

# The diagnostic system of klystron modulator using neural network

Masakatsu MUTOH, Shigekazu URASAWA, Tadahiro OONUMA,  
Yoshinobu SHIBASAKI, \*Isamu ABE and \*Kazuo NAKAHARA

Laboratory of Nuclear Science, Tohoku University  
\*KEK, National Laboratory for High Energy Physics

## Abstract

Voltage and current of a main circuit in a klystron modulator were observed to be changed widely within a few ten milli-seconds just before the modulator became in trouble. These changes formed a peculiar pattern which depended on parts in trouble. The diagnostic system of klystron modulator was tested to distinguish some patterns using neural network.

## ニューラル・ネットワークを応用した クライストロン・モジュレータの診断システム

### 1. はじめに

電子リニアックで使われるクライストロン・モジュレータの故障頻度は他の機器に比べて高い。故障が発生した場合には、その直前に主要な回路の電圧、電流が異常に変化し、変化の様子は故障箇所（故障原因）によって特有のパターンになるものと思われる。そこで各部の動作状態を常時測定し、故障発生直前の変動パターンから故障箇所を特定しようというもので、パターンの認識にニューラル・ネットワークを応用した。センサの数を多くすればより正確な情報が多く得られ、確実な診断が可能となるが、それらを適切に処理するソフトウェアは複雑になる。ここでは少ない既存のセンサを利用して診断することが狙いである。

今のところ、まだ実用状態になってはいないが、ニューラル・ネットワークに異常パターンを学習させ、認識テストを行なったところ良好な結果が得られたので報告する。

### 2. データ収集回路

測定は図1に示す回路の中でIVR直後の交流電圧・電流、直流平滑回路直後の電圧・電流を対象にした。信号はモジュレータのパネル面に取付けられている各電圧・電流計の端子よりピックアップし、図2の測定回路へ導く。信号は先ず、アイソレーション・アンプを通り、交流電圧・電流の信号は更に、実効値を直流に変換する素子を通る。信号処理にはVMEバスのI/Oチャンネルを利用したボード・コンピュータを用いた。信号はマルチプレクサ、サンプルホールド、ADC（12ビット）で収集される。測定は常時3mSec間隔で行ない、1信号当たり100点（300mSec分）のデータがマイクロプロセッサのメモリに蓄積される。

マイクロ・プロセッサは同時にシャットダウン・ステータスもモニタしていて、シャットダウンの発生で、メモリにある測定データ400点（100点×4）をRS-232C回線を使ってパソコンに送る。

図3はシャットダウンしたときの図2の測定回路で得たデータの例である。図3-(a)は放電などによる一時的な過電流、図3-(b)はサイラトロンの連続導通による過電流が原因と思われる電圧・電流パターンである。

ニューラル・ネットワークを応用する場合には、まずいろいろな事例の学習データが必要であるので、ここで用いているパソコンでは、ボード・コンピュータから送られてきたデータをフロッピーディスクへ記録して学習データの収集をしている。ニューラル・ネットワークのシミュレータは今のところ別のパソコンで動作させている。

### 3. ニューラル・ネットワークの学習と認識

ニューラル・ネットワークのシミュレータには、パソコンFMR-70（富士通）にデジタル信号プロセッサ（DSP）を搭載した専用のボードと、シミュレーション・ソフトNEUROSIM/Lを組み合わせたものを使用した。学習用のデータとしては、これまでに得たパターンの中から5つのパターンを選んだ。これらのパターンから特徴的な部分だけを抽出し、更にスムージング処理を行なってつなぎ合わせたものをネットワークの入力データとした。図4はテストに使用した学習データである。5つのパターンを学習させるためのネットワーク（3階層型）の構成は、入力層のニューロン数を140、中間層のニューロン数を40、出力層のニューロン数を5とした。パターンAは出力1がアクテブになるように、・・・、パターンEは出力5がアクテブになるように学習させた。学習方法はネットワークの出力値と期待する出力値（教師信号）との誤差が小さくなるようにニューロン間の重みを自動調整するバックプロパゲーション学習方式である。この例での学習回数は4506回（時間は約4分）であった。

次に、学習済みのネットワークを使って、他のパターンの認識を行なわせた。認識には図5のパターンを用いその結果を表1に示す。出力の値はどの学習パターンに似ているかによって0～1の値を示す。パターンFは出力1の値が他の出力より大きな値でパターンAに似ているという認識結果を示し、他も同様に類似のパターンに識別されていることを示している。

### 4. おわりに

故障診断システムとして実用化するにはもっと多くの故障時の学習データが必要である。それには故障発生を待つだけでなく、回路のシミュレーションなどからパターンを求め、学習データに加えるといったことも必要であろう。更に学習パターンが増えた場合の効率的な学習方法などについても詳細に検討する必要がある。




図1 クライストン・モジュレータのブロック図  
矢印の計器から診断のための信号を得た

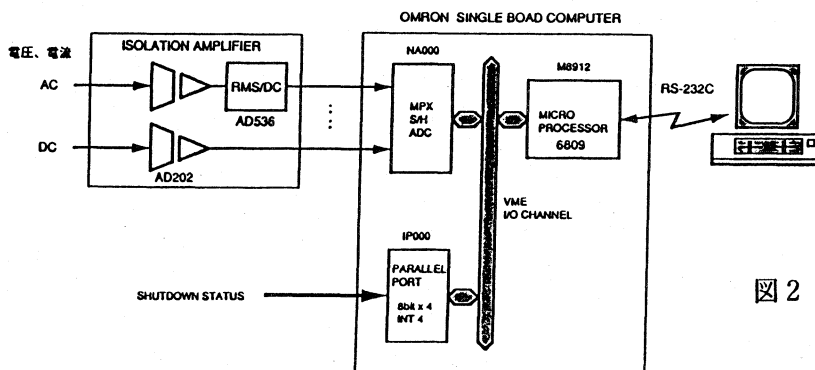


図2 データ収集回路のブロック図




図3 シャットダウン直前の電圧、  
電流の変化 波形は上から交流電圧、  
交流電流、直流電圧、直流電流  
測定時間 (横軸) は300 mSec




図4 学習させた5つのパターン  
(A、B、C、D、E)  
パターンBは図3-(a)、パター  
ンCは図3-(b)を処理したもの

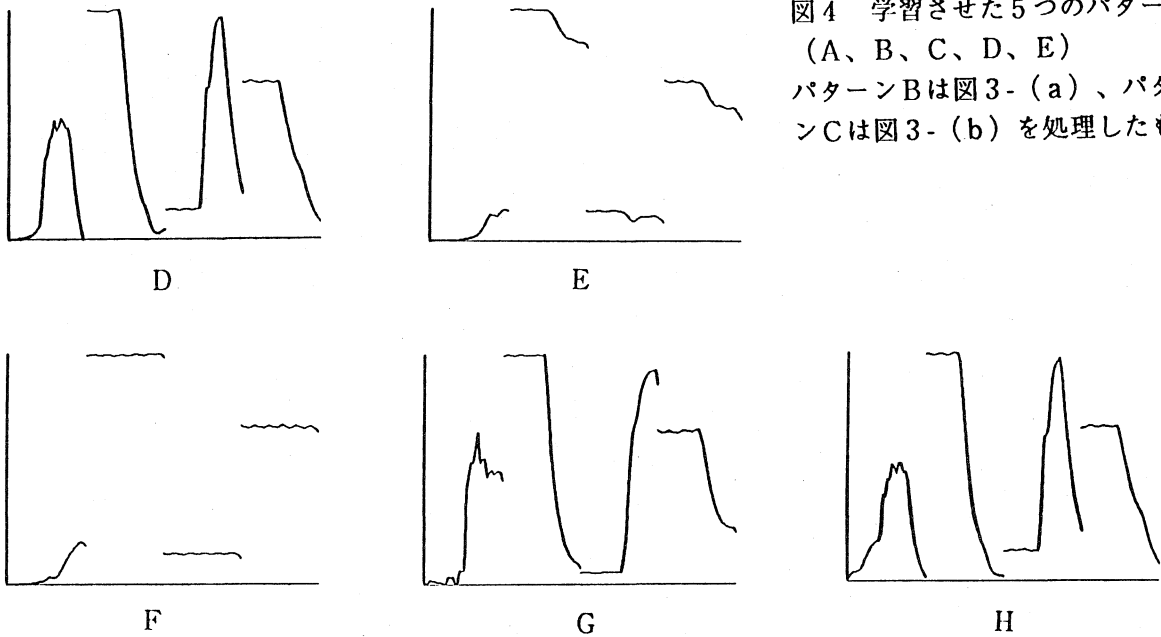


図5 認識テストに用いたパターン  
(F、G、H、I)

表1 認識結果一覧

	出力1 (A)	出力2 (B)	出力3 (C)	出力4 (D)	出力5 (E)
パターンF	0.886	0.008	0.003	0.009	0.176
パターンG	0.116	0	0.872	0.034	0.3
パターンH	0	0.008	0.029	0.903	0.01
パターンI	0.218	0	0.003	0.024	0.84