

4. 胸部 X 線画像における画像再生

胸部 X 線画像は X 線画像の中で最も頻繁に撮影される画像であり、人の全体的な健康状態を診断するために使用される。特に日本においては結核、肺ガン検診のために胸部 X 線画像撮影のマス・スクリーニングが行われている。従来、胸部 X 線画像をデジタル化して診断能向上のために画像処理を報告は多数なされているが、人間の手による調整が必要ない自動化という点では改善の余地があった。本章では画像強調の一つのテクニックであるダイナミックレンジ圧縮 (Dynamic Range Compression, DRC) に対する新たな自動化手法を研究するのが目的であるが、同時に DRC の自動化を可能にするための肺野部のセグメンテーション方法も研究する。

4.1. では、画素毎に判定するセグメンテーション手法について研究する。セグメンテーションの際の特徴量は、各画像の解剖学的相対アドレス、相対濃度、およびエントロピーを使用し、ニューラルネットワークを用いて判断を行っている。4.2. では、Profile ベースのセグメンテーション手法を研究する。画像を1次元 Profile に分解して処理を行い、2 次元に再構成した後に後処理をして、肺野の輪郭を抽出する。4.3. では、4.1. のセグメンテーション結果を利用して、解剖学的情報を利用した画像処理パラメータの自動化手法を研究する。ここで導入する画像処理手法 ADRC、AHEQ はいずれも肺野と縦隔部の解剖学的なセグメンテーションの結果をもとに処理パラメータが決定される。

4.1. 解剖学的特徴量を使用した胸部画像のセグメンテーション

胸部 X 線画像は全世界的にみて代表的な診断画像であり、このデジタル画像を素材にして様々な研究がなされている。[4.1.1-4.1.5] 胸部 X 線画像からの解剖学的構造の抽出は、(1) 解剖学的情報をもとにパラメータを決定する画像処理、(2) 肺野内部に限定して石灰化等の病気を検出する自動検出、あるいは(3) 解剖学的構造をベースに圧縮率を制御する画像圧縮、等に非常に有効である。たとえば、視覚的に全く性質の異なる肺野、縦隔、横隔膜下の領域を抽出して、それぞれに対して異なる画像処理を適用して表示することは有意義なことである。

画像エンハンスメント手法の一つであるダイナミックレンジ圧縮 (DRC) を解剖学的な情報をもとに行う手法 (ADRC) を 4.3. で示すが、そこでは肺野の微細構造を保存しながら肺野全体のダイナミックレンジを圧縮する。[4.1.5] 桂川は肺野のテクスチャーを数量化することにより間質性肺疾患の検出を行っているが、その際に

Nodular、Honeycomb、および Reticular-Pattern の出現エリアを制限するために Ribcage の検出を行っている。[4.1.1]

胸部 X 線画像中で解剖学的部分をセグメンテーションする手法は多く報告されているが、大きくは2つに分類することが可能である。一つは、濃度、周辺ヒストグラム、周辺エントロピー、Gradient、あるいは Co-occurrence マトリックスなどをもとに画素単位で分類する手法である。[4.1.6-4.1.8] 決定アプローチは閾値を使用した線形分離やニューラルネットワークが使用されるが、これらの手法の特徴は比較的安定であるにも係わらず、領域境界での分類が入り組みやすく、クリアな境界を求めるには後処理が必要な点にある。長谷川は画素値のみを入力としてもつコンボリューション型ニューラルネットワーク(Convolution Neural Network)を使用して肺野のセグメンテーションを試みた。ニューラルネットワークの出力を細線化して各点における Tangent を求め、それに基づく後処理を行うことにより肺野の輪郭を滑らかにした。[4.1.7] McNitt-Gray は、最初に画像の Gray-Level、局所的なばらつき、および局所的な Texture をもとにした特徴量のリストを導入し、次に Stepwise-Discriminant 解析をもとにした特徴量選択により、リストから何個かの特徴量を選択し、そして選択された特徴量をもとに線形分離手法やフィードフォワード型ニューラルネットワークの弁別器を学習し、また試験した。空間情報を使用して分離に失敗した画素の再分離を最後に行っている。[4.1.8]

もう一つのセグメンテーション手法は、2次元画像中の Profile や Signature (Profile を複数本平均化したもの) やカーネルからエッジを検出するものである。[4.1.9-4.1.13] これらの手法を使用して検出される X 線胸部画像中の肺の輪郭はクリアになるが、反面、パラメータ決定の際の学習画像から乖離する画像が入力された場合には輪郭が暴走してしまう懸念がある。Kruger は Anterior 胸部 X 線画像中(通常胸部画像は肩甲骨が肺野に写らないように X 線を背中から入射して撮影され、これを Post-Anterior 画像(PA 画像)と呼ぶ。しかし、Kruger は心臓に注目しているので X 線を胸から入射する Anterior 画像(AP 画像とも呼ぶ)を使用している。)から心臓病に関連する数量化された情報を取得する先駆的な研究をしたが、このなかで水平方向と垂直方向の Signature から放射線情報の変化を計算した。[4.1.9]

Powell は、PA 胸部画像から間質性肺疾患を検出する CAD (Computer-aided Diagnosis) に使用するために Ribcage を検出する手法を開発した。ここでは、Ribcage 内部に限定して Small-Texture が計算された。彼は水平方向の Signature とその 2 次の導関数を使用して Ribcage の輪郭点候補を抽出し、それらの候補を

2つの Sinusoidal 関数で Fitting した。[4.1.10] Yueも胸部画像から Rib Borders (肋骨そのもの)を検出する方法を提案しているが、そこでは概略の Rib Borders を知識ベースの Hough 変換で求めて、また抽出エリアを Ribcage の内側に限定している。[4.1.11]

XinもRibcageの境界を自動検出する手法を開発した。最初に垂直方向のProfileをもとに、肺野の上半分中から肺の平均的上端を求め、次に上端から ROI を移動しながら ROI の中で肺のエッジと Ribcage を検出する。そして、肺の上端から発生する左右の Ribcage Border にそれぞれ 3 個の多項式を Fitting させた。彼は 100 個の画像に対して主観的評価を行った。5 人の放射線医に対して 96%の Accuracy と好結果を与えることができた。しかし、ペースメーカーが画像化されているような統計的に未経験の画像に対しては、左右の肺の上端および Ribcage のエッジ抽出に対して大きく誤った結果を出力することも報告している。[4.1.12]

Duryeaも胸部画像から肺野を抽出する手法を報告している。水平 Profile を使用してそれぞれの肺の Upper-medial、Upper-lateral、Lower-medial、および Lower-lateral(それぞれ肺上部の縦隔より、肺上部の Ribcage より、肺下部の縦隔より、および肺下部の Ribcage よりの輪郭を意味する)のエッジを抽出する。このアルゴリズムは 802 例の胸部画像に対して評価され、平均 Accuracy が右肺に対しては 95.7%、左肺に対しては 96.0%と非常に高いパフォーマンスを示した。しかし、彼も右肺が全く検出できないようなケースが存在すること事を紹介している。[4.1.13]

この論文では、最初に肺野の輪郭に対して感度があり、しかも頑健である特徴量を導入し、その特徴量を適応型サイズのハイブリッドニューラルネットワーク (Adaptive-sized Hybrid Neural Network, ASH-NN) の入力としたシステムを提案し評価を行う。上で述べた分類法によると画素ベースのセグメンテーションに分類される。ここでは非常に広い分野で使用されている Error Back-Propagation で学習される多層の Feed Forward ニューラルネットワークを使用しなかった。Back-Propagation の欠点は、(1)大きなネットワークを学習するのに時間を要する、(2)ネットワークサイズ固定のネットワークであり、ネットワーク自身で Topology を変化させることが出来ない、(3)ネットワークの収束が初期ランダムウェイトに大きく影響される、の3つがあげることが出来る。ASH-NNには、(1)ニューロンの数を制御することにより問題の複雑度に対応することが出来る、(2)初期ランダムウェイトにネットワークの収束が影響されない、などのメリットがある。

4.2.では1次元の shift-invariant コンボリューションニューラルネットワーク(CNN)を使用した肺野のエッジ抽出手法を論じる。ただし、この手法ではニューラルネットワークの出力に対して、2値化とラベリングからなる後処理が適用される。最初、画像は垂直方向と水平方向の Profile に分解され、それぞれ1次元の CNN に入力されエッジの候補点が抽出される。1次元 CNN の出力は Profile であるので、この水平、垂直それぞれの Profile から各一枚のエッジ候補画像が生成される。それぞれのエッジ候補画像に対して 2 値化とラベリング処理が施され細かいノイズが除去される。最後にそれらの出力の論理 OR で一枚の画像を生成し、その画像に対してさらにラベリング処理を行い最終画像としている。この手法は、ニューラルネットワークを使用した画素ベースの手法でありながら、内容的には Profile を使用したエッジ検出手法であり、筆者が導入したセグメンテーションの分類上では中間的な性質を持っている。

4.1.1. 解剖学的特徴量を使用したセグメンテーション

ここで提案する手法のフローチャートを Fig.4.1.1 に示す。最初に特徴量として解剖学的な相対アドレス、正規化された濃度(以後、正規化濃度)、およびヒストグラム平滑化されたエントロピー(以後、ヒストグラム平滑化エントロピー)を各画素に対して計算する。特徴量を計算するにあたっては、エッジ検出等の画像処理が使用される。次に、抽出された特徴量を入力とした適応型のハイブリッドニューラルネットワーク(ASH-NN)を使用して、画素単位でクラス分離が行われる。最後に、ニューラルネットワークの出力画像に対して、固定閾値を使用した2値化処理が行われて最終画像が得られる。

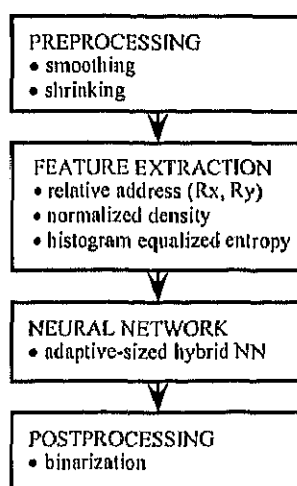


Fig.4.1.1 肺野セグメンテーションの全体処理フロー

(A) 胸部画像データベース

Johns Hopkins 大学付属病院で撮影されたスクリーニング胸部正面画像から診断情報を参照せず無作為に 85 枚の画像を選択する。それらの画像をレーザフィルムデジタイザ(ルミス社モデル 1500)を使用して 2000 x 2500 画素、12 ビットの画像にデジタする。情報量を減らすために、オリジナル画像は 256 x 310 画素へ平均化縮小され、同時に画像内の最大値と最小値の間を 255 レベルに分解するように 8 ビットに変換する。平均化に使用した 8 X 8 画素のカーソルは、物理サイズとしたは 1.4 x 1.4 mm の大きさを有する。画像の縮小は、セグメンテーションの演算時間を減らすために行われたが、胸部正面画像においては 256 x 310 画素の画像でも解剖学的なセグメンテーションの評価をするには十分と考える。また、この程度の分解能があれば、最終目的であるセグメンテーションを利用した画像強調処理への利用が可能である。[4.1.4-4.1.5]。入力画像に対するターゲット(正解)画像は、画像を CRT モニタに濃淡表示し、アドビ社製 Photoshop 環境において医療物理の専門家がマウスポインタで肺野の輪郭をトレースして作成する。この研究においては、胸部正面画像において肺野部とその他の部分に分離することを目的とする。その他の部分は、縦隔部、心臓、横隔膜下、わきの下、首、周辺のソフトティシューおよび背景(X 線が直接透過している部分)から構成される。ただし、肺野と心臓がオーバーラップしている部分は、心臓に分類する。

(B) 解剖学的相対アドレスの抽出

解剖学的相対アドレス(R_x, R_y)は、水平方向と垂直方向のプロファイルをベースとした基準点をもとに、画像中の各画素に対して割り付けられる。胸部正面画像においては、一般的にわれわれは濃度情報をもとに肺野の境界の認識ができる(ただし、心臓との境界は難しい)が、閾値を使用した単純な 2 値化では周辺のソフトティシューや背景も肺野と認識してしまう。なぜなら、肺野とそれらの部位は濃度的には近い値を持っているからである。このような状況で、濃度情報のほかに、肺野の存在しそうな領域を指定する情報を使用することは分類に非常に役に立つ。ここで導入する手法においては、解剖学的相対アドレス(R_x, R_y)は、肺野の存在しそうな領域を指定する特徴量として使用される。Fig.4.1.2 と Fig.4.1.3 に示す解剖学的相対アドレス(R_x, R_y)を算出するための4つの基準点 x_{right} 、 x_{center} 、 Y_{top} 、および Y_{bottom} は、以下に示すようにプロファイル解析により導出される。

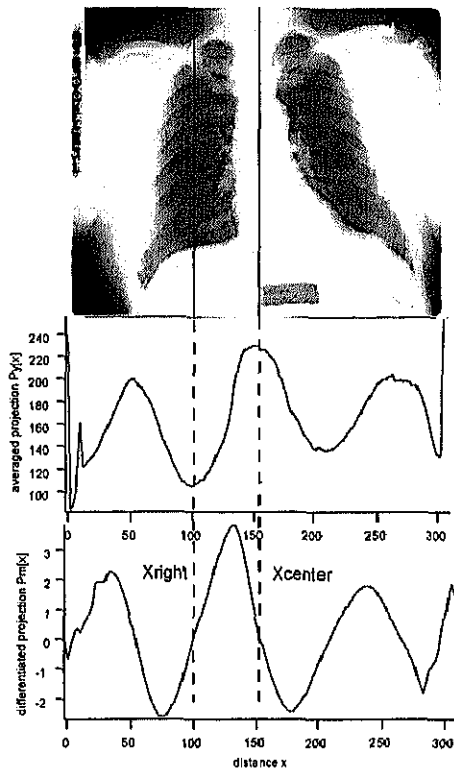


Fig.4.1.2 X方向の相対アドレスの抽出
 相対アドレスの基準点となる x_{center} と x_{right} を、上段の平均化プロジェクション $P_y[x]$ と下段の1次微分 $P_m[x]$ から求める。

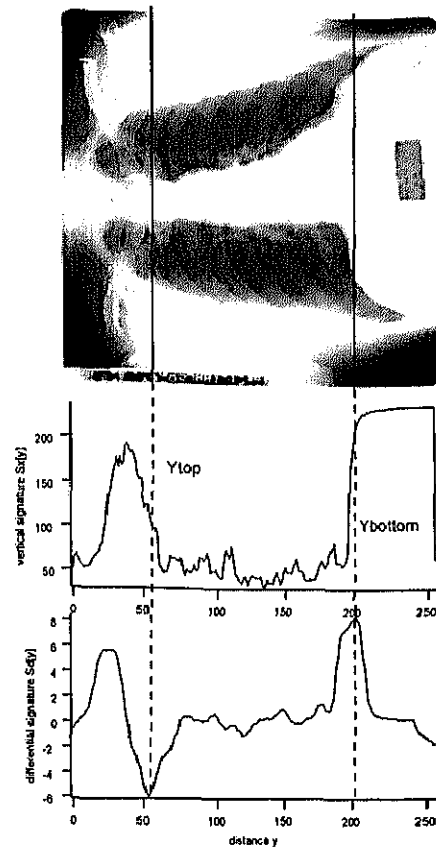


Fig.4.1.3 Y方向の相対アドレスの抽出
 相対アドレスの基準点となる y_{top} と y_{bottom} を、上段の平均化 signature $S_x[y]$ と下段の1次微分 $S_d[y]$ から求める。

最初に解剖学的相対アドレス R_x を決定するベースとなる2つの基準点の導出方法を説明する。 $I[x,y]$ を画像中の画素位置 (x,y) 、 $0 \leq x \leq N-1$ 、 $0 \leq y \leq M-1$ の画素値とする。ここで、 N は画像の列の数、 M は行の数を表す。画素値 $I[x,y]$ はフィルム濃度の逆数を表している。つまり、濃度が高い画素ほど画素値は小さくなる。水平方向の平均プロジェクション $P_y[x]$ は以下のように計算される。

$$P_y[x] = \frac{1}{M} \sum_{j=0}^{M-1} I[x,j], 0 \leq j \leq M-1 \quad (4.1.1)$$

水平プロジェクション $P_y[x]$ 中の小さいピークを削除するために、カーネルサイズ K (物理長 10 mm程度) の平均化フィルタを $P_y[x]$ に適用する。移動平均で平滑化された水平プロジェクション $P_a[x]$ は以下のように表現される。

$$Pa[x] = \frac{1}{K} \sum_{j=-\frac{(K-1)}{2}}^{\frac{(K-1)}{2}} Py[x+j] \quad (4.1.2)$$

ここで K は奇数である。経験的に K は 10–20mm に選択されれば、基準点検出の結果に依存することは無く、感度の高いパラメータではない。平滑化水平プロジェクトン $Pa[x]$ に差分処理を行い、差分結果 $Pd[x]$ に対して式 (4.2.2) と同様の平滑化処理を行ったもの $Pm[x]$ を以下のように求める。

$$Pd[x] = Pa[x] - Pa[x-1] \quad (4.1.3)$$

$$Pm[x] = \frac{1}{K} \sum_{j=-\frac{(K-1)}{2}}^{\frac{(K-1)}{2}} Pd[x+j] \quad (4.1.4)$$

ここでカーネルサイズ K は式 (4.2.2) と同じである。平滑化された差分プロジェクトン $Pm[x]$ をもとに解剖学的相対アドレス R_x の基準点が抽出される。

平滑化差分プロジェクトン $Pm[x]$ に対して、2 点 x_s と x_e と間で最大値と与える点を x_{max} をサーチする。

$$Pm[x_{max}] = \max \{ Pm[x] | x_s \leq x \leq x_e \}, 0 \leq x_s < x_e \leq N-1 \quad (4.2.5)$$

ここで、2 点 x_s と x_e の間に x_{max} を限定した理由を述べる。フィルムスキャナーを使用して X 線フィルムをスキャンする場合、X 線フィルムの外側も含めて画像領域とされるために、制限を設けずに最大画素値の点をサーチするとフィルム外側が常に最高を示してしまうからである。本研究においては、 x_{max} のサーチ範囲を画像の中央に更に限定する目的で、経験的に $x_s = 0.3 \times N$ 、 $x_e = 0.7 \times N$ の用に制限を設定している。他方、半導体フラットパネルを使用した Direct Radiography においては、あらかじめ行われる照射野抽出処理において X 線があたっていない部分は除去されるので画像の周辺に輝度の高い領域はなく、今回のような制限を設ける必要はないと予想される。

基準点 x_{right} は、 $x = x_{max}$ から $x = 0$ に向かってサーチをすすめ、 $Pm[x] = 0$ のラインをクロスする点とする。同様に、基準点 x_{center} は、 $x = x_{max}$ から $x = N-1$ に向かってサーチをすすめ、 $Pm[x] = 0$ のラインをクロスする点とする。

$$x_{right} = \max \{x | Pm[x] < 0, 0 < x < x_{max}\} \quad (4.1.6)$$

$$x_{center} = \min \{x | Pm[x] < 0, x_{max} < x < N-1\} \quad (4.1.7)$$

基準点 x_{center} の解剖学的な意味は両肺の中間点であり、 x_{right} はおおむね右肺の輪郭が鎖骨と交差するポイントを示している。ここでは、基準点 x_{right} と x_{center} にそれぞれ $Rx = 0$ 、 $Rx = 0.5$ の解剖学的相対アドレスを割り付ける。Fig.4.1.2 に水平方法プロジェクション $Py[x]$ 、平滑化差分プロジェクション $Pm[x]$ および基準点 x_{right} と x_{center} の例を示している。

次に、垂直方向(体軸方向)の相対アドレス Ry に対する基準点の決定方法について説明する。 $x = x_{right}$ 近傍での垂直方向のシグナチャー $Sx[y]$ を以下のように計算する。

$$Sx[y] = \frac{1}{K} \sum_{j=-\frac{(K-1)}{2}}^{\frac{(K-1)}{2}} I[x_{right} + j, y], 0 \leq y \leq M-1, \quad (4.1.8)$$

ここで、平均化幅 K は奇数で物理的には 10 mm 程度であり、水平方向で平滑化に使用したカーネルサイズと同様である。 $x = x_{right}$ 近傍でのシグナチャーを採用した理由は、基準点 x_{right} の抽出精度に垂直方向の相対アドレス Ry の基準点が過度に敏感になるのを回避するためである。シグナチャー $Sx[y]$ に対して微小ピークを取り除くために移動平均で平滑化を行い、その結果である平滑化シグナチャー $Sa[y]$ に対して差分処理を行い、差分シグナチャー $Sd[y]$ を求める。

$$Sa[y] = \frac{1}{K} \sum_{j=-\frac{(K-1)}{2}}^{\frac{(K-1)}{2}} Sx[y + j], 0 \leq y \leq M-1 \quad (4.1.9)$$

$$Sd[x] = Sa[y] - Sa[y-1] \quad (4.1.10)$$

差分シグナチャー $Sd[y]$ をもとに以下に示すように基準点をもとめる。最初に差分シグナチャー $Sd[y]$ 中で最大値を示す点 y_{bottom} をサーチする。

$$Sd[y_{bottom}] = \max \{Sd[y] | 0 \leq y \leq M-1\} \quad (4.1.11)$$

この y_{bottom} は、解剖学的には右肺と横隔膜の境界をおおよそ表している。ここで、垂直方向のシグナチャーを計算する際に右肺の水平方向の中央付近である

$x = x_{right}$ を使用した理由を述べておくと、左肺には心臓がオーバーラップしているため、上で求めた y_{bottom} が安定して求まらないためである。

次に右肺の輪郭と鎖骨がオーバーラップする点を示す y_{top} を抽出する。基準点 y_{top} は肺への呼気の吸い込み具合で安定せず、基準点のなかでは最も抽出の難しい点である。そこで、いくつかの経験的な定数を使用する。右肺の垂直方向の中央点 y_{center} を想定して、 y_{top} は $0 \leq y_{top} \leq y_{center}$ の範囲でサーチすることにする。そして、垂直方向の中央点 y_{center} は肺野の水平方向のサイズを使用して $y_{center} = y_{bottom} - 1.5 \times (x_{center} - x_{right})$ の用に経験的に計算する。ただし、フィルムスキャナーから出力される画素のアスペクトが1:1であることが必要である。他方、平滑化シグナチャー $Sa[y]$ を閾値により2値化した2値化シグナチャー $Sb[y]$ を以下のように求める。

$$Sb[y] = \begin{cases} 0, Sa[y] \geq St \\ 1, Sa[y] < St \end{cases} \quad (4.1.12)$$

ここで、定義域は $0 \leq y \leq y_{center}$ として、 $Sb[y] = 0$ と $Sb[y] = 1$ の発生確率が同じになるように閾値 St を選択する。つまり、 $Sb[y]$ の値の頻度 $Hb[i], i = 0, 1$ を考えると以下を満足する。

$$Hb[0] \cong Hb[1] \cong \frac{y_{center} + 1}{2} \quad (4.1.13)$$

最終的に、 $Sb[y]$ を $y = y_{center}$ から $y = 0$ の方向にスキャンして、物理長で25 mmして連続して $Sb[y] = 0$ が連続する最初の点を基準点 y_{top} にする。

$$y_{top} = \max \left\{ y \left| \sum_{i=0}^R Sb[y+i] = 0, 0 \leq y \leq y_{center} \right. \right\} \quad (4.1.14)$$

ここで、 R は物理長25 mmに相当する18画素であり、この R を設定することにより鎖骨の下側の肋骨をスキップする。垂直方向の解剖学的相対アドレスとしては、基準点 y_{top} と y_{bottom} にそれぞれ $Ry = 0$ 、 $Ry = 1.0$ の値を割り付ける。垂直方向のシグナチャー $Sx[y]$ 、差分シグナチャー $Sd[y]$ および基準点 y_{top} と y_{bottom} の例をFig.4.1.3に示す。

(C) 相対濃度の抽出

Direct Radiography システムと異なり S/F システムで撮影されたフィルムをデジタイズして得られた画像の画素値(濃度)は、X 線曝射量、人体のサイズ、現像システムに依存する。よって、デジタイズしたオリジナル画素値 $I[x,y]$ を濃度情報としてそのまま使用することは適切ではない。本手法では、全ての画素値を縦隔部の平均画素値 Mm と肺野の平均画素値 Ml で標準化することにする。

$$In[x,y] = Kd \frac{I[x,y] - Ml}{Mm - Ml} \quad (4.1.15)$$

ここで、 Kd はスケーリング定数である。変換した $In[x,y]$ は相対濃度と呼ぶ $0 \leq x \leq N-1, 0 \leq y \leq M-1$ 。縦隔部と肺野の平均画素値 Mm, Ml と計算するための、それぞれの ROI を指定するために前章でもとめた解剖学的な相対アドレスを使用する。縦隔部に含まれる ROI と、左右それぞれの肺に含まれる ROI の矩形 $R2, R1$ 、および $R3$ をそれぞれ Fig.4.1.4 に示す。

$$Mm = \frac{1}{N2} \sum I[x,y], I[x,y] \in R2 \quad (4.1.16)$$

$$Ml = \frac{1}{(N1 + N3)} \sum I[x,y], I[x,y] \in (R1 \cup R3) \quad (4.1.17)$$

ここで、 $N1, N2$ 、および $N3$ はそれぞれの矩形 ROI ($R1, R2$ 、および $R3$) に含まれる画素数を示す。矩形 $R1, R2$ 、および $R3$ の位置は解剖学的相対アドレスを使用して経験的に以下のように指定される。

$R1$ (右肺):	$R1.tl = (-0.032, 0.161)$	$R3$ (左肺):	$R3.tl = (0.935, 0.161)$
	$R1.tr = (0.055, 0.161)$		$R3.tr = (1.023, 0.161)$
	$R1.bl = (-0.032, 0.539)$		$R3.bl = (0.935, 0.539)$
	$R1.br = (0.055, 0.539)$		$R3.br = (1.023, 0.539)$
$R2$ (縦隔):	$R2.tl = (0.452, -0.419)$		
	$R2.tr = (0.490, -0.419)$		
	$R2.bl = (0.452, 1.119)$		
	$R2.br = (0.490, 1.119)$		

ここで、サフィックスの tl, tr, bl および br は、それぞれ矩形の左上、右上、左下、および右下のアドレスを表している。

(D) ヒストグラム平滑化エントロピーの抽出

上述したように、解剖学的相対アドレス(R_x, R_y)は胸部画像中での肺の存在可能領域を粗く指定する特徴量である。よって、特徴量として相対的濃度にあわせて解剖学的相対アドレスを使用すれば、胸部画像から背景を抽出することなく肺野を粗くセグメンテーションすることが可能と予測できる。しかし、相対的濃度、解剖学的相対アドレスいずれも、輪郭情報という目的では適当ではない。輪郭情報を持った特徴量を追加することでより精度のよいセグメンテーションが出来ると予想できる。

輪郭情報を強調した画像としてエッジ強調画像を考えることができ、アンシャープマスキングや差分等エッジを強調する手法は多く提案されている。大きく線形と非線形的手法に分類できるが、線形のエッジ強調手法はエッジ情報を多く含んだ画像を作ることが出来る反面、偽像を抑制するためのパラメータ制御が難しい場合がある。本研究ではヒストグラム平滑化されたエントロピーを輪郭情報として使用する。エントロピーは画像の特徴量のひとつであるが、ここで提案するものは Haralick が Spatial Gray Level Dependence Matrix 法の中で提案している Co-occurrence マトリックスに依存するエントロピーとは異なる。[4.1.17] Haralick が提案しているエントロピーは距離と角度の関数であるが、ここでは方向性をもったエントロピー特徴量を使用する必要はなく(方向性を持ったものは、石灰化のテクスチャーを解析する場合には使用される)、1次元の確立をベースにしたエントロピー特徴量を使用する。[4.1.18]

Fig.4.1.4 に示された矩形 $R1$ および $R3$ は、肺野のエントロピーを計算するのに使用される。

$$H[x, y] = - \sum_{k=1}^L p_k[x, y] \log_2 p_k[x, y], (x, y) \in (R1 \cup R3) \quad (4.1.18)$$

$$p_k[x, y] = \frac{h_{x,y}(k)}{\sum_{j=1}^L h_{x,y}(j)}, 1 \leq k \leq L \quad (4.1.19)$$

ここで、 $h_{x,y}(k)$ は画像 $I[i, j]$ 、 $x - W/2 \leq i \leq x + W/2$ 、 $y - W/2 \leq j \leq y + W/2$ の座標 (x, y) を中心とした正方カーネル内のヒストグラムを表している。画像中の画素値のレベルは L であり、正方カーネルのサイズ W は経験的に 5 mm 相当にする。計算の目的は、矩形 $R1$ および $R3$ で定義される肺野部内でエントロピーのヒストグ

ラムが平滑化されることである。エントロピー値 $H[x, y]$ が L レベルの階調数を持つ $u_i, i = 1, \dots, L$ に線形に変換されるとし、そのときのエントロピー値 u_i の発生確率が $p_e(u_i)$ で表現されるとすると、それらの確率は矩形 $R1$ および $R3$ 内のヒストグラム $h(u_i)$ から計算できる。

$$p_e(u_i) = \frac{h(u_i)}{\sum_{j=1}^L h(u_j)} \quad (4.1.20)$$

エントロピー値 u_i に対するヒストグラム平滑化されたエントロピーは、以下のように求められる。

$$v_i = Ke \times \sum_{j=1}^{u_i} p_e(u_j) \quad (4.1.21)$$

ここで、 Ke はスケーリング定数である。矩形 $R1$ および $R3$ 以外の領域のエントロピー値についても式(4.1.21)を使用して同様に变换される。もし、式(4.1.21)で計算されるエントロピー値 $H[x, y]$ が $H[x, y]$ の値域よりも大きい場合は $H[x, y]$ は u_L に变换され、値域よりも小さい場合 $H[x, y]$ は u_1 に变换される。

ヒストグラム平滑化エントロピーはカーネル内の画素のばらつきと相関がある量である。つまり、画像中の高周波成分を表現しているといえる。さらに、ヒストグラム平滑化エントロピーは Fig.4.1.5 に示したように肺野領域の統計量をもとにエンハンスされた画像であり、変換カーブは連続であるのでアーチファクト(偽像)を生じる心配はない。

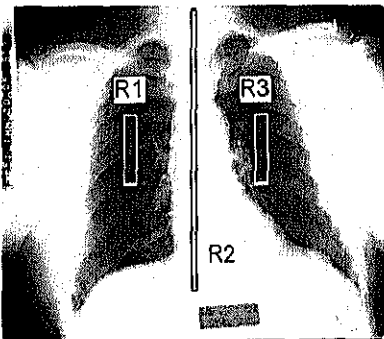


Fig.4.1.4 相対濃度

矩形 $R1$ 、 $R2$ 、および $R3$ は、肺野と縦隔の規準濃度を算出するための ROI を表している。




Fig.4.1.5 平滑化エントロピー
肺野をサンプルする矩形 $R1$ と $R3$ のエントロピーを平滑化するように、画像全体を濃度変換する。

(E) 適応型ハイブリッドニューラルネットワーク(ASH-NN)

適応型ハイブリッドニューラルネットワーク(以後、ASH-NN)を使用して、画素単位でセグメンテーションが行われる。ASH-NNは、Fig.6に示すように入力層、Hidden層、出力層から構成され、入力層には画素毎に計算された4つの特徴量(2次元の解剖学的相対アドレス、相対的濃度、およびヒストグラム平滑化されたエントロピー)が入力される。解剖学的相対アドレス(R_x, R_y)を使用したセグメンテーション問題は明らかに非線形の問題であるので、ニューラルネットワークは都合の良い道具である。

ASH-NNは、Self-Organization Map法(自己組織化マップ)とSupervised-Learning法で学習される。具体的には、Hidden層でのニューロンの位置は、“Winner-take-all”アルゴリズムを使用して自己組織化され、Hidden層のニューロンと出力層との結合は、ニューロン内の各クラスに属する学習データの割合で決定される。他方、ASH-NNはHidden層内のニューロン数を自己最適化する機能もある。よって、構造を最適化するためのTry & Errorをする必要がなく、この点は広く使用されている誤差逆伝播ニューラルネットワークに勝っている。ASH-NNは、長谷川により乳癌の病理画像中から癌細胞の核の検出するために開発された。[4.1.14]ここでは、表記の変更も含めてASH-NNのアルゴリズムをレビューする。

入力パターン $\mathbf{x}_p, p=1, \dots, P$ は n 次元の入力パターンを、 \mathbf{y}_j はHidden層中の j 番目のニューロンの n 次元中での位置をそれぞれ表すとすると、 p 番目の入力パターンと j 番目のニューロンとの距離は下のように表現される。

$$D_j = \|\mathbf{x}_p - \mathbf{y}_j\| \quad (4.1.23)$$

ここで、 $\|\cdot\|$ はユークリッドノルムである。入力パターン \mathbf{x}_p に対する各ニューロンまでの距離を計算し、最小距離 D_{wm} を与えたニューロンを“Winner-Unit”とする。

$$D_{wm} = \min \{D_j | 1 \leq j \leq Nu\} \quad (4.1.24)$$

ここで、 Nu はHidden層内のニューロン数を表している。そして、 i 番目のユニットの最終出力は、以下のように表現される。

$$z_i = w_{wm,i}, 1 \leq i \leq Mc \quad (4.1.25)$$

ここで、 $w_{win,i}$ は Hidden 層内の“Winner”ニューロンと i 番目の出力ユニットとの結合係数を表し、 Mc は出力クラス数を表している。

ASH-NN の学習プロセスの初期状態では、Hidden 層にはニューロンは存在しない。最初の学習パターンが提示された時点で、Hidden ニューロンが以下のように生成される。

$$\mathbf{y}_1(t=0) = \mathbf{x}_1. \quad (4.1.26)$$

これと同時に全ての出力ユニットに対応している内部カウンタ $C_1(i)$ ゼロクリアされる。

$$C_1(i) = 0, 1 \leq i \leq Mc. \quad (4.1.27)$$

クラス i に属する入力パターン \mathbf{x}_p に対して“Winner”ニューロンが決定した時点で $C_{win}(i)$ に 1 に加算される。つまり、内部カウンタはニューロンが勝利“Win”した回数を表している。

t 回目の学習エポックにおいて、 p 番目の学習パターンが提示されて、 win 番目の Hidden ニューロンが式(4.1.23)と式(4.1.24)にしたがって勝利したとき、以下に示すように Hidden ニューロン win の位置は修正される。

$$\mathbf{y}_{win}(t+1) = \mathbf{y}_{win}(t) + \lambda(\mathbf{x}_p - \mathbf{y}_{win}(t)), \quad (4.1.28)$$

$$\lambda = \lambda_0 \times \exp\left(\frac{-t}{10}\right) \quad (4.1.29)$$

ここで、 λ は学習率 (Learning-rate) で、経験的に初期値 λ_0 から学習とともに指数的に減衰するように設計されている。学習が進んだ時点でニューロンの位置が大きく動くと、評価関数が振動する可能性があるからである。同時に Winner ニューロン win の内部カウンタは下のようにインクリメントされる。

$$C_{win}(s_p) \leftarrow C_{win}(s_p) + 1, \quad (4.1.30)$$

ここで、 s_p は入力パターン \mathbf{x}_p のターゲットクラスである。その時に $\sum_{i=1}^M C_{win}(i)$ が閾値 C_{thres} より大きく、かつ $C_{win}(i), 1 \leq i \leq Mc$ 中の 2 個以上が非ゼロであれば、新規

のニューロンが以下のように生成される。

$$\begin{aligned}
 \mathbf{y}_{N+1}(t+1) &= \mathbf{y}_{win}(t+1), \\
 C_{N+1}(i) &= 0, 1 \leq i \leq Mc, \\
 C_{win}(i) &= 0, 1 \leq i \leq Mc, \\
 Nu &\leftarrow Nu + 1.
 \end{aligned}
 \tag{4.1.31}$$

式(4.1.31)から分かるように新規生成されたニューロンは、Winner ニューロン win のコピーである。ただし、その際にニューロンに付随した内部カウンタは全てゼロクリアされる。ニューラルネットワークの学習エポックが新しく始まる際に入力ユニットへの重み係数が下のように計算される。

$$w_{j,i} = \frac{C_j(i)}{\sum_{k=1}^M C_j(k)}
 \tag{4.1.32}$$

以上の重み係数の計算と全ての内部カウンタリセットが行われた後に、次のエポックが開始されるが、以下のようなニューラルネットワークのパフォーマンス評価としてトータルエラーを計算することが出来る。

$$E_t = \sum_{p=1}^P \sum_{i=1}^M |z_i(\mathbf{x}_p) - \delta_{i,s_p}|
 \tag{4.1.33}$$

ここで、 δ_{i,s_p} は Kronecker のデルタである。ニューラルネットワークの画像毎のエラー E_t は以下の用に計算できる。

$$E_z = \frac{1}{N_r} \sum |I_z[x,y] - t[x,y]|
 \tag{4.1.34}$$

ここで、 N_r は画像中のトータル画素数であり、 $I_z[x,y]$ と $t[x,y]$ は、それぞれニューラルネットワークの出力画素値、ターゲット(目標)画素値である。式(4.1.25)と式(4.1.32)から分かるように、出力画像 $I_z[x,y]$ は確率を表現しているので、0 から 1 の間で変異する。画素位置 (x,y) の画素が肺野にクラス割り付けされるときは、ターゲット画素値 $t[x,y]$ は 1 であり、その他の部位に割り付けられるときは、ターゲット画素値 $t[x,y]$ はゼロである。

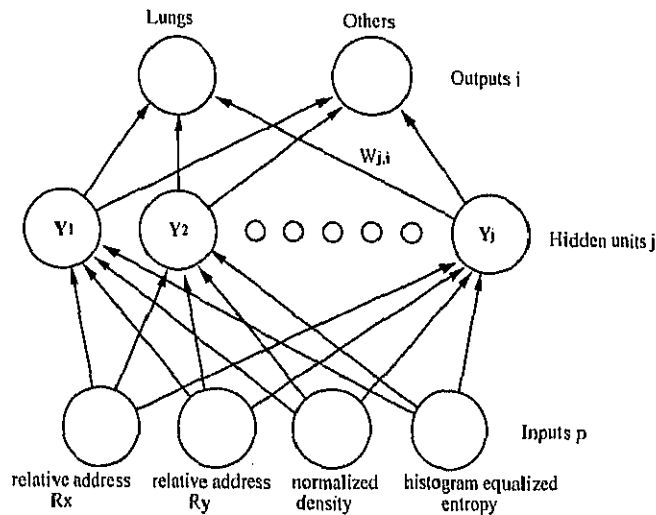


Fig.4.1.6 ASH-NN のアーキテクチャー

4 特徴量の場合、4 入力ユニット、適応的に決定される個数の Hidden ユニットおよび 2 つの出力ユニットで構成される。

(F) ASH-NN 出力画像の 2 値化

前章で決定された ASH-NN の出力画像は、式(4.1.32)から分かるように浮動小数点画像であり、量子化することにより 256 レベル等の濃淡画像に変換することが可能である。セグメンテーション結果を応用する画像処理のアルゴリズムによっては、出力が濃淡画像であることが有用な場合もあるが、4.4 章で説明する解剖学的情報を使用したダイナミックレンジ圧縮処理、コンピュータ診断支援 (CAD)、画像計測等においては 2 値画像が必要であるので、2 値化について調査しておく必要がある。最も簡便かつ論理的な方法は出力値の中央値を閾値 T_c にして 2 値化する方法である。なぜなら、重み係数 w_{ji} は母集団のトレンドを表現しているであろう学習用サンプルの分布確率に対応しているからである。よって、ASH-NN からの出力画素値が閾値 $T_c = 0.5$ 以上の場合は肺野、小さい場合はその他の領域にクラス分けされる。2 値化処理まで含めた全てのプロセスに対する画像毎のエラー E_b は以下のようなになる。

$$E_b = \frac{1}{N_r} \sum [I_b[x,y] - t[x,y]] \quad (4.1.35)$$

ここで、 $I_b[x,y]$ と $t[x,y]$ は、最終 2 値化画像とターゲット画像を表している。

4.1.2. 結果

(A) ASH-NN 出力の評価

前述した 4 つの特徴量(2次元の解剖学的相対アドレス、相対濃度、ヒストグラム平滑化エントロピー)の有効性を評価するために、特徴量の2つの組み合わせを実験した。評価する ASH-NN は、入力層、1 つの Hidden 層、出力層から構成される3層のニューラルネットワークである。特徴量の組み合わせは、(1)3 特徴量(2次元の解剖学的相対アドレス(R_x, R_y)、相対濃度)、(2)4 特徴量((1)にヒストグラム平滑化エントロピーを加えたもの)、の2つである。全体 85 画像からランダムに 14 画像を選択し学習パターンとした。トータル学習パターンは $14 \times 256 \times 310$ 個である。残りの 71 画像でテストが行われるが、評価は画像単位で行われた。解剖学的相対アドレス(R_x, R_y)を算出するための基準点 x_{right} 、 x_{center} 、 Y_{top} 、および Y_{bottom} はほとんどの画像で適切に抽出され、その基準点を使用する相対濃度を計算するための矩形 ROI が間違えなくそれぞれ肺野と縦隔部に当てはまったことを画像で確認した。相対濃度とヒストグラム平滑化エントロピーを計算する際のスケール係数 K_d と K_e は両方とも 2.0 とし、ASH-NN の Learning-rate の初期値 λ_0 は 0.1 とした。

ASH-NN は学習の過程でニューロン数を閾値 C_{thres} を規準に決定する。閾値 C_{thres} の物理的意味は、1 つのニューロンがサポート出来る最大の学習パターンの数を示している。ただし、1 つのクラスのみ(肺野かその他の一方)をサポートする




Fig.4.1.7 テストエラーの比較的小さいセグメンテーション結果
(a)は入力画像、(b)はターゲット画像、(c)は3特徴量 ASH-NN が出力した濃淡画像で E_z は 7.9%、(d)は4特徴量 ASH-NN が出力した濃淡画像で E_z は 6.8%である。3特徴量 ASH-NN は 4871 の Hidden ユニット、4特徴量 ASH-NN は 4914 個の Hidden ユニットで構成されている。




Fig.4.1.8 ニューロン数とエラー
3特徴量ASH-NNと4特徴量ASH-NN
において、Hidden層のニューロン数と
学習エラー、テストエラーの関係を示す。
ニューロン数は閾値 C_{thres} を調節して
加減する。




Fig.4.1.9 画像毎のテストエラー E_z
3特徴量ASH-NNは4871個、4特徴量
ASH-NNは4914個のニューロンを
Hidden層に持つ場合を示す。

ニューロンは閾値 C_{thres} と関係なく無制限に学習パターンをサポートすることが可能である。ここでは、閾値 C_{thres} を3特徴量と4特徴量の両方のニューラルネットワークに対して200から1000の間で適宜調整した。計算時間はニューラルネットワークを構成するニューロンの個数に依存するが、パフォーマンスを計測したほとんどのニューラルネットワークは、ONYXワークステーション(Silicon Graphics社製、190MHzのMIPS R10000プロセッサとR10010浮動少数点プロセッサがデュアル構成)を使用しても学習に数日を要した。

オリジナル入力画像、ターゲット2値画像、3特徴量と4特徴量のASH-NNの出力濃淡画像の例をそれぞれFig.4.1.7に示す。ここで、3特徴量と4特徴量のASH-NNのニューロン数は、それぞれ4871個と4914個である。ニューロン数は同等であるが、4特徴量ASH-NNの肺野輪郭の法がクリアであり、ヒストグラム平坦化エントロピーが目的通りに輪郭の強調に効果があることがわかる。

3特徴量と4特徴量のASH-NNに対してニューロン数を変化させた場合の学習とテストのエラー E をFig.4.1.8に示す。4特徴量ASH-NNの学習エラーは3特徴量ASH-NNのそれに比べて大きいですが、テストエラーはニューロン数が2500以上では4特徴量ASH-NNの方が小さい。4特徴量ASH-NNの方がより一般化(Generalized)したパフォーマンスを示していると云える。さらに、Fig.4.1.9にテスト画像71枚それぞれに対するエラー E_z を3特徴量と4特徴量のASH-NNそれぞれの場合について示す。3特徴量と4特徴量のASH-NNに対する平均画像エラー \bar{E}_z は、それぞれ10.2%と9.8%であった。3特徴量ASH-NNは、数枚の限られた画像に対して4特徴量ASH-NNにまさるパフォーマンスを示しているが、その他の多くの画像で悪いパフォーマンスを示している。つまり、4特徴量ASH-NNはパフォーマンスのばらつきが小さく、おおくずれしない特性を持っていると云える。




Fig.4.1.10 テストエラーの大きいセグメンテーション結果
 (a)は入力画像、(b)はターゲット画像、(c)は3特徴量 ASH-NN が出力した濃淡画像で E_z は 16.0%、(d)は4特徴量 ASH-NN が出力した濃淡画像で E_z は 15.0%である。3特徴量 ASH-NN は 4871 の Hidden ユニット、4特徴量 ASH-NN は 4914 個の Hidden ユニットで構成されている。

71 枚のテスト画像中でもっともエラーが大きかった画像を Fig.4.1.10 に示す。この画像に対する 3 特徴量と 4 特徴量の ASH-NN の平均エラー \bar{E}_z は、それぞれ 16.0%と 15.0%であった。この画像の特異性は、(1)肺野の上部が背景に対してコントラストがない、(2)肺野上部の輪郭が肩の線に極端に近い、(3)肺野が画像中で傾いている、などがあげられる。撮影時に空気の吸い込みが不十分であったことが予想される。3 特徴量と 4 特徴量の ASH-NN の出力画像で共通に見られる特徴は、解剖学的相対アドレスの影響により肺野上部に突起が見られる点である。解剖学的相対アドレスからすれば、肺野上部がもう少し大きいと予測されたのである。この傾向は 3 特徴量 ASH-NN でより顕著である。

(B) 2 値化処理の評価

閾値 $T_c = 0.5$ での 2 値化画像を Fig.4.1.11 に示す。Fig.4.1.11 (a)と(b)に示すようにエラーが小さい画像に関しては、2 値化後も輪郭はスムーズであるが、エラーの大きい(c)と(d)の画像に関しては、小さいドットや粗い輪郭を修正する Labeling や Morphology フィルタ等の後処理が有効と思われる。Fig.4.1.12 に 4 特徴量 ASH-NN のテスト画像 71 枚それぞれに対する濃淡出力エラー E_z と 2 値化出力エラー E_b を示す。濃淡出力エラー E_z と 2 値化出力エラー E_b の平均はそれぞれ 9.8%と 7.6%であった。2 値化の際の閾値 $T_c = 0.5$ はよく機能している。

ここで、確率的ではなく解剖学的な閾値の決定方法を提案する。筆者がトレースすることによって決定した肺野の実際の面積 N_r と、以下に示す式で表現される矩形の面積 N_e は、Fig.4.1.13 に示すような相関があれば閾値決定に利用できる。




Fig.4.1.11 2 値化の結果画像

(a)は Fig.4.1.7(c)の、(b)は Fig.4.1.7(d)の、(c)は Fig.4.1.10(c)の、(d)は Fig.4.1.10(d)のそれぞれ 2 値画像を示す。2 値化後のセグメンテーションエラーは、それぞれ 5.8%、5.3%、14.9%、13.1%である。

$$N_e = (x_{center} - x_{right}) \times (y_{bottom} - y_{top}) \quad (4.1.36)$$

表現を変えれば、解剖学的相対アドレスの基準点から肺野の面積が推定できるということである。Fig.4.1.13 に 85 枚のサンプル画像に対する N_r と N_e の関係を直線と指数カーブでフィッティングした例を示す。256 × 310 画素の胸部正面画像を仮定すると下の式のように肺野の面積が推定できる。

$$\tilde{N}_r = 3405 + 2.47 \times N_e \quad (4.1.37)$$

ここで、 \tilde{N}_r は N_e からの推定肺野面積である。同様に指数関数を使用して近似すると以下のような結果を得る。




Fig.4.1.12 濃淡エラーと 2 値化エラー
テストした 71 枚の画像に対する濃淡画像でのエラー E_z と中心値で 2 値化した 2 値化画像でのエラー E_b の比較。4914 個の RBF ニューロンで構成された 4 特徴量 ASH-NN を使用した。71 枚の平均エラーは、 E_z が 9.8%、 E_b が 7.6%であった。




Fig.4.1.13 肺野を占める画素数 N_r と相対アドレスから推測する画素数 N_e の相関

$$\tilde{N}r = 28696 \times \exp \left\{ - \left(\frac{2Ne - 20428}{12603} \right)^2 \right\} - 1547 \quad (4.1.38)$$

式(4.1.37)または式(4.1.38)を使用して推定された肺野の面積を使用して以下のように2値化の推定閾値 T_e を決定することが出来る。

$$T_e = \max \left\{ k \left| \sum_{j=k}^{255} h(j) \geq \tilde{N}r, 0 < j \leq 255 \right. \right\} \quad (4.1.39)$$

ここで、 $h(j), j = 0, \dots, 255$ は、ASH-NN から出力された浮動小数点画像を、0 から1.0の区間で8ビット濃淡画像に変換した場合のヒストグラムを表している。固定閾値 T_c を使用した場合の平均エラーが0.08であるのに対して、推定閾値 T_e を使用した場合の平均エラーは0.09であった。

4.1.3. 考察

最初にイントロダクションで紹介したその他のセグメンテーション手法との比較を行う。長谷川は、5枚の胸部画像でコンボリューション型ニューラルネットワークを学習し、21枚の胸部画像でテストを行い、主観的評価結果の報告をしている。[4.1.7] 彼の研究の新規性は、正弦角を使用した後処理の開発にある。ニューラルネットワークから出力された肺野のセグメンテーション結果が鎖骨等によって侵食されていることに対して、最初に肺野の外形からラプラシアンフィルタを使用して輪郭を取り出し、その後に抽出された輪郭線をトレースしたときの正弦角に制限を設けることにより侵食部の回復を行っている。しかし、入力としては濃度値をそのまま採用しており、特徴量としての新規性はなく、ニューラルネットワークから出力された画像は、原画像に対して単にローパスフィルタをかけたものと同様のものではなかった。つまり、セグメンテーションとしてのパフォーマンスはほとんど後処理で実現されたと解釈できる。対して、筆者が導入した手法では同様のセグメンテーション結果を後処理なしで実現している。仮に、ニューラルネットワークに大きな差がないとすれば、胸部画像中の肺野のセグメンテーションにおいては、濃度情報だけでは特徴量として不十分であるといえる。

McNitt-Gray は、空間情報を含まない59個の特徴量を局所的に計算し、これら59個の特徴量からの何種類かの部分集合、および全部を入力として誤差逆伝播ニューラルネットワークを学習させた。17枚の胸部画像で学習し、16枚の画像をそれぞれ5個の解剖学的部位に分類した。本手法との簡単な比較を行うために、

彼の結果を肺野とその他の部位(心臓、縦隔部、背景等からなる)の分類になるように計算をしておいた。入力に全 59 特徴量を使用した場合、8 個の特徴量の最適な組み合わせを使用した場合、それぞれに対する肺野の正確度 (Accuracy)は 91.8%、88.0%であった。これに加えて、セグメンテーション結果に制限を加えるための空間情報(解剖学的予想領域)を付加したシステムについても評価している。空間情報を加えることにより、入力に全 59 特徴量を使用した場合、8 個の特徴量の最適な組み合わせを使用した場合、それぞれに対する肺野の正確度は 93.4%、91.9%に向上した。これに対する本手法の結果は 4 個の特徴量を使用した場合の濃淡画像、2 値画像での正解度はそれぞれ 90.2%(100- Ez で計算)、92.4%(100- Eb で計算)であり、同等のパフォーマンスと考えることが出来る。彼の導入した空間情報(解剖学的予想領域)は、本手法で導入した解剖学的相対アドレスと同様の目的で採用された特徴量と考えることが出来る。本手法のニューラルネットワークが非常に大規模で計算時間が膨大であったことは先に述べたが、彼が使用したネットワークのニューロン数はなんと 15 個で、本手法のニューロン数 5000 個に比べると異様にすくない。8 個の特徴量の最適な組み合わせ場合のニューラルネットワークは 8 次元のハイパー空間中でのクラス分離の問題になるわけであるが、これをたった 15 枚のハイパー平面で、しかも 91.9%の正確度を実現することは驚異的である。彼が選択した 8 個の特徴量そのものと、59 個の特徴量からベストの 8 個を選択するステップワイズ分離法の有効性が際立っている。

以下に本研究の成果をまとめる。2 次元解剖学的相対アドレス、相対濃度、およびヒストグラム平滑化エントロピーから構成される 4 つの特徴量を入力とするニューラルネットワークを開発し、胸部画像中の肺野のセグメンテーションを行った。学習データと同様の手法で作成されたテスト画像に対して、92.4%の正確度で肺野の検出を行うことに成功した。解剖学的相対アドレスの抽出方法も 85 枚のサンプル画像の対して安定していた。3 特徴量と 4 特徴量の比較実験より、ヒストグラム平滑化エントロピーは、肺野の輪郭部分での正確度を向上させるのに効果があり、特徴量としての採用目的と一致していた。2 値化の閾値の決定に係わり、実際の肺野の面積と解剖学的相対アドレスから指定される肺野の面積との相関を調べた。2 値化の閾値を相関関係を利用して決定する場合と、ニューラルネットワークの出力範囲の中間点(0.5)とする場合のパフォーマンスを比較し、中間点を閾値とするほうがわずかではあるが良い結果を得た。これは、ASH-NN が肺野境界部(Ribcage Boundary)でも確率的にエッジを構成していることを示している。

問題点として、本手法がローコントラスト画像や、肺野が画像中で傾いている画像

でパフォーマンスが悪いことがあげられる。コントラスト情報として導入した相対濃度は、肺野の内部で濃度が比較的安定していることを前提にしているので、肺野上部と中間部で濃度が変化する症例等には特徴量として不十分になった。肺野の傾きに関しては、本手法のセグメンテーションに入る前に肺野の傾斜を修正する前処理が必要である。最後に、高速のコンピュータを使用してもてて 1 枚の画像のテストに 30 分も要する巨大なニューラルネットワークになり、このままでは筆者が開発しているディジタ撮影装置の画像処理プログラムでは使用できない。大規模システムになると必要とするコンピュータの記憶容量の大きくなる。小規模で高速のシステムの開発が次なる課題である。

4.2. プロファイルベースの胸部画像のセグメンテーション

前項 4.1.では、画素毎にセグメンテーションを行う手法を研究したが、ここでは Profile ベースで輪郭を検出する手法を研究する。4.1.1.でも述べたが、従来の Profile ベースのものは肺野の輪郭点を多項式に Fitting して結果としていたが、ここではビットマップ形式の出力を行い Fitting は行っていない。Fitting を行っても、その多項式と診断との相関を見出すのでなければ意味がない。Fitting をすると輪郭線が滑らかになるが、ビットマップのままでも画像処理にも、計測にも十分役立つと考える。

4.2.1. プロファイルベースのセグメンテーション

ここで研究する Profile ベースのセグメンテーション手法のフローチャートを Fig.4.2.1 に示す。このフローは大きく5つの処理から構成される。最初に 2K x 2.5K 画素の入力画像をサブサンプリングして、256 x 310 画素の画像とする。次に画像を水平方向と垂直方向にそれぞれ分解して Profile を取り出す。画像マトリックスを $N \times M$ として、 N を画像の幅、 M を高さとしたとき、分解により M 本の水平方向の Profile と N 本の垂直方向の Profile が出力されることになる。重要な点は Kruger や Powell の手法とことなり、切り取られた Profile は平均化されたものではないと云うことである。[4.2.1-4.2.2]

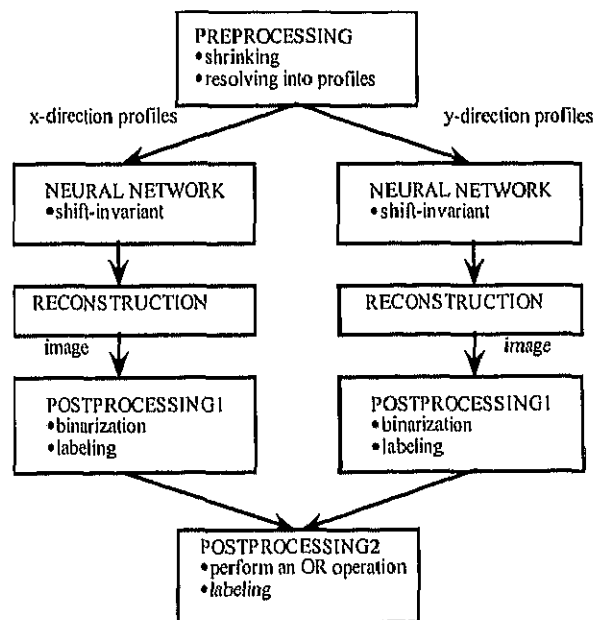


Fig.4.2.1 本手法のダイアグラム

Postprocessing1 での Labeling 処理は、水平方向と垂直方向で異なった処理が行われることに注意。

次に、水平、垂直それぞれの方向に分けて用意された 1 次元のニューラルネットワークにより、それぞれの Profile が個別にテストされる。使用するニューラルネットワークは、テストに先だってデータベースからランダムに選択された 14 枚の画像を分解した、それぞれの方向の Profile で学習が行われている。そして、ニューラルネットワークの出力 Profile を、水平、垂直の方向別に再構成して、結果として 2 枚の画像を得る。1 枚は水平方向の処理により構成された画像であり、他方は垂直方向の処理により構成された画像である。続いて、出力された 2 枚の画像はそれぞれ 2 値化処理され、Labeling により細かい孤立点が除去される。最後に、2 枚の画像を OR 演算で重ね合わせて画像に対して、再度の Labeling 処理を行い最終出力画像とする。

(A) 胸部画像データベース

Johns Hopkins 大学付属病院で撮影されたスクリーニング胸部正面画像から診断情報を参照せずは無作為に 85 枚の画像を選択する。選択された画像は前項 4.1 で使用した同じデータである。それらの画像をレーザフィルムディジタイザ(レミシス社モデル 1500)を使用して 2000 x 2500 画素、12 ビットの画像にデジタル化する。情報量を減らすために、オリジナル画像は 256 x 310 画素へ平均化縮小され、同時に画像内の最大値と最小値の間を 255 レベルに分解するように 8 ビットに変換する。平均化に使用した 8 X 8 画素のカーソルは、物理サイズとしては 1.4 x 1.4 mm の大きさを有する。画像の縮小は、セグメンテーションの演算時間を減らすために行われたが、胸部正面画像においては 256 x 310 画素の画像でも解剖学的なセグメンテーションの評価をするには十分と考える。また、この程度の分解能があれば、最終目的であるセグメンテーションを利用した画像強調処理への利用が可能である。[4.1.4-4.1.5]。入力画像に対するターゲット(正解)画像は、画像を CRT モニタに濃淡表示し、アドビ社製 Photoshop 環境において医療物理の専門家がマウスポインタで肺野の輪郭をトレースして作成する。トレースされた肺野の輪郭は、Morphology フィルターを使用して 2 画素程度の太さになるように画像処理した。この研究においては、肺野と心臓がオーバーラップしている部分は心臓に分類する。

(B) 画像からプロフィールへの分解

縮小した画像の画素位置 (x, y) での画素値を $I[x, y]$ とする。ここで、 N を画像の列数、 M を行数として、 $0 \leq x \leq N-1$ 、 $0 \leq y \leq M-1$ である。 $I[x, y]$ の物理単位は、フィルム濃度の逆数であり、 $I[x, y]$ の値が大きいほどフィルム濃度が低い、

つまり CRT で表現した場合に輝度が高いと云うことになる。水平方向の Profile $P_i[x]$ 、および垂直方向の Profile $Q_j[y]$ は以下のように定義することができる。

$$P_i[x] = I[x, i], 0 \leq i \leq M-1, 0 \leq x \leq N-1,$$

$$Q_j[y] = I[j, y], 0 \leq j \leq N-1, 0 \leq y \leq M-1,$$

水平方向の Profile $P_i[x]$ は水平方向のニューラルネットワークに入力され、垂直方向の Profile $Q_j[y]$ は垂直方向のニューラルネットワークにそれぞれ入力される。

(C) 1次元コンボリューション型ニューラルネットワーク(CNN)

二つの Hidden 層を持つ 1次元コンボリューション型(Shift-invariant)ニューラルネットワークを Fig.4.2.2 に示す。ネットワークモデルは Sigmoid 関数のような非線形な出力特性をもつニューロンから構成される多層フィードフォワードニューラルネットワークである。各レイヤーは何個かのクラスターで構成され、クラスター内部には複数個の Unit が存在する。高位レイヤーの各 Unit は低位レイヤーに属する何個かの Unit に接続される。Unit 間の接続はレセプター(Convolution Kernel)で介在され、

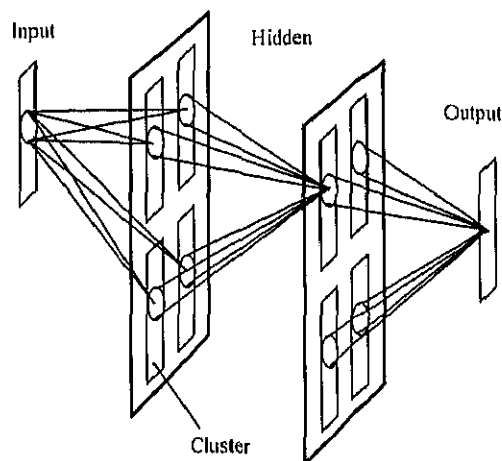


Fig4.2.2 1次元の位置不変 CNN のモデル。

このモデルでは、入力層、2層の Hidden 層、出力層から構成される4層のニューラルネットワークを示す。入力データは 1次元データで、Hidden 層のそれぞれのクラスターは 1次元のニューロン列で構成される。学習フェーズにおいて、接続重み付け係数(interconnection kernels と biases)が決定される。クラスター内のそれぞれのニューロンは、前層から出力と interconnection kernel とのコンボリューション+blas 値を保持する。

これが複数タップを持つことにより局所的に Shift-invariant になっている。独立な重み係数の数は、レイヤーの数、各レイヤー内での Unit の数とそれぞれの Unit のカーネルサイズにより決まる。

先に述べたように長谷川は胸部正面画像から肺野の輪郭を抽出するのに2次元のコンボリューション型ニューラルネットワークを使用している。[4.2.3] 彼は2次元画像を入力とするために2次元のコンボリューション型ニューラルネットワークを使用したが、ここでは2次元の画像を1次元プロファイルに分解して取り扱うので1次元のコンボリューション型ニューラルネットワーク(CNN)を使用する。入力プロファイルは8ビットのグレースケールであり、出力は実数出力となる。以下では、彼が紹介している2次元のコンボリューション型ニューラルネットワークを1次元に変換して再度記述する。

$N_p^l(x)$ と $O_p^l(x)$ を l 層の p 番目のクラスターに属する Unit(x)のそれぞれ入力と出力とする。 $W_{p,q}^l(x)$ を l 層の p 番目のクラスターから $(l+1)$ 層の q 番目のクラスターへのコネクションパターン(重み係数)とする。ここで、 $l = (1, 2, \dots, L)$ 、 $p = (1, 2, \dots, P^l)$ 、 $q = (1, 2, \dots, P^{l+1})$ とする。連続する層の入出力関係は以下のように記述できる。

$$N_q^{l+1} = \sum_{p=1}^{P^l} (O_p^l * W_{p,q}^l)(x) + b_q^{l+1}, \quad (4.2.1)$$

ここで、 b_p^l は l 層の p 番目のクラスターへのバイアス入力であり、*はコンボリューションを表している。Unitからの出力は以下のように表される。

$$O_q^{l+1} = f(N_q^{l+1}(x)) \quad (4.2.2)$$

ここで、 $f(z)$ は Sigmoid 関数を表し、以下のように記述できる。

$$f(z) = \frac{2}{1 + \exp(-z)} - 1. \quad (4.2.3)$$

t 回目の重み係数の変更値を $\Delta W_{p,q}^l(t)$ 、バイアスの変更値 $\Delta b_p^l(t)$ とする。エラー関数(評価関数)は以下のように表すことができる。

$$E = \frac{1}{2} \sum_i \sum_x (T^i(x) - O_i^{l-1}(x))^2, \quad (4.2.4)$$

ここで、 $T^i(x)$ と $O_i^{l-1}(x)$ は、それぞれ i 番目のプロファイルに対するターゲット(目標)とネットワークの出力プロファイルを表している。誤差逆伝播アルゴリズムを使用して修正量は以下のように求めることができる。

$$\Delta W_{p,q}^l(t+1) = \eta(\delta_q^{l+1} * O_p^l)(x) + \alpha \Delta W_{p,q}^l(t), \quad (4.2.5)$$

$$\Delta b_{p,q}^l(t+1) = \eta \sum_i \sum_j \delta_p^l(i,j) + \alpha \Delta b_{p,q}^l(t), \quad (4.2.6)$$

$$\delta_p^l = f'(N_p^l(x)) \sum_q [(\delta_q^{l+1} * \tilde{W}_{p,q}^l)(x)], \quad (4.2.7)$$

$$\tilde{W}_{p,q}^l(x) = W_{p,q}^l(-x), \quad (4.2.8)$$

最後の層では、

$$\delta_1^l = f'(N_1^l(x))(T - O_1^l)(x), \quad (4.2.9)$$

ここで、 $f'(z)$ 、 η 、 α 、および $T(x)$ は $f(z)$ の導関数、学習レイト(Learning Rate)、学習の慣性係数およびターゲットのプロファイルを表している。 δ_p^l は、 l 層の p 番目のクラスターからの誤差伝播の1次導関数である。本手法においては、2次元画像が2方向の1次元プロファイルに分解されるので、2個の1次元コンボリューション型ニューラルネットワークが使用される。

(D) CNN出力画像の後処理

後処理は詳細に述べると5つのプロセスより構成される。最初にニューラルネットワークから出力されたプロファイルを使用して、それぞれの方向に対して1枚、トータル2枚の2次元画像が再構成される。ここで、2枚の画像はそれぞれのプロファイルの方向に両端を何画素か切り取られていることに注意する必要がある。切り取られる画素数は使用されるカーネルサイズとネットワークのレイヤーの数により決まる。再構成された画像はニューラルネットワークの出力値であるため実数値を示している。ここでは、肺野の輪郭部は1、その他はゼロの値をとるように学習するが、ネットワークの出力値は1とゼロの範囲に納まっているとは限らない。本

手法の目的は 2 値画像を得ることにあるので、0.5 は閾値にして、それ以上を肺野の輪郭、以下をその他の領域とする。閾値に 0.5 を用いる根拠は、ニューラルネットワークの学習過程を確率による学習と考えられるからである。また、後で述べるようにネットワーク出力のエッジを非常に急峻であり、閾値により輪郭の位置はあまり変動せずパフォーマンスには影響しない。

2 値化処理の後に、連続する輪郭の数を制限するためにラベリングを行う。ラベリングの過程においては、各輪郭に含まれる画素数がカウントされて、画素数の少ない輪郭がノイズとして削除される。ここで、輪郭の接続を判断する際には 8 近傍で判断される。各方向から再構成された画像に対する制限輪郭数は、経験的に水平方向からの画像では 4 個、垂直方向からの画像では 6 個とした。理論的には、制限輪郭数はそれぞれの方向に対して 2 個であるべきであるが、鎖骨、心臓の存在により輪郭は切断されることが多く、今回使用した 4 個と 6 個では一部の断片はノイズとして誤って削除されている。誤って削除された輪郭の断片に対しては、2 方向から再構成された輪郭の論理 OR を行うことにより復元されることを期待される。最後に論理 OR を行った画像に対して輪郭数は 2 個に制限するように再度ラベリングを行う。

(E) パフォーマンスの評価方法

試験するそれぞれの画像に対して、True-Positive (輪郭を輪郭として検出) N_{TP} 、True-Negative (非輪郭と非輪郭として検出) N_{TN} 、False-Positive (非輪郭を輪郭と誤検出) N_{FP} 、False-Negative (輪郭を非輪郭と誤検出) N_{FN} に相当する画素数を計算する。正解率 (Accuracy) は以下のように計算することが出来る。

$$accuracy = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}}, \quad (4.2.10)$$

4.2.2. 結果

ニューラルネットワークは経験的に 5 層のネットワークを使用した。つまり、入力層、3 つの Hidden 層、および出力層で構成される。入力層のデータ長は水平方向に対しては 256 点、垂直方向に対しては 310 点である。対して出力層のデータ長は水平方向に対しては 232 点、垂直方向に対しては 286 点である。それぞれの方向に対して各 Hidden 層に 5 個のクラスターが設けられた。水平方向に対しては、第 1、第 2、第 3 Hidden 層の各クラスターは 250、244、238 のニューロンから構

成される。垂直方向に対しては、第1、第2、第3Hidden層の各クラスターは304、298、292のニューロンから構成される。各層のクラスター間を接続するカーネルの長さは全て7である。Hidden層内のニューロンは以下に示すような1次元のSigmoid関数である。




Fig.4.2.3 学習に使用したオリジナル画像(a)とターゲット画像(b)の例
 ターゲット画像は、手作業で輪郭追跡した画像に対し Morphological フィルターの dilation と erosion 処理と論理 EXOR を組み合わせた画像処理を行い、輪郭幅が概ね2画素になるように調整された。

$$f(z) = \frac{2}{1 + \exp(-z)} - 1, \quad (4.2.11)$$

入力層のニューロンは以下のような特性を持っており、入力されるプロフィール中の最大信号で正規化される。

$$O_1'(x) = \frac{2 \times I(x)}{\max\{I(x)\}} - 1, \quad (4.2.12)$$

ここで、 $I(x)$ は入力プロフィールの画素値、 $\max\{I(x)\}$ はそのプロフィール中での最大画素値を示す。

学習過程においては、全ての重み係数(カーネルとバイアス)はランダムに-0.1から0.1の範囲で初期設定される。学習レイトと学習の慣性係数はそれぞれ0.1と0.9にした。学習データとしては、81枚の画像の中から14枚を適当に選択し、その14枚から140プロフィールを等分に抽出した。ターゲット画像はAdobe社のPhotoshopを使用してマウスのトレースにより作成された。トレーニングに使用する

プロファイルには肺野の輪郭が少なくとも1つ含まれるようにした。後で述べるが、学習に使用するサンプル数は画素数ベースでカウントし、プロファイル単位ではカウントしていない。その意味においては、学習データで肺野の輪郭に相当するデータは非常に少なくなる。そこで、輪郭学習データを多く含めるために、学習プロファイルには輪郭を含んだものを選択した。オリジナル画像と肺の輪郭をトレースしたターゲット画像を Fig.4.2.3 に示す。

ネットワークの出力は実数出力になり、輪郭部での立ち上りと立下りがとれるように、ターゲット画像の輪郭の線幅は概ね 2 画素になるように画像処理した。さもなければ、輪郭が分離して断片になりやすくなる。1 画素が 1 学習サンプルに対応しているため、水平、垂直それぞれのニューラルネットワークに対応する学習データ数は、 232×140 と 286×140 になる。学習サンプル数はネットワークの規模 (Hidden レイヤーの数、クラスターの数、カーネルの長さ) に見合うように決定した。それぞれのネットワークの自由パラメータ数は 436 である。内訳は、入力と第1 Hidden 層との接続に $7 \times 5 + 5$ 個、第1 Hidden と第2 Hidden 層の接続、第2 Hidden と第3 Hidden 層との接続それぞれに対して $(7 \times 5 + 1) \times 5$ 個、第3 Hidden 層と出力層との接続に $7 \times 5 + 1$ 個となる。学習サンプル数は自由度の数の約 100 倍あり、十分な学習データ数ということが出来る。[4.2.4]

学習過程はエラーが学習サンプル数の 10%より小さくなった時点で打ち切ることとした。学習エポックとしては約 20,000 回と要し、Silicon Graphics 社の ONYX を使用して約 18 時間であった。このコンピュータは 190 MHz MIPS R10000 Processors と MIPS R10010 Floating Point Processor が Dual で構成されるマシンである。学習過程の後に試験データを入力してパフォーマンスが評価された。

Fig.4.2.4 に示すオリジナル画像に対して、それぞれの方向に対するニューラルネットワークの出力から再構成された画像、2 値化画像、およびラベリングにより輪郭の断片数を制限した画像を Fig.4.2.5 に示す。水平方向からの画像を見ると、肺野の上部の輪郭は鎖骨の存在により肺のコントラストが曖昧になるので抽出するのは非常に難しい。また、肋骨のエッジにより右肺の外側面の輪郭が分断されてしまう傾向がある。ニューラルネットワークの出力と 2 値化画像がほとんど同一に見えるのは、ニューラルネットワークの出力のエッジが急峻であるためである。(c) で分かるようにラベリングの過程で右肺の外輪郭の必要な断片が失われている。肋骨が輪郭を繋げる上で障害になっている。




Fig.4.2.4 テストに使用した画像のオリジナルイメージ




Fig.4.2.5 水平方向、垂直方向それぞれの処理途中画像

(a)水平方向のニューラルネットワーク出力を8ビットに変換した濃淡画像、(b)水平方向の2値化画像で閾値は127、(c)水平方向のラベリング画像で、輪郭線は4本に制限されている、(d)垂直方向のニューラルネットワーク出力を8ビットに変換した濃淡画像、(e)垂直方向の2値化画像で閾値は127、(f)垂直方向のラベリング画像で、輪郭線は6本に制限されている。(a)と(d)は濃淡画像であるが、輪郭のエッジが非常に急峻でプリントでは2値画像に見えてしまうことに注意。




Fig.4.2.6 水平、垂直画像をORした画像と最終出力画像
 (a)は、Fig.4.2.5(c)の水平方向ラベリング画像と Fig.4.2.5(f)垂直方向ラベリング画像を論理ORした画像。(b)はOR画像に対して輪郭線が2本になるようにラベリングで制限を加えた最終画像。

垂直方向のニューラルネットワークから再構成された画像を見ると、肋骨と脊椎の接続部の影で肺のコントラストが曖昧になり、両肺の内輪郭がほとんど断片化してしまっている。肋骨の影のない心臓と肺の重なり部分の輪郭は良く抽出されている。ラベリングの過程で首、頸椎部分で発生している細かいノイズは除去されている。ただし、必要な両肺の内輪郭の断片も除去されてしまう。

垂直方向と水平方向のラベリング画像の論理ORをとった画像、およびそれに対してラベリング(これが本手法の最終出力画像である)を行った画像を Fig.4.2.6 に示す。ラベリングの過程においては連続する輪郭の数を2個に制限している。右肺の横隔膜に接する輪郭が2本発生しているのがわかる。水平方向と垂直方向のネットワークでことなる輪郭ラインを検出しているためである。




Fig.4.2.8 71枚のテスト画像に対する正解度(accuracy)
 正解度は式(4.2.10)で計算される。ターゲット画像は、14枚の学習画像と同様の手法により作成された。

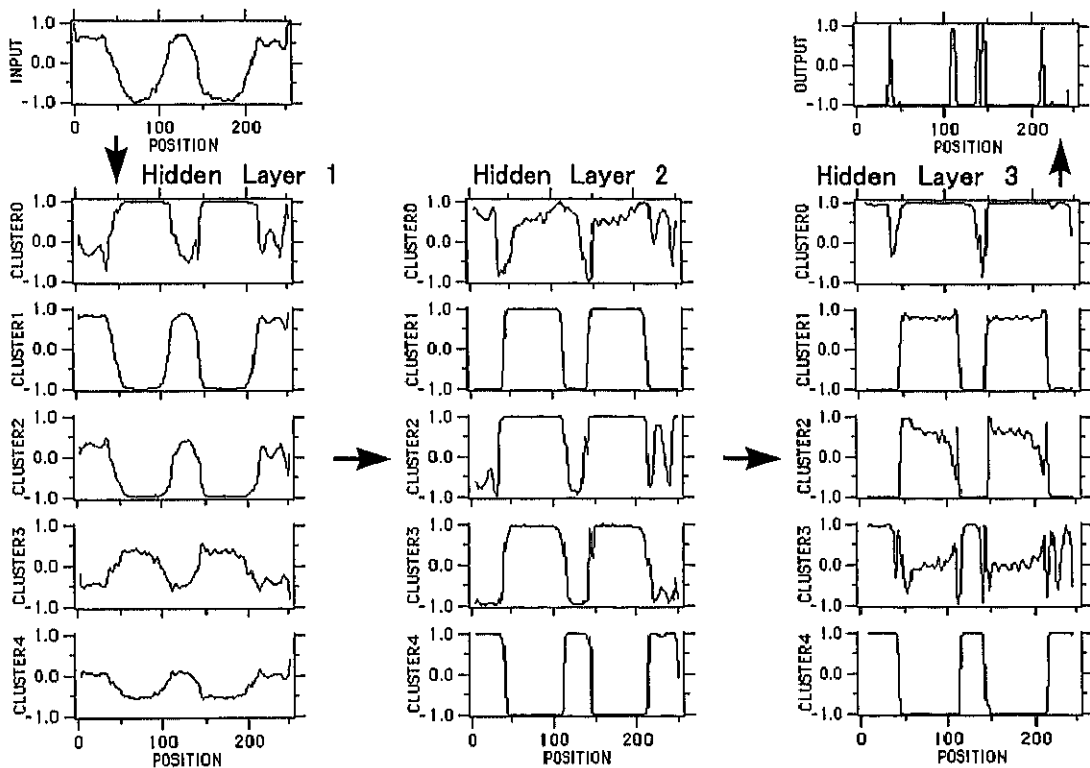


Fig.4.2.7 ニューラルネットワーク内部のエッジ検出の様子
 学習の後に、肺野を横断する水平 Profile を入力した場合の、各 Hidden 層の
 5 個のクラスターと出力エッジ信号を表している。入力 Profile 信号の 2 つの
 谷は、肺による信号の落ち込みを表している。出力 Profile で表現されている
 輪郭エッジの立ち上がり、および立下りは急峻で 2 値データのように見える。

水平方向の 1 本のプロファイルに対するニューラルネットワークの計算過程を Fig.4.2.7 に示す。各層の接続特性を単純に Low-pass、High-pass、または Phase-shift フィルターを分類することは出来ない。しかし、ここで導入したニューラルネットワークのクラスター数、あるいは／および Hidden 層の数は、この問題を学習するには多すぎるように想像できる。それは、いくつかのクラスターのパターンが非常に似通っているからである。規模の小さなネットワークでパフォーマンスを試してみることも考えられる。

ここで導入したニューラルネットワークの目的はエッジの検出であるが、見方を変え
 るとフィルターの自動設計と考えることもできる。また、クラスター間を接続するカー
 ネルのサイズが 7 であることから、バイアス項を無視すると 7 次元空間での処理
 と考えることができる。水平方向を考えた場合、入力されたプロファイルは 232
 個のデータに分解され、接続カーネルと同様に 7 次元空間に分布することになる。
 コンボリューションは 7 次元空間上での内積と考えることができ、高位の層への伝

達は内積の和と考えることが出来る。第 3Hidden 層を考えた場合、それぞれのクラスター内部のある部分がそれぞれのカーネルと非常に強い相関を持っていれば、そこはエッジとして検出されることになる。

学習に使用しなかった 71 枚の画像に対して式(4.2.10)で定義される正解度 (accuracy)を計算した結果を Fig.8.にしめす。提案した手法は 71 枚の画像に対して平均 94%の正解度で輪郭を抽出することが出来た。悪い結果を示す画像は、前章で説明した画素毎のセグメンテーション手法と同様に、撮影時の曝射線量が不足しているために肺野と周囲との濃度差がないものである。このような場合には、肺野と周囲の濃度差を拡大化するような前処理が必要となる。

4.2.3. 考察

画像に対しては 2 次元ベースのニューラルネットワークを使用するのが直感的であるが、本手法では画像を 1 次元プロファイルに分解して 1 次元ニューラルネットワークを適用した。比較的簡単な後処理を加えることにより 71 枚の画像に対して正解度 94%で輪郭検出を行うことが出来た。

2 次元コンボリューションネットワークを使用した長谷川の手法と比較を行う。彼は5枚の画像に対して学習した後に21枚の画像を試験し、主観的なレポートを残している。彼の手法の眼目は後処理にあり、それはニューラルネットワークの出力に対して Laplacian edge detection から始まっている。彼のニューラルネットワークの出力は単なる Low-pass フィルター的な機能しか果たしていないからである。この Laplacian edge detection を含めた後処理により輪郭検出のほとんどが達成されているとって過言でない。他方、Fig.4.2.7 から分かるように筆者が提案した手法においては、ニューラルネットワークは High-pass フィルターの機能を有している。機能の相違はターゲット画像をどのように与えるかに依存している。肺野の輪郭のみを与えるか、肺野の外形を与えるかの相違である。つまり、ターゲット画像の与え方によってはエッジ検出機能を持ったり、外形検出機能を持ったりすることになる。しかし、最終的にエッジ検出を目的とするのであればターゲット画像は輪郭のみを与えたほうが、余分な後処理が不要になり好ましいと考える。ニューラルネットワークのサイズについて比較すると、長谷川のシステムは 1049 にあるのに対して、872 と若干小さい。また、後処理の複雑度を比較すると、彼の手法は輪郭変化の tangent に制限を加える複雑なアルゴリズムである。

1次元のニューラルネットワークを使用するメリットは、(1)ネットワークが小さくなる
(2)ネットワークが小さくなれば学習データも小さくて済む、が考えることができる。
デメリットとしては、1次元でラインを追跡しているので検出が大きい外れる心配
があることである。また、最終段の後処理は2次元上で行う必要があるかもしれ
ない。しかし、本手法のようにラベリング処理を組み合わせることによりパフォー
マンスのよいシステムに完成させることも可能である。今後の課題としては、
Fig.4.2.7に関連して結果の項でも述べたように、ネットワークサイズとパフォー
マンスの関係をネットワーク内部の処理過程を観察しながら研究することである。

4.3. 解剖学的領域情報を利用した画像再生

デジタル X 線画像に於いて、診断に有効な画像を再生 (Reproduce) するための画像処理アルゴリズムは多数報告されている。胸部画像は X 線画像中でもっとも主要な画像であり、胸部画像に関する画像処理アルゴリズム報告が最も多いといってもよい。これらの研究の目的の一つは肺野と縦隔の両方で画像を改善することにある。

X 線フィルムは X 線透過線量換算で約 2 桁のダイナミックレンジを有しているが、肺野と縦隔からの透過線量比は約 1.5 桁近くある。一般的に放射線医は肺野の濃度が 1.6-1.8 に調整されていることを要求するので、透過線量比が約 1.5 桁ある縦隔の濃度はフィルムのベース濃度に近い 0.2-0.4 になってしまう。フィルムをシャーカステンにかけた場合、濃度 0.2-0.4 では人間の目のコントラスト分解能が悪く、従って診断能が悪くなる。つまり、従来のアナログ的なフィルム・スクリーンシステムにおいては縦隔部、横隔膜下の診断は非常に難しかった。

デジタル画像処理により縦隔部、横隔膜下の描出を改善し、縦隔部での血管等の構造線を明瞭化し、横隔膜近くの肺野中の結節を可視化しやすくすれば、フィルム・スクリーンシステムで得られるアナログフィルムより診断能の高い画像を提供することができる。ここでは、最初にデジタル画像処理を行う上での制約条件を明確にしておく。

- (1) 放射線医は空間、および濃度解像力的に優れているフィルムで診断することを好む。つまり、CRT 診断は敬遠される。デジタル画像をフィルム化するレーザイメージャの空間分解能は 300 画素/インチ、濃度分解能 4096 であるのに対し、医療用に使用される高精細 CRT の空間分解能は 150 画素/インチ、濃度分解能 256-1024 である。レーザイメージャで出力したフィルムで診断する場合も、フィルム・スクリーンシステムと同様に肺野部の濃度は 1.6-1.8 でなくてはならず、また肺野で濃度ガンマも 2.8-3.0 が要求される。
- (2) CRT で診断することにしても、放射線医がマウスやトラックボールで階調を調整しながら診断することは、時間が掛かるとともに操作が複雑になる可能性があり診断スループットを落とすことになり敬遠される。

つまり、肺野内部の微細構造の濃度、コントラストを維持しながら、肺野と縦隔部の濃度差を圧縮することにより縦隔部の診断能をさせるような自動調整アルゴリズムが要求されている。

診断に有効な画像をつくるための QA 処理は広義には画像強調処理と解釈することができる。画像強調処理は大きく2種類に分類することが可能である。

- (1) 周波数強調: Unsharp Masking 処理 (USM) や Gradient Operator を使用する
- (2) 濃度変換: Histogram Equalization 処理や Dynamic Range Control を使用する

USM は構造のエッジを明瞭化する場合や画像の高周波成分を強調する場合に広く使用されるテクニックである。よく知られている USM は、オリジナル画像に平均化フィルタをコンボリューションして得られる Unsharp 画像とオリジナル画像の差分を高周波成分としてオリジナル画像に加算して高周波強調された画像を得る。[4.3.1] 一般的に言って USM は、線形と非線形の2つの手法に分類することができる。線形手法においては、前述のように画像の High-Pass 成分にグローバルに重み定数が掛けられ、これがオリジナル画像に画素毎に加算される。非線形手法においては、画像の High-Pass 成分に画素毎に決定された変数が掛けられ、これがオリジナル画像に加算される。ここで画素毎に決定された変数とは、たとえば画素値の強度に依存した値である場合、画素の周辺の構造に依存した値である場合等が考えられる。

Rogowska と Sezan は、胸部 X 線画像に対して線形と非線形の USM を適応し先駆的な研究を行った。[4.3.2-4.3.3] 閾値によって肺野と縦隔部を解剖学的に弁別して乗算係数決定する手法と、非対称なマスクングによりオーバーシュートやアンダーシュート等のアーチファクトを制限する手法が Sezan より提案されている。[4.3.3] Tahoces は異なるマスクサイズによる2枚の Low-Pass 画像の線形和をマスク画像に採用する手法を提案した。[4.3.4] 彼のアイデアは高周波だけでなく中間周波数成分も選択的に強調するものである。また、彼はオリジナル画像と平均化画像のヒストグラムの相違をもとにコントラストを非線形に引き伸ばす手法も提案している。Lin は Radiodense な部分を選択的に強調するための濃度依存的な手法を提案している。[4.3.5] ここで Radiodense な部分を選択する手法として Wavelet フィルタが使用され、フィルタの出力値によりオリジナル画像と Unsharp Mask 画像の組み合わせ比率が決定される。

Gradient operator は局所的な微分を計算することによってエッジ検出を行う手法である。Daponte は Sobel operation と Robert operation の違いを調査し、さらにそれらの後処理として行われる Pill Box、Gauslan、Median フィルタの Noise Reduction 効果について評価した。[4.3.6] Ji は Blockwise の適応型 Unsharp Masking 手法を提案した。ここでは、画像の局所的なコントラストと観察者の Just-Noticeable-Difference をもとに、要求されるコントラストエンハンス量が調整される。[4.3.7]

Histogram Equalization (HE) は非常によく知られたコントラスト強調処理であり、ここでは可能な出力値範囲の中で画素値の分布がフラットになるようにする。実際には画素値の累積分布関数をもとに変換 Look-Up-Table が計算される。Histogram Equalization を画像全体に適用したとすると、その画像のヒストグラム分布が一部の画素値に偏って分布している場合にコントラストは著しく改善される。局所的にヒストグラムが著しく変化する胸部 X 線画像に関しては、画像を細かい領域に分割し局所的な Histogram Equalization を行うところが報告されている。Pizer はこの処理時間を要する適応型 Histogram Equalization (AHE) を短縮化する方法を提案している。ここでは、局所的なヒストグラムは何点かのサンプルポイントでのみ計算され、ヒストグラムが計算されないポイントに関しては4近傍周辺の Histogram Equalization 値からの線形補間で求められる。[4.3.8] また、彼はノイズの過度の強調を押さえるために Clipped AHE 法も提案している。ここでは、コントラスト強調の度合いを制御するために Limiting Slope 値を導入している。[4.3.9]

Zimmerman は、CT 画像を使用して AHE の診断効果を評価している。そして、AHE と従来の Window Width と Window Level を変更させる手法とに診断効果に差がないと結論づけている。[4.3.10] Sherrier は局所的適応型 HE を提案している。ここでは、解剖学的な部分の判断を $K \times K$ カーネル内の累積ヒストグラムのパターンで行っている。この手法では肺野は処理の対象とはならず、縦隔と横隔膜下のみが処理対象となり、肺野から縦隔、横隔膜下に移行する領域では HE の変換 Look-Up-Table は線形補間により計算される。[4.3.11] Crooks は医療画像のエッジ検出、エッジ強調に適応できるヒストグラムシフトアルゴリズムを提案している。ここでは、出力値はオリジナル画素値とその周辺領域の最大値あるいは最小値との差分で計算される。ここで使用される周辺領域の最大値および最小値は、対象画素の $K \times K$ カーネル内の最大値、最小値に Scaling 係数を乗じて求められる。この Scaling 係数を変化させることによりエッジ強調からエッジ検出まで調整することが出来るとしている。[4.3.12] McNitt-Gray は PACS (Picture Archiving and Communication System、医療診断用の画像蓄積、処理装置) で使用される自動エンハンスメントシステムを開発した。ここでは、グローバルなヒストグラムから Dense-Tissue か Soft-Tissue のいずれを強調するかが決定される。[4.3.13]

この項の主題として取り上げるダイナミックレンジ圧縮 (Dynamic Range Compression) は、Look-Up-Table の変更やエッジ強調を直接的 (Direct) なエンハンスメントと考えると、間接的な (Indirect) エンハンスメントと考えることが出来る。胸部 X 線画像の大きな特徴は、肺野から縦隔へと非常にダイナミックレンジが広

く、従来の Windowing 手法では一度に肺野と縦隔を観察することが難しい点にある。微細でしかも有効な情報を保存しながら画像全体を一度に診断可能とするこの DRC は Display 手法と分類されるのかもしれない。富士写真フィルムは DRC を彼らの製品である輝尽性蛍光体を使用したデジタル X 線画像装置 FCR で使用している。[4.3.14] その報告の中で、従来、胸部 X 線画像は肺野を観察する画像と縦隔を観察する画像の2枚の画像を医師に提供して診断が行われてきたが、DRC を適用することにより1枚の画像で診断が可能になるといっている。しかし、富士写真フィルムの手法は、大谷らが提案した自己補償フィルタを参考にしており原理的には新規性のあるものではない。[4.3.15] さらに、彼らの提案している DRC は対象画像内部の解剖学的情報は使用しておらず、また DRC を実行する際のパラメータの決定手法も適応的に決定されるものではない。

前述したように、解剖学的情報をもとに決定されたパラメータを使用して DRC を行う ADRC (Anatomic Region Base Dynamic Range Compression) を提案するのが主題であるが、同様に解剖学的情報を使用して行う AHEQ (Anatomic Region Base Histogram Equalization) および AHEQ と ADRC を連続的に適用する手法もあわせて説明する。他方、ここで導入する ADRC、AHEQ はいずれも肺野と縦隔部の解剖学的なセグメンテーションの結果をもとに処理パラメータが決定される。ここでは、4.1.項で提案した解剖学的なセグメンテーション手法の結果を使用しているが、提案した ADRC、AHEQ がセグメンテーション結果の精度にどれくらい感度があるかも議論する必要がある。

4.3.1. 解剖学的領域情報を利用した画像再生アルゴリズム

(A) 胸部画像データベース

4.2.の肺野セグメンテーションで使用した Johns Hopkins 大学付属病院の 85 枚のスクリーニング胸部正面画像から、セグメンテーションの学習データとして使用した14枚を除いたトータル 71 枚の画像を使用する。それらの画像をレーザフィルムデジタルタイザ (ルミシス社モデル 1500) を使用して 2000 x 2500 画素、12 ビットの画像にデジタル化する。情報量を減らすために、オリジナル画像は 256 x 310 画素へ平均化縮小され、同時に画像内の最大値と最小値の間を255レベルに分解するように 8 ビットに変換する。平均化に使用した 8x8 画素のカーソルは、物理サイズとしたは 1.4 x 1.4 mmの大きさを有する。画像の縮小は、セグメンテーションの演算時間を減らすために行われたが、256 x 310 画素の画像でも本手法の有効性を主観的、客観的に評価をするには十分と考える。

(B) 解剖学的領域の定義

本論分で導入するADRC(Anatomic Region Base Dynamic Range Compression)、AHEQ(Anatomic Region Base Histogram Equalization)、およびAHEQとADRCを連続的に適用する手法は、放射線医が診断しやすくするために、肺野、縦隔部、あるいはその両方の視覚化を改善することを目標とする。そこで、縦隔部の定義を明確にしておく。縦隔部とは、両肺に挟まれた縦隔、心臓、横隔膜および横隔膜下を含んでいる。以後、縦隔部の定義は、上の複合領域とする。

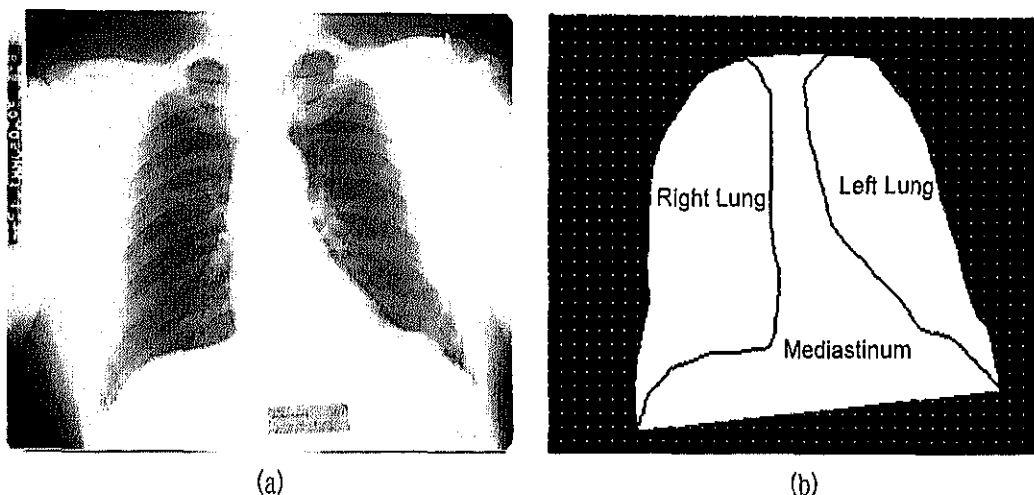


Fig.4.3.1 胸部 X 線画像例のオリジナル画像(a)とセグメンテーション画像(b)
両肺野で挟まれた領域を縦隔部(mediastinum)と定義する。

ADRC と AHEQ で使用する解剖学的情報としては、胸部画像は(1)肺野、(2)縦隔部、および(3)その他にセグメンテーションされている必要がある。しかし、4.1. 項や 4.2 項で提案した手法は、胸部画像を肺野とその他に分離するのみである。そこで、二つの肺輪郭から縦隔部を定義する簡便な方法を用いる。両肺の輪郭の上端をそれぞれ直線で繋ぎ、同様に両方の下端を繋ぐ。次に、上の2本の線分と両肺の内側のアウトラインで形成される領域をもとめ、それを縦隔部とするものである。オリジナル画像と4.2章の手法により肺野がセグメントされた画像を Fig.4.3.1 の(a)と(b)にそれぞれ示す。Fig.4.3.1 (b)のアウトラインで囲まれた領域が、それぞれ右肺、左肺、および縦隔部である。後述するように、ADRC は解剖学的部位間(胸部画像なら肺野と縦隔部)の相関分布の差を利用するが、この前提は解剖学的同一部位内では対象としている計測量が近似していることが前提である。その意味で、ここで定義した縦隔部を構成している縦隔、心臓、横隔膜下等が近似した計測量を持っていることが前提であるが、Fig.4.3.1 (a)から分かるように胸部画像の場合、この前提は成立すると考えて良い。

(C) 解剖学的領域情報を利用したヒストグラム平滑化処理(AHEQ)

ヒストグラム・イコライゼーション(以後、HEQ)は、画像改善では非常に良く知られたテクニックである。HEQは、出力可能なグレイレベル全般にわたって、出力画素値頻度が平坦になるように画素値変換するものである。AHEQと従来のHEQとの相違は、HEQが画像の全領域を対象にするのに対し、AHEQは画像中の診断関心領域(胸部正面画像の場合は、肺野と縦隔部)のみの画素値のヒストグラムを計算し、その分布を出力濃度域全体に対して頻度がフラットになるように変換するものである。つまり、診断画像の場合関心領域は固定されており、胸部正面画像では肺野と縦隔部が診断領域であり、決して肩や首は診断することなく、ヒストグラムを作成する際に肩や首を対象にするのは意味のないことである。ちなみに、放射線医、あるいは病院によっては胸部画像では肺野しか診断しないところもあり、その場合は肺野のみを対象としてヒストグラムを作成するのが合理的である。

AHEQのアルゴリズムを以下に説明する。オリジナル画像の座標 (n,m) での画素値を $I[n,m]$ 、 $0 \leq n \leq N-1$ 、 $0 \leq m \leq M-1$ で表す。ここで、 N は画像マトリックスの列の数、 M を行の数を表している。 $I[n,m]$ は濃度の逆数であるので、フィルム濃度が高いほど画素値 $I[n,m]$ は小さくなる。関心領域(肺野と縦隔部)内の画素値 u_i の発生確率を $p(u_i)$ は以下のように表現できる。

$$p(u_i) = \frac{h(u_i)}{\sum_{j=0}^{L-1} h(u_j)}, 0 \leq i \leq L-1 \quad (4.3.1)$$

ここで、 $h(u_i)$ は関心領域内での画素値のヒストグラムを、 L は画像中の濃度レベル数を表している。画素値 u_i までの累積確率 v_i は以下の用に計算できる。

$$v_i = \sum_{j=0}^i p(u_j) \quad (4.3.2)$$

このとき、AHEQの出力画素値 v'_i は以下のように与えられる。

$$v'_i = \text{int} \left[\frac{v_i - v_{\min}}{1 - v_{\min}} \times (L' - 1) + 0.5 \right] \quad (4.3.3)$$

ここで、 int は整数部分、 L' は出力画素値の最高値、 v_{\min} は累積確率 v 中で最小値を表している。そして、出力画素値は v'_i は、関心領域内ではほぼ均等に分布する。関心領域外の画素値も同様に式(4.3.2)と式(4.3.3)を使用して画素値変換されるが、画素値 $I[n,m]$ が u_{i-1} が大きい場合は u_{i-1} として変換され、画素値 $I[n,m]$ が u_0 より小さい場合は u_0 として変換される。以上説明したように、AHEQでは画素中の全ての画素値が、関心領域のみ画素値分布から抽出されたテーブルで変換される。

(D) 解剖学的領域情報を利用したダイナミックレンジ圧縮処理 (ADRC)

前述したように ADRC を胸部正面画像に応用した場合、(1)ダイナミックレンジの圧縮を肺野に適用する、(2)ダイナミックレンジの圧縮を縦隔部に適用する、(3)ダイナミックレンジの圧縮を肺野と縦隔部の両方に適用する、の3通りを考慮することが出来る。ここでは、従来あまり行われなかったが、胸部画像を CRT モニタのようなダイナミックレンジの狭い表示装置で観察する場合にしばしば起こる肺野中央部の輝度が落ちすぎる(フィルムの場合は濃度がのりすぎる)現象の対応策となる、肺野部のダイナミックレンジ圧縮について検討する。つまり、ここでの ADRC の目的は縦隔部の濃度分布を保存しながら、肺野のダイナミックレンジを圧縮することである。ただし、肺野のダイナミックレンジは圧縮するが詳細情報は保存する必要がある。

ADRC は肺野と縦隔部に対する画素値・平均画素値相関分布を規準に処理が行われる。ここで、画素値・平均画素値相関分布とは、ひとつの解剖学的領域内の画素に対する画素値 $I[n,m]$ と、座標 (n,m) を中心とした $K \times K$ カーネル内の平均画素値 $Ia[n,m]$ との相関分布をいう。平均画素値 $Ia[n,m]$ は以下のように計算できる。

$$Ia[n,m] = \frac{1}{K^2} \sum_{i=-\frac{K}{2}}^{\frac{K}{2}} \sum_{j=-\frac{K}{2}}^{\frac{K}{2}} I[n+i,m+j] \quad (4.3.4)$$

ここで、 K はカーネルサイズ(奇数)で、ここでは経験的に15画素(約20mm)に設定する。ADRCでは K を変化させることにより、自動的に決定されるワーピング関数(ダイナミックレンジ圧縮の対象となる解剖学的領域の相関分布をワープするための関数)が変化する。また、 K はADRCにおいて相関分布を決定する唯一の関数であり、これの選択に関しては考察の項でふれる。

Fig.4.3.2(a)に画像全体と肺野領域のみに対する典型的な画素値・平均画素値相関分布を示す。薄いグレーのドット、濃いグレーのドットは、それぞれ画像全体と肺野領域に対する画素の画素値 $I[n,m]$ と平均画素値 $Ia[n,m]$ を表している。ただし、多くのドットがオーバーラップしているし、画像全体に対するドット分布の上に肺野のドット分布が載っていることに注意を要する。Fig.4.3.2(b)に黒いドットで示す縦隔部の分布を、Fig.4.3.2(a)の画像全体と肺野領域に対する分布に重ねた図を示す。Fig.4.3.2(a)と(b)を比較してみると、縦隔部の分布に比べて肺野の分布がより広く分布しているのがわかる。当然のことであるが、広く分布していればより視覚化は難しいと云うことになる。Fig.4.3.2(c)に、Fig.4.3.2(b)に示した分布をあるワーピング関数でワープした例を示す。このワーピング関数は縦隔部領域の分布はまったくワープさせていない。つまり、ワーピングの適用・非適用を分ける境界線を縦隔部の分布のすぐ下に設定して、境界線の下はワープさせているが、境界線の上はワープさせていないのである。Fig.4.3.2(c)と Fig.4.3.2(b)の肺野領域の分布を比較すると、ワーピングの後で画素値レンジが狭くなっているのが分かる。




Fig.4.3.2 解剖学的部位毎の画素値と周辺平均画素値の相関分布

横軸が画素値、縦軸が周辺平均画素値で、1画素が1点に対応するがオーバーラップすれば点の識別は出来なくなる。(a)画像全体に含まれる画素の相関分布と明るい灰色の点、両肺野に含まれる画素の相関分布を暗い灰色の点で示す。肺野の分布の、画像全体の分布に対する配置を観察できる。(b)縦隔部に含まれる画素を黒い点で表してオーバーラップさせた。この図からも肺野の画素値レンジが縦隔部より広がっていることが分かる。この広いレンジが肺野の視覚化を難しくしている。(c)ADRCのアルゴリズムにより縦隔の分布の下にワーピングラインを設定して、そのラインの下側の分布をワーピングした(画素単位で考えるとシフト)後の相関分布を示す。これで肺野の画素値レンジは15%程度圧縮され、肺野の視覚化改善が期待できる。

(1) ワーピングラインの抽出

上で述べたワーピングの適用・非適用を分ける境界線をワーピングラインと呼ぶこととし、ここでは相関分布からワーピングラインの候補を抽出するアルゴリズムについて説明する。ただし、ワーピングラインは直線である必要はなく曲線であってもかまわず、さらには、ワーピングラインは1本に限定されるものでなく、前述した肺野と縦隔部両方のダイナミックレンジ圧縮するような場合はワーピングラインを2本設定することもできる。しかし、ここでは簡単のために1本の直線のワーピングラインを前提にする。

ここでは縦隔部の相関分布を保存することを考えるので、3本のワーピングライン候補を縦隔部のすぐ上に設定することにする。最初に、縦隔部に属する画素の中で平均画素 $Ia[n,m]$ が最も小さいから3点を以下のように抽出する。

$$y_2 = \min\{Ia[n,m]\}, x_2 = I[n,m], (x_2, Ia[n,m]) \in MD, \quad (4.3.5.1)$$

$$y_1 = \min\{Ia[n,m]\}, x_1 = I[n,m], Ia[n,m] > y_2, (x_1, Ia[n,m]) \in MD, \quad (4.3.5.2)$$

$$y_3 = \min\{Ia[n,m]\}, x_3 = I[n,m], Ia[n,m] > y_2, (x_3, Ia[n,m]) \in MD, \quad (4.3.5.3)$$

ここで、 x 軸と y 軸はそれぞれ画素値 $I[n,m]$ と平均画素値 $Ia[n,m]$ に対応し、 MD は縦隔部に対する相関分布を示し、 $0 \leq x_1 < x_2 < x_3 \leq L-1$ が満たされているとする。3つの最小点を検索プロセスは式(4.3.5.1)、式(4.3.5.2)、式(4.3.5.3)の順に実行される。抽出された3点の相関分布上での座標は、 (x_1, y_1) 、 (x_2, y_2) 、 (x_3, y_3) で表される。ただし、式(4.3.5.2)において複数の点が最小値 y_1 を示す場合があるが、この場合はそれらの点の x 座標値の平均をとって x_1 とする。このことは式(4.3.5.3)に対しても同様であり、その場合は x_3 も平均座標が計算される。

次に、抽出された3点 (x_1, y_1) 、 (x_2, y_2) 、および (x_3, y_3) を使用して3本のワーピングライン候補 $WL1$ 、 $WL2$ 、および $WL3$ が以下のように決定される。

$$\begin{aligned} WL1 : (x_2 - x_1)y &= (y_2 - y_1)x + y_1x_2 - y_2x_1, \\ WL2 : y &= y_2, \\ WL3 : (x_3 - x_2)y &= (y_3 - y_2)x + y_2x_3 - y_3x_2, \end{aligned} \quad (4.3.6)$$

ここで、ワーピングライン候補 $WL1$ は座標 (x_1, y_1) と (x_2, y_2) を通る直線であり、 $WL2$ は座標 (x_2, y_2) を通る傾きゼロの直線であり、 $WL3$ は座標 (x_2, y_2) と (x_3, y_3) を通る直線である。ただし、相関分布の性格によっては最小点 (x_2, y_2) の座標 x_2 が

MD 中の x 軸レンジでの最小点である場合があり、このとき点 (x_1, y_1) は存在しないことになる。そのときは、座標 (x_1, y_1) は (x_2, y_2) と同一座標として、ワーピングライン候補 $WL1$ は存在しない、あるいは $WL2$ と同一であるとする。Fig.4.3.3 に、抽出された 3 点 (x_1, y_1) 、 (x_2, y_2) 、 (x_3, y_3) 、およびワーピングライン候補 $WL1$ 、 $WL2$ 、 $WL3$ 例を示す。ここでは、濃いグレーのドットと黒のドットを使用して、それぞれ肺野と縦隔部の相関分布を示している。Fig.4.3.3 から分かるようにワーピングラインはワープされる相関分布の領域を決定し、ここではワーピングラインの下側領域がワープされるのであるからワーピングライン候補 $WL3$ が最も大きい領域をワープすることになる。

(2) ワーピングアングルの抽出

上で抽出された 3 つのワーピングライン候補を評価する前に、それらに対する適当なワーピングアングルを決定する必要がある。ワーピングアングルはワープの強度を制御するスケールファクタであり、ワーピングアングルが適切なレベルより大きい場合は、画像中にかなりはっきりしたアーチファクトが発生する。以下では、アーチファクトを生じないような適切なワーピングアングルを決定する方法を説明する。基本的なポリシーは、画素値間の大小関係を逆転させないようにすることである。

最初に、ワーピングライン WL と、肺野中の画素の画素値 $I[n, m]$ と平均画素値 $Ia[n, m]$ の相関分布の左側輪郭が交わる点 (x_4, y_4) を抽出する。座標 (x_4, y_4) の求め方を以下に詳しく述べる。肺野の相関分布 LD をワーピングライン WL で 2 分割したときの、上方の相関分布を ULD 、下方の相関分布を LLD とする。上方肺野相関分布 ULD 中で画素値 $I[n, m]$ が最小値を示す (x_u, y_u) を以下のように探索する。

$$x_u = \min\{I[n, m]\}, (I[n, m], y_u) \in ULD \quad (4.3.7)$$

ただし、画素値 $I[n, m]$ が最小値を示すドットが複数点ある場合があるので、平均画素値 $Ia[n, m]$ が最小となる点を y_u とする。

$$y_u = \min\{Ia[n, m]\}, (x_u, Ia[n, m]) \in ULD \quad (4.3.8)$$

上で求めた上方肺野相関分布中の座標 (x_u, y_u) に対して、下方肺野相関分布 LLD 中で最近傍となるドット座標 (x_l, y_l) を以下のように求める。

$$x_l = \min \{ \| (x_u, y_u) - (x_l, y_l) \|, (I[n, m], y_l) \in LLD \quad (4.3.9)$$

ここで、 $\| \cdot \|$ はユークリッドノルムを表している。結局、座標 (x_4, y_4) は、ワーピングライン WL と座標 (x_u, y_u) と (x_l, y_l) を通る直線の交点として求めることができる。

次に、肺野相関分布 LD 中で以下の式を満足するドット座標 (x_5, y_5) を抽出する。

$$x_5 = \min \{ I[n, y], I[n, m] < x_4, I[n, m] < y_4, (I[n, m], y_5) \in LD \quad (4.3.10)$$

もし、 x_4 が肺野相関分布 LD 中の x 方向での最小値であれば、式(4.3.10)を満足する (x_5, y_5) を探すことは出来ない、この場合は (x_5, y_5) に (x_4, y_4) 座標をコピーする。最終的にワーピング角度 φ は、上で求めた座標 (x_4, y_4) と (x_5, y_5) をとおる直線と y 軸に平行な線との角度で定義されて、以下のように求めることができる。

$$\varphi = \begin{cases} 0, (y_4 = y_5), \\ \tan^{-1} \frac{x_4 - x_5}{y_4 - y_5}, (y_4 \neq y_5). \end{cases} \quad (4.3.11)$$

Fig.4.3.3 で示した $WL3$ に対する座標 (x_4, y_4) 、 (x_5, y_5) と抽出されたワーピング角度 φ の例を Fig.4.3.4 に示す。このワーピング角度により、例えば座標 (x_4, y_4) と (x_5, y_5) を通る直線上の点は同じ画素値に変換される。アーチファクトを生じないための基本ポリシーである、画素値間の大小関係を逆転させないワーピング角度になっている事がわかる。




Fig.4.3.3 ワーピングライン候補
ワーピングライン候補 $WL1$ 、 $WL2$ 、 $WL3$ は、肺野と縦隔の相関分布から抽出した座標 (x_1, y_1) 、 (x_2, y_2) 、 (x_3, y_3) をもとに決定。




Fig.4.3.4 ワーピング角度の決定
相関分布から抽出した座標 (x_4, y_4) 、 (x_5, y_5) をもとにワーピング角 φ を決定。各ワーピングラインに依存する。

(3) ワーピングラインとワーピングアングルの評価

ワーピングライン WL とワーピングアングル φ を使用して、ダイナミックレンジ圧縮による画素値変換(ワープ)を以下のように表現することが出来る。座標点 (x_0, y_0) が下方肺野相対分布 LLD に属する点、 (x_0, y_0) がワープされた後の座標を (x_w, y_0) 、ワーピングライン WL を下の直線の式で表せるとする。

$$ax + by + c = 0 \quad (4.3.12)$$

ここで、 a 、 b と c は実数であり、 $b \neq 0$ である。ワーピングライン WL は、点 (x_w, y_0) を通って y 軸に平行な直線と、座標 $(x_w, \frac{-ax_w - c}{b})$ で交わることになる。このとき、点 (x_0, y_0) と $(x_w, \frac{-ax_w - c}{b})$ は式(4.3.11)を満足するので、下の式が成立する。

$$\tan \varphi = \frac{x_w - x_0}{\frac{-ax_w - c}{b} - y_0} \quad (4.3.13)$$

式(4.3.13)を変形して、ワープ後の画素値 x_w は下のように計算される。

$$x_w = \frac{x_0 - (\frac{c}{b} + y_0) \tan \varphi}{1 + \frac{a}{b} \tan \varphi} \quad (4.3.14)$$

ただし、以上の画素値変換(ワープ)で注意を要することは、下方肺野相対分布以外であってもワーピングライン WL よりも下方の画素は、下方肺野相対分布 LLD と同様にワープされることである。さもなくばアーチファクトが発生することは間違いない。

Fig.4.3.5(a)にワーピングライン WL に分割された下方肺野相対分布がワープされる様子を図解する。白の点はワープ前の画素、黒はワープ後を表しているが、このように変換が画素毎に行われる。Fig.4.3.5(b)にワープ後の相対分布を示しているが、ここでは肺野だけでなくその他の領域であってもワーピングライン WL より下方の画素は全てワープされることを示している。ここで注意を要する点は、Fig.4.3.2(c)は ADRC の概念を便宜的に理解するのに示したもので、正確にはワー

ブ後は Fig.4.3.5 (b)のように相関分布が上方に凝縮する。これは、画素値がワーピングにより大きくなるように変換されるので、必然的に周辺の平均画素値も大きくなるからである。 Fig.4.3.5 (b)から明白なように肺野のダイナミックレンジは大幅に圧縮されている。

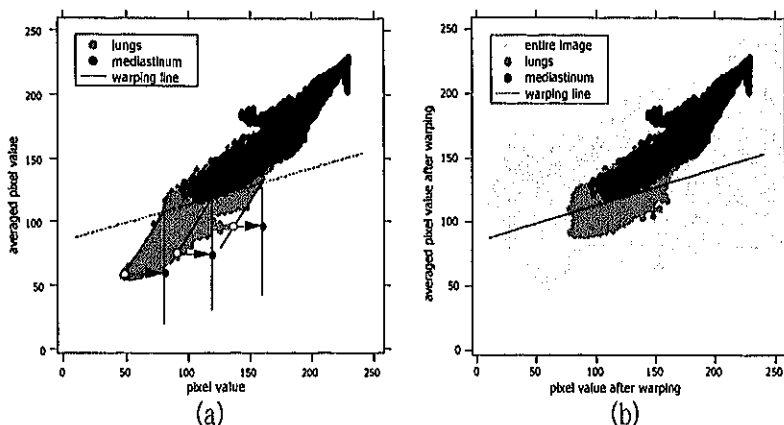


Fig.4.3.5 ワーピングのイメージとワーピング後の相関分布

(a) ワーピングライン WL より下の全ての画素に式(4.3.14)が適用される。ワーピングラインからの距離とワーピングアングルにより白点で示す画素が黒点にワーピングされる。以上の水平方向のシフトを行ったイメージを Fig.4.3.2 で示したが、ワーピング後の相関分布は理解を助けるために作られたものであり、実際は(b)のような相関分布となる。理由はワーピングにより周辺平均画素値もあがるのでワーピングされた領域の分布は上に押し上げられたようになる。

(E) AHEQ と ADRC の組み合わせ処理

ここでは、AHEQ と ADRC の組み合わせ処理について述べる。AHEQ はヒストグラム平滑化用ルックアップテーブルを作成する際に関心領域だけのヒストグラムのみを使用するものであり、胸部正面画像の場合は肺野と縦隔部が関心領域となる。AHEQ は関心領域のコントラストを増加させる方向に処理が動作する。このことはコントラストのもともたない縦隔部にとっては効果的であっても、もともとコントラストのある肺野を対象とした場合しばしばダイナミックレンジを広げすぎて、CRT 診断をする場合などは肺野の中央部が黒くなり過ぎて診断しにくくなる場合がある。他方、ADRC を肺野に適応すれば、肺野の詳細な情報を保存しながらダイナミックレンジ(低周波のコントラスト)を圧縮することが可能である。よって、AHEQ 処理によりいったん肺野と縦隔部のコントラストを統計的に改善して、その後 ADRC により肺野部で広がったダイナミックレンジを押さえる処理が有効と思われる。

(F) 評価手法

ここでは上で導入した AHEQ、ADRC、および AHEQ+ADRC の評価方法について述べる。また、この評価を通して ADRC の際に候補として抽出された 3 つのワーピングラインに対する評価も行う。評価関数 G は以下のように定義される。

$$G = \frac{\text{contrast}}{\text{moment}},$$
$$\text{contrast} = \frac{1}{8W} \sum_{S[n,m] \in OA} \sum_{i=-1}^1 \sum_{j=-1}^1 |S[n,m] - S[n+i, m+j]|, (i,j) \neq (0,0),$$
$$\text{moment} = \frac{1}{W} \sum_{S[n,m] \in OA} |S[n,m] - \text{average}|,$$
$$\text{average} = \frac{1}{W} \sum_{S[n,m] \in OA} S[n,m],$$
(4.3.15)

ここで、 $S[n,m]$ は 2 次元画像、 W は関心領域 OA (この場合は肺野と縦隔部) の画素数を表す。一般的な使用されるコントラスト指標は、 A と B を信号強度とすると $|A - B| / (A + B)$ のように表されるが、Fig.4.3.5 (a) から分かるように ADRC は周辺の平均強度に依存してバイアスを付加する作用であり、この結果を従来のコントラストで計算すると以下ようになる。

$$|(A + \text{bias} - (B + \text{bias})) / (A + \text{bias} + B + \text{bias})| = |A - B| / (A + B + 2 \times \text{bias}) \quad (4.3.16)$$

ここで、 bias の値は肺野のダイナミックレンジ圧縮を考えると正の値である。つまり、ADRC を使用した肺野のダイナミックレンジ圧縮による視覚効果向上を、従来のコントラスト指標で評価するとネガティブな評価しかえられないことになる。つまり、従来のコントラストは Fig.4.3.6 (c) に明らかなような ADRC による視覚効果改善の結果を反映していない。ところで、 bias の値は縦隔部のダイナミックレンジ圧縮を考えると負の値になるので、式(4.3.16)で示した従来のコントラスト指標は役立つかも知れない。ただし、この時にも今回導入した評価関数 G は利用可能である。

したがって、ここでは従来のコントラスト指標を若干補正した新しい評価指標 G を提案する。評価指標 G の contrast 部分は対象画素と周辺画素との局所的な(高周波の)コントラストを表し、 moment の項はグローバルな(低周波の)コントラストを表している。 moment が分母にしているのは、ダイナミックレンジの狭い CRT モ

ニタで画像を診断しようとする場合には、グローバルなコントラストが低い方が望ましいことを示している。一般的にダイナミックレンジ圧縮をすると *contrast* 指標が減少するが、それに増して *moment* 指標が減少すれば全体として評価指標 G が改善されることになる。つまり、評価指標 G が大きい方が、視覚化評価が大きいとしている。また、評価指標 G の改善率 R [%] を以下の用に定義する。

$$R = 100 \times \frac{G_{proc} - G_{org}}{G_{org}} \quad (4.3.17)$$

ここで、 G_{proc} と G_{org} はそれぞれ画像処理後、画像処理前の評価指標 G を表している。

4.3.2. 結果

4.1.項の肺野セグメンテーションで使用した Johns Hopkins 大学付属病院の 85 枚のスクリーニング胸部正面画像から、セグメンテーションの学習データとして使用した 14 枚を除いたトータル 71 枚の画像に AHEQ、ADRC、および AHEQ+ADRC 処理を適用した。256 x 310 画素の画像に対する AHEQ、ADRC の処理時間は、ONYX ワークステーション (Silicon Graphics 社製、190Mhz の MIPS R10000 プロセッサと R10010 浮動少数点プロセッサがデュアル構成) を使用して、それぞれ 3 秒と 7 秒であった。ただし、この処理時間には解剖学的セグメンテーションの処理時間は含まれていない。4.1.項のセグメンテーション時間は、約 5000 ニューロンのネットワークを使用して約 90 分であった。

オリジナル画像、AHEQ 処理後画像、および ADRC 処理後画像の例を Fig.4.3.6 (a)、(b)、(c) にそれぞれ示す。オリジナル画像では縦隔部のコントラストが低く、肺野の中央部は暗すぎて診断に支障がある。オリジナル画像および各処理後画像に対する各評価指標を下の表に示す。

Table 4.3.1 Fig4.3.6 に示した 3 枚の画像の評価指標

画像	<i>contrast</i>	<i>moment</i>	G	R [%]
オリジナル画像	4.7	62.5	7.57 e-2	--
AHEQ 画像	5.1	64.5	7.87 e-2	4.0
ADRC 画像	4.7	57.8	8.09 e-2	6.9

Note: 各指標は関心領域 (計算領域) を肺野と縦隔部に限定したものである。全体画像に対する肺野および縦隔部の比率は、それぞれ 30.1% と 18.5% であった。

Fig.4.3.6 (b)に示した AHEQ から分かるように、縦隔部はコントラストの完全が見られるが、肺野に関しては画素値のレンジを広げすぎて視覚化効果としては悪化しているように見える。これは、Table 4.3.1 の AHEQ 画像に関する指標をみれば分かるように局所的コントラストである *contrast* を改善しているが、低周波のコントラストである *moment* も大きくなってしまっていることに符合している。

Fig.4.3.6 (c)に示す ADRC の結果を見ると、縦隔部のコントラストの改善はないが（これは、当然でここでの ADRC は、縦隔部は全くオリジナルを保存している筈）、肺野に関しては画素値のレンジを圧縮しているので視覚的完全が明らかである。Table 4.3.1 の ADRC 画像に関する指標をみると、局所的なコントラストを保存しながら、グローバルなコントラスト *moment* を圧縮していることがわかる。今回導入した評価指標 *G* は総合評価であるが、ADRC は AHEQ より良い値を示している。ここで、ADRC 処理での各パラメータは、式(4.3.12)で定義されるワーピングラインの傾き $-a/b = 0.08$ 、ワーピングアングル $\varphi = 24.4^\circ$ であった。

Fig.4.3.6に示したオリジナル画像、AHEQ 画像、ADRC 画像に対するプロファイルを図4.3.7(a)に示す。プロファイルを抽出したラインの位置はFig.4.3.6(a)に黒いラインで示している。Fig.4.3.7(a)に示すように AHEQ 画像では、何点かで飽和しているが縦隔部でコントラストが改善している。しかし、肺野から縦隔部へのボーダー部分で必要以上にダイナミックレンジを広げているのが分かる。逆に、ADRC 画像では縦隔部の改善はないが、肺野内部での高周波の信号を保存しながら縦隔部から肺野にかけてのダイナミックレンジを圧縮している。




Fig.4.3.7 各処理画像のプロファイル

(a) Fig.4.3.6(a)で示した水平ラインの画素値プロファイルをオリジナル画像、AHEQ 画像、ADRC 画像と比較する。(b) 3本のワーピングライン候補による処理後画像をプロファイルで比較する。プロファイルの場所は(a)で示したラインの右肺部(向かって左)を拡大したものである。




Fig.4.3.6 AHEQ 処理、および ADRC 処理の画像例
 (a)オリジナル画像、(b)AHEQ 処理後画像、(c)ADRC 処理後画像

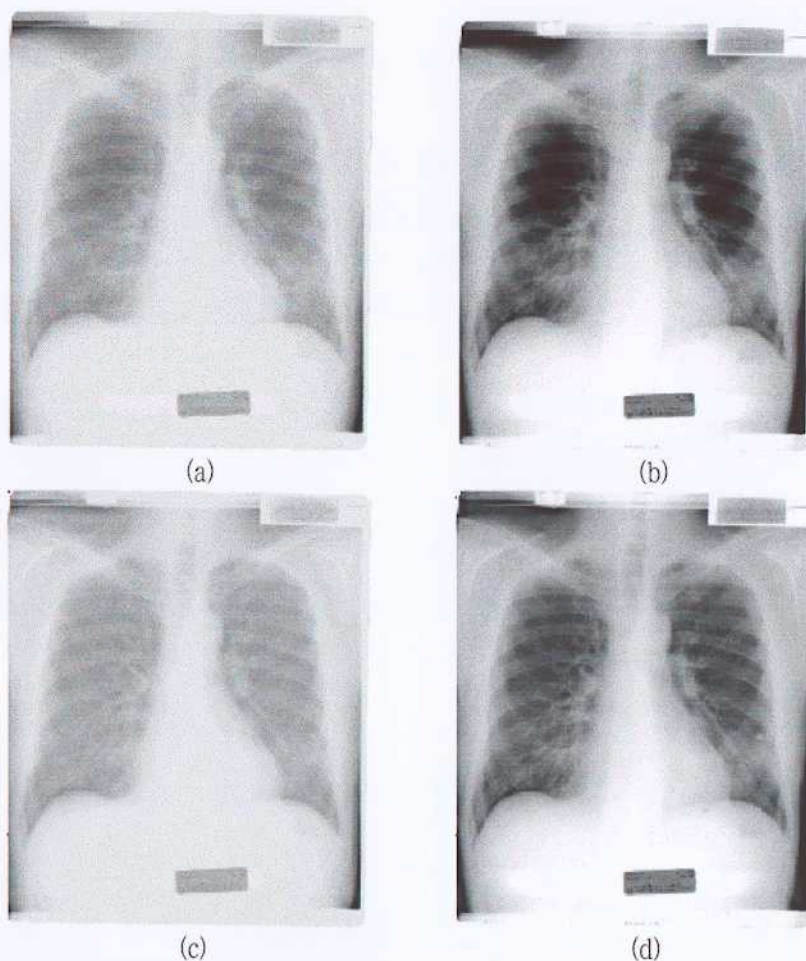


Fig.4.3.9 曝射 X 線量が少ない画像に各処理後画像
 (a)オリジナル画像、(b)AHEQ 画像、(c)ADRC 画像、(d)AHEQ+ADRC 画像

Table 4.3.2 3本のワーピングライン候補の評価指標

ライン	<i>contrast</i>	<i>moment</i>	<i>G</i>	<i>R</i> [%]	$-a/b$	φ
WL1	4.3	56.5	7.68 e-2	1.4	-0.5	28.2
WL2	4.6	56.3	8.17 e-2	7.9	0	27.5
WL3	4.8	57.7	8.29 e-2	9.5	0.25	21.5

Note: Fig.4.3.6 に示した画像に対するもので、各指標は関心領域(計算領域)を肺野と縦隔部に限定したものである。

ADRC 処理での 3 本のワーピングライン候補の比較をプロファイルで行うために Fig.4.3.7(b)に示すが、ここでは Fig.4.3.7(a)の右肺部分を拡大表示している。ワーピングライン WL1 では傾きが負であることから、信号値の低いものがよりワープされることになる。つまり、肺野部分の中央部分がよりワープされることになり、中央部のプロファイルが平坦になっている。3 本のワーピングライン候補に対する評価指標と、ラインの傾き $-a/b$ とワーピング角度 φ を Table 4.3.2 に示す。

ワーピングライン WL2 は傾きがゼロであり、周辺平均信号値が同じであれば、信号値の大きいもの、小さいものが同様にワープされることになる。肺野中央部のプロファイルは、WL1 に比べてオリジナル信号のトレンドを残しているが、肺野のボーダー部分(つまり、縦隔と脇とのボーダー)においてワープしすぎる傾向がある。

ワーピングライン WL3 では傾きが正であり、周辺平均信号値が同じであれば、信号値の大きいものがよりワープされる。つまり、肺野のボーダー部分がよりワープされ、WL1 や WL2 でみられたようなエッジ強調のようなプロファイルにならず、またワーピング角度も小さく抽出される傾向にあるのでより自然な結果となっている。Table 4.3.2 で分かるように、総合指標 *G* でも最もよい結果を示している。




Fig.4.3.8 評価画像 71 枚に対する改善率 *R* とワーピング角度
 (a)ワーピングライン WL1, WL2, 及び WL3 を使用した場合のテスト画像 71 枚に対する改善率。(b)ワーピングライン WL1, WL2, 及び WL3 それぞれに対応するワーピング角度をテスト画像 71 枚に対して示す。

評価画像 71 枚に対する改善率 R を 3 つのワーピングライン $WL1$ 、 $WL2$ 、および $WL3$ に対して求めた結果を Fig.4.3.8(a)に示す。ワーピングライン $WL1$ 、 $WL2$ 、および $WL3$ に対する平均改善率は、それぞれ 2.5%、6.6%、および 11.7%であった。 $WL3$ は他に比べてワーピングアングルが小さいが、一般的にワーピングラインの下方になる画素数が他よりも多くなるので改善率 R は高くなる。改善率 R はワーピング関数(ラインとアングルの組み合わせ)に依存するが、勿論、肺野と縦隔部の相関分布にも依存する。実際、下方肺野相対分布 LLD に含まれる画素数に大きく依存し、 LLD が大きくなればなるほど改善率が大きくなる傾向にあることが容易に予想される。ワーピングライン $WL1$ の改善率はしばしばマイナスになる。これは肺野中央部でのワープし過ぎて、 $contrast$ 値が小さくなりすぎるためと考えられる。

Fig.4.3.8 (b)に、3つのワーピングライン $WL1$ 、 $WL2$ 、および $WL3$ に対する評価画像 71 枚のワーピングアングルを示す。 $WL1$ 、 $WL2$ 、および $WL3$ に対する平均ワーピングアングルは、 30.0° 、 28.2° 、 27.7° であった。ワーピングアングルも肺野と縦隔部の相関分布に依存するが、アングルが小さくなるケースを観察してみると、曝射 X 線量が少なくて肺野と縦隔部の分布が大きく重なっている場合がある。

Fig.4.3.9 に曝射 X 線量が少ない(Under-Exposure)ケースの画像に対する、AHEQ、ADRC、および AHEQ+ADRC の各処理の出力画像を示す。ここで、AHEQ+ADRCとは、ADRC処理に先だててAHEQ処理が行われるものである。Fig.4.3.10にそれぞれに対する相関分布を示す。そして、各画像に対する評価指標を Table 4.3.3 に示す。

Table 4.3.3 Fig.4.3.9 に示す曝射 X 線量が少ない画像例に対する評価指標

画像	$contrast$	$moment$	G	R [%]	$-a/b$	φ
オリジナル	3.2	38.1	$8.32 e^{-2}$	--	--	--
AHEQ	5.3	64.2	$8.22 e^{-2}$	-1.0	--	--
ADRC	3.2	32.1	$9.82 e^{-2}$	18.0	0.09	38.4
AHEQ+ADRC	5.2	58.0	$9.10 e^{-2}$	9.4	0.11	29.2

Note: 各指標は関心領域(計算領域)を肺野と縦隔部に限定したものである。全体画像に対する肺野および縦隔部の比率は、それぞれ 30.1%と 17.6%であった。

オリジナル画像の特徴は Fig.4.3.9 (a)に示す画像から分かるように *contrast* が非常に低いことである。さらに、Fig.4.3.10 (a)からも分かるように *moment* も非常に低い画像になっている。 Fig.4.3.9 (b)に示す AHEQ 処理後の画像の特徴は、腹部では画素値の飽和が認められ、肺野部に関しては、コントラストは改善されているものの、グローバルなダイナミックレンジを広げすぎて肺野の中央部の描出が出来ていない。これは Fig.4.3.10 (b)に示す相関分布からよく観察できて、画素値レンジが広がりすぎていることが分かる。改善率 R はマイナスとなって AHEQ 処理には適さない画像であることが分かる。




Fig.4.3.10 Fig.4.3.9 に示した各画像の肺野と縦隔に含まれる画素の相関分布
(a)オリジナル画像、(b)AHEQ 画像、(c)ADRC 画像、(d)AHEQ+ADRC 画像

Fig.4.3.9 (c)に示す ADRC 処理後の画像では、肺野部のグローバルなダイナミックレンジが圧縮されているのが分かるが、肺野の輝度をもっと落とす効果がこの画像には必要である。改善率 R が 18.0 と非常に高く、これは今回導入した総合指標 G と主観的評価の不一致を表す例となっている。なぜなら、Fig.4.3.6 (c)で示した ADRC 画像の主観的な改善度が Fig.4.3.9 (c)の主観的評価より高いにも関わらず、Fig.4.3.6 (c)の改善率の方が 6.9%と低くなっているからである。Fig.4.3.9 (d)に AHEQ に引き続いて ADRC 処理を行った画像を示す。肺野のコントラスト改善され肺門部からの血管の描出が非常に良く出来ている。肺野の中央部に AHEQ でダイナミックレンジを広げすぎた後が残っているが、これは *moment* が依然として大きくなりすぎていることと符合している。総合指標 G と主観的評価の差異はあるが、AHEQ と ADRC の組み合わせにより、それぞれ単独よりも良好な画像が得られた例である。

Fig.4.3.11 に AHEQ、ADRC、および AHEQ+ADRC 処理の評価画像 71 枚に対する改善率 R を示す。平均改善率は AHEQ、ADRC、および AHEQ+ADRC 処理に対して、2.6%、11.7%、および 7.7%であった。ADRC、および AHEQ+ADRC 処理の際の平均ワーピングアングルは 27.7%、15.5%であった。

相関分布を計算する際のカーネルサイズ K はワーピング関数に影響を及ぼす。ここまでの実験においては 15×15 画素 (物理的には 20mm 正方形) のカーネルを使用してきたが、仮に大きなカーネルを使用すると相関分布は y 軸方向に広がる。ある画素値に対応する周辺平均画素値のバリエーションが広がるからである。すると、Fig.4.3.5 から想像できるようにワーピングアングルは小さくなる。しかし、改善率にはそれほど影響ないことが予想される。なぜなら、 y 軸方向に分布が伸びることにより、ワーピングラインから距離大きくなりワーピング距離が大きくなるからである。

最後に肺野のセグメンテーションの精度と ADRC および AHEQ の関係について議論する。セグメンテーション手法は 4.2 項で提案した手法を使用した。71 枚の画像に対して正解度は 92.4% であり、71 枚それぞれに対する正解度は Fig.4.1.12 示してある。これらの試験画像の順番は Fig.4.3.11 の画像順と同一である。2 つのグラフに相関がないことより改善率はセグメンテーションの正解度に影響されないことが分かる。ADRC および AHEQ のアルゴリズムを考えても容易に推測できることで、肺野の輪郭部での微妙な誤差は相関分布には大きな影響を及ぼさない。




Fig.4.3.11 テスト画像 71 枚に対する各処理の改善率の比較

4.3.3. 考察

Johns Hopkins University Hospital で撮影された 71 枚の胸部正面スクリーニング画像に対して、肺野部を自動的にセグメンテーションする過程に引き続いて AHEQ、ADRC および AHEQ+ADRC の処理を適用し、画像を CRT のようなダイナミックレンジの狭い表示装置で診断する際の視覚化指標において平均 2.6%、11.7%、7.7% の改善を達成した。

AHEQ は縦隔部の視覚化度を非常に良く改善するが、画像によっては肺野のダイナミックレンジを広げすぎ、かえって診断を難しくする場合があった。AHEQ は表示系の十分な描出ダイナミックレンジが保証されているときは安定した処理となることが予想される。ADRC は肺野内部の詳細情報を保存しながら肺野全体のダイナミックレンジを圧縮し、肺野の視覚化には非常に有効であることを示した。ADRC を適用する際に自動的に決定されるワーピングライン $WL1$ 、 $WL2$ 、および $WL3$ を提案した指標をもとに評価した。ワーピングライン $WL3$ がより多くの画素をワーピングするとともに、プロファイルの観察により自然なダイナミックレンジの圧縮を達成できることがわかった。また、結果の項で詳細に述べなかったが、ワーピングライン $WL3$ で示すような傾きが正であるようなワーピングラインは、微小信号のコントラストを緩和する効果があることを追加しておく。この効果は ADRC を線量不足の領域に適用するとき生じる量子雑音の顕在化を緩和するのに利用することができる。

ここで、ADRC の周辺平均画素値を計算する際の K について議論しておかなければならない。 K を 1 にした場合は、相関分布は画素値=周辺平均画素値の直線状に分布することになる。以上で開発したアルゴリズムは問題なく機能するが、ワーピングしたときに付加されるバイアス成分は完全に画素値依存になるので、小信号がキャンセルされる傾向で処理が進む。つまり、ダイナミックレンジは圧縮されるが詳細信号のコントラストも同時に圧縮される。逆に K を画像全体にまで広げると画素値と周辺平均画素値との相関がなくなり、このアルゴリズムは成立しない。今回の実験において K は物理長で 20mm を選択しているが、これにより概ね 10mm 程度以上の構造が周辺平均画素(ボケ画像)に含まれ、10mm 以下の構造は除外される。ボケ画像に残っている成分は ADRC 処理によりコントラストが圧縮される。つまり、この処理を行っても 10mm 程度の結節(病気)は保存されていることになる。

ADRC の改善すべき点に X 線曝射線量不足で撮影された画像に対する適用がある。この場合はもともと肺野内部でコントラストが低いため、予めコントラストを上げる必要がある。そこで ADRC に先だつて AHEQ を適用する手法を提案した。AHEQ+ADRC は肺野同様に縦隔部の視覚化を間然することが出来る。

ADRC の基本的な考え方は、対象としている部位(部分)の相関分布の相違を利用して視覚化改善を行うものであり、他の用途にも応用可能である。本研究においては肺野の視覚化を改善する方向で使用したが、表示系のダイナミックレンジ

が広い場合においては縦隔部の視覚化改善に使用することも考えられる。胸部画像をフィルムに出力する際には縦隔部の濃度を上げて出力することにより縦隔部の診断能を向上させるのに使用されている。胸部画像以外にもマンモグラムにおいても利用が考えられ、その際には乳房のスキンラインの描出に利用できる。また、本研究では画素値と周辺画素値との相関分布を使用した。他の統計量を使用することも可能であり、また相関分布も2次元にとどまらずに3次元以上に拡張することも可能である。