

AANN-기반 센서 고장 검출 기법의 방재시스템에의 적용

김성호 · 이영삼
군산대학교 전자정보공학부

Application of Sensor Fault Detection Scheme Based on AANN to Risk Measurement System

SUNG-HO KIM AND YOUNG-SAM LEE

School of Electronics and Information Engineering, College of Engineering, Kunsan National University,
Kunsan 573-701, Korea

비선형 주성분 분석은 기존에 널리 알려져 있는 주성분 분석기법과 유사한 다변수 데이터 분석을 위한 새로운 접근 방법이다. 비선형 주성분 분석은 AANN(Auto Associative Neural Network)으로 PCA와 마찬가지로 변수들 간에 존재하는 상관관계를 제거함으로써 고차의 다변수 데이터를 정보의 손실을 최소화하면서 최소 차원의 데이터로 변환하는 기법이다. AANN 기반 센서 고장 검출 기법을 실제 방재시스템에 적용하여 봄으로써 센서 드리프트 등과 같은 센서 고장의 검출 및 유효한 센서 보정 성능을 확인하였다.

NLPCA(Nonlinear Principal Component Analysis) is a novel technique for multivariate data analysis, similar to the well-known method of principal component analysis. NLPCA operates by a feedforward neural network called AANN(Auto Associative Neural Network) which performs the identity mapping. In this work, a sensor fault detection system based on NLPCA is presented. To verify its applicability, simulation study on the data supplied from risk management system is executed.

Keywords: AANN(Auto Associative Neural Network), Risk Management System, Sensor Fault Detection, Web-monitoring System

서 론

많은 산업용 프로세스의 경우 시스템 제어 또는 프로세스 상태 모니터링을 위해 다양한 채널들로부터의 센서 출력이 사용되고 있다. 시스템 설계자들이 직면하는 공통된 문제는 시스템 성능에 큰 영향을 미치는 센서 신뢰도 향상에 관한 것으로 이는 모니터링, 진단 및 제어시스템 설계의 중요한 요소로 간주되고 있다. 일반적으로 신뢰성 있는 데이터를 얻기 위해 고장난 센서 교체 및 주기적인 캘리브레이션 같은 센서 유효화 과정은 필연적으로 시스템의 운영중단을 요구하게 되며 이로 인해 상당한 시간과 비용이 낭비되고 있는 실정이다. 따라서 시스템의 효율적 운영을 가능케 하는 성능 기반 자동 센서 유효화 기법의 개발이 절실히 요구된다. 현재 많은 연구자들에 의해 다양한 온라인 센서 유효화기법이 제안된 바 있다(Dunia, 1996; Isermann, 1984; MacGregor and Costas, 1994). 특히 Hines *et al.*(1996)은 Jang(1993)이 제안한 ANFIS (Adaptive Neural Fuzzy Inference System) 및 Kramer (1992)가 제안한 AANN(Auto Associative Neural Network)을 기반으로 한 온라인 센서 유효화기법을 제안하고 이의 유용성을 입

증한 바 있다.

최근 인터넷의 급속한 보급으로 인해 데이터 전송시 발생하는 시공간상의 제약을 쉽게 극복할 수 있게 되어 전 세계 어디서든 지 데이터를 손쉽게 주고받을 수 있게 되었다. 이미 공장자동화, 환경, 생태, 자연재해 모니터링 등과 같은 여러 분야에서도 인터넷 기반 원격 모니터링 기술이 도입되고 있다. 이러한 원격 모니터링 시스템은 일반적으로 사람의 접근이 용이하지 않은 위험한 장소에 설치되는 것이 보통이다. 이로 인해 사람이 측정 현장에 상주하여 데이터를 수집하는 것은 불가능하며 따라서 원격의 서버에서 측정 현장의 데이터를 유선/무선으로 받아들이는 형태를 취하게 된다. 실제로 현재 군산대학교 새만금 환경연구 센터에서는 새만금호의 주된 수량 공급원인 만경강 수계에 다수의 수질 측정 스테이션 및 원격 서버시스템을 설치하고 인터넷을 통해 다수의 연구자에게 측정데이터를 효율적으로 제공할 수 있는 인터넷 기반 원격 모니터링 시스템을 운영중이다.

일반적으로 측정 현장에 설치된 센서들은 여러 요소에 의해 주기적인 센서 보정 및 교체가 요구되며 이로 인해 연속적인 모니터링이 불가능하게 된다. 따라서 원격 모니터링 시스템의 효율적 운영을 위해서는 설치된 센서들의 신속한 고장 검출 및 효율적인 보정기법의 도입이 절실히 요구된다.

*Corresponding author: shkim@kunsan.ac.kr

본 연구에서는 Kramer(1992) 등에 의해 제안된 바 있는 AANN 기반 센서 고장 검출 기법을 현재 강원도 홍천에 설치·운영되고 있는 방재시스템에 실제 적용하여 봄으로써 센서 드리프트 등과 같은 센서 고장의 검출 및 유효한 센서 보정의 가능성 여부를 확인하고자 한다. 본 논문의 구성은 다음과 같다. 2장에서는 AANN-기반 센서 고장 검출 시스템에 대하여 설명하며 3장에서는 AANN 기반 센서 고장 검출 시스템의 방재시스템에 대한 적용에 대해 기술하며 4장에서는 결론을 기술한다.

AANN의 구조 및 특성

AANN(Auto Associative Neural Network)

PCA(Principle Component Analysis)는 선형 매핑에 기반한 기법으로 비선형 데이터에의 직접 적용은 어렵게 된다. 따라서 비선형 데이터의 분석에 적용될 수 있는 기법들이 많은 연구자들에 의해 개발되었다. 이중 Kramer(1992)에 의해 제안된 AANN은 자기 연관 신경망을 이용하여 비선형 PCA를 구현하고자 한 것으로 5 개층(입력층, 매핑층, 병목층, 디매핑층, 출력층)으로 구성되며 구조를 나타내면 Fig. 1과 같다.

Fig. 1의 입력층은 M-차원의 데이터($X_1 \dots X_M$)를 입력으로 받아들인다. 입력된 데이터들은 한개의 계측 스테이션으로부터 측정된 다양한 형태의 센서값이 될 수 있으며 이들은 상호 연관성을 갖고 있어야 한다. 매핑층은 M-차원의 입력 데이터를 이보다 적은 F-차원의 특징 데이터로 축약하는 기능을 수행하는 L-차원의 뉴런으로 구성되며 이의 입출력 특성을 나타내면 식 (1)과 같다.

$$F = G(X) \tag{1}$$

식 (1)에서 G는 매핑층 L-차원의 뉴런 활성화함수(G_1, G_2, \dots, G_L) 들을 요소로 갖는 벡터이며 X는 1xM 차원의 측정변수를 의미하며 F는 1 xF 차원의 축약된 데이터를 의미한다. 이러한 특성을 통해 M-차원의 입력데이터로부터 F-차원의 데이터로의 압축이 가능하며 바틀넥 층의 출력을 통해 압축된 데이터를 얻을 수 있다. 디매핑층은 축약된 1 xF 차원의 데이터를 원래의 차원(1 xM)으로 복구하는 기능을 수행하는 L-개의 뉴런으로 구성되며 이의 특성을 나타내면 식 (2)과 같다.

$$Y = H(F) \tag{2}$$

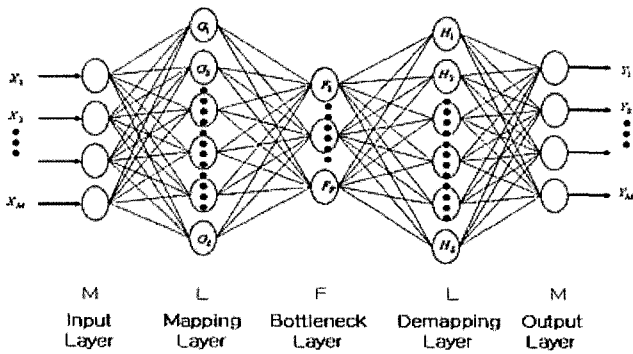


Fig. 1. The Structure of AANN.

식 (2)에서 H는 디매핑층의 L-차원의 뉴런 활성화함수(H_1, H_2, \dots, H_L) 를 요소로 갖는 벡터이며 Y는 자기상관 신경망의 입력으로 사용 된 것과 동일한 1xM 차원 출력 데이터이다. 식 (1), (2)의 뉴런 활 성함수 G, H에는 학습시 조정되어야할 결합강도가 포함되며 이들 은 일반적인 교사학습방법에 의해 다음의 잔차가 최소가 되도록 학습된다.

$$R = X - Y \tag{3}$$

AANN 기반 센서 고장 검출 기법

본 연구에서는 Hines(1996) 등이 제안한 바 있는 AANN을 기 반으로 하는 센서 고장 검출 기법을 사용하고자 하며 이를 나타 내면 그림 2와 같다. AANN은 다른 일반적인 인공신경망의 경우 와 마찬가지로 다차원 비선형 데이터의 상관 정보가 학습을 통해 뉴런 간 결합강도에 분산, 저장되며 따라서 학습된 데이터와는 다 른 데이터가 AANN에 인가된다 할지라도 원래의 데이터를 네트 워크에 저장된 정보로부터 추정하는 것이 가능하게 된다. 이러한 AANN의 데이터 추정 기능을 이용한다면 이상 데이터의 효율적 인 검출할 수 있다.

여기서 X_1, X_2, X_3, X_M 는 실제의 계측 데이터를 의미하며 X'_1, X'_2, X'_3, X'_M 는 입력 계측데이터에 대한 AANN의 출력을 의미 한다. 또한 r_1, r_2, r_3, r_M 는 실제 계측 데이터와 AANN 출력간의 잔차를 의미한다. 일반적으로 학습된 AANN은 입력 데이터의 차 수 보다 적은 뉴런으로 구성되는 바틀넥층의 도입으로 학습시 사 용된 데이터와 다른 데이터가 입력된 경우에도 데이터의 효율적 추정이 가능하게 된다. 따라서 Fig. 2와 같이 AANN을 사용한다 면 학습시와 다른 특성을 갖는 데이터의 발생 여부를 간단히 검 출할 수 있다.

사면 붕괴 방재시스템에 제안된 기법의 적용

사면 방재용 원격 모니터링 시스템의 개요

본 절에서는 전절에서 제안한 AANN 기반 센서 고장 검출 기 법을 사면 붕괴 방재를 위한 시스템에 적용하고자 한다. 적용된 전체 시스템의 구성은 Fig. 3과 같다. Fig. 3과 같이 시스템은 계 측 스테이션 부분과 모니터링 서버 시스템으로 구성된다. 계측 스

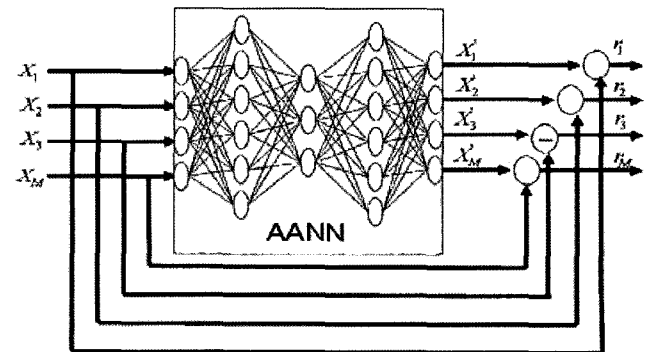


Fig. 2. Structure of abnormal data detection using data estimation characteristic of AANN.




Fig. 3. Structure of Disaster removal system based on AANN.

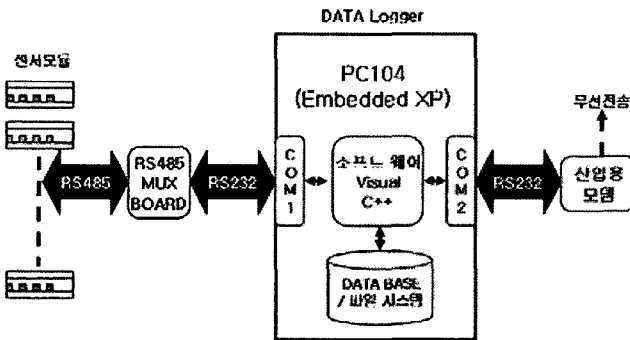


Fig. 4. Structure of Measurement Station.

스테이션은 데이터 로거와 센서 시스템으로 구성되며 센서 데이터의 측정과 측정데이터를 서버시스템으로 전송하고 저장하는 기능을 한다. 모니터링 서버 시스템은 계측 스테이션으로부터 데이터를 취득하고 데이터베이스에 저장하며 웹서비스를 실시 할 수 있도록 설계된다.

계측 스테이션

계측 스테이션은 다수의 센서 모듈로부터 계측 데이터를 가공하며 이상 데이터의 발생을 검출하고 모니터링 서버에 데이터를 전송하는 작업을 수행한다. 다수의 센서모듈을 측정하기 위해 RS-485방식을 이용하였다. 계측 스테이션의 구조는 Fig. 4와 같다.

- 센서 모듈

사면의 안정도를 판별하기 위한 센서들은 3가지 모듈로 구성되며 데이터 로거로부터 명령을 받아 계측을 하게 된다. 계측된 데이터는 A/D변환을 거쳐 RS-485 통신방식을 이용하여 데이터 로거에 데이터를 전송한다. 하나의 데이터로거는 RS485 MUX보드를 이용하여 최대 64개의 센서모듈을 연결 할 수 있다.

- 데이터 로거

Windows Embedded XP가 탑재되는 임베디드 시스템이며 측정현장의 광범위한 영역에 설치되는 각종센서들과의 효과적인 인터페이스를 위해 RS-485 인터페이스를 갖는다. 또한 원격 서버로 전송하기 위해 산업용 모듈이 장착되어 있다. 시스템을 구성하기 위해 PCM 9370보드를 사용하였다.

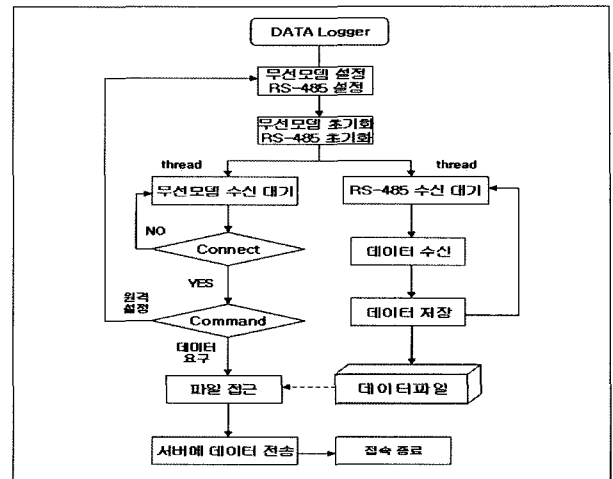


Fig. 5. Flowchart for the data logger applications.

데이터 로거의 동작을 위한 응용 프로그램은 MicroSoft Visual C++을 이용하여 작성 하였으며 현장에서의 센서모듈의 셋팅, 서버로부터의 원격 셋업, 데이터의 측정 및 저장, 모듈테스트, 취득한 데이터의 변화 검출, 모니터링 서버에 데이터 전달 등의 작업을 한다. 응용프로그램의 동작은 Fig. 5와 같다.

계측 스테이션과 서버 시스템의 연결을 위해 RS-232C 통신 방식을 사용하는 GROWELL사의 EK-001B 산업용 무선 모듈을 사용했다.

모니터링 서버

사면 안정관련 데이터를 모니터링 하기 위해 설계된 모니터링 시스템은 다수의 계측 스테이션으로부터 데이터를 수신하고 복원 과정을 거쳐 데이터베이스에 저장한다. 저장된 데이터는 복원, 분석, 모니터링, 원격 셋업, Web 서비스되며 이를 위한 응용 프로그램은 MS Visual Basic을 이용하여 작성했다. 서버 구축을 위해 본 연구에서는 Web 서비스가 가능한 Windows NT계열의 OS(Windows 2000 server)와 데이터베이스 관리를 위한 MS-SQL Server를 이용하였으며 구성은 Fig. 6과 같다.

제한된 기법의 사면계측 시스템에의 적용

강원도 홍천 지역에 설치되어 운영되고 있는 계측 스테이션으로부터 5개의 TW(Tension Wire)모듈과 1개의 강우량계 모듈이

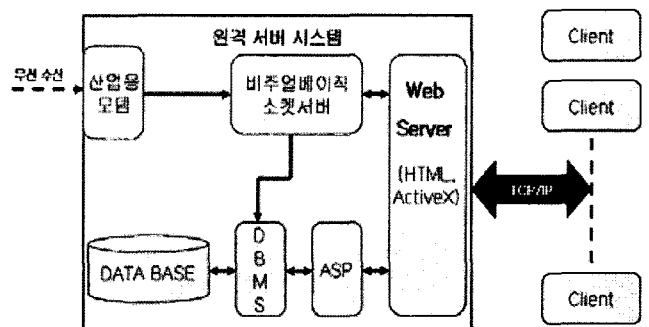


Fig. 6. The Structure of Monitoring Server.




Fig. 7. Measurement data from each sensors (normal state).

설치되어 있으며 TW모듈은 3개의 TW센서와 1개의 온도센서로 구성되어 있다. 특히 이들 센서 중 온도센서는 센서 바이어스 등과 같은 센서 고장으로 인해 주기적인 캘리브레이션 및 교체를 수행해야 한다. 따라서 이들 센서 고장의 검출은 필수적이며 본 연구에서는 2장에서 제안된 AANN 기반 센서 고장 검출 기법을 온도 센서 고장의 검출에 대해 적용하고자 한다.

사면 안정 관련 데이터

본 연구에서 사용된 각각 모듈로부터 측정된 온도 센서 데이터를 나타내면 Fig. 7과 같다. 각각 모듈로부터 약 1분 간격으로 24 시간 동안 측정된 온도 데이터를 나타내며 이 기간의 데이터는 온도센서보정을 마친 후의 것이다.

또한 센서 고장 검출을 위한 시뮬레이션을 위해 바이어스 형태의 데이터를 이용해 센서 고장 검출을 실험 하고자 한다.

AANN의 학습

AANN의 학습에 사용되는 입력력 패턴은 동일하며 따라서 AANN은 1:1 매핑기능을 갖는다. 그러나 앞서 언급한 바와 같이 입력력 뉴런의 수보다 적은 바틀넥층의 도입으로 인해 데이터를 압축 할 수 있으며 또한 비선형 PCA의 특성을 갖게 되어 학습시와는 다른 데이터(이상 데이터)가 입력되어도 정상 동작시의 값을 추정하는 것이 가능하게 된다. 본 연구에서는 각 모듈의 온도데이터 5개를 학습에 사용하였다. 학습에 사용되는 AANN의 입력층은 5개의 뉴런, 매핑층은 8개의 뉴런, 바틀넥층은 2개, 디매핑층은 8개의 뉴런으로 구성하였다. AANN의 학습은 Matlab 신경망 툴의 NEWFF (Feedforward Backpropagation Network)함수를 사용하였다. AANN을 이용한 데이터 압축 및 복원 효과를 위해 AANN을 분리한 형태의 신경망을 구현 하였으며 성능 확인을 위해 Matlab 시뮬링크를 사용하였다.

학습이 완료된 AANN의 성능의 확인을 위해 학습시 사용한 데이터를 AANN에 인가하였으며 이 경우 AANN으로부터 출력되는 데이터는 Fig. 8과 같고 실제 입력데이터와의 오차는 Fig. 9와 같다.

또한 제안된 시스템의 이상 데이터에 대해서 효율적인 이상의 검출이 가능함을 확인하기 위해 5개의 센서 각각에 크기 0.2의 바이어스를 인가하였다. 이 경우 각각의 이상 데이터와 이에 대한 AANN출력을 나타내면 Fig. 10, Fig. 11과 같다. 100에서 200번 스텝사이에 첫 번째 온도 센서에 바이어스를 인가하였으며 300에




Fig. 8. Output characteristic of learned AANN (normal sec).




Fig. 9. Residual between learning data and output of AANN.




Fig. 10. Sensors data in the case of bias 0.2 (abnormal state).

서 400까지는 2번 센서, 500에서 600까지는 3번 센서, 700에서 800까지는 4번 센서, 900에서 1000까지는 5번 센서에 바이어스를 인가하였다.

Fig. 11은 학습이 완료된 AANN에 Fig. 10과 같이 바이어스가 포함된 센서값을 입력하였을 경우 AANN의 출력을 나타낸 것으로 AANN의 출력은 대부분 바이어스가 없을 경우의 정상 센서 값을 출력함을 알 수 있다. 그러나 센서 3번에 바이어스를 500에서 600번 사이에 인가하였을 때 AANN은 만족할 만한 정상 센서 값을 출력하지 못한다. 유사한 센서 데이터들은 강한 상관관계를 갖으며 AANN은 상관관계가 있는 변수들을 바틀넥층으로 결합하여




Fig. 11. Response characteristics of AANN for each sensors (abnormal state)




Fig. 12. Detection of abnormal data.

서로 독립적인 저차의 새로운 변수들을 생성하는데 이러한 과정에서 새로운 변수들이 센서 3번과 완전한 독립을 이루지 못하였기 때문이다. 이때 센서 1, 2, 4, 5번의 AANN의 출력에 약간의 바이어스가 발생하는 이유도 그러한 이유에서이다. 센서 5번에 바이어스를 900에서 1000번 사이에 인가하였을 때도 같은 이유로 유사한 응답특성을 보이고 있다. 비록 센서 3번과 5번이 완전한 독립을 이루지 못했어도 Fig. 12와 같은 AANN과 실제 계측 센서 값과의 잔차를 통해 센서 고장 검출을 충분히 수행 할 수 있다.

$$T = \sqrt{R_1^2 + R_2^2 + R_3^2 + R_4^2 + R_5^2} \quad (4)$$

여기서 $R_i (1 \leq i \leq 5)$ 은 각 센서의 AANN과 실제 계측 센서 값과의 잔차들이다. T가 임계값을 초과 할 때 각 센서에 대한 R의 크기를 비교하여 가장 큰 값을 갖는 센서를 고장으로 판별할 수 있다.

결론

본 연구에서는 다변수 데이터의 해석에 널리 사용되고 있는 AANN을 기반으로 하는 센서 바이어스 고장 검출을 위한 원격 모니터링 시스템을 제안하고 현재 설치 운영되고 있는 홍천지역의 데이터를 이용하여 시뮬레이션을 수행하였으며 시뮬레이션 결과 효율적인 센서 바이어스(센서 고장)의 검출이 가능함을 확인할 수 있었다.

참고문헌

- Dunia, R., 1996. Identification of faulty sensors using principle component analysis, *AIChE J.*, **42**(10): 2797-2812.
- Hines, J.W., D.J. Wrest, and R. E. Uhring, 1996. Plant Wide Sensor Calibration Monitoring, published in the proceedings of The 1996 IEEE International Symposium on Intelligent Control, Sept. 15-18, pp. 378-383.
- Isermann, R. 1984. Process Fault Detection Base on Modelling and Estimation Methodes-A survey, *Automatica*, **20**(4): 387-404.
- Jang, JSR. 1993. *ANFIS: Adaptive-Network-Based Fuzzy Inference System*, IEEE Trans. on Systems, Man and. Cybernetics.
- Kramer, M.A. 1992. Autoassociative neural networks, *Computers in Chemical Eng.*, **16**(4): 313-328.
- MacGregor, J.F., K. Costas, 1994. Process monitoring and diagnosis by multiblock PLS method. *AIChE J.*, **40**(5): 826-838.

2006년 4월 18일 원고접수

2006년 5월 18일 수정본 채택

담당편집위원: 이재학