

# AANN-기반 센서 고장 검출 기법의 센서 네트워크에의 적용

## Application of Sensor Fault Detection Scheme Based on AANN to Sensor Network

이영삼\*, 김성호\*\*  
Young-Sam Lee\*, Sung-Ho Kim\*\*

**Abstract** - NLPICA(Nonlinear Principal Component Analysis) is a novel technique for multivariate data analysis, similar to the well-known method of principal component analysis. NLPICA 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 NLPICA is presented. To verify its applicability, simulation study on the data supplied from sensor network is executed.

**Key Words** : AANN(Auto-associative Neural Network), Sensor Fault Detection, Sensor Network

### 1. 서론

유비쿼터스 사회를 구현하기 위한 한 방향으로 최근 무선 센서네트워크가 대두되고 있다. 무선 통신 기술과 반도체 설계 기술의 발전으로 계측, 연산 및 무선 통신기능을 갖춘 저가격, 저전력의 다양한 센서 노드들이 개발되고 있다. 이러한 센서 노드들은 사람이 접근하기 어려운 작업공간에 살포되며 센서 노드들은 자체적으로 네트워크를 형성하여 센서 노드에서 측정된 내용을 자체적으로 형성된 망을 통해 기간망으로 전달함으로써 사용자들이 원격지에서 자연환경의 변화내용 혹은 감시 내용을 파악할 수 있는 센서 네트워크에 사용된다. 이러한 기능을 갖는 센서 네트워크는 환경, 생태 모니터링, 지진 감시 및 군사용 등에 폭넓게 도입되고 있다[1-2].

측정 현장의 센서 노드들은 여러 가지 요소(노드의 배터리 고갈, 사고로 인한 보드의 파손, 센서의 노화)로 문제가 발생하게 되며 이는 정상적으로 동작하고 있는 무선 센서네트워크의 운용에 악영향을 미치게 된다. 따라서 무선 센서네트워크에 큰 영향을 미치는 센서의 신뢰도는 모니터링, 진단 및 제어시스템 설계의 중요한 요소로 간주되고 있다. 일반적으로 신뢰성 높은 데이터를 얻기 위해서는 고장 난 센서의 교체 및 주기적인 보정과 같은 센서 유효화 과정이 필연적으로 요구된다. 그러나 이러한 과정은 무선 센서네트워크의 적용 분야가 사람이 쉽게 접근하기 어려운 지역에 설치되기 때문에 시스템의 효율적인 운영을 위해서 고장 센서노드의 정확한 검출과 성능 기반 자동 센서 유효화 기법의 개발이 절실히 요구된다. 현재 많은 연구자들에 의해 다양한 온라인 센서 유효화기법이 제안된 바 있다. 특히 Hines 등은 Jang이 제안한 ANFIS (Adaptive Neural Fuzzy Inference System)

및 Kramer등이 제안한 AANN(Auto Associative Neural Network)을 기반으로한 온라인 센서 유효화 기법을 제안하고 이의 유용성을 입증한 바 있다.[3-4] 본 연구에서는 TinyOS 기반 mote들로 구성된 센서 네트워크상에서 오류 센서노드의 검출을 위해 Kramer 등에 의해 제안된 바 있는 AANN 기반 센서노드 고장검출 기법 적용하고자 한다. 또한 적용된 기법의 유용성 확인을 위해 첫째, 실제로 mote 보드를 설계한 후 TinyOS를 탑재하며 둘째, 구현된 mote 보드로 구성된 센서 네트워크에 제안한 기법을 적용하여 봄으로써 유용성 확인을 하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 AANN-기반 센서노드 고장검출 기법에 대하여 설명하며 3장에서는 제안한 기법을 센서 네트워크에 적용하여 고장 센서노드 검출의 유용성을 확인하고자 한다. 끝으로 4장에서는 결론을 기술한다.

### 2. AANN의 구조 및 특징

#### 2.1 AANN(Auto Associative Neural Network)

PCA(Principal Component Analysis)는 선형 매핑에 기반한 기법으로 비선형 데이터에의 직접 적용은 어렵게 된다.

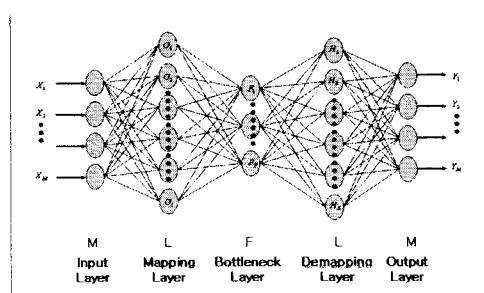


그림 1. AANN의 구조

#### 저자 소개

\* 이영삼 : 君山大學 電子情報工學部 博士課程

\*\* 김성호 : 君山大學 電子情報工學部 教授

따라서 비선형 데이터의 분석에 적용될 수 있는 기법들이 많은 연구자들에 의해 개발되었다. 이중 Kramer등에 의해 제안된 AANN은 자기연관 신경망을 이용하여 비선형 PCA를 구현하고자 한 것으로 5개층 (입력층, 매핑층, 바틀넥층, 디매핑층, 출력층)으로 구성되며 구조를 나타내면 그림 1과 같다.

그림 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 이보다는 적은 F-차원의 특징 데이터로 축약하는 기능을 수행하는 L-차원의 뉴런으로 구성되며 이의 입력 특성을 나타내면 식(1)과 같다.

$$F = G(X) \quad (1)$$

식 (1)에서  $G$ 는 매핑층 L-차원의 뉴런 활성함수 ( $G_1, G_2, \dots, G_L$ )들을 요소로 갖는 벡터이며  $X$ 는  $1 \times M$  차원의 측정변수를 의미하며  $F$ 는  $1 \times F$  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  $1 \times F$  차원의 데이터를 원래의 차원( $1 \times M$ )으로 복구하는 기능을 수행하는 L-개의 뉴런으로 구성되며 이의 특성을 나타내면 식(2)과 같다.

$$Y = H(F) \quad (2)$$

식(2)에서  $H$ 는 디매핑층의 L-차원의 뉴런 활성함수 ( $H_1, H_2, \dots, H_L$ )를 요소로 갖는 벡터이며  $Y$ 는 자기상관 신경망의 입력으로 사용된 것과 동일한  $1 \times M$  차원 출력 데이터이다. 식(1), (2)의 뉴런 활성함수  $G, H$ 에는 학습시 조정되어야 할 결합강도가 포함되며 이들은 일반적인 교사학습방법에 의해 다음의 잔차가 최소가 되도록 학습된다.

$$R = X - Y \quad (3)$$

## 2.2 AANN 기반 센서노드 고장 검출 기법

본 연구에서는 Hines 등이 제안한 바 있는 AANN을 기반으로 하는 센서 고장 검출 기법을 사용하고자 하며 이를 나타내면 그림 2와 같다. AANN은 다른 일반적인 인공신경망의 경우와 마찬가지로 다차원 비선형 데이터의 상관 정보가 학습을 통해 뉴런 간 결합강도에 분산, 저장되며 따라서 학습된 데이터와는 다른 데이터가 AANN에 인가된다 할지라도 원래의 데이터를 네트워크에 저장된 정보로부터 추정하는 것이 가능하게 된다. 이러한 AANN의 데이터 추정 기능을 이용한다면 이상 데이터의 효율적인 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 의미한다. 또한  $r_1, r_2, r_3, r_M$ 는 실제 계측 데이터와 AANN 출력간의 잔차를 의미한다. 일반적으로 학습된 AANN은 입력 데이터의 차수 보다 적은 뉴런으로 구

성되는 바틀넥층의 도입으로 학습시 사용된 데이터와 다른 데이터가 입력된 경우에도 데이터의 효율적 추정이 가능하게 된다. 따라서 그림 2와 같이 AANN을 사용한다면 학습시와 다른 특성을 갖는 데이터의 발생 여부를 간단히 검출할 수 있다.

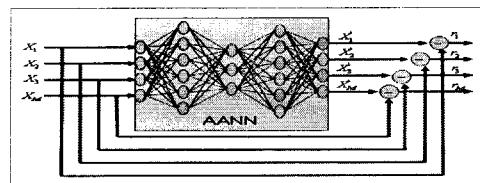


그림 2. AANN의 데이터 추정 기능을 이용한 이상 데이터 검출

## 3. 제안된 기법의 센서 네트워크에의 적용

### 3.1 센서노드의 하드웨어 플랫폼

센서노드는 크게 데이터 처리부, RF 송수신부, 센서부, 외부장치 인터페이스부로 구성된다. 데이터 처리부는 RF 장치, 센서장치, 외부 인터페이스 장치를 제어하는 역할을 하며 이를 위해 ATMEL사의 ATMEGA128L 저전력 8비트 RISC 프로세서를 사용하였다. 이 칩은 내부에 128Kbyte의 FLASH와 4Kbyte의 SRAM 과 EEPROM을 내장하고 있어 TinyOS를 구동하기에 충분하며 전력소비를 줄이기 위한 6가지 슬립모드를 지원한다.

RF 송수신부는 네트워크를 형성하는 센서노드들 간의 통신을 담당한다. RF transceiver 칩으로는 Cipcon사의 CC1000을 사용하였으며 지원하는 300MHz에서 1000MHz 사이의 대역 중 915MHz의 고정 주파수를 사용하였다. 이 칩은 SPI와 I2C 방식의 인터페이스를 이용하여 CPU와 연결되어 최소한의 전력소비를 지원하기 위한 power down mode를 지원한다.

센서부는 센서노드에 부착된 센서의 데이터를 취득하는 역할을 담당하며 온도, 습도, 조도, 초음파 센서등의 기타 여러 가지 센서들을 부착하여 사용 가능하다. 부착된 센서들은 ATMEGA128L에 내장된 10비트 해상도의 AD컨버터와 I2C 방식이나 SPI 방식을 이용하여 취득가능하다.

마지막으로 인터페이스부는 외부장치와의 연결 및 보드 확장을 위해 사용된다. 이를 위해 2개의 UART 포트와 각종 I/O 포트를 지원한다. UART 포트는 PC와 임베디드 장치와의 연결 하기 위해 사용되어지며 I/O 포트는 엑추에이터 노드를 구성하거나 다른 소자를 이용하여 보드를 확장 사용할 수 있도록 한다.

### 3.2 적용 데이터

AANN 기반 센서노드 고장검출 기법의 유용성을 확인하기 위해 5개의 센서노드를 이용하여 센서 네트워크를 구성하였다. 각각의 센서노드들은 온도를 측정하고 측정한 온도 데이터를 싱크노드에 전송한다. 또한 싱크노드는 수신된 데이터를 저장하고 이를 이용하여 제안한 고장검출 기법에 적용한다. 본 연구에서 사용된 각각 센서노드로부터 측정된 온도 데이터를 나타내면 그림 3과 같다. 5개의 센서노드로부터 약

1분 간격으로 24시간 동안 측정한 온도 데이터를 나타내며 이 기간의 데이터는 온도센서보정을 마친 후의 것이다.

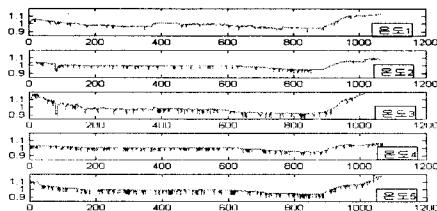


그림 3. 각 스테이션별 측정 데이터 (정상상태)

### 3.3 AANN의 학습 및 적용

AANN의 학습에 사용되는 입력력 패턴은 동일하며 따라서 AANN은 1:1 매핑기능을 갖는다. 그러나 앞서 언급한 바와 같이 입출력 뉴런의 수보다 적은 바틀넥층의 노드으로 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 센서노드의 온도데이터 5개를 학습에 사용하였다. 학습에 사용되는 AANN의 입력층은 5개의 뉴런, 매핑층은 8개의 뉴런, 바틀넥층은 2개, 디매핑층은 8개의 뉴런으로 구성하였다.

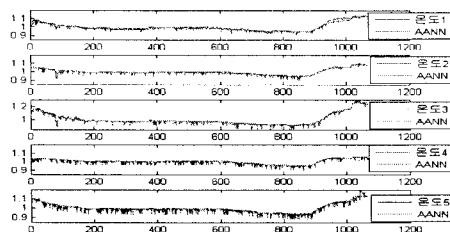


그림 4. AANN 및 센서 응답 특성 (정상상태)

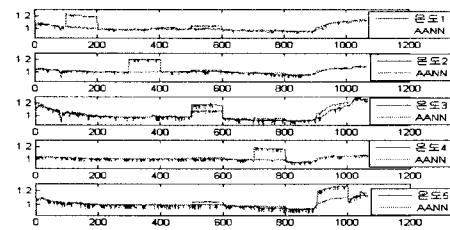


그림 5. AANN 및 센서 응답 특성 (비정상상태)

학습이 완료된 AANN의 성능의 확인을 위해 학습시 사용한 데이터를 AANN에 인가하였으며 이 경우 AANN으로부터 출력되는 데이터와 실제 입력데이터는 그림 4와 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 AANN 출력을 나타내면 그림 5과 같다. 100에서 200번 스텝사이에 첫 번째 온도 센서에 바이어스를 인

가하였으며 300에서 400까지는 2번 센서, 500에서 600까지는 3번 센서, 700에서 800까지는 4번 센서, 900에서 1000까지는 5번 센서에 바이어스를 인가하였다. 그럼 5로부터 학습이 완료된 AANN에 바이어스가 포함된 센서값을 입력하였을 경우 AANN의 출력을 나타낸 것으로 AANN의 출력은 바이어스가 없을 경우의 정상 센서값을 출력함을 알 수 있다. 또한 AANN과 실제 계측 센서값과의 차를 나타내면 그림 6과 같으며 이로부터 임계치 검사를 통한 효율적인 센서 고장의 검출이 가능함을 알 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 센서값과의 차이다. T가 임계값을 초과 할 때 각 센서에 대한 R의 크기를 비교하여 가장 큰 값을 갖는 센서를 고장으로 판별할 수 있다.

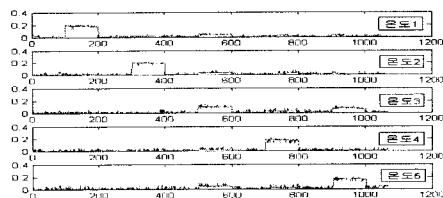


그림 6. 이상 데이터의 검출

### 4. 결론

본 연구에서는 다변수 데이터의 해석에 널리 사용되고 있는 AANN을 기반으로 하는 센서노드 고장검출을 위한 기법을 제안하였다. 제안된 기법의 유용성을 확인하기 위해 5개의 실제 센서 노드를 이용하여 센서 네트워크를 구성하였고 모의실험 결과 효율적인 센서 바이어스(센서고장)의 검출이 가능함을 확인할 수 있었다. 그러나 제안된 알고리즘을 센서네트워크에 보다 적합하게 적용하기 위해서는 적절한 라우팅 알고리즘 연구가 요구된다.

본 연구는 산업자원부가 지정 군산대학교 새만금연구센터의 지원에 의한 것입니다.

### 참 고 문 헌

- [1] B.Krishnamachari, D. Estrin and S. Wicker, "Modelling Data Centric Routing in Wireless Sensor Networks," IEEE INFOCOM'02, June 2002
- [2] W.Ye, J. Heidemann and D.Estrin "An Energy-Efficient MAC Protocol for Wireless Sensor Networks" IEEE INFOCOM'02, June 2002
- [3] MacGregor, J.F., K. Costas, "Process monitoring and diagnosis by multiblock PLS method", AIChE J. , 40(5), 826-838, 1994
- [4] Dunia, R. "Identification of faulty sensors using principle component analysis", AIChE J., 42(10), pp. 2797-2812, 1996.