



# 部分空間法に基づくサポートベクトルマシンに関する研究

北村, 拓也

---

(Degree)

博士 (工学)

(Date of Degree)

2011-03-25

(Date of Publication)

2015-11-27

(Resource Type)

doctoral thesis

(Report Number)

甲5256

(URL)

<https://hdl.handle.net/20.500.14094/D1005256>

※ 当コンテンツは神戸大学の学術成果です。無断複製・不正使用等を禁じます。著作権法で認められている範囲内で、適切にご利用ください。



氏 名 北村 拓也  
博士の専攻分野の名称 博士（工学）  
学 位 記 番 号 博い第 5256 号  
学位授与の要件 学位規則第 5 条第 1 項該当  
学位授与の日付 平成 23 年 3 月 25 日

【 学位論文題目 】

部分空間法に基づくサポートベクトルマシンに関する研究

審 査 委 員

主 査 教 授 阿部 重夫  
教 授 増田 澄男  
教 授 八坂 保能

氏名	北村 拓也		
論文 題目	部分空間法に基づくサポートベクトルマシンに関する研究		
審査委員	区分	職名	氏名
	主査	教授	阿部 重夫
	副査	教授	増田 澄男
	副査	教授	八坂 保能
	副査		
			印
要 旨			
<p>近年注目を集めているサポートベクトルマシン (SVM) は、統計的学習理論に基づいて、学習に用いていないデータに対する識別能力、すなわち汎化能力を最大にする学習を行うことにより、パターン認識器を構成する。これに対して部分空間法は日本で独自の発展を遂げたパターン認識手法である。主成分分析等により各クラスの部分空間を定義し、部分空間を張る固有ベクトルを用いて各クラスの類似度を定義し、未知のデータに対してどのクラスにもっとも類似しているかで認識を行なう。</p> <p>本論文では、SVM と部分空間法を融合することにより、SVM の高い汎化能力と部分空間法の解析容易性の両方の特徴を兼ね備えた部分空間法に基づいた SVM (SS-SVM) とその学習方式を提案している。以下に各章の構成を示す。</p> <p>第1章では研究の背景および本論文のアプローチを述べている。第2章で部分空間法および SVM の理論の概略を述べている。</p> <p>第3章では、部分空間法と SVM の3つのモデル、すなわち LS-SVM (最小自乗 SVM)、LP-SVM (線形計画 SVM)、L2-SVM (L2 ノルムの SVM) を融合して、各々 SSLS-SVM、SSLP-SVM、SSL2-SVM を提案している。すなわち、まず各クラスに属するデータに対してカーネル主成分分析 (KPCA) を行い、各クラス領域を定義し、データの各クラスに対する射影長に対して重みを付与して、この重みを SVM のマージン最大化の原理を用いて最適化することにより汎化能力の向上を図っている。提案方式をベンチマークデータで評価した結果、従来の部分空間法に対して汎化能力が向上すること、さらに識別結果が解析できることを示している。</p> <p>上記の方法では、部分空間を張る固有ベクトルは、対応する固有値の大きい順に選択する方法をとっているが、第4章では、汎化能力をさらに向上するために、部分空間を構成する固有ベクトルを最適化された重みの絶対値の大きさにより選択する方法を提案している。また、ももとの部分空間法では、各クラスの部分空間を他のクラスの部分空間とは独立に構成するために、重みはすべて正となるが、クラス間の重なりを解消するために負の重みが必要であること、また負の重みを導入することにより、汎化能力が向上することを示している。</p> <p>第3章で提案している方式では、すべてのクラスを含む部分空間を張るベクトルをまず選択し、この部分空間で各クラス毎に部分空間を構成しているが、この方式では全体の部分空間の次元が大きくなるために、大規模な問題では学習が遅くなる。第5章では、この問題を解決するために、各クラス毎にそのクラスに属する教師データにより部分空間を構成する方法を提案している。しかし、このままでは、データのクラスに対する射影長の比較が正確に行なえなくなり汎化能力が低下するために、射影長の正規化を行なう処理を導入している。これにより、部分空間の次元が小さくなり、学習の高速化を実現している。</p> <p>汎化能力の高い SS-SVM を構成するためにはパラメータの値の最適化が必要になるが、第6章では、パラメータの最適化処理を軽減する多重構造の部分空間法を提案している。すなわち、異なる特性の部分空間を複数個用意し、各部分空間に対して重みを付与して、SVM の最適化により自動的に最適な部分空間を選択している。ベンチマークデータによる計算機実験では、多少汎化能力が低下するが、学習の高速化が図れることを示している。</p> <p>7章は、研究の結論と今後に残された課題を述べている。</p> <p>以上のように、本研究は部分空間法とサポートベクトルマシンについて、その融合方式を研究したものであり、認識能力および認識の解析可能性について重要な知見を得たものとして価値ある集積であると認める。よって、学位申請者北村拓也は、博士 (工学) の学位を得る資格があると認める。</p>			

(氏名： 北村拓也 NO. 1 )

パターン認識において代表的な識別器として部分空間法やサポートベクトルマシン (SVM: Support Vector Machine) などがある。部分空間法はクラスごとに部分空間を生成することで情報を大幅に削減し、同時に識別処理を行える。しかしながら、識別性能が極めて低い。SVMではマージン最大化を基準に識別ルールを決定することで識別性能が極めて高いが識別部がブラックボックスである。これらのため、近年、部分空間法とSVMの改良に関する研究が活発になされている。本論文では、部分空間法にSVMのマージン最大化の概念を取り入れた部分空間法に基づくSVM (SS-SVM: Subspace-Based Support Vector Machine) とSS-SVMの改良手法を提案する。SS-SVMはそれらの部分空間を構成する軸に対して、それぞれクラスの部分空間の分離、すなわちマージンが最大となるような重みを決定し、重み付けすることにより、識別性能を向上させる。これにより、情報量を大幅に削減でき、識別性能が高く、解析可能な識別手法といえる。また、SS-SVMに対して以下の3つの観点から改良を加える。

- (1) SS-SVMにより識別の観点から最適化された重みを用いた特徴選択によるさらなる識別性能の向上
- (2) 部分空間生成における解くべき問題を縮小することによる学習コストの削減
- (3) モデル選択に要する学習コストの削減

第1章では、研究背景、研究目的、本論文の構成を述べる。第2章では、従来手法である部分空間法とSVMの理論の概略とSVMの多クラス問題への拡張方式、またそれらに広く用いられているカーネル法と代表的なモデル選択である $k$ 分割交差検定法について述べる。

第3章ではSS-SVMを提案する。ここで、一次の連立方程式を解く最小自乗サポートベクトルマシン (LS-SVM: Least Squares Support Vector Machine) を適用した部分空間法に基づくLS-SVM (SSLS-SVM: Subspace-Based Least Squares Support Vector Machine)、線形計画問題を解く線形計画サポートベクトルマシン (LP-SVM: Linear Programming Support Vector Machine) を適用した部分空間法に基づくLP-SVM (SSLP-SVM: Subspace-Based Linear Programming Support Vector Machine)、アクティブ集合を用いた学習法が適用可能であるL2サポートベクトルマシン (L2-SVM: L2 Support Vector Machine) を適用した部分空間法に基づくL2-SVM (SSL2-SVM: Subspace-Based L2 Support Vector Machine) の3つのモデルを提案する。SSLS-SVMでは部分空間の次元数が少なければ学習コストが非常に小さくなる。SSLP-SVMでは識別と同時に特徴選択が行える。SSL2-SVMではサポートベクトル数が少なければ学習コストが非常に小さくなる。計算機実験により、通常の部分空間とSVMと比較することでSS-SVMの有効性を示し、また、それら3つのモデル同士で比較・評価を行う。最後に、SS-SVMの識別部の解析を行う。

第4章では、SS-SVMにおける負の重みをもつ軸の識別への影響の確認とSS-SVMにおける識別性能をさらに向上させるために重みに基づく特徴選択手法を提案する。SS-SVMでは通常

の部分空間法とは異なり、重みの値が負となりうるため、非負制約を設けたSS-SVMと比較することによりそれらの軸が識別において重要となりうることを確認する。また、SS-SVMにおいて各クラスの部分空間を構成する軸の選択を他のクラスの分離を考慮して決定された重みの値に基づいて行う。これにより識別性能を向上させる。計算機実験では、はじめに非負制約を設ける場合と設けない場合のSS-SVMを比較することにより負の重みをもつ軸が重要となりうることを確認する。また、重みの絶対値に基づく軸の選択処理を行うSS-SVMを通常の部分空間法とSS-SVMとSVMとの識別性能を比較することにより、有効性を示す。その際に軸がどれほど削減されているかの確認と最適化された重みと固有値の関連性の解析を行う。

第5章では、SS-SVMにおける学習コスト削減のため、標本特徴空間の縮小と標本部分空間法に基づくSVM (ES-SVM: Empirical Subspace-Based Support Vector Machine) を提案する。1つ目の手法では、SS-SVMにおける部分空間生成の前処理としてあらかじめ写像する標本特徴空間の生成をクラスごとに別々に行う。これにより、その次元数を削減し、部分空間生成の際に用いるカーネル主成分分析 (KPCA: Kernel Principal Component Analysis) の学習コストを大幅に削減できる。2つ目の手法では、各クラスの教師ベクトルそのものを部分空間を構成する軸として取り扱うことによりKPCA の処理を省き、学習コストを削減する。計算機実験により、これらの学習の高速化を示し、また識別性能も劣化しないことを示すことにより有効性を示す。

第6章では、複数のカーネルパラメータにおける部分空間を考慮することによる部分空間法の識別性能を向上させ、SS-SVMと比べてモデル選択に要する学習コストを削減できる多重非線形部分空間法に基づくSVM (MNS-SVM: Multiple Nonlinear Subspace-Based Support Vector Machine) を提案する。MNS-SVMでは、あらかじめ五分割交差検定法によりカーネルパラメータをひとつ決定するのではなく、複数のカーネルパラメータを選択する。次にそれぞれのカーネルパラメータにおけるクラス部分空間を生成する。そして、それらを構成する軸に対して重み付けを行うのではなく、それらの部分空間への射影長をひとつの特徴量とし、カーネルパラメータ数個の特徴量に対してSVMにより重み付けを行うことにより従来のKSMに比べ汎化能力を向上させる。これにより、複数のカーネルパラメータにおける部分空間を考慮でき、どれかひとつのみを選択する必要がない。さらに、あらかじめ選択すべきパラメータの中からカーネルパラメータを削除できるため、モデル選択における学習コストも大幅に削減できる。計算機実験により、通常の部分空間法と識別性能の比較、またSS-SVMとのモデル選択における学習時間のSS-SVM との比較を行うことによりMNS-SVMの有効性を示す。

第7章では、本論文のまとめと今後の課題を述べる。