

비교사 신경망을 통한 심전도 진단의 효율적 학습을 위한 GCS 알고리즘

*오영재, *이종호, **김태선
 *인하대학교 정보통신공학과 **가톨릭대학교 정보통신전자공학부

GCS algorithm for efficient learning in ECG classification by unsupervised ANN

*Yeong Jae Oh, *Chong Ho Lee, **Tae Seon Kim
 * Inha University Information & Communication Engineering
 **Catholic University Communications & Electronics Engineering

Abstract - SOM은 심전도 신호의 진단에 있어서 효과적인 Clustering을 해주는 신경망이라는 것을 몇몇의 실험을 통하여 알 수 있었다.[1] 하지만 출력노드의 크기를 임의로 지정해야 하는 문제점이 있고 일반적으로 출력층의 크기가 클수록 진단결과는 좋지만 연산시간은 오래걸린다는 단점이 있다. 따라서 진단능력과 학습속도 사이의 균형에 관련된 문제가 대두되게 된다. 본 논문에서는 이러한 문제점을 극복하고자 기존의 SOM 신경망의 단점을 보완하고자 GCS(Growing Cell Structures)를 이용한 심전도의 학습속도와 분류능력 사이의 효율성 개선 방안을 제안한다. 이 방법은 GCS를 이용하여 적절한 노드의 수를 찾아내는 것이다. 이를 이용한 심전도 진단의 실험을 통해 기존의 SOM이 할 수 없었던 자체적인 출력노드의 증감을 행함을 확인할 수 있었다. 또한 출력노드의 감소로 인해 연산량이 줄어 학습시간의 효율성이 증가하였다.

1. 서 론

의료분야에서 환자의 질병 진단을 위해 중요하게 고려하게 되는 신호는 심전도(ECG), 뇌전도(EEG), 근전도(EKG)등이 있다. 이중 심전도는 심장의 동반결절로부터 발생하는 미세한 전기신호의 흐름을 감지하여 기록한 것으로서 심장 질환에 대한 다양한 정보들을 내포하고 있다. 이를 정상파형과 비교하여 파형의 형태의 상이함을 비교하여 봄으로서 다양한 심장계 질환을 진단할 수 있다. 디지털 컴퓨터를 이용하여 자동으로 진단하기 위한 많은 연구가 진행되어 왔지만 심전도의 심한 기저선 변동, 환자들간의 상이한 심전도 신호 전압의 분포, 잡음의 영향 등으로 인해 많은 어려움이 있다. 이를 극복하기 위해 다양한 방법이 이용되고 있지만 심전도 패턴을 진단하기에는 매우 미흡하다. 이에 대한 극복방안으로 패턴분류에 있어서 우수한 성능을 보여주는 신경망을 통한 심전도 진단 연구가 활발히 진행되고 있다.[2] 그 중에서 자제조직화 신경망을 이용한 방법은 특정한 목적값없이 스스로 신호들의 패턴을 분류해줌으로서 심전도 진단에 있어서 효과적 성능을 보여주고 있다. 하지만 출력노드의 크기를 임의로 지정해야 하는 문제점이 있고 일반적으로 출력층의 크기가 클수록 진단결과는 좋지만 연산시간은 오래걸린다는 단점이 있다. 따라서 분류능력과 학습속도 사이의 균형에 관련된 문제가 대두되게 된다.

본 논문에서는 이에 대한 극복방안으로서 $I+1$ 개(I 은 출력층의 차원)의 출력노드에서 시작하여 양자화 오차가 일정범위에 들어올때까지 출력노드를 증가시켜주는 GCS(Growing Cell Structures)라는 방법을 사용하여 분류능력과 학습시간 사이의 적절성이 되는 적절한 노드의 개수를 찾는 실험을 진행하여 보았다.

2. 본 론

2.1 GCS (Growing Cell Structures)

GCS는 1994년 Fritzke, B.에 의해 제안되었다.[3] 기존의 자기 조직화 신경망이 패턴의 분류에 있어서는 매우 훌륭한 성능을 보여주지만 출력노드의 개수를 판단하는데 대한 임의성으로 인해 학습시간소요 및 분류능력 간의 trade-off를 조정할 때 사용자 임의로 출력노드를 증감시켜 가며 수동적으로 찾아나가야 하는 비효율성을 가지고 있다. GCS는 이를 극복하기 위해 제안된 방법으로서 대부분의 학습규칙은 자기조직화 신경망의 규칙을 그대로 따른다. 하지만 노드 개수의 증가 혹은 감소에 대한 연산부분이 추가되게 된다.

학습 과정은 아래와 같은 순서에 의해 진행된다.

- ① $I+1$ 개의 output Node를 설정하고, 지정한 횟수동안 학습을 시행한다.
- Cell Counter를 적용하여 승자 뉴런에는 Cell Counter를 1을 증가시키고 나머지는 감소율 alpha에 현재의 count값을 곱한만큼 감소를 시킨다.

$$\Delta\tau_s = 1 \text{ (승자뉴런의 Counter 증가)}$$

$$\Delta\tau_c = -\alpha\tau_c \text{ (모든 뉴런의 Counter 감소)}$$

- ② 지정된 횟수의 학습 및 테스트를 완료한 후

$$h_c = \frac{\tau_c}{\sum_{j \in A} \tau_j} \quad \dots \dots \dots \quad 1)$$

위의 1) 식에 의거 상대적 신호 주파수를 계산하여 가장 주파수가 작은 뉴런을 선정하고 선정한 뉴런과의 이웃뉴런 중 가장 거리가 먼 뉴런과의 중간점에 새로운 뉴런을 생성한다. 이 새로운 뉴런의 Weight 값은

$$\dots \dots \dots \quad 2)$$

위의 2) 식을 이용 보간하여 정한다.

- ③ 각 단계마다 각 cell의 winner로서 선택된 빈도수를 파악한다.

$$(F_c : \text{Voronoi field의 크기})$$

\widehat{p}_c 의 값이 지정된 임계치 p 보다 작으면 Cell을 제거 한다.

- ④ 원하는 진단율 혹은 지정한 노드의 개수의 최대값에 도달하지 못하였으면 1번부터 반복을 한다.

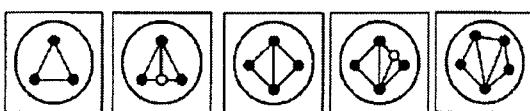


그림1. GCS의 노드증가



그림2. GCS의 노드감소

2.2 심전도(ECG)

심전도는 일반적으로 아래와 같은 파형을 보인다.

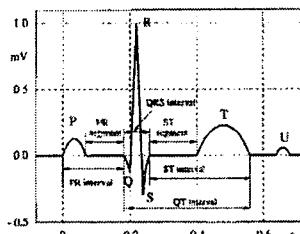


그림3. ECG 신호

그리고 증상의 이상여부는 P-Q-R-S-T의 파형 범위에서 정상파형과의 상이성 여부를 통하여 결정하게 된다.

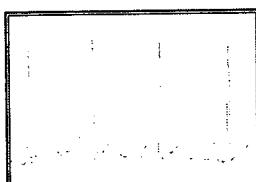


그림4. 정상파형

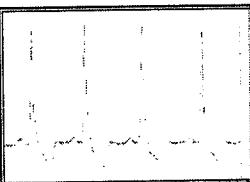


그림5. 좌각차단 파형

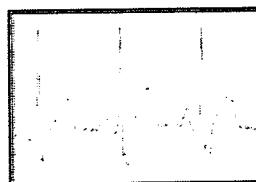


그림6. 우각차단 파형

그림3은 정상파형이다. 정상파형과 비교하여 볼 때 좌각차단의 경우는 ST분절이 낮아진 모습을 볼 수 있다. 그리고 우각차단의 경우 ST분절의 하강 및 T파의 급격한 상승을 볼 수 있다. 이러한 정상파형과 비교할 때의 특정한 이상 파형의 모습을 감지하여 이상여부를 판단하게 된다.

2.3 GCS를 이용한 심전도 진단기

2.3.1 실험데이터 및 방법

실험 데이터는 MIT Arrhythmia DB에서 추출하였다. 실험에 이용할 데이터는 정상파형은 101번, 우각차단은 118번과 212번, 좌각차단은 214번과 x_mitdb/x_109 데이터를 이용하였다. 추출방법은 한주기의

ECG신호를 R-peak를 기준으로 앞으로 80ms, 뒤로 130ms의 크기의 신호를 잘라낸 후 샘플링 주파수 360 Hz로 샘플링을 시행하였다. 이렇게 입력을 위한 신호를 추출한 결과 한 신호당 입력노드의 개수는 221개가 되었다. 학습 및 분류능력 실험을 위해 정상신호 30개, RBBB신호 82개, LBBB신호 45개의 샘플을 제작하여 랜덤하게 입력신호를 배치하고 127개의 샘플을 학습벡터로 30개의 샘플을 테스트 벡터로 이용하였다. 또한 실험의 종료여부의 판단을 위하여 진단율이 평균 98%로 출력노드 3개의 증가때까지 일정하게 유지가 되면 클러스터링이 안정적으로 된 것으로 인식하도록 하였다.

표1. GCS Network 파라미터

승자뉴런의 학습률	0.06
이웃뉴런의 학습률	0.002
Kernel Width	0.75
L-Norm	2
감쇄율	0.0005
alpha	1
노드당 반복횟수	5

특히 정상파형의 경우는 일반적인 모습을 유지하는 경우가 많지만 이상파형들의 경우 같은 증상일지라도 보이는 형태가 약간씩의 차이를 보일수 있으므로 각 2명의 환자에게서 신호를 추출하였다.

2.3.2 실험결과

위의 default Parameter에서 최대 노드수는 36개로 설정하여 실험을 하여 본 결과는 아래와 같다.

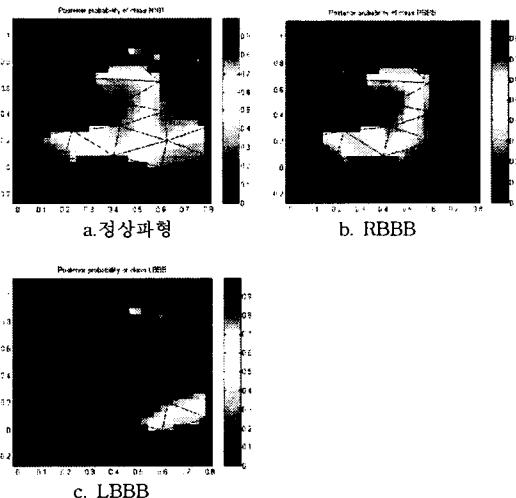


그림7. 각 패턴의 확률 분포

결과적으로 노드의 수가 18개를 넘어가면서 진단율이 100%를 유지하여 노드 20개에서 학습을 중지하였다. 그림 7)은 각 증상에 대한 클러스터링의 상황을 보여준다. 정상파형(a)은 맵의 상단에서 중간까지 골고루 퍼져 있고, RBBB(b)는 맵의 하단 및 중간 좌측에, LBBB(c)는 맵의 최상단에 적절히 클러스터링이 되었음을 알 수 있다. 또한 그림8과 9의 맵의 형성도를 보면 count frequency가 높은 곳에서 노드 생성 빈도가 높음을 확인 할 수 있다.

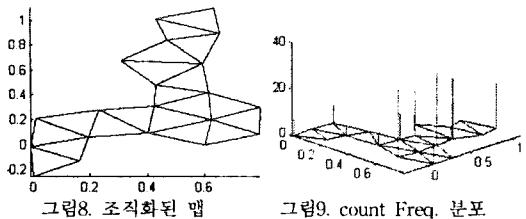


그림8. 조직화된 맵

그림9. count Freq. 분포

그리고 노드의 증가시마다의 패턴의 진단율을 그래프로 나타낸 것은 다음과 같다(그림 12). 노드가 약 10인 구간에서 100%의 진단율을 보였지만 안정적으로 유지되지 못하고 떨어져 계속 학습이 진행된 모습을 볼 수 있다.

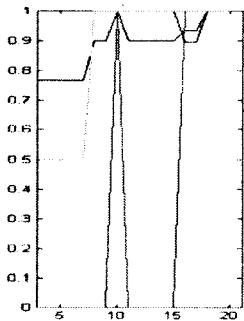


그림 12. 노드개수에 따른 ECG 질병진단율 변화

2.3.3 고 찰

진단률의 신뢰도를 높이고자 파라미터를 다양하게 바꾸어 실험을 해본 결과 대체적으로 최소 14개 ~ 최대 21개 (local minima 제외)의 출력노드에서 신호가 안정화되는 것을 확인 할 수 있었다. 또한 학습횟수가 증가한다고 하여 반드시 좋은 진단률을 보이는 것이 아님 또한 확인 할 수 있었다. 이에 대한 몇몇의 파라미터에서는 local minima 문제 및 불안정성을 보이기도 하였지만 대체적으로 좋은 진단율을 보였다.

표2. 조건별 노드갯수 변화

반복횟수	최대출력 노드	변경 Parameter	최종노드 갯수	비고
5	40	없음	16	
5	40	$\alpha = 0.5$	16	
5	40	$L_{norm}=1$	14	
10	40	없음	21	
10	40	$\alpha = 0.5$	16	
10	40	$L_{norm}=1$	16	
15	40	없음	-	불안정
15	40	$\alpha = 0.5$	19	

자기 조직화 신경망과 비교하여 고려를 할 때 우리가 최적의 노드 조건을 확인할 수 있다면 GCS의 몇몇 연산이 불필요해지므로 학습속도는 더욱 빠르다는 것을 알 수 있었지만, 미리 지정되는 한정된 조건이라는 부분에서 자기 조직화 신경망에 비해 GCS가 더 융통성을 가지고 있는 신경망임을 확인 할 수 있었다. 또한 GCS를 통하여 확인된 결과 (시간 및 출력노드의 숫자)를 자기 조직화 신경망에 적용해본 결과 거의 비슷한 진단율을 보임을 확인할 수 있었다.

표에서도 볼 수 있듯이 파라미터에 따라 최종 노드갯수의 변동은 있지만 대체적으로 20개 안팎의 노드개수로 진단이 가능함을 알 수 있었다. 또한 반복횟수 15에 강제율을 1로 났을때 진단율이 매우 불안정해짐을 알

수 있었었다 그리고 웨이트와 입력값을 값을 측정하는 norm의 L을 몇으로 설정하는가 또한 노드의 개수에 중요한 영향을 기침을 확인할 수 있었다.

위의 표2) 결과를 자기조직화 신경망에 적용하여 학습을 시킨후 분류를 하여본 결과 역시 비슷한 수준의 결과를 얻어내었다. 이는 GCS가 자기 조직화 신경망에서는 할 수 없었던 적절한 수준의 노드를 찾아내주었음을 보여주는 결과라고 할 수 있다.

3. 결 론

본 연구에서는 심전도 진단기로서의 자기조직화 신경망의 출력노드 결정에 대한 제한적 요소를 GCS algorithm를 이용하여 해결하였다.

즉, 실험을 통해 자기조직화 신경망의 출력노드 결정에 있어서의 임의성을 없애주고 또한 최소의 노드에서부터 증가시키는 연산을 하게 되므로, 노드의 개수를 미리 지정하고 학습을 시작하는 자기조직화 신경망에 비해 과도한 연산이 줄어들게 되므로 실질적인 학습속도 개선 및 효율성이 증대된다는 점을 확인하였다.

하지만 GCS의 특성상 노드의 제거 연산시에 많은 경우 새로 생성되었던 노드들이 승자뉴런으로서의 선택되는 일이 상대적으로 적어 생성된 노드가 다시 제거되는 경우가 생기게 된다. 이런 문제점은 신경망의 패턴 분류에 있어서 불안정한 모습 및 잘못된 클러스터링을 유도할 수 있으므로 이런 부분의 보완을 위해 많은 연구가 진행되고 있으며(IHGS [5]) GCS를 이용한 심전도 진단기에서 또한 불안정성 문제의 해결을 위해 지속적인 연구가 필요할 것으로 보인다.

또한 패턴이 적은 대신 다양성을 보완함으로서 좋은 결과를 얻어낼 수 있었지만, 추후의 연구에서는 환자 샘플 및 질환 샘플을 더욱 추가하여 다양한 질병의 진단에 있어서도 긍정적 성능을 보이는 진단기의 모습을 보이고자 한다.

[참 고 문 헌]

- [1] Teuvo Kohonen. Self Organizing Maps. Informat ion Sciences. Springer, second edition, 1997. 6
- [2] R. Silipo and C. Marchesi, "Artificial Neural Networks for Automatic ECG Analysis", IEEE transaction on signal processing 46(5), 1419 1425, MAY 1998
- [3] Fritzke B., "Growing Cell Structures A Self organ izing Network for Unsupervised and Supervised Learning", Neural Networks, 7(9): 1460, 1994a.
- [4] simon, H. Neural Networks, A Comprehensive F oundation, Macmillan Publishing Company, 1994
- [5] Vanco B., "Hierarchical Growing Cell Structures", IEEE ICNN '96, 1996
- [6] Joey Rogers, "Object Oriented Neural Networks in C++", Academic Press, 1997
- [7] "MIT BIH database distributor," Tech. Rep., Beth Israel Hospital, Biomed. Eng., Division KB 26, Boston, MA
- [8] Dale D., "빠르고 정확한 심전도의 이해", 군사출판사, 2003
- [9] Galens S. Wagner, "임상심전도학", 군사출판사, 2003