

공정개선을 위한 인공신경망의 실험적 적용에 관한 연구

한 우 철*

A Study on the Experimental Application of the Artificial Neural Network for the Process Improvement

Woo-Chul Han*

요 약

본 연구에서는 자동화된 데이터의 수집과 자동화된 제조회장에서 수행될 수 있는 공정관리도의 패턴 양상에 대하여 인공지능의 대표적인 기법인 인공신경망을 이용하여 각 패턴의 인식과 이의 검증, 그리고 이상패턴의 발생상황을 모니터링할 수 있는 지능형 공정관리 시스템을 개발하는데 중점을 두었다.

개발된 패턴인식시스템을 이용하여 공정의 상태를 관리하는 작업자의 부담을 한층 덜어줄 수 있으며, 작업자는 공정에 이상패턴이 발생하는 경우에 패턴인식시스템을 통하여 공정상태에 대한 정보를 전달받을 수 있어서 지속적인 품질개선활동을 수행할 수 있게 된다.

Abstract

In this paper a control chart pattern recognition methodology based on the back propagation algorithm and Multi layer perceptron, a neural computing theory, is presented. This pattern recognition algorithm, suitable for real time statistical process control, evaluates observations routinely collected for control charting to determine whether a pattern, such as a cycle, trend or shift, which is exists in the data. This approach is promising because of its flexible training and high speed computation with low-end workstation. The artificial neural network methodology is developed utilizing the delta learning rule, sigmoid activation function with two hidden layers.

In a computer integrated manufacturing environment, the operator need not routinely monitor the control chart but, rather, can be alerted to patterns by a computer signal generated by the proposed system.

* 대림대학 산업시스템경영과 교수

I. 서론

최근 기업경영환경의 변화, 제조공정의 복잡화, 불확실성의 증가 등으로 오늘날의 공정관리는 정확성(Accuracy)과 신속성(Speediness)을 생명으로 하고 있으나, 이에 반해 공정관리 전문가는 부족한 상태이며, 이러한 환경에서 방대한 규모의 데이터에 대한 효율적인 수집·저장·분석 및 관리 등을 요구하고 있는 상황이어서 SPC의 전산화는 필수적인 요건이 되어가고 있다.

이러한 시점에서 컴퓨터과학의 한 분야로서 각광받고 있는 인공지능(Artificial Intelligence) 기법을 이용하여 인간과 유사한 판단수준으로 수행가능한 공정관리 시스템을 개발하여 공정관리 전문가를 대체할 수 있는 가능성이 예상되었으며, 이로써 요구되는 공정관리수준을 달성하고, 기업은 소비자의 요구에 부응할 수 있는 적합품질의 제품생산에 한 걸음 나아 갈 수 있게 되었다.

특히 최근 컴퓨터시스템의 급속한 발전과 더불어 적용영역이 확산된 인공신경망(ANN : Artificial Neural Network) 기법은 품질관리 전문가의 부족을 해결하고, 품질관리 기술자 혹은 공정관리자를 위한 부문에 인공신경망 기법을 적용함으로써 관리도(Control Chart)의 작성 및 분석, 이상원인의 탐지 및 분석, 공정의 이상탐지 자동화에 이용되고 있다.

이와 같이 신경망이 품질관리분야에서 활용되는 이유는 첫째, 많은 양의 데이터뿐만 아니라 잡음(Noise)이 많은 불확실한 자료도 실시간으로 병렬처리(Parallel Processing)가 가능하기 때문에 인과관계의 함수식에 있어 모수가 복잡한 비선형공정과 다중상관관계에 대하여도 학습할 수 있어서 지능적인 품질관리를 위한 소프트웨어 시스템의 구축이 가능하다는 것이다.

둘째, 함수의 추정 및 예측은 기존의 통계학이나 인공지능분야에서도 이미 연구된 기능이기 는 하나, 인공신경망은 뛰어난 패턴인식능력 및 대상인 자료에 대한 뛰어난 적응성 등으로 인하여 기존의 통계학이 갖는 한계를 극복할 수 있다.

셋째, 자기 스스로 학습할 수 있다는 장점으로 전문가

시스템(Expert System)의 구축에는 지식획득의 어려움을 극복할 수 있는 유력한 방법론이 될 수 있어 최근 인공신경망은 그 응용범위를 크게 넓혀가고 있다.

본 연구에서 개발하려는 공정관리도의 패턴인식시스템은 통계적 공정관리(SPC)를 위한 관리도 기법중에서 가장 많이 사용되고, 적합한 관리도로 인식되고 있는 \bar{x} 관리도상에서 발생하고 있는 여러 형태의 패턴데이터를 그림 1과 같이 총 6 가지로 분류된 공정관리도의 특성패턴 - 정상(Normal), 순환(Cycle), 상향경향(Increasing Trend), 하향경향(Decreasing Trend), 공정평균의 상승돌변(Upward Shift), 하강돌변(Downward Shift) - 으로 분류하고, 인공신경망(Artificial Neural Network)을 이용하여 공정관리도의 패턴에 대한 학습을 실시한 후 공정에서 입력되는 데이터의 패턴분류과정을 실시간으로 파악하여 공정의 상태를 감지하는 지능형 품질관리시스템의 응용에 중점을 둔다.

아울러 각 패턴인식에 대한 여러 연구결과를 살펴본 결과, 상당히 많은 학습알고리즘과 다양한 형태의 패턴인식에 대한 연구가 활발한 가운데에서도 실제적으로 현장에서의 적용이 가능한 연구가 이루어지지 못함으로 인하여 이를 좀더 확장하여 최근 각광받고 있으며, 상당히 많은 기업에서 갖추고 있는 컴퓨터 네트워크 시스템내에서 작동가능한 패턴인식기와 이의 적용을 통한 공정의 상태를 감지할 수 있는 공정관리도의 패턴인식 정보시스템(CCPRS : Control Chart Pattern Recognition System)을 구축하여, 전문가가 부족한 제조현장에서 품질관리활동에 많은 도움을 받을 수 있는 실시간 관리시스템의 개발에 목적을 두고 있다.

II. 연구의 방법

본 연구에서 구성한 인공신경망의 구조는 1 개의 입력층과 2 개의 은닉층, 그리고 1 개의 출력층을 갖는 전체 4 개의 층으로 구성된 다층신경망(MLP : Multi Layer Perceptron)의 형태를 기본구조로 하며, 학습방법으로는 일반화된 델타규칙(Generalized Delta Rule) 으로 알려진 오류역전파알고리즘(Error Back-propagation

Algorithm)을 사용하였다.

또한 전체적인 인공신경망의 구조는 2 개의 네트워크 모듈(Module)로 구성되어 있으며, 각 네트워크 모듈은 우수한 학습률을 구하기 위한 반복적인 실험을 통하여

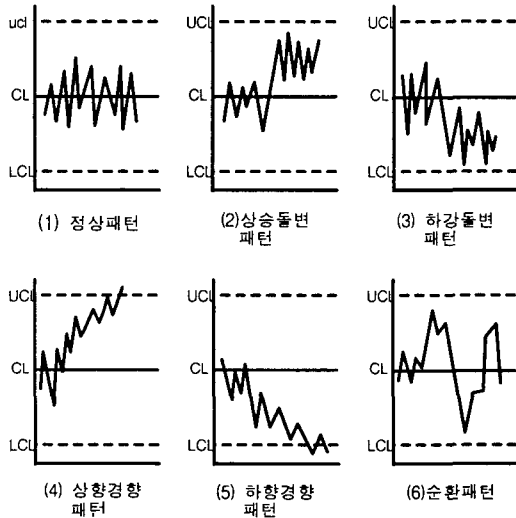


그림 1. 공정관리도의 패턴양상

얻어진 서로 다른 특성의 모수값(Parameter)을 갖는다.

네트워크 모듈 1은 23 개의 입력노드로 구성되어 있으며, 공정관리도의 6 가지 패턴에 대하여 1차적인 학습을 수행하게 되며, 그 결과는 63 개의 입력노드로 구성되어 학습을 수행한 네트워크 모듈 2에서 입력된 \bar{x}_i 값들에 대하여 순차적인 검증을 통해 이상패턴의 발생상황을 모니터링할 수 있는 네트워크의 구성을 제시하였다.

또한 오류역전과 알고리즘이 지닌 문제점인 국부 최소해(Local Minimum Solution)에 빠질 위험, 패턴분류의 경계가 모호하고 복잡해짐에 따라 학습효과가 급격히 느려지는 현상, 수렴에 실패하기도 하는 문제를 해결하기 위하여 네트워크의 각 연결층마다 서로 다른 학습률을 조정하여 적용하고, 반복적인 중복학습과 실험을 수행하였다.

그리고 인공신경망을 이용한 공정관리도의 패턴인식시스템의 성능향상을 위한 가장 중요한 요소인 학습데이터의 구성시, 기존의 여러 연구에서 사용한 시뮬레이션을 통한 인위적 데이터와 실질적인 인공신경망적응을 위하여 실제 제조공정에서 얻어진 품질데이터를 공정관리도의 각 패턴별로 동시에 고려하여 총 48,000개의 데이터 집합을

구성하였다.

Ⅲ. 공정관리도의 패턴인식시스템의 구축

1. 패턴인식시스템(CCPRS)의 구조

공정관리도의 패턴인식을 위한 시스템(CCPRS ; Control Chart Pattern Recognition System)은 그림 3 및 그림 4와 같이 다층신경망(MLP) 형태의 BPN(Back Propagation Network) 구조로 2 개의 은닉층(Hidden Layer)과 1 개의 출력층(Output Layer)으로 이루어진 2 개의 모듈(Module)로 구성되어 있다.

모듈 1은 CCPRS 시스템의 기본이 되는 모듈로서 각각의 패턴양상별로 20개의 입력자료로 갖는 \bar{x} 관리도의 6 가지 패턴양상에 대한 인공신경망의 학습 후에 패턴분류를 수행하기 위한 모듈로 구성되어 있으며, 모듈 2는 각각의 패턴양상별로 구성된 60개의 입력자료를 모듈 1과 동일하게 인공신경망의 학습후 패턴분류를 수행하게 된다.

특히 모듈 2에서는 모듈 1에서 학습된 결과인 연결강도, 즉 가중치(Weight)를 이용하여 모듈 2에서 입력된 60개의 자료에 대한 순차적인 입력자료를 구성하고, 이의 검증을 통하여 정상패턴을 제외한 5 가지 이상패턴에 대하여 각각의 이상패턴의 판단시점을 탐지하는 과정으로 구성되어 있다.

즉, 모듈 1의 입력노드(Input Node)를 통하여 입력 데이터가 입력되면 출력층노드에서는 6 가지의 패턴양상 - 정상(N ; Normal), 순환(C ; Cycle), 상향경향(Increasing Trend ; IT), 하향경향(Decreasing Trend ; DT), 공정평균의 상승돌변(Upward Shift ; US), 공정평균의 하강돌변(Downward Shift ; DS) - 으로 패턴을 분류하여 표 3의 형태로 6 개의 출력을 나타내게 된다.

그리고 모듈 1의 결과치는 학습된 BPN 모듈 2의 입력노드를 통하여 입력된 데이터의 순차적인 반복분석에 적용되어 모듈 2에서 이상패턴의 판단시점에 대한 출력을

하게 되며, 그 결과를 분석함으로써 공정의 상태를 모니터링하게 된다.

표 1. CCPRS 시스템의 전체구조

구성 요소	모듈 1	모듈 2
네트워크	오류역전파(BPN)	오류역전파(BPN)
학습방법	지도학습	지도학습
입력노드	23	63
은닉층	2	2
첫 번째 은닉층노드	23	35
두 번째 은닉층노드	20	27
출력노드	6	6
활성화함수	시그모이드함수	시그모이드함수
출력	이상패턴 분류	이상패턴 분류 변화탐지 및 검증
오차율	RMSE (Root Mean Square Error)	RMSE (Root Mean Square Error)
학습률	0.05, 0.03, 0.01	0.05, 0.03, 0.01
모멘텀계수	0.3	0.3
학습회수	9,000	7,000

2. 학습데이터의 구성

본 연구에서는 6 가지 패턴양상의 인공신경망 학습을 위하여 기존의 여러 연구에서 사용한 일반적인 패턴생성기(Pattern Generator)를 이용한 시뮬레이션기법을 통하여 인위적으로 구성된 데이터집합, 36,000개를 일차적으로 구성하고, 아울러 생산현장에서 추출된 각 패턴양상에 따른 품질특성치를 12,000개 포함하여 총 48,000개의 데이터 집합을 구성하였다.

각 패턴양상에 따른 각 패턴데이터의 구성은 BPN 모듈 1과 모듈 2의 경우 각각 20개, 60개의 데이터를 기준으로 각 패턴별로 전체 100개의 유형을 구성하였다.

3. 입력데이터와 출력패턴

본 연구에서는 3 가지 형태의 입력데이터를 구성하여 성능을 비교한 후 가장 좋은 성능을 보이는 방법을 택하였다.

- (1) $[x_1, x_2, \dots, x_n]$: 크기 n 인 품질특성치를 입력데이터로 구성하는 경우.
- (2) $[x_1, x_2, \dots, x_n, \bar{x}]$: 품질특성치와 평균을 입력데이터로 구성하는 경우.

- (3) $[x_1, x_2, \dots, x_n, \bar{x}, s, R]$: 품질특성치와 평균, 표준편차, 범위를 동시에 고려하여 입력데이터로 구성하는 경우.

입력데이터를 3 가지 구성방법에 따라 CCPRS 시스템의 BPN 모듈 1에 입력하여 3,000번의 학습회수를 기준으로 인공신경망을 학습시킨 후 출력치들의 평균을 계산하여 성능을 비교하였다.

표 2의 결과에서 보듯이 평균, 표준편차, 범위의 통계량을 입력데이터에 포함시킨 3 번째 방법이 가장 우수한 성능을 보이고 있으며, 입력데이터에 3 가지 통계량을 포함시키기로 하였다.

따라서 BPN 모듈 1의 입력층은 23개의 입력노드(Input Node)로 구성되며, 모듈 2는 63개의 입력노드로 구성된다.

표 2. 입력데이터의 구성에 따른 성능비교

입력방법	평균성능	표준편차
$[x_1, x_2, \dots, x_n]$	71.221 %	4.111 %
$[x_1, x_2, \dots, x_n, \bar{x}]$	82.413 %	2.146 %
$[x_1, x_2, \dots, x_n, \bar{x}, s, R]$	90.377 %	1.451 %

출력층은 표 3과 같이 정상패턴을 포함한 이상패턴의 수만큼 출력노드를 구성하고, 1과 0의 출력치를 사용하였다. 따라서 BPN 모듈 1과 모듈 2의 출력층은 6 개의 출력노드(Output Node)로 구성하였다.

표 3. 인공신경망의 출력과 연결패턴

패턴양상	목표 출력(Output Node)					
	1	2	3	4	5	6
정상	1	0	0	0	0	0
순환	0	1	0	0	0	0
상향경향	0	0	1	0	0	0
하향경향	0	0	0	1	0	0
상승돌변	0	0	0	0	1	0
하강돌변	0	0	0	0	0	1

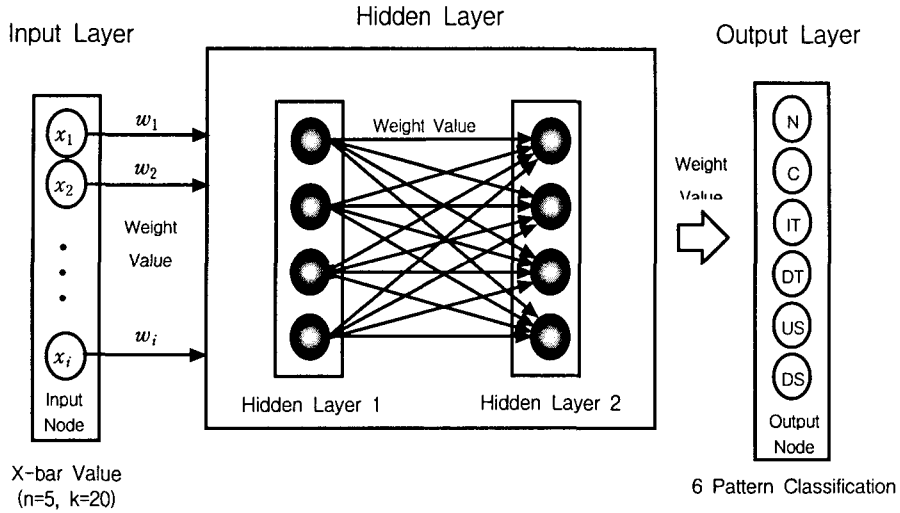


그림 3. CCPRS 시스템의 BPN 모듈 1

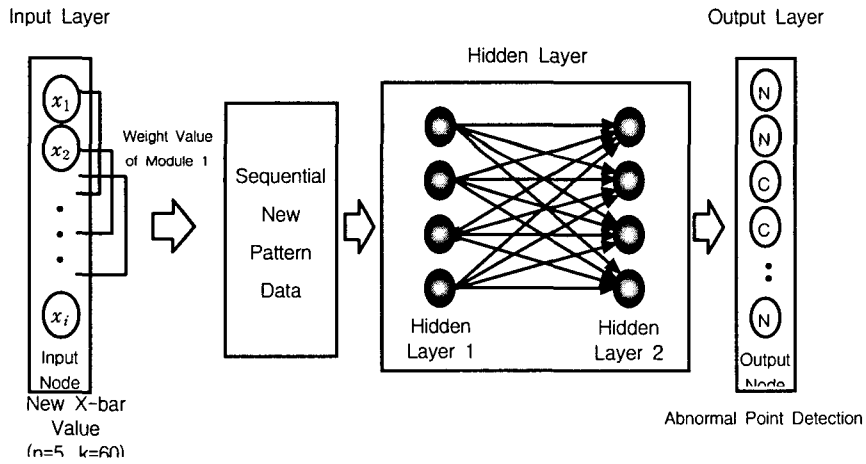


그림 4. CCPRS 시스템의 BPN 모듈 2

4. 은닉층(Hidden Layer)의 노드 수

먼저, BPN 모듈 1의 은닉층의 수를 결정하기 위해 은닉층의 수가 1 개로 구성된 경우에 표 4와 같이 노드의 수를 20, 30, 50의 3 가지로 설정하고, 기본적으로 10,000번의 학습을 수행하였다.

실험의 결과, 그림 5와 같이 은닉층 노드의 수에 관계 없이 학습오차가 감소하지 않고 수행시간만 증가되어 은닉층의 수가 1 개인 경우에는 학습이 이루어지지 않는다고 판단하여 은닉층의 수를 2 개로 설정하였다.

또한 BPN 모듈 2에서 은닉층의 수도 상기한 방법으

로 반복실험한 결과, 학습오차의 감소가 이루어지지 않아서 은닉층의 수를 2 개로 설정하였다.

표 4. 은닉층의 수가 1개인 경우의 실험결과

은닉노드 수	RMSE	수행시간(분)
20	0.33577	16.2
30	0.33575	22.6
50	0.33581	33.3




그림 5. 은닉층 1, 은닉노드 수 20인 경우 오차의 변화

또한 은닉층의 수를 2 개로 설정한 후 각 은닉층노드의 수를 결정하기 위하여 상기한 방법과 유사한 방법으로 반복실험을 수행하였다.

먼저, BPN 모듈 1의 은닉층노드의 수를 결정하기 위해 표 5와 같이 각 은닉층마다 노드의 수를 5 가지의 유형으로 설정하고, 10,000번의 학습을 수행하였다. 실험의 결과, 각 은닉층 노드의 수가 20, 20인 경우부터 학습오차가 크게 감소하는 모습을 보였으며, 노드의 수가 증가함에 따라 수행시간만 크게 증가할 뿐이고, 오차의 감소는 극히 작았다.

표 5. 은닉층의 수가 2개인 경우의 실험결과

은닉층 1	은닉층 2	모듈 1		모듈 2	
은닉 노드수	은닉 노드수	RMSE	수행시간(분)	RMSE	수행시간(분)
20	20	0.01311	26.5	0.01263	28.9
25	20	0.01278	30.8	0.01207	31.0
30	25	0.01266	46.3	0.01144	48.7
35	30	0.01261	57.1	0.01137	58.3
50	40	0.01259	74.7	0.01136	80.9

실험결과를 토대로, BPN 모듈 1의 은닉노드의 수는 각 은닉층마다 20 개를 기준으로 1 개씩 증가시키면서 반복실험을 수행하여 학습오차의 감소가 거의 이루어지지 않는다고 판단되는 경우를 선택하여 첫 번째 은닉층의 노드 수는 23개, 두 번째 은닉층의 노드 수는 20개로 설정하였다.

또한 BPN 모듈 2의 은닉노드의 수를 결정하는 과정도 상기한 방법으로 반복실험을 수행하였으며, 그 결과

첫 번째 은닉층노드의 수는 35개, 그리고 두 번째 은닉층노드의 수는 27개가 적합함을 알 수가 있었다.

5. 학습방법

본 연구에서는 조합값을 얻기 위하여 CCPRS 시스템 모듈의 각 층마다 여러 가지 학습률과 모멘텀계수를 적용시켜 상당히 많은 실험을 수행하였으며, BPN 모듈 1과 모듈 2에서 학습오차가 가장 적을 때의 값으로 첫 번째 은닉층은 0.05, 두 번째 은닉층은 0.03, 출력층의 학습률은 0.01로 설정하였고, 모멘텀계수는 0.3을 적용하였다.

학습데이터의 입력은 구성된 학습데이터의 최대치와 최소치를 0~1 사이의 값으로 선형변환하여 입력하였다.

활성화함수(Activation Function)로서는 시그모이드 함수(Sigmoid Function)를 사용하였다.

인공신경망의 학습회수는 학습오차로 사용된 평균제곱근오차(RMSE : Root of Mean Squared Error)와 학습수행시간을 동시에 고려하였다. $RMSE \leq 0.05$ 를 만족하고, 학습회수의 증가에 따른 오차의 변화가 거의 없는 경우에 충분한 학습이 이루어졌다고 판단하여 학습을 중단하고 전체적인 학습성능을 평가하였다.

또한 $RMSE \geq 0.05$ 인 경우에는 학습회수를 증가시켜 보았으며, 학습회수의 증가에도 불구하고 오차가 감소하지 않는 경우와, 많은 실험과정에서 경험으로 보아 학습수행시간이 너무 긴 경우에는 학습을 중단하고, 은닉노드의 수를 늘리거나 학습률 등의 학습모수치에 조절을 가하는 방법을 사용하였다.

RMSE 값을 기준으로 학습데이터에 대한 인공신경망의 학습수준을 평가하였으며, 학습데이터에 대한 패턴 인식률(PRR : Pattern Recognition Rate)을 설정하여 인공신경망의 성능을 평가하였다.

$$PRR = \frac{NTP}{NCP} \times 100$$

NTP : 전체 학습 패턴의 수
NCP : 정확히 인식된 패턴의 수

이러한 과정을 통하여 BPN 모듈 1과 모듈 2의 학습회수를 반복실험을 통해 구하였으며, 표 6에서 보는 바와 같이 BPN 모듈 1의 경우에 학습회수가 9,000번 이상으로 증가되어도 오차의 변화가 매우 적어서 학습회수는 9,000번이 적절하였고, 동일한 방법으로 BPN 모듈 2의 경우에는 7,000번의 학습회수가 가장 적합함을 알 수 있었다.

표 6. 학습회수에 따른 오차

학습회수	모듈 1		모듈 2	
	RMSE	수행시간(분)	RMSE	수행시간(분)
3,000	0.01475	13.6	0.01439	14.3
5,000	0.01462	19.7	0.01197	20.1
7,000	0.01451	25.7	0.01093	27.1
9,000	0.01447	31.5	0.01090	33.8
10,000	0.01443	34.3	0.01088	37.0

IV. 패턴인식시스템(CCPRS)의 실험 및 성능평가

1. 모듈 1의 실험결과

학습된 BPN 모듈 1의 패턴인식실험을 위하여 정상패턴을 포함한 6 가지 이상패턴에 대하여 각각의 패턴별로 30개의 패턴데이터를 대상으로 패턴인식을 수행한 결과 표 7과 같이 매우 우수한 패턴인식률을 보였으며, 결과적으로 모듈 1의 평균 패턴인식률은 98.59%, RMSE는 0.0154를 보였다.

또한 표 7의 상승돌변과 하강돌변패턴의 경우에는 상향경향과 하향경향패턴과 비교하여 패턴인식률이 약 2% 정도의 차이를 보였으며, 이는 경향패턴과 돌변패턴의 유사성에 비추어볼 때 패턴인식시스템이 경향패턴에 좀더 우수한 패턴인식성능을 나타내고 있음을 알 수 있다.

표 7. 모듈 1의 실험결과

(1) 정상	(2) 순환	(3) 상향경향	(4) 하향경향	(5) 상승돌변	(6) 하강돌변
0.9926	0.0000	0.0000	0.0000	0.0000	0.0000
0.0000	0.9945	0.0000	0.0000	0.0000	0.0000
0.0000	0.0000	0.9906	0.0000	0.0000	0.0000
0.0000	0.0000	0.0000	0.9911	0.0000	0.0000
0.0000	0.0000	0.0000	0.0000	0.9758	0.0000
0.0000	0.0000	0.0000	0.0000	0.0000	0.9711

2. 모듈 2의 실험결과

학습된 BPN 모듈 2의 패턴인식실험도 모듈 1의 실험과 동일하게 정상패턴을 포함한 6 가지 이상패턴에 대하여 각각의 패턴별로 30개의 패턴데이터를 대상으로 패턴인식을 수행하였다.

평균 패턴인식률은 98.67%, RM는 0.0177을 보여 모듈 1과 마찬가지로 매우 우수한 성능을 나타내었다.

특히, 모듈 1의 결과에서는 경향패턴이 돌변패턴과 비교하여 패턴인식시스템이 약간 높은 인식률을 보였으나, 모듈 2에서는 표 8에 나타난 바와 같이 경향패턴과 돌변패턴의 패턴인식성능이 차이가 없는 결과를 보여주었다.

그러나 정상패턴이나 순환패턴의 결과와 비교하여 볼 때 경향패턴과 돌변패턴 모두 약 1% 정도의 성능저하를 보였다.

표 8. 모듈 2의 실험결과

(1) 정상	(2) 순환	(3) 상향경향	(4) 하향경향	(5) 상승돌변	(6) 하강돌변
0.9927	0.0000	0.0000	0.0000	0.0000	0.0000
0.0000	0.9933	0.0000	0.0000	0.0000	0.0000
0.0000	0.0000	0.9837	0.0000	0.0000	0.0000
0.0000	0.0000	0.0000	0.9855	0.0000	0.0000
0.0000	0.0000	0.0000	0.0000	0.9824	0.0000
0.0000	0.0000	0.0000	0.0000	0.0000	0.9831

그리고 모듈 2의 실험을 수행한 후, 모듈 2의 사례를 대상으로 패턴인식 결과에 대한 검증을 수행하였으며, 또한 모듈 1의 결과인 연결가중치를 이용하여 정상패턴을 제외한 5 가지 이상패턴에 대한 인공신경망의 판단시점을 파악함으로써 이상패턴의 변화를 모니터링하였다.

또한 인공신경망 출력에 대한 임계치는 0.80으로 설정하여 이상패턴의 발생여부를 판단하였으며, 각각의 이상패턴에 대한 인공신경망의 출력치들중에서 가장 큰 값을 택하였다.

표 9에서 보는 바와 같이 순환패턴의 경우에 인공신경망이 3 번째 시점부터 계속적으로 높은 출력치를 나타내어 순환패턴이 연속적으로 발생하고 있는 것으로 판단하였음을 알 수 있으며, 경향패턴과 공정평균의 돌변패턴의 경우에는 입력데이터에 내재하고 있는 다른 이상패턴의 영향을 받아 계속적인 높은 출력을 보이지 않아 다른 패턴의 출력과 비교하여 해당되는 이상패턴의 출력치가 가

장 높은 경우의 값만을 출력하여 이상패턴의 발생을 판단하였다.

따라서 가장 높은 출력을 갖는 경우에 해당하는 이상패턴의 발생을 모니터링할 수 있었다.

3. 패턴인식시스템의 성능평가

본 연구에서 구축된 패턴인식시스템의 성능을 평가하기 위해서 각각의 이상패턴을 몇 가지 모수치에 따라서 실험데이터를 구성한 후 구성된 실험데이터를 BPN 모듈 1을 이용하여 10,000회의 반복실험을 통하여 성능을 측정하였다.

실험데이터는 각각 5 가지 이상패턴별로 3,000 개씩 구성하였으며, 또한 구성된 실험데이터 집합은 한 가지 이상패턴만을 포함시켰다.

또한 성능의 비교평가를 위하여 구성된 실험데이터집합의 초기상태는 어떤 이상패턴도 포함하지 않도록 구성하였으며, 이상패턴의 판단을 위한 임계치는 0.80을 적용하였다.

패턴인식시스템의 성능을 평가하는 방법으로는 Hwarng과 Hubele(1993)가 제안한 성능평가지수인 ROT(Rate of Target), ATPRL(Average Target Pattern Run Length), ARLIDX(Average Run Length Index)를 사용하여 구축된 패턴인식시스템의 성능을 평가하였으며, 그 결과를 기준으로 대표적인 연구로 인식되고 있는 Hwarng과 Hubele의 연구결과와 비교하였다.

실험결과를 살펴보면, 우선 경향인 경우에는 기울기가 큰 경우의 패턴인식률이 기존의 연구에서는 급격히 떨어지는 결과를 보였으나, 본 연구에서는 성능이 저하

되지 않는 결과를 보여 기존의 연구와 비교하여 우수함을 알 수 있었으며, 또한 도출된 ROT 지수와 ARLIDX 지수를 비교하여 볼 때에도 기존연구와 비교하여 매우 우수하다고 판단할 수 있었다.

순환인 경우에도 경향의 경우와 동일하게 기존의 연구는 순환의 모수치가 진폭이 큰 경우에 비하여 작은 경우에 높은 ARLIDX 지수치를 나타냈으나, 본 연구의 결과는 진폭이 작은 경우나 큰 경우에 관계없이 우수한 출력을 보였음을 알 수 있다.

표 9. 모듈 1을 이용한 이상패턴의 판단

데이터 번호	(2) 순환	(3) 상향경향	(4) 하향경향	(5) 상승돌변	(6) 하강돌변
1	0.00000	0.00000	0.00000	0.00000	0.00000
2	0.00000	0.00000	0.00000	0.00000	0.00000
3	0.98397	0.00000	0.00000	0.00000	0.00000
4	0.90210	0.00000	0.00000	0.00000	0.00000
5	0.96503	0.00000	0.00000	0.00000	0.00000
6	0.98301	0.00000	0.00000	0.00000	0.00000
7	0.83380	0.00000	0.00000	0.00000	0.00000
8	0.87075	0.93232	0.00000	0.00000	0.00000
9	0.98174	0.95532	0.00000	0.00000	0.00000
10	0.99354	0.97563	0.00000	0.00000	0.00000
11	0.83878	0.98793	0.00000	0.00000	0.00000
12	0.86521	0.97864	0.00000	0.00000	0.82247
13	0.88634	0.00000	0.00000	0.00000	0.84841
14	0.87916	0.00000	0.00000	0.88249	0.89058
15	0.98055	0.00000	0.00000	0.96359	0.93054
16	0.97806	0.00000	0.00000	0.99912	0.97650
17	0.98973	0.00000	0.00000	0.99991	0.94713
18	0.99311	0.00000	0.00000	0.99965	0.96054
19	0.98639	0.00000	0.00000	0.99973	0.97712
20	0.96521	0.00000	0.00000	0.99988	0.98010
21	0.87184	0.00000	0.00000	0.99888	0.98349
22	0.87916	0.00000	0.00000	0.89845	0.99692
23	0.98055	0.00000	0.84211	0.90547	0.99789
24	0.82798	0.00000	0.85008	0.98799	0.98957
25	0.94966	0.00000	0.91547	0.97957	0.98655
26	0.87557	0.00000	0.92258	0.90155	0.99568
27	0.95565	0.00000	0.91451	0.99977	0.88721
28	0.99035	0.00000	0.80427	0.99993	0.99274
29	0.99034	0.00000	0.00000	0.99993	0.97553
30	0.90841	0.00000	0.00000	0.99991	0.99214
31	0.89035	0.00000	0.00000	0.99998	0.97476
32	0.89792	0.00000	0.00000	0.99301	0.95455
33	0.95565	0.00000	0.00000	0.89301	0.96577
34	0.87335	0.00000	0.00000	0.99936	0.98542
35	0.87198	0.00000	0.00000	0.99837	0.99425
36	0.92833	0.87327	0.00000	0.82459	0.92263
37	0.92192	0.88454	0.00000	0.95655	0.94554
38	0.97950	0.94365	0.00000	0.92215	0.92657
39	0.96742	0.95749	0.00000	0.97513	0.87545
40	0.95283	0.95675	0.00000	0.89875	0.94451
41	0.99496	0.87327	0.00000	0.89980	0.92531

표 10. 순환패턴의 성능평가 결과

모수	ATPRL	ROT(%)	ARLIDX
$k = 1.50$	7.55	100.0	7.55
$k = 2.00$	7.32	100.0	7.32
$k = 2.50$	7.14	100.0	7.14

표 11. 상향경향패턴의 성능평가 결과

모수	ATPRL	ROT(%)	ARLIDX
$\alpha = 0.15$	9.05	98.1	9.22
$\alpha = 0.25$	7.90	99.2	7.96
$\alpha = 0.35$	7.98	100.0	7.98

표 12. 하향경향패턴의 성능평가 결과

모수	ATPRL	ROT(%)	ARLIDX
$\alpha = -0.15$	8.90	98.7	9.01
$\alpha = -0.25$	8.08	100.0	8.08
$\alpha = -0.35$	7.85	100.0	7.85

표 13. 상승돌변패턴의 성능평가 결과

모수	ATPRL	ROT(%)	ARLIDX
$\mu = 1.50$	8.22	81.3	10.11
$\mu = 2.00$	6.98	51.7	13.50
$\mu = 2.50$	5.31	39.6	13.40

표 14. 하강돌변패턴의 성능평가 결과

모수	ATPRL	ROT(%)	ARLIDX
$\mu = -1.50$	7.78	82.3	9.45
$\mu = -2.00$	6.92	58.0	11.93
$\mu = -2.50$	5.23	32.3	16.19

표 15. 기존연구와의 성능비교

Hwang and Hubele			CCPRS		
	ROT (%)	ARLIDX		ROT (%)	ARLIDX
Cycle	100	8.01	Cycle	100.0	7.33
Increasing Trend	89.6	9.53	Increasing Trend	99.1	8.38
Decreasing Trend	92.0	9.18	Decreasing Trend	99.6	8.31

전체적으로 표 15에서 보는 바와 같이 기존의 연구결과와 본 연구결과와의 평균 ROT 지수와 평균 ARLIDX 지수치를 비교하여 본 결과, 기존의 연구결과와 비교하여 유의한 차이가 있다고 판단되어, 본 연구에서 구축한 인공신경망을 적용한 공정관리도의 패턴인식시스템(CCPRS)

의 성능이 매우 우수함을 알 수 있었다.

V. 결론

구축된 패턴인식시스템은 작업자의 효율과 생산성을 높이고저 지능적인 패턴인식시스템의 구축에 중점을 두었고, 개발된 패턴인식시스템을 이용하여 공정의 상태를 관리하는 작업자의 부담을 한층 덜어줄 수 있으며, 작업자는 공정에 이상패턴이 발생하는 경우에 패턴인식시스템을 통하여 공정상태에 대한 정보를 전달받을 수 있다.

인공신경망을 이용하여 공정관리도의 패턴인식시스템 구축시 전체적인 패턴인식시스템의 성능은 학습자료의 구성과 은닉층의 수, 은닉노드의 수에 따라 매우 큰 영향을 받는다는 것을 알 수 있었으며, 이러한 요소를 필요이상으로 증가시킬 경우에는 단지 학습시간이 증가되는 현상을 관찰할 수 있었다.

구축된 패턴인식시스템을 다른 인공신경망의 방법과 비교하여 보면, 첫째, 모델의 개발은 표준적인 기법을 이용하여 단순화함으로써 적용의 편의성을 높였고, 둘째, 새로운 모형에 대하여 이론적인 분석이나 새로운 시스템의 개발대신에 품질특성치를 저장하고 있는 데이터베이스로부터 기존의 학습자료와 새로이 선택된 자료를 대상으로 빠르게 재학습이 가능하다는 장점을 지닌다.

따라서 시스템을 이용하여 실시간으로 공정을 관리할 수 있어서 CIM 네트워크 시스템과의 연계시 공정의 개선에 큰 효과를 볼 수 있다.

셋째, 빠르게 수행되며, 합리적인 예산과 시간의 범위 내에서 적용될 수 있다는 점, 넷째, 안정적이며 높은 정확성을 보인다는 점, 다섯째, 객체지향적인(Object Oriented Program) 방법으로 프로그램을 구현하여 그 적용의 범용성을 높였으며, 시스템의 보완 수정을 거친 후 현장에서 적용이 가능하다는 점이다.

그러나 몇 가지 고려하여야 할 사항으로서는 본 연구의 결과가 모든 제조공정의 요구에 부합되는 해결책은 아니라는 점과, 공정에 대한 세부적인 지식과 장기간의 경험을 요구하는 이상원인에 대한 분석은 사람의 경험적인 능력을 결코 넘어서지 못한다는 것이다.

이러한 부분은 앞으로 좀더 많은 연구가 이루어져 공정관리도의 이상원인의 분석을 위한 자동화된 의사결정 알고리즘 즉, 일련의 규칙기반의 전문가시스템(Rule Based Expert System) 혹은 지능적인 에이전트(Agent) 기법 등과 결합, 확대되어 연구되어야 할 것으로 본다.

아울러 공정의 여러 가지 이상패턴이 혼합되어 동시에 발생하는 경우의 동시적인 해석과 그 원인에 대한 연구, 그리고 주로 경험적으로 설정되는 은닉층의 수, 노드의 수, 학습률 등과 같이 인공신경망 시스템에 영향을 미치는 주요 요인들을 좀더 현실적으로 찾아낼 수 있는 일반화된 방법론에 대한 연구가 향후 수행되어야 할 것으로 본다.

참고문헌

- [1] 김대수, 「신경망 이론과 응용(I)」, 하이테크정보, 1993.
- [2] D. C. Montgomery, Introduction to Statistical Quality Control, 3rd ed., Wiley, 1996.
- [3] G. Smith, Statistical Process Control and Quality Improvement, Prentice Hall, 1995.
- [4] J. Lawrence, Introduction to Neural Networks Design, Theory, and Applications, California Scientific, 1993.
- [5] L. Fausett, Fundamentals of Neural Networks, Prentice-Hall, 1994.
- [6] L. Underwood, Intelligent Manufacturing, Addison Wesley, 1994.
- [7] M. T. Hagan, H. B. Demuth, Neural Network Design, PWS Publishing Company, 1996.
- [8] P. C. Badavas, Real-Time Statistical Process Control, Prentice Hall, 1993.
- [9] S. I. Gallant, Neural Network Learning and Expert Systems, A Bradford Book, 1992.

- [10] A. E. Smith, "X-bar and R Control Chart Interpretation Using Neural Computing", Int. J. Prod., Vol.32, No.2, 1994, pp.309-320.
- [11] C. S. Cheng, "A Multi-layer Neural Network Model for the Detecting Changes in the Process Mean", Comput. Ind. Eng., Vol.28, No.1, 1995, pp.51-61.
- [12] D. Cox, "Using C++ for Backpropagation", AI Expert Vol.9, No.12, 1994, pp.14-17.

저자 소개



한 우 철

건국대학교 대학원 산업공학과
(공학박사)

현재 대림대학 산업시스템
경영과 교수

관심분야 : 의사결정지원시스템
경영정보시스템