

画像のパターン解析とその応用

山 口 雅 浩

Image Pattern Analysis and Its Applications

Masahiro YAMAGUCHI

This paper presents pattern analysis techniques and their applications to medical images. After the concept of digital processing systems for supporting image diagnosis is introduced, the methods for multidimensional data analysis, which are quite important in computer-aided image diagnosis, are described. It is also mentioned that part of such analysis methods is based on linear pattern matching techniques such as matched filtering, developed in optical information processing fields. The applications of pattern analysis methods are shown; the analysis of X-ray chest radiographs of pneumoconiosis patients and the microscopic images for pathological diagnosis. Finally, the future aspects in pattern analysis technology for medical image diagnosis are discussed.

Key words: image analysis, medical imaging, computer-aided diagnosis, data clustering, multidimensional image processing, optical information processing

近年、医用画像検査機器や電子カルテに代表される医療情報の電子化が進展するとともに、電子化された情報を用いた遠隔医療や診断支援などのシステムが実現され、今後情報化により医療が大きく変わるものと予想される。特に、データ解析に基づき医師の診断をコンピューターにより支援する技術 (CAD: computer-aided diagnosis) は、実用化されて診断の質の向上に寄与しつつある。

画像解析によって病変部の検出や病変の悪性度の鑑別を行うシステムは、パターン認識の技術を基本としている。従来、エッジ抽出などの前処理の後、二値化してから図形処理の手法が適用される場合が多かった。例えば、病変部や部位ごとの境界線の追跡、血管などのパターンを細線化し形状を解析する方法などが適用されている。一方、光情報処理の分野では歴史的に光学的相関演算やフィルタリングによるパターン処理技術が研究してきた。現在はデジタル処理機器の性能が向上し、光演算を用いなくても大容量のパターン処理が可能になっているが、同様の原理に基づくパターン処理技術は広く利用されている。CAD シス

テムにおいても画素値の二次元分布に対するパターン認識と図形処理を組み合わせて処理を行っている。例えば、テンプレートマッチングによる病変部の検出や、画像からの特徴抽出、多次元の特徴空間上での分類や認識などの方法が用いられる。これらは、相関演算やフィルタリングなどの線形パターン処理の発展形であり、光情報処理分野におけるシステム解析やフィルター設計などの概念を適用することが可能である。

コンピューターによる画像診断システムを実現するには、画像や検査結果などを含む患者情報のデータベースを解析し、診断に有用な特徴量の発見、実例に基づくアルゴリズムの構築、コンピューターによる診断結果の有効性評価などを行うことが必要である。このため、大量の症例データをもとにパターン認識のアルゴリズムやフィルターを構築する技術を適用することが求められる。

本稿では、こういったコンピューター画像診断システムの考え方および実例を紹介するとともに、そのために必要とされるパターン認識技術について、多次元空間での解析

技術を中心に紹介する。また、相関演算などの線形フィルタリング技術との関係を述べ、光情報処理技術の考え方が適用できることを示す。

1. 医用画像診断支援技術

1.1 診断支援システムの考え方

現在の制度上、診断結果に対する責任は医師にある。いかに性能のよい自動診断システムが実現されても、コンピューター機器やソフトウェア（またはそのベンダー）がすべての責任を負うことはできないので、現状ではコンピューターによる診断システムが単独で医療行為に使用されることはない。そこで、コンピューター診断システムは医師の診断を支援するものと位置づけられている。

画像診断システムでは、セカンドオピニオンとしての利用が考えられている場合が多い。検診などにおいては、診断結果の信頼性を高めるために、複数の診断医が独立に読影し、その結果を照合して最終的な診断を確定することが推奨されている（二重読影）。しかし、実際には迅速性、人員配置やコストなどの点で複数の診断医によって独立に読影することが困難な場合も多い。そこで、コンピューターによる診断がセカンドオピニオンとして利用される。米国では、このようなシステムがマンモグラフィー（乳房X線撮影）による乳癌の検診に応用されている¹⁾。このシステムは、画像解析結果に基づいて、乳癌病変の候補領域を自動的に検出する。診断医は、まずこのシステムを用いずにスクリーニングを行った後、本システムにより検出された候補領域を確認する。システムが正常部を誤って病変部としたり（偽陽性）、異常陰影を見落としたり（偽陰性）する可能性もあるので、最終的な確認は診断医が行う。このシステムでは、診断医の読影にフィルムを用いるため、自動検出システムがシャウカステン（X線フィルム観察装置）と一体化されており、上述の診断プロトコルに合わせたシステム構成となっている。

画像を解析してコンピューターによる画像診断支援を行う対象は、基本的に以下のように分類できる。

- (1) 画像中に病変部が存在する場合に、これを検出する
- (2) 病変の状態や種類（悪性・良性の別、進行度など）を判定（鑑別診断）する
- (3) 医師の診断に参考となる数値情報を提供する

(1) は、検診時において画像を用いたスクリーニングを行う場合などに必要とされる。例えば、最近研究が進んでいる肺癌検診用の三次元CT（computed tomography）システム²⁾や、前述のマンモグラフィーによる乳癌検査などがこれにあたる。(2) は、病変が疑われた際に精密検査を

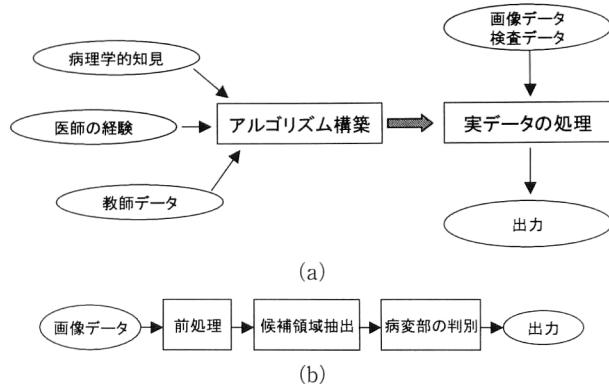


図1 コンピューター画像診断システムの考え方。(a) アルゴリズムの構築と実データへの適用、(b) 画像解析処理の流れ。

行う場合や、治療方針を決めるための検査、治療後の経過観察などに用いられる。(3) は、画像から定量的な数値などを計測し、これを医師に提供するもので、例えば心疾患や血管疾患のCT検査などにおいて、心臓の体積や血管の断面積を算出する技術などが開発されている。

1.2 データ処理手法の構築

画像から病変部の検出や病変の状態・種類の判別などをを行うアルゴリズムを構築する段階では、既知の病理学的もしくは解剖学的知見や医師の経験に基づくコメントなどをもとに、病変部と正常部の違いや悪性度などの関係をモデル化する。図1(a)に示すように、その結果得られたアルゴリズムを実際のデータに適用する。

例えば、X線CTにより得られる画像の画素値(CT値とよばれる)は、X線吸収係数に対応する物理量であるため、骨、脂肪、筋肉等の組織や癌組織のCT値は特定の範囲の値となる。これは画像処理を行うにあたって非常に有用な知識である。また、マンモグラフィーにおいて早期の乳癌病変の存在を示す微小石灰化は、X線の吸収率が周囲と比較してきわめて高いので、マンモグラフィーの画像上で高い画素値をもつ点として現れる。また、病変の形状や、正常な構造との見分け方などの知識をもとにアルゴリズムを構築している。

さらに、対象とする病変について集められた症例を教師データとしてアルゴリズムを構築することも有効である。この場合、教師データとして用いる症例には、画像データとともに信頼性の高い確定診断結果が含まれている必要がある。すなわち他の検査方法による精密検査や、生検によって採取した病変部の細胞診などによる確定診断結果である。明らかな病変の場合には診断結果に関する問題は少ないが、高精度な診断システムを実現するには、診断がある程度難しい教師データを用いるべきであり、教師データの選択には十分に注意を払う必要がある。

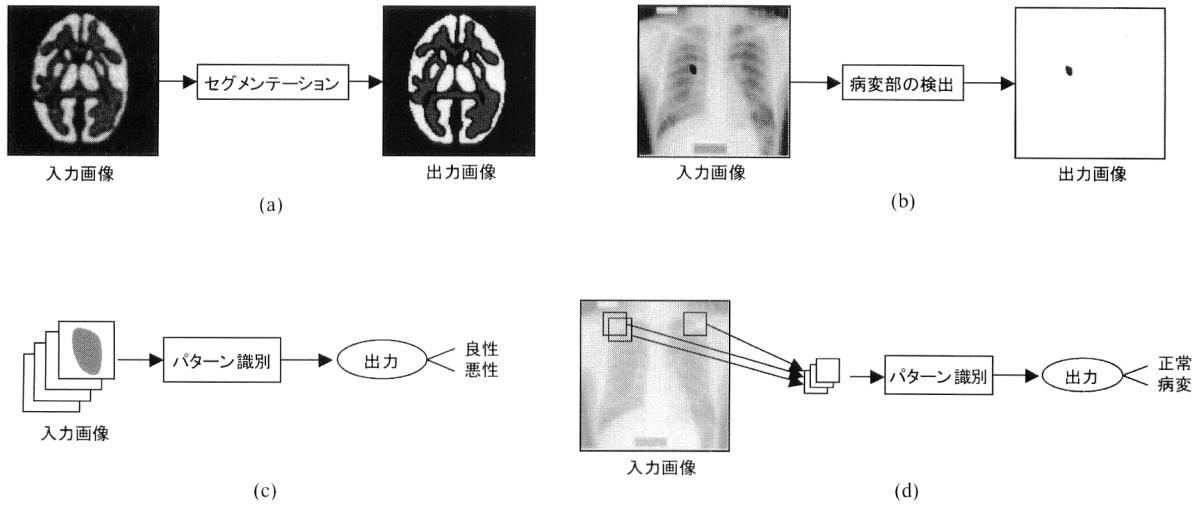


図2 パターン処理の適用類型。(a) 画像のセグメンテーション, (b) 画像中からの病変部の検出, (c) 画像の分類（良悪性などの鑑別）, (d) 画像から小領域を抽出して (c) と同様の処理を行うことで, (b) の病変部の検出を行うことも可能。

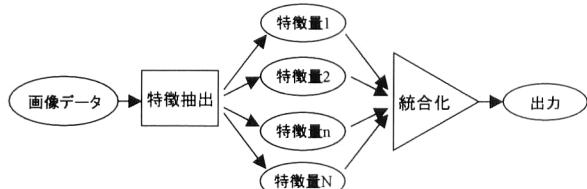


図3 画像からの特徴抽出に基づくパターン分類の流れ。

1.3 処理の流れ

ここでは1章1節に述べたコンピューター画像診断システムのうち, (1) の病変部検出を行う場合を例にとって処理の流れを説明する²⁾。図1(b) に一般的な病変部検出システムにおける処理の流れを示す。まず、画像に対して前処理を行った後、病変の候補となる領域をフィルタリングなどにより抽出する。次に、抽出された領域に対して、本当に病変部かどうかを精査するために判別処理を行い、病変部と疑われる陰影の位置などを出力する。

まず、前処理のステップでは、X線量や検査機器の特性の補正やノイズ除去、対象となる臓器の抽出（例えば肺癌検査においては肺野領域の抽出など）を行う（図2(a)）。X線CTの場合にはCT値を閾値処理することによって領域抽出を行える場合も多いが、組織構造などの画像内のテクスチャーを用いた領域抽出が必要な場合もある。病変候補検出のステップでは、画像の画素値や形状の特徴を用いて病変部と疑われる領域を探索する。多くの場合、図2(b) に示すような一種のテンプレートマッチングの処理を行う。病変部判別のステップでは、上記のようにして抽出された領域の画像を入力として、図2(c) に示すように、より詳細に病変部の特徴を数値化することによって判別を行う。

1章1節に述べた(2)のように、システムを鑑別診断に用いる場合には、パターン解析によって進行度などに関する数値を出力するか、直接良悪性の判別結果を出力する^{3,4)}。この場合、図2(c) に示す処理を行うことになる。

図2(a) や (b) の処理は、図2(d) に示すように、画像の各点を中心として小領域の画像を切り出し、切り出された画像（サブ画像）に対してパターン解析を行って出力を得るものといえる。したがって、基本的には図2(c) の処理と同様の技術に基づく。

図2(c) のような処理を行う方法としては、以下の2つの方法が考えられる。

- ・画像を多次元空間上でのベクトルとして扱い、多次元空間上での分布に基づいて判別を行う
 - ・画像内から抽出した特徴量に基づいて判別する
- 前者の方法の詳細は2章に述べる。後者の方法（図3）では、まず、画像から各種の特徴量を抽出し数値化する。次に数値化されたいくつかの特徴量を統合化し、病変か正常かを表す数値などを出力する。そして抽出された特徴量と診断結果との間を関係付ける。基本的には、 L 種類の特徴量を用いる場合には、 L 次元空間上の各点と診断結果の関係を得ることができればよい。したがって、第2章に述べるような多次元空間上でのデータ解析手法が適用される。このようにして得られた結果に対して、場合によっては知識処理などによって補正を行った上で最終的な診断結果を出力する。

今までに開発されているコンピューター画像診断システムでは、病変部の画像上での特徴量を抽出することでアルゴリズムを構築する。このとき、

A. どのような特徴量に注目するか

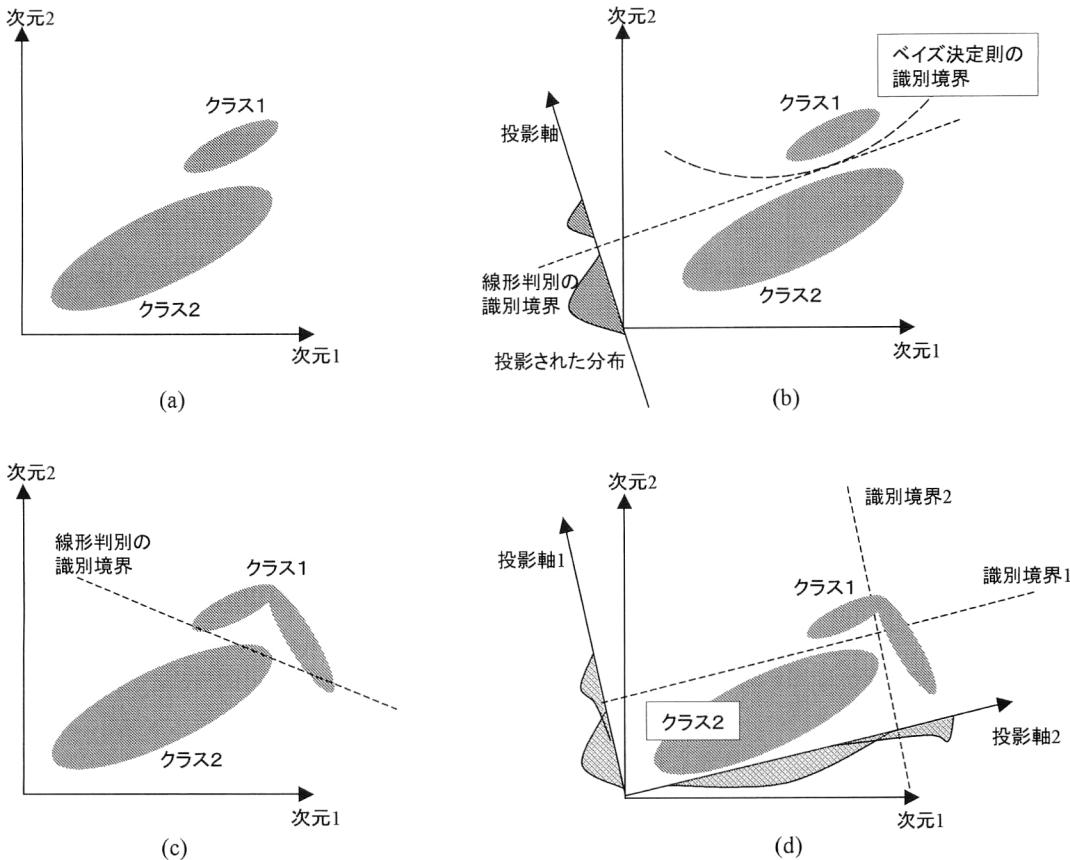


図4 多次元空間（図中では二次元で示している）でのデータ分布と分類の概念図。（a）多次元空間での正常と病変のデータ分布の概念図（各クラスが正規分布の場合）、（b）（a）の分布に基づくデータの識別、（c）多次元空間での正常と病変のデータ分布の概念図（各クラスが単一の正規分布といえない場合）、（d）（c）の分布を複数の線形識別関数により識別する方法の概念図。

B. 特徴量をどのようにして数値化するか

が重要なポイントになるが、Aの課題に対してはさまざまな特徴量を試行錯誤的に選択しているのが現状である。また、Bに対しては、より高度な画像処理手法によって信頼性のある数値を取得することが課題となっている。

2. 多次元空間におけるデータ解析

1章に述べたように、コンピューター画像診断アルゴリズムを構築する際には、多次元空間内のデータ解析が重要な役割を果たす。例えば、

- ・複数の特徴量からなる多次元空間（特徴空間）
- ・カラー画像のように各画素が複数のチャネルをもつ場合の多次元空間（色空間など）
- ・画像（または画像中の小領域）の各画素の値から構成される多次元空間

本章では、多次元空間上におけるパターンの解析方法の基本的な考え方について解説する。

2.1 多次元空間によるデータの表現

画像の各画素値から多次元空間を構成する場合には、画素数 $M \times N (=L)$ とすると、 L 次元空間上で、各画像を 1

つのベクトル（パターンベクトルとよばれる）として扱う。図4(a)に、多数のパターンベクトルを多次元空間上にプロットした様子を簡単のために二次元空間上で概念的に示す。このように病変部と正常の領域が明確に分離すれば問題は簡単であるが、実際には分離しない場合もある。この分布に基づき、パターンの解析を行う。

2.2 パターン分類の方法

病変もしくは正常のどちらのクラスに属するかがあらかじめわかっているデータを多数集め、これらをもとに分類する方法を構築する場合は、教師付きパターン分類とよばれる。一方、各データがどのクラスに属するかについて正解がわかっていない場合に、正常と病変部の特徴を取り出す場合などは、教師なしのパターン分類であり、いっそう難しい問題となる。教師データの信頼性が不十分と思われる場合にも、教師なしのパターン分類の技法を用いて正解を与える解析することが望まれる。

教師付きパターン分類の代表的な方法としては、Fisher の線形識別関数やベイズ決定則などが挙げられる。多くの場合、対象となる分布を多次元の正規分布と仮定し、その際の正判別率が最大になるように分類を行う。線形識別関

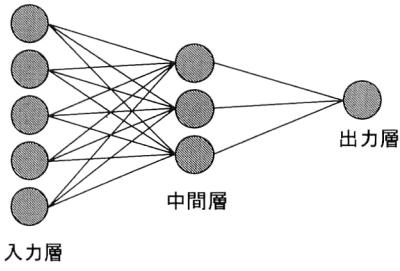


図5 3層の階層型ニューラルネット。

数は、多次元空間からある軸にデータを投影し、その投影値がある閾値よりも大きいか小さいかによってどちらのクラスに属するかを判別する。投影軸は、2つのクラス間における平均の差を最大とし、各クラス内の分散が最小となるように選択される。したがって図4(b)に示すように、クラスの境界は多次元空間内で超平面となる(図4(b)では直線で示されている)。ベイズ決定則では、多次元正規分布を用いてモデル化する場合、事後確率の対数により得られる二次の識別関数の値が最大になるクラスに分類する。この場合一般的にはクラスの境界は二次曲面になる(図4(b))。

線形識別や正規分布を仮定したベイズ決定則では、多次元空間上での分離面を複雑な形状にすることはできないので、例えば図4(c)のように単一の正規分布ではモデル化できない分布の場合、正しく分類できない。しかし仮に多次元空間上で真の分布がわかっていてれば、ベイズ決定則や複数の線形識別関数を用いて、これらを分離することも可能である。図4(d)は、(c)に示す分布について、あらかじめクラス1が2種類の正規分布から構成されているとして投影軸を決定した場合の概念図を示している。投影軸1および2に投影された値が、どちらもある閾値以下であればクラス2、そうでなければクラス1に分類される。実際には、2章4節に述べる方法を用いて多次元空間上での確率密度分布のモデル化を行う必要がある。

また、多次元データの分類にはニューラルネットが用いられることが多い。さまざまなモデルに基づくものが開発されているが、ここでは最も単純で、よく用いられている3層の階層型ネットワークモデル(図5)について考える。 L 次元入力データに対してある病変の状態を表す1つのパラメーターを出力する場合、ニューロンの数は入力層 L 、出力層1となる。図5の各層間の線がニューロン間の接続を表しており、各接続に割り当てられた重みとニューロンの出力との積和演算結果に従って次層の入力が決められる。中間層ニューロンにおいては、閾値関数やシグモイド関数などによる非線形処理が行われるが、簡単のため、閾

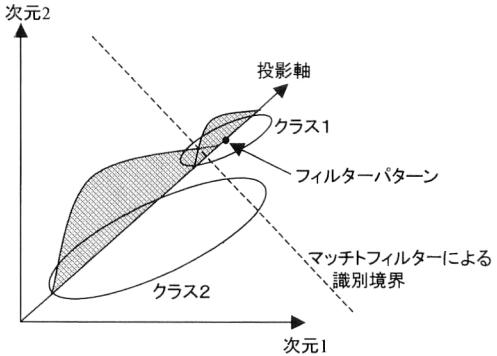


図6 多次元空間におけるマッチトフィルターによるパターン識別の概念図。

値関数の場合を考えてみる。このとき、入力層から中間層への処理は入力のベクトルと各接続重みを表す行列の積であるので、図4のように多次元空間で考えれば、中間層のニューロンと同数の直線に投影していることに対応する。そして、閾値処理によって同じ数の分離超平面を決めている。中間層から出力層の間では、分離された結果を適切に組み合わせて最終的な出力結果を得る。以上のことから、ニューラルネットの場合も、線形識別やベイズ決定則と同様にして多次元空間での分類を行っている。また、確率密度分布のモデル化を「学習」のステップで実行している⁵⁾。ニューラルネットの性能は、中間層ニューロン数や学習のための教師データセットの選択などに依存する。これは多次元空間での確率密度分布のモデル化におけるモデルパラメータ数や教師データ数などの問題と同等である。

以上の他にも、ルールベースにより判定を行う方法なども適用される場合があるがここでは省略する。

2.3 線形識別法と相関演算

線形識別法は、光情報処理の分野で歴史的に知られているマッチトフィルターと関連が深い。マッチトフィルターは多くの場合、図2(b)のようにテンプレートを移動させながら積和演算を行うことによって適用するが、図2(d)のように考えれば多次元空間からある軸への投影とみることができる。単純なマッチトフィルターの場合、識別対象のパターン自体をフィルターとするので、図6に示すように投影を行うことになる。線形判別関数と異なるのは、クラス2に関する情報を用いていない点と、分布の形状を用いていない点である。また、クラス1とクラス2のそれぞれを代表するパターンによるマッチトフィルターを適用し、それぞれの出力値の差を計算すれば、両パターンを表すベクトルの差分方向の軸に投影することになる。

逆に考えれば、画像中のある対象物(病変部など)を検出する場合には、線形識別関数などを用いて設計したフィルターを相関演算により画像に適用できる。識別対象と背

景画像を教師データとして多数集め、これらから線形識別関数によりフィルターを設計すればよい。設計されたフィルターを適用することにより、識別対象が存在する位置に相関ピークが現れることになる。

相関演算や結合相関演算を用いた画像の認識を行う際にも、識別対象と背景画像の確率密度分布をモデル化できれば、線形識別関数を用いることが有効である。また、上述のニューラルネットと線形識別関数の関係から、複数の線形識別関数による相関フィルターを適用した結果を適切に組み合わせることができれば、図4(c)のような複雑な分布をもつ対象物を検出することも可能である。

2.4 多次元確率密度分布の解析

2章2節に述べたように、多次元空間上でパターン分類を行うには、多次元空間上でのデータの分布を適切にモデル化することが重要である。したがって、教師データが得られた場合、

- ① データが多次元空間上で分離しているか
 - ② 線形識別で分離できるか
 - ③ 確率密度分布のモデルとして何を用いれば適切か
- などを確認するために多次元確率密度分布の解析が必要になる。

多次元空間上でデータがどのように分布しているかを観察するために、主成分分析(PCA)がよく用いられる。上位の主成分に対応する軸はデータ分布の大雑把な傾向を把握するのに適しており、下位の主成分はほとんどノイズであるので、無視しても差し支えない場合が多い。ところが2クラス分離の立場からすれば、クラス内での分散が大きい軸が抽出される可能性もあるので、PCAの上位の軸でクラス間の分離を視覚化できるとは限らない。これに対して、F-S(Foley-Summon)変換が利用できる。F-S変換は、多次元空間上での2クラスの分布に対し、クラス間の分散が大きく、クラス内の分散が小さい順に、直交する軸を抽出する。また、その第1軸はFisherの線形識別関数に一致する。このため、F-S変換の上位の軸への投影結果をみると(特に線形識別関数により)、2クラスの分離が可能かどうかを把握しやすい。

線形識別やF-S変換の手法は、各クラスのデータがそれぞれ多次元正規分布に従う分布の場合は良好に働くが、分布が複雑な形状をしている場合には適用が困難である。また、教師なしのデータをもとに診断支援アルゴリズムを構築する場合には、データの多次元空間上での分布から特徴を抽出する必要がある。基本的には、得られたデータから確率密度分布をモデル化するという問題となり、多变量解析の各種の手法を適用することになる。

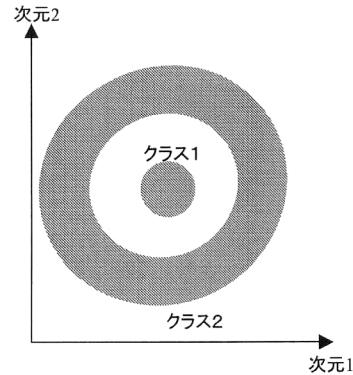


図7 ドーナツ型の分布。正規分布に基づくモデル化では分離是不可能。

データが複数の正規分布をもつ密度分布に従って発生するというモデルは混合正規分布モデル(mixture Gaussian model)とよばれる。K個の正規分布の和で表される密度分布に従ってデータが発生するものとすると、K個の正規分布のパラメーター(平均および分散)と、各データがどの正規分布から発生したのか、の両方を求める必要がある。得られているデータに対して、推定された確率密度分布がどれだけ適合しているかは、尤度により評価できる。そこで、尤度を最大化することで元の密度分布を推定する手法(最尤法)が一般的である。混合正規分布モデルの場合は解析的に最尤推定解を求めることができないので、EM(expectation maximization)アルゴリズムによる繰り返し演算を用いて解く方法が開発されている。これはデータをK個の正規分布に分類して密度分布を推定するもので、一種のクラスタリングといえる⁶⁾。

確率密度が多次元正規分布や混合正規分布によるモデルでは扱えない場合もある。典型的な例は、画像の分散にクラス間の特徴がある場合である。画像内の分散が一定なデータは原点を中心とした超球面上に分布するので、例えば2つのクラスの分布は図7のようになる。このため、正規分布によるモデル化や後述のk-means法などによるクラスタリングはうまく働かない。これに対しては、画像の分散に特徴があることがあらかじめわかっているれば、画像の分散を特徴量として抽出し、分散を1つの軸として扱うことによって分離しやすくする、というアプローチが採られる場合が多い。

得られたデータから多次元空間上で確率密度分布を推定する他の方法として、Parzenの窓関数法がある。これは、多次元空間中である広がりをもつカーネル関数を考え、すべてのデータ点を中心としたカーネル関数状の分布の和を求めるものである。多くの場合カーネル関数としては多次元正規分布が用いられる。この方法は、データの分布に関

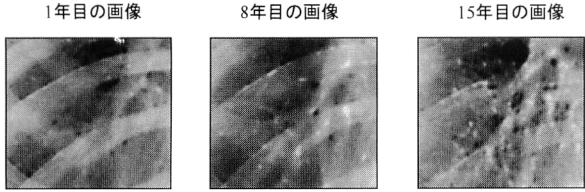


図8 じん肺患者のX線写真（一部）。約30年間に3年ごとに撮影された画像のうちの最初、中間、最後の画像を示している。

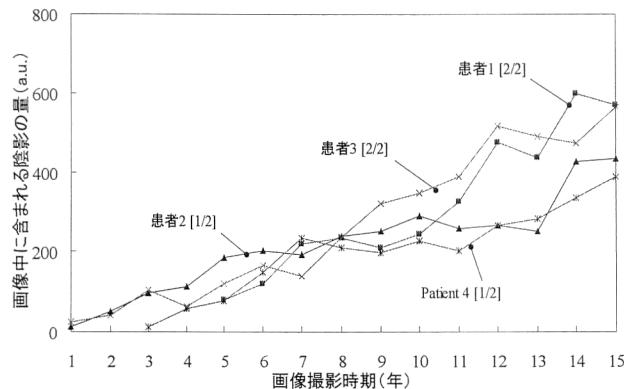


図9 4枚のじん肺X線写真的粒状影の時系列解析結果の例。縦軸は画像からパターンヒストグラムを用いて抽出された粒状陰影の特徴パターンの数。[2/2]および[2/1]の数字は最終年におけるじん肺の管理区分を示しており、数字が大きいほど状態が悪い。画像から求めた縦軸の値との対応がみられる。

する仮定を何ら用いないことから、密度分布の形状にかかわらず適用できる点に特徴がある。しかし、多次元空間の範囲に対してデータ点数が少ないと、元のデータ点がまばらに分布し、この方法でもっともらしい密度分布を推定することは難しい。PCAなどを用いて空間の次元数をあらかじめ削減しておくなどの工夫が必要である。

多次元空間上のデータを、何らかの類似度の定義に基づいてグループ分けし、その結果を確定診断結果などと比較すれば、画像特徴の抽出やパターン分類などに有効である。このような処理は、多変量解析で使用されているクラスタリングの技術に基づくものである。代表的なものとして、*k-means* クラスタリングでは、*k* 個のクラスター中心のうち最も類似度の高いクラスターにデータを分類する。クラスター中心についても繰り返し処理による最適化によって求められる。最大の特徴は演算が容易な点であるが、多次元空間上での距離を類似度として定義すると、多次元空間上を超球で区切って分類することになるので、細長い分布をもつクラスターを抽出することは困難である。なお、各クラスターに属する可能性を帰属度として定義する fuzzy *c*-means 法も画像のセグメンテーションなどに応用されている⁷⁾。

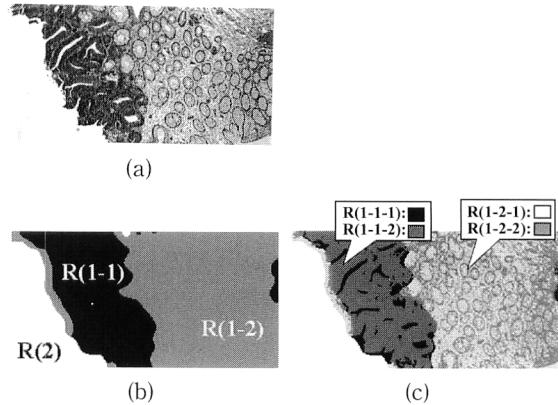


図10 パターンベクトルの階層的クラスタリングによる画像のセグメンテーション結果。(a) 原画像、(b) クラスタリング結果（第2階層）、(c) クラスタリング結果（第3階層）。

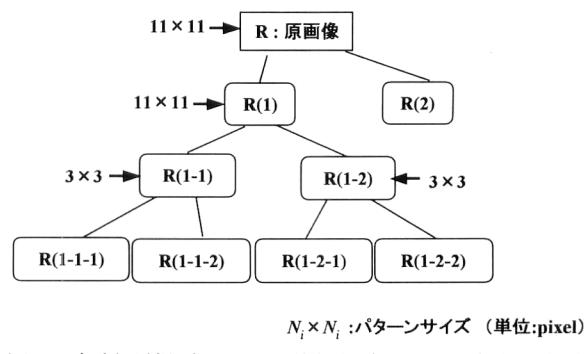


図11 解析の結果得られた階層図。各ノードの横に記した数字は各階層で選択されたサブ画像サイズを示す。

クラスタリングを応用して多次元空間上での確率密度分布を求める方法は、ベクトル量子化の応用として画像解析や画像検索などに利用されている。多次元空間を *k*-means 法などによるクラスタリングを用いて分割し、各クラスターに属するデータ数をカウントすることで、一種のヒストグラムを求める。例えばCT画像による大腸ポリープの検出などに応用されている⁸⁾。また、図8に、2年おきに撮影されたじん肺患者のX線画像の時系列解析に応用した結果を示す⁹⁾。全画像から1画素おきにサブ画像を抽出し、上述の手段で多次元空間でのヒストグラムを求め、各ヒストグラムビンに属するデータの数を時系列で解析する。悪化傾向のじん肺患者のX線写真においては粒状陰影が時間とともに増加するので、時間経過とともに増加傾向にあるビンのみを抽出すると、抽出されたビンに属するデータは粒状陰影の部分を表すことになる。図9のグラフは、以上の方針により4名のじん肺患者の画像から増加傾向のパターンの数をプロットしたものである。[2/2]などの数値はグラフの横軸右端の時点でのじん肺の管理区分であり、数値が大きいほど状態が悪いことを示している。このようにして、じん肺患者の状態の時間的な変化を定量化すること

が可能になる。

上記は非階層的なクラスタリングであるが、データを階層的にクラスタリングを行うことが有効な場合もある。多くの場合、各階層で2分割を繰り返してクラスタリング結果を得る¹⁰⁾。図10は、病理顕微鏡画像を対象として階層的クラスタリングを行った結果の例である¹¹⁾。ここでは、画像面上で定義されたセグメンテーション結果の妥当性を評価する基準に基づいて、各階層で適切なサブ画像サイズを選択する方法を用いている。図11が得られた階層構造である。上位のノードでは 11×11 画素の比較的広い範囲の特徴に基づき、下位ノードでは 3×3 画素と比較的狭い範囲のテクスチャに基づいてセグメンテーションが行われている。なお、この解析結果を医学的知見と照合したところ、R(1-1), R(1-2)で示されている各領域はそれぞれ悪性・良性の領域に対応していた。

3. これからのコンピューター画像診断

通常、医師による画像診断は、①画像や検査データその他患者情報の観察、②医学知識・論理に基づく分析、③経験との照合、などを組み合わせて行われていると考えられる。従来のCADシステムでは、①～③を組み合わせた結果として行われている医師の頭の中での診断プロセスを、一部コンピューターで置き換えるまたは模擬することにより診断を支援するというアプローチが主流といえる。

一方、臨床経験の豊富さは診断の精度に大きく効くことはいうまでもない。巨大な症例データベースが構築されれば、一人の医師では不可能な量の経験をコンピューターに蓄積できる。近年のネットワークや保存媒体等のデジタル情報技術の発展と普及によって、巨大な症例データベースを構築することも可能になりつつあり、これを診断に利用することが期待される。そのためには、①の画像観察(画像解析)、②の知識・論理に基づく分析と、③膨大な症例データを組み合わせて診断結果を導き出すというアプローチが必要となる。

このようなアプローチでは、医師の判断をコンピューター化するのではなく、統計や実例等に基づいて診断することになるため、より客観的な診断が行えると考えられる(最近EBM: evidence-based medicineの考え方方が重要視されている)。また、一人または少数の医師では経験できない量の症例に基づいて解析できれば、従来の診断技術を超えた画像診断を実現できる可能性がある。

画像診断をサポートするためのコンピューター画像診断システムの考え方と、そのために必要な画像解析技術とし

て、多次元空間におけるデータ解析の基本的な技術を紹介した。また、光情報処理分野で発展してきたマッチトフィルターとの関係についても触れた。ここでは医用画像処理を対象として解説したが、画像の多次元空間における解析とパターン分類の技術は、自然画像の解析、画像圧縮、画像検索、画像からの知識抽出など、さまざまな分野に共通するものである。最近、計算機ハードウェアの性能向上に伴って、これまで計算効率の点から困難とされていた手法の適用が可能になっている。また、いろいろな分野で大量の画像がデータベース化され、これを解析することで新たな知識を抽出すること(データマイニング)が期待されていることから、今後こういった技術をさらに発展させていくことが望まれる。光技術自体の出番は少ないが、光情報処理研究で培われたシステム構築技術の発想を元にこのような研究に取り組むことは、十分な価値のあることと思われる。

文 献

- 1) 長谷川玲：“世界ではじ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誌，**56** (2000) 355-358.
- 2) 仁木 登：“肺がん CT 診断支援システム”，医用電子と生体工学，**39** (2001) 103-106.
- 3) 原 武史、谷 芳伸、藤田広志、遠藤登紀子：“乳房 X 線写真における腫瘍陰影の良悪性鑑別システムの開発”，Med. Imag. Technol., **17** (1999) 577-584.
- 4) 斎藤豊文、大坪法幸、鳥脇純一郎、渡辺 涼、横山慶一、高松哲郎：“PSA 染色された前立腺生検組織顕微鏡像を用いた前立腺がんの検出に関する予備的検討”，電子情報通信学会論文誌，**J83-D-II** (2000) 228-236.
- 5) 大山永昭：“光コンピューティングとニューラルネットワーク原理的な類似性と統合型コンピュータ”，応用物理，**62** (1993) 23-27.
- 6) Y. Wang, C. Lau, T. Adali, M. T. Freedman and S. K. Mun: “Quantification of MR brain image sequence by adaptive structure probabilistic self-organizing mixture,” Proc. SPIE, **3034** (1997) 150-164.
- 7) N. R. Smith and R. I. Kitney: “Fast fuzzy segmentation of magnetic resonance images: A prerequisite for real-time rendering,” Proc. SPIE, **3034** (1997) 1124-1135.
- 8) S. B. Göktürk, C. Tomasi, B. Acar, C. F. Beaulieu, D. S. Paik, R. B. Jeffrey, J. Yee and S. Napel: “A statistical 3-D pattern processing method for computer-aided detection of polyps in CT colonography,” IEEE Trans. Med. Imag., **20** (2001) 1251-1260.
- 9) Y. Ugurlu, T. Obi, M. Yamaguchi and N. Ohyama: “Long-term interval change detection from a sequence of personal images,” Opt. Rev., **7** (2000) 44-53.
- 10) T. Hofmann, J. Puzicha and J. M. Buhmann: “An optimization approach to unsupervised hierarchical texture segmentation,” *1997 International Conference on Image Processing (ICIP '97)* (Santa Barbara, CA, 1997) pp. 213-216.
- 11) K. Ohkura, H. Nishizawa, T. Obi, M. Yamaguchi and N. Ohyama: “Unsupervised image segmentation using hierarchical clustering,” Opt. Rev., **7** (2000) 193-198.

(2002年3月26日受理)