

# Spoken Dialogue Systems

# Sprachdialogsysteme

---

Seminar (MSc)

Wintersemester 2011/2012

Timo Baumann

[baumann@informatik.uni-hamburg.de](mailto:baumann@informatik.uni-hamburg.de)

---

# Übersicht heute

---

- Amtl. Bekanntmachungen & Bürgersprechstunde
  - Besprechung der Leseaufgabe
  - Referat über Sprachsynthese
  - hoffentlich anschließende Fragen und Anmerkungen
-

# Termine

Datum	Thema	Referent
17.10.2011	Einführung	–
31.10.2011	Basistechnologien: Spracherkennung	Timo
07.11.2011	Leseaufgabe	--
14.11.2011	Basistechnologien: Sprachsynthese	Timo
21.11.2011	Semantic Frame-based NLU	Alexander
28.11.2011	Dialogablaufsteuerung	Arne
05.12.2011	entfällt	–
12.12.2011	Praktische Dialoggestaltung	Tim
19.12.2011	Evaluation von Dialogsystemen	Steffen
09.01.2012		
16.01.2012	Turn-Taking	Dimitri
23.01.2012	Inkrementelles Dialogmanagement	Wolfram
30.01.2012	Rückblick und Zusammenfassung	alle

# McTear 2004, Kapitel 1-3

---

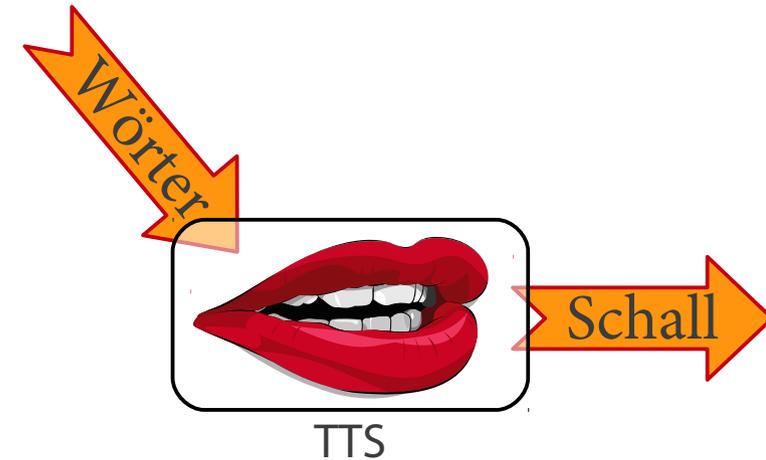
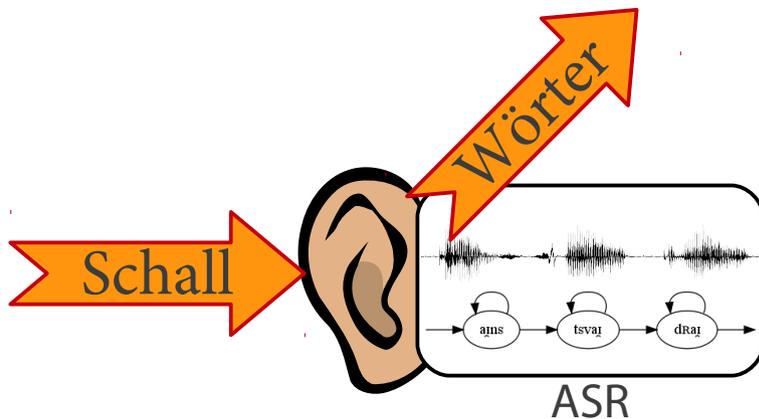
- Platz für Anmerkungen und Fragen

# Ein- und Ausgabe

## für Dialogsysteme

- neulich:  
Spracherkennung

- heute:  
Sprachsynthese

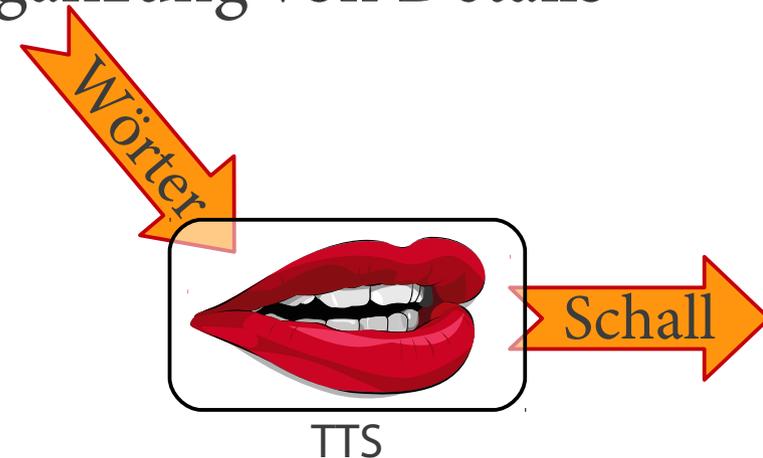
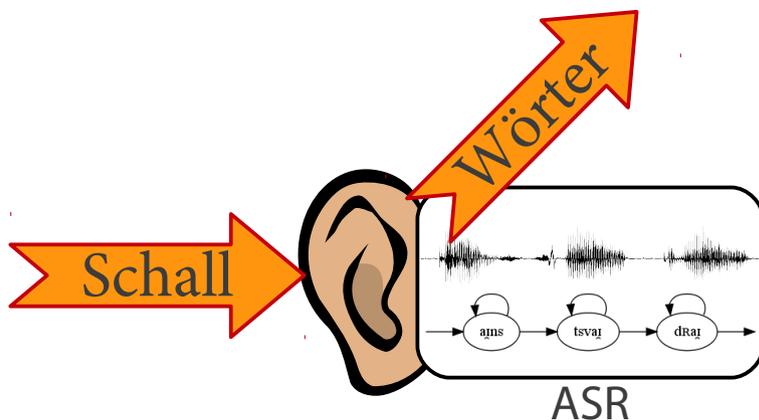


# Ein- und Ausgabe

## für Dialogsysteme

- Spracherkennung
  - Reduktion des Signals auf die Wörter
- Informationsverlust

- Sprachsynthese
  - Wörter allein beschreiben das Signal unzureichend
- Natürlichkeit erst durch Ergänzung von Details



# Geschriebene vs. gesprochene Sprache

---

- Was wird gesprochen aber nicht geschrieben?
    - Hässitationen, Filled Pauses, Conversational Grunts
    - Korrekturen, Tippfehler, Aussprachefehler
    - Betonung (Satz-, Wort-), Rhythmus
    - Prosodie: Intonation, Dauer, Lautheit, Pausen
    - Sarkasmus, Ironie, Emotion
    - extralinguistisches Verhalten: Gesten, Mimik, ...
-

# Geschriebene vs. gesprochene Sprache (Timos Liste)

---

- Text hat keine Sprechmelodie
    - Satzzeichen helfen nicht auf Diskursebene
  - Text enthält keine Angaben über Wortbetonungen
  - Homographen die keine Homophone sind: *Montage*
  - 
  - Abkürzungen, Datums-, Zahlenangaben im Text ...
-

# Linguistische Vorverarbeitung

## Text-to-Speech    Concept-to-Speech

---

- textbasierte linguistische Vorverarbeitung
- konkretes Wissen in der Vorverarbeitung
  - „Das Hindernis bitte umfahren.“

# Linguistische Vorverarbeitung

## Text-to-Speech    Concept-to-Speech

---

- textbasierte linguistische Vorverarbeitung
  - konkretes Wissen in der Vorverarbeitung
    - „Das Hindernis bitte umfahren.“
    - im Sinne von *über* oder *vorbei*?
    - „**ú**mfahren“, oder „um**fáh**ren“?
    - der Text gibt diese Information nicht her
-

# Linguistische Vorverarbeitung

## Text-to-Speech      Concept-to-Speech

---

- textbasierte linguistische Vorverarbeitung
    - „Das Hindernis bitte umfahren.“
  - Erraten der korrekten Sprechweise
  - Strategie: Vermeide Fehler durch schwach ausgeprägte Variation
  - konkretes Wissen in der Vorverarbeitung
  - Konstruktion aus dem angegebenen Kontext
  - kann durch ausgeprägte Variation überzeugen
-

# Abwägung

## Text-to-Speech / Concept-to-Speech

---

- eigentlich verfügt ein Sprachdialogsystem über die für CTS notwendige Information
  - einfachere Anbindung von TTS
    - reine Text-Schnittstelle,  
leichte Integration externer Datenquellen
    - domänenunabhängig (keine Wissensrepräsentation)
  - potentiell viel bessere Qualität von CTS
    - Gegebenheit, Topic, Fokus im Diskurskontext, ...
- teilweise Nutzung von Aussprache-Markup für TTS
-

# Aufbau von Sprachsynthesystemen

---

## 1. linguistische Vorverarbeitung

- Umwandlung in „Targets“, jeweils:  
Lautidentität, Lautdauer, Grundfrequenzverlauf,  
(Lautheit, Prosodielabel, ...)

## 2. Target → Sprachsignal entweder

- a. musterbasiert: vgl. Dynamic Time Warping
    - ♦ Diphonsynthese, konkatenative Synthese
  - b. parameterbasiert: HMMs in der Vorlesung
    - ♦ Vocoding, Parameter aus HMMs generiert
-

# weiterer Inhalt des Referats

---

- Linguistische Vorverarbeitung
  - Diphonsynthese
  - Signalangleichung bei musterbasierten Verfahren
  - konkatenative Synthese
  - Vocoding und HMM-Synthese
-

# Linguistische Vorverarbeitung

---

- Eingabe: entweder Text oder Konzepte
- häufig folgende Schritte

- Tokenisierung

Hallo !

Wie geht 's ?

- Text Normalisierung

hallo !

wie geht 's ?

- POS-Tagging

/ITJ /\$.

/KOKOM /VVFIN /PPER /\$.

- G2P

/halo:


vi: ge:t s /

- Prosodieerzeugung

H\* L-

L+H\* H-%

- akustische Parameter



# Diphonsynthese

---

- Aneinanderreihung von Sprachschnipseln
- Einheiten von jeweils der Mitte eines Targets bis zur Mitte des nächsten:

\_h+ha:+a:l+lo:+o:\_+\_v+vi:+i:g+ge:+e:t+ts+s\_

- Ziel:
    - Verkettung in der stabilen Phase
    - Abdeckung von Koartikulationseffekten
-

# Diphonsynthese

---

- Diphone sind von einem Sprecher aufgenommen
    - eingebettet in einen Trägersatz oder ein Trägerwort
    - zum Beispiel immer betont in der Mitte eines Wortes
  - ~40 Laute → theoretisch 1600 Lautübergänge!
  - Optimierung der Diphonabdeckung durch relativ wenige Trägersätze
    - vgl. IpdS-Sätze
    - ist das sinnvoll?
-

# Signalverarbeitung

---

- Ziele:
    - Verkettungsstellen unhörbar machen
    - Angleichung von Lautheit und Grundfrequenz
    - Manipulation von Grundfrequenz und Dauer
  - PSOLA: Pitch-Synchronous Overlap and Add
    - Lautidentität und -charakteristik bleibt erhalten
    - erlaubt Anpassung der Grundfrequenz
    - erlaubt Anpassung der Lautdauer
  - Lautheit durch Amplitudenskalierung
-

# PSOLA

---

1. Markierung der Signalperioden (am Nulldurchgang)
  - nicht trivial, weil Sprache ein komplexes Signal ist
2. Fensterung im Bereich jeder Periode
3. Überlappen und Addieren der Perioden
  - Verändern der Periode → Grundfrequenzanpassung
  - Wiederholung/Auslassung von Perioden → Daueranpassung
  - Signalcharakteristik bleibt weitestgehend erhalten
    - allerdings Artefakte bei starker Manipulation

# Diphonsynthese – Bewertung

---

- allerdings ändert sich im natürlichen Sprachsignal einiges in Abhängigkeit von Lautheit und Sprechhöhe
  - es bleiben an den Verkettungsstellen unnatürliche Sprünge im Spektrum
    - das Hörorgan kann diese nicht interpretieren  
→ Stimme klingt unnatürlich
  - Vorteile: kleine Datenbasis (Aufnahme und Speicherung), geringer Berechnungsaufwand
-

# Konkatenative Synthese

---

- große Auswahl für Mapping Target → Lautmaterial
    - besser zur Targetsequenz passendes Lautmaterial
    - dadurch weniger (oder keine) Signalverarbeitung nötig
  - Einheitenauswahl als Suche in einem Sprachkorpus
    - untereinander passende Einheiten → Verkettungskosten
    - zum Target passende Einheiten → Targetkosten
  - Suchalgorithmus nach Wahl, potentiell teuer
  - hoher Rechenaufwand, sehr hoher Speicherbedarf
  - deutlich höhere Natürlichkeit des Resultats
-

# Konkatenative Synthese

---

- weiterhin nur „Wiedergabe“ des Lautmaterials, aber keine Abstraktion/Modellierung der Eigenschaften des Lautmaterials
  - z.B. Adaption an Emotionen bleibt unmöglich (es sei denn Sprachkorpus enthält alles Material in emotional gefärbten Varianten)
  - Adaption an Heiserkeit/Schnupfen/Weinen/...
  - Kombination aller Stellschrauben
-

# Vocoding und HMM-Synthese

---

- Quelle-Filter-Modell der Spracherzeugung
    - Stimmlippen im Kehlkopf erzeugen Primärschall
      - ♦ periodisch bei stimmhaften Lauten, obertonreich
      - ♦ Rauschen bei stimmlosen Lauten
    - Ansatzrohr bildet Resonanzkörper
      - ♦ unterschiedlich starke Dämpfung von Frequenzbereichen
      - ♦ zusätzliche Schallquellen bei Konsonanten durch Verwirbelungen (Frikative), Plosive
    - Sprachsignal = Primärschall  $\otimes$  Resonanz ( $\oplus$ Zusatzzahl)
-

# Vocoding II

---

- wir brauchen also
    - Parameterdarstellung des Resonanzkörpers
    - Stimmhaftigkeit → je nach Laut, also bekannt
    - Grundfrequenzverlauf → brauchten wir eh schon
  - früherer Ansatz: Parameter werden regelbasiert für die Laute (und Lauttrajektorien) erzeugt
    - klingt seeeeeehr unnatürlich
  - Resonanzkörperbeschreibung wie bei der ASR
    - dann können wir HMMs auf einem Korpus trainieren!
-

# HSMM-Synthese

---

- heute suchen wir tatsächlich

$$\hat{O} = \operatorname{argmax} O : P(O|W) \quad (\text{bzw. } P(O|\text{Ph}))$$

die wahrscheinlichste Observation zur Phonemfolge

- HSMM: Hidden Semi-Markov Modelle: Anzahl der Observations in einem Zustand ist festgelegt
    - Lautdauermodelle können dies sehr gut bestimmen
    - wir brauchen nicht mehr die optimale Zustandsfolge suchen (sie ist einfach festgelegt)
  - Suche reduziert sich auf lineares Gleichungssystem
-

# HMM-Synthese

---

- Problem 1: die wahrscheinlichste Observation in einem Zustand ist immer genau der Mittelwert
  - Sprünge an Zustandsübergängen
- Abhilfe 1: wie in ASR müssen wir die Kontinuität bei Veränderungen modellieren
  - durch „dynamische Features“, die ins Gleichungssystem mit eingehen; je nach Zustand unterschiedliche Gewichtung der Dynamisierung; meist  $\Delta$  und  $\Delta\Delta$

# HMM-Synthese

---

- Problem 2: immernoch keine Abweichungen von der Ideallinie; zu geringe Varianz im Signal
  - braucht der Mensch, damit es „natürlich“ klingt
- Abhilfe 2: Global Variance Optimization
  - boostet „unwahrscheinliche“ Observations, sodass die globale Varianz erreicht wird, die Mittelwerte erhalten bleiben
  - variablere Synthese, aber eben natürlicher

# HMM-Synthese – Bewertung

---

- höherer Abstraktionsgrad bei ähnlich guter Leistung
  - vergleichsweise klitzekleine Modelle (10MB vs. 500)
  - Erkennung und Synthese aus ähnlichen Modellen
    - aber: beim Menschen grundverschiedene Organe...
  - Nutzbarkeit von ASR-Technologien für Sprecheradaption
-

# Zusammenfassung

---

- Linguistische Vorverarbeitung
  - Diphonsynthese
  - Signalangleichung bei musterbasierten Verfahren
  - konkatenative Synthese
  - Vocoding und HMM-Synthese
    - parameterbasiert
    - Parameter werden aus Korpus gelernt
-

# Spoken Dialogue Systems

# Sprachdialogsysteme

---

Vielen Dank für die Aufmerksamkeit.

---

- 
- Platz für Fragen und Anmerkungen
-

# Termine

Datum	Thema	Referent
17.10.2011	Einführung	–
31.10.2011	Basistechnologien: Spracherkennung	Timo
07.11.2011	Leseaufgabe	--
14.11.2011	Basistechnologien: Sprachsynthese	Timo
21.11.2011	Semantic Frame-based NLU	Alexander
28.11.2011	Dialogablaufsteuerung	Arne
05.12.2011	entfällt	–
12.12.2011	Praktische Dialoggestaltung	Tim
19.12.2011	Evaluation von Dialogsystemen	Steffen
09.01.2012		
16.01.2012	Turn-Taking	Dimitri
23.01.2012	Inkrementelles Dialogmanagement	Wolfram
30.01.2012	Rückblick und Zusammenfassung	alle