

**研究論文****인공 신경망의 패턴분석에 근거한 지능적 부품품질  
관리시스템의 설계**

이장희 · 유성진 · 박상찬

한국과학기술원 산업공학과

**Design of Intelligent Material Quality Control System based on  
Pattern Analysis using Artificial Neural Network**

Jang Hee Lee\* · Song Jin Yu\* · Sang Chan Park\*

\* Department of Industrial Engineering, Korea Advanced Institute of Science and Technology (KAIST)

Keywords: Pattern Analysis, Neural Network, Material Quality Control System

**Abstract**

In resolving industrial quality control problems, a vector of multiple quality characteristic variables is involved rather than a single variable. However, it is not guaranteed that a multivariate control chart based on statistical methods can monitor abnormal signal in case that small changes of relationship between each variables causes abnormal production process. Hence a quality control system for real-time monitoring of the multi-dimensional quality characteristic vector under a multivariate normal process is needed to enhance the production system quality performance.

A pattern analysis approach based on self-organizing map (SOM), an unsupervised learning technique of neural network, is applied to the design of such a quality control system. In this study we present a new material quality control system based on pattern analysis approach and illustrate the effectiveness of proposed system using actual electronic company material data.

**1. 서 론**

국산 제품의 수출이 날로 어려워지고 국내 시장 역시 여러 분야에서 수입품에 의해 급 속히 침식되어 가고 있는 등 최근 우리 경제는 어려움을 겪고 있다. 가격 및 품질면에서

의 경쟁력 상실이 그 주요 원인으로 지적되고 있으며 품질향상을 통한 제품의 원가 절감 및 고급화·다양화가 우리 제품의 경쟁력 강화의 첫째 과제로 인식되고 있다. 또한 소비자의 품질에 대한 관심 증대, 소비자 보호 운동의 확산 그리고 제품책임의 인식 등으로

말미암아 산업 현장에서 효과적인 품질관리 활동이 새삼 강조되고 있다.

또한 최근 고객의 다양한 요구를 만족시키는 다양한 제품 생산을 위한 단품종 소량 생산 체제가 가속화되는 상황下에서, 이에 대응할 수 있는 유연생산시스템 (Flexible Manufacturing System)을 구축하여 셀(cell) 및 라인(line)의 구성 요소들을 효과적으로 통제, 관리하는 것이 필요하다. 이를 위해서는 생산공정의 이상유무 판정 및 원인 진단 기능을 목적으로 하는 효율적인 품질관리시스템을 구축하여야 한다.

과거에는 주로 완제품을 선별 검사하여 품질기준을 충족하지 못하는 제품에 대해서는 폐기 처분이나 재가공 조치를 취하는 등 사후의 품질관리 활동에 큰 비중을 두었다. 그러나 이것이 품질의 향상에 크게 기여를 하지 못하게 됨에 따라서 완제품에 대한 조처보다는 제조공정과정을 관리하여 불량품이 생산되지 않도록 하는 사전 품질관리 활동에 더 큰 비중을 두기 시작했다.

실제로 고객이 만족할 수 있는 고품질 및 신뢰성을 가지는 완제품을 생산하기 위해서 기업은 다수의 중간 단계에서 품질검사를 실시하고 있다. 원자재 또는 반제품에 대하여 제품의 원재료로서 적합성을 검사하는 수입검사, 제품을 생산하는 도중 불량품이 다음 공정으로 이동하는 것을 방지하기 위한 공정검사, 또한 완제품을 출하하기 전에 출하여부를 결정하는 출하검사 등 여러 단계에서 검사를 실시한다. 여기서 출하검사는 만족스럽지 못한 수준의 품질을 가진 제품을 선별하는 사후 품질관리 활동에 해당하므로, 실질적인 품질변동의 감소나 품질 향상을 위해서는 수입검사와 공정검사 활동이 더욱 중요하다 하겠다.

공정검사 활동의 중요한 목적 중의 하나는 공정에 이상요인이 발생하였을 경우 가능한 빨리 이를 탐지하여 수정조치를 취함으로써 공정에 기인한 불량제품의 발생을 사전에 억제하는 것이다. 일반적으로 생산 공정의 모니터링(monitoring)을 위한 중요한 도구로서 관리도(Control Chart)가 널리 사용되고 있는데, 관리도는 공정검사를 통해 수집된 공정 특성치의 측정값의 변동상황을 그래프로 나타내어 공정에 대한 정보(평균, 산포, 불량률 등)를 추정하거나 공정개선을 위한 유익한 정보를 제공한다 [배도선, 1996]. 또한 최근에는 FMS도입에 따른 설비자동화로 인해, 자동데이터설비(automatic data acquisition equipment) 온라인 컴퓨터(on-line computer)의 도움으로 여러 특성치를 모니터링하는 것이 일반화되고 있고 그에 따라서 얻어진 특성치들을 최대한 이용할 수가 있는 다양한 관리도 (EWMA 관리도, CUSUM 관리도 등)가 제시되어 왔다[배도선, 1996, Alt, 1992, Crosier, 1988, Jackson, 1959].

통계적인 접근 방법에 의한 관리도는 그 설계 절차가 매우 합리적인 것으로 평가받고 있으며, 관측치가 단변량인 상황에서는 관리도의 현장 적용 결과의 우수성이 많이 입증되고 있다. 그러나 이러한 통계적인 접근 방법이 특성치가 다변량인 상황에서도 우수한 검출능력을 가질 수 있을 것인지는 미지수이다. 특히, 각 특성치 사이의 미세한 상호 관계 변화가 공정의 이상변화에 중요한 원인이 되는 경우에도 이상 신호를 검출할 수 있을지 보장할 수 없다.

그러나, 통계적인 관리도와 같이 공정검사 데이터에 근거한 효과적인 공정관리 방법이 활발히 연구되고 있는 반면, 부품 또는 원자재의 품질관리를 위한 수입검사 분야에 대한

연구가 미비한 실정이다. 이에 본 연구에서는 부품 또는 원자재 수입검사 업무분야에 효과적으로 적용될 수 있는 부품품질관리시스템의 프로토타입(prototype)을 제시함으로써, 완제품 생산과 관련된 기업 전 분야의 총체적인 품질관리를 실현할 수 있는 기반을 제공하였다. 또한 기존의 통계적인 기법의 대체 방안으로서 신경회로망을 도입하여 신경회로망의 일종인 SOM (self-organizing map) 네트워크를 활용하여 부품품질의 패턴 변화를 분석하고, 그 과정에서 부품품질의 이상 발생을 신속하고 정확하게 검출할 수 있는 방법론을 제시하였다.

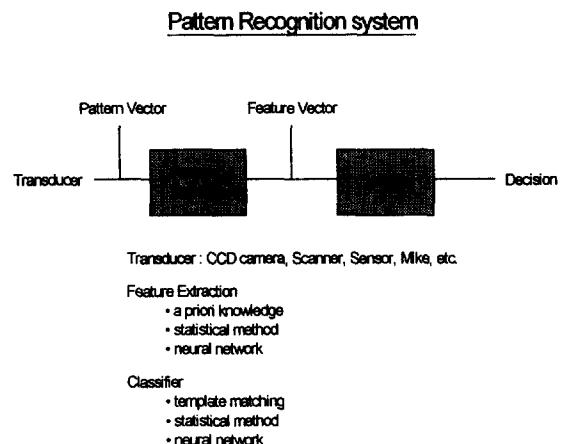
본 논문은 다음과 같이 구성하였다. 먼저, 2장에서 부품 및 생산공정에서 발생하는 다변량의 품질특성치의 패턴변화를 분석할 수 있는 패턴분석시스템의 일반적인 모형을 살펴보고, 3장에서는 SOM 신경망에 기반하여 부품 및 원자재 품질의 패턴을 분석할 수 있는 방법론과 이러한 분석방법론을 제안하였다. 4장에서는 3장에서 제안한 분석방법론을 가지는 부품품질관리시스템의 프로토타입을 제시하고 또한 그 유효성을 검증하기 위해 전자회사의 부품수입검사 자료에 실험적으로 적용한 결과를 제시하였으며 5장에서 결론과 향후 연구 방향에 대해 논하였다.

## 2. 패턴분석시스템

패턴분석시스템은 일반적으로 <그림1>과 같은 모형을 가진다[박민용과 최용식, 1991].

<그림 1>의 특성 추출장치(Feature Extractor)는 입력장치로부터 얻은 패턴 벡터(pattern vector)에서 중요한 특성만을 추출해 내는 시스템이다. 예를 들어, 인간이 눈

으로 나무를 인식하는 경우에 인간은 나무의 모든 면을 전부 분석하는 것이 아니고, 줄기, 잎, 색깔 등 몇 가지의 중요한 특성만을 가지고 인식한다. 특성 추출장치도 마찬가지로 패턴 벡터에서 중복되는 것과 사소한 것들을 가려내어 중요한 특성치만을 추출하여 특성 벡터(feature vector)를 만든다. 즉, 특성 벡터에는 패턴을 인식하는데 중요한 요소들이 들어 있게 된다.



<그림1> 패턴분석시스템 모형

패턴 벡터에서 특성 벡터를 추출하는 이유는 패턴 벡터는 특성 벡터에 비해 아주 양이 많은 반면에 정보의 양은 거의 같으므로 패턴 벡터로 패턴 분석을 하는 경우에는 시간이 아주 많이 걸린다. 특성 벡터는 다시 특성분류기(classifier)에 의해 분석되어 의사결정을 내릴 수 있는 정보를 준다.

특성분류기는 <그림1>에서 보듯이 세 가지 방법에 의해서 구현될 수 있다[Jurgen Schurmann, 1996].

- 1) Template Matching - 미리 저장되어 있

거나 미리 알고 있는 패턴 중에서 가장 비슷한 패턴을 선택하는 방법으로 minimum distance classifier와 k-nearest neighbor classifier 등이 있다. 사전 지식(a priori knowledge)이 없는 경우는 적용하지 못할 뿐만 아니라 현재까지 알고 있는 패턴과 전혀 다른 새로운 패턴이 입력될 경우에는 적용 오차가 매우 크다는 단점이 있다.

2) Statistical Method - 현재 가장 많이 사용되는 방법으로서 학습이 필요하고, 학습방법은 i) Parametric vs. Nonparametric, ii) Supervised vs. Unsupervised learning 등이 있다. 자료의 분포를 알고 있는 경우에는 parametric, 그렇지 않은 경우에는 nonparametric 방법을 사용한다. 또 학습을 할 때 feature vector의 결과 패턴을 사전에 알고 있어서 가르쳐 줄 수 있는 경우에는 supervised, 결과 패턴을 모르는 경우에는 unsupervised 방법을 사용한다. 하지만, i)과 ii)의 방법이 서로 대립되는 것은 아니다. 통계적인 기법에 의한 패턴분석 방법에는 <그림2>와 같은 방법이 있다.

#### Statistical Method

- Discriminant function
  - Linear : Perceptron, Gradient descent method, Least mean square error
  - Nonlinear
- Unsupervised learning
  - Clustering
  - Similarity measure

<그림2> 통계적 분석방법의 종류

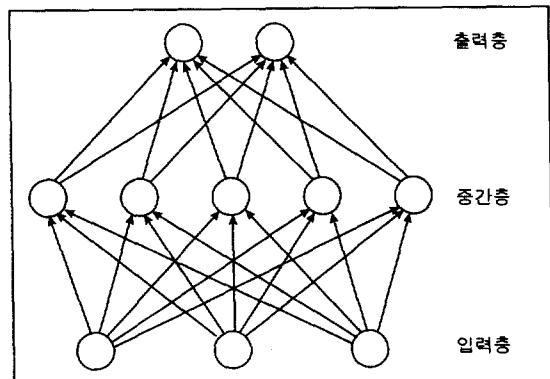
3) 신경회로망(Neural Network) - 최근에 각광을 받는 분야로서 패턴 인식이나 예측분야에 많이 응용되고 있다. 패턴 인식에 있어

서는 <그림3>과 같은 신경망을 주로 사용한다[Jurgen Schurmann, 1996].

- Associative memory
- Perceptron
- Adaline
- Multilayer neural network
- Radial basis function network
- Cascaded-correlation network
- Projection pursuit learning network
- Kohonen feature map
- ART

<그림 3> 신경회로망의 종류

신경회로망의 경우에도 지도 학습(supervised learning)과 비지도 학습(unsupervised learning)으로 크게 나눌 수 있는데 차이점은 통계적인 기법의 경우와 마찬가지다. 일반적인 신경회로망의 형태는 <그림 4>와 같다.



<그림4> 일반적인 신경회로망의 구조

신경회로망은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)과 각 층 사이의 각각의 노드를 연결하는 가중치 벡터로 구성되어 있다. 학습 알고리즘은 백

프로퍼게이션 학습(error back-propagation), LMSE(least mean square error), gradient descent algorithm 등 여러 가지가 있다. 일반적으로 백프로퍼게이션 학습이 많이 이용된다[James & David, 1991].

다면량의 경우에 통계적인 기법은 변수들의 상관관계를 나타내기 위해서 사전 정보를 미리 가지고서 변수들의 상관관계를 모델링 하여야 하지만 신경회로망을 이용할 경우에는 신경회로망 자체가 변수들의 상관관계까지 학습할 때 고려하기 때문에 사전 모델링 단계를 거칠 필요가 없이 학습에 필요한 변수만을 알아내면 된다.

### 3. SOM 신경망과 부품품질 관리시스템

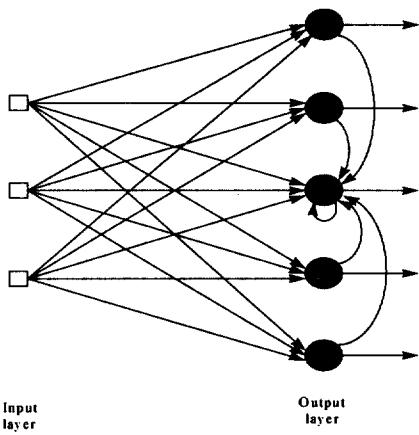
SOM(self-organizing map)은 외부의 피드백이나 지도 없이 스스로 학습하여 입력자료에서 의미 있는 패턴이나 특징을 발견하는 신경망이다[James & David, 1991]. 본 연구에서 활용한 SOM 신경망은 여러 종류의 자기조직화(self-organizing) 네트워크 중에서 SOFM(self-organizing feature map)이라고 알려진 신경망이다[Kohonen, 1982]. 이 네트워크는 경쟁 학습(competitive learning)을 수행하는데, 이것은 네트워크의 출력 뉴런이 활성화되기 위하여 서로 경쟁한 후 어떤 시점에서 단지 하나의 출력 뉴런만을 활성화시킨다. 경쟁에서 이긴 출력 뉴런을 승자획득 뉴런 (winner-takes-all neuron)이라 말하고, 출력 뉴런들 중에서 승자획득뉴런을 유도하기 위해 출력 뉴런 사이에 측면억제연결(lateral inhibitory connection)을 사용한다.

#### 3.1 SOM 학습

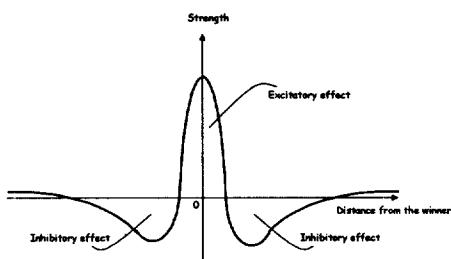
SOM에서는 뉴런이 N-차원으로 구성된 격자(lattice)의 노드에 위치한다. 뉴런은 경쟁적 학습과정에 있는 입력 패턴이나 입력 패턴의 클래스에 따라서 선택적으로 조정(tune)된다. 조정된 뉴런의 위치는 여러 입력 특징들에 대해서 의미 있는 좌표체계가 격자(lattice)에 생성되는 것으로서 격자에 있는 뉴런의 위치는 입력 패턴의 특징에 대응한다. 즉, SOM은 격자에 있는 뉴런의 공간의 위치가 입력 패턴의 고유의 특성과 일치하도록 입력 패턴의 지형적인 지도를 형성한다 [Kohonen, 1982].

<그림5>는 SOM의 간단한 구조를 나타내는데, 두 가지 종류의 연결(connection)이 있다.

그림5에는, 입력층으로부터의 전방 연결(forward connection)이 있고, 자기 피드백(self-feedback)과 측면 피드백을 위한 네트워크 내부의 연결이 있으며 입력신호는 뉴런에 평행하게 들어오게 된다. 두 종류의 지역적 연결(local connection)은 서로 다른 두 가지 목적을 가진다. 각 뉴런에서 입력신호의 가중치 합(weighted sum)은 특성 감지(feature detection)를 수행하기 위한 것으로 각 뉴런은 입력신호의 특정 집합에 선택적인 반응을 한다. 한편, 피드백 연결은 뉴런으로부터 떨어진 거리에 의존하여서 여기(excitatory) 효과나 억제 효과를 생성한다. 즉 거리가 멀어질수록 연결강도는 작아지는 데, <그림6>과 같은 멕시코 모자 함수(Mexican hat function)로 묘사된다. 그림에서 보듯이 뉴런 사이의 측면 상호작용의 영역은 두가지로 나누어진다.



<그림 5> 전방향 연결과 측면 피드백 연결을 가진 뉴런의 1차원 격자(가운데 있는 뉴런에만 측면 피드백 연결을 보임)



<그림 6> 측면 피드백 연결의 멕시코 모자 함수

$x_1, x_2, \dots, x_p$  ( $p$ 는 입력신호 수)를 네트워크에 적용된 입력신호,  $w_{j1}, w_{j2}, \dots, w_{jp}$  를 뉴런  $j$ 의 연결강도,  $c_{j,-K}, \dots, c_{j,-1}, c_{j,0}, c_{j,1}, \dots, c_{j,K}$  ( $K$ 는 측면 상호작용의 반경)를 뉴런  $j$ 에 연결된 측면 피드백 연결강도,  $y_1, y_2, \dots, y_N$  ( $N$ 는 네트워크에서 뉴런 수)을 네트워크의 출력신호로 정의하자. 이때 뉴런  $j$ 의 출력 신호 다음

과 같이 나타낼 수 있다.

$$y_j = \varphi\left(I_j + \sum_{k=-K}^K c_{jk} y_{j+k}\right), \quad j = 1, 2, \dots, N \quad (1)$$

식(1)에서,  $\varphi(\cdot)$ 은  $y_j$ 의 값을 제한하고  $y_j \geq 0$  으로 하는 임의의 비선형 함수이다.  $I_j$  항은 입력신호에 대한 자극의 함수로서 입력신호의 가중 효과(weighted effect)에 의해 뉴런  $j$ 에 나타나는 총외부 조절을 나타낸다. 즉,

$$I_j = \sum_{l=1}^p w_{jl} x_l \quad (2)$$

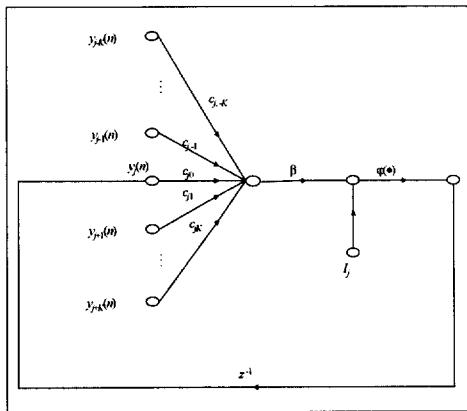
일반적으로 자극  $I_j$ 는 인덱스  $j$ 의 스무드한 함수(smooth function)이다.

비선형 방정식 식 (1)의 해는 relaxation technique을 사용하여 반복적으로 발견할 수 있다. 특히 식 (1)을 다음과 같은 점화식 (difference equation) 형태로 변환할 수 있다.

$$y_j(n+1) = \varphi\left(I_j + \beta \sum_{k=-K}^K c_{jk} y_{j+k}(n)\right), \quad j = 1, 2, \dots, N \quad (3)$$

( $n$ 은 시점)

이 때,  $y_j(n+1)$  은 시점  $n+1$ 에서 뉴런  $j$ 의 출력값이고,  $y_{j+k}(n)$  은 시점  $n$ 에서 뉴런  $j+k$ 의 출력값이다. 또한, 매개변수  $\beta$ 는 relaxation process에서 수렴 속도를 조절하는 변수이다. 식 (3)은 <그림 7>의 신호흐름 그래프와 같은 피드백시스템을 의미한다.



<그림 7> 피드백시스템으로서 relaxation equation을 묘사한 신호흐름 그래프

여기서  $z^{-1}$ 은 단위연기(unit-delay) 연산자이다. 매개변수  $\beta$ 는 시스템의 피드백 요소의 역할을 한다. 시스템은 멕시코 모자함수의 여기 혹은 억제 부분에 따른 정(+)의 피드백, 부(-)의 피드백을 모두 포함한다. 비선형 함수  $\phi(\cdot)$ 은 반응값  $y_i$ 를  $\beta$ 에 할당된 값에 따라서 특정한 형태로 안정화시키는 역할을 한다.  $\beta$ 가 충분히 크면,  $n \rightarrow \infty$  일 때  $y_i$ 의 값이 공간적으로 제한된 집단 즉, 활동 거품(activity bubble)이라 불리는 지역 집단(local cluster)에 집중되는 경향이 있다. 거품은 자극  $I_j$ 에 따른 초기 반응값  $y_i(0)$ 이 최대가 되는 점에 위치하게 된다. 활동 거품의 폭은 여기측면 상호작용과 억제측면 상호작용의 비율에 의존한다. 피드백의 형태에 따라 다음과 같이 서술할 수가 있다.

- 정의 피드백이 강해질수록 활동 거품이 점점 넓어진다.
- 한편, 부의 피드백이 생기면 활동 거품은 점점 좁아진다.

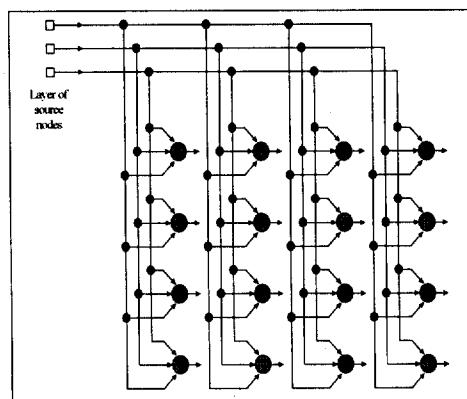
활동 거품이 형성되었다고 가정할 경우,

자극  $I_j$  가 뉴런  $j$  에 들어오면 이 때 뉴런  $j$ 의 출력값은 다음과 같이 된다.

$$y_j = \begin{cases} a, & \text{뉴런 } j \text{ 가 거품안에 있을 때} \\ 0, & \text{뉴런 } j \text{ 가 거품밖에 있을 때} \end{cases}$$

여기서  $a$ 는 뉴런  $j$ 의 입력-출력 관계를 정의하는 비선형함수  $\phi(\cdot)$ 의 극한값이다. 한편, 멕시코 모자 함수의 형태를 가진 측면 피드백에 의한 영향을 계산하기 위해서는 많은 계산이나 시간이 필요하므로 거품의 형성을 이용하여 계산량을 줄일 필요가 있다. 활동 거품안에 있는 뉴런들의 출력값은 모두 같다는 것을 이용하여 뉴런의 지형적인 이웃이라는 개념을 도입할 수 있다. 즉, 활동 거품과 마찬가지로 자극  $I_j$  가 뉴런  $j$  에 들어왔을 때 뉴런  $j$  가 중심 뉴런이거나 중심 뉴런의 이웃이면 같은 출력값을 가지게 한다. 그렇게 함으로써 측면 억제 연결을 제거할 수 있다. 또, 중심 뉴런의 이웃의 크기를 변화시킴으로써 측면 연결의 조절을 꾀할 수 있다.

알고리즘의 개발을 진행하기 위하여 뉴런의 2-차원 격자를 나타내는 <그림 8>을 고려하자.



<그림 8> 뉴런의 2차원 격자

입력 패턴의 집합을 나타내는 입력벡터를 다음과 같이 나타낸다.

$$\mathbf{x} = [x_1, x_2, \dots, x_p]^T$$

또, 뉴런  $j$  의 연결강도벡터를 다음과 같이 나타낸다.

$$\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jp}]^T, \quad j = 1, 2, \dots, N$$

가장 비슷한 입력벡터  $\mathbf{x}$ 와 연결강도벡터  $\mathbf{w}_j$ 을 찾기 위해서  $j = 1, 2, \dots, N$ 에 대해 벡터내적  $w_j \cdot \mathbf{x}$ 을 비교하여 가장 큰 값을 선택한다. 가장 큰 내적  $w_j \cdot \mathbf{x}$ 를 가지는 뉴런을 선택하여 활동거품이 형성될 위치를 결정한다. 만약 입력벡터  $\mathbf{x}$ 와 가장 비슷한 뉴런을 찾기 위하여 인덱스  $i(\mathbf{x})$ 를 사용할 경우에는 다음의 조건식을 적용하여  $i(\mathbf{x})$ 를 결정할 수 있다.

$$i(\mathbf{x}) = \arg\min_j \|\mathbf{x} - \mathbf{w}_j\|, \quad j = 1, 2, \dots, N \quad (4)$$

여기서  $\|\cdot\|$ 는 매개벡터의 유클리디언 크기를 의미한다. 식 (4)의 조건을 만족하는 특정한 뉴런  $i$  가 입력벡터  $\mathbf{x}$ 에 대한 승리획득 뉴런이다.

승리노드  $i(\mathbf{x})$ 의 지형적인 이웃을  $\Lambda_{i(\mathbf{x})}(n)$ 이라 하면,  $\Lambda_{i(\mathbf{x})}(n)$ 은 이산적인 시간  $n$ 의 함수이다. 일반적으로 이웃함수  $\Lambda_{i(\mathbf{x})}(n)$ 은 초기에는 넓지만 시간이 지남에 따라서 감소하는 함수의 형태를 가진다. 이렇게 하면 초기에는 강한 양의 측면 피드백을 가지게 되고 시간이 지남에 따라 음의 측면 피드백이 강해

지게 된다. 승리 뉴런  $i(\mathbf{x})$  주위에 이웃 함수  $\Lambda_{i(\mathbf{x})}(n)$ 를 사용하면 적은 계산량으로도 측면 피드백에 의한 활동 거품을 생성하는 것의 역할을 충분히 수행할 수 있다.

네트워크가 스스로 자기조직화를 하기 위해서는 뉴런  $j$ 의 연결강도벡터  $\mathbf{w}_j$ 가 입력벡터  $\mathbf{x}$ 와 관련되어 변화하여야 한다. 연결강도벡터  $\mathbf{w}_j$ 의 갱신공식은 Kohonen[1982]의 갱신공식을 이용한다 (그림9 참조).

$$\mathbf{w}_j(n+1) = \begin{cases} \mathbf{w}(n) + \eta(n)[\mathbf{x}(n) - \mathbf{w}_j(n)], & j \in \Lambda_{i(\mathbf{x})}(n) \\ \mathbf{w}_j(n), & \text{otherwise} \end{cases} \quad (5)$$

여기서  $\eta(n)$ 은 시점  $n$ 에서의 학습률이다. 위의 식 (5)의 갱신 공식은 획득 뉴런  $i$ 의 연결강도벡터  $\mathbf{w}_i$ 를 입력벡터  $\mathbf{x}$ 로 움직이게 한다. 모든 학습자료를 반복적으로 학습시키면 갱신 공식에 의해 연결강도벡터는 입력벡터의 분포를 따르게 된다

### Summary of SOM Algorithm

1. Initialization. 연결강도벡터(weight vector)를 초기화한다
2. Sampling. 확률을 가지는 입력분포로부터 샘플 뽑는다.
3. Similarity Matching. 시점  $n$ 에서 유클리디언 거리가 최소인 획득(winning) 뉴런을 찾는다  
 $i(\mathbf{x}) = \arg\min_j \|\mathbf{x} - \mathbf{w}_j\|, \quad j = 1, 2, \dots, N$
4. Updating. 모든 뉴런의 연결강도벡터를 갱신한다  
 $\mathbf{w}_j(n+1) = \begin{cases} \mathbf{w}(n) + \eta(n)[\mathbf{x}(n) - \mathbf{w}_j(n)], & j \in \Lambda_{i(\mathbf{x})}(n) \\ \mathbf{w}_j(n), & \text{otherwise} \end{cases}$
5. Continuation. 특성 지도 (feature map)에서 주목 할 만한 변화가 관찰되지 않을 때까지 단계 2로 계속한다

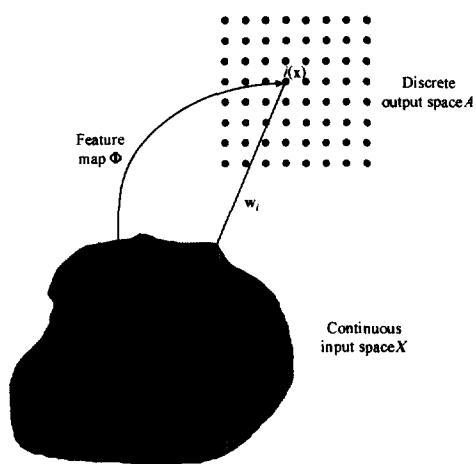
<그림 9> SOM 알고리즘의 요약

### 3.2 SOM 맵핑에 의한 패턴분류

SOM 알고리즘이 일단 수렴하면 (converge) 알고리즘에 의해 계산된 특성지도(feature map)는 입력자료의 중요한 통계적인 특성들을 나타낸다.

토플로지 즉, 연속적인 입력공간을  $X$ 로 나타내고 벡터  $x \in X$  라고 하자. 또,  $A$ 를 이산적인 출력공간이라 하자. 출력공간의 토플로지는 뉴런의 집합을 격자형태의 노드로 배열한 것이다.  $\Phi$ 는 특성지도라고 불리는 비선형 변환으로 (식 6)과 같이 입력공간  $X$ 를 출력공간  $A$ 로 맵핑(mapping)한다.

$$\Phi: X \longrightarrow A \quad (6)$$



<그림 10> 특성지도  $\Phi$ 와 승리노드  $i$ 의 연결강도벡터  $w_i$  사이의 관계

식 (3)은 입력벡터  $x$ 에 반응한 승리뉴런  $i(x)$ 의 위치를 가리키는 식 (6)의 표현으로, 입력벡터  $x$ 가 주어지면 SOFM 알고리즘은 특성지도  $\Phi$ 에 따라 출력공간  $A$ 에 있는 승

리뉴런  $i(x)$ 을 구한다. 이때 뉴런  $i(x)$ 의 연결강도벡터  $w_i$ 은 입력공간  $X$ 에서의 한점을 가리킨다.

출력공간  $A$ 에서 연결강도벡터의 집합  $\{w_j | j = 1, 2, \dots, N\}$ 로 나타나는 자기조직화(self-organizing) 특성지도  $\Phi$ 는 입력공간  $X$ 를 근사화한다. (<그림 10> 참조)

### 3.3 SOM 기반 부품 품질관리

본 연구에서 제안한 SOM신경망을 응용하여 부품 또는 원자재에 대한 수입검사 자료를 모니토링하는 과정에서 나오는 부품/원자재에 대한 다변량(품질) 특성치를 분석하여 부품/원자재의 이상을 판별할 수 있는 부품 품질관리시스템을 제시하고 부품품질관리시스템에서 활용하는 분석 방법론을 소개하고자 한다. 제안된 부품품질관리시스템은 부품 품질의 균일성을 관리하기 위한 시스템으로 부품의 특성이 균일할수록 최종 완제품의 품질 특성이 균일할 확률이 높으므로 공정 및 출하 품질관리와 더불어 부품에서부터 출하까지의 총체적인 품질을 통합적으로 관리할 수 있기 위한 기초적인 역할을 할 수 있다.

#### 3.3.1 SOM을 이용한 부품수입검사 자료 패턴분석

SOM 네트워크로 입력자료를 학습시키면 입력자료에 대해 패턴분석을 한 후 그 결과로서 연결가중치 벡터를 생성한다. SOM의 특성에 따르면 연결가중치 벡터는 입력자료의 정보를 가지고 있으므로, 두 집합의 입력자료가 서로 동일한지를 알기 위해서는 연결가중치 벡터를 비교하는 것이 훨씬 용이하다. 이것은 입력 패턴의 경우 너무 많은 수의 자료를 포함하고 있기 때문에 입력자료가

어떤 정보를 가지고 있는지 분석하기가 어렵기 때문이다. 반면, 연결가중치벡터는 입력자료의 정보를 포함하면서 입력 자료보다는 훨씬 적은 수의 벡터자료만을 가지고 있기 때문이다.

현재 입고된 부품/원자재의 품질 상태를 판단하기 위해서는 우선적으로 수입검사후 부품품질이 합격했을 때의 관측치 벡터들을 수집하여 SOM네트워크로 학습시킨다. 학습이 끝나면 각 출력노드  $j$ 의 연결강도벡터들은  $\mathbf{w}_j^{Accp}, j=1, 2, \dots, N$  ( $N$ 은 출력노드의 총개수)로 나타난다.

또한, 현재 입고된 부품/원자재에서 얻어지는 관측치 벡터를 SOM네트워크로 학습시키면 각 출력노드  $j$ 의 연결강도벡터들이

$$\mathbf{w}_j^{Run}, j=1, 2, \dots, N$$

로 나타난다.

학습된 연결강도벡터  $\mathbf{w}_j^{Run}, j=1, 2, \dots, N$  을

입력 패턴  $\mathbf{x}_j$ 로 하여 연결강도벡터가  $\mathbf{w}_j^{Accp}$ 인 SOM네트워크에서의 승자획득노드를 구한다. 이 과정은  $N$ 개의 연결강도벡터들에 대한 승자획득노드만을 판별할 뿐 SOM 학습때처럼 출력노드의 연결강도값을 변화시키지 않는다.

만약 현재 입고된 부품/원자재가 합격 수준이라면 각 입력벡터  $\mathbf{x}_j$ 가 입력되었을 때 승자노드는 출력노드  $j$ 가 될 확률이 매우 크다. 이것은 현재의 부품/원자재가 합격 수준일 때 현재의 관측치와 기준(즉, 합격) 관측치의 두 집합이 제공해 주는 정보는 같은 것이므로 SOM 네트워크로 학습을 시킨 후의 두개의 연결가중치 벡터 또한 같은 것이

기 때문이다. 즉, SOM에서 맵핑을 하는 함수가 서로 같은 것이 되기 때문이다. 따라서 각 입력 벡터들이 차례로 주어질 경우, 만약 현재 부품이 합격수준의 상태라면 각 출력노드가 승자노드가 되는 횟수는 1에 가까운 값으로 비슷해지게 된다.

그러나 부품이 합격수준과 다른 이상상태, 즉 관측치 벡터의 평균이 변하였거나 각 관측치 요소간의 상관관계가 변하였을 경우, 각 노드가 승자노드가 되는 횟수는 서로 달라지게 된다. 본 논문에서는 이러한 변화를 Shanon의 정보이론(Information Theory)에 근거한 엔트로피(entropy)를 응용하여 정량화하였다.

### 3.3.2 엔트로피에 의한 패턴의 동일성 분석

앞에서 언급한 바와 같이, 두개의 서로 다른 집합의 입력자료가 동일한지를 비교하는 것은 입력자료의 정보가 동일한지를 비교하는 것이므로 Shanon의 정보이론을 이용할 수 있다.

이산적인 값을 갖는 확률변수  $X$ 가 있을 때, 확률이  $p_k$ 인 이벤트  $x = x_k$ 를 관찰한 후에 얻는 정보의 양을 다음 식(7)과 같이 정의할 수 있다.

$$I(x_k) = \log\left(\frac{1}{p_k}\right) = -\log p_k \quad (7)$$

여기서, 로그의 밑은 임의의 수이고, 자연로그이면 정보의 단위는 내트(nats)이고 밑이 2인 로그이면 정보의 단위는 비트(bits)이다. 로그의 밑에 관계없이 식(7)의 정의는 다음과 같은 특성을 나타낸다.

$$1) I(x_k) = 0 \quad \text{for } p_k = 1$$

즉, 이벤트의 결과를 확실하게 알고 있다면 이벤트가 생겼을 때 얻을 수 있는 정보는 없다.

$$2) I(x_k) \geq 0 \quad \text{for } 0 \leq p_k \leq 1$$

$$3) I(x_k) \geq I(x_i) \quad \text{for } p_k \leq p_i$$

즉, 이벤트가 일어날 확률이 적을수록 이벤트가 생김으로써 더 많은 정보를 얻을 수가 있다.

정보  $I(x_k)$ 의 양도 확률  $p_k$ 를 가지는 이산 확률 변수이므로 정보의 평균값은 다음 식 (8)과 같고,  $H(x)$ 를 유한 개수의 이산적인 값을 가지는 확률변수  $X$ 의 엔트로피라고 부른다. 엔트로피는 각 이벤트가 전달하는 정보의 평균적인 양을 수치화한 것이라고 할 수 있다.

$$\begin{aligned} H(x) &= E[I(x_k)] = \sum_{x_k \in A} p_k I(x_k) \\ &= - \sum_{x_k \in A} p_k \log_2 p_k \end{aligned} \quad (8)$$

$$0 \leq H(x) \leq \log_2 |A|$$

여기서  $A$ 는  $x$  가 취할 수 있는 값의 영역이며,  $|A|$ 는  $A$ 의 크기이다. 만약  $p_k$  가 모두  $1/|A|$ 로 동일하면 엔트로피가 최대값인  $\log_2 |A|$  가 되지만,  $x$ 에 따라서  $p_k$ 의 값이 서로 다르다면 엔트로피는 작아지게 된다.

엔트로피는 다음 식(9)에 의해 0과 1사이의 값으로 정규화될 수 있고 본 논문에서는 이러한 정규화된 엔트로피 값을 이용하여 서로 다른 2개의 연결가중치 벡터가 가지는 정보의 동일성 수준을 평가하여 정량화하였다.

$$Entropy^{normal} = \frac{\log_2 |A| - Entropy}{\log_2 |A|} \quad (9)$$

## 4. 실험적 연구결과

### 4.1 부품품질관리시스템의 프로토타입 설계

3장에서 제안한 SOM기반 패턴분석 방법론을 가지는 부품품질관리시스템의 프로토타입을 Visual Basic을 이용하여 개발하였다. 앞에서 언급한 바와 같이, SOM은 비지도 학습 알고리즘을 가지므로 네트워크 구조, 학습률을 중점적으로 고려하였다. SOM 네트워크의 구조란 SOM의 출력 노드의 구조를 의미하는 것으로, SOM의 출력 노드는 격자의 형태로 되어 있고 격자는 1차원, 2차원, ..., N차원 등 모든 차원의 형태가 가능하다. 격자의 차원뿐만 아니라 노드의 개수도 중요한 고려 사항인데 이것은 출력 노드의 개수에 따라 특성지도의 형태가 바뀌기 때문이다.

본 연구에서 개발한 부품품질관리시스템의 프로그램에서는 격자의 차원을 2차원으로 하고 노드수는 10개이하로 제한하였다. 이것은 SOM 맵핑의 그래픽 처리로 인한 속도 저하가 우려되고, SOM의 주된 기능이 입력패턴의 정보를 압축 저장하여 패턴을 분석하는 것이므로 출력노드의 수가 많아지면 의미가 없어지기 때문이다[Kohonen, 1990].

일반적으로 신경회로망을 학습시킬 때 신경회로망의 파라메터 선택은 네트워크가 수렴하는 데 큰 영향을 주지만 파라메터의 선택에 관한 이론적인 방법은 아직 존재하지 않는다. SOM 네트워크의 경우 파라메터

는 학습률  $\eta$  과 이웃 함수(neighborhood function)  $\Lambda_i$  이 있고, 이 두 파라메터가 특성지도 형성에 큰 영향을 준다. 본 논문에서 개발한 SOM 네트워크에서는 두 파라메터를 다음과 같이 학습단계  $n$  의 함수로 만들었다.

$$\eta(n) = \begin{cases} \eta(n-1) - 0.0001, & n \leq 1000 \\ \eta(n-1) - 0.0002, & 1000 < n \leq 5000, \eta(0) = 1 \\ \eta(n-1) - 0.000009, & 5000 < n \leq 15000 \\ 0.01, & n > 15000 \end{cases}$$

$$\Lambda_i(n) = \begin{cases} \left[ \frac{1000}{n} \times \text{격자의 뉴런수} \right], & n \leq 1000 \\ 0, & \text{otherwise} \end{cases}$$

즉, 알고리즘의 초기 단계에서 주로 연결강도벡터  $w_j(n)$ 의 지역적인 순서화가 이루어지므로  $\eta$ 의 값을 크게 하여 특성지도가 잘 형성되게 한다. 알고리즘의 나머지 단계에서는 주로 특성지도의 미세 조정이 필요하다. 연결강도벡터  $w_j$  가 지역적인 순서화를 이루기 위해 이웃 함수  $\Lambda_i(n)$ 의 값을 초기에는 모든 뉴런을 포함할 수 있는 큰 값을 가지고 학습 단계에 따라 값이 줄어들게 한다 [Kohonen, 1988, 1990]

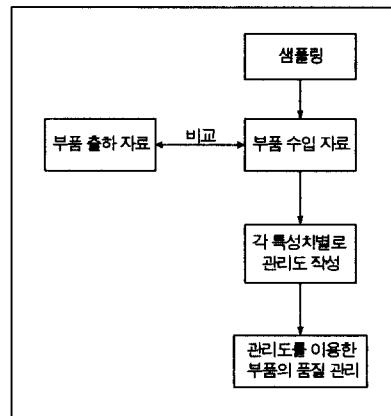
학습 여부는 연결강도의 변화량으로 구분을 할 수가 있다. 연결강도의 변화량의 값이 일정하면 SOM 네트워크가 수렴한 것으로 간주하였다.

## 4.2 부품 수입검사 사례

A 전자회사의 경우 제품을 만드는데 필요한 1000여 종류의 부품을 협력업체로부터 납

품받는다. 각 부품마다 수입하는 로트(lot)는 약 50 박스 정도이고 1 박스에는 약 100개 정도의 부품이 있다. 즉, 각 부품의 로트 크기는 약 5000개 정도이다. 또한, 매달 약 2500회 정도 부품을 수입하고 있는 실정이다.

하나의 로트마다 샘플로 20개 부품을 별도로 가지고 있고 협력업체로부터 샘플에 대해 최대 15개 정도의 측정치를 부품에 대한 품질자료로 받고 있다. A전자회사에서는 샘플에서 2-3개와 로트에서 비파괴 검사로 약 10여개 부품을 임의로 선택하여 부품에 대한 품질검사, 즉 수입검사를 실시하고 있다. 현재 A전자회사에서 부품수입검사를 하고 있는 체계는 그림11과 같다.



<그림 11> A전자회사의 부품수입검사

<그림 11>을 보면 A 전자회사의 경우 협력업체로부터 받은 부품출하자료를 전혀 이용하지 않고 있는데, 그림에서 두 자료의 비교는 사람이 두 자료를 분석도구없이 직감적으로 하고 있는 것을 의미한다. 또, 부품의 품질관리를 위한 관리도를 작성할 때에도 부품에서 중요한 특성치 하나만을 단변량으로 관리하거나 여러 특성치 각각에 대해 관리도

를 작성하고 있는 실정이다. 즉, A전자회사는 부적절한 방법에 의한 부품의 품질관리를 하고 있고 협력업체의 자료를 전혀 활용하지 못하는 문제점을 지니고 있다.

본 연구는 A전자회사의 부품 자료중 Switching Trans 자료의 4가지 특성치에 대한 부품 출하자료(20개)와 수입검사 자료(20개)에 대해 실험적으로 수행하였다. (<그림12> 참조).

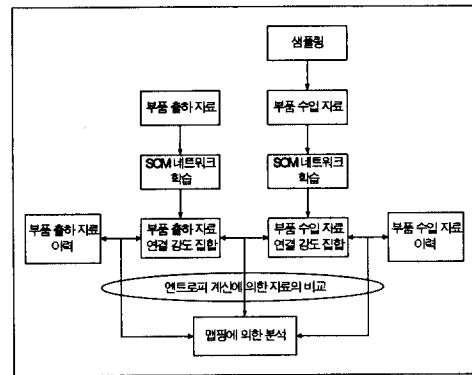
### 4.3 부품품질관리시스템의 활용

A 전자회사의 부품수입검사 업무에 SOM 신경망에 기반한 부품품질관리시스템을 활용하는 다음과 같은 적용Flow을 제안한다.

| 협력업체의 부품출하검사 자료 |     |      |      | A 전자회사의 부품수입검사 자료 |      |      |       |
|-----------------|-----|------|------|-------------------|------|------|-------|
| 1.9             | 4.9 | 6.51 | 12.9 | 1.87              | 4.39 | 6.17 | 12.94 |
| 1.9             | 4.8 | 6.51 | 12.9 | 1.90              | 4.59 | 6.27 | 12.10 |
| 1.88            | 4.8 | 6.52 | 12.6 | 1.90              | 4.30 | 6.26 | 12.75 |
| 1.88            | 4.7 | 6.47 | 12.7 | 1.93              | 4.30 | 6.12 | 12.09 |
| 1.87            | 4.7 | 6.41 | 12.5 | 1.82              | 4.73 | 6.36 | 11.52 |
| 1.9             | 4.8 | 6.49 | 12.7 | 1.88              | 4.74 | 6.09 | 12.91 |
| 1.88            | 4.8 | 6.42 | 12.6 | 1.90              | 4.90 | 6.23 | 12.09 |
| 1.87            | 4.8 | 6.44 | 12.6 | 1.85              | 4.88 | 6.11 | 11.74 |
| 1.87            | 4.7 | 6.39 | 12.7 | 1.90              | 4.78 | 6.23 | 11.79 |
| 1.92            | 4.9 | 6.54 | 12.9 | 1.83              | 4.55 | 6.09 | 12.78 |
| 1.87            | 4.7 | 6.37 | 12.6 | 1.92              | 4.89 | 6.15 | 11.91 |
| 1.85            | 4.6 | 6.33 | 12.5 | 1.85              | 4.64 | 6.22 | 12.04 |
| 1.86            | 4.7 | 6.36 | 12.5 | 1.80              | 4.92 | 6.15 | 12.00 |
| 1.88            | 4.7 | 6.42 | 12.7 | 1.88              | 4.30 | 6.30 | 12.08 |
| 1.86            | 4.7 | 6.35 | 12.6 | 1.91              | 4.83 | 6.25 | 11.61 |
| 1.85            | 4.7 | 6.34 | 12.5 | 1.85              | 4.56 | 6.09 | 12.09 |
| 1.9             | 4.7 | 6.51 | 12.8 | 1.80              | 4.53 | 6.11 | 12.04 |
| 1.87            | 4.7 | 6.4  | 12.7 | 1.87              | 4.84 | 6.17 | 11.58 |
| 1.89            | 4.8 | 6.5  | 12.8 | 1.85              | 4.82 | 6.21 | 12.37 |
| 1.88            | 4.8 | 6.45 | 12.6 | 1.87              | 4.34 | 6.28 | 11.64 |

<그림 12> 부품 자료

<그림 13>에서와 같이, 우선 부품에 대한 샘플링을 통하여 부품 수입검사자료를 얻고, 협력업체로부터 받은 부품출하자료와 수입검사 자료를 부품 품질관리 시스템에 입력한다. 부품 수입검사 자료와 출하자료를 부품 품질관리시스템을 이용하여 SOM 신경망 학습을 시키기 위해, 출력노드 개수 9와 학습 종료조건 0.1을 입력하였다.



<그림 13> SOM 기반 부품품질관리시스템의 활용

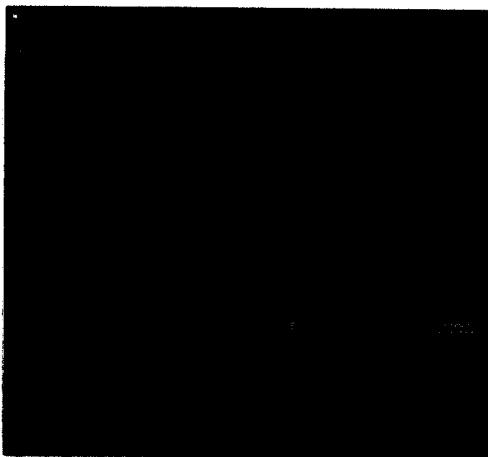
출력노드 개수가 커질수록 입력자료에 대한 정보를 많이 포함하고 있지만 대신에 연결강도벡터의 수가 많아지는 반면 출력노드 개수가 너무 적으면 입력자료에 대한 정보를 많이 잃어버리므로 적절한 수의 출력노드 개수를 정하여야 하는데, 여기서는 변수개수인 4보다 많은 9를 결정하였다. 종료조건은 경험상 적절한 값인 0.1을 결정하였다.

연속적인 시점인 N-2시점, N-1시점, N시점에서의 부품출하자료와 부품수입검사자료에 대해 SOM 네트워크의 학습이 끝나면, <그림 14>와 같은 두 자료에 대한 연결강도집합 파일이 생성된다.

| 부품출하자료의 연결강도벡터 |      |      |       | 부품수입자료의 연결강도벡터 |      |      |       |
|----------------|------|------|-------|----------------|------|------|-------|
| 4,3            |      |      |       | 4,3            |      |      |       |
| 1.91           | 4.87 | 6.52 | 12.90 | 1.87           | 4.81 | 6.22 | 11.65 |
| 1.87           | 4.70 | 6.42 | 12.70 | 1.87           | 4.90 | 6.18 | 12.00 |
| 1.88           | 4.79 | 6.44 | 12.61 | 1.87           | 4.50 | 6.15 | 12.84 |
| 1.90           | 4.77 | 6.50 | 12.77 | 1.90           | 4.30 | 6.21 | 12.09 |
| 1.88           | 4.80 | 6.52 | 12.60 | 1.87           | 4.37 | 6.28 | 11.70 |
| 1.88           | 4.79 | 6.44 | 12.61 | 1.87           | 4.36 | 6.27 | 11.68 |
| 1.86           | 4.68 | 6.36 | 12.53 | 1.85           | 4.59 | 6.18 | 12.13 |
| 1.88           | 4.80 | 6.45 | 12.60 | 1.87           | 4.37 | 6.27 | 11.71 |
| 1.88           | 4.80 | 6.42 | 12.60 | 1.87           | 4.34 | 6.28 | 11.64 |

<그림 14> 연속적인 3시점의 부품출하 및 수입검사 자료에 대한 연결강도 벡터

N시점의 부품출하 및 수입검사자료의 연결강도벡터를 이용하여 <그림15>와 같은 엔트로피에 의한 SOM맵핑결과를 얻을 수 있다.



<그림 15> N시점 부품 출하 및 수입검사자료의 SOM 맵핑결과

<그림 15>에는 다섯개의 맵핑 결과가 있는데 왼쪽 상단 맵핑은 20개의 부품 출하자료를 9개의 출력노드로 맵핑했을때의 패턴분석 결과이고, 오른쪽 상단의 맵핑은 20개의 부품수입자료를 9개의 출력노드로 맵핑했을 때의 패턴분석 결과이다. 하단 왼쪽 첫번째의 맵핑은 부품출하자료의 N시점의 연결강도벡터를 입력패턴으로 설정하고 N시점의 부품수입자료의 연결강도벡터를 SOM 네트워크의 연결강도벡터로 했을 때 출력 노드의 출력값이 기준값, 즉, Criteria가 0.9이상인 것을 맵핑한 결과이다. 여기서 Criteria는 정규화된 엔트로피 값을 나타내고, Criteria가 1에 가까울수록 두개의 자료가 100% 동일한 것을 의미한다. 이러한 맵핑은 부품수입자료를 기준 정보로 사용하여 협력업체가 제공한 부품출하자료가 얼마나 왜곡된 자료인지를,

즉 협력업체의 부품출하검사자료에 대한 신뢰성을 평가하는 것이다.

두 자료의 연결강도벡터가 비슷할수록 맵핑에서 9개의 모든 박스 (즉, 출력노드)가 동일한 색깔을 가지며 박스 안의 값이 커진다. 여기서 박스 안의 값은 각 박스에 속하는 입력패턴의 개수를 의미한다. 반면 두 자료의 연결강도벡터가 다르면 동일한 색깔을 가지는 박스의 수가 작고 박스 안의 값도 작아진다.

<그림 15>의 하단의 나머지 2개의 맵핑은 Criteria를 0.8, 0.7로 달리하였을 때 두 집합이 맵핑된 결과이다.

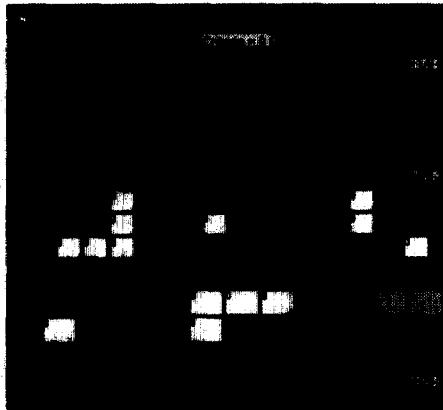
이러한 하단 맵핑 결과로부터, N시점의 출하 및 수입검사 자료는 동일한 패턴을 가짐을 알 수 있고, 따라서 협력업체의 출하검사가 신뢰성이 있다고 판정할 수 있다.

앞에서 언급했듯이 A전자회사의 경우 매월 약 2500회의 부품이 수입되는데 부품품질관리시스템을 통하여 특정 협력업체의 부품출하검사의 자료가 신뢰성이 있다고 판정되면 이 협력업체의 부품에 대해서는 수입검사의 횟수를 줄이고 부품출하검사 자료만으로 품질관리를 함으로써 비용과 시간의 단축을 가져올 수 있다.

한편, 부품의 품질이 균일하면 완제품의 품질 변동을 줄일 수 있으므로 수입된 부품의 로트간 품질이 균일한지를 지속적으로 모니터링 할 필요가 있다. 그러므로, 관리도처럼 로트간의 품질을 확인하기 위하여 부품품질관리시스템에서도 시간 변화에 따른 로트간의 품질정보를 비교할 수 있다. 즉, 연속적인 3 시점인 N-2,N-1, N의 협력업체의 부품출하자료와 전자회사의 부품수입검사자료의 연결강도벡터 집합을 <그림 15>와 동일한 방식으로 적용하면 <그림 16>의 맵핑결과를

얻을 수 있다.

완제품 품질과는 다른, 즉 균일하지 않을 가능성이 크다고 판단할 수 있다.



<그림 16> 연속적인 3시점 로트에 대한 패턴의 이력분석

상단 3개의 맵핑은 ( $N-2, N-1, N$  시점의) 로트간 부품 출하검사자료의 동일성을 분석한 것으로  $N/N-1$ 의 의미는 시점  $N-1$ 의 자료를 기준으로 하였을 때 시점  $N$ 의 자료가 가지는 정보를 맵핑한 것을 말한다. 하단 3개의 맵핑은 ( $N-2, N-1, N$  시점의) 로트간 부품수입검사자료의 동일성을 분석한 것이다. 가운데 3개의 맵핑은 부품수입검사자료를 기준으로 했을 때 부품출하검사자료의 정보를 비교한 것이다.

부품출하검사자료의 맵핑결과로부터  $N-2, N-1, N$  시점의 3개의 로트간에는 부품의 품질이 균일함을 알 수 있다. 그러나 부품수입검사자료의 맵핑으로부터 시점  $N$ 과 시점  $N-1$ , 시점  $N$ 과 시점  $N-2$ , 시점  $N-2$ 와 시점  $N-1$ 의 로트간의 품질은 균일하지 않은 것으로 나타난다. 즉, 샘플링 검사에 의해 얻어진 부품수입검사자료에 따르면 시점  $N$ 의 로트는 그 이전의 로트와 품질상태가 다른 것으로 나타난다. 따라서 시점  $N$ 의 부품을 제품을 만드는 제조공정에 투입할 경우 이전의

## 5. 결 론

최근 예측 분야에 있어서 신경회로망을 응용한 연구가 활발히 진행되고 있고 연구 결과 기존의 통계적인 기법보다 성능이 우월함이 증명되고 있다. 반면, 패턴분석분야에 있어서는 통계적 기법이 많이 적용되고 있는데, 본 논문에서는 패턴분석에 있어서도 SOM 신경망이 효과적으로 적용될 수 있음을 보여주고 있다.

SOM신경망을 이용한 부품품질관리시스템은 부품의 품질 특성치가 단변량일 경우는 물론이고 다변량일 경우에도 부품품질 특성치 변화에 대한 간단하고 정확한 패턴분석이 가능하다. 이러한 패턴분석이 다변량 특성치의 수집과 거의 동시에 이루어질 수 있는 시스템을 기업내에 구축한다면 실시간으로 부품 품질의 이상을 검출할 수 있게 되므로 완제품의 불량률을 줄이는 데 크게 공헌하리라 기대된다.

본 논문에서 제안한 SOM 신경망에 기반한 패턴분석 방법론은 제조공정에서의 공정 특성치에 대한 패턴분석에도 적용할 수 있다. 일반적으로 제조공정으로부터 나오는 특성치 데이터는 무수히 많고 또한 다변량의 데이터이다. 최근 제조공정에서는 자동화시스템에 의해 거의 모든 공정 데이터들을 수집하고 있는 반면 방대한 양의 데이터로 인해 자료의 저장에 급급한 상황이다. 여기에 자료의 분석 및 가공을 위한 도구로서 SOM을 사용할 수 있다. SOM을 사용하여 특성치 자료들의 패턴을 분석할 뿐만 아니라 원

래의 자료 대신 SOM 네트워크의 연결강도 벡터를 저장함으로써 자료의 양도 줄이는 일 거양득의 효과를 얻을 수 있을 것이다.

[10] Kohonen, T., "Self-organizing map", *Proceedings of the IEEE*, Vol. 78, 1990, pp.1464-1480.

## 참고문헌

- [1] 박민용, 최항식 역, “뉴로 컴퓨터”, 대영사, 1991
- [2] 배도선, “최신 통계적 품질관리”, 영지문화사, 1996
- [3] Alt, F. B., “Multivariate Quality Control”, *The Encyclopedia of Statistical Science*, John Wiley, 1992
- [4] Crosier, R. B., “Multivariate Generalizations of Cumulative Sum Quality-control Schemes”, *Technometrics*, Vol.30, 1988, pp.539-549
- [5] Jackson, J. S., “Quality Control Methods for Several Related Variables”, *Technometrics*, Vol.1, 1959, pp.359-377
- [6] James A. Freeman and David M. Skapura, “Neural Networks-Algorithms, Applications, and Programming Techniques”, Addison-Wesley, 1991
- [7] Jürgen Schurmann, Pattern Classification - A Unified View of Statistical and Neural Approaches, John Wiley & Sons, 1996.
- [8] Kohonen, T., “Self-organized formation of topologically correct feature maps”, *Biological Cybernetics*, Vol. 43, 1982, pp.59-69.
- [9] Kohonen, T., “An introduction to neural computing”, *Neural Networks* 1, 1988, pp.3-16.