

# 뉴럴네트웍을 이용한 불안정 공정의 탐지 및 인식

## Neuro Detection and Identification of Nonstationary Manufacturing Processes

허정준 · 김광섭 · 왕지남

아주대학교 산업공학과

### ABSTRACT

공정으로부터 얻어지는 공정특성치는 일반적으로 시계열로 모형화 할 수 있다. 그러므로 공정의 상태변화 감지는 공정을 묘사하는 시계열 모형의 출력에 대한 통계적 분석이나 모형을 형성하고 있는 파라미터들에 대한 감시를 통하여 가능하게 된다. 공정의 상태변화를 감시하기 위한 기존의 방법들은 공정 모형의 구조나 파라미터가 알려져 있거나 가정한 방법론을 제시하고 있다. 그러나 공정변화의 원인을 진단하거나 변동형태 또는 변동시점의 감지에 있어 통계적인 분포가 알려지지 않은 경우나 동적구조를 가진 데이터의 변동감지에는 많은 제약이 존재한다. 또한, 실제로 동적으로 변화하는 공정의 모형구조와 파라미터를 모든 경우에 파악하여 사전에 특정 시계열 모형으로 가정하기는 어렵다.

본 연구에서는 공정으로부터 얻어지는 데이터들을 뉴럴 모형화하여 이들의 이노베이션(innovation)에 대한 연속적인 검정을 통하여 공정의 상태변화를 감지하는 방법을 제시한다. 또한 새롭게 변화된 공정모형의 파라미터 집합에 대한 규명을 특정 시계열 모형을 가정하지 않은 일반화된 모형들에 대한 분류를 통하여 실시하였다.

## 1. 서론

공정의 상태가 시간에 따라 변화하는 동적상황하에서 공정의 변화를 감지하고 새롭게 변화된 공정의 상태에 대한 규명을 실시하는 것은 중요한 임무이다. 일반적으로 제조공정의 상태는 투입과 이에 대응되는 산출에 대한 공정의 모형에 의하여 묘사되어질 수 있다. 즉, 공정상태를 묘사하는 모형의 관측치들을 통하여 공정을 감시할 수 있는 것이다. 그러므로 동적인 공정의 변화 감지는 공정모형 내에서의 평균, 분산, 모형의 구조 또는 파라미터 집합의 변화에 대한 감시를 함으로써 수행될 수 있다.

기존의 연구들은 주로 공정관측치들에 대한 분포를 가정하거나 발생가능한 모형 구조에 대한 제약이 주어진 상태하에서 통계적 분석에 의하여 공정모형의 평균이나 분산의 변화를 감지하는 방법을 다루었다. 그러나 관측치들에 대한 분포가 알려져있지 않거나 가정할 수 없는 경우에는 많은 제약이 존재하게되며 현실적인 면에서 모형의 형태나 구조에 대한 가정을 하는 것은 많은 제약을 주는 것이다. 또한 실제로 공정의 상태변화가 발생하였음에도 불구하고 공정모형의 평균이나 분산이 변화하지 않는 경우도 존재한다.

일반적으로 불안정한 공정의 상태에 대한 규명은 공정 특성치들에 의하여 구성된 모형을 개개의 안정상태의 모형으로 분할함으로써 가능하게된다. 즉, 전체공정모형을 안정상태에 있는 집합들로 나눈 후 각 series에 대한 모델링을 통하여 불안정 상태하의 공정변동을 감지하고 규명 할 수 있는 것이다. 공정 특성치에 의한 전체 모형이 시간에 따라 종속적으로 변화하는 경우 안정상태하에 있는 개개의 공정을 묘사하는 통계량이나 척도가 변화하므로 하나의 mapping 절차로서는 공정의 상태변화 발생시마다 conflict가 발생 할 것이다. 이러한 conflict는 서로다른 안정상태하에 sub-process들을 동일한 모델링에 사용한 경우 발생하게 된다. 즉, 일단 모형이 안정상태하의 sub-process에 fitting 되었다면 새롭게 변화된 안정상태하의 sub-process를 묘사하기 위해서는 새로운 모형이 필요하게 된다.

이에따라 본 연구에서는 공정관측치들에 근거한 뉴럴모델링에 의하여 공정을 일반적인 모형으로 묘사한 후 이들의 이노베이션들에 대한 검정을 통하여 공정을 감시하는 방법을 제시하고자 한다. 또한 공정의 상태변화 감지 결과 유의한 변화가 감지된 경우 새로운 공정을 묘사하는 공정모형에 대한 분류(classification)를 실시하였다. 그림 1에는 본 연구의 대략적인 절차가 나타나 있다.

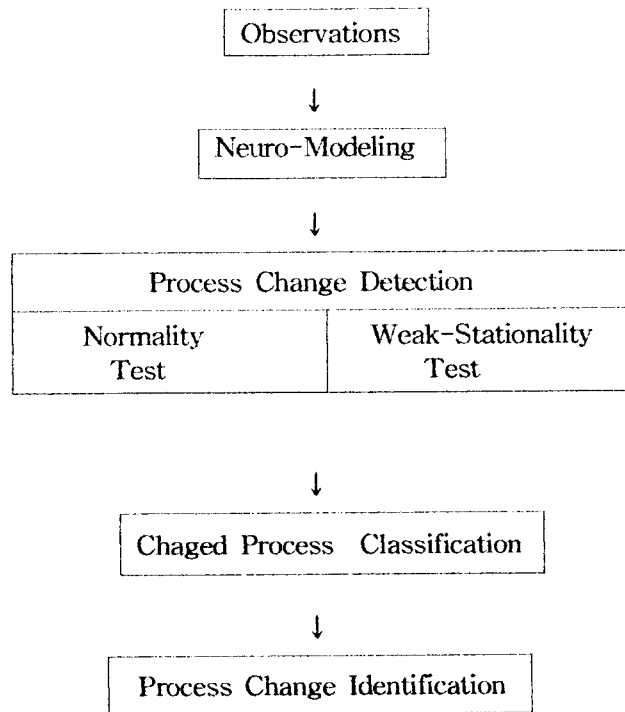


그림 1. 공정의 상태변화 규명을 위한 전체적인 흐름

## 2. 공정의 상태변화 감지

일반화된 뉴럴모형으로 표현되는 공정의 상태변화는 이러한 모형의 관측치들에 대한 연속적인 통계적 검정을 통하여 감지될 수 있다. 뉴럴모형의 실측치에 대한 예측오차(이노베이션 ; innovation)를 감시함으로써 공정의 변동이나 시계열 예측 방정식에 포함되지 않은 설명 불가능한 변수들에 의한 상태변화의 감지가 가능하다.

만약 공정이 안정상태하에 있다면 잔차열(residual series)은 평균이 0에 근접하고 분산이  $\sigma^2$  인 정규분포를 따르는 백색잡음(white noise)이며, 자기상관계수(autocorrelation)는 0이다. 즉, 공정의 안정상태하에서 잔차는 정규분포를 따르고 weak stationarity가 성립 할 것이다. 그러므로 공정의 상태변화 감지는 잔차열에 대한 정규성과 weak stationarity 검정을 통하여 수행될 수 있다. 공정 특성치에 대한 각 시점에서의 관측치를  $y_t$  라 하면, 이들 각각의 샘플링 시점  $t$ 에서의 이노베이션  $e_t$ 들은 다음과 같이 표현될 수 있다.

$$e_t = y_t - \hat{y}_t$$

단,  $y_t$  : t시점에서의 관측치

$\hat{y}_t$  : t시점의 관측치에 대한 예측치

관측치들의 이노베이션들을 이용하여 공정의 상태변화를 감지 할 수 있는데, 이 경우 시점 t에서의 공정 상태변화를 감지하기 위한 통계량은 Ljung-Box 통계량에 의하여 다음과 같이 표현 할 수 있다.

$$Q_t = N(N+2) \sum_{k=1}^m (N-k)^{-1} \gamma_k^2 \quad (1)$$

식 (1)에서  $\gamma_k^2$ 은 시간차(time lag)가 k인 잔차들의 표본 자기상관계수(sample autocorrelation)로서 식(2)와 같이 표현된다.

$$\gamma_k^2 = \frac{\sum_{t=k+1}^N e_t e_{t-k}}{\sum_{t=1}^N e_t^2} \quad (2)$$

단, N : 이동창의 길이(length of moving-window)

그러므로 만약 공정이 안정상태하에 있다면, 위의 통계량  $Q_t$ 는 자유도가 N인 카이제곱 분포 (Chi-square distribution)를 따르게 된다.

즉,

$$Q_t \sim \chi^2(N)$$

이된다.

통계적으로 유의한 거의 모든 공정의 상태 변화는 이노베이션들이 백색잡음 특성으로부터 벗어나는 결과를 가져오므로 위의 카이제곱 통계량을 이용하여 오보(false signal)의 확률인 유의수준  $\alpha$  하에서의 가설검정이 가능하다. 그러므로 위와 같은 연속적인 모니터링에 의하여 공정의 상태 변화감지가 전체 시계열 데이터에 대하여 가능하다.

위의 절차를 단계별로 나타내면 다음과 같다.

- 단계 1. 뉴럴 모형 1 - 모형 n 의 클러스터링(clustering)
- 단계 2. Warm-up data
- 단계 3. 각 뉴럴 모형의 이노베이션 계산

단계 4. 변동감지 통계량 계산

$$Q_t = N(N+2) \sum_{k=1}^m (N-k)^{-1} \gamma_k^2$$

$$\gamma_k^2 = \frac{\sum_{t=k+1}^N e_t e_{t-k}}{\sum_{t=1}^N e_t^2}$$

N : 이동창의 길이

단계 5. 공정변동 감지의 각 시점에서

만약,  $Q_t > \chi_{\alpha}^2(N)$

→ 공정의 상태변화 발생

단,  $\alpha \equiv$  유의수준

공정의 상태 변화의 감지에 대한 개략적인 묘사가 그림 2에 나타나 있다.




그림 2. 공정의 상태 변화 감지를 위한 연속적 검정

3. 베이저안 접근법에 의한 공정의 상태변화 규명

베이저안 접근법은 패턴분류 문제에 있어서 기본적인 통계적 접근법이다. 이는 주어진 문제가 확률적 항목으로서 정의 가능하며, 이에 관련된 확률이 사전에 정의되어짐을 가정할 것이다. 본절에서는 베이저안 패턴인식법을 사용하여 공정의 상태 변화에 대한 규명을 실시하였다.

공정을 묘사하는 뉴럴모형의 이노베이션에 의하여 구성되는 입력 특징벡터(input feature vector) X가 주어진 경우, 평균오차율이 최소화되는 뉴럴모형의 인식(recognition)을 통하여 공정의 상태변화에 대한 규명(identification)을 할 수 있다. 이 절차에서는 베이저안 패턴인식공식(Bayesian pattern recognition formula)에 의하여 공정특성치에 대한 데이터들의 이노베이션과 이에 대한 사전확률(prior probability)이 주어졌을때, 이들이 특정 뉴럴모형에 포함될 사후확률(posterior probability)를 최대화 시킴으로써 평균 오차확률을 최소화하는 뉴럴모형을 규명하였다.

일반적으로 패턴분류기(pattern classifier)를 표현하는 방법에는 여러가지가 있으나 그중 하나가 판별 함수(discriminant function)  $g(X)$ 의 항목으로 표현하는 것이다. 단,  $i = 1, 2, \dots, R$  이 경우 다음의 식 (3)를 만족하면 특징벡터 X가 클래스  $W_i$ 에 assign되었다고 한다.

$$g_i(X) > g_j(X) \text{ for all } i \neq j \quad (3)$$

그러므로 분류기는 R개의 판별함수를 계산하여 이들 중 최대 판별식에 대응되는 범주(category)를 선택하는 역할을 한다.

일반적으로 판별함수 값을 최대화시키는 것은 조건부 위험률을 최소화하는 것이므로 식(4)이 성립한다.

$$g_i(X) = -R(a_i | X) \quad (4)$$

식(4)에서  $R(a_i | X)$ 는  $a_i$  action을 취함으로써 발생하는 기대손실(위험)이다.

즉, 식(5)이 성립한다.

$$R(a_i | X) = \sum_{j=1}^s \lambda(a_i | w_j) \Pr(w_j | X) \quad (5)$$

단,  $\Pr(w_j | X) =$  참 상태(true state)가  $w_j$ 일 확률

특히, 최소 오차률에 의한 패턴분류에 있어 아래의 식(6), (7), (8), (9)은 동일한 의미를 갖게된다. 즉, 동일한 분류법칙(decision rule)에 대해서도 여러가지 판별함수로 표현 가능하다.

$$g_i(X) = \Pr(w_i | X) \quad (6)$$

$$g_i(X) = \frac{\Pr(X | w_i) \Pr(w_i)}{\sum_{j=1}^c \Pr(X | w_j) \Pr(w_j)} \quad (7)$$

$$g_i(X) = \Pr(X | w_i) \Pr(w_i) \quad (8)$$

$$g_i(X) = \log \Pr(X | w_i) + \log \Pr(w_i) \quad (9)$$

### 3.1. 입력 특징벡터의 결정

특징벡터는 고려 중인 뉴럴모형의 특성을 적절하게 묘사해야 한다는 기본 조건에 의하여, 본 절에서는 다음과 같은 13차원의 벡터를 특징벡터로 구성하였다.

$$X = [x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}, x_{11}, x_{12}, x_{13}, x_{14}]$$

$$\text{단, } x_1 = e_T$$

$$x_2 = e_{T-1}$$

$$\begin{aligned}
x_3 &= e_{T-2} \\
x_4 &= e_{T-3} \\
x_5 &= e_{T-4} \\
x_6 &= [ T-5, (T-5)-N+1 ] \text{ 에서의 이노베이션 평균} \\
x_7 &= [ T-5, (T-5)-N+1 ] \text{ 에서의 이노베이션 분산} \\
x_8 &= [ T-10, (T-10)-N+1 ] \text{ 에서의 이노베이션 평균} \\
x_9 &= [ T-10, (T-10)-N+1 ] \text{ 에서의 이노베이션 분산} \\
x_{10} &= [ T-15, (T-15)-N+1 ] \text{ 에서의 이노베이션 평균} \\
x_{11} &= [ T-15, (T-15)-N+1 ] \text{ 에서의 이노베이션 분산} \\
x_{12} &= [ T-20, (T-20)-N+1 ] \text{ 에서의 이노베이션 평균} \\
x_{13} &= [ T-20, (T-20)-N+1 ] \text{ 에서의 이노베이션 분산}
\end{aligned}$$

단,  $e_i$  :  $i$  시점에서의 이노베이션

$T$  : 현 시점 ( $T \geq T_d$ )

$T_d$  : 공정변동의 감지시점

$N$  : 이동창의 폭

### 3.2. 베이시안 접근법에 의한 공정의 상태 변화 규명

입력 특징벡터  $X$ 가 주어진 경우, 평균오차 확률을 최소화하는 뉴럴모형을 선택함으로써 공정의 상태변화 특성을 인식할 수 있다. 공정의 상태 변화 발생시 변동되어진 새로운 모형을  $C_j$  라하고, 뉴럴 모형  $j$ 의 발생확률을 사전에 알고 있는  $\Pr(C_j)$ 라 하자. 단,  $C_j \in \{C_1, C_2, \dots, C_R\}$ . 또한, 관측치들의 이노베이션들로 형성되어진 특징벡터  $X$ 의 조건부 확률을  $\Pr(X|C_j)$ 라하면, 베이즈 법칙에 의한  $C_j$ 의 사후확률은 다음과 같이 표현될 수 있다.

$$\Pr(C_j | X) = \frac{\Pr(X | C_j) \Pr(C_j)}{\sum_{i=1}^R \Pr(X | C_i) \Pr(C_i)} \quad (10)$$

그러므로 위의 사후확률이 최대화되는 뉴럴모형  $C_j$ 를 선택하여 변동 모형에 대한 분류를 하게된다.

위의 (10) 식에서, 분모는 상수항으로 처리 할 수 있으므로 나머지 항에 로그를 취하면,

$$\Pr(C_j | X) \propto \log [ \Pr(X | C_j) ] + \log [ \Pr(C_j) ] \quad (11)$$

로 표현 가능하다.

식(11)에서 관측치들이 정규분포를 따르는 백색잡음으로 이에 대한 QDF(Quadratic Discriminant Function)은 다음과 같다.

$$\Pr(C_j | X) \propto -(X - \mu_j)^T \Sigma_j^{-1} (X - \mu_j) - \log(|\Sigma_j|) + 2 \log(\Pr(C_j)) \quad (12)$$

단,  $\mu_j$  : 뉴럴모형 j의 특징벡터의 평균행렬  
 $\Sigma_j$  : 뉴럴모형 j의 특징벡터의 공분산행렬(covariance matrix)

또한, 식(12)의 항 중  $\log \Pr(C_j)$ 는 클러스터 j의 사전확률이므로 모든 클러스터에 대하여 동일한 값으로 고려하면 식(13)과 같이 표현 할 수 있다.

$$\Pr(C_j | X) \propto -(X - \mu_j)^T \Sigma_j^{-1} (X - \mu_j) - \log(|\Sigma_j|) \quad (13)$$

식 (12)와 (13)을 계산하기 위해서는 각 뉴럴모형 내에서의  $\mu_j$ 와  $\Sigma_j$  가 추정되어야 하는데, 이에 대한 MLE(Maximum Likelihood Estimator)는 다음과 같다.

$$\hat{\mu}_j = \frac{\sum_{i=1}^{M_j} X_{ij}}{M_j}$$

$$\hat{\Sigma}_j = \frac{1}{M_j} \sum_{i=1}^{M_j} (X_{ij} - \bar{X}_j) (X_{ij} - \bar{X}_j)^t$$

단,  $X_{ij}$  : j번째 뉴럴모형의 특징벡터 중 i번째 요소  
 $\bar{X}_j$  : j번째 뉴럴모형의 특징벡터 평균  
 $M_j$  : j번째 뉴럴모형에 고려되어진 특징벡터의 개수

본 연구에서 적용한 베이지안 접근에 의한 공정변동의 규명 절차는 다음과 같다.

단계 1. 현재의 모형을 제외한 나머지 뉴럴모형의  $e_i$  들에 대한 white-noiseness test

$$- E(e_i^t) \doteq 0 \quad \text{for all } i = 1, 2, \dots, n_j$$

단,  $n_j$  : cluster j의 innovation 개수

$e_i^t$  : cluster j의 i번째 data(innovation)



- covariance matrix

$$E(e_i e_j^T) = \begin{cases} \sigma^2 & \text{if } i=j \\ 0 & \text{otherwise} \end{cases}$$

단계 2. 입력 특징벡터의 계산

단계 3. 각 뉴럴모형의 특징벡터 계산

단계 4. 각 뉴럴모형 내의 특징벡터에 대한 평균행렬 및 공분산행렬 계산

단계 5. 각 뉴럴모형의 판별함수 계산

$$g_i(X) = -\frac{1}{2} (X - \mu_i)^t \Sigma_i^{-1} (X - \mu_i) - \frac{1}{2} \log |\Sigma_i|$$

단,  $g_i(X)$  : 뉴럴모형  $i$ 의 판별함수

$X$  : 입력특징벡터 :  $[13 \times 1]$

$\mu_i$  : 뉴럴모형  $i$ 의 특징벡터의 평균행렬 :  $[13 \times 1]$

$\Sigma_i$  : 뉴럴모형  $i$ 의 특징벡터의 공분산행렬 :  $[13 \times 13]$

$|\Sigma|$  : 공분산행렬  $\Sigma$ 의 determinant

$P(C_j)$  : 뉴럴모형  $i$ 의 사전확률

단계 6. 판별함수의 최대화

: 판별함수  $g_i(X)$ 가 최대화 되는 뉴럴모형 선택

#### 4. 최단거리 측정에 의한 공정상태 변화의 규명

벡터공간내에서의 두 벡터간 거리는 유사성의 측정(measure of similarity)에 의한 패턴인식에 널리 이용되어져 왔다. 이 경우 저장된 패턴 중 입력패턴과의 거리가 최소로 되는 패턴이 선택되어진다. 벡터간 거리측정의 방법으로는 유클리디안 거리(Euclidian distance)를 사용하였다.

실측치의 이노베이션들로 구성되는 특징벡터와 주어진 뉴럴모형의 특징벡터간 거리는 다음과 같이 표현된다.

$$D_j = \sqrt{(x_1^j - x_1^o)^2 + (x_2^j - x_2^o)^2 + \dots + (x_i^j - x_i^o)^2 + \dots + (x_M^j - x_M^o)^2}$$

$D_j$  : 뉴럴모형  $j$ 와 입력특징벡터 간의 거리

$x_i^j$  : 뉴럴모형  $j$ 의 대한 특징 벡터 중의  $i$ 번째 요소

$x_i^o$  : 현재 관측치들에 대한 특징 벡터의  $i$ 번째 요소

단,  $j = 1, 2 \dots R$

본절에서는 관측중인 공정 실측치들의 이노베이션으로 구성되는 특징벡터와 주어진 각 모형  $C_j$ 의 특징벡터간 거리를 측정하여, 이들간의 거리가 최소화되는 뉴럴모형을 선택함으로써 공정의 상태 변화의 규명을 하는 방법을 제시한다.

단, 본절에서 사용하는 특징벡터의 구성은 앞절의 베이지안 접근법에서 이용된 특징벡터와 동일한 방식으로 구성되며 이를 위한 절차는 다음과 같다.

단계 1. 현재의 모형을 제외한 나머지 뉴럴모형의  $e_i$  들에 대한 white-noisiness test

$$- E(e_i^j) \approx 0 \quad \text{for all } i = 1, 2, \dots, n_j$$

단,  $n_j$  : cluster j의 innovation 개수

$e_i^j$  : cluster j의 i번째 data(innovation)

- covariance matrix

$$E(e_i, e_j^T) = \sigma^2 \quad \text{if } i=j$$

$$0 \quad \text{otherwise}$$

단계 4. 입력특징벡터의 계산

단계 3. 각 뉴럴모형의 입력벡터 계산

단계 4. 입력 특징벡터와 각 뉴럴모형의 입력벡터 간 거리계산

$$D_j = \sqrt{(x_1^j - x_1^o)^2 + (x_2^j - x_2^o)^2 + \dots + (x_i^j - x_i^o)^2 + \dots + (x_{13}^j - x_{13}^o)^2}$$

$D_j$  : 모형 j 와 입력특징벡터 간의 거리

$x_i^j$  : 뉴럴모형 j의 입력벡터의 i번째 요소

$x_i^o$  : 입력특징벡터의 i번째 요소

$$j = 1, 2 \dots R$$

$$R = 13$$

단계 5.  $D_j$  가 최소로 되는 뉴럴모형 선택

## 5. 뉴럴네트웍에 의한 공정 상태변화의 규명

일반적으로 뉴럴네트웍은 신호처리, 제어, 패턴인식, 음성인식, 비모수 통계기법 등에 적용되어 진다. 뉴럴네트웍은 병렬처리 구조내에서 수많은 연결노드(interconnection node)들로 구성되며, 각 노드의 연결에 할당되는 연결강도(weight)는 사전에 규정된 학습 규칙에 의하여 결정된다. 훈련 중 얻어지는 네트웍의 정보는 노드 상호간의 연결강도에 함축되어 진다. 각 층내에서의 노드들은 연속적인 다른 층의 노

드들과 연결되며, 이러한 연결은 출력층을 향한 단방향(unidirectional) 연결구조를 형성한다. 은닉층의 기능은 정확한 인식이나 분류를 위하여 특징벡터를 서로다른 공간에 사상(mapping)하는데 있다.

이 경우 특징벡터는 뉴럴네트워크의 입력요소(input element)가 되며, 출력(output)은 네트워크의 결과를 구분하고자 하는 몇개의 집단(class)으로 구분지어준다. 뉴럴네트워크의 적용단계는 특징벡터의 선택, 네트워크 구조의 선택, 훈련(training)과 수행(implementation)으로 구성된다. 뉴럴네트워크의 구조와 학습알고리즘에는 여러가지가 있으나 본 절에서는 지도학습(supervised learning) 하에서 백프로퍼게이션 오차법칙(backpropagation error rule)에 의한 전방향(feedforward) 네트워크를 적용시켰다.

네트워크의 은닉층 개수는 하나 또는 두개로 구성되는 것이 일반적인 법칙이며, 두개의 은닉층을 사용하는 경우 네트워크는 복잡한 클러스터(cluster)의 영역도 거의 모두 분류해 낼 수 있게된다. 입력층의 노드 개수는 특징벡터의 크기에 의하여 결정되며, 출력층(output layer)의 노드 개수는 분류하고자 하는 뉴럴모형의 개수와 동일하게 된다. 따라서 본 연구에서는 입력층의 노드 개수를 13개, 출력층의 경우 R개로 설정하였다.

본 절에서 적용한 뉴럴 네트워크에 의한 공정상태 변화의 규명절차는 다음과 같다.

단계 1. 입력층의 노드수 결정 : [1 × 13]

단계 2. 입력층의 결정 : X

단계 3. 은닉층의 수 결정 ≡ 2

단계 4. 출력층의 수 결정 : R

단계 5. 활성화함수(activation function)의 결정

$$f(x) = \frac{1}{1 + \exp(-x)}$$

단계 6.  $I_{jk} = \sum_{i=1}^{n_{k-1}} (W_{ijk} \cdot O_{ik-1}) - T_{jk}$  계산

단,  $I_{jk}$  : k층 i노드의 네트입력(net input)

$W_{ijk}$  : k-1 층의 i 노드와 k 층의 j노드 간의 연결강도

$T_{jk}$  : k층 j노드의 임계값

$n_k$  : k층의 노드 개수

단계 7.  $O_{jk} = f(I_{jk-1})$  계산

단,  $O_{ij}$  : j층 i노드의 출력

단계 8. 백프로퍼게이션에 의한 연결강도 변환

$$\Delta W_{ijk} = -\eta \frac{\partial E}{\partial I_{jk}} O_{ik-1}$$

단,  $\Delta W_{ijk}$  : k-1층의 i 노드와 k 층의 j노드간 연결강도의 변화량

$\eta$  : 학습률(learning rate)

E : 최소화하려는 오차함수

$$\rightarrow \Delta W_{new}(t) = \Delta W(t) + \alpha \Delta W(t-1)$$

단,  $\alpha \equiv 0.7$

## 단계 9. 오차가 주어진 유의 수준이하에 도달할 때까지 반복

### 6. 결론

본 연구에서는 공정으로부터 얻어지는 데이터들을 뉴럴 모형화하여 이들의 이노베이션(innovation)에 대한 연속적인 검정을 통하여 공정의 상태변화를 감지하는 방법을 제시하였다. 또한 새롭게 변화된 공정모형에 대한 규명을 특정 시계열 모형을 가정하지 않은 일반화된 모형들에 대한 분류를 통하여 실시하였다. 공정의 상태변화 감지는 폭이 일정하게 고정된 이동창내에 포함되는 뉴럴모형들의 이노베이션에 대한 연속적인 검정을 통하여 실시하였다. 또한 베이지안 접근법, 최단거리 접근법 및 뉴럴네트웍을 이용하여 변화된 모형에 대한 규명을 실시하였다.

향후 연구과제로는 여러가지 뉴럴네트웍 모형과 알고리즘을 이용하여 공정의 상태 변화의 규명 을 실시할 수 있을 것이며, 반도체 공정에 있어서의 설비 또는 공정에 대한 변화 및 경향을 추적 (tracking)하는 영역으로 적용확대가 가능 할 것이다. 또한, 입력 특징벡터의 구성요소들을 변화시켜 좀 더 높은 수행도를 얻을 수 있을 것으로 기대된다.

### References

- [1] Anderson, T. W., *An Introduction to Multivariate Statistical Analysis.*, 2nd edition, John Wiley & Sons, 1984.
- [2] Anthony J. Hayter and Kwok-Leung Tsui, "Identification and Quantification in Multivariate Quality Control Problems", *Journal of Quality Technology*, Vol.26, No.3, pp.197-208, 1994.
- [3] Bauer, P. and Hackl P., "An Extension of the Mosum Technique for Quality Control", *Technometrics*, Vol.22, No.1, pp.1-7, 1980.
- [4] Berger, J.O., *Statistical Decision Theory and Bayesian Analysis*, 2nd edition, Springer-Verlag, 1985.
- [5] C. Chen and O.G. Okogbaa, "A Conceptual Design of an On-Line Artificial Neural Network for Process Diagnosis", *2nd I.E. Research Conference Proceedings, Univ. of South Florida*.
- [6] G.E.P.Box and G.C.Tiao, "Comparison of Forecast and Actuality", *Applied Statistics*, Vol.25, pp.195-200, 1976.
- [7] G.N. Wang, "An Adaptive Hybrid Neural Network Approach for Learning Nonstationary Manufacturing Processes", Ph. D. Dissertation, Texas A&M Univ., 1993.
- [8] Guoqiang Zhang and Masanobu Taniguchi, "Discriminant Analysis for Stationary Vector Time Series.", *Journal of Time Series Analysis*, Vol.15, No.1, pp.117-126, 1982.
- [9] J.Segan and A.C.Sanderson, "Detecting Change in Time Series", *IEEE Transactions on Information Theory*, Vol.26, pp.249-255, 1980.
- [10] K.J.Dooley and S.G.Kapoor, "An Enhanced Quality Evaluation System for Continuous Manufacturing Processes, Part 1 : Theory", *Journal of Engineering for Industry*,

Vol.112, pp.57-62, 1990.

[11] Ming Chun Chang and David A.Dickey, "Recognizing Overdifferenced Time Series", *Journal of Time Series Analysis*, Vol.15, No.1, pp.1-18, 1994.

[12] Peter de Souza and Peter J.Thomson, "LPC Distance Measures and Statistical Test with Particular Reference to the Likelihood Ratio", *IEEE Transactions on Acoustic, Speech, and Signal Processing*, Vol.ASSP-30, No.2, 1982.

[13] Richard P. Lippmann, "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine*, April, 1987.

[14] R.O. Duda and P.E.Hart, "Pattern Classification and Scene Analysis." , John Wiley & Sons, 1973.

[15] Tep Sastri, Benito Flores and Juan Valdes, "Detecting Points of Change in Time Series.", *Computers Operations Research*, Vol.16, No.3, pp.271-293, 1989.