

# ニューラルネットワークを用いた 心拍データの学習と利用

赤尾維<sup>†1</sup> 野村涼子<sup>†1</sup> 石川由羽<sup>†1</sup> 高田雅美<sup>†1</sup> 城和貴<sup>†1</sup>

近年、少子高齢化の急速な進展や生活習慣病の増加に伴う医療負担の増大が問題となっており、個人で健康管理を行う予防医療が求められている。そのためにリアルタイムで健康を管理できるウェアラブル機器が開発されている。また心拍変動の解析によって心理的ストレスの推定ができることが知られている。心理的ストレスの推定には安定した心拍データが求められるため、ノイズの除去や欠損値の補完が重要である。日常生活においてウェアラブル端末で心拍を取得する際、ノイズの混入や一時的にデータを取得出来ない場合がある。そこで本研究ではニューラルネットワークを用いて心拍の学習を行い、心拍データの欠損を個人の個性を残して補完する手法を提案する。

## Learning Heart Rate Data by Neural Networks and its application

YUI AKAO<sup>†1</sup> RYOKO NOMURA<sup>†1</sup> YU ISHIKAWA<sup>†1</sup>  
MASAMI TAKATA<sup>†1</sup> KAZUKI JOE<sup>†1</sup>

In recent years, increasing medical burden due to the increase of rapid progress and lifestyle diseases of aging becomes a problem, preventive medicine to make personal health management has been required. Wearable device that can manage health in real time has been developed for this purpose. Also known to be able to estimate the psychological stress by analysis of heart rate variability. Since stable heart rate data is required to estimate the psychological stress, completion of removal or missing values of the noise is important. When obtaining the heartbeat on the wearable terminal in daily life, it may not be acquired contamination and temporary data noise. So to perform learning of heart rate by using a neural network in this study, we propose a method to complement leaving the personality of individual defects in heart rate data.

### 1. はじめに

近年、我国では急速な少子高齢化や生活習慣病の増加に伴う医療費負担の増大が大きな社会問題となっており、個人が積極的に健康管理を行う予防医療が求められている。また高ストレス社会は心因性精神障害を引き起こす要因であるとともに生活習慣病などの様々な疾患の一因と言われている。そのため心理的ストレスを推定し解析する事は心因性障害や生活習慣病の予防の一助となると考えられる。ストレスを客観的に推測するための方法として、従来の手法ではアンケートが使用されている。しかしながら、アンケートを答えるための時間が必要な点や、答えること自体をストレスと感じるなどの問題点がある。そこで、近年新たに注目されつつあるのが、心拍計測によるストレス推定である。心理的ストレスは心拍変動から推定する事ができると報告されている[1]。最近ではスマートフォンを用いて心拍を測定しストレス測定するアプリケーションやサービスが売り出されている。たとえば、その一つがストレススキャンという株式会社 DUMSCO が開発した iPhone 向けのアプリケーションである[2]。このアプリケーションは iPhone のカメラに指を 2 分間当てることで得られた動画か

らリアルタイムに心拍数とストレスの測定を行う。指先の毛細血管から血のめぐりの状態を読み取り心拍変動解析をして心拍数や自律神経の状態を測定する。緊張を司る交感神経と休息を司る副交感神経のバランスを測ることでストレス状態の数値化を行う。また測定すればするほど個人の情報を学習しより正確なストレス指数を導き出すことが可能となる。別の例として、日立システムズが提供している疲労・ストレス測定システムがある[3]。これは疲労科学研究所が開発した自律神経測定機器と日立システムズのデータセンターを活用し疲労・ストレス度合いを診断・解析するシステムである。測定方法は自律神経測定器のセンサー部分に両手の指先を 2～3 分挿入し心電図と脈波を同時に測定する。測定されたデータはデータセンターに送られ、心電図から心拍、脈波から指先の静脈の血流状態を計測することで交感神経と副交感神経のバランスと強さから疲労・ストレス状態を算出される。これらは、ストレス測定器に、2 分から 3 分、脈拍を取得できるように接触する必要がある。また、ユーザが自ら測定しようとする意志がある時にしかストレスを測定することができない。つまり、日常のいつストレスを感じているか判明しているならば、その瞬間にユーザの意思によってストレス測定をすればよい。しかしながら、自覚症状がない場合、適切なタイミングで測定できる保証はない。そこで、常日頃から心拍を取得し、ストレス値が危険値になった場合のレコメンドを返

<sup>†1</sup> 奈良女子大学大学院  
Nara Women's University

スマートヘルスケアナビゲーションシステム[4]が開発されている。このスマートヘルスケアナビゲーションシステムでは、ウェアラブルセンサデバイスから得られた生体情報を基に、ユーザに適したレコメンドを瞬時に知らせることができるシステムである。これは小型心拍計などのウェアラブルセンサデバイスの発達により日常で簡単に心拍変動の計測が可能となっていることを活用している。ただし日常生活で小型心拍計を用いて心拍を計測する際、電極のずれや浮き、発汗による電位変動など様々な要因により正確にデータを計測できない場合がある。ストレスの推定には安定した心拍変動のデータが求められるため、ノイズの除去や欠損の補完が必須となる。なお、本研究では心拍変動のデータではなく心拍変動を計算するための心拍時系列データを対象としており、心拍時系列データの一拍分のことを特に心拍パターンと呼ぶ。

ストレス以外の心拍応用分野として、心拍パターンの個性を利用した個人認証の研究が行われている[5]。この研究では、心拍に含まれる個性に関する情報を保つ必要がある。そのため、一意的に心拍データから、ノイズの除去や欠損の補完をするべきではない。つまり、ノイズや欠損値の補完において生体個人の個性を保つことが必要である。そこで本研究では、リカレント型のニューラルネットワークを用いた心拍パターンの学習手法を提案する。この学習により、心拍データのノイズや欠損値を補完する際に個人の心拍波形の個性を反映した補完を行うことが可能となると考えられる。

以下、2章では、ニューラルネットワークを用いた時系列データの学習に関する研究を紹介する。3章では、ニューラルネットワークを用いた心拍パターンの学習手法の提案を行う。4章では、実験に用いた機器の説明や心拍波形の取得方法、前処理について述べ、実験結果を述べる。

## 2. 関連研究

ニューラルネットワークを用いた時系列データに関するパターン認識において脳波に関わる研究は比較的古くから行われており、様々なニューラルネットが提案されている[6]。例えば次元圧縮機能を有する確率ニューラルネットを用いた時系列脳波パターン識別に関する研究がある[7]。生体信号の識別にニューラルネットワークを用いる場合、複数の要因が複雑に絡み合った非線形関係を表現出来るだけでなく、学習的に写像を獲得でき、時間経過に伴う環境の変化にも適応できるなどの点から有効な方法であると言われている。しかしニューラルネットワークへの入力が高次元化することにより学習にかかる時間が膨大になるという問題がある。次元圧縮が可能なニューラルネットワークも提案されているが入力パターンの時系列性は考慮できていない[8]。また誤差逆伝搬法を用いたニューラルネットワークでは、その構造が一様であるため、写像の複雑さ

が増すにつれて、大量の教師データ数や学習の時間、大規模なネットワークが必要である。そこで研究[7]では、混合正規分布と隠れマルコフモデルを内包したリカレント構造を有する確率ニューラルネットと線形判別分析を用いることで、実用的な環境下において次元圧縮した時系列信号の識別を可能にしている。さらに、次元の圧縮により学習や識別に伴う計算時間の大幅に短縮される。

脳波以外に関する研究においても、時系列顔表情のニューラルネットワークを用いた学習が行われている[9]。顔には年齢や性別、感情などの様々な情報が含まれており、この情報は人間同士でコミュニケーションをする場合に非常に重要な役割を担っている。話し相手の表情から推察した相手の感情によって、その後の言動や行動は自然と違いが生じる。この認識をコンピュータでも可能にすれば、人間とコンピュータとの自然なインターフェイスの実現に繋がる。そのため人間の表情から感情を推察できるような能力が求められる。しかし画像データは一般には高次元であり、顔画像をそのまま扱うことは困難である。そこで研究[9]では時系列の顔表情から取り出した画像データをリカレントニューラルネットを用いて次元圧縮し、画像の特徴量抽出を行っている。従来、次元圧縮をする際に秒時計型のニューラルネットワークが用いられている。ただしこれは、時間情報をもたないデータを対象とした手法である。一方、研究[9]ではエルマンネットを基にした秒時計型リカレントニューラルネットを用いて顔の特徴点の時系列情報を次元圧縮することが可能であることを示している。

他には、音声波形をリカレントニューラルネットワークを用いて学習させる音声認識手法も提案されている[10]。従来行われている音声認識手法には、音声波形の切り出しを行ったあとに特徴点抽出を行い時系列パターンのデータ量を大幅に圧縮していた。しかしこの方法ではどの区間を切り出すか、抽出した特徴点が妥当であるかといった点が問題となる。そこでこの研究ではリカレントニューラルネットワークを用いて音声波形そのものの学習をさせる。入力パターンは環境雑音のある成人男性1人が発した“あ”“い”“う”“え”“お”の5つであり、ランダムな順番で連続して学習させた。その結果、高い認識率が得られた。これにより、音声波形そのものを学習パターンとして用いる音声認識手法が可能であることがわかった。

## 3. 心拍パターン学習におけるニューラルネットワークの構造

### 3.1 心拍パターン学習の概要

心拍波形学習の流れを説明する。

- 手順1 ECG (Electrocardiogram, 心電図) の取得
- 手順2 前処理の適用
- 手順3 ニューラルネットワークを用いた学習

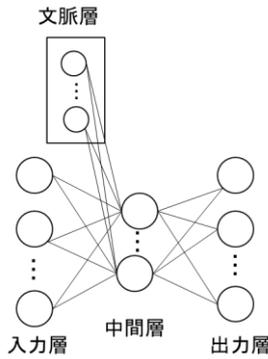


図 1 3層型エルマンネットの構造

手順 1 では、学習の教師データとなる心拍波形を取得するために、ECG を取得する。ここで取得する ECG には、ノイズや欠損が含まれている可能性がある。

手順 2 では、取得された ECG に対して、簡単なノイズ除去と正規化を行う。この際、大きなノイズや欠損が含まれる ECG は、学習の教師データとしてはふさわしくないため、除外する。正規化を行うことにより、心拍波形の学習に適したデータに変換することができる。

手順 3 では、ニューラルネットワークに手順 2 で得られた教師データである心拍波形に関するデータを与える。この際、欠損を補完できるように学習させるために、ランダムに欠損を加えたデータを入力データとして与える。これにより、任意の箇所で見える欠損を補完することができるようになるものと思われる。なお、本研究では、基本のエルマンネットとそれを拡張したモデルを 2 つ提案しそれぞれで学習を行う。

心拍パターンは時間情報をもつ時系列データであるため、時系列性を考慮できるエルマンネットを拡張したモデルを 2 つ提案する。また学習係数と慣性項はニューラルネットワークの学習を行ううえで非常に重要であり、その数によって収束する速度は大幅に異なる。しかし、この 2 つの値についてはニューラルネットワークの構造や学習の度合いに応じて適切な値が異なるため、本研究ではその都度適切に変化させることによって対処するものとする。

3.2 節では基本の 3 層型エルマンネットの説明を行う。

3.3 節では、3 層型エルマンネットを 4 層型に拡張した手法を提案する。3.4 節では、3.3 節の 4 層型エルマンネットの文脈層を拡張した手法を提案する。

### 3.2 3層型エルマンネット

エルマンネットは時系列パターンを学習する

SRN(Simple recurrent network)[11][12]の一種で、構造が単純かつ比較的高い能力をもつことで知られている。3 層のニューラルネットワークに一時刻前の中間層の値を保持する文脈層を加えた構造となっている。3 層型エルマンネット

の構造を図 1 に示す。ある時刻の出力は、その時刻の入力と 1 時刻前の中間層の状態によって決定される。また 1 時刻前の中間層の状態は、さらに過去の影響を受けている。このためエルマンネットは過去の履歴を考慮した処理を可能にし、時系列パターンの処理に適しているといえる[12]。時刻  $t$  における各層のニューロンの出力値は次式で与えられる。

$$h_j(t) = f \left( \sum_i w_{ij}^l(t) I_i(t) + \sum_i c_i(t) - \theta_j \right)$$

$$o_i(t) = f \left( \sum_j w_{ij}^o h_j(t) - \varphi_i \right)$$

$$c_i(t) = h_i(t-1)$$

$I_i(t)$ ,  $h_i(t)$ ,  $o_i(t)$ ,  $c_i(t)$  はそれぞれ時刻における入力層、中間層、出力層、文脈層のニューロン  $i$  の出力値である。 $w_{ij}^l$  は入力層から中間層、 $w_{ij}^o$  は中間層から出力層への結合荷重を表し、 $\theta_j$ ,  $\varphi_i$  はそれぞれ中間層、出力層のニューロン閾値である。出力関数  $f$  はシグモイド関数

$$f(x) = \frac{1}{(1 + e^{-x})}$$

である。結合荷重の学習にはバックプロパゲーション法を用いる。バックプロパゲーション法では出力値と教師信号の誤差を用いて学習を行う。ネットワークにおける誤差は以下のように定義される。

$$E = \sum_{p=1}^P E_p = \sum_{p=1}^P \left\{ \frac{1}{2} \sum_{i=1}^N (T_{pi} - o_{pi}(t))^2 \right\}$$

$P$  は入力データの数、 $N$  は出力層におけるニューロンの数、 $T_{pi}$  は  $p$  番目の入力データに対する教師データを示す。結合荷重の修正方法は以下の通りである。

$$w_{ij}^{k-1,k}(t+1) = w_{ij}^{k-1,k}(t) + \Delta w_{ij}^{k-1,k}(t)$$

$$\Delta w_{ij}^{k-1,k}(t) = -\eta \frac{\partial E}{\partial w_{ij}^{k-1,k}} + \alpha \Delta w_{ij}^{k-1,k}(t-1)$$

$w_{ij}^{k-1,k}(t)$  は時刻  $t$  における  $k-1$  層のユニット  $i$  から  $k$  層のユニット  $j$  への結合荷重であり、 $\eta$  は学習係数、 $\alpha$  は慣性項の係数を示す。また  $\eta$ ,  $\alpha$  は 0 以上 1 以下の値をとる。

以上のような構造のエルマンネットを拡張させた手法を提案する。

### 3.3 提案手法 1 4層型エルマンネット

3.2 節の 3 層型エルマンネットを拡張した 4 層型エルマンネットについて説明する。エルマンネットの中間層を 2 層に増やしたもので各中間層にはそれぞれ文脈層を持たせる。図 2 に提案手法 1 を示す。入力、出力のユニット数を 1、各中間層と文脈層のユニット数は 10 とした。中間層と文脈層の各ユニットは 1 対 1 対応するものとし、入力層、各中間層、出力層はそれぞれ隣り合った層のユニットと全結合する。学習係数と慣性項は学習時にオンラインで調整する。

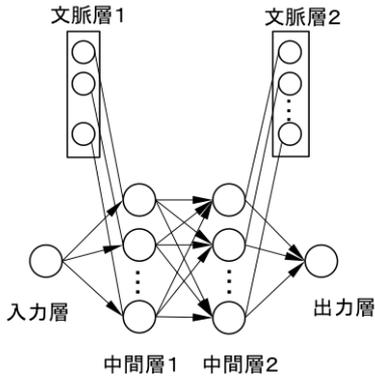


図 2 提案手法 1 の構造

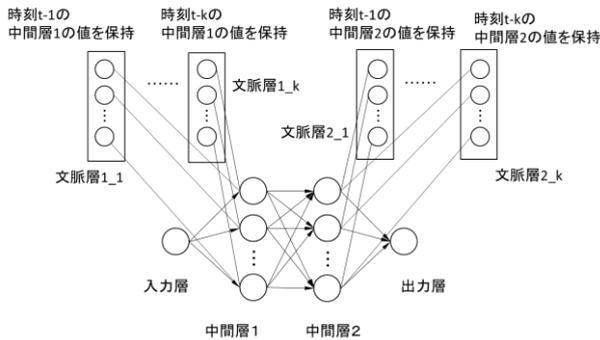


図 3 提案手法 2 の構造

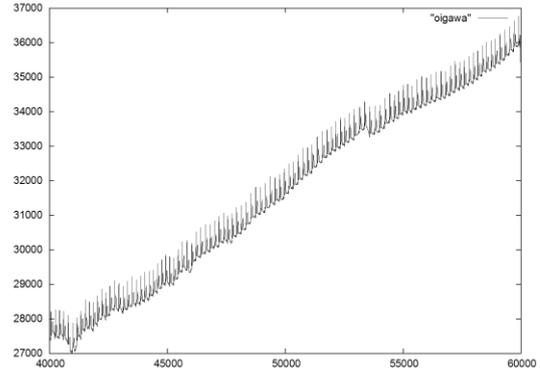


図 4 Enobioで測定したオリジナルの心拍データ

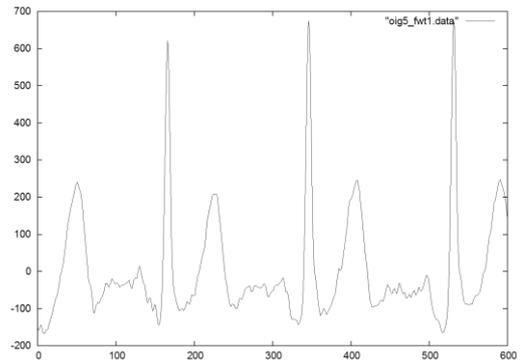


図 5 前処理後のデータ

### 3.4 提案手法 2 文脈層を拡張した 4 層型エルマンネット

提案手法 2 は、提案手法 1 の文脈層の数を増やしたものである。図 3 に提案手法 2 を示す。時系列性をより考慮できるように文脈層の数を増やすこととする。文脈層の層数は扱うデータによって適切な値が違うので、扱うデータに応じて変化させる。文脈層の数を  $k$  とすると一時刻前から  $k$  時刻前までの中間層の値を保持できることになる。中間層  $1_x$  は時刻  $t-x$  の中間層 1 の値を、中間層  $2_x$  は時刻  $t-x$  の中間層 2 の値を保持するものとする。また、文脈層から出力層への結合荷重は、現在の時刻に近い値を保持しているほど、結合荷重も大きくなるものとする。時刻  $t$  での結合荷重を次式で示す。

$$w_{ij}^{c1,x} = \frac{190-x}{17955}, w_{ij}^{c2,x} = \frac{190-x}{17955}$$

$$\sum_{x=1}^k w_{ij}^{c1,x} = 1, \sum_{x=1}^k w_{ij}^{c2,x} = 1$$

文脈層の値は一周期前の文脈層の内部状態と一時刻前の中間層の値の平均をとることとする。時刻  $t$  における文脈層の値を次式で示す。

$$c_i(t) = \frac{c_i(t-189) + o_j(t-1)}{2}$$

学習係数と慣性項は提案手法 1 と同様に学習時にオンライ

ンで調整を行う。

## 4. 実験

### 4.1 実験手法

評価実験において使用するデータ計測機器について説明する。ECG の計測には、EEG, ECG, EOG の 3 種類の生体情報を計測できる Enobio[11]を使用する。サンプリング周波数は 500Hz である。まず、Enobio で計測された ECG から安定した心拍波形を切り出す。被験者は 20 代女性 1 人である。Enobio で測定したオリジナルデータを図 4 に示す。教師データにはノイズが混入しているため、オリジナル信号から安定して計測できている心拍波形を切り出し、ケプストラム法[14]とウェーブレット変換[15]を用いてノイズ除去と正規化を行う。これらの処理により、低周波数に現れる大まかなノイズが除去される。ノイズ除去と正規化した結果の一部を図 5 に示す。

得られたデータは欠損部分のない心拍波形であり、この波形を教師データとする。教師データは心拍波形 1 拍分である 189 点を切り出して使用する。教師データの一部に欠損を与えた学習データを 10 パターン生成する。欠損部分はランダムに設定する。ランダムに選ばれた点は、値を 0 として故意に欠損させる。また、欠損値が補完できているかを確認するためのデータとして、学習データとは別の欠損

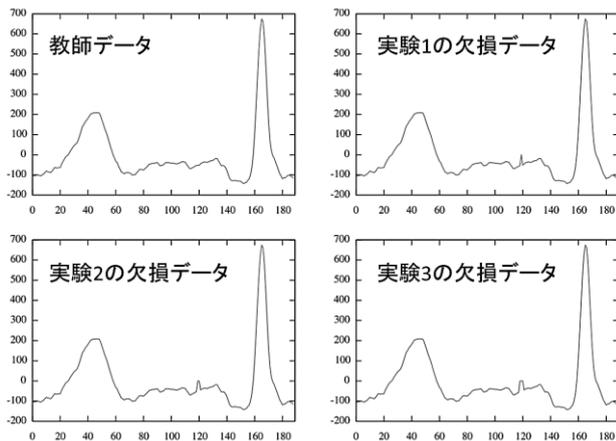


図 6 教師データと欠損データ

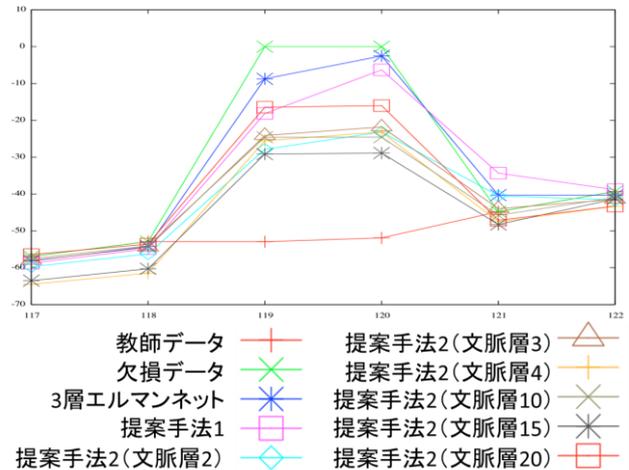


図 8 実験 2 の結果

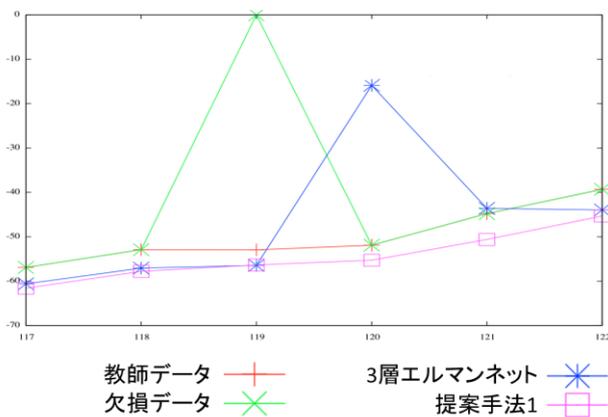


図 7 実験 1 の結果

を与えたデータを用意する。このデータを欠損データとし、欠損データをもとの教師データに補完できれば、学習が成功したといえる。

学習に使用するニューラルネットは、3 章で説明した 3 種類である。基本の 3 層型エルマンネットと提案手法 1, 2 で学習させることで、心拍データの欠損値の補完に有効であるニューラルネットについて調査する。この際、各ニューラルの中間層と文脈層の一層あたりのユニット数は 10 とする。

評価実験として、欠損点数を変化させた 3 種類の検証を行う。まず、実験 1 では、ランダムな 1 点が欠損している入力データ 10 パターンを 3 層型エルマンネットと提案手法 1 により検証する。実験 2 では、ランダムな 2 点が欠損している入力データ 10 パターンを 3 層型エルマンネット、提案手法 1、提案手法 2 の文脈層の数を 2, 3, 4, 10, 15, 20 にした合計 8 種類のエルマンネットで検証する。実験 3 では、ランダムな 3 点が欠損している入力データ 10 パターンを、実験 2 同様の 8 種類のエルマンネットで検証する。教師データと各実験に用いる確認用の欠損データを図 6 に

示す。すべての実験用の欠損データのグラフから、120 点付近で欠損部位が確認される。

#### 4.2 実験結果

まず実験 1 の結果について述べる。実験 1 の学習結果は図 7 の通りである。それぞれ、教師データと確認に用いた欠損データ、各手法を適用した際の出力結果をグラフ化したものである。欠損部分を拡大表示している。教師データと出力データのグラフが一致すれば、欠損値を補完できているといえる。欠損データは教師データから生成されるため、欠損値の 1 点を除いて教師データと一致する。グラフより、3 層型エルマンネットは欠損データをあまり補完しておらず、3 層型エルマンネットにおける心拍データの 1 点の欠損値の補完は不十分だといえる。提案手法 1 では、教師データと出力データは同じような値を取っており、欠損値に着目しても、教師データ同様に滑らかに補完されている。つまり、4 層型エルマンネットを用いた心拍データの 1 点の欠損値の補完は可能であるといえる。

次に実験 2 について述べる。実験 2 の学習結果を図 8 に示す。それぞれの学習回数は 3 層型は約 3000 万回、提案手法 1 は約 1500 万回、提案手法 2 の文脈層 2 層と 3 層の手法では約 600 万回、提案手法 2 の文脈層 4 層では約 500 万回、文脈層が 10 層のものは 300 万回、文脈層が 15 以上のものは約 200 万回であった。またエラー値はそれぞれ 0.1 前後であった。ただし、エラー値は入力データ 10 パターン全てに対する誤差の合計であり、誤差は平均二乗誤差で算出する。まず 3 層型エルマンネットは与えた欠損データとほぼ同様の値を出力しており、欠損を補完できているとはいえない。次に提案手法 1 は、3 層型エルマンネットと比較すると多少教師データに近づいてはいるが、これも欠損を補完できたとは言えない。提案手法 2 の中では、文脈層を 20 層にしたものが最も教師データの値と離れており、文脈層が 15 層のものが一番教師データと近い値をとることが確認できた。しかし、どの手法も欠損を補完できているとは

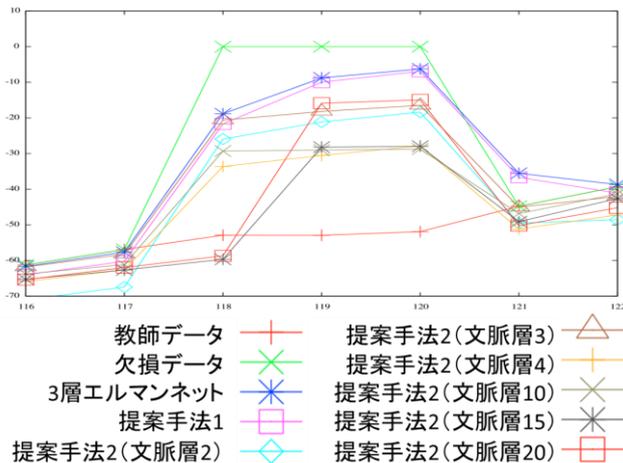


図 9 実験 3 の結果

言い難い結果である。

最後に実験 3 について述べる。実験 3 の学習結果を図 9 に示す。それぞれの学習回数は、3 層型では約 3000 万回、提案手法 1 は約 1500 万回、提案手法 2 の文脈層 2, 3, 4 層に増加させた手法ではそれぞれ約 600 万回、文脈層が 10 層のものは 300 万回、文脈層が 15 以上のものは約 200 万回であった。またエラー値はそれぞれ 0.2 前後であった。3 層型エルマンネットの出力結果が 1 番教師データからは遠く、次に提案手法 2 もほぼ 3 層型の手法と同等の出力結果であった。118 点に着目すると、提案手法 2 の文脈層 15 と文脈層 20 の出力結果は、他の出力と比較して明らかに教師データに近いといえる。しかし、どの手法も欠損を補完できているとはいえない結果であった。

実験 2 と実験 3 において、心拍データの補完が不十分で要因としては、中間層と文脈層のユニット数を 10 に固定して実験を行った事が問題であると考えられる。今後は、中間層と文脈層の数だけでなく、ユニット数も変化させることで、心拍パターンの学習に最適な構造を調査する必要がある。

## 5. おわりに

本稿では、心拍データの欠損値を補完するための、リカレント型ニューラルネットワークを用いた心拍パターンの学習手法の提案を行った。

心拍パターンの学習手法として、エルマンネットを拡張した 2 種類のネットワーク構造を提案し、基本的な 3 層型エルマンネットと、提案手法の計 3 種類を適用して、それぞれ実験を行った。拡張した構造については、エルマンネットの中間層の数を 2 層に増やした 4 層型エルマンネットである提案手法 1 と、提案手法 1 の文脈層の数を拡張した提案手法 2 がある。実験では、心拍データ 1 周期中にランダムに欠損を与えた入力データ 10 パターンを使用して、学習を行った。

実験結果では、欠損点数が 1 点の場合、3 層型エルマンネットでは補完できなかった欠損が、提案手法 1 の 4 層型エルマンネットでは補完された。欠損点数が 2 点、3 点の場合では、文脈層を増加させることで、補完に近づく傾向にはあったが、完全に補完出来ているとは言い難い結果であった。以上の結果から、本稿では、心拍波形の欠損値の補完として、1 点の欠損値の場合のみ、提案手法 1 である 4 層型エルマンネットの有用性を示した。今後の課題は、本研究をもとに中間層や文脈層のユニット数を変化させることで、より心拍に適したニューラルネットの構造を提案することである。

## 参考文献

- 1) 松本佳昭, 森信彰, 三田尻涼, 江鐘偉. (2012). 心拍の揺らぎによる精神的ストレス評価法に関する研究. ライフサポート.
- 2) 参照先: DUMSCO, ストレススキャン:  
<http://www.stress-scan.com>
- 3) 参照先: 株式会社日立システムズ, 疲労・ストレス測定システム: <http://www.hitachi-systems.com/solution/S1301/fses/>
- 4) Real Time Spatiotemporal Biological Stress Level Checking, Marina Uchimura, Yuki Eguchi, Minami Kawasaki, Yoshii Naoko, Tomohiro Umeda, Masami Takata, Kazuki Joe, In Proceedings of 2012 International Conference on Parallel and Distributed Processing Techniques and Applications (PDPTA 2012), II, 744-750 (2012.7)
- 5) NomuraRyoko, UmedaTomohiro, YoshiiNaoko, TakataMasami, JoeKazuki. (2014). Biometrics Authentication using Another Feature of Heart Waveform. BIOSIGNALS 2014 International Conference on Bio-inspired Systems and Signal Processing.
- 6) 福田修, 辻敏夫, 金子真. (1997). ニューラルネットによる時系列脳波パターンの識別. 電子情報通信学会論文誌(D-II).
- 7) 島圭介, 高田大輔, 卜桶, 辻敏夫. (2012). 次元圧縮機能を有するリカレント確率ニューラルネットの提案と時系列脳波パターン識別への応用. 計測自動制御学会.
- 8) M.F. Kelly, P.A. Parker and R.N. Scotto: Neural Network classification of myoelectric signal for prosthesis control, Journal of Electromyography and Kinesiology, 1-4, 229/236/(1991)
- 9) 深谷亮, 松本哲也, 大西昇. (2001). リカレントニューラルネットによる時系列顔表情からの特徴抽出. 信学技情 NC2001-46.
- 10) 渡部修, 早坂美樹. (2009-3). 音声系列の文法的規則獲得における統計学習の役割. 信学技情, NC2008-134.
- 11) Elman, Jeffrey L., "Finding structure in time", Cognitive Science 14, 179-211, (1990)
- 12) Elman, Jeffrey L., "Distributed representations, simple recurrent networks, and grammatical structure", Machine Learning, 7, 195-225, (1991)
- 13) : Starlab Living Science, Enobio: <http://starlab.es/products/enobio>
- 14) Paul S Addison, "The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science Engineering Medicine and Finance," CRC Press, 2002
- 15) D. G. Childers, D. P. Skinner and R. C. Kemerait, The Cepstrum: A Guide to Processing, vol. 65, Proceedings of the IEEE, 1977, pp. 1428-1443.