論文

ニューラルネットワークを用いた肺野X線像の 異常陰影検出システムの高性能化

佐々木 貴啓^{1,2}, 木下 健太郎¹, 岸田 悟¹, 平田 吉春³, 山田 聖悟³

¹ 鳥取大学工学部附属電子ディスプレイ研究センター (TEDREC), 鳥取県鳥取市湖山町南 4-101

² シャープ株式会社 ディスプレイデバイス開発本部, 三重県多気郡多気町五佐奈 1177-1

³ 鳥取大学医学部附属病院 放射線部, 鳥取県米子市西町 36-1

Construction of High-Performance Neural Network Systems for Detection of Abnormal Shadows from X-Ray Images of Lungs

Takahiro Sasaki^{1,2}, Kentaro Kinoshita¹, Satoru Kishida¹,
Yoshiharu Hirata³ and Seigo Yamada³

¹Tottori University Electronic Display Research Center (TEDREC)
4-101 Koyama-minami, Tottori, Tottori 680-8552, Japan

²Display Device Development Group, Sharp Corporation, 1177-1 Gosana, Taki, Mie 519-2192, Japan

³Department of Radiology, Tottori University Hospital, 36-1 Nishi-machi, Yonago, Tottori 683-8504, Japan
E-mail: d09t2003@faraday.ele.tottori-u.ac.jp

Abstract We construct systems including neural networks for detection of abnormal shadows in X-ray images of lungs and investigate the relationship between performance of the systems and pre-processing of input patterns. We use 32 images included 16 types of diseases and picked up 128 one-dimensional numeric sequences from the images. Then, the sequences are pre-processed for input patterns into the neural networks by averaging the values of data in the sequences and using differential filters. From the results, we found that the performance of the systems was affected by the pre-processing of the input patterns. The best values of equal error rate and AUC in our paper were 7% and 0.95, respectively, where the pixel values of the images were used as input patterns. The results obtained by using the one-dimensional numeric sequences from the images were comparable with the results of previous systems using two-dimensional information. Thus, our systems are thought to be useful for computer aided diagnosis with X-ray images of lungs.

Keywords: neural network, one-dimensional numeric sequence, pre-processing, X-ray images of lungs, CAD (Computer Aided Diagnosis)

1. はじめに

コンピュータを用いた医療画像診断支援システムは、画像診断に携わる医師の負担を減らすための有効な手段として期待されている。画像診断において用いられる画像には、様々な情報が含まれている。例えば胸部 X 線像においては、腫瘍等の異常陰影、肋骨や毛細血管等といった身体構造、更には撮影時のノイズ信号等の情報が 1 枚の画像内に混在、重複している。また異常や身体構造には個人差があるため、それらの大きさ、形状および位置は画像毎に異なるものとなる。従って、医療画像診断支援システムには、画像が含むこれらの複雑であいまいな情報の中から異常陰影等に関する規則性を正しく見つけ出す能力が求められる。しかしながら、その能力を実現するためのアルゴリズムはまだ確立されていない。

ニューラルネットワークのような脳機能を模した情報処理は、学習することによって認識対象に存在する規則性を見出すことができる [1] という特長を有しており、医療分野においても強力な分類、意思決定ツールとして様々な用途向けに検討されている [2]。胸部 X 線像の肺野領域における異常陰影検出を目的とした画像診断支援システムへの適用例としては、がんに関連した肺結節の検出 [3, 4, 5, 6, 7, 8]、および肺炎に関連した間質性肺疾患の鑑別診断 [9, 10] について報告がある。これらは特定の症例を対象とした診断支援システムであり、肺野 X 線像に含まれる多くの症例を対象とするものではなかった。また、これらは 2 次元データである肺野 X 線像から得た 2 次元の画像情報を元に診断を行っているが、いずれも対象症例の全てを正しく判定するまでには至っていなかった。例えば、2 次元データである肺野 X 線像の中から 2 次元の関心領域を抽出し、その画素値分布を利用して異常陰影有無の判定を行う文献 [3], [4] では、医療画像診断システムの性能指標として用いられる ROC (Receiver Operating Characteristic) 評価の AUC 値 (Area under ROC Curve) [11] の最も良い値はそれぞれ 0.88 および 0.96 であり、改善の余地が残されていた。更に、2 次元の関心領域を抽出するためには、背景補正、しきい値処理、あるいはパターンマッチング等の複雑な画像処理が必要であった。

一方、我々はこれまでに、従来とは異なる方法として、肺野 X 線像から得られた 1 次元の数値列を利用した画像診断支援システムについて検討してきた [12, 13, 14]。2 次元データである画像からライン状に抽出した 1 次元の数値列をニューラルネットワークへの入力データとして用いた。この方式では、画像の背

景補正やしきい値処理等、関心領域抽出のための画像処理は不要である。画像の肺野内の上端から下端までをサンプリングして得た数値列に対して、FFT による前処理を行い、ニューラルネットワークの入力パターンとして用いた。その結果、12 種類の異常症例に対して、システムはその有無を正しく判定できる能力を有していることが分かった [12]。更に、肺野内の上端から下端までを 4 つの領域に分け、各領域に対して位置を横方向にシフトさせながら複数回サンプリングして得た入力パターンを用い、異常陰影位置の検出性能を評価した。その結果、画素値そのものによる入力パターンを用いた場合に、システムの出力値が、画像内の異常陰影位置に対応した変化を示すことが明らかとなった [13, 14]。しかしながら、これらの結果は、同一画像内から得た未学習パターンに対する汎化能力であり、未学習画像から得たパターンに対する汎化能力は確認できていなかった。また、1 次元数値列に対する前処理条件がシステムの判定性能に及ぼす影響は、十分調査できていなかった。

本論文では、画素値に基づく 1 次元数値列をニューラルネットワークへの入力パターンとして用いた肺野 X 線像の異常陰影検出システムを未学習画像から得たパターンに対して適用し、システムの汎化能力を調査する。更に、入力パターンへの前処理として画素値平均化や微分処理を行い、これらの前処理がシステムの高性能化に及ぼす効果を明らかにする。

2. 実験および評価方法

2.1 システム概要

図 1 は、本研究に用いた肺野 X 線像の異常陰影検出システムにおけるデータ処理の流れを示している。最初に、2 次元画像である胸部 X 線像の肺野領域から 1 次元数値列パターンのサンプリングを行った。次に、サンプリングされた 1 次元数値列パターンに対して、画素値平均化と微分処理による前処理を行い、画素値平均、1 次微分および 2 次微分の入力パターンを得た。これらの入力パターンをニューラルネットワークに入力してネットワークの学習とテストを行った。ニューラルネットワークは、入力パターンの異常陰影有無に関する判定結果を出力した。

図1 本研究におけるデータ処理の流れ

Fig.1 Flow of data processing

2.2 1次元入力パターンのサンプリングと前処理

図2(a)は、本研究で用いた胸部X線像の一例を示している。本研究では、32名の患者から1枚ずつ得た32枚の胸部X線像を使用した。X線像の撮像は、デジタルラジオグラフィCXDI-50G(キヤノン製)を用いて行った。得られたX線像には、肺野領域に異常陰影を持たない正常像が4枚、肺野領域の少なくとも一部に何らかの異常陰影を有する異常像が28枚含まれた。これらの異常像には、次に示す16種類の異常のうち少なくとも一つが含まれた。それらは、肺がん(n=4)、肺腺がん、肺腫瘍、胸水、無気肺(それぞれn=3)、気胸、転移性肺がん、肺結核(それぞれn=2)、肺小細胞がん、肺気腫、非定型抗酸菌症、肺動脈血管肉腫、肺炎、心膜液貯留、肺化膿症、石灰化(それぞれn=1)である。各画像における異常の有無、位置、および病名は、医師によって読影診断された。なお、図に示す画像は楕円で囲んだ領域に異常陰影を有しており、病名は非定型抗酸菌症である。オリジナルの画像形式はDICOM形式、量子化ビット数12ビットであり、これをビットマップ形式、8ビットに変換した。画像のマトリクスサイズ(横×縦)は、2,208×2,688画素、2,208×2,212画素、2,168×2,344画素、および1,728×1,904画素の4種類であり、画素サイズはいずれも160×160 μ mであった。なお、(a)のマトリクスサイズは、2,208×2,212画素である。画像の右肺領域を縦方向に4分割し(A～D)、各分割区間のライン部分から画素値データのサンプリングを行った。これに

よって、4×32枚、つまり計128の1次元数値列のサンプリングパターンを得た。これらの128のサンプリングパターンは、異常陰影を持たない正常パターン68と、異常陰影を含む異常パターン60から構成された。

図2(b)は、領域Bの拡大図および画素値平均化法を示している。最初に、各サンプリングパターンの明るさレベルを合わせるため、各画像の鎖骨部分の画素値を基準として各パターンの画素値を調整した。次に、肺領域の大きさの個人差に起因したサンプリングパターン間のデータ数の違いを補正するため、最近傍補間を用いて、各サンプリングパターンからデータ数128の入力パターンを作成した。その後、これらの入力パターンから、隣り合う2つのデータの平均を取り、データ数64の入力パターンを得た。更に同様の平均化を繰返し、データ数32および16の入力パターンを作成した。これらの入力パターンは、画素値または画素値の平均値からなるデータから構成されている。ここではこれらの入力パターンを画素値平均入力パターンと呼ぶ。上記の平均化によって、データ数の異なる4つの画素値平均入力パターンが作成された。その後、各画素値平均入力パターンの隣り合う画素値の差を取ることによって、4つの1次微分入力パターンを得た。更に、各1次微分パターンから、隣り合う画素の差を取るによって、4つの2次微分入力パターンを得た。これらの前処理を経て、1つのサンプリングパターンから、前処理条件の異なる12の入力パターンを得た。肺野X線像から得た128のサンプリングパターンに対してこれらの前処理を適用し、12の前処

図2 (a) 本研究で用いた胸部 X 線像の例, (b) 領域 B の拡大図および画素値平均化方法
 Fig.2 (a) An example of X-ray images of chest in this study, (b) magnification of the region B in (a) and averaging of pixel values

理条件それぞれについて 128 の入力パターン, つまり計 1,536 の入力パターンを得た。

図 3 は, 上記の手順を用いて図 2(a) の領域 B から得られた 12 の入力パターンを示している。横軸の“0”および“1”はそれぞれ, 図 2(b) に示すサンプリングパターンの下端“0”および上端“1”に対応する。図 3 の各図の番号左側の a, b, c はそれぞれ, 画素値平均, 1 次微分および 2 次微分パターンを意味しており, 右側の数字はパターンのデータ数に対応する。数字が大きいほどデータ数が少ないことを意味している。(a-1)~(a-4) の縦軸は画素値または画素値の平均値であり, 数値が大きいほど明るい表示であることを意味している。(a-1)~(a-4) のデータ数はそれぞれ, 128, 64, 32 および 16 である。(b-1)~(b-4) はそれぞれ画素値平均入力パターン (a-1)~(a-4) から得た 1 次微分入力パターンであり, 各図の縦軸は, 画素値平均入力パターンの隣接画素間の差である。(c-1)~(c-4) はそれぞれ 1 次微分入力パターン (b-1)~(b-4) から得た 2 次微分入力パターンであり, 各図の縦軸は, 1 次微分入力パターンの隣接画素間の差である。(a-1)~(a-4) から, データ数の減少に対応して, 画素値平均入力パターンが平滑化されていることが分かる。この平滑化の進行に対

応して, (b-1)~(b-4) の 1 次微分入力パターン, および (c-1)~(c-4) の 2 次微分入力パターンは, 画素値平均入力パターンの局所的な変化の影響を受けた波形から, 全体的な形状を捉えた波形へと変化している。肺野 X 線像からサンプリングした 1 次元数値列を前処理して得たこれらのパターンを, 我々はニューラルネットワークの学習およびテスト用の入力パターンとして用いた。

2.3 異常陰影検出ニューラルネットワーク

図 4 は, 本研究で異常陰影の検出に用いたニューラルネットワークの構成を示している。入力層, 出力層, および 1 層の中間層から構成される 3 階層型のニューラルネットワークを使用した。入力層-中間層ユニット間, および中間層-出力層ユニット間を結ぶ線で示す通り, 入力層の各ユニットを中間層の全てのユニットと結合させ, 中間層の各ユニットを出力層のユニットと結合させた。更に各ユニット間の結合には, それぞれ重みを付与した。ネットワークの学習アルゴリズムには, バックプロパゲーション法 [15] を用いた。学習用入力パターンに与える教師信号として, 異常陰影を

図3 サンプリングパターンに対する前処理によって得られた1次元入力パターンの例
 (a-1)~(a-4) 画素値平均入力パターン, データ数は順に 128, 64, 32, 16,
 (b-1)~(b-4) 1次微分入力パターン, データ数は順に 127, 63, 31, 15,
 (c-1)~(c-4) 2次微分入力パターン, データ数は順に 126, 62, 30, 14 である。

Fig.3 Examples of input patterns which were obtained by pre-processing sampled patterns, (a-1)~(a-4) were input patterns of averaged pixel values, where the numbers of data were 128, 64, 32 and 16, respectively, (b-1)~(b-4) were input patterns of 1st order differential coefficients, where the numbers of data were 127, 63, 31 and 15, respectively, (c-1)~(c-4) were input patterns of 2nd order differential coefficients, where the numbers of data were 126, 62, 30 and 14, respectively

図4 本研究で用いた階層型ニューラルネットワーク
Fig.4 A hierarchical neural network in this study

有する入力パターンには"0", 正常入力パターンに対して"1"を与えた。教師信号とニューラルネットワークからの出力値との誤差二乗和を減少させるため, 次式を用いて各ユニット間の重みの更新を繰り返した。

$$\Delta w_{kj}(n) = -\eta \frac{\partial E}{\partial w_{kj}(n)} + \alpha \Delta w_{kj}(n-1) \quad (1)$$

ここで, $\Delta w_{kj}(n)$ は学習 n 回後におけるユニット k とユニット j との間の重み更新量, η は学習係数, E は教師信号とネットワーク出力値との誤差二乗和, α は慣性係数, $\Delta w_{kj}(n-1)$ は学習 $n-1$ 回後における重み更新量を示している。入力層ユニット数は, 各入力パターンの1パターン当たりのデータ数と対応させ, 出力層ユニット数は, いずれの場合も1とした。中間層ユニット数, η および α は, それぞれ10~150, 0.0001~0.05 および 0.04~0.05 の範囲で変化させ, ニューラルネットワークの学習回数に対する誤差の減少を確認しながら実験的に求めた。なお, ニューラルネットワークの学習終了条件は, 誤差二乗和 $E \leq 0.02$ とした。

2.4 評価

ニューラルネットワークシステムの未学習画像に対する判定性能, すなわち汎化能力を評価するため, 肺野X線像から得た入力パターンを, ネットワークの学習に使用する学習パターンとネットワークのテストに使用する未学習のテストパターンとに分けた。このとき, テストパターンの数を増やすと, 学習パターン数が減少し, システムの判定性能が低下した。そこで, 本研究におけるニューラルネットワークの学習は, 前処理条件の等しい128入力パターンの中から1画像分の4パターンを除いた124パターンを用いて行った。ニューラルネットワークのテストは, 学習終了後のネットワークに, 学習時に除いた1画像分の4パターンを

図5 入力パターンの前処理条件を変化させた場合の学習回数に対するニューラルネットワークの誤差二乗和

Fig.5 Square errors in neural networks as a function of the number of learning iterations for input patterns pre-processed at several conditions

入力することによって行った。この学習およびテストを, 学習時に除く画像を変えながら繰り返し行い, 全ての画像(パターン)を未学習画像として用いたテスト結果を得た。更に, 上記の学習およびテストを前処理条件の異なる入力パターンを用いて行い, 各前処理条件に対するニューラルネットワークのテスト結果を得た。この方式は, パターン集合を m 分割し, そのうちの1つをテストに使用し, 残りの $m-1$ 個を学習に用いた m 重交叉検証法 [16] と呼ばれるものであり, 画像認識性能に関する評価法の一つである。

システムの判定性能の比較は, これらのテスト結果から等価エラー率 [17] と AUC 値 [11] を求めることによって行った。等価エラー率は, バイオメトリクス認証システム等の性能指標として用いられており, ニューラルネットワークの判定しきい値に対する偽陽性率 (False Positive Fraction, FPF) および偽陰性率 (False Negative Fraction, FNF) から求めることができる。FPF は正常と判断すべきパターンを誤って異常と判断したエラー率であり, FNF は異常と判断すべきパターンを誤って正常と判断したエラー率である。両者が等しい値を持つしきい値におけるエラー率が, 等価エラー率である。従って, これはシステムの判定エラー率そのものを使った性能評価指標である。この等価エラー率を用いて, 入力パターンへの前処理に対するシステムの判定性能を比較した。一方, AUC 値は, FPF と真陽性率 (True Positive Fraction, TPF)

図 6 ニューラルネットワークのしきい値に対する偽陰性率と偽陽性率の例

Fig.6 Examples of FNF (False Negative Fraction) and FPF (False Positive Fraction) as a function of threshold of a neural network

図 7 ニューラルネットワークの入力層ユニット数に対する等価エラー率

Fig.7 Equal error rates of neural networks as a function of the number of units in input layer

の関係をプロットすることで得られる ROC(Receiver Operating Characteristic) 曲線から求められる。TPF とは、異常と判断すべきパターンを正しく異常と判定した割合である。ROC 曲線下側の面積が AUC(Area under ROC Curve) であり、これは医療画像に対する判定性能指標の一つとして用いられている。この AUC 値を用いて、本研究結果を文献 [3], [4] の結果と比較した。

3. 結果と検討

3.1 学習によるネットワークの収束

図 5 は、入力パターンの前処理条件を変化させた場合の学習回数に対するニューラルネットワークの誤差二乗和の例を示している。ここでは、画素値平均、1 次微分および 2 次微分の入力パターンを用い、1 パターンあたりのデータ数、すなわちニューラルネットワークの入力層ユニット数がそれぞれ 128, 127 および 126 の場合の結果を示した。いずれの入力パターンに対しても、学習回数に対して誤差二乗和は減少し、所定の学習終了条件に到達した。ここには示さないが、他の前処理条件の場合においても、本結果と同様、学習回数に対して誤差二乗和は減少し、学習終了条件に到達することが確認できた。従って、本研究で用いた画素値平均、1 次微分および 2 次微分のいずれの入力

図 8 ROC (Receiver Operating Characteristic) 曲線の例

Fig.8 An example of ROC curve

パターンを用いた場合においても、ニューラルネットワークは収束することが分かった。

3.2 未学習パターンに対するネットワークの判定性能

3.2.1 等価エラー率による評価

図 6 は、ネットワークのしきい値に対する偽陰性率 (False Negative Fraction, FNF) と偽陽性率 (False Positive Fraction, FPF) の一例を示している。ここで

図9 画素値入力パターンに伴う ROC 曲線での判定性能の比較
(a), (b), (c) は, 画素値平均入力パターン, 1 次微分入力パターン,
および 2 次微分入力パターンによる ROC 曲線である。

Fig.9 ROC characteristics of neural networks at several numbers of units in input layer, where the kinds of input patterns in (a), (b) and (c) were averaged pixel values, 1st order differential coefficients and 2nd order differential coefficients, respectively

は, 画素値平均入力パターンを用い, ニューラルネットワークの入力層ユニット数が 16 の場合の結果を示した。黒丸のプロットは, FNF を表しており, これは異常と判断すべきパターンを誤って正常と判断したエラー率である。白の四角プロットは, FPF を表しており, これは正常と判断すべきパターンを誤って異常と判断したエラー率である。ともに値が小さいほど, システムの汎化能力が高いことを意味している。図より, FNF はしきい値の増加に対して減少し, FPF はしきい値の増加に対して増加しており, しきい値 0.4 付近において両者は交差していることが分かる。この交差点におけるエラー率が等価エラー率であり, この場合は 7% であった。また, 本結果は, しきい値の変更によって, 検出性能の変更が可能であることを示している。例えば, しきい値を 0.6 とした場合の FNF および FPF は, それぞれ 5% および 9% である。しきい値 0.4 付近における等価エラー率 7% に比べ, FPF は増加するが, FNF, すなわち異常陰影の見落としを少なくすることができる。ニューラルネットワークを用いた本システムが有するこのような特徴は, 実際の臨床において, FPF や FNF の値を見ながら適切な検出性能を定める上で好都合である。

図 7 は, 入力パターンの前処理条件を変化させた場合のニューラルネットワークの入力層ユニット数に対するシステムの等価エラー率を示している。画素値平均入力パターンを用いた場合の等価エラー率は, 1 次

微分および 2 次微分入力パターンを用いた場合より低かった。特に, ニューラルネットワークの入力ユニット数が 16 および 32 の時, 等価エラー率は最も低く, その値は 7% であった。これは, 正常パターンおよび異常パターンそれぞれの 93% が, このシステムによって正しく判定できたことを意味する。以上の結果から, 1 次元数値列パターンを用いた肺野 X 線像の異常陰影検出システムの汎化能力は, 入力パターンの前処理条件の影響を受けて変化する傾向が判明した。また, 本システムによって正しく判定できたパターンおよび判定できなかったパターンは, 入力パターンの前処理条件や入力層ユニット数によって変化した。これは, 異なる入力パターンを用いたシステムを組み合わせることによって検出性能が改善される可能性があることを示唆している。なお, 本システムによって正しく判定できたパターンと判定できなかったパターンとの間で, それらの症例やパターン形状等について, はっきりした違いは見られなかった。

3.2.2 ROC 解析による評価

図 8 は, システムの判定性能を ROC 曲線の形式で示した例である。図 6 の場合と同様, 画素値平均入力パターンを用い, ニューラルネットワークの入力層ユニット数が 16 の場合の結果を示した。ROC 曲線から得られた判定性能は, 図中グレーで示した ROC 曲線下側の面積 (AUC 値) を用いて評価される。この場合

図 10 ニューラルネットワークの入力層ユニット数に対する AUC 値の比較：文献 [3], [4] による AUC 値
Fig.10 Values of AUC as a function of the number of units in input layer: Values of AUC from the references [3] and [4]

の AUC 値は 0.95 であった。

図 9 は、前処理条件が異なる入力パターンを用いた場合のシステム判定性能の ROC 曲線を示している。ここでは、ROC 曲線の左上部 (図 8 の点線部) の結果を示し、各前処理条件における ROC 曲線のグラフ上の位置を比較した。(a), (b), (c) はそれぞれ画素値平均、1 次微分、および 2 次微分の入力パターンを用いた場合の結果を示している。(a) の ROC 曲線は、(b) および (c) に示した ROC 曲線に比べ、左上に位置していることが分かる。例えば、(a) における ROC 曲線は、FPF0.2 において TPF は 0.9 より大きい値であるが、(b) および (c) では、FPF0.2 における TPF は 0.9 以下である。この結果は、画素値平均入力パターンを用いた場合のシステム判定性能が、1 次微分や 2 次微分の入力パターンを用いた場合より高いことを示唆している。

図 10 は、前処理条件が異なる入力パターンを用いた場合のニューラルネットワークの入力ユニット数に対する AUC 値、ならびに文献 [3], [4] から得られた AUC 値を示している。画素値平均入力パターンを用いた場合の AUC 値は、1 次微分および 2 次微分入力パターンを用いた場合より高かった。従って、AUC 値および等価エラー率の両評価から、画素値平均入力パターンを用いた場合に高い判定性能が得られることが分かった。なお AUC 値は、画素値平均入力パターン

を用い、ニューラルネットワークの入力層ユニット数 16 の場合に最も高く、その値は 0.95 であった。

図中の Ref.[3] および Ref.[4] はそれぞれ、文献 [3], [4] で報告された最も高い AUC 値を示している。Ref.[3] は 0.88 であった。この結果は、肺野 X 線像から抽出した 2 次元画像情報の画素値をニューラルネットワークに入力して肺結節の検出を行うことによって求めている。ここでは 2 次元情報の抽出のため、背景補正やパターンマッチング等の画像処理が行われた。なお、ニューラルネットワークの入力層ユニット数は 256 であった。また、Ref.[4] は 0.96 であった。しきい値処理等を用いて肺野 X 線像から抽出した 2 次元画像情報にガウスフィルタと微分フィルタを適用して得た入力パターンをニューラルネットワークに入力し、肺結節を検出している。ここでは、入力層ユニット数が 180, 320 および 720 の 3 種類のニューラルネットワークを組み合わせ求めている。一方、本研究では、画像から抽出した 1 次元の数値列を入力データとして用いており、ニューラルネットワークの入力層ユニット数 16 の場合に、最も高い AUC 値 0.95 が得られた。この AUC 値は、比較した対象陰影は異なるが、文献 [3] の結果より 0.07 高く、文献 [4] の結果より 0.01 低かった。本研究から、肺野 X 線像から得た 1 次元情報を利用することで、2 次元情報を利用した場合と同等の検出結果が得られることが客観的に示された。更に、本研究では画像からの 1 次元数値列のサンプリングに際して背景補正やしきい値処理等の画像処理は不要であり、ニューラルネットワークの入力層ユニット数は、2 次元情報を利用した従来例に比べて 1/16~1/45 である。これらはシステム構築の容易さに寄与するものと考えられる。以上より、本研究で提案する方式は、肺野 X 線像の異常陰影検出システムの実現における有効策の一つであると考えられる。

4. おわりに

ニューラルネットワークを用いた肺野 X 線像の異常陰影検出システムの性能に及ぼす入力パターン前処理の効果进行调查した。肺野 X 線像からサンプリングした 1 次元数値列に対して画素値平均化ならびに微分処理による前処理を行い、ニューラルネットワークへの入力パターンを作成した。それらの結果、システム性能は入力パターンの前処理によって変化した。また、本研究で得られた最も良い等価エラー率および AUC 値は、それぞれ 7% および 0.95 であった。肺野 X 線像から得た 1 次元情報を利用した本システムによって、

2次元情報を用いた検出システムと同等の性能が得られることが客観的に示された。今後は、異常判定前の症例別クラスタリング、および異なる入力パターンの組み合わせを用いたシステムについて検討を進め、更なる検出性能の改善を行う。更に、病の初期兆候についてその検出方法を明らかにし、より効果的な医療診断支援システムの実現を目指す予定である。

参考文献

- [1] 安居院猛, 長橋宏, 高橋裕樹: ニューラルプログラム, 昭晃堂, 1993.
- [2] P.J.G.Lisboa: A review of evidence of health benefit from artificial neural networks in medical intervention, *Neural Networks*, Vol.15, pp. 11-39, 2002.
- [3] S.-C.B.Lo, H.-P.Chan, J.-S.Lin, H.Li, M.T.Freedman and S.K.Mun: Artificial convolution neural network for medical image pattern recognition, *Neural Networks*, Vol.8, No.7/8, pp.1201-1214, 1995.
- [4] G.Coppini, S.Diciotti, M.Falchini, N.Villari and G.Valli: Neural networks for computer-aided diagnosis: detection of lung nodules in chest radiograms, *IEEE Transactions on Information Technology in Biomedicine*, Vol.7, No.4, pp.344-357, 2003.
- [5] M.G.Penedo, M.J.Karreira, A.Mosquera and D.Cabello: Computer-aided diagnosis: A neural-network-based approach to lung nodule detection, *IEEE Transactions on Medical Imaging*, Vol.17, No.6, pp.872-880, 1998.
- [6] K.Nakamura, H.Yoshida, R.Engelmann, H.MacMahon, S.Katsuragawa, T.Ishida, K.Ashizawa and K.Doi: Computerized analysis of the likelihood of malignancy in solitary pulmonary nodules with use of artificial neural networks, *Radiology*, Vol.214, No.3, pp. 823-830, 2000.
- [7] J.Shiraishi, Q.Li, K.Suzuki, R.Engelmann and K.Doi: Computer-aided diagnostic scheme for the detection of lung nodules on chest radiographs: Localized search method based on anatomical classification, *Medical Physics*, Vol.33, No.7, pp.2642-2653, 2006.
- [8] L.Böröczky, L.Zhao and K.P.Lee: Feature subset selection for improving the performance of false positive reduction in lung nodule CAD, *IEEE Transactions on Information Technology in Biomedicine*, Vol.10, No.3, pp.504-511, 2006.
- [9] N.Asada, K.Doi, H.MacMahon, S.M.Montner, M.L.Giger, C.Abe and Y.Wu: Potential usefulness of an artificial neural network for differential diagnosis of interstitial lung diseases: pilot study, *Radiology*, Vol.177, No.3, pp. 857-860, 1990.
- [10] S.Katsuragawa and K.Doi: Computer-aided diagnosis in chest radiography, *Computerized Medical Imaging and Graphics*, Vol.31, pp. 212-223, 2007.
- [11] 石田隆行編集: よくわかる医用画像工学, オーム社, 2008.
- [12] T. Sasaki, K. Kinoshita, S. Kishida, Y. Hirata and S. Yamada: Effect of pre-processing on performance of a

neural network with one-dimensional sampling from X-ray images of chest, 2010 Sixth International Conference on Natural Computation (ICNC 2010), Vol.1, pp.257-261, Yantai, China, 2010.

- [13] T. Sasaki, K. Kinoshita, S. Kishida, Y. Hirata and S. Yamada: Effect of pre-processing and input patterns on performance of neural networks for detection of abnormal positions from X-ray images of chest, 2010 IRAST International Congress on Computer Applications and Computational Science (CACS 2010), pp.654-658, Singapore, 2010.
- [14] 佐々木貴啓, 木下健太郎, 岸田悟, 平田吉春, 山田聖悟: 胸部 X 線画像の異常位置検出へのニューラルネットワークの適用, *信学技報*, Vol.110, No.461, pp.361-366, 2011.
- [15] D.E.Rumelhart, G.E.Hinton and R.J.Williams: Learning representations by back-propagating errors, *Nature*, Vol.323, No.9, pp.533-536, 1986.
- [16] 高田幹雄, 下田陽久監修: 新編 画像解析ハンドブック, 東京大学出版会, 2004.
- [17] バイオメトリクスセキュリティコンソーシアム編集: バイオメトリクスセキュリティ・ハンドブック, オーム社, 2006.

佐々木 貴啓 1992年北見工業大学工学部卒業。1994年同大学院工学研究科修士課程修了。同年富士通(株)入社。2005年シャープ(株)へ転社。現在、鳥取大学工学部附属電子ディスプレイ研究センター(TEDREC)駐在ならびに同大学院工学研究科博士後期課程在学中。液晶ディスプレイ、画像処理、ニューラルネットワークに関する研究に従事。信号処理学会、画像電子学会、電気学会、日本液晶学会会員。

木下 健太郎 1999年立教大学理学部卒業。2001年東京大学大学院理学系研究科博士前期課程修了。2004年同博士後期課程修了。博士(学術)。同年(株)富士通研究所入社。2008年鳥取大学大学院工学研究科情報エレクトロニクス専攻助教。現在に至る。主に抵抗変化型メモリの物性に関する研究に従事。MRS, 応用物理学会会員。

岸田 悟 1977年鳥取大学大学院工学研究科修士課程修了。学術博士。現在、鳥取大学工学部附属電子ディスプレイ研究センター(TEDREC)センター長、および同大学院工学研究科情報エレクトロニクス専攻教授。ニューラルネットワークの基礎と応用に関する研究に従事。電気学会、電子情報通信学会、日本液晶学会会員。

平田 吉春 1974 年鳥取大学医学部附属病院入職。現在、同放射線部技師長。1999 年米国アリゾナ大学留学。2003 年金沢大学大学院医学系研究科保健学専攻博士前期課程修了。ディスプレイ表示の人体、視覚への影響に関わる研究に主に従事。日本放射線技術学会会員。

山田 聖悟 2003 年広島国際大学保健医療学部診療放射線学科卒業。現在、鳥取大学医学部附属病院放射線部診療放射線技師。主に、医用画像表示向け液晶ディスプレイの性能改善、評価に関する研究に従事。日本放射線技術学会会員。

(2011 年 6 月 3 日受付, 7 月 26 日再受付)