

심전도 패턴을 분류하기 위한 신경망 특성 평가

김만선^{*&**}, 김원식^{*}, 노기용^{*}, 이상태^{*}

^{*}한국표준과학연구원 인간정보그룹

^{**}공주대학교 컴퓨터공학과

Characteristics of Neural Networks for ECG Pattern Classification

Mansun Kim^{*&**}, Wuon-Shik Kim^{*}, Gi-Young No^{*}, Sang-Tae Lee^{*}

^{*}Ergonomics & Information Technology Group,

Korea Research Institute of Standards and Science

^{**} Computer Science Engineering Lab., Kongju University

요 약

본 논문에서는 심근허혈 질환을 효율적으로 분류하기 위한 신경망을 설계하였다. European ST-T DB의 심전도로부터 ST 분절의 특징을 추출하여 입력노드를 결정하고 10개의 은닉노드와 1개의 출력노드로 구성하였다. ST 분절의 특징 파라미터를 다양하게 조합하여 학습률과 학습 횟수의 변화에 따른 신경망의 MSE를 계산하였다. 실험 결과 특징 파라미터의 조합을 ST0, ST80, Slope, Area로 하였을 때 MSE가 가장 작았다. 이러한 특징 파라미터를 이용하여 신경망의 입력으로 학습시킨 경우 학습 횟수의 증가에 따라 MSE가 지수함수적으로 감소하였으며 10,000회 이상에서는 둔하게 감소하였다. 또한 학습 횟수가 5,000회, 10,000회, 15,000회 각각의 경우에 대하여 학습률을 0.01부터 0.7까지 증가시키면서 MSE를 계산한 결과 학습 횟수가 증가할수록 MSE를 최소로 하는 최적학습률이 0.1부터 0.04까지 감소하였다.

키워드 : 신경망, 역전파 학습 알고리즘, 학습 횟수, 학습률, 심전도, 특징 파라미터, MSE

1. 서론

신경망은 사람 뇌의 동작에 가깝게 만든 프로그램 또는 데이터 구조 시스템을 말한다. 신

경망은 보통 데이터들의 관계들에 관한 많은 양의 데이터나 규칙이 공급됨으로써 먼저 학습을 하게 된다. 학습 방법으로는 보통 감독 학습 방법과 비감독 학습 방법으로 나뉘어지

며, 전자는 목적 패턴이 있는 것을 말하며, 후자는 목적 패턴이 존재하지 않는 신경망을 말한다. 여기에서 목적 패턴이란 주어진 입력 패턴에 대해 신경망이 출력해 주기 원하는 출력 패턴을 말하며, 외부로부터 주어진 패턴이다. 감독 학습 방법으로서 대표적인 학습 방법으로는 BP (Backpropagation) 알고리즘이 있다.

본 논문에서는 심전도 신호의 패턴을 분류하기 위하여 심전도 패턴의 특징으로부터 추출된 파라미터들을 신경망의 입력으로 하는 BP 신경망 모델을 구축하여 신경망이 패턴 분류를 효과적으로 수행하는지 특성을 평가하였다.

2. 관련 연구

2.1 ECG신호의 ST-episode

돌연사를 일으키는 대표적 심장질환은 허혈성 심장질환, 확장성 심근증, 비후성 심근증이 대부분을 차지하며 특히 허혈성 심장 질환이 돌연사의 80%를 차지하므로 이 질환의 예방 및 조기진단이 중요하다[1][2][3]. 허혈성 심장 질환의 증세로서 협심증과 심근경색증이 있는데, 심전도의 ST 분절이 elevation 또는 depression 되는 episode를 띄게 된다.

그림 1은 심전도 데이터에서 ST 분절, RR 간격, QRS complex, J point 등을 표현한 것이다.

2.2 역전파 학습 알고리즘

다층 퍼셉트론(Multi Layer Perceptron)에 일반화된 델타 규칙(Generalization Delta Rule)을 학습 규칙으로 사용한 알고리즘을 BP 알고리즘이라 한다. 이 규칙의 주요골자는 다음과 같다.




그림 1. 심전도 파형의 구성요소

“만일, 어떤 신경세포의 활성이 다른 신경세포의 잘못된 출력에 공헌을 하였다면, 두 신경세포 간의 연결 가중치를 그것에 비례하여 조절해 주어야 한다. 그리고, 그러한 과정은 그 아래에 있는 신경세포들까지 계속된다.”이다.

이렇게 출력 층에서 발생한 에러를 위층으로 역전파시키므로, 오류 역전파 알고리즘이라 한다. 그림 2는 일반적인 BP알고리즘의 모형이다. 복잡함을 피하기 위해 은닉층이 하나만 있는 경우를 고려하였다.




그림 2. BP 알고리즘 모델

목적 패턴에서 출력 신경세포의 활성값을 뺀 값이 바로 해당 출력 신경세포의 에러값

된다. 그림 2에서 e_7, e_8, e_9 로 나타낸 것이 각 출력 신경세포들의 에러이다. 에러를 여러 번 가공하여 출력층 각각의 신경세포에 대해 델타(δ)라는 것을 구하게 된다. 그리고, $f'(S)$ 는 활성화함수의 미분 값을 말하며, 여기에서는 시그모이드 함수를 사용하였다.

그림 2에서 $\delta_7, \delta_8, \delta_9$ 로 나타낸 것이 해당 출력층 신경세포들의 델타가 되고, 식 (1)과 같다.

$$w(new)_{ij} = w(old)_{ij} + \alpha \delta_j a_i \quad (1)$$

$$\delta_j = a_j(1 - a_j)e_j$$

$$e_j = \begin{cases} t_j - a_j & \leftarrow \text{출력층 신경세포} \\ \sum_k w_{jk} \delta_k & \leftarrow \text{은닉층 신경세포} \end{cases}$$

$w(new)_{ij}$: 신경세포 i, j 사이의 조절된 후 연결 가중치

$w(old)_{ij}$: 신경세포 i, j 사이의 조절되기 전 연결 가중치

α : 학습률 ($0 < \alpha \leq 1$)

δ_j : 신경세포 j의 델타

a_i : 신경세포 i의 활성화값

a_j : 신경세포 j의 활성화값

e_j : 신경세포 j의 에러

t_j : 신경세포 j가 출력층인 경우 해당 목적 패턴의 성분값

w_{jk} : 신경세포 j가 은닉층인 경우 위층 신경세포 k에 달린 연결 가중치

δ_k : 신경세포 j가 은닉층인 경우 위층 신경세포 k의 델타

3. 신경망의 성능 평가

3.1. ST분절 특징 파라미터

ST 분절 구간 설정은 RR 간격이 600ms보다 클 경우는 R-peak에서 60ms 후부터, 그렇지 않은 경우는 40ms 후부터 160ms 동안으로 하였다[1]. ST 분절의 특징을 추출하기 위하여 RR 간격이 600ms보다 클 경우 또는 그렇지 않을 경우에 대하여, ST0[ST 분절이 시작되는 지점(R+60 또는 R+40 ms)에서의 진폭], ST80[R+140 또는 R+120 ms 지점에서의 진폭], ST 분절의 slope, ST 분절의 면적(ST 분절의 구간에서 ST 분절과 isoelectric level로 둘러싸여진 면적)을 ST 분절의 특징을 나타내는 파라미터의 후보로 설정하였다.

신경망의 입력층으로 구성할 특징 파라미터들의 조합을 선정하기 위하여 심전도 파형 패턴 분류시 발생하는 오차를 가장 적게 하는 특징 파라미터들의 조합을 선택해야 한다. 여러 문헌을 참고하여 3가지 그룹(A, B, C)을 구성하였다[2][4].

A 그룹 = [ST0, ST80, Slope, Area]

B 그룹 = [ST0, ST80, Slope]

C 그룹 = [ST80, Slope, Area]

3.2. 신경망

본 연구에서 사용된 신경망은 한 개의 은닉층(Hidden Layer)을 가지며, 10개의 은닉노드로 구성하였다. 학습방법으로는 목적패턴과 신경망에 의한 출력패턴을 비교하는 감독학습방법을 사용하였다. 출력패턴과 목적패턴의 차이로 나타나는 에러 값에 의한 연결강도의 변화를 위해 역전파 알고리즘의 학습방식이 이용

되었으며, 역전파 알고리즘의 에러 값 조정을 위하여 MSE(Mean Squared Error)값을 사용하였다. 그림 3은 학습과정을 나타낸다.

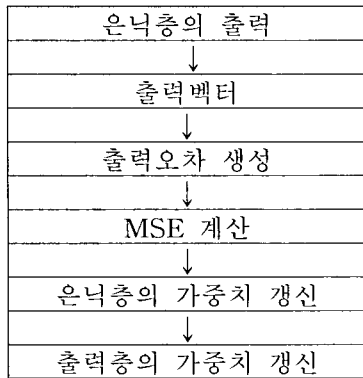


그림 3. 역전파 알고리즘의 학습 과정

활성함수로서 시그모이드 함수를 사용하여 구성했으며 MSE 함수는 식 (2)와 같다.

$$MSE = \sigma^2 = \frac{1}{N} \sum_{k=1}^N (T_k - O_k)^2 \quad (2)$$

전체 네트워크 구조는 3개의 층으로 입력층, 은닉층, 출력층 각각 1개의 층으로 구성하며, 각 층의 노드의 수는 입력노드 5, 은닉노드 10, 출력노드 1개로 구성한다.

4. 실험 및 결과

European ST-T database의 e0105, e0111를 선택하였으며, European ST-T database로부터 ST 분절에서 임상소견 중 정상(normal)과 비정상(ST episode를 갖는 데이터)으로 분류하였다.

1) 특징 파라미터 선정에 관한 실험

실험 결과 그림 4와 같이 3가지 그룹 중에서 MSE가 가장 작게 나타나는 A그룹, 즉,

[ST0, ST80, Slope, Area]을 ST 분절 특징과 라미터 조합으로 선정하였다.




그림 4. 그룹들간의 MSE 비교

2) 학습 횟수의 변화가 MSE에 미치는 영향

그림 5에서는 학습 횟수의 증가에 따라 MSE는 지수 함수적으로 감소함을 볼 수 있으며, 10,000회 이상에서는 MSE가 느리게 감소함을 알 수 있었다.

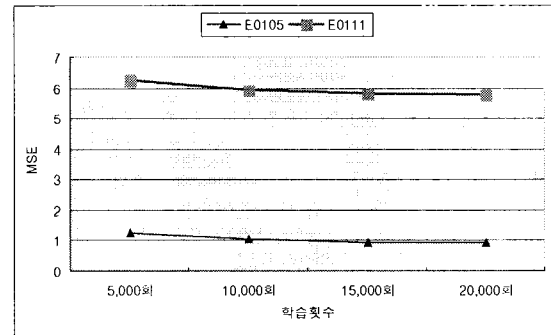


그림 5. 학습 횟수와 MSE값 비교

3) 학습률의 변화가 MSE에 미치는 영향

학습률은 대개 0.01~1 범위의 값을 사용한다. 학습률을 0.1부터 0.7까지 0.2의 간격으로 실험한 결과 MSE의 분포가 0.1부근에서 가장 작게 나타나서 다시 0.01부터 0.01간격으로 0.1까지 실험해보았다. 아래의 표 1은 e0105와 e0111 데이터를 학습횟수 5,000회, 10,000회, 15,000회에서 다양한 학습률로 실험한 결과이다.

그림 6과 그림 7은 학습률에 따른 MSE를 e0105와 e0111에 대해서 그래프로 보여준다. e0105 데이터에서는 학습을 5,000회 반복시킨 경우 MSE는 학습률 0.1지점에서 최소값을 보였고, 10,000회에서는 0.05에서 15,000회에서는 0.04에서 각각 최소값을 보였으며, e0111 데이터에서 이에 상응하는 최적학습률은 각각 0.08, 0.07, 0.05로 나타났다.

표 1. 학습률과 MSE값 비교

학습률	E0105			E0111		
	5,000회	10,000회	15,000회	5,000회	10,000회	15,000회
0.01	1.69	1.68	1.68	8.69	8.55	8.24
0.02	1.68	1.66	1.60	8.55	7.62	6.42
0.03	1.65	1.49	1.17	8.10	6.20	4.93
0.04	1.57	1.21	0.89	7.37	6.09	4.50
0.05	1.47	0.97	0.90	6.65	4.89	4.30
0.06	1.35	1.00	0.90	6.18	4.84	4.30
0.07	1.27	1.00	0.91	5.98	4.67	4.33
0.08	1.23	1.10	0.92	5.88	4.71	4.36
0.09	1.22	1.04	0.95	6.02	4.80	4.52
0.10	1.21	1.06	0.97	6.28	4.98	4.56
0.15	3.25	1.41	1.18	6.79	6.91	6.80
0.20	7.45	6.03	5.79	7.49	7.09	6.81
0.25	11.44	9.24	9.12	10.09	7.78	7.04
0.30	19.27	11.74	10.99	13.00	13.0	14.26




그림 6. e0105 경우 학습률에 따른 MSE




그림 7. e0111 경우 학습률에 따른 MSE

5. 고찰

심전도 ST 분절의 특징을 나타내는 파라미터의 조합으로서 A 그룹이 가장 우수하게 나타났다는데, 그 이유는 동일한 ST 분절 구간에서 더 많은 정보(B, C 그룹은 3개의 파라미터를 사용한 반면에 A 그룹은 이 파라미터들을 모두 포함하고 또 다른 파라미터를 1개 추가)를 추출하여 신경망을 학습시켰기 때문이라고 사료된다. 그러나, A 그룹이 ST episode의 특징을 가장 잘 나타낼 수 있는지는 신경망 학습에 사용되지 않은 다른 집단의 심전도 데이터를 이용한 신경망의 성능검증이 추가로 필요하다.

학습 횟수의 증가에 따른 신경망의 MSE는 지수 함수적으로 감소하였고 10,000회 이상에서는 그 감소가 둔화되는 경향을 보였다. 심장 질환 분류의 임상용으로 사용되기 위하여는 보수적 차원에서 충분한 학습 횟수가 요구된다. 학습률 변화에 따른 MSE를 계산한 결과 5,000회, 10,000회, 15,000회 각각의 경우에 대하여 MSE를 최소로 하는 최적 학습률은 학습 횟수가 클수록 작아지는 경향을 보였다. 학

습 횟수에 따른 MSE의 차이는 학습률이 작은 경우(대략 0.2 이하)에는 학습 횟수가 많을수록 더 작은 MSE값을 가졌으나, 학습률이 큰 경우는 신경망이 불안정하게 되어 이러한 경향이 없어졌다. 이러한 현상은 그림 7에 잘 나타나 있다. 또한, 학습 횟수가 5,000회, 10,000회, 15,000회로 증가함에 따라 학습률 변화에 대한 MSE의 극소값은 점차적으로 감소하였으며 극소점의 위치는 학습률축상에서 좌측(학습률이 작은값) 방향으로 안정되게 이동하는 경향을 보였다.

결론적으로, 학습률을 아주 작게 취할 경우 MSE의 최소화를 위한 보장이 확실해지는 장점이 있지만, 요구되는 학습 횟수가 증가(시간이 많이 걸림)하는 단점을 가진다. 반면에 학습률을 큰 값이 되도록 설정할 경우 MSE를 최소로 하는 지점을 지나치는 불안정성을 나타나게 된다. 따라서, 환자로부터 측정된 심전도로부터 심장질환을 정확하고 빠르게 분류하기 위하여는 학습의 속도를 높이면서 안정성을 갖는 적응성 학습률을 이용한 신경망 설계의 연구가 추가로 요구된다.

참고 문헌

- [1] F. W. Stallmann and H. V. Piberger, "Automatic recognition of electrocardiographic waves by digital computer", *Circ. Res.*, Vol. 1, No. 9, pp. 1138~1143, 1961.
- [2] Y.Suzuki, and K.Ono, "Personal computer system for ECG ST-segment recognition based on neural networks", *Medical & Biological Engineering & Computer*, Vol. 30, No. 1, pp. 2~8, 1992.
- [3] 박광리, "스트레스 심전도의 잡음 제거를 위한 WAF와 WIF의 설계", 박사학위논문, 연세대, 2000.
- [4] W.J.Tompkins, "Biomedical Digital Signal Processing", Prentice Hall International Edition, New Jersey, 1993.