

신경회로망을 이용한 분산계층 구조용 도로 유지관리설비의 고장정보처리에 관한 연구

A Study on the Fault Signal Process of Hierarchical Distributed Structure for Highway
Maintenance systems using neural Network

류승기* · 문학룡* · 홍규장* · 최도혁* · 한태환** · 유정웅***

(Seung-Ki Ryu · Hak-Yong Moon · Gyu-Jang Hong · Do-Hyuk Choi · Tae-Hwan Han · Jeong-Woong Yu)

요 약

본 논문에서는 도로 교통 정보설비의 유지관리를 위해 지능형으로 수행하는 원격감시제어 시스템을 제안하였다. 제안된 시스템은 국도 3호선에 설치되는 도로교통 설비에 대하여 유지관리를 수행하도록 시스템적으로 구축되어 있으며, 전송된 고장 정보는 중앙감시센터의 고장 정보 분석 알고리즘에 의해서 정보의 특성을 파악하도록 하였다. 분석 알고리즘은 신경회로망을 이용하여 다중으로 발생하는 고장정보에 대해서 지식 기반의 고장현상을 추론하도록 제안하였다.

고장 정보 분석 알고리즘의 유용성을 확인하기 위해 현장에서 실시간으로 전송되는 바이너리 신호의 패턴을 5가지 형태로 분류하여 성능을 분석하였으며, 이를 중앙감시센터에서의 유지관리용 운영환경 하에서 구현되도록 하였다.

Abstract

This paper proposed a design of intelligent supervisory control systems for maintenance of highway traffic information equipment and processing algorithm of equipment fault data. The fault data of highway traffic equipment are transmitted from remote supervisory controller to central supervisory system by real time, the transmitted fault data are analyzed the characteristic using evaluation algorithm of fault data in central supervisory system. The evaluation algorithm includes a neural network and fault knowledge-base for processing the multi-generated fault data.

For validating the evaluation algorithm of intelligent supervisory control systems, the method of analysis used to the five pattern of binary signal by transmitted real time and the operating user-interface constructed in central supervisory system.

1. 서 론

자동차 보유대수가 최근 10년 사이에 10배 이상, 1일 차량 통행량이 17배로 폭증하면서 도로 사용에

대한 효율성을 높이기 위한 여러 가지의 연구 보고가 이루어지고 있다[1~4].

이들 연구는 도로 상에 광범위하게 분포하고 있는 차량들을 인지하여 현재의 교통 상태 및 사고 유무 등을 운전자에게 실시간으로 제공하는 목적을 가지고 물류비 저감과 도로의 효율적인 사용을 유도하기 위한 국가적인 인프라 구축에 초점이 맞추어져 있다.

*정회원 : 한국건설기술연구원

**정회원 : LG 산전

***정회원 : 충북대학교 전기공학과

접수일자 : 1998. 8. 19.

일반적으로, 도로의 차량을 검지한 정보는 유·무선 통신망을 활용하여 일정한 지역으로 전송하며, 대부분 주(Master)-종(Slave)의 토폴로지(Topology)가 주류를 이루고 있다. 전송되는 정보는 동영상(1.544Mbps) 또는 텍스트(9.6kbps이상)형태로 운전자에게 교통상황 정보를 제공하고 있다[1].

한국도로공사[2]에서는 고속도로를 대상으로 영상 검지기와 루프(loop) 검지기를 활용하여 가시 정보(VMS)와 함께 Web과 ARS를 이용하여 교통정보를 운전자에게 제공하고 있다. 서울시[3]에서는 올림픽 도로를 대상으로 영상검지기를 활용하여 가시적 정보제공과 함께 Web에 정보를 제공하고 있다. 교통개발연구원에서 과천시에 설치하여 운영하고 있는 방식도 위와 유사하게 구현되어 있다[4]. 이와 같이 운영되고 있는 도로정보를 실시간으로 제공하는 목적으로 구축된 시설로서 시스템의 유지관리를 지원할 수 기반은 시스템적으로나 정책적으로 미비한 실정이다.

본 연구에서는 국도 3호선(약 50[km])에 도로 정보화 장비들을 설치하여 교통관리체계를 구축하였으며, 이에 대해 효과적인 유지관리 방법을 도출하는 데 목적으로 한다. 구현된 유지관리시스템은 현장의 감시 대상 시설, 정보처리 형태, 지리적 여건, 그리고 향후 확장성을 고려하여 Master 레벨의 개발환경은 UNIX-OS와 관계형 데이터 베이스 환경과 클라이언트-서버 구조로 설계하였으며, 모든 정보는 실시간으로 운영되도록 이루어져 있다. 특히, 경보를 이용한 설비의 고장 원인 검색을 지능형으로 수행하기 위해서 추론엔진과 진단지식 베이스가 별도로 분리된 병렬 모듈형 구조를 가지고 고장진단과 유지관리를 지원하도록 하였다. Slave 레벨은 현장 시설의 상태 정보와 각종 시설물의 관리 정보 등을 모니터링을 수행하고 발생한 결과를 상위 계층에 전송하고, 일부 원격 감시제어 정보를 하위 계층에 전송할 수 있도록 하였다.

일반적인 설비의 고장진단은 각종 보호설비에서 발생하는 이상 정보를 감시하여 보수조치를 취하는 예방보존의 방식을 취하고 있지만 관련 법률안에 근거한 점검과 진단 등의 대행 업무를 수행하고 있는 것이 추세이다. 이와 같은 업무를 지원하는 감시반은 발생하는 경보 신호로 설비의 이상유무를 판단하도록 구현되어 있지만, 해당분야의 전문 지식을 갖춘

전문가에 의한 진단이 선행되거나, 진단에 필요한 진단 규칙이 완전하게 구축되어 있을 경우 진단 업무에 대한 신뢰성이 확보될 수 있다[5],[7]. 그러나, 도로정보 체계를 실현하는 설비들에 관련된 유지보수 규칙, 진단 규칙 및 전문가가 미비하여 고장 진단과 유지관리에 부담감을 주고 있는 실정이다[6]. 따라서, 본 연구에서는 도로 정보체계에서 경보를 활용한 지능형 유지보수 진단시스템의 유용성을 검토하며 구성된 진단 규칙 체계는 다음과 같다.

하드웨어적으로는 전력설비의 감시체계를 적용하여 기존의 고장진단 규칙을 활용할 수 있도록 기획되어 있으며, 소프트웨어적으로는 현장에서 랜덤하게 발생하는 경보를 이용하여 고장진단을 수행할 수 있도록 추론엔진과 고장진단 지식베이스로 이루어져 있다. 추론엔진을 구성하는 방법에는 우선 순위 규칙, 관계 데이터 베이스 등과 같은 기법을 적용할 수 있으나, 이들 모두는 진단 규칙이나 전문가 규칙에 활용할 수 있는 지식기반이 정립된 경우에 추론 결과에 대한 신뢰성이 확보되므로 본 연구에서는 신경회로망을 적용토록 하였다. 추론에 적용된 신경회로망은 다음과 같다. 적용된 신경 회로망은 기울기강화법(Gradient decent method)으로 학습하도록 구성되어 있으며 운전 중에 발생할 수 있는 경보들에 대한 가상된 시나리오를 구성하여 중간층 노드 수와 학습률, 관성항을 변경하면서 학습을 수행하였다. 그러나, 신경회로망은 서술된 자료만을 활용하여 병렬 동작으로 그 결과를 도출하므로 추론된 결과가 그대로 지식적 표현과 전문가 지식으로 반영되는 것이 어려운 문제이므로 고장 진단 지식베이스와 연계토록 구성하였다.

고장 진단 지식베이스는 고장원인(symptom)/고장(fault)관계로 데이터 베이스화 되어 있지만 활용한 진단 지식베이스는 도로 환경 구조에 활용할 수 있도록 건축물의 전기설비에서 사용하는 진단 규칙의 일부를 개정하여 서술되어 있다.

2. 분산형 도로관리체계의 유지관리 시스템

본 연구는 국도 3호선의 50[km]에 시설되고 있는 교통 정보화 관련설비들을 원격지에서 실시간으로 상태감시·제어가 되도록 하였다. 본 시스템은 그래

픽 통합 환경을 갖추고 항상 원거리에 떨어져 있는 계통의 안정성을 운전원이 우선적으로 확보할 수 있도록 경험적 지식이 가장 많이 존재하는 주 시스템에 부여하여 운전원의 판단을 돕는 다는 원칙하에 개발하였다. 개발된 시스템은 윈도우 환경에서 MMI 환경과 관계형 데이터베이스(Oracle)와 신경회로망의 고장진단 알고리즘이 운영환경 내에서 구성되도록 하였다.

2.1 시스템의 구성 및 경보처리 체계

2.1.1 시스템 구성

유지관리 시스템은 국도 상에 분산·분포되어 있는 시설을 실시간으로 감시하기 위한 감시제어모듈과 감시정보를 가공·처리·저장·제공하기 위한 중앙 처리부로 구성된다. 본 시스템이 적용된 일반국도 3호선(50km구간)에는 34개의 검지기기와 5개의 VMS 및 현장 정보를 수집하여 처리와 가공을 수행하는 무인지역센터 1개소와 종합 감시센터로 이루어져 있다. 그림 2.1은 본 시스템의 전체적인 구성도이다.




그림 2.1 유지관리 시스템 구성체계
Fig. 2.1 The configuration structure of maintenance system.

표 2.1 시스템의 감시 대상 및 기능
Table 2.1 Monitoring target and function of system

대 상 설 비	감시방법	기 능	
		중단 제어부 RTU-S	방범-부전반 상태 감시-전원(상용/비상) 제어-환경:온도/습도 등 통신-전송선로 회선상태
검지기 전원공급/보호설비 통신보호/지원설비 VMS보호/지원설비 지락/낙뢰감시 방재/방범설비 공조설비 출입/통제감시 전산장비상태감시 진동(충격)감시	상태상태/경보 상태상태/경보 상태상태/경보 경보/제어 상태상태/제어 상태상태	지역/소구역 제어부 RTU-M RTU-L	검지기-전원/동작 감시-전원감시 방재-방범-화재/Door감시 -환경감시:온도/습도 등 제어-환경:함온/함습 제어 통신-전송선로 회선상태

유지관리에 활용하는 감시 규모는 현장 부분은 설치된 시설의 중요성, 지리적 여건 및 주변 환경적인 요소와 4개소의 한전 전원 공급의 연계성 등을 고려하여 감시대상을 9개의 구간으로 구분하였고 각각에 감시장치(RTU : Remote Terminal Unit)를 설치하였다. 표 2.1은 본 시스템에서 감시를 위하여 구성한 감시점이다.

2.1.2 경보처리체계

본 감시반에서 채택하고 있는 감시내용은 주로 설비 기기의 작동상태, 고장상태, 계측치, 원격제어, 보호 계전기의 동작 여부, 차단기의 동작 여부와 현장의 환경 정보 등을 상태 신호로 변환하여 실시간 운전 상태를 감시하도록 구성되어 있다. 그러나, 이들 경보 요소를 가지고 정전이 발생하는 요소를 분석하는 것은 시스템 적으로 불가능한 것이 본 감시 방식에서 단점으로 지적될 수 있다. 감시반의 하드웨어는 감시, 제어 및 계측을 수행하도록 감시점과 1:1로 구조화되어 종합 감시센터에서 관리할 수 있도록 구성되어 있다. 표 2.1의 감시점을 기준으로 구성된 감시점들은 현장 부분의 각각의 시설에는 14점, 두곳의 센터 부분에는 각각 21점으로 구성 총 126개의 감시 점수로 구성되어 있다. 이들 감시점을 가지고 분류될 수 있는 고장 분류는 표 2.2와 같다.

표 2.2 감시시설의 고장 분류
Table 2.2 The classified failure of monitoring facility

구 분	감시설비	시스템에서 수용가능한 감시점	
		적용설비	감시방법
절연파괴로 진단되는설비	계기용 변성기	계기용변성기	계측치 이상발생
동작기능 불안현상으로 진단되는설비	보호계전기 상태신호 제어신호	보호계전기	경보발생 신호감시
		상태신호	상태변화감시
		제어신호	제어신호완료 여부감시
절연파괴의 기능불안현상으로 진단되는 설비	계전기,개폐기	계전기	동작여부 신호감시
		개폐기	동작여부 신호감시
온도 습도의 기능불안 현상으로 진단되는 설비	제어기,계전기,개폐기,릴레이	제어기,계전기,개폐기,릴레이	온도, 습도 감시
단자, 접속부 기능 불안으로 진단되는 설비	제어기,계전기,개폐기외 설비	제어기,계전기,개폐기외설비	진동감시

표 2.3 검지가 및 VMS 입·출력점
Table 2.3 Input·output point of detector & VMS facility

구분	VO Contents	VO Type	Unit	Boundary Condition		신경회로망 입·출력		
				Zero	Full	내용	입력	출력
상태감시	입력 전원 전압	Ai	V	0	300	상태감시	Di	1
	누전 경보	Di	알람	복귀	알람	경보감시	Di	2
	낙뢰 발생	Di	회	0	1	상태,누적	Di	3
	AVR	Di	알람	Off	On	경보감시	Di	4
	저전압(UVR)	Di	알람	Off	On	경보감시	Di	5
	통신상태감시	Di	상태	Off	On	상태감시	Di	6
환경감시	제어함내부온도	Ai	℃	-30	90	경보감시	Di	7
	제어함내부습도	Ai	%	5	98	경보감시	Di	8
	제어함진동/충격	Di	알람	복귀	알람	경보감시	Di	9
	진원Surge 발생	Di	알람	Off	On	상태감시	Di	10
	통신Surge 발생	Di	알람	Off	On	상태감시	Di	11
제어실행부	주전원원격제어	Do	상태	Off	On	상태감시	Di	12
	제어함 팬 원격제어	Do	상태	Off	On	상태감시	Di	13
	제어함하터 원격제어	Do	상태	Off	On	상태감시	Di	14

이를 근거로 감시점을 분리하면 세 가지의 프레임 형태 즉 상태 감시 그룹, 환경감시 그룹, 제어 실행 감시 그룹으로 구분이 가능하고 이를 이용하면 8개의 출력으로 정리할 수 있다. 이들 관계를 입력과 출력요소로 정의하면 표 2.3, 2.4와 같이 설정할 수 있고 이를 지능형 고장진단용 user interface로 설계한다.

표 2.4 센터 입·출력점
Table 2.4 Input·output point of center

구분	VO Contents	VO Type	Unit	Boundary Condition		신경회로망 입·출력		
				Zero	Full	내용	입력	출력
상태감시	입력전원전압	Ai	V	0	300	상태감시	Di	1
	입력전원전류	Ai	A	0	50	상태감시	Di	2
	누전 경보	Di	알람	복귀	알람	경보감시	Di	3
	낙뢰	Di	회	0	1	상태,누적	Di	4
	AVR	Di	상태	Off	On	경보감시	Di	5
	저전압(UVR)	Di	알람	Off	On	경보감시	Di	6
환경감시	과전류(OCR)	Di	알람	복귀	알람	경보감시	Di	7
	과전압(OVR)	Di	알람	복귀	알람	경보감시	Di	8
	방범(Door개폐)	Di	상태	닫힘	열림	상태감시	Di	9
	내부온도	Ai	℃	-30	90	경보감시	Di	10
	내부습도	Ai	%	5	98	경보감시	Di	11
제어실행부	진동(충격)	Di	알람	복귀	알람	경보감시	Di	12
	항온항습동작	Di	상태	꺼짐	작동	상태감시	Di	13
	항온항습고장	Di	알람	복귀	알람	상태감시	Di	14
	진원Surge발생	Di	알람	Off	On	상태감시	Di	15
제어실행부	통신Surge발생	Di	알람	Off	On	상태감시	Di	16
	주전원원격제어(차단)	Do	상태	Off	On	상태감시	Di	17
	주전원원격제어(투입)	Do	상태	Off	On	상태감시	Di	18
	Door원격제어(On/Off)	Do	상태	닫힘	열림	상태감시	Di	19
	항온항습기원격제어(가동)	Do	상태	On	-	상태감시	Di	20
	항온항습기원격제어(제동)	Do	상태	-	Off	상태감시	Di	21

2.2 경보처리 지식베이스

경보 처리를 위하여 표 2.3, 2.4의 입력을 기준으로 작성된 계통 모델의 데이터베이스에는 기본 운전 지침서, 발생 경보들의 분류, 각종 지시계 내역 및 조작스위치의 기능 분석을 수행하며, 각 계통에 관련된 운전 전문가들의 경험적 지식을 프레임 형태로 구현한다. 랜덤하게 입력되는 신호 중에서 발생한 경보의 고유 번호, 이름, 우선 순위, 발생시간, 정보 종류들은 운전 이력 데이터베이스에 저장하여 감시 대상에 대한 노후화와 관리를 감시하는 데 활용한다. 발생한 경보를 활용하여 제안된 알고리즘을 이용한 고장진단을 수행하기 위해서 고장 원인/고장관계를 이용한 고장진단 데이터베이스를 표 2.5와 같이 구성한다. 고장 진단 지식베이스는 현장에서 랜덤하게 발생하는 다중 경보를 활용하여 고장 진단을 수행하는데 있어서 일차적으로 신경 회로망에서 최소 경보 요소로 추출하고 추출된 결과를 고장진단 지식 베이스와 연계하여 그 결과를 운전원이 유지보수에 활용하도록 한다.

표 2.5 고장진단 지식베이스
Table 2.5 Troubleshoot knowledge-base

경보부분	해당감시 그룹	경보발생원인
계속치 이상	계속치 경보	외함 및 부상의 부식, 파손 누유여부, 변상기 용량 및 배율의 적정여부, 집지시설상태 확인, 수·배전반 전력계의 동작상태와 과부하, 과전압과 불평형등의 지시계확인.
계전기 이상	OCR, UVR, OVR, ELD	탭 및 레버 위치 적정여부, 먼지등 이물질 침입여부, 계전기 오동작, 제어배선 탈락 및 오결선 여부.
상태감시	상태감시그룹	조작회로 및 조작기구의 적정, 차단기 이음, 청소여부.
경보에 그룹별 공통 대처사항	제어감시경보 릴레이경보	수배전반 전력계의 동작상태와 과부하, 과전압과 불평형등의 지시계확인. 각종 표시 램프 작동여부 외함 및 절구류 부식 손상, 개폐기, 차단기 등의 조작 적정여부. 진동에 제어배선 탈락, 적정동작 온도 및 부식에 따른 손상.

그러나, 도로 시설에 관련된 유지보수 관련하여 마련된 진단 규칙과 경험적 사실이 미비하므로 단순히 운전 중에 발생하는 경보를 가지고 보존 업무를 지원하기는 어려운 사항이다. 따라서, 운전원들에게 우선적으로 건축 전기설비 관련 진단 규칙을 활용하여 현재 감시 규모 내에서 설비보존 업무를 수행할 수 있도록 업무체계를 지원한다.

3. 신경회로망 모델링을 이용한 고장해석

고장정보에 의한 보수 진단을 하기 위해 본 연구에서는 유지보수 전문가들에게서 직접 구할 수 있는 고장 리스트로부터 고장원인 및 고장 형태의 고장 진단 지식베이스를 구성하고, 다층 신경회로망을 이용하여, 다중으로 발생된 고장정보로부터 고장 진단 지식베이스와 연계된 고장해석을 수행하였다.

3.1 추론을 위한 알고리즘 분석

신경회로망의 학습과정은 역전파 알고리즘을 사용하고, 연결강도를 학습하는 알고리즘으로는 오차의 제곱이 가장 많이 감소하는 방향으로 변화하는 기울기 강하법(Gradient decent method)을 이용하였다. 기울기 강하법은 지역 최소점(Local minima)에 빠질 수 있으므로 본 연구에서는 이를 개선하기 위해 중간층 노드수, 학습률, 그리고 모멘텀 상수를 조절하고, 연결강도의 초기치를 랜덤하게 설정하여 학습하도록 하였다. 신경회로망의 수렴성능을 확인하기 위해 학습오차에 대한 평가함수를 식 (3.1)로 표현하고 이로부터 오차를 줄이도록 학습시켰다.

$$J = \frac{1}{2} E^T(k+1)E(k+1) \quad (3.1)$$

$$E(k+1) = [E_1^T(k+1) E_2^T(k+1) \dots E_n^T(k+1)]^T \quad (3.2)$$

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

$$\begin{aligned} R_j(k) &= \sum_i W_{ij} \cdot I_i(k) \\ H_j(k) &= f(R_j(k)) \\ Z(k) &= \sum_j W_{0j} \cdot H_j(k) \end{aligned} \quad (3.3)$$

여기서, $I_i(k)$, $H_j(k)$, $Z(k)$ 는 각각 신경회로망의 입력, 중간층의 출력 그리고 신경회로망의 출력이고, W_{ij} , W_{0j} 는 입력과 출력층에서의 연결강도이다. 학습을 위한 연결강도에 대한 오차 함수의 기울기는

다음과 같다.

$$\frac{\partial J}{\partial W_{0j}} = \left\{ \frac{\partial E^T(k+1)}{\partial Z(k)} \cdot \frac{\partial J}{\partial E(k+1)} \right\} \frac{\partial Z(k)}{\partial W_{0j}} \quad (3.4)$$

$$\frac{\partial Z(k)}{\partial W_{ij}} = \frac{\partial Z(k)}{\partial H_j(k)} \frac{\partial H_j(k)}{\partial R_j} \frac{\partial R_j(k)}{\partial W_{ij}} \quad (3.5)$$

$$\frac{\partial Z(k)}{\partial H_j} = \left[\frac{\partial \hat{z}_1(k)}{\partial H_j(k)} \frac{\partial \hat{z}_2(k)}{\partial H_j(k)} \dots \frac{\partial \hat{z}_n(k)}{\partial H_j(k)} \right]^T \quad (3.6)$$

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

$$W_i(t+1) = W_i(t) + \eta \cdot \left(-\frac{\partial J}{\partial W_i} \right) + \alpha \delta W_i(t) \quad (3.7)$$

$$W_0(t+1) = W_0(t) + \eta \cdot \left(-\frac{\partial J}{\partial W_0} \right) + \alpha \delta W_0(t) \quad (3.8)$$

여기서, η , α 는 각각 학습률과 모멘텀이다. 출력값과 요구 출력패턴이 일치하면 학습이 종료되나 그렇지 못할 경우 이 차이를 감소시키기 위해 하단 방향으로 기울기 강하법에 의해 연결강도를 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 추론을 위한 신경회로망 설계

본 연구에서 구성한 신경회로망의 각 층은 처리기의 조합으로 회로망 내 인접층 사이의 모든 처리기들과 상호 연결되어 있으나, 같은 층 내 처리기 사이는 연결되어 있지 않다. 중간층과 출력층 처리기는 시그모이드 전달함수를 갖도록 하였다. 중간노드의 수량은 학습성능을 결정하는 중요한 인자이지만 이를 선정하는 방법은 네트워크의 복잡성을 감안하여 결정하고 있다. 즉, 경험적으로 중간층의 크기를 정하게 되는데 일반적으로 중간층의 노드 수는 입력층보다 비교적 많은 수가 필요로 한다. 만일 학습성능이 나쁘면, 더 많은 중간층의 노드수가 필요하고 성공하였을 경우에는 노드 수를 약간 줄여서 전체 시스템의 성능을 최적화 한다.

연결강도는 $-0.5 \leq \omega \leq 0.5$ 의 범위로 처리하였다.

입력층 처리기 노드 수는 표 2.3과 2.4와 같이 현장 검지장치 14점, VMS 14점, 센터부 21점을 신경회로망의 입력노드로 설정하였고, 출력점으로는 검지장치와 VMS에 대해 각 4개점, 센터 8점으로 구성하였다. 출력층 처리기에서는 해당 출력 결과와 이에 관계되는 점검부분을 관리자에게 통보와 함께 발생이력을 데이터베이스에 저장하도록 하였다.

4. 모의실험

4.1 고장해석 실험방법 및 평가

신경 회로망 훈련에 사용된 정보는 다음과 같은 시나리오를 가지고 수행하였다. 각각의 경우에서 정상적인 운전 상태에서 현장에서 발생하는 경보, 상태 신호 및 환경에 관련된 신호로 가정하였으며, 출력 정보는 해당 최소 경보 출력 항목이고 이에 대한 점검 목록이다. 먼저, 표 4.1은 검지장치로부터의 고장 정보와 신경회로망의 입출력 인터페이스를 일례로 정리한 것이다.

표 4.1 고장검출정보와 학습정보
Table 4.1 Learning information & fault detection data

입력 I/F	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
검지장치	내용	전원	누전	낙뢰	AVR	저전압	통신	항세	항세	진동	전원	통신	원격	편제어	허터
상태	정상	정상	정상	정상	정밀	정상	정상	정상	정상	정밀	정상	정상	정상	정상	정상
검출정보	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0

입력 I/F	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
검지장치	내용	전원	누전	낙뢰	AVR	저전압	통신	항세	항세	진동	전원	통신	원격	편제어	허터
상태	정상	정밀	정상	정상	정상	정상	정상	정상	정상	정밀	정상	정상	정상	정상	
검출정보	0	1	0	0	0	0	0	0	0	0	0	0	0	0	

출력 I/F	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 제안한 신경 회로망의 성능을 확인하기 위해, 학습률 ($0 < \eta \leq 1$)을 0.9, 0.7, 0.5로 설정하였고, 모멘텀 상수 ($0 < \alpha \leq 1$)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 실효 오차(RMSE)를 평가하여 중간층 노드수와 학습률 그리고 모멘텀 상수를 결정하였다.

4.2 실험결과 및 분석

4.2.1 중간층 노드 수 영향 분석

중간층 노드 수의 선정을 위하여 표 4.1의 고장정보를 이용하여 모의 실험한 결과는 표 4.2와 같다. 중간층 노드 수의 영향은 입·출력층 노드 수의 2배보다 적게 선정하는 것이 경험적으로 적용되고 있다. 모의 실험결과에 따르면 중간층 노드수가 적을수록 학습오차는 약간 증가하는 특성을 보였으나 그 변화량이 매우 적어서 무시할 정도이었다. 실험방법은 표 4.1의 학습자료를 토대로 학습률과 모멘텀 상수, 그리고 중간층노드수를 변화시키면서 학습성능(RMSE)을 비교하였다. 그리고, 표 4.2의 RMSE값은 최종적으로 학습을 수행한 결과이다. 표 4.2에서 알 수 있듯이 중간층 노드수의 변화에 대한 영향보다는 모멘텀 상수와 학습률에 대한 영향을 상대적으로 받고 있음을 알 수 있다.

표 4.2 학습성능 (학습횟수:50, η :학습률, α :모멘텀)
Table 4.2 Learning performance

학습오차	$\eta=0.9$ $\alpha=0.3$	$\eta=0.7$ $\alpha=0.3$	$\eta=0.5$ $\alpha=0.3$	$\eta=0.3$ $\alpha=0.3$	$\eta=0.1$ $\alpha=0.3$
Hidden Nodes	RMSE	RMSE	RMSE	RMSE	RMSE
10-100	0.00652	0.01487	0.02348	0.03302	0.06163

학습오차	$\eta=0.9$ $\alpha=0.1$	$\eta=0.7$ $\alpha=0.1$	$\eta=0.5$ $\alpha=0.1$	$\eta=0.3$ $\alpha=0.1$	$\eta=0.1$ $\alpha=0.1$
Hidden Nodes	RMSE	RMSE	RMSE	RMSE	RMSE
10-100	0.01559	0.02273	0.02924	0.03908	0.07195

4.2.2 모멘텀과 학습률 영향 분석

중간층 노드수의 변화에 대한 학습성능(표 4.2)에 비해, 모멘텀 항의 계수와 학습률은 학습성능에 비교적 영향을 주었으며, 그 결과로 학습률과 모멘텀 계수변화에 대한 학습성능은 표 4.3과 같다.

표 4.3 학습성능 (학습횟수:50, 중간층노드:30)
Table 4.3 Learning performance (Epochs:50, H/N:30)

	$\eta=0.9$	$\eta=0.7$	$\eta=0.5$	$\eta=0.3$	$\eta=0.1$
α	RMSE	RMSE	RMSE	RMSE	RMSE
0.1	0.01559	0.02273	0.02924	0.03908	0.07195
0.3	0.00652	0.01487	0.02348	0.03302	0.06163
0.5	0.00066	0.00261	0.01191	0.02344	0.04911
0.7	0.00061	0.00309	0.00377	0.03468	0.02797
0.9	0.00000	0.00001	0.00000	0.00000	0.00011

학습횟수는 50회로 제한하였고, 이 때 η , α 를 변

화시키면서 RMSE를 분석하였다. 학습결과에 대해서 오차한계를 10-2이내로 설정한 경우, 학습률과 모멘텀 계수의 설정범위를 각각 $0.3 \leq \eta < 1$, $0.5 \leq \alpha < 1$ 범위 내의 값(표 4.3의 역상영역)으로 설정하면, 비교적 양호한 학습성능을 볼 수 있다.

표 4.2, 4.3과 그림 4.1은 최적 학습계수(중간층 노드수, 학습률, 모멘텀 계수)를 결정하기 위한 변수 보정과정을 실시한 것이고 이로부터 적절한 학습오차의 한계를 설정하였다. 보정된 학습계수를 이용하여 고장정보가 발생하는 패턴을 5가지의 가상목표 패턴을 설정한 후, 이에 대한 학습성능을 분석하였다.




그림 4.1 학습률과 모멘텀 학습성능
Fig. 4.1 Performance of learning rate & momentum

4.2.3 고장 패턴별 학습성능 분석

신경회로망의 학습성능을 분석하기 위해 다음과 같이 5가지 경우의 고장 해석을 목표패턴으로 제시하여, 이에 대한 학습성능 결과를 표 4.4에 각각 비교 분석하였다. 신경회로망에서는 학습종료를 결정하는 방법으로 학습오차 범위의 설정과 학습횟수를 제한하는 형태가 일반적이며, 표 4.4의 결과는 학습횟수를 제한한 것으로, 최종 학습횟수에서의 RMSE값과 그 때의 신경회로망 출력이다.

- 패턴A : 검지장치(지역시스템)1과 검지장치(지역시스템) 2에서 전원부 경보와 검지장치 1에서 제어부 고장경보 발생
- 패턴B : 검지장치 1에서 전원부 경보 발생, 검지장치 2에서 전원부 이상 및 써지 경보 발생
- 패턴C : 검지장치 1에서 전원부와 합체 이상경보 발생, 검지장치 2에서 전원과 제어부 이상경보 발생
- 패턴D : 검지장치 1에서 합체 이상경보 발생과 제어부 이상발생, 검지장치 2에서 합체와 제어부 고장경보 발생
- 패턴E : 검지장치 1에서 전원부, 합체 고장 경보와 써지 경보 발생, 점지장치 2에서 전원부 고장과 써지 경보 발생

표 4.4 패턴별 학습성능 (학습횟수:50, 중간층노드:30)
Table 4.4 Learning performance by pattern

패턴	구분	η	α	학습률	No. of EP								
					1	2	3	4	5	6	7	8	
패턴 A	a	0.9	0.7	학습	0.9999	0	0	0	0.9999	0.9999	0	0	0
	b	0.7	0.5	학습	0.99378	0	0	0.99278	0.99378	0	0	0	0
	c	0.5	0.3	학습	0.96165	0	0	0.96165	0.96165	0	0	0	0
패턴 B	a	0.9	0.6	학습	1	0	0	0	1	0	0	1	0
	b	0.7	0.4	학습	0.99977	0	0	0	0.99977	0	0.99977	0	0
	c	0.5	0.2	학습	0.95637	0	0	0	0.95637	0	0.95637	0	0.95637
패턴 C	a	0.9	0.5	학습	0.99857	0.99857	0	0	0.99857	0	0	0.00857	0
	b	0.7	0.4	학습	0.99821	0.99821	0	0	0.99821	0	0	0.99821	0
	c	0.5	0.3	학습	0.96165	0.96165	0	0	0.96165	0	0	0.96165	0
패턴 D	a	0.9	0.7	학습	0	1	0	0	1	0	1	1	0
	b	0.7	0.3	학습	0	0.97571	0	0.97571	0	0.97571	0.97571	0	0
	c	0.5	0.1	학습	0	0.95226	0	0.95226	0	0.95226	0.95226	0	0
패턴 E	a	0.9	0.3	학습	1	1	1	1	0	0	1	0	1
	b	0.9	0.3	학습	0.99836	0.99836	0.99836	0	0	0.99836	0	0.99836	0
	c	0.7	0.2	학습	0.99821	0.99821	0.99821	0	0	0.99821	0	0.99821	0
c	0.5	0.1	학습	0.95226	0.95226	0.95226	0	0	0.95226	0	0.95226	0	

그림 4.2는 모멘텀 값을 0.5로 고정한 후 학습률을 변화하면서 학습오차를 분석한 결과로서 학습률의 증가변화에 대해서 오차가 10-2이내로 점근하고 있다. 또한, 학습률을 0.5로 고정한 후, 모멘텀 계수를 변화시키면서 학습오차를 분석한 결과이며, 목표오차 이내로 점근하고 있다. 두 경우의 학습결과에서 보듯이 양호한 학습성능을 보이는 학습계수의 범위를 설정할 수 있었다.

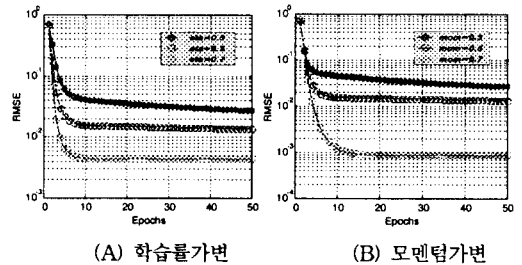


그림 4.2 학습횟수에 의한 학습성능
Fig. 4.2 Learning performance by Epochs

학습 결과에서 알 수 있듯이, 전문가 지식에 의한 고장 해석을 목표패턴으로 설정하였고, 신경회로망 학습을 통해 고장 해석한 결과, 표 4.4를 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 학습성능을 보였다. 신경 회로망의 출력된 정보들이 목적된 출력에 수렴하고 있으므로 이들의 출력 결과를 진단 지식베이스의 진단 지식과 연계를 통하여 보수점검 규칙을 실시간으로 운영환경에 표현할 수 있다. 이와 같이 추론된 결과를 GUI환경과 장비 이력관리를 위한 데이터베이스와 연

계하여 운영환경 측면에서 평가하면 다음과 같다. 기존의 정보 처리 방법에서는 발생 순서에 따라 단순히 화면에 표시하고, 발생된 결과들은 운전이력 데이터베이스(그림 4.3)에 저장과 함께 운전원은 이 결과를 보고 다음의 행위를 수행한다. 그러나 본 연구에서는 신경 회로망과 고장 진단 지식베이스를 통합한 광역에 설치되어 있는 감시설비의 현재 증상을 운전원이 화면을 통해서 인식하므로 전문적인 지식이 부족한 비전문가도 증상을 정확히 인지할 수 있으며, 전체적으로 제안한 고장 진단방식이 교통관리체계와 같은 분산계층구조의 대규모 시스템에 활용 가능하리라 판단된다. 이와 같은 대규모 시스템의 유지관리를 위해서는 지금까지의 고장 정보 처리 방법을 포함하여 수많은 설비 장비의 관리기능도 요구된다. 그림 4.3은 장비 이력관리 창과 고장 정보처리 환경을 구현한 것이다.




그림 4.3 시스템의 DB구조와 GUI환경
Fig. 4.3 DB structure and GUI view of maintenance system

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 신경회로망과 고장진단 지식베이스를 이용하여 최소 고장정보 요소를 추론하도록 구현되어 있으며, 학습성능을 모의실험하면서 고장정보처리 결과를 비교·분석하였다. 고장정보처리에 있어 양호한 학습성능을 보이는 학습계수의 적정 범위를 결정하였고, 여러 종류의 고장해석 패턴에 적용하여 유용함을 보였다. 그러나, 현재의 감시점과 고장 진단 지식베이스에 대한 정보가 부족하여 정보 처리면에서 더 이상의 효과를 기대 할 수는 없지만, 감시점을 비롯하여 고장진단 지식베이스 등이 누적된다면 그 효과

는 충분히 있을 것으로 판단된다. 그리고, 신경회로망을 활용한 고장정보 처리 기법과 장비관리용 이력 데이터베이스를 통합하여 처리할 수 있는 유지관리 시스템이 국도상의 교통관리 시스템을 지원할 수 효과적인 인프라 구축이라 판단된다. 향후 감시의 정보화와 진단의 효율성을 높이기 위해서는 교통관리 시스템의 여건에 맞는 고장진단 지식베이스에 대한 연구가 지속적으로 수행되어야 한다.

참고 문헌

- (1) 한국건설기술연구원, "수도권 도로 교통정보관리체계 구축 기본설계 및 평가연구," 1997.
- (2) 한국도로공사, "고속도로 교통관리 기본설계 및 시범구간(pilot project)실시설계," 1992.
- (3) 서울시정연, "도시고속 도로교통관리시스템 운용전략수립," 1997.
- (4) 교통개발연구원, "과천지역 지능형 교통시스템(ITS)시범 운영 및 평가를 위한 기본시례 및 실시설계, 1996.
- (5) 한국건설기술연구원, "전기설비보수지원용 진단프로그램 개발," 1997.
- (6) Martin Schockle, Mathias Hinkelmann, "Development of a Fault Diagnosis Tool Applying Associative and Rule Based Methods," International Energy Agency Annex 25, 1995.
- (7) M. Toyoda et al 2., "Supervisory Control System for Express ways," Fuji Elec. Jour. Vol.62 No.12 pp.772-776, 1989.
- (8) Baba K., Erubitsu I., "Explicit representation of knowledge acquired from plant historical data using neural network", Proceedings of IJCNN '90 San Diego, vol.3, pp. 155-160, 1990.
- (9) S.K.Ryu, "A study on the multi-hierarchical maintenance system of electrical demand facilities for building intelligent", '97 Proc. of 36th SICE Annual Conference, pp.1057- 1060, 1997.

◇ 저자 소개 ◇

류 승 기 (柳承基)

1967년 12월 13일생. 1999년 충북대 대학원 전기공학과 박사. 현재 한국건설기술연구원 연구원

최 도 혁 (崔度赫)

1962년 3월 9일생. 1997년 숭실대 대학원 전기공학과 박사수료. 현재 한국건설기술연구원 선임연구원

문 학 룡 (文鶴龍)

1963년 9월 5일생. 1998년 숭실대 대학원 전기공학과 박사수료. 현재 한국건설기술연구원 선임연구원

홍 규 장 (洪圭壯)

1960년 1월 24일생. 1997년 숭실대 대학원 전기공학과 졸업(박사).

한 태 환 (韓泰煥)

1958년 3월 5일생. 1998년 충북대 대학원 전기공학과 졸업(박사). 현재 LG산전(주)

유 정 웅 (柳正雄)

1941년 1월 20일생. 1987년 단국대 대학원 전기공학과 졸업(박사). 현재 충북대 전기공학과 교수