

複素数を用いたニューラルネットワークによる送電線の故障区間標定

田中 始男*・坪井 始*・小林 富士男*・美咲 隆吉*・高橋 政行*

Estimation of Fault Location for Transmission Lines by Neural Network Using Complex Back Propagation Learning Algorithm

Motoo TANAKA, Hajime TSUBOI, Takayoshi MISAKI,
Fujio KOBAYASHI and Masayuki TAKAHASHI

ABSTRACT

Distribution patterns of ground wire current along transmission lines have been analyzed by a experts in order to find the fault location. Various types of fault location methods using multi-layered feed forward type neural network models have been proposed and these efficiencies have been shown in several papers. The amplitudes and the phase angles are used as the input data of the neural network.

If we use complex number for the neural network, we can relate the amplitude and the phase angle to each other. In this paper, we propose a fault location method using the multi-layered feed forward type neural network model. In the proposed method, the neurons are expressed by the sigmoid functions which are extend to the complex number and we use the complex back propagation learning algorithm.

1. まえがき

送電系統は多くの鉄塔で構成されているため、故障時に生じる異常電流を検出するためのセンサをすべての鉄塔に設置することは現実的ではない。そのため、数十鉄塔毎にセンサを設置している。従来は専門家がこれらから検出された信号を分析して故障区間を判断していた。最近、送電線の故障区間標定に計算機を利用することが検討され、ファジィ理論やニューラルネットワークを使う方法が提案されている⁽¹⁾。しかし、ファジィ理論を用いる場合には、系統ごとの細かな違いに対処するためにメンバーシップ関数を用いてルールを記述する必要があり、そのために多くの労力が費やされる等の実用上の問題点がある。ニューラルネットワークを用いる故障区間標定では、ルールを記述する必要はないので、この点で有利である。

一方、複素数のニューロンで構成された階層型のニューラルネットワーク⁽²⁾が提案され複素数を扱う分野への応用が期待されている。

一般に、電気回路網の解析では複素数が用いられるので、本報告では、故障区間標定の入力データであるセンサー検出電流を複素数として取り扱える複素数を用いたニューラルネットワーク(以下複素NNと略す)を送電線の故障区間標定に利用し、その有効性を確認する。

2. 故障区間評定モデル

図1に示すような、201の鉄塔で構成された送電系統にセンサーが14個設定されている計算モデルを用いた。故障が起きた場合にセンサーで検出される電流を回路解析プログラム(EMTP)で求め、これを入力データとした。そして、この時の故障区間を教師データとして学習させ




Fig.1 Computational model of transmission line.

た。

3. 複素数を用いた階層型ニューラルネットワーク

故障区間の評定には、図2に示す入力層、中間層、出力層を持つ階層型のニューラルネットワークを用いている。また、各層のニューロンとニューロン間の重みは全て複素数であり、各ニューロンの出力関数 f は次式を用いている。

$$f(z) = f_r(x) + jf_r(y) \quad (1)$$

ただし、

$$z = x + jy \quad (2)$$

$$f_r(u) = 1 / (1 + \exp(-u)) \quad (3)$$

また、 j は虚数単位である。

学習アルゴリズムとしては、教師パターンとネットワーク出力の差が最小になるように重みの修正を行う最急降下法に基づいた誤差逆伝搬学習アルゴリズムを用いて

いる。

また、図1のモデルでは故障区間数が7であるため、これに対応するように出力層のユニット数は7として、故障した区間に対応する出力を1、他を0としている。

入力層に与えるデータは次式のように、各センサーで検出される電流と位相を複素電流として取り扱った場合の実部と虚部、及びセンサー間の複素電流値の差としている。

$$i_i, i_i - i_{i+1} \quad (4)$$

ここで、

$$i_i = I_i \{ \cos(\theta_i - \theta_0) + j \sin(\theta_i - \theta_0) \} \quad (6)$$

$$I_i = |i_i| \quad (7)$$

である。

中間層のユニット数については、図1の計算モデルの故障区間が7であるので、この倍数の7、14、21、28のそれぞれについて評価を行う。




Fig.2 Multi-layered feedforward type neural network model.

4. 計算結果

送電系統の各定数を仮定して回路解析プログラムで求めた故障時の複素電流をニューラルネットの入力信号としている。そのため、送電線モデルと実際の送電系統の各定数の違いやセンサーの誤差などにより、実際の送電線の故障区間標定において用いられる入力データはシミュレーション結果と異なる可能性がある。したがって、

シミュレーション結果の誤差がニューラルネットワークの標定精度に与える影響について検討する必要がある。そのため、学習が終了した後に、入力データに誤差を加えて故障区間を標定した。誤差は乱数を用いて与え、その範囲は電流の大きさについて $\pm 15\%$ 、位相について ± 15 度とした。




Fig.3 Number of fault-locating errors.




Fig.4 Errors between target signals and output signals.




Fig.5 Number of iteration steps.

4.1 教師信号

教師信号は、基本的には故障区間に対応するネットワークの出力を1、他を0とする。しかし、複素NNではネットワークの出力として各ユニット毎に実部と虚部が得られるので、故障区間を表わす方法として、以下の4つのケースについて比較を行った。

- ケース1：故障区間に対応する出力の実部のみを1、他は全て0とする。
- ケース2：故障区間に対応する出力の実部と虚部を1、他を全て0とする。
- ケース3：故障区間に対応する出力の実部を1、他の実部を0、虚部は全て1とする。

中間層のユニット数を21とした場合について計算結果を図3に示す。図3は誤差を考慮した未学習の42,700パターンを入力信号について誤認識した件数を比較している。また、図4は教師信号とネットワーク出力の差を全パターンについて合計した値を比較している。両図はいずれも値が小さいほど標定精度が高いことを意味するので、教師信号はケース1の形式で与えれば良いことがわかる。また、図5に誤差逆伝搬学習アルゴリズムでのネットワークの重み修正のための反復回数を示している。同図よりケース1では少ない反復で学習が終了していることがわかる。したがって、教師信号としてはケース1の形式を用いれば、他の形式に比べて少ない学習回数で誤りの少ない故障区間標定ができることがわかる。

4.2 重みの初期値

学習過程で必要な各層のニューロンを関連づける重み

の初期値は、0～1までの値を乱数によって与えている。初期値が標定精度に及ぼす影響について検討するために、乱数系列の異なる4種類の初期値について比較した。4.1節と同様な計算モデルについて、図6(a)に誤認識件数、図6(b)に教師信号とネットワーク出力の差の合計、図6(c)に学習終了までの反復回数を示す。いずれの初期値でも標定精度は同様な結果となることがわかる。また、比較のために実数を用いたニューラルネットワーク（以下実NNと略す）の場合について図7(a)、図7(b)、図7(c)に示す。これらの結果より、複素NNでは学習回数についても重みの初期値の影響を受けにくいことがわかる。

4.3 複素NNと実NNの比較

中間層のユニット数と誤認識件数の関係を図8(a)と図8(b)に示す。両図は、2種類の事故について、それぞれ、42,700パターン、30,400パターンの未学習の入力信号についての標定結果である。また、一般に用いられている実数を用いたニューラルネットワークによる結果(RNN)も同図に示している。実NNでは、実部と虚部の関係を無視して、複素NNと同じ入力データを実の各入力層ユニットの入力としている。複素NNと実NNのいずれも最適な中間層のユニット数では、0.5%以下の誤認識件数である。また、中間層ユニット数が7では、実NNは学習過程で誤差が極小値に収束し、学習が終了していない。したがって、これらの結果より、最適な中間層ユニット数では複素NNと実NNは同程度の故障区間標定ができ、少ない中間層ユニットの数では複素NNは実NNよりも故障区間標定に適していると考えられる。




Fig.6 Comparison of initial values of neural network using complex number. (a) number of fault-locating errors, (b) errors between target signals and output signals, (c) number of iteration steps.




Fig.7 Comparison of initial values of neural network using real number. (a) Number of fault-locating errors, (b) errors between target signals and output signals, (c) number of iteration steps.

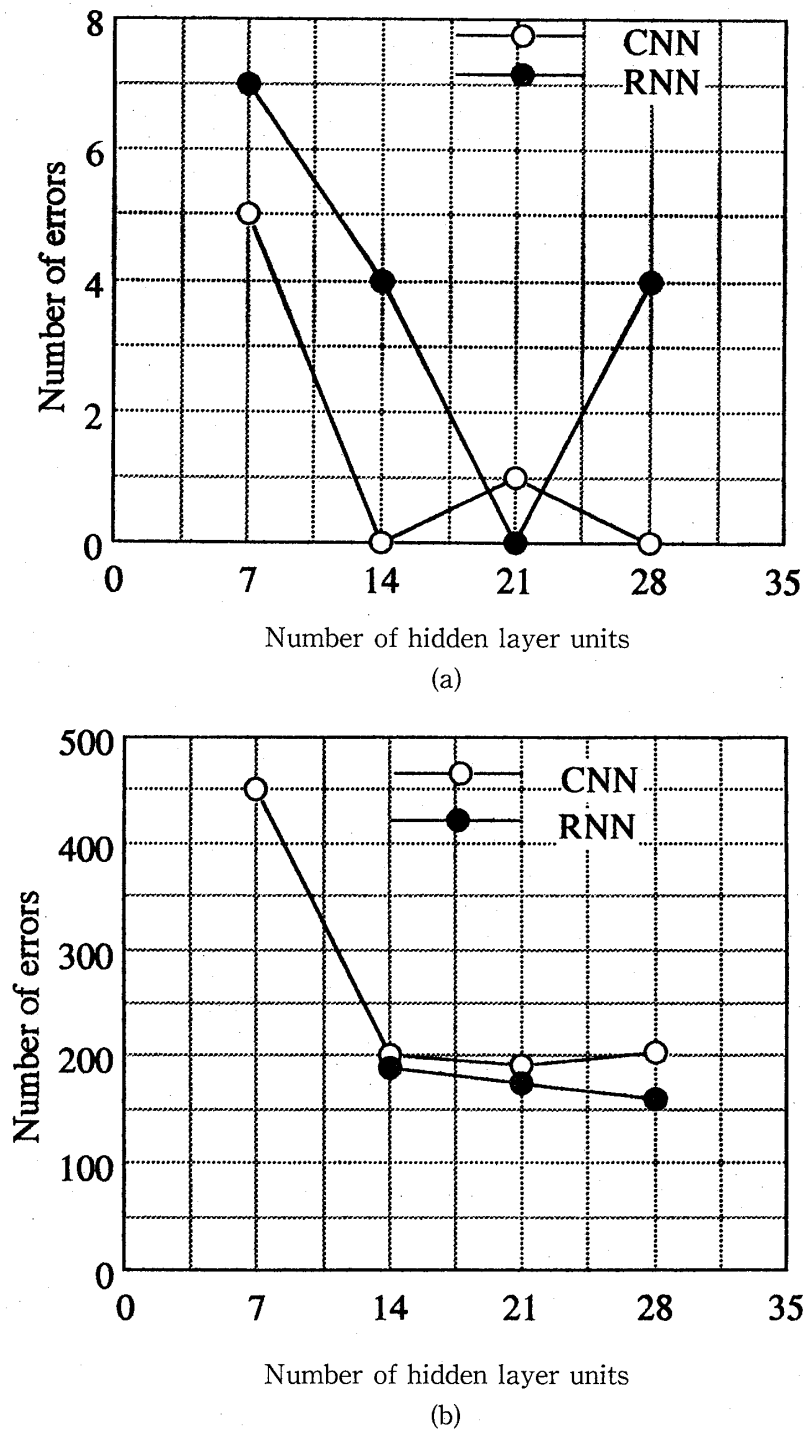


Fig.8 Comparison of number of fault-locating errors. (a) using 30,400 cases, (b) using 42,700 cases.

図9(a)と図9(b)に誤差逆伝搬学習アルゴリズムにおける反復回数と中間層ユニット数の比較を示す。複素NNは実NNに比べて少ない反復回数で学習が終了しており、複素NNの学習能力が優れていることがわかる。ネットワークの構造と学習アルゴリズムは同じであるので、これらの複素NNと実NNの差は複素NNで実部と虚部の関連を利用していることから生じていると考えられる。

5. むすび

複素数を用いたニューラルネットワークによる送電線の区間標定法を提案し、回路解析プログラムの計算結果を利用して提案手法の有効性を確認した。得られた結果をまとめると次のようになる。

- (1) 回路解析プログラムで得られる故障時の電流分布に基づいて乱数を用いて擬似的に発生させた事故電流を入力データとして故障区間標定をした結果、提

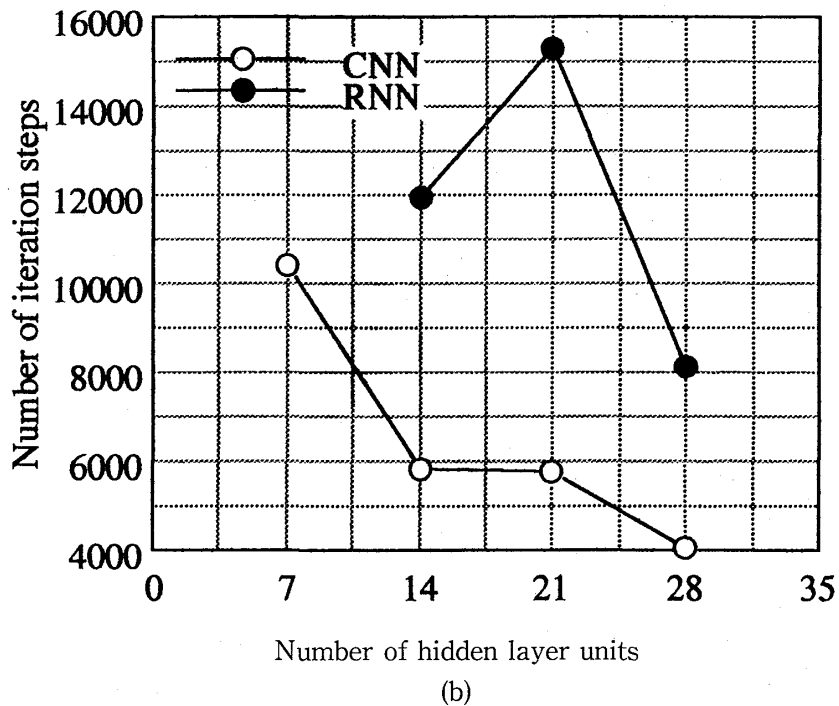
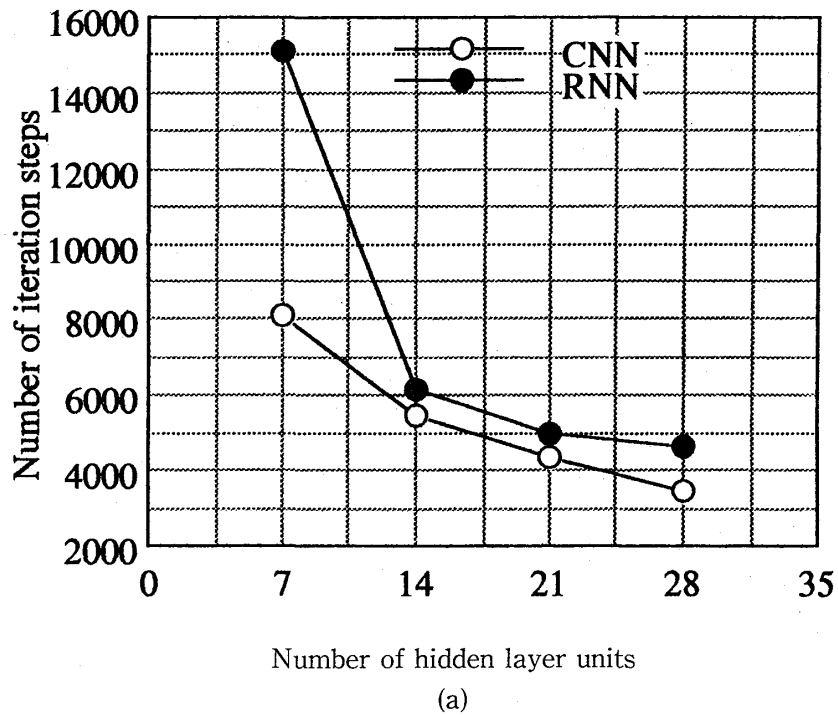


Fig.9 Comparison of number of iteration steps. (a) using 30,400 cases, (b) using 42,700 cases.

案手法では誤認識率は0.5%以下となることを示した。

- (2) 従来用いられている実数を用いるニューラルネットワークと比べて、少ない中間層のユニット数では高い故障区間認識率が得られることがわかった。

Vol.110, No.7, pp.420-427 (平2)

- (2) 新田、古谷：“複素バックプロパゲーション学習”，情報処理学会論文誌，Vol.32, No.10, pp.1319-1329 (平3)

参考文献

- (1) 狩野 均、金田 正久、金丸 公春：“推論型ニューラルネットワークによる送電線の故障区間評定”，電学論C,