# リカレントニューラルネットワークを用いた 複雑な特性を持つディジタルフィルタの設計法

吉村 宏紀・清水 忠昭・佐山 卓史・井須 尚紀・菅田 一博 知能情報工学科

A Construction Method of a Filter with Complicated Characteristics by Use of Recurrent Neural Network Hiroki YOSHIMURA, Tadaaki SHIMIZU, Takashi SAYAMA, Naoki ISU, Kazuhiro SUGATA

Department of Information and Knowledge Engineering, Faculty of Engineering, Tottori University, Tottori, 680 Japan E-mail: rocky@ike.tottori-u.ac.jp

Abstract: We developed a new method to construct a digital filter with recurrent neural networks by using the back propagation through time(BPTT) learning. We presented a systematic method to create teacher signals by multiplying the Maximum length linear shift register sequence (M sequence) and desired dynamics in the frequency domain and by transforming it to the time domain. Digital filters were constructed from fully cross-coupled and partially cross-coupled recurrent neural networks. Partially cross-coupled recurrent neural networks modeled after Direct Type I and II of IIR digital filter acquired appropriate properties through the learning. Our method is featured to be construct any complicated filter with desired dynamics from a recurrent neural network.

Key words: Neural network, digital filter, IIR, Speech synthesis, BPTT, M sequence

### 1. はじめに

リカレントニューラルネットワーク (Recurrent Neural Network: 以下RNN) は、ネットワークを構成 するユニット間のフィードバック結合によって動的 特性を持つため、時系列データの処理に適用できる [1]~[6]. ユニットの応答関数として線形関数を用 い、バイアス値(しきい値)を0とすることにより、 RNNの入出力関係はIIRディジタルフィルタと同 じ形式の伝達関数で表現することができる. 伝達関 数の係数は、RNN の結合荷重によって定まるので、 学習によって各ユニット間の結合加重を適当に決定 できれば、RNNを用いてディジタルフィルタを構成 することができる. 本研究では、RNNがディジタル フィルタの機能を獲得するように BPTT 法による学 習[7][8]を行い、学習後のネットワークの周波数特 性を検討した。本手法は、複雑な特性を持つディジタ ルフィルタの設計方法として非常に有効であること を示した.

## 2. RNNを用いたIIRディジタルフィルタの学習 構成法

#### (学習データ)

RNN がディジタルフィルタとして機能するよう

に、入力信号及び教師信号(期待出力信号)を学習データとして与えて学習を行った(図1). ネットワークの入力信号には、63点を1周期とする最大周期列(M系列)を用いた. M系列は擬似白色性信号であり、全離散周波数で等しいパワーを持つ2値系列である. この入力信号に63点DFTを施し、得られたスペクトルに構成するべきフィルタ特性を掛合わせた後、63点IDFTを施して得られた63点系列を1周期とする周期関数を期待出力信号とした.

さて、RNNを構成するユニットは時間遅れ素子としてモデル化されている。ネットワークに時刻nで入力された信号は、時刻n+1以降のユニット出力に影響を及ぼす。従って、RNNの学習では、入力信号に対して1点以上遅らせた期待出力信号を教師信号としてネットワークに与えなければならない。入力信号に対してd点遅らせた期待出力信号を教師信号として用いた。以降、この学習データの与え方をd点遅れ学習と呼ぶことにする。

## (学習則)

RNNの学習アルゴリズムには,通時的誤差逆伝播学習(Back Propagation Through Time, BPTT) 法を用いた. これは,RNNを時間ステップ分だけの階層を有する階層型ネットワークに変換して学習を行う方法である(図2). 各時刻ごとにネットワークのコ

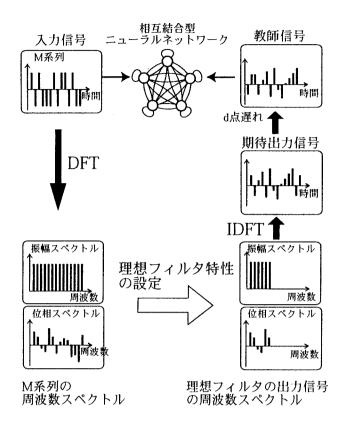


図1 リカレントニューラルネットワークを用いた ディジタルフィルタの構成法

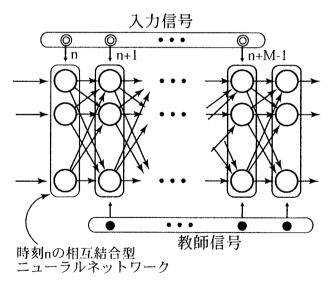


図2 通時的誤差逆伝播学習法 (BPTT)

ピーを作り、時刻順に並べて階層型ネットワークを構成する。ある時刻(階層)のユニットが次の時刻 (階層)のユニットと結合し、その結合荷重が全ての階層間で等しいネットワークとして表現される。このネットワークに誤差逆伝播学習を適用する。これによって、出力自乗誤差の時間総和は極小値に収束 する.

本研究では、ユニットの初期状態(時刻 0 におけるユニット出力)を全て 0 とし、結合荷重の初期値には -0.01 ~+0.01 の範囲の乱数を与えた。全てのユニットの応答関数は線形関数とし、各ユニットへの入力の総和をそのユニットの出力とした。また、ユニットはバイアス値(しきい値)を持たないものとした。

## (フィルタ特性)

RNNの学習後に、学習に用いた入力信号とは異なる63点M系列をRNNに入力し、出力信号に63点DFTを施してフィルタの振幅および位相特性を求めた.

## 3. 完全結合型 RNN を用いたフィルタ構成

全てのユニットが自らを含め全てのユニットと結合を持つ構造の完全結合型RNNを用いて基本的フィルタを構成した.

## (方法1)

ユニット数6個(入力ユニット1個, 出力ユニッ ト1個, および隠れユニット4個) の完全結合型 RNNを用いて、低域通過フィルタ(LPF)を構成 した. RNN の学習のために、63点M系列(離散周波 数1~31) を入力信号に用いた、便宜上、サンプリ ング間隔は1[s]とした. 期待出力信号は理想フィル 夕の出力とし、通過域の周波数成分は振幅1(0 [dB]) で位相差なく通過し, 阻止域(高域) 周波数成 分は完全に遮断する(振幅0)ものとした. 入力信 号を63点DFTした後、LPF構成のために離散周 波数 16~31 のスペクトルを除去し、63 点 I DFT を施して期待出力信号を得た. この期待出力信号を d点(d=1,2,…7) 遅らせた信号をネットワーク出力 の教師信号として, 各々BPTT法により学習を 行った. 1回の学習に適用する時間区間 (エポック) は63点(1周期)とし、学習回数は30万回とした。 ただし、学習定数  $\eta = 0.0001$ 、慣性係数  $\alpha = 0.1$  とし た.

### (結果1)

学習時に用いた入力信号とは異なる 63 点M系列を、学習終了後の RNN に入力して出力信号を求めた、入力信号に対する出力信号のスペクトラムの比を求め、RNNの入出力関数 (フィルタ特性) を得た、図 3 a、3 bに最も学習誤差が小さくなった 3 点遅れの振幅および位相特性を示す、細い破線が理想フィルタの特性を表わしており、実線は 3 点遅れ学習によって得られた RNN のフィルタ特性を表わしてい

る.図3aに示すように、RNNはLPFの特性を有しており、特に遮断周波数付近では急峻な利得の低下が得られた.しかし、阻止域での利得の低下は緩やかであった.また、通過域での位相差は6°以下と小さく、非常に良好な位相特性であった(図3b).

## (方法2)

上記の結果より、阻止域での遮断特性の向上を計るために、学習に用いる入力信号(M系列)の高周波数領域(教師信号で阻止域に設定した周波数領域)の振幅を20倍に大きくしたものを時間領域の信号に変換して、同様の学習を行った。この場合、学習に用いる入力信号はM系列ではなくなる。

## (結果2)

図4に、3点遅れ学習の振幅および位相特性を示す。図4aに示すように、方法2により学習を行ったRNNは、方法1に比べて、阻止域における利得を大幅に改善することができた。しかし、通過域では、方法1の方が平坦な特性となった。位相特性は、通過域での位相差が最大19°となり、方法1に比べて位相特性は低下した(図4b)。

## 4. 結合制限型 RNN によるフィルタ構成

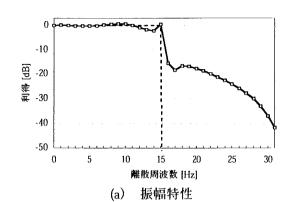
ユニット間の結合を制限した構造のRNNを3種考案し、前章と同様の学習を行って基本的フィルタを構成した。これらのRNNの伝達関数と等しい次数をもつIIRディジタルフィルタを従来法により設計し、振幅および位相特性の比較を行った。

#### (方法)

図5に示す3種のRNNを構成した、ユニット間の 結合は図中の実線矢印および破線矢印で表わされた 結合のみに限定し、波線矢印の結合加重は1に固定 して学習によって変化しないものとした. 図5aは, 直接型Iと呼ばれる構造のIIRディジタルフィル タを模したRNNであり、以降A型と呼ぶ、A型RNN の入出力関係を伝達関数によって表現すると式(1) となり、11個のユニットによって5次のフィルタが 構成される. 図5bは,直接型IIの構造を模したRNN であり、以降B型と呼ぶ、B型RNNの入出力関係を 伝達関数表現すると式(2)となり、7個のユニット によって5次のフィルタが構成される. 図5cは、自 己結合を多用したRNNであり、以降C型と呼ぶ、C 型 RNN の入出力関係は式(3)と表わされ、7個の ユニットによって5次のフィルタが構成される.た だし,

A = -(a+b+c+d+e)

B = a(b+c+d+e)+b(c+d+e)+c(d+e)+de+f



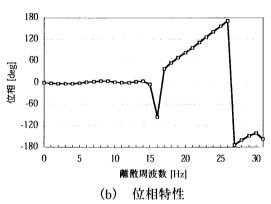
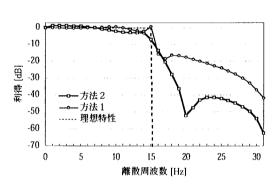
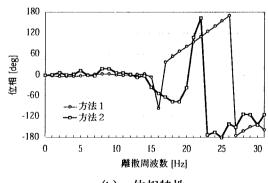


図3 完全結合 RNN の周波数特性

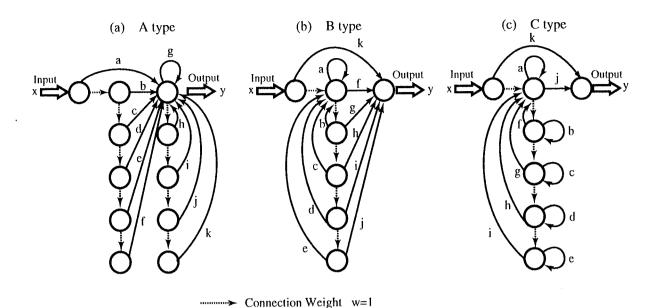


## (a) 振幅特性



(b) 位相特性

図4 学習に用いる入力信号の利得を変化させた完 全結合型 RNN の周波数特性



結合を制限した RNN によるディジタルフィルタの構成

C = (a(b(c+d+e)+c)d+e)+de)+b(c(d+e)+de)+cde)-g+f(c+d+e)

D = abcd+abce+abde+acde+bcde-h+g(e+d)-f(c(d+e)+de)

E = -abcde-i+he-gde+cdef

F = -(b+c+d+e)

G = b(c+d+e)+c(d+e)+de

H = -(b(c(d+e)+de)+cde)

I = bcde

である. これらの RNN を用いて, 前章と同様の方法で学習を行い, 低域通過フィルタ (LPF) を構成した. ただし, 学習定数  $\eta=0.0001$ 、慣性係数  $\alpha=0.1$ , 学習回数は 30 万回とし, d 遅れ学習 ( $d=1,2,\cdots,7$ ) を行った.

また、これらと等しい遮断周波数を持つように、バタワース及びチェビシェフ特性の5次IIRディジタルフィルタを従来法により設計し、その振幅および位相特性を求めてRNNによるフィルタの特性と比較した.

#### (結果)

A型、B型、C型の全てのRNNで、3点遅れ学習で学習誤差が最小となった。図6に学習後の各RNNのフィルタ特性と、バタワースおよびチェビシェフ特性をもつ5次IIRディジタルフィルタの振幅および位相特性を示す。A型(図6a,b)およびB型RNN(図6c,d)の周波数特性は、ほとんど同じ特性となった。A型およびB型RNNの振幅特性は、通過域ではチェビシェフフィルタより平坦な特性をも

ち、阻止域では遮断周波数付近においてバタワース およびチェビシェフフィルタより急峻な利得の低下 が得られた. また, 23[HZ]まではバタワースフィル タよりも良好な遮断特性を得た. これらの結果より, A型,B型RNNはバタワースおよびチェビシェフ フィルタの長所を合わせ持つ特性となった. 通過域 では理想フィルタと一致した. しかし, 阻止域での 利得は遮断周波数から離れても充分には低下しな かった,一方,A型,B型RNNの通過域での位相差 は最大で15°であり、13[Hz]より低い周波数では概 ね4°以下であった. 既存のフィルタの中でも位相 特性の良いとされるバタワースフィルタの位相差は 最大値で32°, 13[Hz]以下の周波数でも11°の位相 差を持つことから、A型およびB型RNNは既存の フィルタ特性と比べて、非常に良好な位相特性が得 られた、C型RNN(図6e,f)は利得の変化が緩徐 であり、A型およびB型ほど良好なフィルタ特性が 得られなかった.

## 5. 複雑な特性を持つフィルタの構成

複雑な周波数特性を持つフィルタをRNNの学習によって構成した.少ない重み結合で良好なフィルタ特性を有したB型RNNを用い,ユニット数の増減により伝達関数の次数を変化させてフィルタ特性を検討した.

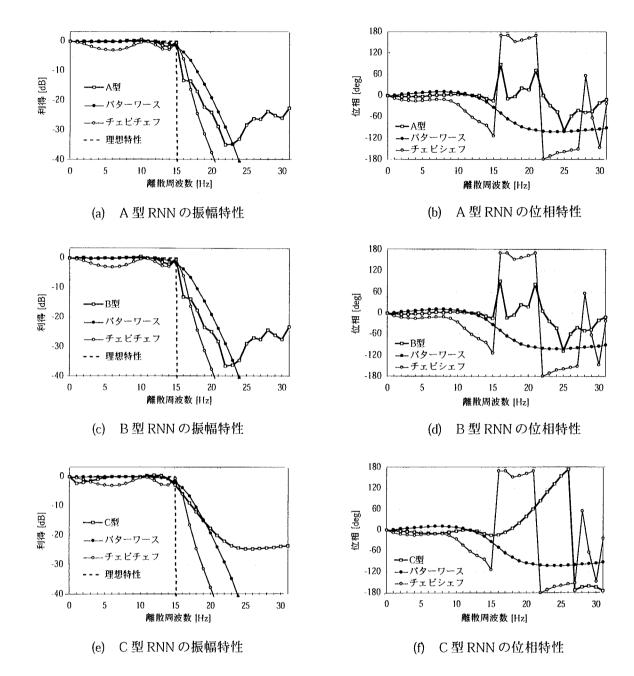


図6 結合を制限した RNN によるディジタルフィルタの周波数特性

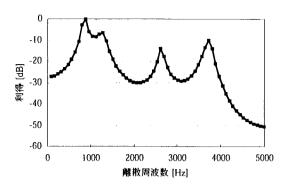
#### (方法)

LPC分析により得られた音声信号/a/のスペクトル 包絡 (図7a) を構成するベきフィルタ特性と考え,2章 (学習データ) に示した手順に従って教師信号を作成し,B型RNNの学習を行いフィルタを構成した.図7aに示すように,学習に用いる音声信号/a/(教師信号)の振幅特性は4つのピーク周波数(ホルマント周波数)を持つ特性となっている.B型RNNはフィルタの伝達関数の次数が5次,8次,および12次となるように構成し,d点遅れ学習(d=1,2,…,12)

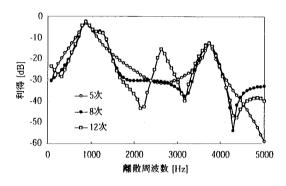
を行った. 学習定数  $\eta = 0.0001$ , 慣性係数  $\alpha = 0.1$ , 学習回数 は30万回とした. また, M系列は127点で1周期のものを用いた.

## (結果)

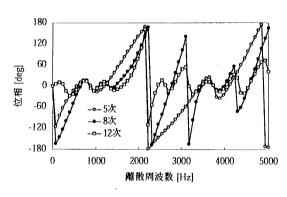
図7b, cに各次数のB型RNNの学習によって構成されたフィルタの振幅および位相特性を示す.図7bに示すように、振幅特性はB型RNNの次数が高いほど、教師信号の振幅特性に近づいた. 5次のRNNは、第2、第3ホルマントの特性が得られず、8次のRNNは、第3ホルマントの特性が得られな



## (a) 教師信号の振幅特性



(b) B型RNNの振幅特性



(c) B型RNNの位相特性

図7 B型RNNによる複雑な周波数特性の獲得

かった. 12次のRNNは、教師信号の持つすべてのホルマント周波数にピークを持つ特性となった。また、12次のB型RNNの位相特性は、ホルマント周波数に対応する周波数から利得が-3[dB]下がったところまでの帯域で17°以下であった

さらに、学習後の各B型RNNにインパルス列を入力して、音声合成を行った。この結果、各B型RNNとも、音声信号/a/を合成することができた。合成された音声信号/a/を比べると、12次B型RNNによっ

て合成された信号が、最も高品質であった.

## 6. 考察

提案したフィルタ構成法により、全ての結合の型 のRNNは、学習によってフィルタ特性を獲得した、 学習後のRNNの振幅特性は、通過域は平坦な特性と なった. また、阻止域付近では従来法によるフィル タ(バターワース、チェビシェフ)に比べて、急峻 な特性が得られた. しかし, 阻止域における利得は 遮断周波数付近での減少の後はほとんど減少しな かった、この理由は、出力信号と教師信号の誤差自 乗和を評価関数としていることに起因していると考 えられる. つまり、ネットワークの学習に用いる教 師信号に理想フィルタの特性を用いているため、周 波数領域で見ると、遮断周波数付近に学習誤差の割 合が多く含まれている. RNNは誤差のパワーの総和 を減少するように学習しており、誤差パワーの大き な遮断周波数付近の特性を特に修正するように学習 している、そのため、阻止域における利得を減少さ せることができなかったと考えられる。阻止域での 特性を向上させる方法の1つに、3章の(方法2)で 示したように、阻止域に設定した周波数領域で学習 に用いる入力信号のM系列のパワーを大きくする方 法が挙げられる.この方法は,阻止域で生じた学習 誤差に重みづけをしたのと同じ効果を与えており, 有効であった.

RNNによるフィルタの位相特性は、信号の通過域においては位相差をほとんど生じない非常に良好な特性となった。これは、出力信号と教師信号の時間領域での誤差自乗和を学習の評価関数としているため、フィルタの通過域を帯域とする教師信号と位相の合った信号を出力するようにRNNの学習を行うためであると考えられる。逆に、教師信号に含まれない周波数帯域すなわち阻止域では位相合わせの学習が行われず、位相差が比較的大きく現れたものと思われる。

#### 7. おわりに

RNNがIIRディジタルフィルタと同じ伝達関数で表現できるという特徴をいかして、RNNによるディジタルフィルタの構成方法を新しく提案した、ニューラルネットワークを具体的な問題に応用するときの最大のボトルネックは、大量の学習データをどのように取得するかである。この問題に対して、M系列を用いて非常に簡単な方法で統一的に学習デー

夕を作成する方法を提案した.

我々が提案した構成方法の一番の特徴は、どんなに複雑な特性を持ったディジタルフィルタであっても、複雑で難しい計算をすることなく、ユニット数を増加させるだけで同一の学習によって、所望のフィルタ特性を作れることである。これを、実際に発声された音声信号の母音スペクトラム特性をRNNで作り、構成方法の有効性を確かめた。

## 参考文献

- [1] Tsoi, A.C. and Back, A.D.; Locally recurrent globally feedforward networks: A critical review of architectures, IEEE Trans. Neural Networks, 5: 229-239, 1994.
- [2] Connor, J.T., Martin, R.D., and Atlas, L.E.; Recurrent neural networks and robust time series prediction, IEEE Trans. Neural Networks, 5: 240-254, 1994.

- [3] 村島淳, 二見亮弘, 星宮望; 時系列を発生する神 経回路の一般化能力について, 信学技報, NC93-103, 173-180, 1994,
- [4] 柳谷尚寿, 高橋治久, 富田悦次; リカレントネットワークを用いた連族音声認識, 信学技報, SP93-111, 55-62, 1993.
- [5] 平進太郎; 階層的統合と相互結合型神経回路網による時系列パターンの認識, 信学技報, PRU93-18, 9-16, 1993.
- [6] 戸田謙一, 二見亮弘, 星宮望; 時系列の短期記憶 を行なう神経回路機構モデル, 信学技報, NC92-61, 7-13, 1992.
- [7] Williams, R.J. and Zipser, D.; A learning algorithm for continually running fully recurrent neural networks, Neural Computation, 1: 270-280, 1989.
- [8] 水野政司, 高木秀彦, 郷原一寿; リカレントネットワークのBPTTを応用した実時間学習法, 信学技報, NC92-83, 23-30, 1992.

