

## 振幅と周期が時間とともに変化する時系列データの ニューラルネットワークによる予測

小野寺光永<sup>†</sup>, 長嶋雲兵<sup>†</sup>, 吉田裕亮<sup>†</sup>, 青山智夫<sup>††</sup>, 細矢治夫<sup>†</sup>

### 概要

本研究では、時間とともに振幅と周期が同時に変化する時系列データの予測を行うために、ニューラルネットワークからなるモデルを構築した。このモデルは、振幅変換および周期変換を行なうための2つのニューラルネットワークと、それらを統括する一つのニューラルネットワークからなる。このモデルを用いた数値実験の結果、本研究で用いた全てのサンプルデータが、3周期以上の予測を学習と同程度の精度で行なうことができることがわかった。この予測精度は、主に振幅変換関数の予測精度に依存することがわかった。

## Neural network reproduction of time series data with varying amplitudes and frequencies

Mitsue Onodera<sup>†</sup>, Umpei Nagashima<sup>†</sup>, Hiroaki Yoshida<sup>†</sup>, Tomoo Aoyama<sup>††</sup>, Haruo Hosoya<sup>†</sup>

### Abstract

An artificial neural network simulation was applied to the recognition and reproduction of time series data whose amplitudes and frequencies simultaneously change with time. The model is composed of two neural networks respectively predicting the change of amplitudes and frequencies. The results of all our numerical experiments show that this model can predict the values of at least three following periods with the same order of accuracy. The quality of this prediction mainly depends on the prediction of amplitude change.

### 1 はじめに

従来、時系列データの解析は、自己回帰モデル、ニューラルネットワークモデル等によって行われてきた。自己回帰モデルとは、自分自身の過去の値を説明変数とする統計的モデルであり、時系列データを解析する上で最も基本的な方法である [1]。これまでに、この方法により、周期が一定であり振幅が変化する時系列データの予測が行われている [2]。一方、振幅が一定であり、周期が変化する時系列データの解析には、ウェーブレット変換を用いた方法が広く用いられている [3]。また、ニューラルネットワークモデルは、脳における神経細胞の信号伝達系をモ

デルとした情報処理手法であり、パターン認識、最適化問題など、様々な分野に応用されている [4]。この手法による時系列現象の解析は、主に株価予測などの経済的な分野で使われている。ニューラルネットワークモデルを使った青山らの方法 [5] では、振幅が一定であり、周期が変化する時系列データが再現可能であることが報告されている。

ところが、生体の断層イメージを測定する核磁気共鳴 (NMR: nuclear magnetic resonance) のシグナルのような、振幅と周期が同時に時間とともに変化していく時系列データを解析することは、ほとんど行われていなかった。そこで本研究では、ニューラルネットワークを用いたモデルを構築して、時間と

<sup>†</sup>お茶の水女子大学情報科学科

Department of Information Sciences, Ochanomizu University

<sup>††</sup>宮崎大学工学部電気電子工学科

Department of Electrical and Electronic Engineering, Miyazaki University

ともに振幅と周期が変換する時系列データの予測に関してその有効性を調べた。

## 2 モデル

本モデルでは、対象とするデータ（時間とともに振幅、周期とも変化する時系列データ）を表す関数  $F(t_i)$  が、振幅変換関数  $g(t_i)$  と周期変換関数  $c(t_i)$  の積として以下のように表されると仮定する。

$$F(t_i) = g(t_i) \times c(t_i) \quad (2.1)$$

この仮定の下で、以下の処理によりデータの予測を行う。

- (1) 振幅変換関数  $g(t_i)$  をニューラルネットワーク (NN) により求め、 $c(t_i) = g(t_i)^{-1} F(t_i)$  より  $F(t_i)$  を振幅一定のデータ  $c(t_i)$  に変換する。
- (2) 青山らの方法 [5] により  $c(t_i)$  の予測を行う。
- (3) (2.1) 式を用いて求める結果を得る。

全体の処理のモデルを Fig.1 に示す。ただし、第3層の  $\times$  はかけ算を行なうことを表す。左から入力された時刻  $t_i$  は、 $v_1$  および  $v_2$  という重みをかけられ、それ自身ニューラルネットワークである  $g_{NN}$  と  $c_{NN}$  に渡される。（ $g_{NN}$  と  $c_{NN}$  の構造は後述する。） $g_{NN}$  と  $c_{NN}$  の出力は、それぞれ  $w_1$ 、 $w_2$  という重みをかけられ  $F(t_i)$  が計算される。ネットワークの重み  $v_1$ 、 $v_2$ 、 $w_1$ 、 $w_2$  は、入力  $t_i$  に対する教師データを  $F_i(t_i)$  として学習させることにより、バックプロパゲーションにより決定する。

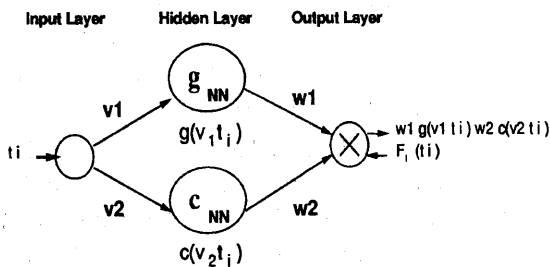


Fig.1. Overview of neural network model for time series data where amplitudes and frequencies are changing

次に、振幅変換のためのニューラルネットワーク  $g_{NN}$  について述べる。

### 2.1 振幅変換関数の予測

振幅変換関数  $g(t_i)$  の予測を行うために、入力  $t_i$  (時間) に対し  $g(t_i)$  を出力するニューラルネットワークを構築した。本研究で用いた振幅変換のためのニューラルネットワークは、入力層ニューロン数2、中間層ニューロン数20、出力層ニューロン数1の3層から成る、パーセプトロン型ニューラルネットワークである。ここで中間層のニューロン数20に特別な意味はない。ただし入力層のニューロンのうちの1つはバイアスニューロンである。またニューロンの動作関数として、中間層ではシグモイド関数、出力層では線形関数を用いた。出力層において線形関数を用いたのは、 $[0, 1]$  を越える出力を保証するためである。

ネットワークの学習は、予測対象データは、周期変換関数  $c(t_i)$  が振幅変換関数  $g(t_i)$  によりなんらかの変化を受けた結果であるという前提の下に、少なくとも振幅変換前のデータの極値は一定であったと考えることにより行う。変換前の極大値が1.0、極小値が-1.0であったと仮定すると、 $\{d: \delta F / \delta t |_{t=d_i} = 0\}$  について、

$$F(d) = |g(d)| \quad (2.2)$$

の関係が成り立つ。従って、入力  $d(t_i)$  に対する出力を  $F(d(t_i))$  として学習させることは、振幅変換関数  $g$  を学習させることと等価である。

### 2.2 周期変換、周期データの予測

周期変換及び周期データの予測は青山らの方法 [5] を採用した。これは、周期が変化する関数を、振幅と周期が時間とともに変化する周期関数と周期を変化させる関数との合成関数であるとして周期を変換させ、振幅と周期が時間とともに変化する周期関数に戻したのち、ニューラルネットワークにより

学習、予測を行うものである。振幅と周期が時間とともに変化しない周期関数の予測については、これまでにニューラルネットワークにより精度良く行うことができることが知られている [6]。

本研究で用いた周期予測のためのニューラルネットワークは、入力層ニューロン数 17、中間層ニューロン数 30、出力層ニューロン数 1 の 3 層から成る。中間層ニューロン数 30 に特別な意味はない。ただし入力層のニューロンのうち 1 つはバイアスニューロンである。またニューロンの動作関数は、 $g_{NN}$  同様、中間層ではシグモイド関数、出力層では線形関数を用いた。また、入力層のニューロンに入力するデータは  $[0.1, 0.9]$  にスケールされる。

### 3 数値実験とその結果

数値実験には以下のデータ列を用いた。

$$(1) \text{data } 1[i] = \frac{\sin((0.01976i)^2)}{(0.01976i)}$$

( $i=0 \sim 492$ , ただし、 $\text{data}[0]=0.0$ )

$$(2) \text{data } 2[i] = 100 \cos(0.3(i+11)+1) \exp(-0.005(i+11)) \\ + 25 \cos(0.31(i+11)+3) \exp(-0.003(i+11))$$

( $i=0 \sim 1025$ )

ただし data 1 では上記のデータを  $[-1, 1]$  にスケールしたものを用いた。また、全体のモデルの各重み  $v_1, v_2, w_1, w_2$  は、全て 1.0 としている。

誤差の計算と評価には、相対誤差の平均と標準偏差を用いる。相対誤差を用いるのは、減衰データを扱うため、絶対誤差よりも誤差と真の値との比の比較が重要だからである。以降本稿では、相対誤差をただ単に誤差という。

#### 3.1 data 1 の結果

data 1 は、時間の経過とともに振幅が  $1/t$  で減衰し、周期が  $t^2$  に比例して短くなるデータである。Table 1 に data 1 を実行した際の実データと予測結果との周期毎の誤差の平均と標準偏差を示した。 $t=0 \sim 401$  の 10 周期を用いて学習を行った後、 $t=402 \sim 492$  の 5 周期の予測を行った。(振幅変換の学習区間は第 1 ~ 第 10 周期、周期データの

学習区間は第 8 ~ 第 10 周期である。従って、Table 1 の第 8 周期から第 10 周期の値は学習結果である)。振幅変換関数の学習回数は 20000 回、周期データの学習回数は 3000 回である。この時の学習の精度は振幅変換で 0.017、周期変換で 0.045 であった。

また Fig. 4 に、実データ、予測結果、振幅変換関数  $g(t)$  のニューラルネットワークによる予測結果を示した。グラフ中の縦線は、それ以前が学習に用いられ、それ以降が予測結果であることを示す。

周期	平均誤差	標準偏差
第 8 周期	0.016	0.029
第 9 周期	0.095	0.144
第 10 周期	0.106	0.205
第 11 周期 (予測第 1 周期)	0.115	0.162
第 12 周期 (予測第 2 周期)	0.222	0.358
第 13 周期 (予測第 3 周期)	0.199	0.238
第 14 周期 (予測第 4 周期)	0.455	1.119
第 15 周期 (予測第 5 周期)	0.652	1.416

Table 1. Mean relative error and standard deviation of data 1

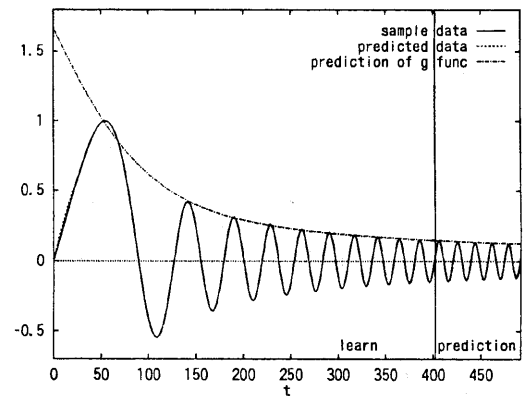


Fig. 4. Prediction of  $\sin(t^2)/t$ , where solid and two broken lines indicate the sample data, predicted data and predicted  $g$  function, respectively

Table 1 をみると予測全周期において学習結果と同等の 0.1 のオーダーの精度で予測できており、 $\sin(t^2)/t$  という関数の学習と予測が、我々のモデルを用いて精度良く行われたということが出来る。この他、 $\sin(t^2) \exp(-t)$ 、 $\sin(1/t)/t$  から成るデータ列に対しても、data 1 と同様、精度良く予測可能であることがわかった。従って、 $g(t)$  を学習、予測するニューラルネットワークにより振幅変換関数  $1/t$ ,

$\exp(-t)$  が十分に表現できたということができる。また、周期についても、青山らの方法により周期変換関数  $t^2, 1/t$  が精度良く変換可能であるということが出来る。

### 3.2 data 2 の結果

data 2 は、NMR などの信号に代表的な multiple nonstationary frequencies の近似関数で、周期変化のない周期関数の多項式から成るデータである。そのため data 1 よりも複雑であり、実データのグラフ (Fig.5) からわかる通り、予測開始時刻により、同じ学習幅を用いても予測精度が異なることが予想された。そこで、予測開始時刻を  $t=400$  (case 1)、 $t=803$  (case 2) とし、そこから data 1 と同様に 5 周期の予測を行うことで、適切な振幅変換の学習区間を調べることにした。ただし周期関数の学習には、data 1 と同様に、振幅変換の学習区間中の後半の 3 周期を用いた。それぞれの学習回数は、振幅変換関数の学習が 30000 回、周期データの学習が 3000 回である。




Fig.5. Multiple nonstationary frequencies whose amplitudes and frequencies simultaneously change with time (data 2)

#### 3.2.1 第 20 周期から第 24 周期の予測 (case 1)

学習区間による予測精度の違いを見るために、第 20 周期 ( $t=400$ ) から第 24 周期 ( $t=503$ ) の予測を、振幅変換の学習区間が予測前 5 周期 ( $t=296 \sim 399$ : case 1.1)、予測前 10 周期 ( $t=192 \sim 399$ : case 1.2) の場合について行った。周期変換の学習区間は、第 17 周期 ( $t=338$ ) から第 19 周期 ( $t=399$ ) である。この時の学習の精度は、case 1.1

が振幅変換で 0.017、周期変換で 0.043、case 1.2 が振幅変換で 0.025、周期変換で 0.043 であった。

Table 2.1, Fig.6.1 (case 1.1), Table 2.2, Fig.6.2 (case 1.2) の内容は data 1 と同じである。ただし第 17 周期から第 19 周期の値は学習結果である。また Fig.6.1 の 2 本の縦線は、縦線にはさまれた部分が振幅変換の学習区間であることを示す。Fig.6.2 の学習区間は  $t=192 \sim 399$  (縦線で示した) である。

周期	平均誤差	標準偏差
第 17 周期	0.016	0.046
第 18 周期	0.126	0.188
第 19 周期	0.067	0.058
第 20 周期 (予測第 1 周期)	0.222	0.410
第 21 周期 (予測第 2 周期)	0.102	0.120
第 22 周期 (予測第 3 周期)	0.256	0.355
第 23 周期 (予測第 4 周期)	0.292	0.546
第 24 周期 (予測第 5 周期)	0.317	0.464

Table 2.1. Mean relative error and standard deviation of data 2, case 1.1

周期	平均誤差	標準偏差
第 17 周期	0.016	0.045
第 18 周期	0.127	0.190
第 19 周期	0.070	0.067
第 20 周期 (予測第 1 周期)	0.220	0.414
第 21 周期 (予測第 2 周期)	0.106	0.119
第 22 周期 (予測第 3 周期)	0.259	0.357
第 23 周期 (予測第 4 周期)	0.306	0.531
第 24 周期 (予測第 5 周期)	0.336	0.466

Table 2.2. Mean relative error and standard deviation of data 2, case 1.2

Table 2.1, 2.2 を見ると、case 1.1, 1.2 どちらも、予測全周期において学習誤差と同等の 0.1 のオーダーの精度で予測が行われており、精度の良い予測が行なわれたということができる。両者を比較すると、ほとんど差がないが、細かく見ると予測第 2 周期目以降は学習区間が長い case 1.2 の結果の方が悪いことがわかる。これは case 1.2 では、予測に必要な  $t=200$  付近の振幅変換の傾きがゆるやかな箇所を振幅変換の学習データに含んだため、振幅変換関数の予測精度を落したことによる。その他、本稿に詳細は示さなかったが、学習区間を更に長くとり  $t=0 \sim 399$  としたものについても同様のことが確かめられた。

以上の結果から、この区間の予測には、振幅変換の学習に予測前 5 周期分用いれば充分であるという

結論を得た。また周期については、青山らの方法により、この区間の予測に関する周期変換が精度良く行われたことがわかる。




Fig.6.1. Magnified figure for  $t=192 \sim 503$  (learn range:  $t=296 \sim 399$ ), case 1.1

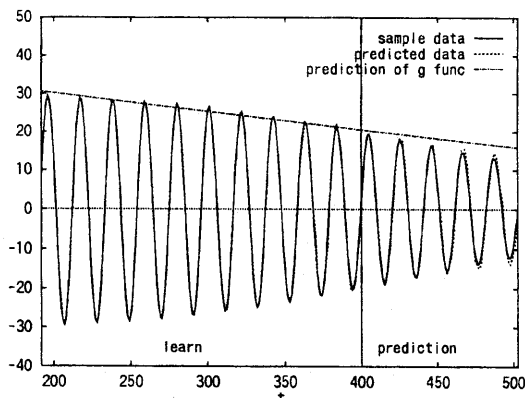


Fig.6.2. Magnified figure for  $t=192 \sim 503$  (learn range:  $t=192 \sim 399$ ) case 1.2

### 3.2.2 第40周期から第44周期の予測 (case 2)

第40周期 ( $t=803$ ) から第44周期 ( $t=905$ ) の予測を、振幅変換の学習区間が予測前3周期 ( $t=743 \sim 802$ : case 2.1)、予測前5周期 ( $t=708 \sim 802$ : case 2.2) の場合について行った。周期変換の学習区間は、第37周期 ( $t=743$ ) から第39周期 ( $t=802$ ) である。この時の学習の精度は、case 2.1 が振幅変換で0.023、周期変換で0.041、case 2.2 が振幅変換で0.285、周期変換で0.043であった。

Table 3.1, Fig. 7.1 (case 2.1), Table 3.2, Fig. 7.2 (case 2.2) の内容は data 1 と同じである。ただし第37周期から第39周期の値は学習結果である。また Fig. 7.2 の学習区間は  $t=708 \sim 802$  (縦線で示した) である。

周期	平均誤差	標準偏差
第37周期	0.013	0.036
第38周期	0.196	0.411
第39周期	0.177	0.394
第40周期 (予測第1周期)	0.132	0.154
第41周期 (予測第2周期)	0.428	0.782
第42周期 (予測第3周期)	0.270	0.163
第43周期 (予測第4周期)	1.094	1.607
第44周期 (予測第5周期)	0.642	0.576

Table 3.1. Mean relative error and standard deviation of data 2, case 2.1

周期	平均誤差	標準偏差
第37周期	0.022	0.075
第38周期	0.182	0.376
第39周期	0.142	0.300
第40周期 (予測第1周期)	0.198	0.204
第41周期 (予測第2周期)	0.401	0.262
第42周期 (予測第3周期)	0.565	0.321
第43周期 (予測第4周期)	1.055	0.555
第44周期 (予測第5周期)	1.141	0.402

Table 3.2. Mean relative error and standard deviation of data 2, case 2.2

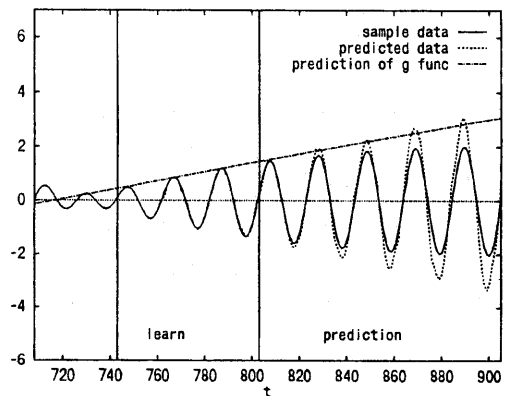


Fig.7.1. Magnified figure for  $t=708 \sim 905$  (learn range:  $t=743 \sim 802$ ) case 2.1

Table 3.1, 3.2 を見ると、case 2.1, 2.2 どちらにおいても予測第3周期目までは学習誤差と同等の0.1のオーダーの精度で予測できており、十分に予測ができていたということが出来る。両者を比較すると、長期間の学習を行った case 2.2 の方がむしろ結

果が悪いことがわかる。これは、case 2.2 では学習区間を長くとしたが、予測に必要な変化の性質は case 2.1 と同様に学習していないためであり、この場合学習区間を長くすることは無意味であることがわかる。その他、本稿に詳細は示さなかったが、学習区間を予測前 10 周期以上としたものでは、case 2.1, 2.2 に比べ結果が悪いことがわかった。

以上のことから、この区間の振幅変換の学習には、予測開始前 3 周期分程度あれば充分であるといえることができる。またこの区間においても、青山らの方法により周期変換が精度良く行われたといえる。




Fig.7.2. Magnified figure for  $t=708 \sim 905$   
(learn range:  $t=708 \sim 802$ ) case 2.2

### 3.2.3 data 2 のまとめ

case 1, 2 ともに振幅変換の学習区間の長さにかかわらず、予測開始後 3 周期までは学習誤差と同等の精度で予測を行うことができた。振幅変換の学習区間については、長期の学習区間は、かえって予測精度を落す場合があることがわかった。また、本稿に詳細は示さなかったが、 $t=213$ 、 $t=606$  からの予測を行った際にも同様のことが確かめられた。従って、振幅変換の学習区間としては、たかだか 5 周期分程度で充分であるという結論を得た。また周期変換については、周期変化のない周期関数の多項式で表現される data 2 の場合でも、青山らの方法により周期変換を精度良く行うことができた。

## 4 まとめと結論

本研究では、時間とともに振幅と周期が同時に変化する時系列データの予測を行うために、ニューラルネットワークを用いたモデルを構築し、数値実験を行った。その結果、本研究で用いたサンプルデータ全てにおいて、学習後 3 周期先程度の予測データ領域の変化が充分予測可能であった。この中で、周期変換については青山らの方法によりほぼ正確に行うことができることが確かめられ、予測精度は振幅変換関数の予測結果に大きく依存することが判った。以上の結果から、本研究で用いたニューラルネットワークモデルは、振幅、周期が時間とともに変化する時系列データの解析に有効であるといえることができる。

今後の課題として、ノイズを含むデータに対しても適用してみたい。

## 参考文献

- [1] 北川源四郎, 時系列解析プログラミング, 岩波書店, 東京, 1993.
- [2] G.L.Bretthorst, *Bayesian Model Selection: Examples Relevant to NMR*, Maximum Entropy and Bayesian Methods, J.Skilling(Ed.), Kluwer Acad. Publs., Dordrecht, 1989, pp.377.
- [3] 南慶一郎, 河田聡, 時間で特性が変化する信号の新解析手法 — 時間 - 周波数解析, インターフェース, 20(1994), 110-121.
- [4] 萩原将文, ニューロ・ファジィ・遺伝的アルゴリズム, 産業図書, 東京, 1994.
- [5] 青山智夫, 井須芳美, 長嶋雲兵, 階層型ニューラルネットワークによる時系列現象の予想, IPSJ Sig Notes, 95-HPC-59(1995), 13-17.
- [6] 上村龍太郎, 回帰ニューラルネットワークによる時系列パターンの復元, 情報処理学会人工知能研究会報告, 70(1990), 1-10.