

낙상 검출을 위한 NEWFM 기반의 최소의 특징입력 선택[☆]

Selecting Minimized Input Features for Detecting Automatic Fall Detection Based on NEWFM

신 동근* 이 상 홍** 임 준 식***
Dong-Kun Shin Sang-Hong Lee Joon Shik Lim

요 약

본 논문은 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)기반의 특징 추출기법을 사용하여 낙상을 검출하는 방안을 제안하고 있다. 비중복면적 분산 측정법에 의해 중요도가 가장 낮은 특징입력을 하나씩 제거하면서 최소의 특징입력을 선택하였다. 특징입력으로써 가속도 센서를 통해 입력된 가속도 변화량을 웨이블릿 변환한 33개의 계수들 중 비중복면적 분산측정법에 의해서 추출된 19개의 계수가 사용되었다. 제안된 방법으로 민감도가 95%, 특이도가 97.25%, 정확도가 96.125%를 나타내었다.

Abstract

This paper presents a methodology for a fall detection using the feature extraction method based on the neural network with weighted fuzzy membership functions (NEWFM). The distributed non-overlap area measurement method selects the minimized number of input features by removing the worst input features one by one. Nineteen number of wavelet transformed coefficients captured by a triaxial accelerometer are selected as minimized features using the non-overlap area distribution measurement method. The proposed methodology shows that sensitivity, specificity, and accuracy are 95%, 97.25%, and 96.125%, respectively.

☞ Keyword : Fall Detection(낙상), Fuzzy Neural Networks(퍼지신경망), Wavelet Transforms(웨이블릿변환), Feature selection (특징추출)

1. 서 론

최근 의료기술의 발달로 인해 고령인구가 급속히 증가하고 있고 활동능력이 떨어지는 노인에게 일어날 수 있는 일상생활에서의 응급상황은 심각한 문제가 되고 있다. 특히 낙상은 노인들이 가장 두려움을 갖고 있는 문제 중 하나로 자신의 의지

와 관계없이 갑자기 넘어져서 뼈와 근육 즉 근골격계에 상처를 입는 사고를 말한다. 노인들은 일단 한번 낙상을 경험하게 되면 또 넘어질 수 있다는 두려움 때문에 행동의 제한이 오게 되고 그러한 행동의 제한 상태는 또 다른 낙상의 위험을 야기할 수 있으며 결국 악순환을 초래하게 된다.

낙상을 검출하기 위한 기존 연구 방법으로는 임계점(threshold)에 의한 방법[1][2][3], 신경망을 이용한 방법[4] 등이 있다. 임계점(threshold)에 의한 방법은 예상치 못한 낙상에 대해서는 판별이 불가능한 사각지대(blind area)가 존재한다는 단점이 있다. 신경망을 사용하는 경우에는 임계점방법에 비하여 구조가 복잡하지만 사각지대가 없다는 장점이 있어 낙상 검출에 효과적이다.

본 논문은 가중 퍼지소속함수를 이용한 신경망

* 정 회 원 : 삼육대학교 컴퓨터학부 교수
dkshin@syu.ac.kr(교신저자)
** 정 회 원 : 경원대학교 전자계산학과 박사수료
shleedosa@kyungwon.ac.kr
*** 중신회원 : 경원대학교 컴퓨터소프트웨어학 교수
jslim@kyungwon.ac.kr


[2009/02/19 투고 - 2009/02/27 심사 - 2009/03/18 심사완료]
☆ 이 연구는 2009년도 삼육대학교 학술연구비 지원에 의한 결과임

(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)[6][11]기반의 낙상 검출을 위하여 비중복면적 분산측정법[5][11]을 사용하여 여러 개의 특징입력 중에서 중요도가 가장 낮은 특징입력을 하나씩 제거하면서, 최소화된 특징입력으로 고도의 검출성능을 구하는 방안을 제안하고 있다. NEWFM은 각 입력에 대해 퍼지이론의 경계합(Bounded Sum)[6]을 이용하여 검출을 위한 가중 퍼지소속함수들을 생성한다. 이와 같이 단순화된 최소의 특징입력에 대한 가중 퍼지소속함수들로 간단한 퍼지규칙을 만들 수 있으며 예측이나 분류의 효율을 낮추는 특징입력을 제거함으로써 더욱 효과적인 결과를 줄 수 있다.

본 논문은 NEWFM 기반의 비중복면적 분산측정법을 사용하여 낙상을 검출하기 위해서 33개의 특징입력으로부터 중요도가 가장 낮은 특징입력을 하나씩 제거해가면서 가장 높은 검출성능을 나타내었던 19개의 최소 특징입력을 추출하고, 이 최소 특징입력들에 대한 학습된 가중 퍼지소속함수를 제시하고 있다. 본 논문에서의 데이터 수집에는 2개의 2축 가속기를 수직으로 연결하여 구성된 3축 가속도 데이터를 사용하였다. 10명의 피검자에게 800개의 샘플을 추출하였고 추출된 샘플은 전처리와 웨이블릿 과정을 거쳐 NEWFM에 적용하였다.

2. 낙상 검출 모델의 설계

본 논문에서는 웨이블릿 변환과 비중복면적 분산측정법[5]을 NEWFM 알고리즘에 적용하여 가속도 신호에서 낙상과 비낙상을 분류하는 낙상진단 모델을 설계하였다. 그림 1은 낙상 검출 모델의 다이어그램으로서 전처리 과정 후 특징을 추출하였고, NEWFM 알고리즘을 이용하여 낙상을 검출하였다.




(그림 1) 낙상진단 모델 다이어그램


본 실험에서는 60Hz의 주파수 범위를 갖는 가속도 신호를 최대값을 기준으로 전후 1.5초씩 3초를 윈도우 프레임으로 사용하였다. 전처리 과정과 특징 추출 방법으로는 가속도 변화량의 절대값과 웨이블릿 변환 계수를 사용하였다. 최종적으로 낙상 분류를 위해 추출된 퍼지 규칙은 가중 퍼지소속 함수의 경계합을 표현하는 좌표 값만을 가지고 있으며 이를 이용하여 검증 및 테스트 과정을 거치게 된다.

2.1 가속도 센서

일상생활에서 발생하는 가속도는 $\pm 12g$ 의 범위를 갖는다[7]. 그러나 허리에 센서를 부착하는 경우는 가속도의 범위가 $\pm 4g$ 를 넘지 않는다[8]. 이에 본 연구에서는 그림 2의 $\pm 10g$ 의 측정 범위와 60Hz의 대역폭을 갖는 ADXL210E를 사용하여 실험을 하였다. 가속도 센서는 그림 3과 같이 피검자의 허리에 고정시켜 사용하였다.



(그림 2) 가속도 센서



(그림 3) 가속기의 착용 위치

2.2 데이터 수집

본 논문에서는 실험을 위하여 표 1과 같이 8개의 시나리오로 데이터를 수집하였다. 데이터 수집을 위하여 20대 중반부터 30대 초반까지의 남자

대학원생 10명을 실험군으로 선정하였다. 표 1과 같이 8개의 시나리오에서 데이터를 수집하기 위하여 연구실 내부에 실험 환경을 조성하였다. 또한 약 한 달 동안 데이터를 3번에 걸쳐서 수집하였는데 그 이유는 처음 두 번 수집한 데이터는 실험에 대한 피검자의 미숙으로 실험 데이터가 좋지 못하였다.

(표 1) 데이터 수집 유형

분 류		Data 수집개수/1인	피검자수	총계
낙상	건다가 낙상	10	10	100
	뛰다가 낙상	10	10	100
	의자에서 낙상	10	10	100
	침대에서 낙상	10	10	100
비낙상	걷는 경우	10	10	100
	뛰는 경우	10	10	100
	앉는 경우	10	10	100
	눕는 경우	10	10	100
합 계				800

실험은 다양한 인체활동 상태를 10개의 시나리오로 분류하였고 각 시나리오당 10개의 데이터를 추출, 총 800개의 데이터를 추출하여 실험에 사용하였다. 각 데이터의 샘플링 레이트는 60Hz이며 윈도우 프레임은 그림 4와 같이 최대값을 중심으로 전후 각각 1.5초씩 3초 윈도우 사이즈를 적용하였다.

2.3 전처리 (가속도 변화량)


본 논문에서 사용된 3축 가속도 센서는 2개의 2축 가속도 센서로 구성되어 있다. 각각의 가속도 센서는 X, Y축의 가속도 값(벡터값)과 Y, Z축의 가속도 값(벡터값)을 출력한다. 본 논문에서는 이 두 개의 서로 다른 값을 웨이블릿 변환에 적용하기 위해 가속도 변화량의 합을 이용한 전처리를 시행하여 하나의 값으로 변환 하였다. 표 1과 같이 수집된 데이터의 전처리를 위하여 2개의 2축 가속도 센서에서 출력된 XY축과, YZ축의 가속도 신호를 XY(t), YZ(t)라고 할 때 식 (1)을 통하여 각 XY, YZ축의 가속도 변화량인 XYd(t), YZd(t)값을 구한다.

$$\begin{aligned}
 XY_d(t) &= |XY(t) - XY(t-1)| \\
 YZ_d(t) &= |YZ(t) - YZ(t-1)| \\
 t &= 1, 2, \dots, 180 (1/60\text{sec})
 \end{aligned}
 \tag{1}$$


식 (1)을 통해 구한 XYd(t), YZd(t)값을 더하여 식 (2)와 같이 XY축과 YZ축의 가속도 변화량의 합 S(t)를 구한다.

$$S(t) = XY_d(t) + YZ_d(t)
 \tag{2}$$

그림 5(a)와 5(c)는 전처리 전의 낙상과 비낙상 신호를 나타내고 있고, 그림 5(b)와 5(d)는 식 (1)과 (2)의 전처리 과정 후 낙상과 비낙상 신호를 나타낸다.

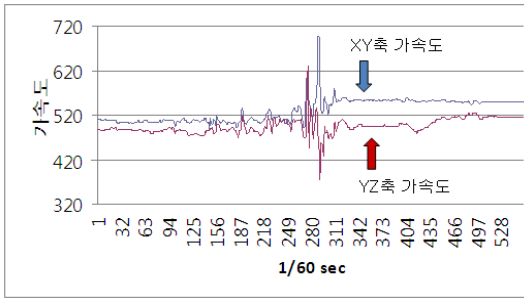


(a) 비낙상 윈도우 프레임의 예




(b) 낙상 윈도우 프레임의 예

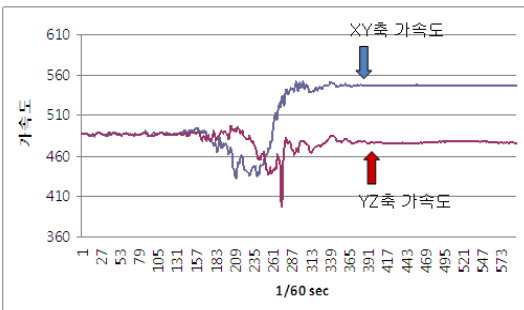
(그림 4) 비낙상(a)과 낙상(b)의 윈도우 프레임의 예



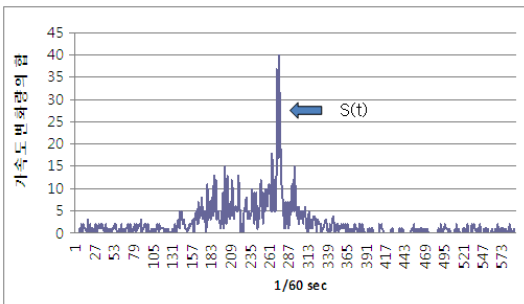
(a) 전처리 전 낙상



(b) 전처리 후 낙상



(c) 전처리 전 비낙상

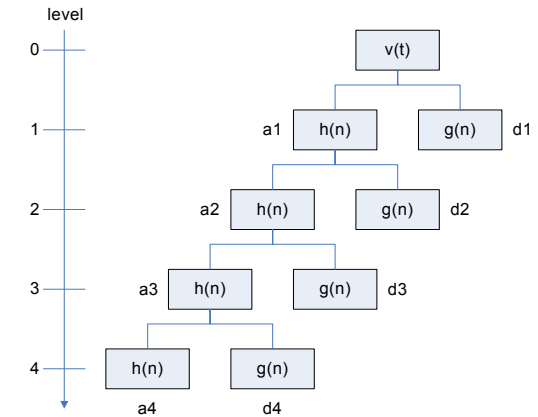


(d) 전처리 후 비낙상

(그림 5) 전처리 전·후 신호 비교

2.4 특징추출 (웨이블릿 변환)

웨이블릿 변환은 신호처리에 있어서 시간상의 국소적인 특정 지점에서의 주파수 특성을 분석함으로써 전역적 주파수 특성 정보를 주는 푸리에 분석의 단점을 보완해 준다. 비연속 웨이블릿 변환은 시간-주파수 신호를 다양한 스케일의 비연속 신호로 분리해 준다. 그림 6은 이분 비연속 웨이블릿 분리 구현을 위한 필터뱅크를 보여주고 있다[10]. detail이라고 하는 $g(n)$ 은 웨이블릿 계수와 관련된 FIR(Finite Impulse Filters) 고대역필터(High-pass Filters) 계수이고, approximation이라고 하는 $h(n)$ 은 스케일 함수 계수와 관련된 FIR 저대역필터(Low-pass Filters) 계수이다. 각 필터를 지나 그 길이가 반으로 감소한 $h(n)$ 신호로 다음 스케일 레벨에서, 반복하여 변환 시킨다. 웨이블릿 변환으로 추출된 웨이블릿 계수는 웨이블릿 모함수(mother wavelet)에 대한 유사도로써 이는 스케일에 의해 주어진 시간에 따른 주파수 신호를 나타낸다.



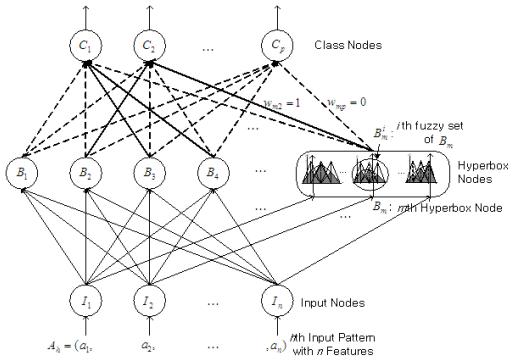
(그림 6) 스케일 레벨 4인 이분 비연속 웨이블릿 변환

본 논문에서는 스케일 레벨 4인 이분 비연속 Haar 웨이블릿 변환을 수행하여 33개의 계수를 생성하였다. 이들은 그림 6에서 보인바와 같이 d_3 에서 22개, d_4 에서 11개의 계수들로 구성되어 있다. 이들 33개의 계수가 신경망의 초기 특징입력 이 된다.

2.5 가중 퍼지소속함수 기반 신경망 (Neural Network with Weighted Fuzzy Membership Function, NEWFM)

NEWFM[6]은 입력으로부터 학습된 가중 퍼지 소속함수의 경계합을 이용하여 클래스 분류를 하는 지도학습(supervised) 퍼지 신경망이다. 가중 퍼지소속함수의 경계합은 가중치를 갖는 대, 중, 소의 3개 퍼지소속함수의 경계합을 하나의 퍼지소속함수로 합성한 것이다. NEWFM의 구조는 그림 7에서 보는 바와 같이 입력, 하이퍼박스, 클래스의 3개 계층으로 구성되어 있다. 입력 계층에는 n개의 입력노드들로 구성되며 각 입력노드는 하나의 특징입력을 입력받게 된다. 하이퍼박스 계층은 m개의 하이퍼박스 노드로 구성되고, 1번째 하이퍼박스 노드 B_1 은 단 하나의 클래스 노드에 연결되며 n개의 퍼지집합을 갖는다.

본 논문에서는 그림 1의 특징 추출 과정에서 웨이블릿 변환된 계수들이 그림 7의 n개의 특징입력을 갖는 h번째 입력 $A_h = (a_1, a_2, \dots, a_n)$ 에 대한 NEWFM의 입력값으로 사용되어진다.



(그림 7) 가중 퍼지소속함수 신경망(NEWFM)의 구조


3. 특징 선택 (비중복면적 분산 측정법)

퍼지규칙이나 중요한 특징입력을 선택하는 것은 최근 논문에서 언급되어지고 있다[9]. 본 논문에서는 그림 1의 웨이블릿 변환으로부터 생성된

33개의 초기 특징입력 중 비중복면적 분산 측정법 [5][11]에 의해 중요도가 가장 낮은 특징입력을 하나씩 제거하면서 검출성능이 가장 높은 19개의 최소 특징입력을 추출하였다. 이 방법은 i번째 특징입력에 대해 식 (3)에 의해 그 중요도를 측정한다.


$$f(i) = (Area_N^i + Area_F^i)^2 / \left(\frac{1}{1 + e^{-|Area_N^i - Area_F^i|}} \right) \quad (3)$$

여기서 AreaF와 AreaN은 각각 낙상 및 비낙상에 대해 더 우세한 퍼지함수의 면적을 의미한다. 그림 8은 낙상과 비낙상의 검출을 위한 33개의 초기 특징입력으로부터 식 (3)에 의해 측정된 중요도가 가장 높은 것과 가장 낮은 것에 대한 가중 퍼지소속함수의 경계합(BSWFM)[6]의 예를 보여주고 있다. 흰 부분과 검은 부분의 면적이 각각 AreaF와 AreaN을 나타내고 있다. AreaF+AreaN 면적이 넓으면서 AreaF와 AreaN의 넓이가 균등히 분산되어 있으면 두 클래스를 분류할 수 있는 특징을 더 많이 가지고 있다고 볼 수 있다.



(그림 8) 33개의 초기 특징입력 중 중요도가 가장 높은 것과 가장 낮은 가중 퍼지소속함수의 경계합(BSWFM) 예

그림 9는 특징입력이 33개 일 때 비중복면적 분산측정법을 사용하여 가장 나쁜 특징입력의 누적개수를 구한 것이다. 이와 같이 비중복면적 분산측정법에 의해 입력 데이터 33개 특징입력 중 $f(i)$ 값이 가장 낮은 11 번째 ($i=11$) 웨이블릿 계수 특징입력을 제거하고 NEWFM을 다시 실행하여 학습시키게 된다. 이를 분류 결과가 사전 목표 값을 유지하는 동안 가장 낮은 특징입력의 $f(i)$ 값을 갖는 특징입력을 하나씩 반복하여 제거한다.



(그림 9) 가장 퍼지소속함수의 경계함(BSWFM)에 대한 비중복면적 분산측정법을 이용한 특징입력 순위 누적 예

(표 2) 33개의 웨이블릿 계수와 최종 선택된 19개의 특징입력(✓)

순번	웨이블릿 계수	선택	순번	웨이블릿 계수	선택
1	1 번째 계수		18	7 번째 계수	
2	2 번째 계수	✓	19	8 번째 계수	✓
3	3 번째 계수		20	9 번째 계수	
4	4 번째 계수	✓	21	10 번째 계수	✓
5	5 번째 계수	✓	22	11 번째 계수	✓
6	6 번째 계수	✓	23	12 번째 계수	✓
7	7 번째 계수	✓	24	13 번째 계수	✓
8	8 번째 계수	✓	25	14 번째 계수	✓
9	9 번째 계수	✓	26	15 번째 계수	✓
10	10 번째 계수		27	16 번째 계수	✓
11	11 번째 계수		28	17 번째 계수	✓
12	1 번째 계수		29	18 번째 계수	
13	2 번째 계수		30	19 번째 계수	
14	3 번째 계수	✓	31	20 번째 계수	
15	4 번째 계수	✓	32	21 번째 계수	
16	5 번째 계수		33	22 번째 계수	
17	6 번째 계수	✓			

최소의 특징입력 추출을 위해 NEWFM기반의 비중복면적 분산측정법을 사용하여 33개의 초기 특징입력 중 중요도가 가장 낮은 특징입력을 하나씩 제거하면서 예측성능이 가장 높은 19개의 최소 특징입력을 추출하였다. 표 2는 초기 특징입력으로 사용한 33개의 웨이블릿 계수를 나타내었고 중요도가 높아 최종 선택된 19개의 최소 특징입력을 “✓”로 표시하였다.

4. 실험 결과

(Experimental Results)

식(4)는 분류 성능 평가를 위해 사용되었으며 사용된 식들의 의미는 다음과 같다. TP(true positive)는 낙상이 낙상으로 분류되는 것을, FP(false positive)는 비낙상이 낙상으로 분류되는 것을 의미한다. TN(true negative)은 비낙상이 비낙상으로 분류되는 것을 의미하며 FN(false negative)은 낙상이 비낙상으로 분류되는 것을 의미한다. 민감도(sensitivity), 특이도(specificity), 정확도(accuracy)은 식 (4)와 같이 정의된다.

$$\text{민감도} = \frac{TP}{TP+FN} \times 100$$

$$\text{특이도} = \frac{TN}{TN+FP} \times 100 \quad (4)$$

$$\text{정확도} = \frac{TP+TN}{TP+FN+TN+FP} \times 100$$

표 4에서는 NEWFM의 성능을 평가하기 위해서 역전파 알고리즘(backpropagation, BP)과의 비교를 시도하였다. NEWFM은 96.125%의 낙상 분류율을 BP는 93.625%의 낙상 분류율을 보여주고 있다. BP의 경우는 표 3에서 epochs, 은닉층 노드의 개수에 따른 실험결과를 정리하였다. BP의 실험에서는 학습율은 0.01, momentum은 0.7로 설정하였다. 표 3의 BP 실험결과에서 알 수 있듯이 epoch가 40000, 은닉층 노드의 개수가 2개일 때 가장 높은 낙상 분류율을 나타내었다. BP에는 최

소의 특징입력 추출을 위한 방법이 없기 때문에 32개의 특징입력을 이용하여 구한 결과 값이다. NEWFM 분류성능에 있어서는 19개의 최소 특징입력을 이용하여 구한 결과 값이다. 실험결과 96.125%의 높은 분류율을 보였으며 민감도는 95%, 특이도는 97.25%의 안정성 있는 결과를 보였다.

(표 3) BP의 성능 비교

Epochs	은닉층 노드의 개수	민감도(%)	특이도(%)	정확도(%)
30000	2	90.5	96.25	93.375
	4	89.5	96.5	93
	8	89.75	96.25	93
40000	2	91	96.25	93.625
	4	90.25	96.25	93.25
	8	90.5	96.25	93.375
50000	2	91.25	95.75	93.5
	4	83.5	97.5	90.5
	8	83	97	90

(학습율 : 0.01, momentum : 0.7)

(표 4) NEWFM과 BP의 성능 비교

	민감도(%)	특이도(%)	정확도(%)
NEWFM	95	97.25	96.125
BP	91	96.25	93.625

(표 5) 낙상 시나리오별 분류 성능

분 류		Total	Correct	Error	분류율
낙상	바닥에서 낙상	100	94	6	94
	침대에서 낙상	100	94	6	94
	뛰다가 낙상	100	94	6	94
	의자에서 낙상	100	98	2	98
소계		400	380	20	95
비낙상	걷는 경우	100	100	0	100
	눕는 경우	100	98	2	98
	뛰는 경우	100	94	6	94
	앉는 경우	100	97	3	97
소계		400	389	11	97.25
총 계		800	769	31	96.125

낙상 시나리오별 낙상진단 모델의 성능은 표 5와 같다. 낙상의 경우 400개의 낙상 데이터 중 20

개의 데이터가 비낙상으로 분류되어 95%의 분류율을 보였고, 비낙상의 경우 400개의 비낙상 데이터 중 11개가 낙상으로 분류되어 97.25%의 분류율을 보였다. 낙상에서는 의자에서 낙상을 하는 경우가 98%로 가장 높은 분류율을 보였으나 바닥이나 침대, 뛰는 경우가 비교적 낮은 분류율을 보였다. 특히 뛰는 경우는 낙상과 비낙상 모두에서 가장 낮은 분류율을 보였다. 이는 뛰는 경우에 가속도의 변화량이 크게 나타나 낙상의 분류율이 낮아진 것으로 판단되며 향후 이를 보완하기 위한 방법이 연구되어야 할 것으로 보인다. 또한 본 논문에 사용된 데이터는 인증된 데이터가 아니라 단점이 있어, 좀 더 정확한 성능 평가를 위해서는 더 많은 모집단을 통해 데이터를 축적해야 할 필요가 있다.

5. 결 론

본 논문은 NEWFM과 비중복면적 분산측정법 [5]을 이용하여 중요도가 가장 낮은 특징입력을 하나씩 제거하면서 낙상 검출을 위한 최소의 특징입력을 선택하는 방안을 제안하고 있다. 또한 이렇게 구한 최소의 특징입력을 이용하여 낙상에 대한 검출성능의 최대값을 구하는 방안을 제안하였다. 본 논문에서는 특징입력으로써 가속도 센서를 통해 입력된 가속도 변화량을 웨이블릿 변환한 33개의 계수들 중 비중복면적 분산측정법에 의해서 추출된 19개의 계수가 사용되었다. 제안된 방법으로 민감도가 95%, 특이도가 97.25%, 정확도가 96.125%를 나타내었다. 추후에는 본 논문에서 사용한 알고리즘을 사용하여 실시간 낙상 시스템을 구현할 것이다.

참 고 문 헌

- [1] M.J.Mathie, B.G.Celler, N.H.Lovell, A.C.F.Coster, "Classification of basic daily movements using a triaxial accelerometer" Medical & Biological

- Engineering & Computing 2004, Vol. 42. 679~687
- [2] Dean M. Karantonis, Nigel H. Lovell, "Implementation of a Real-Time Human Movement Classifier Using a Triaxial Accelerometer for Ambulatory Monitoring" IEEE Transactions on information technology in biomedicine, vol. 10, no. 1, jan 2006
- [3] Amit Purwar, Do Un Jeong, Wan Young Chung, "Activity Monitoring from Real-Time Triaxial Accelerometer data using Sensor network" International Conference on Control, Automation and Systems 2007. Oct. 17-20 in COEX, Seoul, Korea
- [4] L. Jatoba, U.Grobamann, "Development of a Self-Constructing Neuro-Fuzzy Inference System for Online Classification of Physical Movements" 2007. IEEE
- [5] J. S. Lim and S. Gupta, "Feature Selection Using Weighted Neuro-Fuzzy Membership Functions," The 2004 International Conference on Artificial Intelligence(IC-AI'04), VOL. 1, pp. 1301-1315, Las Vegas, Nevada, USA. June 21-24, 2004.
- [6] J. S. Lim, "Finding Fuzzy Rules by Neural Network with Weighted Fuzzy Membership Function," International Journal of Fuzzy Logic and Intelligent Systems, Vol. 4, No.2, pp.211-216, September, 2004.
- [7] Carlijn V.C. Bouten, Karel T. M. Koekkoek, Maarten Verduin, Rens Kodde, Jan D. Janssen, "A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity", IEEE Transactions on Biomedical Engineering, Vol.44, pp.136-147, 1997.
- [8] 이승형, "가속도 센서를 이용한 행태 분석 모니터링 시스템 개발". 연세대학교 대학원, 2003.
- [9] S-M Zhou and J. Q. Gan, "Constructing L2-SVM-Based Fuzzy Classifiers in High-Dimensional Space with Automatic Model Selection and Fuzzy Rule Ranking," IEEE Trans. on Fuzzy Systems, Vol. 15, No. 3, pp. 398-409, 2007
- [10] S. Mallat, "Zero Crossings of a Wavelet Transform," IEEE Trans. on Information Theory, Vol. 37, pp. 1019-1033, 1991.
- [11] Joon S. Lim, "Finding Features for Real-Time Premature Ventricular Contraction Detection Using a Fuzzy Neural Network System", IEEE Trans. on Neural Networks, VOL. 20, No. 3, pp. 522-527, MARCH 2009.

● 저 자 소개 ●



신 동 근 (Dong-Kun Shin)

1986년 인하대학교 전자계산학과 졸업(학사)
1996년 동국대학교 대학원 전자계산학과 졸업(공학석사)
1999년 인하대학교 대학원 컴퓨터정보공학과 수료(공학박사수료)
1997.9~2006.2 삼육의명대학 컴퓨터정보과 교수
2006.3~현재 삼육대학교 컴퓨터학부 교수
관심분야 : Neuro-fuzzy System, HCI, Software Engineering, etc.
E-mail : dkshin@syu.ac.kr



이 상 흥 (Sang-Hong Lee)

1999년 경원대학교 공과대학 전자계산학과 졸업(공학사)
2001년: 2001년 경원대학교 일반대학원 전자계산학과 졸업(공학석사)
2006년~현재 경원대학교 일반대학원 전자계산학과 박사과정
관심분야 : neuro-fuzzy systems을 이용한 주기예측, 전문가 시스템
E-mail : shleedosa@kyungwon.ac.kr



임 준 식 (Joon S. Lim)

1986년: 인하대학교 전자계산학과(학사)
1989년: University of Alabama at Birmingham, Dept. of Computer Science (M.S.)
1994년: Louisiana State University, Dept. of Computer Science (Ph.D.)
1995년~현재 : 경원대학교 전자거래학부 교수(현)
관심분야: neuro-fuzzy systems, biomedical systems
E-mail : jslim@kyungwon.ac.kr