Ultrasonographic Diagnosis of Cirrhosis Based on Preprocessing Using Pyramid Recurrent Neural Network

Jianming Lu Member (jmlu@faculty.chiba-u.jp)

Jiang Liu Non-member (liujiang@fuji.waseda.jp)

Xueqin Zhao Non-member (zhxq@graduate.chiba-u.jp)

Takashi Yahagi Non-member (yahagi@faculty.chiba-u.jp)

Keywords: pyramid recurrent neural network, discrete wavelet transformed, cirrhosis

In this paper, a pyramid recurrent neural network (PRNN) is applied to characterize the hepatic parenchymal diseases in ultrasonic B-scan texture. A pyramid network is able to exploit the activation functions of low degree hidden layers, while the conventional multilayer network architectures utilize only the activation functions of the last hidden layer to approximate the target function.

The cirrhotic parenchymal diseases are classified into 4 types according to the size of hypoechoic nodular lesions. The B-mode patterns are discrete wavelet transformed (DWT), and then the compressed data are feed into a pyramid recurrent neural network to diagnose the type of cirrhotic diseases. Simulation result shows that the proposed system is suitable for diagnosis of cirrhosis diseases.

The proposed diagnosis system using PRNN and DWT in this paper is shown in Fig. 1 and Fig. 2 respectively.

Fig. 1. PRNN

Fig. 2. The diagnosis system using PRNN and DWT

The diagnosis results using PRNN and DWT is shown in Table 1.

Compared with the 3-layer neural networks, the performance of the proposed pyramid recurrent neural network is improved by utilizing the lower layer effectively.

Table 1. Diagnosis results using PRNN and DWT

Type	Type 0	Type I	Type II	Type III	Accuracy
Type 0	25	4	1	1	86.2 %
Type I	24	96	14	5	69.1 %
Type II	2	3	31	8	70.5 %
Type III	0	1	2	10	76.9 %

ピラミッド型リカレントニューラルネットワークを用いた 超音波断層像による肝硬変の病状診断

正員 呂 建明* 非会員 劉 江**
非会員 趙 雪琴* 非会員 谷萩 隆嗣*

Ultrasonographic Diagnosis of Cirrhosis Based on Preprocessing Using Pyramid Recurrent Neural Network

Jianming Lu*, Member, Jiang Liu**, Non-member, Xueqin Zhao*, Non-member,
Takashi Yahagi*, Non-member

In this paper, a pyramid recurrent neural network is applied to characterize the hepatic parenchymal diseases in ultrasonic B-scan texture. The cirrhotic parenchymal diseases are classified into 4 types according to the size of hypoechoic nodular lesions. The B-mode patterns are wavelet transformed, and then the compressed data are feed into a pyramid neural network to diagnose the type of cirrhotic diseases. Compared with the 3-layer neural networks, the performance of the proposed pyramid recurrent neural network is improved by utilizing the lower layer effectively. The simulation result shows that the proposed system is suitable for diagnosis of cirrhosis diseases.

キーワード：ピラミッドリカレントニューラルネットワーク，離散ウェーブレット変換，肝硬変

Keywords: pyramid recurrent neural network, discrete wavelet transformed, cirrhosis

1. はじめに

現在の医療分野の臨床診断では，高解像，高速処理可能な医用超音波診断装置が普及している⁽¹⁾。旧来のは，超音波を生体に照射して生体内より得られる反射波をグラフ化するもので，イメージを捉えづらいものだったが，これを2次元画像化することで直観的な扱いやすいものとなった。現在ではこの画像を用いた診断というのは非常にポピュラーなものとなっており，価格も下がり開業医などでも目にする事ができる。

さらに近年においては，超音波診断装置の機能は多岐にわたっており，たとえば，現在一般的に普及している装置では，ドプラ効果を利用したカラー情報としての血流観測や，3次元表示機能による視覚的認識効果の向上などが可能となっている。また，装置自体のデジタル化が進み，高精度のビーム制御が可能となり，ダイナミックレンジの向上から非線形波動による画像化なども実用化されてきている。

また同時に，超音波造影剤が普及し実際の臨床現場で用いられるようになり，既存の装置で微小血流検出できるなど，各種の診断における超音波診断装置の重要性は高まってきている。

本研究の対象である肝疾患の診断においては，前述のような診断装置の進歩に伴い，肝表面，肝実質および病変部位などの観測や血流の詳細な把握が可能となり，その有効性は飛躍的に向上している。しかし現状では，消化器分野の臨床診断は，超音波診断装置のモニタ上に表示される断層画像（Bモード画像）を専門医が観察することで診断するという‘医師の経験’，‘画像読み取り技術’に強く依存した定性的な診断の段階にとどまっており，超音波を用いての非観血，無侵襲な組織病変の質的評価を実現することが強く望まれている。

肝臓病変を定量的に診断しようという試みは，これまでに医学および工学のそれぞれの立場から複数の研究が進められている。その例として，硬変した肝臓のBモード画像中に見られる低エコーパターンのサイズを元に，病変の進行度を分類しようという試み（木村分類法⁽²⁾）がある。これは，肝硬変の特徴である結節からのエコーが低輝度で表示されるという前提の基に考えられた手法であるが，分類が目視によって行われる，再現性が低いなど，客観的・定量的評価には不十分であるといえる

* 千葉大学大学院自然科学研究科

〒 263-8522 千葉県千葉市稲毛区弥生町 1-33

Graduate School of Science and Technology, Chiba University
1-33 Yayoi-cho Inage-ku Chiba, 263-8522

** 早稲田大学大学院国際情報通信研究科

Graduate School of Global Information and Telecommunication Studies, Waseda University

また、工学系の研究として、Bモード画像のテクスチャ解析⁽³⁾、フラクタル解析⁽⁴⁾など画像の特徴量を用いた定量化の検討も行われている。しかし、既に述べたように医師の経験や勘といったパラメータは数値化解析するのは極めて困難であり、またそれにかかる時間も膨大なものとなることが容易に想像でき現実的ではない。

そこで本研究では、ある程度適切な学習方法さえあればブラックボックスとして扱ってよく、学習データについて構造的な、あるいはアルゴリズム的な分析を要さない手法としてニューラルネットワーク (NN: Neural Network) を使用したシステムを開発する。実際に临床上でも利用され、その有効性があることが実証されている⁽⁵⁾。最近では、着目領域の拡大、各パラメータの差違による特性なども検討され、その能力も改善されてきている。文献(6)では、著者らは領域拡大に伴う計算量の増加の軽減のために、前処理に離散コサイン変換 (DCT: Discrete Cosine Transform) を行い特徴量を減らし、その結果 DCT の適用が計算量を軽減し、且つ診断への影響が良好であったことを示した。しかし、この方法では計算が単純なために処理速度は速いが、進行度の低い I 型が正常である 0 型、またはより進行度の高い II 型へと誤診される可能性が高かった。そこで文献(7)では前処理として、局在的な数値の変動に対応できるという点で画像圧縮に優れているウェーブレット変換 (DWT: Discrete Wavelet Transform) を前処理に用いた超音波診断システムを提案する。DWT は高周波成分を含ませることで、画像の緩い濃淡の変化を残し、より原画像に近い形に圧縮が行えるので、診断能力が向上できると考えられる。

本論文では、ピラミッド型リカレントニューラルネットワーク (PRNN: Pyramid Recurrent Neural Network) を用いた超音波画像診断システムを提案する。従来の階層型ネットワークは構成が単純で、ネットワークの規模を大きくすると表現能力を高めることができるが、逆に汎化能力は劣化してしまい、超音波画像診断システムにおいて、診断精度は低いものとなっていた。出力層直前の層だけでなく、すべての層を有効に活用することで汎化能力、表現能力をともに向上させたピラミッド型リカレントニューラルネットワークを超音波画像診断システムに用いることで、システムの診断精度を向上させる。シミュレーション結果より、本提案システムは、従来の前処理に DCT を行った階層型 NN を用いたシステムに比べて全ての型において診断精度が向上し、より正確に診断できることを示す。

2. ニューラルネットワークを用いた診断システム

超音波診断装置では、生体内において音響特性の異なる組織が散乱体となり、探触子より照射された音波が反射される。診断に使用されている超音波断層画像 (B モード画像) は、これらの受信信号を輝度変調して画像化したものであるが、画像は散乱体の分布構造によって大きく変化する。現在の臨床診断では、病変の進行に伴う画像変化を目視で確認することが主流となっている、しかし生体の組織

図 1 システム構成

Fig. 1. System components

図 2 NN を利用した診断システム

Fig. 2. The diagnosis system using NN

構造と B モード画像との関係についてはまだ十分な解析がなされていない。すなわち、病変進行によって画像変化が起こることは経験的に知られているが、それが組織中のどのような構造を反映しているのかという点が明らかとなっていない。

そのため、画像の診断は医師の経験に基づいて行われ、そこには個人差による診断の差が生じてしまった。そこで、この個人差を薄めるための定量的診断を行うため、画像を NN で処理することで解決するという提案がされた⁽⁵⁾。

NN とは脳が行っている情報処理を計算機で実現しようというもので、神経細胞をあらわすニューロンを相互に結合させて、目的に合った入出力関係を得るものである。

〈2・1〉システムの概要 図 1 に本システムの基本構成を示す。図 2 に文献(5)で提案されたシステムの構成を示す。文献(5)では、NN の構成は階層型 NN、バックプロパゲーション (BP: Back Propagation) 方式を使用した。階層型 NN とは、入力信号を出力に向かって 1 方向に流していく構造の NN のことを言う。入力層は超音波断層像からディスプレイ画面上で関心領域 16×16 の画像を切り出したものを使用した。入力ベクトルを S とし、出力ベクトルを R とする。入力層と中間層の間の重みベクトル (行列) を W とし、中間層と出力層の間の重みベクトルを V とする。各要素は以下の通りである。

$$\mathbf{S} = [s_1, s_2, s_3, \dots, s_{256}]^T \dots\dots\dots (1)$$

$$\mathbf{R} = [r_1, r_2, r_3, r_4]^T \dots\dots\dots (2)$$

$$\mathbf{W} = [w_1, w_2, w_3, \dots, w_{128}]^T \dots\dots\dots (3)$$

$$\mathbf{w}_k = [w_{k1}, w_{k2}, w_{k3}, \dots, w_{k64}]^T \dots\dots\dots (4)$$

$$k = 1, 2, 3, \dots, 128 \dots\dots\dots (5)$$

$$\mathbf{V} = [v_1, v_2, v_3, v_4]^T \dots\dots\dots (6)$$

$$\mathbf{v}_m = [v_{m1}, v_{m2}, v_{m3}, \dots, v_{m128}]^T \dots\dots\dots (7)$$

$$m = 1, 2, 3, 4 \dots\dots\dots (8)$$

但し、 T は転置を表す。

BP 方式はパーセプトロンの学習則を拡張したもので、入力パターンに対する NN の実際の出力パターンと、教師信号として与えられる望ましい出力パターンとの 2 乗誤差を減らすように、シナプス間の結合荷重を調節する。以下に NN の順方向アルゴリズムを示す。

BP 学習則による NN の順方向処理:

$$\text{中間層: } u_j = f(\sum w_{ji}x_i) \dots\dots\dots (9)$$

$$\text{出力層: } u_r = f(\sum w_{rk}x_k) \dots\dots\dots (10)$$

$$\text{シグモイド関数: } f(\sum) = \frac{1}{[1 + \exp(-\sum)]} \dots\dots\dots (11)$$

出力層で得られた結果 $y_1, y_2, \dots, y_M$ は外部から与えられる教師信号 $d_1, d_2, \dots, d_M$ と比較され、誤差 δ が算出される。以下に誤差 δ の計算式を示す。

$$\delta_r = d_r - y_r \dots\dots\dots (12)$$

誤差に基づいて中間層と出力層間の結合荷重 $w_{rk}(t+1)$ は変更される。入力層と中間層間の結合荷重を変更するときには出力側の δ_r の荷重和を求めて修正量を決定する。以下に、学習係数を η としたときの、BP 学習則による結合荷重の変更アルゴリズムを示す。

結合荷重の変更アルゴリズム:

$$\Delta v_{rj}(t+1) = \eta_r \delta_r f'(u_r) u_j \dots\dots\dots (13)$$

$$v_{rj}(t+1) = v_{rj}(t) + \Delta v_{rj}(t+1) \dots\dots\dots (14)$$

$$\Delta w_{ji}(t+1) = \eta_j \delta_j f'(u_j) s_k \dots\dots\dots (15)$$

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t+1) \dots\dots\dots (16)$$

$$\delta_j = \sum_{r=1}^4 \delta_r v_{rj} \dots\dots\dots (17)$$

〈2・2〉 問 題 点 病状診断の際に NN を利用したシステムは、パターン識別を肝硬変の病状診断に用いたという点では、その有効性を示すことはできた。しかし、診断性能をより高めるために関心領域を拡大する必要がある、それに伴い NN の計算量が増加する。その結果、学習や診断に時間がかかり実用的な速度を保持できなくなるといった問題が発生した。

3. ウェーブレット変換を前処理に用いた診断システム

第 2 章の問題点の解決方法の一つとして、本論文では、前処理にウェーブレット変換を利用して入力画像を圧縮し、計算量を減少させる方法を提案する。

〈3・1〉 ウェーブレット変換 ウェーブレット自体にはいくつもの関数が存在するが、無限区間の両端が 0 に収束する性質を持った波である。図 3 にその 1 例を示す⁽⁸⁾。

変換を行う際は、関数 $f(x)$ に対し図 3 のようなウェーブレット (マザーウェーブレットという) $\psi(x)$ を b 平行移動、 a 伸縮したものを無限に重ね合わせることになる。ウェーブレット変換と逆ウェーブレット変換の式を以下に示す。

$$(W_\psi f)(b, a) = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{|a|}} \psi\left(\frac{x-b}{a}\right) f(x) dx \dots\dots\dots (18)$$

$$f(x) = \frac{1}{C_\psi} \int \int_{R^2} (W_\psi f)(b, a) \frac{1}{\sqrt{|a|}} \psi\left(\frac{x-b}{a}\right) \frac{dad b}{a^2} \dots\dots\dots (19)$$

なお、逆変換の右边が定義できるためには、以下の条件を満たす必要がある。

$$\int_{-\infty}^{+\infty} \psi(x) dx = 0 \dots\dots\dots (20)$$

画像処理の場合はウェーブレット変換は離散化して使われる。ウェーブレットの座標 $(b, 1/a)$ を 2 つの整数 j, k によって $(b, 1/a) = (2^{-j}k, 2^{-j})$ と置き、ウェーブレット変換 $(W_\psi f)(2^{-j}k, 2^{-j})$ を $d_k^{(j)}$ と書くと以下のように書き換えられる。

$$d_k^{(j)} = 2^j \int_{-\infty}^{+\infty} \overline{\psi(2^j x - k)} f(x) dx \dots\dots\dots (21)$$

$$f(x) = \sum_j \sum_k d_k^{(j)} \psi(2^j x - k) \dots\dots\dots (22)$$

ここで逆変換が成り立つためには $\psi(x)$ が基底関数を作ることができなければならない。そこでスケーリング関数 $\phi(x)$

図 3 ウェーブレットの 1 例

Fig. 3. One example of wavelet

図 4 ウェーブレット変換を利用した診断システム

Fig. 4. The diagnosis system using wavelet transformed

図 5 原画像

Fig. 5. Original image

というものをを用意する。これは与えられた数列 p_k に対してトゥー・スケール関係と呼ばれる関係式

$$\phi(x) = \sum_k p_k \phi(2x - k) \dots \dots \dots (23)$$

を満たす関数である。レベル j を固定してすべての整数 k についての $\psi(2^j x - k)$ が張る空間を V_j とおく。するとトゥー・スケール関係から $V_j \subset V_{j+1}$ が導かれる。スケーリング関数を使ってマザーウェーブレットを

$$\psi(x) = \sum_k q_k \phi(2x - k) \dots \dots \dots (24)$$

と定義でき、このマザーウェーブレットは補空間 $W_0 = V_1 \setminus V_0$ の基底関数となることが示される。ここまでは 1 次元関数についての説明であるが、2 次元関数である画像情報に対して変換を行う際は、縦方向、横方向に対し、それぞれ 1 次元情報として独立に変換することで実現される。

〈3・2〉 システムの概要 図 4 にウェーブレット変換を前処理に用いたシステムの構成を示す。使用するウェーブレットとしては、Daubechies(DB) ウェーブレットを用いる⁽⁸⁾。DB ウェーブレットはウェーブレット変換による画像圧縮にはよく使われているものであり、高速アルゴリズムに適しているからである。高速アルゴリズムは、本来なら変換を行う各レベル j ごとに数列 $\{p_k\}$ からスケーリング関数 $\phi(x)$ を計算し、それを元にレベル 0 の離散数列

(a) DCT で圧縮した画像

(b) 一部拡大

図 6 DCT で圧縮した画像

Fig. 6. Compressed image by DCT

(a) DWT で圧縮した画像

(b) 一部拡大

図 7 DWT で圧縮した画像

Fig. 7. Compressed image by DWT

を作ることを、入力信号をそのまま離散数列として使用することにより、計算量を大幅に削減するものである。この近似は信号のデータ圧縮、あるいは画像処理への応用においては問題ないことが知られている。

ウェーブレット変換を前処理に用いることで、画像を圧縮でき、PRNNの入力層のニューロン数を減少でき、PRNNの入力層のニューロン数を減少すれば、NNの学習時間や診断時間を短縮することができると考えられる。また、文献(6),(7)の方法の診断精度を更に向上するために、本論文では、汎化能力、表現能力が高いピラミッド型リカレントニューラルネットワークを用いるシステムを提案する。

〈3・3〉 DCTとDWTの圧縮精度 図5に原画像を示す。図6(a)にDCTで圧縮した画像、図6(b)にその一部を拡大した画像、図7(a)にウェーブレット変換で圧縮した画像、図7(b)にその一部を拡大した画像を示す。図5, 図6(a), 図7(a)を見ると、DCTで圧縮を行ったものは画像の緩い濃淡の変化が起こっている個所を潰してしまっているが、ウェーブレット変換で圧縮を行ったものはその変化を残し、より原画像に近い形への圧縮が行われている。2つの違いは図6(b), 図7(b)を見ればより顕著にわかる。また、DCTの画像で生じたモスキート歪みがウェーブレット変換の画像では生じないことがよく知られている。本論文でウェーブレット変換を用いたのは、このように、より鮮明な画像を使用する事が、診断能力の向上にもつながると考えたためである。

4. 提案システム

第3章で述べたように、階層型NNを用いた診断システムの診断精度は低いものとなっていた。そこで本研究では低次の層を有効に活用することで汎化能力、表現能力を向上させたピラミッド型リカレントニューラルネットワーク⁽⁹⁾⁽¹⁰⁾を用いた超音波画像診断システムを提案する。

〈4・1〉 ピラミッド型リカレントネットワーク ピラミッド型ネットワークとは、従来の階層型NNの入力層と中間層からなる基底層、出力層という2つの部分から構成されたネットワークである。図8にピラミッド型リカレントニューラルネットワークの構成を示す。

基底層の l 層($l \geq 1$)のユニット j において、その出力値 o_j^l は

$$o_j^l = f_j^l(o^{l-1}, w_j^l) \dots\dots\dots (25)$$

$$o_j^l = o_j^{l-1} + d o_j^{l-2} \dots\dots\dots (26)$$

と定義される。ここで、 f_j^l はユニット j の活性化関数、 w_j^l は f_j^l の可変内部パラメータベクトル、 d は忘却係数であり、 $0 \leq d \leq 1$ の値をとる。また、出力層のユニット k の出力値 y_k は

$$y_k = f_k(a_{kj}^l, o_j^l) \dots\dots\dots (27)$$

と定義される。ここで、 a_{kj}^l は基底層の l 層のユニット j と出力層のユニット k との間の結合荷重、 f_k は出力層のユニットにおける活性化関数である。また、0層(入力層)の出力値 o_j^0 は

$$o_j^0 = x_j \dots\dots\dots (28)$$

図8 PRNN
Fig. 8. PRNN

図9 PRNNとDWTを利用した診断システム
Fig. 9. The diagnosis system using PRNN and DWT

である。ただし、 x_j は0層のユニット j への入力である。

このようにピラミッド型リカレントニューラルネットワークは、基底層の各ユニットから直接出力層に向かう結合が存在することにより、出力は出力層直前の層のみならず、すべての層を有効に活用することができ、ネットワークの汎化性能、表現能力が向上する⁽⁹⁾。

〈4・2〉 提案法 図9にPRNNとDWTを用いた診断システムの構成を示す。診断システムには超音波断層像からディスプレイ上で 16×16 の画像を切り出したものを入力する。超音波断層像においては専門の医師により疾患の進行度に応じて0型(結節性エコー病変が認められない), I型(非結節性, 結節の大きさが3mm未満), II型(細結節性, 結節の大きさが3mm以上, 5mm未満), III型(粗結節性, 結節の大きさが5mm以上)の4種類に分類されている。図10に各型でのBモード肝画像の一例を示す。切り出した画像に対し、DWTで画素数 8×8 まで圧縮し、それをPRNNに入力する。PRNNのユニット数は入力層64, 中間層は2層でそれぞれ100, 出力層4とする。入力層, 中間層のシグモイド関数は

$$f(x) = \frac{1}{1 + \exp(-2x)} \dots\dots\dots (29)$$

とし、出力層のシグモイド関数は

図 10 各型での B モード画像の一例

Fig. 10. 4 types of B-scan image

$$f(x) = \frac{1}{1 + \exp(-0.01x)} \quad \dots\dots\dots (30)$$

とする。学習方法は BP 法を拡張したものを用いた。出力層では 4 つの数値が出力として現れる。この数値は各型への類似度となっており、出力層に対し I 型なら (0100) と教師信号を与えて学習を行う。診断の際は 4 つの出力値のなかでもっとも大きいものを選択し、その出力値に対応する型を診断結果とする。また、図 9 では入力ベクトルを $\mathbf{S}$ 、出力ベクトルを $\mathbf{R}$ 、入力層と第 1 中間層の間の重みベクトルを $\mathbf{W}$ 、第 1 中間層と第 2 中間層の間の重みベクトルを $\mathbf{V}$ 、入力層、第 1、第 2 中間層と出力層の間の重みベクトルを $\mathbf{A}$ とし、各要素を以下のようにする。

$$\mathbf{S} = [s_1, s_2, s_3, \dots, s_{64}]^T \quad \dots\dots\dots (31)$$

$$\mathbf{R} = [r_1, r_2, r_3, r_4]^T \quad \dots\dots\dots (32)$$

$$\mathbf{W} = [w_1, w_2, w_3, \dots, w_{100}]^T \quad \dots\dots\dots (33)$$

$$\mathbf{w}_n = [w_{n1}, w_{n2}, w_{n3}, \dots, w_{n64}]^T \quad \dots\dots\dots (34)$$

$$n = 1, 2, 3, \dots, 100 \quad \dots\dots\dots (35)$$

$$\mathbf{V} = [v_1, v_2, v_3, \dots, v_{100}]^T \quad \dots\dots\dots (36)$$

$$\mathbf{v}_m = [v_{m1}, v_{m2}, v_{m3}, \dots, v_{m100}]^T \quad \dots\dots\dots (37)$$

$$m = 1, 2, 3, \dots, 100 \quad \dots\dots\dots (38)$$

$$\mathbf{A} = [a_{kj}^l]^T \quad \dots\dots\dots (39)$$

$$l = 0, 1, 2 \quad \dots\dots\dots (40)$$

$$k = 1, 2, 3, 4 \quad \dots\dots\dots (41)$$

$$j = \begin{cases} 1, 2, 3, \dots, 64 & l = 0 \\ 1, 2, 3, \dots, 100 & l = 1, 2 \end{cases} \quad \dots\dots\dots (42)$$

但し、 T は転置を表す。

PRNN の学習アルゴリズム：

各層の出力は

$$\text{入力層：} o_j^0 = x_j \quad \dots\dots\dots (43)$$

$$\text{中間層：} o_j^l = f_j^l(\mathbf{o}^{l-1}, \mathbf{w}_j^l) \quad \dots\dots\dots (44)$$

$$o_j^l = o_j^{l-1} + d o_j^{l-2} \quad \dots\dots\dots (45)$$

$$\text{出力層：} y_k = f(a_{kj}^l, o_j^l) \quad \dots\dots\dots (46)$$

$$\text{シグモイド関数：} f\left(\sum\right) = \frac{1}{[1 + \exp(-\sum)]} \quad \dots\dots\dots (47)$$

となる。出力層で得られた結果 y_1, y_2, y_3, y_4 は外部から与えられる教師信号 d_1, d_2, d_3, d_4 と比較され、この 2 つから誤差 E が算出される。以下に誤差 E の計算式を示す。

$$E_r = \frac{1}{2} \|\mathbf{d}_r - \mathbf{y}_r\|^2 \quad \dots\dots\dots (48)$$

誤差 E に基づいて結合荷重 a_k^l, w_j^l は変更される。以下に、学習係数を η としたときの、BP 学習則による結合加重の変更アルゴリズムを示す。

$$\mathbf{a}_k^l(n+1) = \mathbf{a}_k^l(n) + \Delta \mathbf{a}_k^l \quad (0 \leq l \leq 3) \quad \dots\dots\dots (49)$$

$$\mathbf{w}_j^l(n+1) = \mathbf{w}_j^l(n) + \Delta \mathbf{w}_j^l \quad (0 < l \leq 3) \quad \dots\dots\dots (50)$$

更新量 $\Delta \mathbf{a}_k^l, \Delta \mathbf{w}_j^l$ はそれぞれ、

$$\begin{aligned} \Delta \mathbf{a}_k^l &= -\eta \frac{\partial E}{\partial \mathbf{a}_k^l} \\ &= \eta \delta_k \mathbf{o}^l \quad \dots\dots\dots (51) \end{aligned}$$

$$\begin{aligned} \Delta \mathbf{w}_k^l &= -\eta \frac{\partial E}{\partial \mathbf{w}_k^l} \\ &= \eta \delta_{kj}^l \mathbf{o}^l \quad \dots\dots\dots (52) \end{aligned}$$

となる。ここで、 δ_k は

$$\delta_k = (\mathbf{d}_r - \mathbf{y}_r) f' \quad \dots\dots\dots (53)$$

である。また、 δ_{kj}^l はまず、 $l = 2$ のユニット j において、

$$\delta_{kj}^l = \left(\sum_k \delta_k \mathbf{a}_{kj}^l \right) f' \quad \dots\dots\dots (54)$$

さらに、 $l = 0, 1$ のユニット j において、

$$\delta_{kj}^l = \left(\sum_k \delta_k \mathbf{a}_{kj}^l \right) \left(\sum_j \delta_{kj}^2 \mathbf{w}_j^2 \right) f' \quad \dots\dots\dots (55)$$

となる。

5. シミュレーション

第 4 章で提案した診断システムについて超音波断層像を用いた診断を行い、その有効性を示す。

〈5・1〉 シミュレーション条件 PRNN の学習は、医

師の選んだ信頼性の高い画像各型 3 枚計 12 枚の画像から関心領域をそれぞれ 10 点ずつ抽出し、計 120 枚の画像を学習画像として 10 万回学習させる。学習の際、各型の画像を順番に読み込み、120 枚読み込んだものを 1 回として数える。これは同じ型の画像を連続で学習させることにより 1 つの型へ重みが偏るのを防ぐためである。

学習を終えた PRNN に対して学習画像とは別に、医師の診断結果のある画像を未知の画像として入力し、その結果を統計処理する。ここで用いる未知の超音波画像は 0 型 29 枚、I 型 139 枚、II 型 44 枚、III 型 13 枚とする。

処理方法として、各型の画像 1 枚から 10 箇所抽出し、それぞれ PRNN に入力する。各型に対応した出力のうち最も値の大きいものを入力画像の診断結果とし、10 枚の結果から多数決で選ばれたものを最終的な診断結果とする。本論文の多数決は、10 枚の診断結果のうち 6 枚以上が同じ結果となった場合、多数決によって 6 枚以上の結果を出した型を診断結果とする。ただし、III 型と診断したものが 1 つでもある場合、III 型の肝硬変であると診断する。これは 0～III 型のうち III 型が最も重要だからである。しかし、10 枚の診断結果のうち 6 枚以上が同じ結果となった場合、III 型と診断したものがあっても、多数決によって 6 枚以上の結果を出した型を診断結果とする。入力した画像に対して正しい診断結果を出力した割合を診断精度として従来システム、提案システムについて比較する。

6. シミュレーション結果

表 1 に従来の階層型 NN と DCT を利用した診断システムの出力結果、表 2 に従来の階層型 NN と DWT を利用した診断システムの出力結果、表 3 に PRNN と DCT を利用した診断システムの出力結果、表 4 に PRNN と DWT を利用した診断システムの出力結果を示す。表 1～表 4 から、本提案手法は従来手法に比べて診断の精度が高くなっていることがわかる。表 1～表 4 より、提案手法は各型において従来手法より診断精度が向上している。特に 0 型、I 型において診断精度が大きく向上したことがわかる。また、表 1～表 4 の正診率より本提案法も従来法より有効であることがわかる。但し、正診率 = $100 \times (\text{同じ型の正解枚数}) / (\text{同じ型の全枚数})$ とする。

7. 考 察

これらの結果は階層型ネットワークの変わりにピラミッド型リカレントニューラルネットワークを用いることにより、汎化能力、表現能力が向上し、学習の能率が上がったため、診断精度の向上に繋がったと考えられる。また、DCT に代わって DWT を用いることで、DCT を行った場合に生じたモスキート歪みを生じさせず、また、高周波成分を含ませることで、画像の緩い濃淡の変化を残し、より原画像に近い形に圧縮が行える。従って、診断能力が向上できると考えられる。シミュレーション結果より、本提案法は各型ともに向上しており、従来のシステムに比べて、より

表 1 NN と DCT を用いた場合の出力結果

Table 1. Diagnosis results using NN and DCT

型	0 型と診断	I 型と診断	II 型と診断	III 型と診断	正診率
0 型	6	5	2	16	20.7 %
I 型	52	40	13	34	28.8 %
II 型	11	9	13	11	29.5 %
III 型	5	2	0	6	46.2 %

表 2 NN と DWT を用いた場合の出力結果

Table 2. Diagnosis results using NN and DWT

型	0 型と診断	I 型と診断	II 型と診断	III 型と診断	正診率
0 型	19	9	2	1	65.5 %
I 型	37	66	23	13	47.8 %
II 型	6	10	19	9	43.2 %
III 型	1	3	2	7	53.8 %

表 3 PRNN と DCT を用いた場合の出力結果

Table 3. Diagnosis results using PRNN and DCT

型	0 型と診断	I 型と診断	II 型と診断	III 型と診断	正診率
0 型	11	10	3	5	37.9 %
I 型	40	60	32	7	43.2 %
II 型	6	8	20	10	45.5 %
III 型	1	2	2	8	61.5 %

表 4 PRNN と DWT を用いた場合の出力結果

Table 4. Diagnosis results using PRNN and DWT

型	0 型と診断	I 型と診断	II 型と診断	III 型と診断	正診率
0 型	25	4	1	1	86.2 %
I 型	24	96	14	5	69.1 %
II 型	2	3	31	8	70.5 %
III 型	0	1	2	10	76.9 %

正確な診断が可能になると考えられる。

8. おわりに

本研究では、PRNN と DWT を用いた超音波画像診断システムを提案した。従来の階層型ネットワークは構成が単純で、ネットワークの規模を大きくすると表現能力を高めることができるが、逆に汎化能力は劣化してしまい、超音波画像診断システムにおいて、診断精度は低いものとなっていた。出力層直前の層だけでなく、すべての層を有効に活用することで汎化能力、表現能力をともに向上させた PRNN を超音波画像診断システムに用いることで、システムの診断精度が向上した。シミュレーション結果より、提案システムは従来の階層型 NN を用いたシステムに比べて全ての型において診断精度が向上し、より正確に診断できることを示した。診断結果に対して感度と特異度などの指標を用いて数値的に評価することを今後の検討課題としたい。また実用化を目指して更なる高精度の診断システムを提案するの今後の検討課題としたい。

(平成 17 年 4 月 5 日受付, 平成 19 年 4 月 13 日再受付)

文 献

- (1) 岡部哲夫・瓜谷富三:「医用画像工学」, 医歯薬出版株式会社
T. Okabe and T. Uritani: "Medical Imaging Systems", Ishigaku Publishers. INC
- (2) 木村隆生・江原正明・大藤正雄・近藤福雄:「肝実質所見に基づく肝硬変の超音波分類とその臨床的有用性」, 日本消化器病学会雑誌, Vol.86, No.7, pp.61-73 (1989)
- (3) 谷口信行・伊東紘一・川井夫規子・中村みちる・尾本きよか・坂入順子・横田京子・矢田 宏:「同時生起行列によるテクスチャー解析を用いた超音波像の検討」, 日本超音波医学会研究発表会抄録集, p.260 (1995)
- (4) C. Mich ele and G. Sylviane: "A histological semiquantitative scoring system for evaluation of hepatic fibrosis in needle liver biopsy specimens: Comparison with morphometric studies", *Hepatology*, Vol.20, No.2, pp.349-355 (1994)
- (5) 福田浩之・江原正明・大藤正雄・吉野進也・谷萩隆嗣・小林 暁:「慢性肝炎, 肝硬変における Neral Network による超音波肝実質パターンの評価とその臨床的有用性に関する研究」, 日本画像医学雑誌, Vol.14, No.1, pp.39-48 (1995)
- (6) A. Kobayashi, S. Watanabe, M. Ebara, J. Lu, and T. Yahagi: "Ultrasonographic Diagnosis of Cirrhosis Based on Preprocessing Using DCT", *IEICE Trans. Fundamentals*, Vol.E86-A, No.4, pp.968-971 (2003)
- (7) Y. Sun, J. Lu, and T. Yahagi: "Classification of Cirrhosis From B-Scan Images Using Discrete Wavelet Transform", *International Journal of Computational Intelligence and Applications*, Vol.5, No.4, pp.457-470 (2005)
- (8) 中野宏毅・山本鎮男・吉田靖男:「ウェーブレットによる信号処理と画像処理」, 共立出版株式会社 (1999)
- (9) 星野美保・趙 晋輝:「多層 RBF ネットワークとピラミッド型ネットワークによる階層型ネットワークの表現力および汎化性」, 第 16 回デジタル信号処理シンポジウム講演論文集, pp.613-618 (2002)
- (10) S. Haykin: *Neural Networks*, Prentice Hall (1999)

呂 建 明 (正員) 1993 年千葉大大学院自然科学研究科生産科学専攻(博士課程)修了。工博。同年千葉大・工・情報・助手, 1994 年同大学院自然科学研究科・助手。1998 年同大学院自然科学研究科・助教授。現在, 適応デジタルフィルタ, 適応デジタル信号処理, デジタル画像処理, パターン認識, デジタル音声信号処理, デジタル通信, デジタル制御, システムの推定理論, ニューラルネットワークの理論と応用などの研究に従事。電子情報通信学会, 計測自動制御学会, 日本機械学会, 信号処理研究会各会員。

劉 江 (非会員) 2001 年中国重慶工学院電子工学学部応用電子技術専攻卒業。2001 年千葉大学大学院自然科学研究科研究生に入学。2006 年早稲田大学大学院国際情報通信学科修士課程修了。現在, 同大学院博士課程在学中。無線通信, 画像処理, 画像圧縮の研究に従事。

趙 雪 琴 (非会員) 1991 年中国海洋大学情報システム専攻卒業。2004 年 3 月千葉大学大学院自然科学研究科知能情報専攻(修士課程)修了。同年 4 月同大学大学院情報科学専攻博士課程に進学, 現在に至る。適応デジタルフィルタ, 画像処理, 画像圧縮などの研究に従事。

谷 萩 隆 嗣 (非会員) 1966 年東工大・理工・電子卒業。1971 年同大学院理工学研究科電子工学専攻(博士課程)修了。工博。1971 年千葉大・工・電子・講師, 1974 年同電子・助教授, 1984 年同電気・教授, 1989 年同情報・教授, 1998 年同大学院自然科学研究科・教授。デジタルフィルタ, デジタル画像処理, パターン認識, デジタル音声信号処理, デジタル通信, デジタル制御, 適応デジタル信号処理, ニューラルネットワーク, 数値解析, 推定理論など, 主として広義のデジタル信号処理の研究に従事。IEEE Japan Chapter of Signal Processing 前会長。「デジタル信号処理ライブラリー」(コロナ社)企画・編集責任者。著書「デジタル信号処理の理論, 第 1 巻～第 3 巻」(コロナ社, 1985, 1985, 1986), 「デジタル信号処理と基礎理論」(コロナ社, 1996), 「音声と画像のデジタル信号処理(共著)」(コロナ社, 1996), 「VLSI と デジタル信号処理(共著)」(コロナ社, 1997), 「マルチメディアと デジタル信号処理(共著)」(コロナ社, 1997), 「ニューラルネットワークとファジィ信号処理(共著)」(コロナ社, 1998), 「情報通信とデジタル信号処理(共著)」(コロナ社, 1999), 「高速アルゴリズムと並列信号処理(共著)」(コロナ社, 2000), デジタルフィルタと信号処理」(コロナ社, 2001) など。IEEE, 電子情報通信学会, システム制御情報学会, 日本印刷学会各会員。