

비정상(非定常) 시변 신호 인식기의 실시간 구현 및 근피로도 측정에의 응용

이진 · 이영석 · 김성환

=Abstract=

Real Time Implementation of Time Varying Nonstationary Signal Identifier and Its Application to Muscle Fatigue Monitoring

Jin Lee, Young Seock Lee, Sung Hwan Kim

A need exists for the accurate identification of time series models having time varying parameters, as is important in the case of real time identification of nonstationary EMG signal. This paper describes real time identification and muscle fatigue monitoring method of nonstationary EMG signal. The method is composed of the efficient identifier which estimates the autoregressive parameters of nonstationary EMG signal model, and its real time implementation by using T805 parallel processing computer. The method is verified through experiment with real EMG signals which are obtained from surface electrode. As a result, the proposed method provides a new approach for real time implementation of muscle fatigue monitoring and the execution time is 0.894ms/sample for 1024Hz EMG signal.

Key words : Nonstationary EMG signal, Autoregressive model, Parallel processing computer, Real time identification and Muscle fatigue monitoring

서 론

오늘날 관례적인 신호처리 기법에서, 대부분의 강력하고 효율적인 알고리즘들은 종종 정상성(stationarity)의 가정 하에서, 또한 처리하고자 하는 신호의 기저(basis) 부분을 선형 시불변 미분 방정식의 해가 되는 복소 지수 함수로 구성되어 있다는 가정하에서 출발하고 있다. 이러한 가정들은 신호 및 시스템의 특성이 시간에 따라 변하지 않는 통계적 파라미터를 가지는 모델들에 대해서는 충분한 정당성을 인정받으며 많은 응용분야에서 사용되어져 왔다.

그러나 생체를 그 근원으로 하여 얻어지는 신호들은 때

때로 이러한 가정들이 잘못지 않으며, 관례적인 신호처리 기법의 사용은 부적절한 결과를 가져온다.

근육의 활동을 중계하는 한 방편으로 오래전부터 사용되어져온 근전도(electromyogram) 신호는 근육내의 생리학적 발생기전 및 외부 조건적 변화요인 등에의하여 시간에 따라 통계적 특성들이 변화하는 시변 비정상성(time-varying nonstationarity)을 갖는 생체 신호중의 하나이다. 그러므로 이러한 특성을 나타내며 구성되는 근전도 시계열(time-series)을 정확히 분석하여 인식(identification)하기 위해서는, 소프트웨어 혹은 하드웨어적인 면에 있어서, 새로운 방법론이 요구된다. 최근 들어 비정상 근전도 신호를 분석하여, 장애자의 기능을 전기 자극으로 제어하

서울시립대학교 전자공학과

Dept. of Electronics Eng., Seoul City Univ.

이 논문은 1994년도 한국학술진흥재단의 공모 과제 연구비에 의하여 연구되었음.

통신저자: 이진, (130-743) 동대문구 전농동 8-3, Tel. (02) 210-2318, Fax. (02) 249-6802

려는 시도¹⁾ 및 이를 통해 여러 가지 임상적으로 유용한 자료, 운동단위 활동전위 (motor unit action potential), 근피로도, 신경 전도속도 등을 추출하여 실제 진단 자료로 활용하고자 하는 의도 등에서 비정상 근신호인식 알고리즘에 대한 연구가^{2,3)} 활발히 진행되고 있다.

특히 근피로도의 측정을 정량화 하고자 하는 연구는 여러 연구자들에 의해 계속되어져 오고있다. L. Lindstrom⁴⁾, P. A. Lynn⁵⁾, C. J. De Luca⁶⁾ 등의 연구자들은 dip 해석법, 영점 교차 (zero-crossing) 해석법, 주파수 해석법들을 이용한 근피로도 측정방법을 제안하였으나, 이들 모두는 정상성의 가정 하에서 출발한 알고리즘의 적용으로 인하여 근전도 신호의 스펙트럼이 시간에 따라 불규칙하게 변할 때에는 여러 가지 문제점을 유발시키는 것으로 평가되고 있다. 근래에 R. F. Inbar⁷⁾는 시간을 한정하여 짧은 주기 (0.64초) 동안에 표면전극 (surface electrode)으로 수집한 근전도 신호를 부분적으로 정상 (piecewise stationary)이라고 가정하고 자기회귀 (autoregressive) 모델링한 다음 파라미터들을 추정하여 그중 첫번째 시불변 자기회귀 파라미터인 a_1 을 근육의 피로도 측정에 응용하였다. 그러나 이 연구는 off-line의 일괄처리 (batch processing) 방식으로 실제로 임상에서의 실시간 (real time) 근피로도 측정에 사용될 수 없으며, 근본적인 문제로 표면전극으로부터 얻어진 근전도 신호의 타당한 자기회귀 모델은 시간에 따라 변하게 되며 각각의 모델 파라미터들은 시변 특성을 가지며 매 샘플 단위로 변하게 된다.

따라서 본 연구에서는 비정상 시변 근전도 신호 인식 알고리즘과 이의 실시간 처리가 가능한 병렬 처리 컴퓨터를 기본으로하는 하드웨어 시스템으로의 구현을 통해서 새로운 비정상 근신호 인식기를 구성 하였으며, 이를 통해 추출된 시변 자기회귀 모델 파라미터를 이용하여 실시간으로 근 피로도를 측정 할수 있는 방법을 제안하였다. 제안된 방법은 상태 공간에서 시변 파라미터를 갖는 근전도 신호의 선형 자기회귀 모델을 구성하고, 칼만 필터 (Kalman filter) 알고리즘을 응용하여 모델 파라미터들을 매 샘플 단위로 추정 할수있도록 고안한 다음, 추정된 자기회귀 파라미터의 변화 특성을 정량화하여 근 피로도를 측정할수 있는 새로운 시도로 이루어졌으며, 이를 T805 병렬처리 컴퓨터를 이용하여 실시간 비정상 근신호 인식기로 구현하였다. 또한, 통계적 검증법인 Run 테스트를 이용하여 실제 근전도 신호의 비정상성을 입증하였고, 타 연구자의 연구 결과와 파라미터 인식능력을 비교하여 비정상 근신호 인식기의 성능을 평가하였으며, 관례적인 주파수 해석법을 통한 파워 스펙트럼 (power spectrum)의 변

화 추세와, 자기회귀 모델 파라미터의 변화 추세를 비교, 검토함으로써 제시된 근피로도 측정 방법의 타당성을 입증 하였다.

상태 공간에서의 근전도 신호인식

비정상성을 갖는 근전도 신호는 다음과 같이 시변 파라미터들을 포함하는 자기회귀 모델로 나타낼 수 있다.

$$u(n) = -\sum_{k=0}^M a_k(n)u(n-k) + e_0(n) \quad (1)$$

여기서 $u(n)$ 은 근전도 신호

$a_k(n)$ 은 시변 자기회귀 파라미터

$e_0(n)$ 은 평균=0, 분산= σ^2 인

정상 잡음 (stationary noise) 프로세스

M 은 모델차수를 각각 나타낸다.

윗식에서 이산시간 (discrete time) n 에 대한 모델 파라미터들의 변화가 전체 프로세스의 동적 특성을 좌우하게 된다. 또한 식 (1)은 다음과 같이 상태 공간 방정식 (state-space equation) 형태로 바꿔 쓸 수 있다.

$$u(n) = \mathbf{u}^T(n-1)\boldsymbol{\omega}_0(n) + e_0(n) \quad (2)$$

여기서 $M \times 1$ 벡터인 $u(n-1)$ 은 $u(n-1), \dots, u(n-M)$ 을 구성요소로 갖는 측정 행렬 (measurement matrix)이고, $\boldsymbol{\omega}_0(n)$ 은 상태 벡터 (state vector)로써

$$\boldsymbol{\omega}_{0k}(n) = -a_k(n) \quad k=1, 2, \dots, M \text{ 이다.}$$

그러므로 식 (2)는 선형동적 (linear dynamic) 자기회귀 모델의 측정 방정식 (measurement equation)이 된다. 이로부터 상태 벡터인 $\boldsymbol{\omega}_0(n)$ 은 다음과 같은 임의 보행 (random walk)⁸⁾ 모델로 나타낼 수 있다.

$$\boldsymbol{\omega}_0(n+1) = \boldsymbol{\omega}_0(n) + \mathbf{v}(n) \quad (3)$$

여기서 $\mathbf{v}(n)$ 은 평균=0을 갖는 정상 잡음 프로세스이고, 상관행렬 (correlation matrix)은 단위행렬 (identity matrix) I 가 된다. 또한 $\{e_0(n)\}$ 과 $\{\mathbf{v}(n)\}$ 은 서로 직교 (orthogonal) 하며 통계적으로 독립인 성질을 갖는다.

다음으로 상태 방정식인 식 (3)을 회귀적 (recursive)으로 풀기위한 과정은 칼만 필터 알고리즘을 응용하면 식 (4) - 식 (8)과 같다.

$$G(n) = K(n, n-1)u(n-1) [u^H(n-1)K(n, n-1)u(n-1) + \sigma^2]^{-1} \quad (4)$$

$$\alpha(n) = u(n) - u^T(n-1)\hat{\omega}(n-1) \quad (5)$$

$$\hat{\omega}(n) = \hat{\omega}(n-1) + G(n)\alpha(n) \quad (6)$$

$$K(n) = K(n, n-1) - G(n)u^H(n-1)K(n, n-1) \quad (7)$$

$$K(n+1, n) = K(n) + qI \quad (8)$$

여기서 $G(n)$ 은 샘플타임 n 에서의 칼만 이득
 $\alpha(n)$ 은 샘플타임 n 에서의 innovation 벡터
 $K(n)$ 은 샘플타임 n 에서의 error의 상관행렬 (correlation matrix)을 각각 나타낸다.

본 연구에서는 이와같이 상태 공간에서의 근신호 인식을 그림 1의 흐름도와 같이 병렬로 수행하여 시변 파라미터를 가지는 근전도 신호모델의 계수들을 매샘플단위로 적응적으로 추정하였다.

실시간 처리 시스템 구성

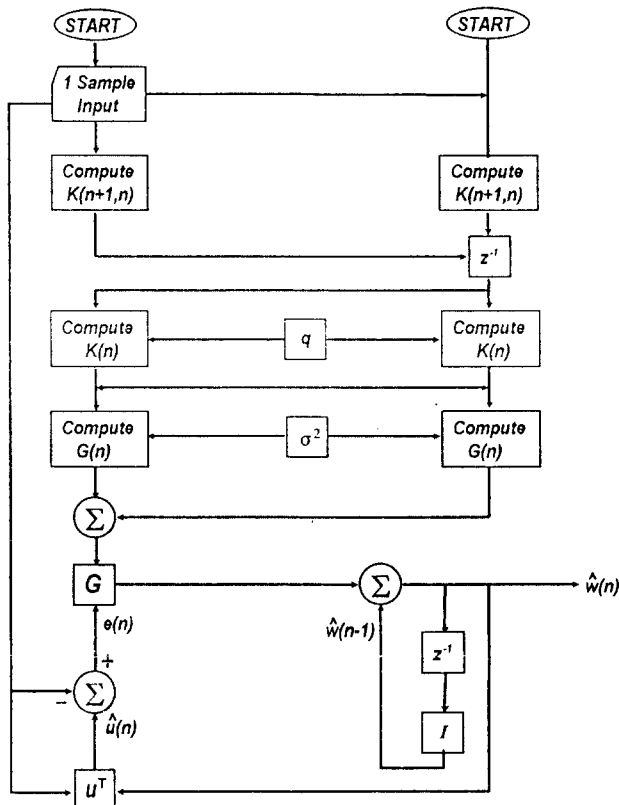


그림 1. 비정상 근신호 인식기의 병렬 처리 소프트웨어 흐름도
 Fig. 1. Parallel processing software flowchart of nonstationary EMG identifier

마이크로 프로세서를 이용하여 신호 처리 알고리즘을 실시간으로 처리 하고자 할때, 가장 큰 영향을 주는 것은 연산에 요구되는 곱셈의 량이다. 상태 공간에서의 신호 인식 알고리즘을 수행하기 위해서 필요한 곱셈의 연산량은 식(4)~(8)의 행렬 연산으로부터 다음과 같이 구할수 있다. 만약, 근전도 신호 인식기의 차수가 M 이라고 가정하면, 식(4)와 (5)로부터 각각 M^2 의 연산이 필요하고, 식(6)에서 $3M^2$ 의 연산이 필요하다. 그리고 식(7)의 연산은 식(6)의 연산 결과를 이용할 수 있으므로 곱셈 연산을 필요로하지 않는다. 그러므로 곱셈에대한 전체 연산량은 식(9)와 같이 나타낼 수 있다.

$$\text{전체연산량 } O_c = 5M^2 \quad (9)$$

식(9)의 연산량에 대한 식으로부터 전체 연산량은 차수가 증가할 때마다 차수의 제곱에 비례해 기하 급수적으로 증가함을 알수 있다. 그러므로 본 연구에서 제시한 비정상 근신호 인식기의 실시간 처리 시스템으로의 구현시 발생하는 연산량을 매 샘플 단위로 처리하기 위해서는 많은 연산 시간이 필요하므로, 실시간 처리가 어렵거나, 실시간으로 처리하기 위해서는 고속 연산이 가능한 마이크로 프로세서를 사용하여야 한다. 그러나 실시간 구현을 위해 사용하는 고속 연산 전용 마이크로 프로세서는 신호 인식기의 차수에 의존하는 연산시간을 갖고 있기 때문에 시스템의 구성상 유연성이 떨어지며, 가격또한 연산 속도에 비례하여 고가인 것이 결점이다. 그러므로 본 연구에서는 연산을 수개의 프로세서가 각각 동시에 독립적으로 연산을 처리할 수 있는 병렬 처리 컴퓨터를 이용하여 실시간으로 구현하였다.

일반적인 병렬 처리 시스템에서 N 개의 병렬 처리 프로세서를 갖추고 있다고 해서 프로세서가 1개일 때의 성능에 비하여 N 배의 성능향상을 보이는 것은 아니다¹²⁾. 왜냐하면 수개의 병렬 처리 프로세서를 사용할 때마다 각 프로세서간의 데이터 또는 파라미터의 통신에 소요되는 시간으로 인해 프로세서의 수에 따라 선형적으로 연산속도가 증가하는 것을 방해하기 때문이다.

본 연구에서는 프로세서간의 채널 통신망의 구조나, 수치적인 정밀성 및 처리 속도를 고려하여 INMOS 사의 IMS T805 병렬처리 컴퓨터를 사용하여 근피로도 측정을 위한 비정상 근신호 인식기의 실시간 처리를 수행하였다. 그림 2는 본 연구에서 제안된 실시간 비정상 근신호 인식기의 하드웨어 블록 선도이다.

IMS T805 병렬처리 컴퓨터는 64 비트 부동 소수점(64




그림 2. 비정상 근신호 인식기의 하드웨어 블록 선도
 Fig. 2. Hardware block diagram of proposed nonstationary EMG signal identifier

bit floating point) 연산부와 고속 연산 처리를 위한 4킬로 바이트의 내부 RAM, 그리고 각 프로세서 채널간의 통신이 가능한 4개의 INMOS 표준 통신 링크를 갖고 있으며, 단일 프로세서나 수개의 프로세서군과 이들 사이의 채널 통신을 이용하여 병렬 처리가 가능하도록 하였다. 그리고 각각의 단위 연산(unit operation)에서 곱셈이나, 나눗셈 연산을 1회 수행시는 440nsec, 덧셈 연산을 1회 수행 할때에는 220nsec의 연산 시간이 필요하며, 만약 2개 이상의 프로세서가 병렬로 연결되었을 경우에는 두 프로세서간의 데이터나 파라미터를 교환하는 통신 시간을 필요로 한다¹²⁾. 그림 2에서 볼수있는 바와같이 각각의 T805 프로세서 모듈들에 대해 데이터를 분배하여 연산을 수행한 다음 그 결과를 다시 채널 링커를 통하여 각 프로세서 모듈에 재분배 하였고, 식 (4)-(8)의 연산식들은 모두 행렬식으로 연산이 행해지기때문에 반복적인 연산 메커니즘을 합수화하여 처리함으로써 효율적인 연산이 수행되도록 하였으며, 프로세서간의 채널 통신에서 대기 상태가 없도록 연산량을 분배함으로써 양쪽 T805 프로세서에서 동일한 연산량이 수행되도록 하여 실시간 처리가 가능하도록 하였다.

실험 및 결과 고찰

본 연구에서는 정상인 피검자를 대상으로 실제 근전도 신호를 수집하여 다음과 같이 두 부분에 중점을 두고 실험하였다.

첫째, 수집된 근전도 신호의 비정상성을 통계적 방법을 통해 입증하고, 이로부터 비정상 시변 자기회귀 파라미터 추정 능력을 타 연구자의 방법과 비교, 검토함으로써 본 연구의 근전도 신호 인식기가 우




그림 3. 실제 근전도 신호 (file: LJ, 이두박근)
 Fig. 3. Raw EMG signal (file: LJ, biceps muscle)

월함을 입증하였고,

둘째, 새롭게 제안된 방법인 실시간 근피로도 측정실험을 통해 그실용성에 대한 예를 기존의 방법과 비교하여 제시하였다.

이를 위해서 피검자 3인(LJ, JCW, SKW)으로부터 근전도 표면 전극(3M 2237)을 이두박근(biceps muscle) 혹은 교근(masseter muscle)에 부착, 고정시키고 1분 동안 최대 수축력(100% MVC : maximal voluntary contraction)으로 가능한한 유지시키며 샘플링 주파수를 이두박근의 경우 512Hz와 교근의 경우 1024Hz로 하여 근전도 신호를 수집하였다. 이때, 샘플링 주파수를 달리한 이유는 타 연구자와의 직접적인 비교를 하기 위함과 실제 근육에따른 근전도 신호의 주파수 대역에 따른 것이다^{3,4)}

그림 3은 정상인의 이두박근으로부터 2초 동안 수집한 실제 근전도 신호를 나타내고 있다

신호의 통계적 특성을 이용하여 비정상성을 검증하는 방법은 Bendat와 Piersal⁹⁾에 의해 제안되었으며, 그 방법은 원래 신호 $u(n)$ 을 N개의 등간격으로 나눈 다음 각 간격에서 데이터의 평균, 편차, 분산을 구해서 Run 테스트를 수행하고 이로부터 유의수준(level of significance)을 이용하여 대상 신호의 상태를 검사하는 것이다.

표 1에 그림 3의 근전도 신호를 32블럭으로 나누어 계산한 각 블럭의 통계값들을 나타내었다.

표 1의 자료를 가지고 Run 테스트를 수행한 결과 Run 수가 6이며, 이는 안정성 범위의 임계하한값 $r_{n,1-\alpha/2} = 10$ 와 임계 상한값 $r_{n,\alpha/2} = 22$ 사이에 존재치 않으므로 비정상성이 검증된다. 여기서는 유의수준으로 0.05로 하였고 n은 구간의 갯수이며 임계값 r은 Run 분포표⁹⁾에 의해 구해

표 1. 근전도 신호의 각 구간별 통계값 (32 블럭별 평균과 표준편차: 32샘플/1블럭, file: LJ, 이두박근)

Table 1. Interval statistical value of EMG signal (mean and standard deviation of 32 block: 32 samples/block, file: LJ, biceps muscle)

| 통계값 블럭 | 평균 | 표준편차 | 통계값 블럭 | 평균 | 표준편차 |
|-----------|--------|-------|-----------|--------|-------|
| 1 | -0.006 | 0.359 | 17 | -0.043 | 0.536 |
| 2 | -0.010 | 0.484 | 18 | 0.028 | 0.556 |
| 3 | 0.041 | 0.406 | 19 | -0.011 | 0.720 |
| 4 | -0.036 | 0.453 | 20 | 0.009 | 0.789 |
| 5 | 0.025 | 0.415 | 21 | -0.024 | 0.512 |
| 6 | -0.056 | 0.509 | 22 | 0.016 | 0.512 |
| 7 | 0.033 | 0.453 | 23 | -0.026 | 0.492 |
| 8 | -0.034 | 0.455 | 24 | 0.023 | 0.458 |
| 9 | 0.035 | 0.475 | 25 | 0.017 | 0.570 |
| 10 | -0.034 | 0.442 | 26 | 0.027 | 0.598 |
| 11 | 0.011 | 0.551 | 27 | -0.069 | 0.530 |
| 12 | 0.002 | 0.592 | 28 | 0.003 | 0.425 |
| 13 | 0.039 | 0.717 | 29 | 0.006 | 0.492 |
| 14 | -0.037 | 0.673 | 30 | -0.016 | 0.423 |
| 15 | 0.007 | 0.644 | 31 | -0.010 | 0.360 |
| 16 | 0.011 | 0.408 | 32 | 0.034 | 0.459 |

진다. 그러므로 이 검증을 통하여 근전도 신호는 비정상성을 갖는다는 것을 알 수 있으며 Inbar³⁾의 정상성의 가정은 타당치 않음을 입증할 수 있다. 다음으로 그림 3의 이두박근으로부터 수집한 근전도 신호에 대해서 모델 차수를 4차로 하여 자기회귀 파라미터를 추정한 결과를 1초 간격으로 표시하여 그림 4에 나타내었다. 근전도 신호의 자기회귀 모델 차수는 일반적으로 근전도 패턴 인식, 근피로도 해석 및 하반신 마비자를 위한 전기자극 기능제어 등의 연구들에서 4차가 적절하다는 연구결과^{1, 10, 11)}가 알려져 있으며 본 연구에서도 차수를 달리하여 여러 번 실험해 이를 확인할 수 있었다.

그림 4에 나타낸 바와같이 본 연구에서 제시한 실시간 근피로도 측정을 위해서 $a_1(n)$ 부터 $a_4(n)$ 까지 파라미터를 추정하여 분석 해본결과 $a_1(n)$ 파라미터만이 일관성을 가지고 감소 하였으며 나머지 파라미터들의 변화 추세는 임의적이었다. 또한 모델 차수의 변화에 따른 $a_1(n)$ 파라미터 변화의 기울기 차이도 거의 없음을 확인하였다. 다음으로 그림 5에 $a_1(n)$ 파라미터 추정결과를 타 연구자의 결과와 비교하여 나타내었다.

그림 5(a)는 제시한 방법이 근전도 신호의 비정상성을 쫓아가며 매샘플마다 자기회귀 파라미터를 적응적으로 추정하는 반면, 256샘플의 블럭 데이터를 가지고 자기 상




그림 4. $a_1(n) - a_4(n)$ 파라미터 추정 결과
(a) $a_1(n)$ (b) $a_2(n)$ (c) $a_3(n)$ (d) $a_4(n)$
Fig. 4. $a_1(n) - a_4(n)$ parameter estimation results
(a) $a_1(n)$ (b) $a_2(n)$ (c) $a_3(n)$ (d) $a_4(n)$




그림 5. AR 모델 파라미터 추정 결과(file: LJ, 이두박근)
(a) 본 연구의 방법으로 추정된 $a_1(n)$ 계수
(b) Inbar의 방법(3)으로 추정된 $a_1(n)$ 계수
Fig. 5. Estimation result of AR model parameters(file: LJ, biceps muscle)
(a) $a_1(n)$ parameter estimated by proposed method
(b) $a_1(n)$ parameter estimated by Inbar's method (3)

관계수방법으로 선형 예측 (Linear prediction)한 그림 5(b)의 결과는 시간에 따른 신호의 비정상성향을 전혀 추정할 수 없음을 보여주고 있다.

그림 6은 이두박근으로부터의 근전도 신호에 대해서 매 샘플 단위로 자기회귀 파라미터를 추정하여, 1초의 시간




그림 6. 추정된 파라미터의 순시값과 평균값 (file: LJ, 이두박근)
(a) 매 초 마다의 $a_1(n)$ 파라미터
(b) 1초 블록의 평균 $a_1(n)$ 파라미터
Fig. 6. Instantaneous and mean value of the estimated parameter (file: LJ, biceps muscle)
(a) $a_1(n)$ parameter showed by every second
(b) $a_1(n)$ parameter showed by average value during 1 second




그림 8. 근 피로도 측정결과 (file: SKWM, 교근)
(a) 본 연구에서 제시된 방법으로 측정된 근 피로도
(b) Luca의 방법(6)으로 측정된 중간 주파수 변화에 의한 근 피로도
Fig. 8. Muscle fatigue monitoring results (file: SKWM, masseter muscle)
(a) Muscle fatigue monitoring by using proposed method
(b) Muscle fatigue monitoring by using Luca's method based on median frequency change

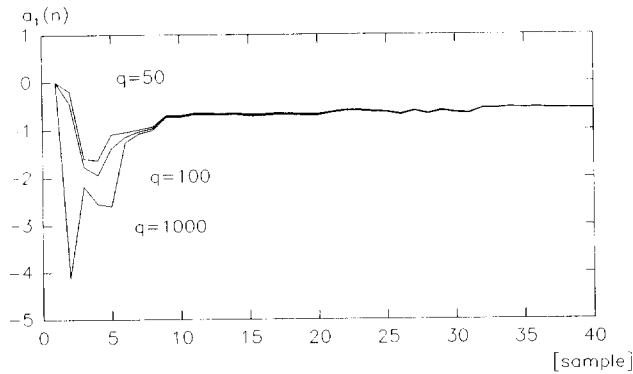


그림 7. 초기조건의 변화에 따른 파라미터 $a_1(n)$ 의 수렴특성
Fig. 7. Convergence characteristics of parameter $a_1(n)$ to various initial conditions

간격으로 $a_1(n)$ 파라미터를 표시한 결과와 1초 블록 내의 512개 파라미터들의 평균을 구하여 표시한 결과를 각각 나타내었다.

이 결과는 제시한 근전도 신호 인식기가 신호 모델의 전체적인 특성을 그대로 반영하는 동시에 60초 동안 매 샘플타임에서의 시변 모델 파라미터를 정확히 추정하는 능력을 보여주는 것으로 실시간 처리 가능성 및 알고리즘의 수치적 안정성을 입증하는 것이다.

다음으로 시변 비정상 근신호 인식기의 초기값으로 입력해 주어야 하는 잠음벡터 $v(n)$ 의 분산 q 의 변화에 따른 파라미터 수렴특성을 그림 7에 나타내었다.

식 (3)의 임의 보행 모델에서 $v(n)$ 의 잠음 분산 값은 수

렴성을 보장하기 위해 적절한 초기 값의 선택이 필요하며, 그 값을 50~1000으로 주었을 때 초기 요동과 수렴속도에서 약간의 차이를 보이며 정상적으로 동작함을 알 수 있으며, 세 경우 모두 10샘플 이내에 수렴하는 빠른 수렴속도를 나타내고 있다.

근육의 활동을 나타내는 한 방편으로 근전도 분석은 오래 전부터 이용되어 왔으며, 근육의 수축이 지속적으로 일어나면 그 부위의 피로를 유발시킨다는 연구가 알려져 있다. 생리학적으로는 근육내의 H^+ 이온의 방출에 의해서 체내에 젖산(lactic acid)이 축적되며 이에 따라 근섬유(muscle fiber)의 전도 속도가 감소되고 운동단위 활동전위(MUAP)의 발생주기가 점점 느려지는 현상이다⁶⁾.

본 연구에서는 자기회귀 모델 파라미터, 특히 비정상 근신호에 대한 시변 $a_1(n)$ 계수를 이용하여 실시간으로 근 피로도를 측정할 수 있는 새로운 방법을 제시하였고, 또한 이를 주파수 해석법⁶⁾과 비교 검토하였다.

그림 8에 (a)는 피검자 SKW의 교근 으로부터 1분간 100% MVC를 유지시키며 수집한 근전도 신호로부터, 비정상 시변 근신호 인식기로 측정된 $a_1(n)$ 파라미터를 표시하였으며 (b)는 주파수 해석법을 통해 1초간 블록 데이터의 중간 주파수(median frequency)를 계산하여 나타낸 결과이다.

비정상 근전도 신호 모델의 시변 파라미터들 중 특히 가중치가 큰 모델 파라미터인 $a_1(n)$ 값은 근피로에 따라 약 -0.59 에서 -1.33 로 떨어져 약 -18.2° 의 기울기를 가

표 2. 프로세서 수에 따른 연산시간 비교

Table 2. Comparison of processing time to used processors

| 프로세서 | T805 병렬컴퓨터 (프로세서 1) | T805 병렬컴퓨터 (프로세서 2) |
|----------|------------------------|------------------------|
| 연산시간 | | |
| 실제 처리시간 | 0.993 msec | 0.894 msec |
| 추정한 연산시간 | 0.905 msec | 0.602 msec |




그림 9. AR 모델 파워 스펙트럼 추정 결과(file:SKWM 교근)
Fig. 9. Estimation result of AR model power spectrum (file: SKWM, masseter muscle)

지고 변화함을 알 수 있으며, 이는 블럭별 중간 주파수가 204Hz에서 48Hz로 떨어져 약 -16.9° 의 기울기로 변화하는 (b)의 결과와 그 추세가 일치한다. 또한 지금까지 가장 널리 사용되는 방법인 주파수해석법의 단점인 블럭 데이터의 FFT(fast fourier transform)를 계산하는데 소요되는 처리속도 문제에 대한 해결책을 제시해준다.

표 2는 동일한 데이터를 대상으로 병렬 처리 컴퓨터를 통해 수행한 연산시간 결과를 나타내었다.

1024Hz의 근전도 신호를 실시간으로 처리 하기 위해서는 한 샘플의 연산을 0.976ms이내에 처리 하여야함으로 1 개의 T805 프로세서를 사용했을 경우에는 제안된 방법의 실시간 처리가 불가능함을 알수있으며, 2개의 T805 프로세서로서 구성된 본 연구의 비정상 근신호 인식기는 894ms/sample의 연산속도를 보여 실시간 처리능력을 입증하고 있다. 또한 추정한 연산 시간을 통해 각 프로세서 사이의 데이터 및 파라미터 교환, 그리고 프로세서 내부의 제어신호 교환 등으로 인하여 0.29ms의 시간이 소비되었음을 알수있다.

다음 그림 9는 위에서 구한 모델 파라미터들을 가지고 모델 파워 스펙트럼(model power spectrum) 추정 알고리

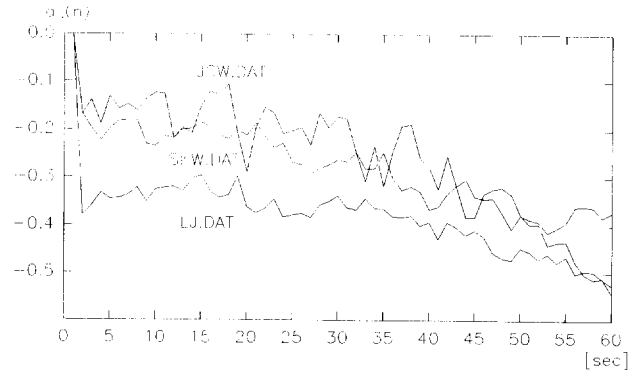


그림 10. 피검자 3인의 근피로도 측정 결과(이두박근)
Fig. 10. Muscle fatigue monitoring for the three subject(biceps muscle)

즘¹¹⁾을 이용하여 구한 각 블럭의 3차원 파워 스펙트럼을 표시한 것이다.

시간이 지남에 따른 근육의 피로도를 반영하여 주파수 분포가 저주파대역으로 떨어지는 현상을 볼수 있으며, 이는 본 연구에서 제시한 근전도 신호 인식기가 시간에 따라 변화하는 시변 모델 파라미터를 추정함을 보여주고있다.

다음은 제시한 근피로도 측정방법의 객관성을 입증하기 위해서 피검자 3인을 대상으로 동일한 실험조건으로 이두박근에서 수집한 근전도 신호로부터 측정된 근피로도 결과를 그림 10에 나타내었다.

각 개인의 근육의 활성도에 따라, JCW의 경우 파라미터 값이 -0.17 에서 -0.54 로 변하여 그 기울기가 약 -14.1° 이며, SKW는 -0.17 에서 -0.37 로 변하여 그 기울기가 약 -10.9° 이고, LJ의 경우는 -0.38 에서 -0.53 으로의 변화와 약 -8.3° 의 기울기를 나타내며 피검자 JCW가 타인에 비하여 약간의 근피로도를 더 가져옴을 알수 있다. 또한 앞에서의 실험 결과와 비교해보면 교근의 경우는 기울기가 약 -16° 이상으로 이두박근의 경우보다 빠른 근 피로도를 갖는 것으로 볼수있다.

결 론

본 연구에서는 시변 특성을 갖는 근전도 신호의 인식을 위한 비정상 신호처리 알고리즘과 이의 실시간 처리 하드웨어 시스템을 구현함으로써 새로운 실시간 비정상 근전도 신호 인식기를 제안하였다. 제안된 방법의 타당성은 세명의 정상인 피검자를 대상으로 하여 실제 근전도 신호를 수집하여 타연구자의 결과와 비교, 검토함으로써 실험

을 통해 입증 하였으며, 이를 바탕으로 근 피로도 측정에 응용함으로써 새로운 실용예를 보여 주었다. 그리고 통계적 검증법을 통하여 근전도 신호의 비정상성을 입증 하므로써 비정상 신호 인식기의 적응적인 파라미터 추정능력의 필요성을 언급하였다.

또한, 새롭게 제시한 실시간 근피로도 측정 방법인 자기회귀 파라미터 $a_i(n)$ 의 변화 추세를 관례적인 주파수 해석법을 통한 중간 주파수의 변화추세와 비교, 평가함으로써 이의 타당성을 입증하였다.

본 연구는 그밖에도 시간에 따라 변하는 뇌파신호의 분석, 지진파의 해석, 원자로의 중성자 잡음 측정을 통한 안전진단, 기계고장의 예측, 전력선로의 부하 예측 등에 부분적으로 정상이란 가정 하에 제시된 알고리즘들을 대신하여 유용하게 사용될 수 있으리라고 사료된다.

참 고 문 헌

1. A. T. Moser, D. Groupe, "Identification of nonstationary models with application to myoelectric signals for controlling electrical stimulation of paraplegics", IEEE Trans., ASSP, Vol. 37, No. 5, pp. 713-719, 1989.
2. K. B. Englehart, P. A. Parker, "Single motor unit myoelectric signal analysis with nonstationary data", IEEE Trans., BME, Vol. 41, No. 2, pp. 168-179, 1994.
3. O. Paiss, G. F. Inbar, "Autoregressive modeling of surface EMG and its spectrum with application to fatigue", IEEE Trans., BME, Vol. 34, No. 10, pp. 761-770, 1987.
4. L. Lindstrom, R. Magnusson and I. Petersen, "Muscular fatigue and action potential conduction velocity changes studies with frequency analysis of EMG signal", Electromyography, Vol. 10, pp. 341-356, 1970.
5. P. A. Lynn, "Direct on-line estimation of muscle fiber conduction velocity by surface electromyography", IEEE Trans., BME, Vol. 26, pp. 564-571, 1979.
6. F. B. Stulen, C. J. De Luca, "Frequency parameter of the myoelectric signal as a measure of muscle conduction velocity", IEEE Trans., BME, Vol. 28, pp. 515-523, 1981.
7. G. Kitagawa, W. Gresch, "A smoothness priors time varying AR coefficient modeling of nonstationary covariance time series.", IEEE Trans., Automat. contr., Vol. AC-30, pp. 48-56, 1985.
8. A. Papoulis, Probability random variables and stochastic processes, 2nd Ed., New York, McGraw-Hill, 1984.
9. J. S. Bendat, A. Piersol, Measurement and analysis of random data, New York, Wiley, 1966.
10. M. Maranzana-Figini, R. Molinari, and G. Sommariva, "The parametrization of the electromyographic signal: An approach based on simulated EMG signals", Electromyogr. clin. Neurophysiol., Vol. 24, pp. 47-65, 1984.
11. D. Graupe, Time series analysis, Florida, R. E. Krieger, 1984.
12. The Transputer data book, 2nd Ed., INMOS, chap. 4, 1989.