

テクスチャ領域を抽出するニューラルネット学習モデルの 識別関数選定

藤本 勉†

A Selection of Transfer Function of Neural Network Learning Model
for Textural Region Segmentation

Tsutomu FUJIMOTO†

Abstract: In a scheme of construction of a region segmentation system for sea-fog area, several type of transfer function and the best unit number of hidden layer of a 3-layerd neural network that models texture characteristics shown at sea-fog area are investigated. Sigmoid, Gaussian, hyperbolic tangent and hyperbolic secant transfer function are compared in the point of remaining error and training speed. It is found Gaussian transfer function is the best for sea-fog area modeling. One to fifty units of a hidden layer examined in accuracy and training speed, and no more five units of a hidden layer is necessary for the above propose. The best unit number is around 10 units.

Keyword: Transfer function, Neural network, APT, NOAA, Fog

1. まえがき

極軌道衛星 (NOAA) が直接送信する低分解能画像データ (APT; Automatic Picture Transmission Data) のリモートセンシングは、パソコンを中核とする比較的簡易なシステムで実施可能であり、漁船などにおいて実用に供されている。しかし、データのレベル分解能、および空間分解能の制限から学術的研究の対象になることが少なく、利用技術の開発は遅れている。著者は、利用技術開発に関する研究成果の一部として、同時に取得できる近赤外 (0.725-1.0 μm) および熱赤外 (10.5-11.5 μm) 画像データのインタレース合成画像において、海霧発生域が特有なテクスチャを呈することを明らかにした[1-3]。

本論文は、海霧発生域を分離抽出するシステム構築のため、先ず同領域が呈すテクスチャ特徴量をモデル化する3層型ニューラルネットの識別関数の選定、および中間層ユニット数の最適決定を述べる。

ニューラルネットの設計において、ニューロンの連続値モデルの識別関数としては、形式ニューロン (McCulloch-Pitts, 1943) に採用されたヘビサイド関数を滑らかにして、連続値をとる関数に置き換えたシグモ

イド関数が用いられることが多い。しかし実際問題としては、全てのユニットの識別関数を同一にする必要はなく、シグモイド関数以外の使用も考えられる。シグモイド関数以外の選択により、高速で汎化能力に富んだ学習を行うニューラルネットの構築が期待される。シグモイド関数、ガウス関数、双曲線正接関数、及び双曲線正割関数について調査した結果、従来採用されてきたシグモイド関数に代わり、ガウス関数が学習時間、モデルの精度においても優位であることを明らかにする。

次に、中間層のユニット数について、ユニット数が少なければ解けない問題が存在し、多すぎれば学習時間が長くなる。ネットワークの設計に当っては、学習後のネットワークにとって必要とされる精度を達成する最小のユニット数を選定するのが望ましく、実際には、問題に応じて試行錯誤的に中間層ユニットの数を決定していく必要がある。1から50までのユニット数を調査した結果、ユニット数が5を超えると精度の向上は僅少になり、ユニット数10程度で十分であることを明らかにする。

2. 多階層形ニューラルネットワーク

試みた後向き誤差伝播学習則 (Backpropagation) の概要を図 2.1 により述べる。

1. 入力層 (第1層) の第 i ノードに入力されたトレーニングパターン系列 $s(p, i)$ は、値が0から1の範囲に

† 宇部工業高等専門学校電気工学科, 宇部市
Department of Electrical Engineering, Ube National College of
Technology, Ube-shi, Yamaguchi, 755 Japan

なるよう正規化した後、最初の隠れ層に出力する。

$$x(p, i, 1) = \frac{s(p, i) - \min\{s(p, i)\}}{\max\{s(p, i)\} - \min\{s(p, i)\}} \quad (2.1)$$

2. 第 ℓ 層 (隠れ層、及び出力層) の第 k ノードに供給された前の層からの出力は、結合の重み $\omega(j, k, \ell)$ との積和がとられ、オフセット値 $B(k, \ell)$ を加えて内部ポテンシャルを形成する。

$$y(p, k, \ell) = \sum_j x(p, j, \ell-1) \omega(j, k, \ell) + B(k, \ell) \quad (2.2)$$

ここに、 j は第 $\ell-1$ 層のノード数である。この内部ポテンシャルは、各ノードに固有の識別関数 $f\{\}$ により、この層からの出力を形成する。

$$x(p, k, \ell) = f\{y(p, k, \ell)\} \quad (2.3)$$

3. 出力層からの出力 $x(p, m, o)$ は、教師パターン $\hat{x}(p, m)$ との比較により誤差関数 $E(p, m, o)$ として評価される。

$$E(p, m, o) = \{x(p, m, o) - \hat{x}(p, m)\} x'(p, m, o) \quad (2.4)$$

ここに、 $x'(p, m, o) = f'\{y(p, m, o)\}$ は、識別関数の第 1 次導関数である。

4. 隠れ層 (第 ℓ 層) の第 k ノードの誤差 $E(p, k, \ell)$ は、次の第 $\ell+1$ 層の誤差が後向きに伝播し、次式で計算される。

$$E(p, k, \ell) = x'(p, k, \ell) \sum_n \{E(p, n, \ell+1) \omega(k, n, \ell+1)\} \quad (2.5)$$

ここに、 n は次の第 $\ell+1$ 層の第 n ノードを示す。

5. これより、第 $T+1$ 回反復学習時の結合の重みの修正量は、

$$\begin{aligned} \Delta\omega(j, k, \ell)_{T+1} &= \omega(j, k, \ell)_{T+1} - \omega(j, k, \ell)_T \\ &= \eta \sum_p \{E(p, k, \ell) x(p, j, \ell-1)\} + \alpha \{\omega(j, k, \ell)_T - \omega(j, k, \ell)_{T-1}\} \end{aligned} \quad (2.6)$$

で求める。ここに η は学習定数、 α は慣性定数である。

6. 以上の反復学習を設定回行った後、残留している誤差を次式で算出する。

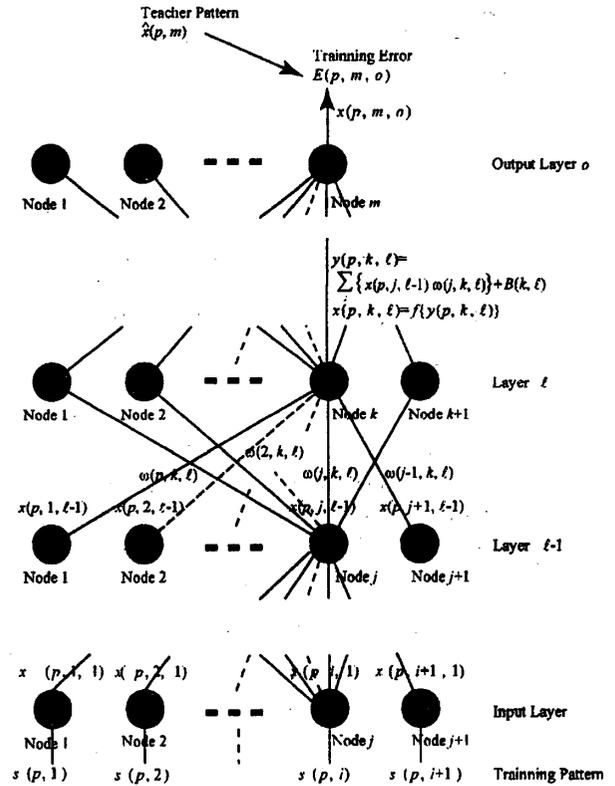


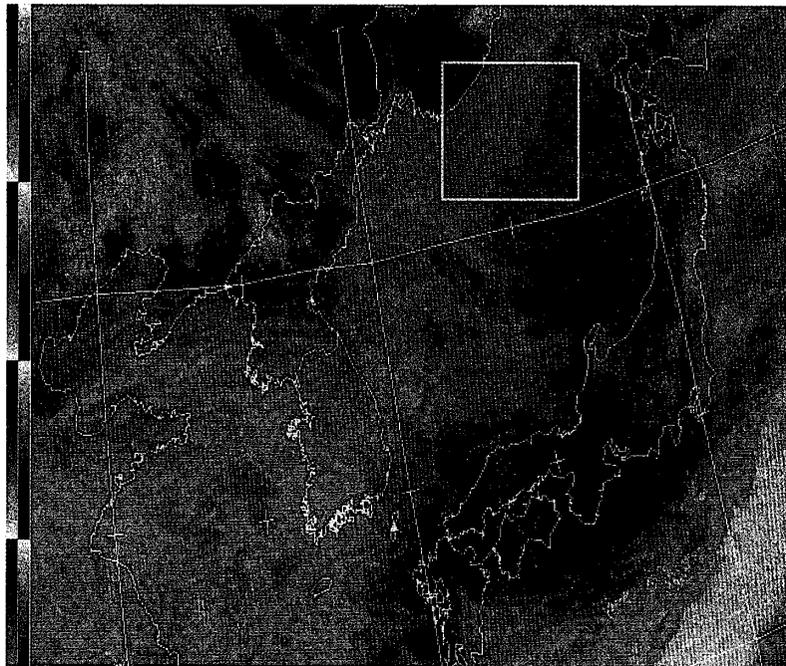
Fig. 2.1 Multi-Layer Neural Network

$$RMS\ Error = \sqrt{\frac{\sum_p \sum_m \{x(p, m, o) - \hat{x}(p, m)\}^2}{P_T K_T}} \quad (2.7)$$

p は p 番目のトレーニングパターンであり、 k は第 k ノードである。 P_T は全トレーニングパターン数、 K_T は出力ノード数である。

3. トレーニングデータ

トレーニングに使用した画像を図 3.1 に示す。1994 年 6 月 6 日、0 時 21 分 (UTC) から受信した NOAA-9 の APT 画像データである。APT-CH.A (AVHRR-CH.2, 近赤外) データは、アルベド値に変換し、APT-CH.B (AVHRR-CH.4, 熱赤外) データは、著者が提案している高分解能データ (HRPT) の温度変換法に準拠する方法 [4] を使って輝度温度に変換したのち、インタレース合成したものである。沿海州にある大規模な海霧は、近赤外バンドでは、雲域と同じく白色を呈し、高アルベド値を示す。一方、海霧は海面高度にあるため、熱



940606 0021Z, ch.2 & 4 interlaced, Nakhodka.

Fig. 3.1 Interlaced NOAA-APT Image. APT-CH.A(AVHRR-CH.2, Near-IR) and APT-CH.B(AVHRR-CH.4, Thermal-IR) are interlaced. NOAA-9, 1994 June 6, 0041Z.

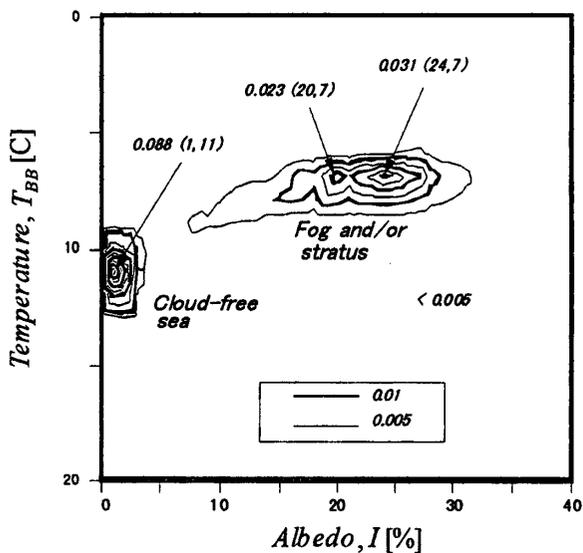


Fig. 3.2 Co-occurrence Probability of Sea-Fog Area and Cloud-Free Sea, off Nakhodka, Russia. NOAA-9, 1994 June 6, 0041Z.

赤外バンドでは、海面温度と類似の温度を示し、黒色を呈す。従って、インタレース合成した画像においては、白色及び黒色を呈す走査線が、交番ライン状のテクスチャを示す。テクスチャを定量化する手段として、

インタレース合成画像の第 $2k$ 走査線 (近赤外バンド) 上の第 j 番目画素が示すアルベド値 $v(j, 2k)$ と、第 $2k + 1$ 走査線 (熱赤外バンド) 上の第 j 番目画素が示す輝度温度 $t(j, 2k + 1)$ との同時生起確率 $p\{v(j, 2k), t(j, 2k + 1)\}$ を調べた。図 3.1 の白線枠内を調査した結果を図 3.2 に示す。海霧発生域は、輝度温度の変動幅は、約 1°C と小さいが、アルベド値は大きく変動する。そのために同時生起確率の分布パターンは、アルベド軸を長軸とする楕円状となることが明らかになった。

4. ニューラルネットの学習実験

前節において求めた海霧発生域が呈する同時生起確率の分布パターンモデルを生成する 3 階層形ニューラルネットを構築し、その学習結果を調査した。

入力層は、 $v(j, 2k)$ 、及び $t(j, 2k + 1)$ を入力する 2 ノードであり、出力層は、 $p\{v(j, 2k), t(j, 2k + 1)\}$ のモデル値を出力する 1 ノードである。

第 2 層 (中間層、隠れ層) のノード数を 1 から 50 まで変化し、同時に第 2 層、及び出力層の識別関数(2.3 式)を図 4.1 に示す、

- (1).シグモイド関数

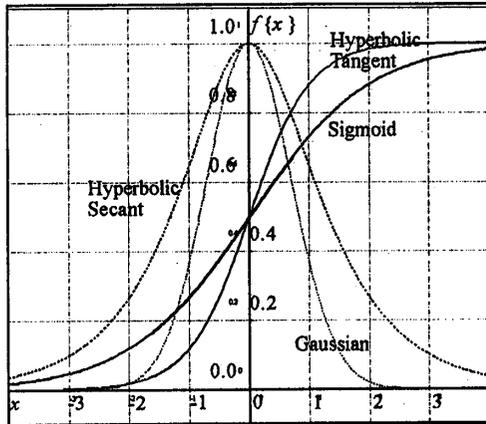


Fig. 4.1 Transfer Functions

$$x(p, k, \ell) = \frac{1}{1 + e^{-y(p, k, \ell)}} \quad (4.1)$$

(2). ガウス関数

$$x(p, k, \ell) = e^{-\{y(p, k, \ell)\}^2} \quad (4.2)$$

(3). 双曲線正接関数

$$x(p, k, \ell) = \frac{\tanh\{y(p, k, \ell)\} + 1}{2} \quad (4.3)$$

(4). 双曲線正割関数

$$x(p, k, \ell) = \operatorname{sech}\{y(p, k, \ell)\} \quad (4.4)$$

に変えて試みた。なお、学習定数 (η) は、 10^{-4} に、慣性定数 (α) は、0.85 に固定した。学習回数は、シグモイド関数以外は 10^6 回に、シグモイド関数は学習状態の収束が不十分であったので、 2×10^6 回にして実施した。

図 4.2 は、第 2 層のノード数に対する学習終了時の残留誤差を示している。ノード数が 5 以上であれば、顕著な違いはない。残留誤差は、ガウス関数の場合が最も少なく、ノード数 5 から 50 における平均誤差は 3.7×10^{-2} 、標準偏差は 1.8×10^{-3} であるのに対し、シグモイド関数は誤差が最も多く、ノード数 5 から 50 における平均誤差 7.0×10^{-2} 、標準偏差 5.6×10^{-3} なる結果を得た。双曲線正接関数、及び双曲線正割関数の場合は、両者の中間になる。

図 4.3 は、第 2 層のノード数に対する学習終了時の実データ (図 3.2) に対する学習モデルの相関係数を示

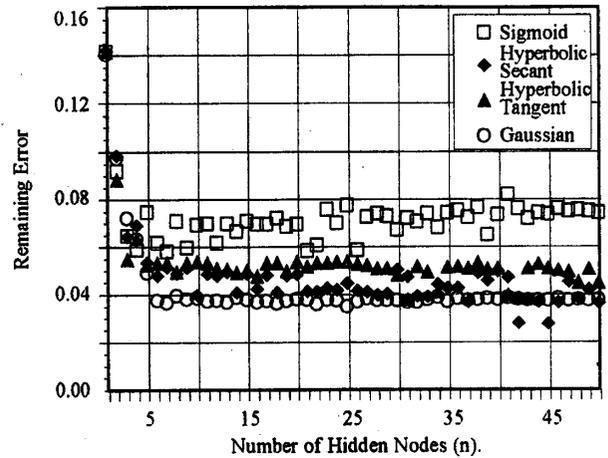
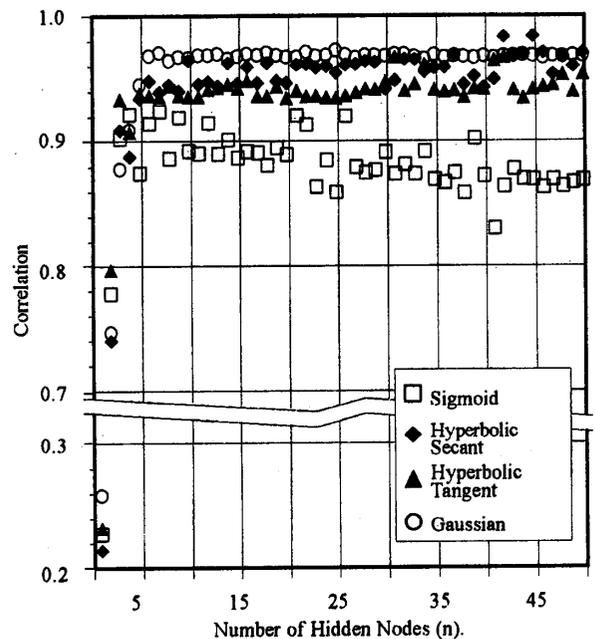


Fig. 4.2 Number of Nodes of Hidden Layer vs. Remaining Model Error.

Fig. 4.3 Number of Nodes of Hidden Layer vs. Correlation between Learning Model and Actual $P\{v(j, 2k), r(j, 2k+1)\}$.

している。ノード数が 5 以上であれば、顕著な違いはない。ガウス関数の場合が、最も相関が高いモデルが学習されており、ノード数 5 から 50 における平均値は 0.966、標準偏差は 3.7×10^{-3} であるのに対し、シグモイド関数はノード数 5 から 50 における平均値が 0.882、標準偏差が 19.6×10^{-3} なる結果を得た。双曲線正接関数、及び双曲線正割関数の場合は、両者の中間になる。

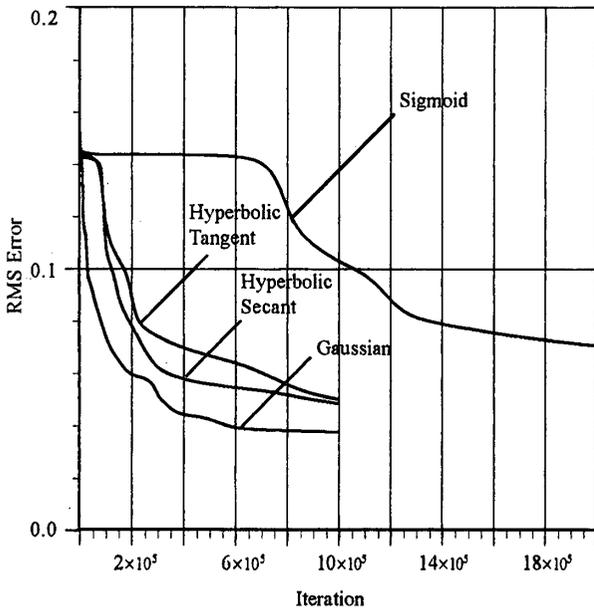


Fig. 4.4 Error History of Sigmoid, Gauss, Hyperbolic Tangent and Hyperbolic Secant transfer Function Neural Networks.

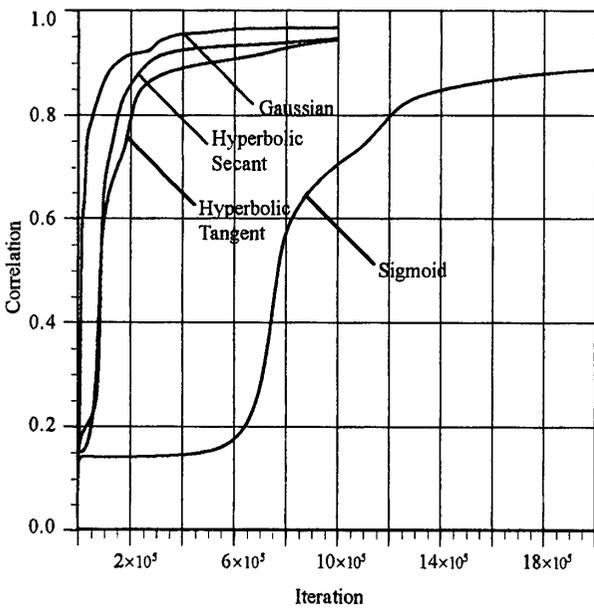


Fig. 4.5 History of Correlation between Laming Model and Actual $P\{v(j, 2k), t(j, 2k+1)\}$.

上の結果、いずれの識別関数を採用した場合も、第2層のノード数は5以上が適当であると結論できるので、次に第2層のノード数が15の場合に限定して、学習の進行状況を比較した。

図4.4は、2-15-1 ノード数のニューラルネットの繰り

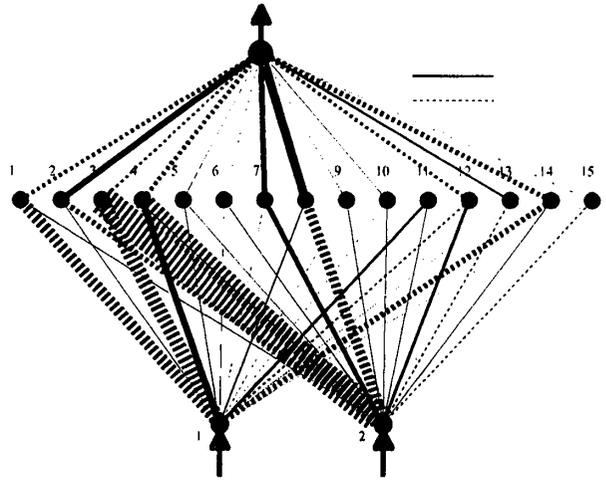


Fig. 5.1 2-15-1 Node Neural Network Model of Sea-Fog Area. Solid Lines show + weight, Dotted lines show - weight. Line width corresponds to weight value.

返し回数に対する残留誤差の減少の様子を表わしている。この図においても識別関数にガウス関数を採用した場合が、誤差の減少が最も早いことが分かる。双曲線正割関数の場合もほぼ同様である。シグモイド関数を採用した場合、その履歴は非常に特徴的な経過を辿り、学習回数が60万回を超えたところで、急速誤差の減少が始まる。

図4.5は、繰り返し回数に対する相関の変化を表わしている。識別関数にガウス関数を採用した場合が、相関の増加が最も早く、双曲線正割関数の場合もほぼ同様である。シグモイド関数を採用した場合は、学習に長い時間が掛かり、ガウス関数の場合の大略2倍は必要である。

5. 海霧発生域のモデル

前節の結果に基づいて、ガウス関数を識別関数に持つ3層ニューラルネットにより、海霧発生域が示す同時生起確率の分布パターンのモデルを構築した。採用したニューラルネットは2-15-1のノード数を有す。図5.1に、モデルを示している。同図において実線のパスは結合の重みが正值のものであり、点線は負値のパスである。パスの線幅は結合の重みの大きさに比例している。

図5.2は、本ニューラルネットが出力した海霧発生域の同時生起確率 $p\{v(j, 2k), t(j, 2k+1)\}$ の分布パターンのモデルである。実データ(教師データ、図3.2)と

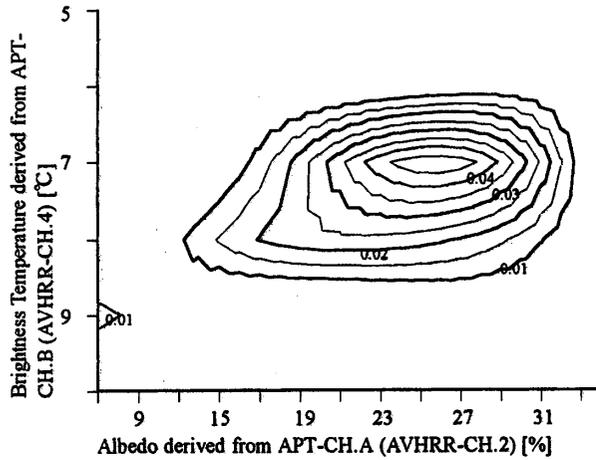


Fig. 5.2 Learning Model of $p\{v(j, 2k), t(j, 2k+1)\}$ constructed by 2-15-1 Node Gaussian Neural Network.

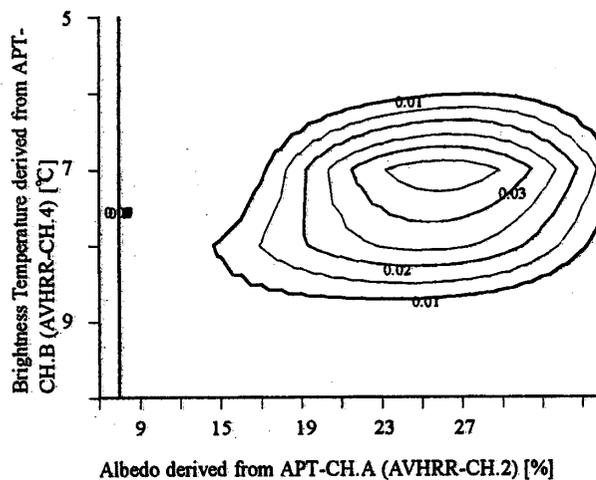


Fig. 5.5 Learning Model of $p\{v(j, 2k), t(j, 2k+1)\}$ constructed by 2-15-1 Node Sigmoid Neural Network.

比較すると細部についてはモデル化出来ていない部分もあるが、全体的には満足できるものである。これを確認するために、 $p\{v(j, 2k), t(j, 2k+1)\} > 0.01$ の画素対 $(j, 2k), (j, 2k+1)$ を表示したものを図5.3に、比較のため原画像(図3.1)から同じ領域を拡大したものを図5.4に示している。本ニューラルネットは1画素対(2画素)につき1画素を出力するため、走査線本数が半分に減じてはいるが、概ね良好なモデルであるといえる。図5.5は、比較のため識別関数にシグモイド関数を採用

した2-15-1ノード数のネットワークが出力した同時生起確率 $p\{v(j, 2k), t(j, 2k+1)\}$ の分布パターンのモデルである。明らかに、ガウス関数を採用した場合の方が、モデルの精度がより高いことが分かる。

6. 結果の検討、及びむすび

海霧発生域を分離抽出するシステム構築のため、先ず同領域が呈すテクスチャ特徴量をモデル化する3層型ニューラルネットの識別関数の選定、および中間層ユニット数の最適決定を述べた。

ニューラルネットの設計において、ニューロンの連続値モデルの識別関数としては、シグモイド関数が用いられることが多い。しかし実際問題としては、シグモイド関数以外の使用も考えられる。シグモイド関数以外の選択により、高速で汎化能力に富んだ学習を行うニューラルネットの構築が期待される。海霧発生域の同時生起確率の分布パターンを対象にして、シグモイド関数、ガウス関数、双曲線正接関数、及び双曲線正割関数について調査した結果、従来採用されてきたシグモイド関数に代わり、ガウス関数が学習時間、モデルの精度においても優位であることが明らかにした。

次に、中間層のユニット数について、ユニット数が少なければ解けない問題が存在し、多すぎれば学習時間が長くなる。ネットワークの設計に当っては、学習後のネットワークにとって必要とされる精度を達成する最小のユニット数を選定するのが望ましく、実際には、問題に応じて試行錯誤的に中間層ユニットの数を決定していく必要がある。1から50までのユニット数を調査した結果、いずれの識別関数を採用した場合にあっても、ユニット数が5を超えると精度の向上は僅少になり、ユニット数10程度で十分であることを明らかにした。

7. 参考文献

- [1] 藤本 勉：ラインインターレースによる気象衛星ノア-APT処理、動画像計測処理研究会、画像計測とその応用技術に関する特別講演会&シンポジウム、pp. 15-20 (1994-7)
- [2] 藤本 勉：NOAA-APTによる霧または層雲域の観察、日本リモートセンシング学会第17回(平6秋季)学術講演会論文集、pp. 139-142 (1994-12)
- [3] 藤本 勉：インターレースNOAA-APTによる海霧域の観察と、統計的テクスチャ特徴に基づく定性化、日本リモートセンシング学会誌、Vol. 15, No. 5, pp. 34-44 (1996-1)

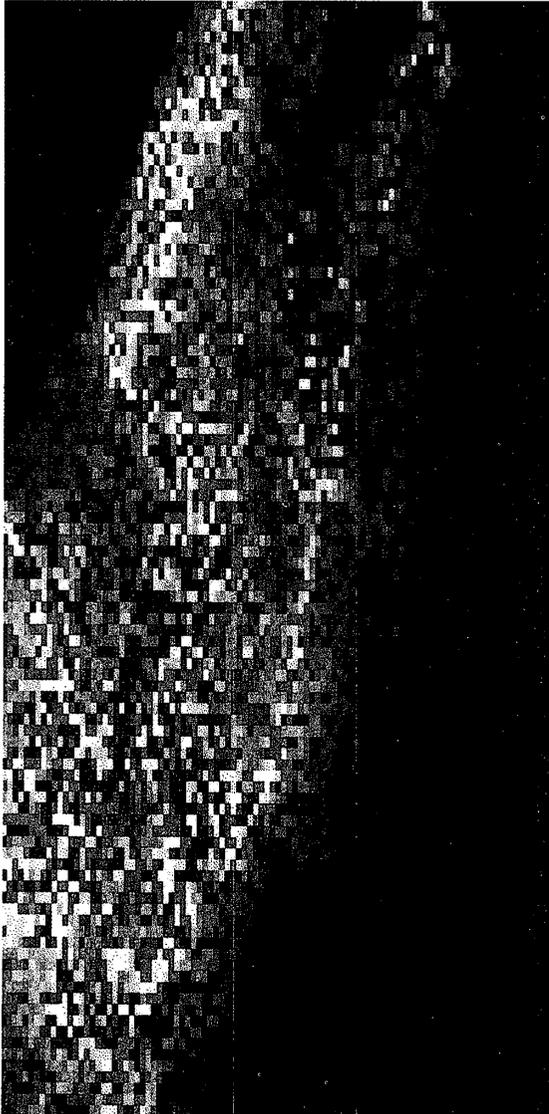


Fig. 5.3 Sea-Fog Region Segmented by 2-15-1 Node Gaussian Transfer Function Neural Network.



Fig. 5.4 Interlace NOAA-APT Image of Sea-Fog Area, Japan Sea off Nakhodka, Russia. NOAA-9, 1994 Jun 6, 0021Z.

- [4] 藤本 勉, 三池秀敏 : 低分解能赤外衛星画像 (NOAA APT) のオンライン温度変換と精度評価, 電子情報通信学会論文誌, Vol. J79-B-II, No. 11, pp. 933-940 (1996-11)
- [5] 白井 支朗, 岩田 彰ほか : 基礎と実践ニューラルネットワーク, コロナ社, (1995-10)
- [6] 中野 肇, 坂口 豊ほか : ニューロコンピュータの基礎, コロナ社 (1991-11)

(平成9年9月24日受理)