

Support Vector Machine による過渡安定度判定

日大生産工 (院) ○長峯 豊
日大生産工 佐藤 正弘

1. まえがき

電力系統は広域にわたり複雑に構成されており、系統事故が広域停電へと発展する場合がある。このため、与えられた系統状態のもとで予め想定した系統事故が発生した場合、それが安定か不安定かを予測し、対策をたてる予防制御を施す必要がある⁽¹⁾。

予防制御の手段として、ある系統状態で発電機が脱調するか判断する過渡安定度判定がある。

過渡安定度判定を実際に行うには、リアルタイムに測定したデータを用い、評価する必要がある。本稿では、パターン認識の一手法である、Support Vector Machine (以下 SVM) を用いてその評価を行い、前研究⁽²⁾で行ったニューラルネットワーク (以下 NN) による手法と比較検討も併せて行う。

2. 過渡安定度判定の手法

2.1 線形 SVM

サポートベクターマシン (SVM) は 2 クラスの分類問題を解くための線形識別器である。その手法は、ユークリッド空間上で学習サンプルの中から別クラスと最も近いサンプルを各クラスで選出し、各クラスの凸包を結んだ線分の中点を直交するように識別境界となる超平面を設定し、クラスの分類を行うものである。図 1 にその概念を、以下に過程を示す。

線形識別関数を以下のように置く。

$$f(x) = \text{sign}(g(x)) \quad \cdots (1)$$

$$g(x) = \mathbf{w}^t \mathbf{x} + b \quad \cdots (2)$$

ただし、 $\mathbf{x}$ は学習サンプル、 $\mathbf{w}$ は重みベクトル、 b はバイアス項であり、上付きの t は転置を示す。

ここで、学習サンプルを完全に線形識別できるものと考え、以下のようにクラス y_A, y_B を分類するものとする、

$$g(x) = \mathbf{w}^t \mathbf{x}_i + b \quad \begin{cases} \geq 1 & \text{if } \mathbf{x}_i \in y_A \\ \leq -1 & \text{if } \mathbf{x}_i \in y_B \end{cases} \quad \cdots (3)$$

学習サンプル $\mathbf{x}_i$ と識別境界との最小距離は、

$$\min_{i=1, \dots, n} \frac{|\mathbf{w}^t \mathbf{x}_i + b|}{\|\mathbf{w}\|} = \frac{1}{\|\mathbf{w}\|} \quad \cdots (4)$$

であり、この範囲に学習サンプルが存在しないことを意味する。つまり、 $-1 < g(x) < 1$ の範囲に学習サンプルが存在しない




図 1. 線形 SVM の概念

ように $1/\|\mathbf{w}\|$ の値が最大となる $\mathbf{w}$ と b の値を設定する。これを最大化すれば良いので、(4)式を各クラスで考慮した $2/\|\mathbf{w}\|$ を扱い易くし、目的関数を以下のように定義する。

$$\min_{\mathbf{w}} \frac{1}{2} \|\mathbf{w}\|^2 \quad \cdots (5)$$

$$\text{制約条件 } y_i(\mathbf{w}^t \mathbf{x}_i + b) - 1 \geq 0 \quad \cdots (6)$$

ここで、重みベクトル $\mathbf{w}$ 、バイアス項 b をラグランジュの未定乗数法を用いてラグランジュ乗数ベクトル $\boldsymbol{\lambda}$ を学習により算出することで求めることを考えると、ラグランジュ関数 L_p は、

$$L_p(\mathbf{w}, b, \boldsymbol{\lambda}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \lambda_i \{y_i(\mathbf{w}^t \mathbf{x}_i + b) - 1\} \quad \cdots (7)$$

最適解において、 L_p の勾配が 0 になると考えると、 $\mathbf{w}$ 、 b で偏微分することにより、以下の関係が導かれる。

$$\sum_{i=1}^n \lambda_i y_i = 0 \quad \cdots (8)$$

$$\mathbf{w} = \sum_{i=1}^n \lambda_i y_i \mathbf{x}_i \quad \cdots (9)$$

これらを(7)式に代入すると、以下のような $\boldsymbol{\lambda}$ のみに関する最大化問題となる。

$$\max_{\boldsymbol{\lambda}} \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i,j=1}^n \lambda_i \lambda_j y_i y_j \mathbf{x}_i^t \mathbf{x}_j \quad \cdots (10)$$

$$\text{制約条件 } \lambda_i \geq 0, \quad \sum_{i=1}^n \lambda_i y_i = 0 \quad \cdots (11)$$

最適な $\boldsymbol{\lambda}$ から、(9)式を用いて $\mathbf{w}$ を算出する。 b は(6)式の関係より、以下のように求められる。

$$b = -\frac{1}{2}(\mathbf{w}'\mathbf{x}_A + \mathbf{w}'\mathbf{x}_B) \quad \cdots (12)$$

ここで、 $\mathbf{x}_A$, $\mathbf{x}_B$ はそれぞれクラス y_A , y_B に属するサンプルであり、 λ_A , λ_B は正となる。この $\lambda_i > 0$ のサンプル $\mathbf{x}_i$ をサポートベクターと呼び、図1では○で囲んで示した。

また、完全に線形分離できない場合、(11)式を次のように変更すると、制約条件を緩めることができる。この手法はソフトマージンと呼ばれる。

$$\text{制約条件} \quad 0 \leq \lambda_i \leq C, \quad \sum_{i=1}^n \lambda_i y_i = 0 \quad \cdots (13)$$

C は制約条件を緩めるためのパラメータで、実験的に設定を行う。

〈2.2〉 非線形 SVM

元の特徴空間におけるベクトル $\mathbf{x}_i$ を線形分離可能な別の特徴空間に変換する $\Phi(\mathbf{x})$ を考えると、(9)式より、

$$\mathbf{w} = \sum_{i=1}^n \lambda_i y_i \Phi(\mathbf{x}_i) \quad \cdots (14)$$

(14)式を(2)式に代入し、識別関数を得ると、

$$g(\mathbf{x}) = \sum_{i=1}^n \lambda_i y_i \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}) + b \quad \cdots (15)$$

このとき $\Phi(\mathbf{x})$ の高次のベクトル内積はカーネルトリックと呼ばれる手法により、以下のようにカーネル関数 K で置き換えることができる。

$$K(\mathbf{x}, \mathbf{x}_i) = \Phi(\mathbf{x})^T \Phi(\mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2\sigma^2}\right) \quad \cdots (16)$$

カーネル関数 K はいくつかの手法が提案されているが、今回は(16)式のガウシアンカーネルを使用した。ここで σ は分散を示し、指定値である。

これらにより、識別関数、目的関数は以下のように置き換えられる。

$$g(\mathbf{x}) = \sum_{i=1}^n \lambda_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \quad \cdots (17)$$

$$\max_{\lambda} \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i,j=1}^n \lambda_i \lambda_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad \cdots (18)$$

$$\text{制約条件} \quad 0 \leq \lambda_i \leq C, \quad \sum_{i=1}^n \lambda_i y_i = 0 \quad \cdots (19)$$

〈2.2〉 ニューラルネットワーク

ニューラルネットワークとは、生体の神経細胞 (neuron) の構造を模倣し、それらを組み合わせることにより人口神経細胞網 (Artificial Neural Network) をつくり、与えられたパターンの相関を学習しようとする知的情報処理技術の一手法である。各ニューロンの働きを以下に示す。

$$z = f\left(\sum_{i=1}^d x_i w_i - \theta\right) \quad \cdots (20)$$

$$f(x) = \frac{1}{1 + \exp(-x)} \quad \cdots (21)$$

$$E(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^n (z_i - t_i)^2 \quad \cdots (22)$$

ただし $\mathbf{w}$ は各ニューロン間の結合係数、 θ は閾値を示す。

(20)式に示すように、各ニューロンが d 次元のサンプル $\mathbf{x}$ を入力したとき z を出力される。これを(22)式のように、出力値 z と教師値 t の二乗誤差を、入力サンプル数 n 個分とった評価関数より、結合係数 $\mathbf{w}$ を修正することで学習を行う。

3. 学習の手法

〈3.1〉 最急降下法による学習

SVM, NN とともに学習に最急降下法を用いた。SVM の目的関数(11), (18)式を $F(\lambda)$ と置き、 λ に関して最急降下法を適用すると、(23)式に、同様に NN の評価関数(22)式を w に関して適用し、(25)式のように計算を行った。

$$\lambda_i' = \lambda_i + \eta \frac{\partial F(\lambda_i)}{\partial \lambda_i} \quad \cdots (23)$$

$$\mathbf{w}' = \mathbf{w} - (1 - \alpha) \eta \frac{\partial E(\mathbf{w})}{\partial \mathbf{w}} + \alpha \Delta \mathbf{w}^{old} \quad \cdots (24)$$

ただし、 λ' , $\mathbf{w}'$ はそれぞれ更新後の値、 η は学習係数、 α は慣性定数、 $\Delta \mathbf{w}^{old}$ は前回更新時の変化分を示す。

この最急降下法を用いて学習した結果から、SVM においては重みベクトル $\mathbf{w}$ を決定、識別関数 $g(\mathbf{x})$ が正の値であれば安定、負の値であれば不安定と識別する。

NN においては更新されたネットワークに再度 $\mathbf{x}$ を入力し、その出力結果、 $z < 0.2$ なら安定、 $z > 0.8$ ならば不安定、それ以外の値は曖昧であると判定することとした。

〈3.2〉 ネットワークの感度解析による使用変数の選択^②

NN において前研究で行った感度解析による使用変数の選択を用いた。以下にその手法を示す。

まず、学習を行うのに十分な大きさを持ったネットワークを構築し、ある程度まで収束させる。そのとき学習の過程で入力が出力に及ぼす影響を、以下の(25)式に示す感度解析 (sensitivity analysis) によって算出する^④。

$$Sens = \left(\left(w^f \right) / \eta \left(w^f - w^i \right) \right) \cdot \sum_n [\Delta w(n)]^2 \quad \cdots (25)$$

ただし $Sens$ を感度、 w^i を学習前の重み、 w^f を学習後の重みとする。

算出した感度を元に影響力の少ないニューロン及び不必要な接続を見つけ、ネットワークから取り除き、必要な接続のみでネットワークを再構成する。この過程をプルーニング^④と呼ぶ。プルーニングを行ったネットワークはさらに最初の学習プロセスに戻ることによって、誤差をより小さくすることが可能と考えられる。

同一入力層ニューロンからの接続の感度の大きさが、システムに与える影響力であると考え、その平均感度の小さなニューロンから順に削除し、ネットワークに影響のある入力変数の選定を行う。

4. シミュレーションによる有効性の確認

本稿では、図2に示す電気学会EAST10機系統モデル⁽⁵⁾を用いて検討を行った。まず、各発電機出力、負荷、母線電圧について、正規乱数を用いてばらつきを与えたデータを作成する。そのデータを基に次の想定事故を考え、過渡安定度計算を行い、結果より各母線の電圧 V 、電圧位相 θ の値、計94個を安定度判定における変数として用いる。入力データは範囲スケールによる正規化を行い、0～1のアナログ値として用いた。

4.1 想定事故1 線路<11>一回線地絡事故

想定事故として線路<11>の母線(11)側において一回線地絡事故が0.07[s]継続するものとした。事故対象は一波脱調とし、脱調パターンはG1が単機で脱調する型である。この想定事故について、405ケース（安定パターン223ケース、不安定パターン182ケース）を用意し、安定度判定を行った。

用意した全405ケースのうち、305ケースを学習用サンプルとして、残り100ケース（安定50ケース、不安定50ケース）をテスト用サンプルとして用い、SVM、NNそれぞれ判定を行った。また、感度解析による使用変数の選択も併せて行い、使用変数による誤判定の違いを得た。その結果を表1と図3に示す。なお線形SVMの結果はソフトマージンを用いてのものである。

94変数を用いた場合でNNの誤判定には曖昧と判定されたものを含むため、単純な比較はできないが、ネットワークの出力値が0.5を基準に安定と不安定を判定するものとする、誤判定は1個のみであり、非線形SVMと同等の識別率であるとも考えられる。

感度解析により使用変数を選択していくと、図3の結果

表1. 想定事故1の判定結果

判定手法	誤判定数		
	94変数	3変数	2変数
線形SVM	6	3	4
非線形SVM	1	0	1
NN	14	0	3




図2. 電気学会EAST10機系統モデル⁽³⁾




図3. 変数の数に対する識別誤差（想定事故1）




図4. angle11 と angle1 の値の分布（想定事故1）

にあるように3変数のときも誤判定が少なかったため、感度の高かった順に母線(1)、(11)の位相差(angle1、angle11)と母線(11)の電圧(voltage11)を変数として用いている。また、わかりやすくするため、中でも感度の高かったangle1とangle11の分布の様子を図4に示した。

どの判定手法においても3変数のときに最も誤判定が少なく、これは、3次元から2次元にした際必要な特徴情報が欠け落ちたことを示していると考えられる。

いずれの結果でも非線形SVMは良好な識別率を持っているが、計算時間はNNよりも多くかかった。

4.2 想定事故2 線路<18>二回線地絡事故

次に線路<18>の母線(13)側において二回線地絡事故が0.07[s]継続する事故を想定した。10秒以内にいずれかの発電機が脱調している場合不安定、回復するものを安定とした。この想定事故について、837ケース（安定パターン521ケース、不安定パターン316ケース）を用意し、そのうち737ケースを学習サンプルとして残り100ケースをテスト用サンプルとして用いて、安定度判定を行った。その結果を表2に、感度解析による誤判定数を図5に示す。

表2. 想定事故2の判定結果

判定手法	誤判定数			
	94変数	18変数	7変数	2変数
線形SVM	11	5	7	22
非線形SVM	4	1	1	18
NN	9	1	5	66




図5. 変数の数に対する識別誤差 (想定事故2)




図6. voltage22 と voltage31 の値の分布 (想定事故2)

図5にあるようにNNの場合変数がある程度減らすまで一定の誤差がでてしまう。これは、ある変数がノイズとなり、局所解に陥ったためと考えられる。非線形SVMはこれによらず、良好な識別率を持つ。

また、この想定事故では6変数以下とすると、どの手法を用いても誤判定が増える。これは、特徴を現す次元が大きいため、6変数では事故ケースの特徴を現しきれなかったと考えられる。

想定事故1と同様に、感度の高い2変数、母線(22)と(31)の電圧の値を分布したものを図6に示した。安定と不安定のサンプルが混ざり合っているため、パターンを把握し難い。線形SVMである程度分類できているのは、未知のパターンが識別境界から遠い場所に多く分布していたためである。非線形SVMにおいても同様である。しかし、ソフトマージンのパラメータを変更することで、ある程度誤差を減らすことはできた。これはテストサンプルに対して有効であっただけで、汎化能力が向上したとは判断できない。

また、誤判定、曖昧な判定となったサンプルについては、過渡安定度計算の結果、発電機G1の基準母線G3との位相差をプロットした電力動揺のグラフより、その特性を調べると、図7のような特性を持つサンプルがいくつかあった。図は想定事故1において94変数を用いて非線形SVMで判定を行った際に誤判定となったサンプルのものである。

本稿でのサンプルの採集は、2[sec]以内に位相差が180[deg]を超えていないものを安定、超えて上昇をつづけるものを不安定としてクラス分けを行っているが、この図では2[sec]を超えてから脱調している。このような場合は




図7. 曖昧な判定サンプルの電力動揺例

安定度限界に属すると考えられる。NNではこれを曖昧であると判定することによって、安定限界である可能性を検討することができる。SVMでは識別関数 $g(x)$ の値によって、検討することが可能であるが、ソフトマージンの能力と重なる点が多く、その判断が難しい。

5. まとめ

以上の結果より、SVMによる安定度判定の妥当性と、感度解析による変数選択によって、SVMにおいても識別能力が向上することを確認した。また、SVMとNNで安定度判定を行い比較した際にSVMが以下のような特徴を持っていることを確認した。

- ・高い識別能力
- ・過学習の問題が無く汎化能力に優れる
- ・ソフトマージンにより識別境界を調整できる
- ・局所解に陥ることがない
- ・カーネルの選択、パラメータの決定を行う必要がある
- ・計算時間が長い

中でも汎化能力、過学習の問題が無い点、局所解に陥ることがない点は非常に優れた点と言える。

しかし、今回作成したプログラムでは、計算時間がNNよりも数倍の時間を要する。これは、先のカーネルの選定、パラメータの決定とともに、計算量を削減するアルゴリズムを考え、また、その他の特徴抽出の手法との組合せも今後の課題とする。

参考文献

- (1) 関根他：「電力系統工学」，コロナ社 (1979),p1
- (2) 長峯豊，及川昭，佐藤正弘：「ニューラルネットワークによる過渡安定度における使用変数の選択法」，平成18年電気学会全国大会講演論文集[6](2006)，pp.275-276
- (3) 前田英作：「痛快！ サポートベクトルマシン ～古くて新しいパターン認識手法～」，情報処理学会誌，Vol.42，No.7，(2001)., pp.676-683
- (4) Bahman Kermanshahi：「ニューラルネットワークの設計と応用」，昭晃堂 (1999),p18,pp.61-72, pp.43, pp.49-50
- (5) 電力系統モデル標準化調査専門委員会：「電力系統の標準モデル」，電気学会技術報告，第754号(1999-11)