

研究

部分的固定重みを持つ角膜内皮細胞写真の
画像処理ニューラルネットワーク

長谷川 玲・伊東 一良・一岡 芳樹

大阪大学工学部応用物理学教室 〒565 吹田市山田丘 2-1

(1992年7月6日受付, 1992年10月19日受理)

Neural Network with Fixed Weights for Image Processing
of Human Corneal Endothelium

Akira HASEGAWA, KAZUYOSHI ITOH and Yoshiki ICHIOKA

Department of Applied Physics, Faculty of Engineering,
Osaka University, 2-1, Yamadaoka, Suita 565

(Received July 6, 1992; Accepted October 19, 1992)

If training sets for networks are not unintentionally selected, generalization fails. In this paper, we propose a method to solve this problem in training neural networks for image processing of human corneal endothelial micrograms. The proposed method is to fix weights between the input and the first hidden layers during the process of learning by the back-propagation algorithm. We employ Fourier-Zernike's Polynomials for the fixed connection weights. It is shown that the fixed weights favorably transform the characteristics of training sets. Experimental results showed that well generalized networks were obtained.

1. はじめに

画像のパターン認識や特徴抽出処理において、最近、ニューラルネットワークが注目を集めている。その理由はニューラルネットワークの並列性と学習能力にある。このニューラルネットワークを実用化する際、ネットワークの「汎化」が問題となっている。ネットワークの「汎化」とは、学習データセットに含まれない入力データに対してもネットワークが良好な結果を出力することをいう。一般に、教師付き学習法を用いて学習を行ったとき、ネットワークの汎化は保証されない。これは、最近注目されている誤差逆伝播法¹⁾を用いても同様である。この問題を解決する方法として、接続重みの絶対値を小さくする方法^{2,3)}、自由パラメータ数を減少させる方法^{4,5)}など数々の方法が提案されている。これらの方法は、学習データセットが理想的であることを前提条件としている。ここで、学習データセットが理想的であるとは、学習データが対象関数の定義域から偏りなく選出されていることをいう。もし学習データセットが対象関

数の定義域に対して偏りを持っていた場合には、上述の学習方法は利用できない。学習データセットが学習対象関数の定義域に対して偏りを持つという問題は、ニューラルネットワークを現実問題に応用した場合に深刻である。現実問題では、対象関数の定義域は未知な場合が多く、学習データを定義域から偏りなく選出するのが困難なためである。

学習データセットが学習対象関数の定義域に対して偏りを持つという問題は、われわれが研究している角膜内皮細胞写真の画像処理⁶⁾の際にも起こっている。角膜内皮細胞写真は通常、シェーディングなど、さまざまな雑音を含んでいる。しかし、学習データセットとして用いられる画像は全体の一部分にすぎず、本来、内皮細胞写真が含んでいる雑音をすべて含んでいる訳ではない。これが、学習データセットが学習対象の定義域に対して偏りを持つ原因となる。

本来、あらゆる雑音を学習データセットが含んでいれば、それを学習したネットワークの内部には、これらの雑音を除去する機能が組織される。例えば、あらゆる雑

音を含んだ自然風景を「学習」した網膜は、ランダム雑音が支配的な高周波成分をカットするだけでなく、天候などで支配されやすい直流成分の変動を押さえる機能を持っているといわれている⁷⁾。しかし、一部の雑音しか含んでいない学習データセットを学習したネットワークには、このような前処理の機能は構築されず、処理がこの一部の雑音に依存してしまう。これを避けるためには、これらの雑音を除去する前処理の機能を、なんらかの方法で構築することが不可欠である。

このような観点に基づき、われわれは角膜内皮細胞写真の画像処理ニューラルネットワークにおいて、偏りを持つ学習データセットから汎化能力の高いネットワークを構築する方法を提案する。提案する方法は、ネットワークの入力-第1中間層間の接続重みをネットワークの前処理部分と考え、学習データの偏りを補正するようなパターンでこれらを置き換える方法である。学習時にはこれらを固定して他の重みのみを学習する。この固定重みの最適化は、この固定重みによって変換された学習データセットの偏りが最も小さくなるように、学習データセットのベクトル空間での分布を観察することによって行う。本手法により、従来に比べ汎化能力の高いネットワークを構築することができた。

2. 入力-第1中間層間の重み固定ネットワーク

2.1 ネットワークモデルと学習

ネットワークモデルを **Fig. 1** に示す。図中の灰色の各四角形は1画面分のユニットの配列を、各円錐形はユニット間の接続を意味している。このモデルは、入力-第1中間層間の重みを固定していることを除いて、われわれがこれまでに用いてきたものと同じである⁸⁾。このモデルは画像処理を目的としており、次の特徴を持つ。①階層型である。②各層はいくつかのクラスタに分割されている。各クラスタは2次元的に配置されたユニットに




Fig. 1 Neural network model with local space-invariant interconnections. Interconnections between the input and first hidden layers are fixed.

より構成される。③各クラスタ間の接続は位置不変である。④ユニットの受容野は制限されている。

$l+1$ 層目のクラスタ q に属するユニット (x, y) の入力総和 $N_{q^{l+1}}(x, y)$ 、出力 $O_{q^{l+1}}(x, y)$ は次式で与えられる。

$$N_{q^{l+1}}(x, y) = \sum_{p=1}^{P^l} [O_{p^l} * W_{p,q^l}]_{(x,y)} + b_{q^{l+1}} \quad (1)$$

$$O_{q^{l+1}}(x, y) = f(N_{q^{l+1}}(x, y)) \quad (2)$$

ここで、 $*$ は畳み込み累積和、

$$[g(x', y') * h(x', y')]_{(x,y)} = \sum_i \sum_j (g(i, j) h(i-x, j-y)) \quad (3)$$

を表し、 W_{p,q^l} は l 層目のクラスタ p と $l+1$ 層目のクラスタ q 間の重みパターン、 $b_{q^{l+1}}$ はバイアスを示す。また、 f は、

$$f(x) = \frac{2}{1 + \exp(-x)} - 1 \quad (4)$$

であり、値域は $[-1, 1]$ である。

入力画像と目標出力画像は $[-1, 1]$ の値を持つものとする。学習時は入力-第1中間層間の重み、バイアスは固定し、第1中間層以降の接続重み、バイアスを次式によって変更する。

$$\Delta W_{p,q^l}(t) = \eta (\delta_{q^{l+1}} * O_{p^l}) + \alpha \Delta W_{p,q^l}(t-1) \quad (5)$$

$$\Delta b_{p^l}(t) = \eta \sum_i \sum_j \delta_{p^l}(i, j) + \alpha \Delta b_{p^l}(t-1) \quad (6)$$

$$\delta_{p^l} = f'(N_{p^l}) \sum_q (\delta_{q^{l+1}} * \hat{W}_{p,q^l}), \quad (l < L) \quad (7)$$

$$\hat{W}_{p,q^l}(x, y) = W_{p,q^l}(-x, -y)$$

$$\delta_{1^L} = f'(N_{1^L})(T - O_{1^L}) \quad (8)$$

ここで、 T は目標出力画像、 η は学習係数、 α は慣性係数である。

2.2 固定重み

2.2.1 学習データセットの偏り

まず、学習対象と用いる学習データセットを示し、今後用いる言葉を定義する。**Fig. 2** (a)の画像A (画素数 199×199)、(b)の画像B (画素数 199×199)は角膜内皮細胞写真である。学習データセットは画像Aの白線内に示される二つの部分画像 (画素数 67×67) である。これらを今後、学習画像と呼ぶ。学習画像内に中心画素を持つ任意の 31×31 画素の部分画像が、一つの学習データに相当する。したがって、学習に用いた学習データの総数は 8978 個になる。与えた学習画像に対して、目標出力画像として人の手によるトレース画像を与えた (**Fig. 2** (c))。

用いたネットワークは 31×31 画素の部分画像を入力とし、スカラーを出力する階層型ネットワークである。

このネットワークは961次元実数値関数とみなせる。各入力データは961次元ベクトル空間の1点であり、入力データを複数含んだ学習画像、画像A、Bはそれぞれこの空間での分布と考えられる。今後、画像に含まれたデータの、高次元ベクトル空間での分布を、画像の分布と呼ぶ。

学習画像の分布の偏りを調べる。961次元ベクトル空間は直接観察できないため、この空間を2次元平面に投影し、その投影像を観察する。投影する平面は学習画像から無作為に抽出した500個の学習データの分布のKarhunen-Loève展開(KL展開)により得られる第1, 第2固有ベクトルを含む平面を選んだ。ベクトル空間内のクラスタの様子を視覚化するために投影を用いる方法はよく使われており、投影面の選び方にもさまざまな方法が提案されている⁸⁾。ここでは分布の大きな分散方向が得られるKL展開による方法が有効であると考えた。

Fig. 3 (a), (b)に投影像を示す。図中、黒丸は学習画像に含まれるデータ、白丸は画像A、または画像B




Fig. 2 Photomicrographs of a human corneal endothelium and their training data: (a) a photomicrograph that includes the training set (image A), (b) a photomicrograph that does not include the training set (image B), and (c) desired images drawn by hand.

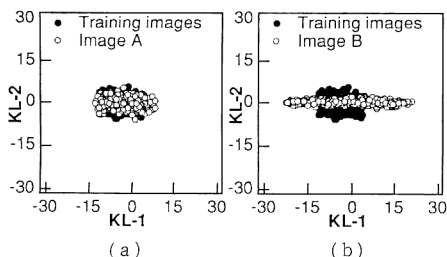


Fig. 3 Distribution maps of data that are included in (a) training images and image A, (b) training images and image B.

に含まれるデータを示している。画像Aに含まれる各データは、ほぼ学習データの近傍に位置している。一方、画像Bの分布は第1固有ベクトル方向に大きな分散を持ち、画像Bに含まれるデータには、いずれの学習データの近傍にも含まれないものが観察できる。これらより、学習後のネットワークは画像Aに対しては良好な結果を出力できるが、画像Bの一部に対しては良好な結果は出力できないことが予想できる。

画像Bの分布が大きな分散を持つ第1固有ベクトル方向は $(1, 1, 1, \dots, 1, 1)$ 方向と一致する。これは、画像Bに含まれるデータのKL展開によって得られる。 $(1, 1, 1, \dots, 1, 1)$ 方向は各データの成分の平均値に対応する。したがって、画像Bに含まれるデータの成分の平均値がさまざまな値を持っていることになる。これは、画像Bに含まれる 31×31 画素の部分画像がさまざまな背景直流雑音を持っていることに相当する。つまり、学習データセットは $(1, 1, 1, \dots, 1, 1)$ 方向について偏りを持ち、その原因は背景直流雑音にある。また、Fig. 3では観察できないが、 $(1, 1, 1, \dots, 1, 1)$ と直交する方向においても、学習データセットからはみ出している未学習データも存在することも考えられる。以上より、角膜内皮細胞の学習データは、 $(1, 1, 1, \dots, 1, 1)$ 方向、および、それに直交する方向に偏りを持っていることがわかった。したがって、角膜内皮細胞写真の画像処理ネットワークの前処理としては、 $(1, 1, 1, \dots, 1, 1)$ 方向の分布の偏りを除去し、かつ、 $(1, 1, 1, \dots, 1, 1)$ と直交する方向の偏りを補正するものが必要である。

2.2.2 固定重みの最適化

背景直流雑音、つまり $(1, 1, 1, \dots, 1, 1)$ 方向の成分を除去するには、 $(1, 1, 1, \dots, 1, 1)$ と直交するベクトルとの内積をとればよい。われわれのモデルでは、重みの合計がゼロとなるパターンと入力画像との畳み込み累積和を計算すれば良いことになる。画像処理の立場から考えた場合、固定する重みに課せられる条件として、重み合計がゼロとなること以外に次のものが挙げられる。①線分の抽出に向いている、②高周波成分をカットできる、③パターン形状によるアーティファクトが少ない。①の条件は、画像処理の目的が細胞膜の抽出であるために必要であり、②の条件は不要なランダム雑音を除去するために必要である。また、③の条件は、正確な細胞の形状を得るために欠かせない。これらの条件を満足するパターンとして、われわれはフーリエ・ツェルニケ多項式(circle polynomials of Fourier-Zernike, CPFZ)⁹⁾から得られる1, 2次のパターン(Fig. 4)を用いた。Fig.

4 の白部分は正の重み, 黒部分は負の重みを表す. CPFZ は円盤の直交展開系の一つである. CPFZ の1次以降のパターンは, 高周波成分を除去し, 方向性微分, 2次微分を抽出する. さらに, CPFZ パターンは円形の形状を持つため, パターン形状によるアーティファクトが少ない.

0次を除いた各 CPFZ パターンとの畳み込み累積和をとることにより, (1, 1, 1, ..., 1, 1) 方向の偏りは除去できる. しかし, (1, 1, 1, ..., 1, 1) と直交する方向においても, 学習データセットが定義域に対して偏りを持っている可能性がある. Fig. 3 では観察されなかったが, (1, 1, 1, ..., 1, 1) と直交する方向において, 学習データセットの分布からはみ出しているデータも存在するはずである. このような偏りは, 単に CPFZ パターンとの畳み込み累積和を行っただけでは取り除けない.

この偏りは, ノルムが大きな CPFZ パターンを用い, 畳み込み累積和後の各値を飽和型非線形関数で変換することにより取り除くことができる. ここでは, 重みパターンのノルムはパターンを構成する各重みの値の二乗和の平方根 (ユークリッドノルム) と定義する. ノルムを大きくすれば, 学習データセットの分布の広がりが大きくなる. ここで, 非線形関数の飽和特性を利用すると, ノルムが十分大きければ, 分布は飽和型非線形関数の領域によって定められる領域内において最大限の広がりを持つ. ただし, このときノルムを大きくし過ぎると, 学習データセットの分布の内部が疎になり, かえって偏りができてしまう. 以上の考察から, CPFZ パターンとの畳み込み累積和によって求められる学習データセットの分布の広がりが飽和し始めるとき, その分布を与えるノルムの値が最適値であると考えた.

このノルムの最適値を求める具体的な手順を次に示す.

(A) ノルム N_S のパターンと学習画像との畳み込み




Fig. 4 Patterns of Fourier-Zernike's polynomials.

累積和を行い, 各出力値を飽和型非線形関数 $y = f_{sat}(x)$ で変換する. ただし, ノルム N_S は比較的小さく, 得られる画像の分布の広がりは飽和していないものとする.

(B) ノルム N_B のパターンを用いて同様の計算を行う. このとき, ノルム N_B は十分大きく, 得られる画像の分布の広がりは飽和しているものとする.

(C) (A)において得られた画像に含まれるデータの KL 展開を行う. これから得られる第1, 第2固有ベクトルによって決定される平面に, 上で得られた画像内のデータをそれぞれ投影する.

(D) (A)で求めた画像に含まれる最大の投影ベクトルの大きさ r_S , (B)で求めた画像に含まれる最大の投影ベクトルの大きさ r_B を求める (Fig. 5 (a), (b)参照).

(E) 非線形関数 $y = f_{sat}(x)$ が飽和し始める時の入力を X_{sat} とした時, 次式で求められる k を計算し (Fig. 5 (c)参照), ノルムの大きさが N_S の CPFZ パターンの各重みを k 倍することにより, 最適のノルムを持つ重みパターンを作成する.

$$k = \frac{X_{sat}}{f_{sat}^{-1}(Y_{\infty} \cdot r_S / r_B)},$$

$$Y_{\infty} = \lim_{x \rightarrow \infty} f_{sat}(x). \quad (9)$$

われわれは, ここで, $f_{sat}(x)$ が飽和し始める時の入力




Fig. 5 Optimal norms of fixed weight patterns connecting input and first hidden layers : distribution map of training image convoluted by CPFZ patterns whose norms are (a) N_S and (b) N_B : (c) nonlinear function (see the text for details).

X_{sat} を, $f_{sat}(x)$ の出力が Y_{∞} の 99% に達した点と定義した.

3. 実験

3.1 ノルムの最適値

固定重みパターンのノルムの最適値を, 上述の方針に従って求めた. $N_S=1.0$, $N_B=200.0$ の場合の学習データセットの分布から求められる r_S/r_B は 0.56 であった. 飽和型非線形関数として式(4)を用いれば, $Y_{\infty}=1.0$, $X_{sat}=5.29$ である. よって式(9)より, ノルムの最適値 N は 4.2 となる. Fig. 6 (a), (b) に, ノルムの大きさが 4.2 の CPFZ パターンと学習画像, 画像 A, B との畳み込み累積和を計算して得られる各画像の分布の投影像を示す. 黒丸は学習データセット, 白丸は画像 A, または B に含まれているデータを示す. CPFZ パターンとの畳み込み累積和によって, 画像 A, B 内のほぼすべてのデータが学習データの近傍に変換されているのが観察できる.

3.2 細胞膜の抽出

入力-第1中間層の重みとして CPFZ パターンを用いた場合と, すべての接続重みを学習によって決定した場合について, 画像 A, B に対する出力画像を比較する. 用いたネットワーク構造を表すパラメータを Table 1 に示す. 表中のユニット数の欄に用いられている n は 2 次元の出力層内のユニット数の平方根を表す. Table 1 に示したネットワーク構造は実験的に最適と判断された




Fig. 6 Distribution maps of data that are included in images convoluted by CPFZ patterns whose norms are 4.2: (a) training images and image A, (b) training images and image B.

ものである. 学習環境は, $\eta=0.1$, $\alpha=0.9$, 接続重みとバイアスの初期値は -0.3 から 0.3 の一様乱数を用いた. 学習は最大 2000 回まで行った. 最適な学習回数を決するため, 異なる画像から切り出した三つの部分画像を validation set として用いた. これらのうち, 少なくとも一つのセットに対する誤差が増加すれば, 過学習が起こったと判断し, 学習をその直前で打ち切った.

すべての接続重みを学習した場合, 最適な学習回数は 900 回, 学習画像に対する誤差は 1564.372 であった. 入力-第1中間層の重みをノルムの大きさが 4.2 の CPFZ パターンで固定し他の重みを学習した場合は 1050 回, 学習画像に対する誤差は 1814.219 であった. 誤差は次式で定義されている.

$$E = \sum_j |T_j - O_j|^2 \quad (10)$$

学習データセットに対する誤差のみで優劣を判断すると, すべての接続重みを学習した場合の方が優れている. しかし, 問題は汎化能力を持っているか否かである.

すべての重みを学習した場合と, 入力-第1中間層の重みを固定し他の重みを学習した場合の, 画像 A, B に対する出力結果を, それぞれ Fig. 7 (a), (b) に示




Fig. 7 Output images: (a) when the weights between input first hidden layers are not fixed and (b) when these weights are fixed with CPFZ patterns during the learning process.

Table 1 Network structure.

Layer	Input	1st hidden	2nd hidden	3rd hidden	Output
Number of clusters	1	5	1	5	1
Number of units in a cluster	$(n+30)^2$	$(n+20)^2$	$(n+12)^2$	$(n+6)^2$	n^2
Size of receptive field		11×11	9×9	7×7	7×7

す。すべての重みを学習した場合、画像Aに対しては全体にわたって細胞膜を抽出している。画像Bに対する出力では一部の細胞内部に雑音を多く残している。また、画像の上部においてコントラストの低い部分が観察できる。これは、画像Bの分布が学習画像の分布から大きくはみ出していたためである。一方、入力-第1中間層の重みを固定した場合は、両画像に対する出力画像の画質はほぼ等しく、全体にわたって細胞膜を抽出している。しかし、細胞膜の欠落箇所が目立つ。細胞膜欠落の原因は、シグモイド関数の非線形性によって情報が欠落したためと考えられる。このような細胞膜の部分的な欠落は、これらの部分を学習データに含めることによって補うことが可能である。また、従来からの画像処理技術によっても補える¹⁰⁾。

ノルムの大きさが最適値より小さい場合、および、極端に大きい場合の出力画像を Fig. 8 に示す。ノルムの大きさは小さい場合が 1.0、大きい場合が 200.0 である。ノルムの大きさが 1.0 の場合には、画像Aに対しては良好な出力を与えているが、画像Bに対してはコントラストが低い。一方、ノルムの大きさが 200.0 の場合は、いずれに対しても同程度の画質の画像を出力しているが、雑音が多く認められる。

以上の結果から、われわれの実験においては、入力-第1中間層間の接続重みをノルムが 4.2 の CPFZ パターンで固定したネットワークが高い汎化能力を持っていることがわかった。これにより、入力-第1中間層間の重みを CPFZ パターンで固定する方法の有効性が確認できた。

3.3 固定接続重みのノルムの最適性

3.1 で求めたノルムの最適性を検証する。ノルムの大きさが異なる九つのネットワークを学習させ、それらの




Fig. 8 Output images when norms of CPFZ patterns are 1 and 200.

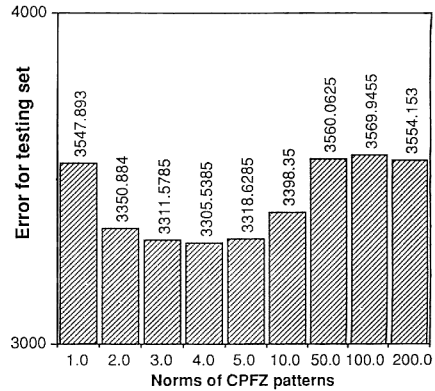


Fig. 9 Comparison of errors associated with testing images: The learning processes were stopped when errors associated with training images converged to a certain level.

汎化能力を調べた。実験したネットワークの持つ CPFZ パターンのノルムの大きさは、1.0, 2.0, 3.0, 4.0, 5.0, 10.0, 50.0, 100.0, 200.0 である。この九つのネットワークを学習データセットに対する誤差が同程度になるまで学習させ、その時の未学習データに対する誤差を比較した。結果を Fig. 9 に示す。横軸はノルムの大きさ、縦軸は未学習データに対する誤差を示している。Fig. 9 から、CPFZ パターンのノルムの大きさが 4.0 のネットワークが最も高い汎化能力を持っていることがわかる。

4. ま と め

角膜内皮細胞写真の画像処理問題において、ネットワークの入力-第1中間層の重みを最適化された重みパターンで固定する方法を提案した。固定重みの最適化は、学習データセットの定義域に対する偏りを小さくするよう、学習データセットのベクトル空間での分布を観察しながら行う。このことにより、汎化能力の高いネットワークが構築できる。われわれが行った実験では、重みパターンとして CPFZ パターンが適当であり、これを入力-第1中間層間の重みに採用することにより学習画像を含まない画像に対しても良好な結果を得ることができた。また、CPFZ パターンのノルムの大きさがネットワークの汎化能力に与える影響についても実験し、分布の観察によって求められるノルムの最適性を検証した。

文 献

- 1) D. E. Rumelhart, G. E. Hinton and R. J. Williams : "Learning internal representations by error propagation," *Parallel Distributed Processing* (Cambridge,

- MIT Press, 1986) pp. 318-362.
- 2) Y. LeCun, J. S. Denker and S. A. Solla : "Optimal brain damage," *Advances in Neural Information Processing Systems* (San Mateo, Morgan Kaufmann, 1990) pp. 598-605.
 - 3) A. Hasegawa, O. Matoba, K. Itoh and Y. Ichioka : "Learning generalization by validation set," *Jpn. J. Appl. Phys. Part 1*, **31** (1992) 2459-2462.
 - 4) C. Ji, R. R. Snapp and D. Psaltis : Generalizing smoothness constraints from discrete samples," *Neural Comp.*, **2** (1990) 188-197.
 - 5) S. J. Nowlan and G. E. Hinton : "Simplifying neural networks by soft weight-sharing," *Neural Comp.*, **4** (1992) 473-493.
 - 6) W. Zhang, A. Hasegawa, K. Itoh and Y. Ichioka : "Image processing of human corneal endothelium based on a learning network," *Appl. Opt.*, **30** (1991) 4211-4217.
 - 7) J. J. Atick and A. N. Redlich : "What does the retina know about natural scenes?," *Neural Comp.*, **4** (1992) 196-210.
 - 8) W. Siedlecki, K. Siedlecka and J. Sklansky : "Mapping techniques for exploratory pattern analysis," *Machine Intelligence and Pattern Recognition* (North-Holland, Elsevier Science Publishers B. V., 1988) pp. 277-299.
 - 9) M. Born and E. Wolf : *Principles of Optics*, 6th ed. (Pergamon Press, Oxford, 1980) pp. 464-466.
 - 10) A. Hasegawa, K. Itoh and Y. Ichioka : "Detection of cell membranes in human corneal endothelial micrograms using mathematical morphology," *Jpn. J. Appl. Phys. Part 1*, **31** (1992) 798-804.