

各種ニューラルネットワークと主成分分析による指紋の隆線方向抽出

木村 陽代[†] 森 康久仁[‡] 松葉 育雄[‡]

あらまし 指紋照合方法の1つであるマニューシャマッチング方式は端点や分岐点等微小な特徴点に着目するため、押捺時のかすれやゆがみや汚れの影響を受けやすく、特徴点抽出前のノイズ除去や隆線強調が重要になる。画像前処理の一例として、指紋画像中の局所領域ごとの隆線方向を求め、それに対応した方向性フィルタをかける方法が多く採用されている。本研究では、その隆線方向抽出方法として、あいまいなデータの近似に有効な各種ニューラルネットワークと主成分分析を用いた場合のノイズに対する耐性と短所を考察した。その結果、鮮明な画像では動径基底関数ネットワークが最も有効であるが、劣化の耐性が高いのは主成分分析を用いた方法であることが分かった。

Local ridge direction extraction of fingerprint

by various neural networks and principal components analysis

Haruyo KIMURA[†] Yasukuni MORI[‡] Ikuo MATSUBA[‡]

Abstract Since the minutia matching system is easy to be influenced of patchiness, twist and dirt at the time of stamp, the noise reduction and ridge enhancement before minutia extraction are important. As an example of pre-processing, the method is to compute the ridge direction for each section and convolve with the directivity filter corresponding to each block. The present study compares various neural networks with principal components analysis. It is found that the radial bases function (RBF) network shows the most effective performance on clear images, and principal components analysis has strong robustness for degradation.

1. はじめに

現在、指紋画像はその万人不同性や終生不変性から個人識別や犯罪捜査等様々な目的に使用され、それにより照合方法は主に画像マッチング方式とマニューシャマッチング方式の2方式に大別される。前者は広範囲の形状を捉えるもので、2値画像を調べる手法、周波数空間での位相相関を評価する手法、画像をブロック分割し隆線方向分布に着目する手法[1]等があり、大局的な特徴(隆線のパターン等)での指紋の分類に多く用いられる。一方後者は局所的形状を捉えるもので、マニューシャと呼ばれる隆線の分岐点や端点等特徴点の出現位置、角度、周囲のマニューシャの相関位置情報により照合を行い、画像マッチング方式後の候補パターンやそれ単独での指紋同一判定に用いられる。マニューシャマッチングの照合方法としては、まず指紋画像を採取し、ノイズ除去や隆線を強調する画像前処理を行った後、2値化・細線化し、マニューシャを抽出する。そしてその相対的な位置や個数を用いて照合を行う

[2][3][4][5]。しかし特に犯罪捜査に用いられる遺留指紋画像では隆線が鮮明でない場合が多く、登録指紋でも乾燥指や亀裂によるかすれ等の画質の低下や回転・位置ずれやひずみがおこることがあり、これはマニューシャ抽出に悪影響を与える。よって、マニューシャマッチング方式では隆線の強調や劣化画像の画像前処理が重要であるといえる。画像処理としては、局所的な隆線方向を抽出し、それに応じたフィルタをかける方法が多く用いられる。また、この方向抽出技術は特徴点の照合以外にも、指紋画像の形状での照合方法や指紋分類方法としても用いられることがある[6][7]。

本研究では指紋画像の隆線方向抽出方法として、あいまいなデータの近似に有効である各種ニューラルネットワークと主成分分析を用いた方法の劣化画像に対する耐久性と短所を考察する。

[†] 千葉大学大学院 自然科学研究科 知能情報工学専攻

Graduate School of Science and Technology, Chiba University

[‡] 千葉大学 工学部情報画像工学科

Department of Information and Image Science, Faculty of Technology,

Chiba University




図1 マニューシャマッチング方式の流れ

2. 隆線方向抽出方法

指紋画像の隆線方向抽出方法として,[8]での方法と同様,まず2値化した指紋画像(256×256pixels)を特定の大きさのブロック(16×16pixels)に分割する.その中で特定の大きさの窓(5×5pixels)を走査させ,階層型ネットワーク,動基底関数(RBF)ネットワーク,主成分分析,競合学習ネットワークにより隆線方向を求める.精度を高めるため各ブロックの隆線方向をブロック内の窓のから抽出された方向の多数決で決定する.

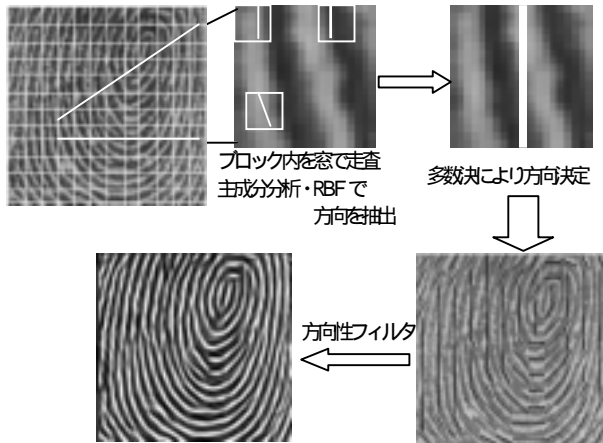


図2 画像処理の流れ

2.1 劣化指紋画像

本研究で使用する指紋画像は[9]から引用したものである.また,実際の指紋採取の際起こる画像劣化の一例としてかすれた場合を想定し,隆線のエッジ部の画素値を増やす(白くする)処理を行




図3 劣化画像

ったノイズ付加画像を,そのノイズ量によって4種作成する.ここでノイズ量とは2値化画像として比較した場合のエラーピクセルの割合をいう.

2.2 RBF及び階層型ニューラルネットワーク

窓画像の隆線方向抽出で使用するRBFニューラルネットワークは中間層のノード関数としてガウス関数を用い,中間層j番目のノードの出力を $\xi_j(\bar{x})$ とすると

$$\xi_j(\bar{x}) = \exp\left\{-\frac{(\bar{x} - \bar{\mu}_j)^2}{\sigma_j^2}\right\} \quad (2.1)$$

となる.ここで \bar{x} は入力画像であり, $\bar{\mu}_j$ は入力画像の平均, σ_j^2 は分散を初期値とする.このネットワークでは出力は各中間層ノードの出力と重みの積を足し合わせて求められ,i番目のノードの出力を y_i とすると,

$$y_i = \sum_{j=1}^N w_{ji} \xi_j(\bar{x}) \quad (2.2)$$

であり,Nは中間ノード数, w_{ji} は中間層j番目と出力層i番目のノード間の重みである.

教師パターンとしては図4に表わす5×5pixelsの8方向パターン各2種類の計16パターンを与え,8方向に対応する出力ノード中その方向のみ1を出力し,それ以外の方向に対応する出力ノードでは0を出力するよう事前に学習させる.学習則は出力ノードの平均2乗誤差Eが最小になるよう $w_{ji}, \bar{\mu}, \sigma^2$ を以下のように変更する. u_w, u_μ, u_σ はそれぞれの学習率, $\Delta w_{ji}, \Delta \mu_{jk}, \Delta \sigma_j$ はそれぞれの変更量, o_i は教師パターンの出力,Mは入力パターンの次元である.

$$E = \frac{1}{2} \sum_{i=1}^8 (o_i - y_i)^2 \quad (2.3)$$

$$\Delta w_{ji} = -\frac{\partial E}{\partial w_{ji}} = u_w \cdot (o_i - y_i) \cdot \xi_j \quad (2.4)$$

$$\Delta \mu_{jk} = -\frac{\partial E}{\partial \mu_{jk}} = u_\mu \cdot 2 \cdot \frac{(x_k - \mu_{jk})}{2} \sum_{i=1}^8 \{(o_i - y_i) \cdot w_{ji}\} \quad (2.5)$$

$$\Delta \sigma_j = -\frac{\partial E}{\partial \sigma_j} = -u_\sigma \cdot \frac{2}{\sigma_j^3} \sum_{k=1}^M \{(x_k - \mu_{jk})^2\} \sum_{i=1}^8 \{(o_i - y_i) \cdot w_{ji}\} \quad (2.6)$$




図4 教師パターン(黒が1,白が0に対応)

また階層型ニューラルネットワークでは,中間層・出力層のノード関数として以下に表わすシグモイド関数を用いた3層のネットワークでシミュレーションを行う.

$$S(x) = \frac{1}{1 + \exp(-x)} \quad (2.7)$$

入力層と中間層，中間層と出力層間の重みの変更は誤差逆伝播法を用いる．このネットワークでもRBFニューラルネットワークと同様に教師パターンとして図4の16パターンをあらかじめ学習させておく．

以上の学習後実際の指紋画像を与え，窓画像の方向を抽出する．ブロック内を窓で走査し，窓画像方向の多数決によりブロックの方向を決定する．




図5 RBFネットワーク

2.3 主成分分析と競合学習

主成分分析では2値化された各指紋画像ブロック中の黒の点のみ存在するとし，主成分分析を行いその第1主成分を求める．図6(a)のように，求めた第1主成分に最も近い方向を窓の方向とする．ただし，この方法では図6(b)のような場合正しい隆線方向に対して垂直な方向が求められてしまう．このような状況を回避するため，ブロック内の窓画像から抽出された方向の多数決をブロックの方向とする．

また競合学習では重みの初期値を図4のような8方向各2パターンとする．よって出力ノード数は16となる．出力層*i*番目のノードの重み $\bar{w}_i (= w_{i1}, w_{i2}, \dots, w_{iM})$ ，*p*番目の入力画像 $\bar{x}_p (= x_{p1}, x_{p2}, \dots, x_{pM})$ とすると，出力 y_i は，

$$y_i = \sqrt{\sum_{j=1}^M (w_{ij} - x_{pj})^2} \quad (2.8)$$

となり，この出力 y_i が最小になったものが勝者ノードである．勝者ノードの重みの変更式は，*k*番目のノードが勝者ノードであるとすると，

$$\Delta w_{kj} = \eta (x_{pj} - w_{kj}) \quad (2.9)$$

となる．ここで η は学習係数， Δw_{kj} は w_{kj} の変更量である．この重みの変更をブロック内の窓によって切り出した画像すべてを入力画像として行い，一定の回数繰り返す．十分に学習が行われた後再度ブロック内の窓によって切り出した画像

入力し，各ノードの勝者となった回数をカウントする．主成分分析での方法と同様，図4の(b)のような誤りを減らすため，勝者になった回数の最も多いノードだけでなく，勝者になった回数の多いものから順に3パターンについて主成分分析を行い，その平均からブロックの方向を決定する．




図6 主成分分析による方向抽出

3. シミュレーション

階層型RBFニューラルネットワークの入力層ノード数は25であり，中間層ノード数16，出力ノード数8(8方向に対応)とする．階層型ネットワークの学習率は0.5 RBFネットワーク学習率 u_w ， u_μ ， u_σ は0.1，競合学習学習率0.01として，図2の16パターンをすべて記憶するまで学習を行い，その後指紋画像を入力し隆線方向を求めた．

評価方法としてはまず，各方法を用いた場合に元画像から抽出した隆線方向を比較する(図8)．次に，劣化画像から抽出した隆線方向の，筆者の主観で決めた方向を正しい方向とした場合(図9)と，元画像から得られた方向を正しい方向とした場合(図10)との差異を評価した．正しいとした方向から劣化画像の抽出方向が22.5°ずれるごとに方向評価値を+1し，画像全体の和を求めてその方向評価値が最も小さいものが正確に方向を抽出できている．




図7 各方法による隆線方向抽出

図7より，競合学習ネットワークと主成分分析ではほぼ等しい方向が得られた．これは，競合学習ネットワークと主成分分析では最終的に同じ主成分分析により方向を求めており，その前段階としてブロック内で競合学習を行うか単純に多数決を行うかの違いしかないと考えられる．また，階層型ネットワークは全体的に誤った方向が多く抽出され，RBFニューラルネット

ワークにより求めた方向は，大きく隆線から離れているものはないがやや滑らかさにかけるといえる．反対に主成分分析ではRBFに比べ細部では隆線に忠実な方向が得られているが部分的に隆線に対して垂直方向が抽出されているものが見られる．その理由としては，図6(b)に表わすように窓内で隆線部分が2分されている場合が考えられる．ここでは270°付近ではなく45°付近として方向抽出が行われていると考えられる．このような場合の対策として1つの窓だけではなくブロック内の走査させた窓の平均をとっているが，根本的な解決にはなっていない．よって今後の課題としては，図6(a)のような場合の正しい方向の抽出方法が必要になる．

以上のような影響から図8ではノイズ量が少ない範囲ではRBFニューラルネットワークのほうが評価値が小さいが，ノイズ量が増えるに従い逆転する．RBFネットワークと階層型ネットワークがノイズに弱い原因としては，今回用いたノイズでは画像が隆線のエッジから薄くなるように付加したため，図4に示す教師パターンよりも1のピクセルが全体的に少なくなり正しく判別できなかったことが考えられる．

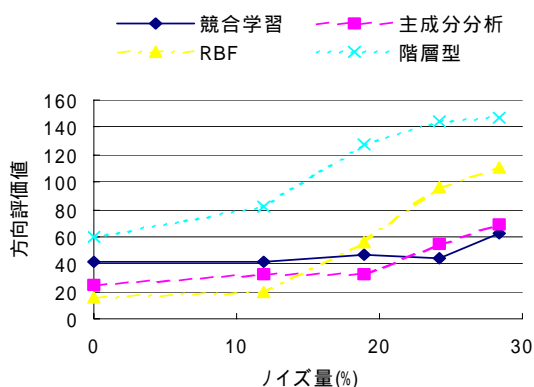


図8 主観方向との差異




図9 元画像方向との差異

4.まとめ

画像が非常に鮮明であるならばRBFネットワークは方向抽出の精度は高いが，画像の劣化の影響を大きく受けるといえるのに対し，主成分分析は鮮明画像でもある程度のエラーを含むが劣化によってそのエラーがそれほど増大せず，本研究で使用した種類のノイズに関しては耐性が強いといえる．しかし，ノイズの種類として他にもかすれや汗によるにじみ等が考えられ，それらのすべてにおいて主成分分析のほうが有効であるとは断言できないため，今後は画像のノイズの種類により方向抽出方法を選択する必要がある．

文献

- [1]小林哲二，細線化画像パターンマッチングによる指紋照合，電子情報通信学会論文誌，Vol. J79-D- ， pp. 330-340，1996
- [2]河嶋操，木地和夫，指紋と掌紋による個人識別技術，情報処理，Vol. 25，pp. 599-605，1984
- [3]笹川耕一，池端重樹，個人確認用指紋照合技術の現状と動向，システム/制御/情報，Vol. 35，pp. 8-15，1991
- [4]A. K. Jain, L. Hong, S. Pankanti, R. Bolle, An Identity-Authentication System Using Fingerprints, IEEE, Vol. 85, pp. 1365-1387, 1997
- [5]浅井紘，星野幸夫，木地和夫，マニユージャネットワーク特徴による自動指紋照合，電子情報通信学会論文誌，Vol. J72-D- ， pp. 724-740，1989
- [6]K. A. Nagaty, Fingerprints classification using artificial neural networks: a combined structural and statistical approach, Neural networks, Vol. 14, pp. 1293-1305, 2001
- [7]若原徹，木村義政，鈴木章，塩昭夫，佐野睦夫，指紋隆線方向分布とマニユージャ対応付けを用いた指紋照合，電子情報通信学会論文誌，Vol. J86-D- ， pp. 63-71，2003
- [8]K. A. Nagaty, On learning to estimate the block directional image of a fingerprint using a hierarchical neural network, Neural Networks, Vol. 16, pp. 133-144, 2003
- [9] The Los Alamos FTP site, www3.lanl.gov/pub/misc/WSQ