

# 초기공정에서 공정변화에 대한 신경망을 이용한 관리도 형태 연구† (A study on the control chart pattern for detecting shifts using neural network in start-up process)

이 희춘\*  
(Hee-Choon Lee)

**요약** 이 논문에서는 초기공정에서 개별관측치를 이용하여 공정변화를 지적하는 효율적인 관리도 패턴을 제시한다. 신경망 모델을 적용한 공정관리 기법이 부분적으로 통계적이거나 다른 분석기법보다 우월하지 않을 수도 있지만 학습된 자료관계는 분석적 가정이나 잘못된 모수 때문에 발생하는 오류를 평가할 수 있는 능력이 있으므로 완벽한 공정관리 모델을 추구할 수 있다. 이 논문에서는 BP 알고리즘을 사용하며, 신경망을 이용한 관리도는 작은 공정변화에 특히 예민하다. 공정관리에 영향을 주는 최적의 모수를 구하는 유용한 방법이 신경망을 이용하는 방법을 제시하며 신경망을 이용한 관리도와 X, EWMA 관리도 비교를 위해 평균 런의 길이를 이용한다.

**Abstract** This paper propose the control chart pattern to provide a more comprehensive scheme for detecting process shifts using individual observations in start-up process. In this paper, which uses the backpropagation algorithm, two samples are fed into the trained neural network to provide outputs ranging from 0 to 1. The main advantage of using neural networks approach with a control chart is that the neural network has almost no delay in detecting small shift. This paper illustrates how neural networks can provide a useful method for optimizing parameter(connection weights) that affect process control. Simulation results show that the performance of the proposed control chart using the neural network (NNCC) is quite promising.

## 1. 서론

생산 공정라인에서 공정상태를 조사하여 적절한 조치를 취하는 것은 좋은 품질을 생산하는데 대단히 중요하며, 공정의 이상유무에 대한 판단을 내리며 그 원인을 찾아내는 대표적인 기법으로 관리도가 있다. 관리도의 일반적인 형태는 W. A. Shewhart(1931)에 의해 Shewhart 관리도가 제안되었으며, E. S. Page(1954)는 누적합(cumulative sum : CUSUM) 관리도를 연구하였다. 또한 S. M. Roberts (1959)에 의해 개발된 지수 가중 이동 평균(exponentially

weighted moving average : EWMA) 관리도 등이 있으며 이들 관리도들은 여러 학자들에 의해 연구, 발전되어 왔다. Shewhart 관리도 형태는 제조와 서비스 공정 모두에 품질 개선도구로서 이용되어 왔으며 이상원인을 지적하는 기본적인 법칙은  $3\sigma$  관리한계선 밖에 혹은 안에 통계량이 위치하는 것을 조사하는 것이다. 즉 관리한계선 안쪽으로 통계량이 위치해 있으면 정상상태로, 바깥쪽에 위치해 있으면 공정이 이상상태임을 지적한다. 전통적인 관리도 기법에서 몇 가지 개선이 이루어졌는데 가장 개선이 많이 이루어진 것은 CUSUM 관리도의 도입이었다. CUSUM 관리도는 공정의 작은 변화를 지적하는데 있어 민감도를 향상시켰으나 이용면에서는 shewhart 관리도보다 쉽게 적용하지 못한다는 단점이 있다. 즉 계산의 복잡성과 적용의 어려움

\* 상지대학교 응용통계학과

† 이 논문은 2001학년도 상지대학교 교내연구비 지원에 의한 것임

때문에 실제 사용에 있어 많은 제약이 따른다. EWMA 관리도는 전통적인 Shewhart 관리도의 구조를 개선하여 개발하였으며 공정의 작은 변화와 큰 변화 모두에 관리능력이 향상되었으며 적용면에서도 용이하다.

대량생산체제에서의 공정관리는 공정의 초기시점에서 많은 양의 자료를 수집하여 표준 관리도를 작성한 다음 공정의 이상유무를 판단하였다. 그러나 현재의 생산공정형태는 다품종 소량 단기생산공정으로서 가능한 공정의 초기부터 개별관측치를 이용하여 공정관리를 할 필요가 있으며 제 1종 오류를 작게 해주는 관리도 기법의 필요성이 부각되었다. 즉 공정에 이상이 없는데도 불구하고 공정을 중지시키는 제 1종 오류( $\alpha$ )를 가능한 줄일 필요가 있으며 관측된 자료가 유효 적절하게 공정관리기법에 반영되는 합리적이고 간단하면서도 효율적인 관리도 기법의 개발이 필요하다. 따라서 관측치의 특성이 통계량에 정확하게 반영될 수 있도록 하는 새로운 기법의 연구가 대두되었다.

최근에는 공정관리에 신경망(neural network)을 적용시키는 시도가 몇몇 학자에 의해 연구되어지고 있다. Gue와 Dooley(1992)는 역전파(backpropagation) 학습(training)을 이용하여 양의 평균과 분산변화를 구별하는 신경망 모델을 연구하였다. Puth(1991)는 부그룹 크기 5개를 갖고 공정평균변화를 지적하는 역전파 네트워크를 성공적으로 구성하였으며 제 1종, 제 2종 오류 모두에서  $2\sigma$ 를 고려한  $\bar{X}$  관리도의 평균 런 길이(ARL)의 효율이 비슷하다는 것을 증명하였다. Hwang과 Hubele(1993)는 6개의 비정상적인 관리도를 구별지을 수 있는 역전파 관리도 형태를 연구하였다. Chang과 Aw(1994)는 단측, 양측 평균변화를 지적하기 위해 4계층 역전파 망과 퍼지 인터페이스 시스템을 제안하여 일반적인 shewhart 관리도보다 제 1종, 제 2종 오류 모두에서 성능이 향상되었음을 증명하였다. Smith(1994)는 인공적인 신경망에 의해 해석되고 진단되는 Shewhart  $\bar{X}-R$  관리도를 공식화하였다. Anderson et al.(1990)과 Smith(1993)는 실제 작업라인에서 학습에 의해 진단될 수 있는 신경망을 적용하여 성공적으로 모델화될 수 있음을 제안하였다.

연속적으로 생산된 공정으로부터 다음과 같은 측정자료가 있다고 가정하자.

$$x_t = \mu + \varepsilon_t, \quad t=1, 2, \dots \quad (1)$$

여기에서  $\varepsilon_t$ 는 평균이 0이고 분산이  $\sigma^2$ 인 확률 표본 오차이다. 관측값  $x_t$ 는  $t$  번째 시점에서 얻은 것으로 공정평균이  $\mu$  이고 공정분산이  $\sigma^2$  인 공정분포로부터 선택되어진다고 가정한다.

$$x_1, x_2, \dots, x_{t-1}, x_t, x_{t+1}, \dots$$

이 논문에서는 초기공정에서 개별관측치를 가지고 신경망 개념을 공정관리 기법에 적용하는 신경망을 이용한 관리도(neural network control chart : NNCC) 기법을 제안한다. Chang과 Aw(1994)가 제안한 기법을 참고로 다층 신경회로망을 이용한 공정관리 기법을 참고로 초기공정에서의 변화를 지적하기 위한 관리도 기법을 연구하며 기존의 전통적인  $\bar{X}$ , EWM 관리도와 효율성을 비교한다.


## 2. 공정관리를 위한 신경망 모델 설계

공정으로부터 관측된 값을 이용하여 통계량을 구하고 이들 통계량이 관리도의 관리한계선을 벗어날 경우 공정을 중지하는 공정관리 기법이 기존의 일반적인 방법이다. 물론 사전에 표준 관리도를 만드는데 이때  $3\sigma$  관리한계선을 기본으로 한다.

초기공정에서 개별관측치로부터 얻은 정보를 이용하여 공정진행에 대한 학습을 시켜본 뒤 여기에서 얻은 정보를 바탕으로 생산라인에서 나오는 제품의 이상유무를 판별하거나 예측하도록 하는 기법을 생각할 수 있다. 공정의 이상유무를 판단할 수 있는 공정진단의를 고려할 수 있다. 즉 신경망 함수는 숙련된 공정진단사와 같은 역할을 할 수 있도록 설계한다.

Minsky와 Papert(1969)에 의해 제안된 퍼셉트론 모델과 같이 하나의 조정층(single-adjustable layer)으로 구성되는 모델들의 한계점들 때문에 한 개 이상의 은닉층을 쓰는 새로운 모델이 1980년대 중반에 제안되었다. 즉 신경망을 이용한 공정관리는 두 가지 범주로 나누어 설명되는데 학습은 역전파 알고리즘을 이용하며 검사는 학습된 신경망의 성능을 평가한다. 신경망은 입력층, 은닉층, 출력층으로 구분하여 설계한다. Smith(1994) 등에 의해 2개 이상의 입력노드와 1개의 출력노드를 갖는 학습된 신경망 구조는 정보를 축약시키고 공정을 수행하는데 충분하며, 가능한 은닉층의 노드수를 늘림으로서 신경망 블랙박스의 민감도를 증가시킬 수 있다는 것이 증명되었다.

여기에서는 초기공정에서 개별관측치를 고려하고 완전하게 연결된 은닉층과 1개의 출력값이 나오는 출력층을 고려하며 모든 노드에 연결된 3계층 역전파 망을 설계한다. 즉 입력자료가 2개 있으며 15개의 연결 가중치와 하나의 출력노드가 있는데 이때 출력노드는  $[0, 1]$  사이의 값을 갖도록 한다. 그리고 은닉층의 수를 증가시켰을 때의 효율성을 확인한다.



<그림 1> 신경망 관리도에서의 결정영역

공정으로부터 얻은 자료를 바로 관리한계선을 고려한 관리도에 적용시키는 것이 아니라 학습된 신경망을 통과시켜 본다. 시그모이드 비선형 활성화함수를 적용할 경우 결정영역이 직선이 아닌 완만한 곡선으로 경계지워지므로 행위의 분석이 약간 복잡하지만 미분이 가능하므로 오히려 은닉층을 학습할 수 있는 역전파 학습 알고리즘을 수행시킬 수 있다. 대부분의 다층 퍼셉트론은 역전파 학습 알고리즘을 사용하여 학습할 수 있다. 따라서 전이함수로서 많이 사용하는 시그모이드 함수를 이용하며, 비선형 변환함수는 다음으로 주어진다. 즉 현재 층 노드에서의 출력은 다음 식에 의해 구할 수 있다.

$$f(\text{wet}) = \frac{1}{1 + e^{-\text{wet}}} \quad (2)$$

여기에서  $\text{wet} = \sum_{j=1}^n w_{ji} \cdot x_j$ 이다.  $w_{ji}$ 는  $i$  번째 입력노드에서  $j$  번째 출력노드까지 연결된 연결 가중치이며  $x_j$ 는 입력층  $i$  노드의 출력값을 나타내며  $n$ 은 입력층의 노드 수이다. 출력패턴과 목표패턴을 비교해 가면서 차이를 줄여나가는 방향으로 연결 가중치를 조절하는데 상위층에서 역전파하여 하위 층에서는 이를 근거로 하여 다시 자기층에서의 연결 가중치를 조정해 나가는 기법이다.

일반화 델타규칙(generalized delta rule) 역전파 학습 알고리즘은 최소자승(least mean square) 알고리즘의 비선형적인 확장이다. 연결 가중치는 2개의 개별관측치의 각각의 부분군은 시스템이 만족스러운 평균자승오차(mean squared error)에 수렴할 때까지 반복적으로 새롭게 한다. 제안된 네트워크의 역전파 학습을 위해 다음과 같은 분포를 이용하여 최적 연결 가중치를 구하여 블랙박스를 만든다.

출력층 신경세포들의 오류  $e_j = t_j - x_j$ 와  $\delta$  값  $\delta_j = x_j(1 - x_j)e_j$ 을 구해 은닉층으로 전파한다. 역전파된  $\delta$ 로부터 은닉층 세포들의 오류  $e_j = \sum_k w_{jk} \delta_k$ 와  $\delta$ 를 구해 역전파시킨다. 신경세포  $i, j$  사이에 조절되기

전의 연결 가중치를  $w(\text{old})_{ij}$ 라 할 때 새롭게 조절된 연결가중치  $w(\text{new})_{ij}$ 는 다음 식을 이용하여 구할 수 있다.

$$w(\text{new})_{ij} = w(\text{old})_{ij} + \alpha \delta_j x_i + \beta \Delta w_{ij}(\text{old}) \quad (3)$$

여기에서  $\alpha$ 는 연결 가중치의 조절 량을 결정하는 학습률 ( $0 < \alpha \leq 1$ )이며,  $\beta$  ( $0.7 \leq \beta \leq 0.9$ )는 모멘텀 제어상수이다.  $t_j$ 는 신경세포  $j$ 가 출력층인 경우 해당 목표패턴의 성분값을 나타내며  $x_j$ 는 각각 신경세포  $j$ 의 활성화값을 나타낸다.

역전파 학습을 위해 2개의 그룹에서 각각 100개의 표본을 이용하여 신경망의 블랙박스를 만들 수 있으며 이때 그룹을 구별하기 위한 각각의 분포에 해당하는 목표패턴을 이용한다.

<표 1> 그룹 및 분포에 따른 목표패턴

구분	분포	목표패턴
정상그룹	$N(0,1)$	0
비정상그룹	$N(0+\text{공정변화},1)$	1

결과의 신뢰성을 높이기 위해 10,000번의 반복학습을 하였으며 입력층과 은닉층 그리고 출력층 사이의 연결 가중치를 각각 구하였다. 1개의 은닉층을 고려할 때 은닉층에 5개의 노드를 두며 이때 학습오류는 0.0334이었다. 은닉층의 개수를 늘릴 때와의 비교를 위해 2개의 은닉층을 두며, 첫 번째 은닉층의 노드수는 5개, 두 번째 은닉층의 노드수는 4개로 하며 이때 학습오류는 0.0083이었다. 학습율은 70%로 모멘텀 제어계수는 0.9로 하였다.

### 3. 개별관측치를 이용한 신경망 관리도 적용

적당한 제조공정으로부터 관측치를 얻기 위한 방법으로 모의실험을 이용하며, 여기에서 생성된 확률수를 이용한다. 이 논문에서는 IMSL의 ggnml을 이용하여 평균이 0이고 표준편차가 1인 정규분포로부터 만들어 낸 확률수를 활용하며, 제조공정에서 얻은 관측치로 대체하여 이용한다. 이때 ramberg와 schmisser 방법, 즉 초기공정으로부터 2개의 표본을 택하며 여러 가지 표준편차에서 측정할 수 없는 우연요인에 따른 변화는 무시한다. <그림1>과 같은 결정영역을 고려한다.



<그림 2> 신경망 관리도에서의 결정영역

공정관리를 위한 신경망 블랙박스를 만들어 초기 공정변화의 이상유무를 판단하는데 다음의 알고리즘을 참고한다.

1 단계 : 2개 그룹에서 각각의 분포와 해당 목표패턴을 이용하여 신경망의 블랙박스를 만든다. 이때 역전파 학습 알고리즘을 이용한다. 여기에서 1개의 은닉층 안에 5개의 노드를 두므로 입력층에서 은닉층까지의 10개, 은닉층에서 출력층까지 5개의 연결 가중치를 구하여 신경망 블랙박스를 만든다.

2 단계 : 블랙박스에 2개의 입력노드를 이용하여 공정의 자료를 입력시킨다.

3 단계 : 출력노드로부터 빠져 나온 자료를 이용하여 공정관리를 진행한다. 출력노드에서 나온 자료가 0이면 정상상태이고 1이면 비정상상태로 판단한다. 3·오차한계를 고려할 때 [그림2]을 참고로 출력노드에서 나온 결과 값이 [0.06, 0.18], [0.82, 0.94]에 위치하면 관측치를 재조사하여 이상유무를 다시 한번 점검해 볼 필요가 있다고 판단한다. 즉 요주의 공정영역을 돕으로서 제 1종 오류를 줄일 수 있다

4 단계 : 2 단계로 간다.

공정에서의 변화를 임의로 [0, 3.0]0.25로 변화시켜 가면서 공정의 이상원인을 지적하는 시기를 조사한다. 2σ 관리한계선을 고려한 상태에서 잘못된 신호로 인한 공정중지의 경우를 보기 위해 제 1종 오류(α)를 확인할 필요가 있다.

$$\alpha = \Pr(x \leq (\mu_0 - k\sigma) \text{ 혹은 } x \geq (\mu_0 + k\sigma))$$

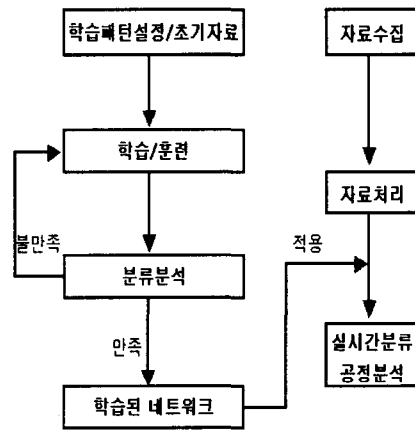
$$= 2 \int_k^{\infty} \phi(x) dx \quad (4)$$

여기에서 σ는 공정이 정상상태일 때의 표준편차이며 k는 공정평균에서 변화를 표시한다. μ<sub>0</sub>는 공정이 정상상태일 때의 평균을 나타낸다. φ는 표준 정규밀도함수를 나타낸다.

<그림 3>은 제안된 학습된 신경망을 공정분석에 적용할 수 있는 루틴이다. 초기연결가중치를 구하기 위해 BP 학습을 반복하여 블랙박스를 만든다. 그리고 개별관측치를 이용한 실시간 공정분석에 적용한다.

신경망 모델을 적용한 공정관리 기법이 부분적으로 통계적이거나 다른 분석기법보다 우월하지 않을 수도 있지만 학습된 자료관계는 분석적 가정이나 잘못된 모수 때문에 발생하는 오류를 평가할 수 있는 능력이 있으므로 완벽한 공정관리 모델을 추구할 수 있다.

또한 학습은 다수의 관련되거나 관련되지 않는 입출력 자료를 동시에 관리할 수 있으며 연속적 혹은 산발적인 재학습에 의해 공정변화의 조건을 동적으로 수정할 수 있다. 또한 비용에 영향을 받는 실시간 공정관리에 곧바로 적용될 수 있으므로 초기 공정관리에 적합할 수 있다.



<그림 3> 신경망 관리도 적용기법

#### 4. 결과 및 향후연구과제

X, EWM 관리도와 신경망을 이용한 관리도를 비교할 때 평균 런 길이를 이용한다. 평균 런 길이는 공정이 이상상태라고 판단할 때까지의 관리한계선 안에 표시된 통계량의 수의 평균을 말한다. 여기에서는 정규분포로부터 각각의 공정변화에 대한 변화를 알아보며 결과의 신뢰성을 위해 10,000번의 모의실험을 하였다. 다음의 표는 2σ 관리한계선을 고려할 때의 X, NN, EWM 관리도의 평균 런의 길이를 나타낸 것이다. 표에서 은닉층의 개수가 2개와 3개일 때를 조사하였으며 지수가중 이동관리도의 가중치가 0.15, 0.20, 0.25일 때 각각 계산되었다.

은닉층의 개수를 증가시키는 것이 효율을 크게 향상시킬 수 없음을 확인할 수 있었다. 공정의 작은 변화에서 표준 X 관리도보다 NN 관리도가 민감하다는 것을 알 수 있다.

공정변화가 매우 작을 때는 EWM 관리도와 효율성이 비슷하며 변화가 어느 정도 클 경우에는 오히려 EWM 관리도가 우수함을 알 수 있다. 신경망을 이용한 관리도 기법은 초기공정에서 매우 작은 변화에 효과적임을 알 수 있으며 학습방법을 조절하여 공정변화의 형태 및 크기를 확인할 수 있다. 또한 NN 관리도에서 요주의 공정영역을 들으므로 실제적 공정관리에서 심리적인 효과를 줄 수 있다.

<표 2> X, NN, EWM 관리도의 평균 런의 길이 비교

공정 변화	X	NNCC		EWM		
		1	2	$\lambda=0.15$	$\lambda=0.20$	$\lambda=0.25$
0.00	255.39	251.74	259.95	256.65	257.69	258.40
0.25	249.27	187.13	188.07	205.74	216.95	224.96
0.50	223.64	125.04	127.00	75.29	99.57	120.47
0.75	183.91	68.52	65.82	12.04	24.57	39.05
1.00	137.27	5.06	4.33	1.78	3.01	7.16
1.50	60.24	1.26	1.00	1.00	1.01	1.05
2.00	17.65	1.00	1.00	1.00	1.00	1.00
2.50	3.54	1.00	1.00	1.00	1.00	1.00
3.00	1.00	1.00	1.00	1.00	1.00	1.00

초기공정에서 개별관측치를 이용한 통계량 X와 범위(R)를 이용한 NNCC에 대해서는 좀 더 깊은 연구가 진행되어야 한다.

### 참 고 문 헌

[1] Andersen K., Oook G.E., Karsai G. and Parmaswamy K., "Artificial neural networks applied to arc welding process modeling and control", IEEE Transaction on Industry Application, Vol, 26, pp 824-830, 1990.  
 [2] Champ C. and Woodall W., "Exact results for shewhart control charts with supplementary run rules", Technometrics, Vol. 29, No 4, pp. 393-399, 1987.  
 [3] Chang S.I. and Aw C.A., "A process mean control chart using neural networks", Proceeding of the 3rd Industrial Engineering Research Conference, May 18-19, Atlanta, Georgia, pp. 337-442. 1994.  
 [4] David E. R and James L. McClelland and

PDP research Group, Parallel Distributed Precessing, Vol 1, The MIT precess, London, 1986.

[5] Hwang H.B. and Hubele N.F., "  $\bar{X}$  control chart pattern recognition using neural nets", 45th Annual Quality Congress, Milwaukee, pp. 884-889, 1991.

[6] Hwang H.B. and Hubele N.F., "  $\bar{X}$  control chart pattern identification through efficient off-line neural network traing", IEE Transactions, Vol 25, No 3, pp. 27-40, 1993a.

[7] IMSL, inc, "IMSL user's math/stat manual", 1989

[8] Nelson L.S., "The shewhart control chart-tests for special causes", J.Q.T, Vol 16, No 4, pp. 237-239, 1984.

[9] Pugh G. Allen, "synthetic neural networks for process control", computer and engineering, Vol 17, No 14, pp. 24-26, 1989.

[10] Pugh G. Alle, "A comparison of neural networks to SPC chart", computer and engineering. Vol 21, No 14, pp. 253-255, 1991.

[11] Smith A.E., "  $\bar{X}$ -R control chart interpretation using neural computing", Internatinal Journal of Production Research, 32(2), pp 309-320.

[12] Teresia R., "The Back-Propagation Algorithm", <http://hydra.ikp.liu.se>, 2000.

[13] Yuan Gue and Kevin J. Dooley, "Identification of change structure in statistical process control", Int. Journal proceeding research, Vol 30, No 7, pp. 1655-1669. 1992.

[14] 김대수, neural networks - theory and applications(I), 하이테크정보, 1992.

[15] 임영도, 이상부, 퍼지, 신경망, 유전진화, 도서출판 영과일, 1996.



이 희 춘 (Lee Hee Choon)

1974년 2월 강원대학교 수학교육과 졸업(이학사)

1981년 2월 경희대학교 교육대학원 수학교육전공(교육학석사)

1983년 2월 경희대학교 대학원 수학과 수리통계전공졸업 (이학석사)

1987년 8월 경희대학교 대학원 수학과 수리통계전공졸업  
(이학박사)

1989년 3월~1991 9월 동신대학교 통계학과 조교수

1991년 9월~현재 상지대학교 자연과학군 응용통계학과  
부교수

관심분야 : 응용통계분야, 전산통계분야