

신경망을 사용한 뇌파 및 Artifact 자동 분류*

안창범* · 이택용* · 이성훈**

=Abstract=

Automatic EEG and Artifact Classification Using Neural Network

Chang Beom Ahn*, Taek Yong Lee*, and Sung Hoon Lee**

The Electroencephalogram(EEG) and evoked potential(EP) have widely been used for study of brain functions. The EEG and EP signals acquired from multi-channel electrodes placed on the head surface are often interfered by other relatively large physiological signals such as electromyogram(EMG) or electroculogram(EOG). Since these artifact-affected EEG signals degrade EEG mapping, the removal of the artifact-affected EEGs is one of the key elements in neuro-functional mapping. Conventionally this task has been carried out by human experts spending lots of examination time. In this paper a neural-network based classification is proposed to replace or to reduce human expert's efforts and time. From experiments, the neural-network based classification performs as good as human experts: variation of decisions between the neural network and human expert appears even smaller than that between human experts.

Key words : EEG, Artifact, Neural Network, Classifier

서 론

뇌파(EEG) 및 뇌유발전위(Evoked Potential)를 이용한 영상 시스템은 뇌의 기능을 2차원 topography 형태로 볼 수 있기 때문에 X-ray 단층촬영(Computerized Tomography)이나 핵자기 공명 영상(Magnetic Resonance Imaging) 등에 의하여 얻어지는 구조적 영상과는 다른 정보를 제공해준다¹⁾. 머리에 부착된 전극들로부터 수신된 미세한 뇌파는 증폭 및 디지털 변환을 거쳐 컴퓨터에 저장되며 여러 가지 시간 및 공간, 주파수 영역 등에서의 신호처리를 거치게 된다. 이 과정에서 중요한 것은 artifact가 없는 뇌파

를 분리하여 선택적으로 신호처리에 사용하는 것이다²⁾. Artifact의 주요원인은 환자의 움직임에 기인하는데 특히 눈은 뇌와 밀접한 연관이 있기 때문에 눈의 움직임은 artifact 발생의 주원인이 된다³⁾. 일반적으로 좋은 뇌파신호는 주기성이 강하고 진폭의 변화가 그다지 크지 않은 반면에 artifact를 가지고 있는 뇌파는 주기성이 약하고 진폭의 변화가 심하다. 그러나 정량적인 판단기준은 알려지지 않고 있으며 전문가의 경험적인 지식에 의존하고 있다. 기존의 대부분의 뇌파 및 뇌유발전위 시스템들은 수신된 뇌파를 전문가(의사)가 직접 눈으로 확인하면서 뇌파와 artifact를 판정해 왔는데 이때 많은 시간이 소요되고 또한 이과정

* 광운 대학교 전기공학과

* Department of Electrical Engineering, Kwangwoon University

** 연정 뇌기능 수면 연구소

** Yonjung Brain Function and Sleep Research Center

* 본 논문은 상공자원부에서 시행한 공업기반기술개발사업의 지원을 받았음.

통신저자: 안창범, (139-701)서울시 노원구 월계동 447-1 광운대학교 전기공학과, Tel. (02) 940-5148, Fax. (02) 909-3159




그림 1. 국제 뇌파 및 임상 신경대사 협회에서 추천하는 10-20 시스템의 32개 전극(32 채널) 배치도.

Fig. 1. The 32 channel electrode placement recommended by the International Federation of Societies for Electroencephalography and Clinical Neurophysiology known as 10-20 system.

전체 시스템의 자동화에 큰 제약이 되어 왔다. 본 논문의 목적은 전문가가 artifact를 판정하는 경험적 지식을 이용하여 전문가 수준의 신경망을 구성하는데 있다^{4,5}.

뇌파신호와 전처리과정

본 논문에서 뇌파신호는 머리표면에 부착된 32개의 전극(32 채널)으로부터 수신된다. 32개의 전극은 그림 1과 같이 국제 뇌파 및 임상 신경대사 협회에서 추천하는 10~20 시스템으로 배치되어 있다⁶. 32개의 전극들을 통하여 들어오는 뇌파신호는 디지털 신호처리를 위하여 각 채널마다 1초당 256샘플을 하였으며 해상도는 12bits/샘플을 사용하였다. 연속적으로 수신된 뇌파신호는 epoch라 불리는 단위시간으로 나뉘어져 전처리 과정을 거친 후 epoch 단위로 양질의 뇌파인지 artifact 인지를 판정 받게 된다⁷. 본 논문에서는 한 epoch를 1 초로 하였으며, 이 경우 1Hz의 주파수 해상도를 가지게 된다. 신경망학습은 궁극적으로 입력데이터의 특징과 바라는 출력값 간의 상관과정으로 볼 수 있는데 입력데이터 특징을 신경망이 보다 잘 추출할 수 있도록 전처리 과정을 거침으로써 신경망의 학습효율을 향상시킬 수 있다. 본 연구에서 사용한 전처리 과정의 block diagram을 그림 2에 나타내었으며 각 과정

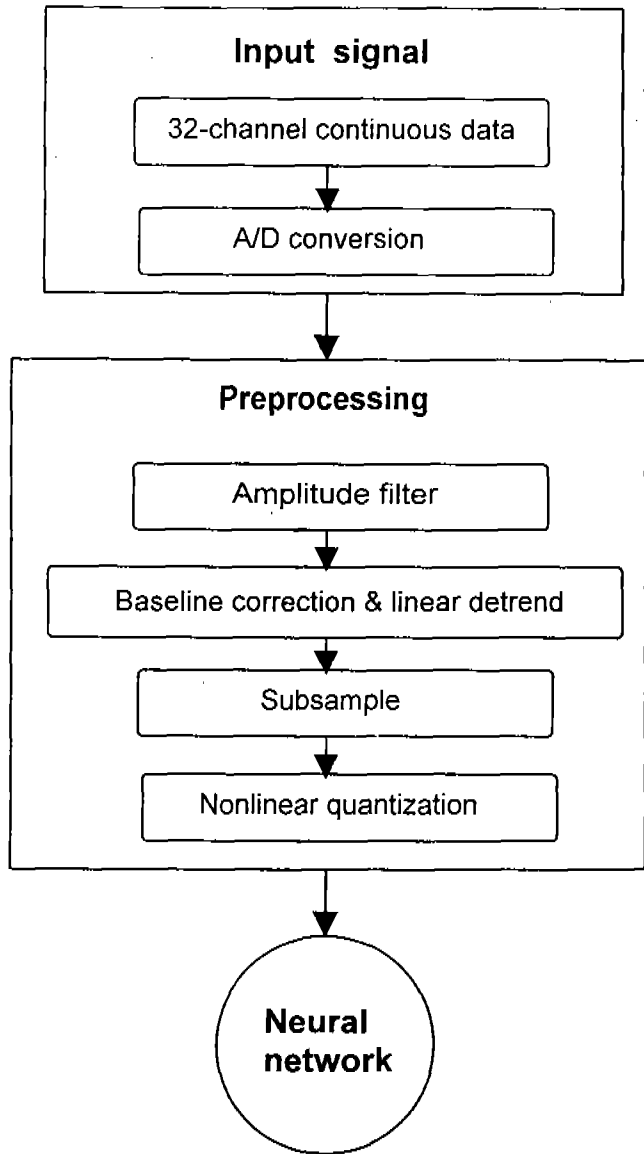



그림 2. 입력 데이터의 전처리 과정에 대한 전체 block diagram.

Fig. 2. Block diagram for the preprocessing of the EEG signal for the neural network.


에 대한 설명은 아래와 같다.

1. 신호크기 검사, baseline 교정 및 선형 교정

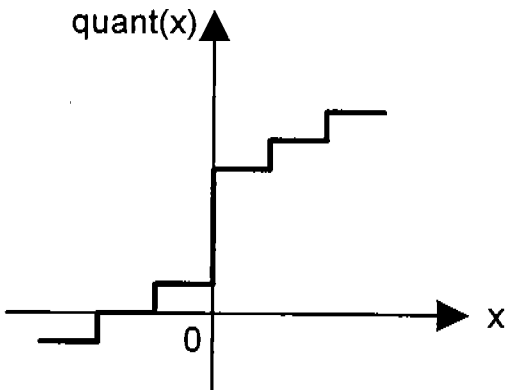
신호크기 검사는 입력데이터의 크기를 검사하여 offset이나 기타 다른 큰 생체신호에 의하여 뇌파신호가 포화(saturated)되었거나, 또는 전극의 접촉 불량으로 인하여 신호가 지나치게 작은 경우를 배제한다. 신호크기 검사를



(a) Bilevel quantizer



(b) Multilevel quantizer



(c) Hybrid nonlinear quantizer

그림 3. 입력 뇌파신호의 전처리 과정에 사용된 세가지 양자기들.

Fig. 3. Three quantizers used for the preprocessing of EEG data for the neural network.

통과한 뇌파신호는 전기적인 offset을 제거하기 위하여 신호의 d. c. 값에 해당하는 baseline 교정과 환자의 움직임과 관련한 선형적으로 증가하거나 감소하는 artifact를 제거하기 위한 선형 교정을 적용한다.

2. Subsampling

전문가가 뇌파와 artifact를 분류할 때 입력신호의 일부 특징보다 전체적인 파형에 기초를 두어 판정하는 것을 고려하여 본 논문에서는 256 샘플된 뇌파신호를 4개의 샘플 points 마다 1개씩을 취하여 샘플수를 64 points로 줄였다. Subsampling은 신경망의 입력 특징 추출을 용이하게 할 뿐만 아니라 신경망의 입력노드 수를 줄여서 학습 수렴 및 처리속도에 향상을 가져온다.

3. 비선형 양자기

신호크기의 양자화는 subsampling과 유사하게 신경망의 입력 특징 추출을 용이하게 하고 학습 수렴속도를 향상시킨다. 다양한 신경망 양자기에 대한 시뮬레이션을 통하여 학습 및 일반화 과정에 효율적인 것으로 판명된 대표적인 양자기를 소개하면 그림 3과 같다.

1) 이치 양자기

입력데이터의 값을 두 단계로 양자화함으로서 뇌파신호의 진폭보다는 주기적인 특성을 강조한 양자기이다(그림 3(a)). 즉

$$\text{quant}(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

여기에서 x 는 입력(-2048 ~ 2047)을 나타내고 $\text{quant}(x)$ 는 양자기 출력을 나타낸다. 이치 양자기를 사용할 경우 학습수렴 및 처리속도가 빠르고 학습된 신경망의 성능도 전문가와 근사하게 나타난다. 이것은 전문가가 artifact를 판정할 때 뇌파의 주기적인 성질에 중점을 두어 판단하는 것과 일치한다.

2) 다치 양자기

다치 양자기는 입력데이터의 크기에 비례하는 양자값을 가짐으로써 이치 양자기에 비하여 뇌파신호의 진폭특성에 보다 중점을 둔다(그림 3(b)).

$$\text{quant}(x) = \text{int}(x/10) + \alpha \quad (2)$$

여기에서 α 는 신경망의 입력 bias에 해당하며 양자화출력을 0에 대해 비대칭적으로 만들기 위해 도입된 상수이다. 양자기의 출력이 0에 대하여 대칭적으로 주어졌을 경우 연결강도 간에 상쇄효과가 있어 신경망의 일반화에 어려움이 많은 것으로 나타났다. 다치 양자기의 성능은 관련 파라미터의 설정값에 따라 이치 양자기와 비슷한 특성을

보이고 있다(그림 8).

3) 복합 비선형 양자기

복합 비선형 양자기는 신경망의 입력노드에 뇌파신호의 주기적인 성질과 진폭정보를 동시에 제공하는 양자기로서 주기성을 강조하는 이치 양자기의 장점과 파형의 진폭을 나타내는 다치 양자기의 장점을 최대한으로 활용하였다(그림 3(c)). 복합 비선형 양자기는 입력신호의 주기성을 강조하기 위하여 입력값의 0 부근에 큰 폭의 양자화 step size를 가지고 있다. 즉

$$quant(x) = \begin{cases} int(x/10) + \beta, & x \geq 0 \\ int(x/10) + \gamma, & x < 0 \end{cases} \quad (3)$$

여기에서 β 및 γ 는 신경망의 입력 bias로 0 부근의 양자화 step size를 크게 하기 위하여 도입된 상수들이다. 복합 비선형 양자기는 본 논문에서 제안하는 뇌파 및 artifact분류의 신경망 운영특성곡선에서 가장 우수한 성능을 보이고 있다(그림 8).

신경망 구성 및 학습

본 논문에서 사용한 신경망은 그림 4에서 보인 multilayer perceptron 구조로 입력층, 은닉층, 출력층의 3층으로 구성되어 있다^{8,9)}. Multilayer perceptron은 입력노드에 연결된 뇌파의 정보가 연결강도를 통하여 은닉층으로 전달되며, sigmoid 함수를 거친 은닉층의 결과가 또 다른 연결강도를 통하여 출력층으로 전달된다(순방향 전파). 출력층으로 전달된 신호는 sigmoid 함수를 거쳐 신경망의 출력으로 나타난다. 본 논문에서는 한 epoch를 단위로 전처리 과정을 거친 각 채널의 뇌파신호를 입력신호로 사용하였고(입력노드 수:64), 단층인 은닉층 노드 수는 입력노드의 수와 동일하게 하였다(은닉층 노드 수:64). 1개의 출력노드를 통하여 얻어지는 출력은 0에서 1사이의 연속적인 값을 갖게 된다. 즉

$$H_j = f\left(\sum_i W_{ji}^h I_i\right) \quad (4)$$

$$O = f\left(\sum_j W_j^o H_j\right)$$

여기에서 I 는 전처리된 입력값이며, H 는 은닉층 노드 출력을 나타내고, O 는 출력노드 값이다. W_{ji}^h 는 j 번째 은닉층 노드와 i 번째 입력노드 간의 연결강도를 나타내고 W_j^o 는 j 번째 은닉층 노드와 출력노드 간의 연결강도를 나타낸다. f 는 sigmoid 함수로서 아래와 같이 정의된다.

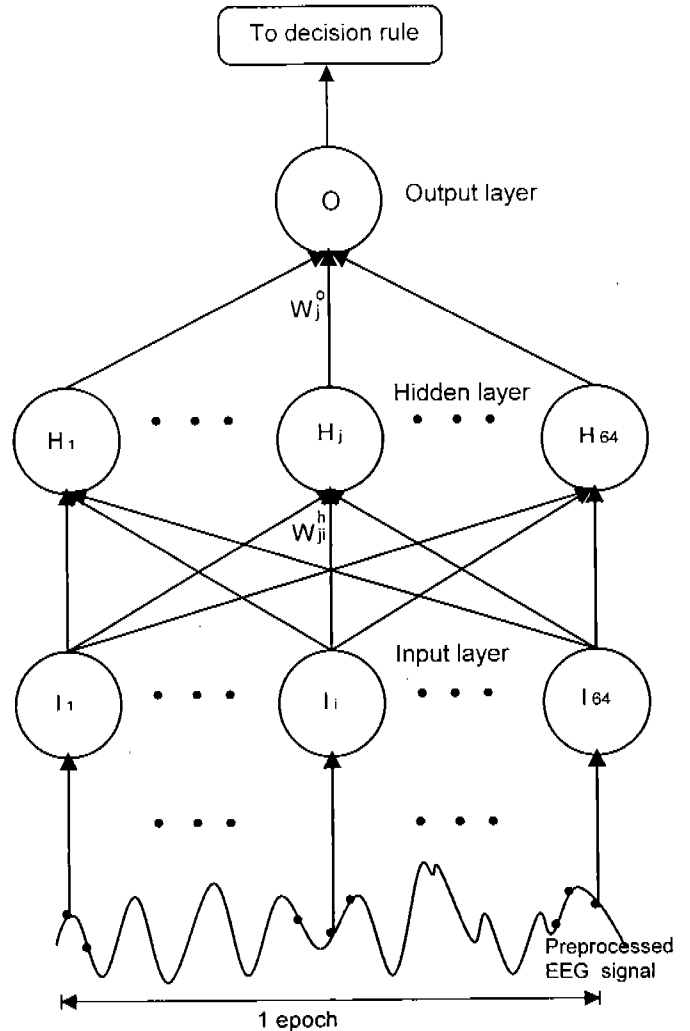


그림 4. Artifact 자동판정 시스템에서 사용한 신경망 구조. 신경망 구조는 3층으로 구성된 multilayer perceptron으로서 입력층 및 은닉층의 노드수는 각각 64개씩이고 출력층 노드수는 1개로 구성되어 있다.

Fig. 4. Neural network architecture used for the automatic EEG and artifact classifier. The network is composed of three layers, i. e., the input layer with 64 nodes, the hidden layer with 64 nodes, and the output layer with a single output node.

$$f(x) = \frac{1}{1+e^{-x}} \quad (5)$$

신경망의 학습을 위해서는 전문가가 뇌파신호를 판정한 데이터를 기반으로 역전파(backpropagation) 알고리즘을 사용하였다⁸⁾. 이 알고리즘은 입력노드의 정보가 연결강도를 통하여 순방향으로 전달된 신경망 출력과 바람직한 출력값 간의 오차를 역방향으로 전파하여 오차가 최소가 되

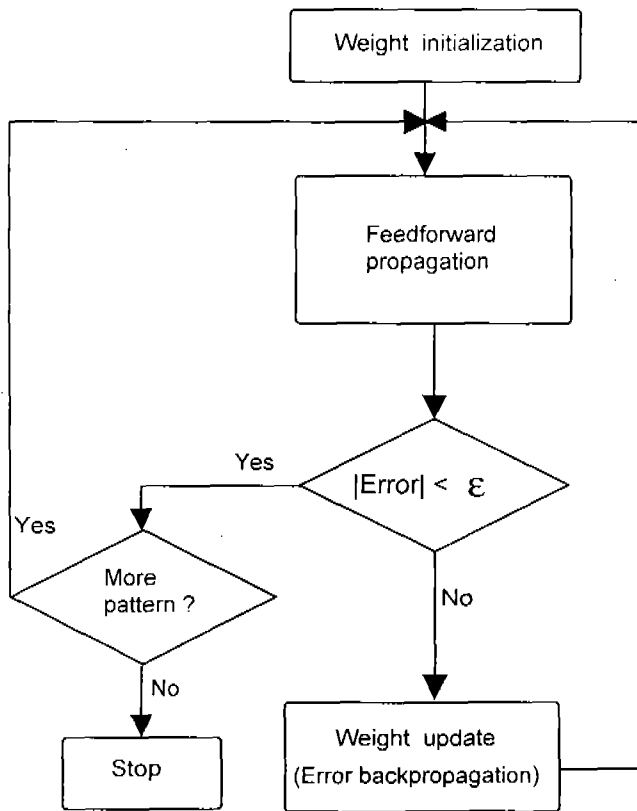


그림 5. 본 논문에서 사용한 학습 알고리즘. 전문가에 따른 뇌파 분류의 변동성질을 고려하여 오차허용범위(ε)를 설정하여 신경망이 전반적인 과형인식을 하도록 하였다.

Fig. 5. Schematic diagram of the learning algorithm of the neural network. Due to the inherent fuzzy character of the expert-dependent variation of the EEG and artifact classification, an error allowance(ε) is introduced.

도록 연결강도를 갱신하는 것이다. 즉

$$\begin{aligned}
 W_j^o(n) &= W_j^o(n-1) + \eta \delta^o H_j \\
 W_{jk}^h(n) &= W_{jk}^h(n-1) + \eta \delta_j^h I_i
 \end{aligned}
 \tag{6}$$

여기에서 $W_j^{o(n)}$ 과 $W_{jk}^{h(n)}$ 은 각각 n 번째 추정된 연결강도를 나타내고, η 는 학습을 파라미터로서 0과 1사이의 값이다. 또한

$$\begin{aligned}
 \delta^o &= (D-O)O(1-O) \\
 \delta_j^h &= H_j(1-H_j) \delta^o W_j^o
 \end{aligned}
 \tag{7}$$

이고 D는 원하는 출력값을 나타낸다.

그림 5는 신경망 학습 과정을 도식적으로 나타내고 있다. 그림 5에서 ε는 오차 허용범위로서 신경망의 학습 및 일반화과정에 중요한 영향을 미치는 파라미터이다. 일반

적으로 prototype이 정해져 있는 패턴인식 등에서의 신경망 학습은 원하는 출력과 신경망 출력간의 오차를 가능한 최소로 하는 것이(이론적으로는 0) 바람직하다. 그러나 본 연구의 뇌파분류에서는 명확한 prototype이 없기 때문에 전문가에 따라 분류가 상당히 다를 수 있어 각각의 입력신호에 대하여 오차가 거의 0이 되도록 연결강도를 바꾸어 나가는 것은 신경망 학습과정의 수렴에 어려움을 가져올 수 있고, 또한 전체적인 성능을 떨어뜨릴 수도 있다. 인위적으로 만든 신호(또는 패턴)들과는 달리 생체신호인 뇌파는 분류에 있어 근원적으로 애매모호한(fuzzy) 특성을 갖기 때문에 본 연구의 학습과정에서는 다소 오차를 허용함으로써 경우에 따라서 잘못 내려진 판정일 수도 있는 특정한 sample 과형에 의하여 연결강도가 크게 지배받지 않도록 하였다.

신경망의 학습에 사용된 데이터는 전문가에 의하여 “양질의 뇌파”, “중질의 뇌파”, “artifact”의 세가지 유형으로 분류되었으며, 원하는 출력으로 각각 1.0, 0.5, 0.0이 할당되었다. 이상적으로는 양질의 뇌파에 가까운 정도에 따른 0에서 1 사이의 연속적인 값의 할당과 이에 따른 학습이 바람직하나 현실적으로 전문가의 판정에 어려움이 많아 세가지 분류를 채택하여 학습을 시켰다. 따라서 신경망의 학습은 신경망의 출력 노드값이 세가지 유형으로 분류된 학습데이터에 대하여 바라는 출력값의 오차허용범위 이내가 되도록 연결강도를 조절하는 것이다.

실제 임상적용에서는 측정된 데이터를 뇌파와 artifact의 두가지로만 분류하여 artifact는 버리고 뇌파만을 처리하여 topography를 만들게 되므로 신경망의 출력 다음단에 최종 판정을 위한 decision rule을 도입하였다. Decision rule은 학습이 완료된 신경망에 독립적으로 적용되었으며 신경망의 일반화시험 등의 성능평가에서는 실제 임상적용과 동일하게 decision rule을 포함하여 시험하였다. 최종 판정을 신경망의 출력과 decision rule의 두 단계로 분리시킨 것은 보다 효과적인 학습과 측정된 데이터의 특성에 따라 뇌파와 artifact의 분류를 interactive하게 조절할 수 있도록 하기 위한 것이다.

전문가가 판정한 세가지 뇌파신호의 예를 그림 6에 나타내었다. 그림 6에서 볼 수 있듯이 좋은 뇌파신호는 주기성이 강하고 진폭의 변화가 그다지 크지 않은 반면에 artifact를 가지고 있는 뇌파는 주기성이 약하고 진폭의 변화가 심함을 알 수 있다. 신경망의 학습에 사용된 전문가가 판정한 뇌파신호의 분포를 표 1에 나타내었다. 학습 및 시험데이터는 신경망의 성능과 평가에 중요한 영향을 미치므로 본 논문에서는 전문가가 동일한 데이터 set를 사용




그림 6. 전문가가 판정한 뇌파신호의 예. 가로축은 1 epoch에 해당되는 1초간의 시간을 나타내고 세로축은 amplitude 를 나타낸다. (a), (b): 양질의 뇌파, (c), (d): 중질의 뇌파, (e), (f): artifact.

Fig. 6. Typical waveforms of good EEG and artifact. The horizontal axis denotes the time period of 1 second (1 epoch) and the vertical axis denotes amplitude of the measured EEG. Typical waveform of good EEG are shown in (a) and (b), middle quality EEG are in (c) and (d), and artifact are in (e) and (f).

의 시간간격을 가지고 반복적으로 분류하여 분류가 일치하는 데이터만을 추출하여 사용하였다(분류가 일치하는 데이터는 전체 데이터의 약 78% 였다).

양질 및 중질의 뇌파와 artifact의 세가지로 분류한 학습 데이터를 오차허용범위를 ϵ 으로 하여 학습시킨 신경망은 학습데이터에 대하여 다음의 출력범위를 갖게 된다.

$$O \in \begin{cases} (0, \epsilon), & \text{artifact} \\ (0.5 - \epsilon, 0.5 + \epsilon), & \text{중질의 뇌파} \\ (1 - \epsilon, 1), & \text{양질의 뇌파} \end{cases} \quad (8)$$

따라서 학습데이터에 대한 신경망의 출력분포는 ϵ 의 설정에 따라 (0, 1) 까지 연속적일 수도 있고 ($\epsilon = 0.25$), 또는 불연속적인 구간을 가질 수도 있다 ($\epsilon < 0.25$). 식 (8)에서 중질의 뇌파는 양질의 뇌파나 artifact에 비하여 분류의 불확실성이 커서 보다 넓은 구간 (2ϵ)을 허용하였다. 이것은 신경

표 1. 신경망의 학습에 사용된 뇌파 분포. 여기에서 epoch는 1 초로 하였고 주파수의 해상도는 1Hz 이다.

Table 1. Distribution of the EEG learning data set segmented by the period of an epoch (1 second) for the neural network.

EEG Class	Number of epochs	Ratio (%)
Good EEG	225	45
Middle quality EEG	115	24
Artifact	155	31
Total	495	100

망의 학습에서 중질의 뇌파를 최소로 사용하였음을 뜻한다. 충분히 많은 데이터로 학습이 잘된 신경망일 경우 학습에 사용되지 않은 일반 데이터가 입력 되었을 때 출력은 좋은 뇌파에 가까울수록 1에, artifact에 가까울수록 0에 접근할 것으로 기대된다. 뇌파 및 artifact의 분류는 신경망의 출력에 아래의 decision rule을 적용하여 최종적으로 얻어진다.

$$D = \begin{cases} \text{양질의 뇌파}, & O \geq T \\ \text{artifact}, & O < T \end{cases} \quad (9)$$

여기에서 D 는 판정을 나타내고, T 는 문턱값을 나타낸다.

신경망의 운영특성곡선 및 적용

신경망의 성능은 전처리 과정에서의 양자기 종류, 신경망 학습과정에서의 오차허용범위, decision rule의 문턱값 등 여러 가지 요소에 의하여 영향을 받게 되는데 최적의 신경망을 구성하기 위해서는 객관적인 성능평가 및 비교가 필요하다. 본 논문에서는 통신 분야에서 널리 사용되고 있는 수신기 운영특성 (Receiver Operating Characteristics: ROC) 곡선과¹⁰⁾ 유사하게 신경망 운영특성 (Neural network Operating Characteristics: NOC) 곡선을 정의하여 객관적인 평가의 기준으로 삼았다. 신경망 운영특성곡선은 출력노드의 문턱값을 매개변수로 하여 세로축에 양질의 뇌파를 바르게 판정한 확률 (P_R : right identification probability)과 가로축에 신경망이 artifact를 양질의 뇌파로 잘못 판정한 확률 (P_F : false identification probability)을 이차원적으로 나타낸 것이다.

그림 7과 같이 측정된 데이터 집합에서 양질의 뇌파와 중질의 뇌파, 그리고 artifact의 집합을 각각 S_G, S_M, S_A 로 나타내고, 신경망의 출력에 decision rule을 적용하여 최종




그림 7. 전문가가 분류한 양질의 뇌파(S_G), 중질의 뇌파(S_M), artifact(S_A)의 집합과 신경망과 decision rule에 의하여 양질의 뇌파로 판정된 집합(S_N)의 Venn diagram.

Fig. 7. Venn diagram for the EEG data classes. The S_G , S_M , and S_A represent classes of good EEG, middle quality EEG, and artifact, respectively. The data set classified as good EEG by the neural network and decision rule is represented as S_N .

적으로 양질의 뇌파로 판정을 받은 데이터 집합을 S_N 으로 나타내면 P_R 과 P_F 는 다음과 같이 표시될 수 있다.

$$\begin{aligned}
 P_R &= \Pr\{X \in S_N \mid X \in S_G\} \\
 &= \Pr\{X \in (S_G \cap S_N)\} / \Pr\{X \in S_G\} \\
 P_F &= \Pr\{X \in S_N \mid X \in S_A\} \\
 &= \Pr\{X \in (S_A \cap S_N)\} / \Pr\{X \in S_A\}
 \end{aligned}
 \tag{10}$$

여기에서 $\Pr\{X \in A\}$ 는 데이터 X 가 A 집합에 속할 확률을 나타내고, $\Pr\{X \in A \mid X \in B\}$ 는 데이터 X 가 B 집합에 속했다는 조건하에서 X 가 A 에 속할 조건부 확률을 나타낸다. 양질의 뇌파와 artifact 중간정도로 구분된 데이터 집합(S_M)은 전문가에 따라 변동이 커서 신경망 운영특성 분석에서는 고려하지 않았다. 일반적으로 문턱값이 1에 가까워질수록 artifact가 양질의 뇌파로 판정 받을 확률(P_F)은 줄어들지만 또한 양질의 뇌파를 놓칠 확률도 증가하여 P_R 도 줄어들게 된다. 반면에 문턱값이 1에서 멀어지면 P_R 과 P_F 는 함께 증가하게 된다. 따라서 신경망의 성능을 비교할 때 비교하고자 하는 신경망의 운영특성 곡선들을 구하여 주어진 P_F 에 대하여 가장 높은 P_R (가장 왼쪽상단에 위치하는 NOC 곡선)을 갖는 것이 가장 우수한 신경망이 된다.

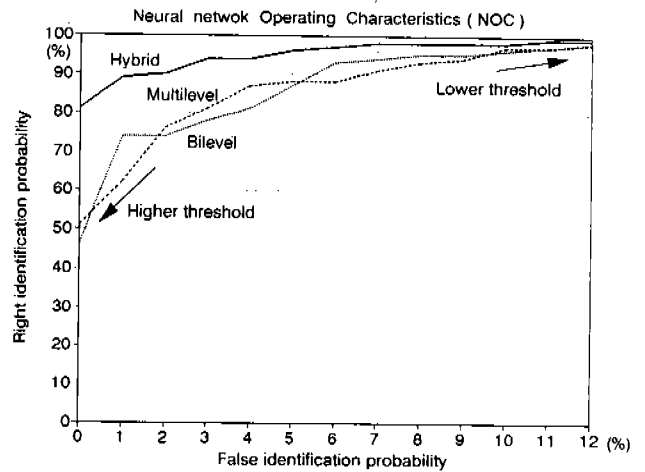


그림 8. 신경망 운영특성 곡선을 이용한 이치 양자기 (Bilevel), 다치 양자기 (Multilevel), 복합 비선형 양자기 (Hybrid)들의 성능 비교. 복합 비선형 양자기가 가장 우수한 것으로 나타났다.

Fig. 8. The neural network operating characteristics (NOC) curves for the three quantizers (bilevel, multilevel, and hybrid nonlinear quantizers) used in the preprocessing. The nonlinear hybrid quantizer shows the best performance of the three quantizers.

본 논문에서는 아래와 같이 신경망 구성에서 중요한 몇 가지 요소에 대하여 신경망 특성곡선을 이용하여 성능을 비교하였으며 이를 이용하여 최적의 신경망을 구성하였다. 신경망의 성능검사를 위해서는 전문가에 의하여 세가지 유형으로 분류된, 앞의 학습과정에서 사용되지 않은 596개의 뇌파신호를 사용하였으며 그 결과를 요약하면 아래와 같다.

1. 전처리 과정에서의 양자기에 따른 신경망 성능 분석

앞에서 언급한 3가지 양자기에 따른 신경망의 성능을 신경망 운영특성 곡선을 사용하여 살펴보았다. 본 실험에서는 학습수렴 및 일반화성능 등을 고려하여 식 (2)와 (3)의 상수를 $\alpha=5$, $\beta=10$, $\gamma=3$ 으로 하였다. 세가지 양자기를 사용하여 전처리 과정을 거친 모든 학습데이터에 대하여 오차허용범위를 0.2로 하여 학습이 가능하였다(global minima에 도달). 연결강도의 초기값은 신경망의 성능에 영향을 미칠 수 있는데, 이치 양자기를 사용한 학습의 경우 초기값에 크게 영향을 받지 않는 것으로 나타났다. 반면에 다치 양자기와 복합 비선형 양자기를 사용한 학습의 경우 초기값의 영향이 컸고 특히 양자기의 출력단계가 많을수록 학습에 어려움이 많아 적절한 초기값의 설정이 중

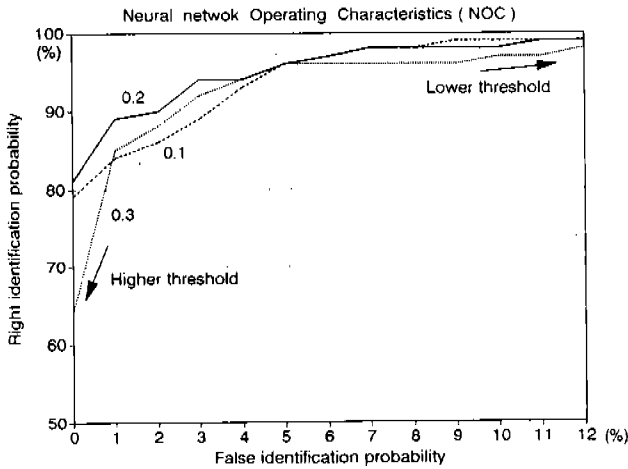


그림 9. 신경망 운영특성 곡선을 이용한 오차허용범위(0.1, 0.2, 0.3)에 따른 신경망의 성능비교. 오차허용범위를 0.2로 하여 신경망을 학습시켰을 때 성능이 가장 우수한 것으로 나타났다.

Fig. 9. The neural network operating characteristics curves obtained with three error allowances (0.1, 0.2, and 0.3). The network with the error allowance of 0.2 shows the best performance.

요한 것으로 나타났다. 본 논문에서는 연결강도의 초기값으로 이치 양자기의 경우 0.1 이하의 random 한 숫자를 사용하였고, 다치 양자기와 복합 비선형 양자기의 경우 이치 양자기에서 학습된 연결강도를 초기값으로 사용하였다. 세가지 양자기를 사용하여 학습시킨 신경망에 대하여 시험데이터를 적용하여 얻은 신경망 운영특성 곡선을 그림 8에 나타내었다. 그림 8에서 보듯이 이치 양자기와 다치 양자기는 성능이 비슷한 것으로 나타났고(문턱값에 따라 우열이 바뀐), 복합 비선형 양자기가 성능이 가장 우수한 것으로 나타났다. 이것은 전문가의 뇌파와 artifact를 구분하는 기준이 주기성이 강조된 뇌파파형에 기초를 두고 있다는 사실과 잘 일치하고 있다.

2. 학습과정에서의 오차허용범위에 따른 신경망 성능분석

학습과정에서 오차허용범위(0.1, 0.2 및 0.3)에 따른 신경망 운영특성 곡선을 그림 9에 나타내었다. 그림 9에서 보듯이 신경망의 성능은 오차허용범위를 0.2로 하였을 때 가장 뛰어난 것으로 나타난다. 이것은 학습데이터 및 시험데이터의 분류에 전문가에 따른 불확실성이 있기 때문에 연결강도를 개개의 입력데이터에 대하여 원하는 출력에 엄격하게 맞추어 학습시키기 보다는 신경망 출력과 원하

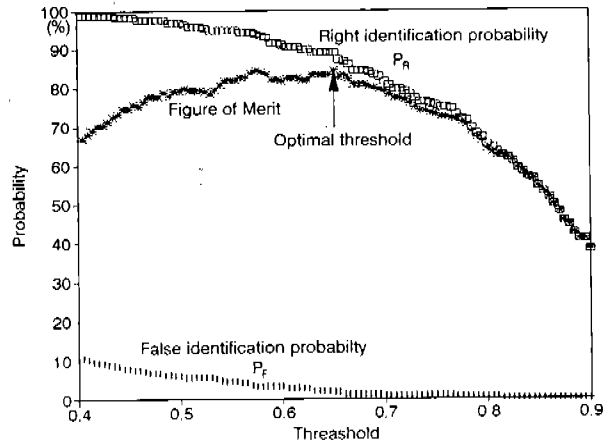


그림 10. 신경망이 올바르게 판정할 확률에서 잘못 판정할 확률을 가중치를 고려하여 뺀 차이를 figure of merit으로 정의하여 선정한 최적의 문턱값.

Fig. 10. The optimal threshold chosen by maximizing the figure of merit defined by the right identification probability subtracted by the weighted false identification probability.

는 출력사이에 다소 오차를 허용함으로써 전체적으로 더 좋은 성능을 얻을 수 있음을 뜻한다.

3. 문턱값의 최적화

신경망 운영특성곡선에서 보듯이 신경망의 출력값은 decision rule의 문턱값에 따라 양질의 뇌파를 바르게 판정할 확률 P_R 과 artifact를 양질의 뇌파로 잘못 판정할 확률 P_F 가 상호 연계적으로 바뀌게 된다. 본 논문에서는 아래의 양을 Figure of Merit(FM)으로 하여 최적의 문턱값을 결정하였다.

$$FM = P_R - k \cdot P_F \quad (11)$$

여기에서 k 는 상수이다. 진단에 사용되는 topography는 좋은 뇌파로 판정된 뇌파신호들의 평균 스펙트럼이므로 좋은 뇌파가 늘어나는 것과 artifact가 있는 뇌파가 첨가되어 noise가 증가되는 것을 SNR의 최적화란 측면에서 FM을 정의할 수도 있다. 이 경우 FM은 신경망이 좋은 뇌파라고 판정한 데이터들 안에 들어있는 좋은 뇌파 수에서 artifact의 수를 가중치를 고려하여 뺀 차이로 볼 수 있다. 즉,

$$FM' = \#(S_N \cap S_G) - k' \#(S_N \cap S_A) \\ \propto [\Pr\{X \in (S_N \cap S_G)\} - k' \Pr\{X \in (S_N \cap S_A)\}] \quad (12)$$

여기에서 $\#(A)$ 는 집합 A 의 원소 수를 나타내는 함수이다. 식 (10)을 이용하여 FM' 을 다시 표시하면

$$FM' = \Pr\{X \in S_G\} \cdot \Pr\{X \in S_N | X \in S_G\} \\ - k' \Pr\{X \in S_A\} \cdot \Pr\{X \in S_N | X \in S_A\} \quad (13) \\ = P_G \cdot P_R - k' P_A \cdot P_F \\ = P_G \{ P_R - k' (P_A/P_G) \cdot P_F \}$$

여기에서 P_G 및 P_A 는 양질의 뇌파 및 artifact가 발생할 확률을 각각 나타낸다. 식 (13)과 식 (11)을 비교해보면 $k = k'(P_A/P_G)$ 일 때 FM 과 FM' 을 최대화 하는 문턱값은 동일하게 된다.

그림 10은 앞에서 구성한 최적의 신경망의 운영특성 곡선과 $FM(k=3)$ 을 함께 나타낸 것이다. 여기에서 FM 을 최대화 하는 문턱값은 $T=0.65$ 일 때 얻어지며 이때 신경망이 좋은 뇌파를 검출할 확률(P_R)은 89% 이고 artifact를 좋은 뇌파로 잘못 인식할 확률(P_F)은 1.6% 가 된다. 실제 임상적용에서는 전문가가 신경망에 의하여 판정된 데이터들을 검사하면서 문턱값을 interactive 하게 바꿀 수 있는데 이 경우 측정된 뇌파신호들에 대한 개별 신경망의 출력은 이미 계산되어 있기 때문에 추가적인 연산없이 판정의 변경이 용이하다.

4. 신경망과 전문가와의 성능비교

앞절에서는 신경망의 일반화성능을 신경망 운영특성 곡선을 통하여 검출 확률과 잘못 인식할 확률 등으로 정량적인 분석을 하였다. 본 절에서는 이러한 신경망의 성능을 전문가와 비교해 봄으로써 상대적인 성능을 분석해 보았다. 이를 위하여 신경망과 전문가 간의 뇌파 분류에서의 차이를 동일 전문가가 일주일의 간격을 가지고 반복하여 분류하였을 때와 서로 다른 두 전문가가 분류하였을 때의 차이와 비교해 보았다. 분류는 양질의 뇌파, 중질의 뇌파, artifact의 세가지로 하였고 그 결과를 표 2에 요약하였다. 표 2에서 조금 다르게 분류한 경우는 양질의 뇌파를 중질의 뇌파로(또는 역으로) 또는 중질의 뇌파를 artifact로(또는 역으로) 분류한 경우를 의미하며, 상치된 분류는 양질의 뇌파를 artifact로(또는 역으로) 분류한 경우를 나타낸다. 표 2에서 보듯이 뇌파분류는 전문가에 따라 상당한 차이가 있고, 동일인이라 하더라도 시간에 따라 상당한 변화

표 2. 신경망을 포함한 전문가들 사이의 분류일치정도 비교. 첫째 열은 신경망과 전문가(신경망 학습 및 시험데이터의 분류자) 사이의 차이를 나타내고 있고, 둘째 열은 한 전문가가 동일한 데이터를 일주일 간격으로 두 번 판정했을 때 나타나는 차이, 그리고 셋째 열은 서로 다른 두 전문가가 판정한 차이를 나타낸다.

Table 2. Variations of classifications between the neural network and experts. First column denotes the variation of classifications between the neural network and human expert who provides knowledge to the neural network. Second column denotes variation between two classifications made by an expert with a time interval of 1 week. Third column shows variation of the classifications between two human experts.

Classification	Neural network and expert (knowledge provider)	One expert (classified twice with a time interval of 1 week)	Two experts
Identical classifications	74.5 %	77.5 %	62.8 %
Classifications with small disagreements	25.0 %	20.8 %	24.8 %
Contradictory classifications	0.5 %	1.7 %	12.4 %
Total	100.0 %	100.0 %	100.0 %

가 있음을 알 수 있다. 표 2에서 신경망과 전문가와의 차이는 동일 전문가가 일주일 간격을 가지고 두 번 분류하였을 때 나타나는 차이 정도이며 서로 다른 전문가들 간의 차이 보다는 오히려 적음을 알 수 있다.

일반적으로 수신된 뇌파의 약 80%는 다른 생체신호가 혼합된 artifact이고 약 20%만이 임상적으로 사용가능한 뇌파이다. 보통 이러한 뇌파를 분리하기 위하여 전체 데이터를 전문가가 검색하게 되는데 여기에 많은 시간이 소요되며 이 과정이 전체 검사과정의 자동화에 큰 문제점으로 남아 있다. 본 논문에서 제안하는 전문가와 거의 비슷한 성능을 보이는 신경망을 채용하여 일차적으로 전체 데이터의 약 80%에 해당하는 artifact를 걸러낸 후(screening), 신경망에 의하여 좋은 뇌파라고 판정된 약 20%의 데이터만을 전문가가 재검색하여도 검사시간을 상당히 단축할 수 있을 것이다.

결 론

본 논문에서는 multilayer perceptron 구조의 신경망을 이용하여 측정된 뇌파에서 순수 뇌파신호와 EOG, EMG

등의 다른 생체신호가 내재한 artifact를 자동으로 분류하는 방법을 제안하였다. 학습의 효율성을 향상시키기 위하여 subsampling과 복합 비선형 양자기를 이용한 전처리 과정을 사용하였다. 전문가에 의한 뇌파판정에 내재한 근원적인 불확실성을 고려하여 오차허용범위를 설정함으로써 학습과정에 유연성을 크게 하였다. 객관적인 신경망 성능 평가를 위하여 뇌파를 바르게 판정할 확률과 잘못 판정할 확률을 이용한 신경망 운영특성 곡선을 도입하였고 이를 이용하여 신경망의 성능을 객관적으로 비교 분석하였다. 학습에 사용되지 않은 시험데이터를 이용하여 신경망의 일반화를 시험해 본 결과 좋은 뇌파를 검출할 확률은 89%로 나타났고, artifact를 좋은 뇌파로 잘못 판정할 확률은 1.6%로 나타났다. 전문가들 간에도 뇌파판정에 상당한 차이가 있는 것을 감안하면 신경망을 통한 판정수준은 거의 전문가 수준으로 볼 수 있으며, 의사가 판정하기에 앞서 artifact가 있는 뇌파를 스크린함으로서 진단시간을 상당히 줄일 수 있고 더 나아가 판정에 객관성을 기할 수 있을 것으로 기대된다.

참 고 문 헌

1. K. A. Maurer and T. Dierks, Atlas of Brain mapping, pp. 1-6,

Springer-Verlag, New York, 1991.

2. A. S. Gevin and N. H. Morgan, "Classifier-directed signal processing in brain research", IEEE Trans. Biomed. Eng., Vol. BME-33, pp. 1054-1068, 1986.

3. E. Niedermeyer and F. L. Da Silva, Electroencephalography: Basic Principles, Clinical Applications, and Related Fields, 3rd ed., pp. 1063-1086, Williams & Wilkins, Baltimore, 1993.

4. C. B. Ahn, T. Y. Lee, J. H. Woo, and S. H. Lee, "Application of Neural Network to Automatic Artifact Detection in Computerized EEG Neuro-Functional Mapping System", Proc. '94 ICONIP, pp. 500-504, Seoul, Oct 17-21, 1994.

5. 안창범, 이택용, 우종호, 이성훈, "신경망을 이용한 뇌파신호에서의 Artifact 자동 판정", '94 FAN, 춘계 학술대회 논문집, pp. 371-374, 1994.

6. R. Cooper, J. W. Osselton, J. C. Shaw, EEG Technology, 3rd ed. pp. 91-98, Butterworths, Boston, 1980.

7. S. H. Lee, H. W. Ko, S. K. You, W. K. Kim, H. S. Lee, and H. Y. Lee, "Development of a Computerized EEG Imaging System with a Personal Computer", Yonsei Medical Journal, Vol. 30, pp. 45-53, 1989.

8. J. A. Freeman and D. M. Skapura, Neural Networks: Algorithm, Applications, and Programming Techniques, pp. 89-125, Addison-Wesley, New York, 1991.

9. S. Haykin, Neural Networks: A Comprehensive Foundation, pp. 138-181, IEEE Press, New York, 1994.

10. H. Van Trees, Detection, Estimation, and Modulation Theory, pp. 36-44