

센서 고장 검출 기법의 수질 계측 시스템에의 적용

이 영 삼*, 한 윤 종*, 김 성 호*
*군산대학교 전자정보공학부

Application of Sensor Fault Detection Method to Water Measurement System

Young-Sam Lee*, Yun-Jong Han*, Sung-Ho Kim*
*School of Electronics and Information Eng. , Kunsan National University,

Abstract - NLPCA(Nonlinear Principal Component Analysis) is a novel technique for multivariate data analysis, similar to the well-known method of principal component analysis. NLPCA can be implemented by a feedforward neural network called AANN (AutoAssociative Neural Network) which performs the identity mapping. In this work, a sensor fault detection system based on NLPCA and Maximum Likelihood Estimation scheme is presented. To verify its applicability, simulation study on the data supplied from Saemangeum measurement stations is executed.

1. 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 제어 시스템 설계의 중요한 요소로 간주되고 있다. 일반적으로 신뢰성 있는 데이터를 얻기 위해 고장난 센서 교체 및 주기적인 캘리브레이션과 같은 센서 유효화 과정은 필연적으로 시스템 운영의 중단을 요구하게 되며 이로 인해 상당한 시간과 비용이 낭비되고 있는 실정이다. 따라서 시스템의 효율적 운영을 가능케 하는 자동 센서 유효화 기법의 개발이 절실히 요구된다. 현재 많은 연구자들에 의해 다양한 온라인 센서 유효화 기법이 제안된 바 있다. 특히 Hines 등은 Jang이 제안한 ANFIS (Adaptive Neural Fuzzy Inference System) 및 Kramer등이 제안한 AANN(AutoAssociative Neural Network)을 기반으로 한 온라인 센서 유효화 기법을 제안하고 이의 유용성을 입증한 바 있다[1-2].

최근 새만금 사업 등과 같은 대규모 국책사업이 진행됨에 따라 개발로 인해 발생할지도 모르는 환경문제에 대한 관심이 높아지고 있다. 현재 군산대학교 새만금 환경연구 센터에서는 완성될 새만금호의 주된 수량 공급원인 만경강 수계에 다수의 수질 계측 스테이션을 설치하고 다양한 수질관련 계측 데이터를 수집하여 체계적인 수질 모니터링을 수행하고 있다. 일반적으로 계측 스테이션에 설치된 센서들은 물에 포함된 각종 유기물 등 여러 요소에 의해 주기적인 센서 보정 및 교체가 요구되며 이로 인해 연속적인 모니터링이 불가능하게 된다. 따라서 수질 모니터링 시스템의 효율적 운영을 위해서는 설치된 센서들의 신속한 고장 검출 및 효율적인 보정 기법

의 도입이 절실히 요구된다.

본 연구에서는 온라인 센서 유효화 기법 중의 하나인 AANN과 통계 분석 기법으로 널리 사용되고 있는 최우 추정법(MLE: Maximum Likelihood Estimate) 병합한 센서 고장검출 시스템을 제안하고 만경강 수계상에 설치된 스테이션으로부터의 계측 데이터에 실제 적용하여 봄으로써 센서 드리프트 등과 같은 센서 고장의 검출 및 센서 보정의 가능성 여부를 확인하고자 한다. 본 논문의 구성은 다음과 같다. 2장에서는 AANN을 기반한 센서 고장검출 시스템에 설명하며 3장에서는 AANN 기반 센서 고장검출 시스템의 새만금 환경 모니터링 데이터에 대한 적용에 대해 기술하며 4장에서는 결론을 기술한다.

2. AANN 기반 센서 고장 검출 시스템

2.1 AANN 의 구조

Kramer등에 의해 제안된 AANN은 기존에 널리 알려져 있는 PCA(Principle Component Analysis) 기법과 유사한 다변수 데이터 분석을 위한 새로운 접근 방법이다. 이러한 AANN 역시 PCA와 마찬가지로 변수들간에 존재하는 상관관계를 제거함으로써 고차의 다변수 데이터를 정보의 손실을 최소화하면서 최소 차원의 데이터로 변환하는 기법이다. 일반적으로 PCA에서는 데이터들간에 존재하는 선형 상관관계만을 고려하지만 AANN은 데이터에 존재하는 선형 및 비선형 상관관계를 효율적으로 처리할 수 있다는 장점을 갖는다. Kramer에 의해 제안된 AANN은 그림 1과 같은 자기연관 신경망에 의해 구현된다.




그림 1. AANN의 구조
Fig.1 Structure of autoassociative neural network

그림 1의 mapping layer는 m-차원의 입력 데이터를 이 보다는 적은 f- 차원의 특징 데이터로 축약하는 기능을

수행하는 l 개의 뉴런으로 구성되며 이의 입·출력 특성을 나타내면 식(1)과 같다.

$$T = G(Y) \quad (1)$$

여기서 G 는 mapping layer의 l 개의 뉴런 활성화함수 (G_1, G_2, \dots, G_l)들을 요소로 갖는 벡터이며 Y 는 $1 \times m$ 차원의 측정변수를 의미하며 T 는 $1 \times f$ 차원의 축약된 데이터를 의미한다. 그림1의 demapping layer는 축약된 $1 \times f$ 차원의 데이터를 원래의 차원($1 \times m$)으로 복구하는 기능을 수행하는 l 개의 뉴런으로 구성되며 이의 특성을 나타내면 식(2)와 같다.

$$\hat{Y} = H(T) \quad (2)$$

여기서 H 는 demapping layer의 l 개의 뉴런 활성화함수 (H_1, H_2, \dots, H_l)를 요소로 갖는 벡터이며 \hat{Y} 는 자기상관 신경망의 입력으로 사용된 것과 동일한 $1 \times m$ 차원 출력 데이터이다.

식(1), (2)의 뉴런 활성화함수 G, H 에는 학습시 조정되어야 할 결합강도가 포함되며 이들은 일반적인 교차학습방법에 의해 다음의 오차가 최소가 되도록 학습된다.

$$E = Y - \hat{Y} \quad (3)$$

2.2 AANN 기반 센서고장 검출 시스템

본 연구에서는 Hines 등이 제안한 바 있는 AANN을 기반으로 하는 센서 고장 검출 시스템을 사용하고자 하며 이를 나타내면 그림 2와 같다[4].




그림 2. AANN 기반 센서 고장검출 시스템의 구조
Fig. 2. Structure of sensor fault detection system based on AANN

여기서 s_1, s_2, s_3, s_4 는 실제 재측 데이터를 의미하며 s'_1, s'_2, s'_3, s'_4 는 입력 재측데이터에 대한 AANN의 출력을 의미한다. 또한 r_1, r_2, r_3, r_4 는 실제 재측 데이터와 AANN 출력간의 잔차를 의미한다.

일반적으로 학습된 AANN은 입력 데이터의 차수 보다 적은 뉴런으로 구성되는 bottleneck layer의 도입으로 인해 다음과 같은 특성을 갖게 된다. 즉, m -차원의 입력 데이터들간에 존재하는 상관관계는 f -차원의 데이터로 축약되며 이 과정에서 입력 데이터들간의 상관관계와 관련된 정보들이 input layer와 mapping layer 및 mapping layer와 bottleneck layer 간의 신경망 결합강도에 분산·저장되게 된다. 이로 인해 학습시 사용된 데이터와 다른 입력(센서바이어스 등과 같은 센서 고장 데이

터)이 AANN에 입력된다 할지라도 AANN은 고장이 없을 경우의 센서값을 출력하게 된다. 따라서 그림 2의 AANN의 출력과 센서입력에 대한 잔차는 0이 아닌 값을 갖으며 이 잔차의 검사를 통해 센서 바이어스 등과 같은 센서 고장의 검출을 효율적으로 수행될 수 있게 된다. 중요한 것은 AANN이 상기의 특성을 갖기 위해서는 반드시 입력 데이터들간에 강한 상관관계가 존재해야 하며 이를 위해서는 물리적인 다중센서 중첩도 또는 측정 변수들간의 선형, 비선형 상관관계에 의해 생성되는 추가적인 변수의 사용이 요구된다.

2.3 통계학적 의사결정 로직

그림 2의 고장검출로직은 일반적으로 널리 사용되고 있는 최우추정법을 기반으로 구현되었다. 고장검출로직은 실제 센서의 출력과 AANN의 출력과의 잔차를 입력으로 사용한다. 일반적으로 센서가 정상적으로 작동할 경우 잔차의 평균은 0이 되며 분산은 센서신호에 더해지는 잡음과 관련된 어떤 값을 갖는다. 만약 센서에 고장이 발생한다면 잔차의 평균은 0이 아니고 분산 또한 정상 운전시와는 다른 값을 갖게 된다. 이러한 변화는 최우추정법에 의해 추정되는 파라미터에도 나타나게 되며 이를 이용한다면 효율적인 센서고장검출이 가능하게 된다. 센서의 동작이 정상적일 때 최우추정법에 의해 추정된 파라미터들로부터 고장검출을 위한 임계값을 미리 설정하고 실시간 모니터링 중에 추정된 파라미터들이 임계값의 범위를 초과하면 고장, 그렇지 않다면 정상으로 분류한다.

3. 새만금 환경 모니터링 시스템에의 적용

3.1 새만금 수질 데이터에 대한 AANN의 적용

현재 군산대학교 새만금 환경연구센터에서는 새만금 사업 종료 후 생성되는 새만금 담수호의 주된 수급원이 될 만경강유역의 수질관리를 위해 5개소에 원격 계측 스테이션을 설치·운영중이며 스테이션으로부터 Ph, 수위, 전기전도도(EC) 및 온도 등의 4가지 계측값이 새만금 환경연구센터의 서버로 전송되고 있다. 특히 이들 센서 중 온도 및 Ph 센서는 센서 바이어스 등과 같은 센서 고장으로 인해 주기적인 캘리브레이션 및 교체를 수행해야 한다. 따라서 이들 센서고장의 검출은 필수적이며 본




그림 3. 계측스테이션 I의 센서값
Fig. 3. Sensor values from measurement stations I

연구에서는 2장에서 제안된 AANN 기반 센서 고장 검출 알고리즘을 계측스테이션 I, III, V로부터의 온도, EC, 수위 계측데이터에 적용하고자 한다.

3.2 수질 계측 데이터

본 연구에서는 2003년 2월부터 3월까지 1시간 간격으로 측정된 수위, 온도, EC 계측데이터를 사용하였다. 계측스테이션 I로부터의 측정 데이터를 나타내면 그림 3과 같다.

3.3 AANN의 학습

AANN의 학습에 사용되는 입출력 패턴은 동일하며 따라서 AANN은 1:1 mapping 기능을 갖는다. 그러나 2.2절에서 언급한 바와 같이 입출력 뉴런의 수보다 적은 bottleneck layer의 도입으로 인해 AANN은 NLPCA의 특성을 갖게 되어 학습시와는 다른 데이터(센서고장)가 입력되어도 정상상태의 값을 출력할 수 있게 된다.

본 연구에서는 계측스테이션 I, III, V호기에서 측정된 온도, 수위, EC 계측데이터를 학습에 사용하였다. 즉 input layer 및 output layer는 9개의 뉴런으로 구성되었고, mapping layer와 demapping layer는 24개, bottleneck layer는 4개의 뉴런으로 구성되었다. AANN의 센서 바이어스 고장검출 기능을 확인하기 위해 Matlab 시뮬링크를 사용하였으며 이를 나타내면 그림 4와 같다.

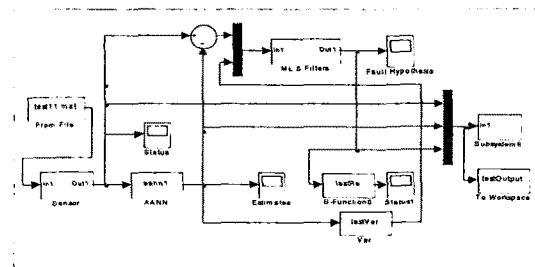


그림 4. 센서고장 검출을 위한 Matlab 시뮬링크 블록도
Fig. 4. Simulink block diagram for sensor fault

학습 완료된 AANN의 성능확인을 위해 계측스테이션 I의 데이터 중 온도데이터에 ramp 형의 바이어스를 인가하였으며 이 경우의 AANN의 출력 및 실제 계측센서의 출력을 나타내면 그림 5와 같다. 그림 5로부터 ramp 형의 센서 바이어스가 인가되어도 AANN은 바이어스가 없을 경우의 정상 값을 출력함을 알 수 있다. 또한 2.3절에 언급한 최우추정법으로 AANN과 실제 계측센서 값 사이에서 발생하는 잔차, 분산의 변화 등을 이용하여 고장 검출을 수행하였다. 고장검출로직은 센서가 정상적으로 동작할 때 0, 고장을 검출하였을 때 1을 출력하며

AANN과 실제 계측센서의 출력이 그림 5와 같을 때 고장검출로직의 출력은 그림 6과 같다.




그림 5. AANN 및 센서 응답 특성
Fig. 5. Response characteristics for each sensors and AANN




그림 6. 최우추정법 기반 고장검출로직의 출력
Fig. 6. Output of fault detection logic based on MLE

4. 결 론

본 연구에서는 다변수 데이터의 해석에 널리 사용되고 있는 AANN 기법과 MLE 기법을 병합한 센서고장검출 시스템의 유용성 확인을 위해 현재 설치 운영되고 있는 새만금 환경 모니터링 데이터에 실제 적용하여 보았다. 적용 결과 센서 바이어스 고장검출을 효율적으로 수행함을 확인할 수 있었다. 그러나 보다 효율적인 센서고장 검출 시스템의 설계를 위해서는 AANN의 구조 선정에 대한 체계적인 연구가 요망된다.

본 연구는 과학기술부·한국과학재단 지정 군산대학교 새만금환경연구센터의 지원에 의한 것입니다.

[참고 문헌]

- [1] MacGregor, J.F., K. Costas, "Process monitoring and diagnosis by multiblock PLS method", *AIChE J.*, 40(5), 826-838, 1994
- [2] Dunia, R. "Identification of faulty sensors using principle component analysis", *AIChE J.*, 42(10), 2797-2812, 1996
- [3] Kramer, M.A., "Autoassociative neural networks," *Computers in Chemical Eng.*, Vol.16, No.4, pp.313-328, 1992
- [4] J. W. Hines, D. J. Wrest, and R. E. Uhring, "Plant Wide Sensor Calibration Monitoring," published in the proceedings of The 1996 IEEE International Symposium on Intelligent Control, Sept. 15-18, pp.378-383, 1996