

▣ 연구논문

초기공정에서 X-R 통계량을 이용한 신경망 관리도 설계

The Design of a neural network control chart using X-R statistics in start-up process

지 선 수¹⁾
Ji, Sun Su

Abstract

I propose the control chart pattern to provide a more comprehensive scheme for detecting process X and R shifts using individual observations in start-up process. It is important to automate the identification of special disturbances to facilitate real-time manufacturing. This papers formulates X-R charts for interpretation by artificial neural networks. In this papers, which uses the backpropagation algorithm, two samples are fed into the trained neural network to provide outputs ranging from 0 to 1. Simulation results show that the performance of the proposed control chart using the neural network(NNCC) is quite promising. Using these NN charts, guidelines are given for detecting and classifying process X and R shifts.

1. 서론

대량 생산체제에서의 공정관리는 많은 양의 자료를 수집하여 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 오류를 범하게 할 확률(α)을 가능한 줄일 필요가 있으며 관측된 자료가 유효 적절하게 공정관리기법에 반영되는 합리적이고 간단하면서도 효율적인 관리도 기법의 개발이 필요하다. 따라서 관측값의 특성이 통계량에 정확하게 반영될 수 있도록 하는 새로운 기법의 연구가 대두되었다. 제조업자는 생산된 제품의 품질을 보증하기 위해 공정에서 특별한 공정변화를 자동으로 구별할 수 있는 품질 관리 시스템을 필요로 하게 되었다. 최근까지 제조공정을 관리하기 위해 통계적 개념을 이용한 개선된 SPC 공정관리 적용기법에 대한 연구가 진행되어 왔다. SPC 관리기법은 관리한계선 밖에 점들이 위치하면 공정을 중지하고 조사하는 정보만을 제공한다.

실시간 제조공정에서 특별한 변화를 신속하게 인지하는 기법, 즉 공정관리에 신경망(neural

1) 원주대학/교수

network)을 적용시키는 시도가 몇몇 학자에 의해 연구되어지고 있다. Gue와 Dooley(1992)는 역전파(backpropagation) 학습을 이용하여 양의 평균과 분산변화를 구별하는 신경망 모델을 연구하였다. Puth(1991)는 부 그룹 크기 5개를 갖고 공정 평균변화를 지적하는 역전파 네트워크를 성공적으로 구성하였으며 제 1종, 제 2종 오류 모두에서 2σ 를 고려한 \bar{X} 관리도의 평균 런 길이(ARL)의 효율이 비슷하다는 것을 증명하였다. Hwang와 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 인터페이싱 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. Chang과 Aw(1996)는 공정의 평균변화를 구별하기 위해 신경망 퍼지 관리도를 제안하여 불확실 수준에 따라 정상·이상상태 평균 런의 길이(ARL) 모두에 관해서 기존의 \bar{X} 관리도보다 향상되었음을 증명하였다.

이 논문에서는 연속적으로 생산된 공정으로부터 다음과 같은 측정자료가 있다고 가정한다.

$$x_t = \mu + \epsilon_t, \quad t=1, 2 \dots$$

여기에서 ϵ_t 는 평균이 0이고 분산이 σ^2 인 확률 표본오차이다. 관측값 x_t 는 t 번째 시점에서 얻은 것으로 공정평균이 μ 이고 공정분산이 σ^2 인 공정분포로부터 선택되어진다고 가정한다.

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

초기공정에서 개별관측치를 이용하여 관리도 설계를 할 때 입력자료가 가지고 있는 공정변화 정보를 바탕으로 공정의 위치(X)와 크기(R) 변화를 자동적으로 감지하는 것이 중요하다. 이 논문에서는 초기공정에서 개별관측치를 이용한 X-R 통계량을 가지고 신경망 개념을 공정관리 기법에 적용하는 신경망 관리도(neural network control chart: NNCC) 기법을 제안한다. 또한 공정변화의 크기와 형태를 구별할 수 있는 능력 있는 시스템을 만들기 위해 다층 신경회로망을 이용한 공정관리 기법을 연구하며 기존의 전통적인 X-R 관리도와 효율성을 비교한다.

2. 전통적인 X-R 관리도 설계

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

대부분의 생산공정의 초기공정에서 미세한 공정변화를 가능한 빨리 감지하여 생산라인을 멈추고 이상원인을 제거하는 조치를 취해야한다. 즉 초기공정에서 작은 변화에 민감하고 정보손실이 적은 통계량을 이용하여 공정을 조사하고 관리하는 것이 중요하다. 개별관측치를 이용한 관리도 연구는 Nelson(1982)에 의해 시작된 이후로 Crowder(1987)와 Roes et al.(1993) 등에 의해 연구, 발전되어 왔다. Adke and Hong(1997)은 개별관측치를 이용하여 X, MR 관리도를 평가할 수 있는 검사기법을 제안하였다.

초기 공정에서 개별관측치를 관리해야하는 상황에서 X-R 관리도는 용도상의 제약은 다르지만 어떤 관리도보다 효과적인 공정분석 도구로서 활용될 수 있다. 일반적으로 X-R 관리도는 공정의 확일성과 안정성을 확인하기 위해 R 관리도를 먼저 적용하여 공정편차가 안정된 상태에서 X 관리도를 적용한다.

공정평균이 μ 이고 공정표준편차가 σ 인 공정분포로부터 t 번째 시점에서 택해진 표본을 x_t 이라 하자. 시점 t 에서 관심 있는 관리통계량 $W_t(x_t, r_t)$ 를 계산할 수 있으며 통계량 W_t 는 일

반적으로 모수 값이 커지면 커지는 경향이, 작아지면 작아지는 경향이 있다고 가정한다. 여기에서 $r_t = |x_t - x_{t-1}|$, $t \geq 2$ 이며 근사적인 $k\sigma$ 관리한계는 $E(W_t) \pm k \cdot SD(W_t)$ 로 계산하여 관리도를 설계할 수 있다. 개별관측치 위치와 이동범위의 평균과 분산은 다음과 같이 각각 계산할 수 있다.

$$\begin{aligned} E(x_t) &= \mu_X, \quad \text{Var}(x_t) = \sigma_X^2 \\ E(r_t) &= 0, \quad \text{Var}(r_t) = \sigma_R^2 \end{aligned} \tag{1}$$

첫 번째 단계로서 R 관리도를 적용하기 위한 관리한계선은 다음과 같이 구할 수 있다.

$$UCL_R = \mu_R + k \sigma_R \tag{2}$$

여기에서 k 는 임의의 상수이며 μ_R 과 σ_R 은 공정이 통계적으로 안정된 상태에서 구한 관리값이다. 일반적으로 R 관리도에서의 관리하한은 0으로 하여 공정관리를 수행한다. 관리통계량이 관리한계선을 벗어나면 공정을 중지하고 이상요인을 찾아서 제거하는 후속조치를 취한다.

두 번째 단계로서 R 관리도를 적용한 결과 공정이 안정상태인 경우에 X 관리도를 적용할 수 있으며 관리한계선은 다음과 같이 구할 수 있다.

$$\begin{aligned} UCL_X &= \mu_X + k \sigma_X \\ LCL_X &= \mu_X - k \sigma_X \end{aligned} \tag{3}$$

μ_X 와 σ_X 는 공정이 통계적으로 안정된 상태에서 계산된 관리값이다. 3σ 관리한계선을 고려한 상태에서 잘못된 신호로 인한 공정중지의 경우를 보기 위해 제 1종 오류를 범하게 할 확률(α)을 확인할 필요가 있다.

$$\begin{aligned} \alpha &= \Pr(r_t > \mu_R + 3 \sigma_R) + \\ &\Pr(x_t \leq (\mu_X - 3 \sigma_X) \text{ 혹은 } x_t \geq (\mu_X + 3 \sigma_X) | r_t \leq \mu_R + 3 \sigma_R) \end{aligned} \tag{4}$$

전통적인 X, X-R 관리도를 적용했을 경우 공정변화에 따른 제 1종 오류를 범하게 할 확률은 [표 1]과 같다.

[표 1] 전통적인 X, X-R 관리도에서 공정변화에 따른 제 1종 오류를 범하게 할 확률


공정변화	X	X-R[Roes et al(1993)]
0.00	0.0020	0.00058
0.50	0.0050	0.00098
1.00	0.0183	0.00228
1.50	0.0559	0.00467
2.00	0.1378	0.00811

3. X-R 통계량을 이용한 신경망 관리도 설계

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 공정진단과의 같은 역할을 할 수 있도록 설계한다.

Minsky와 Papert(1969)에 의해 제안된 퍼셉트론 모델을 개선하여 한 개 이상의 은닉층을 쓰는 새로운 모델이 1980년대 중반에 제안되었다. 일반적으로 신경망을 이용한 공정관리는 두 가지 범주로 나누어 설명되는데 학습은 역전파 알고리즘을 이용하며 검사는 학습된 신경망의 성능을 평가한다.

여기에서는 초기공정에서 개별관측치를 고려하고 완전하게 연결된 은닉층과 1개의 출력값이 나오는 출력층을 고려하며 모든 노드에 연결된 3계층 역전파 망을 설계한다. 즉 입력자료가 2개 있으며 18개의 연결 가중치와 하나의 출력노드가 있는데 이때 출력노드는 [0, 1] 사이의 값을 갖도록 한다. 그리고 은닉층의 수를 증가 시켰을 때 효율성을 확인한다.



[그림 1] 3계층 신경망 모델 구조

공정으로부터 얻은 자료를 바로 관리한계선을 고려한 관리도에 적용시키는 것이 아니라 학습된 신경망을 통과시켜 본다. 대부분의 다층 퍼셉트론은 역전파 학습 알고리즘을 사용하여 학습할 수 있으며 전이함수로서 많이 사용하는 시그모이드 함수를 이용하며, 비선형 변환함수는 Scalettar와 Zee(1988)에 의해 제안된 squashing 함수를 이용한다. 즉 현재층 노드에서의 출력은 다음 식에 의해 구할 수 있다.

$$y(wet) = \frac{1}{1 + e^{-wet}} \tag{5}$$

여기에서 $wet = \sum_{j=1}^n w_{ji} \cdot x_j$ 이다. w_{ji} 는 i 번째 입력노드에서 j 번째 출력노드까지 연결된 연결 가중치이며 x_j 는 입력층 j 노드의 출력값을 나타내며 n 은 입력층의 노드 수이다.

출력패턴과 목표패턴을 비교해 가면서 차이를 줄여나가는 방향으로 연결 가중치를 조절하는데 상위층에서 역전파하며, 하위층에서는 이를 근거로 하여 다시 자기층에서의 연결 가중치를 조정해 나가는 기법이다.


출력층 신경세포들의 오류 $e_j = t_j - x_j$ 와 δ 값 $\delta_j = x_j(1 - x_j)e_j$ 을 구하여 은닉층으로 전파한다. 역전파된 δ 로부터 은닉층 세포들의 오류 $e_j = \sum_k w_{jk} \delta_k$ 와 δ 를 구하여 역전파시킨다. 신경세포 i, j 사이에 조절되기 전의 연결 가중치를 $w_{ij}(old)$ 라 할 때 새롭게 조절된 연결가중치

$w(\text{new})_{ij}$ 는 다음과 같이 쓸 수 있다[16].

$$w(\text{new})_{ij} = w(\text{old})_{ij} + \alpha \delta_j x_j + \beta \Delta w_{ij}(\text{old}) \tag{6}$$

여기에서 α 는 연결 가중치의 조절 량을 결정하는 학습률 ($0 < \alpha \leq 1$)이며 β ($0.7 \leq \beta \leq 0.9$)는 모멘텀 제어상수이다. t_j 는 신경세포 j 가 출력층인 경우 해당 목적 패턴의 성분값을 나타내며 x_i , x_j 는 각각 신경세포 i, j 의 활성화값을 나타낸다[16].

연결 가중치는 2개의 개별관측치의 각각의 부분군은 시스템이 만족스러운 평균자승오차에 수렴할 때까지 반복적 학습에 의해 새롭게 한다. 제안된 네트워크의 역전과 학습을 위해 임의의 모집단으로부터 같은 조건으로 선택된 다음과 같은 자료를 이용하여 최적 연결 가중치를 구하여 블랙박스를 만든다.



역전과 학습을 위해 4개의 그룹을 참조하며 400개의 표본을 이용하여 신경망의 블랙박스를 만들 수 있으며, 이때 그룹을 구별하기 위한 각각의 분포에 해당하는 목표패턴을 이용한다.


그룹	형태	목표패턴
A(㉿)	정상상태	0.00
B(⊖)	이상상태(X shift)	0.33
C(⊕)	이상상태(R shift)	0.66
D(⊗)	이상상태(X and R shifts)	0.99

결과의 신뢰성을 높이기 위해 10,000번의 반복학습을 하였으며 입력층과 은닉층 그리고 출력층 사이의 연결 가중치를 각각 계산하였다. 1개의 은닉층에 6개의 노드를 가지고 학습시킨 결과 학습오류는 0.06261이었다. 여기에서는 학습율은 70%로 하였으며 모멘텀 제어계수는 0.85로 하였다.

4. 개별관측치를 이용한 신경망 관리도 적용

경험적인 모델과 확률분포를 가정하는 것보다 좋은 자료를 이용한 관계를 학습하는 것이 중요

하다. 이 논문에서는 적당한 제조공정으로부터 관측치를 얻기 위한 방법으로 모의실험을 이용하며, 여기에서 생성된 확률수를 이용한다. IMSL의 ggubs를 이용하여 평균이 0이고 표준편차가 1인 분포로부터 만들어 낸 확률수를 활용하며, 제조공정에서 얻은 관측치로 대체하여 이용한다. [그림 2]와 같은 결정영역을 고려한다.



[그림 2] 신경망 관리도에서의 결정영역

초기공정으로부터 2개의 표본을 택하며 여러 가지 편차에서 측정할 수 없는 우연요인에 따른 변화는 무시한다. 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 학습알고리즘을 이용한다. 여기에서 1개의 은닉층 안에 6개의 노드를 두고 층 사이의 연결 가중치를 구하여 신경망 블랙박스를 만든다.
- 2 단계 : 블랙박스에 2개의 입력노드를 이용하여 공정의 자료를 입력시킨다.
- 3 단계 : 출력노드로부터 빠져 나온 자료를 이용하여 공정관리를 진행한다. 출력 결과값이 [0.00, 0.11]이면 정상상태로 판정한다. [0.22, 0.44]이면 X의 변화, [0.55, 0.77]이면 R의 변화, [0.88, 1.00]이면 X, R의 변화가 있는 이상상태로 판정한다. 출력노드에서 나온 결과값이 요주의 공정영역에 위치하면 관측치를 재조사하여 이상유무를 다시 한번 점검해 볼 필요가 있다고 판단함으로써 제 1종 오류를 줄일 수 있다
- 4 단계 : 2 단계로 간다.

일반적인 X와 X-R 관리도와의 효율을 비교하기 위해 평균 런의 길이를 이용한다. [표 2]는 각각의 공정변화에 대해 X, X-R, NN 관리도의 평균 런의 길이를 구한 표이다.

[표 2] 각각의 공정변화에 대해 X, X-R, NN 관리도의 ARL 변화

공정변화	X	X-R	NN
0.00	499.376	494.496	457.832
0.50	386.926	320.618	387.154
1.00	262.300	208.940	0.002
1.50	136.344	92.604	0.002
2.00	11.968	6.546	0.002
2.50	0.002	0.002	0.002
3.00	0.002	0.002	0.002

개별관측치를 가지고 초기의 공정관리를 할 때 X와 X-R 관리도보다 신경망을 이용하는 관리

도가 효율적임을 확인할 수 있다. 특히 공정변화가 0.75σ 이상이면 이상원인을 완벽하게 감지할 수 있음을 알 수 있다.

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.

5. 결과 및 향후연구과제

신경망을 이용하여 공정을 관리할 경우 공정의 이상유무와 변화의 형태를 구별지을 수 있다. 따라서 NNCC는 제조공정에서의 진단문제를 해결하기 위한 적절한 기법이며 요주의 공정영역을 돕으로서 공정관리의 심리적 효과를 얻을 수 있다. 평균이 0이고 분산이 1인 분포로부터 각각의 공정변화에 대한 공정변화의 형태를 알아본다. 결과의 신뢰성을 위해 10,000번의 모의실험을 하였다.

[표 3] NNCC에서 각각의 공정변화에 대한 공정변화의 형태

공정변화	A그룹	B그룹	C그룹	D그룹
0.00	497.8320	2.1720		
0.25	444.2140	55.7900		
0.50	387.2060	112.8000	0.0020	
0.75	0.0020	497.7980	2.2060	0.0020
1.00		0.0020	132.4140	367.5900
1.25			0.0020	500.0020
1.50				500.0020
2.00				500.0020

입력자료가 가지고 있는 공정변화 정보를 바탕으로 0.25σ 의 공정변화가 발생했을 경우 위치(X)가 변경되었음을 감지하는 감지율이 11.2%, 0.75σ 의 변화가 발생했을 경우 위치를 감지할 감지율이 99.56%, 범위(R)가 변경되었을 감지할 인지율이 4.4%임을 확인할 수 있다. 신경망을 이용한 관리도 기법은 초기공정에서 공정 변화의 형태를 확인하는데 효과적임을 알 수 있다. Off-line에 의해 학습된 블랙박스를 이용하여 공정에서의 실시간으로 공정변화 형태를 분류할 수 있다.

참고문헌

- [1] Adke S. R. and Hong X.. "A Supplementary Test Based on the control chart for Individuals", J.Q.T. Vol 29, No 1. pp. 16-20, 1997.
- [2] Allen Pugh G., "A comparison of neural networks to SPC chart", computer and

- engineering, Vol. 21, No. 14, pp. 253-255, 1991.
- [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] Hopner J. and Wolff H., "The Design of a Fuzzy-Shewhart Control Chart", Research Report 52 of University Ulm, 1995.
- [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 training", IEE Transactions, Vol 25, No 3, pp. 27-40, 1993a.
- [7] IMSL, inc, "IMSL user's math/stat manual", 1989.
- [8] Ji Seonsu, "A study on the control chart pattern for detecting shifts using neural network in start-up process", submitted for publication, 2000.
- [9] Nelson L. S., "Control chart for Individual Measurements", J.Q.T, Vol 14, pp. 172-173, 1982.
- [10] Pugh G. Alle , "A comparison of neural networks to SPC chart", computer and engineering. Vol 21, No 14, pp. 253-255, 1991.
- [11] Saniga, E. M. "Economic Statistical Control Chart Design with an Application to \bar{X} and R Charts", Technometrics, Vol. 31, No 3, pp. 313-321, 1989.
- [12] Smith A.E.. " \bar{X} -R control chart interpretation using neural computing", International Journal of Production Research, 32(2), pp 309-320.
- [13] Teresia R., "The Back-Propagation Algorithm", <http://hydra.ikp.liu.se>, 2000.
- [14] Rose Kit C. B. and Does Ronald J. M. M and Schurink Yvonne, "Shewhart-type control charts for individual observations", Journal of Quality Technology, Vol 25, No 3, pp. 188-198, 1993.
- [15] 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.
- [16] 김대수, neural networks - theory and applications(I), 하이테크정보, 1992.