

博士論文審査結果報告書

論 文 題 目

**Study on Quasi-Linear Kernel Composition for Support
Vector Machines using Supervised, Unsupervised and
Transfer Learning**

申 請 者

Weite LI

情報生産システム工学専攻
ニューロコンピューティング研究

2019 年 1 月

パターン分類は機械学習において重要な研究課題の一つであり、スパムメールフィルタリング、遺伝子同定、タンパク質分類など、広い分野で応用されている。分類器は、訓練用データサンプルセットから学習することによって構築される。すなわち、データから特定の分類規則を獲得されることにより、新しいデータに対しても正しく分類が行われることが期待される。サポートベクターマシン (Support Vector Machine: SVM) は、マージン最大化によって優れた汎化性等の性能を持つ線形分類器として近年多くの注目を集めている。また、SVM はカーネル法によりデータを高次元特徴空間に写像することによって非線形分類問題を扱うことを可能にしている。従来の SVM モデルでは基本カーネル関数あるいはこの基本カーネルの組合せで合成されるカーネル関数を利用しているが、基本カーネル関数の形が固定されているので、分類境界線に関する先見情報があっても利用しにくいという問題がある。それに対して先行研究 (Zhou et al., 2014) では、分類境界線を近似する局所線形モデルの情報で準線形カーネル関数を合成する準線形 SVM が提案されている。モデリングの観点からみれば、準線形 SVM では Coarse-to-Fine という二つのステップからクラス間の分類境界線のモデルを構築している。Coarse-step では、複数の局所的線形モデルを補間し線形回帰で表現される非線形モデルを構築する。一方、Fine-step では、Coarse-step で得られた回帰ベクターの内積をカーネル関数として利用し SVM でモデルの線形パラメータを更に最適化することによってマージン最大化分類器を実現している。SVM の観点からみれば、Coarse-step では、SVM のためのカーネル関数の合成を行っている。しかし、体系的な合成法はまだ課題として残っている。

そこで本研究では、上記の課題を解決するため、クラス間の分類境界線を近似する三つの非線形モデルおよびパラメータ推定法を提案している。まず、ラベル付データが十分ある場合に、ラベル情報を活用し幾何法によりラベルが異なるサンプルの凸包集合の線形識別モデルを構築することによって線形回帰で表現される分類境界線の非線形モデルを構築し、教師有り学習で SVM のためのカーネル関数を合成している (第 2 章)。次に、データが十分あるが、ラベル付データが少ない場合に、Winner-take-all Autoencoder でパーティションする方法を導入し、分類境界線の区分線形モデルを構築することによって、教師なし学習で SVM のためのカーネル関数を合成している (第 3 章)。最後に、データが少ない場合に、他のドメインのデータで訓練済多層パーセプトロンを利用し分類境界線の区分線形モデルを構築することによって、転移学習で SVM のためのカーネル関数を合成している (第 4 章)。

以下に、本論文の構成と各章の概略について述べ、評価を与える。

第 1 章では、非線形分類、SVM およびカーネル法、カーネル関数の合成問題について述べ、本研究の背景・目的を明らかにしている。

第 2 章では、教師有り学習で SVM のためのカーネル関数を合成する方法に

について述べている。まず、データサンプルのラベル情報を利用して分類境界線付近のデータサンプルを検出し、分類境界線に沿ってそれぞれのクラスのデータサンプルからなる凸包集合を多数作成する。次に、幾何法で異なるクラスの凸包集合の間に線形識別モデルを多数構築する。最後に、数多くの線形識別モデルに対しグリーディ法を用いて最小限の線形識別モデルを残すように分類境界線を近似する局所線形モデルを自動的に抽出し、線形回帰で表現される非線形モデルを構築する。これにより、教師あり学習で SVM のためのカーネル関数の合成を行っている。性能評価の数値例では、提案された SVM と従来のマルチ線形 SVM (PSVM, H.Cheng et al. 2010) を Yeast Gene Data からなる 10 のベンチマークデータセットに適用して比較し、総合評価 F-score では、9 データセットで提案された SVM が従来の PSVM より優れており、1 データセットで従来の PSVM が優れていた (以降これを win/tie/lose で 9/0/1 と記す)。また、教師あり学習で合成されたカーネル関数を用いた SVM と従来の RBF (Radial Basis Function) カーネル関数および線形カーネル関数を用いた SVM と比較した結果、総合評価 F-score では、win/tie/lose でそれぞれ 10/0/0 と 10/0/0 となり、提案された教師あり SVM のためのカーネル関数の合成法が有効であることを明らかにしている。

第 3 章では、教師なし学習で SVM のためのカーネル関数を合成する方法について述べている。まず、ゲート付線形ネットワークを利用し間接的な方法で区分線形モデルの構築を行う。これにより、パーティション問題はより簡単な 2 進数配列となるゲート制御信号を生成することに変換される。次に、Winner-take-all Autoencoder というスパースモデリング技術で多様なゲート制御信号を生成し、柔軟な区分線形モデルを構築することによって、クラス間の分類境界線を近似する線形回帰で表現される非線形モデルを構築する。これにより、ゲート制御信号でカーネル関数を合成する方式を提案し、データのラベル情報があれば活用して、またラベル情報がなければ、Autoencoder で抽出したデータのマニフォールド情報を含んだゲート制御信号に基づいて、教師なしで SVM のためのカーネル関数の合成する手法を実現している。性能評価の数値例では、提案された SVM と従来の局所的線形 SVM (LLSVM, L.Ladicky and P.Torr, 2011) を UCI 機械学習リポジトリのデータセットからなる 10 のベンチマークデータセットに適用して比較した結果、正確度では、win/tie/lose で 7/2/1 となった。また、教師なし学習で合成されたカーネル関数を用いた SVM と従来の RBF カーネル関数および線形カーネル関数を用いた SVM と比較した結果、正確度では、win/tie/lose でそれぞれ 10/0/0 と 10/0/0 となり、提案された教師なし SVM のためのカーネル関数の合成法が有効であることを明らかにしている。

第 4 章では、転移学習で SVM のためのカーネル関数を合成する方法について述べている。まず、ReLU 活性化関数を持つ多層パーセプトロンモデルを用いて、クラス間の分類境界線のモデリングを行う。次に、多層パーセプトロン

モデルに対して、活性化関数 $\text{ReLU}(x) = \max\{0, x\}$ をゲート付線形ユニットとみなして、ゲート付多層線形ネットワークと多層パーセプトロンによるゲート信号生成器とのそれぞれ独自のパラメータを持つ二つ部分に分離する。ゲート付多層線形ネットワークで区分線形モデルを構成することにより、分類境界線を近似する線形回帰で表現される非線形モデルを構築する。これにより、多層パーセプトロンで生成するゲート信号を用いた深層カーネル関数の合成方法を提案している。また、多層パーセプトロンの事前訓練が必要であるが、データが十分であればそれを活用して、データが十分でなければ、別のドメインのデータを用いて、転移学習で多層パーセプトロンの訓練を行う。これにより、転移学習で SVM のための深層カーネル関数の合成を実現している。性能評価の数値例では、提案されたカーネル関数を用いた SVM と従来の RBF カーネル関数を用いた SVM を MNIST とその変種からなる 7 つのベンチマークデータセットに適用して比較し、正確度では、win/tie/lose で 7/0/0 となった。また、ベンチマークデータセット CIFAR-10 と CIFAR-100 では、従来の転移学習を用いた深層ニューラルネットワーク(Deep Neural Network: DNN)分類器と比較した結果、提案された深層カーネル関数を合成し利用した SVM で、それぞれ 3.8% と 4.7% の正確度の向上となり、提案された転移学習で得られた深層カーネル関数の有効性が明らかにされている。

第 5 章では結論として、本研究の成果について総括し、今後の研究課題を論じている。

以上を要約すると、本論文では、線形回帰で表現される三つの非線形モデルとパラメータ推定法を提案し、クラス間の分類境界線をモデリングすることによって、教師あり学習、教師なし学習および転移学習でデータのマニフォールド情報を含んだ準線形カーネル関数の合成を行っている。また、提案された SVM のためのカーネル関数の合成法を複数の実世界のデータセットに適用しその有効性を明らかにしている。これらの成果は機械学習、ニューロコンピューティング分野の発展に寄与するところ大である。よって、本論文は、博士(工学)の学位論文として価値あるものと認める。

2019 年 1 月 9 日

審査員

主査	早稲田大学	教授	博士(情報工学)(九州工業大学)	古月 敬之
副査	早稲田大学	教授	工学博士(早稲田大学)	吉江 修
	早稲田大学	教授	博士(工学)(早稲田大学)	藤村 茂