

少量の平行データを用いた Non-negative Matrix Factorization による 雑音環境下の声質変換*

☆藤井貴生, 相原龍, 中鹿亘, 滝口哲也, 有木康雄 (神戸大)

1 はじめに

声質変換は, 入力された音声の言語情報を保ったまま, 話者性や感情といった特定の情報のみを変換する技術である. 応用例としては話者変換や感情変換 [1, 2] をはじめとし, 発話支援 [3] など多岐に渡る. これまで様々な声質変換の手法が提案されており, 中でも Gaussian Mixture Model (GMM) を用いた手法 [4] に代表されるような統計的アプローチに基づく手法 [5, 6] が広く用いられている.

戸田ら [7] は従来の GMM を用いた声質変換法に動的特徴と Global Variance を導入することでより自然性の高い音声として変換する手法を提案している. Helander ら [8] は Partial Least Squares (PLS) 回帰分析を用いることにより, 従来手法における過適合の問題を回避するための手法を提案している. また従来手法では, 入力話者と出力話者が同じテキストを発話して得られる平行データが必要であるが, この平行データを使用せずに声質変換を行うために, GMM の話者適応を行う手法 [9] や Eigen-Voice GMM (EV-GMM) [10, 11] などが提案されている.

我々はこれまで, 従来の統計的手法とは異なる, スパース表現に基づく Exemplar-based な声質変換手法を提案してきた [12]. スパース表現に基づくアプローチは信号処理の分野において注目されており, 音声信号処理の分野でも音声認識や音源分離, 雑音抑圧などにおいて, その有効性が報告されている [13, 14]. このアプローチでは, 与えられた信号は少量の学習サンプルや基底の線形結合で表現される. 例えば音源分離に用いる場合, まず学習サンプルや基底を音源毎にグループ (辞書) 化し, 混合音声をそれらのスパース表現にする. その後, 目的音声の辞書に対する重みベクトルのみを取り出して用いることで, 目的音声のみを分離する. Gemmeke ら [15] は雑音の重畳した音声を, クリーン音声辞書とノイズ辞書のスパース表現にし, クリーン音声辞書に対する重みを音声認識における Hidden Markov Model (HMM) の尤度算出に用いることで, 雑音にロバストな音声認識を行う手法を提案している.

本研究では, スパースコーディングの代表的な手法として Non-negative Matrix Factorization (NMF) [16] を用いる. ここでは, 入力話者の音声辞書 (入力話者辞書) と出力話者の音声辞書 (出力話者辞書) からなる同一発話内容の平行辞書を構築する. 変換時には, 入力音声を NMF によって, 入力辞書に含まれる少量の基底からなるスパース表現にする. 得られ

た入力辞書の基底毎の重み係数 (アクティビティ) に基づいて, 入力話者辞書の基底を出力辞書内の基底と置き換え, 線形結合することで, 出力話者の音声へと変換する.

本稿では, 少量の平行データを用いた NMF による声質変換手法を提案する. 我々が提案してきた従来の NMF による声質変換手法では, 入力話者と出力話者の大量のデータをあらかじめ用意しておかなければならないという問題点があった. そこで, 出力話者の少量の音声データのみを辞書適応に用いることで, 入力話者辞書から出力話者辞書を生成する手法を提案する. 評価実験では, 雑音重畳音声に対して, 提案手法の有効性を示す.

2 NMF による雑音環境下の声質変換

入力話者の辞書に付随する雑音辞書は, 雑音の重畳した入力音声の非音声区間のフレームから構築される. NMF による雑音除去手法において, 観測信号の l 番目のフレームは, クリーン音声から構築した辞書とノイズ辞書の非負の線形結合により近似される.

$$\begin{aligned} \mathbf{x}_l &= \mathbf{x}_l^s + \mathbf{x}_l^n \\ &\approx \sum_{j=1}^J \mathbf{b}_j^s h_{j,l}^s + \sum_{k=1}^K \mathbf{b}_k^n h_{k,l}^n \\ &= [\mathbf{B}^s \mathbf{B}^n] \begin{bmatrix} \mathbf{h}_l^s \\ \mathbf{h}_l^n \end{bmatrix} \quad s.t. \quad \mathbf{h}_l^s, \mathbf{h}_l^n \geq 0 \\ &= \mathbf{B} \mathbf{h}_l \quad s.t. \quad \mathbf{h}_l \geq 0 \end{aligned} \quad (1)$$

$\mathbf{x}_l^s$ と $\mathbf{x}_l^n$ はそれぞれ入力話者のクリーン音声の振幅スペクトル, 雑音の振幅スペクトルを表す. $\mathbf{B}^s, \mathbf{B}^n, \mathbf{h}_l^s, \mathbf{h}_l^n$ は入力話者の辞書, 雑音の辞書, そして l フレームにおけるそれぞれのアクティビティを表す. (1) 式を時間-周波数のスペクトログラムで表現すると, 以下の通りになる.

$$\begin{aligned} \mathbf{X} &\approx [\mathbf{B}^s \mathbf{B}^n] \begin{bmatrix} \mathbf{H}^s \\ \mathbf{H}^n \end{bmatrix} \quad s.t. \quad \mathbf{H}^s, \mathbf{H}^n \geq 0 \\ &= \mathbf{B} \mathbf{H} \quad s.t. \quad \mathbf{H} \geq 0. \end{aligned} \quad (2)$$

本手法ではスペクトルの形状のみを考慮するため, まず $\mathbf{X}$, $\mathbf{B}^s$ 及び $\mathbf{B}^n$ について, フレーム毎, あるいは辞書内のサンプル毎に, 各周波数ビンの振幅の総和で正規化を行う. クリーン音声と雑音のアクティビティが並んだ行列 $\mathbf{H}$ はスパース制約付き NMF [15] によ

*Voice Conversion using a Small Parallel Corpus based on Non-negative Matrix Factorization in Noisy Environments, by Takao Fujii, Ryo Aihara, Toru Nakashika, Tetsuya Takiguchi, Yasuo Ariki (Kobe univ.)

り推定される.

$$\begin{aligned} \mathbf{M} &= \mathbf{1}^{(D \times D)} \mathbf{X} \\ \mathbf{X} &\leftarrow \mathbf{X} / \mathbf{M} \\ \mathbf{B} &\leftarrow \mathbf{B} / (\mathbf{1}^{(D \times D)} \mathbf{B}) \end{aligned} \quad (3)$$

$\mathbf{1}$ は全ての要素が 1 の行列である. スパース制約付き NMF において $\mathbf{H}$ を推定するためにコスト関数が設定されている. コスト関数の式と $\mathbf{H}$ の更新式は以下のようになる.

$$d(\mathbf{X}, \mathbf{B}\mathbf{H}) + \|(\lambda \mathbf{1}^{(1 \times L)}) * \mathbf{H}\|_1 \quad s.t. \quad \mathbf{H} \geq 0. \quad (4)$$

$$\begin{aligned} \mathbf{H}_{n+1} &= \mathbf{H}_n * (\mathbf{B}^T (\mathbf{X} / (\mathbf{B}\mathbf{H}))) \\ &\quad ./ (\mathbf{1}^{((J+K) \times L)} + \lambda \mathbf{1}^{(1 \times L)}). \end{aligned} \quad (5)$$

(4) 式を最小するように $\mathbf{H}$ が推定される. 第一項は $\mathbf{X}$ と $\mathbf{B}\mathbf{H}$ の Kullback-Leibler divergence である. 第二項は $\mathbf{H}$ をスパースにするための L1 ノルム正則化項である.

3 少量の平行データを用いた声質変換

我々がこれまで提案してきた NMF による声質変換法では, 大量の音声データをあらかじめ用意しておかなければならないという問題点があった. 本稿では出力話者の少量の音声データを辞書適応に用いることで, 入力話者の辞書から出力話者の辞書を作成する手法を提案する. Fig. 1 に話者辞書の適応を用いた平行辞書作成の概要を示す. 適応データである出力話者の STRAIGHT[17] スペクトル $\mathbf{X}^t$ は, 適応行列 $\mathbf{A}$, 入力話者辞書 $\mathbf{B}^s$ 及び入力信号のアクティビティ行列 $\mathbf{H}^s$ の線形結合によって表現される.

$$\mathbf{X}^t \approx \mathbf{A}\mathbf{B}^s\mathbf{H}^s \quad (6)$$

ここで, 入力話者辞書 $\mathbf{B}^s$ は入力話者の音声から抽出した STRAIGHT スペクトルを並べたものである. アクティビティ行列は入力話者辞書からどの基底を選択するかという指標になる行列であるので, 本稿では適応に用いる出力話者と同じ発話内容である入力話者音声から推定した重み行列を用いている. ここで得られた適応行列 $\mathbf{A}$ と入力話者辞書 $\mathbf{B}^s$ の線形結合によって出力話者辞書 $\hat{\mathbf{B}}^t$ が生成される.

$$\hat{\mathbf{B}}^t = \mathbf{A}\mathbf{B}^s \quad (7)$$

適応行列 $\mathbf{A}$ は, 下記評価関数に基づき求められる.

$$\mathbf{A} = \arg \min_{\mathbf{A}} D(\mathbf{X}^t | \mathbf{A}\mathbf{B}^s\mathbf{H}^s) \quad (8)$$

本論文における D は Kullback-Leibler divergence を表す. また, 適応行列 $\mathbf{A}$ は, 文献 [18] で音源分離における基底の適応行列の推定として提案されている方法と同様にして, 以下の式により推定される.

$$\begin{aligned} \mathbf{A} &\leftarrow \mathbf{A} * (\mathbf{X}^t / (\mathbf{A}(\mathbf{B}^s\mathbf{H}^s))) (\mathbf{B}^s\mathbf{H}^s)^T \\ &\quad ./ (\mathbf{B}^s\mathbf{H}^s)^T \end{aligned} \quad (9)$$




Fig. 1 辞書適応による平行辞書作成

4 評価実験

4.1 実験条件

本実験ではテストデータの入力音声に雑音重畳音声を用いた. 従来の GMM を用いた手法と, 辞書適応を行わない従来の NMF による変換手法と比較を行った. ATR 研究用日本語音声データベースから, 男性話者と女性話者それぞれ 3 名ずつの音声データを使用した. 入力話者と出力話者の組み合わせは男性 1 から女性 1 及び男性 2 から女性 2, 男性 1 から男性 2 及び男性 3 から男性 1, 女性 1 から女性 2 及び女性 3 から女性 1 の合計 6 パターンを用意した. サンプリング周波数は 8kHz とした. 従来の NMF 変換で用いる平行辞書の構築及び提案手法における辞書適応には, 10 単語, 25 単語, 50 単語, 216 単語の平行データをそれぞれ用いた. 比較手法である GMM に基づく声質変換のための学習サンプルには, 辞書を構築したのと同様音声のケプストラムをフレーム間同期を取ることで平行データとして用いた. ケプストラムは STRAIGHT スペクトルから計算される線形ケプストラムで, 次元数は 40 である. GMM の混合数は 64 とした.

テストデータには比較・提案手法ともに平行辞書内に含まれない 50 単語に雑音信号を加算したものをを用いた. 雑音信号は CENSREC-1-C データベースにて食堂内で収録された音声の無音声部分の雑音を用いた. 雑音信号の平均 SNR は 10dB とした. 雑音辞書は評価音声毎に発話の前後区間から構築しており, 雑音辞書に含まれるサンプル数は平均 104 である. テスト時の入力音声及び入力話者辞書の構築には 256 次元の振幅スペクトルを, 出力音声の生成及び出力話者辞書の構築には 513 次元の STRAIGHT スペクトルを用いた. これは, 本稿の入力音声には雑音が重畳しており, 音声信号の分析合成ツールである STRAIGHT[17] ではその雑音を上手く表現できないという問題があるためである. アクティビティ行列の推定の更新回数は 300 回とした.

提案手法の有効性を確かめるため, 客観評価実験を行った. 513 次元の STRAIGHT スペクトルを特徴量とし, 式 (10) で表される Normalized Spectrum Distortion(NSD)[19] によって各手法との比較を行った.




Fig. 2 SNR 10dBにおける男性1→女性1と男性2→女性2への変換時の平均NSD




Fig. 3 SNR 10dBにおける男性1→男性2と男性3→男性1への変換時の平均NSD

$$NSD = \sqrt{\frac{\|S^Y - S^{\hat{X}}\|^2}{\|S^Y - S^X\|^2}} \quad (10)$$

ただし、 S^X , S^Y , $S^{\hat{X}}$ はそれぞれ入力話者のスペクトル、出力話者のスペクトル、変換後のスペクトルを表す。

また、成人男女10名による、聴取実験を行った。評価にはテストデータに用いた男性1から女性1への変換時の客観評価で用いた50単語の中から、無作為に抽出した25単語を用いた。評価方法はMOS評価基準に基づく主観評価による「聞き取りやすさ」と、目標話者の実際の音声にどちらが近いかを選択するXAB法とした。MOS評価基準ではGMMに基づく変換手法、従来のNMF変換手法及び話者適応を行う提案手法の3通りの変換音声に対して評価を行った。XAB法に基づく評価においては、従来のNMF変換手法と提案手法のそれぞれで変換した音声の評価に用いた。NMFを用いる2つの手法における辞書の構築及び適応には50単語を用いた。

また、SNRを20dBとした場合の客観評価実験も行った。入力話者と出力話者の組み合わせは男性1から女性1、男性1から男性2、女性1から女性2の合計3パターンを用意した。従来手法の辞書構築および辞書適応の単語数はSNR 10dBの条件と同様とした。

4.2 実験結果

SNR 10dBにおけるNSDをFig. 2, Fig. 3, Fig. 4に示す。これらの実験結果より、提案手法では、10単語の少量適応音声データのみで従来の216単語を用いたパラレル辞書と同程度の精度が得られているのが分かる。

更に、Fig. 5, Fig. 6はそれぞれ聴取実験によって




Fig. 4 SNR 10dBにおける女性1→女性2と女性3→女性1への変換時の平均NSD

得られたMOS値とXAB法に基づく評価結果である。Fig. 5より、216単語を用いて学習したGMMに基づく変換手法と従来のNMF変換手法と比べて、本提案である話者適応を用いた変換手法を用いた場合が最も高いMOS値を示している。Fig. 6においては、25単語からパラレル辞書を構築する従来手法よりも、話者適応を用いてパラレル辞書を作成する本手法が有効であることが分かる。

Fig. 7からFig. 9にSNR 20dBにおける客観評価の結果を示す。ここでも、辞書適応を行う本提案が従来のNMF変換に比べて全体的に良い結果となった。




Fig. 5 聴取実験によるMOS値




Fig. 6 聴取実験によるXAB評価

5 おわりに

本稿では、雑音重畳音声に対して、入力話者辞書から推定されたアクティビティ行列と出力話者辞書の内積から得られたスペクトルから音声を再合成するNMFを用いた声質変換を行った。実験結果より、辞書適応を用いることで入力話者と出力話者それぞれの同一発話内容の音声から作成する少量のパラレルデータのみから声質変換を行う本手法の有効性が示された。今後はNMFを用いた変換手法における辞書の構築において、音素ごとのクラスタリングを行うことによって、より入力系列を表現するのに適した基底を選択できる手法の検討を進めていく。




Fig. 7 SNR 20dB における男性 1 → 女性 1 への変換時の NSD




Fig. 8 SNR 20dB における男性 1 → 男性 2 への変換時の NSD

参考文献

- [1] Y. Iwami, T. Toda, H. Saruwatari, and K. Shikano, "GMM-based Voice Conversion Applied to Emotional Speech Synthesis," *IEEE Trans. Speech and Audio Proc.*, Vol. 7, pp. 2401–2404, 1999.
- [2] C. Veaux and X. Robet, "Intonation conversion from neutral to expressive speech," in *Proc. INTERSPEECH*, pp. 2765–2768, 2011.
- [3] K. Nakamura, T. Toda, H. Saruwatari, and K. Shikano, "Speaking-aid systems using GMM-based voice conversion for electrolaryngeal speech," *Speech Communication*, Vol. 54, No. 1, pp. 134–146, 2012.
- [4] Y. Stylianou, O. Cappe, and E. Moulines, "Continuous probabilistic transform for voice conversion," *IEEE Trans. Speech and Audio Processing*, Vol. 6, No. 2, pp. 131–142, 1998.
- [5] M. Abe, S. Nakamura, K. Shikano, and H. Kuwabara, "Voice conversion through vector quantization," in *Proc. ICASSP*, pp. 655–658, 1988.
- [6] H. Valbret, E. Moulines and J. P. Tubach, "Voice transformation using PSOLA technique," *Speech Communication*, Vol. 11, No. 2-3, pp. 175–187, 1992.
- [7] T. Toda, A. Black, and K. Tokuda, "Voice conversion based on maximum likelihood estimation of spectral parameter trajectory," *IEEE Trans. Audio, Speech, Lang. Process.*, Vol. 15, No. 8, pp. 2222–2235, 2007.
- [8] E. Helander, T. Virtanen, J. Nurminen, and M. Gabbouj, "Voice conversion using partial least squares regression," *IEEE Trans. Audio, Speech, Lang. Process.*, Vol. 18, No. 5, pp. 912–921, 2010.
- [9] C. H. Lee and C. H. Wu, "MAP-based adaptation for speech conversion using adaptation data selection and non-parallel training," in *Proc. INTERSPEECH*, pp. 2254–2257, 2006.




Fig. 9 SNR 20dB における女性 1 → 女性 2 への変換時の NSD

- [10] T. Toda, Y. Ohtani, and K. Shikano, "Eigenvoice conversion based on Gaussian mixture model," in *Proc. INTERSPEECH*, pp. 2446–2449, 2006.
- [11] D. Saito, K. Yamamoto, N. Minematsu, and K. Hirose, "One-to-many voice conversion based on tensor representation of speaker space," in *Proc. INTERSPEECH*, pp. 653–656, 2011.
- [12] Ryoichi Takashima, Tetsuya Takiguchi, and Yasuo Ariki, "Exemplar-Based Voice Conversion in Noisy Environment," *IEEE Workshop on Spoken Language Technology (SLT2012)*, pp. 313–317, 2012.
- [13] T. Virtanen, "Monaural sound source separation by non-negative matrix factorization with temporal continuity and sparseness criteria," *IEEE Trans. Audio, Speech, Lang. Process.*, Vol. 15, No. 3, pp. 1066–1074, 2007.
- [14] M. N. Schmidt and R. K. Olsson, "Single-channel speech separation using sparse non-negative matrix factorization," in *Proc. INTERSPEECH*, pp. 2614–2617, 2006.
- [15] J. F. Gemmeke, T. Viratnen, and A. Hurmalainen, "Exemplar-Based Sparse Representations for Noise Robust Automatic Speech Recognition," *IEEE Trans. Audio, Speech, Lang. Process.*, Vol. 19, Issue 7, pp. 2067–2080, 2011.
- [16] D. D. Lee and H. S. Seung, "Algorithms for non-negative matrix factorization," in *Proc. Neural Information Processing System*, pp. 556–562, 2001.
- [17] H. Kawahara, I. Masuda-Katsuse, and A. de Cheveigne, "Restructuring speech representations using a pitch-adaptive time-frequency smoothing and an instantaneous-frequency-based F0 extraction: Possible role of a repetitive structure in sounds," *Speech Communication*, Vol. 27, pp. 187–207, 1999.
- [18] Emad M. Grais, and Hakan Erdogan, "Adaptation of speaker-specific bases in non-negative matrix factorization for single channel speech-music separation," in *Proc. INTERSPEECH*, pp. 569–572, 2011.
- [19] T. En-Najjary, O. Rosec, and T. Chonavel, "A voice conversion method based on joint pitch and spectral envelope transformation," in *Proc. ICSLP*, pp. 199–203, 2004.