

AR 매개 변수를 이용한 근육 피로의 측정

○ * * * *
김 흥래, 왕 문성, 최 윤호, 박 상희

* 연세 대학교 전기공학과

Measurement of Muscle Fatigue using AR Parameters

○ * * * *
H.R. Kim, M.S. Wang, Y.H. Choi, S.H. Park

* Dept. of Electrical Eng., Yonsei Univ.

ABSTRACT

This paper describes the AR model of EMG signal during maximum voluntary contraction. By comparing the AR coefficients and the reflection coefficients of the AR model with the median frequency of power spectrum, it is proved that muscle fatigue can be measured by the AR and the reflection coefficients. In the estimation procedure of AR model parameter, the autocorrelation method is superior to the covariance method, and it is determined that the optimal order is six. As the muscle becomes fatigued, the median frequency of power spectrum is declined, and the AR coefficient [a_1] and the reflection coefficient [k_1] are also decreased. Therefore the muscle fatigue can be measured by the AR parameter.

1. 서 론

신호처리의 기술이 발달함에 따라 신호가 포함하고 있는 정보내용을 알맞은 매개변수로 표현하는 방법이 많이 연구되어 왔다. 이것은 그 신호가 포함하고 있는 본질적인 특징을 유지하면서 신호의 의사성분(spurious component)과 잡음을 제거함으로써 간편하게 신호의 분류와 패턴인식을 할 수 있다는 점에서 바탕적인 일이다.

이러한 접근 방법은 ECG (electrocardiogram : 심전도)나 EEG (electroencephalogram : 뇌전도)와 같은 유사주기(quasi-periodic) 신호에 적용되어 왔으며, 지난 10년 동안에는 EMG (electromyogram : 근전도) 신호를 AR (autoregressive : 자기회귀) 모델링 함으로써 데이터 수의 감축과 EMG 신호의 기능 분류를 하려는 몇 가지 성공적인 시도가 있었다.

본 연구에서는 EMG 신호를 AR 모델로 모델링 한 후 AR 모델의 몇 가지 매개변수를 사용하여 근육이 피로한 동안의 생리학적인 변화를 추적 하려고 한다.

근육피로의 생리학적 과정은 이미 알려져 있는 현상으로 AR 모델의 적용 가능성을 시험하기에 적당한 보기가 될 수 있으며, EMG를 AR 모델링 함으로써 그 매개변수를 이용하여 지금까지 근육피로를 측정하는 데에 사용되어 온 근육피로 감시기(muscle fatigue monitor: MFM)를 간단한 소프트웨어로 대체할 수도 있을 것이다. 지금까지 개발된 근육피로 감시기들은 모두 근육의 피로가 가중되고 있는 동안의 중간 주파수 (median frequency)를 감시함으로써 근육이 피로해지는지를 과정을 측정해 왔는데, 본 논문에서는 이 중간 주파수의 주이와 AR 모델의 매개변수들의 주이를 각각 감시하여 유사성을 추출함으로써 AR 모델의 계수만으로 피로를 측정할 수 있는 근거를

마련하였다. 이러한 방법을 사용하면 간단한 소프트웨어만으로 짧은 시간 안에 근육의 피로를 측정할 수 있다.

2. EMG 신호의 AR 모델링

2-1. AR 모델

EMG 신호를 AR 모델로 모델링할 때, EMG 신호의 각 샘플 $x(n)$ 은 식(1)과 같이 과거의 샘플 $x(n-k)$ 에 독립적인 오차 $e(n)$ 를 합한 선형 조합으로 표현된다.

$$x(n) = -\sum_{k=1}^p a_k x(n-k) + e(n) \quad (1)$$

여기서, $x(n)$: 모델로 된 신호의 샘플

a_k : AR 계수

$e(n)$: 오차

p : 모델의 차수

이때 $e(n)$ 은 백색잡음(white noise)이며, 모델은 $e(n)$ 을 입력, $x(n)$ 을 출력으로 갖는 선형 시스템으로 해석될 수 있다.

2-2. 모델의 매개변수 추정

실험에 의해 얻어진 EMG 신호 데이터로부터 아래와 같은 매개변수들이 계산된다.

a_i , $i=1, 2, \dots, p$ AR 계수
 k_i , $i=1, 2, \dots, p$ 반사 계수

(reflection coefficients)

이때, AR 계수 a_i 는 임의 에너지 $\sum_n e^2(n)$ 을 최소로 하는 알고리즘에 의해 계산되며, k_i 는 정규 방정식(normal equation)에서 a_i 를 계산하는 반복(iterative) 알고리즘에 의해 만들어지는데, 모든 i 에 대해서 k 의 절대값이 1보다 작으면 모델의 차수 $p(i:p)$ 에 대해 독립적인 유용한 성질을 갖는다.

한편 AR 계수와 반사계수를 추정하는 방법에는 자기상관법(autocorrelation method), 공분산법(covariance method), Burg 방법 등이 널리 쓰인다. 본 연구에서는 자기상관법과 공분산법을 사용하여 매개변수를 추정한 후 비교하였고, Burg 방법은 데이터를 처리하는데 계산시간이 너무 많이 소요되므로 본 논문에서는 고려하지 않았다.

2-3. 모델의 차수

AR 모델링에서 모델의 차수를 선택하는 것은 매우 중요한 일이다. 왜냐하면, 모델의 차수가 커질수록 오차가 줄어들고 스팩트럼의 해상도(resolution)는 좋아지지만 계산시간이 길어지게 되며, 반대로 차수가 작으면 계산시간은 적게 걸리지만 오차가 커지고 스팩트럼의 해상도가 떨어지게 되기 때문이다. 따라서, 신호가 포함하고 있는

정보의 손실을 최소한으로 하면서 계산시간을 줄일 수 있는 최적 차수를 결정하여야 한다.
차수를 선택하는데에는 여러 가지 방법이 있는데 본 논문에서는 Akaike 가 제안한 AIC (Akaike Information Criterion) 방법을 이용하였으며 그 식은 다음과 같다.

$$AIC(p) = N \ln(F_p) + 2p \quad (2)$$

여기서, F_p 는 오차의 분산, N은 데이터 수, p는 차수이다.
AIC 방법은 차수 p를 변화시킬 때 p의 함수 $AIC(p)$ 가 최소값을 갖는 p를 최적 차수로 결정하게 된다.

3. 근육 피로의 측정

3-1. 근육 피로의 생리학적 고찰

근육의 수축(voluntary contraction)이 지속되어서 근육이 피로해지면 젓간과 같은 신진 대사의 부산물이 근육 내에 축적되게 된다. 이때 그 부산물들이 축적되는 것은 그것들의 생성이 증가하는 것 때문일 수도 있고, 근육의 강력한 수축에 의해 혈류가 감소됨으로써 그것들을 재대로 제거하지 못하기 때문에 일 수도 있으나, 젓간의 축적과 부가적으로 일어나는 pH의 저하가 오랫동안 국소적 근육 피로(local muscle fatigue)와 근육 통의 원인으로 알려져 왔다.

축적된 부산물을 온도 센서에서 활동전위의 전도속도 (conduction velocity)를 감소시키는데 이것은 Stalberg에 의해 증명되었다. 한편 전도 속도가 감소되면 운동 단위 활동전위의 시간 주기(time duration)가 커지고, 따라서 스팩트럼은 점주파 대역으로 천이된다.

근전도 신호의 전력 스팩트럼은 전극의 위치, 단일 섬유의 활동 전위 형태, 활동전위 전도속도, 운동 단위의 크기와 전극으로부터의 거리, 운동 단위 발화율 등과 같은 많은 물리적 요소와 관련이 있는 것으로 알려지고 있으며, 국소적 근육피로를 측정하는데 스팩트럼의 축소를 이용하는 것은 이미 임상용 통해 입증되었다.

3-2. AR 매개변수를 이용한 근육 피로의 측정

근육의 피로가 진행됨에 따라서 EMG 신호의 스팩트럼은 점주파 대역으로 천이하게 되는데, 이것은 곧 EMG 신호가 더 좁은 대역으로 되고, 뼈쇄 잡음의 성질을 덜 가지게 되는 것을 의미한다. 따라서 신호는 더 예측 가능하게 되어서 임여 에너지 V_p 가 감소하게 된다. 또한 자기상관 함수가 더 넓어지므로 자기상관 계수 $\hat{r}(1)$ 은 증가하고 반자계수 k_1 은 단순히 $-\hat{r}(1)$ 이므로 k_1 은 감소하게 된다. 그러므로, k_1 은 피로도 측정의 매개변수로 될 수 있다.

a_i 와 k_1 에 대한 모든 $\hat{r}(1)$ 의 영향은 좀 더 복잡하지만 역시 피로도를 감시하는데 적용할 수 있으며, k_1 은 다음과 같이 간단히 계산되므로 소프트웨어만으로도 실시간에 가까운 빠른 계산을 수행할 수 있다.

$$k_1 = \frac{\hat{r}(1)}{a_i} = -\frac{\sum_{n=0}^{N-2} x(n)x(n+1)}{\sum_{n=0}^{N-1} x(n)x(n)} \quad (3)$$

4. 실험

4-1. 실험 장치

EMG 신호는 이두박근에 부착된 표면 전극을 통해서 얻어지고, 증폭기와 필터, A/D 변환기를 통해서 마이크로컴퓨터에 데이터 블록으로 저장된다.

본 실험에서는 Ag-AgCl 전극(Beckman model 650418, 직경 17mm)을 사용하였으며 이두박근을 따라서 3.5cm 간격으로 부착했다. 피부와 전극 사이에 바르는 전해질(electrolyte)에 의한 출력 신호의 드리프트(drift)를 없애기 위해서 ENG averaging coupler (Beckman, model 9852A)를 사용

하였고, 전극의 반전지 전위(halfcell potential)를 제거하기 위하여 1% 석 염수에 넣어 안정화시켰으며 외부 잡음을 줄이기 위해서 전극과 증폭기를 연결하는 선은 입력 케이블(Beckman, Part no. 215268)을 사용하였다. 신호의 증폭과 필터링에는 Beckman 사의 K-511A dynograph 기록기를 사용하였다.

4-2. 실험 방법

생체 신호는 매우 미약하기 때문에 신호를 측정할 때의 모든 환경을 충분히 안정한 상태로 유지하여야 한다. 전극에서의 잡음과 측정기에서의 잡음을 가능 한 줄이기 위해서 모든 계기는 완전히 접지시켰고, 실험을 시작하기 전에 충분히 동시에 안정화시켰다. 실험은 피검자가 몸을 완전히 고정시킨 상태에서 시행되었으며, 빠른 국소 피로를 유도하기 위해서 100% 최대 수축(maximal voluntary contraction; MVC)을 하였다. 실험이 진행되는 동안 피검자는 계속적으로 일정한 힘을 주어야 하며 등간장 수축(isometric contraction)을 하여야 한다.

피로가 진행되는 과정을 살펴보기 위하여 65.5초 간에 걸쳐서 EMG 신호 데이터를 계속적으로 검출하였고, 검출된 EMG 신호는 1000 samples/sec로 샘플링되어서 1MB 퍼스널 컴퓨터에 저장된다.

계산은 매개 변수의 일시적인 변화를 추적하기 위해서 256개의 데이터 샘플을 포함시키는 윈도우를 사용한다. 일단 계산이 수행된 후에는 64개의 샘플씩 윈도우를 진행시킴으로써 a_i 와 k_1 의 연속적인 그래프를 얻게 된다.

5. 실험 결과 및 고찰

5-1. 모델의 차수

EMG 신호 데이터를 식(2)의 AIC 방법에 적용 시킨 결과가 그림 1에 있다. 데이터 블록에 따라 약간의 차이는 있지만 5 또는 6차의 최적 차수를 구할 수 있었다. 대체로 피로가 심하지 않은 상태의 EMG 신호에서는 최적 차수가 6으로, 피로가 많이 진행된 신호에서는 최적 차수가 5로 결정되었다. 따라서, 본 연구에서는 최적 차수를 6으로 결정하였다.

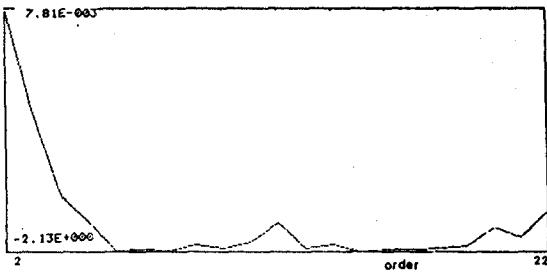


그림 1. EMG 신호에 대한 AIC 함수

5-2. 모델의 매개변수 추정

자기상관법과 공분산법에 의해 계산된 AR 계수들은 거의 같은 값을 보이며, 표 1에 나타난 바와 같이 각 AR 계수들의 평균은 두 가지 방법이 거의 같은 값을 보이지만 분산은 자기상관법에 의한 결과가 더 작음을 알 수 있다. 또, 계산 시간도 자기상관법이 공분산법에 비해 약 40% 정도가 빠르므로, 계산시간과 정확도의 관점에서 볼 때 자기상관법이 공분산법보다 더 나음을 알 수 있다. 한편 그래프에서 보이는 진동(oscillation)은 AR 모델의 변화를 나타내는 것은 아니며, 단지 샘플 EMG 데이터의 랜덤 특성(random nature)에서 기인하는 것이다.

표 1. 추정 방법에 따른 AR 계수의 평균과 분산

AR coefficient method	mean		variance	
	auto.	covar.	auto.	covar.
a_1	-1.106757	-1.112715	0.005965	0.006771
a_2	0.054484	0.053626	0.012672	0.014716
a_3	0.147483	0.154233	0.008324	0.009461
a_4	0.049287	0.049995	0.008545	0.009542

5-3. 근육 피로

MVC를 하기 전 피로하지 않은 상태의 전력 스펙트럼과 MVC 직후의 아주 피로한 상태의 전력 스펙트럼이 그림 2에 있다. 그림 2로부터 피로가 진행됨에 따라서 전력 스펙트럼이 저주파대로 천이 했음을 확실히 볼 수 있다.

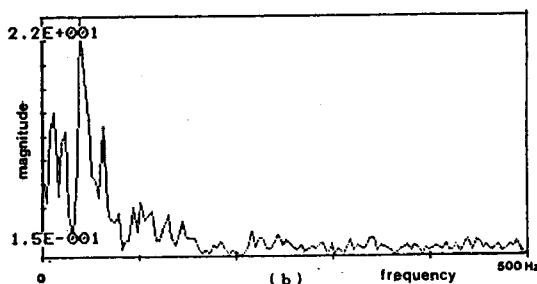
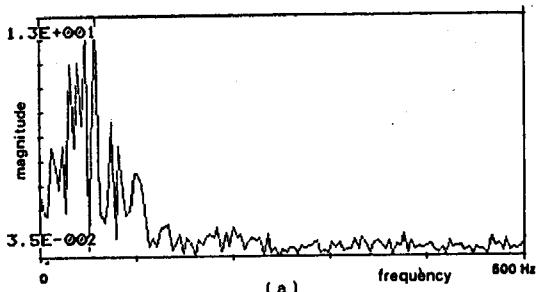


그림 2. (a) 피로하기 전 상태의 EMG 신호에 대한 전력 스펙트럼
(b) 피로한 상태의 EMG 신호에 대한 전력 스펙트럼

65.5초간 근육이 최대 수의 수축을 할 때, 전력 스펙트럼의 중간 주파수가 변화하는 과정이 그림 3에 있다. 근육이 피로해짐에 따라 중간 주파수는 100Hz에서 66Hz로 약 40% 정도 감소했으며, 이것은 전력 스펙트럼이 저주파대로 천이하는 것과 관련이 있다.

최대 수의 수축을 하는 동안의 AR 계수와 반사 계수의 추이는 그림 4와 그림 5에 나타난 바와 같다. 이 때 a_1 은 -0.785에서 -1.212로, k_1 은 -0.061에서 -0.110으로 각각 36%와 45% 정도 감소하는데 이것을 중간 주파수의 추이와 비교해보면 거의 유사함을 알 수 있다. IBM/AT 퍼스널 컴퓨터를 이용할 때 중간 주파수 측정법은 약 45분의 처리 시간을 요하며, AR 계수는 약 5분, k_1 만을 계산하면 1분 정도에 계산을 수행할 수 있다. 따라서, 근육의 피로를 관찰하는 데 AR 계수와 반사 계수를 사용하면 훨씬 짧은 시간 내에 좋은 결과를 얻을 수 있으며, 특히 k_1 은 근육 피로의 과정을 잘 반영하면서 짧은 시간 내에 처리가 가능하므로 근육의 피로를 관찰하는데 아주 적당한 매개변수임을 알 수 있다.

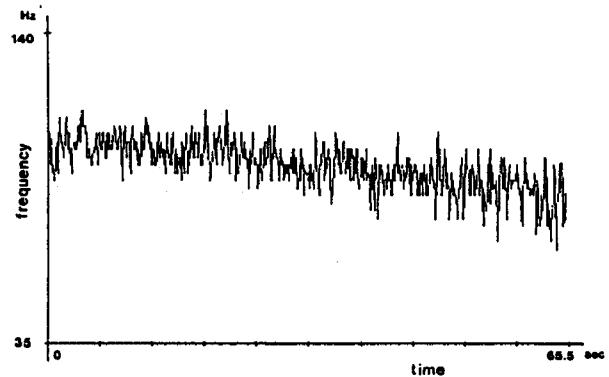
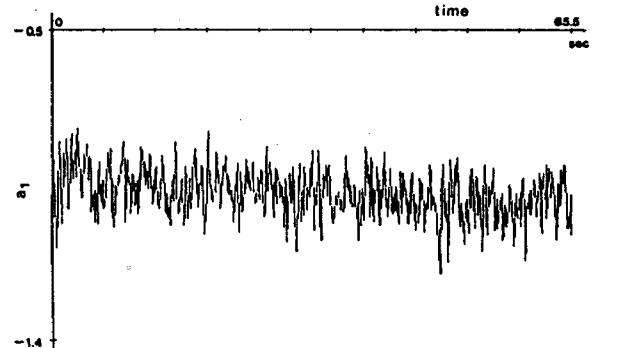
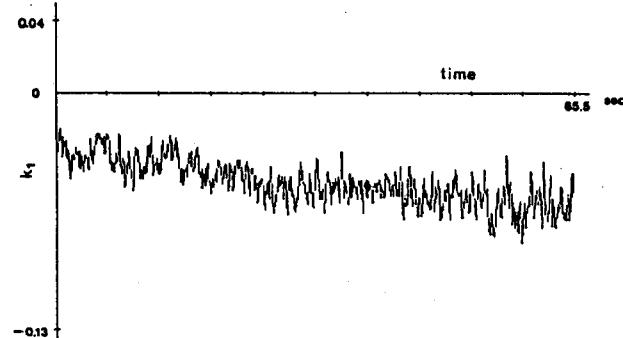


그림 3. 근육피로를 반영한 중간 주파수의 변화

그림 4. 근육피로를 반영한 AR 계수 a_1 의 변화그림 5. 근육피로를 반영한 반사계수 k_1 의 변화

6. 결 론

본 연구의 목적은 근육이 최대 수의 수축을 하는 동안의 EMG 신호를 AR 모델에 적용한 후 그 AR 계수와 반사 계수를 구하고, 전력 스팩트럼의 중간 주파수와 비교함으로써 근육이 피로해지는 과정의 생리적 변화를 관찰하는데 있으며, 실험을 통해 얻어진 결과는 다음과 같다.

1) 매개변수 추정 알고리즘은 그 속도와 정확도에 있어서 자기상관법이 공분산법보다 더 우수하였다.

2) 차수를 선택하는 데에는 AIC 방법을 사용하였고, 이때 최적 차수는 6으로 결정되었다.

3) MVC 직전과 직후의 전력 스팩트럼을 비교함으로써, 근육이 피로해지면 EMG 신호의 전력 스팩트럼이 저주파대로 천이 하며, 이에 따라서 전력 스팩트럼의 중간 주파수가 떨어지게 됨을 확인하였다.

4) 근육이 피로해지는 동안의 AR 계수와 반사 계수를 연속적으로 계산하여 전력 스팩트럼의 중간 주파수의 주이와 비교한 결과 a_1 과 k_1 이 유사한 주이를 나타내는 것을 알 수 있었고, 특히 k_1 은 피로를 반영하는 특성이 풀풀한 매개변수임을 알았다.

본 연구에서의 근육 피로 측정 알고리즘을 사용하면 근육의 피로 상태를 알 수 있고, 나아가서 신경근육계의 질병이나 이상을 진단하는데 응용할 수도 있을 것이다. 또한 근력이나 근육의 지구력을 측정하여 근육의 효율적인 트레이닝에 이용할 수 있으므로 스포츠 과학에의 응용도 기대할 수 있다.

참 고 문 헌

- [1] L. Basano and P. Ottone, "Real - time FFT to monitor muscle fatigue," IEEE Trans. Biomed. Eng., vol. BME-33, pp. 1049 - 1051, 1986
- [2] C.J. De Luca, "Physiology and mathematics of myoelectric signals," IEEE Trans. Biomed. Eng., vol BME-26 pp. 313-325, 1979
- [3] L.D. Gilmore and C.J. De Luca, "Muscle fatigue monitor(MFM) : Second generation," IEEE Trans. Biomed. Eng., vol. BME-32, pp. 75-78, 1985
- [4] S.M. Kay and S.L. Marple, "Spectrum Analysis - A modern perspective," Proc. IEEE, vol. 69, pp. 1380-1419, 1981
- [5] J. Makhoul, "Linear prediction : A tutorial review," Proc. IEEE, vol. 63, pp.561-579, 1975
- [6] J.D. Markel and A.H. Grey, Linear Prediction of Speech. Berlin : Springer-Verlag, 1976
- [7] S.L. Marple, Digital Spectral Analysis with Application, Prentice-Hall, 1987
- [8] R. Merletti, D. Biey, M. Biey, G. Prato and A. Orusa, "Online monitoring of the median frequency of the surface EMG power spectrum," IEEE Trans. Biomed. Eng., vol. BME-32, pp. 1-7, 1985
- [9] S.J. Orfanidis, Optimum Signal Processing : An Introduction. Macmillan Publishing Company, 1985
- [10] F.B. Stulen and C.J. De Luca, "Frequency parameters of the myoelectric signal as a measure of muscle conduction velocity," IEEE Trans. Biomed. Eng., vol. BME-28, pp. 515-523, 1981
- [11] F.B. Stulen and C.J. De Luca, "Muscle fatigue monitor : A noninvasive device for observing localized muscular fatigue," IEEE Trans. Biomed. Eng., vol. BME-29, pp. 760-768, 1982
- [12] 변 윤식, "다기능 보철 제어를 위한 근전도 신호 식별," 박사학위 논문, 연세대학교 대학원, 1985