

博 士 論 文

Mモード超音波画像を用いた高精度肝硬変診断
に関する研究

A Study on Liver Cirrhosis Diagnosis with High Accuracy
Using Ultrasonic M-mode Images

平成 26 年 3 月

林 孝哉

山口大学大学院医学系研究科

目次

第 1 章	序論	1
1.1	歴史的背景と本研究の意義	1
1.2	本研究の目的と関連研究	10
1.3	本論文の構成	14
第 2 章	特徴抽出系の改良	16
2.1	はじめに	16
2.2	バイラテラルフィルタによる画質改善	20
2.3	テンプレート処理を用いた大動脈壁位置の抽出処理	22
2.4	大動脈壁位置抽出精度向上のための重み付きテンプレート処理	25
2.5	肝硬変識別のための特徴抽出	27
2.5.1	画像特徴 1	27
2.5.2	画像特徴 2	29
2.6	計算機実験	32
2.6.1	実験方法	32
2.6.2	重み付きテンプレート処理による大動脈壁位置抽出	33
2.6.3	バイラテラルフィルタを用いた大動脈壁位置抽出の改良	39
2.6.4	バイラテラルフィルタを用いた特徴 2 の抽出改良	42

2.7	おわりに	49
第 3 章	識別系の高精度化	50
3.1	はじめに	50
3.2	特徴選択の導入	52
3.3	識別器の選定	54
3.4	計算機実験	58
3.4.1	実験方法	58
3.4.2	特徴選択法と識別器の組合せによる識別性能の評価実験	60
3.5	おわりに	64
第 4 章	結論	65
	参考文献	69
付録 A	M モード画像の画像センシング	80
付録 B	追加実験	84
B.1	実験目的	84
B.2	実験方法	84
B.3	実験結果	85

第 1 章

序論

1.1 歴史的背景と本研究の意義

厚生労働省「人口動態統計（2012 年度）」によると，我が国において肝臓と肝硬変による死亡者数は 2012 年には年間 4 万 8 千人にも上っている．肝硬変とは，「著明な線維化とともに肝実質の再生結節形成を示す肝障害の終末像」と定義されている [1]．すなわち，慢性的な肝障害によって肝細胞が壊死・脱落と再生を繰り返すことで，肝細胞に線維の増生が起こる．この線維化によって肝臓が硬化する．また，びまん性に線維組織に囲まれた再生結節が形成される．肝硬変は難治性の肝臓癌を併発する可能性が極めて高い [2]．肝硬変の病因としては，C 型肝炎ウイルスによるものが約 70%，B 型肝炎ウイルスによるものが約 15%，アルコール性が約 10%，その他自己免疫性肝炎などが数%であるとされている [1]．肝臓癌や肝硬変は，肺癌，大腸癌，胃癌，膵癌，乳癌などに次ぐ死亡者数となっている．肝臓癌や肝硬変などの慢性肝疾患は重要な死因の一つであり，社会的ニーズとしてその対策が急務となっている．このように，肝硬変は生命にかかわる疾患であるため，肝硬変の早期発見・早期治療が望まれている．

今日，慢性肝炎や肝硬変の確定診断の標準は肝生検とされている．しかし，肝生検は侵襲的であることから肝血管の損傷による出血といった合併症を併発する問題，肝生検のスキル

には熟練を要する問題，得られた肝組織が十分な大きさでない場合には診断が困難となる問題，さらには肝組織の採取部位によってはサンプリングエラーや診断誤差の問題，入院を必要とする問題があると言われている [3]~[8]．このように，危険性の伴う肝生検は患者への負担が大きいため，容易に実施することはできない．

近年，非侵襲的な画像診断法として，超音波エラストグラフィが注目されている [9]~[18]．超音波エラストグラフィとは，組織の弾性（Elasticity）を画像化する方法（Graphy）の総称（Elastography = Elasticity + Graphy）であり，測定原理の違いにより大きく 2 通りの方法に分類される．一つは組織の歪みの差を画像化する方法であり，もう一つは剪断波伝播速度を測定する方法である [11]．しかし，超音波エラストグラフィを利用するには，エラストグラフィ専用の装置が必要で，これは通常の超音波装置とは異なる．また，2012 年現在，保険適用が認められた超音波エラストグラフィ装置は FibroScan のみであることから，超音波エラストグラフィの機器は必ずしも多くの医療機関で導入されていないという現状が報告されている [19],[20]．本研究では，研究成果を多くの医療機関で利用できるよう，すなわち広く普及させるためには，特殊ではない装置を用いて得られる画像であることが重要と考える．したがって，多くの医療機関で使用されている通常の超音波装置で得られる超音波画像を対象にする．

超音波画像診断は手軽に利用でき，非侵襲的に生体内部の情報を獲得でき，放射線被爆の心配もなく，人体に安全であるため，肝硬変診断に広く用いられている．肝疾患領域の超音波診断は，1970 年代から盛んに行われており，特にウィルス性肝疾患に合併する肝細胞癌の早期発見のスクリーニング検査として重要な役割を果たしている [21],[22]．

超音波装置は，1916 年ごろ，潜水艦探知を目的として開発された．超音波は，人間の耳には聞こえない音であるとされている．人間の耳に聞こえる範囲の音は周波数が 20~20,000Hz とされている．これを超える音波が超音波であるが，人間の耳に聞こえる音であっても，計測やエネルギー源など人間のコミュニケーション以外の目的で使用される音も超音波と考えてよいとされている [23],[24]．診断領域で扱われる超音波には，2~30MHz の

周波数が使用されている [23]. 超音波を人体内に入射させると, 人体内の各組織はそれぞれ音響学的性質が異なっていることから, 超音波は異なる組織の境界面で反射や屈折を起こす. この反射波の特性を利用したものが超音波診断である.

この超音波の臨床医学分野への最初の応用は, 1942年に Dussik が頭部断層の透過画像を得るため超音波を用いた研究がはじめとされており, 1949年には Ludwig により胆石を対象とした超音波を腹部へ応用した研究が報告されている [23]. さらに, 1950年の Wild の A モード法, 1952年の Howry の B モード法, 1954年の Edler らの M モード法, 1956年の里村のドプラ法など, 医用診断装置に直結する研究が始まった [24]. 1990年代後半に入ると, 装置のデジタル化により画質が向上し, 三次元エコー, 超音波組織診断, 遠隔医療などの技術が開発された [25].

超音波には以下に挙げる特徴がある. 一般的に利用される超音波診断装置では微弱なパルス音波が用いられるため放射線被曝も無く人体に対して安全である. 生体内での超音波伝播速度が電磁波と比較して数万倍遅く, さらに波長も短いため, 超音波は生体内を直進する性質を持つ. 超音波は生体中や液体中で減衰が非常に小さくよく伝播するため, 皮下情報の可視化が可能であるという性質を持つ. さらに, 強い超音波の発生が容易なため, キャビテーションにより機械作用や薬理作用を生むことができる [26].

一般に超音波診断装置は, プローブ (探触子), 発振部, 走査部, 表示部といったブロックにより構成されている. 超音波の発信と受信はプローブと呼ばれるデバイスによって行われる. プローブの先端に電圧を加えると, プローブは歪みを生じる. この歪みが, 電氣的振動となり超音波を発生させる. この現象は, 電圧が加わると歪みを生じる物質がプローブの先端に装着されていることにより起こる. この現象をピエゾ効果もしくは圧電効果という. また, この効果を持つ物質を振動子と呼ぶ. 生体内からの反射波は, 超音波を発信していないときにプローブの先端によって受信され, その振動が電気信号に変換される. そして, プローブの走査と表示部の走査線とを対応させ, 表示部に画像として表示する. プローブからは 1 秒間に 1000 回前後の超音波を発生させているが, 実際に超音波を発生している時間は

その 0.1% 程度でしかなく，残りの時間は反射波の受信に費やされている [23]．現在使用されている超音波診断装置のほとんどは電子走査式リアルタイム装置である．振動子を直線状に配列させると矩形の視野が得られ（リニア走査型），扇型に配列すると扇型の視野（セクタ走査型）が得られる．この電子走査式リアルタイム装置では，振動子の処理は 1/30 秒程度で行われ，1 秒間に 30 枚前後の超音波画像が連続して得られるため，生体内をリアルタイムで観察できる [23]．現在，超音波診断装置は診断や治療に有効な画像診断装置となっている．超音波診断装置の長所は，非侵襲的，小型簡便，低コストであるのに加え，動画として情報が得られ，前述したように人体に安全であることなどが挙げられる [27]．

エコー法の基本的な表示様式には，A モード，B モード，M モードがある．A（amplitude：振幅）モードとは，超音波を発信してからその反射波を受信するまでの時間を横軸とし，縦軸には反射波の振幅（強度）を記録したものである．人体内の各組織の伝播速度がほぼ一定であると仮定すると，反射波を受信するまでの時間は反射対象までの距離にほぼ比例することとなり，横軸は距離を表すこととなる．A モード画像は，画像から得られる情報が少なく，プローブの当て方によって得られる画像が大きく異なり再現性に乏しいという短所がある．このため，現在では A モード単独の装置は生産されていない．




図 1.1: B モード画像

次に、B (brightness : 輝度) モードは、A モード画像の振幅 (強度) を輝度に変換して表示したものである。プローブを動かし、超音波の走査を行うことで、2次元画像すなわち検査対象の断面像 (断層像) を表示する (図 1.1 参照)。この B モードの応用分野は臓器一般であり、生体の形態や性状の認識が可能となり、診断がより容易となった。

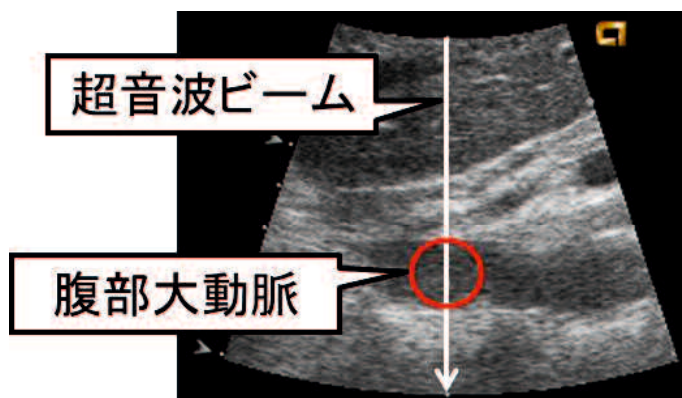


図 1.2: 超音波ビーム上の輝度を走査




図 1.3: M モード画像

最後に、M (motion: 運動) モードは、プローブを固定した状態で、反射対象とプローブとの距離の時間的経過を表示したものである。図 1.2 のように、1 本の超音波ビーム上にある輝度の強度を、時間軸上に一定速度で走査したものである (図 1.3 参照, M モード画像センシングの詳細については付録を参照)。心臓のように検査対象が運動している場合、その部位が時間経過とともにどのように動くか (プローブに近づいたり、遠ざかったりする動き) を表示するのに便利な方法である。M モードの装置は単独でも用いられるが、最近では B モードの装置に組み込まれており、B モード画像と M モード画像を同時に表示させることができる。M モードは心臓弁や心室などの運動性の診断に用いられ、その分野では特に UCG (ultrasound cardiography) と呼ばれている [26],[28]~[30]。

しかし、超音波画像診断においても、医師の知識、技術を要し、経験に頼るところが多く、そのため診断結果に個人差が生じる。これを回避する一手段にコンピュータによる支援診断がある。コンピュータ支援診断 (Computer-Aided Diagnosis: CAD) システム開発の歴史は古く、1960 年代から行われている [31]。1970 年代には、塵肺症診断を目的として胸部医用画像を分析する研究 [32],[33] やゼロマンモグラフィにおける異常領域の検出や鑑別に関する研究 [34],[35] などが行われた。しかし、この当時の研究はコンピュータが医師の代

わりに診断を行うものと考えられており、それらは自動診断と呼ばれた [36]。その後、1980年代に入り、シカゴ大学の土井によりコンピュータの結果を医師が利用するという考え方が提唱され、これがコンピュータ支援診断と呼ばれた [37]。1998年6月には、世界最初のコンピュータ支援診断システムが商用化に成功したことから [38]、この年をCAD元年となった [39]~[41]。その後、コンピュータ支援診断の研究は、対象とする臓器や疾患について多様化がなされ、それに伴ってコンピュータ支援診断に用いられる画像のモダリティも多様化した。現在、コンピュータ支援診断システムは、病院など医療現場への導入が大きく期待されている。

医用画像の分析に関する研究は、上記のようにコンピュータによる自動診断から支援診断へと変遷した。土井 [36],[37] は、コンピュータ支援診断と自動診断の共通点および相違点について次のように指摘している。まず、コンピュータ支援診断と自動診断の共通点であるが、両者ともコンピュータを用い、デジタル画像を定量的に分析し、医師の診断に必要な情報を抽出することである。そして、集団検診など多数の画像を観察することを想定していることである。通常、大多数の正常のなかに小数の異常が含まれる状況が考えられるが、その際医師はすべての画像に対して見落としが無いよう迅速かつ正確に診断することが要求される。この作業は医師にとって、肉体的にも精神的にも多大なる負担がかかる。そこで診断にコンピュータを利用することで、これら医師の負担軽減が期待できる。

一方、コンピュータ支援診断と自動診断の相違点は、コンピュータによる分析結果や抽出情報の利用の仕方にある。自動診断はコンピュータによる診断結果を最終的診断とするのに対し、コンピュータ支援診断はコンピュータの分析結果や抽出情報を参考にして医師が最終的診断を行う。この相違点はコンピュータの出力による診断能力（特性）にも影響を与え、自動診断ではコンピュータの診断能力に高い感度が要求されることを意味している。その点、コンピュータ支援診断ではコンピュータの診断能力は必ずしも医師の能力を上回る必要が無く、最終的診断は医師とコンピュータ両者の能力の相乗効果によって行われる。

コンピュータ支援診断の研究が行われる中、コンピュータの処理能力や周辺技術、アルゴ

リズムなどが質的に向上している。コンピュータが診断に用いられる範囲も対象となる臓器や疾患など多岐にわたり、支援診断に期待される内容も多様化している。医師による診断や治療に有益な情報を提供するため、コンピュータ支援診断の出力として、与えられた画像に対する正常・異常等の診断、医師の診断に用いられる特徴の計測、輪郭・領域抽出といったセグメンテーションの結果、仮想化された人体など3次元像の表示、注意すべき陰影へのマーキング、などがある [42]。コンピュータ支援診断で扱われる医用画像は、人体内部の状態や状況を観測することを目的として開発されてきた。そのためコンピュータ支援診断で用いられる画像モダリティにも多くの種類が存在し、それらは観測手段や適用される臓器など画像モダリティごとにそれぞれ特徴がある（表 1.1 参照）。

超音波画像を用いたコンピュータによる肝硬変診断の高精度化は、患者一人ひとりの肝硬変の診断やその進行状態を数値で客観的に捉えることが期待でき、コンピュータ画像診断において大きな意義を持つと考えられる。

表 1.1: 医用画像の種類（文献 [43] の図 1 を基に作成）

対象	観測手段	画像の種類	適用対象の例
人体 表面	視察	一般視診	一般検診, 外傷, 皮膚
	可視投影光	モアレ像	脊椎, 体型, 形成外科
	赤外線	サーモグラム	乳房, 血行, 神経系
	電磁界	体表面電位図, 心・脳磁図	心臓, 脳
人体 内部	視察	内視鏡, 眼底写真	気管支, 胃, 大腸, 眼底
	X 線	直接/間接/DR (静止透過像) テレビ/シネアンジオグラフィ/ DSA (動画透過像) CT (断面像, 3次元像)	ほぼ全器官, 部位
	RI (γ 線/ 陽電子線)	シンチグラム (静止画, 動画) PET/SPECT (断面, 3次元像)	心, 肝, 脳, 等
	超音波	エコー像 (A, B, M モード, 断層 ドップラー; 2, 3次元静止画, 動画)	乳房, 心, 腹部, 他
	NMR	MRI (断面, 3, 4次元動画) アンジオグラフィ (3次元, 動画)	心, 脳, 骨, 他
組織 標本	可視光	光学顕微鏡像 (2, 3次元静止画)	細胞診, 染色体, 血球, 病理組織標本, 等
	電子線	電子顕微鏡像 (2, 3次元静止画)	
微細 構造	可視光	分子画像 (顕微鏡像)	細胞 (種類・動き・遺伝子)
	X 線	マイクロ CT	組織の標本

1.2 本研究の目的と関連研究

前節では，肝硬変の早期発見・早期治療が重要であること，超音波検査が肝硬変診断に広く用いられているが，その診断結果は医師の知識や経験によることについて述べた．また，超音波画像を用いた肝硬変のコンピュータ支援診断の高精度化の意義についても述べた．

超音波画像を用いたコンピュータ支援診断では，肝疾患に関する研究は数多く報告されている．たとえば，テクスチャ解析により，正常肝臓と肝臓がんの識別 [44]～[47]，正常と脂肪性肝疾患の識別 [48]～[50]，線維化率の定量的評価 [51],[52] を行う方法がある．また，散乱体分布情報の統計解析による肝硬変の病変の定量的評価 [53]～[58] などがある．

前述したように，医用診断に利用される超音波画像には B モード画像と M モード画像がある．肝硬変診断に用いられる超音波画像の研究は B モード画像を対象としたものが主流である．しかし，M モード画像は時系列データの診断に有効であるにも関わらず，M モード画像と B モード画像を併用した手法 [59] が 1 件報告されているだけで，M モード画像単独を用いた研究は調査した限りでは報告されていない．仮りに M モード画像を用いた診断の改良ができれば，B モード画像と M モード画像との併用により，さらなる診断の高精度化が実現できると考える．そこで，本研究では，M モード画像の可能性を期待し，将来的には B モードとの併用も視野に入れ，M モード画像を対象とする．

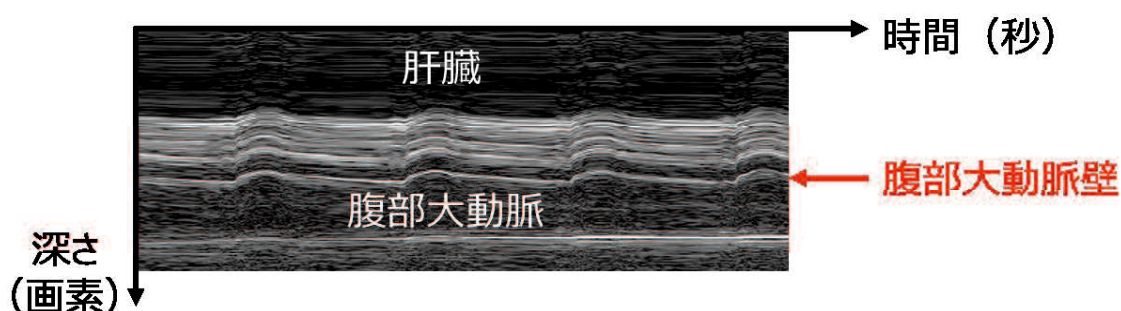


図 1.4: Mモード画像




図 1.5: 正常の大動脈壁位置データ



図 1.6: 肝硬変の大動脈壁位置データ

M モード画像は、臓器の位置の時間的変化を測定し画像化したものであり、臓器の動きを観察することに適している。実際、医師が超音波画像により肝硬変診断を行う際、M モード画像で肝臓の動的特性を診ている。肝硬変肝臓は正常な肝臓に比べ、肝硬化が進行している。肝臓の硬さが腹部大動脈壁の振幅に影響を与えることに着目する。図 1.4 が腹部大動脈の M モード画像である。画素値の小さい部分、すなわち暗い部分が腹部大動脈である。腹部大動脈の上に位置する数画素が腹部大動脈壁である。大動脈壁は拍動に応じて周期的に膨張収縮を繰り返す。肝臓は大動脈の上に位置しているため、図 1.5 のように肝臓が柔らかければ大動脈壁の振幅も大きくなり、逆に図 1.6 のように肝臓が硬ければ大動脈壁の振幅も小さくなる。これに着目して特徴抽出を行い、肝硬変か正常かを識別することが考えられる。このように、腹部大動脈の動的特性を観察するのに M モード画像の方が適している。

M モード画像を用いた代表的な肝硬変識別には、Zhou らが提案した腹部大動脈壁（以下、大動脈壁）の動きを計測する手法がある [59]。肝硬変の肝臓は正常な肝臓に比べ肝硬化

が進行するのに伴い、肝硬化の進行度が腹部大動脈の膨張収縮の度合に影響することに着目して特徴抽出を行い、肝硬変か正常かを識別する。Zhou らは大動脈壁位置抽出に相関係数を用いているが、予備的実験を行ったところ超音波画像では大動脈壁の輪郭が不明瞭であるため、十分な抽出精度が得られない。また、M モード画像での輪郭追跡法には、Rabben ら [60] のエネルギー最小化問題による手法がある。しかし、Rabben らの手法は追跡精度が十分でなく、輪郭追跡に人間による多大な補正作業も要求される。このため臨床応用可能な肝硬変識別のために実用性を考え、軽微な補正作業などの人間による処理を用いた高精度な大動脈壁位置抽出法が求められている。

本研究の肝硬変診断処理は、大きく分けて大動脈壁位置抽出処理と肝硬変識別処理の 2 つの処理からなる。大動脈壁位置抽出処理は、M モード画像から大動脈壁位置の時間経過に伴う深度の変化をとらえる処理である。得られた大動脈壁位置データと画像の両方から肝硬変識別に用いる特徴を抽出する。そして、肝硬変識別処理において肝硬変か正常かの識別を行う。

前述したように、超音波画像は一般に低画質である。肝硬変識別の高精度化のためには、超音波画像の画質改善が必要である。超音波画像に対するノイズ軽減手法として、平滑化フィルタを用いた手法やニューラルネットワークによる手法などが報告されている [61]～[66]。エッジ保存型の平滑化フィルタの一つとして、バイラテラルフィルタがある。一般的なフィルタによる不明瞭な画像の先鋭化では、エッジの強調が期待できるが、ノイズの強調も伴う。バイラテラルフィルタはこのような欠点を克服しようとして、ノイズを抑制しつつ、エッジ強調を行うものである。実際、医用の分野で超音波画像に対してもバイラテラルフィルタを適用した文献として [67]～[70] がある。本研究は、超音波画像の画質改善のために、単純なエッジ強調ではなく、平滑化でノイズを抑制しつつエッジを強調することの期待できるバイラテラルフィルタを用いる。

また、大動脈壁位置抽出には、従来研究で必要とされる人間による補正作業を軽微とした重み付きテンプレート処理を用いた大動脈壁位置抽出処理手法を用いる。テンプレート処理

の距離に重みを付ける手法には文献 [71]～[83] がある。これらの中で、本手法に関わりの深いものに、ガウシアン重みを用いた手法 [79] がある。それはテンプレート画像と入力画像との画素値の差分総和にガウス関数を用いて重み付けを行ったもので、ユークリッド距離に重みを付けたものとみなすことができ、重み付きユークリッド距離 [84] に類するものである。距離に重みを付ける他の手法として、重み付き市街地距離 [85]、重み付きミンコフスキー距離 [86],[87]、重み付きマハラノビス距離 [88]～[92]、などがある。

以上のように、臨床応用に向けた、超音波画像を用いた肝硬変診断手法の高精度化を本研究の目的とする。特徴抽出系では、大動脈壁位置抽出と特徴抽出という2つの処理からなる。大動脈壁位置抽出の高精度化のために、バイラテラルフィルタの適用と重み付きテンプレート処理を提案する。また、画像からの特徴抽出の改良には、バイラテラルフィルタの適用を提案する。さらに、肝硬変識別性能の向上のために、特徴選択法と識別器の最適な組合せも検討する。

1.3 本論文の構成

本研究では肝硬変識別の高精度化のために特徴抽出系の改良と肝硬変識別性能の高精度化を行う。

本研究の肝硬変診断は、大きく分けて大動脈壁位置抽出と肝硬変識別の2つの処理からなる(図 1.7 参照)。大動脈壁位置抽出処理は、Mモード画像から大動脈壁位置の時間経過に伴う深度の変化をとらえる処理である。得られた大動脈壁位置データと画像の両方から肝硬変識別に用いる特徴を抽出し、肝硬変か正常かの識別を行う。

本論文は、以下のように構成されている。第2章では、特徴抽出系の改良について提案する。まず、Mモード画像から大動脈壁位置を抽出する手法では、超音波画像の画質を改善するために、エッジを保存する平滑化フィルタの一つであるバイラテラルフィルタの適用を検討する。また、大動脈壁位置抽出の性能向上のために、重み付きテンプレート処理を用いる。次に、画像からの特徴抽出前に画像に対しバイラテラルフィルタを適用する。Fisher比による比較実験を通して、バイラテラルフィルタの有効性を検討する。

第3章では、識別系の高精度化について述べる。有効な特徴選択法と識別器の組合せを選定するために、比較実験を行う。特徴選択法の候補には、Fisher比、SFS法を用いる。また、識別器は、ユークリッド距離識別器、Fisher線形識別器、Bayes2次識別器、RDA法を候補とする。

第4章は、結論である。本手法について総括し、今後の課題と展望について述べる。

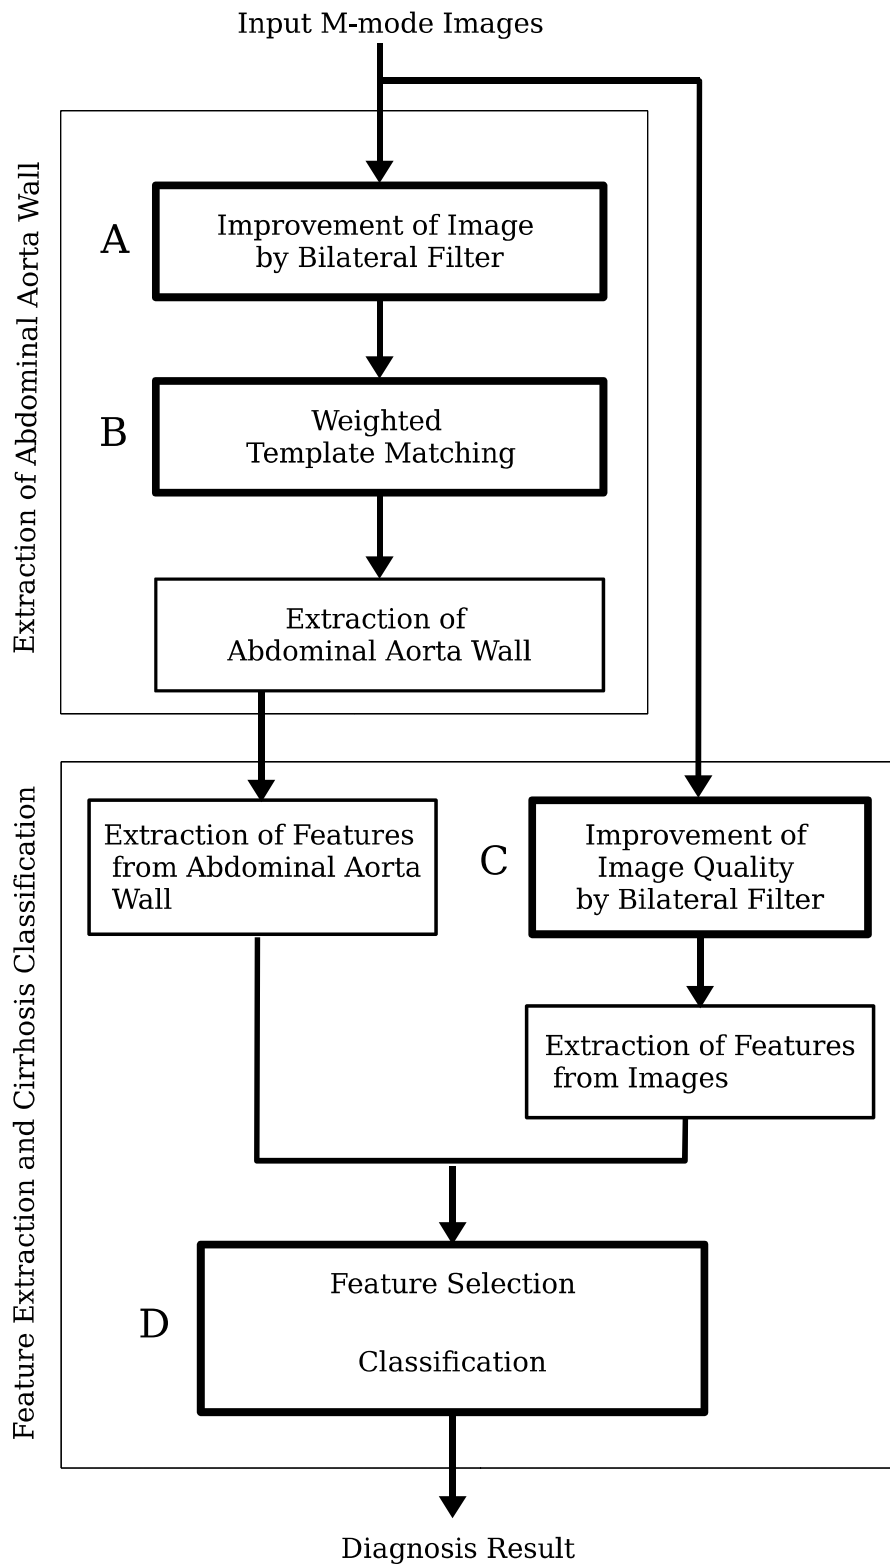


図 1.7: 大動脈壁位置抽出と肝硬変からの特徴抽出と識別のフロー

第 2 章

特徴抽出系の改良

2.1 はじめに

肝硬変識別のための M モード画像からの特徴抽出について述べる．一般に肝硬変の肝臓は正常な肝臓に比べ肝硬化が進行している．本研究では肝硬化の進行度が腹部大動脈の膨張収縮の度合に影響を与えることに着目する．

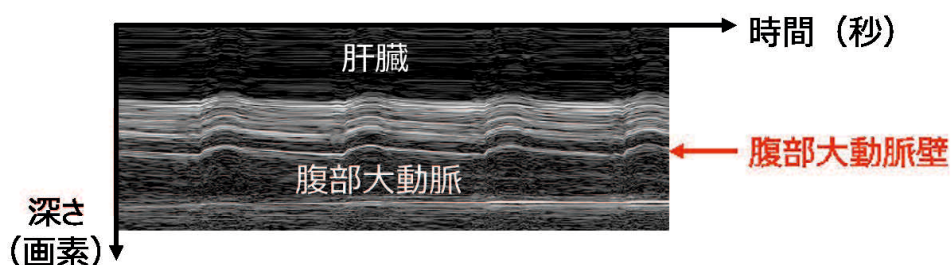


図 2.1: 腹部大動脈壁

腹部大動脈の M モード画像の例を図 2.1 に示す．ここで，画像内の画素値の小さい，すなわち暗い領域が腹部大動脈である．大動脈壁位置抽出処理は，図 2.1 で矢印の大動脈壁位置の時間経過に伴う深度の変化をとらえる処理である．正常肝臓の M モード画像の例を図 2.2 (a) に，肝硬変肝臓の M モード画像の例を図 2.2 (b) に示す．これらから，正常肝臓

の画像と肝硬変肝臓の画像とでは，大動脈壁位置の時間的変化に違いがあることがわかる．

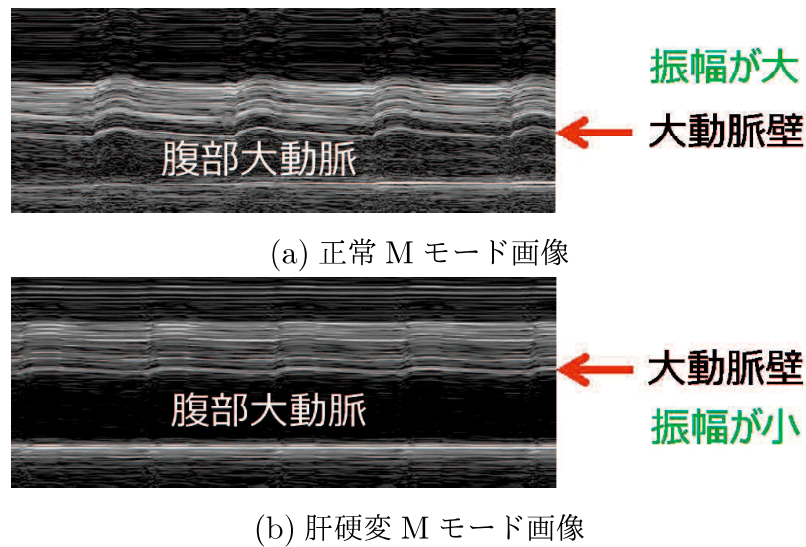


図 2.2: M モード画像

画像への正常あるいは肝硬変のラベル付けは，肝臓専門医によって医学的根拠を基に行われる．計算機実験では，これらの画像を用いて肝硬変の識別実験を行い，本手法の有効性を検討する．ラベル付けされた画像から特徴抽出を行い，識別器の設計を行う．診断ではコンピュータにラベルを伏せて肝硬変識別を行う．肝硬変識別を目的としたコンピュータ支援診断の流れを図 2.3 に示す．




図 2.3: 肝硬変識別を目的としたコンピュータ支援診断の流れ

Zhou らは相関係数を用いて大動脈壁位置抽出を行っていたが，超音波画像は一般に画質が低く，大動脈壁の輪郭が不明瞭であることが，大動脈壁位置の抽出性能を低下させる要因の一つとなっている．

本研究では大動脈壁位置の抽出性能を改善するために，エッジを保存する平滑化フィルタ

の一つであるバイラテラルフィルタを適用する（図 2.4 処理 A）。また，相関係数に改良を加えた重み付き相関係数を用いた重み付きテンプレート処理を用いる（図 2.4 処理 B）。さらに，画質改善を目的としたバイラテラルフィルタも適用する（図 2.4 処理 C）。

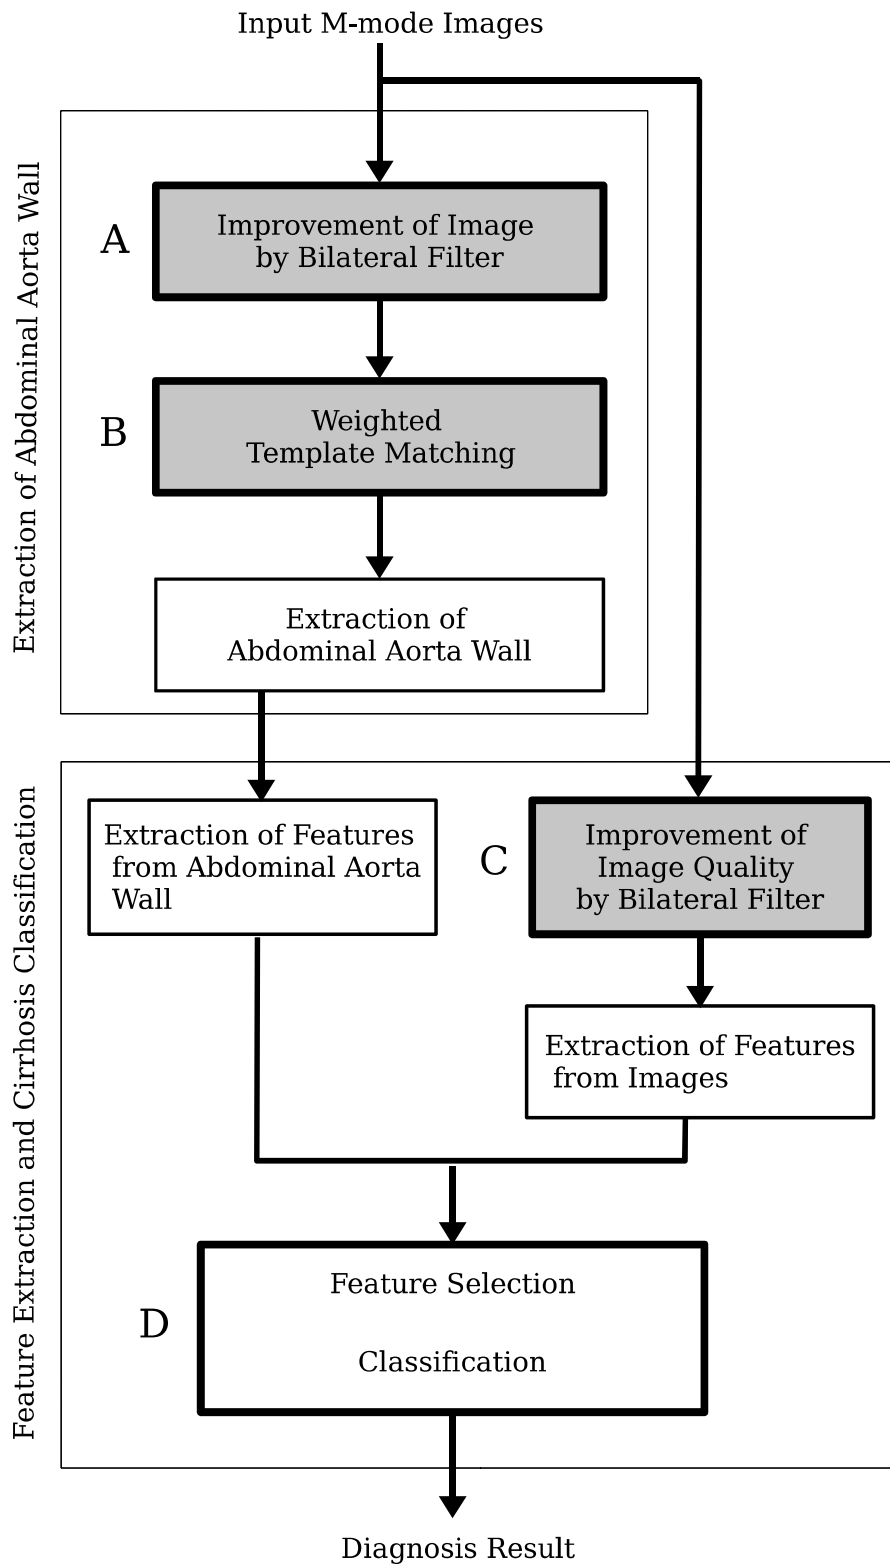


図 2.4: 大動脈壁位置抽出と肝硬変からの特徴抽出と識別のフロー

2.2 バイラテラルフィルタによる画質改善

バイラテラルフィルタは、注目画素からの距離と、注目画素の画素値との差に応じて、ガウス分布に従う重みを付けた平滑化フィルタである [93]。平均化フィルタやガウシアンフィルタが画像全体を平滑化するのに比べ、このバイラテラルフィルタはエッジを保存した平滑化を行う点に特長がある。

図 2.5(a) の入力画像 $f(u, v)$ と (b) のフィルタ $h(m, n, f)$ のコンボリューションを行うことによって、(c) の出力画像 $g(u, v)$ が得られる。


$$g(u, v) = \iint f(u - m, v - n)h(m, n, f)dm dn \quad (2.1)$$

式 (2.1) を離散量で表すと、入力画像を $f(u, v)$ 、出力画像を $g(u, v)$ としたとき、バイラテラルフィルタのフィルタリング計算は式 (2.2) で表される [94]。


$$g(u, v) = \frac{\sum_{n=-w}^w \sum_{m=-w}^w f(u + m, v + n) \exp\left(-\frac{m^2 + n^2}{2\sigma_d^2}\right) \exp\left(-\frac{(f(u, v) - f(u + m, v + n))^2}{2\sigma_r^2}\right)}{\sum_{n=-w}^w \sum_{m=-w}^w \exp\left(-\frac{m^2 + n^2}{2\sigma_d^2}\right) \exp\left(-\frac{(f(u, v) - f(u + m, v + n))^2}{2\sigma_r^2}\right)} \quad (2.2)$$

σ_d と σ_r は、距離に応じた重みと画素値の差による重みを表すガウス分布を決めるためのパラメータである。 σ_d の値が大きくなるほど注目画素から離れている画素の画素値がぼかされる。また、 σ_r の値が大きくなるほど注目画素の画素値との差がより大きい画素の画素値をぼかす特性がある。注目画素は、フィルタリングによってその画素値と近い値を持つ近傍画素の画素値との差が小さくなるように、その画素値が置き換えられる。


M モード画像にバイラテラルフィルタを適用することで、臓器の時間軸方向の画素値同士は、より相関が高くなり、画像は先鋭化され、臓器の境目はより鮮明になる。画質が改善さ



(a) 入力画像 : $f(u, v)$



(b) フィルタ : $h(m, n, f) = \exp\left(-\frac{m^2+n^2}{2\sigma_d^2}\right) \exp\left(-\frac{(f(u, v)-f(u+m, v+n))^2}{2\sigma_r^2}\right)$



(c) 出力画像 : $g(u, v)$

図 2.5: コンボリューション

れると、高精度な肝硬変識別を可能とする特徴が、大動脈壁から抽出されると考えられる。このようにバイラテラルフィルタの特性を活かすことで、Mモード画像から肝硬変識別に有効な特徴の抽出が期待できる。このバイラテラルフィルタを、大動脈壁位置抽出と画像からの特徴抽出の両方に前処理として適用する。

2.3 テンプレート処理を用いた大動脈壁位置の抽出処理

大動脈壁位置抽出精度が肝硬変識別の精度に影響を与えるため、抽出精度の低い大動脈壁位置データは肝硬変識別精度の低下の要因となることが考えられる。そこで大動脈壁位置抽出精度を向上させるために、重み付きテンプレート処理を用いる。

最初に、従来のテンプレート処理 [94]~[96] による大動脈壁位置抽出処理の手順を述べる。まず、目視により抽出の開始点を指定する。開始点は、画像処理のスタート時を時刻 $t = 0$ とおき、この時刻 $t = 0$ において大動脈壁を構成する画素の中から画素値が最大となる画素とした。図 2.1 に示したように、大動脈壁は大動脈と隣接した数画素から構成されている。画素値が最大となるのは、反射波が強い部分であり、多くの場合、それは臓器と血液との境界である大動脈壁となる。そのため、開始点として画素値が最大となる画素を選択した。なお、大動脈壁を構成する画素数が約 200 画素から 600 画素であるため、医師が各画像に対して大動脈壁を構成する画素をすべて手動で抽出することはできない。

(1) 候補点の決定

図 2.6 に示すように、時刻 t における画像中の大動脈壁位置データを $j_t(t = 0, 1, \dots, i, i + 1, \dots)$ とする。時刻 $t = i$ において、大動脈壁位置データとして j_i が抽出されているとする。次時刻 $t = i + 1$ の大動脈壁位置データの候補点は、 j_i を中心に上下 ω 画素を探索領域として、この領域から 1 点選択する。 $\omega = 2$ のときの探索領域を図 2.6 に示す。

(2) テンプレート処理

(1) で定めた探索領域の中から以下に述べるテンプレート処理によって大動脈壁位置データを決定し、その点を次時刻 $t = i + 1$ の大動脈壁位置データ j_{i+1} とする。

テンプレートを時刻 $t = 0$ における大動脈壁位置データ j_0 を中心とした上下 r 画素の範囲とする。テンプレートの大きさは横 1 画素、縦 $2r + 1$ 画素となり、図 2.7 に

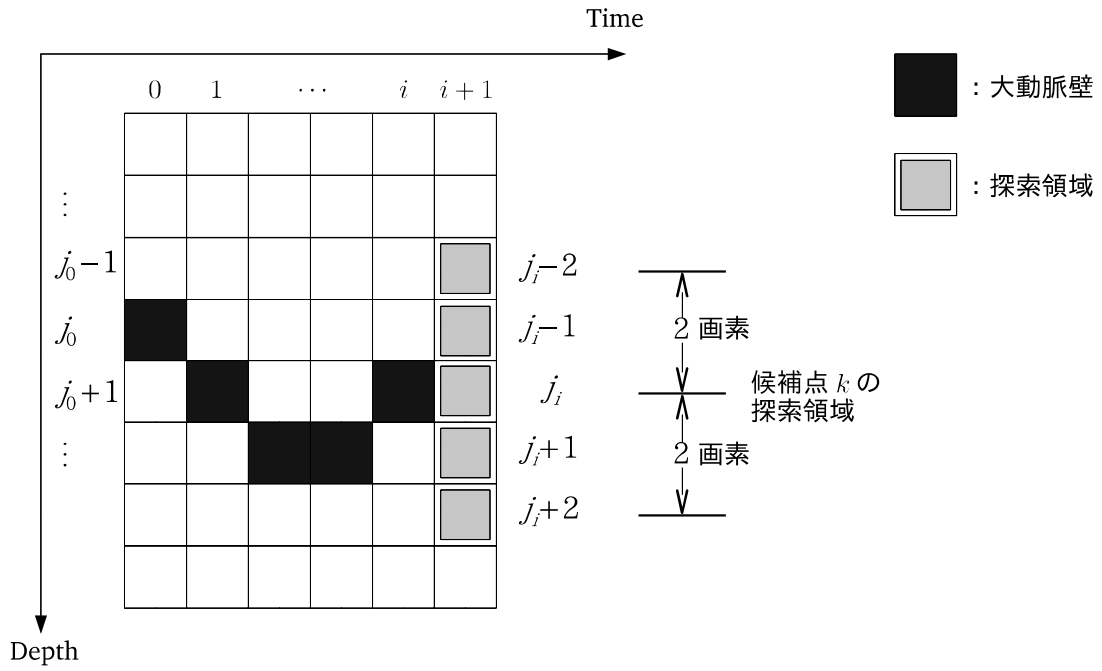


図 2.6: 候補点の探索領域

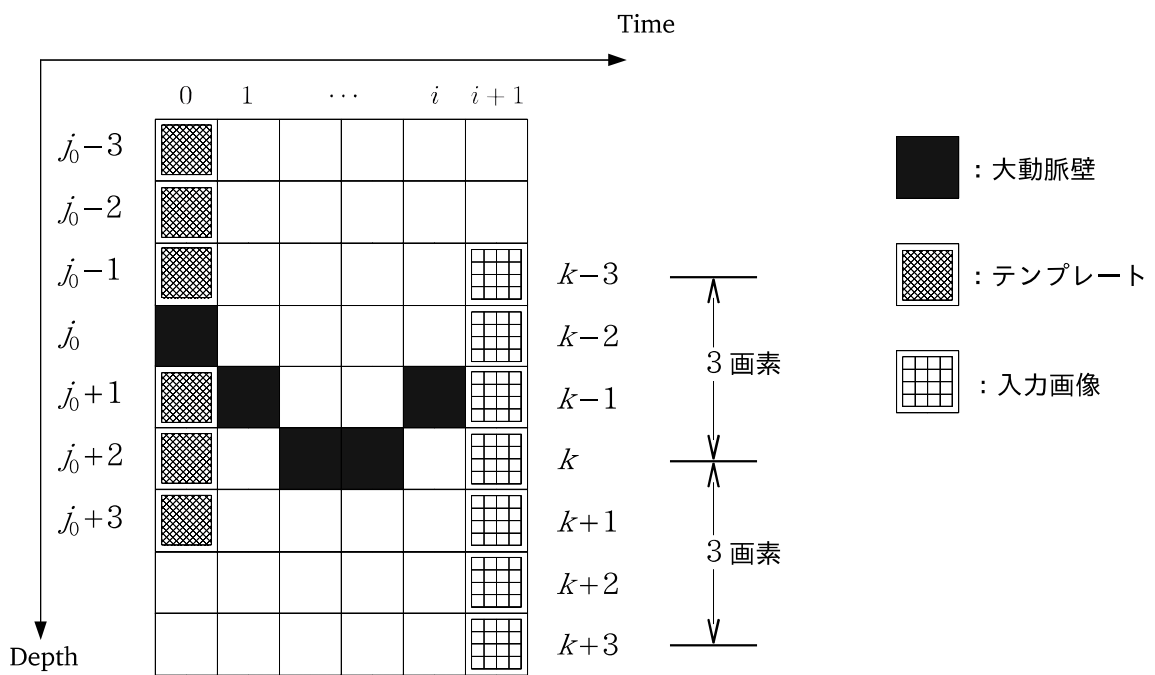


図 2.7: テンプレート処理

$r = 3$ のテンプレートの例を示す.

探索領域から候補点を選択する. 例として, 図 2.7 のように位置 $j_i + 1$ を候補点 k とする. 入力画像は時刻 $i + 1$ における候補点 k を中心とした上下 3 画素である. 全候補点に対してテンプレートと入力画像とでテンプレート処理を行い, その中で最も類似度の高い候補点を次時刻 $t = i + 1$ の大動脈壁位置データ j_{i+1} として決定する.

一般にテンプレート処理では, 類似度にユークリッド距離の 2 乗和や相関を用いる. 本研究では, 類似度に相互相関係数を用いる.

テンプレートの大きさは横 1 画素, 縦 $2r + 1$ 画素であり, 時刻 0 における位置 $j_0 + d$ の画素値を $y_{j_0+d}(0)$, テンプレートと重ね合わせた対象画像の画素値を $y_{k+d}(i + 1)$ とすると, 相互相関係数 R は式 2.3 で表される [59],[97].

$$R = \frac{\sum_{d=-r}^r [y_{j_0+d}(0) - \bar{y}_{j_0}(0)] [y_{k+d}(i + 1) - \bar{y}_k(i + 1)]}{\sqrt{\sum_{d=-r}^r [y_{j_0+d}(0) - \bar{y}_{j_0}(0)]^2 \sum_{d=-r}^r [y_{k+d}(i + 1) - \bar{y}_k(i + 1)]^2}} \quad (2.3)$$

ここで, $y_d(i)$ は時刻 $t = i$ における深さ $d(1, 2, \dots, D)$ の画素値である. D は M モード画像の縦方向の画素数である. また, $\bar{y}_{j_0}(0)$ は, 位置 j_0 を中心にした上下 3 画素の画素値の平均であり, $\bar{y}_k(i + 1)$ は, 時刻 $i + 1$ における位置 k を中心にした上下 3 画素の画素値の平均である.

(3) 繰り返し

(2) のテンプレート処理を時刻 $t = 1, \dots, i, i + 1, \dots$ について繰り返し行う. 結果として, M モード画像から大動脈壁位置データの列が得られる.

2.4 大動脈壁位置抽出精度向上のための重み付きテンプレート処理

本節では、重み付きテンプレート処理の重みについて説明する。大動脈壁の周囲に存在する画素値の大きい画素が大動脈壁位置の抽出に悪影響を与える。しかし、従来のテンプレート処理では大動脈壁からの距離が考慮されず、これら周囲の画素が大動脈壁誤抽出の原因の1つとなる。これから抽出する大動脈壁はすでに抽出された大動脈壁位置の近くにあると考えられ、抽出された大動脈壁位置 j_{i-1} からの距離が遠くなるに従い、大動脈壁の可能性は小さくなる。そこで、抽出された大動脈壁位置からの距離に応じた重みを画素値に付ける。重みは指数関数値であらわす。具体的には、抽出された大動脈壁位置からの距離 d に応じた重みは平均 0、分散 σ^2 の正規分布に従うものとし、重みを付けた画素値 Y を

$$Y_{j_{i-1}+d}(i) = y_{j_{i-1}+d}(i)e^{-\frac{d^2}{2\sigma^2}} \quad (2.4)$$

とする。ここで、 $y_{j_{i-1}}(i)$ は、時刻 i における深さが $j_{i-1}(1,2,\dots,D)$ 番目の画素とする。D は M モード画像の縦方向の画素数である。また、重みを付けた画素値 Y の平均 \bar{Y} を

$$\bar{Y}_k(i) = \frac{\sum_{d=-r}^r y_{k+d}(i)e^{-\frac{(k-j_{i-1}+d)^2}{2\sigma^2}}}{\sum_{d=-r}^r e^{-\frac{(k-j_{i-1}+d)^2}{2\sigma^2}}} \quad (2.5)$$

とする。重みを決定する σ の定め方は 2.6.2 節で後述する。

この Y (式 (2.4)) および \bar{Y} (式 (2.5)) を従来の相互相関係数 R (式 (2.3)) の y, \bar{y} と

置き換え, 重み付き相互相関係数 R_W (式 (2.6)) を得る.

$$R_W = \frac{\sum_{d=-r}^r [Y_{j_0+d}(0) - \bar{Y}_{j_0}(0)] [Y_{k+d}(i+1) - \bar{Y}_k(i+1)]}{\sqrt{\sum_{d=-r}^r [Y_{j_0+d}(0) - \bar{Y}_{j_0}(0)]^2 \sum_{d=-r}^r [Y_{k+d}(i+1) - \bar{Y}_k(i+1)]^2}} \quad (2.6)$$


2.5 肝硬変識別のための特徴抽出

最も抽出精度の高いパラメータの組合せを用いて抽出された大動脈壁位置データからの特徴1と画像からの特徴2を合わせた計19特徴 [59] により肝硬変識別を行う。


肝硬変識別の特徴として、大動脈壁の動きを的確に反映していることが最も重要であると考え、大動脈壁だけでなく、大動脈の影響を受ける周辺の臓器の画素にも着目する。用いる19特徴は、5特徴 [98] と14特徴 [99] である。各特徴が肝硬変を識別するために、画像中において着目すべき情報とどのように対応しているかを以下に説明する。

2.5.1 画像特徴1

図2.8(a)および(b)に示すように、肝臓の硬化が大動脈壁の膨張収縮に影響を与えることに着目し、大動脈壁の動きから肝硬変識別の特徴を抽出する。



(a) 正常の大動脈壁位置データ



(b) 肝硬変の大動脈壁位置データ

図2.8: 抽出された大動脈壁位置データ

画像特徴 1 の計算では, 各時刻 t における大動脈壁位置データの実寸値 $X(t)$ ($t = 0, 1, \dots$) を用いる. 画素の実寸値は撮影時の状況により異なるため, 式 (2.7) により大動脈壁位置 [pixel] を実寸値 [mm] に変換する.

$$\text{大動脈壁位置の実寸値 [mm]} = \frac{\text{大動脈壁位置 [pixel]} \times \text{画像の縦幅 [mm]}}{\text{画像の縦の画素数 [pixel]}} \quad (2.7)$$

この特徴は, 大動脈壁位置データ 1 周期分の最大振幅, 標準偏差, フーリエ係数である. フーリエ係数は, 0 次から 2 次までとする.

- 最大振幅は, 大動脈の膨張収縮に伴う大動脈壁位置データの変化の最大振幅を表す.

$$A = \max_t X(t) - \min_t X(t) \quad (2.8)$$

- 標準偏差は, 大動脈の膨張収縮による大動脈壁位置データ変化の標準偏差を表す.


$$S = \sqrt{\frac{1}{N_t} \sum_t [X(t) - \bar{X}]^2} \quad (2.9)$$

- フーリエ係数は, 大動脈の膨張収縮の運動に着目し, 大動脈壁位置データから 0 次から 2 次までのフーリエ係数を得て, それを特徴 f_3, \dots, f_5 とする.


$$C_k = \left| \frac{1}{N_t} \sum_t X(t) e^{-j\omega t 2\pi/N_t} \right| \quad (k = 0, 1, 2) \quad (2.10)$$

ここで, \bar{X} は $X(t)$ の平均, N_t は 1 周期の画素数, $|Z|$ は複素数 Z の絶対値を表す.

2.5.2 画像特徴 2



(a) 正常 M モード画像



(b) 肝硬変 M モード画像

図 2.9: M モード画像

この特徴は、図 2.9 のように大動脈壁だけでなく、その周囲の臓器の動きにも着目する。この特徴は画素値の相関のフーリエ係数で表され、相関は一般的な相関を R_i としたとき $R'_i = 1 - R_i$ で表される、式 (2.11) と式 (2.12) の 2 つの修正相関係数 $R'_i (i = 1, 2)$ を得る。

- 時間間隔 τ を固定した状態での時刻 t における画像の縦列の画素値と時刻 $t + \tau$ における縦列の画素値との相関 R'_1 は、各時刻 t における単位時間あたりの大動脈壁の変化量を表す。図 2.10 のように、この値が大きければ大動脈壁の各時刻の変化量は大きく、つまり肝臓は柔らかく、逆に図 2.11 のように値が小さければ肝臓は硬いことを示す。

$$R'_1(t, \tau) = 1 - \frac{\sum_{d=1}^D [y_d(t) - \bar{y}(t)] [y_d(t + \tau) - \bar{y}(t + \tau)]}{D \cdot \sigma_y(t) \cdot \sigma_y(t + \tau)} \quad (2.11)$$

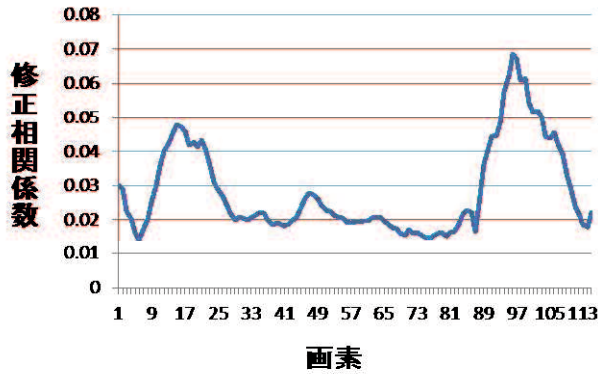


図 2.10: 正常の R'_1




図 2.11: 肝硬変の R'_1

- 時刻 0 における画像の縦列の画素値と時刻 t における縦列の画素値との相関 R'_2 は、各時刻 t における大動脈壁および近傍の臓器や脂肪組織の動きに着目した特徴である。

$$R'_2(t) = 1 - \frac{\sum_{d=1}^D [y_d(t) - \bar{y}(t)] [y_d(0) - \bar{y}(0)]}{D \cdot \sigma_y(t) \cdot \sigma_y(0)} \quad (2.12)$$

ここで、 $y_d(t)$ は時刻 t における縦 1 列中にある $d(1, 2, \dots, D)$ 番目の画素の濃淡値、 $\bar{y}(t)$ および $\sigma_y(t)$ はそれぞれ $y_d(t)$ の平均と標準偏差を表す。




図 2.12: 正常の R'_2




図 2.13: 肝硬変の R'_2

この修正相関係数 R'_2 は、各時刻 t における大動脈壁および近傍の臓器の動きに着目した特徴である。図 2.12 のように、この値が大きいほど時刻 0 と t の 2 列間における大動脈壁および近傍の臓器の動きが大きく、つまり肝臓は柔らかく、逆に図 2.13 のように値が小さければ肝臓は硬いことを示す。

2 つの修正相関係数 R'_1 と R'_2 についてそれぞれ 0 次から 6 次までのフーリエ係数 D_k , E_k を特徴 f_6, \dots, f_{12} , f_{13}, \dots, f_{19} として用いる。

表 2.1 に、画像特徴 1 の 5 特徴と画像特徴 2 の 14 特徴を合わせた 19 特徴の一覧を示す。

表 2.1: 特徴一覧

入力データ	特徴		名称
画像特徴 1	最大振幅		f_1
	標準偏差		f_2
	フーリエ係数	0 次	f_3
		1 次	f_4
		2 次	f_5
画像特徴 2	時刻 t と時刻 $t + \tau$ における縦列の画素値の相関のフーリエ係数	0 次	f_6
		1 次	f_7
		2 次	f_8
		3 次	f_9
		4 次	f_{10}
		5 次	f_{11}
	時刻 0 と時刻 t における縦列の画素値の相関のフーリエ係数	0 次	f_{13}
		1 次	f_{14}
		2 次	f_{15}
		3 次	f_{16}
		4 次	f_{17}
		5 次	f_{18}
		6 次	f_{19}

2.6 計算機実験

2.6.1 実験方法

計算機実験では，山口大学医学部附属病院から提供された M モード画像（サンプル）を用いた．前述したように，画像への肝硬変と正常のラベル付けは，肝臓の専門医による．画像数は，肝硬変サンプル数 28（16 名），正常サンプル数 21（12 名）の計 49 である．画像は，いずれも 8 ビット階調画像である．今回使用した画像の画素数は，横幅が 200 画素から 600 画素，縦幅がおよそ 180 画素である．ここで，1 画素の縦の長さは，実寸値で 0.28mm から 0.48mm である．

まず，重み付きテンプレート処理（図 2.4 処理 B）の有効性を大動脈壁位置抽出の抽出精度から評価するために，重み付きテンプレート処理と従来のテンプレート処理とを比較する．次に，画質改善のためのバイラテラルフィルタによる前処理（図 2.4 処理 A）の有効性を実験により検証するため，バイラテラルフィルタを適用した画像を用いた大動脈壁位置抽出と前処理なしの画像を用いた抽出とを比較する．最後に，画像からの特徴抽出において，前処理なしとバイラテラルフィルタ処理の比較（図 2.4 処理 C）を行い，バイラテラルフィルタによる画質改善の効果を検証する．

2.6.2 重み付きテンプレート処理による大動脈壁位置抽出

予備実験として、図 2.7 の大動脈壁位置抽出に用いる領域範囲を決めるパラメータ ω の値を求めた。この予備実験には、バイラテラルフィルタによる前処理なしの画像と前処理ありの画像とを用いた。 ω の値には、目視により大動脈壁位置抽出が可能となる範囲であることを確認して 1, 2, 3 を ω の候補値として与え、従来のテンプレート処理により大動脈壁位置抽出実験を行った。なお図 2.6 にあるテンプレート処理のパラメータ r の値は、3 とした。またバイラテラルフィルタのパラメータの候補値は、 $\sigma_d = 1, 3, 5, 10$, $\sigma_r = 10, 30, 100, 300, 500$ とした。評価は、目視により大動脈壁の抽出に成功した画像数の比較により行った。なお抽出の開始点は、目視により大動脈壁上の画素に決定した。

予備実験の結果、パラメータの最適な組み合わせは 2 通りあり、共にパラメータ値 $\sigma_d = 3$, $\sigma_r = 300$ であるバイラテラルフィルタによる前処理を適用した画像を用い、 ω の値は 1 または 2 としたときであった。このとき、4 枚の画像で抽出に失敗した。抽出失敗の原因の一つとして、大動脈壁位置の変化量が 1 画素を越える部分で誤った抽出をしていた。精度良く大動脈壁位置を抽出するために ω の値は 1 より 2 とする方が、より確実であると考え。一方、 ω の値を 3 と大きくした場合は、探索範囲が広くなりすぎ、抽出に成功した画像数は 33 枚と減少している。以上から、抽出に用いる探索範囲 ω の値は、2 とした。また、重み付きテンプレート処理の式 R_W (式 (2.6)) のパラメータ r および σ の候補値を表 2.2 に示す。

表 2.2: パラメータ r および σ の候補値

$r = \{3, 5, 7, 9, 11, 13, 15, 17, 19, 21, 23, 25, 27, 29\}$
$\sigma(\text{式 (2.4)}) = \{1, 2, 3, 4, 5, 10, 15, 20, 25, 30, 35, 40, 45, 50\}$

重み付きと従来のテンプレート処理を用いた各処理について大動脈壁位置抽出結果の例を図 2.14 に示す。原画像が図 2.14(a) である。図 2.14(c) の赤線が、目視により抽出した大動

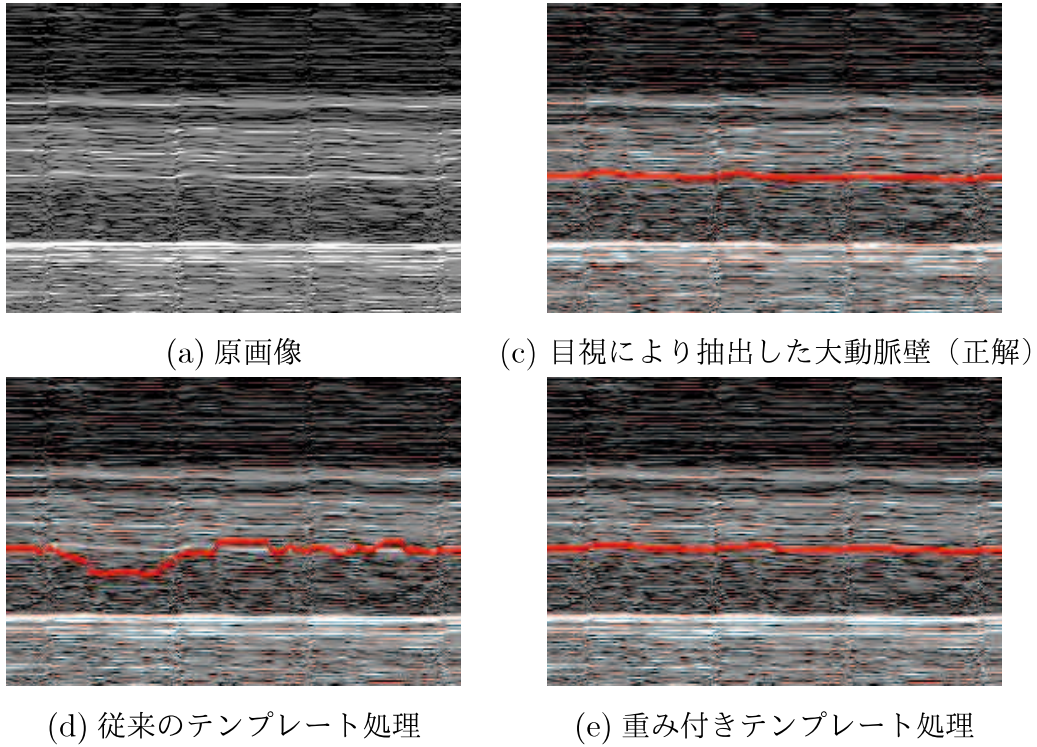


図 2.14: 抽出結果の画像 (1)

脈壁である。従来のテンプレート処理による抽出処理では、図 2.14(d) に示すように大動脈壁位置抽出に失敗している。一方、重み付きによる結果（図 2.14(e)）では、従来のテンプレート処理の結果（図 2.14(d)）と比較して誤抽出が低減されている。重み付きは、注目画素から離れた、画素値の大きな画素の影響を小さくする効果がある。この重みによって従来のテンプレート処理より高精度に大動脈壁を抽出できていると考える。

次に、正解として人間が抽出した大動脈壁位置と各処理により得られた位置との抽出誤差の二乗平均平方根 RMS （式 (2.13)）[100] により比較した。

$$RMS = \sqrt{\frac{\sum_{i=1}^{width} d_i^2}{width}} \quad (2.13)$$

ここで、 d_i は時刻 i における目視により抽出した正解位置と各処理により抽出された位置と

の差分の絶対値 [mm] である。以下，この差分の絶対値を誤差とする。また， $width$ は画像の幅 [pixel] である。なお，誤差の平均 $Mean$ および最大値 Max は式 (2.14)，式 (2.15) により得る [100]。


$$Mean = \frac{\sum_{i=1}^{width} d_i}{width} \quad (2.14)$$

$$Max = \max_i d_i \quad (2.15)$$


RMS ， $Mean$ ， Max それぞれについて，各パラメータ毎に全画像 49 枚の平均値を求めた。重み付きと従来のテンプレート処理を用いた各処理について大動脈壁位置抽出の結果を表 2.3 に示す。重み付きと従来のテンプレート処理による抽出結果で， RMS 上で最良となるパラメータの値を表 2.4 に示す。

表 2.3: 大動脈壁位置抽出精度


	重み付きテンプレート処理 (処理 B)	従来のテンプレート処理
RMS	0.57	0.85
$Mean$	0.40	0.62
Max	1.58	2.43



(e)



(c) 正解



(d)

表 2.4: パラメータの最適値

	パラメータ
重み付きテンプレート処理 (処理 B)	$r = 9, \sigma = 4$
従来のテンプレート処理	$r = 23$

重み付きで RMS の値が最小となったのは、重み付きテンプレート処理のパラメータが $r = 9, \sigma = 4$ のときであった。表 2.3 より、 RMS の値は従来のテンプレート処理のとき 0.85 であるのに対し、重み付きでは RMS の値が 0.57 となり抽出性能が向上した。 $Mean$ については従来の処理が 0.62 であったのに対し、重み付きでは 0.40 となり誤差の平均値が改善されている。同じく、 Max の値は従来の処理が 2.43 であるのに比べ、重み付きのそれは 1.58 となり、誤差の最大値についても改善された。以上の結果から、重み付きテンプレート処理を用いた大動脈壁位置抽出が有効であると考ええる。

従来のテンプレート処理において、パラメータ $r = \{ 3, 5, 7, 9, 11, 13, 15, 17, 19, 21, 23, 25, 27, 29 \}$ の各 r の値毎の $RMS, Mean, Max$ の値を表 2.5 に示す。表 2.5 から、 $r = 23$ のとき $RMS, Mean, Max$ すべての値について最小であることから、従来のテンプレート処理では $r = 23$ が最良であると考ええる。

表 2.5: 従来テンプレート処理におけるパラメータ r に対する RMS , $Mean$, Max の値

r	RMS	$Mean$	Max
3	1.75	1.33	4.19
5	1.31	0.99	3.21
7	1.27	0.96	3.26
9	1.30	1.01	3.18
11	1.21	0.88	3.14
13	0.95	0.70	2.58
15	0.93	0.68	2.56
17	0.95	0.69	2.65
19	0.87	0.64	2.52
21	0.98	0.70	2.71
23	0.85	0.62	2.43
25	0.90	0.66	2.55
27	0.93	0.70	2.59
29	0.97	0.73	2.61

最後に、重み付きテンプレート処理において、パラメータ r と σ の値を変えた時の RMS の値を 3次元プロットしたものを図 2.15 に示す。ここで、縦軸の目盛間隔は 0.2 である。また、パラメータ r と σ の最適な組合せである $r = 9$, $\sigma = 4$ の座標を矢印で示す。

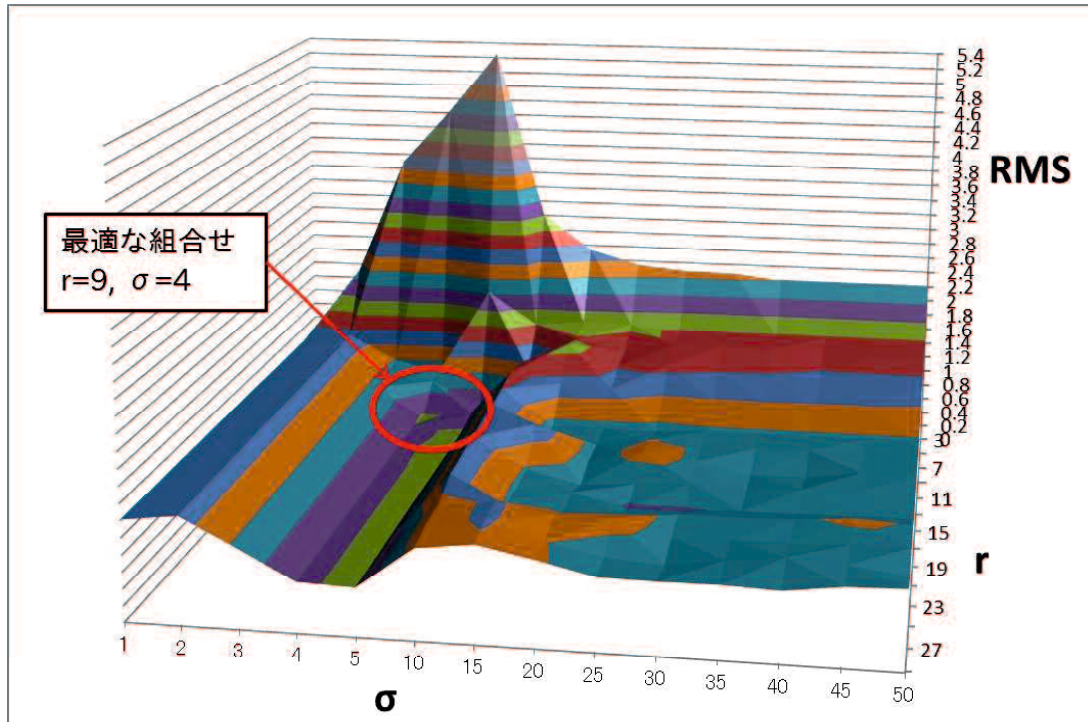


図 2.15: 様々な r と σ に対する RMS 値の 3次元プロット

2.6.3 バイラテラルフィルタを用いた大動脈壁位置抽出の改良


次に、画質改善を目的としたバイラテラルフィルタによる前処理の有効性を評価するために、前処理なしとの比較を、抽出誤差の RMS , $Mean$, Max により行った。式 (2.2) のバイラテラルフィルタのパラメータは文献 [93] を参考にし、表 2.6 に示す σ_d と σ_r の候補値を用い、フィルタサイズを決める w は注目画素からの距離による重みを表すパラメータの最大候補値である 10 画素より大きな値となる 11 画素とした。なおテンプレート処理には、重み付きテンプレート処理を用いた。

表 2.6: バイラテラルフィルタのパラメータ


$\sigma_d = \{0.1, 0.5, 1.0, 3.0, 5.0, 10.0\}$
$\sigma_r = \{10, 30, 100, 300, 500, 700\}$

まず、バイラテラルフィルタ処理と前処理なしの画像を用いた大動脈壁位置抽出結果の例を図 2.16 に示す。バイラテラルフィルタ処理画像を図 2.16(b) に示す。前処理なしの画像を用い、重み付きテンプレート処理による抽出結果は図 2.16(e) である。一方、図 2.16(f) のように重み付きテンプレート処理とバイラテラルフィルタ両処理を併用した場合には、大動脈壁位置抽出の精度がより向上していることが示されている。バイラテラルフィルタを適用することで、画像を先鋭化したことが、精度を高めた要因となっている。このことから、重み付きテンプレート処理とバイラテラルフィルタによる相乗効果が示された。特に、バイラテラルフィルタの特長であるエッジの保存が効果的であると考えられる。


大動脈壁位置抽出についてバイラテラルフィルタの効果を検証するため、 RMS , $Mean$, Max それぞれについて、各パラメータ毎に全画像 49 枚の平均値を求めた。バイラテラルフィルタ処理と前処理なしの画像を用いた大動脈壁位置抽出結果を表 2.7 に示す。抽出結果で、 RMS が最良となるパラメータの値を表 2.8 に示す。バイラテラルフィルタ有り




(a) 原画像




(b) バイラテラルフィルタ処理画像



(c) 目視により抽出した大動脈壁（正解）



(e) 重み付きテンプレート処理




(f) 重み付きテンプレート処理
および バイラテラルフィルタ

図 2.16: 抽出結果の画像 (2)


RMS の値が最小となったのは、 $\sigma_d = 0.5$ 、 $\sigma_r = 500$ のときであった。表 2.7 より、 RMS の値は前処理なしでは 0.57 であるのに対し、バイラテラルフィルタ有りでは RMS の値が 0.52 となり、より高精度に大動脈壁の抽出が行われた。 $Mean$ では前処理なしが 0.40 であったのに対し、バイラテラルフィルタ有りでは 0.37 と誤差の平均値が改善されている。同じく、 Max の値は前処理なしが 1.58 であるのに比べ、バイラテラルフィルタのそれは 1.37 となり、誤差の最大値も改善された。

表 2.7: 大動脈壁位置抽出精度


	バイラテラルフィルタ (処理 A)	前処理なし
<i>RMS</i>	0.52	0.57
<i>Mean</i>	0.37	0.40
<i>Max</i>	1.37	1.58



(f)



(c) 正解



(e)

表 2.8: パラメータの最適値

	パラメータ
バイラテラルフィルタ (処理 A)	$\sigma_d = 0.5, \sigma_r = 500$


2.6.4 バイラテラルフィルタを用いた特徴2の抽出改良

画像からの特徴2の抽出において、バイラテラルフィルタの効果を実験により検証する。予備実験として、バイラテラルフィルタのパラメータ値を仮設定した。予備実験の目的は、バイラテラルフィルタを適用した画像から、特徴抽出に最適であると考えられる画像を目視で判定し、そのときのパラメータ値を仮設定することである。本予備実験で用いるバイラテラルフィルタのパラメータ σ_d と σ_r の候補値を表 2.9 に示す。これらパラメータの組合せを用いたバイラテラルフィルタの適用画像を図 2.17 に示す。


表 2.9: バイラテラルフィルタのパラメータの候補

$$\begin{array}{c} \sigma_d = \{1.0, 5.0\} \\ \sigma_r = \{10, 100, 500\} \end{array}$$


$\sigma_d = 1$ のとき、 σ_r の値によらず画質改善の効果が小さく、特徴抽出には適していない (図 2.17(a)(b)(c))。 $\sigma_d = 5$ 、 $\sigma_r = 500$ の場合 (図 2.17(f))、画素値の差に応じた重みを決定するパラメータが大であることから、エッジが保存されておらず、画像全体がぼけており、特徴抽出に適していない。 $\sigma_d = 5$ 、 $\sigma_r = 100$ では (図 2.17(d))、エッジ保存がされた平滑化が行われ、高精度な識別のための特徴抽出が可能と考える。 $\sigma_d = 5$ 、 $\sigma_r = 10$ の場合 (図 2.17(e)) は $\sigma_d = 5$ 、 $\sigma_r = 100$ (図 2.17(d)) と比較して画質改善の効果が少なく、高精度な識別を行う特徴の抽出が困難と考える。以上の結果から、パラメータ値を $\sigma_d = 5$ 、 $\sigma_r = 100$ と仮設定する。次に、バイラテラルフィルタによる前処理なしの画像と前処理ありの画像とからそれぞれ 14 特徴を抽出する。式 (2.11) の時間間隔 τ は、文献 [99] より周期の $1/10$ とした。




(a) $\sigma_d = 1, \sigma_r = 10$




(b) $\sigma_d = 1, \sigma_r = 100$




(c) $\sigma_d = 1, \sigma_r = 500$



(d) $\sigma_d = 5, \sigma_r = 10$



(e) $\sigma_d = 5, \sigma_r = 100$



(f) $\sigma_d = 5, \sigma_r = 500$

図 2.17: パラメータの組合せによるバイラテラルフィルタ処理画像

一般に特徴の評価には,

- 特徴抽出時に行う
- 特徴抽出と識別器と組合せて識別実験を通して行う

といった二つの方法が考えられる. しかし, 後者の識別実験による評価では特徴抽出と識別器との組合せも考慮する必要があるため, 本研究では特徴抽出時に単独での評価を行うことを基本とする. なお, 後述の画像特徴 1 と画像特徴 2 の両方の必要性を示す実験においては, 最終評価であることから特徴抽出法と識別器と組合せて識別実験を通して行った.

特徴の改善を示すために, 同一の画像群を対象に, バイラテラルフィルタによる前処理ありの場合の特徴と前処理なしの場合の特徴を比較するために有意差検定を行った.

Fisher 比は, 1 次元, すなわち特徴を個別に評価する特徴評価関数であり, 分散で正規化された平均間ユークリッド 2 乗距離と解釈される. 特徴 f_j に対する Fisher 比 $J(f_j)$ は, 次式で定義される.

$$J(f_j) = \frac{(\mu_{1(j)} - \mu_{2(j)})^2}{P(\omega_1)\sigma_{1(j)}^2 + P(\omega_2)\sigma_{2(j)}^2} \quad (2.16)$$

$\mu_{i(j)}$ と $\sigma_{i(j)}^2$ は, それぞれ特徴 f_j 上のクラス ω_i の平均と分散である. また, $P(\omega_1)$ および $P(\omega_2)$ は, 各クラスの事前確率である. この $J(f_j)$ の値が大きいほど, 識別に有効な特徴であることを示す.

まず, 画像特徴 2 の $f_6 \sim f_{19}$ について検証する. バイラテラルフィルタによる前処理なしの画像と前処理ありの画像とから抽出した特徴からそれぞれ Fisher 比を算出する. 各特徴について, Fisher 比を用い, 対のある有意差検定を行った. 正常サンプルから 15 サンプル, 肝硬変サンプルから 15 サンプルの計 30 サンプルをランダムに選び, バイラテラルフィルタによる前処理ありの画像からの特徴を $\hat{f}_6, \dots, \hat{f}_{19}$, 前処理なしの画像からの特徴を f_6, \dots, f_{19} とする. これらの特徴の Fisher 比の値をそれぞれ $J(\hat{f}_i)$, $J(f_i)$ と表す. こ

れを 100 回繰り返す。ここで、 i : 特徴の番号 ($6 \leq i \leq 19$), j : 反復回数 ($1 \leq j \leq 100$) である。両者の差 z_i^j を

$$z_i^j = J(\hat{f}_i^j) - J(f_i^j) \quad (2.17)$$

とする。未知なる平均 μ , 標準偏差 σ の母集団から $z_i^1, z_i^2, \dots, z_i^{100}$ が抽出されたとし, それらの標本平均を \bar{z}_i , 標本標準偏差を $\hat{\sigma}_i$ とする。この標本平均 \bar{z}_i , すなわち $\bar{z}_i = \frac{1}{n} \sum_{j=1}^n z_i^j$ は, n が大きいとき中心極限定理により正規分布に従う。すなわち $\bar{z}_i \sim N(\mu, \frac{\hat{\sigma}_i^2}{n})$ であることが知られている。この \bar{z}_i を規準化し,

$$T = \frac{\bar{z}_i - \mu}{\frac{\hat{\sigma}_i}{\sqrt{n}}} \quad (2.18)$$

とすれば, T は $N(0, 1)$ に従う。

仮説を立てる場合, その仮説が棄却されることを予想して設定し, この仮説を帰無仮説という。ここで, 帰無仮説 $H_0: \mu = 0$ を立てる。これは, 両者に差が無いことを意味している。この帰無仮説 H_0 を検定する。

$\mu = 0$ のとき, 式 (2.18) は

$$Z = \frac{\bar{z}_i}{\frac{\hat{\sigma}_i}{\sqrt{n}}} \quad (2.19)$$

となる。

帰無仮説が正しいにもかかわらず, この仮説が誤りである, すなわち帰無仮説を棄却する基準を有意水準という。この有意水準は, 通常 1% あるいは 5% が使われる [101],[102]。本研究では, 有意水準 5% より厳しく検定を行うため, 有意水準を 1% とした。

有意水準 1% とすれば, 片側検定の境界値は 2.33 であり, この境界値よりも Z の実現値 z が大きい場合は帰無仮説 H_0 が棄却される。表 2.10 に, 各特徴の Z の実現値 z を示す。画像特徴 2 の 14 特徴すべてについて Z の実現値 z は境界値より大であり, 帰無仮説 H_0 は棄却され, 提案のバイラテラルフィルタの前処理による画像からの特徴 \hat{f} の Fisher 比が有

意に大きくなったことが示された。

バイラテラルフィルタが低画質の画像を大動脈壁の形状を保持したまま平滑化することにより画質改善が行われ、その結果として前処理なしの画像に比べ肝硬変識別に有効な特徴をより高精度に得ることができたと考えられる。このことから、バイラテラルフィルタによる前処理が識別性能向上に有効であると考えられる。

表 2.10: 各特徴の有意差検定の結果

特徴	Z の実現値 z	1% 有意差
\hat{f}_6	30.68	有り
\hat{f}_7	33.21	有り
\hat{f}_8	31.09	有り
\hat{f}_9	44.07	有り
\hat{f}_{10}	42.36	有り
\hat{f}_{11}	37.44	有り
\hat{f}_{12}	29.14	有り
\hat{f}_{13}	31.66	有り
\hat{f}_{14}	24.47	有り
\hat{f}_{15}	28.51	有り
\hat{f}_{16}	16.74	有り
\hat{f}_{17}	17.81	有り
\hat{f}_{18}	22.59	有り
\hat{f}_{19}	20.70	有り

次に、画像特徴 1 の $f_1 \sim f_5$ に対する差の有意差検定について述べる。バイラテラルフィルタによる前処理なしの画像を用い、従来のテンプレート処理では、大動脈壁位置抽出に失敗した画像数が多く、同一画像での比較が行えない。なお、各手法における抽出失敗画像数は以下の通りである。

追加実験として、 $f_1 \sim f_5$ についての Fisher 比の平均の差の有意差検定を対で行う評価実験を行った。抽出に失敗したサンプルを除いた同一サンプルを用いて、提案手法と従来のテ

表 2.11: 各手法の大動脈壁位置抽出失敗画像数

バイラテラルフィルタと 重み付きテンプレート処理 とによる手法（提案手法）	前処理なしと 従来のテンプレート処理
4 枚	7 枚

ンプレート処理について各 5 特徴を検定する.

有意水準を 1% としたときの結果を表 2.12 に示す.

表 2.12: $f_1 \sim f_5$ についての有意差検定の結果

特徴	Z の実現値 z	1% 有意差
\hat{f}_1	29.39	有り
\hat{f}_2	33.69	有り
\hat{f}_3	25.41	有り
\hat{f}_4	29.38	有り
\hat{f}_5	35.95	有り

表 2.12 から, 5 特徴すべてで有意差が認められた.

次に, 画像特徴 1 と画像特徴 2 の両方が必要であることを示すために, 以下の実験を行った. 実験目的は, 肝硬変識別に, 全 19 特徴が必要であることを誤識別率により検証することである. 実験方法は, 49 サンプル上で, 同一特徴数で誤識別率の比較を行う. 画像特徴 1 の 5 特徴と揃えるため, 特徴数を 5 とする. 特徴数を 5 とするため, Fisher 比により 19 特徴からの特徴選択を行い, Fisher 比の大きい 5 特徴を選ぶ. なお識別器は, Fisher 線形識別器とした. Holdout 法を 100 回独立に繰り返して誤識別率を推定した.

画像特徴 1 の 5 特徴と 19 特徴から 5 特徴を誤識別率により比較した結果を表 2.13 に示す.

表 2.13 から, 画像特徴 1 の 5 特徴のみに比べ, 全 19 特徴から 5 特徴を選択した場合の誤

表 2.13: 5 特徴と全 19 特徴からの 5 特徴を選択した識別結果

使用した特徴	誤識別率
画像特徴 1 の 5 特徴	21.7 %
全 19 特徴から特徴選択により選ばれた 5 特徴	15.5 %

識別率が減少しており，全 19 特徴からの特徴を用いる必要があることが示された．

肝硬変識別で用いる画像特徴 1 と画像特徴 2 を整理する．画像特徴 1 は，2.6.3 節の処理で *RMS* の値が最小となったパラメータの組合せにより求められたものを用いた．抽出精度の悪い大動脈壁位置データは肝硬変の識別性能を低下させるため，予備実験により *RMS* の値が 1.40mm 以上となったものについては抽出に失敗したとし，抽出に失敗した画像では，目視により大動脈壁位置を抽出した．この大動脈壁位置データから前述の画像特徴 1 の 5 特徴を得て，画像特徴 2 の 14 特徴と合わせた計 19 特徴を用いて次章では肝硬変識別を行う．

2.7 おわりに

第2章では、Mモード画像から肝硬変識別に用いる特徴抽出の改良について、バイラテラルフィルタと重み付きテンプレート処理の適用を提案した。計算機実験の結果から、バイラテラルフィルタと重み付きテンプレート処理が、大動脈壁位置抽出と画像からの特徴抽出に有効であることを検証し、バイラテラルフィルタが大動脈壁位置抽出と特徴抽出の両面で、また重み付きテンプレート処理が大動脈壁位置抽出に有効であった。

肝硬変識別の高精度化には、特徴抽出の高精度化のみならず、有効な特徴の選択や識別手法の最適化も求められる。次章では、特徴選択の導入や識別器の選定について論じる。

第 3 章

識別系の高精度化

3.1 はじめに

前章で，肝硬変識別に用いる特徴抽出の改良について論じた．この特徴を用い，正常か肝硬変かの識別処理を行う．

本章では，識別系の高精度化について検討する．特徴選択法と識別器の組合せの中から，最適な組合せを見つける処理（図 3.1 処理 D）である．特徴選択法は Fisher 比と SFS 法を候補とし，識別器の候補はユークリッド距離識別器，Fisher 線形識別器，Bayes2 次識別器，RDA 法を比較対象として，これらの組合せの中から最も有効な特徴選択法と識別器を比較実験により選定する．

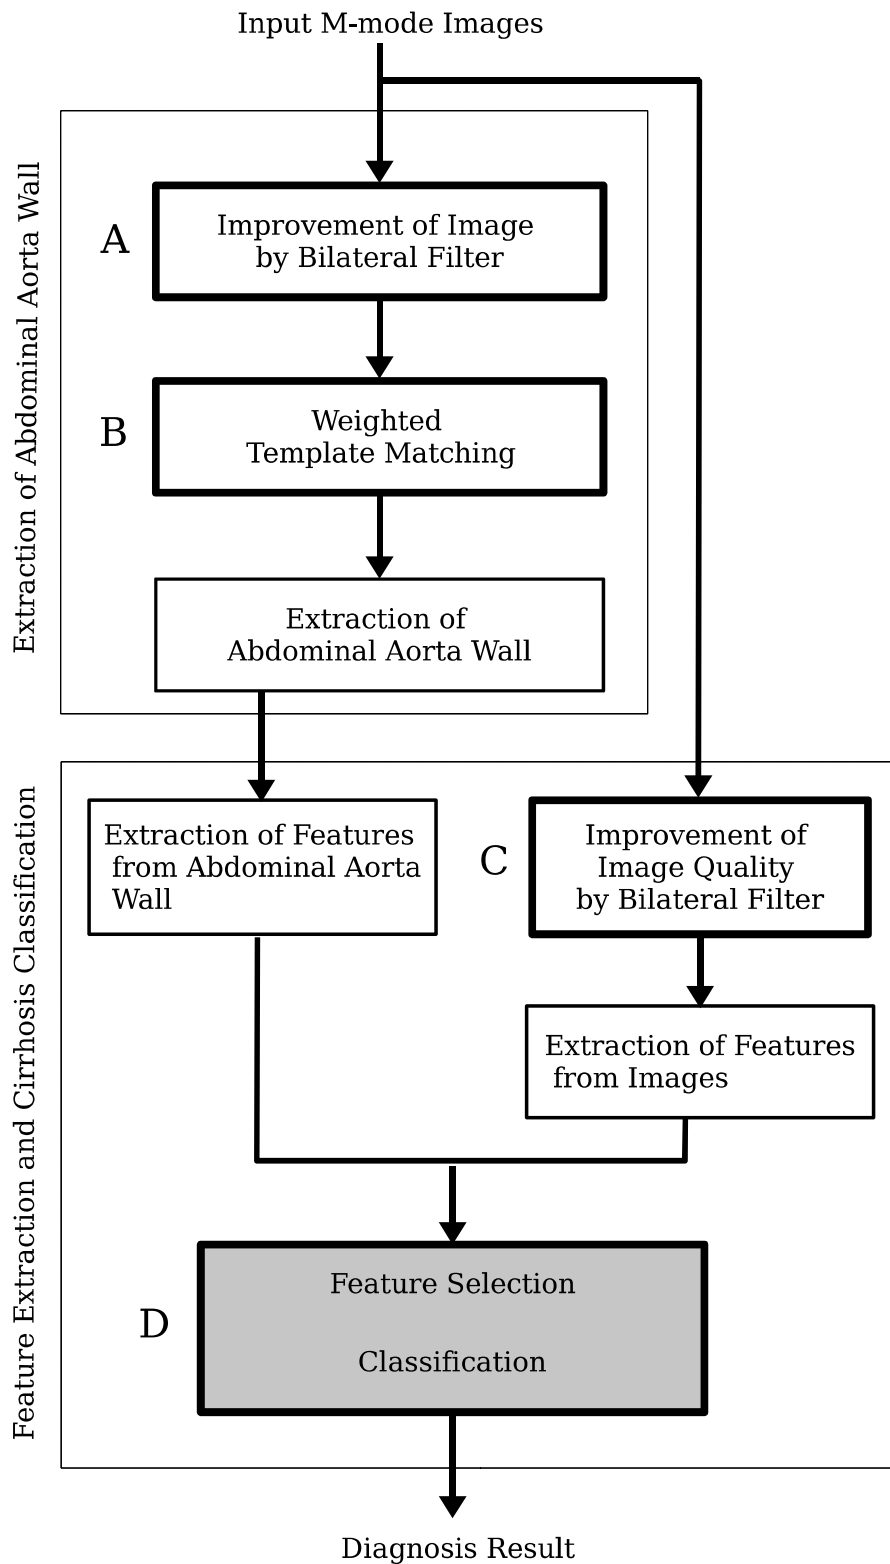


図 3.1: 大動脈壁位置抽出と肝硬変からの特徴抽出と識別のフロー

3.2 特徴選択の導入

肝硬変識別を目的として、前章では、画像特徴1の5特徴および画像特徴2の14特徴を抽出し、計19特徴が得られる。一般に多くの特徴を用いるときに、ピーキング現象の問題が指摘されている [103]。ピーキング現象とは、訓練サンプルが一定のとき、特徴数を増加させると最初は識別率が上昇するが、ある特徴数を越えると識別率が減少する現象である。ピークとなる最適な特徴数は未知であり、最適な特徴数を求めることは、識別器、訓練サンプル数、データによって異なるため、困難とされている。しかし、一般に候補となる特徴の数はこの最適数より大であるため、適当な特徴選択を行うことで識別性能の向上が期待できる。すなわち、特徴の中から識別に有用なものを選択する機能が必要となる。その一つの方法として、特徴選択法がある。

特徴選択法として、Fisher 比による特徴選択法と逐次型前向き最適化法 (Sequential Forward Selection 法:SFS 法) [103] による特徴選択法を候補とする。

SFS 法とは特徴の組合せを評価して特徴を選択する手法である。SFS 法は、まず第1特徴は単独で特徴評価関数による評価を行い、候補の特徴の中から最も優れた特徴を選択し、第2特徴以降はすでに選択された特徴と候補の特徴を組合せて評価し、最も優れた特徴を一つずつ追加していく。SFS 法のアルゴリズムを次に示す。

候補となる特徴の集合を $Y = \{e_1, e_2, \dots, e_n\}$ とする。いま、 k 個の特徴がすでに選択されており、その特徴集合を $X_k = \{e_{i_1}, e_{i_2}, \dots, e_{i_k}\}$ とする。 X_0 を空集合としたとき、 $k+1$ 番目の特徴は

$$J(X_k \cup \{e^+\}) = \max J(X_k \cup \{e\}), \quad (3.1)$$
$$e \in Y - X_k, k = 0, 1, 2, \dots, d$$

のとき、 e^+ であり、 $X_{k+1} = X_k \cup \{e^+\}$ となる。ここで、 J は統計的距離であり、 $Y - X_k$

は Y と X_k の集合差, すなわちまだ選択されていない特徴の集合である. これを繰り返すことで, J の意味でもっともすぐれた特徴が一つずつ追加される.

SFS 法の特徴評価関数には, マハラノビス距離 [103] を用いた. マハラノビス距離 J_M は,

$$J_M = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \quad (3.2)$$

で定義される.

3.3 識別器の選定

高精度な肝硬変識別を実現するために、識別器の選定を検討する。肝硬変識別に対してどのような識別器が最適であるかは、実際にいくつかの識別器による実験を試み、そのデータに適した識別器を選定することが実際的である。そこで、肝硬変識別に適した識別器の選定実験を行った。

候補となる識別器は、ユークリッド距離識別器、Fisher 線形識別器、Bayes2 次識別器、そして RDA 法で、これらの比較実験を行う [103]~[106]。

いまクラス ω_i の訓練サンプル $x_1^i, x_2^i, \dots, x_{N_i}^i$ が与えられているとする。 N_i はクラス ω_i の訓練サンプル数である。この N_i 個の訓練サンプルを用いてクラス ω_i の平均ベクトル、共分散行列の不偏推定量はそれぞれ

$$\hat{\boldsymbol{\mu}}_i = \frac{1}{N_i} \sum_{j=1}^{N_i} x_j^i \quad (3.3)$$

$$\hat{\boldsymbol{\Sigma}}_i = \frac{1}{N_i - 1} \sum_{j=1}^{N_i} (x_j^i - \hat{\boldsymbol{\mu}}_i)(x_j^i - \hat{\boldsymbol{\mu}}_i)^T \quad (3.4)$$

で与えられる。事前確率 $\hat{P}(\omega_i)$ については、

$$\hat{P}(\omega_i) = \frac{N_i}{N_1 + N_2} \quad (3.5)$$

とする。

まず、ユークリッド距離識別器について述べる。2 クラスの共分散行列が単位行列で事前確率も等しいとき、次式で表されるユークリッド距離識別器となる。

$$\begin{aligned} (\mathbf{x} - \hat{\boldsymbol{\mu}}_2)^T (\mathbf{x} - \hat{\boldsymbol{\mu}}_2) &> (\mathbf{x} - \hat{\boldsymbol{\mu}}_1)^T (\mathbf{x} - \hat{\boldsymbol{\mu}}_1) && \rightarrow \mathbf{x} \in \omega_1 \\ &< && \rightarrow \mathbf{x} \in \omega_2 \end{aligned} \quad (3.6)$$

この識別器は幾何的には、識別面が平均ベクトル間を結ぶ線の垂直 2 等分線となる線形識

別器である.

次に, Fisher 線形識別器について述べる.

等共分散行列を

$$\hat{\Sigma}_F = \hat{P}(\omega_1)\hat{\Sigma}_1 + \hat{P}(\omega_2)\hat{\Sigma}_2 \quad (3.7)$$

と仮定する. このとき, 線形識別関数として

$$\hat{\mathbf{W}} = \hat{\Sigma}_F^{-1}(\hat{\boldsymbol{\mu}}_2 - \hat{\boldsymbol{\mu}}_1) \quad (3.8)$$

$$\hat{w}_0 = \frac{1}{2}(\hat{\boldsymbol{\mu}}_1 + \hat{\boldsymbol{\mu}}_2)^T \hat{\Sigma}_F^{-1}(\hat{\boldsymbol{\mu}}_1 - \hat{\boldsymbol{\mu}}_2) + \log_e \frac{\hat{P}(\omega_2)}{\hat{P}(\omega_1)} \quad (3.9)$$

とおくと, Fisher 線形識別器では

$$\begin{aligned} \hat{\mathbf{W}}^T \mathbf{x} + \hat{w}_0 < 0 &\rightarrow \mathbf{x} \in \omega_1 \\ &> 0 \rightarrow \mathbf{x} \in \omega_2 \end{aligned} \quad (3.10)$$

によって, パターン \mathbf{x} を識別する.

また, Bayes2 次識別器では

$$\hat{d}_i(\mathbf{x}) = \frac{1}{2}(\mathbf{x} - \hat{\boldsymbol{\mu}}_i)^T \hat{\Sigma}_i^{-1}(\mathbf{x} - \hat{\boldsymbol{\mu}}_i) + \log_e \frac{|\hat{\Sigma}_i|^{1/2}}{\hat{P}(\omega_i)} \quad (3.11)$$

を定義し,

$$\begin{aligned} \hat{d}_1(\mathbf{x}) < \hat{d}_2(\mathbf{x}) &\rightarrow \mathbf{x} \in \omega_1 \\ &> \hat{d}_2(\mathbf{x}) \rightarrow \mathbf{x} \in \omega_2 \end{aligned} \quad (3.12)$$

として, パターン \mathbf{x} をクラスへ識別する.

RDA (Regularized Discriminant Analysis) 法は, サンプル数の少なさによる標本 Bayes2 次識別器の識別性能劣化を克服する手法である. この手法は, Bayes2 次識別器と線形識別器との統合パラメータ $\lambda(0 \leq \lambda \leq 1)$ と共分散行列の補正パラメータ $\gamma(0 \leq \gamma \leq 1)$ を導入し, 少ないサンプル数の問題に対処するための手法である. 以下に RDA 法について述べる.

各クラスの共分散行列からの \hat{S}_i と、それらの平均化行列 \hat{S} との線形結合行列 $\hat{\Sigma}_i^\lambda$ を

$$\hat{\Sigma}_i^\lambda = \frac{(1-\lambda)\hat{S}_i + \lambda\hat{S}}{(1-\lambda)N_i + \lambda N} \quad (3.13)$$

で定義する。ここで、

$$N = N_1 + N_2 + \cdots + N_m \quad (3.14)$$

$$\hat{S}_i = N_i \hat{\Sigma}_i \quad (3.15)$$

$$\hat{S} = \sum_{i=1}^m \hat{S}_i \quad (3.16)$$

である。 $\hat{\Sigma}_i^\lambda$ は、 λ の値によって

$$\hat{\Sigma}_i^{\lambda,\gamma} = \begin{cases} \hat{\Sigma}_i, (\lambda = 0) \\ \sum_{i=1}^m \hat{P}(\omega_i) \hat{\Sigma}_i, (\lambda = 1) \end{cases} \quad (3.17)$$

となる。 つぎに最終的に用いる共分散行列 $\hat{\Sigma}_i^{\lambda,\gamma}$ を

$$\hat{\Sigma}_i^{\lambda,\gamma} = (1-\gamma)\hat{\Sigma}_i^\lambda + \gamma c_i(\lambda) I_n \quad (3.18)$$

で定義する。 $c_i(\lambda)$ は

$$c_i(\lambda) = \frac{\text{Tr}[\hat{\Sigma}_i^\lambda]}{n} \quad (3.19)$$

によって与えられる。 ここで、 $\text{Tr}[A]$ は行列 A のトレースである。 共分散行列の固有値は分散であるから、 $c_i(\lambda)$ は固有値の平均値、つまり分布の平均的広がりを表している。 γ は $\hat{\Sigma}_i^\lambda$ と平均的広がり共分散行列を線形結合させるパラメータである。 この $\hat{\Sigma}_i^\lambda$ を式 (3.11) に代入し、

$$\hat{d}_i(\mathbf{x}) = \frac{1}{2}(\mathbf{x} - \hat{\boldsymbol{\mu}}_i)^T (\hat{\Sigma}_i^{\lambda,\gamma})^{-1} (\mathbf{x} - \hat{\boldsymbol{\mu}}_i) + \log_e \frac{|\hat{\Sigma}_i^{\lambda,\gamma}|^{1/2}}{\hat{P}(\omega_i)} \quad (3.20)$$

を用いて標本 Bayes2 次識別器を実現する。すなわち,

$$\begin{array}{lcl} \hat{d}_1(\mathbf{x})_{RDA} & < & \hat{d}_2(\mathbf{x})_{RDA} \quad \rightarrow \mathbf{x} \in \omega_1 \\ & > & \rightarrow \mathbf{x} \in \omega_2 \end{array} \quad (3.21)$$

である。なお, $\gamma = 0$ のもとで, $\lambda = 0$ であれば RDA は Bayes2 次識別器となり, また $\lambda = 1$ であれば 2 クラス問題の RDA は線形識別器となる。

3.4 計算機実験

3.4.1 実験方法

画像特徴 1 からの 5 特徴と画像特徴 2 からの 14 特徴の計 19 特徴で記述された 49 サンプルを用いて誤識別率を推定した。本研究では、Holdout 法 [103], [104] を独立に 100 回繰り返した。Holdout 法は与えられたサンプル集合をランダムに訓練サンプルとテストサンプルとに分割し、訓練サンプルを用いて識別器を設計し、次いで訓練サンプルとは独立なテストサンプルを用いて識別性能を評価する方法である。Holdout 法のサンプルの分割は訓練サンプルとして肝硬変サンプル 15 と正常サンプル 15 の計 30 サンプル、テストサンプルとして肝硬変サンプル 13 と正常サンプル 6 の計 19 サンプルとした。Holdout 法を独立に 100 回繰り返し、誤識別率の平均値を求めた (図 3.2)。

肝硬変識別処理において、特徴選択法と識別器の候補の中から最適な組合せを実験により選定する。

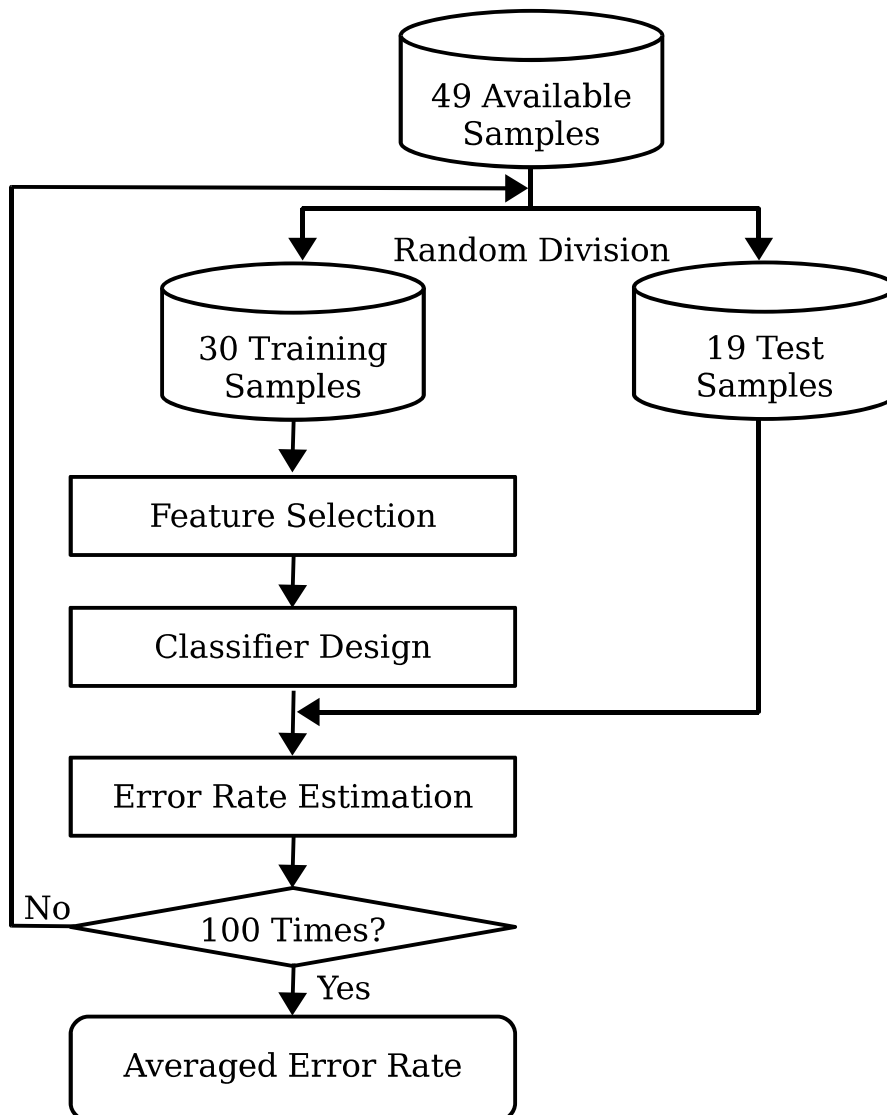


図 3.2: 肝硬変識別のフロー

3.4.2 特徴選択法と識別器の組合せによる識別性能の評価実験

本節では、画像特徴1からの5特徴と画像特徴2からの14特徴を合わせて19特徴に対し、特徴選択法と識別器の組合せによる肝硬変識別を行い、その識別性能により検討する。

特徴選択法の候補には、Fisher比に基づく選択法とSFS法を、識別器には、ユークリッド距離識別器、Fisher線形識別器、Bayes2次識別器に、RDA法を候補とし、それらの組合せを、誤識別率により比較する。特徴数を1から19に変え、それぞれの特徴数で特徴選択法と識別器のすべての組合せで誤識別率が最小となったグラフを図3.3に示す。




図 3.3: 特徴数と誤識別率との関係

実験結果から、特徴数が2のとき、特徴選択法にSFS法を、識別器にFisher線形識別器としたとき、誤識別率が最小の13.4%となった。以上から、SFS法により特徴選択法を行い、Fisher線形識別器を用いることが、識別性能の高精度化に有効であった。

次に、誤識別率が最小となったとき（2特徴）の感度と特異度を表3.1に示す。ここで、

感度および特異度は式 (3.22) および式 (3.23) により定義する.

$$\text{感度} = \frac{\text{肝硬変テストサンプルを肝硬変と識別したテストサンプル数}}{\text{肝硬変テストサンプル数}} \quad (3.22)$$

$$\text{特異度} = \frac{\text{正常テストサンプルを正常と識別したテストサンプル数}}{\text{正常テストサンプル数}} \quad (3.23)$$

表 3.1: 感度と特異度 (2 特徴)

		特徴選択			
		Fisher 比		SFS 法	
		感度 (%)	特異度 (%)	感度 (%)	特異度 (%)
識別器	ユークリッド距離	78.2	67.8	78.1	70.5
	Fisher 線形	86.9	71.5	90.5	78.2
	Bayes2 次	82.5	71.5	87.9	77.0
	RDA 法	82.3	69.8	88.2	76.0

特徴選択法を SFS 法とし, そして識別器を Fisher 線形識別器としたとき感度および特異度の両方が高いことから, 特徴選択法は SFS 法を, 識別器は Fisher 線形識別器の組合せを最適な組合せであることが分かる.

次に, SFS 法の特徴選択法で, Holdout 法 100 回の試行で上位に選択された特徴の中で, 特徴数が 2 のときの出現度 Top5 の特徴とそれぞれの出現回数を表 3.2 に示す.

表 3.2: 選択された特徴の出現頻度 Top5

順位	1 位	2 位	2 位	4 位	5 位
特徴	f_{10}	f_1	f_4	f_2	f_5
出現回数	96	25	25	22	18

SFS 法による特徴選択法で, 選択された特徴の上位は, 画像特徴 1 からの最大振幅 f_1 , 標準偏差 f_2 とフーリエ係数 f_4 と f_5 , 画像特徴 2 からの時刻 t と $t + \tau$ の修正相関係数のフー

リエ係数 f_{10} であった。

時間間隔 τ を固定した状態での時刻 t における画像の縦列の画素値と時刻 $t + \tau$ における縦列の画素値との相関からの特徴で、前述した出現度の上位が f_{10} であり、これは 4 次成分に相当する。この特徴 f_{10} は大動脈の膨張収縮を表す有効な特徴である。大動脈の膨張収縮は、心拍による血流が影響する。血流量は 1 心拍の間に変動する。変動波を形成する周波数成分の中で、肝硬変識別に有用な特徴としてとして 4 次成分が選択されたと考えらる。

また、実システムを構築するには、特定の特徴を用いて識別を行うため、これらを決めなくてはならない。そこで、全 49 サンプルを用い、特徴選択法は SFS 法を用いた。選択された上位 2 特徴を表 3.3 に示す。

表 3.3: 全 49 サンプルを用いて特徴選択により選択された 2 特徴

特徴	f_{10}, f_2
----	---------------

最後に, 各識別器の設計時間を表 3.4 に示す(CPU:AMD Athlon64X2 6400+(3.2GHz)).

なお, 計測した時間は Holdout 法 100 回試行の設計時間 (単位: 秒) である.

表 3.4: 各識別器の設計時間 (単位: 秒)

特徴数	ユークリッド距離	Fisher 線形	Bayes2 次	RDA 法
1	0.008	0.023	0.026	44.787
2	0.008	0.024	0.027	48.607
3	0.008	0.024	0.028	51.207
4	0.008	0.025	0.028	51.802
5	0.008	0.025	0.029	54.396
6	0.008	0.027	0.030	56.985
7	0.008	0.026	0.030	58.414
8	0.008	0.026	0.030	58.882
9	0.008	0.026	0.031	62.010
10	0.008	0.026	0.032	65.051
11	0.008	0.027	0.033	67.828
12	0.008	0.028	0.034	71.196
13	0.008	0.028	0.035	73.923
14	0.008	0.029	0.036	76.243
15	0.009	0.029		76.651
16	0.008			76.151
17	0.008			86.463
18	0.008			89.500
19	0.008			97.314

3.5 おわりに

第3章では、識別率の高精度化のために特徴選択法と識別器の最適な組合せを検討した。特徴選択法では Fisher 比と SFS 法を候補とし、識別器ではユークリッド距離識別器、Fisher 線形識別器、Bayes2 次識別器、RDA 法を候補とし、これらの組合せを比較するために計算機実験を行い、SFS 法による特徴選択法と Fisher 線形識別器の組合せが識別性能の観点から最も優れていることを明らかにした。

次章では、本研究の結論、今後の課題と展望について述べる。

第4章

結論

肝硬変の早期発見・早期治療の必要性が高まる中、肝硬変診断に広く用いられている超音波検査はその診断結果が医師の知識や経験に頼るところが多い。したがって、超音波画像を用いた客観的かつ定量的な手法が求められている。このような問題に対して、超音波画像を用いた肝硬変診断の高精度化について論じた。

本研究では、超音波画像を用いた肝硬変診断の高精度化のために、バイラテラルフィルタと重み付きテンプレート処理を用いた特徴抽出系の改善を提案し、計算機実験を通して、大動脈壁位置抽出と特徴抽出にバイラテラルフィルタが有効であること、大動脈壁位置抽出に重み付きテンプレート処理が有効であることを検討した。さらなる高精度化のため、特徴選択法と識別器の組合せについて検討した。以下に各章を要約し、本研究のまとめとする。

第2章では、Mモード超音波画像からの特徴抽出の改良について論じた。まず、超音波画像からの大動脈壁位置抽出の処理を述べた。大動脈壁位置抽出に、バイラテラルフィルタによる画質改善と重み付きテンプレート処理を適用した。計算機実験を通して、バイラテラルフィルタと重み付きテンプレート処理の有効性について検討した。バイラテラルフィルタの特長であるエッジを保存する平滑化が、超音波画像の画質改善に与える効果を調べた。次に、特徴抽出に対して、バイラテラルフィルタを適用した。Fisher比を用いた対のある有

意差検定を通して、バイラテラルフィルタの有用性が明らかになった。これらの実験結果より、バイラテラルフィルタが大動脈壁位置抽出と特徴抽出の両面で、また重み付きテンプレート処理が大動脈壁位置抽出に有効であることが示された。

第3章では、さらなる高精度化のため、特徴選択法と識別器の組合せに関する実験について述べた。特徴選択法については、Fisher比、SFS法を候補とし、識別器の候補には、ユークリッド距離識別器、Fisher線形識別器、Bayes2次識別器、RDA法の識別器を用い、誤識別率により識別性能の評価を行った。実験の結果、特徴選択法にSFS法、識別器にFisher線形識別器とした組合せが最も高い識別性能を持った。以上から、SFS法による特徴選択法、識別器にFisher線形識別器を用いることが有効と考える。

本研究に関連する今後の課題、また展望を述べ、本研究のむすびとする。

本研究では、特徴抽出にフーリエ係数を用いたが、ウェーブレット変換の適用が課題となる。ウェーブレット変換は、時間と周波数の両方を同時に解析する処理である[96]。フーリエ変換は時間領域の情報が失われるが、ウェーブレット変換では時間の情報も解析できる。そのため、識別に有効な特徴をウェーブレット変換により大動脈壁位置データから抽出する。

また、肝硬変識別の識別器としてサポートベクターマシンを用いることや、組合せ最適化問題を解くときに遺伝的アルゴリズムを用いて最適解を探索することも今後の課題として挙げられる。

さらに、肝硬変診断には超音波エラストグラフィも有効であるとされているが、本研究では研究成果を多くの医療期間で利用できるよう超音波画像を用いた。しかし、超音波エラストグラフィの有効性を考え、超音波画像と超音波エラストグラフィとの比較も今後の課題とする。

最後に、本手法を肝硬変の定量化にも応用できると考えられる。本研究の肝硬変識別では肝硬変か否かの二者択一しかできないが、患者が現在どのような状態であるのかを数値で表現されることも望まれている。これを肝硬変の定量化と呼ぶ。一般に識別面は正常サンプル

と肝硬変サンプルを識別するよう設計される。たとえば、ある一人の患者について、肝硬変発見時と治療後の検査結果が入力されたとき、治療後のサンプルは肝硬変発見時のサンプルに比べ識別面からの距離が大きくなっていると考えられる。このように、識別面とサンプルの距離によって肝硬変の程度を画像から可視化でき、この値によって患者の肝臓の健康状態を判断できると考えられる。この他、多次元パターン空間上のパターン分布を Fisher 線形識別器や Bayes2 次識別器を通した可視化や正規直交判別ベクトル法による可視化を適用することによって [103], 個々の患者の肝臓の健康状態を可視化することが可能になる。これは個別化医療の実現に関係することであり、今後重要となると考えられる。

謝辞

山口大学大学院医学系研究科応用分子生命科学系専攻教授 浜本義彦先生には、指導教員として本研究に関して終始御指導御鞭撻を頂いた。ここに深謝の意を表す。また、本論文の審査において、同大学院理工学研究科教授 大林正直先生，同研究科教授 多田村克己先生，同研究科教授 松藤信哉先生，同研究科教授 中村秀明先生，同研究科准教授 水上嘉樹先生，同研究科准教授 伊藤暁先生，同研究科准教授 山口真悟先生，同大学院医学系研究科准教授 藤田悠介先生には副査として御助言を頂くとともに本論文の細部にわたり御指導を頂いた。深謝の意を表す。さらに、宇部工業高等専門学校制御情報工学科教授 三谷芳弘先生には、研究遂行にあたり日頃より有益な御討論御助言を頂いた。ここに深謝の意を表す。

実験に用いた超音波画像を御提供いただいた山口大学医学部附属病院医療人育成センター准教授 瀬川誠先生，他医学部第一内科の関係諸氏に感謝の意を表す。

最後に、御協力頂きました山口大学工学部知能情報工学科の情報認識工学研究室の関係諸氏に心より御礼申し上げます。

参考文献

- [1] 井廻道夫, 熊田博光, 坪内博仁, 林紀夫, ”肝臓病学,” 朝倉書店, 2006.
- [2] 織田敏次, 御厨修一, 服部信, 岡博, ”肝炎 肝硬変 肝癌,” 金原出版, 1990.
- [3] 橋本悦子, ”肝線維化の臨床診断,” 医学と薬学, Vol. 56, No. 3, pp.334-339, 2006.
- [4] 孝田雅彦, ”診断とフォローアップ : 2. 肝線維化の進展度評価 : 組織診断から非侵襲的評価法へ,” 日本内科学会雑誌, Vol. 97, No. 1, pp.17-22, 2008.
- [5] 辰巳千栄, 工藤正俊, 上嶋一臣, 藤本研治, 加藤道夫, 外村明子, 三竹毅, ”C型慢性肝炎に対する非侵襲的肝線維化評価—Fibroscan と Elastography—,” 肝胆膵, Vol. 57, No. 5, pp.749-754, 2008.
- [6] 吉岡健太郎, 橋本千樹, 川部直人, 原田雅生, 西川徹, 市野直浩, 刑部恵介, ”Fibroscan(R)による線維化診断と発癌予測,” 肝胆膵, Vol. 65, No. 6, pp.1029-1034, 2012.
- [7] 椎名毅, ”Real-time elastography の工学的基礎,” 肝胆膵, Vol. 65, No. 2, pp.285-293, 2012.
- [8] 増崎亮太, 建石良介, 小俣政男, 杉岡陽介, 池田均, ”Transient Elastography を用いた肝線維化の評価,” 医科器械学, Vol. 76, No. 12, pp.883-887, 2006.
- [9] 椎名毅, ”Real-time elastography の工学的基礎,” 肝胆膵, Vol. 65, No. 2, pp.285-293, 2012.
- [10] J. Ophir, I. Céspedes, H. Ponnekanti, Y. Yazdi, and X. Li, ”Elastography: A Quantitative Method for Imaging the Elasticity of Biological Tissues.” Ultrason.

- Imaging, Vol. 13, No. 2, pp.111-134. 1991.
- [11] 矢田典久, "Real-time Tissue Elastography による肝線維化診断," 肝胆膵, Vol. 65, No. 6, pp.1043-1048, 2012.
- [12] 玄田拓哉, 小谷知弘, 佐藤俊輔, 成田諭隆, 菊池哲, 平野克治, 市田隆文, "線維化の診断-ファイブロスキャン," 肝胆膵, Vol. 57, No. 2, pp.233-239, 2008.
- [13] 建石良介, 小池和彦, "Transient Elastography(FibroScan(R))," 肝胆膵, Vol. 65, No. 2, pp.277-283, 2012.
- [14] 増崎亮太, 建石良介, 小俣政男, 杉岡陽介, 池田均, "Transient Elastography を用いた肝線維化の評価," 医科器械学, Vol. 76, No. 12, pp.883-887, 2006.
- [15] 川部直人, 橋本千樹, 吉岡健太郎, "非侵襲的肝硬度測定法," 現代医学, Vol. 56, No. 2, pp.289-295, 2008.
- [16] 増崎亮太, 吉田晴彦, 建石良介, 池田均, 小俣政男, 小池和彦, "慢性肝疾患診療における超音波エラストグラフィー「FibroScan」の有用性," Medical Technology, Vol. 40, No. 1, pp.77-82, 2012.
- [17] 辰巳千栄, 工藤正俊, 上嶋一臣, 藤本研治, 加藤道夫, 外村明子, 三竹毅, "C型慢性肝炎に対する非侵襲的肝線維化評価—Fibroscan と Elastography—," 肝胆膵, Vol. 57, No. 5, pp.749-754, 2008.
- [18] 矢田典久, 工藤正俊, "Real-time Tissue Elastography による非侵襲的肝線維化診断," 肝胆膵, Vol. 65, No. 2, pp.295-301, 2012.
- [19] 飯島尋子, "画像検査を用いた新しい線維化診断法," 医学のあゆみ, Vol. 240, No. 9, pp.733-738, 2012.
- [20] 吉岡健太郎, 橋本千樹, 川部直人, 原田雅生, 西川徹, 市野直浩, 刑部恵介, "Fibroscan(R) による線維化診断と発癌予測," 肝胆膵, Vol. 65, No. 6, pp.1029-1034, 2012.
- [21] 飯島尋子, "造影超音波診断," 肝臓, Vol. 47, No. 4, pp.173-180, 2006.
- [22] 阿部真久, 小川真広, 松本直樹, 中河原浩史, 廣井喜一, 森山光彦, "消化器系の画像診断

- の進歩,” 日大醫學雜誌, Vol. 68, No. 2, pp.116-120, 2009.
- [23] 高橋睦正, ”必修 放射線医学 (改訂第4),” 南江堂, 1999.
- [24] 千原国宏, ”超音波 (ME 教科書シリーズ),” コロナ社, 2001.
- [25] 三輪健, 二川俊二, 別府倫兄, 有山襄, 須山正文, ”超音波診断装置の進歩,” 外科治療, Vol. 83, No. 5, pp.523-528, 2000.
- [26] 日本超音波医学会, ”新超音波医学 (1),” 医学書院, 2000.
- [27] 木村雄治, ”画像診断装置学入門,” コロナ社, 2007.
- [28] 蜂屋順一, ”TEXT 放射線医学,” 南山堂, 1994.
- [29] 中島真人, 渡辺快, ”新しい超音波診断技術,” 南江堂, 1984.
- [30] 朱敏秀, ”超音波心臓診断法,” 新潟医福誌, Vol. 4, No. 1, pp.103-111, 2004.
- [31] 藤田広志, ”コンピュータ支援診断 (CAD) 研究 : 過去から未来へ (第58回総会学術大会宿題報告),” 日本放射線技術學會雜誌, Vol. 59, No. 11, pp.1327-1337, 2003.
- [32] R. P. Kruger, W. B. Thompson, and A. F. Turner, ”Computer diagnosis of pneumoconiosis,” IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-4, No. 1, pp.40-49, 1974.
- [33] J. R. Jagoe and K. A. Paton, ”Reading chest radiographs for pneumoconiosis by computer,” Br J Ind Med., Vol. 32, No. 4, pp.267-272, 1975.
- [34] L. V. Ackerman and E. E. Gose, ”Breast lesion classification by computer and zeroradiograph,” Cancer 30, pp.1025-1035, 1972.
- [35] W. Hand, J. L. Semmlow, L. V. Ackerman, and F. S. Alcorn, ”Computer screening of xeromammograms : A technique for defining suspicious areas of the breast,” Computer and Biomed Research 12, No. 5, pp.445-460, 1979.
- [36] 土井邦雄, ”CAD 開発における国際的歴史と実用化の世界情勢,” インナービジョン, Vol. 19, No. 12, pp.1-4, 2004.
- [37] 土井邦雄, ”コンピュータによる医用画像の定量的分析 : 自動診断とコンピュータ支援

- 診断の共通点と相違点,” 医用画像情報学会雑誌, Vol. 21, No. 1, pp.8-10, 2004.
- [38] 長谷川玲, ”世界で初めて商品化されたマンモグラフィ用 CAD : ImageChecker,” 日本放射線技術学会雑誌, Vol. 56, No. 3, pp.355-358, 2000.
- [39] 土井邦雄, ”世界、そして、日本の CAD の現状と今後の動向,” インナービジョン, Vol. 14, No. 10, pp.2-4, 1999.
- [40] 藤田広志, ”コンピュータ支援診断 (CAD) の現状概観 (<特集>診断支援技術論文特集号),” 日本放射線技術学会雑誌, Vol. 63, No. 12, pp.1389-1395, 2007.
- [41] 小畑秀文, ”医用画像の計算機支援診断技術の現状と動向,” 医用画像情報学会雑誌, Vol. 21, No. 1, pp.11-18, 2004.
- [42] 鳥脇純一郎, ”医用画像の診断支援 (CAD) における画像処理技術の展開,” 電子情報通信学会技術研究報告. MI, 医用画像, Vol. 102, No. 56, pp.27-34, 2002.
- [43] 鳥脇純一郎, 目加田慶人, ”人体内部の計測と診断 (<特集>人をみる),” 情報処理学会論文誌. コンピュータビジョンとイメージメディア, Vol. 47, No. 9, pp.32-45, 2006.
- [44] D. Mitrea, P. Mitrea, S. Nedevschi, R. Badea, M. Lupor, M. Socaciu, A. Golea, C. Hagi, and L. Ciobanu, ”Abdominal Tumor Characterization and Recognition Using Superior-Order Cooccurrence Matrices, Based on Ultrasound Images,” Computational and Mathematical Methods in Medicine, Vol. 2012, Article ID 348135, 2012.
- [45] S. Poonguzhali and G. Ravindran, ”Automatic Classification of Focal Lesions in Ultrasound Liver Images Using Combined Texture Features,” Information Technology Journal, Vol. 7, No. 1, pp.205-209, 2008.
- [46] D. Mittal, V. Kumar, S. C. Saxena, N. Khandelwal, and N. Kalra, ”Neural Network based Focal Liver Lesion Diagnosis Using Ultrasound Images,” Computerized Medical Imaging and Graphics, Vol. 35, No. 4, pp.315-323, 2011.
- [47] C. -C. Wu, W. -L. Lee, Y. -C. Chen, C. -H. Lai, and K. -S. Hsieh, ”Ultrasonic liver

- tissue characterization by feature fusion,” *Expert Systems with Applications*, Vol. 39, No. 10, pp.9389-9397, 2012.
- [48] F. Minhas, D. Sabih, and M. Hussain, ”Automated Classification of Liver Disorders using Ultrasound Images,” *Journal of Medical Systems*, Vol. 36, No. 5, pp.3163-3172, 2012.
- [49] U. R. Acharya, S. V. Sree, R. Ribeiro, G. Krishnamurthi, R. T. Marinho, J. Sanches, and J. S. Suri, ”Data mining framework for fatty liver disease classification in ultrasound: A hybrid feature extraction paradigm,” *Medical Physics*, Vol. 39, No. 7, pp.4255-4264, 2012.
- [50] N. Sriraam, J. Roopa, M. Saranya, and M. Dhanalakshmi, ”Performance Evaluation of Computer Aided Diagnostic Tool (CAD) for Detection of Ultrasonic Based Liver Disease,” *Journal of Medical Systems*, Vol. 33, No. 4, pp.267-274, 2009.
- [51] G. -T. Cao, P. -F. Shi, and B. Hu, ”Liver fibrosis identification based on ultrasound images captured under varied imaging protocols,” *J Zhejiang Univ Sci B.* , Vol. 6, No. 11, pp.1107-1114, 2005.
- [52] H. Toyoda, T. Kumada, N. Kamiyama, K. Shiraki, K. Takase, T. Yamaguchi, and H. Hachiya, ”B-Mode Ultrasound With Algorithm Based on Statistical Analysis of Signals: Evaluation of Liver Fibrosis in Patients With Chronic Hepatitis C,” *American Journal of Roentgenology*, Vol. 193, No. 4, pp.1037-1043, 2009.
- [53] 山口匡, 蜂屋弘之, ”硬変肝画像中の組織散乱体情報による病変進行度評価の検討,” *電子情報通信学会技術研究報告. US, 超音波*, Vol. 97, No. 135, pp.1-8, 1997.
- [54] 山口匡, 蜂屋弘之, ”硬変肝組織中の超音波散乱体分布情報の検討,” *電子情報通信学会技術研究報告. US, 超音波*, Vol. 98, No. 369, pp.7-14, 1998.
- [55] 蜂屋弘之, 小山田裕之, ”超音波断層画像の散乱体分布情報による肝硬変評価法,” *電子情報通信学会技術研究報告. US, 超音波*, Vol. 95, No. 132, pp.1-8, 1995.

- [56] 山口匡, 蜂屋弘之, ”超音波断層画像を用いた硬変肝組織散乱体分布情報の検討 (超音波医用論文 < 特集 >),” 電子情報通信学会論文誌. A, 基礎・境界, Vol. 84, No. 12, pp.1475-1483, 2001.
- [57] 蜂屋弘之, 原尚志, 杉本照和, 平城浩一, ”肝硬変組織構造と B モード画像の関係の検討,” 電子情報通信学会技術研究報告. US, 超音波, Vol. 99, No. 349, pp.27-34, 1999.
- [58] 安原航, 五十嵐悠, 山口匡, 蜂屋弘之, ”肝組織変化シミュレーション手法により生成した超音波画像を用いた肝病変定量指標の検討,” 電子情報通信学会技術研究報告. US, 超音波, Vol. 110, No. 234, pp.23-28, 2010.
- [59] G. Zhou, Y. Wang, W. Wang, Y. Sun, and Y. Chen, ”Decision of cirrhosis using liver’s ultrasonic images,” Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference Shanghai, pp.3351-3354, 2005.
- [60] S. I. Rabben, A. H. Torp, A. Støylen, S. Slørdahl, K. Bjørnstad, B. O. Haugen, and B. Angelsen, ”Semiautomatic contour detection in ultrasound M-mode images,” *Ultrasound in Med. & Biol.*, Vol. 26, pp.287-296, 2000.
- [61] 辻上昌範, 竹村淳, 伊東正安, 濱本和彦, ”超音波 3 次元データによる組織の領域分割,” 電子情報通信学会技術研究報告. US, 超音波, Vol. 94, No. 155, pp.17-24, 1994.
- [62] マルエンノント ニポン, 田部井誠, 上田光宏, ”超音波 B モード像の輝度制御について (< 特集 > 医用超音波),” 電子情報通信学会技術研究報告. US, 超音波, Vol. 96, No. 320, pp.25-32, 1996.
- [63] 呉炯錫, 西村敏博, ”ファジィ分類を用いた能動的ニューラルネットワークによる超音波医用画像のスペックルノイズ除去 (高精細画像の処理・表示及び一般),” 電子情報通信学会技術研究報告. IE, 画像工学, Vol. 107, No. 358, pp.79-82, 2007.
- [64] 大城政邦, 椿井正義, 玉木康博, 西村敏博, ”輝度勾配ベクトル場による超音波画像からの領域抽出 (医・工学連携における新しい計測・解析技術開発への期待),” 電子情報通信学会技術研究報告. MBE, ME とバイオサイバネティクス, Vol. 106, No. 506,

- pp.33-36, 2007.
- [65] 大城政邦, 椿井正義, 西村敏博, ”輝度勾配ベクトル場を用いた超音波画像の特徴抽出 (高精細画像の処理・表示, 及び一般),” 電子情報通信学会技術研究報告. IE, 画像工学, Vol. 106, No. 397, pp.15-18, 2006.
- [66] 春田航, 山田晃, 伊東正安, ”内部エコーによる診断情報の抽出 (アコースティックイメージング・一般),” 電子情報通信学会技術研究報告. US, 超音波, Vol. 104, No. 350, pp.11-14, 2004.
- [67] M. Ali, D. Magee, and U. Dasgupta, ”Signal Processing Overview of Ultrasound Systems for Medical Imaging,” Texas Instruments White Paper (SPRAB12-November 2008), November, pp.1-27, 2008.
- [68] S. Balocco, C. Gatta, O. Pujol, J. Mauri, and P. Radeva, ”SRBF: Speckle Reducing Bilateral Filtering,” *Ultrasound in Medicine & Biology*, Vol. 36, No. 8, pp.1353-1363, 2010.
- [69] F. M. Cardoso, M. M. S. Matsumoto, and S. S. Furuie, ”Edge-Preserving Speckle Texture Removal by Interference-Based Speckle Filtering Followed by Anisotropic Diffusion,” *Ultrasound in Medicine & Biology*, Vol. 38, No. 8, pp.1414-1428, 2012.
- [70] J. Tang, S. Guo, Q. Sun, Y. Deng, and D. Zhou, ”Speckle reducing bilateral filter for cattle follicle segmentation,” *BMC Genomics*, Vol. 11, Suppl 2, S9, 2010.
- [71] J. Dehmeshki, X. Ye, X. Y. Lin, M. Valdivieso, and H. Amin, ”Automated detection of lung nodules in CT images using shape-based genetic algorithm,” *Computerized Medical Imaging and Graphics*, Vol. 31, No. 6, pp.408-417, 2007.
- [72] D. T. Nguyen, P. Ogunbona, and W. Li, ”Human Detection Based on Weighted Template Matching,” *Multimedia and Expo, 2009. ICME 2009. IEEE International Conference*, pp.634-637, 2009.
- [73] J. L. Turney, T. N. Mudge, and R. A. Volz, ”Recognizing Partially Occluded Parts,”

- Pattern Analysis and Machine Intelligence, IEEE Transactions, Vol. PAMI-7, No. 4, pp.410-421, 2009.
- [74] O. W. Layton, E. Mingolla, and N. A. Browning, "A motion pooling model of visually guided navigation explains human behavior in the presence of independently moving objects," *Journal of Vision*, Vol. 12, No. 1, article 20, pp.1-19, 2012.
- [75] R. Marfil, L. Molina-Tanco, J. A. Rodriguez, and F. Sandoval, "Real-time object tracking using bounded irregular pyramids," *Pattern Recognition Letters*, Vol. 28, No. 9, pp.985-1001, 2007.
- [76] R. N. Strickland, T. Draelos, and Z. Mao, "Edge detection in machine vision using a simple L1 norm template matching algorithm," *Pattern Recognition*, Vol. 23, No. 5, pp.411-421, 1990.
- [77] 山川烈, 内野英治, 森下雅子, "セファロ画像における重み付き類似性測度を用いた計測点の抽出," *Biomedical fuzzy and human sciences : the official journal of the Biomedical Fuzzy Systems Association*, Vol. 2, No. 1, pp.93-101, 1996.
- [78] 加野亜紀子, 池添潤平, 安原美文, 藤田広志, "胸部集団検診 X 線画像を対象とした経時差分処理における新しい自動重ね合せ法 (次世代医用画像技術論文特集)," *電子情報通信学会論文誌. D-II, 情報・システム, II-パターン処理*, Vol. 83, No. 1, pp.263-270, 2000.
- [79] 田中邦彦, 平井有三, "非類似度関数による非キャリブレーション型ステレオアルゴリズム," *電子情報通信学会技術研究報告. NC, ニューロコンピューティング*, Vol. 100, No. 687, pp.95-101, 2001.
- [80] G. -H. Li, M. F. Jackson, and J. F. MacDonald, "Weighted least squares fitting with multiple templates for detection of small spontaneous signals," *Journal of Neuroscience Methods*, Vol. 164, No. 1, pp.139-148, 2007.
- [81] D. Lee and K. N. Plataniotis, "Lossless compression of HDR color filter array image

- for the digital camera pipeline,” *Signal Processing: Image Communication*, Vol. 27, No. 6, pp.637-649, 2012.
- [82] 岡遼太郎, 長井隆行, ”F-015 分散重み付き相関係数を用いた協調フィルタリング手法 (F 分野:人工知能・ゲーム),” *情報科学技術フォーラム一般講演論文集*, Vol. 6, No. 2, pp.371-372, 2007.
- [83] M. A. Lubinski, S. Y. Emelianov, and M. O’Donnell, ”Speckle Tracking Methods for Ultrasonic Elasticity Imaging Using Short-Time Correlation,” *IEEE Trans. Ultrason., Ferroelect., Freq. Contr.*, Vol. 46, No. 1, pp.82-96, 1999.
- [84] 高木幹雄, 下田陽久, ”新編 画像解析ハンドブック,” 東京大学出版会, 2004.
- [85] X. -Q. Wu, K. -Q. Wang, and D. Zhang, ”Wavelet Energy Feature Extraction and Matching for Palmprint Recognition,” *Journal of Computer Science and Technology*, Vol. 20, No. 3, pp.411-418, 2005.
- [86] D. -F. Li, Z. -G. Huang, and G. -H. Chen, ”A systematic approach to heterogeneous multiattribute group decision making,” *Computers & Industrial Engineering*, Vol. 59, No. 4, pp.561-572, 2010.
- [87] D. -F. Li, ”A fuzzy closeness approach to fuzzy multi-attribute decision making,” *Fuzzy Optimization and Decision Making*, Vol. 6, No. 3, pp.237-254, 2007.
- [88] 西田昌史, 有木康雄, ”ガウス分布から導出される部分空間法による話者照合法の検討,” *電子情報通信学会技術研究報告. SP, 音声*, Vol. 99, No. 120, pp.9-16, 1999.
- [89] 加藤寧, 安倍正人, 根元義章, ”改良型マハラノビス距離を用いた高精度な手書き文字認識,” *電子情報通信学会論文誌. D-II, 情報・システム, II-情報処理*, Vol. 79, No. 1, pp.45-52, 1996.
- [90] D. Yeung, D. Wang, W. Ng, E. Tsang, and X. Wang, ”Structured large margin machines: sensitive to data distributions,” *Machine Learning*, Vol. 68, No. 2, pp.171-200, 2007.

- [91] E. Krusińska, "A valuation of state of object based on weighted Mahalanobis distance," *Pattern Recognition*, Vol. 20, No. 4, pp.413-418, 1987.
- [92] E. Krusińska and J. Liebhart, "Objective evaluation of degree of illness with the weighted Mahalanobis distance. A study for patients suffering from chronic obstructive lung disease," *Computers in Biology and Medicine*, Vol. 17, No. 5, pp.321-329, 1987.
- [93] C. Tomasi and R. Manduchi, "Bilateral filtering for gray and color images," *Proceedings of the 1998 IEEE International Conference on Computer Vision*, Bombay, India, 1998.
- [94] デジタル画像処理編集委員会（監修），"デジタル画像処理，" 財団法人画像情報教育振興委員会（CG-ARTS 協会），2004.
- [95] 画像処理ハンドブック編集委員会（編集），"画像処理ハンドブック，" 昭晃堂，1987.
- [96] 田村秀行，"コンピュータ画像処理，" オーム社，2002.
- [97] I. A. Hein and W. D. O'Brien, "Current time-domain methods for assessing tissue motion by analysis from reflected ultrasound echoes-A review," *IEEE Transactions on Ultrasonics Ferroelectrics, and Frequency Control*, Vol. 40, No. 2, pp.84-102, 1993.
- [98] R. S. Adler, J. M. Rubin, P. H. Bland, and P. L. Carson, "Quantitative tissue motion analysis of digitized M-mode images: gestational differences of fetal lung," *Ultrasound Med & Biol.*, Vol. 16, No. 6, pp.561-569, 1990.
- [99] M. Tristram, D. C. Barbosa, D. O. Cosgrove, J. C. Bamber, and C. R. Hill, "Application of Fourier analysis to clinical study of patterns of tissue movement," *Ultrasound Med & Biol.*, Vol. 14, No. 8, pp.695-707, 1988.
- [100] S. Hu, E. A. Hoffman, and J. M. Reinhardt, "Automatic lung segmentation for accurate quantitation of volumetric X-Ray CT images," *IEEE Trans. on Medical*

- Imaging, Vol. 20, pp.490-498, 2001.
- [101] 岡田泰榮, “統計,” 共立出版, 1966.
- [102] 北川敏男, 稲葉三男, “基礎数学統計学通論,” 共立出版, 1960.
- [103] 浜本義彦, “統計のパターン認識入門,” 森北出版, 2009.
- [104] K. Fukunaga, “Introduction to Statistical Pattern Recognition,” Second Edition, Academic Press, 1990.
- [105] R. A. Fisher, “The Use of Multiple Measurements in Taxonomic Problems,” *Annals of Eugenics*, Vol. 7, No. 2, pp.179-188, 1936.
- [106] J. H. Friedman, “Regularized Discriminant Analysis,” *Journal of the American Statistical Association*, Vol. 84, No. 405, pp.165-175, 1989.
- [107] 辻本文雄, 松原馨, 井田正博, “腹部超音波テキスト～上・下腹部～ 改訂第三版 (Atlas Series 超音波編),” ベクトル・コア, 2002.
- [108] 河西千広, “超音波診断装置,” *インナービジョン*, Vol. 6, No. 7, pp.81-84, 1991.

付録 A

M モード画像の画像センシング

プローブを図 A.1 の実線のように置くことで，腹部の断面を捉えることができる。




図 A.1: 肝の見え方 (文献 [107]p.7 の図を基に作成)

超音波は，均一な媒体の中では一定の周波数で伝播するが，音響的な性質（音響インピーダンス）の異なる 2 つの媒体の境界面では一部のエネルギーが反射し，一部は透過しさらに奥へと進んでいく（図 A.2）。




図 A.2: 超音波の反射と透過（文献 [108] の図 1 を基に作成）

超音波の反射の程度は，境界面を構成する組織の音響インピーダンスの差によって決まる（表 A.1）．音響インピーダンス Z は，組織の密度 ρ と音速 c との積

$$Z = \rho \cdot c \tag{A.1}$$

で表され，境界における差が大きいほど大きな反射を起こす（図 A.3）．

超音波が異なる組織の境界面に垂直に当たると反射率 R_Z は

$$R_Z = \frac{Z_2 - Z_1}{Z_1 + Z_2} \tag{A.2}$$

で表される．反射した信号をプローブで受信し，この受信した信号を輝度変調して輝度の強度に変換した後，時間軸上に一定速度で走査したものが M モード法である．M モード画像を図 A.4 に示す．図のように，組織からの超音波の反射が強ければ M モード画像上では明

表 A.1: 組織の音響インピーダンス

物質	音響インピーダンス ($g/cm^2 \cdot sec$)
水	1.48 ~ 1.51
脂肪	1.38 ~ 1.40
肝臓	1.65
筋肉	1.68 ~ 1.70
血液	1.60 ~ 1.61
骨	6.00 ~ 7.80

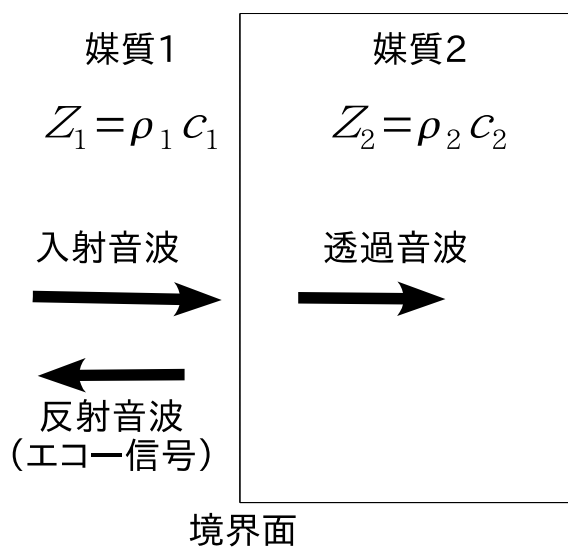


図 A.3: 超音波の反射 (文献 [23] の図 III - 99 を基に作成)

るく、弱ければ暗く表示される。

この M モード画像は、臓器の位置の時間的变化（プローブに近づいたり、遠ざかったりする動き）を測定し画像化したものであり、臓器の動きを観察することに適している。これは B モード画像にはない大きな特長である。肝硬化が進行すると、肝臓の硬さが硬くなる。肝硬化の進行度が腹部大動脈の膨張収縮の度合いに影響する。例えば、肝硬変の肝臓は正常な肝臓に比べ、腹部大動脈の膨張収縮の度合いが小さくなる。M モード画像はその腹部大動脈の膨張収縮の度合いによる弾性的変化を表す時系列データを読み取ることに適しており、




図 A.4: Mモード画像

Mモード画像単独の解析から肝硬変の定量化や肝硬変の診断が期待できる。

付録 B

追加実験

B.1 実験目的

前述の実験では特徴抽出に用いる大動脈壁位置データは、大動脈壁位置抽出に失敗した場合は、人間により抽出した大動脈壁位置データを用いていた。本付録では二つの追加実験結果を書き加える。まず追加実験 1 では、大動脈壁位置抽出に失敗したサンプルを除外、すなわち抽出に成功したサンプルのみを用いて肝硬変識別の誤識別率を推定する。追加実験 2 では、大動脈壁位置抽出に失敗した場合も、失敗したデータをそのまま用いて肝硬変識別の誤識別率を推定する。

B.2 実験方法

本実験の基本データは以下のとおりである。

- 画像データ：計 49 （肝硬変：28，正常：21）
- 2 クラス問題（肝硬変 or 正常）
- 誤識別率推定法：Holdout 法 （試行回数 100 回）
- 特徴選択：SFS 法

- 識別器：Fisher 線形識別器

追加実験 1 と 2 において、「前処理なしの画像に従来のテンプレート処理（従来手法）」と「バイラテラルフィルタによる前処理を行った画像に重み付きテンプレート処理（提案手法）」を比較評価する。

追加実験 1

大動脈壁位置抽出に失敗したサンプルは肝硬変識別の推定からは除外，すなわち位置抽出に成功したサンプルのみを用いて肝硬変識別を行い，誤識別率を推定する。

- 使用サンプル数：計 40 （肝硬変：21，正常：19）
- 分割数：訓練サンプル（肝硬変：12，正常：12），テストサンプル（肝硬変：9，正常：7）

追加実験 2

大動脈壁位置抽出に失敗した場合はそのまま失敗した大動脈壁位置データを用いて肝硬変識別を行い，誤識別率を推定する。

- 使用サンプル数：計 49 （肝硬変：28，正常：21）
- 分割数：訓練サンプル（肝硬変：15，正常：15），テストサンプル（肝硬変：13，正常：6）

B.3 実験結果

特徴選択を 2 特徴としたときの誤識別率（%）を表 B.1 に示す。なお，参考のため，本体での結果は 13.4% である。

※本体での提案手法の実験方法

大動脈壁位置抽出に失敗した場合は人間により抽出した大動脈壁位置データに差し替

表 B.1: 誤識別率 (%) による比較 (2 特徴)

追加実験 1		追加実験 2	
提案手法	従来手法	提案手法	従来手法
15.6	36.2	14.2	41.5

えて肝硬変識別を行い，誤識別率を推定する．

- 使用サンプル数：計 49 （肝硬変：28，正常：21）
- 分割数：訓練サンプル（肝硬変：15，正常：15），テストサンプル（肝硬変：13，正常：6）

以上から，追加実験 1 と比較して追加実験 2 の誤識別率が小さくなっている．また，本体での提案手法は，実験 2 よりもさらに誤識別率が小さくなっている．参考のため，2 特徴以外の場合の結果を表 B.2 に示す．特徴数に関係なく提案手法が優れていることが分かる．

表 B.2: 特徴数を変えた各実験の誤識別率 (%)

特徴数	追加実験 1		追加実験 2	
	提案手法	従来手法	提案手法	従来手法
1	25.3	38.9	17.0	40.5
2	15.6	36.2	14.2	41.5
3	17.3	32.4	16.0	39.7
4	18.1	30.8	17.5	35.9
5	20.1	28.3	18.6	33.3
6	20.4	27.3	19.4	32.7
7	20.5	25.3	20.6	31.6
8	21.3	25.5	21.1	29.9
9	23.7	26.7	21.8	30.7
10	24.4	26.8	22.4	30.8
11	25.8	27.6	23.4	30.3
12	27.2	27.8	24.7	30.8
13			25.1	30.7
14			26.4	31.2
15			27.9	32.0