

発声訓練システムのための音声可視化手法

長山 格, 赤松 則男, 吉野 俊樹

徳島大学工学部知能情報工学科

本報告では、発声訓練システムにおける音声パターンの可視化にニューラルネットワークを応用し、利用者の容易な理解を可能にする新しい手法を提案する。通常、言語障害教育やリハビリテーション等に用いられる発声訓練システムは、音声パターンを波形やスペクトルパターンなど複雑な形式で表示することが多い。これらは音声情報の全体像を表示するのに適しているが、複雑であるために規範パターンと比較しにくいという難点がある。これに対して、本報告で提案する手法は、多次元パターンとして表される音声パターンを平面上の点で表現することにより、利用者の理解を容易にすることができる。本報告では、提案手法について述べるとともに、日本語母音の可視化に適用した結果を示す。

Phonetic Visualization for Speech Training System by Using Neural Network

Itaru Nagayama, Norio Akamatsu, Toshiki Yoshino

Faculty of Engineering, University of Tokushima
Tokushima-shi, 770 Japan

A speech training system and a voice visualizer are useful machines for speech impairment patients. The speech training system indicates the vocal pattern(spectrum pattern or wave-form) on display for patients to train their pronunciation. But human being cannot recognize the complex multidimensional representation of patterns as like spectrum pattern or wave-form. Therefore, the man-machine interface of speech training system has a green hand. In this paper, we propose a Neuro-NLM, to build up the new interface for speech training system. We have investigated on a basic system which can easily visualize 5 Japanese vowels /A/, /I/, /U/, /E/, /O/. The system displays the multidimensional pattern of vowel onto two dimensional (2-D) space corresponding to the original pattern. User can compare his vowel pattern distribution in the 2-D plane with standard one during his training stage.

1. まえがき

先天的事由や疾病などにより、言語、聴覚機能に支障を持つ患者は疾病統計上少なからぬ数を占める。これらの患者に対し、速やかな言語発声機能の回復を図るために発声訓練が行われる。すなわち、施療者によって発声のための口蓋調節や調息法などの指導が施されるが、被訓練者にとって発声状態の把握が容易ではない。このとき、音声情報を視覚化することによって訓練効果を高めることができるので、発声リハビリシステムとして音声直視装置や発声訓練システムが開発されている。しかし、これらのシステムは音声波形やスペクトルパターンをVDT画面上で表示する形式のものであり、規範パターンとの比較や差異の理解が容易ではない。特に、小学生以下の児童が患者である場合、複雑なパターンの相違を理解することは難しく、訓練意欲を減退させる要因ともなる。従って、発声パターンの表示方法を改善する必要がある。一般に、波形やスペクトルはn次元ベクトル $X_n=(x_1, x_2, \dots, x_n)$ で表すことができる。しかし、人間にとてn次元の多次元パターン群の分布や相違をそのままの形で認識することは困難である。

本報告では、NLM法(Non-Linear Mapping) [1]とニューラルネットワークを用いてn次元パターンを2次元平面に写像することにより、複雑な発声パターンの相違を容易に理解できる手法を提案する。これをニューロNLMと呼ぶ。以下では、ニューロNLMの実現方法を述べ、日本語母音の可視化に適用した結果を示す。

2. ニューロNLM

2. 1 NLM法

n次元パターンを、2次元（または3次

元）空間で表すために、NLM法(Non-Linear Mapping)が用いられる。NLM法は、最急降下法などの最適化法を用いて、n次元空間におけるパターン間の距離関係を保存するように2次元空間における座標を決定するものである。すなわち、n(>2)次元空間におけるk個のパターンを $X_i, (i=1, \dots, k)$ とし、これをp(=2)次元空間上に写像したものを $Y_i, (i=1, \dots, k)$ とする。n次元空間でのパターン X_i と X_j 間の距離を $d_1 = \text{dist}[X_i, X_j]$ で定義し、p次元空間上での対応するパターン Y_i 、 Y_j 間の距離を $d_2 = \text{dist}[Y_i, Y_j]$ で定義する。ただし、 $\text{dist}[u, v]$ は、ベクトル u 、 v 間のユークリッド距離とする。p次元空間におけるパターン $Y_i, (i=1, 2, \dots, k)$ の座標をランダムに選び、初期値とする。

$$\begin{aligned} Y_1 &= (y_{11}, \dots, y_{1p}) \\ Y_2 &= (y_{21}, \dots, y_{2p}) \\ &\dots \\ Y_k &= (y_{k1}, \dots, y_{kp}) \end{aligned} \quad (1)$$

このように決めたとき、n次元空間とp次元空間における各パターンの配置誤差を示す評価関数Eを次式で定義する。

$$E = (1 / \sum [d_1]) \cdot \sum ([d_1 - d_2]^2 / d_1) \quad (2)$$

ここで、最急降下法などの最適化法を用いて評価関数Eの値を最小化し、p次元空間上のパターン $Y_i, (i=1, 2, \dots, k)$ の座標を決定する。

NLMは、上述の最適化を行うことによって実行される。すなわち、あらかじめ与えられたパターン群の非線形写像として2次元平面上の座標が得られる。それゆえ、新たに未知のパターンが与えられると再び

最適化計算を実行する必要があり、直ちに2次元平面上の座標を得ることはできない。

2. 2 ニューロNLM

上記のNLMにおける最適化によって、 n 次元ベクトルと2次元ベクトル間の非線形変換が行われる。ここで、ニューラルネットワーク（以下、NNと略記する）を用いて、 n 次元パターン群を入力パターン、2次元パターン群を教師パターンとして学習を実行すると、NNはこれらの非線形写像関係を学習する。すなわち、NNは、 n 次元空間から2次元空間への写像を学習する。すでに、中間層に十分な素子数を持つNNは任意のマッピングが可能であることが知られているので、適当な構造を持つNNを用いることにより、高次元から低次元への非線形写像を学習することができる。従って、学習後のNNを用いることによって、 n 次元の未知入力パターンに対する2次元ベクトルを出力することが可能である。すなわち、ニューロNLMは、未知パター

ンへの対応が可能である点に特徴がある。

図1にニューロNLMの概念図を示す。

3. 実験

3. 1 日本語母音の可視化

単音節母音 /A/, /I/, /U/, /E/, /O/ を対象として実験を行う。これらの母音について、それぞれ20個ずつ合計100個の音声データを用いる。各音声データはFFTを行って周波数データに変換する。一般に、音声の波形データは変動が激しいため、より安定であると考えられる周波数データを用いる。実験では、以下の手順を行って学習データを作成する。

- (1) 取り出された母音音声区間の差分データを求めて直流成分を除去し、高周波成分を強調する。
- (2) ハミング窓を掛け、FFTによりパワースペクトルを求める。
- (3) パワースペクトルから、メルスケール化した周波数帯域毎に平均パワーを求める。
- (4) 各帯域データをデシベル化した後、 $-80 \sim 0$ dB の区間を $-0.9 \sim 0.9$ の範囲に正規化する。

ここで、(3)において、16個の周波数帯域について計算するので、各母音の音声データは最終的に16次元のベクトルパターンとなる。

作成した16次元の音声データを、NLMによって2次元平面へマッピングした。2次元平面へのマッピング結果を図2に示す。明らかに、100個の音声パターンは、それぞれの母音領域に分離されていることがわかる。

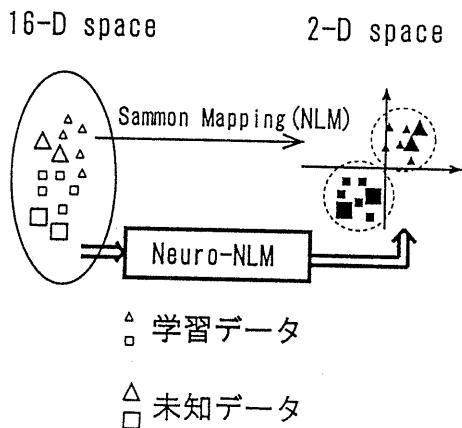


図1 ニューロNLMの概念図

3. 2 NNによる学習

3. 1 で得られた16次元ベクトルパー

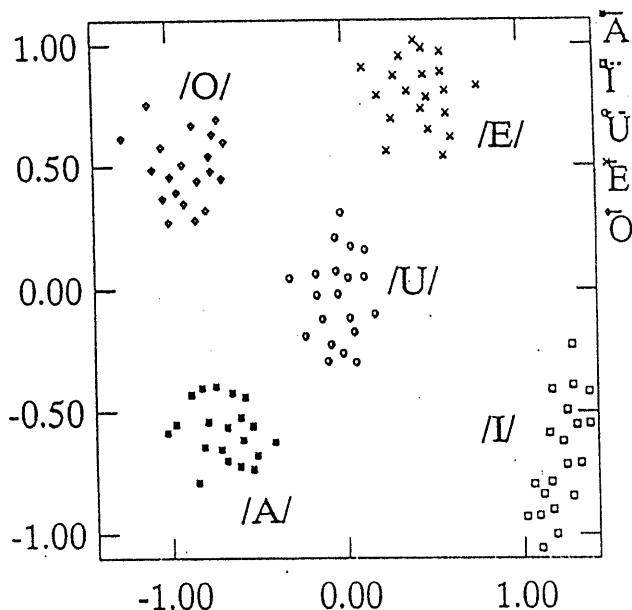


図2 NLMによる日本語母音の2次元平面への写像結果

$X_i; (i=1, \dots, 100)$ を入力パターンとし、対応する 2 次元ベクトルパターン $Y_i; (i=1, \dots, 100)$ を教師パターンとして NN で学習を行った。このとき、2 次元平面でのパターン $Y_i; (i=1, \dots, 100)$ の分布範囲が $|1.0|$ を超える場合は、全体を $-1.0 \sim 1.0$ の範囲に正規化する。学習法としてモーメント付き BP 法を用い、学習率を 0.037、モーメントを 0.45 とし、学習回数 2 万回まで学習を行った。NN は 3 層構造であり、中間層のユニット数について比較するため表 1 に示す 4 種類のネットワークについて調べた。中間層および出力層における各ユニットの入出力関

数は $y = \tanh(x); (-1.0 < y < 1.0)$ を用いる。

4. 実験結果

4. 1 学習曲線

NN による非線形写像学習の学習曲線を図 3 に示す。縦軸は平均自乗誤差、横軸は学習回数を表す。明らかに、NN の中間層

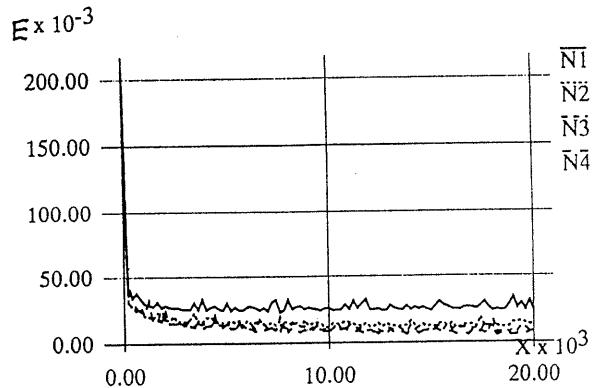


図3 NN の学習曲線

表1 実験に用いたNN

No.	入力層－中間層－出力層
N1	1 6 - 4 - 2
N2	1 6 - 8 - 2
N3	1 6 - 1 2 - 2
N4	1 6 - 1 6 - 2

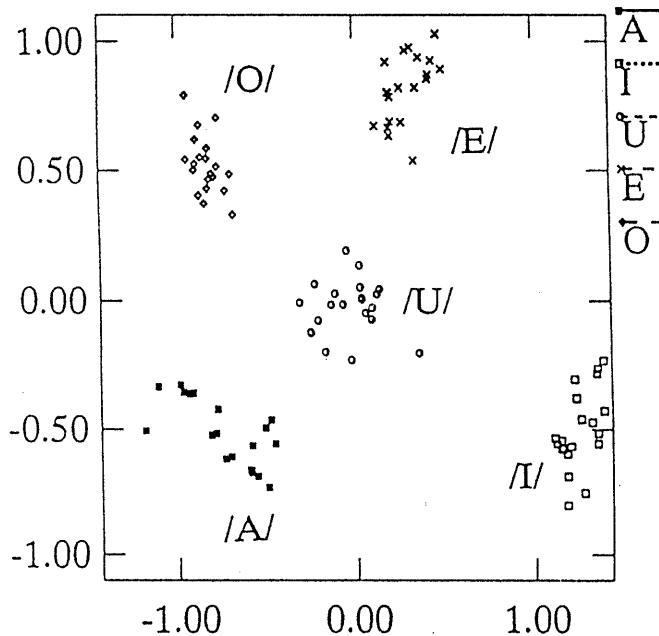


図4 ニューラルネットワークによる日本語母音テストデータ
の2次元平面への写像結果

ユニット数が多いほど、学習誤差が小さくなっていることがわかる。

4. 2 テストデータへの適用

未学習の音声データを新しく採取し、3.1と同様に各母音について20個ずつ合計100個作成し、テストデータとする。このとき、学習データを採取した人物Aとは別の人Bの音声を採取した。学習終了後のNNにテストデータを入力したときの出力を示す。このとき、実験用いた4種類のNNについて同様の結果を得たので、図4には中間層ユニット数8個の場合について示す。明らかに、各母音データは、それぞれの領域付近にマッピングされていることがわかる。これは、未学習のデータに対する汎化性が獲得されていることを示す。従って、母音音声パターンに関する16次元空間から2次元平面へのニューラルネットワークが可能である。

4. 3 近傍性の保存

ニューラルネットワークは、各母音領域と入力データの位置関係が、2次元平面上で視覚的に理解できる点に特徴がある。このとき、各母音に対する類似性が保存されていることが重要である。すなわち、各母音に類似した入力データは、その母音領域の中心の近くへ写像されることが必要である。これを近傍性の保存と呼ぶ。本節では、近傍性の保存について述べる。ここで、16次元空間におけるある領域 a の中心を C_a 、領域 a に属するパターンを X_a とし、2次元平面上の対応する領域を a' 、 a' の中心を $C_{a'}$ 、領域 a' に属するパターンを Y_a とする。近傍性の保存とは、 $\text{dist}[C_a, X_a]$ と $\text{dist}[C_{a'}, Y_a]$ が比例することである。

近傍性の保存について調べる。まず、元の16次元空間において各母音パターンの平均パターン(C_i, C_e, C_o ; 領域の中心に相当する)を作成する。次い

で、各平均パターンから半径 δ の超球表面上に分布する近傍性テストデータを 30 個ずつ合計 150 個作成する。近傍性テストデータと各平均パターン (C_a, C_i, C_u, C_e, C_o) をニューロ NLM によって 2 次元平面へマッピングし、 $dist[C_a', Y_a]$ を求める。図 5 に結果を示す。横軸は δ を表し、縦軸は $dist[C_k', Y_k]; (k=a,i,u,e,o)$ の平均値を表す。

明らかに、16 次元空間での距離と 2 次元平面での距離が比例的関係にあることがわかる。すなわち、ニューロ NLM は音声パターンの類似性を保存することが可能であり、発声訓練における音声の比較に用いることができる。

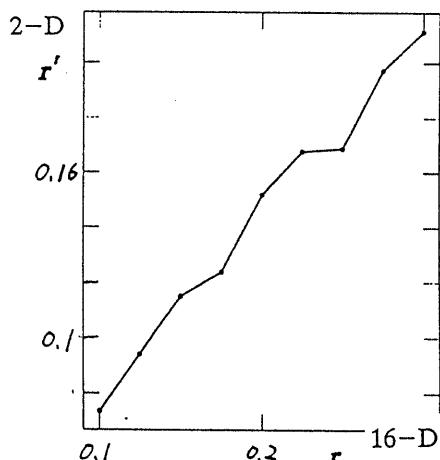


図 5 ニューロ NLM における近傍性の保存

4. 4 写像の歪曲性

高次元空間から低次元空間へ非線形写像を行った場合、その非線形性により写像空間が歪曲することが考えられる。すなわち、元の 16 次元空間での直線が 2 次元空間では大きく歪曲した曲線になることが考えられる。しかし、発声訓練では規範パターン

と入力パターンとの比較を行うことが重要であるため、極端な歪曲が生じることは錯覚をもたらす恐れがある。一般に、非線形写像では、その性質から写像に多少の曲がりが生じざるを得ないが、極端に歪曲した写像は好ましくない。従って、写像の歪曲性を検討する必要がある。

ここでは、16 次元空間での直線が、ニューロ NLM による非線形変換を経た 2 次元空間でどのような状態に変換されるかを観測することによって写像の歪曲性を調べる。16 次元空間中の 2 点 $A (a_1, a_2, \dots, a_{16})$ と $B (b_1, b_2, \dots, b_{16})$ を結ぶ直線 L は次式で表される。

$$L = (1-t)A + tB, (0 \leq t \leq 1) \quad (3)$$

従って、 t に対する L の座標を入力パターンとする NN の出力を観測する。学習に用いた母音音声データの平均パターン間を結ぶ直線は 5C2 (=10) 本があるので、これらのニューロ NLM による写像を調べることにより、歪曲性の大まかな様子がわかる。

実験で用いた 4 種の NN に対する歪曲性を観察した結果を図 6 に示す。図 6 より、明らかにニューロ NLM は非線形写像の実現にあたり、写像空間を歪めていることがわかる。また、中間層ユニット数が多いほど曲線の歪みが多くなっている。図 3 と併せて考慮すると、学習曲線の誤差が小さいほど歪みが大きくなる傾向にあることから、学習精度が高いことは必ずしも音声パターンの比較に適しているとはいえない。従って、音声パターンの位置関係を正しく把握するためには歪曲性の小さい NN が望ましい。すなわち、表 1 の NN 構造では、中間層ユニット数 4 個の NN が最も歪曲性が少ないニューロ NLM が可能である。

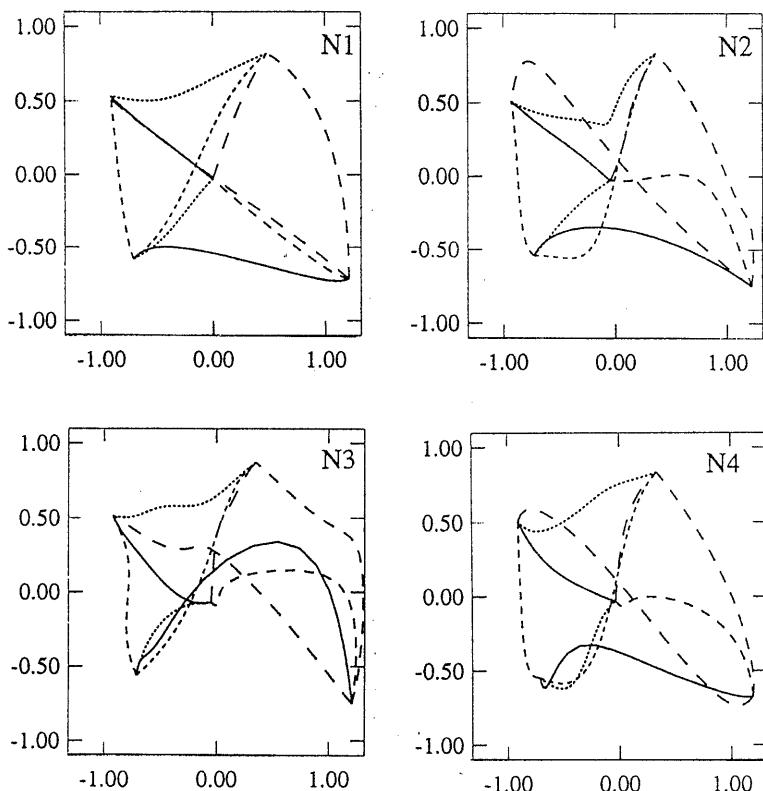


図6 ニューロNLMの空間歪曲性

5. まとめ

本論文では、発声訓練システムにおけるパターン表示方式の改善を目的とするニューロNLMを提案した。ニューロNLMによって多次元パターン群を2次元平面上にマッピングすれば、視覚的に理解し易くなる。そのため、利用者に対する効果的な訓練教育が可能になると思われる。今後は、①ニューロNLMの性質についてさらに詳しく検討すること、②子音音声の表示への拡張、及び③ニューロNLMを用いた訓練システムの設計、試作と実際の教育訓練効

果について調べる方針である。

参考文献

- [1] Sammon J.W.: "A Nonlinear Mapping for Data Structure Analysis," IEEE Trans. on Computers,C-18,5,pp.401-409(1969).
- [2] Chang C.L.,Lee R.C.T.: "A Heuristic Relaxation Method for Nonlinear Mapping in Cluster Analysis," IEEE Trans. on Systems, Man and Cybernetics,SMC-2,pp.197-200(1973).

- [3] Rumelhart D.E., McClelland J.L. and the PDP Research Group:"Parallel Distributed Processing," vol.1,MIT Press(1986).
- [4] Lippmann R.P.: "Pattern classification using neural networks," IEEE.comm,pp. 47-64,Nov.(1989).
- [5] Levitt H.: "Technology and speech training: An affair to remember," The Volta Review, 91(5), pp.1-6(1989).
- [6] Watanabe A., Ueda Y., Shigenaga A.: "Color display system for connected speech to be used for the hearing impaired", IEEE Trans. ASSP.vol.33, No.1,1985.