

## 전자제품생산의 조정공정을 위한 지능형 제어알고리즘

### Intelligent Control Algorithm for the Adjustment Process During Electronics Production

장석호, 구영모, 고택범, 우광방  
(Seok-Ho Jang, Young-Mo Koo, Taek-Beom Koh and Kwang-Bang Woo)

**Abstract :** A neural network based control algorithm with fuzzy compensation is proposed for the automated adjustment in the production of electronic end-products. The process of adjustment is to tune the variable devices in order to examine the specified performances of the products ready prior to packing. Camcorder is considered as a target product. The required test and adjustment system is developed. The adjustment system consists of a NNC(neural network controller), a sub-NNC, and an auxiliary algorithm utilizing the fuzzy logic. The neural network is trained by means of errors between the outputs of the real system and the network, as well as on the errors between the changing rate of the outputs. Control algorithm is derived to speed up the learning dynamics and to avoid the local minima at higher energy level, and is able to converge to the global minimum at lower energy level. Many unexpected problems in the application of the real system are resolved by the auxiliary algorithms. As the adjustments of multiple items are related to each other, but the significant effect of performance by any specific item is not observed. The experimental result shows that the proposed method performs very effectively and are advantageous in simple architecture, extracting easily the training data without expertise, adapting to the unstable system that the input-output properties of each products are slightly different, with a wide application to other similar adjustment processes.

**Keywords :** neural network, control algorithm, electronics production, auxiliary fuzzy algorithms, multi-adjustment process

#### I. 서론

다양한 전자제품의 생산은 단품종 소형화 및 경량화 추세이며, 따라서 고집적·고정밀의 기술이 요구된다. 또한, 다기능 및 고성능화로의 급변하는 추이는 제품의 life cycle이 단축되고, 단품종 소량생산, 신소재 개발 및 신제조기술의 단기화가 요구된다. 따라서, 제품생산기술의 자동화에 대한 요구가 높아지면서, 생산공정, 반송 및 물류의 자동화가 진행되고 있다. 생산공정 자동화는 주로 조립공정에 치중되어 있거나 단위공정장비의 자동화와 관련되고 있다. 더 나아가 CALS & CIM 구축에 의해 제품의 기획 단계에서부터 판매 및 사후관리에 이르는 전 과정의 통합관리시스템 구축이 현실화되고 있다.

검사조정공정의 자동화는 생산공정시스템 자동화의 완성을 위해 필수적 과제 중의 하나이다. 시각정보를 기준으로 제품의 완성도 및 성능을 평가하는 TV, VTR, 캠코더, 평판 디스플레이 등과 같은 전자제품의 경우, 아직도 작업자의 시각판정과 수작업에 의한 검사 조정에 의존한다. 이러한 작업과정은 장시간의 반복작업이 수행되며, 따라서 작업자의 피로도를 가중시켜 오동작 유발 가

능성이 높으며, 신속한 작업수행을 위해서는 작업자의 오랜 경험과 숙련이 요구된다. 따라서, 조정공정의 자동화는 공정의 효율성과 제품 품질향상에 절대적 효과를 기대할 수 있다. 본 연구에서는 캠코더의 최종 생산단계에서 조정공정 자동화를 수행하고자 한다. 캠코더는 영상과 음성신호의 출력에 의한 제품의 특성상 다양한 미세신호의 조정이 그 대상이 된다. 화면조정에서 색깔의 농도, 선명도, 명암 등의 조율은 각각 완전히 독립적이 아니거나 상호 간섭적인 특성을 나타내기도 한다. 이러한 시각정보를 처리 가능한 계측정보(전압, 주파수 등)로 변환하여 이를 근거로 제품 내의 가변소자를 조정하여 제품특성규정을 충족시키도록 한다.

자동조정알고리즘 구현을 위해 신경회로망 기법이 도입되었다. 신경회로망이 자동제어에 이용되기 위한 제어구조와 이에 따른 기대효과에 대하여는 많은 연구가 진행되었다[1]~[4]. 검사조정 자동화를 위한 연구는 산업용의 제한된 분야에서 수행되고 있으며, 그 연구 결과가 공개되기는 쉽지 않다. 김형철 등[5]은 수작업에 의한 공정진행을 컴퓨터에 의한 자동조정으로의 변환, 그리고 그 시스템 구축에 의미를 두고 있으며, 적용대상은 Okamura 등[6]과 마찬가지로 텔레비전 수상기로 하고 있다. 여기에 지능형 제어기법을 도입하기 시작하여 구영모 등[7]은 신경회로망 기법을, 정태신 등[8]은 펴지논리제어기를 도입하였다. 이승구 등[9]은 입출력 관계가 불확실한 가전제품을 대상으로 하여 신경회로망 간접적

접수일자 : 1997. 8. 14., 수정완료 : 1998. 7. 13.

장석호, 우광방 : 연세대학교 기계전자공학부 전기공학전공

구영모 : 삼성전자(주) 생산기술센터 자동화연구소

고택범 : LG 하니웰(주) 연구소

※ 본 논문은 선도기술개발사업(G7과제)의 세부과제로서 삼성전자(주)의 지원으로 수행되었습니다.

응제어기를 도입하였다. [7]-[9]의 대상시스템은 비선형성이 높고 계측신호의 추출이 난해하며 초기상태의 정보가 없을 뿐 아니라 작업자의 경험에 크게 영향을 받는다. 이를 해결하기 위한 신경회로망 기법과 퍼지논리제어기의 도입은 그 우수성이 입증되었으나, 학습시간이 오래 걸리거나 퍼지규칙 생성을 위한 지식기반 구축을 위한 노력이 요구된다. 대상 제품의 조정소자가 다수의 납품업체로 납품 받기 때문에 그 특성이 납품업체마다 다소 차이를 나타내며, 그 약간의 차이가 미세조정에는 큰 영향을 나타낸다. 이와 같은 제품이 혼합되어 유입될 경우 온라인 학습의 문제점이 부각될 수 있으며, 모든 경우에 대하여 숙련된 작업자로부터 지식기반을 구축하는 것은 쉽지 않은 일이다.

본 논문에서는 신경회로망 기법을 기반으로 하고 있으며, 학습용 데이터의 축소를 위하여 조정영역을 조정점 근처의 미세조정영역과 그 밖의 영역으로 나누어 두 개의 신경회로망 제어기를 설계하였다. 조정소자 특성변화에 대하여는 온라인 학습을 수행하는 대신에 퍼지 보상기법에 의해 제어신호를 보상하도록 하여, 대상 조정항목인 가변소자가 납품업체나 시기에 따라 그 입력력 특성이 변동할 수 있는 가변성에 대하여 용이하게 대처할 수 있도록 하였다. 물론 제어신호 보상을 위한 퍼지규칙은 특별한 로직을 갖고 있지는 않다. 다만 조정공정의 특성상 구동 모터의 회전동작시 overshoot을 방지하여 역회전시 발생하는 시간손실을 최소화하는 것이다. 이는 대상소자의 특성변화에 기인하기도 하지만 결정적으로는 구동모터의 기구적 결함에 기인한다.

신경회로망 제어기에 의한 자동조정의 이점은 대상조정제품 및 조정항목 특성에 대한 축적된 지식이 요구되지 않는다는 것이다. 간단히 추출된 학습 데이터를 이용하여 조정항목의 특성을 손쉽게 모델링할 수 있다. 기존의 조정방법은 대상소자의 특성 규정을 위해 구간별 선형화를 통해 근사식을 산출함으로서 입력상태에 대응하도록 하였다. 이 경우 대상소자의 특성 변화에 능동적으로 대처할 수 있는 능력이 부족하며, 대상소자의 특성이 변할 때마다 새로운 근사식을 생성해야하는 번거로움이 발생한다. 그리고, 상호 간섭적인 특성을 나타내는 두 개 이상의 조정대상항목에 대하여 동시조정을 시도함으로서 조정시간의 단축을 유도하고자 한다. 이는 곧 제품의 생산성과 밀접한 연관을 갖고 있다. 비선형성에 대한 적응 능력이 높은 신경회로망에 의한 다중조정(multi-adjustment)공정 응용을 통해 제시된 조정기법의 장점이 입증된다.

한편, 실시스템 적용시 발생되는 모터 기구부의 기능 때문에 신경회로망 제어기의 제어신호 오차보상이 요구된다. 물론, 모터 기구부에 기인하는 출력오차도 개발된 신경회로망 제어기에 의하여 보상시킬 수 있다. 실시간에 의한 온라인 학습이 요구되고, 이에 소요되는 시간은 공정 수행시간에 결정적인 지장을 초래하게 된다. 조정공정은 수초 내에 완료되어야 하며, 연속적으로 대상 제품이 유입되며 동시에 계측부가 상하로 압착되어 계측신호 및 기준신호가 송수신된다. 이와 같이 연속적이고 신

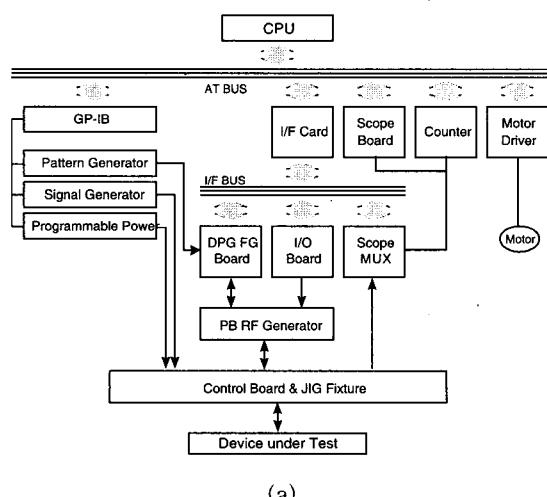
속한 처리가 요구되는 공정 특성상 신경회로망의 초기학습과 퍼지 규칙에 의한 온라인 보상기법이 최적의 공정흐름을 확인할 수 있다. 모터 기구부의 문제점 분석결과 일반화된 규칙을 유도할 수 있었다. 따라서 퍼지규칙에 근거한 보상 알고리즘을 신경회로망 제어기와 접목하여 보다 지능화된 제어기를 구성한다.

본 논문은 캠코더 생산라인의 최종 단계에서 수작업으로 수행되던 검사조정 공정의 자동화를 위하여, 지능형 제어기법인 신경회로망과 퍼지 알고리즘을 이용하였다. 작업자의 시각판정에 의한 검사조정은 장시간 작업할 경우 눈의 피로도가 가중되어 작업 능률이 떨어질 뿐 아니라, 신속한 공정수행을 위해서는 작업자의 높은 숙련도를 요구한다. 한편, 제시된 지능형 제어알고리즘을 통한 자동조정 결과는 숙련된 작업자의 작업 속도보다 다소 빠르며, 두 가지 이상의 검사조정 항목에 대한 동시 조정이 가능하여 생산성 향상을 기대할 수 있다.

## II. 검사조정시스템(test & adjustment system)

완제품의 성능검사 및 조정공정을 위한 검사조정시스템이 캠코더를 대상으로 설계되었다. 자동검사조정시스템의 요소기술로는 신호계측, 제어기설계, 정밀 위치제어, function 검사조정, 그리고 지능형 검사조정기술 등이 포함된다. 세부기능에는, regression 해석, FFT, 임의의 파형 탐색, 검파기, 비교기, window 비교기, 파형의 일정 영역에서 상한 및 하한치 설정, 파형 탐색에서 잡음수준 지정기능, 파형 기억 및 재생 등이다. 검사조정시스템의 하드웨어 구성은 그림 1(a)에 보여준다.

숙련된 작업자는 현장에서 드라이버를 이용하여 각 조정점을 조정하여 측정점으로부터 계측된 파형을 관측하여 목표점에 조준한다. 따라서, 자동검사조정을 위한 시스템 기능의 구조는 측정점으로부터 계측신호를 검색하여 필요한 정보 전달을 수행하는 계측부, 전달된 정보를 취득하여 측정치와 목표치를 비교 판단하여 필요한 제어 입력 즉, 드라이버 구동펄스값을 산출하는 제어부, 그리고 여기서 출력치는 제어입력의 처리에 의해 실제 조정이 수행되는 드라이버 구동부로 구성된다. 기능별 검사조정시스템의 블럭선도는 그림 1(b)와 같다.



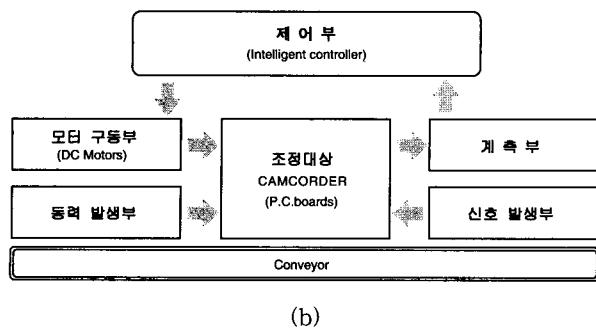


그림 1. 검사조정시스템의 (a) 하드웨어 구성과 (b) 기능 블럭선도.

Fig. 1. Test & adjustment system (a) H/W (b) functionality block diagram.

- 1) 동력/신호발생부 : 캠코더 P.C.board를 동작시키는데 필요한 전원과 각종 신호를 공급하는 기능을 수행하며, power supply(programmable), pattern generator, signal generator, PBRF generator 등으로 구성된다.
- 2) 계측부 : 검사조정을 위하여 대상물(P.C.board)로부터 습득한 아날로그 또는 디지털 신호를 인지할 수 있는 신호로 만드는 것이다. 계측신호가 숫자일 수도 있으나 파형 분석시 FFT, DFT, pattern matching, pattern recognition, digital filtering 등에 의해 검사결과를 판정하는 디지털 신호처리 기법이 요구된다. 기본적인 제어기준신호는 전압(V<sub>Peak-to-Peak</sub>) 또는 주파수가 된다.
- 3) 모터 구동부 : 소형직류모터와 실리콘 드라이버 텁으로 구성된 구동부는 조정대상(가변소자)에 정착되어 제어부 출력을 구동신호로 변환하여 구동하게 된다. 모터는 1기판에 8축이 장착되어 8개의 조정대상이 동시 조정된다. 이 과정에서 드라이버의 텁과 조정대상간에 드라이버의 회전방향이 반전될 때 백래쉬(backlash)가 발생하게 되며 조정신호와 실제 조정결과에 상당한 오차발생 요인이 된다.
- 4) 제어부 : 제어입력 산출을 위하여 개발된 알고리즘이 포함된다. 제어 알고리즘은 신경회로망기법을 이용한다. 신경회로망 알고리즘의 이용은 조정공정에 비선형성에 대하여 학습효과가 우수하고 현장 공정에 직접 적용할 수 있다. 그리고 조정공정에서 그 제어 특성이 만족치 않을 경우 조정영역을 구획화하여 각 부분에 대하여 독립적으로 학습된 몇 개의 신경회로망을 병렬화하여 비선형성이 극심한 공정을 보완하게 된다.

### III. 지능형 제어기 설계

#### 1. 신경회로망 학습방법(learning method)

조정대상 소자의 비선형 특성에 대한 적응능력 습득을 위하여 다층구조를 갖는 오차역전파 학습 신경회로망 기법이 적용된다. 일반적으로 제어목적을 위하여 사용되는 오차역전파 신경회로망 구조는 1개의 중간층이 사용된다 [10]. 본 연구에서도 신경회로망의 기본 구조는 입력층, 중간층, 출력층으로 구성된다. 각 층은 신경 조직의 뉴우런에 해당하는 노드로 구성되며 각 노드의 자체적인 활성함수 또는 판단함수(actuation or logistic function)는

다음의 시그모이드 형태의 함수로 정의한다.

$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad (1)$$

이 함수는 들어오는 입력의 범위에 따라 0과 1범위의 값을 갖으며 이를 통해 입력패턴의 애매한 부분까지 논리적인 영역구분을 하게되고 각 층간의 뉴우런 연결을 위한 하중벡터( $\overline{W}$ 를 변화를 통해 신경회로망 학습과 적응이 유도된다. 이때 하중벡터는 현재 상태에서 신경회로망의 출력  $y_N(k)$ 과 실시스템의 출력  $y(k)$ 의 차이를 비용함수(cost function) 또는 성능지표(performance index)  $J$ 의 최소화하는 방향으로 변화시킨다.

$$J = \lim_{N \rightarrow \infty} \frac{1}{2} \sum_{k=1}^N [y(k) - y_N(k)]^2 = \lim_{N \rightarrow \infty} \frac{1}{2} \sum_{k=1}^N e(k)^2 \quad (2)$$

이때, 하중벡터의 변화식은 다음과 같다.

$$\overline{W}(k) = \overline{W}(k-1) - \eta \frac{\partial e(k)^2}{\partial \overline{W}(k-1)} \quad (3)$$

여기서, 출력오차  $e(k) = y(k) - y_N(k)$ 은 단계적으로 최소화될 것이다.  $\eta$ 는 학습률(learning rate)이며 하중의 변화 속도를 결정하는 파라미터이다. 학습시간 개선과 국부최소치를 피하기 위해 개선된 학습알고리즘이 도입된다. 즉, 비용함수 출력 오차의 norm으로 구성되는 기존의 학습방법에 오차의 변화율의 norm을 접목시킴으로써 오차변화율을 최소화시키는 방향으로 학습 성능이 고속화된다. 이 경우 오차의 변화율은 다음과 같이 나타낼 수 있으며,

$$\begin{aligned} e^*(k) &= \frac{\Delta y(k)}{\Delta t} - \frac{\Delta y_N(k)}{\Delta t} \\ &= \frac{y(k) - y(k-1)}{T} - \frac{y_N(k) - y_N(k-1)}{T} \quad (4) \\ &= \Delta y(k) - \Delta y_N(k) \quad (\text{샘플링 주기 } T=1 \text{로 가정하면}) \end{aligned}$$

비용함수로 사용하는 새로운 평균오차함수( $J_N$ )는 다음과 같다.

$$J_N = \lim_{N \rightarrow \infty} \frac{1}{2} \sum_{k=1}^N [e^2(k) + e^{*2}(k)] \quad (5)$$

따라서, 신경회로망 하중벡터 조정식은 다음과 같이 수 정된다.

$$\begin{aligned} \overline{W}(k) &= \overline{W}(k-1) - \eta_1 \frac{\partial e^2(k)}{\partial \overline{W}(k-1)} \\ &\quad - \eta_2 \frac{\partial e^{*2}(k)}{\partial \overline{W}(k-1)} \quad (6) \end{aligned}$$

여기서,  $\eta_1$ 과  $\eta_2$ 는 각각 출력오차와 오차의 변화율에 대한 학습률이다. 그리고, (4)로부터 다음 식을 얻을 수 있다.

$$\begin{aligned} e^*(k) &= e(k, \overline{W}(k-1)) - e(k-1, \overline{W}(k-1)) \\ &= e(k) - e(k-1) \quad (7) \end{aligned}$$

(7)의  $e(k)$  및  $e(k-1)$ 은 신경회로망의 하중벡터  $\overline{W}(k-1)$ 에 근거한 예측 오차들이다. 따라서, (6)에 의해 개선된 법칙은 다음과 같이 정리된다.

$$\begin{aligned} \bar{W}(k) = & \\ & \bar{W}(k-1) - 2[\eta_1 e(k) + \eta_2 e^*(k)] \frac{\partial e(k)}{\partial \bar{W}(k-1)} \\ & + 2\eta_2 e^*(k) \frac{\partial e(k-1)}{\partial \bar{W}(k-1)} \end{aligned} \quad (8)$$

이 개선된 법칙에 의해 두 가지의 학습능력 향상을 기대할 수 있다. 첫째, 학습 과정에서의 수렴속도 향상이다. 그 이유는 (6)에서 하중벡터의 탐색방향이  $k$ 번쨰 학습단계에서의 예측오차 뿐 아니라 변화하는 경향의 오차까지 고려하기 때문이다. 이에 대한 도식적 설명은 그림 2와 같다. 여기서,  $k-1$  단계와  $k$  단계에서의 예측오차는 비교적 작지만, 시스템과 신경회로망 사이의 변화경향에 대한 오차는 매우 크다는 것을 알 수 있다. 이러한 경향은  $k+1$  단계에서 매우 큰 값의 예측오차를 유발시킬 수 있다. 새로 도입된 법칙의 장점은 신경회로망 학습시 직면하는 이와 같은 문제점을 해결할 수 있다는 것이다. 즉, 한편으로는 예측오차  $e(k)$ 를 감소시키고 다른 한편으로는 시스템과 신경회로망 사이의 변화경향에 대한 오차  $e^*(k)$ 를 감소시키는 것을 목표로 하고 있다. 따라서, 예측오차  $e(k+1)$ 이 일반적인 오차역전파 학습법에 의한 오차보다 더 적게되어 학습속도의 향상효과를 기대할 수 있다.

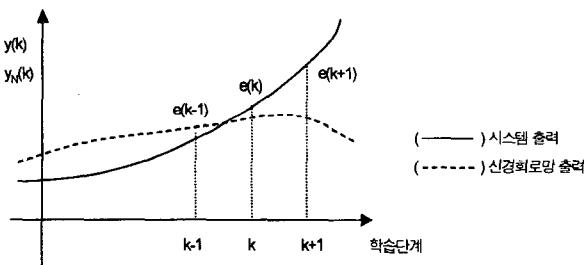


그림 2. 예측오차에 대한 도식 설명.

Fig. 2. The schematic illustration of prediction errors.

둘째, 높은 에너지 수준에서의 국부최소치 도달을 피하여 낮은 에너지 수준의 최소치에 수렴하는 것을 가능하게 해준다. (2)와 (5)로부터 다음 식이 유도될 수 있다.

$$\frac{1}{2} \sum_{k=1}^N [e^2(k) + e^{*2}(k)] > \frac{1}{2} \sum_{k=1}^N [e^2(k)] \quad (9)$$

국부최소영역에서 개선된 학습오차 지표가 일반적 학습오차 지표에 비하여 훨씬 크기 때문에, 이 국부최소영역을 피하여 더 낮은 에너지 수준의 최소값으로 수렴할 수 있게 된다[11]. 일반적으로 신경회로망 학습에서 초기 작업은 알고리즘 형성을 위한 파라미터 선정 문제인데, 이에 대해서는 뚜렷한 규칙이 없으며 경험적으로 얻어진 값을 채택한다. 학습의 종료는 학습용 데이터를 바탕으로 (5)에서 정의한 비용함수를 최소화하는 시점과 함께 학습된 신경회로망의 일반화 능력의 지표로서 학습 데이터 패턴 외의 부수적인 평가용 데이터를 가한 결과에 대해서도 좋은 성능을 나타내는지를 동시에 관찰하여 그 시점을 정한다[10].

## 2. 신경회로망 제어기 구조

조정대상시스템의 단일 입력력 공정은 다음 식으로 나타낼 수 있다.

$$\begin{aligned} y(k+1) = & f[y(k), y(k-1), \dots, y(k-p+1), u(k), \\ & u(k-1), \dots, u(k-q)] \end{aligned} \quad (10)$$

여기서,  $y(\cdot)$ 는 출력,  $u(\cdot)$ 는 입력이다. 입력의 크기는 제한하여  $u_{min} \leq u(k) \leq u_{max}$ 을 만족하게 하며, 제어기 설계 목적은  $y(k)$ 가 목표치  $r(k)$ 을 추종하도록 제어입력  $u(k)$ 를 검색하는 것이다. 이 때,  $p$ 와  $q$ 는 공정의 현재 출력이 과거 몇 번째 입력과 출력상태에 의해 영향을 받는지를 결정하는 계수로서, 공정의 특성을 파악하여 이를 선행적으로 추정해야 한다. 이것은 곧 공정모델의 차수를 추정하는 작업이다[12].

신경회로망에 의한 조정공정 제어기는 신경회로망 애뮬레이터(NNE)와 신경회로망 제어기(NNC)로 구성된다. (10)의 공정 입력 출력 관계를 수학적으로 유도하기 어려운 대상 시스템을 NNE의 학습을 통해 (10)의  $f(\cdot)$ 와 유사한 애뮬레이터 함수  $\varphi E(\cdot)$ 를 생성한다. 즉, NNE는 대상시스템의 모델링 결과라 할 수 있다.

$$\begin{aligned} \kappa_e(k) = & [y(k), y(k-1), \dots, y(k-p+1), \\ & u(k-1), \dots, u(k-q)]^T \end{aligned} \quad (11)$$

$$y_e = \varphi E(\kappa_e) \quad (12)$$

여기서,  $y_e$ 는 NNE 출력,  $\kappa_e$ 는 NNE 입력 패턴이다.  $p$ 와  $q$ 를 추정함으로써 NNE를 학습시킬 패턴데이터의 입력형태가 (11)과 같이 결정되며, 패턴 입력  $\kappa_e(k)$ 에 대한 실시스템 출력  $f(\kappa_e)$ 와 NNE 출력  $\varphi E(\kappa_e)$  사이의 오차  $e(k) = f(\kappa_e) - \varphi E(\kappa_e)$ 의 Norm과 오차의 변화율  $e^*(k) = e(k) - e(k-1)$ 의 Norm을 동시에 고려한 오차를 최소화하는 방향으로 학습이 진행된다.

NNC는 (10)의 공정에 대한 역함수가 존재할 경우 설계 가능하며, (13)과 같은 함수  $g(\cdot)$ 가 존재하게 된다.

$$u(k) = g[y(k+1), y(k), \dots, y(k-p+1), \quad (13) \\ u(k-1), u(k-2), \dots, u(k-q)]$$

이때,  $g(\cdot)$ 은 NNC를 학습시켜 모방함수  $\varphi C(\cdot)$ 를 만들 수 있다.

$$\begin{aligned} \kappa_c(k) = & [r(k+1), y(k), \dots, y(k-p+1), \\ & u(k-1), \dots, u(k-q)]^T \end{aligned} \quad (14)$$

$$u_c = \varphi C(\kappa_c) \quad (15)$$

여기서,  $r(k+1)$ 은 미지의  $y(k+1)$  대신 사용된 목표치 (reference)이다.

(15)가 충분히 학습된 후,  $\varphi C(\cdot)$ 은 (14)와 같은 제어기의 입력에 대하여 목표치  $r(k+1)$ 을 유도할 수 있도록 하는 적당한 제어입력  $uC(k)$ 를 생성하게 된다[12]. 그럼 3은 NNE와 NNC 학습을 위한 구조도이다. 대개의 공정에서 충분한 성능을 갖춘 신경회로망 제어기의 구성이 어렵다. 첫째, 제어기 설계는 공정의 역함수 모델을 바탕으로 하는데 실제 입력데이터를 주고 출력데이터를 검출하기는 쉬운 반면 출력데이터를 바탕으로 입력데이터를

추정하기는 어렵다. 둘째, 학습을 위한 패턴 데이터가 구성되었다 하더라도 유한 개의 데이터가 공정의 대표적인 특성을 담고 있는지는 불분명하기 때문에 실제로 특정한 일부 영역에서는 마치 학습이 전혀 이루어지지 않은 것처럼 올바른 제어출력을 산출하지 못한다. 셋째, 신경회로망의 특성상 공정에서 추출하여 공정 밖에서 학습하는 것(off-line learning) 외에 신경회로망을 공정에 적용한 후 학습 진행중(on-line learning)에도 계속하여 공정 특유성을 체득하는 것이 필요하다[13].

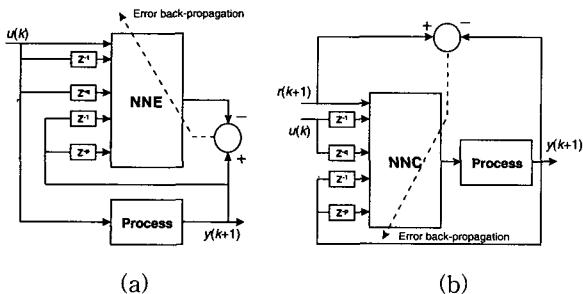


그림 3. 학습 구조 : (a) 신경회로망 에뮬레이터와 (b) 신경회로망 제어기.

Fig. 3. Training architectures for : (a) NNE and (b) NNC.

본 연구에서는 플랜트의 특성상 공정에 대한 역함수가 존재하며, 직접 역함수 제어를 기본 구조로 선택하였다. 이 구조는 플랜트의 역함수 특성을 신경회로망으로 모델링하고 이를 플랜트의 앞에 직렬 연결하는 일반적인 방법이다. 이렇게 구성된 신경회로망 제어기는 플랜트가 동작하는 전 영역에 대해 학습한 후 구성된 것이므로 실제로 조정점 부근에서의 미세한 제어에서는 정확도가 떨어진다. 따라서, 전 조정영역에 대한 개별적인 신경회로망과 부가적으로 조정점 근처의 국부영역에 대해 학습한 보조 신경회로망(sub-NNC)을 병렬로 접목하여 상호 보완도록 한다. 이와 같은 제어기 구조는 상호 간섭성이 비교적 적은 다중 항목의 동시조정에도 적용할 수 있다(그림 4).

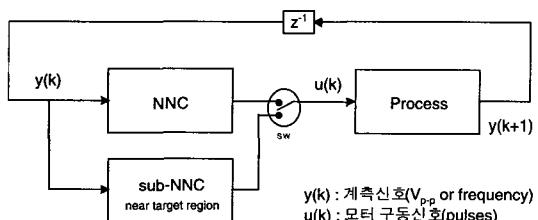


그림 4. 신경회로망 제어기와 보조제어기를 이용한 조정공정제어.

Fig. 4. Adjustment control utilizing NNC and sub-NNC.

두 가지의 조정항목이 우선순위(priority)를 갖고 수행되며 상호 종속적인 특성이 강할 때, 즉, 먼저 조정되는 조정항목이 출력에 따라 나중의 조정항목이 영향을 받는 경우의 제어기 구조는 그림 5와 같다.

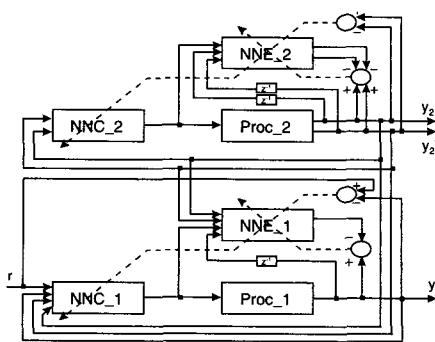


그림 5. 상호 간섭적 다중항목 동시조정을 위한 제어기 구조.

Fig. 5. Structure of the multi-adjustment controller for co-dependent processes.

각 조정항목에 대하여 별도의 NNE와 NNC가 부가되어 있다. 조정항목 1(Proc\_1)의 경우는 입력변수와 출력변수가 각각 1개이며, 조정항목 2(Proc\_2)는 입력변수 1개, 출력변수 2개를 갖는다. 즉, 조정항목 1의 경우는 계측값이 특정값을 나타내도록 입력변수인 모터의 구동량을 조정하는 것이고, 조정항목 2의 경우에는 두 계측점에서 계측된 값의 차이가 0이 되도록 입력변수를 조정하는 것이다.

### 3. 퍼지 보상알고리즘

위에서 제시한 신경회로망 조정알고리즘을 이용하여 별도로 제작된 시벌플랜트용 검사조정시스템을 동작시켜 캠코더의 검사조정공정을 수행한 결과, 대상 조정항목인 가변소자가 납품업체나 시기에 따라 발생되는 입출력 특성 변화, 시스템 H/W의 기구적 문제 등으로 다음과 같은 현상들이 발생했다.

첫째, 납품업체가 다른 대상소자의 경우 제어목표점이 변동할 수 있으며, 제어목표점을 기준으로 좌우의 특성곡선이 다소 변화를 나타낸다. 이로 인하여 최초 학습된 제어신호로는 목표점을 벗어나서 지나쳐 버리거나(overshoot) 못 미치는 결과를 초래한다. 못 미치는 경우에는 진행방향으로 추가 회전을 제공하면 시간적으로 미세한 손실을 낳지만, 지나쳐 버리는 경우 역회전 입력을 가하면 또 다른 오차를 발생시키거나 시간적으로 큰 손실을 가져온다. 따라서, overshoot를 방지하는 것이 보상 알고리즘의 기본 개념이다. 둘째, 가변소자의 텁(tip)과 이를 회전시키기 위해 안착되는 드라이버간의 구조적 부정확성 때문에 발생하는 백래쉬의 문제이다. 즉, 드라이버의 회전방향이 반전될 때 미세한 회전량이긴 하지만 가변소자 축면에서는 공회전 공간이 발생한다. 그러나, 이 미세한 양이 출력의 변화에 상당한 영향을 미친다. 따라서, 회전방향의 반전시 이를 보상해줄 수 있도록 부가적인 알고리즘이 요구된다. 세째, 회전방향이 반전되지 않은 상황에서도 전단계의 모터 회전량에 따라 현재의 회전량이 영향을 받는다는 것이다. 예를 들어, 1000펄스 씩 5회전 한 회전량과 5000펄스로 1회전한 회전량이 차이를 나타낸다는 것이다. 그 차이가 무시할 수 없을 정도이기에 목표점을 지나쳐 버리는 경우가 발생하기도 한다. 물론,

신경회로망의 학습시 전단계의 제어입력과 현재의 제어입력에 대한 충분한 학습이 이루어졌다면 이 문제는 쉽게 해결될 수 있다. 그러나, 이를 위해서는 최초 신경회로망의 오프라인 학습시 요구되는 학습용 데이터의 확보가 용이하지 않다. 학습을 위해 요구되는 제어입력의 전반적인 범위를 수용하기 위해서는 전단계 회전량과 현재의 회전량에 대한 경우의 수가 너무 많기 때문이다. 그리고, 연속적으로 들어오는 조정 대상플랜트(캠코더 P.C.boards)를 정위치에 고정시키고, 검사 및 조정을 위한 기구부가 안착되고, 검사조정을 위한 신호발생 및 계측 등 일련의 동작들을 수행하기 위하여 컴퓨터가 온라인 학습을 수행할 수 있는 시간적 여유를 갖지 못한다는 것이다. 따라서, 온라인 학습을 대신할 수 있는 부가적 알고리즘이 요구되며, 급격한 특성변화에 대한 신경회로망 재학습은 시스템의 가동이 휴지상태일 때 수행하도록 한다.

표 1. 제어신호 보상을 위한 보상결정규칙.

Table 1. Performance decision rules to compensate the control signal.

Scale factors		$\alpha(k)$						
		NL	NM	NS	ZO	PS	PM	PL
$U_{NEURAL}(k)$	NL	1.0	0.8	0.7	0.0	1.0	1.0	1.0
	NM	0.7	0.6	0.5	0.0	1.0	1.0	1.0
	NS	0.5	0.4	0.3	0.0	1.0	1.0	1.0
	ZO	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	PS	1.0	1.0	1.0	0.0	0.3	0.4	0.5
	PM	1.0	1.0	1.0	0.0	0.5	0.6	0.7
	PL	1.0	1.0	1.0	0.0	0.7	0.8	1.0

Scale factors		$C(k)$						
		NL	NM	NS	ZO	PS	PM	PL
$U_{NEURAL}(k)$	NL	0.0	0.0	0.0	0.0	-1500	-1600	-1800
	NM	0.0	0.0	0.0	0.0	-1200	-1300	-1400
	NS	0.0	0.0	0.0	0.0	-800	-1000	-1000
	ZO	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	PS	-1000	-1000	-800	0.0	0.0	0.0	0.0
	PM	-1400	-1300	-1200	0.0	0.0	0.0	0.0
	PL	-1800	-1600	-1500	0.0	0.0	0.0	0.0

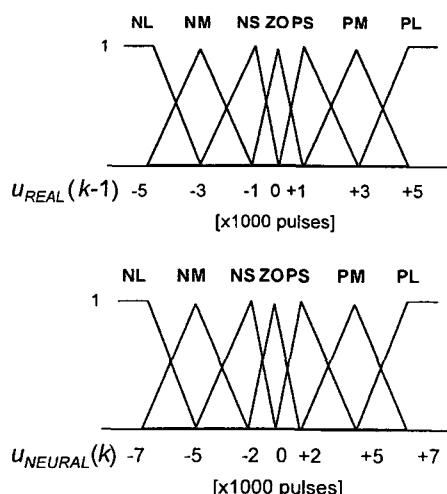


그림 6. 멤버쉽 함수.

Fig. 6. Membership function.

위의 문제점을 해결하기 위한 보상 알고리즘을 퍼지 논리(fuzzy logic)를 이용하여 해결했다. 즉, overshoot를 방지하기 위한 대상소자 특성변화 및 모터 회전관성 보상은 전단계 및 현단계에서의 NNC 출력, 즉 모터 구동 펄스값에 따라 현재의 NNC 출력에 적절한 비례상수를 곱하여 이를 보상하도록 하였으며, 백래쉬 문제는 일정한 값을 가감하여 이를 보상하도록 한다. 이를 식으로 표현하면 (16)과 같으며, 표 1은 보상결정 규칙을 그림 6은 멤버쉽 함수를 보여준다.

$$u_{REAL}(k) = \alpha(k) \times u_{NEURAL}(k) + C(k)[\text{pulses}] \quad (16)$$

여기서,  $\alpha(k)$ 는 overshoot 방지를 위한 보상인자,  $C(k)$ 는 백래쉬 보상인자이다. 여기서 산출된 보상결정 규칙은 반복된 실험을 통하여 얻어진 결과이며, 대상소자의 다양한 특성변화에도 유동적으로 대처할 수 있는 보상치이다.  $u_{NEURAL}(k)$ 는 신경회로망 제어기로부터 산출된 제어입력으로 DC모터 구동을 위한 펄스값이다.  $u_{REAL}(k-1)$ 은 전단계의 DC모터 구동 펄스값이다.

#### IV. 실험 및 결과고찰

본 실험에서 사용되는 캠코더의 조정공정들은 특성상 다음과 같이 분류한다. 1) 출력과 입력이 각각 1개인 단일 입력과 단일 출력 공정(SISO), 2) 출력과 입력이 각각 두 개 이상이며, 조정점들 간에 서로 간섭이 일어나는 공정(MIMO).

##### 1. 신경회로망 학습성능 개선

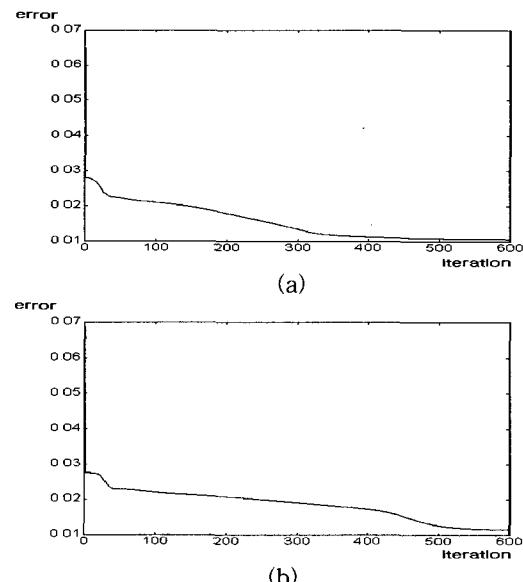


그림 7. 오차 수렴성능의 비교 : (a) 기존의 방법  
(b) 개선된 방법.

Fig. 7. Comparison of error convergence by (a) the conventional method and (b) the improved method.

오차의 변화율을 포함시킨 개선된 학습알고리즘(4)-(6)과 기존의 학습알고리즘과의 에러수렴 속도와 모델링 성능의 비교(그림 7,8)에서 개선된 알고리즘이 학습 수렴속도가 향상되고 높은 에너지 수준에서 국부최소값에 빠지는

것을 방지하여 낮은 에너지 수준에서 전역최소값으로 수렴할 가능성이 훨씬 높다는 것을 알 수 있다.

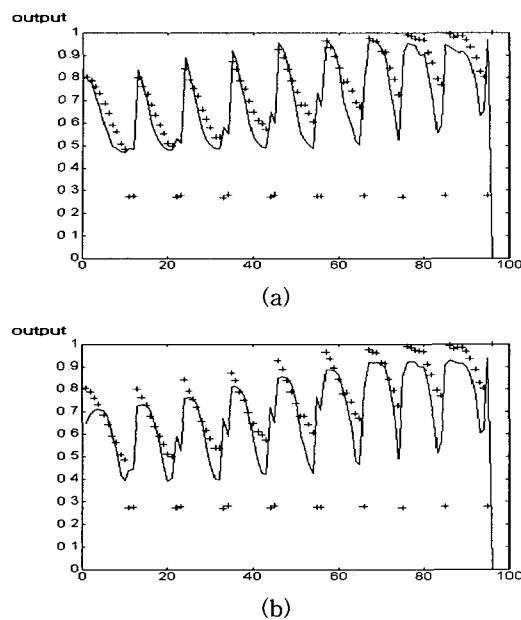


그림 8. 공정 모델링의 비교 : (a) 기존의 방법 (b) 개선된 방법(+++ : 목표치, — : 신경회로망 추정치).

Fig. 8. Comparison of process modeling by (a) the conventional and (b) improved method (+++ : desired, — : chasing).

## 2. 단일 입력/단일 출력(SISO) 조정점

단일 입력 출력 공정의 예로서, ‘고주파 전송주파수(RF carrier frequency)’ 조정 공정에 대한 실험결과를 검토한다. 이는 캠코더 내에 고주파 전송주파수를 특정 주파수 (4.38 MHz)에 일치시키는 공정이다. 이 경우는 단일입력/단일출력으로서 계측점으로부터 입력되는 값은 주파수이고 출력은 모터의 구동펄스이다. 조정목표치는 4.38 MHz이고, 허용오차는  $tol = \pm 0.015$  MHz로 한다.

공정 특성이 증감이 단조롭고 뚜렷하며 실제 공정 출력에 대해 조정을 위한 유사제어출력을 구할 수 있다. 여기서, 유사제어출력은 목표점에서 시작하여 가변소자를 임의의 양만큼 회전시킨 후 발생하는 새로운 주파수 지점이  $F_n$ 인 경우,  $F_n$ 에서 목표점에 도달하기 위해서는 같은 양의 역방향 회전이 되면 이를 제어출력치로 택하게 된다. 이 값은 그러나 백래쉬와 전단계 회전량을 고려하지 않은 상태며 실제로는 이상적 제어출력이 될 수 없으며 일정량의 오차는 감안하고 적용하는 셈이 된다. 목표점(adjusting point) 근접점에서는 신경회로망 학습이 제어출력을 제대로 추종하지 못한다. 이는 학습패턴 데이터가 조정영역 전체의 광범위한 데이터를 중심으로 학습시킬 경우 신경회로망은 특정한 지점에 대해서는 기대 한 만큼의 수렴정도를 보이지 않는 자체 특성에 기인한 것 때문이다. 목표치 접근점에서는 미흡한 학습성능과 학습패턴으로 사용한 유사제어출력의 내재적인 오차, 그리고 실제 공정에서 모터의 조정 텁과 가변소자의 나사

머리사이의 구조적 결함 등의 원인으로 인해 목표점 부근에서의 미세조정 단계에서 진동과 정상상태오차를 낼 수 있다. 이러한 진동상태를 방지하고 정상상태 오차를 줄이기 위하여 그림 6과 같은 퍼지 보상알고리즘을 적용하였다. 모든 실험결과는 퍼지 보상알고리즘에 의해 보상된 제어신호에 의해 조정된 결과이다.

표 2는 RF Carrier frequency 조정항목에 대한 실험결과이다. 결과를 살펴보면, 평균 3.6회의 조정횟수와 2.52초의 평균 조정시간을 나타내었다. 이는 기존 조정방법의 평균 3초에 비하여 우수한 결과이며, 숙련된 작업자에 의한 조정능력과 상응하는 결과이다. 적용례 26, 40의 경우는 초기상태가 조정점으로부터 멀리 떨어져 있으므로 다소 조정이 지연되었다.

표 2. 고주파 전송주파수 조정 결과.

Table 2. The results of adjustment for RF Carrier frequency.

조정 예	초기상태 (Hz)	조정 회수	조정시간 (초)	조정 예	초기상태 (Hz)	조정 회수	조정시간 (초)
1	4088151	2	1.86	21	4294894	3	1.87
2	4236014	4	2.64	22	4273556	3	1.82
3	4165856	2	1.76	23	3835043	4	2.80
4	3863581	3	2.41	24	3718924	4	3.02
5	4919753	6	3.79	25	4121392	3	2.09
6	3829260	3	2.42	26	5140590	7	3.79
7	4810787	6	3.02	27	4658567	3	2.08
8	3808528	5	3.13	28	4608451	2	1.81
9	4263480	3	2.04	29	5294117	3	2.91
10	4485299	1	1.38	30	2905895	8	5.06
11	4708954	3	2.20	31	4283559	2	1.37
12	4054012	3	2.31	32	4182756	2	1.76
13	3999694	4	2.47	33	3736421	4	3.02
14	4132255	3	2.14	34	4125360	2	1.87
15	4083356	3	2.19	35	3225495	6	4.12
16	4697686	3	2.20	36	4722854	3	2.14
17	5166764	3	2.91	37	4873867	2	2.19
18	5189437	4	2.92	38	4501734	2	1.65
19	4437634	8	2.80	39	4452788	2	1.48
20	4690176	3	2.19	40	2222687	8	5.10
목표치 : 4.38 MHz				평균 허용오차 : $\pm 0.015$ MHz			
				3.6			
				2.52			

## 3. 다중 입력/다중 출력(MIMO) 조정점

이는 캠코더의 영상기판(VCR 기판)의 가변소자(variable resistor)인 VR202와 VR208을 조정하여 각각의 측정점 TP1과 TP2으로부터의 계측치 파형의 전압최고치(VP-P)를 각각 2.5VP-P와 0.7VP-P로 조정하는 공정으로, 이때 허용오차는 각각  $\pm 0.05$ VP-P와  $\pm 0.02$ VP-P이다. 이때 가변소자의 회전과 측정점의 출력특성을 관찰해보면, 그림 9에서 알 수 있듯이 TP1, TP2에서의 계측파형은 가변소자 VR202와 VR208가 변함에 따라 서로 영향을 주고 받는 상호 의존적인 관계에 있게 된다. 따라서, 이들의 조정공정은 상호 간섭이 발생하는 다중 입력과 다중출력(MIMO) 형태로 간주된다.

실제 학습에 사용한 패턴 데이터는 입력을 VR이 특정 위치에 있을 때의 전압치가 되게 하고, 출력은 이 경우 목표 전압치에 도달하기 위한 VR의 회전량이 되게 한다. 두 측정점에서 나올 수 있는 전압치들이 서로 다른 값을

갖도록 하는 경우는 무수히 많다. 따라서, 입출력 특성을 모델링하기 위한 패턴 데이터의 수집에는 실험계획법과 같은 특별한 기법이 요구되기도 한다. 그러나, 여기서는 방대한 패턴 데이터에 의한 학습이 그 정보량에 비해 학습결과의 정밀도에는 큰 차이가 나타나지 않는다는 것을 여러 차례 실험을 통하여 알아볼 수 있었다. 따라서, 소수의 데이터 표집을 통해 학습 패턴을 구성하였다. 즉, 일반적으로는 랜덤 입력을 주어서 대표적 학습 데이터 패턴을 구성하지만, 이 공정에서는 이 방법으로는 학습 데이터 표집의 국부성(locality)을 피한다고 기대할 수 없다. 본 논문에서는 VR202와 VR208을 목표점을 중심으로 시계방향과 시계반대방향으로 반회전( $\pm 180^\circ$ )만큼의 조합을 학습 데이터 표집영역으로 삼는다. 이는 반회전을 넘긴 후의 조정의 경우 이것의 역방향으로 조정을 한다면 반회전에 못 미쳐서 조정을 할 수 있는 VR의 특성 때문이다. 즉, 각 VR의 반회전량을 6등분하여 한쪽이 그 한 섹터만큼 움직인 때마다 다른 쪽은 반 회전에 해당하는 6섹터만큼을 모두 회전하도록 하는 식으로  $6 \times 6$ 개의 데이터 패턴을 구성한다. 이런 방식으로 정회전과 역회전이 고려되면 총  $2 \times 6 \times 6$ 개의 데이터 패턴이 구성된다.

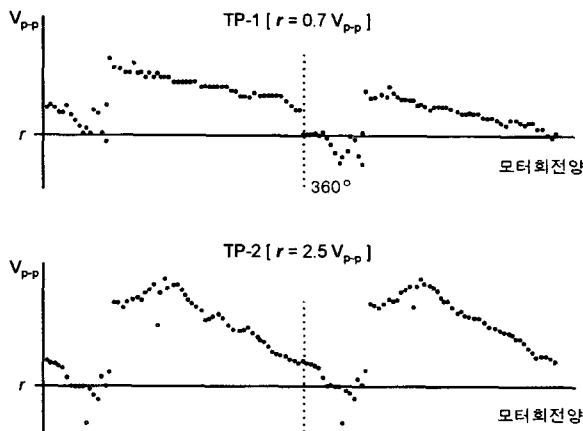


그림 9. PB OUT LEVEL 측정점의 출력 과형 (TP1, TP2).

Fig. 9. The voltage waveforms for the PB OUT LEVEL (TP1 and TP2).

신경회로망 학습용 데이터의 구성은, 최초 목표점에서 시작하여 각각의 VR을 회전시킨 후 계측된 전압치를 학습입력으로, 이때 회전시킨 회전량이 역으로 보면 곧 목표점에 도달하기 위한 제어입력이 되므로 학습교사치로 설정한다. 따라서, 이는 위 단일 출력 조정과 마찬가지로 유사제어출력을 사용하여 실공정에서 정상상태오차를 가지게 된다.

구성된 학습패턴 데이터를 가지고 각 중간층의 개수와 파라미터를 바꿔가며 학습오차의 수렴을 관찰하고 이를 각각 공정에 적용하여 그 성능을 비교한 결과 표 3의 결과를 얻었다. 이 결과에서 학습 수렴오차값은 중간층의 노드 수가 4개일 때 가장 적고, 5개일 때는 다른 경우보다 학습 수렴오차는 큰 반면 적용 성능은 평균조정횟수와 발산진동횟수의 경우 상대적으로 낮게 나타난다. 이

는 신경회로망의 학습패턴이 아무리 우수하다 하더라도 일반화 능력에 있어서의 제한성 때문이다. 이 조정공정에는 적용성능이 우수한 5개의 중간층 노드 수를 채택하였다.

표 3. 파라미터 변화에 따른 학습결과와 적용성능 (각 모델당 공정 적용 15회).

Table 3. The results of training and applicabilities with parameter changes.

신경회로망 구조동정(중간층 노드수)			
중간층노드수	4	5	6
최소수렴오차	0.593	0.6114	0.5992
조정횟수평균(회)	2.3	1.7	2.0
발산진동횟수	1	1	2
조정오차평균	0.112	0.199	0.172

표 4. 신경회로망 제어기에 의한 조정 결과.

Table 4. The results of the adjustment using NNC.

조정 예	조정 전 TP1 (V <sub>p-p</sub> )	조정 전 TP2 (V <sub>p-p</sub> )	조정 횟수 (회)	조정 후 TP1 (조정 오차)	조정 후 TP2 (조정 오차)
1	2.2	0.6300	1	2.605 (0.105)	0.7272 (0.2720)
2	2.76	0.8000	2	2.430 (0.070)	0.6812 (0.0188)
3	2.66	0.5600	3	2.765 (0.265)	0.7760 (0.0760)
4	2.98	0.9800	2	2.755 (0.255)	0.7964 (0.0964)
5	3.20	0.9600	1	2.330 (0.170)	0.6468 (0.0532)
6	2.32	0.7500	2	2.440 (0.060)	0.6744 (0.0256)
7	1.84	0.5400	2	2.515 (0.015)	0.7020 (0.0200)
8	2.68	0.8296	2	2.320 (0.165)	0.6460 (0.0540)
9	2.02	0.5272	1	2.650 (0.150)	0.7540 (0.0460)
10	2.32	0.5704	2	2.545 (0.045)	0.7028 (0.0280)
11	2.88	0.8000	2	2.755 (0.255)	0.7964 (0.0964)
12	2.43	0.7500	1	2.610 (0.110)	0.7284 (0.0284)
13	1.95	0.5600	1	2.400 (0.100)	0.6680 (0.0120)
14	1.78	0.4408	1	2.470 (0.030)	0.6892 (0.0108)
15	3.18	0.9108	3	2.445 (0.045)	0.6948 (0.0050)
평균			1.73	0.1583	0.038

표 5. 신경회로망 부제어기에 의한 미세조정 결과.

Table 5. The results of the mini-adjustment using sub-NNC.

조정 예	조정 전 TP1 (V <sub>p-p</sub> )	조정 전 TP2 (V <sub>p-p</sub> )	조정 횟수 (회)	조정 후 TP1 (조정 오차)	조정 후 TP2 (조정 오차)
1	2.605	0.7272	1	2.515 (0.015)	0.7056 (0.0056)
2	2.430	0.6812	1	2.475 (0.025)	0.6920 (0.0080)
3	2.765	0.7760	5	2.525 (0.025)	0.7112 (0.0112)
4	2.755	0.7964	2	2.530 (0.030)	0.7100 (0.0100)
5	2.330	0.6468	2	2.495 (0.005)	0.7008 (0.0080)
6	2.440	0.6744	1	2.455 (0.045)	0.6852 (0.0148)
7	2.515	0.7020		NNC에서 조정 완료	
8	2.320	0.6460	1	2.470 (0.003)	0.6892 (0.0108)
9	2.650	0.7540	1	2.530 (0.003)	0.7108 (0.0108)
10	2.545	0.7028	1	2.515 (0.015)	0.7028 (0.0028)
11	2.755	0.7964	2	2.530 (0.003)	0.7100 (0.0100)
12	2.610	0.7284	1	2.520 (0.002)	0.7068 (0.0068)
13	2.400	0.6680	1	2.460 (0.004)	0.6896 (0.0104)
14	2.470	0.6892		NNC에서 조정 완료	
15	2.445	0.6948	3	2.475 (0.025)	0.6948 (0.0052)
평균			1.46	0.01346	0.0088

실제 공정에서 특정 입력 데이터나 조정점 부근에서 진동하거나 발산하는 경우를 관찰하게 된다. 그 이유는 학습에 사용된 제한된 양의 데이터 외의 다른 입력값에 대하여 올바르게 반응하는 추상화능력을 전적으로 갖지 못하기 때문이다. 또한, 단일 출력력 공정에서와 같이 기구부의 구조적 결함이 존재하기 때문이다. 이를 보정하기 위해서, 앞의 그림 4와 같이 조정점 부근에서의 좁은 영역에 대한 비교적 세밀한 학습용 데이터를 추출하여 이를 중심으로 새롭게 학습한 신경회로망 부제어기 (sub-NNC)를 구성하였다. NNC의 조정 결과 출력값이 목표값과 특정한 오차 범위 이내로 들어오면, sub-NNC 가 목표점 근처에서의 미세조정을 담당하게 된다. 표 4는 NNC를 통한 조정 결과이며, 표 5는 sub-NNC에 의한 결과이다.

NNC에 의한 조정은 대략적으로 목표점 근처까지는 도달했으나 조정 후 오차는 공정에서 요구하는 허용오차의 범위를 넘는다. 따라서, NNC 조정을 한 연속선상에서 sub-NNC를 적용한다. 실험결과, 임의의 입력전압에 대하여 NNC와 sub-NNC는 각각 평균 1.73회, 1.46회, 총 3.2회만에 조정이 완료됨을 알 수 있다.

## V. 결론

본 논문에서는 캠코더 조립공정 중 최종 PCB 레벨 상의 조정공정의 자동화를 위하여 신경회로망기법을 적용하는 제어알고리즘을 개발하고 이에 의한 지능형 제어방식을 구현하였다. 이 조정공정들은 입력력 특성이 비선형적이고 특정 조정항목들은 조정점들 간의 상호 간섭현상이 나타나므로 다중항목 동시조정이 쉽지 않다. 이를 위한 제어기법으로는 신경회로망을 이용하였으며, 신경회로망의 학습시 문제점과 제어기 설계시 문제점, 그리고 실시간으로 적용되는 문제점들에 관하여 고려하였다. 이와 같은 문제점들은 퍼지 보상알고리즘을 연계시켜 해결책을 제시하였다.

개발된 제어기는 그 구조가 간단하며, 전문적인 지식의 필요 없이 손쉽게 학습용 데이터를 확보할 수 있으며, 가변적인 제어대상 시스템들에 대한 적응능력을 갖는다. 뿐만 아니라, 유사 공정들에 대하여 광범위한 적용이 용이하다. 다중항목의 동시조정공정의 경우 상호의존적인 문제로 인한 신경회로망제어기 출력오차를 최소화하기 위하여 목표점 근처의 좁은 영역에 대하여 충분한 학습을 수행한 결과 향상된 결과가 유출되었다.

작업자의 시각판정에 의한 검사조정은 장시간 작업할 경우 눈의 피로도가 가중되어 작업 능률이 떨어질 뿐 아니라, 신속한 공정수행을 위해서는 작업자의 높은 숙련도를 요구한다. 한편, 제시된 지능형 제어알고리즘을 통한 자동조정 결과는 숙련된 작업자의 작업 속도보다 다소 빠르며, 두 가지 이상의 검사조정 항목에 대한 동시조정이 가능하여 생산성 향상을 기대할 수 있다. 그리고, 제시된 제어알고리즘은 검사조정 시스템의 자동화 뿐 아니라 일반 전자제품의 조정공정에도 광범위하게 응용할 수 있다.

## VI. 참고문헌

- [1] K. S. Narendra and Partha Sarathy, "Identification and control of dynamical systems using neural networks," *IEEE Trans. Neural Networks*, vol. 1, pp. 4-27, March, 1990.
- [2] R. P. Lippmann, "An introduction to computing with neural nets," *IEEE ASSP Magazine*, pp. 4-21, April, 1987.
- [3] D. Psaltis, A. Sideris and A. A. Yamamura, "A multi-layered neural network controller," *IEEE Control Systems Magazine*, pp. 17-20, April, 1988.
- [4] B. Bavarian, "Introduction to neural networks for intelligent control," *IEEE Control Systems Magazine*, pp. 3-7, April, 1988.
- [5] H.-C. Kim, H.-S. Oh and S. K. Kim, "Samsung computer aided testing & adjustment system," *KIEE '92 Workshop of the Society for the Research of Robotics and Automation*, pp. 56-59, 1992.
- [6] Y. Okamura, Y. Yatabe, I. Sasao, H. Kasai, N. Takatori, "Automatic adjustment and test system for television receivers," *National Technical Report*, vol. 36, no. 2, pp. 65-72, April, 1990.
- [7] Y. M. Koo, S. K. Lee, Y. M. Rhee and K. B. Woo, "Application of neural network for the intelligent control of computer aided testing and adjustment system," *Journal of the KITE*, vol. 30, pp. 79-88, 1993.
- [8] T. Chung, Z. Bien, D. Han, J. Park and W. Sim, "Intelligent control approach automation of adjustment process and application to color picture tube system," *Proc. of the Asian Control Conference*, pp. 749-752, Tokyo, July, 1994.
- [9] 이승구, 윤상철, 김주완, "가전제품의 지능형 제어를 위한 신경회로망 응용," 한국 퍼지 및 지능시스템학회 '97 춘계학술대회논문집, pp. 176-179, 1997.
- [10] L. Fausett, "Fundamentals of neural networks-architectures, algorithms and applications," Prentice-Hall, Inc., 1994.
- [11] D. Popovic and D. Xiaosong, "The approach of on-line modeling of dynamic systems with neural network," *Proc. of the Asian Control Conference*, pp. 655-658, Tokyo, July 27-30, 1994.
- [12] J. Tanomaru and S. Omatsu, "Process control by on-line trained neural controllers," *IEEE Trans. Industrial Electronics*, vol. 39, no. 6, pp. 511-521, Dec., 1992.
- [13] P. D. Wasserman, *Advanced Methods in Neural Computing*, Van Nostrand Reinhold, pp. 120-146, 1993.
- [14] M. Khalid, S. Omatsu and R. Yusof, "MIMO furnace control with neural networks," *IEEE Trans. Control Systems Technology*, vol. 1, no. 4,

pp. 238-245, Dec., 1993.

- [15] V. B. Rao and H. V. Rao, "C++ neural networks

and fuzzy logic," *Management Information Source, Inc.*, 1993.

### 장 석 호



1988년 연세대 전기공학과 졸업.  
1990년 동 대학원 전기공학과 졸업(석사). 1993년~현재 동 대학원 박사과정. 관심분야는 자동화 및 지능제어, 전자제품 검사조정 알고리즘, 생산계획 및 스케줄링, 반도체 생산시스템 모델링 및 시뮬레이션.

### 고 택 범



1981년 연세대 전기공학과 졸업.  
1983년 동 대학원 전기공학과 졸업(석사). 1996년 동 대학원 전기공학과 졸업(Ph.D). 현재 LG하니웰 연구실장. 관심분야는 반도체공정 자동화 및 인텔리전트 빌딩.

### 구 영 모



1984년 연세대 전기공학과 졸업.  
1986년 동 대학원 전기공학과 졸업(석사). 1993년 동 대학원 전기공학과 졸업(Ph.D). 현재 삼성전자(주) 생산기술센터 자동화 연구소 선임연구원 박사과정. 관심분야는 지능형제어, 검사조정시스템, Display Media 검사자동화.

### 우 광 방



1934년 1월 25일생. 1957년 연세대 전기공학과 졸(석사). 1962년 및 1964년 오래곤 주립대학 전기공학과에서 석사 및 박사학위 취득. 1966년~1971년 워싱턴대 전기공학과 조교수, 1971년 미 국립 암 연구소 책임연구원, 1980년 재미한국인과학기술자협회장, 1982년~현재 연세대 전기공학과 교수, 1992년~현재 연세대학교 자동화기술연구소 소장, 1995년 당 학회 회장. 주요관심분야는 반도체공정자동화 및 스케줄링, 인공지능제어기법, FMS.