

Sprachverarbeitung I / 9 HS 2016

Sprachsynthese: Fourier-Analyse-Synthese

Buch: Kapitel 9.2.5

Beat Pfister



Sprachverarbeitung I / 9

Vorlesung: **Sprachsynthese** (Teil I.4)

Dauer- und Grundfrequenzveränderung von
Sprachsignalen mittels Fourier-Analyse-Synthese

Dieses Thema wird im Buch Ausgabe 2017 nur noch rudimentär behandelt.
Eine ausführliche Behandlung ist im Anhang B der Ausgabe 2008 zu finden.
(Dieser Anhang ist in ZIP-Archiv Folien_SPV1.zip enthalten.)

Übung: Grundfrequenzsteuerung

Sprachsynthese

Verkettung von Diphonen:


—→ Dauer und Grundfrequenz müssen verändert werden
(einzeln, d.h. voneinander unabhängig)

Methoden:


- LPC-Analyse-Synthese
- PSOLA (pitch-synchronous overlap add)
- Fourier-Analyse-Synthese

>>>

Dauerveränderung mittels Fourier-Analyse-Synthese




Signal mit 3 Komponenten
($f_s = 8000$ Hz, $F_0 = 110$ Hz)




N -Punkt-DFT

($N = 0.04 \cdot f_s = 320$)


Signal verlängert auf 225 % Dauer



Dauerveränderung mittels Fourier-Analyse-Synthese




Signal mit 3 Komponenten
($f_s = 8000$ Hz, $F_0 = 110$ Hz)



hochauflösende DFT !



Signal verlängert auf 225 % Dauer



Fourier-Analyse-Synthese

Dauer und Grundfrequenz eines Sprachsignals verändern:

1. Zerlegung des Signals in Sinuskomponenten

>>>

2. Veränderung der Frequenz der Sinuskomponenten

3. Rekonstruktion der Signalabschnitte mit gewünschter Dauer

Fourier-Analyse-Synthese

Dauer und Grundfrequenz eines Sprachsignals verändern:

1. Zerlegung des Signals in Sinuskomponenten

→ Schätzen der spektralen Zusammensetzung

>>>

2. Veränderung der Frequenz der Sinuskomponenten

3. Rekonstruktion der Signalabschnitte mit gewünschter Dauer

Fourier-Analyse-Synthese

Dauer und Grundfrequenz eines Sprachsignals verändern:

1. Zerlegung des Signals in Sinuskomponenten

—→ Komponenten schätzen aus Maxima der hochauflösenden FT

—→ Signal ist nicht stationär

>>>

2. Veränderung der Frequenz der Sinuskomponenten

3. Rekonstruktion der Signalabschnitte mit gewünschter Dauer

Fourier-Analyse-Synthese

Dauer und Grundfrequenz eines Sprachsignals verändern:

1. Zerlegung des Signals in Sinuskomponenten
 - Komponenten schätzen aus Maxima der hochauflösenden FT
 - Abschnittweise Analyse (Kurzzeitanalyse)
2. Veränderung der Frequenz der Sinuskomponenten
3. Rekonstruktion der Signalabschnitte mit gewünschter Dauer

Fourier-Analyse-Synthese

Dauer und Grundfrequenz eines Sprachsignals verändern:

1. Zerlegung des Signals in Sinuskomponenten
 - Komponenten schätzen aus Maxima der hochauflösenden FT
 - Abschnittweise Analyse (Kurzzeitanalyse)
2. Veränderung der Frequenz der Sinuskomponenten
(wird später behandelt)
3. Rekonstruktion der Signalabschnitte mit gewünschter Dauer

Fourier-Analyse-Synthese

Dauer und Grundfrequenz eines Sprachsignals verändern:



1. Zerlegung des Signals in Sinuskomponenten
 - Komponenten schätzen aus Maxima der hochauflösenden FT
 - Abschnittweise Analyse (Kurzzeitanalyse)
2. Veränderung der Frequenz der Sinuskomponenten
(wird später behandelt)
3. **Rekonstruktion der Signalabschnitte mit gewünschter Dauer** >>>

Fourier-Analyse-Synthese


Dauer und Grundfrequenz eines Sprachsignals verändern:

1. Zerlegung des Signals in Sinuskomponenten
 - Komponenten schätzen aus Maxima der hochauflösenden FT
 - Abschnittweise Analyse (Kurzzeitanalyse)
2. Veränderung der Frequenz der Sinuskomponenten
(wird später behandelt)
3. Rekonstruktion der Signalabschnitte mit gewünschter Dauer

Anwendung auf einen Sprachsignalausschnitt




Spektrum eines Sprachsignals mit fallendem F_0




Beobachtung:

Spektrum des stimmhaften
Signals ist nicht harmonisch!

Erwartetes Spektrum: ?



Spektrum eines Sprachsignals mit fallendem F_0




Beobachtung:

F_0 des Signals fällt schnell
(≈ 7 Oktaven/s)


Frage:

Ist das ein Problem ?



>>>

Spektrum eines Sprachsignals mit fallendem F_0



Sprachsignal:


F_0 fällt schnell (≈ 7 Oktaven/s)

Beobachtung:


Spektrum des stimmhaften
Signals ist nicht harmonisch!

Grund:

Stationaritätsbedingung der FT
ist **nicht** erfüllt !



Spektrogramm eines Sprachsignals $F_0 \approx 100$ Hz



Probleme bei der Spektralanalyse von Sprachsignalen

- **Signal stimmhaft:** Spektrum aber nicht harmonisch!

>>>

- a) Bereiche vermeintlich harmonisch (systematischer Fehler)
Grund: Starke F_0 -Änderung innerhalb Analyseabschnitt
(Stationaritätsbedingung der FT ist verletzt)

Lösung?

- b) Bereiche ohne Struktur (kein systematischer Fehler)
Grund: schwache Frequenzkomponenten ungenau


Lösung?

- **Signal stimmlos:** spektrale Zusammensetzung?


>>>

Lösung dieser Probleme → gute Schätzung des Spektrum



Gute Schätzung der Frequenzkomponenten



Nach abschnittweiser
Stationarisierung liefert
die Mehr-Fenster-Fourier-
transformation für
obiges Sprachsignals ein
zuverlässiges Resultat



Gute Schätzung der Frequenzkomponenten



Rekonstruktion des Sprachsignal


Gegeben: Schätzung der zeitabhängigen Signalkomponenten
(das “wirkliche” Spektrum)

Frage: Wie wird daraus das Signal rekonstruiert?
(ev. mit Dauer- und / oder F_0 -Veränderung)

Signalrekonstruktion aus dem “wirklichen” Spektrum


Prinzip: Rekonstruktion des Signals innerhalb eines Abschnittes durch Superposition der Sinussignale, die den Frequenzkomponenten entsprechen

Problem: An den Abschnittsgrenzen ergeben sich i.a. Unstetigkeitsstellen bzw. Diskontinuitäten




Rekonstruktion des Signals mittels OLA-Technik

Die abrupten Übergänge zwischen den Abschnitten werden durch
“gleitende” ersetzt → Überblenden (*windowed overlap-add*)




Dauerveränderung bei der Rekonstruktion des Signals




Kompensation der Phase der i -ten Komponente: $\Delta p_m(i) = 2\pi f_m(i) (m - 1) \Delta t$

Dauerveränderung eines instationären Signals

Originalsignal: Grundfrequenzverlauf $100(1+t)$ Hz (≈ 2 Okt/sec)



Verändertes Signal: Streckungsfaktor 1.7



>>>

Vermeiden grosser Zeitverschiebungen

Vorgehen bei der Dauer- und / oder Frequenzmodifikation:

Zeitliche Verschiebung beschränken! (auf maximal eine halbe Signalperiode)

Achtung: Implementation so konzipieren, dass sich Ungenauigkeiten der F_0 -Bestimmung nur lokal auswirken!


Beispiel: Iterative F_0 -Phasennachführung bei Dauermodifikation: $D \cdot Z_T$

$$\Delta_{\varphi_o}(m+1) = \{\Delta_{\varphi_o}(m) + 2\pi F_0(m) D \cdot (Z_T - 1)\} \widetilde{\text{mod}} 2\pi$$


$$\text{wobei } a \widetilde{\text{mod}} b = \begin{cases} a \bmod b & \text{für } a \bmod b < b/2 \\ a \bmod b - b & \text{sonst} \end{cases}$$

Dauerveränderung absolute zeitliche Verschiebung $< T_0/2$

Originalsignal: Grundfrequenzverlauf $100(1+t)$ Hz (≈ 1 Okt/sec)



Verändertes Signal: Streckungsfaktor 1.7



Frequenzveränderung

Prinzip: Skalieren der Frequenzkomponenten: $f'_i = Z_F \cdot f_i$, für alle i

Achtung: Auch hier Kompensation der Phase nötig!
(analog zur Dauerveränderung)



Hörbeispiel: Originalsignal (wie vorher)



Frequenzen skaliert mit Faktor 1.6







Dauerveränderung mittels Fourier-Analyse-Synthese: 130 %




Dauer- und F_0 -Veränderung bei Sprachsignalen

Hörbeispiele: Sprache (4 kHz Bandbreite)

- Originalsignal: 
- Dauerfaktor: 1.3 
- Frequenzfaktor: 0.7 
- 1.2 

Verändern der Tonhöhe in Sprachsignalen




Tonhöhe nimmt zu

→ Abstand der Frequenzlinien
nimmt zu


Wie wirkt sich das Verändern der Tonhöhe aus?

Verändern der Tonhöhe in Sprachsignalen



Tonhöhe nimmt zu



→ Abstand der Frequenzlinien
nimmt zu



Spektrale Enveloppe
und Formanten müssen
erhalten bleiben !

>>>










Mittels Fourier-Analyse-Synthese F_0 auf 73 % reduziert



Veränderung von Dauer und F_0 mittels Fourier-Analyse-Synthese

Originalsignal (8 kHz Abtastrate)



		Grundfrequenz		
		80%	100%	125%
Dauer	80%			
	100%			
	125%			

Zusammenfassung

Dauer- und Grunfrequenzänderung mittels Fourier-Analyse-Synthese:

- Genaue Schätzung der spektralen Zusammensetzung
 - Abschnitte mit grosser F_0 -Änderung (Stationarisierung)
 - Signalkomponenten mit rel. geringer Leistung (mehrfach Analyse)
- Frequenzveränderung:
 - Skalieren der Frequenz der Komponenten
 - Beibehalten der spektralen Enveloppe
- Dauerveränderung und Rekonstruktion:
 - Zeitverschiebung auf $T_0/2$ beschränken
 - Überblenden der Synthese-Abschnitte (windowed overlap-add)





Thema der nächsten Lektion

Spracherkennung

Zur Übersicht der Vorlesung *Sprachverarbeitung I* >>>





Fourier-Analyse

Zerlegung in Sinuskomponenten







Fourier-Synthese

Superposition von
frequenzveränderten
Sinuskomponenten







Tonhöhe: 170 %







Fourier-Synthese

Superposition von
frequenzveränderten und
verlängerten / verkürzten
Sinuskomponenten



Tonhöhe: 170 %

Dauer: 140 %



Fourier-Analyse-Synthese

Tonhöhen- und Daueränderung eines Signals $x(n)$:


1. Zerlegen in Sinuskomponenten $\longrightarrow Y_i = \{f_i, a_i, p_i\}$, mit $i = 1, \dots, I$
(Ermitteln der spektralen Zusammensetzung)
2. Frequenzänderung $\longrightarrow f'_i = z_f \cdot f_i$, für alle i
3. Daueränderung $\longrightarrow d' = z_d \cdot d$
(Generieren von Sinuskomponenten der Dauer d')
4. Superposition der generierten Sinuskomponenten
 $\longrightarrow x'(n)$

<<<




Fourier-Analyse

Zerlegung in Sinuskomponenten

Resultat: **3 Komponenten**
(nicht N aus DFT)




Signal mit 3 Komponenten
($F_0 = 110$ Hz)




<<<

Schätzen der spektralen Zusammensetzung



Signal mit 3 Komponenten
($f_s = 8000$ Hz, $F_0 = 110$ Hz)




- ➔
- 1. Komponente: $f_1 = 110$ Hz / $a_1 = \dots$ / $p_1 = \dots$
 - 2. Komponente: $f_2 = 220$ Hz / $a_2 = \dots$ / $p_2 = \dots$
 - 3. Komponente: $f_3 = 330$ Hz / $a_3 = \dots$ / $p_3 = \dots$


Fensterlänge ? >>>

Auflösung der DFT ? >>>

Schätzen der spektralen Zusammensetzung



Signal mit 3 Komponenten
($f_s = 8000$ Hz, $F_0 = 110$ Hz)




- ➔
- 1. Komponente: $f_1 = 110$ Hz / $a_1 = \dots$ / $p_1 = \dots$
 - 2. Komponente: $f_2 = 220$ Hz / $a_2 = \dots$ / $p_2 = \dots$
 - 3. Komponente: $f_3 = 330$ Hz / $a_3 = \dots$ / $p_3 = \dots$


Fensterlänge $\geq 2.5 \cdot T_0$

Auflösung der DFT ? >>>

Schätzen der spektralen Zusammensetzung



Signal mit 3 Komponenten
($f_s = 8000$ Hz, $F_0 = 110$ Hz)




- ➔
- 1. Komponente: $f_1 = 110$ Hz / $a_1 = \dots$ / $p_1 = \dots$
 - 2. Komponente: $f_2 = 220$ Hz / $a_2 = \dots$ / $p_2 = \dots$
 - 3. Komponente: $f_3 = 330$ Hz / $a_3 = \dots$ / $p_3 = \dots$


Fensterlänge $\geq 2.5 \cdot T_0$
hochauflösende DFT

<<<

Vergrößerung der Dauer




Signal mit 3 Komponenten
($f_s = 8000 \text{ Hz}$, $F_0 = 110 \text{ Hz}$)



hochauflösende DFT !

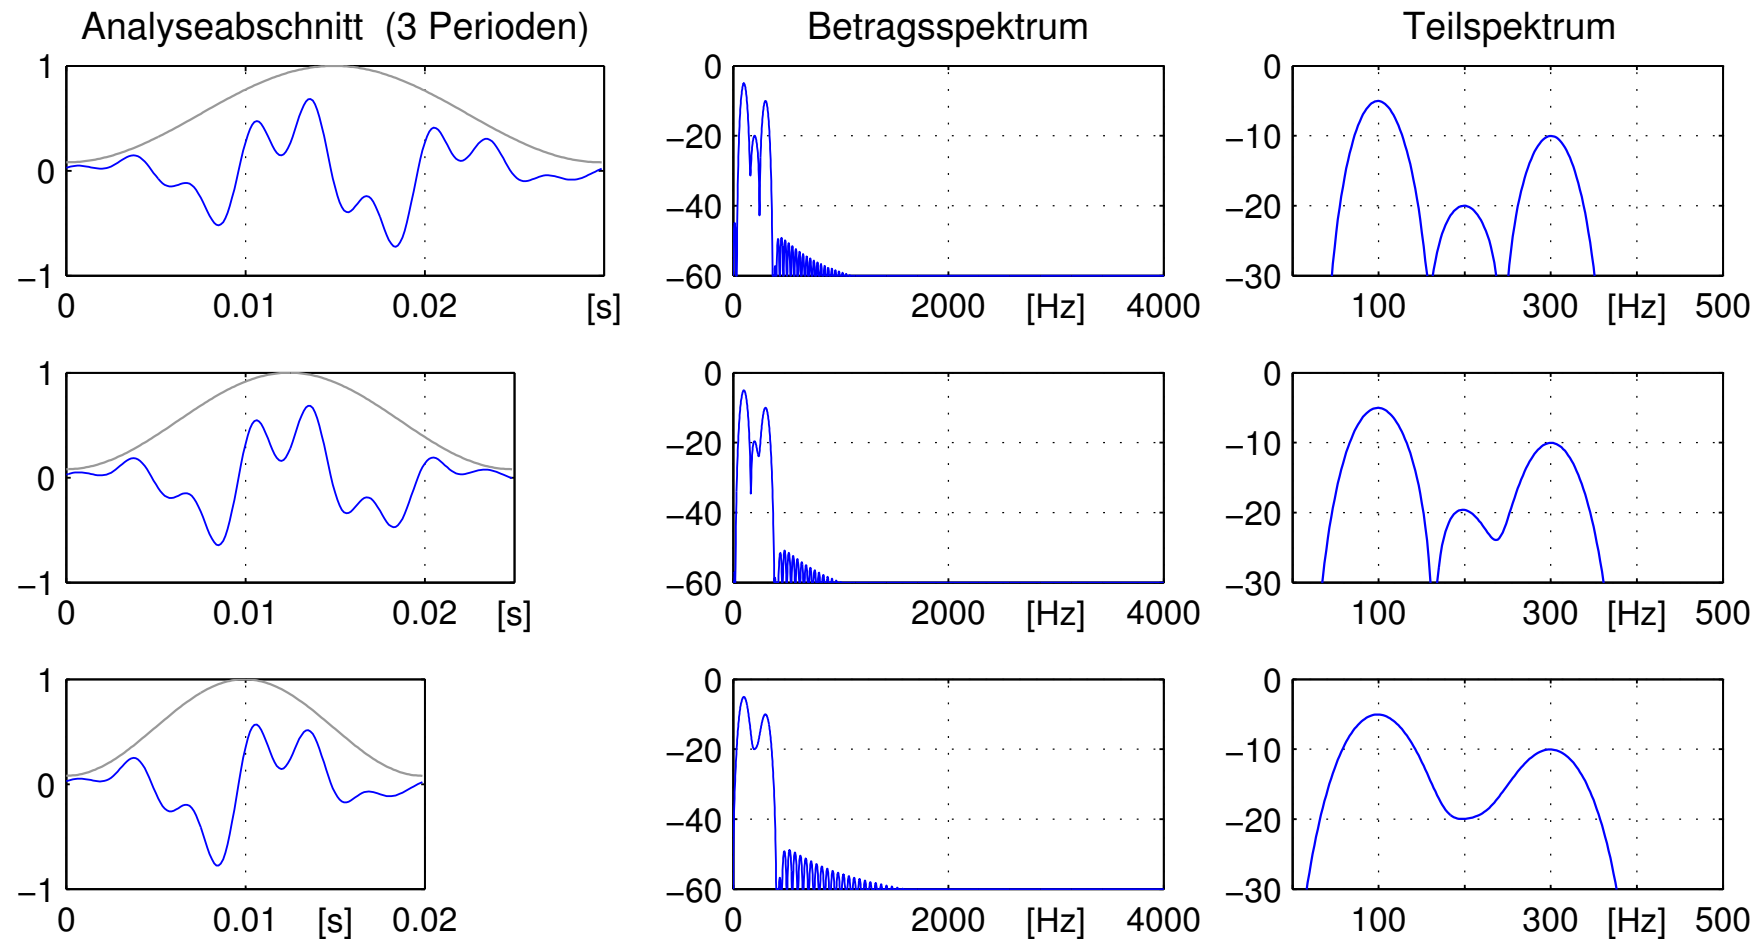
Signal verlängert auf 225 % Dauer



<<<

Einfluss der Länge des Hamming-Fensters




Fourieranalyse eines periodischen Signals ($F_0 = 100$ Hz) mit versch. Fensterlängen





<<<

Frequenz-Auflösung der diskreten Fourier-Transformation



Erhöhung der Genauigkeit durch Ergänzung mit Nullen (*zero padding*)



auf doppelte Länge
mit Nullen ergänzt




auf vierfache Länge
mit Nullen ergänzt




<<<



Darstellung der Kurzzeit-Fourier-Transform. instationärer Signale



Darstellung des “wirklichen Spektrums” harmonischer Signale





“Wirkliches Spektrum” mit Amplituden und Phaseninformation





<<<



Veränderung der Grundfrequenz: -5 Okt/s





Veränderung der Grundfrequenz: -1 Okt/s





Veränderung der Grundfrequenz: -2 Okt/s



Veränderung der Grundfrequenz: -5 Okt/s




Veränderung der Grundfrequenz: -5 Okt/s



<<<

Spektrum eines Sprachsignals mit fallendem F_0



Sprachsignal:


F_0 fällt schnell (≈ 7 Oktaven/s)

Beobachtung:

Spektrum des stimmhaften
Signals ist nicht harmonisch!

Grund:

Stationaritätsbedingung der FT
ist **nicht** erfüllt !



<<<

Spektralanalyse für Signale mit schnellen Grundfrequenzveränderungen

Unter der Annahme, dass für einen kurzen Signalabschnitt (Analysefenster) der Verlauf der Grundfrequenz durch eine Gerade approximierbar ist, also $F_0(t) \approx F_0(0) + \dot{F}_0 t$ ist, lässt sich das Spektrum des Signals auf zwei Arten bestimmen:

- a) Abtastratenkonversion vor der Fouriertransformation mit der variablen Abtastfrequenz: $\dot{f}_s \approx \dot{F}_0$


>>>

- b) Fouriertransformation mit einem Satz orthogonaler Funktionen, deren Frequenz gilt: $\dot{f}_k \approx \dot{F}_0$.

>>>

<<<

Reduktion der Instationarität durch variables Abtasten




Nötig: Abtastratenwandler für variable Abtastraten

Spektrum eines Signals mit starkem F_0 -Anstieg

Analyse eines Signals
mit F_0 -Anstieg
von 1 Okt. pro 0.2 s:

- ohne Stationarisierung
(links)
- mit Stationarisierung
(rechts)



<<<

Fouriertransformation für Signale mit grossem \dot{F}_0

Implizite Transformation der Zeitachse in der DFT, indem die Punkte

$$n = \{0, 1, \dots, N-1\}$$

der diskreten Zeitachse durch die Punkte

$$\tilde{n} = n + \varphi(n)$$

der modifizierten Zeitachse ersetzt werden. Die DFT ist dann zu schreiben als:



$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi k(n+\varphi(n))/N}$$

- Achtung:**
- Aliasing-Effekte nicht vermeidbar
 - Term $\varphi(n)$ verhindert Anwendung der FFT

<<<

Analyse schwacher spektraler Komponenten


Fouriertransformation
liefert für schwache
Frequenzkomponenten
eines Sprachsignals
keine zuverlässigen Werte



Analyse schwacher spektraler Komponenten

Fouriertransformation
liefert für schwache
Frequenzkomponenten
eines Sprachsignals
keine zuverlässigen Werte

→ Analyse mehrerer,
zeitlich leicht
verschobener Fenster
und Nachverarbeitung



<<<


Auswirkung der akkumulierten Zeitverschiebung

Frequenzkomp. in Abschnitt (a):

100, 200, 300 Hz

Frequenzkomp. in Abschnitt (b):

100, 201, 301 Hz



Auswirkung der akkumulierten Zeitverschiebung

Frequenzkomp. in Abschnitt (a):


100, 200, 300 Hz

Frequenzkomp. in Abschnitt (b):

100, 201, 301 Hz

zeitliche Streckung um 25 %


→ akkum. Zeitverschieb.: 0.5 s



Anmerkung: Ist nur bei periodischen Signalabschnitten ein Problem !

<<<


Schätzen der spektralen Envelope mittels linearer Prädiktion



Problem: Spektrale Maxima sind oft sehr schmal und hoch (Allpol-Filter), insbesondere bei hohen Stimmen

→ verursacht Töne oder Geräusche!

Schätzen der spektralen Envelope mittels cepstraler Glättung



Problem: Schmale spektrale Maxima oft zu tief geschätzt !

→ Laute werden undeutlich ! Lösung:


Schätzen der spektralen Enveloppe

- Gute Schätzung:
- Cepstrale Glättung des LPC-Spektrums
 - Schätzen der Enveloppe aus dem “wirklichen” Spektrum (durch geeignete Interpolation)

>>>


<<<

Schätzen der Enveloppe aus dem “wirklichen” Spektrum




Frage: Wie soll interpoliert werden ?

Cos-Interpolation des “wirklichen” Spektrums



Envelope aus Cos-Interpolation des “wirklichen” Spektrums



<<<

