

신경회로망을 이용한 도로정보시스템의 고장정보처리 알고리즘 구현 및 적용에 관한 연구

류승기·최도혁·홍규장·문학동·임혁규·김재철

한국건설기술연구원, 송실대학교

A Study on implementation of the Fault Signal Process Algorithm for Highway Information System using Neural Network

Seung-Ki Ryu · Do-Hyuk Choi · Gyu-Jang Hong · Hak-Yong Moon · Hyuk-Kyu Lim · Jae-Chul Kim  
Korea Institute of Construction Technology · Soong-Sil University

1. 서론

현대 문명의 발달에 따른 차량 보유대수의 증가로 차량 통행량이 17배로 폭증하면서 도로 사용에 대한 부가가치를 높이기 위하여 여러 가지의 연구 보고가 이루어지고 있다. 이들 연구는 도로 상에 광범위하게 분포하고 있는 차량들을 인지하여 현재의 교통 상태 및 사고 유무 등을 운전자에게 실시간으로 제공하는 목적을 가지고 불류비 저감과 도로의 효율적인 사용을 유도하기 위한 국가적인 인프라 구축에 초점이 맞추어져 있다.

본 연구에서의 국토 관리용 유지관리 시스템은 수도권지역의 일반국도를 중심으로 구축되는 교통관리체계의 유지관리를 목적으로 한다. 국토 유지관리 시스템은 정보처리 용량, 지리적 여건, 그리고 향후 확장성을 고려하여 주(Master)의 기본개발환경은 UNIX-OS와 RDB구조의 데이터베이스 환경과 Client-Server 구조로 설계하였으며, 모든 정보는 실시간으로 운영되도록 이루어져 있다. 또한, 시스템 통합(SI) 및 지능형 유지관리 기법 등이 적용된 그래픽 통합 환경을 갖춘 도로 정보 제공 시설의 관리 기법(MMI 환경) 및 신경회로망을 이용한 고장진단 및 해석 시스템을 구현하였다.

2. 대규모 교통관리체계를 위한 유지관리 시스템 설계

제한한 시스템은 대규모 도로 교통관리체계의 유지관리를 지원하도록 운영자환경을 제한하여 실시간으로 정보교환을 수행하며 구성체계와 고장 정보처리 방법을 제안하였다.

2.1 시스템의 구성체계

본 시스템은 국토 상에 분산·분포되어 있는 검지장치의 상태를 감시하기 위한 감시제어모듈, 감시정보를 가공·처리·저장·제공하기 위한 중앙 처리부로 구성되며 그림 1과 같다. 전체적인 시스템의 구성체계는 광역으로 분산되어 있는 검지장치를 효과적으로 제어하기 위해서 분산 계층구조로 하였으며 구조는 그림 2와 같다.

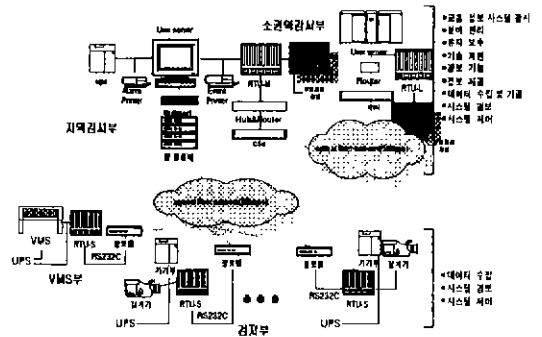


그림 1. 유지관리 시스템 구성 체계




그림 2. 분산 계층적 시스템 구성도

또한 유지관리 시스템의 지역 제어부와 소권역 제어부는 중단 제어부에서 전달되는 다중의 고장 정보 및 운영상태 정보로부터 정보처리 부하를 적절하게 분담하여 시스템의 성능을 합리화하는 비집중형 구조를 갖도록 하였다. 본 시스템의 정보처리 대상과 기능은 표 1과 같다.

표 1. 시스템의 정보처리 대상 및 기능

대	상	대	상	대	상	대	상
검지기	지형설비	중단 제어부 (RTU-S)	방화	불연방 상태	지역 및 소권역 제어부 (RTU-M, RTU-L)	검지기	전원상태, 동적상태
전원공급 및 토요설비	통신정보 및 지형설비		감시	신원(상용 및 비상)		환경	온도, 습도 등
VMS보호 및 지형설비	지형 및 난화설비	지역 제어부 (RTU-M, RTU-L)	제어	환경	환경설비	제어	환경
방재, 방화설비	공조설비		감시	전원상태, 동적상태	방화	방화, 화재, Door	제어
유압, 풍속감시	주요통신장치 상태감시		제어	환경	온도, 습도 등	통신	통신신호
전동(충격)감시			통신	통신신호	최신상태		

본 시스템의 주요 관리 설비는 현장의 검지장치, VMS, 각 센터 등이며, 시스템의 상태감시 정보는 현장 및 센터 설비 기기의 작동상태, 고장상태, 계측치, 원격제어 등이다. 이와 같이 다양한 유지관리에 대한 정보의 흐름은 지속적으로 수행되며, 그림 3는 정보 전송의 계층적 흐름을 표현한 논리적 구성도이다.




그림 3. 시스템 정보전송의 논리적 구성도

## 2.2 고장 정보 검출방법

대상 설비 중에서 고장정보를 처리하기 위한 감시사항은 설비상태정보, 계측정보, 전원 및 통신서지(Surge)정보 그리고 제어정보 등으로 분류하였다. 그림 4는 현장에 설치된 검지장치의 고장정보를 처리하기 위한 감시제어의 회로 구성도이다.

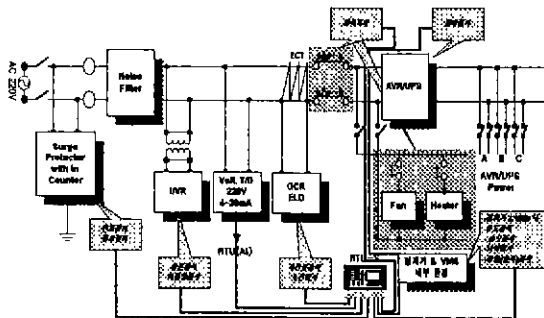


그림 4. 검지장치용 고장정보 처리의 감시제어도

그림 5는 지역 및 소권역 제어부 시스템의 고장정보 처리방법을 표현한 것이고, 여기서 지역 제어부의 고장정보 처리는 지역 제어부 시스템의 무인화와 온라인화를 목적으로 하고 있다.




그림 5. 중앙처리부 고장정보 처리의 감시제어도

## 2.3 고장 검출정보의 요소분석

시스템의 고장정보 처리를 위해 각 위계에서 발생하는 고장정보의 내용과 형태를 분석하였고 이로부터 고장해석을 수행하기 위해 신경회로망의 입출력 관계를 표 2와 같이 분석하였다. 고장 정보는 RTU에 의해 감시·제어되며, 이러한 정보는 광케이블을 통해 56Kbps급으로 중앙처리 영역에 전송된다. 아울러, RTU와 검지장치 간은 RS 232C통신방식을 사용하였다.

표 2. 고장정보의 입출력 리스트

구분	I/O Content	I/O Type	Unit	설정 Range	설정 Value	신경회로망 내역	입출력 종류	출력 종류	비고
검지장치	검지기 입력 전압 전압	AI	V	0	300	상태감시	Di	J	Do 1
	검지기 누전 경보	DI	발광	복귀	알림	상태감시	Di	2	
	검지기 낙뢰 발생	DI	회	0	1	상태감시	Di	3	
	검지기 AVR	DI	발광	OFF	On	상태감시	Di	4	
	검지기 저전압(LVRF)	DI	발광	OFF	On	상태감시	Di	5	
	검지기 통신(통신상태)	DI	상태	OFF	On	상태감시	Di	6	
	검지기 제어할 내부 온도	AI	℃	-30	90	상태감시	Di	7	
	검지기 제어할 내부 습도	AI	%	5	98	상태감시	Di	8	
	검지기 제어할 진동(충격)	DI	발광	복귀	알림	상태감시	Di	9	
	검지기 전선 Surge 발생	DI	발광	OFF	On	상태감시	Di	10	
	검지기 통신 Surge 발생	DI	발광	OFF	On	상태감시	Di	11	
	검지기 주전원 원격제어	Do	상태	OFF	On	제어감시	Di	12	
	검지기 제어할 원격제어	Do	상태	OFF	On	제어감시	Di	13	
	검지기 제어할 히터 원격제어	Do	상태	OFF	On	제어감시	Di	14	
가변정보표지점시스템(VMS)	VMS 입력 전압 전압	AI	V	0	300	상태감시	Di	1	Do 1
	VMS 누전 경보	DI	발광	복귀	알림	상태감시	Di	2	
	VMS 낙뢰 발생	DI	회	0	1	상태감시	Di	3	
	VMS AVR	DI	발광	OFF	On	상태감시	Di	4	
	VMS 저전압(LVRF)	DI	발광	OFF	On	상태감시	Di	5	
	VMS 출력	DI	상태	OFF	On	상태감시	Di	6	
	VMS 제어할 내부 온도	AI	℃	-30	90	상태감시	Di	7	
	VMS 제어할 내부 습도	AI	%	5	98	상태감시	Di	8	
	VMS 제어할 진동(충격)	DI	발광	복귀	알림	상태감시	Di	9	
	VMS 전선 Surge 발생	DI	발광	OFF	On	상태감시	Di	10	
	VMS 통신 Surge 발생	DI	발광	OFF	On	상태감시	Di	11	
	VMS 주전원 원격제어	Do	상태	OFF	On	제어감시	Di	12	
	VMS 제어할 원격제어	Do	상태	OFF	On	제어감시	Di	13	
	VMS 제어할 히터 원격제어	Do	상태	OFF	On	제어감시	Di	14	
지역 및 소권역 제어부	센터 입력 전압 전압	AI	V	0	300	상태감시	Di	1	Do 1
	센터 입력 전압 전류	AI	A	0	30	상태감시	Di	2	
	센터 누전 경보	DI	발광	복귀	알림	상태감시	Di	3	
	센터 낙뢰	DI	회	0	1	상태감시	Di	4	
	센터 AVR	DI	상태	OFF	On	상태감시	Di	5	
	센터 저전압(LVRF)	DI	발광	OFF	On	상태감시	Di	6	
	센터 과전류(OCR)	DI	발광	복귀	알림	상태감시	Di	7	
	센터 과전압(OVR)	DI	발광	복귀	알림	상태감시	Di	8	
	센터 발광(Door 개폐 상태)	DI	상태	단원	알림	상태감시	Di	9	
	센터 내부 온도	AI	℃	-30	90	상태감시	Di	10	
	센터 내부 습도	AI	%	5	98	상태감시	Di	11	
	센터 진동(충격)	DI	발광	복귀	알림	상태감시	Di	12	
	센터 발광(습기 동작)	DI	상태	적정	적응	상태감시	Di	13	
	센터 향온(습기 고장)	DI	발광	복귀	알림	상태감시	Di	14	
센터 전선 Surge 발생	DI	발광	OFF	On	상태감시	Di	15		
센터 통신 Surge 발생	DI	발광	OFF	On	상태감시	Di	16		
센터 주전원 원격제어(차단)	Do	상태	OFF	On	제어감시	Di	17		
센터 주전원 원격제어(부담)	Do	상태	OFF	On	제어감시	Di	18		
센터 Door 원격제어(On/Off)	Do	상태	단원	발원	제어감시	Di	19		
센터 향온(습기 원격제어)	Do	상태	-	-	제어감시	Di	20		
센터 향온(습기 원격제어)	Do	상태	-	OFF	제어감시	Di	21		

## 3. 신경회로망 모델링을 이용한 고장 해석

본 연구에서는 고장정보에 의한 진단을 위해 유지보수 전문가들과 함께 작성한 고장 리스트로 진단 지식베이스를 구성하고, 다층 신경회로망을 이용하여 고장해석을 수행하였다.

### 3.1 신경회로망 모델링

본 연구에서 학습과정은 역전파알고리즘을 사

용하였다. 또한 이러한 역전과 알고리즘의 연결 강도의 결정은 학습오차의 제곱이 가장 많이 감소하는 방향으로 변화하는 기울기 강하법 (Gradient decent method)을 이용하였다. 그림 6은 기울기 강하법에 대한 개념도로 궤적 ①은 모멘텀 상수를 포함하지 않은 경우이고, 궤적 ②는 모멘텀 상수를 포함한 경우이다.




그림 6. 기울기 강하법

입력층 처리기 노드는 표 2의 고장정보 리스트에서 현장 검지장치 14점, VMS 14점, 센터부 21점을 신경회로망의 입력노드로 설정하였고, 출력점으로는 검지장치와 VMS에 대해 각 4개점, 센터 8점으로 구성하였다.

신경회로망의 수렴성능을 확인하기 위해 학습 오차에 대한 평가함수는 다음과 같으며 이로부터 오차를 줄이도록 학습시켰다.

$$J = \frac{1}{2} E^T(k+1)E(k+1)$$

$$E(k+1) = [E_1^T(k+1) \cdots E_N^T(k+1) \cdots E_N^T(k+1)]^T$$

오차함수(E)는 지역 시스템과 지역 기준 모델의 출력 오차를 학습함수로 나타낸 것이고, 입력층과 출력층 그리고 1개의 중간층을 가지는 다층 신경회로망 구조로서 수학적 모델로 표현하면 다음과 같다.

$$R_i(k) = \sum_j W_{ij} \cdot I_j(k)$$

$$H_i(k) = f(R_i(k))$$

$$Z_i(k) = \sum_j W_{ij} \cdot H_j(k)$$

여기서,  $I_i(k)$ ,  $H_j(k)$ ,  $Z_i(k)$ 는 각각 신경회로망의 입력, 중간층의 출력, 신경회로망의 출력이고,  $W_{ij}$ ,  $W_{ij}$ 는 입력과 출력층에서의 연결강도이다. 학습을 위한 연결강도에 대한 오차 함수의 기울기는 다음과 같다.

$$\frac{\partial J}{\partial W_{ij}} = \left\{ \frac{\partial E^T(k+1)}{\partial Z(k)} \cdot \frac{\partial J}{\partial E(k+1)} \right\} \cdot \frac{\partial Z(k)}{\partial W_{ij}}$$

$$\frac{\partial J}{\partial W_{ij}} = \left\{ \frac{\partial E^T(k+1)}{\partial Z(k)} \cdot \frac{\partial J}{\partial E(k+1)} \right\} \cdot \frac{\partial Z(k)}{\partial W_{ij}}$$

$$\frac{\partial Z(k)}{\partial W_{ij}} = \frac{\partial Z(k)}{\partial H_j(k)} \frac{\partial H_j(k)}{\partial R_j} \frac{\partial R_j(k)}{\partial W_{ij}}$$

$$\frac{\partial Z(k)}{\partial H_j} = \left[ \frac{\partial \hat{z}_1(k)}{\partial H_j(k)} \frac{\partial \hat{z}_2(k)}{\partial H_j(k)} \cdots \frac{\partial \hat{z}_n(k)}{\partial H_j(k)} \right]^T$$

여기서,  $Z_i(k) = \hat{Z}_i(k)$  ( $i=1, 2, \dots, n$ )이고, 기울기를 이용한 신경회로망 연결강도는 다음과 같다.

$$W_i(t+1) = W_i(t) + \eta \cdot \left( -\frac{\partial J}{\partial W_i} \right) + \alpha \Delta W_i(t)$$

$$W_O(t+1) = W_O(t) + \eta \cdot \left( -\frac{\partial J}{\partial W_O} \right) + \alpha \Delta W_O(t)$$

여기서,  $\eta$ ,  $\alpha$ 는 각각 학습률과 모멘텀이다. 출력값과 요구 출력패턴이 일치하면 학습이 종료되나 그렇지 못할 경우 이 차이를 감소시키기 위해 하단 방향으로 기울기 강하법에 의해 연결 강도를 보정한다. 학습률과 모멘텀 항은  $0 < \eta < 1$ ,  $0 < \alpha < 1$ 사이의 값과 중간층 노드수를 변화시키면서 반복학습에 의해 추론된 출력값과 실제의 출력 데이터의 오차 값이 일정범위 안에 들면 학습을 종료하여 학습성능을 분석하였다.

### 3.2 고장정보 해석 방법

본 연구에서는 여러 지역에 분산된 설비요소로부터 다중으로 발생하는 고장정보의 형태와 다중으로 검출되는 다중 고장정보에 대해 최적의 고장정보를 추출하여 신경회로망의 학습자료로 사용하였다. 일반적으로 N개의 지역 시스템들로 전체 시스템을 구성하거나 전체 시스템을 N개의 지역시스템으로 나눌 때, i번째 지역 시스템을 이산시간 상태공간 모델로 표현하면 다음과 같다.

$$X_i(k+1) = f_i(X_i(k), U_i(k)) + g_i(X_1(k), \dots, X_i(k), \dots, X_N(k)) \quad (i, j=1, 2, \dots, N, j \neq i)$$

여기서,  $X_i \in R^m$ ,  $U_i \in R^m$ ,  $f_i(\cdot)$ ,  $g_i(\cdot)$ 는 상태변수, 입력변수, i번째 지역시스템의 비선형 함수, i번째 지역시스템에 작용하는 상호작용 요소를 나타내는 비선형 함수이다.

본 연구에서는 신경회로망을 이용하여 지역시스템(각 감시장치, VMS 등)에 발생하는 다중 고장정보에서 고장해석을 하기 위해 전문가의 지식을 기준적인 고장해석으로 정의하여 이와 비교하여 발생하는 편차를 줄이도록 학습시키고 있다.

## 4. 시스템의 모의 실험

### 4.1 고장해석 실험방법 및 평가

먼저, 표 3은 표 2의 설정 학습패턴에 대한 모의 실험으로 검지장치로부터의 고장정보와 신경회로망의 입출력 인터페이스를 일례로 정리한 것이다.

표 3. 고장검출정보와 학습정보

패턴 VF	1	2	3	4	5	6	7	8	9	10	11	12	13	14
검지장치 1	내용	전원	부전	낙피	AVF	지진	통신	할도	할도	전동	통신	통신	통신	통신
상태	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상
검출정보	0	0	0	0	1	0	0	0	0	1	0	0	0	0
검지장치 2	내용	전원	부전	낙피	AVF	지진	통신	할도	할도	전동	통신	통신	통신	통신
상태	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상	정상
검출정보	0	1	0	0	0	0	0	0	0	0	0	0	0	0

속력 VF	1	2	3	4	5	6	7	8
학습정보(패턴 A)	1	0	0	1	1	0	0	0

고장 검출정보 및 학습 정보 패턴에 대해 제 1안한 신경 회로망의 성능을 확인하기 위해, 학습률( $0 \leq \eta \leq 1$ )을 0.9, 0.7, 0.5로 설정하였고, 모멘텀 상수( $0 \leq \alpha \leq 1$ )는 0.7, 0.5, 0.3으로 변화시켰고, 중간층 노드수를 10개에서 100개 사이를 변화시켰다. 모의실험을 수행하는 방법은 중간층 노드 수와 학습률 그리고 모멘텀 상수를 변경하면서 학습횟수와 목적출력에 대한 실패 오차(RMSE)를 평가하여 중간층 노드수, 학습률 및 모멘텀 상수를 결정하였다.

4.2 실험결과 비교 분석

4.2.1 중간층 노드 수 영향 분석

중간층 노드 수의 선정을 위하여 표 3의 고장정보를 이용하여 모의 실험한 결과는 표 4와 같다. 중간층 노드 수의 영향은 임·출력층 노드 수의 2배 보다 적게 선정하는 것이 경험적으로 적용되고 있다. 실험방법은 표 3의 학습자료를 토대로 학습률과 모멘텀 상수, 그리고 중간층 노드수를 변화시키면서 학습성능(RMSE)을 비교하였다. 그리고, 표 4의 RMSE값은 최종적으로 학습을 수행한 결과로 중간층 노드수의 변화에 대한 영향보다는 모멘텀 상수와 학습률에 대한 영향을 상대적으로 받고 있음을 알 수 있다.

표 4. 학습성능(학습횟수:50,  $\eta$ :학습률,  $\alpha$ :모멘텀)

·6학습오차	$\eta=0.9$	$\eta=0.7$	$\eta=0.5$	$\eta=0.3$	$\eta=0.1$
	$\alpha=0.3$	$\alpha=0.3$	$\alpha=0.3$	$\alpha=0.3$	$\alpha=0.3$
Hidden Nodes	RMSE	RMSE	RMSE	RMSE	RMSE
10-100	0.01559	0.02273	0.02348	0.02302	0.06163

학습오차	$\eta=0.9$	$\eta=0.7$	$\eta=0.5$	$\eta=0.3$	$\eta=0.1$
	$\alpha=0.1$	$\alpha=0.1$	$\alpha=0.1$	$\alpha=0.1$	$\alpha=0.1$
Hidden Nodes	RMSE	RMSE	RMSE	RMSE	RMSE
10-100	0.01559	0.02273	0.02348	0.02302	0.06163

4.2.2 모멘텀과 학습률 영향 분석

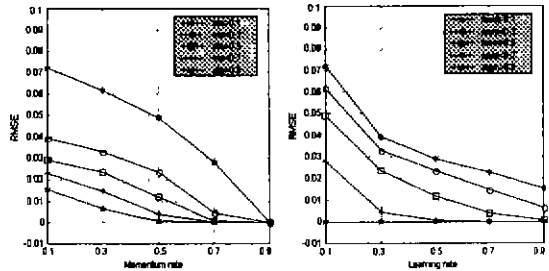
중간층 노드수의 변화에 대한 학습성능(표 4)에 비해, 모멘텀 항의 계수와 학습률은 학습성능에 비교적 영향을 주었으며, 그 결과로 학습률과 모멘텀 계수변화에 대한 학습성능은 표 5와 같다.

표 5. 학습성능(학습횟수:50, 중간층 노드수:30)

$\alpha$	$\eta=0.9$	$\eta=0.7$	$\eta=0.5$	$\eta=0.3$	$\eta=0.1$
	RMSE	RMSE	RMSE	RMSE	RMSE
0.1	0.01559	0.02273	0.02324	0.03908	0.07195
0.3	0.01559	0.01487	0.02348	0.03302	0.06163
0.5	0.01559	0.01299	0.01191	0.02344	0.04911
0.7	0.01559	0.01178	0.00772	0.00968	0.02797
0.9	0.00008	0.00000	0.00000	0.00000	0.00000

학습횟수는 50회로 제한하였고, 이 때  $\eta, \alpha$ 를 변화시키면서 RMSE를 분석하였다. 학습결과에 대해서 오차한계를  $10^{-2}$ 이내로 설정한 경우, 학습률과 모멘텀 계수의 설정범위를 각각  $0.3 \leq \eta < 1, 0.5 \leq \alpha < 1$  범위 내의 값(표 5의 역상영역)으로 설정하면, 비교적 양호한 학습성능을 볼 수 있다.

표 4, 5와 그림 7은 최적의 학습계수(중간층 노드수, 학습률, 모멘텀 계수)를 결정하기 위한 변수 보정 과정을 실시한 것이고 이로부터 적절한 학습오차의 한계를 설정하였다. 보정된 학습계수를 이용하여 고장정보가 발생하는 패턴을 5가지의 가상목표 패턴을 설정한 후, 이에 대한 학습성능을 분석하였다.



(a) 학습률 가변 (b)모멘텀 가변  
그림 7. 학습오차와 모멘텀 관계

4.2.3 고장 패턴별 학습성능 분석

신경회로망의 학습성능을 분석하기 위해 5가지 경우의 고장 해석을 목표패턴으로 제시하였다. 표 6의 결과는 학습 횟수를 제한하였으며, 최종 학습횟수에서의 RMSE 값과 그 때의 신경회로망 출력값이다.


- 패턴 A : 검지장치(지역시스템) 1, 검지장치(지역 시스템) 2 전원부 경보, 검지장치 1 제어부 고장경보 발생
- 패턴 B : 검지장치 1 전원부 경보 발생, 검지장치 2 전원부 이상, 써지 경보 발생
- 패턴 C : 검지장치 1 전원부/합체 이상경보 발생, 검지장치 2 전원부/제어부 이상경보 발생
- 패턴 D : 검지장치 1 합체 이상경보 발생/제어부 이상발생, 검지장치 2 합체/제어부 고장경보 발생

패턴 E : 검지장치 1 전원부/함체 고장 경보/써지 경보 발생, 검지장치 2 전원부 고장/써지 경보 발생

표. 6. 패턴별 성능(학습회수:50, 중간노드 수:30)

No. of WF		1	2	3	4	5	6	7	8
목 표 출 령		1	0	0	1	1	0	0	0
패턴 A	a $\eta=0.9$ $\alpha=0.7$ 학습 출력	0.99999	0	0	0.99999	0.99999	0	0	0
	b $\eta=0.7$ $\alpha=0.5$ 학습 출력	0.99376	0	0	0.99376	0.99376	0	0	0
	c $\eta=0.5$ $\alpha=0.3$ 학습 출력	0.96165	0	0	0.96165	0.96165	0	0	0
목 표 출 령		1	0	0	0	1	0	1	0
패턴 B	a $\eta=0.9$ $\alpha=0.5$ 학습 출력	0.99977	0	0	0	0.99977	0	0.99977	0
	b $\eta=0.7$ $\alpha=0.4$ 학습 출력	0.98521	0	0	0	0.98521	0	0.9852	0
	c $\eta=0.5$ $\alpha=0.2$ 학습 출력	0.96637	0	0	0	0.96637	0	0.9663	0
목 표 출 령		1	1	0	0	1	0	0	1
패턴 C	a $\eta=0.9$ $\alpha=0.5$ 학습 출력	0.99857	0.99857	0	0	0.99857	0	0	0.0086
	b $\eta=0.7$ $\alpha=0.4$ 학습 출력	0.98521	0.98521	0	0	0.98521	0	0	0.9852
	c $\eta=0.5$ $\alpha=0.3$ 학습 출력	0.96165	0.96165	0	0	0.96165	0	0	0.9616
목 표 출 령		0	1	0	1	0	1	1	0
패턴 D	a $\eta=0.9$ $\alpha=0.7$ 학습 출력	0	0.99998	0	0.99998	0	0.99998	0.9999	0
	b $\eta=0.7$ $\alpha=0.3$ 학습 출력	0	0.97571	0	0.97571	0	0.97571	0.9757	0
	c $\eta=0.5$ $\alpha=0.1$ 학습 출력	0	0.95226	0	0.95226	0	0.95226	0.9522	0
목 표 출 령		1	1	1	0	0	1	0	1
패턴 E	a $\eta=0.9$ $\alpha=0.3$ 학습 출력	0.99336	0.99336	0.99336	0	0	0.99336	0	0.9933
	b $\eta=0.7$ $\alpha=0.2$ 학습 출력	0.96821	0.96821	0.96821	0	0	0.96821	0	0.9682
	c $\eta=0.5$ $\alpha=0.1$ 학습 출력	0.95226	0.95226	0.95226	0	0	0.95226	0	0.9522

그림 9의 (a)는 모멘텀 값을 0.5로 고정된 후 학습률을 변화하면서 학습오차를 분석한 결과로서 학습률의 증가변화에 대해서 오차가  $10^{-2}$  이내로 점진적으로 감소하고 있다. 그리고, 그림 8의 (b)는 학습률을 0.5로 고정된 후, 모멘텀 계수를 변화시켜가면서 학습오차를 분석한 결과이며, 목표 오차 이내로 접근하고 있음을 보이고 있다. 두 경우의 학습결과에서 보듯이 양호한 학습성능을 보이는 학습계수의 범위를 설정할 수 있었다.



(a) 학습률 변화시 (b) 모멘텀 변화시  
그림 8. 학습오차

학습 결과에서 알 수 있듯이, 전문가 지식에

의한 고장 해석을 목표패턴으로 설정하였고, 신경회로망 학습을 통해 고장 해석한 결과, 표 6을 토대로 전문가적 지식의 목표 패턴에 대해서 패턴 A는 96.1%, 패턴 B는 95.6%, 패턴 C는 96.2%, 패턴 D는 96.2%, 패턴 E는 95.2%의 정확성을 가지고 인식하였다.

신경 회로망의 출력된 정보들이 목적된 출력에 수렴하고 있으므로 이들의 출력 결과를 진단 지식베이스의 진단 지식과 연계를 통하여 보수 점검 규칙을 실시간으로 운영환경에 표현할 수 있다. 즉, 광역으로 분포되어 있는 각 지역 시스템의 고장 정보를 실시간으로 정보를 해석하여 고장에 신속히 대처할 수 있다. 본 연구에서는 제안한 신경망과 고장 진단 지식베이스를 통해 분산 운영되는 지역시스템의 정보를 가지고 고장 내용을 관리자가 파악할 수 있도록 유지관리 시스템을 구현하였다.

#### 4.3 시스템 운영환경 구현 및 모의 실행

유지관리시스템의 개발환경은 윈도우95를 운영체제로 하였으며, 32bit용 비주얼베이직(VB) 소프트웨어를 이용하여 전체화면과 운용루틴을 구성하였다. 장비관리데이터베이스는 VB와 링크되어 있는 MS Access 엔진을 사용하였으며 구조는 그림 9와 같은 형태로 설계하였다. 현장에 설치 운영되는 검지장비, VMS, 센터 설비 등을 기능적으로 모듈화 하여 테이블을 구성하였고, 정의한 테이블에는 검지장비의 세부 사양과 설치위치 등의 내용을 관리할 수 있도록 필드와 인덱스구조를 포함하였다. 그림 10는 본 연구의 유지관리 시스템 운영환경을 구현한 것으로, 운영환경 안에서 장비관리를 위한 이력관리 환경과 고장정보 처리를 수행하는 신경망의 학습과정, 그리고 설비상태를 실시간으로 감시하는 온라인 환경을 동시에 표출한 것이다.





그림 9. 장비이력 DB 그림 10. 통합 환경

#### 5. 결론

본 연구에서는 현재 시스템의 고장정보를 중심으로 고장 발생시 관리자들에게 고장정보에 따른 조치요소를 결정할 수 있도록 유지관리 시스템을 구현하여 미숙련자도 운전이 가능하도록 하였다. 유지관리 시스템에는 신경회로망의 역전파 알고리즘과 고장 진단 지식베이스를 이용하

여 최소 고장정보 요소를 추론하도록 구현되어 있으며, 학습성능을 모의 실험하면서 고장정보처리 결과를 비교·분석하였다. 고장정보처리에 있어 양호한 학습성능을 보이는 학습계수의 적정 범위를 결정하였고, 여러 종류의 고장해석 패턴에 적용하여 유용함을 보였다.

신경회로망을 활용한 고장 정보 처리 기법과 장비관리용 이력 데이터베이스를 통합하여 처리할 수 있는 유지관리 그래픽 인터페이스 환경을 제안하였다. 이를 이용하여 고장발생에 대한 전문가적 지식정보를 관리자에게 제공하므로써, 비전문가도 현재의 운전상태를 손쉽게 파악할 수 있는 것이 특징이다. 따라서, 고장 진단 지식베이스에 대한 정보가 더욱 축적되면, 고장정보의 처리 성능은 더욱 향상될 것으로 판단된다.

#### 참고문헌

1. 한국건설기술연구원, "수도권 도로 교통정보 관리체계 구축 기본설계 및 평가연구," 1997.
2. 한국도로공사, "고속도로 교통관리 기본설계 및 시범구간(pilot project)실시설계," 1992.
3. 한국건설기술연구원, "전기설비 보수지원용 진단프로그램 개발," 1997.
4. 홍규장 외, "공동주택에서 신경회로망을 이용한 승강기 계통 경보처리 시스템 개발 연구," 한국조명·전기설비학회지, Vol. 11, No. 4, 1997.
5. Martin Schockle, Mathias Hinkelmann, "Development of a Fault Diagnosis Tool Applying Associative and Rule Based Methods," International Energy Agency Annex 25, 1995.
6. C.T. Lin and C.S.G. Lee, "Neural fuzzy Systems," Prentice-Hall, 1996.
7. J.Hu, "Fault detection of nonlinear systems based on quasi-ARMAX model", '97 Proceeding of 36th SICE Annual Conference, pp.323-324, 1997.