

# 複素リカレントニューラルネットワークを用いた メロディの記憶と想起

木ノ内 誠<sup>†</sup> 萩原 将文<sup>†</sup>

本稿では、複素数値化されたリカレントニューラルネットワークを用いてメロディの記憶と想起を行うシステム MUSIC (MULTilayer network for Sequential Inputs using Complex neurons) を提案する。従来のニューラルネットワークを用いた連想記憶モデルでは、時系列を静的パターンに変換してから扱うのに対し、提案システム MUSIC では、時系列を直接扱うことが可能である。提案システム MUSIC を、複数の小規模ネットワークへの分割・統合というアプローチによって拡張することにより、メロディ検索システムを実現する。ここでは、従来の音楽検索システムが必要としていた、データベースとのマッチング処理はいっさい行わないという特長を持つ。また、検索の手掛かりとして、曲名や作曲者などの文字情報ではなく、メロディの一部を用いるため、ユーザーにとって利用しやすいものとなっている。さらに、想起が逐次的に行われるため、入力に対するインタラクティブな処理を行うことが可能である。提案システム MUSIC では、複数音中からのメロディ抽出が可能となっている。

## Memorization of Melodies Using Complex-valued Recurrent Neural Network

MAKOTO KINOUCHI<sup>†</sup> and MASAFUMI HAGIWARA<sup>†</sup>

In this paper, we propose a music search system using a complex-valued recurrent neural network. In the proposed system, melodies are treated as temporal sequences. In the conventional associative memory models, melodies should be given at a time and they are treated as static patterns. The proposed system can treat a number of melodies by some smaller networks. Such architecture has an advantage that the pattern matching process is not required. The proposed system uses a part of the melodies as a key instead of the text information. It is demonstrated that the proposed system can be applied for the noise reduction system. The memorization ability of temporal sequences can be used for a lot of fields, e.g. control, information processing, thinking support systems, and so on.

### 1. まえがき

近年のコンピュータ技術の発展にともない、従来から行われていた事務処理や計算などの実務的なことがらだけでなく、趣味やゲームなどに対する需要が高まっている。コンピュータを用いた音楽もその1つであり、作曲・演奏・楽譜の作成など多くの応用がなされている。こうした分野では、人間の直観や感性が重視される。また、多くのユーザーは機械の操作を必ずしも得意としておらず、ユーザーにとってコンピュータの存在を意識させない技術が重要となる。

音楽に対するコンピュータの応用の一分野として、楽曲の検索があげられる。通常の音楽データベースでは

曲名、歌詞、演奏者や作曲者などの文字情報からの検索を行う。しかし、ユーザーが検索を必要とする場合には、これらの情報がまったく分からず、メロディのごく一部しか知らないことが多い。そのため、旋律情報からの検索を可能とするものとして、ハミング歌唱を手掛かりとしてメロディを検索するシステムが提案されている<sup>1)</sup>。しかし、インターフェースは大きく改善されているものの、検索方法については、データベースとのパターンマッチングを用いる従来の方式を踏襲している。パターンマッチングによる手法は検索に要する時間や柔軟性の点で、人間にとて必ずしも使いやすいものとはいえない。通常、手掛かりとして与えられる情報には多くの誤りを含んでおり、パターンマッチングをとる手法では、検索結果を候補としてあげるにとどまる。したがって、最終的な結果を得るために候補の1つ1つを確認する作業が残ってしまう。そこで、よ

<sup>†</sup> 慶應義塾大学理工学部

Faculty of Science and Technology, Keio University

り人間の感性に則した柔軟な検索を行う必要があると考えられる。

人間の脳を模倣した知識処理を行うモデルとして、ニューラルネットワークの研究がさかんに行われている。ニューラルネットワーク研究の一分野として、連想記憶モデルがあり、現在までに数多くの研究がなされている<sup>2)~6)</sup>。従来のコンピュータで用いられている記憶では、アドレスを指定して記憶を呼び出すのに対し、これらのモデルでは、手掛かりとして与えられる入力に対して記憶した内容そのものを想起する。したがって、入力にノイズや欠落がある場合でも、記憶した内容を正しく想起できる能力がある。

これらの連想記憶モデルは、いずれも静的なパターンに対するものである。時間的なパターンを扱う際には、一括入力によって静的パターンへの変換を行う必要がある。したがって、本質的な時系列処理にはならない。

一方、ニューラルネットワーク自身に、時間的な処理能力を持たせる方法として、時間遅延を持つ結合を付加する方法がある。この手法は次の2つに大別される<sup>7), 8)</sup>。

- (1) 入力から出力へ向かう順方向に、遅延を持った結合を付加する方法<sup>9), 10)</sup>。TDNN (Time Delay Neural Network) と呼ばれる。
- (2) ネットワーク内に遅延をともなうフィードバック結合を付加する方法<sup>11)~17)</sup>。RNN (Recurrent Neural Network) と呼ばれる。

(1) では、入力から出力への最大遅延経路により、扱うことのできる時系列の長さが限定される。この問題は静的なモデルに対して一括入力を行う際にも存在する。(2) ではこのような制約はない。

我々は、ネットワーク内で用いる数値を複素数に拡張することによって、RNN の処理能力を高めた MNCF (Multilayer Network using Complex neurons with local Feedback) を提案している<sup>18)~22)</sup>。

本論文では MNCF を用いてメロディの記憶と想起を行うシステム MUSIC (MULTilayer network for Sequential Inputs using Complex neurons) を提案する。MUSIC では、記憶しているメロディの一部が入力されると、その続きを想起する。したがって、メロディ検索を行うことができる。ここではデータベースとのパターンマッチング処理はいっさい不要である。また、入力を行なうにつれて、しだいに想起結果が現れるため、インタラクティブな検索が可能である。

リカレントネットワークを用いたメロディの記憶については文献 23) でも提案されている。しかし、文献 23) では隣接する 2 つの音の関係のみを学習し、過去の

履歴については忘却項を加えることによって取り扱っているため、時系列処理の潜在的性能に劣っている。

2 章では、提案システム MUSIC で用いる MNCF について簡単に説明する。3 章では、MUSIC によってメロディを記憶と想起する方法について述べ、計算機シミュレーションによって検証を行う。4 章では、MUSIC をメロディ検索に応用する際に必要となるネットワークの大規模化の手法について述べる。5 章では、複数音中からのメロディ抽出について述べる。

## 2. MNCF と CBPT

提案システム MUSIC で用いる複素リカレントネットワーク MNCF (Multilayer Network using Complex neurons with local Feedback) と学習アルゴリズム CBPT (Complex Back-Propagation for Temporal sequences) について簡単に説明する<sup>21)</sup>。

### 2.1 MNCF

図 1 に MNCF の構造を示す。図 2 に MNCF で用いられている自己フィードバックを持った複素ニューロンを示す。複素ニューロンは入出力、結合荷重、閾値に複素数を用いている。

$n$  層の  $j$  番目のニューロンの出力は次式によって計算される。

$$y_j^{(n)}(t) = f(u_j^{(n)}(t)) \quad (1)$$

$$u_j^{(n)}(t) = \sum_i w_{ji}^{(n)} y_i^{(n-1)}(t) + v_j^{(n)} y_j^{(n)}(t-1) + \theta_j^{(n)} \quad (2)$$

ここで  $u_j^{(n)}(t)$  はニューロンへの入力和、 $w_{ji}^{(n)}$  は  $(n-1)$  層の  $i$  番目のニューロンから  $n$  層の  $j$  番

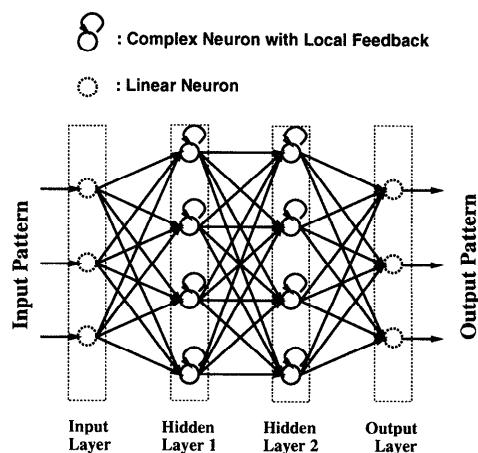


図 1 MNCF の構造  
Fig. 1 The structure of the MNCF.

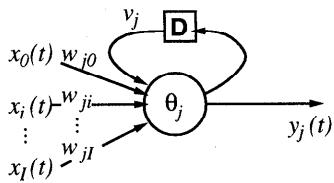


図2 自己フィードバックを持つ複素ニューロン  
Fig. 2 Complex neuron with local feedback.

目のニューロンへの結合荷重,  $v_j^{(n)}$  は自己フィードバックの荷重,  $\theta_j^{(n)}$  は閾値である。また,  $f(x)$  は次式で示される複素シグモイド関数である。

$$f(x) \equiv \tanh(\text{Re}x) + j \tanh(\text{Im}x) \quad (3)$$

なお MNCF では、虚部を無視することにより、入出力として実数値を扱うことも可能である。

## 2.2 CBPT

時刻  $t$  における結合荷重  $w_{ji}^{(n)}$  の更新量は次式によって計算される。

$$\Delta w_{ji}^{(n)}(t) = -\eta \sum_{\tau=0}^{T-1} \overline{y_i^{(n-1)}(t-\tau)} \delta_j^{(n)}(t, \tau) \quad (4)$$

ここで  $\bar{a}$  は  $a$  の共役複素数を表す。 $\eta$  は学習係数,  $T$  は学習のために遡る時間（学習考慮時間）である。 $T$  の値は大きいほど勾配法に厳密に従うため、ある程度までは性能の向上が期待できる。しかし、1回の学習に要する計算時間は  $T$  にほぼ比例するため、学習が可能な範囲でできるだけ小さな  $T$  を設定することが好ましい。

$\delta_j^{(n)}(t, \tau)$  は次式によって定義される。

(i) 中間層 ( $n \neq N$ )

$$\delta_j^{(n)}(t, \tau) = \begin{cases} 0 & (\tau < 0) \\ * \left\{ \sum_k \frac{\overline{w_{kj}^{(n+1)}}}{v_j^{(n)}} \delta_k^{(n+1)}(t, \tau) + v_j^{(n)} \delta_j^{(n)}(t, \tau-1) \right\} & (\tau \geq 0) \end{cases} \quad (5)$$

(ii) 出力層 ( $n = N$ )

$$\delta_j^{(N)}(t, \tau) = \begin{cases} 0 & (\tau \neq 0) \\ y_j^{(N)}(t) - d_j^{(N)}(t) & (\tau = 0) \end{cases} \quad (6)$$

ここで、\* は次式によって定義される演算子である。

$$x * y \equiv (\text{Re}x \text{Re}y) + j(\text{Im}x \text{Im}y) \quad (7)$$

また、 $f'(x)$  は次式によって定義され、複素シグモイド関数の導関数に相当する。

$$f'(x) \equiv \left\{ \frac{\partial}{\partial \text{Re}x} + \frac{\partial}{\partial \text{Im}x} \right\} f(x). \quad (8)$$

CBPT は、より一般化されたバックプロパゲーション

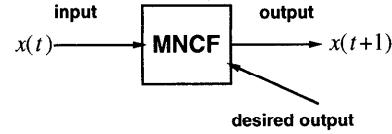


図3 記憶  
Fig. 3 Memory process.

ン・アルゴリズム<sup>24)</sup>であり、Jordan ネットワーク<sup>11)</sup>、Elman ネットワーク<sup>12)</sup>などにも適用可能なアルゴリズムとなっている。

## 3. MUSIC によるメロディの記憶と想起

メロディの記憶と想起を工学的観点からとらえると、メロディ中のある1つの音は、先行するいくつかの音によって決定されていると考えられる。この点に注目して、MUSIC (Multilayer network for Sequential Inputs using Complex neurons) では以下の方法で記憶と想起を実現する。

### 3.1 メロディの符号化

音符と休符を9ビットの {-1, +1} パターンに符号化する。具体的には、7つの音階に7ビット ('a' から 'g') を割り当てる。ここで異名同音については、同じ音として扱うこととする。同様に休符にも1ビット ('r') を割り当てる。これらの符号には音符の長さは含まれないため、「前の音が続いている」ことにもう1つのビット ('-') を割り当てる。

### 3.2 記憶

符号化されたメロディを時系列  $x(t)$  とする。記憶時には、図3に示すように、逐次的に  $x(t)$  を入力し、次の入力である  $x(t+1)$  を出力の教師信号として、MNCF を学習させる。 $x(t)$  が逐次的に与えられるために、1時刻の入力  $x(t)$  から  $x(t+1)$  への写像ではなく、以前の数時刻の入力  $x(t-\tau), \tau = 0, 1, 2, \dots, \tau_{\max}$  から  $x(t+1)$  への写像が学習される。

静的なニューラルネットワークや TDNN を用いる場合には、出力に影響を与える長さである  $\tau_{\max}$  の値が、その最大遅延経路によって限定されてしまう。これに対し、MUSIC ではリカレントニューラルネットワークである MNCF を用いるため、過去の入力をすべて反映することができる。

### 3.3 想起

MUSIC では、学習後にしばらく入力  $x(t)$  を与えると、出力は次第に次の入力  $x(t+1)$  と同じものになっていく。出力と次の入力が同じである状態が安定して続く場合には、MNCF の出力を入力の代わりに用いることが可能である。したがって、図4に示す

表1 バルトークの「ミクロコスモス」からの7つのメロディ  
Table 1 7 melodies from Bartók's *Mikrokosmos*.

#1	cde-fedrefgfedc-
#2	cdedefg-fedcd-e-fgfedcd-efedc---
#3	edcdcba-bcded-c-babcded-cbaba---
#4	a-g-fefga---g-f-gfede---f-g-g-e-fga-g---feded---
#5	bcd-cde-dcdef-e-fed-e-dcbcd-c---
#6	abc-d-cba---bcd-c-bab---cbaga-b-cdcba-g-abc-b-ag---
#7	gab-cba-bab---cdc-bab-rabcb-a-g---

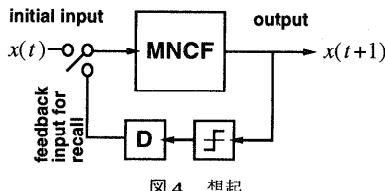


図4 想起  
Fig. 4 Recall process.

のような MNCF 外部でのフィードバックを行うことにより、以降は記憶された時系列が再現されることになる。

このような動作は、メロディーの一部を手掛けりとして与えて、その続きを想起することに相当する。ここで与えられる手掛けりは、メロディー中のどの一部分でも構わない。また、メロディー全体の長さに対して、非常に短い手掛けりからの想起も可能である。

### 3.4 計算機シミュレーション

計算機シミュレーションの結果を示す。ここでは、MUSIC と Elman のネットワーク<sup>12)</sup>を比較検討した。なお、Jordan のネットワーク<sup>11)</sup>は内的なフィードバックが出力層からのみであり、この問題を取り扱うのに適さないため、対象とはしなかった\*\*。

記憶するメロディーとして、バルトーク作曲の「ミクロコスモス」<sup>25)</sup>から選んだ7つのメロディ（表1）を用いた。

ニューロン数は MUSIC では 9-30-30-9 とし、Elman のネットワークでは 9+60(context)-60-9 とした。また、いずれのネットワークでも学習定数  $\eta = 0.01$ 、学習考慮時間  $T = 2$  として学習を行った。

図5に学習曲線の例を示す。MUSICの方が Elman のネットワークよりも、学習速度および学習後の誤差のいずれでも優れていることが分かる。

図6に、500エポック学習後に、メロディーの全体を入力し続けたときに、誤った音が输出された数を示す。

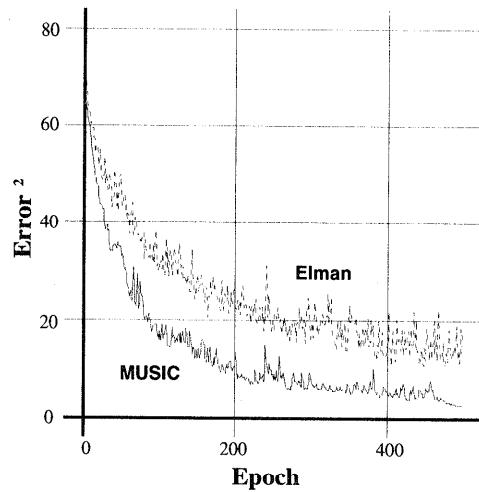


図5 学習曲線  
Fig. 5 Learning curves.

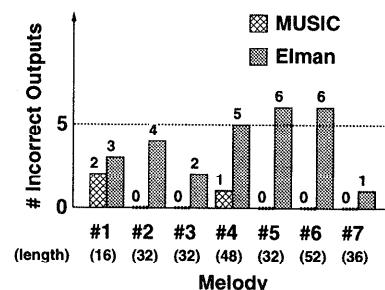


図6 誤った音の想起数  
Fig. 6 Incorrect outputs.

す。MUSIC はほとんど正しい音を出力しているが、Elman のネットワークは多くの音を誤って出力している。これは図5に見られるように、学習後の誤差が十分に小さくならないためである。MUSIC でも 3 つの誤った音が输出されているが、複数のメロディーの冒頭がまったく同じためで、これらは理論的に不可避な誤りである。

表2に想起の例を示す。この例においては MUSIC は正しいメロディーを完全に想起しているが、Elman の

\* 出力値を閾値処理して {-1, +1} に整える必要がある。

\*\* 学習終了時に文脈層と入力層の内容が一致してしまい、時間情報を保持するはずの文脈層が無意味となってしまうためである。

表 2 想起の例 (下線部は誤った想起部分)  
Table 2 Presented and recalled notes (Underline means incorrect recall).

presented		recalled
(#2) <u>cded</u>	MUSIC Elman	<u>efg-fedcd-e-fgf</u> <u>fedcd-efedc---</u> <u>efg-fedcd-e-fgf</u> <u>fedc---f-g-f-g</u>
(#3) <u>edcd</u>	MUSIC Elman	<u>cba-bcded-c-bab</u> <u>cded-cbab---cbaga-b-cd</u>
(#4) <u>a-g-</u>	MUSIC Elman	<u>fefga---g-f-gfede---f-g-g-e-fga-g---fede---</u> <u>fefga---g-f-gfede---b-agag---bcd---cdc-bab-rab</u>
(#5) <u>bcd-</u>	MUSIC Elman	<u>cde-dcdef-e-fed-e-dcbcd-c---</u> <u>cde-f-gc-b-cdcba-g---fbacgg-</u>
(#6) <u>abc-</u>	MUSIC Elman	<u>d-cba---bcd-c-bab---cbaga-b-cdcba-g-abc-b-ag---</u> <u>d-cbaga-b-cbaga-b-cdcba-gabcd---cdc-bab-a-g---fe</u>
(#7) <u>gab-</u>	MUSIC Elman	<u>cba-babcd---cdc-bab-rabcb-a-g---</u> <u>cba-babcd---cdc-bab-gcde---cbaga</u>

ネットワークでは、途中で誤った音を出力してしまうため、正しい想起はできないことが分かる。

表 2 に示した以外の入力を与えた場合にも、MUSIC は 7 つのメロディをそれぞれ独立して想起することができる事を確認した☆。これは Elman のネットワークでは不可能であった。

以上から、提案方法である MUSIC を用いたメロディの記憶と想起が実現可能な事が示された。また、従来型のリカレントニューラルネットワークである Elman のネットワークと比較して、MUSIC がより問題に適している事が確認された。

#### 4. メロディ検索システムへの応用

実際のメロディ検索システムに応用するためには、MUSIC に記憶する曲数を増やすなければならない。一般に、ニューラルネットワークの記憶容量はそのニューロン数によって決定されるため、MUSIC 自体を大規模化する方法が考えられる。しかしながら、この方法には次にあげるような問題点がある。

- (1) ニューロン数が増えるため、1 回の入力あたりの計算時間が膨大になる。
- (2) 記憶するパターン数が増加するため、1 エポックあたりの計算時間が膨大になる。
- (3) CBPT では、パターン入力ごとに学習を行うため、学習定数を小さくしないと振動しやすくなる。学習定数が小さいと学習速度が遅くなる。
- (4) 記憶パターン間の相関が高くなるため、学習がうまくできない。

このように、1 つの MUSIC によって数多くのメロディを記憶するには限界がある。そこで複数の小規模

な MUSIC を使用し、それを統合して扱うことにより大規模な問題を扱うことができるようになる。複数の小規模なニューラルネットワークを分割・統合する手法としては、Comb NET<sup>26)</sup>やその改良型である CombNET-II<sup>27)</sup>などが提案されている。これらは、大量の静的パターンを扱うことによく成功している。

ここでは、次に述べるような方法によって、小規模な MUSIC の統合を行う。複数の各 MUSIC には学習に無理のない曲数を記憶させる。想起時には、すべての MUSIC に対して、手掛かりとする入力を与える。手掛けり入力が記憶されている曲の一部である場合、その MUSIC は、次第にその入力と同じ音を出力するように反応する。一方、記憶されていない場合には、ランダムな音が出力される。したがって、各 MUSIC の出力と手掛けり入力との照合を行い、同じになったものを選択すれば正しい想起を行うことが可能である。

##### 4.1 計算機シミュレーション

記憶の対象として小学校低学年の教科書<sup>28)~30)</sup>から転調を含まない 79 曲を選んだ。1 曲は 32~192 音を含み、79 曲すべてを合計すると 5862 音である☆☆。

ニューロン数が 9-30-30-9 の MUSIC を 10 個使用し、ランダムに選んだ 7~8 曲ずつをそれぞれの MUSIC に記憶させた。学習定数は  $\eta = 0.01$ 、学習考慮時間は  $T = 3$  とした。学習時に、各曲を入力する前に内部状態をリセットしているため、「曲の冒頭である（それ以前に音がない）」ということも情報となっている。

200 エポックごとに学習状況をチェックしたところ、各 MUSIC とも 600 エポック以降はほとんど、誤差が改善されなくなった。1000 エポック学習後に、メロディの全体を入力し続けたときに、誤った音が出力さ

\* 複数のメロディに共通するような短い入力の場合には、該当するいずれか 1 つのメロディが想起された。

\*\* 1 曲あたりの平均は 74 音である。

表3 誤った音の個数

Table 3 Number of incorrect notes.

# incorrect outputs	0	1	2	3	4~
# melodies	24	34	14	4	3

れた数を表3にまとめる。記憶させた音の総数5862に対して、誤った音は101であった。

ここで想起に誤りが生じるのは次の2つの理由による。

(1) 冒頭が共通の曲があるため、理論的に不可避の誤り。

(2) 繰返しの部分で、次に進むか繰り返すかを誤る。

想起の際には、出力が8音\*連続して入力と同じになった場合にそのネットワークを選択することにした。この条件で79曲について、さまざまな箇所の入力をを行い想起結果を調べた。

60曲については、いずれも1つのMUSICのみが入力と同じ音を出力するようになり、以降その出力を入力として与えることにより正しい想起結果が得られた。

残りの19曲についても、1つのMUSICのみが正しく反応したが、フィードバックによる想起を開始した後に、曲が無限ループに陥るか、リフレインを省略して曲が早く終わってしまった。これは、前述の(2)による誤りのためである。

提案システムの欠点として、リフレインに対する弱さがあげられる。ごく一部からの想起が可能な反面、大きな繰返しがある場合にそれが何回目であるかを判別することができない。しかしながら、人がメロディを思い出す場合にもしばしば起こることであるため、むしろ自然であるともいえる。

リフレインの切り替わる部分について、自己フィードバックの代わりに手がかりとする入力を与えれば、正しい想起は可能であった。したがって、リフレインに関する処理機構を付加することによって、この問題は回避可能である。

## 5. 複数音からのメロディ抽出

前章で見られたように、学習後のMUSICは記憶したメロディだけに正しい反応を見せるようになる。そこで複数の音を同時に入力した場合に、記憶したメロディだけを抽出できるのではないかと考えられる。

MUSICの出力をそのまま用いるだけでなく、入力と比較して総合的に評価した方が良い結果が得られると思われる。そこで、MUSICの出力(次の音の予測)

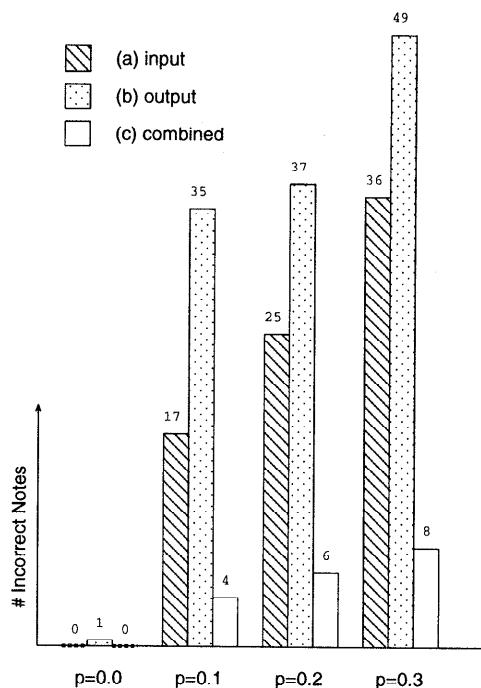


図7 MUSICを用いたノイズの除去結果(「丘の上」)  
Fig. 7 Noise reduction by the MUSIC ("Oka no Ue").

と、実際の入力(複数の音)を加算して評価を行うことにする。ここではMUSICの出力をアナログ値として扱い、次の入力との加算を行った後に最大値をとったものを選択する。

### 5.1 計算機シミュレーション

記憶する曲としては「丘の上(128音)」「若き血(176音)」「慶應義塾歌(264音)」の3曲を用いた。ニューロン数9-50-50-9のMUSICを学習定数 $\eta = 0.01$ 、学習考慮時間 $T = 3$ で400エポック学習させた。

記憶したメロディにノイズを加えたものを与えることにより、擬似的に複数の音が存在する環境を作る。ここでは次のノイズを想定した。

- 各時刻において、確率 $p$ で9ビット中の1ビットを反転させる。すなわち、本来の信号が欠落したり、雑音が同じ強度で加わることになる。この場合、信号の大小判別によるノイズ抑圧は不可能である。メロディが途切れ途切れであったり、他の音が加わったりした状態に相当する。

図7に、「丘の上」について、いくつかの反転確率 $p$ に対する(a)入力中の誤り数( $p$ により定まる)、(b)MUSICの出力中の誤り数、(c)入力とMUSICの出力を加算して評価したもののが示す。他の2曲についても同様の結果が得られた。

図7より、(b)のMUSICの出力をそのまま使用し

\* およそ1フレーズに相当する。

た場合には、ノイズ抑圧効果はあまり見られないことが分かる。これは、曲の中には似ている箇所が数多くあり、MUSIC が複数の音を候補として出力してしまうためである。一方、(c) の MUSIC の出力と入力を加算して評価した場合には、顕著なノイズ抑圧効果が見られる。これは、前述の MUSIC が output する次の音の候補が、実際の入力と一致することが多いことを示している。(b) では単純に第 1 候補（最大の出力をしたニューロン）だけを評価しているが、第 2 候補（2 番目に大きな出力をしたニューロン）に実際の音が数多く含まれているものと思われる。

以上から、MUSIC を用いた記憶と想起を応用して、信号の大小判別では不可能なノイズの抑圧が可能なことが示された。これは複数の音が聞こえる環境から記憶したメロディを抽出することに相当すると考えられる。

## 6. むすび

複素数値化されたリカレントニューラルネットワークである MNCF を用いてメロディの記憶と想起を行うシステム MUSIC を提案した。計算機シミュレーションにより、提案システム MUSIC によるメロディの記憶と想起が実現可能なことが確認された。また、従来型のリカレントネットワークである Elman のネットワークと比較して、MNCF を用いた提案システム MUSIC が問題により適していることが示された。

さらに、複数の小規模ネットワークへの分割・統合というアプローチによって、提案システム MUSIC がメロディ検索システムへ拡張できることが確認された。提案システム MUSIC では入力を与えるにつれて、しだいに次の入力と一致した音を出力し始める。したがって、口ずさんだ音を入力とし、それに合わせてスピーカから音を発するようなインタラクティブなシステムへの応用が考えられる。

提案システム MUSIC の記憶と想起の機能によって、信号の大小判別では不可能な、複数音からのメロディ抽出が可能であることが確認された。提案システム MUSIC は、メロディ以外の時系列にも適用可能であると思われる。時系列の連想記憶は、音声や動画像を扱えるだけではなく、ここで見られるように雑音の抑圧などにも応用可能であり、工学上非常に重要であるといえる。

**謝辞** 本研究は(財)サウンド技術振興財団の助成によって行われました。

## 参考文献

- 1) 藤山哲也, 高島洋典: ハミング歌唱を手掛りとするメロディ検索, 信学論, Vol.J77-D-II, No.8, pp.1543-1551 (1994).
- 2) Nakano, N.: Associatron - A model of associative memory, *IEEE Trans. Syst. Man. Cybern.*, Vol.2, No.3, pp.380-388 (1972).
- 3) Hirai, Y.: A model of human associative processor (HASP), *IEEE Trans. Syst. Man. Cybern.*, Vol.13, No.5, pp.851-857 (1983).
- 4) Hopfield, J.J.: Neural networks and physical systems with emergent collective computational abilities, *Proc. National Academy of Sciences*, Vol.USA 79, pp.2554-2558 (1982).
- 5) Kosko, B.: Bidirectional Associative Memories, *IEEE Trans. Syst. Man. Cybern.*, Vol.18, No.1, pp.49-60 (1988).
- 6) Hagiwara, M.: Multidirectional associative memory, *Proc. Int. Joint Conf. on Neural Networks*, Washington, D.C., USA, pp.3-6 (1990).
- 7) 石川真澄: ニューラルネットワークによる動的システムの学習と制御, 電学論, Vol.109-D, No.4, pp.225-229 (1989).
- 8) 麻生英樹: ニューラルネットワークによる時系列の学習, 電学論, Vol.110-C, No.3, pp.112-118 (1990).
- 9) Waibel, A., Hanazawa, T., Hinton, G., Shikano, K. and Lang, K.J.: Phoneme Recognition Using Time-Delay Neural Networks, *IEEE Trans. Acoust., Speech, Signal Processing*, Vol.37, No.3, pp.328-339 (1989).
- 10) Day, S.T. and Davenport, M.R.: Continuous-Time Temporal Back-Propagation with Adaptive Time Delays, *IEEE Trans. Neural Networks*, Vol.4, No.2, pp.348-354 (1993).
- 11) Jordan, M.I.: Serial Order: A parallel distributed processing approach, ICS Report 8604, UC San Diego (1986).
- 12) Elman, J.L.: Finding Structure in Time, *Cognitive Science*, Vol.14, No.2, pp.179-211 (1990).
- 13) Frasconi, P., Gori, M. and Sada, G.: Local Feedback Multilayered Networks, *Neural Computation*, Vol.4, pp.120-130 (1992).
- 14) Shimohara, K., Uchiyama, T. and Tokunaga, Y.: Subconnection Neural Network for Event-Driven Temporal Sequence Processing, *Neural Networks*, Vol.6, pp.709-718 (1993).
- 15) Parlos, A., Chong, K.T. and Atiya, A.F.: Application of the Recurrent Multilayer Perceptron in Modeling Complex Process Dynamics, *IEEE Trans. Neural Networks*, Vol.5, No.2, pp.255-266 (1994).

- 16) 西 正明, 降矢順治, 中村維男: ディレイ素子内包型バックプロパゲーションニューラルネットワーク (BPD) の一構成, 信学論, Vol.J78-D-II, No.10, pp.1522-1529 (1995).
- 17) 田伏未来, 木ノ内誠, 萩原将文: Mixture of Experts を用いたリカレントネットワークによる時系列処理, 信学技報, NC 96-168 (1997).
- 18) 木ノ内誠, 萩原将文: 自己フィードバックを有する複素バックプロパゲーション, 信学技報, NC 94-40 (1994).
- 19) Kinouchi, M. and Hagiwara, M.: Learning Temporal Sequences using Complex Neurons with Local Feedback, *Proc. IEEE Int. Conf. on Neural Networks*, Perth, Australia, pp.3165-3169 (1995).
- 20) Kinouchi, M. and Hagiwara, M.: Memorization of Melodies by Complex-valued Recurrent Network, *Proc. IEEE Int. Conf. on Neural Networks*, Washington, D.C., USA, pp.1324-1328 (1996).
- 21) 木ノ内誠, 萩原将文: 複素ニューロンによる時系列の学習, 電学論, Vol.116-C, No.7, pp.748-754 (1996).
- 22) 木ノ内誠, 萩原将文: リカレントネットワークを用いたメロディの記憶と想起, 日本 ME 学会 ME におけるニューロ情報処理研究会講演論文集, Vol.5, pp.3-4 (1997).
- 23) Todd, P.M.: A Connectionist Approach to Algorithmic Composition, *Computer Music Journal*, Vol.13, No.4, pp.27-43 (1989).
- 24) Rumelhart, D.E., Hinton, G.E. and Williams, R.J.: Learning internal representation by error propagation, *Parallel Distributed Processing*, Vol.1, pp.318-362, MIT Press (1986).
- 25) Bartók, B.: *Mikrokosmos*, Boosey & Hawkes (1994).
- 26) 岩田 彰, 當麻孝志, 松尾啓志, 鈴村宣夫: 大規模 4 層ニューラルネット "Comb NET", 信学論, Vol.J73-D-II, No.8, pp.1261-1267 (1990).
- 27) 堀田健一, 岩田 彰, 松尾啓志, 鈴村宣夫: 大規模ニューラルネット "CombNET-II", 信学論, Vol.J75-D-II, No.3, pp.545-553 (1992).
- 28) 市川都志春ほか: 小学生のおんがく 1, 教育芸術社 (1996).
- 29) 市川都志春ほか: 小学生の音楽 2, 教育芸術社 (1996).
- 30) 市川都志春ほか: 小学生の音楽 3, 教育芸術社 (1996).

(平成 9 年 6 月 30 日受付)

(平成 10 年 2 月 2 日採録)



木ノ内 誠

1971 年 4 月 6 日生。1994 年 3 月慶應義塾大学理工学部電気工学科卒業。1996 年 3 月同大学大学院理工学研究科修士課程修了。現在、同大学大学院理工学研究科博士課程在学中。ニューラルネットワークの研究に従事。



萩原 将文（正会員）

1959 年 10 月 29 日生。1987 年慶應義塾大学大学院博士課程修了。現在、同大学助教授。1991 年より 2 年間アメリカ Stanford 大学訪問研究員。ニューラルネットワーク、ファジイシステム、GA の研究に従事。工学博士。1986 年丹羽記念賞、1987 年電子情報通信学会学術奨励賞、1990 年 IEEE 論文賞、1994 年安藤記念学術奨励賞、1996 年ファジイ学会著述賞受賞。