

2축 가속도 신호와 Extreme Learning Machine을 사용한 행동패턴 분석 알고리즘

論 文
56-7-25

The Analysis of Living Daily Activities by Interpreting Bi-Directional Accelerometer Signals with Extreme Learning Machine

申 侑 植* · 李 榮 範* · 李 明 鎬†
(Hang-Sik Shin · Young-Bum Lee · Myoungho Lee)

Abstract - In this paper, we propose pattern recognition algorithm for activities of daily living by adopting extreme learning machine based on single layer feedforward networks(SLFNs) to the signal from bidirectional accelerometer. For activity classification, 20 persons are participated and we acquire 6-types of signals at standing, walking, running, sitting, lying, and falling. Then, we design input vector using reduced model for ELM input. In ELM classification results, we can find accuracy change by increasing the number of hidden neurons. As a result, we find the accuracy is increased by increasing the number of hidden neuron. ELM is able to classify more than 80 % accuracy for experimental data set when the number of hidden is more than 20.

Key Words : Extreme Learning Machine, Activity of Daily Living, Accelerometer

1. 서 론

인체의 운동량을 객관적으로 측정하기 위한 연구는 운동 부족으로 인한 현대 사회의 만성 질환들의 관리와 관계되어 최근 활발히 연구되고 있다[1]. 기존의 연구에서는 관찰자의 직접적인 관찰을 통하여 운동량을 측정하는 방법을 주로 사용해 왔으나 근래에 이르러는 가속도센서(accelerometer)를 사용하여 인체의 움직임을 측정하는 방법에 대한 연구가 다수 수행되고 있다[2]. 가속도 센서를 이용하여 움직임을 측정하는 초기의 연구는 단방향(unidirectional) 가속도 센서를 이용하여 정적상태와 동적 상태를 구분해내는 연구에서 시작하였으나[3] 센서 기술과 신호처리 기술의 발달로 자세 모니터링(posture monitoring)과 일반적인 활동상태를 의미하는 ADL(Activity of Daily Living) 분석까지 그 범위를 넓혀가고 있다[4,5]. 또한 실버계층을 위한 낙상감지(fall detection)에 대한 연구도 가속도 센서를 이용하여 활발하게 수행되고있다[6,7]. 최근의 연구에서는 다양한 행동패턴을 분석하기 위하여 단방향 가속도 센서보다는 2축이나 3축을 사용한 다축 가속도 센서가 주로 사용되고 있으며 사용의 편의성 및 다양한 기능의 추가를 목적으로 하는 smart wearable 센서 또한 가속도 센서의 응용 연구분야로 자리잡아가고 있다[8].

본 논문에서는 Extreme Learning Machine(ELM)을 사용하여 서기, 걷기, 뛰기, 앉기, 넘어지기 등의 일반적인 활동 상태 및 자세에 대하여 분류를 수행하였다. ELM은 기존의

은닉층의 파라미터가 트레이닝 데이터와 완벽히 독립적인 단일계층-피드포워드 네트워크(Single Layer Feedforward Networks, SLFNs)으로 다양한 활동함수(activation function)를 적용할 수 있고 단일 은닉계층을 사용하므로 기존의 신경회로망(Neural Network, NN)보다 처리속도가 빠르다는 장점을 가지고 있다[9]. 본 논문에서는 2축 가속도 센서에서 획득한 x, y축에 대한 신호를 모델링하여 입력벡터를 생성하고 ELM연산을 수행하여 각 동작 및 활동상태를 분류해 내었다.

2. 본 론

본 연구는 먼저 개발된 2축 가속도 센서와 무선 통신 모듈을 이용하여 피험자로부터 각각의 활동신호를 측정해 내고 측정된 신호를 각 활동 상태에 따라 분류한 후 ELM을 적용하여 활동 상태를 분류해내는 과정을 거쳐 수행되었다. 각각의 단계에 해당하는 내용은 다음과 같다.

2.1 Bidirectional Accelerometer

가속도 신호의 측정을 위해서 analog device사의 ADXL202를 사용한 가속도 신호 측정 모듈을 개발 하였다.

2.1.1 Specification

실험에 사용된 가속도 센서의 성능 사양은 표 1과 같다. 실시간 데이터 획득을 위해서 가속도 센서와 무선 통신 모듈을 구현하여 실시간 가속도 신호 측정이 가능하도록 설계하였다.

무선 통신 모듈은 크기와 통신 속도를 고려하여 2.4GHz의 통신 주파수를 가지는 Nordic사의 nRF2401을 사용하여 구현 하였다.

* 正 會 員 : 延世大學教 電氣電子工學科 博士課程
† 교신저자, 正會員 : 延世大學教 工大 電氣電子工學科
正教授 · 工博

E-mail : mhlee@yonsei.ac.kr

接受日字 : 2006年 12月 29日

最終完了 : 2007年 4月 23日

표 1 가속도 센서 ADXL202의 특성

Table 1 Specifications of accelerometer sensor ADXL202

항목	사양
신호출력	PWM(Pulse Width Modulation)
대역폭 (kHz)	6 kHz
전원입력 (V)	3 to 5.25 V
범위	+/- 2 g
민감도	12.5 %/g
축의 수	2
정확도 (%)	±16
작동온도	-40 to 85°C
패키지	E-8
노이즈밀도 (ug/rHz)	200

2.1.2 Appearance

개발된 무선 가속도 측정 모듈의 외형은 그림 1과 같다. 측정모듈은 대략 7.5 cm x 2.5 cm x 0.7 cm(Width x Height x Depth)의 크기를 가지며 휴대가 용이하도록 설계되었다.




그림 1 개발한 2축 가속도센서의 외형

Fig. 1 Appearance of bidirectional accelerometer

2.2 ELM(Extreme Learning Machine)

ELM 알고리즘은 \tilde{N} 개의 은닉뉴런(hidden neuron)을 가지는 single layer feed forward network(SLFNs)로 매우 빠른 학습속도를 구현해낸 알고리즘으로 수행 속도면이나 복잡성 등의 측면에서 기존의 신경회로망이나 SVM(Support Vector Machine)등에 비하여 우수한 성능을 가지는 것으로 알려져 있다[10].

2.2.1 Basic Concept of ELM

$x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 과 $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in R^m$ 일 때, N 개의 임의의 샘플 (x_i, t_i) 를 가정하면 \tilde{N} 개의 은닉뉴런(hidden neuron)을 가지는 일반적인 SLFN의 활성화함수(activation function) $g(x)$ 는 다음수식 1과 같이 모델링 된다.

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = t_j, \quad j = 1, \dots, N. \quad (1)$$

이 때, $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 는 i 번째 은닉 뉴런에 연결된 입력 뉴런(input neuron)에 주어지는 가중치벡터(weight vector)를 의미하고, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 는 은닉뉴런과 i 번째 출력뉴런(output neuron)간의 가중치 벡터를 의미한다. b_i 는 i 번째 뉴런의 임계치(threshold)를 의미한다. 식 1을 벡터형식으로 표현하면 다음 식 2와 같이 표현 할 수 있다.

$$H\beta = T \quad (2)$$

이 때,

$$H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_1 \cdot x_1 + b_1) \\ \vdots & \dots & \vdots \\ g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) & \dots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \end{bmatrix}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}$$

과 같다.

Huang[11]과 Huang, Babri[12]의 연구에서 H 는 신경회로망의 은닉층 출력행렬(hidden layer output matrix)로 명명되었는데 이 때 i 번째 행은 i 번째 은닉뉴런의 출력벡터로 정의되어진다.

2.2.2 Indication Matrix

2-클래스 분류의 경우 수식 3과 같이 threshold를 이용하여 패턴 분류를 수행하게 되는데 다-클래스 분류의 경우(multi-class classification problem) threshold를 사용하는 방법에는 한계가 존재한다. 따라서 다-클래스 분류에 있어서는 수식 4와 같은 지시행렬(indication matrix)를 사용하여 패턴 분류를 수행한다.

$$th(g) = \begin{cases} 0, & g < t \\ 1, & g \geq t \end{cases}, \quad g: interference \quad (3)$$

$$IND = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad (4)$$

2.3 Input Vector Design

ELM 알고리즘을 적용하여 행동분류를 수행하기 위해서는 획득한 가속도 신호를 이용하여 ELM에의 입력 패턴을 도출하여야한다. 본 논문에서는 ELM의 입력 패턴을 도출해 내기 위하여 1~10의 차수를 가지는 reduced model[13]을 사용하여 다양한 입력 패턴에 대한 에러율(error rate)를 계산한 뒤 가장 적합하다고 판단되는 입력 패턴을 결정하였다. 패턴 분류를 위해서 총 3개의 벡터를 입력 패턴으로 사용하였으며 사용된 입력 패턴은 다음과 같다.

2.3.1 Difference between x and y axis

x-dimension 에서 획득한 신호와 y-dimension 에서 획득한 신호의 절대 거리를 계산하는 것으로 수식 5와 같은 과정을 거쳐 입력 벡터를 산출해낸다. D_x 는 x-dimension의 입력 벡터를, D_y 는 y-dimension의 입력 벡터를 나타낸다.

$$I_1 = |D_x - D_y| \quad (5)$$

2.3.2 Total mean power of axes

x-dimension과 y-dimension에서 획득한 신호의 합에 대한 power를 계산함으로써 전체 움직임의 양적 정도를 구분하기 위한 것으로 수식 6과 같이 표현된다. N은 각 dimension의 입력벡터 크기를 나타낸다.

$$I_2 = \frac{\sqrt{(D_x - D_y)^2}}{N} \quad (6)$$

2.3.3 Time averaging

x-dimension과 y-dimension 벡터 component의 합을 구하고 time-averaging을 위한 값을 입력벡터로 설정하였다. 수식 7은 time averaging에 대한 수식을 표현한 것이다.

$$I_3 = \frac{1}{2N} \sum_{n=1}^N (D_{xn} + D_{yn}) \quad (7)$$

2.4 Evaluation Method

시뮬레이션을 통한 결과 검증을 위해서 측정된 데이터 셋에 대하여 4-fold cross validation method를 적용하였다 [14]. 4-fold cross validation 은 그림 2와 같이 주어진 dataset을 fold의 수만큼으로 분류하여 dataset 자체에서 알고리즘 검증을 수행하는 방법이다.



그림 2 4-fold cross validation 검증법
Fig. 2 Evaluation method using 4-fold cross validation

3. 실험

실험을 수행하는데 있어서 20명의 피험자를 대상으로 서기, 걷기, 뛰기, 앉기, 눕기, 넘어지기의 패턴에 대하여 5번씩 반복측정을 수행하여 총 120개의 데이터를 확보하였다. 이때 개발한 동작측정 모듈은 피험자의 우측 허리에 부착하여 실험을 수행하였으며 중력 방향을 x축, 피험자의 정면을 y축으로 고정하여 가속도 신호를 측정 하였다. 실험에 참가한 피험자들의 기본 정보는 표 2와 같다. 표 3에서는 가속도 신호를 이용하여 분류하기 위한 패턴들에 대한 실험 프로토콜을 나타내었다.

표 2 피험자의 기본적인 신체정보

Table 2 Basic information of subject

분류	평균	표준편차
나이 (세)	26.63	2.41
신장 (cm)	172.71	5.63
체중 (kg)	68.92	8.57

표 3 행동 분류를 위한 동작 패턴

Table 3 Activity pattern for motion classification

Class	행동	측정방법
0	서기	곧게 서서 움직임 없이 10초간 측정
1	걷기	트레드밀을 사용하여 2km/h로 10초간 측정
2	뛰기	트레드밀을 사용하여 7km/h로 10초간 측정
3	앉기	의자에 앉은 채로 10초간 측정
4	눕기	등을 지면에 대고 움직임 없이 10초간 측정
5	넘어지기	매트위로 넘어지는 동작에 대한 신호를 측정

그림 3은 실험에 사용된 가속도 센서를 사용하여 획득한 데이터를 나타낸 것이다. 상단의 신호는 x축에서 획득한 신호를 나타낸 것이며 하단의 신호는 y축에서 획득한 신호를 나타낸 것이다.

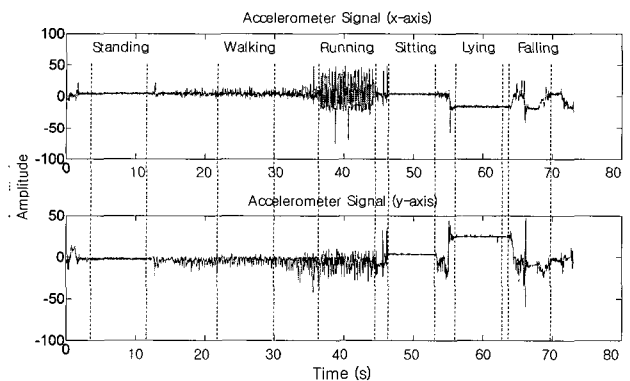


그림 3 획득한 가속도 신호(위: x축 신호, 아래: y축 신호)
Fig. 3 Obtained acceleration signal (top: x-axis signal, bottom: y-axis signal)

정확도를 측정하기 위해서 4번의 반복적인 4-fold cross validation을 수행한 후 각각의 결과의 평균값을 취해 정확도를 평가하였다. 본 연구에서는 ELM의 활성화함수로 sigmoid 함수와 sine 함수를 사용하였고 두 결과를 비교하였다. 그림 4와 5는 sigmoid 함수를 활성화함수로 사용하였을 때의 ELM의 정확도와 수행 시간에 대한 그림으로 training set과 testing set 각각에 대한 수행 결과를 나타내었다

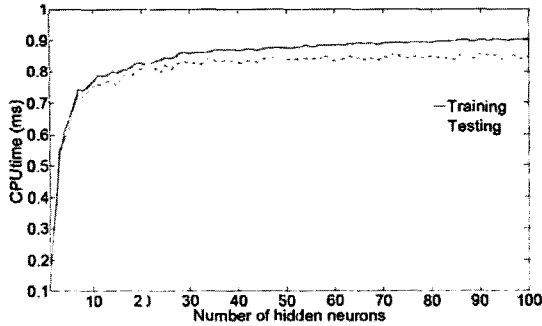


그림 4 히든뉴런개수 변화에 따른 행동분석의 정확도 (sigmoid activation)
 Fig. 4 Accuracy of activity analysis by changing the number of hidden neuron (sigmoid activation)

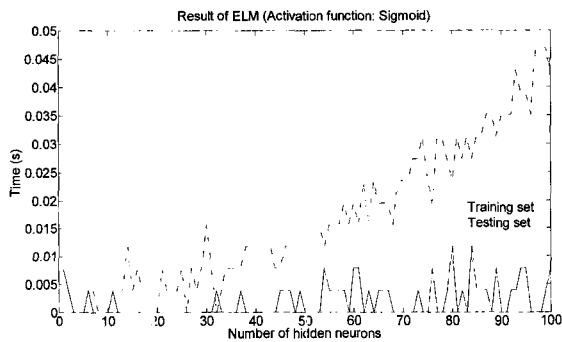


그림 5 히든뉴런개수 변화에 따른 수행시간 변화 (sigmoid activation)
 Fig. 5 Cputime by changing the number of hidden neuron (sigmoid activation)

시뮬레이션 결과를 분석해 보면 training set과 testing set의 경우 모두에서 히든뉴런이 증가함에 따라 측정 정확도가 증가하는 것을 확인 할 수 있었다. 단, training set의 경우 대략 90 % 정도의 정확도까지를 획득 할 수 있었고, testing set의 경우에는 80 % 정도의 정확도를 확보할 수 있었다. 수행시간의 경우 training 과정에서는 히든뉴런의 수에 따라 지속적으로 증가하는 것을 확인 할 수 있었고 testing set에 대해서는 히든뉴런의 수와 무관함을 확인 하였다(mean=0.0021 s, standard deviation=0.0030 s).

그림 6과 7은 활성화함수로 sine함수를 사용하였을 때 정확도와 수행 시간을 나타낸 것이다. 결과에서 확인 할 수 있듯이 sine 함수를 활성화함수로 사용하였을 경우에도 sigmoid 함수를 활성화함수로 사용 하였을 경우와 유사한 분류 정확도를 가지는 것을 확인 할 수 있다. 수행시간의 경우에는 활성화함수와 무관함을 확인 할 수 있다(mean=0.0021 standard deviation=0.0029).

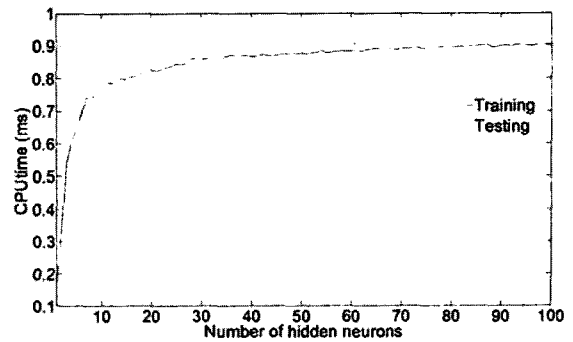


그림 6 히든뉴런개수 변화에 따른 행동분석의 정확도 (sine activation)
 Fig. 6 Accuracy of activity analysis by changing the number of hidden neuron (sine activation)

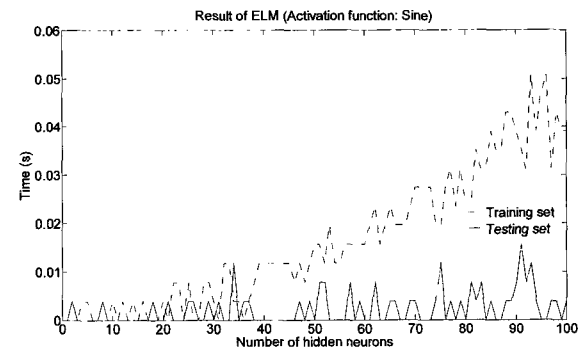


그림 7 히든뉴런개수 변화에 따른 수행시간 변화 (sine activation)
 Fig. 7 Cputime by changing the number of hidden neuron (sine activation)

히든뉴런의 개수 변화에 따른 각 행동 패턴에 대한 분류 정확도에 대한 결과는 각 행동패턴간의 유의성 및 오차 가능성을 보여주는 예로 그림 8, 그림 9에서는 sigmoid, sine 함수를 activation 함수로 사용하였을 경우 각각에 대한 행동패턴의 분류결과를 나타내었다.

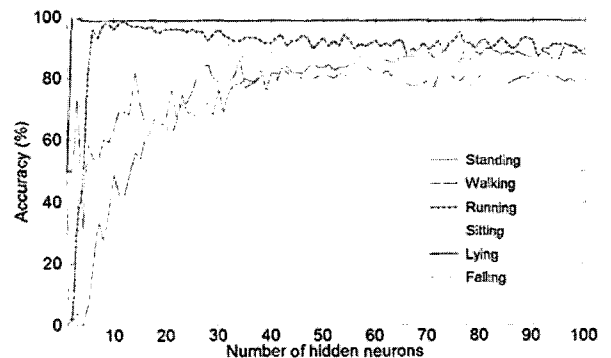


그림 8 히든뉴런 개수 변화에 따른 각 행동 패턴에 대한 분류 정확도 변화 (sigmoid activation)
 Fig. 8 Accuracy changing of each activity patterns by changing of the number of hidden neuron (sigmoid activation)

표 4 각 행동패턴에 대한 추정율 비교 (sigmoid activation)

Table 4 Mutual error table for each activity pattern (sigmoid activation)

Actual /Estimation	Standing	Walking	Running	Sitting	Lying	Falling
Standing	91 (80.53%)	2 (1.77%)	0 (0.00%)	19 (16.81%)	0 (0.00%)	1 (0.88%)
Walking	11 (9.73%)	99 (87.61%)	0 (0.00%)	2 (1.77%)	0 (0.00%)	1 (0.88%)
Running	1 (0.88%)	5 (4.42%)	105 (92.92%)	0 (0.00%)	0 (0.00%)	2 (1.77%)
Sitting	33 (29.20%)	0 (0.00%)	0 (0.00%)	79 (69.91%)	0 (0.00%)	1 (0.88%)
Lying	0 (0.00%)	0 (0.00%)	2 (1.79%)	0 (0.00%)	110 (98.21%)	0 (0.00%)
Falling	4 (3.57%)	2 (1.79%)	3 (2.68%)	0 (0.00%)	0 (0.00%)	103 (91.96%)

표 5 각 행동패턴에 대한 추정율 비교 (sine activation)

Table 5 Mutual error table for each activity pattern (sine activation)

Actual /Estimation	Standing	Walking	Running	Sitting	Lying	Falling
Standing	89 (78.76%)	2 (1.77%)	0 (0.00%)	21 (18.58%)	0 (0.00%)	1 (0.88%)
Walking	17 (15.04%)	88 (77.88%)	0 (0.00%)	6 (5.31%)	0 (0.00%)	2 (1.77%)
Running	0 (0.00%)	7 (6.19%)	103 (91.15%)	0 (0.00%)	0 (0.00%)	3 (2.65%)
Sitting	31 (27.43%)	0 (0.00%)	0 (0.00%)	81 (71.68%)	0 (0.00%)	1 (0.88%)
Lying	0 (0.00%)	1 (0.89%)	0 (0.00%)	0 (0.00%)	110 (98.21%)	1 (0.89%)
Falling	2 (1.79%)	3 (2.68%)	4 (3.57%)	2 (1.79%)	0 (0.00%)	101 (90.18%)

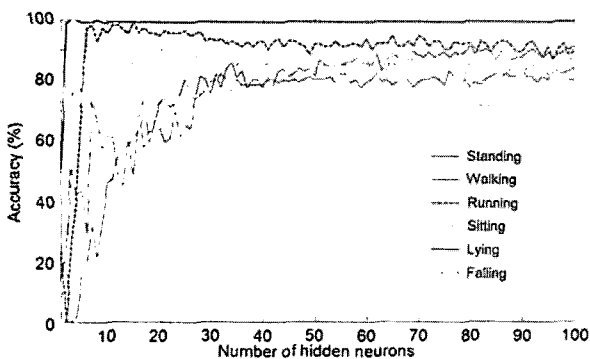


그림 9 히든뉴런 개수 변화에 따른 각 행동 패턴에 대한 분류 정확도 변화 (sine activation)

Fig. 9 Accuracy changing of each activity patterns by changing of the number of hidden neuron (sine activation)

실험 결과에서 확인 할 수 있듯이 두 가지 활성화함수의 경우 모두에서 히든뉴런의 수가 증가함에 따라 전반적인 분류

정확도가 증가함을 확인 할 수 있다. 모든 활성화함수에 대하여 뛰기, 눕기, 넘어지기의 결과는 히든 뉴런의 수가 일정수 이상일 때 히든 뉴런의 증가에 비교적 영향을 덜 받고 높은 정확도를 나타냄을 확인 할 수 있다. 전반적인 정확도는 히든 뉴런수의 증가에 따라 증가함을 알 수 있고 두 가지 활성화 함수에 따라 패턴별 분류결과에 약간의 차이를 가지나 전체적인 정확도는 유사한 것으로 나타났다. 각 행동 패턴간의 오차원인을 분석하기 위해 실제 입력 데이터와 추정데이터로 구성된 오차비교표는 표 4, 표 5와 같다. 표 4는 sigmoid activation의 경우에 대한 결과를 나타낸 것이고 표 5는 sine activation에 대한 결과를 나타낸 것으로 표의 대각 성분은 TP를 그 외의 성분은 각각 FP(False Positive)와 FN(False Negative)를 나타낸다.

표 4와 표 5의 데이터는 히든 뉴런의 개수를 100개로 설정 하였을 때의 실험 결과로 sigmoid activation의 경우 서기와 앉기 상태의 결과를 제외하면 대략 90 % 정도의 분류 정확도를 확보할 수 있다. 서기와 앉기의 경우 두 가지 활성화 함수 모두에서 상호 오차율이 높은 것을 확인 할 수 있는데 이는 두 가지 경우를 구별하기 위한 새로운 Input vector의 추가가 필요한 부분이라 생각할 수 있다.

4. 결 론

본 논문에서는 2축 가속도 신호를 이용하여 6개의 일상생활 패턴에 대한 패턴분류를 수행하였고 대략 80 %정도의 정확도를 확보하였다. ELM을 사용한 가속도 신호의 패턴 분류 결과가 히든뉴런의 개수 및 활성화함수에 따라 다양한 결과를 보여주고 있음을 고려할 때 ELM알고리즘을 위한 최적의 활성화 함수에 대한 연구와 입력 벡터를 선정하는 것에 대한 연구가 추가적으로 수행되어야 할 부분이라고 할 수 있다.

ELM 알고리즘은 실험결과에서 확인 할 것과 같이 적절한 히든뉴런의 개수에 대해서 매우 짧은 학습시간을 가지며 실제 적용시에는 히든뉴런의 수와 무관하게 입력 패턴의 길이에 따라 연산시간이 결정 되므로 연산량에 대한 유동적인 조절이 가능하다고 할 수 있다.

단, 지금까지의 연구 결과를 고려할 때 선행되어야 할 연구로는 다음과 같은 것들을 고려할 수 있다.

먼저, 실제 ADL을 분석하기 위하여 측정 되어야만 하는 행동패턴에 대한 연구가 수행되어 행동패턴의 종류를 규정 되어야 하고, 각 행동 패턴에 대한 최적 가속도 센서의 요구 사양에 대한 연구가 수행되어야 한다.

본 연구에서는 서기, 앉기, 눕기 등의 정적인 동작과, 걷기, 뛰기, 넘어지기 등의 동적인 동작에 대한 구분을 수행하지 않았기 때문에 가속도 센서가 활동량을 분석하는 것임을 고려할 때 동작간의 구분이 다소 명확하지 못한 부분이 존재하였을 수 있다고 판단되고 오차율에 영향을 주었을 수 있다고 판단되었다. 이러한 오차원인을 개선하기 위하여 3축을 이용한 가속도 센서에 대한 연구 및 각 행동 패턴의 특성을 명확하게 반영하는 입력벡터에 대한연구가 부가적으로 수행된다면 더욱 정확하게 행동 패턴을 분류해 낼 수 있을 것으로 전망된다.

감사의 글

본 논문은 정보통신부 및 정보통신연구진흥원의 정보통신선도기반기술개발사업의 연구결과로 수행되었습니다. (과제번호 2006-s-093)

참 고 문 헌

- [1] Henry J. Montoye, Han C. G. Kemper, Wim H. M. Saris, Richard A. Washburn, "Measuring physical activity and energy expenditure", Human Kinetics, pp.72-96, 1996
- [2] 이승형, "가속도 센서를 이용한 행태 분석 모니터링 시스템 개발" 단세대학교 대학원, pp. 1-31, 2003년 12월
- [3] Veltink, P.F., Bussmann, HansB.J. de Vries, W. Martens, WimL.J. Van Lummel, R.C., "Detection of static and dynamic activities using uniaxialaccelerometers", Rehabilitation Engineering, IEEE Transactions on [see also IEEE Trans. on Neural Systems and Rehabilitation], Vol. 4, no. 4, pp. 375-385, Dec 1996
- [4] Nait-Charif, H. McKenna, S.J, "Activity summarisation and fall detection in a supportive home environment", Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference on, Vol.4, pp. 323- 326, Aug. 2004
- [5] G Perolle, P. Fraisse, M. Mavros, I. Etxeberria, "automatic fall detection and activity monitoring", LUXEMBOURG, April 2006
- [6] Prado, M. Reina-Tosina, J. Roa, L., "distributed intelligent architecture for falling detection and physical activity anlysis in the elderly", EMBS/BMES Conference, 2002. Proceedings of the Second Joint, Vol. 3, pp. 1910- 1911, Oct. 2002
- [7] Suhuai Luo and Qingmao Hu, "A dynamic motion pattern analysis approach to fall detection", Biomedical Circuits and Systems, 2004 IEEE International Workshop on ,pp. 1-5 - 1-8a, Dec 2004.
- [8] Chen, J. Kwong, K. Chang, D. Luk, J. Bajcsy, R. , "Wearable Sensors for Reliable Fall Detection", Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference, pp. 3551-3554, Sept. 2005
- [9] Guang-Bin Huang, Qin-Yu Zhu, Chee-Kheong Siew, "Extreme learning machine: Theory and applications", Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on, vol. 2, pp. 985-990, July 2004
- [10] Guang-Bin Huang, Qin-Yu Zhu and Chee-Kheong, "Extreme Learning Machine: Theory and Applications", Neurocomputing, vol. 70, pp. 489-501, May 2006.
- [11] Guang-Bin Huang and H. A. Babri, "Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions" IEEE Transactions on Neural Networks, vol. 9, no. 1, pp. 224--229, 1998.
- [12] Guang-Bin Huang, "Learning capability and storage capacity of two-hidden-layer feedforward networks" IEEE Transactions on Neural Networks, vol. 14, no. 2, pp. 274--281, 2003.
- [13] Toh, K.-A, Wei-Yun Yau and Xudong Jiang, "A Reduced Multivariate Polynomial Model For Multimodal Biometrics And Classifiers Fusion", IEEE Trans.on Circuits and Systems for Video Technology (Special Issue on Image- and Video-Based Biometrics), vol.14, no.2, pp.224-233, Feb 2004.
- [14] B. Efron and R. Tibshirani, "An Introduction to the Bootstrap". Chapman & Hall/CRC, May 1994

저 자 소 개



신 항 식 (申 伉 植)

1979년 10월 10일생. 2003년 연세대학교
기계전자공학부 졸업. 2005년 동 대학원
전기전자공학과 졸업(공학석사). 2005년~
현재 동 대학원 전기전자공학과 박사과정
Tel : 02-2123-7721

Fax : 02-312-2770

E-mail : glority@yonsei.ac.kr



이 영 범 (李 榮 範)

1979년 6월 16일생. 2005년 연세대 전기
전자공학부 졸업. 2007년 동 대학원 석
사. 2007년~현재 동 대학원 전기전자공
학과 박사과정

Tel : 02-2123-4947

Fax : 02-312-2770

E-mail : youngtiger@yonsei.ac.kr



이 명 호 (李 明 鎬)

1946년 6월 11일생. 1972년 연세대 전기
공학과 졸업. 1978년 동 대학원 전기공학
과 졸업(공학박). 1980년~현재 연세대 전
기전자공학부 정교수

Tel : 02-2123-4946

Fax : 02-312-2770

E-mail : mhlee@yonsei.ac.kr