

Einführung in die Spracherkennung & Sprachsynthese

Lucia D. Krisnawati

Vorlesungsinhalt

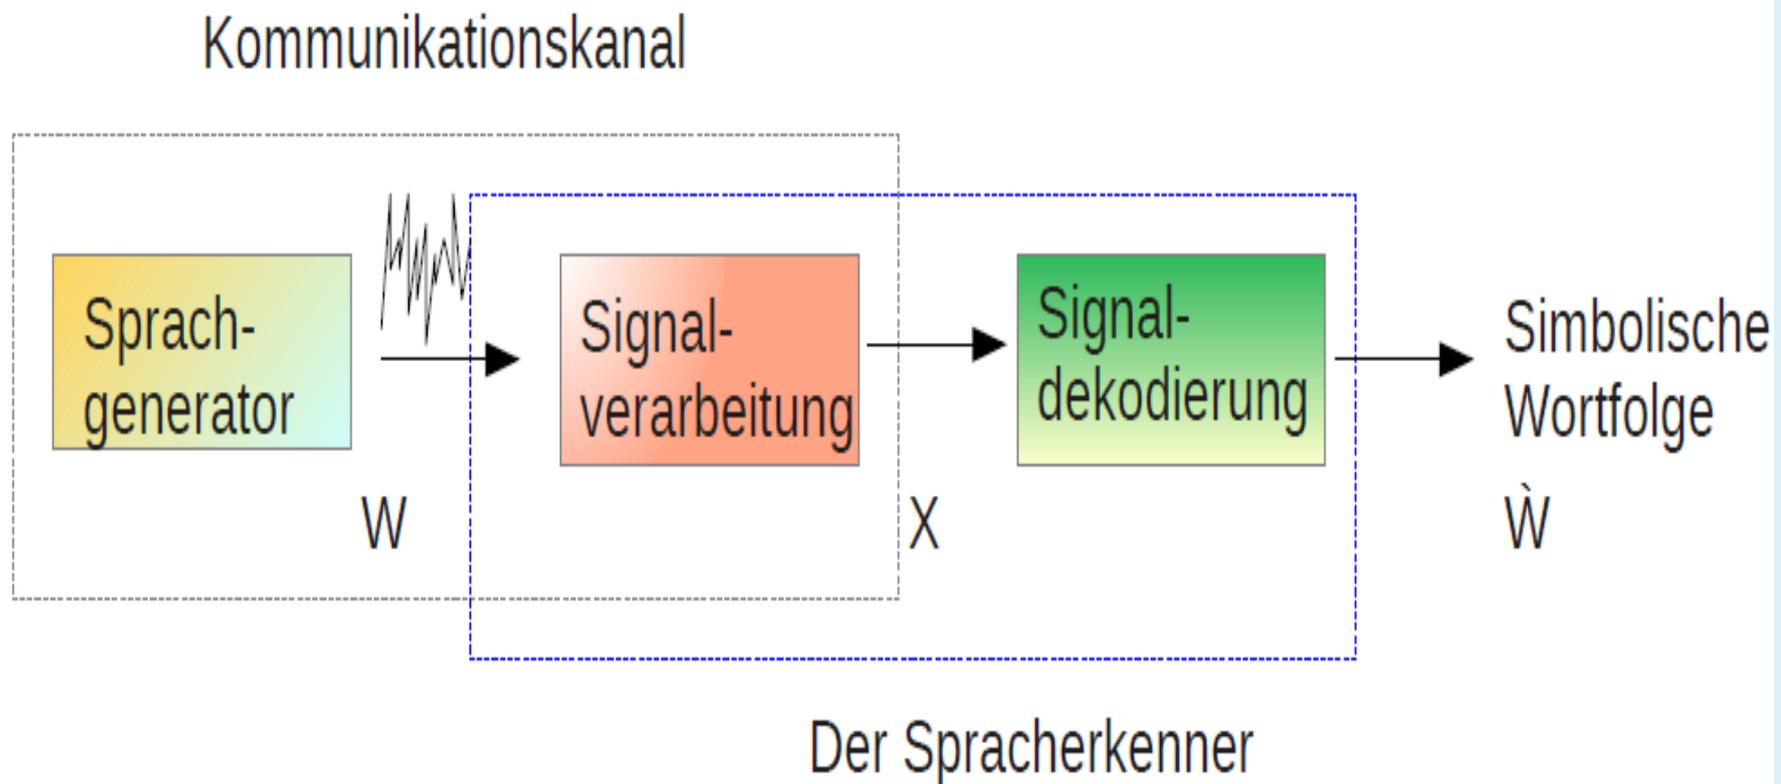
- Spracherkennung:
 - Einleitung
 - Die Architektur der Spracherkennung
 - Die Spracherkennungskomponente
 - Sie Anwendungen & Demo
- Sprachsynthese:
 - Die Architektur der Sprachsynthese
 - Die Komponente der Sprachsynthese
 - Die Anwendungen & Demo

Was ist automatische Spracherkennung (ASR) ?

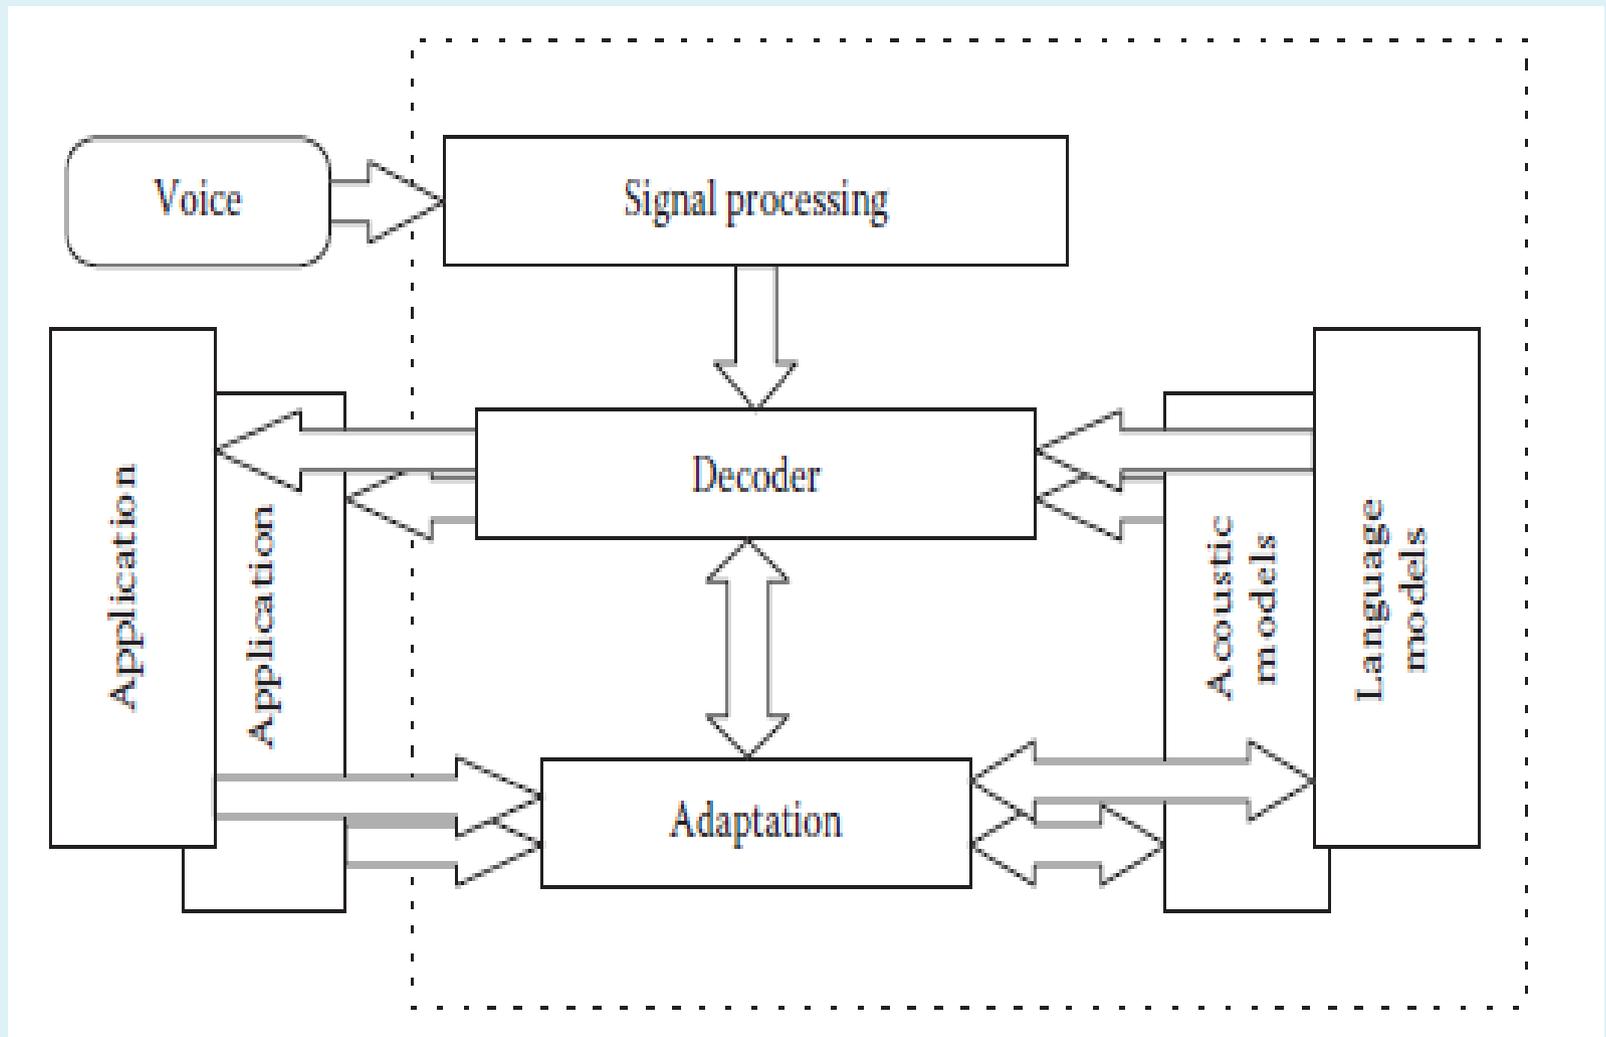


Ziel der ASR

- Ziel der ASR ist die symbolische Darstellung einer sprachlichen Äußerung, die als akustisches Signal vorliegt.



Die Architektur der ASR

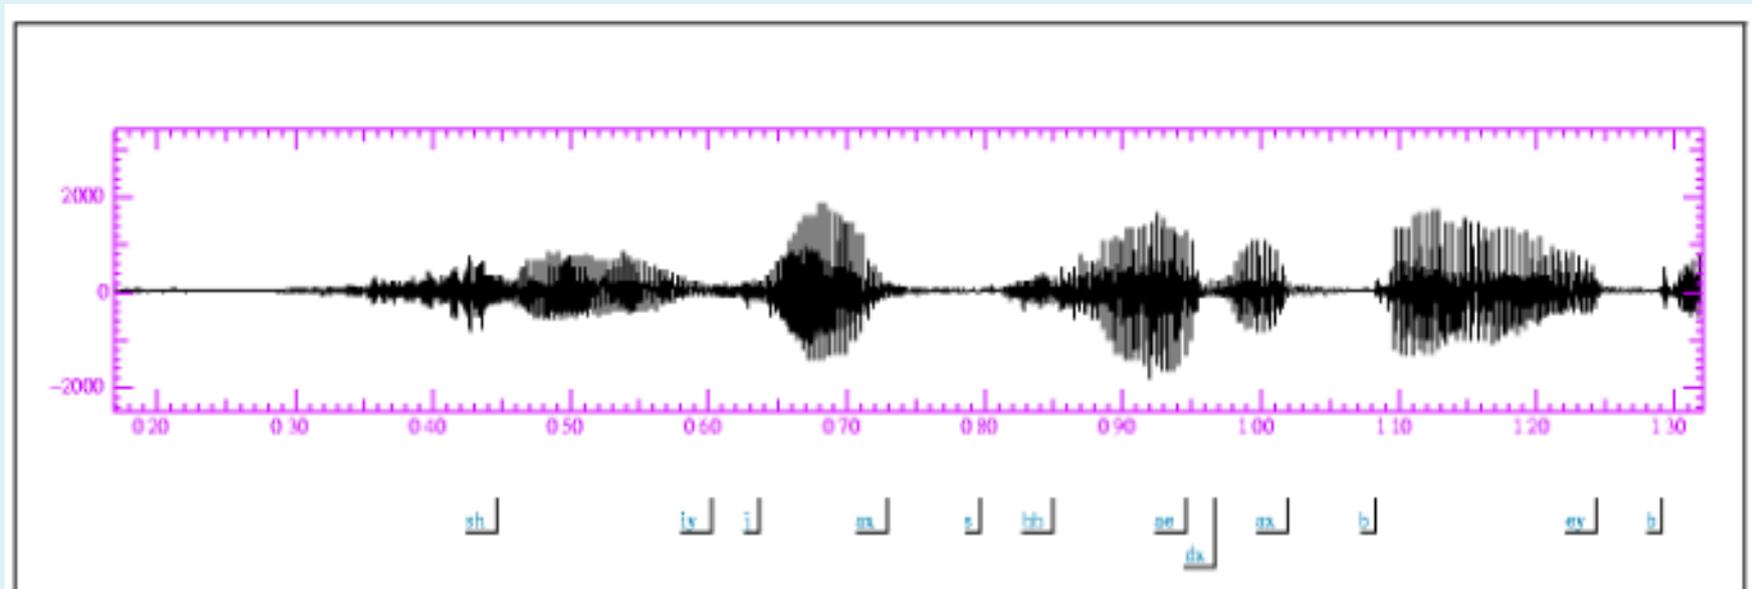


Die Architektur der ASR

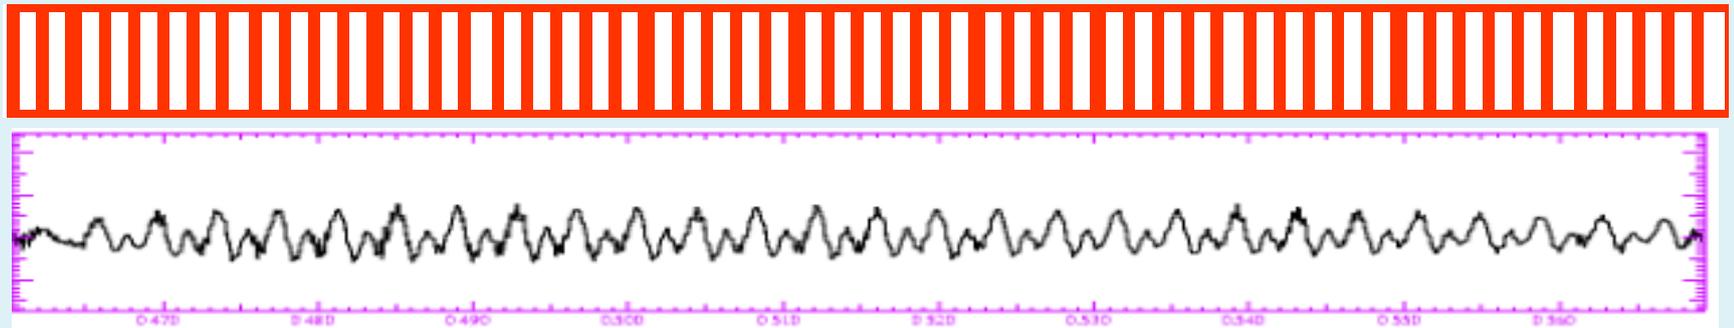
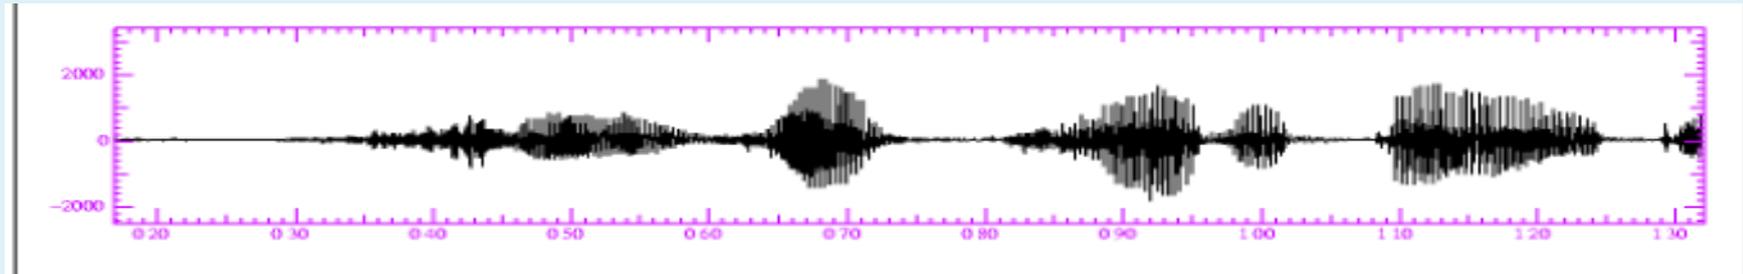
- Die Komponenten der Spracherkennung:
 - Signal Verarbeitung
 - Dekodierung, die 2 Modelle ausnutzt:
 - Akustische Modellierung
 - Sprachmodellierung
 - Adaptation

Signalverarbeitung

- 2 Hauptmerkmale eines akustischen Signals:
 - Die Frequenz : wie oft wiederholt sich eine Schallwelle in einem Durchlauf pro Sekunde
 - Die Amplitude: zeigt die Höhe des Luftdrucks
- Wie interpretieren wir eine Schallwelle?



Signalverarbeitung




- Die Schallwelle wird im Fenstersegment etwa 10,15,20 ms geschnitten.
- Das Fenstersegment wird in Spektrumsmerkmale transformiert.
- Spektrumsmerkmal ist eine Repräsentation der Schallwelle bezüglich der Frequenzverteilung.

Signalverarbeitung

- Die Phase der Merkmalsextraktion besteht aus:
 - Signalabtastung
 - Quantisierung
 - Phonererkennung
- Signalabtastung:
 - Das kontinuierliche Signal wird an Äquidistante Zeitpunkten abgetastet.
 - Nach dem Shannon'schen Abtasttheorem reichen 8kHz & 16kHz aus um die Hauptspektralanteile abtasten zu können.
 - Mindestens gibt es 2 Abtastungen in einem Ablauf, eine für positive Werte und die andere für negative Werte.
 - Die Speicherung erfolgt für Diktieranwendungen auf 16 bit & für Telefonanwendungen auf 8 bit.

Signalverarbeitung

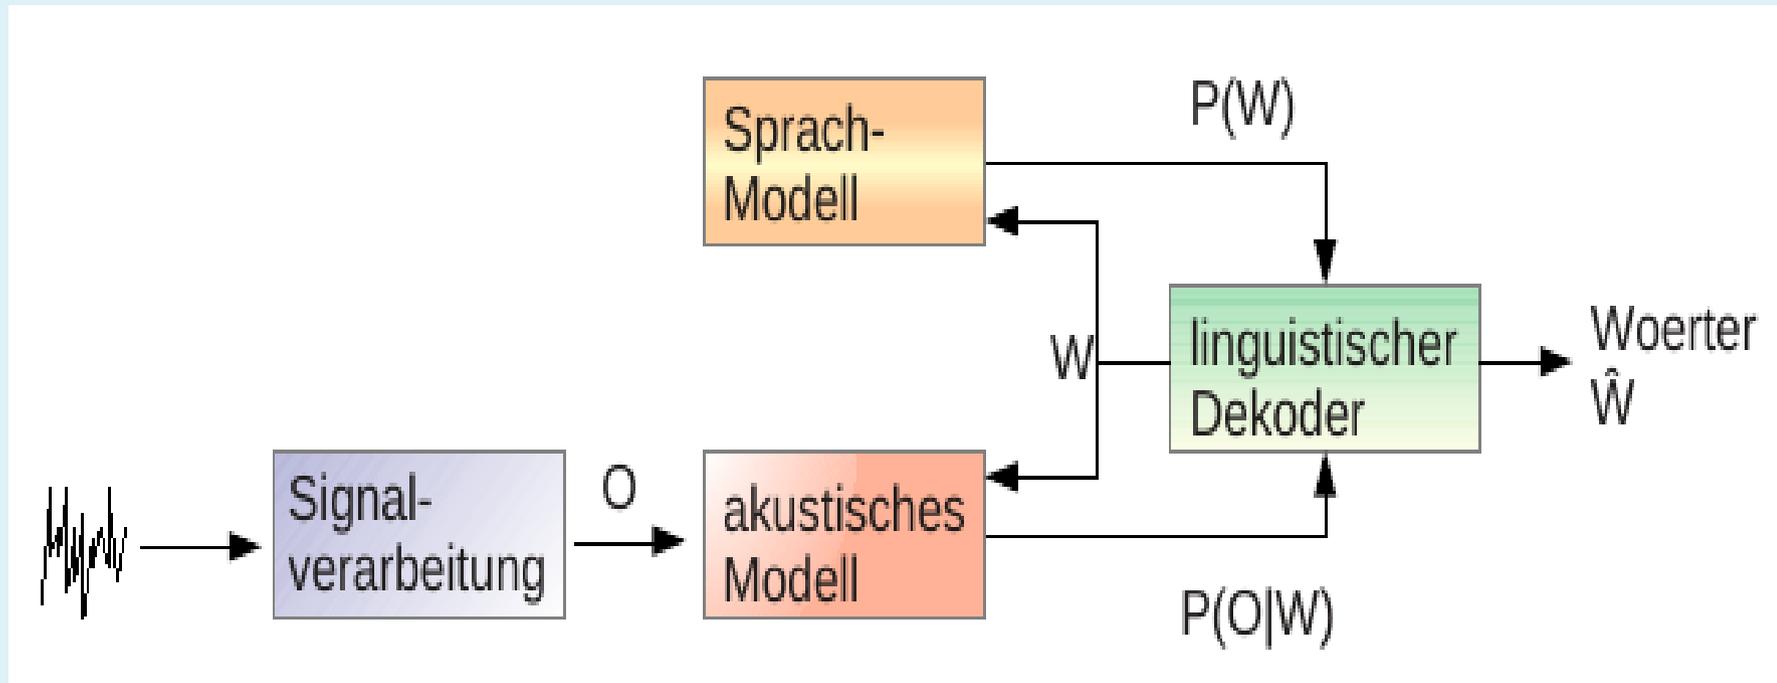
- Quantisierung:
 - Das abgetastete Signal wird quantisiert.
 - Quantisierung ist ein Umwandlungsprozess einer real-bewerteten Zahl zu einem Integer.
 - Resultat ist eine Diskrete Folge von Signalwerte



Signalverarbeitung

- Phonererkennung :
 - Benutzt statistische Ansätze wie Neuronale Netze oder Gaussianisches Modell, um das individuelle Phon zu erkennen, z.B. [p], [b].
 - Die Ausgabe ist ein wahrscheinlichster Merkmalsvektor eines Phons in jedem Fenstersegment.
 - Wie berechnet man eine Wahrscheinlichkeit der Merkmalsvektoren?
 - Erst wird die Signalwerte in einem berechenbar diskreten Symbol „geclustert“.
 - Die Wahrscheinlichkeit von gegebenen Cluster wird durch ihre Häufigkeiten im Trainingsdata berechnet.

Dekodierung



- Ziel der Dekodierung ist die Entdeckung einer Wortfolge, deren akustische & Sprachmodelle ganz ähnlich zu der Eingabe in der Form einer Merkmalvektorfolge sind.

Dekodierung

- Wahrscheinlichkeitsmodell
 - Umformulierung mit Bayes :

$$\hat{W} = \underset{W \in \mathcal{L}}{\operatorname{argmax}} \frac{P(O|W) P(W)}{P(O)}$$

- übrig bleibt:

$$\hat{W} = \underset{W \in \mathcal{L}}{\operatorname{argmax}} P(O|W) P(W)$$

- $P(O|W)$: welche akustische Beobachtungen sind bei Äußerung einer Wortfolge W zu erwarten → **akustisches Modell.**
- $P(W)$: Welche Wortfolgen sind im Anwendungskontext zu erwarten → **Sprachmodell**

Akustisches Modell



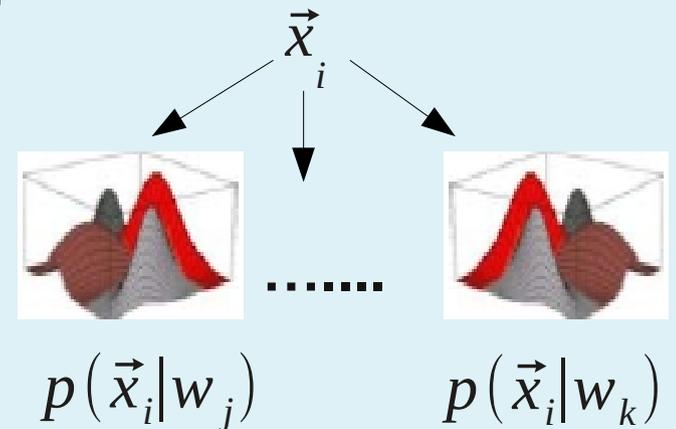
- Berechnung der Merkmalsvektoren

$$P(O|W) = \prod_{i=0}^N P(\vec{x}_i|w_i)$$

- Jede phonetische Einheit wird z.B. von Gaussdichtung modelliert:

$$P(\vec{x}|w) = \sum_{j=0}^M g_j N(\vec{x}|\mu_j, \Sigma_j)$$

- Wobei g_j , μ_j , & Σ_j für die Gewichtung, Mittelwert & Kovarianz stehen



Sprachmodell

- ASR-System schränkt viele möglichen Wortkombinationen beim Sprachmodell ein:
 - Finite-state network
 - Deterministisch, sequenzielle Hemmung (Wortpaar).
 - Probabilistisch, sequenzielle Hemmung (Bigramm, Trigramm)
 - Bi-/Trigramme sind das dominierende Sprachmodell für ASR:

$$P(W_i | w_{i-2}, w_{i-1}) = \frac{C(w_{i-2}, w_{i-1}, w_i)}{C(w_{i-2}, w_{i-1})}$$

wobei $C(x)$ steht für die Anzahl des Vorkommens von x in Trainingsdata.

Sprachmodell

- zB. in Training data: „John read her book. I read a different book. John read a book“
- Die Benutzung der Bigramme, um 3. Satz zu berechnen:

$$P(\text{John}|\langle s \rangle) = \frac{C(\langle s \rangle, \text{John})}{C(\langle s \rangle)} = \frac{2}{3} \quad P(\text{read}|\text{John}) = \frac{C(\text{John}, \text{read})}{C(\text{John})} = \frac{2}{2}$$

$$P(a|\text{read}) = \frac{C(\text{read}, a)}{C(\text{read})} = \frac{2}{3} \quad P(\text{book}|a) = \frac{C(a, \text{book})}{C(a)} = \frac{1}{2}$$

$$P(\langle s \rangle|\text{book}) = \frac{C(\text{book}, \langle s \rangle)}{C(\text{book})} = \frac{2}{3}$$

- $P(\text{john}, \text{read}, a, \text{book}) = P(\text{John}|\langle s \rangle)P(\text{read}|\text{John})P(a|\text{read})P(\text{book}|a)P(\langle /s \rangle|\text{book}) \approx 0.148$

Adaptation

- Adaptation bezieht sich auf die Fähigkeit, um sich lernen zu können.
- Hintergrund: Mensch-geliefertes Wissen ist sehr schnell veraltet, z.B. Aussprachewörterbuch
- Selbstlernende Fähigkeit wird durch Generalisierung realisiert:
 - kleine Testdaten, die ganz ähnlich zu Trainingsdaten
 - Trainingsdatenpartition
- Die Adaptation ist noch eine Herausforderung in heutzutage ASR

ASR Anwendungen & Demo

- Samsung's Smartphone :

- Voice Talk, Voice command, voice search

[/mounts/Users/student/lucia/Documents/lucias-file/CL1/lecture/Samsung Galaxy S II Voice Talk App Demo using Justin Bieber - Glenn Ong of Glich's Life.mp4](#)

- Android vs Iphone

- Google Now vs Siri

[/mounts/Users/student/lucia/Documents/lucias-file/CL1/lecture/Google Now vs. Siri: The results speak for themselves.mp4](#)

ASR Anwendungen

- Sprach-gesteuerter Software im Auto, z.B. BMW



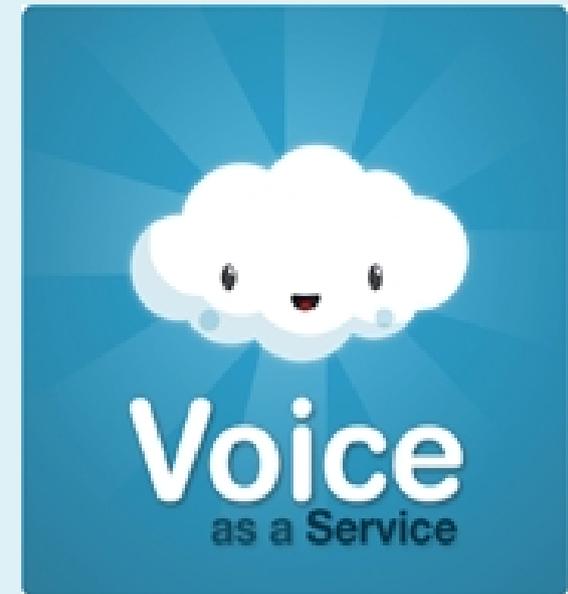
- Front-end Technology in Dialogsysteme:
 - Deutsche Bahn, (0800-1-507090 oder 0241-604020)
 - Sparda-Bank

Probleme der ASR

- Phonologische Variationen:
 - Lokale und globale Kontexte
- Individuelle Variationen:
 - Anatomie & sozial-linguistischer Faktor
- Umgebungsfaktor:
 - Störungen, Geräusch
- Variationen der Sprachbenutzung
 - Syntax, Semantik, Diskurs
- Real-Welt Probleme
 - Störung des Redeflusses, neue Wortschätze
-

Sprachsynthese

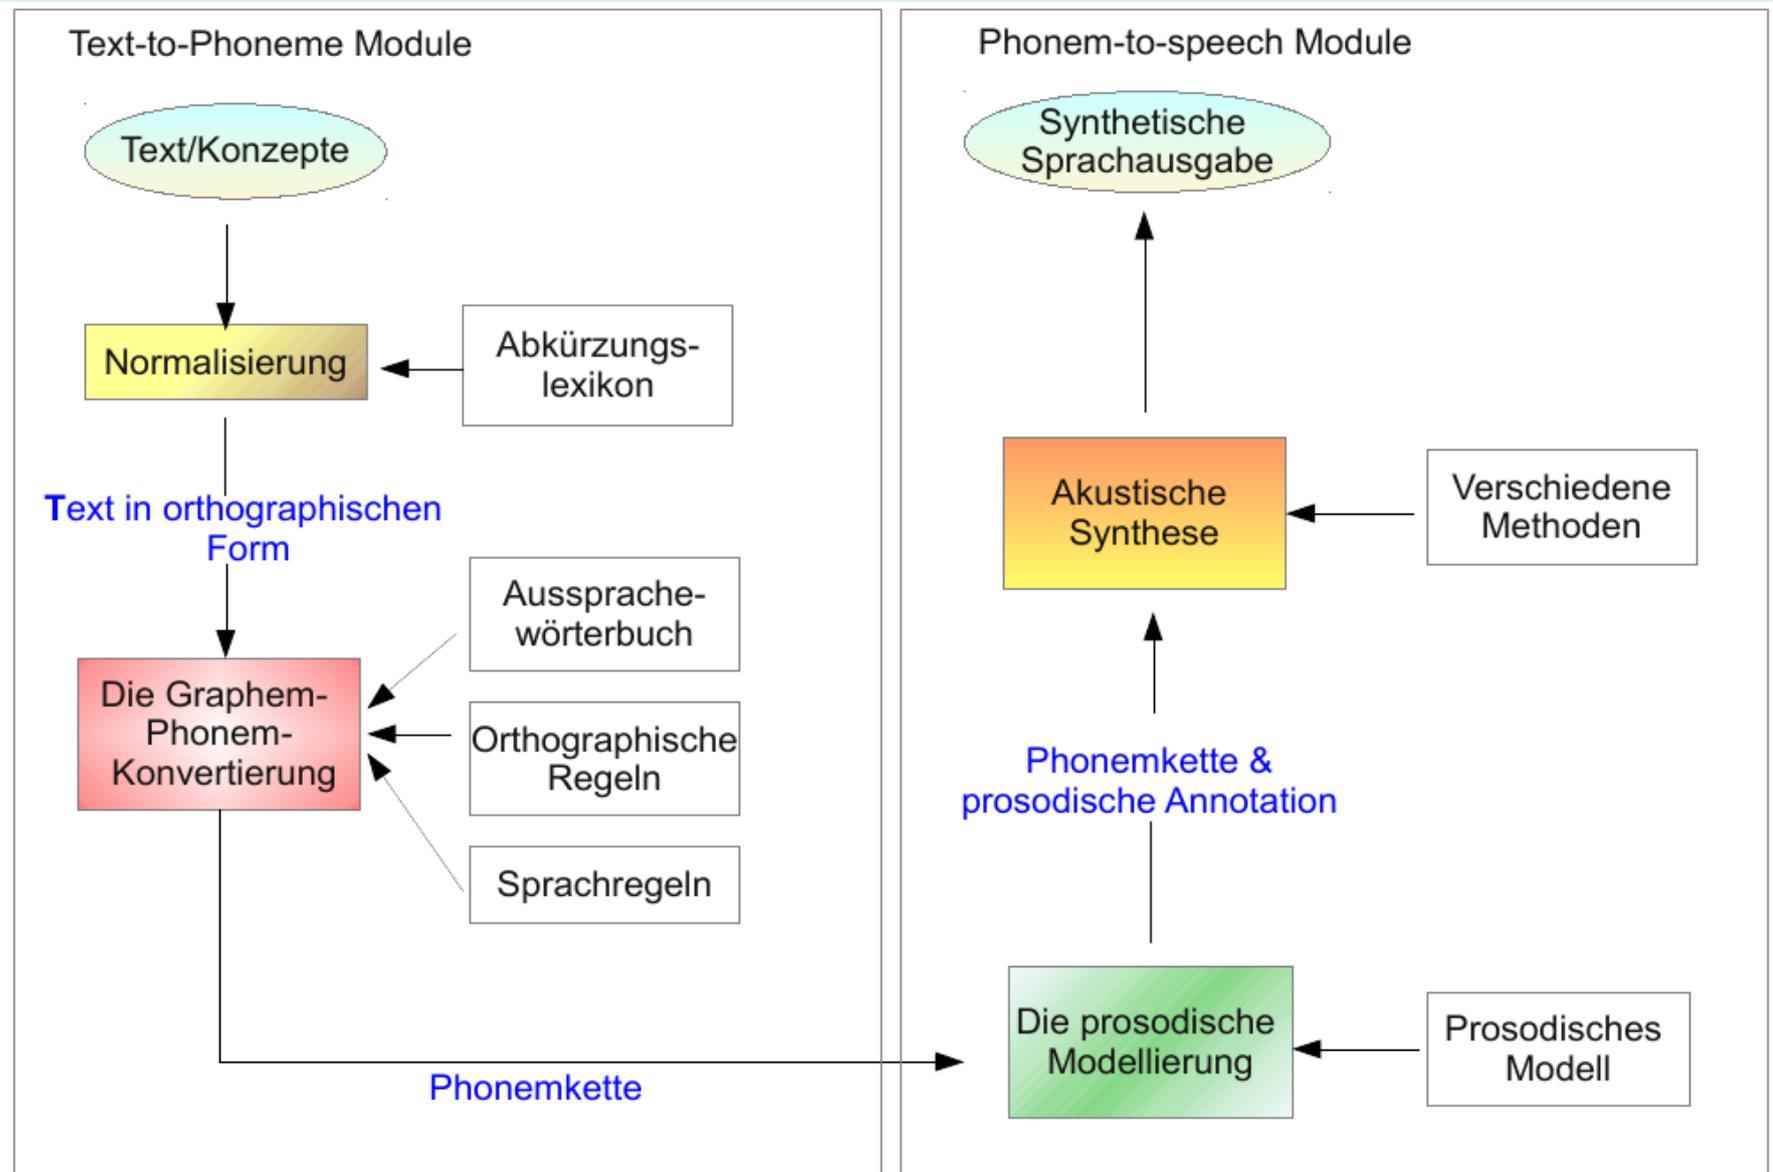
Was ist eine Sprachsynthese?



Sprachsynthese

- Sprachsynthese wird auch als 'Text-to-Speech' (TTS) genannt.
- TTS ist ein System, das Text als Eingabe in einer synthetischen Sprache konvertiert
- Eingabetyp:
 - Text-zu-Sprache vs. Konzept-zu-Sprache (CTS)
 - In CTS wird die Inhalt der Gespräch/Nachricht durch internen Repräsentationen ermittelt.
 - z.B. Datenbank aus Anfragesystem

Die Architektur der TTS



Komponente der TTS

- Komponente einer TTS:
 - Textnormalisierung
 - Graphem-Phonem-Konvertierung
 - Prosodische Modellierung
 - Akustische Synthese

Textnormalisierung

- Jedes Wort & Text, das besondere Aussprache hat, soll ins Lexikon gespeichert werden:
 - Abkürzungen (Dr., Str. usw)
 - Akronyme (UNESCO, ADAC, BaFög)
 - Spezielle Symbole (&, %)
 - Schreibkonventionen (\$5 Million, 12°C)
 - Zahlen (Telefon, Datum)
 - 1995 1,995
 - 199 5236 

Graphem-Phonem-Konvertierung

- Benutzung einer Aussprachewörterbuch
 - Enthält Lemma und ihre Aussprache
 - Viele Ausnahme sollen auch im Lexikon/Wörterbuch vorhanden sein
- Lexikon oder Regeln?
 - Es gibt kein Problem bei der Wortsuche und Speicherung → Sehr schnell
 - Aber benötigt Regeln für die unbekanntenen Wörter
- Manche Wörter haben mehrfachen Aussprachen
 - Freie Variation (either, economics)
 - Konditionierte Variation (schwache Forme, the, adult)
 - Homograph (does, content)

Graphem-Phonem-Konvertierung

- Die Homograph-Disambiguierung benötigt eine syntaktische Analyse
 - He makes a record of everything they record.
 - She is getting number as she stays in room number 124.
- Syntaktische Analyse ist auch benötigt, um die prosodische Merkmale zu bestimmen.

Prosodische Modellierung

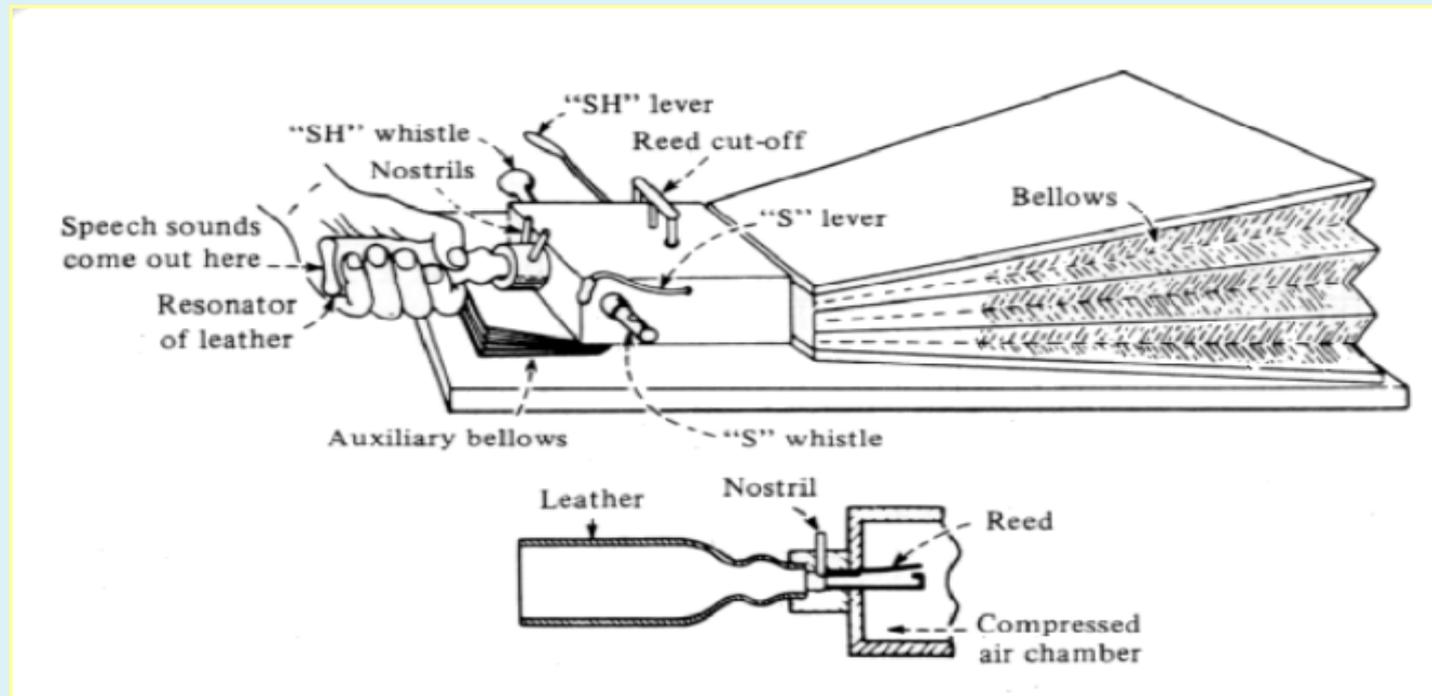
- Die Tonhöhe (pitch), Länge, Lautheit
- Die Satzmelodie (Tonhöhe):
 - Wird benötigt, um den monotonen Klang zu vermeiden
 - Sehr eng verbunden mit der Syntax (Frage, Aussage)
 - Wird benötigt, um den Satz zu thematisieren

Akustische Synthese

- Die alternativen Methoden:
 - Artikulatorische Synthese
 - Formantsynthese
 - Konkatenative Synthese
 - Diphon Synthese
 - Unit Selection Synthese

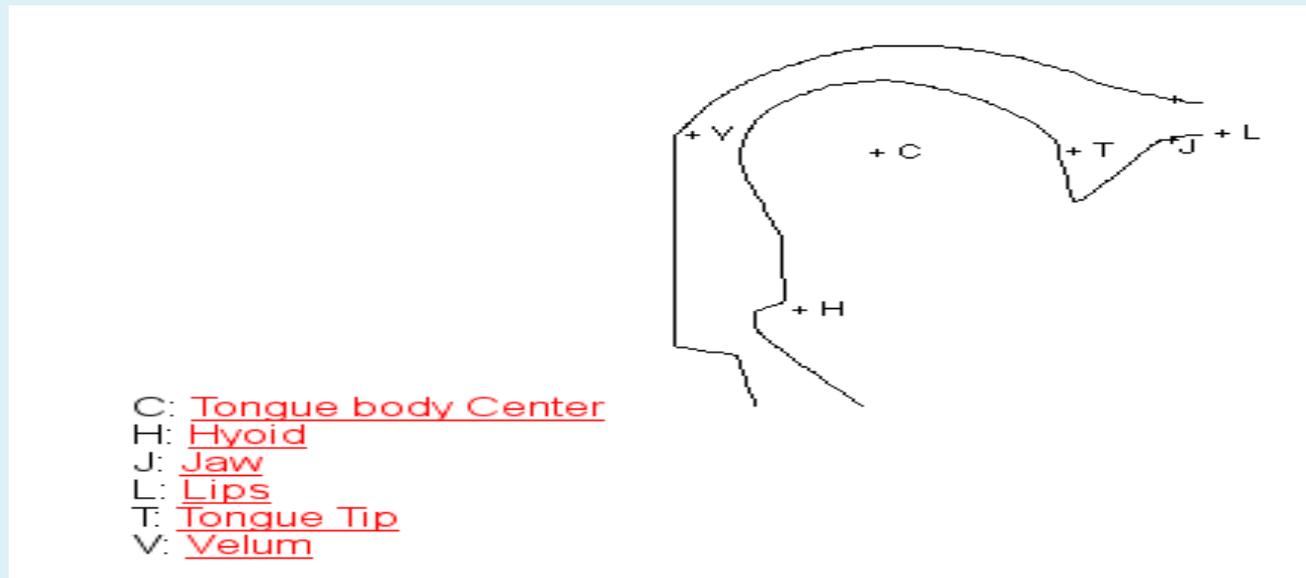
Die artikulatorische Synthese

- Physikalisches Modell für Simulation der Artikulation von Sprachlauten.
 - Man versucht die menschliche Sprachproduktion nachzubilden.
- Wolfgang v. Kempelen (1734-1804) benutzte die Bälge, Röhre, & Blätter.



Die artikulatorische Synthese

- Die moderne Version simuliert die Effekte der artikulatorischen Positionen, z.B. Model des Schwingenden Lippen, Model des Vokaltrakts



- Zu viel Arbeit ohne gutes Ergebnis
- Beispiel:
/mounts/Users/student/lucia/Documents/lucias-file/CL1/lecture/koeln_artikulator_demo.mp3

Die Formantsynthese

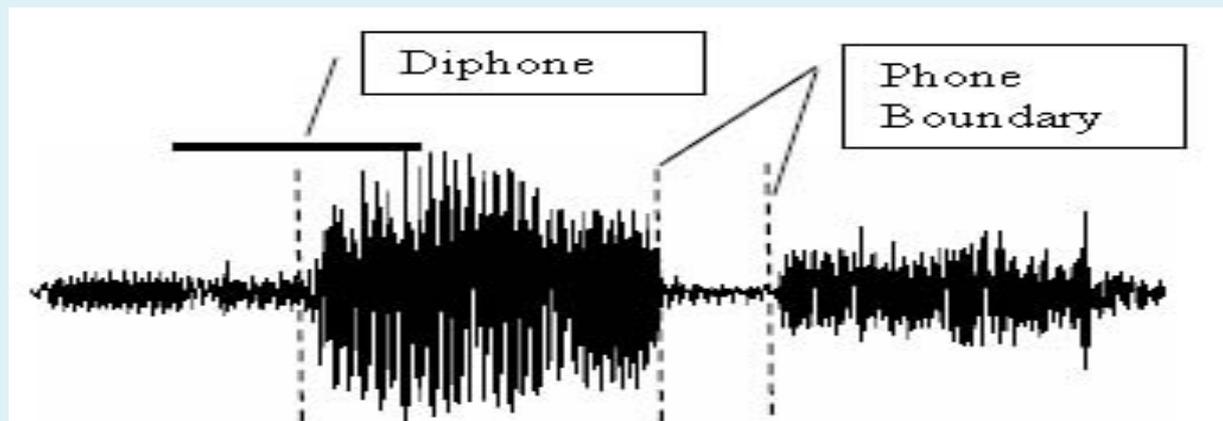
- Formant: die Konzentration akustischer Energie in einem bestimmten Frequenzbereich.
- Formantsynthese versucht die relevanten Merkmale von der akustischen Signalen nachzubilden:
 - Amplitude & Formantfrequenz
 - Die Resonanz & Geräusch, z.B für Nasale, Laterale, Frikative, usw.
- Die werte der akustischen Parameter werden von den Regeln der Aussprachebezeichnung abgeleitet.
- Das Ergebnis ist verständlich aber klingt unnatürlich.
- Beispiel: Eloquence
 - /mounts/Users/student/lucia/Documents/lucias-file/CL1/lecture/el_oqdemo.mp3

Konkatenative Synthese

- Basis ist eine Sprachdatenbank
 - Sprache wird aufgenommen, segmentiert und annotiert.
- Die Verkettung der Sprachsignale erfolgt durch Auswahl der am besten zueinander passenden Teilsignale.
- Das Segment könnte in Form von:
 - einem Phonem, Wort, eine Phrase, oder
 - Kombination von Phonem, Wort & Phrase
 - Oder etwas anders, das intelligenter ist, z.B. Diphon, Unit.

Diphon Synthese

- Das Sprachsignal wird durch Verkettung von Diphonen erzeugt, Die Prosodie-Anpassung durch Signalmanipulation.
- Diphon:
 - Nachbar-Laut Kombinationen oder
 - Das Fragment von des Sprachsignals, das quer durch Phonemgrenze schneidet.
- Sehr wichtig für natürlicher Klang



Konkatenative Synthese

- Die Eingabe sind phonetische Repräsentationen & prosodische Merkmale.
- Die Länge, Tonhöhe, & Lautheit des Diphonsegments können digital manipuliert.
- Beispiele:
 - Konkatenative Synthese: First Byte
/mounts/Users/student/lucia/Documents/lucias-file/CL1/lecture/firstbyte_demo.mp3
 - Diphon Synthese: Babeltech's Babil
</mounts/Users/student/lucia/Documents/lucias-file/CL1/lecture/diphon.mp3>

Unit Selection Synthese

- Aus einer sehr großen Datenbasis werden die am besten passenden Sprachteile (units) miteinander verkettet.
 - Unit → Phonem, Diphonem, Halbsilben, Morphem
- Die unit (Segmente) werden mit einem Verzeichnis von einer Reihe akustischer & phonetischer Eigenschaften (Grundfrequenzverlauf, Dauer, Nachbarn) gespeichert.
- Eine Reihe von möglichst großen Segmenten werden durch Suchalgorithmen, z.B. gewichtete Entscheidungsbäume, für die Synthese bestimmt.

Unit Selection Synthese

- Die sehr bekannte Variation ist non-uniform unit selection Synthese.
- In Non-uniform Unit Selection Synthese erfolgt die Verkettung der Sprachteile durch die unterschiedliche Länge
- Beispiel: cerevoice

/mounts/Users/student/lucia/Documents/lucias-file/CL1/lecture/aristech_s1-Alex.mp3

Anwendungen der Sprachsynthese

- Ansagen in:
 - Telefon- & Navigationssystemen
 - Öffentlicher Verkehr (U-bahn, Bus)
- Dialogsysteme (incl. IVR)
- Voice-reading App:
 - Emails Aloud, translation reader (Google)
 - Voice Aloud reader (Android):
 - Webseiten, Nachrichten, emails, SMS, PDF files
- App 4 Diffable



Spracherkennung & sprachsynthese Demo



Literatur

- [1] Huang, X., & Deng, L., (2010). An Overview of Modern Speech Recognition. In Indurkya, & Damerau (Eds.), *Handbook of Natural Language Processing*. Chapman & Hall/CRC. Kap 15.
- [2] Jurafsky, D., & Martin, H. (2000). *Speech and Language Processing: an Introduction to Natural Language Processing, Computational Linguistics, & Speech Recognition*. New Jersey: Prentice Hall. Kap 4 & 7.
- [3] Thakur, B.M., Chettri, B, & Shah, K.B. (2012). Current Trends, Frameworks & Techniques Used in Speech Synthesis – A Survey. In. *International Journal of Soft Computing and Engineering (IJSCE)*, Vol 2(2), pp. 442-446.
- [4] Willet, D. (2000). *Beitraege zur statistischen Modellierung und effiziente Dekodierung in der automatischen Spracherkennung*. Dissertation.
- <http://ttsamples.syntheticspeech.de/deutsch/>