

冠雪碍子閃絡現象予測用ニューラルネットワークの 構成法及び最適化法

Configuration and Optimization of Neural networks For Flashover Prediction of Insulators Covered with Snow

○村上 武*, 吉田 等明**, 恒川 佳隆**, 三浦 守**,
上所 操***, 立崎 修二***

○Takeshi Murakami*, Hitoaki Yoshida**, Yoshitaka Tsunekawa**,
Mamoru Miura**, Misao Josho***, Shuji Tachizaki***

*青森日本電気ソフトウェア(株), **岩手大学, ***東北電力(株)

*NEC Software Aomori Ltd., **Iwate University, ***Tohoku Electric Power Co., Inc.

キーワード: 閃絡(flashover), ニューラルネットワーク(neural network), 誤差逆
伝播法(back propagation method), 遺伝的アルゴリズム(genetic algorithm)

連絡先: 〒020-8551 盛岡市上田 4-3-5 岩手大学工学部情報工学科
三浦 守, Tel/Fax:(019)629-2838, E-mail:mamoru@iwate-u.ac.jp

1. はじめに

送電線は、電力供給業務上必要不可欠の設備であり、この設備の故障は高度に電化した現代社会に非常に重大な影響を及ぼす可能性がある。とりわけ冬季に発生する送電線への着氷雪による故障は、影響範囲が広くなり設備被害にまで発展することもあり得るため、電力供給上の大きな問題になっている。これに対し、着雪機構の研究および各種の着雪対策の研究が実施されているが[1]、被害を完全に回避できるまでには至っていない。

送電線の着雪による被害を未然に防止するためには、送電線設備の強化および難着雪対策と共に、着雪による送電線被害発生の予測が極めて重要であり、その自動化と精度向上が強く望まれている。しかし、送電線への着雪がもたらす被害の発生状況とその際の気象状況との間には、因果関係が曖昧かつ複雑な

ため、従来の論理的プログラミングによる解析法[2][3][8][9][10]では、その被害を予測することが困難である。

一方、ニューラルネットワーク (Neural network: 以下 NN と略す) を用いると、学習・自己組織化機能によって、人間には発見が困難な情報を自動的に獲得することが期待できる。当研究室では、着雪による被害の発生状況と気象条件との相関関係を検討し、NN による送電線着雪被害予測システム[4]を構築した。その結果、認識率は約 30~60%であった。また、短期の被害予測を目的とし、送電線碍子上を流れる漏れ電流だけを入力データとする NN を用いた冠雪碍子閃絡現象の予測手法を提案した[5][6][7]。この手法による認識率は 60~80%と比較的高率であり、今後に期待されている。しかし問題点として、ネットワーク構成が複雑であり、また学習時間が非常に長いことが挙げられている。これらの問題点を解決するためにネットワーク構成を変更するなど大

幅な改良を行った。これにより比較的簡単な構成の NN を用いて短時間で学習が可能となり、認識率及び予測時間の向上がみられたので報告する。

2. 冠雪碍子閃絡現象

冠雪碍子閃絡現象とは、送電線を鉄塔に釣り下げまたその送電線と鉄塔の間を絶縁するための碍子連(図1)に大量の雪が降り積もり、その雪によって濡れた碍子連に絶縁破壊が生じ、大きな電流(漏れ電流)が流れ、閃絡(Flashover:以下FOと略す)に至る現象である。




図1 閃絡実験の模式図

冬季に、碍子の冠雪は降雪により生じ降雪量が増えるにしたがい多くなるが、被冠雪物に比べて冠雪が多くなると途中で一部落下の現象が生ずる。降雪がやめば、気温の上昇と共に融雪し、落下または消滅という過程をたどるが、この繰り返しの中で冠雪が残存した場合は、次の降雪により冠雪上面部の面積に応じて発達してゆく。

碍子の冠雪碍子閃絡現象は、このように気象条件などによって発達した冠雪融解→抵抗低下→碍子の漏れ電流の発生→融解というサイクルで更に碍子連の耐電圧を低下させ、ある条件に至ったとき絶縁が破壊され碍子連または冠雪を通して閃絡が起こるものと推定される。

図2に碍子連上を流れる漏れ電流波形の例を示す。図2(a)は非閃絡(Non flashover:以下NFOと略す)の例であり、同図(b)は閃絡(FO)の場合である。グラフ中で縦軸がスケールオーバーしているところが閃絡点である。図2(a)の非閃絡波形の中には、ほぼ一定のレベルを保っている場合(93_9)や、比較的高いレベルを示すが閃絡に至らない場合(93_5)がある。また、図2(b)の閃絡波形の中には、徐々に電流レベルが大きくなり最後に閃絡に至る場合(93_6)や、比較的低いレベルを保っていたのが突然閃絡に至る場合(93_7)など、様々な状態が存在することが分る。

閃絡が起こる条件としては気象条件、冠雪状態、

雪質など様々な要因が考えられるが、これらが集約された結果が漏れ電流波形に現れていると筆者等は考え、この漏れ電流だけを閃絡予測のデータとして用いている。

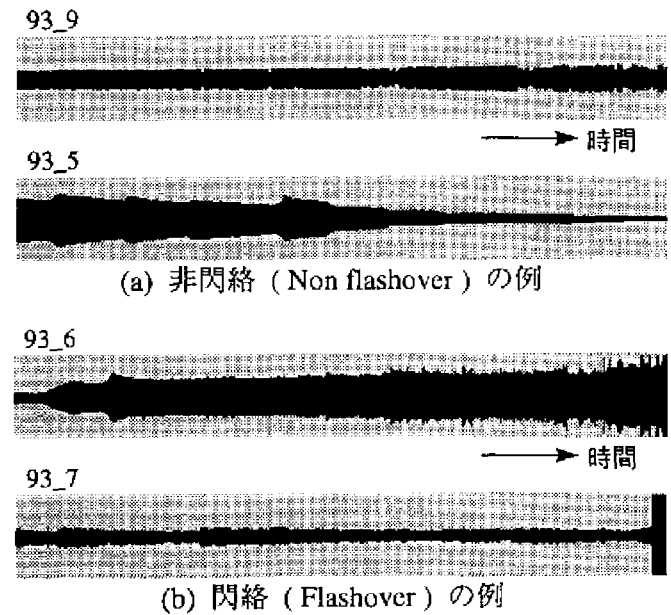


図2 漏れ電流の例

3. 従来の構成法

図3に従来の NN 構成を示す。漏れ電流データ及びその一次微分データを共に学習データとして用い、それぞれを別々な NN で学習させる。その後、統合 NN により最終的な学習を行い、これを予測に用いる。この比較的複雑な NN 構成は漏れ電流オリジナルデータ及びその一次微分の性質の違いを考慮した結果である。すなわち、漏れ電流オリジナルデータの電流レベルに着目したネットワーク1及び一次微分データによる漏れ電流の変化量に着目したネットワーク2にそれぞれ異なる性質を学習させ、それらを統合することにより2つの性質を併せて学習させることが目的である。

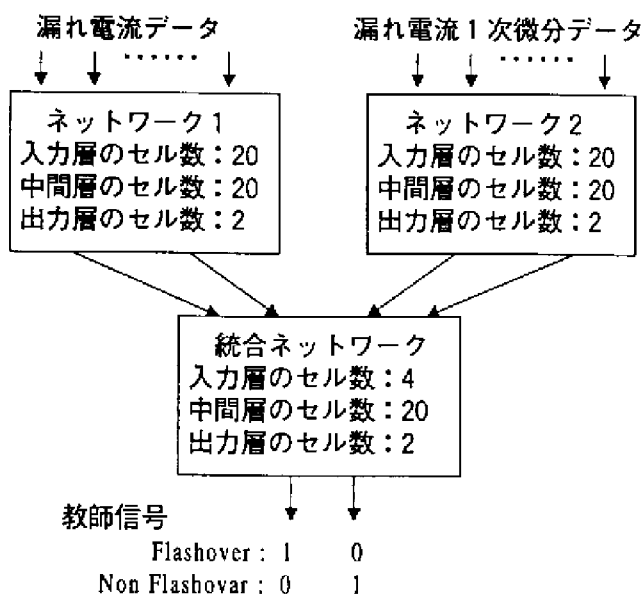


図3 従来のネットワーク構成




図4 ネットワークへの入力方法

次に、学習データの入力方法は、図4のように逐次的に行われる。これは、漏れ電流の時間変化を学習させることが目的であるが、それがNNの複雑さと相まって学習時間が非常に長くなるものと考えられる。

学習が終了したNNに漏れ電流データを順次入力し、統合NNの2出力の差がある値を最初に超えたとき、その時点点を閃絡予測点とし、その時点から実際に閃絡する時点までの時間を閃絡予測時間とする。

以上の構成によって、認識率が58.3%～83.3%、平均閃絡予測時間が21.7秒～51.3秒という結果が得られている。また入力データとして印加電圧と漏れ電流の比（コンダクタンス）を用いた場合、認識率が75.0%～83.3%、閃絡予測時間が34.9秒～38.2秒という結果となっている。

4. 新しい構成法

4-1 ネットワーク構成

従来の比較的複雑なNNを単純化し、学習時間の短縮化を計るための新しい構成法を示す。まずNNは

図5のように比較的簡単な階層NNを用いる。入

力層のニューロン数の40は漏れ電流の1周期分に相当する。入力データの形式は図6のように電流レベルの符号が負から正に変化する箇所を入力開始点とし、それ以降の40点を入力データとする。この規格化により、漏れ電流データ全体を1回学習するために必要な学習回数が、従来の1/40に減少する。

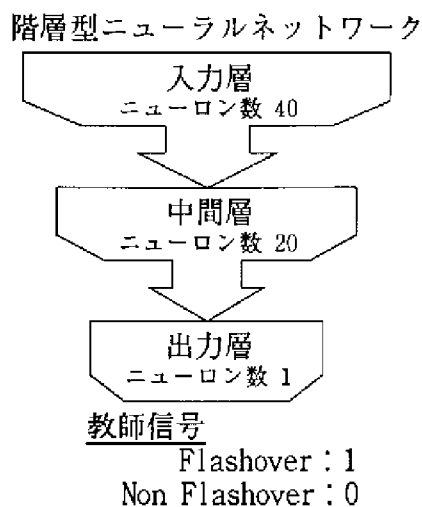


図5 ネットワーク構成

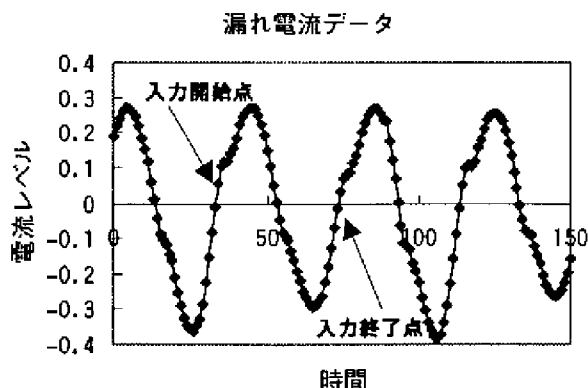


図6 入力データの規格

4-2 学習方式

図7に学習のアルゴリズムを示す。学習データの入力方式は、従来のように時系列データを逐次的に入力するのではなく、ランダムに入力開始点を選択し入力する。これは学習の収束を最優先としたもので、従来の手法のような漏れ電流に関する時間変化の学習は行われていないことになる。

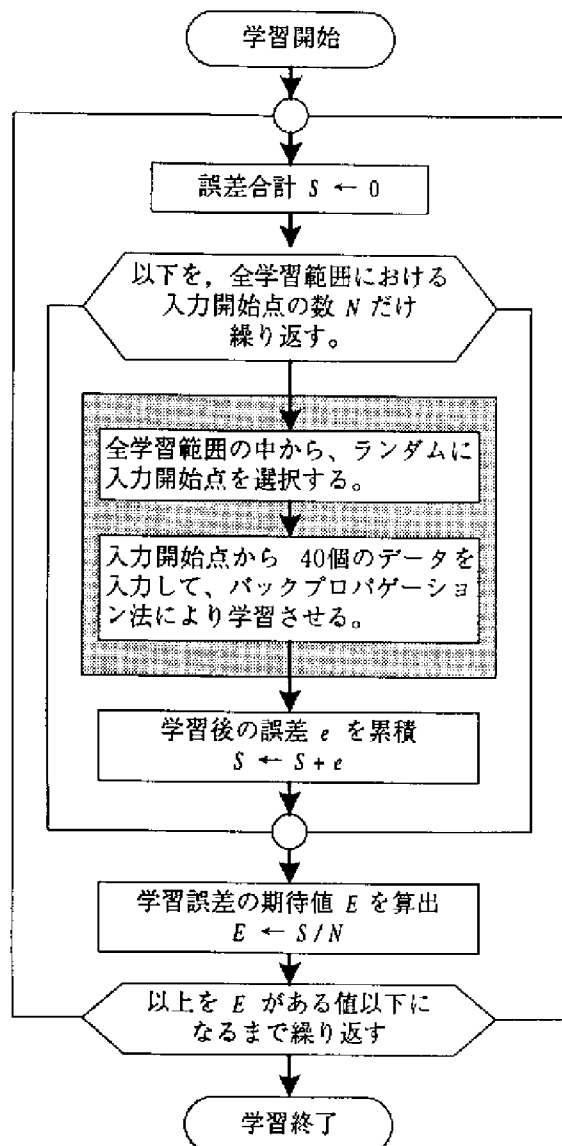


図7 学習アルゴリズム

4-3 入力データの学習範囲

学習を効率的に行うには、特徴あるデータを学習データとして選択することが望ましい。そのための簡単な手法として、図8のように閃絡データについては、閃絡点からそれ以前のある範囲を学習させる。




図8 学習データの学習範囲

これは、“閃絡点に近いほど、より多く閃絡の傾向を示す波形が存在している”という仮定に基づいている。また、非閃絡データについては単純に全体を学習させるものとする。

4-4 学習結果

以上で述べた新しい構成法を用い、93年度のデータを学習させた結果を示す。

4-4-1 学習条件

表1に学習条件を示す。入力データの種類を漏れ電流の一次微分データとしたのは、学習の収束率がオリジナルデータと比較して格段に優れているからである。また、学習効率は0.001と、通常のNN学習に用いる値と比較して非常に小さい値であるが、学習データ数の膨大さ($O(10^3)$)から考えると妥当と思われる。

表1 学習条件

学習データ	FO	93_3 (200,000~250,400)
		93_6 (150,000~188,900)
	NFO	93_5
		93_9
入力データの種類	漏れ電流の一次微分データ	
学習効率	0.001	
シグモイド関数の定数 u *	0.75	
中間層のニューロン数	20	
学習の終了条件	学習誤差 0.1 以下 または 学習回数 500回	
計算機	Origin2000	

*シグモイド関数 $f(x) = \frac{1}{1 + \exp(-2x/u)}$

4-4-2 学習の収束状況

この学習条件による20回の試行結果、20回中17回収束し、収束過程は図9のようになった。20回の試行における平均学習回数は337.0回、平均学習時間は13分52秒であった。これを従来手法で用いた計算機(HP 9000/715)のCPU時間に換算すると約1時間20分となる。従来の手法による学習時間が日単位であることを考えると、新しい構成により学習時間を大幅に短縮できたことがわかる。




図9 学習の収束状況




図10 ネットワークの認識例

(ア) は漏れ電流データ, (イ) はネットワーク出力, (ウ) はパルス密度を示す。

4-5 閃絡の判断方法

以上のように学習させた NN に、漏れ電流一次微分データを入力したときの出力の一例を図 10 に示す。図(a), (b) 共に非学習データであり、それぞれ非閃絡、閃絡データの認識例を示す。

まずネットワークの出力である (イ) に着目すると、図(a)は後半で、図(b)では全体的に高くなっているのがわかる。従来の判断方法ではネットワークの出力がある値を超えたとき閃絡と判断する。つまり、この場合ネットワークの出力が図(a), (b) 共に最大値に達しているため、両方とも閃絡と判断してしまう。

そこで新たな判断方法が必要となる。

そのために、まずネットワーク出力に対してあるしきい値 θ を定め、それを超えたとき 1, それ以外は 0 とする。これによりネットワーク出力はパルス列と見なされる。(以下では θ をパルス判定しきい値とする) そして、そのパルス列についてある時間窓 n におけるパルス密度を求める。すなわち、

$$Pulse[i] = \begin{cases} 1 & N[i] \geq \theta \\ 0 & N[i] < \theta \end{cases} \quad \dots(1)$$

$$Dns[j] = \frac{1}{n} \sum_{i=1}^n Pulse[i+j] \quad \dots(2)$$

ここで、 $N[i]$ は i 番目の入力に対するネットワー

ク出力値で、 $Pulse[i]$ はそのときのパルス値、 $Dns[j]$ は j 番目から $j+n-1$ 番目の入力の間パルスが発生する割合、すなわちパルス密度を示す。ここでは $n=100$ 、 $\theta=0.9$ としてある。このパルス密度の時間変化を示したものが (ウ) である。この大きさについては図(a)と図(b)の間に明らかな違いが見られる。この理由に関して以下のように考えられる。

閃絡データの学習範囲の中には閃絡の兆候を示している波形が多く含まれているはずであるが、そうでない波形も含まれている可能性は否定できない。非閃絡データの学習に関しても同じで、閃絡の兆候を示す波形は存在しているが、低頻度に現れているため閃絡に至らないと考えられる。この場合、ある一瞬のネットワーク出力の大小だけで閃絡を判断することは明らかに難しい。よって時間変化を調べればよいと考えるであろう。従来法で逐次的学習法を取り入れたのは、この時間変化を学習させようとしたことが主な理由であった。本手法ではランダム学習なので時間軸に沿った学習はなされていない。しかし、パルス密度はネットワーク出力の時間変化における平均値と考えることができ、閃絡判別の段階で時間変化を考慮して行ったため、良好な結果が得られたと考えられる。

次に、パルス密度を用いた閃絡の判別手法について述べる。ここでは単純にあるしきい値を超えたとき閃絡と判断する。(このしきい値を以下では“閃絡判定しきい値”とする) そのしきい値を求めるために、全漏れ電流データそれぞれについてパルス密度の最大値を求めた。その分布を図 11 に示す。閃絡データは 80% 付近からそれ以上に分布し、非閃絡データは全域的に分布している。

閃絡判定の際、閃絡データを非閃絡と判断することだけは避けなければならない。このため、しきい値は閃絡データ分布の最小値 80 より小さい値である必要がある。また、認識率を最大にするには、閃絡データの分布より低い非閃絡データの分布の最大値 64 より大きい必要がある。さらに、閃絡予測時間を大きくするためには、しきい値はできるだけ低い方がよい。以上のような条件によって、図 11 において閃絡判定しきい値は 65 が適当といえる。ここで、このとき正しく認識された NFO データの個数が認識率と等価となるため、以下ではこれを“NFO 認識数”として、これを学習・認識性能比較に用いる。

次に、予測時間も含めた最終的な閃絡判断結果を表 2 に、従来との比較を表 3 に示す。全体の結果を見ると、認識率が 79.3% と従来方式と同等程度であるが、予測時間が 2 倍近く伸びているのがわかる。




図 11 パルス密度の最大値の分布

表 2 認識率と予測時間
(学習データ：93年度のデータ)

93年度			97年度		
データ	予測	時間[s]	データ	予測	時間[s]
1 : FO	FO	16.2	1 : NFO	FO	-
2 : NFO	NFO	-	2 : FO	FO	106.5
* 3 : FO	FO	92.3	3 : FO	FO	37.3
4 : NFO	NFO	-	4 : NFO	NFO	-
* 5 : NFO	NFO	-	5 : NFO	NFO	-
* 6 : FO	FO	87.4	6 : NFO	NFO	-
7 : FO	FO	94.0	7 : NFO	NFO	-
8 : FO	FO	2.0	8 : NFO	FO	-
* 9 : NFO	NFO	-	9 : FO	FO	263.8
10 : FO	FO	25.9	10 : NFO	NFO	-
	認識率	100%	11 : FO	FO	163.2
	平均予測時間 [s]	53.0	12 : NFO	FO	-
			13 : NFO	FO	-
				認識率	69.2%
				平均予測時間 [s]	135.8

94年度		
データ	予測	時間[s]
1 : FO	FO	107.7
2 : NFO	FO	-
3 : FO	FO	112.2
4 : FO	FO	58.4
5 : NFO	NFO	-
6 : NFO	FO	-
	認識率	66.6%
	平均予測時間 [s]	92.8

全体の認識率	79.3%
平均予測時間 [s]	89.8

注)
FO : Flashover, 閃絡
NFO : Non-Flashover, 非閃絡
*印は学習データを示す

表 3 性能評価

	認識率	平均予測時間
従来手法	83.3% (10/12)	38.2秒~51.3秒
本手法	79.3% (23/29)	89.8秒

5. GA による構成の最適化

本提案による閃絡予測 NN を構成するためには、様々なパラメータの調整を要する。例えば、NN の出力をパルスと判定するしきい値（以下パルス判定しきい値）、シグモイド関数の定数、閃絡データの学習範囲及び学習データなどである。これらの設定を解析的に行うのは時間的に効率的ではないと判断し、これらの調整に対し、効率的な探索手法といわれる遺伝的アルゴリズム（Genetic Algorithm：以下 GA）を適用した。

5-1 GA の構成

GA 操作に関しては、一般に単純 GA と呼ばれている基本的な方式を用いる。その構成を以下に示す。

遺伝子座	: 0 or 1
選択淘汰方法	: ルーレット方式
交叉方法	: 一点交叉
交叉率	: 0.4
突然変異方法	: 遺伝子反転
突然変異率	: 0.02
個体数	: 12
遺伝子長	: 30

遺伝子型の構成を表 4 に示す。学習データは 93 年度及び 94 年度のデータの中から選択され、ある遺伝子座の値が 1 のとき、それに対応するデータを学習させる。図 12 に遺伝子型の例を示す。

表 4 遺伝子型の構成

パラメータ	遺伝子座の数 n	変換式 ($0 \leq x \leq 2^n - 1$)	パラメータの範囲
シグモイド関数の定数	6	$0.05x + 0.1$	0.10 ~ 3.25
パルス判定しきい値	4	$0.05x + 0.15$	0.15 ~ 0.90
学習データ	15		
閃絡データの学習範囲	5	$3,000x + 10,000$	10,000 ~ 103,000

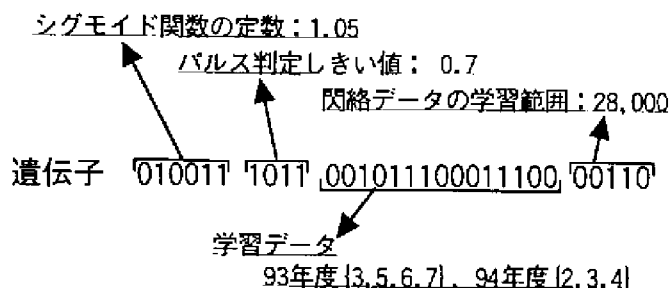


図 12 1 個体の遺伝子型例

適応度には NFO 認識数を用いる。ここでは、以下のようにスケールリングを行っている。

(適応度) = { (NFO 認識数) / (全 NFO データ数) }³
 GA による世代交代アルゴリズムを以下に示す。

- 初期遺伝子の生成
- 以下を繰り返す
 - 全個体の適応度計算
 - 選択淘汰
 - 交叉、突然変異

また、NN 学習の終了条件を新たに

- ・ 平均学習誤差が 0.1 以下になった場合
- ・ 学習時間が 10 分を越えた場合
- ・ 学習回数が 300 回を越えた場合
- ・ 平均学習誤差が 0.5 以上である期間が 10 以上続いた場合

とした。これは 1 個体あたりの計算時間をできるだけ短くすることが目的である。

5-2 GA による探索結果

上に示した構成により 100 回の世代交代を行った。表 5 に認識率の優れた個体の出現過程を示す。世代交代が進むに従って、NFO 認識数の優れた個体が生じていることが分かる。0~9 世代においてすでに NFO 認識数が 12 個である個体がみられ、さらに 20~29 世代で 13 個の個体が発生し、このとき全体の認識率は約 90%を示す。なお 100 世代以降では、NFO 認識率のより優れた個体は出現しなかった。

次項では、NFO 認識数が 13 個である遺伝子について認識結果を調べる。

表 5 NFO 認識数ごとの個体数変化

世代	認識率 (NFO認識数)			
	79%(10)	83%(11)	86%(12)	90%(13)
0 ~ 9	19	33	4	0
10 ~ 19	17	21	2	0
20 ~ 29	22	11	3	1
30 ~ 39	24	17	2	0
40 ~ 49	39	9	5	0
50 ~ 59	34	25	12	1
60 ~ 69	30	24	9	8
70 ~ 79	20	15	23	7
80 ~ 89	35	23	14	4
90 ~ 99	32	14	6	2

5-3 認識結果

NFO 認識数が 13 を示した個体のある学習結果について認識結果を示す。表 6 はその個体が示した学習条件である。図 13 は全データの最大パルス密度の分布を示す。この分布より閃絡判定しきい値は 88 と求まる。このしきい値を用いて認識を行った結果を表 7 及び表 8 に示す。全体の認識率が約 9 割に達し、平均予測時間も従来の手法を上回っていることが分かる。

表 6 学習条件

パラメータ		値
シグモイド関数の定数		1.0
パルス判定しきい値		0.35
閃絡データの学習範囲		82,000
学習データ	93	#2, #4, #5, #7, #9, #10
	94	#1, #6

表 7 認識率と予測時間

学習データ：93 年度及び 94 年度のデータ

93 年度

データ	予測	時間[s]
1 : FO	FO	2.8
* 2 : NFO	NFO	-
3 : FO	FO	36.7
* 4 : NFO	NFO	-
* 5 : NFO	NFO	-
6 : FO	FO	78.9
* 7 : FO	FO	121.7
8 : FO	FO	2.0
* 9 : NFO	NFO	-
* 10 : FO	FO	36.4
認識率		100%
平均予測時間 [s]		46.4

97 年度

データ	予測	時間[s]
1 : NFO	FO	-
2 : FO	FO	112.5
3 : FO	FO	26.0
4 : NFO	NFO	-
5 : NFO	NFO	-
6 : NFO	NFO	-
7 : NFO	NFO	-
8 : NFO	NFO	-
9 : FO	FO	251.3
10 : NFO	NFO	-
11 : FO	FO	18.6
12 : NFO	FO	-
13 : NFO	NFO	-
認識率		84.6%
平均予測時間 [s]		129.9

94 年度

データ	予測	時間[s]
* 1 : FO	FO	99.1
2 : NFO	FO	-
3 : FO	FO	52.6
4 : FO	FO	13.2
5 : NFO	NFO	-
* 6 : NFO	NFO	-
認識率		83.3%
平均予測時間 [s]		55.0

全体の認識率	89.7%
平均予測時間 [s]	65.5

注)
FO : Flashover, 閃絡
NFO : Non-Flashover, 非閃絡
*印は学習データを示す

表 8 性能評価

	認識率	平均予測時間
従来の手法	83.3% (10 / 12)	38.2 秒
本手法	89.7% (26 / 29)	65.5 秒




図 13 認識結果 (最大パルス密度の分布)

5-4 スキーマ解析

GA による世代交代を何度も繰り返していくと、遺伝子型の一次元配列の中に意味のあるパターンが発生する。このようなパターンをスキーマ (schemata) と呼ぶ。具体的にここでは、スキーマは {1, 0, *} の 3 種の記号列で表され、各個体の同じ遺伝子座に注目し、その遺伝子が全ての個体において同じか (0 or 1)、それとも異なるか (*) を示したものとする。

まず、今回行った GA の探索結果の中から、認識率が最大の 89.7% を示した全ての個体を抜き出し、それらの遺伝子型を表 9 に列挙する。0, 1 で示されている部分が遺伝子型の内容を示す。そして、表に示されている全遺伝子についてのスキーマを表下に示す。このスキーマより少なくとも以下のことが言える。

1, 次のデータは学習データとして適当である。

{ 93_7, 93_8, 93_9, 94_1, 94_6 }

2, 次のデータは学習データとして必要ない。

{ 93_1, 94_2 }

3, シグモイド関数の定数は、010000~011111

すなわち 0.9~1.65 が適当と考えられる。

表9 最大認識率を示した個体の遺伝子型

世代	個体番号	遺伝子型																											
		シグモイド関数の定数	パルス判定しきい値	学習データ										FOデータ学習範囲															
				93年度					94年度																				
		1	2	3	4	5	6	7	8	9	1	2	3	4	5	6													
x	27	6	0	1	0	0	0	0	1	0	1	1	0	1	0	1	0	0	1	1	1	1	0	1	0	0			
x	53	9	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	0	1	0	1	
	58	0	0	1	1	0	0	0	0	0	0	1	0	1	1	1	1	1	1	0	0	0	1	1	1	0	0	1	
x	61	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
x	61	2	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
x	61	3	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
x	62	3	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
x	62	4	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
x	63	6	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	64	1	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	69	11	0	1	0	0	0	1	0	0	1	1	0	1	0	1	1	1	1	0	0	0	1	1	0	0	1	0	0
	71	7	0	1	0	0	0	0	0	0	0	1	0	1	0	0	1	1	1	0	0	0	0	1	1	0	0	1	
	75	1	0	1	0	0	0	1	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	75	0	0	1	0	0	0	1	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	76	7	0	1	0	1	1	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	79	6	0	1	0	0	0	1	1	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	79	7	0	1	0	1	1	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	79	4	0	1	0	1	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	80	2	0	1	0	1	1	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	83	11	0	1	0	0	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	1	1	0	0	1	
	84	7	0	1	0	0	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	1	1	0	0	1	
	87	9	0	1	0	0	0	1	0	0	0	0	0	1	0	1	1	1	1	1	0	0	0	1	1	0	0	1	
	89	2	0	1	0	1	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1	
	93	10	0	1	0	1	0	0	0	1	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	1	0	0	1
	99	5	0	1	0	1	0	0	0	1	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1	0	0	0	1

スキーマタ 01*****0*****11110***1*****

このようにスキーマタ解析を行うことにより、高い認識率を示すときの遺伝子型の傾向を知ることができる。つまり、スキーマタで{0 or 1}によって示されている遺伝子は、高い認識率を示すために必要な遺伝子であるといえる。よって、今後GAによる探索を同じ条件で行う場合、スキーマタで{*}によって示される部分のみを遺伝子として表すことによって、GA探索をより効率的に行うことができる。

5.5 学習・認識の再現性

同じ遺伝子型をもつ複数の個体について、認識結果の違いを調べる。そのために、表9中で最も多い遺伝子型 011000000101011011110001110101 (×印)を持つ個体を、全世代にわたる全個体の中から抜き出した。

その結果62個体が見つかり、それらの認識率の分布は図14のようになり、認識率が最大となる確率は $5/62 = 8.1\%$ であった。このように遺伝子型が全く同一(すなわち学習条件が同一)であっても、結果が大きく異なって現れることがわかる。




図14 同じ遺伝子型をもつ個体の認識率の分布

このように認識率分布がばらつく理由としては、膨大な学習パターン数や学習方法自体の問題もあり得るが、NNの極小解に陥りやすい性質が最大の原因と考えられる。この場合、NNを用いてより高精度な認識率を目指す場合、認識率のばらつきは避けられないものと考えられる。よって、同一条件でNN学習を繰り返す必要がある。ここで、GAという探索アルゴリズムでは、同一の探索点において複数回の探索が可能であるため、あえて繰り返しを行わなくてもGA自体が試行と同様のことを行ってくれるのである。この点から、本NN構成とGAの組み合わせが非常に有効であると言える。

6. まとめ

従来の手法における問題点である比較的複雑な構成及び非常に長い学習時間を改善するため、NN構成から根本的に以下のような変更を加えた。

- ・比較的簡単な階層NN
- ・入力データの規格化
- ・ランダム学習
- ・パルス密度を用いた閃絡判断手法

さらに、様々なパラメータ設定及び学習データの選択に対して遺伝的アルゴリズムを用いた結果、学習時間、認識率及び予測時間は共に従来より向上し、本手法によるNN構成及び遺伝的アルゴリズムの組み合わせが有効であることが分かった。

今後の課題として、更に認識率を向上させる方法及び具体的な閃絡予測システムとしての検討などが挙げられる。

参考文献

- [1] T.Kamiyama,et al.: "The Mechanism of snow Accretion Growth on Conductors in Relation to Weather Condition in the Kantoh Plain" ,5th International Workshop on Atmospheric icing of Structures, B5-7,Tokyo,1990
- [2] 田中・大坪・大窪・馬場・長谷美・村上：“送電線着雪予測システムについて(その1), (その2)” 昭63日本雪氷学会全大, 211/213(1988)
- [3] 雀・西谷・長谷川・奈良：“電線着雪対策決定支援エキスパートシステムの開発”，電学論B, 103 卷8号, 669/676(1990)
- [4] 高橋：“ニューラルネットワークを利用した送電線着雪被害予測”，岩手大学情報工学科卒業研究報告書(1993)
- [5] 渡邊：“ニューラルネットワークを用いた冠雪閃絡現象の予測に関する研究”，岩手大学情報工学科卒業研究報告書(1995)
- [6] 王・渡邊・瓜田・吉田・恒川・三浦・上所・立崎：“ニューラルネットワークを用いた冠雪閃絡現象の予測”，電気関係学会東北支部連合大会論文集, 1E14(1995)
- [7] 王・吉田・恒川・三浦・上所・立崎：“ニューラルネットワークを用いた冠雪閃絡現象の予測 —第2報—”，情報学会第3回東北支部研究会資料(1995)
- [8] 山本・金丸・狩野・伊地知・近野：“ニューラルネットワークを利用した送電線着雪情報判定手法”，電学論B,112 卷7号, 585/592(1992)
- [9] 狩野・金田・金丸：“推論形ニューラルネットワークによる送電線の故障区間標定”，電学論C,110 卷7号, 420/427(1990)
- [10] 狩野・金田・金丸：“ニューラルネットワークによる送電線事故区間標定の高機能化”，電学論 B,111 卷11号, 1215/1222(1991)