

병렬 Radial Basis Function 회로망을 이용한 근전도 신호의 패턴 인식에 관한 연구

김세훈, 이승철, 김지운, 박상희
연세대학교 전기공학과

A study on EMG pattern recognition based on parallel radial basis function network

Se-Hoon Kim, Seung-Chul Lee, Ji-Un Kim, Sang-Hui Park
Dept. of Elec. Eng.

Abstract - For the exact classification of the arm motion this paper proposes EMG pattern recognition method with neural network. For this autoregressive coefficient, linear cepstrum coefficient, and adaptive cepstrum coefficient are selected for the feature parameter of EMG signal, and they are extracted from time series EMG signal. For the function recognition of the feature parameter a radial basis function network, a field of neural network is designed.

For the improvement of recognition rate, a number of radial basis function network are combined in parallel, comparing with a backpropagation neural network, an existing method.

1. 서 론

인간이 근육을 수축할 때 발생하는 근전도 (electromyogram : EMG) 신호를 인식하고자 하는 문제는 보철 제어를 위한 핵심적인 한 부분이다 [1]-[3]. 사족을 절단 당한 사람들의 손상되지 않은 근육에서도 표면 근전도 신호가 검출될 수 있다는 사실에 근거하여 보철 제어에 있어 인간의 의지에 따른 동작 명령의 인식에 근전도 신호의 이용이 꾸준히 제안되어 왔다 [4]. 하지만, 근전도 신호 자체로는 복잡성과 비선형적 성질이 강하기 때문에 정확한 수학적 모델링이 매우 어렵다 [5].

패턴 인식 분야의 발전과 발 맞추어 근전도 신호의 인식 분야에서도 다양한 인식기가 도입되었다. 초기에 도입된 선형적 분리를 시작으로 최근에는 이산 흡필드 신경 회로망이나 역전파 신경 회로망이 도입되었고, 인공지능 기법인 퍼지 기법이 활용되기도 하였다 [6]-[8].

본 논문에서는 기존의 연구를 바탕으로 추출된 근전도 신호로부터 특징 파라미터를 추출하고, 추출된 특징 파라미터를 신경 회로망을 이용하여 기능 분리를 하고자 한다. 먼저 특징 파라미터로 자기 회귀 모델 계수와 선형 켈스트럼 계수를 사용하고 좀 더 안정성이 높은 적응 켈스트럼 계수를 사용하고자 한다. 기능 분리를 위한 인식기로는 최근 연구가 진행되고 있는 RBF(radial basis function) 회로망을 사용하고자 한다. RBF 회로망은 복잡한 분포를 가진 패턴들을 분리하는데 지역적인 비선형 방법을 도입함으로써 역전파 신경 회로망이 광역적으로 비선형 분리를 시도하는데서 발생하는 지역 최소값 문제를 개선하는데 매우 효과적이다. 이와 함께 RBF 회로망을 병렬로 결합하여 인식률을 향상시키고, 최종적으로 기존의 역전파 신경 회로망의 성능과 비교하고자 한다.

2. 본 론

2.1 근전도 신호의 다중 특징 추출

대부분의 신호처리 응용 분야에서는 처리하고자 하는 대상 신호를 대표하는 응축된 파라미터를 다루게 된다. 이렇게 함으로써 불필요한 성분이나 노이즈를 제거할 수 있고 패턴의 인식에 좀 더 효율적으로 이용할 수 있다. 생체 신호처리에 있어서도 이러한 접근 방법은 ECG 신호와 같이 상대적으로 단순한 결정적인 신호에서부터 통계적으로 정상적인 EEG 신호에서도 성공적으로 적용되고 있다 [3][8].

기존의 근전도 신호처리 분야에서는 절대 적분, 절대 차분 평균, 자기 회귀 모델 계수, 그리고 선형 켈스트럼 계수 등과 같은 근전도 신호의 확률 통계적 파라미터들을 특징 파라미터로 사용하였다. 이에 본 논문에서는 자기 회귀 모델 계수와 선형 켈스트럼 계수, 그리고 보다 안정적인 적응 켈스트럼 계수를 특징 파라미터로 선택하여 RBF 회로망에 적용하였다.

2.1.1 특징 파라미터

근전도 신호는 비안정적인 신호지만 자기 회귀 모델을 이용하여 선형 예측 계수를 추정해 보면 파라미터의 시간에 따른 변동 범위가 비교적 적으며, 단 구간 (100ms) 내외에서는 비교적 안정된 신호라고 볼 수 있다 [7].

$$\hat{x}(n) = - \sum_{k=0}^{p-1} a_k x(n-k) \quad (2.1)$$

자기회귀 모델은 과거 p 개의 신호 값을 이용하여 현재의 신호 값을 추정하는 방법으로 추정된 신호 $\hat{x}(n)$ 은 식 (2.1)과 같이 계수 a_k 와 p 개의 이전 신호 $\{x(n-1), x(n-2), \dots, x(n-p)\}$ 와의 선형조합으로 나타내어진다 [11].

선형 켈스트럼 계수는 일반적으로 자기 회귀 모델 계수보다 안정적인 인식률을 제공한다. 이는 근전도 신호에 대한 에너지 스펙트럼 정보와 스펙트럼의 퍼진 정도에 대한 정보를 포함하는 2차 통계 특성을 가지고 있기 때문이다. 식 (2.2)에서처럼 선형 켈스트럼 계수는 자기 회귀 모델 계수로부터 순환적으로 구할 수 있다 [11].

$$c_k = -a_n - \frac{1}{n} \sum_{k=0}^{n-1} k c_k a_{n+k} \quad n > 0 \quad (2.2)$$
$$a_0 = 0, a_k = 0; k > n-1$$

근전도 신호의 비안정적인 특성상 정확한 특징의 추출을 위해서는 적응 필터 알고리즘이 필수적이다. 그 중에서도 근전도 신호의 극심한 시변성을 고려한다면 수렴성이 매우 뛰어나 알고리즘이 필요하다. 이에 본 논문에서는 블록 처리 최적 알고리즘에 적응 필터 알고리즘을 결합한 하이브리드 형태의 적응 필터를 이용한 적응 켈스트럼 계수를 파라미터로 선정하였다 [8].

2.2 신경 회로망의 설계

패턴인식의 과정은 크게 두 가지로 나뉜다. 하나는 파라미터의 선택 과정이고, 다른 하나는 인식기의 설계이다. 인식기의 선택은 파라미터의 선택에 비하여 비교적 일반적이므로 근전도 신호의 인식을 위하여 다양한 인식기

가 적용되어 왔다. 가장 기본적인 선형 분리기로 시작하여 통계적인 분포를 이용하여 최적의 결정 경계 (decision boundary)를 갖는 베이시안 인식기로 발전되어 왔고, 최근에는 다양한 신경 회로망이 근전도 신호의 인식을 위하여 적용되었다[6][7].

패턴 인식 분야에 사용된 신경 회로망은 이산 홉필드 회로망과 다중 퍼셉트론, 그리고 역전파 신경 회로망 등이 있다. 역전파 신경 회로망은 비교적 뛰어난 인식 능력을 가진 회로망으로 패턴 인식 분야에 많이 사용되고 있다.

본 논문에서는 근전도 신호의 패턴 인식을 위하여 개선된 K-NN(K-Nearest-Neighbor) 클러스터링 기법을 적용한 RBF 회로망을 설계하고자 한다. RBF 회로망은 역전파 신경 회로망이 가진 지역 최소값 문제를 어느 정도 극복한 신경 회로망으로 최근 많은 연구에 활용되고 있다.

2.2.1 역전파 신경 회로망

역전파 신경 회로망은 다중 다층의 퍼셉트론으로 이루어진 신경 회로망으로 일반적인 단일 퍼셉트론의 성능을 개선하였다. 첫째로 다층의 퍼셉트론을 이용하여 단일 퍼셉트론이 가질 수 있는 단일 결정 경계선의 한계를 넘어서 여러 개의 결정 경계선으로 클래스를 분리할 수 있다. 둘째로 비선형 시그모이드 함수를 뉴런의 출력단에 도입함으로써 비선형적인 분리를 가능하게 한다. 그림 1은 역전파 신경 회로망의 구조로 입력층과 출력층, 그리고 은닉층으로 구성되어 있다.




그림 1 역전파 신경회로망의 구조

역전파 신경 회로망은 복잡한 패턴의 인식에 있어서 비교적 뛰어난 성능을 인정받고 여러 분야에 사용되고 있으나, 학습 알고리즘에 존재하는 지역 최소값의 문제가 남아있다. 학습 기준 함수의 전역 최소값으로 수렴해야 하지만, 초기 위치에 따라 지역 최소값으로 수렴하는 문제가 지역 최소값 문제인데 초기값을 잘 선택해야 하는 것은 물론이고, simulated annealing과 같은 수치 해석적인 방법을 도입하기도 한다.

2.2.2 RBF 회로망

신경 회로망 분야에서 최근 활발히 연구되고 있는 분야는 RBF(radial basis function) 회로망이다. RBF 망은 색다른 분리 방법을 제안하는데 바로 벡터 공간의 변형이다. 입력 벡터의 차원을 증가시키거나 같은 차원이라도 공간을 변형하여 입력 패턴의 분리도를 증가시키고자 하는 것이 RBF 회로망의 기본적인 동작 원리이다[12]. 그림 2에서 보듯이 RBF 회로망은 기본적으로 입력층과 은닉층, 그리고 출력층으로 구성된다[10]. 역전파 신경 회로망과는 달리 한 층의 은닉층을 갖는다.

식 (2.3)은 입력 벡터 \vec{x} 에 대한 출력 결과이다. 여기서 ϕ 는 RBF이고 \vec{w} 는 은닉층의 출력결과 ϕ 와 출

력층간의 연결강도이다.




그림 2 RBF 회로망의 기본 구조

$$\begin{aligned}
 y &= w_0 + \vec{w} \cdot \vec{\phi} \\
 \vec{\phi} &= \Phi(\vec{x}) \\
 \vec{w} &= (w_1, w_2, \dots, w_j, \dots, w_M) \\
 \vec{x} &= (x_1, x_2, \dots, x_i, \dots, x_N)
 \end{aligned} \quad (2.3)$$

RBF Φ 는 $\Phi: R^N \rightarrow R^M$ 의 관계를 갖는 함수로 N 차원상의 입력 벡터 $\vec{x} = (x_1, x_2, \dots, x_N)$ 에 대하여 M 차원상의 출력 벡터 $\vec{\phi} = (\phi_1, \phi_2, \dots, \phi_M)$ 간의 함수 관계를 맺는 다차원 함수이다. 이러한 함수 Φ 는 입력 벡터 \vec{x} 와 중심벡터 \vec{c} 사이의 거리 $r = \|\vec{x} - \vec{c}\|$ 에 의존하는데 거리 r 은 기하학적 거리를 주로 사용한다.

중심 벡터와 입력 벡터 \vec{x} 사이의 거리에 따라 결정되는 좌표 ϕ 는 중심에서 가까울수록 큰 출력을 멀어질수록 작은 출력을 내도록 설계된다. 그렇게 함으로써 표준으로 정해진 중심벡터와 기하학적으로 가까운 입력 벡터에 대해서는 긍정적인 출력을 기하학적으로 먼 입력 벡터에 대해서는 부정적인 출력을 나타내게 된다. RBF의 이러한 출력 기능으로 가우시안 함수가 주로 사용된다. 결국 중심 벡터 \vec{c}_j 와 폭 σ_j 를 고려할 때 입력 벡터 \vec{x} 에 대한 RBF의 출력 벡터 $\vec{\phi}$ 의 j 번째 좌표 ϕ_j 는 식 (2.4)와 같이 계산된다.

$$\begin{aligned}
 \phi_j &= \exp \left[-D_j^2 / (2\sigma_j^2) \right] \\
 D_j^2 &= (\vec{x} - \vec{c}_j)^t (\vec{x} - \vec{c}_j)
 \end{aligned} \quad (2.4)$$

2.2.2 RBF 회로망의 학습

RBF 회로망을 학습시키기 위해서는 세 가지 작업이 필요하다. 첫째는 각 패턴의 중심벡터를 선정하는 것이고, 둘째는 RBF의 폭을 결정하는 것 셋째는 연결강도를 학습시키는 것이다. RBF 회로망을 학습시키는 방법은 크게 세 가지로 분류된다[10]. 첫째는 임의로 고정된 중심 벡터와 폭을 선택하여 연결강도와 관계된 역행렬을 구함으로써 회로망을 결정하는 것이고, 둘째는 중심 벡터와 폭을 연결강도와 함께 회귀적으로 학습시키는 것이다. 마지막으로 본 논문에서 사용하고자 하는 방법은 중심 벡터를 클러스터링 방법으로 구하고, 연결 강도를 최소 평균 자승 방법에 의하여 학습시키는 것이다.

입력 패턴의 클러스터링을 위하여 1991년 Musavi가 제안한 개선된 K-NN 방법을 사용하였다. 알고리즘은 다음과 같다.

<반복적인 클러스터링 알고리즘>

Step 1. 각 학습 벡터를 클러스터로 지정함으로써 초기화한다.

- step 2. 임의대로 각 클러스터의 순번을 지정한다. ($L = 1, \dots, C$)
- step 3. 첫 번째 클러스터를 선택한다. ($L = 1$)
- step 4. 주변의 같은 클래스에서 임의의 클러스터를 같은 클러스터로 선택한다.
- step 5. 두 개의 클러스터에서 새로운 중심 벡터를 구한다.
- step 6. 상대 거리 d_{opp} 를 계산한다.
상대 거리는 step 5.에서 구한 새로운 중심 벡터와 가장 가까운 다른 클래스의 클러스터의 중심 벡터 사이의 거리이다.
- step 7. 자기 반경 R 을 계산한다.
자기 반경은 자신 클러스터에 포함된 벡터 중 중심 벡터에서 가장 먼 벡터와 중심 벡터와의 거리이다.
- step 8. 클러스터링 파라미터 α 를 사용하여 선택된 클러스터를 포함할 지 여부를 판정한다.
a. 만일 $d_{opp} > \alpha R$ 이면 step 5.로 이동한다. ($C = C + 1$)
b. $d_{opp} \leq \alpha R$ 이면 두 클러스터간의 합병을 취소하고 step 5.로 이동한다. ($L = L + 1$)
- step 9. step 4.에서 step 8.까지 $L = C$ 일 때까지 반복

클러스터링 방법에 의하여 구해진 중심벡터를 이용하여 RBF를 통과한 입력 패턴을 비교적 선형적으로 분리하기 쉬운 분포를 갖는다. 이렇게 새로운 공간으로 재분포된 입력 패턴에 대하여 최소 평균 자승 학습법을 이용하여 은닉층과 출력층의 연결강도를 학습시킨다. 갱신식은 식 (2.5)와 같다.

$$\begin{aligned} w_j(t+1) &= w_j(t) - \gamma \delta(t) \phi_j \\ w_0(t+1) &= w_0(t) - \gamma \delta(t) \\ \delta(t) &= y(t) - d(t) \end{aligned} \quad (2.5)$$

식 (2.5)에서 $\delta(t)$ 는 현재 입력 벡터에 대한 출력 값과 기대값과의 차이이고, γ 는 학습률이다. w_0 는 바이어스 항이다.

3. 결 론

실험에 사용하기 위하여 팔운동에 대한 근전도 신호를 대상으로 삼아 6가지의 기본 운동, 즉 굴곡운동, 신전운동, 내전운동, 반장운동, 어깨의 안쪽 회전운동, 그리고 바깥쪽 회전운동에 대하여 각 동작마다 50회씩 시계열(time series) 근전도 신호를 측정하였다. 각 시계열 근전도 신호로부터 128ms씩 해밍 윈도우(중첩비율 50%)를 취하여 특징 파라미터를 추출하였는데, 특징 파라미터로는 자기 회귀 모델 계수, 선형 캡스트럼 계수, 그리고 적응 캡스트럼 계수를 추출하였고, 12차 계수를 사용하였다. 결국 특징 파라미터별로 400개의 패턴을 시험용으로 제작하였고, 학습용으로 6000개의 패턴을 시험용과 달리 제작하였다.

표 1 각 신경 회로망의 특징 파라미터별 오인식률 비교

특징 파라미터	신경 회로망	상대 오인식률(%)
자기 회귀 모델 계수	역전파	100
	RBF ① / 클러스터(5789)	95.3
	RBF ② / 클러스터(1245)	93.5
	RBF ③ / 클러스터(543)	95.4
선형 캡스트럼 계수	역전파	80.3
	RBF ① / 클러스터(4753)	76.3
	RBF ② / 클러스터(1550)	74.9
	RBF ③ / 클러스터(532)	75.2
적응 캡스트럼 계수	역전파	70.1
	RBF ① / 클러스터(5343)	64.0
	RBF ② / 클러스터(1931)	64.0
	RBF ③ / 클러스터(581)	62.6

RBF 회로망의 비교대상인 역전파 신경 회로망은 은닉층 400(200노드×2층)개의 노드를 사용하여 6000개의 학습용 패턴을 학습하였고, 성능의 비교를 위하여 자기 회귀 모델 계수를 역전파 신경회로망에 학습시킨 경우를 기준으로 상대 오인식률을 통하여 비교하였다.

인식률의 향상을 위하여 RBF 회로망 3개를 병렬 연결하여 상대 오인식률을 비교하였는데, 회로망의 결합시 단순 평균과 가중 평균을 이용하였다.

표 2 병렬 radial basis function 회로망의 오인식률

병렬 신경 회로망	결합기 구성	상대 오인식률(%)
회로망 조합 ① (5000개 내의 조합)	평균	58.7
	가중 평균	56.8
회로망 조합 ② (1000개 내의 조합)	평균	59.1
	가중 평균	56.8
회로망 조합 ③ (500개 내의 조합)	평균	58.7
	가중 평균	56.8

오인식률의 비교결과 역전파 신경 회로망에 비하여 RBF 회로망의 성능이 우수하였고, 회로망을 조합한 경우 상당한 인식률의 개선을 보였다. 각 회로망의 신뢰도를 반영한 가중 평균의 경우가 가장 안정적인 패턴 인식을 보였다.

[참 고 문 헌]

- [1] G. N. Saridis, and H. E. tephanou, "A hierarchical approach to the control of a prosthetic arm," IEEE Trans. on SMC., vol. SMC-7, No. 6, pp. 407-420, Jun. 1977.
- [2] Sukhan Lee, and George N. Saridis, "The control of a prosthetic arm by EMG pattern recognition," IEEE Trans. on Automat. Contr., vol. AC-29, pp. 290-302, Apr. 1984.
- [3] O. Paiss, and G. F. Inbar, "Autoregressive modeling of surface EMG and its spectrum with application to fatigue," IEEE Trans. on Biomed. Eng., vol. BME-34, pp. 761-770, Oct. 1987.
- [4] G. F. Inbar, and Antoine E. Noujaim, "On surface EMG spectral characterization and its application to diagnostic classification," IEEE Trans. on Biomed. Eng., vol. BME-31, Sep. 1984.
- [5] Fuquin Q. Xiong, and Ed. Shwedyk, "Some aspects of nonstationary myoelectric signal processing," IEEE Trans. on Biomed. Eng., vol. BME-34, pp. 166-172, Feb. 1987.
- [6] M. F. Kelly, P. A. Parker, and Robert N. Scott, "The application of neural networks to myoelectric signal analysis: a preliminary study," IEEE Trans. on Biomed. Eng., vol. 37, pp. 221-23-, Mar. 1990.
- [7] 조정호, "신경 회로망을 이용한 근전도 신호 기능 인식에 관한 연구," 연세대학교 대학원, 석사학위 논문, 1990.2.
- [8] 이석필, "인공지능 기법에 의한 근전도 신호의 패턴 인식에 관한 연구," 연세대학교 대학원, 박사학위 논문, 1997.6.
- [9] James A. Freeman, David M. Skapura, *Neural networks: algorithms, applications, and programming techniques*, Addison-Wesley, 1991.
- [10] Simon Haykin, *Neural networks: a comprehensive foundation*, IEEE Press, pp. 236-284, 1994.
- [11] Steven M. Kay, *Modern spectral estimation: theory and application*, Prentice Hall, 1988.
- [12] Musavi, M. T., Faris, K. B., Chan, K. H., and Ahmed, W., "On the implementation of RBF technique in neural networks," ACM ANNA-91, Anal. Neural Network Appl., pp. 110-115, 1991.