

びまん性肺疾患診断における階層的特徴選択アプローチ

遠藤 瑛泰^{1,a)} 永田 賢二^{2,3} 木戸 尚治⁴ 庄野 逸^{1,b)}

概要：びまん性肺疾患の診断は医師の目視により CT 画像上の陰影から判断されるが、見られる陰影は多種多様であり、診断が難しい場合がある。このような問題に対して計算機による診断支援を適用させる場合、パターン認識を用いた陰影の識別が有効である。パターン認識においては、入力に不適切な特徴が含まれると汎化性能が低下するおそれがあるので適切な特徴選択が必要である。本研究では、テクスチャ特徴から有効な特徴の組み合わせを検索するというアプローチをとるものとする。一般に特徴選択問題は組み合わせ最適化であるため、特徴数が多い場合、すべての組み合わせの有効性を確認することは困難になる。そこで本研究では、二段階の階層的な特徴選択手法を考える。一段階目の選択では、特徴の特徴の出自による大まかなグループ単位での刈り込みを行い、二段階目では刈り込まれたグループに属する特徴全ての組み合わせを検索するという手法を採用している。評価にはテスト用データにおける状態密度分布を用いて、有効な組み合わせの汎化性能とスパース推定との比較を行った。

キーワード：びまん性肺疾患, 特徴選択, 組合せ最適化, ES-SVM

A Hierarchical Approach for Feature Selection with Diffuse Lung Disease

AKIHIRO ENDO^{1,a)} KENJI NAGATA^{2,3} SHOJI KIDO⁴ HAYARU SHOUNO^{1,b)}

Abstract: It is difficult that diagnose Diffuse Lung Disease(DLD) from the textures on the CT image which are diverse. In such cases, pattern recognition using computers is effective. On one hand, unnecessary feature got as input, then there is a risk that the generalization ability being worse. In this research, for DLD classification with texture features, we tried to selected the effective features combination for each class. However, since texture features are too much, it is difficult to check all combinations. Therefore, we approached reducing combinations with a hierarchical feature selection. First, we selected effective combination of groups which include features extracted by a texture analysis. Second, from features in selected group, we selected combination of features. To evaluate selected feature combination, we calculated test scores about all combinations and compared to Lasso which is one of sparse estimation method.

Keywords: Diffuse Lung Disease, Feature Selection, Combinational Optimization Problem, ES-SVM

1. はじめに

びまん性肺疾患とは肺全体の広範囲にわたって様々な異

常陰影が見られる病気の総称であり、炎症性疾患、感染症、腫瘍性疾患などの様々な肺疾患が含まれている [1]。図 1 にびまん性肺疾患と診断された肺の CT 画像の例を示す。図中、円で囲まれた部分のように肺の広範囲において白い陰影構造が写っており、この部分がびまん性肺疾患で見られる異常陰影である。びまん性肺疾患で見られる陰影パターンを識別する計算機診断支援システムを構築することで、今まで医師の目視評価によって行われてきた陰影パターンの識別を定量的に評価することが可能になる。また、シス

¹ 電気通信大学大学院情報理工学研究所 〒182-8585 東京都調布市調布ヶ丘 1-5-1

² 国立開発法人産業技術総合研究所 人工知能研究センター 〒135-0064 東京都江東区青海 2-4-7

³ 科学技術振興機構「さきがけ」 〒102-0076 東京都千代田区五番町 7

⁴ 山口大学大学院創成科学研究科 〒755-8611 宇部市常磐台 2-16-1

a) e1830017@edu.cc.uec.ac.jp

b) shouno@uec.ac.jp




図1 びまん性肺疾患と診断された患者の肺 X 線 CT 画像の例。円で囲まれたような白くなっている部分が病変である。

テムによって解析した結果を医師に客観的な判断材料として提供することで、病変の見落としや医師の経験による診断結果のばらつきを減少させ、より正確な診断が可能になると期待されている。

本研究では、テクスチャ特徴を用いたびまん性肺疾患の陰影パターン識別手法の提案を行う。パターン識別において、入力として与える特徴に不適切なものが含まれると、未知データに対する予測精度の低下を引き起こす可能性がある。そのため、特徴選択を行い、有効な特徴の組み合わせを調べることで、診断支援システムにより適した識別器を構築することが期待できる。

今回用いるテクスチャ特徴は、菅田らの手法に従い、6種のテクスチャグループを用いる [2]。これらのテクスチャグループは画像テクスチャ解析で用いられる同時生起行列 (Co-Occurance Matrix: COM), ランレンジ行列 (Run Length Matrix: RLM), 濃淡ヒストグラム (Gray Level Histogram: GLH), 差分統計量 (Gray-Level Differential: GLD), 動径方向パワースペクトル (Fourier Power Spectrum of r : Fr), 方位パワースペクトル (Fourier Power Spectrum of θ : Ft) である [6]。これらのテクスチャ特徴グループは、多次元量であるため、各グループに対して、統計処理を施し、最終的には 39 種の特徴を画像の特性を表すデータとして用いる。

Nagata らは、このような特徴の組み合わせ全てを総当りに求め、各組み合わせでの汎化指標を評価するという方法を取っている [4]。しかしながら、ここで考えなければならないことは、特徴の組み合わせの総数である。全ての組み合わせの数は、 $2^{39} - 1$ だけ存在し、現状の計算機能力ではその全ての組み合わせを確認することは困難である。そこで、有効なテクスチャ解析のグループの選択により特徴の刈り込みを行い、その後さらに特徴選択を行う、階層的なアプローチで特徴選択を行う。

また、スパース推定の文脈では、組み合わせ最適化 (L0




図2 本研究における特徴選択の概要図。

正則化に相当) を緩和した形で、L1 正則化といった手法が議論されている [5]。一方、本研究は L0 正則化に対して、ある種のグループ的な制約を埋め込んだアプローチと捉えることができる。このため、本手法との L1 正則化を用いた手法との比較は重要であり、これについても考察を行う。

以下では、まず 2 章において、全体的な枠組みと要素手法の解説を行い、実験の概要と結果をそれぞれ 3, 4 章において説明を行う。

2. 手法

本研究の特徴選択の枠組みを図 2 に示す。まず、CT 画像から抽出したテクスチャ特徴を計算する。次にこれらの特徴から特定の特徴を選択するものとする。このとき、選択特徴の組み合わせは二値ベクトル s で表現することができる。ここではベクトル s を状態ベクトルと呼ぶことにする。次に、評価手法であるが、ここでは状態ベクトル s によって決定された特徴を用いて識別器を構築し、この識別器の汎化性能を指標とする。ここでは、交差検証 (Cross Validation: CV) 法を用いた汎化指標を用いる。CV 法による汎化指標を $-E(s)$ として表すと、特徴選択問題は、エネルギー $E(s)$ の最小化問題に帰着させることができる。

以降、用いた各種手法の解説を行う。

2.1 階層的特徴選択法

ここでは、階層的な特徴選択方法について述べる。特徴の総数が少ない場合は全ての組み合わせを総当りで調べることが可能であるが、特徴総数が一定の数よりも大きくなった場合は組合せ爆発が起こり、計算困難が生じる。そこで、本研究では二段階の階層的なアプローチを取るものとする。ここでは“同じテクスチャ特徴グループに属する特徴が、パターン識別に有効に働きやすい”ということを仮定している。

ここではテクスチャ特徴グループとして 2.2 節に用いられる 6 種類のグループ (COM, RLM, GLH, GLD, Fr, Ft) を大きな特徴グループとして取り扱い、組み合わせ特徴を考




図3 階層的特徴選択の概要図. (a) 第一段階での特徴グループの選択を行い, (b) 第二段階では第一段階で選ばれたグループに属する特徴からさらに選択を行う.

える. すなわち, ある特徴グループを選択する場合, そのグループに属する全ての特徴を選択した状態ベクトル s を考えることになる. このように考えると, 組み合わせの総数としては $2^6 - 1$ となるため全ての組み合わせを考えても十分に計算可能になる. これが第1段階目の選択手法となる. (図3.(a) 参照)

第二段階目の選択手法は, 第一段階で選ばれた選択特徴グループ内部に含まれる特徴についての取捨選択を行う. ここでは総数が計算可能な範囲であれば, 全ての組み合わせを網羅的に列挙し, 探索を行い, 計算困難な数であれば, Nagata らによって提案された, マルコフ連鎖モンテカルロ法に基づいた近似的全状態探索 (Approximated Exhaust Search: AES) を適用することを考える [4]. (図3.(b) 参照)

2.2 テクスチャ特徴

画像処理におけるテクスチャとは, 特有の模様などが持つ繰り返される輝度パターンのことである [6]. テクスチャを表す特徴を構造的もしくは統計的に数値化することで計算機上でテクスチャの表現を扱うことが可能になる. 数値化されたテクスチャの特徴はテクスチャ特徴と呼ばれる. テクスチャ特徴は人間がデザインした由来のわかる特徴であるため, 識別結果の意味付けを容易にできるという利点がある.

本研究では先行研究 [2][3] で用いられたテクスチャ特徴を用いる. ここでのテクスチャ特徴は, 前述の通り, 幾つかのテクスチャ特徴グループに分けられる. これらは同時生起行列 (COM), ランレンジス行列 (RLM), 濃淡ヒストグラム (GLH), 差分統計量 (GLD), 動径方向フーリエパワースペクトル (Fr), 方位フーリエパワースペクトル (Ft) といった異なる6つのグループである. これらのグループから縮約統計量を求めることで, トータルの特徴数として

index	略称	テクスチャ特徴グループ
0-5	COM	同時生起行列
6-10	RLM	ランレンジス行列
11-17	GLH	濃淡ヒストグラム
18-24	GLD	差分統計量
25-31	Fr	動径方向フーリエパワースペクトル
32-38	Ft	方位フーリエパワースペクトル

表1 使用したテクスチャ特徴のインデックスおよび対応するテクスチャ特徴グループとその略称.

は39種の統計量が得られることになる (表1).

2.3 ES-SVM 法

特徴選択を行うためには, 選ばれた特徴を入力とした識別器を用意する必要がある. ここでは, 識別機として線形のサポートベクターマシン (Support Vector Machine: SVM) を用いる. 線形 SVM はある特徴空間において, 分離超平面を挟んだクラス間の距離 (マージン) が最大化されるように一次関数の決定関数を定義する手法である [8]. 全ての状態ベクトル s を SVM によって網羅的に探索する手法は, 全状態探索型 SVM (Exhaustive Search SVM: ES-SVM) 法と呼ばれる.

本研究では, 陰影のパターンごとに一対他の2クラス分類問題を考えた ES-SVM を行い, それぞれの陰影パターンに適した状態ベクトル s の探索を行った.

2.4 交差検証法

構築した識別器の識別性能を確認する手法として, 交差検証 (Cross Validation: CV) 法を用いた評価を行った. CV 法はデータセットを K 個に分割し, $(K - 1)$ を訓練データとして識別器の構築に使用し, データセットすべてを用いて性能評価を行う [7]. このとき, 識別器の構築に使用しなかったデータは未知のデータの役割を果たしている. このような性能評価を K 通り行うことで, 識別器が持つ識別性能とすることが出来る.

本研究では, 性能評価を行う際に識別器の構築に用いなかったデータのみで評価を行う K -fold CV 法を用いた. ある状態ベクトル s について, K -fold CV 法を用いて識別率を計算し, CV スコアとした. CV スコアを正負を反転させたものをエネルギー $E(s)$ とし, 状態探索ではエネルギー $E(s)$ が最小, つまり CV スコアが最大となるような状態ベクトル s を探索した.

3. 実験

3.1 実験データ

本研究では大阪大学より提供された, びまん性肺疾患を対象とした X 線 CT 画像を用いて実験を行った. このデータは医師の指導の下, びまん性肺疾患の陰影パターン




図4 ROI画像7種類の典型例。a, b, c, dがびまん性肺疾患の陰影クラスである。

症例 (class)	状態探索用	テスト用
Consolidation(CON)	26 枚	26 枚
Ground-Glass Opacity (GGO)	50 枚	46 枚
Honeycomb (HCM)	72 枚	73 枚
Reticular (RET)	70 枚	66 枚
Emphysema (EMP)	294 枚	296 枚
Nodular (NOD)	65 枚	65 枚
Normal (NOR)	359 枚	355 枚
計	936 枚	927 枚

表2 CT画像から切り出した各症例のROI画像の枚数。

4クラスである浸潤影 (consolidation; CON), すりガラス状陰影 (ground-glass opacity: GGO), 蜂巣状陰影 (honeycomb: HCM), 網状影 (reticular: RET), 及び, びまん性肺疾患に類似する陰影パターン2クラスである肺気腫 (emphysema: EMP), 粒状影 (nodular: NOD), 正常な陰影パターン1クラスである正常 (normal: NOR) の計7クラスに分類されたデータである。このX線CT画像より, 医師が指定した陰影が 32×32 の関心領域 (Region of Interest: ROI) に8割以上含まれるように切り出しを行ったROI画像を作成した。実験では, このROI画像から39個のテクスチャ特徴を抽出し, ラベル付きデータとして用いた。データはROI画像の枚数のオーダー及び各クラスの枚数のオーダーが同程度になるように2つに分け, それぞれ状態探索用データとテスト用データとして用いた。データの分割の際には医師の指導に従い, 状態探索用データとテスト用データの内訳に同一患者のX線CT画像より作成したROI画像が含まれないようにした。

3.2 実験方法

本実験では状態探索用データとテスト用データを用いて, 状態探索による特徴選択と選ばれた状態の汎化性能を確認した。状態探索による特徴選択では, 状態探索用デー

class	CON	GGO	HCM	RET	EMP	NOD	NOR
CV score	1.00	0.947	0.989	0.925	0.947	0.936	0.929
All other	0.972	0.947	0.923	0.925	0.686	0.931	0.616

表3 各クラスにおける, グループ選択によって選ばれた状態のCVスコア (上段) と, どのようなデータに対しても目的クラス以外と判断した際のスコア (下段)

タのみを使用し, $K=5$ の K -fold 交差検証法により, 状態のエネルギーを算出し, 特徴選択を行った。ここでは, 2.1節で説明したとおり, 階層的な特徴選択を行う。第一段階においては, テクスチャ特徴グループは6つのグループ (COM, RLM, GLH, GLD, Fr, Ft) から選択を行う。この時, 組み合わせは $2^6 - 1$ 個なので十分計算可能である。第二段階では選ばれたグループに属している特徴から選択を行った。

4. 結果

4.1 第一段階選択の結果

第一段階の特徴選択では, 6つのグループ選択の組み合わせを表す63状態を確認し, 評価した。

グループの選択における状態探索において, 最もCVスコアが高かったグループの組み合わせを図5に示す。横軸にはグループを並べ, もっともCVスコアが良い状態を縦軸に順に並べた。塗りつぶされている部分が使われているグループを表し, 使われていないグループは白く表した。クラスによって複数の状態が同一スコアで選ばれているが, 使っているグループが少ない状態を採用することとした。

CONクラスの識別ではGLHに属しているテクスチャ特徴のみを用いることで, 他のグループに属している特徴を用いた結果よりも良い状態であることが分かる。また, 他のクラスにおいても, 選択のされ方は様々では在るが, 全てのグループを同時には使わない方が, 良い識別器を構築できることが分かる。

GGOとRETのクラスを除いたクラスでは, 同一の選択パターンは存在しない。このことは各陰影クラスが, それぞれ固有の特徴に適したテクスチャ特徴グループの組み合わせを持つことを示唆している。

表4.1はグループの選択における各クラスで最も良いCVスコアを示した。どのクラスにおいても, 最も良い状態におけるCVスコアは90%を超えている。

また, グループ選択の63状態における状態密度分布を確認した。図6はCONとGGOの状態密度分布である。横軸にエネルギー, 縦軸には状態密度を示している。図中に示している縦のラインは, 全ての学習データを目的クラス以外と判定する識別器のエネルギー位置を示している。このようなラインが低いエネルギー値になる状況としては, 学習データが偏っており, 対象クラスのデータ数が少ない場合が考えられる。すなわち, あえて, 少数しかデータ点を持たない対象クラスの識別能力を捨て, 大多数の対象以外の識別能力をあげることで評価精度を稼ごうとするケー




図5 各クラスにおいてグループ選択で最も高い CV スコアの状態の列挙。上から CON, GGO, HCM, RET, EMP, NOD, NOR の結果である。横軸にグループを示し、縦軸方向に選ばれた状態を並べた。塗りつぶされているグループが使用しているグループを表している。HCM では GLH, Fr, Ft の 3 つのグループが選ばれている。

スである。図 6 左は、CON のケースを表している。このケースではラインの値よりもエネルギーの低い状態が多数存在しており、識別に有効なグループが多数存在していることが考えられる。一方、GGO クラスでは、ラインの値よりもエネルギーが低い状態が存在しておらず、識別に有効なグループが存在しない。すなわち、十分に分離する識別器を構築することが難しいクラスであることが考えられる。このようなケースでは識別がうまく出来ないクラスであると判断を行うこととした。CON クラスのように全てを目的クラス以外と判断した時のエネルギーよりも有効な状態が多数存在しているクラスとしては、EMP, HCM, NOR の 4 クラスである。残りの GGO, RET, NOD のクラスは全てを目的クラス以外と判断した時のスコアよりも有効な状態が半数も存在していなかった。

第一段階の結果から、CON クラスは GLH 特徴グループから得られる特徴 7 個、EMP クラスは {COM, GLH} の 2




図6 グループ選択における状態密度分布。横軸にエネルギー、縦軸に密度を示している。右側は CON, 左側は GGO の状態密度分布である。All other を基準に、CON では十分にクラスを分離している状態が多数存在しているが、GGO では全ての状態が基準以上のエネルギーであることが分かる。

グループから得られる特徴 13 個、HCM クラスは {GLH, Fr, Ft} の 3 グループから得られる 21 個、NOR クラスは {COM, RLM, GLH, GLD} の 4 グループから特徴 25 個に刈り込みを行うこととした。これらの特徴からさらに第二段階の特徴を選択することになる。

4.2 第二段階

第二段階では第一段階の結果より、CON, EMP, HCM, NOR クラスにおいて選択された特徴グループに属する特徴を用いて、ES-SVM/AES-SVM 法を適用した。CON, EMP, HCM クラスにおいては、状態数が比較的少ないため ES-SVM 法を適用したが、NOR クラスにおいては、全状態数が約 3.0×10^8 状態と多いため、交換 MCMC 法を用いて近似的な ES-SVM 法 (AES-SVM) を適用した。

図 8 に、NOR クラスの状態探索によって得られた CV スコアが高い組み合わせを列挙している。縦軸に特徴、横軸に CV スコアが高い順に、同じ CV スコアの組み合わせは使用している特徴が少ない順に 100 状態列挙した。CV スコアが高い組み合わせでは使う特徴と使わない特徴に傾向があり、特徴の取捨選択が行われていることが分かる。CON, HCM, EMP クラスにおいても CV スコアの高い状態において、ある特徴を使用している状態が集中していることが確認出来た。

4.3 評価

全ての組み合わせのテスト用データに対するスコアを計算した結果を確認した。テスト用データの識別率を調べる ES-SVM においては、CON, HCM, EMP, NOR の各クラスに対して適用した。表 4.3 に状態探索において最も高い CV スコアの組み合わせの CV スコアとテスト用データに対するスコア、第一段階で刈り込まれた特徴に対して L1 正則化を適用した線形識別器のテスト用データに対するスコアを示す。表 4.3 より、今回見つけた各クラスの CV スコアが高い組み合わせは、テスト用データに対しても高いスコアを示していることが分かった。この結果より、今回の階層的な特徴選択で、CON, HCM, EMP, NOR クラス




図7 NOR クラスの第二段階の特徴選択において CV スコアの高い組み合わせを 100 状態列挙した。縦軸に特徴、横軸方向に CV スコアが高い順番で並べた。塗りつぶされている部分がその組み合わせで使用している特徴である。

class	CON	HCM	EMP	NOR
CV score	1.00	0.996	0.990	0.957
Test score	0.998	0.988	0.963	0.917
L1	0.983	0.984	0.934	0.853

表4 第二段階の特徴選択で選ばれた状態の CV スコア (上) とテスト用データのスコア (中), L1 正則化を適用した時のテスト用データのスコア (下)。

の各陰影パターンを適切に表現した特徴の組み合わせを選択出来たと考えられる。

さらに、スパース推定による次元削減手法との比較として、L1 正則化を適用した線形識別器を構築し、テスト用データに対するスコアとの比較を行った。表 4.3 から、どのクラスにおいても L1 正則化を適用したスコアよりも、状態探索によって選ばれた組み合わせを用いた場合のほうが高いスコアを示していた。図 8 は NOR クラスの横軸にエネルギー、縦軸に状態密度を示した状態密度分布である。図中に特徴選択で選んだ特徴の組み合わせのスコアの位置を破線、L1 正則化のスコアの位置を点線で示している。L1 正則化のスコアよりも高い組み合わせは全状態のうち約 59%存在していた。一方で、特徴選択で選ばれた状態よりもスコアの高い状態は全状態中で、約 6%だけ存在している。CON, HCM, EMP のクラスにおいても同様な結果が得られた。この結果から、L1 正則化は十分に高いスコアであるが、全状態の中には、それ以上に有効な特徴の組み合わせは数多く存在しており、特徴選択によって選ばれた組み合わせは全状態の中でも十分に高いスコアを持つ状態であり、汎化性能も十分高いことが分かった。

5. 結論

本研究では、テクスチャ特徴を用いたびまん性肺疾患画像の識別において特徴選択を行い、識別器を構築した。特徴選択を二段階に分けて行うことで、特徴を刈り込み、特




図8 NOR クラスのテスト用データのスコアに関する状態密度分布。横軸にエネルギー、縦軸に密度を示している。図中、特徴選択で選ばれた状態の負のスコアを破線、L1 正則化の負のスコアを点線で示している。

徴の全ての組み合わせの中から有効な特徴の組み合わせを見つけることが出来た。さらに、L1 正則化のようなスパース推定による結果が特徴選択によって選ばれた組み合わせと比較すると、特徴選択で選んだ組み合わせのほうが十分に汎化性能が高かった。

謝辞 本研究の実験に使用した X 線 CT データを提供していただいた、大阪大学附属病院に深く感謝いたします。本研究の一部は、科学研究費 (JSPS) 16H01542, 16K00328 のサポートを受けて行われた。

参考文献

- [1] 国立研究開発法人 国立国際医療研究センター, びまん性肺疾患, <http://www.hosp.ncgm.go.jp/s003/010/050/index.html>.
- [2] 菅田 良博, 木戸 尚治, 庄野 逸, 胸部 CT 画像を用いたびまん性肺疾患画像解析のための 2 次元と 3 次元特徴解析の比較, 医用画像情報学会雑誌, Vol. 25, No. 3, pp. 43-47, 2008.
- [3] Makoto KOIWAI, Nodoka IIDA, Hayaru SHOUNO, *Feature Selection for Diffuse Lung Disease using Exchange Markov Chain Monte-Carlo Method*, PDPTA'16.
- [4] Kenji Nagata, Jun Kitazono, Shinichi Nakajima, *An Exhaustive Search and Stability of Sparse Estimation for Feature Selection Problem*, IPSJ Transactions on Mathematical Modeling and Its Applications, 8 (2), 2330, 2015.
- [5] Robert Tibshirani, *Regression Shrinkage and Selection via the lasso*, J.Royal Stat. Soc. B, Vol.58, No.1, 267-288(1996).
- [6] 財団法人画像情報教育振興協会, デジタル画像処理.
- [7] C. M. Bishop 著, 監訳: 元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇, *Pattern recognition and machine learning-パターン認識と機械学習*, シュブリンガー・ジャパン, 2007-2008.
- [8] 竹内 一郎, 鳥山昌幸, サポートベクトルマシン, 講談社, 2015.