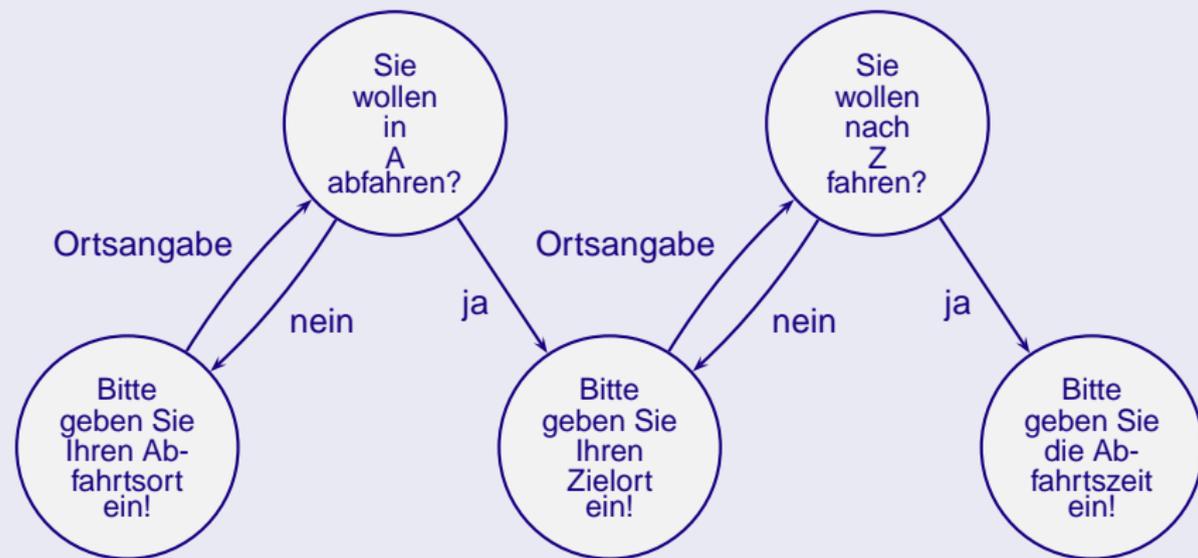
# Dialogmodellierung

- sprecherunabhängige Spracherkennung ist unsicher
- insbesondere bei Telefoneingabe
- Erhöhen der Zuverlässigkeit durch Rückfragen



# Dialogmodellierung

- sprecherunabhängige Spracherkennung ist unsicher
- insbesondere bei Telefoneingabe
- Erhöhen der Zuverlässigkeit durch Rückfragen



# Dialogmodellierung

- theoretische Grundlage: deterministischer endlicher Automat

# Dialogmodellierung

- theoretische Grundlage: deterministischer endlicher Automat
  - einfachstes Automatenmodell der Informatik
  - effiziente Implementierung
  - gute Vorhersagefähigkeit → starke Einschränkung des aktiven Wortschatzes

# Dialogmodellierung

- theoretische Grundlage: deterministischer endlicher Automat
  - einfachstes Automatenmodell der Informatik
  - effiziente Implementierung
  - gute Vorhersagefähigkeit → starke Einschränkung des aktiven Wortschatzes
- für natürliche Dialogführung zu rigide → Erweiterungen nötig

# Dialogmodellierung

- theoretische Grundlage: deterministischer endlicher Automat
  - einfachstes Automatenmodell der Informatik
  - effiziente Implementierung
  - gute Vorhersagefähigkeit → starke Einschränkung des aktiven Wortschatzes
- für natürliche Dialogführung zu rigide → Erweiterungen nötig
  - wechselnde Prompts
  - "Hineinreden" in den Prompt (barge in)
  - ...

# Dialogmodellierung

- Dialogmodellierung erfordert Vorhersehen möglicher Nutzerreaktionen
  - Hineinversetzen in den Nutzer
  - Wizard-of-Oz-Experimente

# Dialogmodellierung

- Dialogmodellierung erfordert Vorhersehen möglicher Nutzerreaktionen
  - Hineinversetzen in den Nutzer
  - Wizard-of-Oz-Experimente
- Dialogmodellierung schränkt die sprachliche Möglichkeiten eines Nutzers stark ein
  - Lenkung des Nutzers durch Vorgabe zulässiger Äußerungen (akustisches Menü)