

高次局所自己相関特徴に基づく AdaBoost を用いた 乳腺超音波画像からの異常検出

山崎 優大¹ 岩田 昌也² 野里 博和² 坂無 英徳^{1,2}

概要: 日本（アジア）人での乳がん検診では乳腺超音波検診が有効であると言われている。しかし、乳腺超音波検診では乳がんの疑いのある病変の見落としが起る可能性がある。そこで、本論文では、高次局所自己相関 (HLAC) 特徴を用いた乳腺超音波画像からの病変の自動検出手法を提案する。提案手法では、判別分析と AdaBoost を用いて正常な乳腺と病変を識別する識別器を構成し、乳腺超音波画像から病変の検出を行う。実験の結果、提案手法により乳腺超音波画像から病変の検出が可能であるということが示された。

キーワード: 高次局所自己相関特徴, AdaBoost, 超音波画像, 乳がん

Anomaly Detection from Breast Ultrasound Images Using AdaBoost Based on Higher-order Local Autocorrelation Feature

YUDAI YAMAZAKI¹ MASAYA IWATA² HIROKAZU NOSATO² HIDENORI SAKANASHI^{1,2}

Abstract: Ultrasonography in breast cancer screening is effective in Japan(Asia). However, sonographer may overlook abnormal on ultrasonography in breast cancer screening. In order to overcome this problem, we propose anomaly detection method from breast ultrasound images based on HLAC feature. The proposed method detects anomaly using discriminant analysis and adaboost. We demonstrate anomaly detection from breast ultrasound images using proposed method.

Keywords: Higher-order Local Autocorrelation(HLAC),AdaBoost,Ultrasound images,Breast cancer

1. はじめに

日本では乳がん罹患率、死亡率が年々増加している [1][2]. 乳がんは日本人女性のがん患者の中で最も多く、日本人女性の 16 人に 1 人は乳がんを経験すると言われている。乳がんは他のがんに比べ進行度が遅いため、早期発見を行うことで、乳がんによる死亡を抑えることができる。また、乳房の切除なしに治療を行うことが可能である。

乳がんの早期発見を行うためには定期的に検診を受けることが重要である。乳がん検診では X 線を用いて乳房の撮

影を行うマンモグラフィを用いた検診が一般的である [3]. しかし、乳がんの年齢別罹患率のピークが若い日本（アジア）人は、乳腺が発達しているため、マンモグラフィでは画像全体が白くなる。そのため、若い年齢層での女性では乳がんの検出率が低下する。そこで、マンモグラフィに加え、超音波を併用した検診が効果的であると言われている [4].

乳腺超音波検診では検査者が超音波プローブ（探触子）を手動で操作し、撮影と観察を同時に行う。乳がんの疑いのある病変が描出されるシーンのみを静止画像として保存し、保存された画像をもとに医師が診断を行う。そのため、検査結果が検査者の技量や経験に左右され、乳がんの見落としが起る危険性がある。

乳腺超音波検診での乳がんの見落としをなくするため、乳腺超音波画像におけるコンピュータ診断支援 (Computer-

¹ 筑波大学 システム情報工学研究科
Graduate School of Systems and Information Engineering,
University of Tsukuba

² 産業技術総合研究所 情報技術研究部門
ITRI, AIST

Aided Detection/Diagnosis;CAD) システムが開発されている。CAD システムとは医用画像をコンピュータを用いて定量的に解析し、その結果を「第2の意見」として医師が利用することで、診断の質の向上や診断時間の削減を実現するシステムである [5]。乳腺超音波画像における従来の CAD システムでは、病変と正常な乳腺組織の濃度値の差を利用して病変の輪郭を抽出し、病変を検出している [6]。しかし、乳腺超音波画像では病変が不鮮明に描出されることがあり、不鮮明に描出された病変では、病変の輪郭抽出が困難であるという問題がある。

そこで、本論文では従来技術における問題を解決するアプローチとして、病変の輪郭抽出不要な特徴量である高次局所自己相関 (Higher-order Local Autocorrelation; HLAC) 特徴 [7] を用いて、乳腺超音波画像から病変を自動検出手法を提案する。

提案手法では、正常な乳腺画像と病変画像から HLAC 特徴を抽出し、判別分析と AdaBoost [8] により、複数の識別器を作成し、統合することで動画像として撮影される乳腺超音波画像からの病変の検出を行う。

2. 乳がん検診の現状

2.1 乳がん検診

乳がん検診では、問診、視触診、画像検査が行われる。乳がん検診により異常ありと診断された場合に、生検などの確定診断を行い、確定診断において異常が存在すれば最終的に乳がんとして診断される。欧米では、画像検査の1つであるマンモグラフィを検診に導入することで乳がんによる死亡率の減少に成功している。しかし、日本(アジア)人女性での乳がんの年齢別罹患率のピークは40歳代であり、欧米の80歳代と比べて極端に若い。若い年齢層の女性は乳腺が発達しており、マンモグラフィでは画像全体が白く描出される。その結果、病変の影と背景の区別が困難となり、若い年齢層でのマンモグラフィ検診では乳がんの検出率が低下してしまう [9]。そこで、乳腺の影響を受けにくく、若い年齢層での女性に対しても乳がんの検出率が高い乳腺超音波検診が注目されている。

2.2 乳腺超音波検診

乳腺超音波画像では音の反射を利用して乳房の断面を撮影する。図1に示すように画面上部から順に、皮膚、脂肪、乳腺、大胸筋、肋骨などが描出される。これらの組織において、乳腺領域に発生するがんを乳がんと呼ぶ。

乳腺超音波検診では、機器の仕様や検査及び読影技術の標準化が実現していないのが現状である [10]。そのため、検査者の経験や技量により診断基準が異なり、検査結果にばらつきが生じやすく、乳がんを見落とす危険性がある。

そこで、乳がんの見落としをなくすことを目的としてコンピュータによるがんの自動検出を行う手法に関する研究




図1 乳腺超音波画像の基本的な構造

が進められている。

2.3 コンピュータ診断支援 (CAD) システム

コンピュータ診断支援 (Computer-Aided Detection/Diagnosis; CAD) システムとは医用画像をコンピュータを用いて定量的に解析し、その結果を「第2の意見」として利用することで、診断の質の向上や診断時間の削減を実現するシステムである [5]。

乳がん検診における CAD システムでは主にマンモグラフィを対象としたものが多く、商用化されているシステムもある [11]。しかし、日本での乳がん検診では超音波による検診が効果的であることから、乳腺超音波検診における CAD システムの開発が急務となっている。

乳腺超音波画像における従来の CAD システムに関する研究では、乳腺超音波画像において病変の濃度値が正常な乳腺組織と比較して小さいことに着目し、画像処理を用いて、病変候補となる部位の輪郭を抽出する。抽出された病変候補の輪郭の形や大きさなどを計測し、計測した値を基に病変の検出を行う [6]。しかし、超音波画像は音の干渉によりノイズを多く含むため、従来手法では病変部位の輪郭抽出が困難である。輪郭抽出に失敗した病変に対しては形や大きさなどの特徴の計測ができず、病変の検出は不可能である。

3. 提案手法

3.1 提案手法のアプローチ

従来技術における病変部位の輪郭抽出が困難であるという問題を解決するため、輪郭抽出不要な特徴量である高次局所自己相関 (HLAC) 特徴を用いた乳腺超音波画像からの病変の検出手法を提案する。提案手法は図2のように学習フェーズと検出フェーズにより構成される。

学習フェーズでは、あらかじめ分類された正常な乳腺画像と病変画像に前処理を施し、HLAC 特徴を抽出する。得られた HLAC 特徴から判別分析と AdaBoost を用いて正常な乳腺と病変を識別する識別器を作成する。

検出フェーズでは、動画像として入力される乳腺超音波画像から病変の検出を行う。動画像の各フレームに対して検査ウィンドウを画像の左上から右下まで走査する。検査ウィンドウ内の領域において HLAC 特徴を抽出し、学習フェーズで作成した識別器を用いて正常な乳腺と病変を識




図 2 提案手法のフローチャート

別する。病変として判定された領域に異常ウィンドウを表示し、乳腺超音波画像から病変の検出を行う。

以下、図 2 に示すフローチャートに沿って各処理の詳細説明を行う。

3.2 前処理

乳腺超音波画像において、病変の濃度値は正常な乳腺と比較して低く描出される。HLAC 特徴は、濃度値の高い領域の特徴を捉えるため、濃度値の低い病変の特徴を捉えることは困難である。そこで、乳腺超音波画像から病変の特徴を捉えるため、濃度反転処理を行う。また、乳腺超音波検診では、検査者のマニュアル操作により、乳腺超音波画像の明るさやコントラストを変化させることが可能である。そのため、撮影された動画画像により明るさやコントラストが異なり、HLAC 特徴に影響を与える可能性がある。そこで、明るさやコントラストの影響を低減するために、濃度反転処理を施した画像からヒストグラム均一化による正規化された画像と Sobel フィルタによる勾配画像の 2 種類の画像を作成する。

3.3 特徴抽出

本節では、静止画像からの HLAC 特徴の抽出方法について詳しく述べる。

3.3.1 高次局所自己相関 (HLAC) 特徴

HLAC 特徴は画像の認識や計測のために有効な画像特徴として自己相関関数を拡張した、形や大きさ、模様などの幾何学的特徴を抽出することに優れた特徴量である [7]。HLAC 特徴は、グレースケールの対象画像を f とすると、変位方向 $(a_1, \dots, a_N)$ に対して、 N 次自己相関関数

$$x(a_1, \dots, a_N) = \int f(r)f(r+a_1) \cdots f(r+a_N)dr \quad (1)$$

により定義される。ここで、 N 次自己相関関数の次数 N を 0, 1, 2 とする。また、参照画素 r と相関を取る画素までの幅 Δr を 1 とし、変位方向を参照画素 r の周囲 3×3 画素の領域に限定すると HLAC 特徴は図 3 に示すような 35 個




図 3 HLAC 特徴のマスクパターン




図 4 HLAC 特徴の相関幅

のマスクパターンから構成される。ここで、平行移動により重複するパターンは等価であるため、それらの重複するパターンは無視されているものとする。なお、図 3 においての②で表現されているものはその画素値の 2 乗を表し、同様に③は 3 乗を表す。

HLAC 特徴は、自己相関関数により定義されるため、ノイズに頑健という性質がある。この性質より、ノイズを多く含む超音波画像において正常な乳腺、病変の幾何学的特徴を抽出できると考えられる。

3.3.2 HLAC 特徴の相関幅

変位方向を参照画素 r の周囲 3×3 画素の領域に限定して HLAC 特徴を抽出することにより、対象画像の局所的な幾何学的な情報が抽出される。しかし、乳腺超音波検診では検査者は、局所的な情報だけでなく、乳がんの出現する乳腺全体を観察し、大局的な情報を用いて診断を行っている。そこで、HLAC 特徴抽出を行う際に、図 4 のように参照画素 r から相関をとる点までの幅 Δr を変化させ、複数の HLAC 特徴を抽出する。相関幅 Δr を変化させることにより、病変の大きさに対応した HLAC 特徴を抽出することが出来る。

3.3.3 画像ピラミッドからの HLAC 特徴抽出

HLAC 特徴は参照画素とその近傍画素の画素値の積を画像全体に対して足し合わせて得られる局所的な特徴である。そのため、高解像度の画像から抽出された特徴は病変の識別のためには細かすぎる可能性がある。識別に有効な解像度から特徴抽出を行うため、様々な解像度の画像からなる画像ピラミッドを作成し、作成した全ての解像度の画像から HLAC 特徴の抽出を行う。

画像ピラミッドは、画像を重ならない小領域に分割し、




図5 画像ピラミッドの構成例 (3 階層)

各小領域を画素の平均値で置き換えるという操作を K 回繰り返すことで、 $K+1$ 階層の画像から構成される。図5に3階層からなる画像ピラミッドの構成例を示す。

3.4 識別器の構成

学習フェーズにおいて、得られた HLAC 特徴から正常な乳腺、病変を識別するため、判別分析と AdaBoost を用いて識別器を構成する。本節では識別器の構成方法について詳しく述べる。

3.4.1 判別分析

判別分析とは、複数のサンプルがいくつかのクラスに分類されているとき、未知のサンプルがどのクラスに属するかを識別する多変量解析手法である。

本論文では、未知のデータから得られた HLAC 特徴を2クラスに識別するため、マハラノビス汎距離 (Mahalanobis generalized distance) を基準として識別を行う。未知のデータから得られた特徴ベクトル x とクラス $i(i=1,2)$ とのマハラノビス汎距離 D は、

$$D^2 = (x - m_i)^T \Sigma_i^{-1} (x - m_i) \quad (2)$$

となる。ここで、 m_i 、 Σ_i はそれぞれクラス $i(i=1,2)$ の平均、共分散行列である。

未知のデータを D が最小となるクラスに分類し、正常な乳腺と病変の識別を行う。

3.4.2 AdaBoost による識別機の構成

正常な乳腺の形や模様は様々であり、正常な乳腺画像から抽出した HLAC 特徴の分布は複数のクラスに分かれている可能性がある。その場合、1つの識別器では様々な分布での正常な乳腺と病変を識別することは困難である。そこで、複数の識別器を統合することで、様々な分布の正常な乳腺と病変を識別する識別器を AdaBoost [8] により構成する。

AdaBoost (Adaptive Boosting) とは、弱識別器を複数用意し、それらを統合することで識別精度の高い強識別器を構成する Boosting という学習手法の1つである。

AdaBoost では、全ての学習サンプルに均等な初期重みを与え、誤識別されたサンプルに対し、重みを大きくするように更新される。各クラスのサンプル数が異なる場合、

サンプル数が多いクラスのサンプルを正しく認識するような弱識別器が選択される。そのため、サンプル数の少ないクラスのサンプルに対しての識別精度が低下する可能性がある。

そこで、本論文では、各クラスのサンプル数に与える重みの和が等しくなるようにサンプルに重みを与え、サンプル数の偏りに影響されない弱識別器を選択する。本論文で用いる AdaBoost のアルゴリズムを以下に示す。ここで、クラス $i(i=1,2)$ に属するサンプルの数を $N^{(i)}$ 、全サンプル数を $N(N=N^{(1)}+N^{(2)})$ とする。また、クラス1に属する学習サンプル x_k は、クラスラベル $y_k = +1$ 、クラス2に属する学習サンプル x_k は、クラスラベル $y_k = -1$ が与えられているものとする。 k はサンプル番号を表し、 $k=1, \dots, N$ である。 t は更新回数を表す。

Step1: 重みの初期化

各クラスに属する学習サンプルの重み $D_1^{(i)}(k)$ を次式のように初期化する。

$$D_1^{(i)}(k) = \frac{1}{2N^{(i)}} \quad (3)$$

Step2: $t=1 \dots T$ に対し、以下の (a)~(d) を実行する

(a) 学習サンプルに与えられた重みを基に、誤り率

$$\epsilon_t = \sum_{i=1}^2 \sum_{k=0}^{N^{(i)}} D_t^{(i)}(k) \quad (4)$$

が最小となる $h_t(x)$ を選ぶ。

(b) (a) の処理で選択された弱識別器 $h_t(x)$ の誤り率 ϵ_t を基に信頼度 α_t を算出する。

$$\alpha_t = \frac{1}{2} \log \left(\frac{1 - \epsilon_t}{\epsilon_t} \right) \quad (5)$$

ただし、 $\epsilon_t = 0.5$ の場合は、 $\alpha_t = 0$ となり、重みの更新を終了する。

(c) 弱識別器 $h_t(x)$ において、正しく識別したサンプルには重みを小さく、誤識別したサンプルには重みを大きくするように重みを更新する。

$$D_{t+1}^{(i)}(k) = D_t^{(i)}(k) \exp(-\alpha_t y_k h_t(x_k)) \quad (6)$$

(d) 更新した各クラスの重みの和が $\frac{1}{2}$ になるように重みの正規化を行う。

$$D_{t+1}^{(i)}(k) = \frac{D_{t+1}^{(i)}(k)}{2Z_{t+1}^{(i)}} \quad (7)$$

ここで、

$$Z_{t+1}^{(i)} = \sum_{k=0}^{N^{(i)}} D_{t+1}^{(i)}(k) \quad (8)$$

Step3: 強識別器の構成

Step2 にて選ばれた弱識別器 $h_t(x)$ に信頼度 α_t を重み付け、統合することで強識別器 $H(x)$ を作成する。こ

ここで, $\text{sign}(x)$ は符号関数を表し, x の符号を出力する関数である.

$$H(x) = \text{sign}\left(\sum_{t=1}^T \alpha_t h_t(x)\right) \quad (9)$$

3.5 乳腺超音波画像からの乳腺検出手法

検出フェーズにおいては, 入力された動画画像の各フレームから超音波画像の任意の領域を矩形に切り出す検査ウィンドウを画像左上から右下まで走査する. 検査ウィンドウ内の領域から, 学習フェーズと同様に前処理を行い, その画像から HLAC 特徴の抽出を行う.

検査ウィンドウ内の領域から得られた HLAC 特徴と学習フェーズで構成した識別器を用いて正常な乳腺, 病変の識別を行う. 病変と判定された領域において, 病変領域であることを表す異常ウィンドウを表示し, 病変の検出を行う.

4. 検証実験

4.1 実験データ

本実験で使用した乳腺超音波画像は東芝:Aplio を用いて撮影された. 画素数は 800×600 , フレームレートは 30fps, 256 階調の動画画像である.

実験では, 病変ありと診断された被験者 4 人から撮影された動画画像 A, B_1, B_2, C, D を用意した. まず, 学習フェーズにおいて使用する学習データとして, 動画画像 A, B_1 から 50×50 画素の静止画像をランダムに切り出し, 正常な乳腺画像を 7347 サンプル, 病変画像を 1050 サンプルの合計 8397 サンプル作成した. 次に, 検出フェーズにおいて使用する検証用データとして, 動画画像 B_2, C, D から乳腺領域のみを手動で切り出し, 532×227 画素, 30fps の動画画像を作成した. この検証用動画画像の各フレームから学習データと同じ画素数である 50×50 の検査ウィンドウをラスタスキャンし, 提案手法により病変と判定された領域に異常ウィンドウを表示する.

4.2 識別器の構成

本実験では, AdaBoost により強識別器を構成するため, 画像の前処理, HLAC 特徴抽出, 次元削減後の次元数を様々に組み合わせて 130 個の弱識別器を作成した.

画像の前処理に関しては, 3.2 節に述べた前処理により 2 種類の画像を作成する. 作成した 2 種類の画像から HLAC 特徴抽出を行う.

HLAC 特徴抽出では, 相関幅 Δr を $1, 2, \dots, 10$ とする. 相関幅 Δr が 1 の場合には, 画像ピラミッドを 2, 3, 4 階層作成し, 13 通りの HLAC 特徴抽出を行った. さらに, 異なる超音波画像の明るさの違いの影響を低減するため, 得られた HLAC 特徴に対し, 特徴ベクトルのノルムが 1 に




図 6 実験結果

なるように正規化を施した.

得られた特徴量は高次元となるため, 構成される識別器が学習データに適合し, テストデータに対する汎化性能が損なわれる可能性がある. そこで, 得られた特徴量に対し, 主成分分析を用いて, 次元削減を行う. 次元削減後の次元数を決定する累積寄与率は 0.99, 0.999, 0.9999, 0.99999, 0.999999 の 5 通りとした.

これらのパラメータを組み合わせることで 130 通りの特徴空間を形成し, 弱識別器を作成する. そして, AdaBoost を用いることで, 弱識別器を統合し最終的な強識別器を構成する. 強識別器を構成する弱識別器の数は, 予備実験より, 病変画像を正しく病変と識別する真陽性率が最大となる 20 個とした.

4.3 評価方法

本実験では, 真陽性を基準に評価を行う. 提案手法が病変として判定した領域に病変が含まれている場合, その領域を真陽性とする. テストデータである動画画像 B_2, C, D の結果から, 次式により真陽性率を求め, 動画画像 B_2, C, D での真陽性率の比較を行った.

$$\text{真陽性率} = \frac{\text{真陽性の数}}{\text{病変が描出されるフレームの数}} \quad (10)$$


4.4 実験結果

提案手法により検出された病変の結果を図 6 に示す. 動画画像 B_2, C, D において提案手法が病変として判定した領域に病変が含まれている. この結果から, 提案手法により, 病変部位の輪郭抽出を行うことなく乳腺超音波画像から病変の検出が可能であることが示された.

次に, 動画画像 B_2, C, D での真陽性率を表 1 に示す. 動画画像 B_2 の場合では, 真陽性率が 86%(12 個/14 個) であるのに対し, 動画画像 C での真陽性率が 50%(2 個/4 個), 動画画像 D での真陽性率が 50%(3 個/6 個) と病変の検出性能が低下した. 動画画像 B_2 では学習データと同じ被験者から撮影された動画画像であり, 動画画像 C, D は学習データと異なる被験者から撮影された動画画像である. このことから, 構成された識別器が, 学習した被験者の乳腺超音波画像の特徴を捉え, 学習データと異なる被験者に対しての汎化性能

動画像 B_2	86%(12 個/14 個)
動画像 C	50%(2 個/4 個)
動画像 D	50%(3 個/6 個)

表 1 被験者毎の真陽性率



(a) 過検出 (b) 病変の見落とし

図 7 検出に失敗した例

が不十分であったと考えられる。したがって、学習データと異なる被験者の影響を受けずに病変の検出を行うためには、様々な被験者からサンプルを取り、それらのサンプルを用いて識別器を構成することが必要であると考えられる。

提案手法により検出に失敗した例を図 7 に示す。図 7(a) は正常な乳腺を病変として検出している過検出の例である。乳腺組織とその他の組織との境界が病変と類似しているため過検出したものと考えられる。病変を正しく検出している場合、同一領域に複数の異常ウィンドウが表示される。しかし、過検出の場合は異常ウィンドウの数が 1 個のものが多く、そこで、同一領域に表示される異常ウィンドウの数が、予め設定した閾値以下であれば除去を行うという処理を施すことにより、過検出を低減することが可能である。

また、図 7(b) は病変領域であるにもかかわらず異常ウィンドウが表示されていないという病変の見落としの例である。これは、病変が検査ウィンドウと比較して小さく、検査ウィンドウ内に正常な乳腺領域が多く描出されているためだと考えられる。そこで、複数のサイズの検査ウィンドウを用いることにより、異なる大きさの病変の検出が可能であると考えられる。

さらに、乳腺超音波画像は乳房の断面を描出したものであり、X 線 CT 画像のように 3 次元データを構成することができる。そのため、乳腺の立体的な特徴を捉えることが可能である。そこで、HLAC 特徴を立体データに拡張した立体高次局所自己相関 (Cubic Higher-order Local AutoCorrelation; CHLAC) 特徴 [12] を用いることで、病変の立体的な特徴を抽出することができ、精度よく乳腺超音波画像からの病変の検出が可能であると考えられる。

5. おわりに

本論文では、従来の乳腺超音波画像における CAD システムでの病変部位の輪郭抽出が困難であるという問題点を解決するため、病変部位の輪郭抽出不要な HLAC 特徴を用いて、乳腺超音波画像からの病変の検出手法を提案した。

提案手法では、対象物の輪郭抽出不要な特徴量である HLAC 特徴を乳腺超音波画像から抽出を行い、判別分析と

AdaBoost による学習手法を用いて様々な模様として描出される正常な乳腺と病変を識別する識別器を作成し、乳腺超音波画像から病変の検出を行った。実験では、提案手法の有効性を検証するため、乳腺超音波画像から、乳腺領域のみを手動で切り出して、病変の検出を行った。実験の結果、病変領域に異常ウィンドウが表示され、提案手法により、病変の検出が可能であることが示された。

今後は、大きさの異なる病変の見落としの問題に対し、様々な大きさの病変に対応するため、検査ウィンドウのサイズを変化させて、病変の検出を試みる。次に、正常な乳腺を病変として検出する過検出の問題に対し、同一領域に表示される異常ウィンドウが少ない場合は異常ウィンドウの除去を行い、過検出の削減を目指す。

さらに、乳房内の断面として撮影られる乳腺超音波画像から 3 次元データを生成し、3 次元データに対する特徴量である CHLAC 特徴を用いて病変の検出精度の向上を目指す。

謝辞 本研究を進めるにあたり、貴重な乳腺超音波画像のデータをご提供頂いた高松平和病院の何森亜由美先生、がん研究会有明病院の岩瀬拓士先生に深謝致します。

参考文献

- [1] 人口動態統計によるがん死亡データ (1958~2010 年), 国立がん研究センターがん対策情報センター
- [2] 地域がん登録全国推計によるがん罹患データ (1975 年~2006 年), 国立がん研究センターがん対策情報センター
- [3] がん予防重点健康教育及びがん検診実施のための指針について, 厚生労働省, 2008 年 3 月 31 日
- [4] 増岡秀次, " 乳癌検診における超音波 (US) の有用性について ", 日乳癌検診学会誌, 2007, No.16, pp.52-59
- [5] 次世代医療機器評価指標の公表について, 厚生労働省医薬食品局審査管理課, 平成 23 年 12 月 7 日
- [6] 石原福太郎, 福岡大輔, 村松千左子, 原武史, 高田悦雄, 遠藤登喜子, 森田孝子, 藤田広志, " 全乳房超音波画像における 3 次元的情報に基づいた腫瘍像の自動検出法の開発 ", 電子情報通信学会技術研究報告, MI, 医用画像 2011-01-12, Vol.110, No.364, pp.87-91
- [7] 大津展之, 栗田多喜夫, 関田巖, " パターン認識-理論と応用 ", 行動計量学シリーズ 12, 朝倉書店, 東京 (1996)
- [8] P.Viola, M.Jones, " Rapid object detection using boosted cascade of simple features ", Proc. of CVPR, pp.511-518, 2001
- [9] 橋本秀行, 押田恵子, 梶原崇恵, 築瀬由美子, 榊朋子, 渡邊美香, 大下あけみ, 鈴木圭子, 小出優子, 大木洋子, 木津初恵, 大鹿倫代, 早田篤子, 川上義弘, " 乳房超音波検査を用いた乳癌検診 ", 日本乳癌検診学会誌 2008-03-30, Vol.17, No.1, pp.37-45
- [10] がん検診に関する検討会中間報告「老人保健事業に基づく乳がん検診及び子宮がん検診の見直しについて」, 厚生労働省がん検診に関する検討会, 2007 年 6 月
- [11] 富士フイルムマンモグラフィ CAD, FUJIFILM Medical Systems USA, Inc. 長谷川玲, 日本放射線技術学会雑誌, 2007 年 12 月
- [12] Takumi Kobayashi, Nobuyuki Otsu, " Action and Simultaneous Multiple-Person Identification Using Cubic Higher-order Local Auto-Correlation ", Pattern Recognition, International Conference on, Vol.4, pp.741-744, 2004