

신경망 운영특성곡선을 이용한 최적의 뇌파 및 Artifact 분류기 구성

이택웅*, 안창범*, 이성훈**

*광운대학교 전기공학과, **연정 뇌기능 수면 연구소

Development of an Optimal EEG and Artifact Classifier
Using Neural Network Operating Characteristics

T.Y. Lee*, C.B. Ahn*, and S.H. Lee**

* Department of Electrical Engineering, Kwangwoon University

** Yonjung Brain Function and Sleep Research Center

Abstract

An optimal EEG and artifact classifier is proposed using neural network operating characteristics. The neural network operating characteristics are two dimensional parametric representations of the right and false identification probabilities of the network classifier. Since 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), 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. Using the neural-network based classification, human expert's efforts and time can be substantially reduced. 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.

I. 서론

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 제공해준다 [1]. 머리에 부착된 전극들로부터 수신된 미세한 뇌파는 증폭 및 디지털 변환을 거쳐 컴퓨터에 저장되며 여러가지 시간 및 공간, 주파수 영역 등에서의 신호처리를 거치게 된다. 이 과정에서 중요한 것은 artifact 가 없는 뇌파를 분리하여 선택적

으로 신호처리에 사용하는 것이다 [2]. Artifact 의 주요원인은 환자의 움직임에 기인하는데 특히 눈을 뇌와 밀접한 연관이 있기 때문에 눈의 움직임은 artifact 발생의 주원인이 된다 [3]. 일반적으로 좋은 뇌파신호는 주기성이 강하고 진폭의 변화가 그다지 크지 않은 반면에 artifact 를 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 artifact 를 판정해 왔는데 이때 많은 시간이 소요되고 또한 이과정에서 전체 시스템의 자동화에 큰 제약이 되어 왔다. 본 논문의 목적은 전문가가 artifact 를 판정하는 경험적 지식을 이용하여 전문가 수준의 신경망을 구성하는데 있다 [4].

II. 전처리과정

본 논문에서 뇌파신호는 머리표면에 부착된 32개의 전극(32 채널)으로부터 수신된다. 32개의 전극은 국제 뇌파 및 임상 신경대사 협회에서 추천하는 10-20 시스템으로 배치되어 있다. 32개의 전극들을 통하여 들어오는 뇌파신호는 디지털 신호처리를 위하여 각 채널마다 1 초당 256 샘플을 하였으며 해상도는 12 bits/샘플 을 사용하였다. 연속적으로 수신된 뇌파신호는 epoch 라 불리는 단위시간으로 나뉘어져 전처리 과정을 거친 후 epoch 단위로 양질의 뇌파인지 artifact 인지를 판정 받게 된다. 본 논문에서는 한 epoch 를 1 초로 하였으며, 이 경우 1Hz 의 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 간략한 설명은 아래와 같다.

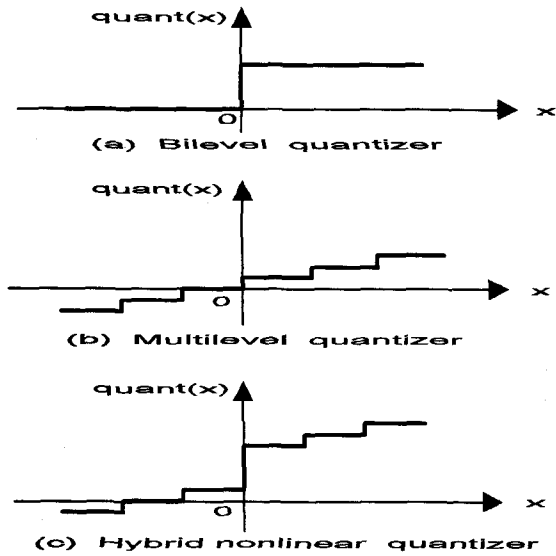


그림 1. 입력 뇌파신호의 전처리 과정에 사용된 세가지 양자기들.

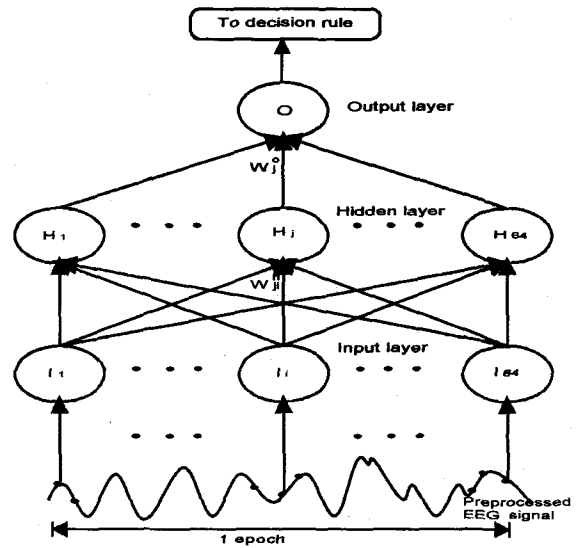


그림 2. Artifact 자동판정 시스템에서 사용한 신경망 구조.

A. 신호크기 검사, baseline 고정 및 선형 고정

신호크기 검사는 입력데이터의 크기를 검사하여 offset 이나 기타 다른 큰 생체신호에 의하여 뇌파신호가 포화 (saturated)되었거나, 또는 전극의 접촉 불량으로 인하여 신호가 지나치게 작은 경우를 배제한다. 신호크기 검사를 통과한 뇌파신호는 전기적인 offset 을 제거하기 위하여 신호의 d.c. 값에 해당하는 baseline 고정과 환자의 움직임과 관련한 선형적으로 증가하거나 감소하는 artifact 를 제거하기 위한 선형 고정을 적용한다.

B. Subsampling

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

C. 비선형 양자기

신호크기의 양자화는 subsampling 과 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 1 과 같다.

III. 신경망 구성 및 학습

본 논문에서 사용한 신경망은 그림 2 에서 보인 multilayer perceptron 구조로 입력층, 은닉층, 출력층의 3층으로 구성되어 있다 [5]. Multilayer perceptron 은 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 epoch 를 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 0 에서 1 사이의 연속적인 값을 갖게 된다.

신경망의 학습을 위해서는 전문가가 뇌파신호를 판정한 데이터를 기반으로 역전파(backpropagation) 알고리즘을 사용하였다 [5]. 이 알고리즘은 입력노드의 정보가 연결강도를 통하여 순방향으로 전달된 신경망 출력과 바람직한 출력값 간의 오차를 역방향으로 전파하여 오차가 최소가 되도록 연결강도를 갱신하는 것이다.

신경망의 학습에 사용된 데이터는 전문가에 의하여 "양질의 뇌파", "중질의 뇌파", "artifact" 의 세가지 유형으로 분류되었으며, 원하는 출력으로 각각 1.0, 0.5, 0.0 이 할당되었다. 신경망의 학습에 사용된 전문가가 판정한 뇌파신호의 분포를 표 1 에 나타내었다. 학습 및 시뮬데이터는 신

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

표 1 신경망의 학습에 사용된 뇌파 분포.

경망의 성능과 평가에 중요한 영향을 미치므로 본 논문에서는 전문가가 동일한 데이터 set 를 일주일의 시간간격을 가지고 반복적으로 분류하여 분류가 일치하는 데이터만을 추출하여 사용하였다.

일반적으로 prototype 이 정해져 있는 패턴인식 등에서 신경망 학습은 원하는 출력과 신경망 출력과 간의 오차를 가능한 최소로 하는 것이 바람직하다. 그러나 본 연구의 뇌파분류에서는 명확한 prototype 이 없기 때문에 전문가에 따라 분류가 상당히 다를수 있어 학습과정에서 다소 오차를 허용함으로써 경우에 따라서 잘못 내려진 판정일 수도 있는 특정한 sample 파형에 의하여 연결강도가 크게 지배받지 않도록 하였다.

실제 임상적용에서는 측정된 데이터를 뇌파와 artifact 의 두가지로만 분류하여 artifact 는 버리고 뇌파만을 처리하여 topography 를 만들게 되므로 신경망의 출력 다음단계 최종판정을 위한 decision rule 을 도입하였다. 뇌파 및 artifact 의 분류는 신경망의 출력에 아래의 decision rule 을 적용하여 최종적으로 얻어진다.

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

여기에서 D 는 판정을 나타내고, T 는 문턱값을 나타낸다.

IV. 신경망의 운영특성곡선

본 논문에서는 통신 분야에서 널리 사용되고 있는 수신기 운영특성(Receiver Operating Characteristics: ROC) 곡선[6] 과 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 classification probability) 과 가로축에 신경망이 artifact 를 양질의 뇌파로 잘못 판정할 확률(P_F : false classification probability)을 이차원적으로 나타낸 것이다.

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

A. 전처리 과정에서의 양자기에 따른 신경망 성능 분석

그림 1 에서 보여준 3가지 양자기에 따른 신경망의 성능을 신경망 운영특성 곡선을 사용하여 살펴보았다. 본 실험에서는 세가지 양자기를 사용하여 전처리 과정을 거친 모든 학습데이터에 대하여 오차허용범위를 0.2 로 하여 학습이 가능하였다. 세가지 양자기를 사용하여 학습시킨 신경망에 대하여 시험데이터를 적용하여 얻은 신경망 운영특성 곡선을 그림 3 에 나타내었다. 그림 3 에서 보듯이 이치 양자기와 다치 양자기는 성능이 비슷한 것으로 나타났고, 복합비선형 양자기가 성능이 가장 우수한 것으로 나타났다. 이것은 전문가의 뇌파와 artifact 를 구분하는 기준이 주기성이 강조된 뇌파파형에 기초를 두고 있다는 사실과 잘 일치한다.

B. 학습과정에서의 오차허용범위에 따른 신경망 성능분석

학습과정에서 오차허용범위(0.1, 0.2 및 0.3)에 따른 신경망 운영특성 곡선을 그림 4 에 나타내었다. 그림 4 에서 보듯이 신경망의 성능은 오차허용범위를 0.2 로 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 다소 오차를 허용함으로써 전체적으로 더 좋은 성능을 얻을 수 있음을 뜻한다.

C. 신경망과 전문가와의 성능비교

신경망의 일반화성능을 신경망 운영특성 곡선을 통하여 검출 확률과 잘못 인식할 확률을 통한 정량적인 분석과 함께 신경망의 성능을 전문가와 비교해 봄으로써 상대적인 성능을 살펴 보았다. 분류는 양질의 뇌파, 중질의 뇌파, artifact 의 세가지로 하였고 그 결과를 표 2 에 요약하였다. 표 2 에서 조금 다르게 분류한 경우는 양질의 뇌파를 중질의 뇌파로(또는 역으로) 또는 중질의 뇌파를 artifact 로(또는 역으로) 분류한 경우를 의미하며, 상치된 분류는 양질의 뇌파를 artifact 로(또는 역으로) 분류한 경우를 나타낸다. 표 2 에서 보듯이 뇌파분류는 전문가에 따라 상당한 차이가 있고, 동일인이라 하더라도 시간에 따라 상당한 변화가 있음을 알 수 있다. 표 2 에서 신경망과 전문가와의 차이는 동일 전문가가 일주일 간격을 가지고 두 번 분류하였을 때 나타나는 차이 정도이며 서로 다른 전문가들 간의 차이보다는 오히려 적음을 알 수 있다.

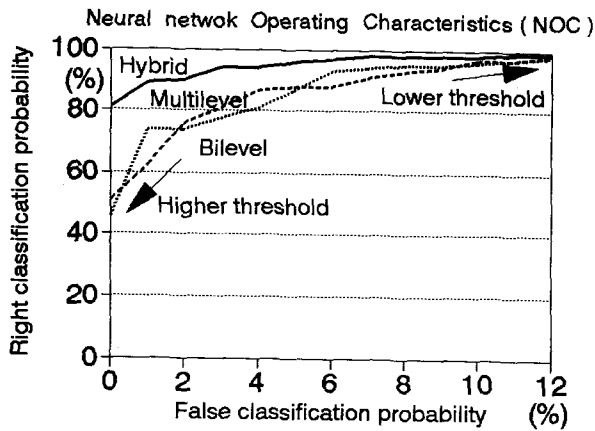


그림 3. 신경망 운영특성 곡선을 이용한 이치 양자기 (Bilevel), 다치 양자기(Multilevel), 복합 비선형 양자기 (Hybrid) 등의 성능비교.

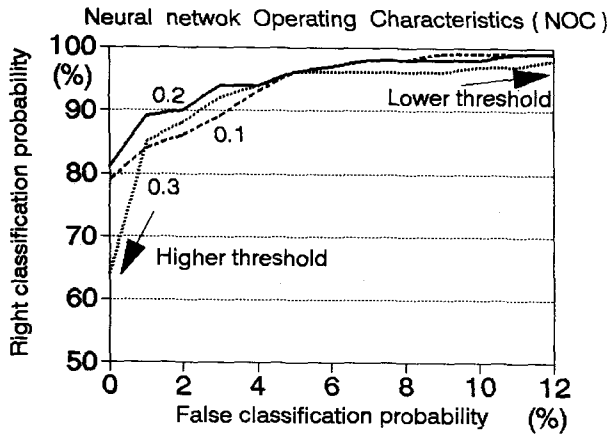


그림 4. 신경망 운영특성 곡선을 이용한 오차허용범위 (0.1, 0.2, 0.3)에 따른 신경망의 성능비교.

Classification	Neural network and expert	One expert	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 %

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 세째열은 서로 다른 두 전문가가 판정한 차이를 나타낸다.

V. 결론

본 논문에서는 multilayer perceptron 구조의 신경망을 이용하여 측정된 뇌파에서 순수 뇌파신호와 EOG, EMG 등의 다른 생체신호가 내재한 artifact 를 자동으로 분류하는 방법을 제안하였다. 객관적인 신경망 성능평가를 위하여 뇌파를 바르게 판정할 확률과 잘못 판정할 확률을 이용한 신경망 운영특성 곡선을 도입하였고 이를 이용하여 신경망의 성능을 객관적으로 비교 분석하였다. 학습의 효율성을 향상시키기 위하여 subsampling 과 복합 비선형 양자기를 이용한 전처리 과정을 사용하였다. 전문가에 의한 뇌파판정에 내재한 근원적인 불확실성을 고려하여 오차허용범위를 설정함으로써 학습과정에 유연성을 크게 하였다. 학습에 사용되지 않은 시험데이터를 이용하여 신경망의 일반화를 시험해 본 결과 좋은 뇌파를 검출할 확률은 89% 로 나타났고, artifact 를 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 artifact 가 있는 뇌파를 스크린함으로써 진단시간을 상당히 줄일 수 있고 더 나아가 판정에 객관성을 기할 수 있을 것으로 기대된다.

참고 문헌

- [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, 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, 1994.
- [5] J.A. Freeman and D.M. Skapura, Neural Networks : Algorithm, Applications, and Programming Techniques, pp. 89-125, Addison - Wesley, New York, 1991.
- [6] H. Van Trees, Detection, Estimation, and Modulation Theory, pp. 36-46, John Wiley and Sons, New York, 1968.