

## ニューラルネットワークによる誘電率の推定

## Estimation of Electric Permittivity Using Neural Network

木村昭穂、松坂知行 (八戸工業大学)

Akio Kimura, Tomoyuki Matuzaka  
(Hachinohe Ins. of Tech.)

キーワード：ニューラルネットワーク (Neural Network)、誘電率(Electric Permittivity)

連絡先：〒031 八戸市大字妙字大開881-1 八戸工業大学情報システム工学研究所

木村昭穂、Tel：(0178) 25-3111、Fax：(0178) 25-1691

## 1. はじめに

最近、電力需要の増加に伴い電力機器が、高電圧化・高機能化する傾向にある。電力機器の信頼性向上の一つの要因として、絶縁材料の誘電率の特性が大きく左右する。誘電率を機器に組み込まれた状態で測定することは困難な場合が多い。その様なことから、機器の周りの電界や電位を測定し、そのデータを基に誘電率が推定できると便利である。絶縁体の誘電率の推定の試みとしてニューラルネットワークを用いた。ニューラルネットワークは、一種のブラックボックスとみなせ、一つのニューラルネットワークは、そのネットワークのリンク荷重が決定されると、そのニューラルネットワークの特性が決定される。ブラックボックスの中身の物理的な意味を考慮することは困難であるが、ニューラルネットワークで入力と出力を関係づけることが出来るという優れた点を有している。また、ニューラルネットワークの学習アルゴリズムとしてBP法が理論的に明確で極めて汎用性の高いアルゴリズムであることが知られている。し

かし、BP法の欠点は、ネットワークのシステム誤差を所定値に収束させるために学習回数が多くにわたることである。そこで、ニューラルネットワークの収束誤差の改善や学習回数の減少、ひては計算時間の短縮のために拡張カルマンフィルタを適用した。計算は誘電体の誘電率が不均一であると仮定し、階層型ニューラルネットワークを用いて誘電率の同定を行なった。

## 2. ニューラルネットワーク

ニューラルネットワーク<sup>(1)(2)</sup>のユニットの伝達関数としてシグモイド関数を用いた。ただし、 $x$ は入力、 $w$ はシナプス荷重、 $f(x)$ は出力である。

$$f(x) = \frac{1}{1+e^{-wx}} \quad (1)$$

また、シナプス荷重 $w$ を1とすると、シグモイド関数の出力は0~1の範囲となる。そこで、入力データや教師データがこの範囲内にあるように、次式を用いて規格化を行った。

$$I_{ik}^{nor} = \frac{I_{ik} - I_{\min k}}{I_{\max k} - I_{\min k}} \quad (2)$$

$$P_{ik}^{nor} = \frac{P_{ik} - P_{\min k}}{P_{\max k} - P_{\min k}} \quad (3)$$

ただし、 $I_{ik}^{nor}$  : 規格化された入力データ、 $I_{ik}$  : 学習パターン  $i$  の  $k$  番目のデータ、 $I_{\max k}$  :  $k$  番目のデータの最大値、 $I_{\min k}$  :  $k$  番目のデータの最小値、 $P_{ik}^{nor}$  : 規格化された教師データ、 $P_{ik}$  : 学習パターン  $i$  の  $k$  番目のデータ、 $P_{\max k}$  :  $k$  番目のデータの最大値、 $P_{\min k}$  :  $k$  番目のデータの最小値である。

### 3. 拡張カルマンフィルタによる学習

線形確立システムの状態方程式<sup>(2)~(5)</sup>は、

$$\{x\}_{t+1} = [F]\{x\}_t + [G]\{w\}_t \quad (4)$$

$$\{y\}_{t+1} = [H]\{x\}_t + \{v\}_t \quad (5)$$

のように表わされる。

ただし、 $\{x\}_t$  : 状態ベクトル、 $\{y\}_t$  : 観測ベクトル、 $\{w\}_t$  : ガウス白色システムノイズ、 $\{v\}_t$  : ガウス白色観測ノイズ、 $[F]_t$  : システム行列、 $[G]_t$  : 駆動行列、 $[H]_t$  : 観測行列である。

推定パラメータに相当する状態ベクトルは、それ自身時間的遷移構造を持たないので、時間軸について一定である。システムに誤差の混入がないという条件を付け、システム行列に単位行列を選ぶと状態ベクトルは、

$$\{x\}_{t+1} = [I]\{x\}_t \quad (6)$$

のように表わされる。

線形確立システムに学習アルゴリズムとして観測更新アルゴリズムといわれるカルマンフィルタを適用する。(7)~(11)式はフィルタ方程式 $\{x\}_{t/t}$ 、カルマンゲイン $[K]_t$ 、推定誤差共分散行列 $[P]_t$ 、初期条件を示したものである。

(a) フィルタ方程式

$$\{x\}_{t/t} = \{x\}_{t/t-1} + [K]_t[\{y\}_t - [H]_t\{x\}_{t/t-1}] \quad (7)$$

(b) カルマンゲイン

$$[K]_t = [P]_{t/t-1}[H]_t^T[[H]_t[P]_{t/t-1}[H]_t^T + [R]_t]^{-1} \quad (8)$$

(c) 推定誤差共分散行列

$$[P]_t = [P]_{t/t-1} - [K]_t[H]_t[P]_{t/t-1} \quad (9)$$

$$t = 0, 1, 2, 3, \dots$$

(d) 初期条件

$$\{x\}_{0/0} = x_0, [P]_{0/0} = \sum_0 \quad (10)$$

ここで $\{x\}_{t/t}$ は現在( $t/t$ )より1ステップ前( $t/t-1$ )に計算されたシナプス荷重の推定値 $\{x\}_{t/t-1}$ にある修正分を加えて得られた現在の値である。また、 $[P]_{t/t}$ についても同様

である。[K]<sub>t</sub>は1ステップ前の[k]<sub>t-1</sub>の値とは関係なく計算され[K]の現在(t)の値である。[H]<sub>t</sub>についても同様である。初期条件x<sub>0</sub>およびΣ<sub>0</sub>が与えられると[H]<sub>t</sub>が既知であることからカルマンゲイン[K]および推定誤差共分散行列[P]が直ちに計算される。次に反復公式(7)式を用いて新しい推定値{x}を求める。

(5)式の観測式は状態量{x}について線形になっているが、推定値は定式化において非線形となる。

$$\{y\}_t = \{h(\{x\}_t)\}_t + \{v\}_t \quad (11)$$

上式の{y}<sub>t</sub>を推定値{x<sub>t,t-1</sub>}のまわりにテイラー展開を行い、高次の項を無視すると、次のような線形式が得られる。

$$\{\eta\}_t = [H]_t \{x\}_t + \{v\}_t \quad (12)$$

$$[H]_t = \left. \frac{\partial \{h\}_t}{\partial \{x\}_t} \right|_{x=x_{t,t-1}}$$

ここで{η}<sub>t</sub>は次式のように表わされる。

$$\{\eta\}_t = \{y\}_t - \{h(\{x\}_{t,t-1})\}_t + [H]_t \{x\}_{t,t-1} \quad (13)$$

{η}<sub>t</sub>は観測量{y}<sub>t</sub>から計算できるので、線形システムと同じ扱いが可能である。状態量としてシナプス荷重を選び(6)式を用いて表わすと次式のようにになる。

$$\{w\}_{t+1} = [I] \{w\}_t \quad (14)$$

(3)、(14)式より(13)式の{η}<sub>t</sub>を求めると、次式のようにになる。

$$\{\eta\}_t = \{O\}_t - \{h\}_t + \left\{ \frac{\partial h}{\partial w} \right\}_t \{w\}_{t,t-1} \quad (15)$$

ここで、{O}<sub>t</sub>は教師データ、{w<sub>t,t-1</sub>}は1ステップ前に計算したシナプス荷重、{h}<sub>t</sub>は入力データによる出力である。

### 3. 解析結果

図1は、解析モデルを示したものである。図中の斜線の部分は誘電体であり、誘電体中の要素a、b、cは誘電率が異なるものとする。ニューラルネットワークを用いて解析するに当たり、入力のツニット数は8、中間層の層数は1でこの時のユニット数は3または6、出力ユニット数は3または6、教師データ数は4または10として、それぞれを組み合わせて行った。表1はその組み合わせを示したものである。図2は教表1のa、b(師データ数が4で中間層のユニット数が3、出力層のユニット数が3)のときのネットワークの構造を示したものである。図3は、表1のaの条件で行ったときのネットワークの平均出力誤差を示したものである。学習回数が50回ぐらいから急に減少していることが分かる。平均出力誤差が徐々に減少に至らない主な理由は、中間層のユニット数が少ないことによるものと思われる。急激な現象は、学習効果とカルマンフィルタによるものと思われる。図4は表1のb(教師データが10)のときの平均出力誤差を示したものである。平均出力誤差がある学習回数から一定であるのは、中

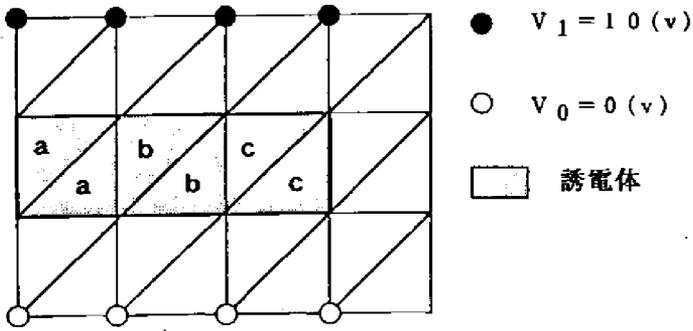


図1 解析モデル1

表1. ニューラルネットの計算例

| 計算例 | 中間層の<br>ユニット数 | 出力の<br>ユニット数 | 教師<br>データ数 |
|-----|---------------|--------------|------------|
| a   | 3             | 3            | 4          |
| b   | 3             | 3            | 10         |
| c   | 6             | 3            | 4          |
| d   | 6             | 3            | 10         |
| e   | 6             | 6            | 4          |
| f   | 6             | 6            | 10         |

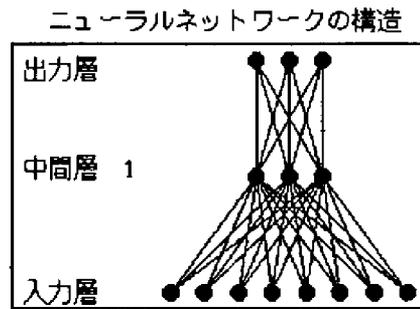


図2 ニューラルネットワークの構造 (表1のa, b)

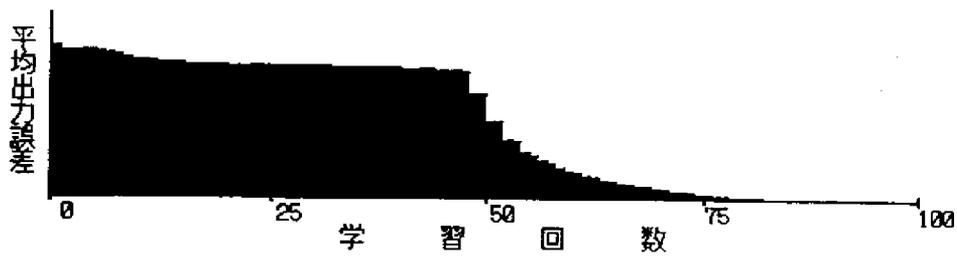


図3 学習回数と平均出力誤差 (表1のa)

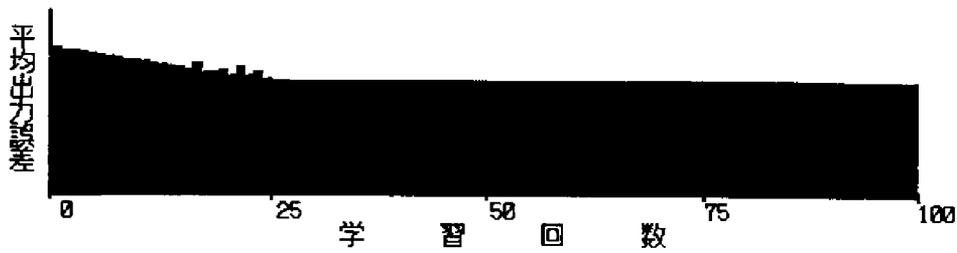


図4 学習回数と平均出力誤差 (表1のb)

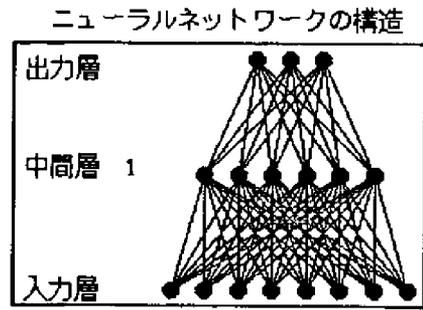


図5 ニューラルネットワークの構造  
(表1のc, d)

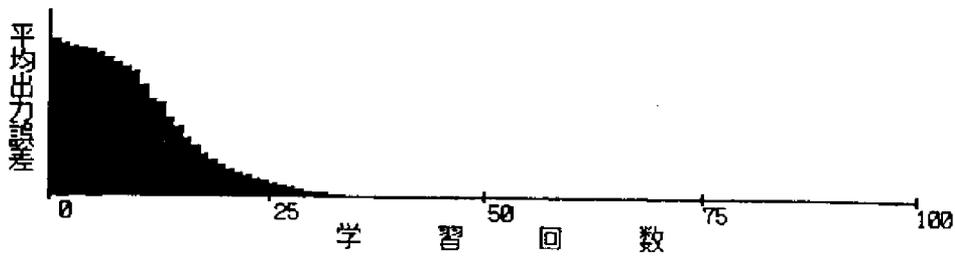


図6 学習回数と平均出力誤差 (表1のc)

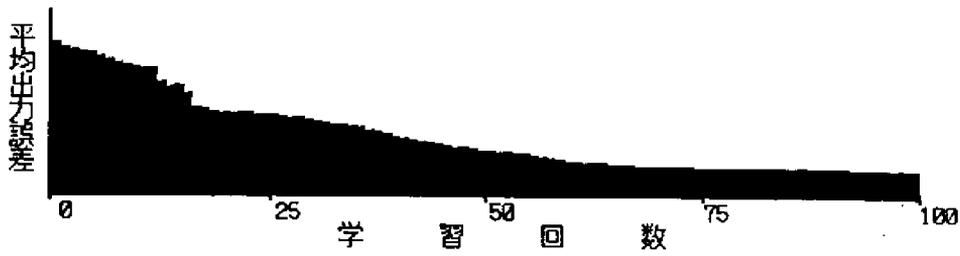


図7 学習回数と平均出力誤差 (表1のd)

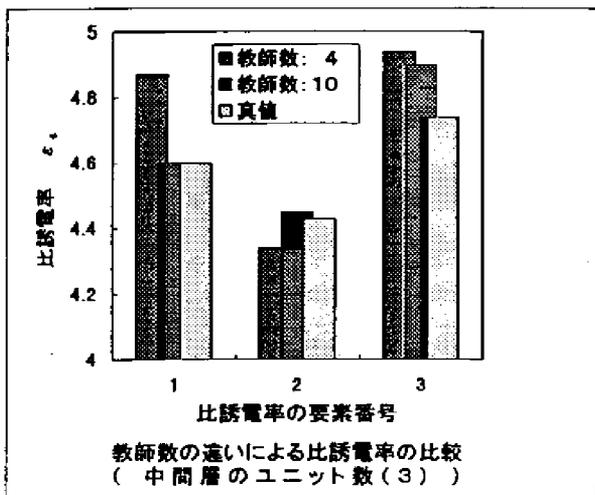


図8 計算値と真値比較の  
(表1のa, b)

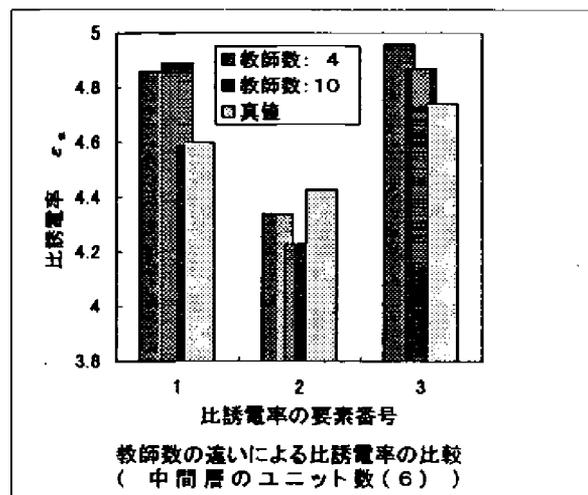


図9 計算値と真値比較の  
(表1のc, d)

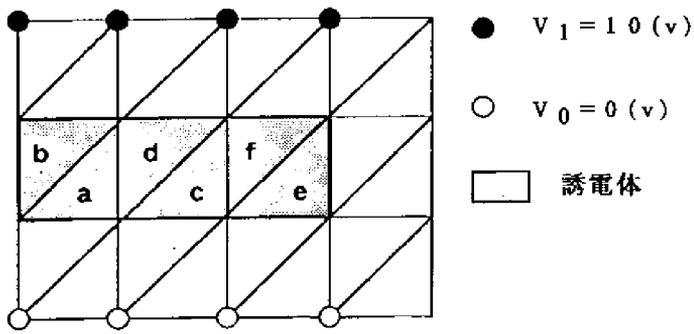


図10 解析モデル2

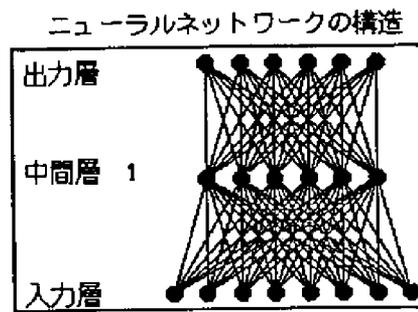


図11 ニューラルネットワークの構造  
(表1のe)

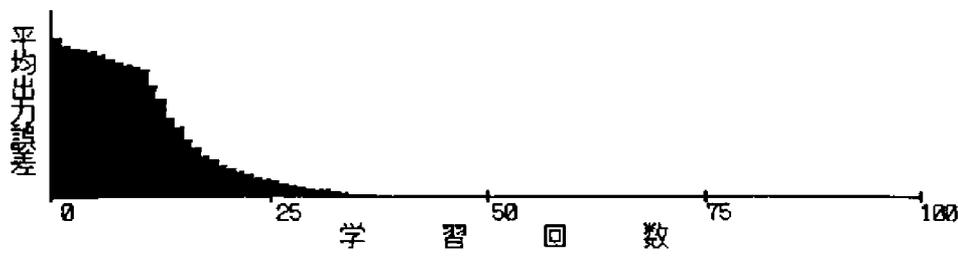


図12 学習回数と平均出力誤差 (表1のe)



図13 学習回数と平均出力誤差 (表1のf)

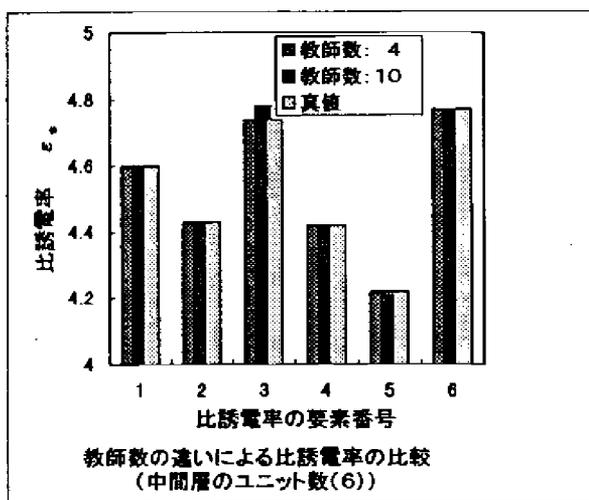


図14 計算値と真値比較の  
(表1のc, d)

間層のユニット数が少ないことと、教師データ数が多くなり計算誤差が大きくなったことによるものと思われる。図5は表1のc、d（中間層のユニット数を6）のときのニューラルネットワークの構造を示したものである。図6は表1のc（教師データが4）のときの平均出力誤差を示したものである。学習回数が34回程度で収束しているのは、中間層のユニット数を増やしたことにより、出力のユニットの情報が増加したことによるものと思われる。図7は表1のd（教師データが10）のときの平均出力誤差を示したものである。図4の表1のb（教師データが10、中間層のユニット数が3）のときと比較すると、平均出力誤差が徐々に減少していることが分かる。

図8は表1のc中間層のユニット数が3のときの教師データ数の違いによる比誘電率の真値と計算値を比較を示したものである。図4と比較すると教師データ数が多いと平均出力誤差が大きいことがいえる。平均出力誤差が大きい割には、真値に近いことがいえる。教師データ数の学習効果によるものと思われる。図9は表1のc、dのときの教師データ数の違いによる比誘電率の真値と計算値を比較を示したものである。図8と比較するとどちらかといえば、中間層のユニット数が多いほうが真値に近いことが分かる。

図10は要素中の誘電体の誘電率  $a$ ,  $b$ ,  $c$ ,  $d$ ,  $e$ ,  $f$  が異なる場合のときの解析モデルを示したものである。図11はこのときのニューラルネットワークの構造を示したものである。図12は表1のe（教師データが4）のときの学習回数に対する平均出力誤差を示したものである。学習回数が34回程度で収束しているのは、入力ユニット数、中間層素のユニット数、出力層のユニット数が適当であり、計算誤差が小さいことによるものと思われる。図13は表1のf（教師データ数が10）のときの学

習回数に対する平均出力誤差を示したものである。学習回数が約30回程度から出力誤差が一定であるのは、教師データが多くなり、計算誤差が大きくなったためによるものと思われる。図14は、教師データ数の違いによる真値と計算値を比較したものである。教師データ数が多いと一部において真値と少し違うが、ほぼ同じであることが分かる。

#### 4. まとめ

階層型ニューラルネットワークに拡張カルマンフィルターの学習アルゴリズムを用いて、誘電率の同定が行なえるようになった。また、中間層のユニット数によって収束が大きな影響を受けることがいえる。中間の層のユニット数は、出力層のユニットよりも多いと全体的に誤差が小さいことがいえる。今後の課題として、複雑なものについての応用と検討が必要である。

#### 参考文献

- (1) 市川：階層型ニューラルネットワーク、共立出版
- (2) 村瀬他：カルマン・ニューロコンピューティング、森北出版
- (3) 片山：応用カルマンフィルタ、朝倉書店
- (4) 村瀬、小山、石田：順・逆解析入門、森北出版
- (5) 中野、西山：パソコンで解くカルマンフィルタ、丸善