テキスト音声合成のための Auto-encoder を用いた音響モデル化に頑健な音響特徴量抽出（継続）

代表研究者　高　木　信　二　国立情報学研究所　コンテンツ科学研究系　特任助教
共同研究者　山　岸　順　一　国立情報学研究所　コンテンツ科学研究系　准教授

1 はじめに

統計的パラメトリック音声合成を実現する代表的な手法として，隠れマルコフモデル(Hidden Markov Model; HMM)に基づく枠組みが挙げられる．HMM に基づく音声合成を用いることである程度高品質な音声の合成を実現できるが，決定木に基づくコンテキストクラスタリングにより学習データが分割されてしまうことや，出力分布として単純なガウス分布が状態単位で割り当てられるといった問題が存在する．近年では，このような問題に対してニューラルネットワークを用いることが検討されており，例えば，HMM 音響モデルとニューラルネットワークを組み合わせる手法や，HMM 音響モデルの枠組み全体をニューラルネットワークに置き換える手法が提案され，ニューラルネットワークに基づく音声合成システムは高い性能を持つことが報告されている．

統計的パラメトリック音声合成システムは，STRAIGHT や WORLD 等の高品質ボコーダを用い構築されることが多い．これらボコーダを利用し音響特徴量の抽出，及び，音響特徴量から音声波形の生成が行われる．統計的パラメトリック音声合成では，音響モデルを用いテキストから音響特徴量の予測を行い，ボコーダを用いて音声波形の生成を行う．近年，DNN を用いることで統計的パラメトリック音声合成システムの性能は改善されているが，DNN に基づく統計的パラメトリック音声合成システムにおいても，ボコーダを用いることで音声の劣化が生じてしまう問題がある．この問題に対して様々な研究が報告されており，例えば，励振源モデルの改良，Sinusoidal ボコーダの利用，複素スペクトルのモデル化，音声波形そのものの利用が挙げられる．しかし，統計的パラメトリック音声合成システムおいて，ボコーダを用いたことによる品質劣化を回避することは依然として問題である．

本研究では音声波形もしくはより現信号に近い入力を利用した統計的音声合成システム構築を目指す．統計的パラメトリック音声合成において，FFT スペクトルからの Griffin/Lim 法による位相復元，逆短時間フーリエ変換に基づく音声波形生成を検討する．FFT スペクトルに基づく提案システムの構築には少なくとも，1) FFT スペクトルの調波構造の予測，2) 適切な位相復元を可能とする高精度な FFT スペクトルの生成が必要となる．本研究では，調波構造を含む FFT スペクトルの高精度な生成を行うため，1) DNN 音響モデルの入力(言語特徴量に加え F0 に関する特徴量の利用)，2) DNN 音響モデルの学習基準 (Kullback-Leibler divergence の利用)，3) DNN 音響モデルにより予測された FFT スペクトルのピーク強調 (信号処理に基づくポストフィルタの利用)の検討を行う．実験では，FFT スペクトルに基づく合成音声と高品質ボコーダ WORLD に基づく合成音声の比較を行った．

2 DNN に基づく音響モデル

2-1 概要

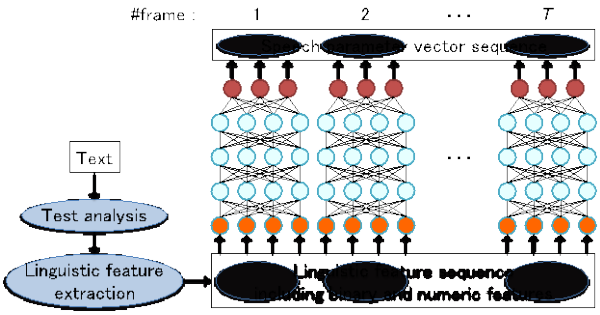

図 1：A framework for the DNN-based acoustic model

従来，HMM が音響モデルとして広く用いられているが，近年，DNN に基づく音響モデルが提案されている．本セクションでは代表的な DNN 音響モデルの 1 つであるについて簡潔にレビューし，FFT スペクトルモデル化のための DNN 音響モデルの学習基準について述べる．

図 1 に DNN 音響モデルの枠組みを示す．本手法は HMM 音声合成におけるコンテキストクラスタリングに用いられる決定木と同様の役割を持ち，DNN を用いることでテキストから抽出された言語特徴が音声から抽出された音声パラメータに写像される．入力データである言語特徴にはバイナリデータ(例えば，コンテキストに関する質問の答え)と数値データ(例えば，フレーズ内の単語の数，単語内のシラブルの位置，音素継続長)を用いることができる．DNN 音響モデルの利点の一つとして，例えば i-vector による話者情報といった言語特徴量以外の特徴量を入力として容易に利用できる点が挙げられる．通常，音声パラメータには音源，スペクトルを表現する特徴量とそれらの時間微分が用いられている．本研究では，単純な FFT により得られた高次元振幅スペクトルを音響特徴量として扱う．DNN は学習データから抽出された言語特徴と対応する音声特徴を用いて，確率的勾配降下法により学習することができる．また，任意テキストの音声パラメータは学習された DNN からフォワードプロパゲーションを用いることで予測できる．

2-2 学習基準

テキスト音声合成のための DNN 音響モデルの構築では，学習基準として最小二乗誤差(SE)が用いられることが多い．最小二乗誤差に基づく学習基準は，以下のように表される．

$$E_{SE} = \frac{1}{2}\sum_{t=1}^{T}\sum_{d=1}^{D}(o_{t,d} - y_{t,d})^2 \quad (1)$$

ここで，$y_{t,d} = g_d^{(N)}(h_t)$ と $o_{t,d}, h_t, t, d, N$ はそれぞれ観測(音響特徴量)，DNN 音響モデルの入力(言語特徴量)，フレームインデックス，次元，DNN のモデルパラメータを表す．また，関数 $g_d^{(N)}(\cdot)$ は DNN によって表現される非線形変換である．

本研究では高次元 FFT スペクトルを学習データとして用いる．本研究では FFT スペクトルを直接学習データとして用いる利点を活かし，適切な音響モデルの構築を行うため，Kullback–Leibler divergence (KLD)に基づく評価基準を用い，DNN 音響モデルの学習を行う．KLD 基準は非負値行列因子分解に基づく音源分離において広く利用されている．本研究で用いた KLD に基づく学習基準を以下に示す．

$$E_{KL} = \sum_{t=1}^{T}\sum_{d=1}^{D} o_{t,d}\log\frac{o_{t,d}}{y_{t,d}} - o_{t,d} + \tilde{y}_{t,d} \quad (2)$$

ここで，$\tilde{y}_{t,d} = s_d y_{t,d} + b_d$ であり，s_d と b_d は学習データから前もって計算され，正規化された値を元に戻す処理に用いる値である．KLD に基づく学習基準を適用するためには観測とは正の数である必要がある．本研究では，出力層にシグモイド関数を用い正規化された 0 から 1 の間の値を出力することで，$y_{t,d}$ が取り得る値の範囲の制限を行い，KLD に基づく学習基準を適用する．

また，以下の通り表現される $y_{t,d}$ に関する偏微分を用い，確率的勾配降下法により DNN のパラメータは効率良く学習できる．

$$\frac{\partial E_{SE}}{\partial y_{t,d}} = y_{t,d} - o_{t,d} \quad (3)$$

$$\frac{\partial E_{KL}}{\partial y_{t,d}} = s_d\left(1 - \frac{o_{t,d}}{s_d y_{t,d} + b_d}\right) \quad (4)$$

3 位相復元に基づく音声波形生成

本セクションでは，提案システムで用いられる音声波形生成アルゴリズムについて述べる．本研究では，DNN 音響モデルから調波構造を含む振幅スペクトルが予測されると仮定し，FFT スペクトルからの位相復元，逆短時間フーリエ変換，および重加算法(OLA)に基づく音声波形生成を用いる．FFT スペクトルからの位相復元としてGriffin/Lim法による位相復元を用いる．この位相復元アルゴリズムは，1) 逆短時間フーリエ変換，重加算法による波形生成， 2) 窓掛け処理，短時間フーリエ変換によるスペクトル分析の繰り返し処理に基づく．このアルゴリズムでは振幅スペクトルの値は更新されず固定されるが，位相情報は繰り返し毎に短時間フーリエ変換を行った際に得られる位相情報により更新を行う．

提案システムでは，以下の手順により音声波形生成を行う

- DNN 音響モデルにより FFT スペクトルを予測する
- Griffin/Lim 法による位相復元を行う．
- 音響モデルにより予測された FFT スペクトルと復元された位相情報を用い，逆短時間フーリエ変換，及び重加算法により音声波形生成を行う

4 実験

4-1 実験条件

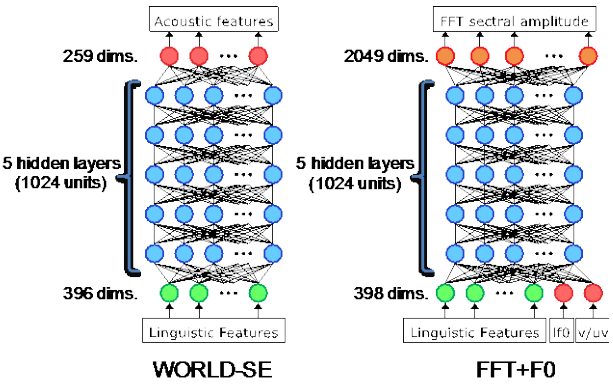

図 2: Configurations of neural networks used for acoustic models. FFT-SE, FFT-KLD, FFT-SE+F0, FFT-KLD+F0 use right side configuration (FFT+F0), though log F0 and voiced/unvoiced values were not used for constructing FFT-SE and FFT-KLD.

表 1: データベースの詳細.

Speaker	Professional female
#Utterance (Train)	12,085
#Sentence (Test)	200
Sampling rate	48kHz

表 2: Inputs, output references and objective criteria for training each acoustic model are listed in this table. Here, v/uv and bap represent voiced/unvoiced values and band aperiodicity measures, respectively.

Model name	Input	Output reference	Objective criterion	Waveform generation
WORLD-SE	Lingistic features	Mel-cep, log F0, v/uv, bap	Square error	Vocoder
FFT-SE	Lingistic features	Log FFT spectral amplitude	Square error	Phase reconstruction + iFFT
FFT-KLD	Lingistic features	FFT spectral amplitude	KL-divergence	Phase reconstruction + iFFT
FFT-SE+F0	Lingistic features, log F0, v/uv	Log FFT spectral amplitude	Square error	Phase reconstruction + iFFT
FFT-KLD+F0	Lingistic features, log F0, v/uv	FFT spectral amplitude	KL-divergence	Phase reconstruction + iFFT

Blizzard Challenge 2011 において配布された約 17 時間の英語データを実験に用いた．表 1 にデータベースの詳細を示す．

実験では，5 種類の音響モデル(WORLD-SE, FFT-SE, FFT-KLD, FFT-SE+F0, FFT-KLD+F0)の構築を行った．表 2 にこれら音響モデル構築に用いた入力特徴量，出力特徴量，学習基準を示す．FFT スペクトルのための DNN 音響モデル構築では，学習基準だけでなく入力特徴量について検討を行っており，FFT-SE+F0 と FFT-KLD+F0 では F0 情報(log F0, 有声/無声パラメータ)を音響モデルの入力として用いている．WORLD-SE の構築には,WORLD スペクトル包絡から抽出したメルケプストラムを用いた.その他の音響モデル構築には，高次元 FFT スペクトルが音響特徴量として用いたが，学習基準として二乗誤差に基づく学習基準を用いた音響モデル(FFT-SE, FFT-SE+F0)では log スケールの FFT スペクトル，KLD に基づく学習基準を用いた音響モデル(FFT-KLD, FFT-KLD+F0)では linear スケールの FFT スペクトルをそれぞれ学習に用いた．音声波形生成として，WOLRD-SE では WORLD ボコーダを用い，その他のシステムでは，Griffin/Lim 法による位相復元に基づく音声波形生成アルゴリズムを用いた．

FFT 長 4096 で FFT スペクトル,WORLD スペクトルを得た.WORLD-SE 構築に用いた特徴量は 259 次元であり，59 次 WORLD メルケプストラム，対数基本周波数，25 次非周期成分とそれらの Delta，Delta^2，及び，1 次元有声/無声パラメータである．英語コンテキストラベルは発音辞書 Combilex を用いて作成された．DNN 音響モデルの入力として用いられる言語特徴量は 396 次元である．また，言語特徴に含まれる音素継続長は HMM を用いて推定した．DNN 音響モデルの入力として用いられる言語特徴
量，F0 情報は平均 0 分散 1 に正規化を行った．WORLD-SE, FFT-SE, FFT-SE+F0 で用いられる音響特徴量は 0.0--1.0 の範囲へ正規化を行った．FFT-KLD, FFT-KLD+F0 の学習に用いる FFT スペクトルについては正規化処理は行わないが，式(2)，(4)の通り 0.0--1.0 の範囲への正規化を元に戻す値は用いられる．図 2 に実験で用いた音響モデルのネットワーク構造を示す．全ての DNN の全ての隠れ層，出力層のユニットでシグモイド関数を用いた．

WORLD-SE, FFT-SE+F0, FFT-KLD+F0 に対して信号処理に基づくケプストラムのためのポストフィルタを適用した．WORLD-SE では，予測されたメルケプストラムに対してポストフィルタを適用した．FFT-SE+F0 と FFT-KLD+F0 では,1) DNN 音響モデルにより予測された 2049 次 FFT スペクトルを 2049 次ケプストラムに変換，2) 2049 次ケプストラムに対してポストフィルタを適用,3)ポストフィルタが適用されたケプストラムを 2049 次振幅スペクトルに変換し，ケプストラムのためのポストフィルタを適用した．

FFT-SE+F0 と FFT-KLD+F0 の学習には学習データから得られた言語特徴量，有声/無声パラメータ，log F0，FFT スペクトルを用いた．FFT-SE+F0 と FFT-KLD+F0 を用いた音声の合成時には，テキストから得られた言語特徴量と WORLD-SE を用い得られた log F0，有声/無声パラメータを入力として利用した．

主観評価実験には MUSHRA 法を用い，自然音声を隠れアンカーとして使用した．被験者数は 9 人である．各被験者は被験者ごとにテスト文からランダムに選ばれた 20 文章を比較した．

4-2 実験結果

(1) スペクトログラム

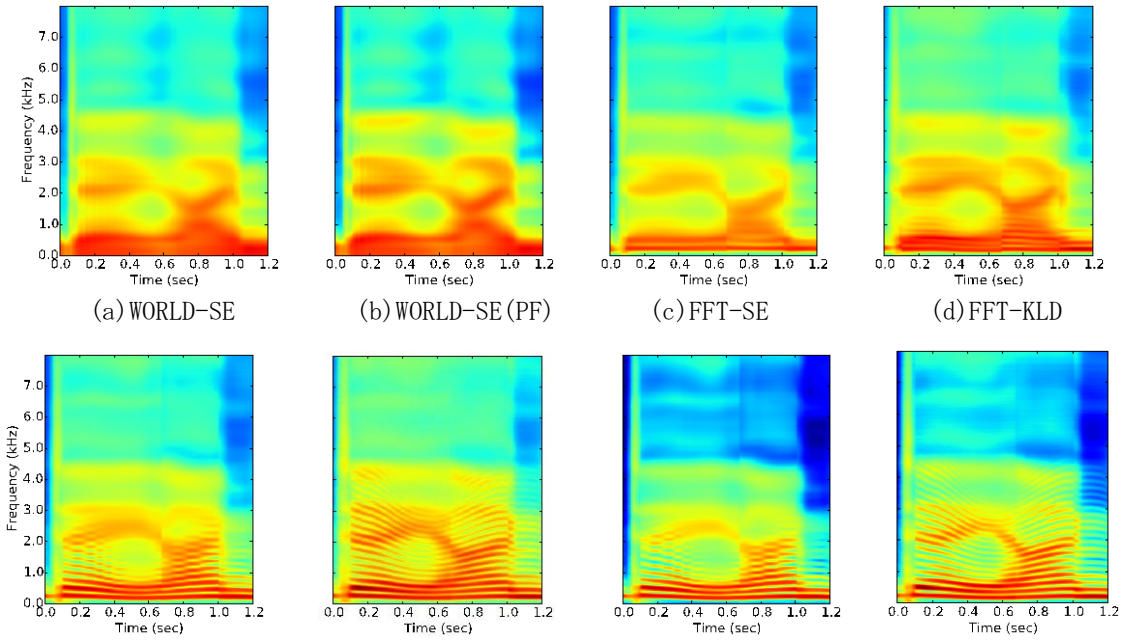

(a) WORLD-SE　(b) WORLD-SE (PF)　(c) FFT-SE　(d) FFT-KLD

(e) FFT-SE+F0　(f) FFT-KLD+F0　(g) FFT-SE+F0 (PF)　(h) FFT-KLD+F0 (PF)

図 3: Low-frequency parts (8 kHz) of synthetic spectral amplitudes in each system. PF means the post-filter.

図 3 に各システムにおいて生成されたスペクトログラムの一部を示す. 図 3 より, 明示的に F0 情報を入力として用いた音響モデル(FFT-SE+F0, FFT-KLD+F0)は, 他の音響モデルと比較して調波構造の予測が行えていることがわかる. また, 入力に F0 情報を利用していないシステム(FFT-SE, FFT-KLD, WORLD-SE)の結果を比較すると, FFT-SE と FFT-KLD は WORLD-SE と比較して微かに調波構造の一部が予測されているが, F0 を入力として利用したシステムと比較して予測精度は低い.

次に, 学習基準の違いに注目すると, 二乗誤差基準を用い構築された音響モデル(FFT-SE, FFT-SE+F0)と比較し, KLD 基準を用い構築された音響モデル(FFT-KLD, FFT-KLD+F0)では調波構造のピークがより強調されたスペクトルの予測が行われている. また, FFT-SE+F0 では十分に予測できていない 3.0kHz から 4.0kHz 付近の調波構造が, FFT-KLD+F0 では予測されている. このことから, KLD 基準による音響モデル学習が, 調波構造を含む FFT スペクトルのモデル化に有効であるとわかる.

最後に, 図 3 よりポストフィルタを適用することで, 調波構造のピーク強調が行われていることがわかる. これらの結果から, DNN 音響モデルへの入力としての F0 情報の利用, KLD 基準による音響モデル学習, 信号処理に基づくポストフィルタの利用が, 調波構造を含む FFT スペクトルの生成に有効であることがわかる.

(2) 主観評価実験結果

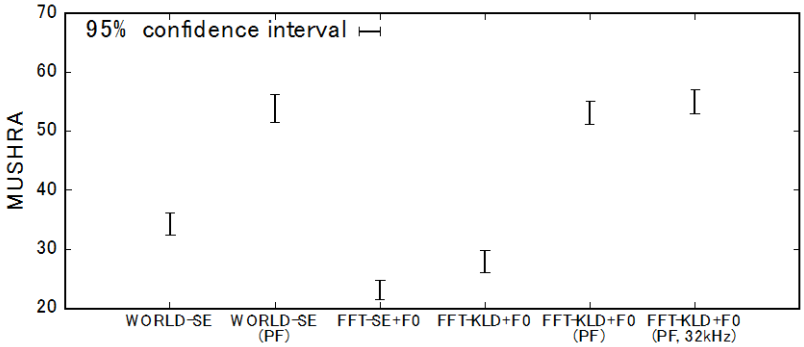

図 4: Subjective results.

図 4 に主観評価実験結果を示す. 隠れアンカーの結果は図から除いている. 主観評価実験では 32kHz にダ

ウンサンプリングした音声を用い音響モデル(FFT-KLD+F0 (PF, 32kHz))を新たに構築した．音響モデルの構築方法，音声波形生成の手順はFFT-KLD+F0(PF)と同様であるが，FFT長は2048とした．32kHzと48kHzの自然音声の品質は同等であると考えられるが，32kHzとすることで大幅にFFTスペクトルの次元数の削減が行われ，DNN音響モデルの学習が容易になることが期待される．主観評価実験ではWORLD-SE, WORLD-SE (PF), FFT-SE+F0, FFT-KLD+F0, FFT-KLD+F0 (PF), FFT-KLD+F0 (PF, 32kHz)による6種類のシステムを用いた．

まず，ポストフィルタを適用していないシステム間で比較を行うと，図4よりKLD基準を用いたシステム(FFT-KLD+F0)が二乗誤差基準を用いたシステム(FFT-SE+F0)より評価が良いことがわかる．このことはKLD基準がFFTスペクトルのための音響モデル構築に有効であることを示している．しかし，ポストフィルタの適用を行っていないFFTスペクトルに基づくシステム(FFT-SE+F0, FFT-KLD+F0)の性能は，WORLDボコーダに基づくシステム(WORLD-SE)より低い結果となった．

次に，FFTスペクトルに基づくシステムにおいて，ポストフィルタの適用の有無について結果を比較すると，図4よりポストフィルタを適用したシステム(FFT-KLD+F0 (PF))は適用していないシステム(FFT-KLD+F0)と比較し，大幅に性能が向上していることがわかる．ポストフィルタの適用を行っていないシステム(FFT-KLD+F0)では復元された位相が適切ではなく，ノイズを多く含む音声が合成されたが，ポストフィルタの適用によりノイズが低減された．この結果よりポストフィルタによるFFTスペクトルのピーク強調が，Griffin/Lim法による位相復元，音声波形生成に有効であるとわかる．

最後に，ポストフィルタを適用したFFTスペクトルに基づくシステム(FFT-KLD+F0 (PF), FFT-KLD+F0 (PF, 32kHz))と高品質ボコーダWORLDに基づくシステム(WORLD-SE (PF))を比較すると，図4よりほぼ同程度の性能となっている．ポストフィルタを適用した場合でもFFTスペクトルに基づくシステムはGriffin/Lim法による位相復元，波形生成に伴いノイズが生じているが，ボコーダを用いた合成で生じるバジー感は無い音声の合成が行われた．

5 まとめ

本研究では，統計的パラメトリック音声合成において，FFTスペクトルからGriffin/Lim法により位相復元，短時間フーリエ変換，および重加算法(OLA)に基づく音声波形生成を検討した．提案システムでは，STRAIGHTやWORLDといった高性能ボコーダを用いず音声波形の生成が行われる．音声合成実験により，調波構造を含むFFTスペクトルのDNN音響モデル構築には,明示的なF0情報のDNN音響モデルへの入力としての利用，KLDに基づく学習基準の利用が有効であることがわかった．また，主観評価実験の結果より，音響モデルによるFFTスペクトルの予測精度は十分に高いとはいえず，ポストフィルタの適用が高品質な音声の合成に必要であることがわかった.ポストフィルタを適用したFFTスペクトルに基づく提案システムの性能は，高性能ボコーダWORLDに基づく音声合成システムの性能と同程度であった．

【参考文献】

[1] K. Tokuda, Y. Nankaku, T. Toda, H. Zen, J. Yamagishi, and K. Oura, “Speech synthesis based on hidden Markov models,” Proceedings of the IEEE, vol. 101, no. 5, pp. 1234- 1252, 2013.

[2] H. Zen, A. Senior, and M. Schuster, “Statistical parametric speech synthesis using deep neural networks,” Proceedings of ICASSP, pp. 7962- 7966, 2013.

[3] Y. Fan, Y. Qian, F. Xie, and F. K. Soong, “TTS synthesis with bidirectional LSTM based recurrent neural networks,” Proceedings of Interspeech, pp. 1964- 1968, 2014.

[4] L. Juvela, B. Bollepalli, M. Airaksinen, and P. Alku, “High-pitched excitation generation for glottal vocoding in statistical parametric speech synthesis using a deep neural network,” Proceedings of ICASSP, pp. 5120- 5124, 2016.

[5] Q. Hu, J. Yamagishi, K. Richmond, K. Subramanian, and Y. Stylianou, “Initial investigation of speech synthesis based on complex-valued neural networks,” Proceedings of ICASSP, pp. 5630- 5634, 2016.

[6] A. van den Oord, S. Dieleman, H. Zen, K. Simonyan, O. Vinyals, A. Graves, N. Kalchbrenner, A. Senior, and K. Kavukcuoglu, “Wavenet：A generative model for raw audio,” CoRR, vol. abs/1609.03499, 2016.
[7] S. Takaki and J. Yamagishi, “A deep auto-encoder based low-dimensional feature extraction from FFT spectral envelopes for statistical parametric speech synthesis,” Proceedings of ICASSP, pp. 5535- 5539, 2016.
[8] D. W. Griffin and J. S. Lim, “Signal estimation from modified short-time Fourier transform,” Acoustics, Speech and Signal Processing, IEEE Transactions on, vol. 32, pp. 236- 243, 1984.
[9] G. E. Hinton and R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” Science 28, vol. 313, no. 5786, pp. 504- 507, 2006.
[10] H. S. S. D. D. Lee, “Algorithms for nonnegative matrix factorization,” Proceedings of Adv. Neural Inform. Process. Syst., pp. 556- 562, 2001.
[11] T. Yoshimura, K. Tokuda, T. Masuko, T. Kobayashi, and T. Kitamura, “Incorporation of mixed excitation model and postfilter into HMM-based text-to-speech synthesis,” IEICE, vol. J87-D-II, no. 8, pp. 1565- 1571, 2004.

〈発　表　資　料〉

題　　名	掲載誌・学会名等	発表年月
An Autoregressive Recurrent Mixture Density Network for Parametric Speech Synthesis	ICASSP	2017 年 3 月
DNN に基づくテキスト音声合成のための FFT スペクトルを用いた位相復元に基づく音声波形生成	第 18 回音声言語シンポジウム	2016 年 12 月
Investigation of Using Continuous Representation of Various Linguistic Units in Neural Network based Text-to-Speech Synthesis	IEICE Transactions on Information and Systems	2016 年 10 月
DNN に基づくテキスト音声合成における話者・ジェンダー・年齢コード利用の検討	音声研究会	2016 年 10 月
Speaker Adaptation of Various Components in Deep Neural Network based Speech Synthesis	9th Speech Synthesis Workshop	2016 年 9 月
巨大特定話者データを用いた HMM・DNN・RNN に基づく音声合成システムの性能評価	第 112 回音声言語情報処理研究会	2016 年 7 月