

신경회로망을 이용한 헤어컷 실기 평가에 관한 연구

한 경 희* · 조 병 일**

A study on an Evaluation of Hair-Cut Practical Examination using Neural Network

Kyung-Hee Han* · Byooung-II Cho**

<목 차>

- 제 1장. 서론
 - 제 2장. Hair-Cut 실기 평가 방법
 - 제 3장. 신경회로망의 개요 및 학습 알고리즘
 - 제 4장. 신경회로망을 이용한 Hair-Cut 실기 평가
 - 제 5장. 실험결과
 - 제 6장. 결론
- 참고문헌

Abstract

A practical application of neural network is described for practical examination evaluation of Hair-Cut. The neural network system has 5 input variables, basic techniques and posture, operating procedure, skilled level and harmonic state, bias and 1 output variable, practical examination marks. In this paper a neural network system was described for evaluation of Hair-Cut practical examination impartially and objectively.

* 부산여사대학 피부미용학과

** 한국해양대학교 전지통신공학과

제 1 장. 서 론

시스템 인식(system identification)은 시스템의 연속적인 측정결과로부터 동적 시스템의 수학적 표현으로 추측하는 작업이다. 동적 시스템을 수학적 표현으로 인식하여, 그 인식된 시스템이 응용되어지는 분야는 다양하다. 전형적인 응용은 시뮬레이션(simulation), 예측(prediction), 고장 진단(fault diagnostic) 그리고 제어 시스템의 설계 등을 포함한다^{11,12}.

특히, 제어 분야에서는 플랜트(plant)의 모델링이 매우 중요하다. 플랜트를 모델링하는 방법에는 간단한 선형 시스템에서처럼 물리법칙 등에 의한 수학적 모델링 방법과 복잡한 시스템에 적용하는 시스템 인식 방법이 있다. 기존의 제어이론에 의한 시스템 인식방법은 실험 데이터 취합, 모델 구조 결정, 파라미터 추정(parameter estimation), 검증 등의 과정으로 구성되어 있다. 이에 수학적으로 모델링할 수 없는 복잡한 시스템을 인식하기 위해서는 먼저 플랜트의 실험 데이터를 어떻게 얻을 것인가를 먼저 결정해야 하며, 아울러 플랜트 모델의 구조를 결정해야 한다. 그리고 취합된 데이터와 모델 구조를 이용해서 모델의 파라미터를 플랜트에 맞게 조정하고 최종적으로 모델의 유용성을 확인해야 한다. 이 과정을 통해 얻어진 모델은 복잡한 시스템을 인식하게 된다. 기존의 제어이론에서는 대부분 선형 모델을 채택하고 있으며, 플랜트의 파라미터 추정방법으로는 수학적으로 잘 정립된 방법을 사용하고 있다.

반면에 시스템 인식방식으로 신경회로망을 사용할 경우, 플랜트의 출력과 신경회로망의 출력이 동일하도록 신경회로망의 웨이트(weight)가 조정되면 신경회로망은 플랜트를 정확히 인식하게 된다. 이러한 신경회로망에 의한 시스템 인식 방식은 기존 방식과 비교해 볼 때 신경회로망이 범용성을 갖고 있기 때문에 선형함수 뿐만 아니라 복잡한 비선형 함수를 용이하게 구현할 수 있다. 그리고, 신경회로망으로 동적 시스템을 인식할 수 있는 방법이 많은 연구자에 의해 연구되었으며, 응용되어지고 있다. 그러므로, 본 논문에서는 신경회로망을 미용실기시험 평가에 적용하여 보다 객관적이고 공정한 평가 방법의 하나로 제시하고자 한다. 현재 전문대 피부미용과 교육과정에서는 기초이론과 미용관련이론, 피부관리, hair, make-up, 기타 미용 실습으로 크게 나누고 있는데 이 중 hair 관련 실습을 살펴보면 cut이론 및 실습, permanent실습, 셋팅 드라이 이론 및 실습, 염색과 탈색, hair design실습 등의 과목이 있다. 이 중 대부분이 실습 과목이기 때문에 매 학기마다 실기 평가가 행해지고 있는데 미용은 그 특성상 매우 주관적이고 애매한 평가 방식에 의해 그 과정과 결과가 평가되고 있어서 정확하고 공정하게 평가되고 있다고 말하기 어려운 실정이다. 이에 미용 실기 평가의 과학화와 합리화를 이루기 위해서 신경회로망을 통해 평가 방법의 과학화를 시도해 보고자 한다.

본 논문의 구성을 살펴보면 제 2장에서는 Hair-Cut 실기 평가 방법에 대해서 설명하였으며, 제 3장에서는 신경회로망의 개요 및 학습 알고리즘에 대하여 설명하였으며, 제 4장에서는 신경회로망을 이용한 Hair-Cut 실기 평가 방법에 대하여 설명하였다. 그리고 제 5장에서는 본 논문에서 제시된 신경회로망 인식 모델에 관한 컴퓨터 시뮬레이션을 행하였고, 결론은 제 6장에서 맺었다.

제 2 장. Hair-Cut 실기 평가 방법

이 연구에서는 헤어컷 평가 방법에 관해서 연구하고자 한다. 먼저 커트시 브로킹 및 각 부 작업 순서를 나타내면 다음과 같다.

- ①-1, ①-2 그림과 같이 두발을 5등분한다.
- ② 크라운 헤어(crown hair)를 네이프·헤어(nape hair)에 맞추어 테이퍼링을 행한다. 이때에는 네이프·헤어를 가이드에서 행한다.
- ③ 네이프·헤어 및 크라운·헤어의 형클어진 두발을 자른다.
- ④ 크라운·헤어에 붙어 있는 사이드·헤어를 횡적, 종적으로 테이퍼링을 행한다.
- ⑤ 끝으로 톱·헤어를 그림과 같이 방사선상으로 조금씩 나눠잡고, 사이드 헤어나 크라운 헤어와 관련하여 테이퍼링을 실시한다. 이것이 끝나면 전체를 정돈하여 고르지 않은 부분만을 잘라 내고 모양을 갖춘다.

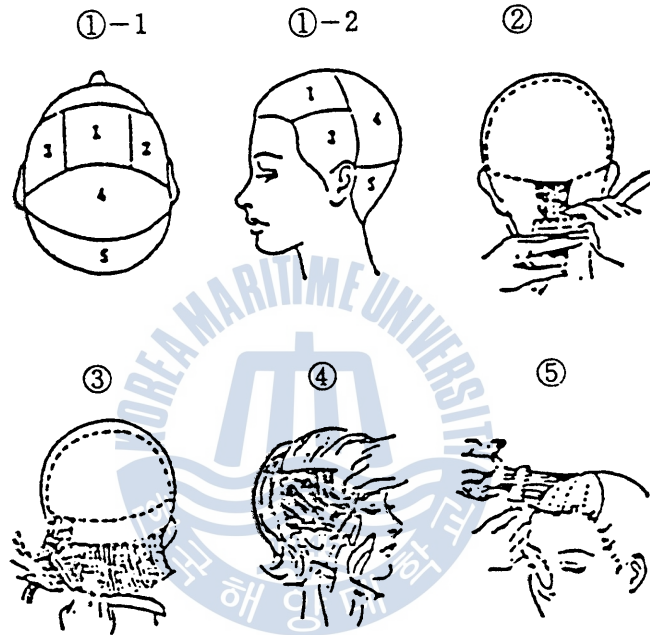


그림 1 커트작업순서

그리고, 현행 평가되고 있는 평가방법을 정리해 보면 다음과 같다. 구체적인 평가 기준으로 4가지로 나누어 평가되고 있다.

- 첫째 : 기본기법및 자세
- 둘째 : 시술순서
- 셋째 : 숙련도
- 넷째 : 종료후 조화미

기본기법및 자세에서는 물 축이기, 브로킹, 자세가 모두 우수하고 처리 숙련도가 능숙할 때 좋은 평가를 받을 수 있으며, 시술 순서에서는 만약 순서에 입각하지 않으면 정확한 시술에 무리가 오고 주어진 과제에 대한, 적응력을 기대하기가 곤란하므로 커트의 각 부 작업 순서가 정확하여야 좋은 평가를 받을 수 있다.

그리고 숙련도에서는 가위질, 빗질, 손놀림, 슬라이스 기법, 손가락 놀림이 자연스럽게 연결되어야 좋은 외곽선의 흐름, 각 포인트에서의 각도, 머리전체선의 윤곽의조화가 매우 우수하여 작품의 특성을 흠없이 완벽하게 표현하여야 좋은 평가를 받을 수 있다. 이 내용을 구체적으로

도표화 하면 표.1과 같다.

표. 1 헤어커드 채점기준

종목 점수	가. 기본기법및 자세	나. 시술순서	다. 숙련도	라. 조화미
20	물축이기 및 브로킹 이 알맞지 않을 때	순서를 일부 바꾸어 시술할 때	가위및 빗쥐는 방법이 서툴렀을 때	각 포인트에서의 각도 및 외곽선의 흐름이 불안정 할 때
40	물축이기는 알맞으나 브로킹이 미숙 할 때	바른 순서로 진행하다가 역순으로 다시 손질하는 경우	가위및 빗쥐는 방법은 옳으나 가위질 및 빗질이 서투를 때	외곽선의 흐름, 각 포인트에서의 각도 중 어느 하나가 불안정하며 전체조화가눈에 띄게 불안할 때
60	물축이기가 고르고 브로킹이 정확하나 작업자세가 다소 불안정한 수준일때	커트의 작업순서를 지키면서 바르게 시술하나 텐션과 슬라이스 및 파넬양의 처리기능이 미숙한 수준일 때	가위질과 빗질을 무난히 부드럽게 행할 때	외곽선의 흐름, 각 포인트에서의 각도 및 머리전체의 조화가 이루어져 작품의 특성을 나타내는 정도의 수준이 될 때
80	물축이기 및 브로킹이 고르고 정확하며 작업자세가 양호할때	다른 모든 사항은 바르게 하나 텐션과 슬라이스 및 파넬양 처리기능중 어느 하나가 미숙한 수준일 때	가위질, 빗질, 스트랜드의 테이퍼링 및 블런팅이 무리없이 시술되며 조화를 이룰 때	외곽선의 흐름, 각 포인트에서의 각도, 머리전체의 조화가 잘 이루어졌으나 어느부분의 일부 두발 연결이 불안한 감을주는 수준일 때
100	물축이기, 브로킹, 자세등이 모두 우수하고 처리숙련도가 능숙할 때	모두를 정확하고 바르게 시술할 때	위 사항이 모두 능숙하며 두부 부위별 두발의 연결이 종적 횡적 조화를 이룰 때	외곽선의 흐름, 각 포인트에서의 각도, 머리전체의 조화가 매우 우수하여 작품의 특성을 흠없이 완벽하게 표현했을 때

제 3장. 신경회로망의 개요 및 학습 알고리즘

신경회로망은 인간과 의사 소통하고 학습을 통해 지식과 경험을 축적 하여 스스로 상황을 판단할 수 있는 인간과 유사한 것을 만들고자하여 생겨난 인공지능의 한 분야로써, 인간을 비

못한 동물들이 가지고 있는 뇌에 대한 연구결과를 근거하여 인공적으로 지능을 만들어 보고자 하는 연구이다.

다시 말해, 뇌에 존재하는 생물학적 신경세포와 그것들의 연결관계를 단순화시키고 수학적
으로 모델링하므로써 뇌가 나타내는 지능적 형태를 구현해 보고자 하는 것이다.

신경회로망은 개념적으로 매우 단순하며 그러한 단순함에 불구하고 복잡한 뇌가 나타내는
여러 가지 특성들을 보여주고 있다. 특히, 사람의 뇌가 경험을 통해 학습하듯이, 주어진 입력에
대해 자신의 내부구조를 스스로 조직화함으로써 학습해 나가는 능력은 신경회로망이 가지는 독
특한 특성중의 하나이다.

지금까지의 연구 결과를 통해 신경회로망은 애매하고 불완전한 화상, 음성, 문자 등의 패턴
인식과 특징 추출, 로봇이나 플랜트 등의 제어^{[3][4][5][6]}, 각종 센서로부터의 정보 인식, 판단, 계획
등의 처리와 그들 결과를 이용한 조작기(manipulator)의 운동제어, 자기조직화 기능을 적용하면
실시간 제어가 가능하고 동시에 적응성 있는 로봇의 구현이 기대된다. 원인과 결과의 인과 관
계가 애매하고 복잡한 문제 즉, 기후나 지진, 경제문제 등을 신경회로망의 자기 조직화를 이용
하여 복잡하고 어려운 규칙을 자동으로 획득하는 문제 등에 응용되고 있다.

3.1 신경회로망의 배경

신경회로망에 대한 연구는 1943년 맥컬럭(McCulloch)과 피츠(Pitts)에 의해 처음으로 가능성
이 제시되었다. 그들은 인간의 두뇌를 수많은 신경세포들로 이루어진 잘 정의된 계산기라고
생각했다. 단순한 논리적 임무를 수행하는 모델을 보여주었고, 또한 패턴분류 문제가 인간의
지능적인 행위를 규명하는 이론에 매우 중요하다는 것을 인식하였다.

헵(Hebb)은 두 뉴런사이의 웨이트를 조정할 수 있는 최초의 학습 규칙에 대한 제안을 하였
으며, 이 규칙은 학습에 관한 연구를 발전시켰으며 적응적인 신경회로망의 연구에 많은 영향을
끼쳤다.

실질적인 신경회로망에 관한 연구는 로젠블러트(Rosenblatt)의 1957년 퍼셉트론(perceptron) 모
델이 발표되면서부터라 할 수 있다. 여기에서는 학습 프로세스에 알파 강화 규칙을 사용하고
있으며, 퍼셉트론에 대한 관심의 주된 이유는 어떤 타입의 패턴이 입력층에 주어졌을 때 이 모
델이 반응하게 하는 웨이트의 집합을 스스로 발견하는 자동적인 절차에 있다. 학습은 현재 주
어진 입력에 대하여 현재의 각 웨이트를 조정함으로써 얻어질 수 있었다.

민스키(Minsky)와 파퍼트(Papert)등이 '퍼셉트론즈'(perceptrons)란 저서에서 퍼셉트론 모델
을 수학적으로 철저히 분석하여, XOR 함수와 같이 단순한 비선형 분리 문제도 풀 수 없다는
것을 밝혀내고 난 후 신경회로망에 관련된 연구는 약 20년간 침체의 길을 걷게 되었다.

1970년대 말과 1980년대 초반 코호넨(Kohonen), 홉필드(Hopfield), 커크패이트릭
(Kirkpatrick), 힌턴(Hinton), 그로스버그(Grossberg), 러멜하트(Rumelhart)등이 신경회로망을 다
시 활성화시켰다. 여기서 사용되어진 역전파(backpropagation) 학습 알고리즘은 오차를 정정하
는 규칙으로써, 입력에 대해 원하는 반응과 실제로 얻어진 것들에 대한 차이를 줄여 나가는 것
이다. 오류 전파(error propagation)에 의한 내부 학습에서 입력패턴은 충분한 은닉층 유닛들
만 있으면 항상 코드화될 수 있다. 이 과정은 신경회로망의 웨이트를 반복적으로 조정하여 실
제 신경회로망의 벡터와 원하는 출력간의 차이를 줄여 나간다.

3.2 생물학적 뉴런과 인공적 뉴런 사이의 고찰

뉴런(neuron)은 생체 속에서 정보 처리를 위해 특별한 분화로 이루어진 세포이다.

그림 2에 나타난 것처럼 뉴런은 크게 정보처리의 핵심이 되는 세포체, 또는 소마(soma)와 기억의 핵심이 되는 뉴런간의 연결사이에 존재하는 매우 좁은 간극 즉, 시냅스(synapse)의 두 부분으로 이루어져 있다. 생물학적 뉴런의 신호 전달 과정은 시냅스 전 뉴런의 활동 전위 펄스가 시냅스 후 뉴런의 막전위 변화를 일으킴으로써 정보가 전달된다.




그림 2. 생물학적 뉴런의 구조

뉴런은 자신과 연결된 많은 다른 뉴런들로부터 전기, 화학적 신호들을 시냅스를 통해 받아들여 종합한다. 그 값이 임계치(threshold)라고 부르는 뉴런 고유의 한계 값보다 커지면 뉴런은 발화(fire)되어 다른 신경세포에 자신의 출력을 전달한다. 즉, 다른 뉴런들로부터 받아들인 신호들을 종합한 결과, 자신의 내부 전압이 임계치 이상이 되면 그 뉴런은 발화되고, 그렇지 않은 경우 발화되지 않는다.

뉴런들 간의 정보전달 과정에서 매우 중요한 것은 어떤 뉴런들 간에는 비교적 정보가 잘 전달되는 반면, 어떤 뉴런들 간에는 정보가 잘 전달되지 않는다는 점이다. 그리고 이러한 정보전달 정도에 대한 권한과 책임은 시냅스에게 있다. 이러한 뉴런을 수학적으로 모델링하면 그림 3과 같이 된다.

수상 돌기(dendrite)는 다른 뉴런으로부터 입력을 받아들이는 곳으로써 이 입력을 소마로 운송한다. 즉, 그림 3에서 값을 입력하는 부분이다. 소마는 수상 돌기로부터 받은 값들을 처리하는 부분으로 그림 3에서는 값이 집결되는 부분을 말한다.

축색돌기(axon)는 소마로부터 처리된 값을 다른 뉴런으로 전송하는 부분 즉, 출력되는 부분을 말한다. 시냅스에서는 뉴런과 뉴런사이의 신호전송을 담당하는 부분으로써 펄스가 발생했을 때 이 펄스에 의한 전위가 막전위 보다 높았을 때는 흥분성 시냅스가 되어 신호가 전송이 되고 낮을 때는 억제성 시냅스가 되어 신호 전송을 막는다. 일반적으로 시냅스는 신경회로망에




그림 3. 기본적인 뉴런의 구조

서 조정 가능한 웨이트라 한다.
 요약해서 말하면, 그림 3의 뉴런은 입력과 각 입력에 대응하는 웨이트를 곱하여 합한 값 $[\sum(X_i * W_i)]$ 에 대해서 함수관계를 적용한 값을 출력한다. 여기에서 θ 는 뉴런 자체의 임계치 또는 바이어스(bias)로써 $\sum(X_i * W_i)$ 이 임계치 보다 작을 때는 뉴런이 활성화되지 않도록 하는 역할을 한다. 여기서 함수관계를 신경회로망에서는 활성화함수(activation function)라고 하며, 그림 4에 나타내었다.




그림 4. 뉴런의 활성화 함수

신경회로망에서 많이 사용되는 대표적인 활성화함수로는 단극성 함수(unipolar function), 양극성 함수(bipolar function), 그리고 선형 함수(linear function) 등이 있다.

3.3 다층신경회로망과 학습 알고리즘

역전파 학습 알고리즘(back-propagation learning algorithm)은 역사적으로 신경회로망의 발전에 매우 중요한 역할을 한 알고리즘 중의 하나이다.

신경회로망은 뉴런과 시냅스로 구성된 생체의 신경 조직을 단순화시켜 모방한 모델을 기본으로 하고 있으며, 한 절점에서의 뉴런은 인접한 많은 뉴런으로부터 입력신호를 받아서 하나의 결론을 출력하게 되고 시냅스는 뉴런의 출력을 받아서 가중치를 곱한 후 다른 뉴런으로 보내게 된다. 이러한 소자들은 입력층과 출력층 그리고 은닉층으로 나뉘어져 전체 신경망을 구성한다.

은닉층에서는 학습을 통해 습득된 지식을 이용하여 주어진 입력에 대해 관련된 정보를 인출

하게 되는데, 신경회로망의 학습은 신경회로망에 입력패턴이 주어져 신경망의 동작결과인 출력 패턴이 나왔을 때 이것을 입력패턴에 대한 목적패턴과 같아지도록 스스로 자신의 웨이트를 조절하는 반복과정이다. 다시 말해 신경회로망으로 하여금 일련의 자료들을 경험하도록 하여 신경회로망이 주어진 규칙에 따라 스스로 자신의 웨이트를 조절하는 과정이다. 이러한 과정을 그림으로 나타내면 그림 5에서 나타내었다.

그림 5에서 m은 입력층의 노드(node) 수, l은 은닉층의 노드 수, n은 출력층의 노드 수이며, 직선은 전방향전파(forward propagation)를 나타내고 점선은 역방향전파(backward propagation)를 보여주고 있다.

전방향전파 과정은 주어진 입력패턴 x에 대해 은닉층의 q번째 뉴런의 입력으로 받게되는 값으로부터 시작한다.

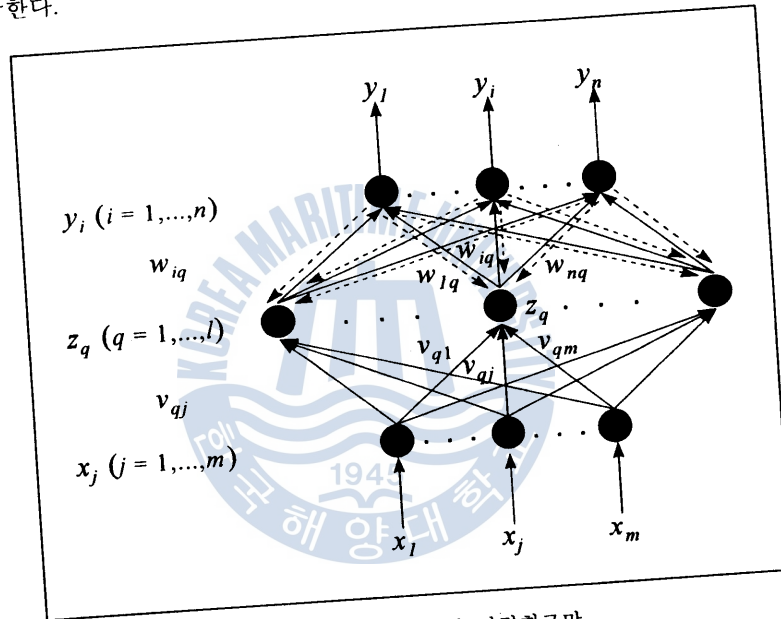


그림 5. 3층구조의 신경회로망

식(1)에 의해 은닉층으로의 입력이 계산된다.

$$\text{net}_q = \sum_{j=1}^m v_{qj} x_j \quad (1)$$

은닉층의 출력은 식(2)와 같다.

$$z_q = f(\text{net}_q) = f\left(\sum_{j=1}^m v_{qj} x_j\right) \quad (2)$$

식(2)의 $f(\cdot)$ 을 활성화함수(activation function)라 한다. 출력층으로의 입력은 식(3)과 같고

$$\text{net}_i = \sum_{q=1}^l w_{iq} z_q = \sum_{q=1}^l w_{iq} f\left(\sum_{j=1}^m v_{qj} x_j\right) \quad (3)$$

신경회로망의 출력으로서는 식(4)와 같다.

$$\begin{aligned} \text{net}_q &= \sum_{j=1}^m v_{qi} x_j \\ y_i &= f(\text{net}_i) = f\left(\sum_{q=1}^l w_{iq} z_q\right) = f\left(\sum_{q=1}^l w_{iq} f\left(\sum_{j=1}^m v_{qi} x_j\right)\right) \end{aligned} \quad (4)$$

식(1)에서 식(4)는 주어진 입력으로부터 뉴런층을 통하는 전방향으로 전파되는 과정을 나타낸 것이다.

역방향전파 과정은 주어진 오차에 대한 역전파 과정이다.

우선 학습에 사용되는 평가함수(cost function)는 식(5)와 같이 정의한다.

$$\begin{aligned} E(\mathbf{w}) &= \frac{1}{2} \sum_{i=1}^n (d_i - y_i)^2 = \frac{1}{2} \sum_{i=1}^n [d_i - f(\text{net}_i)]^2 \\ &= \frac{1}{2} \sum_{i=1}^n \left[d_i - f\left(\sum_{q=1}^l w_{iq} z_q\right) \right]^2 \end{aligned} \quad (5)$$

주어진 경사하강법(gradient-decent method)에 의해 은닉층과 출력층사이의 웨이트를 식(6)에 의해 갱신한다.

$$\Delta w_{iq} = -\eta \frac{\partial E}{\partial w_{iq}} \quad (6)$$

식(6)에서 사용되는 갱신 규칙 $\partial E / \partial w_{iq}$ 은 식(7)로 풀이할 수 있다.

$$\begin{aligned} \Delta w_{iq} &= -\eta \left[\frac{\partial E}{\partial y_i} \right] \left[\frac{\partial y_i}{\partial \text{net}_i} \right] \left[\frac{\partial \text{net}_i}{\partial w_{iq}} \right] \\ &= \eta [d_i - y_i] [f'(\text{net}_i)] [z_q] \triangleq \eta \delta_{oi} z_q \end{aligned} \quad (7)$$

여기에 사용된 δ_{oi} 은 출력층의 i-th 노드에 대한 오차신호(error signal)이고, 식(8)에 의해 정의된다.

$$\begin{aligned} \delta_{oi} &\triangleq -\frac{\partial E}{\partial \text{net}_i} = -\left[\frac{\partial E}{\partial y_i} \right] \left[\frac{\partial y_i}{\partial \text{net}_i} \right] \\ &= [d_i - y_i] [f'(\text{net}_i)] \\ f'(\text{net}_i) &: \partial f(\text{net}_i) / \partial \text{net}_i \end{aligned} \quad (8)$$

입력층과 은닉층사이의 웨이트는 식(9)에 의해 갱신된다.

$$\begin{aligned} \Delta v_{wj} &= -\eta \left[\frac{\partial E}{\partial v_{wj}} \right] = -\eta \left[\frac{\partial E}{\partial \text{net}_q} \right] \left[\frac{\partial \text{net}_q}{\partial v_{wj}} \right] \\ &= -\eta \left[\frac{\partial E}{\partial z_q} \right] \left[\frac{\partial z_q}{\partial \text{net}_q} \right] \left[\frac{\partial \text{net}_q}{\partial v_{wj}} \right] \end{aligned} \quad (9)$$

식(7)에 의해 식(9)은 식(10)으로 유도된다.

$$\Delta v_{wj} = \eta \sum_{i=1}^n (d_i - y_i) f'(\text{net}_i) w_{iq} | f'(\text{net}_q) x_j \quad (10)$$

식(10)를 정리하면 식(11)과 같이 쓸 수 있다.

$$\Delta v_{qj} = \eta \sum_{i=1}^n [d_{oi} w_{iq}] f'(\text{net}_q) x_j = \eta \delta_{hq} x_j \quad (11)$$

식(11)에서 δ_{hq} 은 은닉층으로부터 만들어지는 오차신호이고 식(12)와 같이 정의된다.

$$\begin{aligned} \delta_{hq} &\triangleq - \frac{\partial E}{\partial \text{net}_q} = - \left[\frac{\partial E}{\partial z_q} \right] \left[\frac{\partial z_q}{\partial \text{net}_q} \right] \\ &= f'(\text{net}_q) \sum_{i=1}^n \delta_{oi} w_{iq} \end{aligned} \quad (12)$$

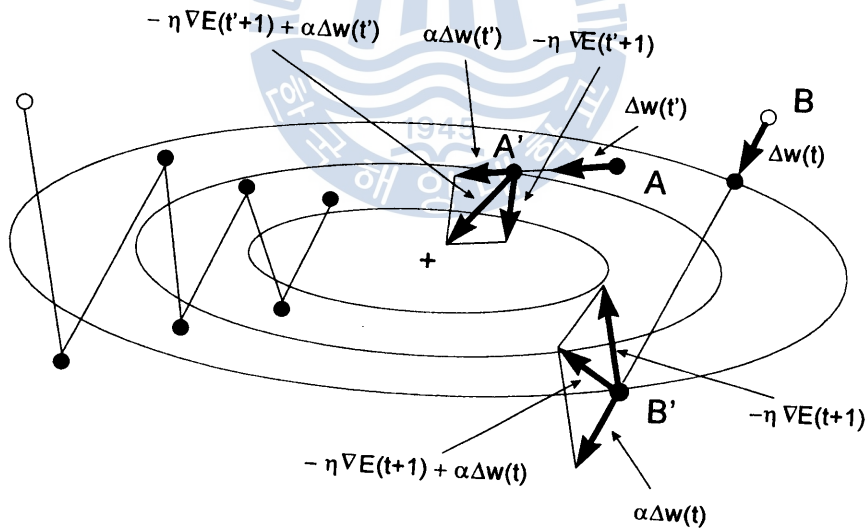
이상과 같은 갱신방법을 “generalized delta learning rule” 이라 부른다. 또한, 웨이트의 갱신은 학습의 가속화를 위해 모멘텀항(momentum coefficient)을 첨가한 경사하강법에 의해 학습되어진다.

$$\Delta v_{qi}(t+1) = \alpha \Delta v_{qi}(t) - \eta \frac{\partial E}{\partial v_{qi}} \quad (13)$$

$$\Delta w_{iq}(t+1) = \alpha \Delta w_{iq}(t) - \eta \frac{\partial E}{\partial w_{iq}} \quad (14)$$

α : 모멘텀항

η : 학습율



[일반학습]

[모멘텀을 첨가한 학습]

그림 6. 2차평면에 대한 예러 경사 하강법

위 식을 그림으로 나타내면 그림 6과 같다.

위 그림 6에서 왼쪽 부분은 모멘텀항이 없을 때의 경로를 나타내는 것이고, 오른쪽 부분은 모멘텀항을 추가했을 때에 나타나는 경로를 나타낸 그림이다. 위에서 보는 바와 같이 모멘텀항이 있을 때의 학습속도가 상대적으로 빠르다는 것을 알았다.

제 4장. 신경회로망을 이용한 Hair-Cut 실기 평가

먼저 그림 7과 같은 시험대상물에 대한 Hair-Cut 실기 평가 방법에 대해서 나타내면 그림 8과 같다.




그림 7. 헤어커트 실기 시험 대상물

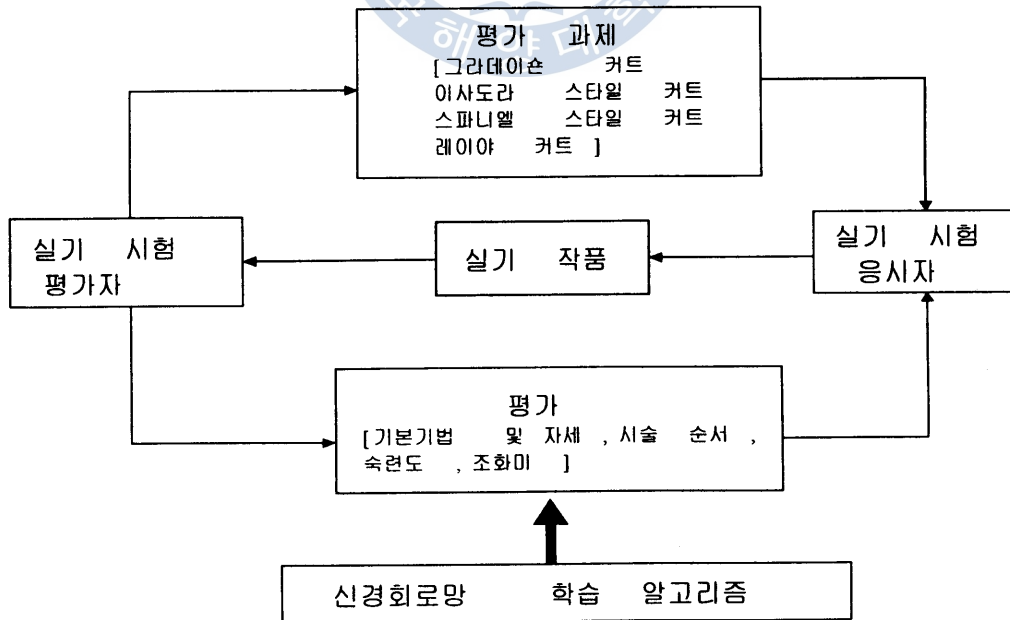


그림 8. 헤어커트 평가 방법

그리고 신경회로망 학습 알고리즘을 도입한 헤어커트 평가 방법의 블록도를 그려보면 그림 9와 같다.

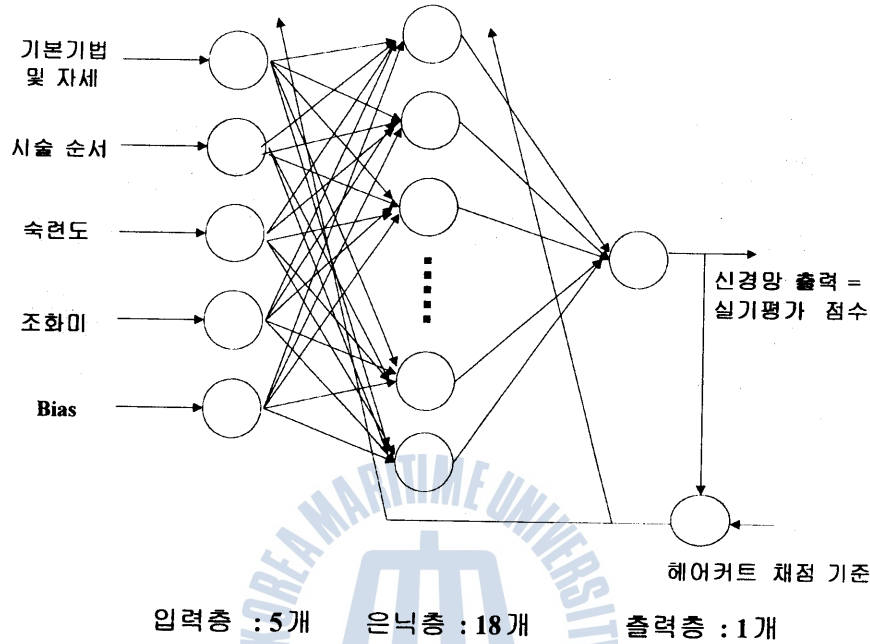


그림 9. 신경회로망을 도입한 헤어커트 평가 블록도

본 논문에서 사용된 신경회로망의 구조는 그림 9에서 나타내었고 세부사항은 다음과 같다.

- ① Activation function : $\lambda = 0.001$, bipolar
- ② Learning constant : $\eta = 5.95$
- ③ Momentum : 0.9
- ④ Input node : 5 (바이어스 : -1 포함)
- ⑤ Hidden node : 18 (바이어스 : -1 포함)
- ⑥ Output node : 1

최종적으로 각각의 파라미터가 ①~⑥과 같을 때 양호한 학습속도를 보였고, 오차율 0.1%에 쉽게 접근 하였으며 활성화함수는 시그모이드 함수를 사용했다.

그 구조를 살펴보면 입력층은 뉴런의 수가 5개로 각각의 뉴런에 입력되는 변수는 평가 항목 기본기법 및 자세, 시술 순서, 숙련도, 조화미, Bias 등이고 출력층의 출력값은 실기평가 점수이다.

여기서 사용되어진 신경회로망은 3장에서 제시된 다층 신경회로망을 사용하였고 학습 알고리즘으로는 오류 역전파 알고리즘을 사용했다.

채점 기준에 따라 각각의 입력에 대하여 컴퓨터 시뮬레이션을 실행하였다.

시뮬레이션하기 위한 데이터를 표2와 같이 구성한다.

각각의 입력 변수 패턴에 대하여 출력변수의 값이 나오도록 학습하였다.

각각의 입력 변수에 해당하는 것이 있으면 1, 그렇지 않으면 0을 입력 뉴런에 입력하고 그 학습 패턴수는 80개로 하였다.

표 2 입력과 출력변수에 대한 신경회로망의 학습 데이터

종목 점수(출력변수)	입력 변수			
	기본기법 및 자세(X_1)	시술순서(X_2)	숙련도(X_3)	조화미(X_4)
20	0, 1	0, 1	0, 1	0, 1
40	0, 1	0, 1	0, 1	0, 1
60	0, 1	0, 1	0, 1	0, 1
80	0, 1	0, 1	0, 1	0, 1
100	0, 1	0, 1	0, 1	0, 1

제 5장. 실험 결과

이 장에서는 본 연구에서 제안한 신경회로망 학습 알고리즘을 이용한 학습의 결과를 보여준다.

예 1)

종목 점수(출력변수)	입력 변수			
	기본기법 및 자세(X_1)	시술순서(X_2)	숙련도(X_3)	조화미(X_4)
20	0	0	0	0
40	1	0	0	0
60	0	0	0	0
80	0	0	1	1
100	0	1	0	0

출력값 $Y = 76.2$

예 2)

종목 점수(출력변수)	입력 변수			
	기본기법 및 자세(X_1)	시술순서(X_2)	숙련도(X_3)	조화미(X_4)
20	0	0	0	0
40	0	0	0	0
60	1	0	1	0
80	0	1	0	1
100	0	0	0	0

출력값 $Y = 68.9$

예 3)

종목 점수(출력변수)	입력 변수			
	기본기법 및 자세(X_1)	시술순서(X_2)	숙련도(X_3)	조화미(X_4)
20	0	0	0	0
40	0	0	0	0
60	1	0	0	0
80	0	1	0	1
100	0	0	1	0

출력값 $Y = 82.2$

제 6장. 결 론

본 논문에서는 헤어커트 실기 시험 평가 방법에 신경회로망을 적용하여 평가자의 주관적이고 애매한 평가방법의 문제점을 객관적이고 공정한 평가 방법으로 평가하는 방법을 제시하여 그 타당성을 검토하였다.

먼저 다층 구조 신경회로망 시스템을 설명하고 헤어커트 실기 시험 평가 시스템의 구성 및 그 학습 알고리즘을 제시하였다. 그리고 제시된 알고리즘의 컴퓨터 시뮬레이션을 통해 기대한 결과를 얻을 수 있었으며, 이 방법을 실기 평가의 모든 분야에 적용하면 보다 더 좋은 평가 방법이 될 것으로 사료된다.

참 고 문 헌

- [1] T. J. Sejnowski and C. R. Rosenberg, "Parallel networks that learn to pronounce English text", Complex Syst., Vol.1 pp. 145-168, 1987.
- [2] Richard C. Port, Robert H. Bishop, "Modern Control Systems" 7th edition, Addition-Wesley Publishing Company. Inc, pp.30-169, 1995.
- [3] K. S. Narendra and K. Parthasarathy, "Neural networks and dynamical systems. Part I: A gradient approach to Hopfield networks", Center Syst. Sci., Dept. Electrical Eng., Yale University, New Haver, CT, tech. rep. 8820, Oct. 1988.
- [4] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators", Dept. Economics, University of California, San Diego, CA, discussion pap., Dept. Economics, June 1988.
- [5] K. S. Narendra and L. E. McBridge, Jr., "Multiparameter self-optimizing system using correlation techniques", IEEE Trans. Automat. Contr., vol. AC-9, pp. 31-38, 1964.
- [6] S. Weerasooria and M. A. El-Sharkawi, "Identification and Control of a dc motor using back-propagation neural network", IEEE Trans. on Energy Conversion, vol. 6, no. 4, Dec. 1991.
- [7] M. Minsky and S. Paper, Perceptrons, MIT Press, 1969.
- [8] Y. Chen and F. Bastani, "ANN with Two Dendrite Neurons and Weight Initialization", Proc. IJCNN, Baltimore, Vol.III, pp.139-146, 1992.
- [9] C. Koch, T. Poggio, "Multiplying with Synapses and Neurons", in Single Neuron Computation, T. Mckenna, J. Davis, and S. F. Zonnetzer[eds.], pp. 3165-3455, 1992.
- [10] Jacek M. Zurada, Introduction to Artificial Neural Systems., West Publishing Company, pp. 163-235, 1993.
- [11] Siger Omatu, Mazuki Khalid and Rubiyah Yusof, "Neuro-Control and its Application", Springer, pp. 96-118, pp.34-166, 1996.