

リカレント型ニューラルネットワークによる逆フィルタの構成

5E-4

丹羽建一 西野順二 小高知宏 小倉久和
福井大学工学部

1 はじめに

媒質を伝播する信号は、途中の様々な要因のために元の信号と比較すると一般に大きく変化する。この変化の要因は様々であるが、一般には非線形な効果を含んでいると考えられる。例えば人の循環器を伝播する脈波について考えると、大動脈における波形は動脈を伝播するに伴って変形し、上腕動脈より末梢に近い橈骨動脈で観測されるような波形に変化する。この場合、人の血管系を伝達していく過程を非線形伝達関数による変形ととらえることができる。このような信号の変化について、伝達関数を推測し、元の信号を同定することは医学的にも重要なことである。

このような信号変化の推定は、信号の伝達してきた系を一つのフィルタとみれば、未知のフィルタによって変形した信号を元の信号に戻すような逆フィルタを構成することに相当する。本研究の目的は、この変形した信号から元の信号を導く逆フィルタをニューラルネットワークの汎化学習能力によって獲得し、その結果からネットワークのもつ学習効果について考察する。本研究ではコンピュータシミュレーションによる予備的な実験について報告する。

2 学習ネットワーク

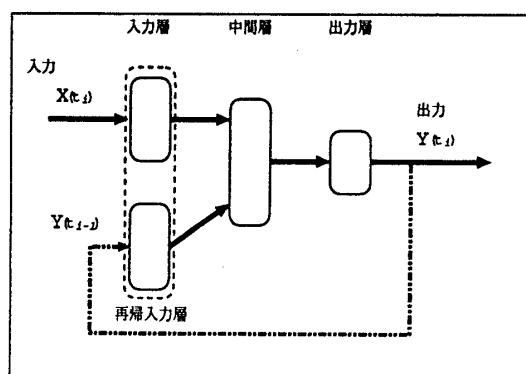


図1: ネットワークモデル

A study to construct inverse filter by the recurrent neural network.
Kenichi Niwa, Junji Nishino, Tomohiro Odaka, Hisakazu Ogura
Fukui University

我々があつかう信号は時間に依存する関数の形で表現できるので、時空間写像（時空間パターン認識）を可能にする方法の一つである、リカレントニューラルネットワーク [1] をもちいる。ネットワークの構成は、入力層、中間層（一層）、出力層の三層からなる階層型モデルである。入力層は、時系列データを入力する実入力層と出力層のフィードバックを受ける再帰入力層からなる。中間層は、実入力層と再帰入力層と全結合し、中間層の出力はすべて出力層に送る。ネットワークのモデルを図1に示す。

入力時系列データは Δt でサンプリングした

$$x(t_i), \quad t_i = i\Delta t, \quad i = 0 \sim T$$

とする。実入力層は、 k 個のユニットからなり、 t_0 から過去に連続する k 個のサンプリングデータ

$$x(t_0 - i\Delta t), \quad i = 0 \sim k-1$$

を受ける。

再帰入力層は、同様に出力層からの出力時系列データを

$$y(t_i), \quad t_i = i\Delta t, \quad i = 0 \sim T$$

とすると、 h 個のユニットからなり、 Δt ずつ遅れた h 個のデータ

$$y(t_0 - i\Delta t), \quad i = 1 \sim h$$

を受け取る。図2に時間遅延の発生を示す。この図のなかでは下にいく毎に Δt ずつ遅延が発生する。

実入力層と再帰入力層において不足するデータについては、すべて $x(0)$ で外挿した。




図2: 時間遅延生成

3 シミュレーションによる逆フィルタの学習実験

3.1 シミュレーションの方法

リカレント型ニューラルネットワークによる逆フィルタの学習能力をチェックするため、モデル時系列データを用いて実験を行った。リカレント型ニューラルネットワークは時系列データの特徴をとらえることができるが、逆フィルタ学習に対して、どのように働くかはよくわかっていない。そこで、特徴の異なるいくつかの基本波形に対し、フィルタを通した波形を入力時系列データとし、基本波形を出力するネットワークを学習により構成する実験をおこなう。

基本波形としては、

A ガウス型波形 $x(t) = e^{-\frac{t^2}{k}}$

$$k = 700$$

B 正弦波形 $x(t) = \sin(t * \frac{2\pi\omega}{T})$
 $\omega = 1, T = 100$

C ウェーブレット型波形
 $x(t) = e^{-\frac{t^2}{k}} \sin(t * \frac{2\pi\omega}{T})$
 $\omega = 8, T = 100, k = 700$

D 三角波形 $x(t) = -|t| + 1$
 を用意した。逆フィルタの学習能力はフィルタの性質にも依存すると考えられるから、いくつかのデジタルフィルタを用意する。線型が非線型か、あるいは巡回型か非巡回型かの影響を明らかにするため、

a 線型非巡回型フィルタ

$$y(t) = \frac{\sum_{i=0}^k w_i x(t-i)}{\sum_{i=0}^k w_i}$$

b 線型巡回型フィルタ

$$y(t) = \frac{\sum_{i=0}^l w_i y(t-1) + \sum_{i=0}^k w_i x(t-i)}{\sum_{i=0}^l w_i + \sum_{i=0}^k w_i}$$

c 非線形非巡回型フィルタ

$$y(t) = \frac{\sum_{i=0}^k w_i x(t-i)(1 - e^{-x(t)})}{\sum_{i=0}^k w_i}$$

d 非線形巡回型フィルタ

$$y(t) = \frac{\sum_{i=0}^l w_i y(t-i) + \sum_{i=0}^k w_i x(t-i)(1 - e^{-x(t)})}{\sum_{i=0}^l w_i + \sum_{i=0}^k w_i}$$

の4つのフィルタを用意した。すべてのフィルタは、 w_i によって重みの和が1になるように正規化をしている。このフィルタと上の基本波形との組み合わせに対して学習シミュレーションを行った。それぞれのパラメータは $k = 4$, $l = 1$, $w_i = \frac{1}{1+i}$ とした。本シミュレーションでは、フィルタを通した波形に対し

て、ゲイン効果が陽に現われないようにするため、出力波形の最大振幅が基本波形の最大振幅と一致するように正規化してから学習に用いた。学習用データセットは、基本波形にフィルタの出力の一周期分を100分割してサンプリングしたものを用いる。

3.2 シミュレーション結果

実験の進行状況は、デジタルフィルタ、データセット、シミュレーションシステムについて完成しており、現在ネットワークモデルに従ってネットワークを構築、実験を続けている。これまでのところ、予備的な実験をとおして信号の復元がある程度可能であることを確認しており、シミュレーション計画にしたがってネットワークの学習能力データを収集している。詳細については口頭で報告する。

4 今後の課題

今回のシミュレーションにもとづいて、様々な時系列データについてニューラルネットワークによる学習を適用していくことを検討する。例えば、動脈を伝播する脈波形、神経繊維を伝播するパルス波形など、実際の人体における波形解析をおこなう計画である。また、人の体は常に一定の状態ではなく、絶えず時間的に変動しているものである。このような効果がある場合、逆フィルタ学習においてそのような影響があるか、変動の様子の学習への影響の関係についてシミュレーションによる解析をおこなう。われわれは、MRIによる医用動画像についても研究をおこなっているが、動画像も時系列データとみた時様々なフィルタ効果を受ける。逆フィルタを構成することにより画像の再構成の精度を向上させることができるのではないかと考えている。

[参考文献]

1. R. ヘクト, ニールセン, ニューロコンピューティング, トッパン, 1992
2. 松岡 清利, ニューロコンピューティング, 朝倉書店, 1995