

센서드리프트 판별을 위한 통계적 탐지기술 고찰

서인용^{1†} · 신호철¹ · 박문규¹ · 김성준²

Statistical Techniques to Detect Sensor Drifts

In-Yong Seo · Ho-Cheol Shin · Moon-Ghu Park · Seong-Jun Kim

ABSTRACT

In a nuclear power plant (NPP), periodic sensor calibrations are required to assure sensors are operating correctly. However, only a few faulty sensors are found to be calibrated. For the safe operation of an NPP and the reduction of unnecessary calibration, on-line calibration monitoring is needed. In this paper, principal component-based Auto-Associative support vector regression (PCSVR) was proposed for the sensor signal validation of the NPP. It utilizes the attractive merits of principal component analysis (PCA) for extracting predominant feature vectors and AASVR because it easily represents complicated processes that are difficult to model with analytical and mechanistic models. With the use of real plant startup data from the Kori Nuclear Power Plant Unit 3, SVR hyperparameters were optimized by the response surface methodology (RSM). Moreover the statistical techniques are integrated with PCSVR for the failure detection. The residuals between the estimated signals and the measured signals are tested by the Shewhart Control Chart, Exponentially Weighted Moving Average (EWMA), Cumulative Sum (CUSUM) and generalized likelihood ratio test (GLRT) to detect whether the sensors are failed or not. This study shows the GLRT can be a candidate for the detection of sensor drift.

Key words : Support Vector Regression, Principal Component, GLRT

요약

원자력발전소에서 센서의 주기적 교정은 안전운전을 위해 꼭 필요하다. 그러나 실제 드리프트가 발생하여 교정을 요하는 센서는 약 2% 미만이다. 또한, 센서의 작동 상태를 매 핵연료 주기마다 수행하는 것은 고장 혹은 드리프트가 발생한 센서를 최대 18개월까지 감지하지 못한 채 운전할 위험이 있다. 원전의 안전운전 및 불필요한 교정을 줄이기 위해 센서의 상시 교정 감시가 필요하다. 이를 위해 주성분 분석과 Support Vector Regression(SVR)을 이용한 PCSVR 알고리즘을 개발하였고, 고리 원전 3호기의 출력증발 데이터를 이용하여 검증하였다. 주성분분석은 선형변환을 통한 입력공간의 축소 및 노이즈 제거 효과를 나타내며, AASVR은 해석학적 및 기계학적 모델로 모델링하기 힘든 복잡계를 쉽게 나타낼 수 있는 장점이 있다. SVR의 세가지 파라미터는 반응표면분석법에 의해 최적화하였다. 센서의 고장탐지를 위해 모델 출력의 잔차를 슈하르트 관리도, EWMA, CUSUM 및 일반화우도비검정(GLRT)을 통해 그 결과를 비교하였다. 미세한 드리프트에 대해 CUSUM과 GLRT가 우수한 결과를 보였다. 개발된 알고리즘은 수출형 원전 APR1000 설계시 적용가능 할 것으로 판단된다.

주요어 : 상시감시, SVR, 주성분분석, 드리프트, 일반화우도비검정(GLRT)

1. 서론

과거 원자력발전소의 센서교정은 연료교체 시기에 이

루어졌다. 이러한 방법은 센서의 상태를 정기적으로만 점검할 수 있다는 점에서 바람직하지 않다. 센서에 결함이 발생하더라도 교정시기가 올 때까지는 계속 비정상적으로 동작할 것이기 때문이다. 또한 정기적인 정비방법은 정상적인 센서에 대해서는 불필요한 교정을 하게 하는 측면도 있다. 최근의 연구보고에 따르면, 수동으로 교정이 이루어지는 센서 중에서 실제로 교정이 필요한 것은 2% 정도로 나타났다(Hines 등, 2007). 따라서 발전소 측은 운

2009년 6월 30일 접수, 2009년 9월 8일 채택

¹⁾ 전력연구원 원자력발전연구소

²⁾ 강릉대학교 산업정보경영공학파

주 저자 : 서인용

교신저자 : 서인용

E-mail: iyseo@kepri.re.kr

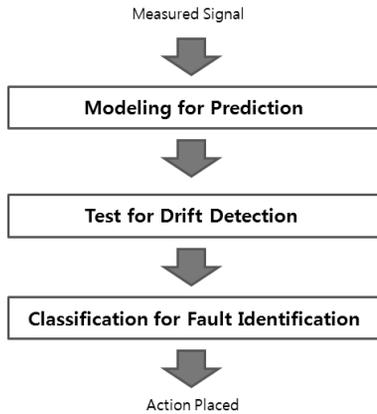


그림 1. OLM 시스템 구축의 3단계



그림 2. Auto-association Model

전 중에도 센서의 상태를 모니터링하면서 결함이 검출된 센서에 대해서만 선별적으로 교정하는 방안에 대해 관심을 갖기 시작하였고 센서교정을 목적으로 하는 On-line Monitoring (OLM) 기술은 바로 이러한 배경을 두고 도입되었다.

그림 1에서 보는 바와 같이, 발전소의 OLM 시스템의 구축은 크게 3단계 즉 모델링, 결함탐지, 결함식별로 구분될 수 있다.

첫 번째인 모델링 단계에서 OLM을 통한 센서교정이 가능하려면 우선 주어진 입력을 그대로 모사하여 출력으로 내보낼 수 있는 모델 즉 Auto-association 모델을 구축해야 한다(Wrest 등, 1996). 이는 곧 입력을 추정하는 것과 같은 문제로서, 예를 들어 센서들로부터 얻은 압력, 수위, 온도 등 프로세스의 측정값 (x_1, x_2, \dots, x_m) 으로부터 그 참값에 대한 예측치 $(\hat{x}_1, \hat{x}_2, \dots, \hat{x}_m)$ 을 어떻게 제시할 것인가로 요약된다. 이와 같은 Auto-association 문제는 다음 그림 2와 같이 나타낼 수 있다.

이 문제를 다루기 위해 Artificial Neural Network (Fantoni 등, 1998), Kernel Regression (Bickford 등 2003), Multivariate State Estimation Technique (MSET) (Mott 등, 1987) 등의 방법이 사용되고 있다. 신경회로망을 이용한 Plant Evaluation and Analysis by Neural Operators (PEANO)가 할덴 원자로 프로젝트에 의해 개발되었으며,

이는 입력층, 맵핑층, 병목층, 디맵핑층, 출력층 등 총 5가지의 뉴런 계층을 포함하고 있다. 커널 회귀분석이란 과거의 표본 데이터로부터 기중평균을 취하여 파라미터 값을 추정하는 방법이다(Atkeson 등, 1997). 한편, MSET은 원자력발전소의 고감도 선행적 모니터링을 위해 미국 알곤 국립연구소에서 개발된 비선형적, 비모수형 모델링 기법이다.

또한 본 연구에서 사용될 Support Vector Machine (SVM) 역시 유망한 대안의 하나로 많은 연구가 이루어지고 있다.

두 번째 단계는 불확실성 분석으로 바로 본 연구에서 다루고자 하는 부분이다. 이 것은 일단 모델링이 이루어져서 센서측정값을 예측할 수 있다면 이를 얼마나 신뢰할 수 있는지를 통계적으로 검증하는 단계라고 하겠다. 본 연구에서는 통계적인 일반화우도비검정 (Generalized Likelihood Ratio Test, GLRT)와 CUSUM (Cumulative Summation)을 제안하고자 한다. GLRT는 평균의 미세한 변화를 검출하는 데 유용한 방법으로서 OLM 센서의 드리프트 탐지에도 적절하게 활용될 수 있다. 본 연구에서는 11개 센서 중 7번인 증기발생기 주급수 유량 센서를 이용하여 GLRT의 적용을 예시하고, 그 활용방안에 대해서 논의하고자 한다.

세 번째는 식별단계로서 결함이 발생했다면 과연 어떤 결함이었는가를 찾는 단계이다. 이를 위해서는 각종 패턴 인식기술과 베이즈안통계가 많이 활용되어야 한다. 본 연구에서 다룰 GLRT 역시 식별문제를 위해 확장될 수 있다.

전력연구원은 계측기 신호를 검증하기 위하여 주성분 기반 AASVR을 이용하여 온라인 감시체통(PCSVR)을 개발하였다(In-Yong Seo 등, 2008). 이 논문의 연구목적은 PCSVR의 잔차를 이용하여 Shewhart, EWMA, CUSUM, GLRT의 통계적 방법에 의한 관리도를 적용하여 고장 감지능력을 비교 고찰하는 것이다.

2. PCSVR 기반 상시감시기술

본 논문에서는 발전소 센서 상시감시용 모델을 구축하기 위해 Support Vector Regression (SVR)을 이용하였다. 발전소 상시감시모델은 고리원전 3호기의 1, 2차측 11개의 센서로부터 1분 간격으로 얻어진 데이터를 이용하여 개발되었다. 본 모델은 특히 상시감시체계의 핵심이라 할 수 있는 Auto-association 성능을 강화하기 위해 주성분특징 추출단계를 적용하였다. 즉 11개의 데이터채널은 주성분분석을 통해 7개의 주성분채널로 압축되고, 이

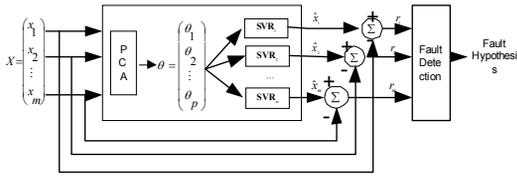


그림 3. 상시감시를 위한 SVR 앙상블

를 다시 11개의 채널로 복원된다. 따라서 복원될 채널마다 개별적인 SVR 모델링이 이루어졌고, 이를 다시 총합함으로써 본 상시감시체계는 다음 그림 3의 SVR 앙상블로 구성되었다.

다음은 그림 3의 PCA Based AASVR (PCSVR)이 원전의 계측기 센서의 건전성 판별에 어떻게 적용되는지를 설명하기 위해 우선 SVR의 이론적 배경과 함께 PCA의 적용방안을 살펴보기로 한다.

2.1 SVR과 PCA를 이용한 모델링 절차

통계적 학습이론에 근거한 Support Vector Machine (SVM)은 최근 패턴인식을 포함한 다양한 분야에서 분류, 회귀, 추정 등의 문제를 다루는 데 널리 활용되고 있다(Vapnik, 1988). 신경회로망 등 많은 방법이 Empirical Risk Minimization에 기초하고 있는 반면 SVM은 Structural Risk Minimization에 기초한다. 이런 연유로, SVM 쪽이 보다 적은 학습데이터로도 더 나은 일반화능력을 보여줄 수 있으며, 유망한 대안으로 주목받고 있다(Gunn, 1988).

SVM은 클래스 간의 최소거리를 최대화하는 초평면(Hyperplane)을 찾아냄으로써 클래스를 분류하는 방법이다. 만약 클래스를 최적으로 분리하는 초평면(Optimal Separating Hyperplane, OSH)이 존재하지 않을 경우에는 원 데이터를 보다 높은 차원의 공간으로 사상시키고 새로운 영역에서 OSH를 찾게 된다. 최적분류를 위해 복잡한 관계식을 이용하면 학습데이터에 대한 의존도가 높아져서 과적합(Over-fitting)이 발생하기 쉽고 따라서 분류의 일반화 능력도 저하된다. SVM은 이 문제를 해결하기 위해 비선형적인 변수변환을 이용하여 보다 높은 차원에서 선형적인 판별함수 즉, OSH를 찾고자 하는 것이다. 바로 이 아이디어를 함수관계식을 추정하는 회귀문제로 확장한 것이 바로 Support Vector Regression이다. 상시 감시를 위한 Auto-association 문제도 역시 회귀문제에 해당되므로 SVR로 다룰 수 있다.

우선 학습데이터셋을 아래와 같이 나타내기로 한다.

$$\{(x_i, y_i) | x_i, y_i \in R^m \text{ for } i = 1, 2, \dots, n\}$$

즉, x_i 와 y_i 는 각각 센서입력과 센서출력을 나타내는 m 차원의 벡터이다. m 차원의 입력변수 x_1, x_2, \dots, x_m 를 p 차원의 주성분 $\theta_1, \theta_2, \dots, \theta_p$ 으로 압축하는 것은 다음과 같이 나타낼 수 있다.

$$\begin{aligned} \theta_1 &= q_{11}x_1 + q_{12}x_2 + \dots + q_{1m}x_m \\ \theta_2 &= q_{21}x_1 + q_{22}x_2 + \dots + q_{2m}x_m \\ &\dots \\ \theta_p &= q_{p1}x_1 + q_{p2}x_2 + \dots + q_{pm}x_m \end{aligned} \tag{1}$$

단 p 는 m 보다 같거나 작은 정수이다. 벡터 a_i 와 x 를 $a_i = (q_{i1}, q_{i2}, \dots, q_{im})$ 과 $x = (x_1, x_2, \dots, x_m)$ 로 각각 정의하면, 식 (1)은 다음과 같이 표현할 수 있다.

$$\theta_i = a_i^T x \tag{2}$$

단 $i = 1, 2, \dots, p$ 이다. 따라서 k 번째 출력에 대한 SVR로 구하게 될 최적회귀식 (Optimum Regression Line, ORL)은 다음과 같다.

$$f_k(\theta) = w_k^T \theta + b_k, \quad k = 1, 2, \dots, m \tag{3}$$

식 (3)의 w_k 와 b_k 는 미지의 상수로서 모델링과정에서 그 값이 결정되어야 한다. 여기서 k 번째 출력변수 $y^{(k)}$ 에 대한 손실함수를

$$L_k(y_k) = \begin{cases} 0, & |f_k(\theta) - y^{(k)}| < \epsilon_k \\ |f_k(\theta) - y^{(k)}| - \epsilon_k, & \text{elsewhere} \end{cases} \tag{4}$$

와 같이 정의한다. 예측편차가 ϵ_k 보다 작을 때에는 페널티를 발생시키지 않는다고 해서 식 (4)를 ϵ -insensitive Loss Function이라고 부른다. SVR에서 가장 많이 사용되는 손실함수이다. 그러면, $y^{(k)}$ 에 대한 ORL을 구하기 위한 최적화문제는 다음과 같이 나타낼 수 있다(Vapnik, 1988).

$$\begin{aligned} \text{Minimize } \Phi(w_k, \xi_k) &= \frac{1}{2} w_k^T w_k + C_k \sum_{i=1}^n (\xi_{k,i} + \xi_{k,i}^*) \\ \text{s.t. } & y_i^{(k)} - w_k^T \theta_i - b \leq \epsilon_k + \xi_{k,i} \\ & w_k^T \theta_i + b - y_i^{(k)} \leq \epsilon_k + \xi_{k,i}^* \\ & \epsilon_k, \xi_{k,i}, \xi_{k,i}^* \geq 0 \text{ for } i = 1, 2, \dots, n \end{aligned} \tag{5}$$

여시, $k = 1, 2, \dots, m$ 이고 $\xi_{k,i}$ 와 $\xi_{k,i}^*$ 는 그림 4에서 보는 바와 같이 x_i 가 ϵ -insensitive zone (이를 ϵ -tube라고 함)

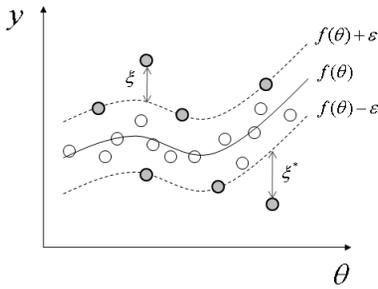


그림 4. SVR with ϵ -tube

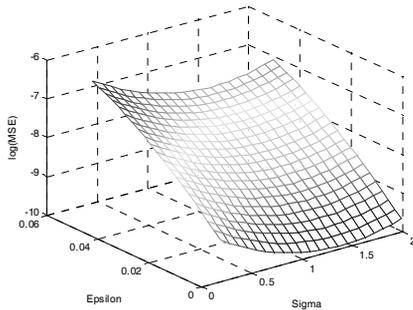


그림 5. $\log(\text{MSE})$ 에 대한 반응표면도

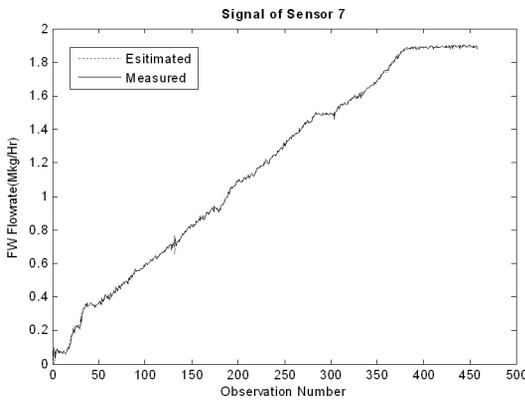


그림 6. 채널7의 모델입력과 출력데이터

을 벗어난 경우를 위한 여유변수 (Slack Variable)를 의미한다. 상수 C_k 는 튜브크기에 대해 부여되는 페널티를 의미하며, 0에 가까게 설정될수록 튜브 폭에 관대한 결과를 초래하게 된다.

단, 여기서 θ_i 라 하면 벡터 θ 의 i 번째 요소가 아니라 x 에 대한 i 번째 관측치벡터에 대응되는 주성분벡터를 의미한다는 데 유의해야 한다.

앞의 문제 (5)는 쌍대문제라 바꾼 후 quadratic programming(QP)으로 풀 수 있으며, 그 결과 k 번째 센서출력변

수에 대한 ORL을 다음과 같이 구할 수 있다.

$$f_k(\theta) = w_k^{*T} \theta + b_k^* = \sum_{i=1}^n (\lambda_{k,i} - \lambda_{k,i}^*) \theta_i^T \theta + b_k^* \quad (6)$$

단, $k = 1, 2, \dots, m$ 이고 $\lambda_{k,i}$ 와 $\lambda_{k,i}^*$ 는 각각 i 번째 제약식에 대한 비음의 라그랑지승수를 의미한다.

지금까지 살펴본 내용은 선형회귀식을 찾는 과정이었고 커널함수 $K(\theta_i, \theta) = \phi(\theta_i)^T \phi(\theta)$ 를 이용하여 비선형 변환을 적용할 때에는 다음과 같이 비선형 최적회귀식을 구할 수 있다.

$$f_k(\theta) = \sum_{i=1}^n (\lambda_{k,i} - \lambda_{k,i}^*) K(\theta_i, \theta) + b_k^* \quad (7)$$

단, 바이어스항은 다음과 같이 임의의 Support Vector 인 θ_r 과 θ_s 를 이용하여 계산된다.

$$b_k^* = -\frac{1}{2} \sum_{i=1}^n (\lambda_{k,i} - \lambda_{k,i}^*) [K(\theta_i, \theta_r) + K(\theta_i, \theta_s)] \quad (8)$$

이 과정을 반복하여 각각의 출력에 대한 총 m 개의 SVR을 얻고 그림 3에 제시된 바와 같이 PCSVR 양상부를 구축함으로써 원전센서의 상시감시문제를 다룰 수 있게 된다. 본 논문에서는 비선형변환함수로서 가장 널리 쓰이고 있는 아래의 가우시안커널(Gaussian Kernel)을 이용하기로 한다.

$$K(\theta_i, \theta) = \exp \left\{ -\frac{(\theta - \theta_i)^T (\theta - \theta_i)}{2\sigma^2} \right\} \quad (9)$$

2.2 PCSVR에 의한 원전 데이터 모델링

지금까지 설명한 PCSVR을 이용하여 고리원전 3호기 데이터로부터 상시감시모델을 구축하기로 한다. 실제로 모델링을 위해서는 세 개의 파라미터의 값을 사전에 정해 주어야 한다. 식 (9)의 σ , 식 (4)의 ϵ , 식 (5)의 C 가 바로 그들이다. 모델의 단순성을 확보하기 위해 이들 파라미터는 센서출력에 모두 공통인 것으로 가정한다. 이들 값을 효율적으로 결정하기 위해 본 논문에서는 반응표면분석법(Response Surface Methodology)을 사용하였다. 분석결과, 각 실험점에서 훈련데이터의 평균자승오차(MSE)를 최소화하는 최적조건은 각각 $\sigma^* = 1.4$, $\epsilon^* = 0.0005$, $C^* = 6.8$ 인 것으로 나타났다. 다음 그림 5는 σ 와 ϵ 에 대한 $\log(\text{MSE})$ 의 반응표면도를 보여주고 있다.

다음은 11개의 센서채널 중 7번째 채널을 대상으로 통계적공정관리(SPC)의 적용절차를 살펴본다. 표본수는 458

개이며 입력값과 예측값은 다음 그림 6과 같다. 그림 6에서 실선은 입력데이터이고 점선은 출력데이터를 나타낸다. 모델잔차는 입력값과 모델 예측값의 차이로서

$$r_i = x_i - \hat{x}_i \quad (10)$$

와 같이 나타낸다. 단 $i = 1, 2, \dots, 458$.

그림 7은 센서 7의 잔차를 나타낸다. 458개의 잔차를 살펴보면, 발전소 저출력 운전에 해당하는 처음 30개는 대단히 불안정적인 값을 나타내고 있고, 특히 시스템의 과도현상에 기인하는 No. 132와 No. 304에서 0과 멀리 떨어져있는 값이 관측되고 있다. 이러한 점을 종합적으로 고려할 때, 잔차 전체를 분석대상으로 삼는 것은 무리가 있으므로 본 연구에서는 No. 151에서 No. 300까지의 잔차를 분석데이터로 삼고자 한다.

본 연구에서는 잔차를 대상으로 SPC를 수행해야 하므로 잔차에 대한 정규성을 검증하기 위해 히스토그램과 정규확률도(Normal Probability Plot)를 작성하였다.

그림 8의 히스토그램은 잔차가 0을 중심으로 하는 정규분포의 모양을 갖추고 있음을 보여준다. 단, 히스토그램의 모양은 계급의 수와 경계를 어떻게 정하는가에 의존한다. 따라서 정규분포에 얼마나 가까운지를 알아보려면 그림 9의 정규확률도를 작성해 보는 것이 좋다. 개별 잔차들은 정규확률도 상에 점으로 표시되어 있다. 이들이 직선에 가깝게 모여 있을 때 정규성을 갖는다고 판단한다. 정규분포로부터 이탈이 심하다면 직선 주위에서 흩어지는 모습이나 곡선적인 모습을 보이게 된다. 그림 9는 미니탭®을 이용하여 잔차의 정규확률도를 그린 것이고, Anderson-Darling 시험결과는 0.217, 가설검증 통계량 P값은 0.841로 잔차가 정규분포를 따른다고 말할 수 있다.

2.3 관리도에 의한 통계적 탐지방법

2.3.1 Shewhart 관리도

20세기 초에 Dr. Walter Shewhart에 의해 고안된 관리도는 통계적 공정관리를 위한 대표적인 수법 중 하나로 중심선과 한계를 설정한 후, 관측된 데이터를 시간 순 혹은 샘플 순으로 타점해 나가면 관리도가 작성되는 것이다.

$$\begin{aligned} UCL &= \mu + 3\sigma \\ CL &= \mu \\ LCL &= \mu - 3\sigma \end{aligned} \quad (11)$$

이때 False Alarm 발생 확률은 0.27%로서 이는 정규분포에서,

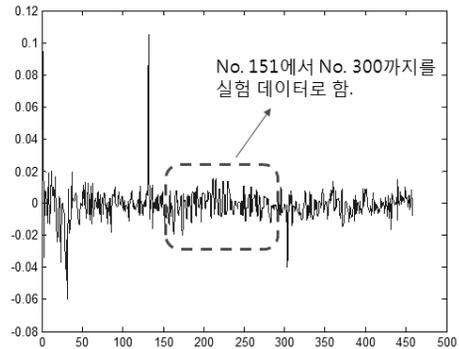


그림 7. 센서 7의 잔차데이터

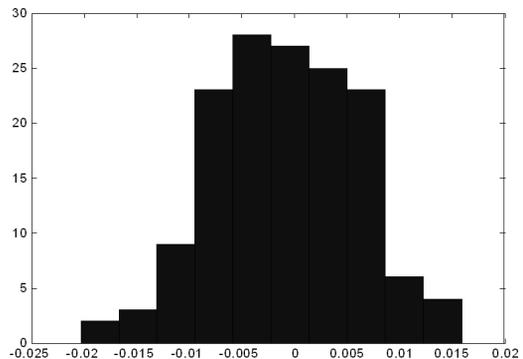


그림 8. 잔차에 대한 히스토그램

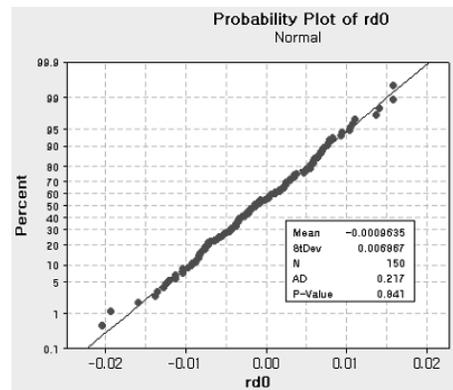


그림 9. 잔차에 대한 정규확률도

$$\Pr(\mu - 3\sigma \leq X \leq \mu + 3\sigma) = 0.9973 \quad (12)$$

이기 때문이다.

2.3.2 EWMA 관리도

슈하르트 관리도는 이해하기 쉽고 단순하다는 장점이 있지만, 가장 최근에 이루어진 타점으로만 의사결정을 내리게 되므로 정보의 손실이 크다는 단점이 있다. 이를 보완하

기 위해 제안된 관리도로서 대표적인 것이 Exponentially Weighted Moving Average (EWMA) 관리도와 Cumulative Sum (CUSUM) 관리도가 있다.

먼저 EWMA 관리도를 살펴본다. 무엇보다도 EWMA 관리도는 x 대신 다음에 정의되는 z 를 타점하는 것이 다르다(Lucas 등, 1990).

$$z_i = \lambda x_i + (1 - \lambda)z_{i-1} \quad (13)$$

$$\sigma_{z_i}^2 = \sigma^2 \left(\frac{\lambda}{2 - \lambda} \right) [1 - (1 - 2\lambda)^{2i}] \quad (14)$$

λ 는 현재의 예측값이 과거의 측정데이터에 의해 얼마만한 영향을 받는지를 결정하는 0과 1사이의 상수로서, 큰 값일수록 과거데이터에 영향을 덜 받고 현재 데이터에 큰 가중치를 제공한다. EWMA 관리도의 중심선과 상하한은 다음 식 (15)로 나타낼 수 있다. 샘플번호 i 에 따라 관리한계가 다르게 될 수 있음을 유의해야 한다.

$$\begin{aligned} UCL_i &= \mu_0 + L\sigma_{z_i} \\ CL &= \mu_0 \\ LCL_i &= \mu_0 - L\sigma_{z_i} \end{aligned} \quad (15)$$

2.3.3 CUSUM 관리도

CUSUM 관리도에서는 x_i 대신 다음으로 정의되는 누적합 (Cumulative Sum)을 타점하는 것이 다르다.

$$C_i = \sum_{j=1}^i (x_j - \mu_0) \quad (16)$$

누적합은 목표치로부터의 편차를 누적시킨 것으로 과거의 정보가 모두 담겨있다고 볼 수 있다.

2.3.4 GLRT를 이용한 관리도

잔차에 대한 σ 가 알려져 있는 경우로 가정할 때 시점 t 에서의 Generalized Likelihood Ratio (GLR)은 다음과 같다(Kay, 2008; Runger 등, 2003).

$$GLR_t = w(\bar{x}_t)^2 / \sigma^2 \quad (17)$$

이고, \bar{x}_t 는 최근 윈도우 크기 w 개의 데이터로 구한 평균을 의미하므로

$$\bar{x}_t = \sum_{i=t-w+1}^t x_i / w \quad (18)$$

와 같이 구한다. GLRT의 검정통계량 G_t 는 시점 t 에서 얻어지는 GLR 중 window size 내에서 가장 큰 것으로 정의되므로 다음과 같이 구할 수 있다.

$$\begin{aligned} G_t &= \max [GLR_t(k), 1 \leq k \leq w] \\ &= \max [k \overline{x_t(k)}^2 / \sigma^2, 1 \leq k \leq w] \end{aligned} \quad (19)$$

단, $\overline{x_t(k)}$ 는 최근 k 개의 데이터로 시점 t 에서 구한 평균으로서 다음과 같이 표현된다.

$$\overline{x_t(k)} = \sum_{i=t-k+1}^t x_i / k \quad (20)$$

3. 드리프트 탐지 시험

드리프트가 발생했을 때 이를 신속하게 검출하기 위해 시프트와 드리프트 두 가지 유형을 가정할 수 있다. 첫 번째는 어떤 특정시점 이후로 평균이 δ 만큼 증가한 상황을 말한다. 통계적 가설검정의 문제로 보면

$$H_0: \mu = \mu_0 \quad \text{vs} \quad H_1: \mu = \mu_0 + \delta \quad (21)$$

가 된다. 본 사례에서는 $t=50$ 에서 δ 가 +0.01일 경우를 다룬다. 두 번째는 측정값에 비례하여 드리프트가 발생하는 상황을 다룬다. 역시 통계적 가설로 표현하면,

$$H_0: \mu = \mu_0 \quad \text{vs} \quad H_1: \mu = \mu_0(1 + \delta) \quad (22)$$

가 된다. 본 연구에서는 첫 번째의 평균의 단순한 시프트로 한정하여 설명한다. 본 사례에서는 역시 $t=50$ 에서 δ 가 +0.01인 경우로서 그림 10은 시프트가 발생한 입력신호에 대한 모델의 출력신호의 잔차를 그린 것이다.

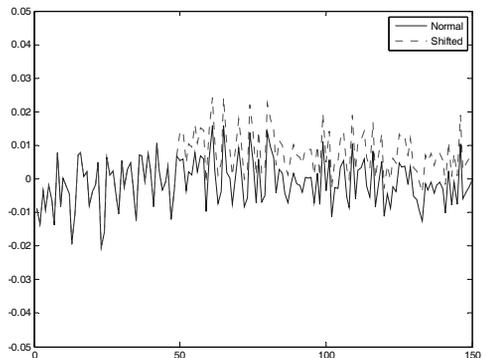


그림 10. 시프트 H_1 잔차 ($\delta=+0.01$)

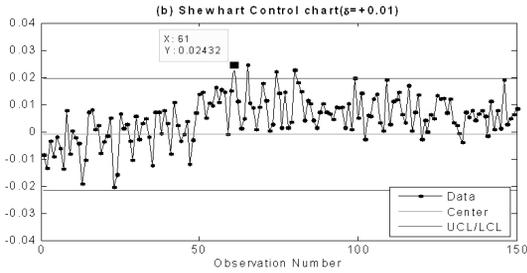
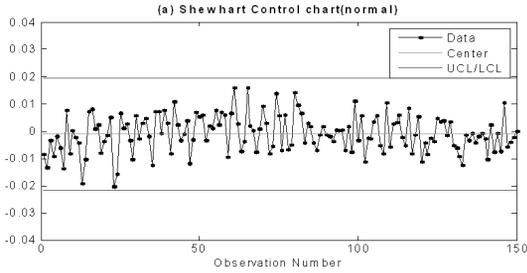


그림 11. 슈하르트 관리도($\delta=0.01$)

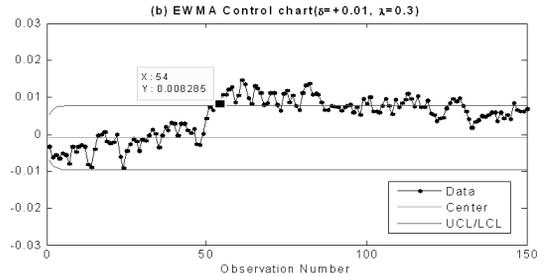
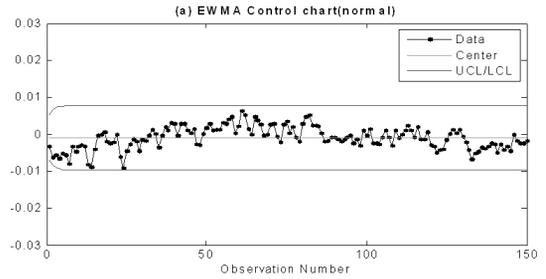


그림 13. EWMA 관리도($\lambda=0.3$)

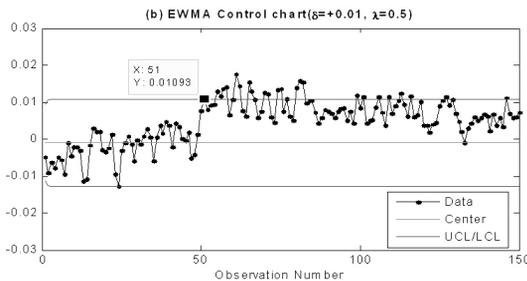
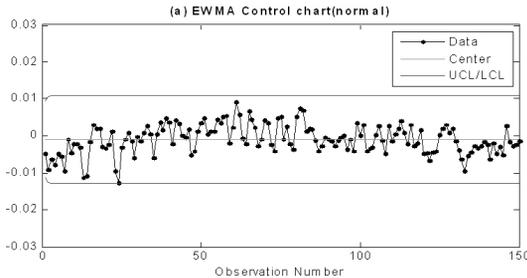


그림 12. EWMA 관리도($\lambda=0.5$)

50번째 이후의 모든 데이터에 발생한 시프트를 얼마나 빨리 탐지해내는가가 발전소 OLM에서는 중요 관심사이다. 이를 위해 Shewhart, EWMA, CUSUM, GLRT를 차례대로 적용해 본다.

먼저 Shewhart 관리도 작성결과는 그림 11과 같다. 그림 11(a)는 정상상태에 대한 Shewhart 관리도로서 모든 잔차가 $\mu \pm 3\sigma$ 인 Upper Control Limit(UCL)과 Lower Control Limit(LCL)의 범위 안에 있음을 알 수 있다. 그

림 11(b)는 드리프트 발생 잔차에 대한 슈하르트 관리도로서, 드리프트 발생 후 11번째 데이터에서 처음으로 고장이 탐지되고 있다. 그러나 UCL을 초과하는 데이터는 100개 중 4개 정도로 드리프트 발생을 단정하기 어려운 결과를 보여준다.

그림 12는 EWMA에 대한 결과로서 (a)는 정상상태 일 경우, (b)는 시프트 드리프트 발생시 $\lambda=0.5$ 에 대한 결과이다. UCL과 LCL은 식 (15)에 의해 결정되며 이 시험에서 $L=3$ 을 사용하였다. 드리프트 발생 후 첫번째 데이터에서 고장이 탐지되었고, 100개의 드리프트 발생 데이터 중 23개가 고장으로 탐지되었다.

그림 13은 $\lambda=0.3$ 에 대한 EWMA에 대한 결과로서 UCL과 LCL의 범위가 $\lambda=0.5$ 에 비해 줄어들었고, 더 많은 수의 데이터(48개)에서 고장을 감지 할 수 있음을 알 수 있다.

그림 14는 잔차에 대한 CUSUM 관리도로서 (a)는 정상상태 일 경우, (b)는 시프트 드리프트 발생시에 대한 결과이다. 센서가 정상시에는 CUSUM의 크기가 +1과 -1 사이에 있음을 보여준다. CUSUM 관리도에서 사용한 한계치인 UCL은 0.2796, LCL은 -0.3084로서, 이는 잔차의 정규분포(평균 -0.00096347, 표준편차 0.0069)와 같은 무작위수를 1000회 발생시켜 CUSUM을 반복 시험하여 얻은 최대치와 최소치이다. CUSUM 관리도에서는 드리프트 발생 후 29번째 데이터에서 고장을 탐지하였고, 이 시점 이후로는 CUSUM이 계속 증가하여 고장 판정의 일관

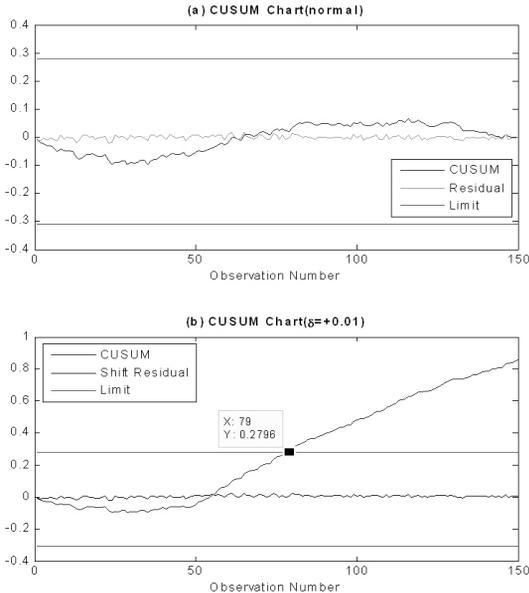


그림 14. CUSUM 관리도($\delta=0.01$)

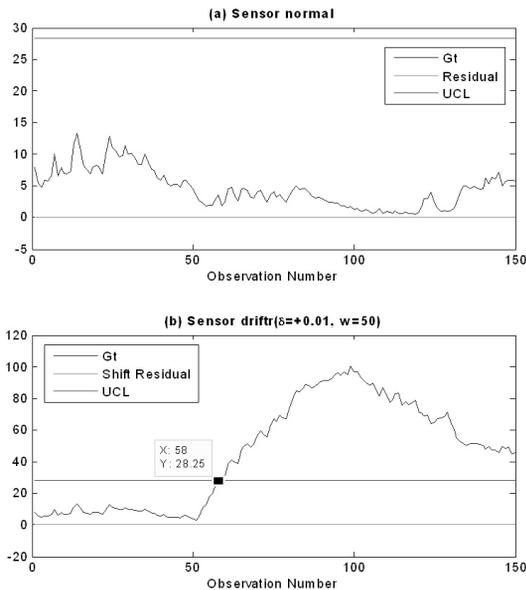


그림 15. GLRT 관리도($\delta=0.01$)

성 있는 결과를 보여준다. EWMA에 비하여 탐지 시점은 늦지만, 일관성 있는 판정결과를 보여주는 것이 장점이다.

그림 15는 잔차에 대한 GLRT 관리도로서 (a)는 정상 상태 일 경우, (b)는 시프트 드리프트 발생시에 대한 결과이다. 센서가 정상시에는 Gt 통계량이 양수(+)이며, 거의 15 이하임을 보여준다. GLRT 관리도에서 사용한 한계치인 UCL은 28.25로서, CUSUM의 경우와 마찬가지로

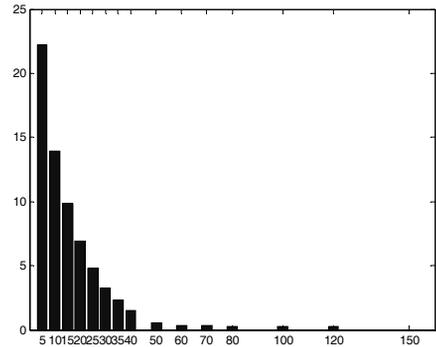


그림 16. 윈도우 크기와 Gt의 MSE비교

표 1. 고장 탐지 최초시점 및 탐지확률 비교

	Shewhart	EWMA	CUSUM	GLRT
탐지점	11	1	29	8
탐지확률(%)	4	23	71	92

1000회 반복 시험하여 얻은 Gt의 최대치이다. 이 시험에서 사용한 윈도우의 크기는 50이다. 그러므로 UCL을 결정하기 위한 시험에서 매번 발생시킨 무작위수는 200개 임에 유의해야 한다.

그림 16과 같이 여러 가지 윈도우 크기에 대한 Gt 통계량의 MSE를 비교한 결과 윈도우의 크기는 50이 최적인 것으로 나타났다. 그림 15의 GLRT 관리도에서는 드리프트 발생 후 8번째 데이터에서 고장을 탐지하였고, 이 시점 이후로는 Gt 통계량이 계속 UCL보다 훨씬 크기 때문에 CUSUM과 마찬가지로 일관성 있는 판정결과를 보여준다.

다음 표 1은 각 관리도에 대해 시프트 발생 후 고장이 탐지된 최초시점 및 탐지확률을 비교하고 있다.

Shewhart관리도와 EWMA 관리도는 미세한 드리프트에 대해 탐지확률이 매우 낮으며, CUSUM과 GLRT는 첫 고장 탐지 이후에는 고장발생에 대한 일관성 있는 판정을 준다. GLRT는 CUSUM 보다 고장을 빨리 탐지한다는 것을 알 수 있지만, 이 둘 다 센서의 드리프트 판정 알고리즘으로 사용가능함을 알 수 있다.

4. 결 론

본 연구에서는 주성분과 SVR을 이용한 발전소 온라인 모니터링 시스템에 있어 센서의 결함 탐지를 위한 통계적 방법에 대해 고찰하였다. 전통적인 슈하르트 관리도는 비

록 다양한 분야에서 널리 활용되고 있으나 미세한 드리프트 탐지에는 취약하다. 본 연구에서 제시된 일반화우도비검정(GLRT)은 과거의 데이터를 효과적으로 활용함으로써 이러한 단점을 극복하며, CUSUM보다 빨리 고장을 탐지할 수 있다. 본 연구에 사용된 데이터는 원전의 출력 증발 기간 중 취득한 데이터를 모델링 후 잔차를 이용하여 일부 구간에서는 정규분포를 보이지 않았다. 그러나 원전은 기저부하를 담당하고 있으므로 항상 일정한 출력을 내고 있어 시스템 과도현상 거의 없기 때문에 잔차가 정규분포를 보일 것으로 예측된다. 그러므로 CUSUM이나 GLRT 등의 방법은 발전소 계측기의 $\pm 1\%$ 내외의 시프트 및 드리프트 탐지에 매우 유용할 것으로 보인다.

참 고 문 헌

1. Atkeson, C. G., A. W. Moore, and S. Schaal (1997), "Locally Weighted Learning", *Artificial Intelligence Review*, Vol. 11, pp. 11-73: 1997.
2. Bickford, R., Holzworth, R.E., R.D. Griebenow, and A. Hussey (2003), "An Advanced Equipment Condition Monitoring System for Power Plants," *Transactions of the American Nuclear Society*, New Orleans, LA: Nov 16-20, 2003.
3. Fantoni, P., S. Figedy, and A. Racz (1998), "A Neuro-Fuzzy Model Applied to Full Range Signal Validation of PWR Nuclear Power Plant Data", *FLINS-98*, Antwerpen, Belgium.
4. Gunn, S. R. (1998), "Support Vector Machines for Classification and Regression," *Technical Report*, University of Southampton.
5. Hines, J. W. and Garvey, D. (2007), "Process and Equipment Monitoring Methodologies Applied to Sensor Calibration Monitoring," *Quality and Reliability Engineering International*, Vol. 23, pp. 123-135.
6. In-Yong, Seo., S. J. Kim, "An On-line Monitoring Technique Using Support Vector Regression and Principal Component Analysis," *CIMCA 2008*, Vienna, Austria, December 10-12, 2008.
7. Kay, S. (2008), *Fundamentals of Statistical Signal Processing*, Vol. II, Prentice-Hall.
8. Lucas J. M. and Saccucci, M. S. (1990), "Exponentially Weighted Moving Average Control Schemes: Properties and Enhancements," *Technometrics*, Vol. 32, pp. 1-29.
9. Mott, Y., and R. W. King (1987), *Pattern Recognition Software for Plant Surveillance*, U.S. DOE Report.
10. Runger, G. and Testik, C. (2003), "Control Charts for Monitoring Fault Signatures: Cuscore versus GLR," *Quality and Reliability Engineering International*, Vol. 19, pp. 387-396.
11. Vapnik, N., (1988), *Statistical Learning Theory*, Wiley, New York.
12. Wrest, D. Hines, J. W. and Uhrig, R. E. (1996), "Instrument Surveillance and Calibration Verification Through Plant Wide Monitoring Using Autoassociative Neural Networks", *Proceedings of The 1996 American Nuclear Society Inter-national Meeting on Nuclear Plant Instrumentation, Control and Human Machine Interface Technologies*, University Park, PA.



서인용 (iyseo@kepri.re.kr)

1984 성균관대학교 전기공과 학사
1989 부산대학교 전기공학과 석사
2000 브라운대학교 응용수학과 석사
2003 브라운대학교 전기공학과 공학박사
2008 충남대학교 경영학과 석사
1984~현재 한전전력연구원 책임연구원

관심분야 : 모델링&시뮬레이션, System Identification



신호철 (hcshein@kepri.re.kr)

1988 경희대학교 원자력공학과 학사
1992 경희대학교 원자력공학과 석사
1994~현재 한전전력연구원 책임연구원

관심분야 : 계측기 드리프트



박문규 (mgpark@kepri.re.kr)

1984 과학기술원 원자력공학과 석사
1993 과학기술원 원자력공학과 공학박사
1984~현재 한전전력연구원 수석연구원

관심분야 : 원자력계측제어, 시뮬레이션



김성준 (sjkim@kangnung.ac.kr)

1989 연세대학교 응용통계학과 학사
1991 과학기술원 산업공학과 석사
1995 과학기술원 산업공학과 공학박사
1995~현재 강릉대학교 산업정보경영공학과 교수

관심분야 : 품질경영, 지능정보, DOE/SPC