

ニューラルネットワークを用いた電力システムの過渡安定度判定

日大生産工 (院) ○長峯 豊
日大生産工 (院) 及川 昭
日大生産工 佐藤 正弘

1. まえがき

電力システムとは、電気エネルギーを発生してから消費するまでの一連のプロセス、すなわち発電所で発生した電力を送電線、変電所、配電線を介し、工場や家庭に供給するシステムである⁽¹⁾。

電力システムはライフラインとして欠かすことのできないシステムであり、電力供給に支障があった場合、国民生活、経済活動など、無数の場面で甚大な被害を及ぼすことが懸念される。

このシステムは広域にわたり複雑に構成されており、系統事故から広域停電へと波及する可能性がある。この対策のため、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、それが大きな事故波及につながるかどうか絶えず予測し、対策をたてるための予防制御を施しておくことが必要である。

電力システムの安定度の指標として、定態安定度、過渡安定度がある。前者は電力システム内の各要素が擾乱に対して平衡状態を維持し得る能力、後者は平衡状態が崩れた場合に再び平衡状態に回復し得る能力を示す。

予防制御の手段として、与えられた系統状態をもとにその過渡安定度を判定することが考えられる。

過渡安定度判定は、多くの事故を想定し、各想定事故において過渡安定度計算を行い、そのサンプルを用いて種々の手法で安定度の評価をするものである。

本稿では過渡安定度判定を、ニューラルネットワークを用いたパターン認識で行う。

ニューラルネットワークで学習を行う際、入力に用いる変数、中間層の数、学習係数など多くの値を最適に設定する必要があるが、特にネットワーク規模と学習精度に関する問題を主に考える。

2. 過渡安定度判定の手法

本稿では過渡安定度判定に、誤差逆伝播法⁽²⁾ (Back

Propagation) を用いたニューラルネットワークによるパターン認識を用いる。

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工神経細胞網 (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。

図 1 に本稿でも用いている階層型ニューラルネットワークの構造例を示す。この例における、各ニューロンでの計算と、出力に用いた関数を以下に示す。

$$h_1 = x_1 w_1 + x_2 w_2 - w_3 \quad \dots (1)$$

$$h_2 = x_1 w_4 + x_2 w_5 - w_6 \quad \dots (2)$$

$$z = f(f(h_1) \cdot w_7 + f(h_2) \cdot w_8 - w_9) \quad \dots (3)$$

$$f(x) = \frac{1}{1 + \exp(-x)} \quad \dots (4)$$

x : 入力値 w : 荷重係数 θ : 閾値

h : 中間層に入力される値 z : 出力値

(1)~(3)式の右辺第3項が w となっているが、図 1 の入力層の最終段に閾値 $\theta = 1$ と置き、そこにかかる荷重係数の値をバイアスとして用いているためである。

ニューロンの働きは本来、ある一定の入力値を超えると信号を出力する、閾値素子となっている。誤差逆伝播法では、荷重係数の修正を行うのに偏微分を用いるため、この働きをある関数で近似することにより、計算を行うが、本稿では(4)式に示すシグモイド関数を用いている。

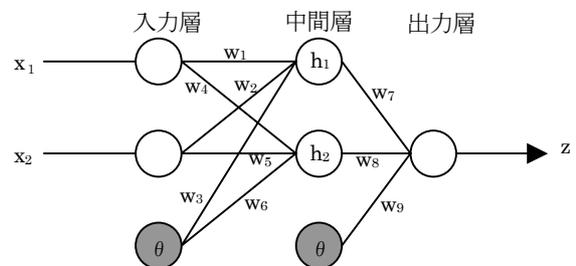


図 1. 階層型ニューラルネットワーク

Method to determine the stability of state in electric power system
using the Artificial Neural Network

Yutaka NAGAMINE, Akira OIKAWA and Masahiro SATO

ニューラルネットワークにおける学習とは、この計算における、荷重係数 w の値を以下の(5)式のように修正していくことにあたる。

$$w^{(k+1)} = w^{(k)} + \Delta w^{(k)} \quad \dots (5)$$

ここで、修正量 Δw は以下の(6)式の評価関数を(7)式のように偏微分することで計算される。

$$E(w) = \frac{1}{2} \sum_i (z_i - t_i)^2 \quad \dots (6)$$

$$\Delta w^{(k+1)} = -(1 - \alpha)\eta \frac{\partial E(w^{(k)})}{\partial w^{(k)}} + \alpha \Delta w^{(k)} \quad \dots (7)$$

$E(w)$: 評価関数 z : ネットワーク出力値

t : 教師信号 η : 学習係数 α : 慣性定数

学習係数 η は w を変化させる割合であり、学習の速さを決めるものである。この値の取り方によっては、学習が振動し収束しない場合があるため、シミュレーションによって経験的に定める必要がある。大規模なネットワークにおいて、 η を大きくすると極大点に収束してしまうことも多い。

慣性定数 α は前回の学習の結果を考慮し、同符号に変動する場合はその勾配を大きく、異符号に変動する場合は勾配を小さくするもので、学習の振動を抑え、収束特性を改善するものである。

電力システムの過渡安定度判定にこれを応用するにあたり、これらの最適値の設定、最適規模のネットワーク構成を行うことにより、高速かつ高精度な過渡安定度判定を望むことが可能であると考えられる。

3. 最適規模ネットワークの構成

パターン認識を行う際、入力ベクトルが多次元である場合、実際にはその認識に寄与しない変数も含まれていることがある。特にニューラルネットワークでは、入力ベクトル、中間層ニューロン、ニューロン間の結合が、それぞれ変数としての役割を果たすため、不用意に中間層のニューロンを増やしてしまうと、学習時間の増加だけでなく、不要な接続に対しての学習をしてしまい、認識精度にも支障をきたす可能性がある。

そこで、プルーニング⁽²⁾ (pruning) 法を用いることによって、最適なニューロン数を選択することを検討する。その過程を以下に示す。

3.1) ネットワークの感度解析

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

中に出力に対する入力の影響を、以下の(8)式に示す感度解析 (sensitivity analysis) によって算出する。

$$Sens = \left(\frac{w^f}{\eta(w^f - w^i)} \right) \cdot \sum_n [\Delta w(n)]^2 \quad \dots (8)$$

$Sens$: 感度 w^i : 学習前の重み w^f : 学習後の重み

この式は、重みの変化分の合計である後の項を算出すると同時に、学習においてその接続が受ける影響を示した前項との掛け合わせで成り立つ。

3.2) プルーニング

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。これがプルーニングのプロセスである。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。

不必要な接続の除去は接続の重みを 0 とすることによって模擬することができる。これにより接続除去後のネットワークの妥当性を確認した後、新しい最適規模のネットワークを再構築する。

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⁽³⁾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、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] 継続したものとした。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) の過渡安定度計算を行い、この結果より、各母線の電圧 V 、電圧位相角 θ を安定度判定における変数として用いる。

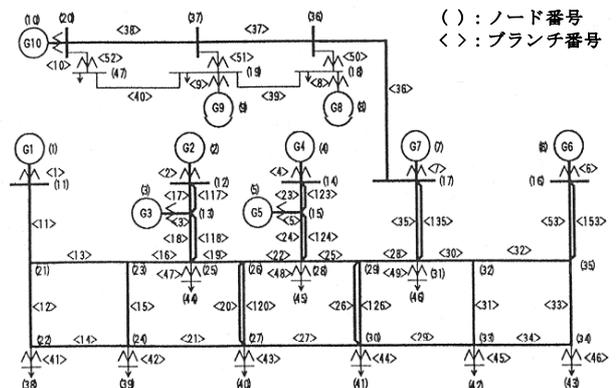


図2. 電気学会EAST10機系統モデル⁽³⁾

4.1 初期ネットワークの構成

本稿ではネットワークにプルーニングプロセスを施すため、初期ネットワークの規模、つまり中間層のニューロン数を大きめにする必要がある。これには、入力と出力の数の平均を取るタンブ法²⁾を用いた。これより、入力層 94、中間層 47、出力層 1 のネットワークを構成した。荷重係数の初期値には正規乱数を用いたばらつきのある値に、以下の(9)式に示す、範囲スケールによる正規化を施し、-0.1~0.1 の間の値とする。入力データに関しても同様に正規化を行い、0~1 のアナログ値として用いた。

$$Y = a \cdot \frac{X - X_{\min}}{X_{\max} - X_{\min}} + b \quad \dots (9)$$

Y : 正規化後の値 X : 正規化対象の値

X_{\max} : 変数 X の最大値 X_{\min} : 変数 X の最小値

a : 正規化後の値の範囲

b : 正規化後の最小値の 0 からの距離

また、学習係数 η 、慣性定数 α の値は、学習の際に振動しない値を試行錯誤的に求めた結果、 $\eta = 0.01$ 、 $\alpha = 0.3$ とした。

荷重係数の更新には 1 セットのデータが与えられるごとに逐次更新する方法と、全セットのデータを与えた後、一括更新する方法があるが、逐次更新では振動が大きくなる点と、学習のデータの並びによる影響が大きくなることを考慮し、一括更新とした。

4.2 ネットワークのプルーニング

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、構成したネットワークに、先に作成した 47 母線の電圧 V と電圧位相角 θ を変数とした 94 個の変数を入力、学習を行う。ネットワーク出力と教師値の二乗誤差の総和を平均したものを総誤差として求め、総誤差が 0.01 以下となるまで繰り返した。

その後(8)式に従って接続感度を計算し、除去する接続とニューロンを選定していく。なお、入力の全てのパターン中で θ_3 は電圧位相角が全て 0 であるが、このノードは出力に一切寄与しないため、感度も 0 と置き、ネットワークから積極的に取り除かれることとなる。

中間層から出力層への接続は、感度が最小となる箇所を探し、それに基づいて削除対象となる感度範囲を決め、中間層のニューロンの削除対象として検討する。

入力層から中間層への接続は、同じ入力層のニューロンからの接続の平均感度が 10^{-3} 以下となる箇所を探し、該当する入力層のニューロンを削除する。

また、同じ中間層のニューロンに接続した、入力層からの接続の感度を合計し、その大きさで順位を決める。その時、順位が半数よりも下回っていれば、その中間層のニューロンを削除する。

なお、入力層、中間層それぞれの最終段のニューロンは閾値で、学習のバイアスとなっているため、これを削除対象とはしない。

以上のルールに従って、入力層 13 個、中間層 9 個のニューロン数を持ったネットワークを再構築した。

これを用いて再学習を行い、総誤差を 10^{-3} まで収束させた結果を、プルーニングを施さず、同様に収束させた結果と共に図 3 に示した。この結果は総誤差が 0.01 になるまで収束させた後、再学習時の計算回数を示したものである。

図 3 より、プルーニングを施した場合、収束までの学習回数が減っていることがわかる。しかしながら、学習精度としては、プルーニングを行わない場合と行った場合とで変わらず、誤判定は 4 点であり、識別率は 95.7[%] となった。いずれも、本来安定であるものが不安定として判定されている。また、判定基準として、ネットワーク出力が 0~0.2 の場合を安定、0.8~1 の場合を不安定とし判定結果としている。0.2~0.8 までのネットワーク出力値の場合、0.5 未満を曖昧であるが安定、0.5 以上を曖昧であるが不安定として結果としており、曖昧な判定のものは除外した結果で識別率としている。

ここで、誤判定したサンプル、および、曖昧と判定したサンプルのネットワーク出力に注目する。

誤判定したサンプルについては、正しく判定できたサンプルに比べて値が小さく、つまり誤差は大きくなっており、判定能力に影響するものと考えられる。

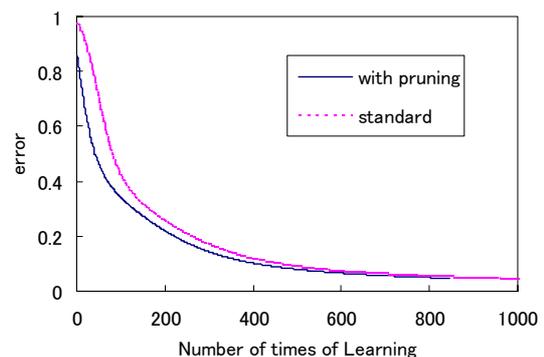


図 3. 学習回数に対する総誤差値

これを受けて、収束判定条件を総誤差 10^{-5} として更に学習をつづけてみると、誤判定点の改善はせず、更に、本来不安定とするものが安定という誤判定となる点もでてきた。これは、過学習による暗記化⁽⁴⁾によるものであると考えられる。

暗記化とは、図5に示すように、過学習により既知サンプルの特徴を反映しすぎてしまい、未知データに対する識別能力が悪くなってしまう場合のことである。ニューラルネットワークにおける学習は本来、図4のように多くの未知データに対して誤差を小さくする一般化が目的である。学習の暗記化を防ぐためには、収束判定条件の設定の仕方によるが、これについても試行錯誤的に求める必要がある。

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 の基準母線との位相差をプロットした電力動揺のグラフにより、その特性を調べると、図9のような特性を持つサンプルがいくつかあった。

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(図6)、超えて上昇をつづけるものを不安定(図7)としてクラス分けを行い、図8のようにようなものは除外している。

図8、図9の波形のような第一波脱調でない場合は安定度限界に属すると考えられる。つまり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のである。

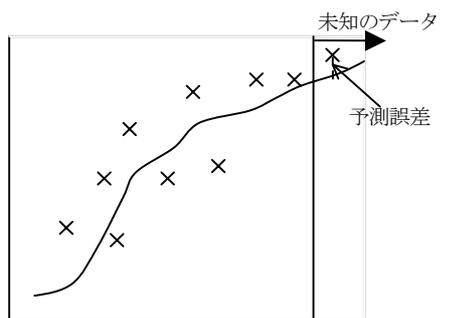


図4. 学習の一般化例

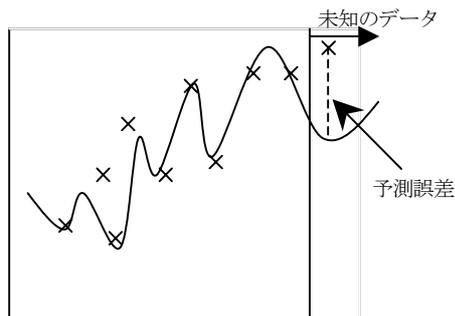


図5. 学習の暗記化例

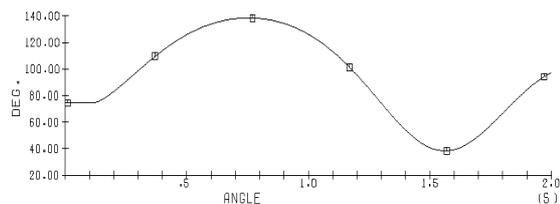


図6. 安定の場合の電力動揺例

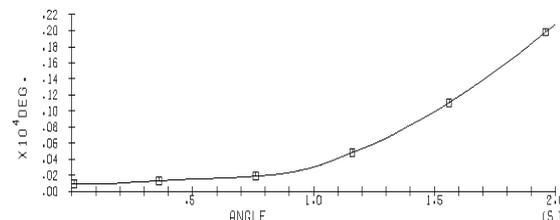


図7. 不安定の場合の電力動揺例

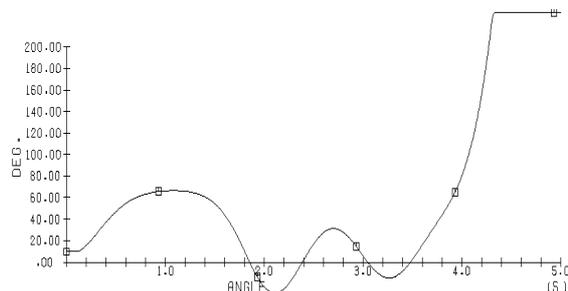


図8. 判断のつかない場合の電力動揺例

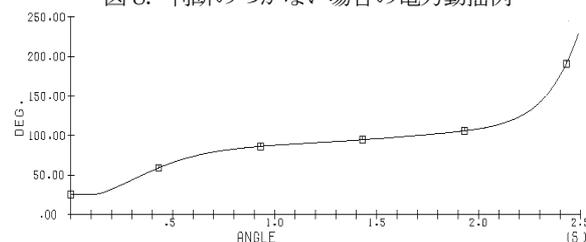


図9. 曖昧な判定サンプルの電力動揺例

5. まとめ

本稿では、ニューラルネットワークを用いた過渡安定度判定の妥当性と問題点を確認した。同時にプルーニングによる変数選択を検討した。しかし、新しいネットワークを構築は発見的方法で行っているため、その論理的な手法を確立し、効率をさらに改善する必要がある。

また、変数選択において、相関係数行列⁽⁴⁾を用いる等その他の手法も提案されており、それらとの比較や、同時利用も併せて今後の検討課題とする。

参考文献

- (1) 関根他：「電力系統工学」，コロナ社（1979），p1
- (2) 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
- (3) 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）
- (4) 大野：「多変量解析入門」，同友館，（1998），pp. 19-120