

Akıllı telefonların algılayıcılarının verilerini kullanarak Yapay Sinir Ağları ile İnsan Hareketlerinin Sınıflandırılması

Classification of Human Movements with Artificial Neural Networks using Smartphone Sensors' Data

Kübra Tural¹, Erhan Akdoğan²

¹Mekatronik Mühendisliği Bölümü
Manisa Celal Bayar Üniversitesi
kubra.tural@cbu.edu.tr

²Mekatronik Mühendisliği Bölümü
Yıldız Teknik Üniversitesi
eakdogan@yildiz.edu.tr

Özetçe

İnsan hareketi algılama konusu, insandan ve insanın yaşadığı çevreden toplanan verileri değerlendirerek insanın eylemini önceden kestirmeye çalışmaktadır. Algılayıcı verileri, insanlardan ivmeölçer gibi araçlarla dahili veya kamera gibi araçlarla harici olarak toplanabilir. Yapılan çalışmalarda insan hareketleri *temel hareketler* ve *hareket geçişleri* olmak üzere iki farklı gruba ayrılmaktadır. Araştırmacılar çoğunlukla temel hareketler üzerine çalışmalar yapmaktadır; çünkü hareket geçişlerini tespit etmek oldukça karmaşıktır. Bu çalışmada, belde taşınan bir akıllı telefonun algılayıcıları kullanılarak elde edilen genel bir veri setinden yararlanılmıştır. Bu veri seti daha önce yapılan bir çalışmanın tüm araştırmacılara açık olarak yayınlanan verilerdir. Yapılan çalışmadan farklı olarak bu çalışmada veri seti kullanılarak belirlenen hareketler yapay sinir ağları metodu ile kestirilmektedir. Kullanılacak veri setinde ivme ve jiroskop verileri ile temel hareketler bulunmaktadır. Performans analizi hata matrisi ile yapılmıştır. Sonuçlar, öğrenme çıktısında elde edilen sonuçlar ile büyük oranda örtüşmektedir.

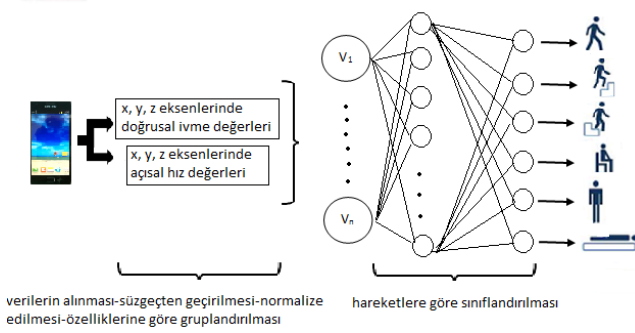
Abstract

Human Activity Recognition is a research area that it is focused on human movements by interpreting sensory information collected from people and environment they live in. Sensory information can be obtained from people using wearable sensors such as accelerometers, magnetometers and from people's environments using tools such as cameras. Human movements consist of two parts. One part includes basic activities (BAs) and the other includes postural transitions (PTs). Most of the researches are related with basic activities because detection of postural activities is more complex. In this study, human movement is predicted by using artificial neural networks. A public dataset of the smartphone's sensor module is used training and testing the artificial neural network algorithm. The dataset includes six basic activities, acceleration and gyroscope data. Performance analysis is indicated with confusion matrix.

1. Giriş

Son yıllarda algılama ve hesaplama teknolojilerinin gelişmesi, insanların çevresiyle olan etkileşiminin gözlemlenmesine büyük katkı sağlamıştır. İnsan fiziksel hareketlerinin algılanması, özellikle motor bozukluğu ve fiziksel hareketlerinde kısıt olan insanlarda günlük yaşamlarını sürdürmede ihtiyacı olan ortam bilgisinin algılamasında kullanılan yöntemlerden biridir [1]. Ağ sistemlerinin yaygınlaşması ve genişlemesiyle, akıllı ortam (Ambient Intelligence) kavramı ortaya çıkmıştır. Akıllı ortamlar, çoğunlukla hasta, yaşlı veya engelli insanların günlük yaşam kalitesini (QoL) artırmaya yönelik tasarlanmaktadır [2]. Genel olarak akıllı ortamlar, kapalı ortamda bulunan kamera, yaklaşım ya da ışık sensörü gibi sensörler ile insanın hareketlerini algılayan ve bu hareketlere göre ortamı değiştirebilen sistemler iken destekli akıllı yaşam (Assisted Ambient Living) sistemleri ise, akıllı ortamların engelli ya da yaşlı insanlara yardımcı olan akıllı sistemler içeren bir alt sistemdir [2]. Bu sistemlerin kullanıcıyı rahatsız etmeyen, erişimi kolay, kullanıcının konumuna duyarlı, adaptif olma gibi özellikleri vardır. Bu sistemler, insan-makine etkileşimini de meydana getirmektedir [3]. İnsan-makine etkileşimine örnek olarak; sağlık açısından önemli kalp ritmi, kan şekeri gibi hayati parametrelerin takibini sağlayan taşınabilir araçların kullanılması, telefon veya saat gibi farklı araçlardan elde edilen verilerin bir bulut ortamında bir araya getirilerek tek sistemden erişilebilir olması ve akıllı evlerde yaşanılması gibi uygulamalar verilebilir.

İnsan hareketlerinin algılamada kullanılan algılayıcılar, *ortam algılayıcıları* ve *giyilebilir algılayıcılar* olarak iki ana gruba ayrılmaktadır. Ortam algılayıcıları kamera, mikrofon, derinlik algılayıcısı, termometre gibi kullanıcıya dolaylı olarak etkilenen algılayıcılarıdır. Giyilebilir algılayıcılar ise kullanıcı ile temas halinde olabilen algılayıcılarıdır. İvmeölçer, jiroskop veya bunları içeren akıllı telefon, saat, gözlük gibi nesnelere örnek olarak verilebilir [3].



Şekil 1: Hareket algılama sisteminin temel yapısı.

Bu çalışmada, içinde 3-eksenli ivmeölçer ve jiroskop bulunan bir akıllı telefon ile insan hareketi algılama sistemi geliştirilmiştir. Bu sistemde, algılayıcılardan gelen bilgiler sınıflandırılarak kullanıcının hareketi tahmin edilmektedir. Algılayıcı verisi olarak erişime açık olarak paylaşılan bir veri seti kullanılmıştır [4]. Yapılan çalışmalara bakıldığında sınıflandırmaya dayalı tahmin mekanizmalarında çoğunlukla denetimli lineer sınıflandırma yöntemi olan destek vektör makinesi (SVM) yöntemi kullanıldığı görülmektedir. Bu çalışmada farklı olarak denetimli öğrenme yöntemlerinden biri olan yapay sinir ağları yöntemi ile hareketler sınıflandırılarak sistemin performansı incelenmiştir.

2. İnsan Hareketi Algılama Sistemi

2.1. İnsan Hareketi

İnsan hareketi algılama (HAR) sistemi, insanın bulunduğu ortamdan ve insandan topladığı algılayıcı bilgisini yorumlayarak insanın o anki davranışını anlamayı amaçlamaktadır. Bu şekilde kullanıcının durumu ile ilgili gerektiğinde bilgi aktarabilmektedir. İnsan hareketleri temel olarak 3 ana gruba ayrılmaktadır. Bunlar; kısa olaylar, temel aktiviteler ve karmaşık aktivitelerdir. Kısa olaylar, vücut duruşu ile duruşlar arası geçişleri gibi kısa zamanlı hareketleri içermektedir. Temel aktiviteler ise daha uzun zamanlı aktiviteleri içerirken; bu aktiviteler dinamik veya statik olabilmektedir. Ayakta durmak, yürümek vb. örnek verilebilir. Karmaşık aktiviteler, birkaç durumu birlikte içeren veya nesnelere etkileşimde olarak gerçekleştirilen hareketlerdir. Müzik aleti çalmak, spor hareketleri yapmak, sosyal aktivitelerde bulunmak gibi eylemler bu duruma örnek verilebilir [5].

Bu çalışmada temel aktiviteler grubundan hareketler bulunmaktadır. Temel hareket (BAs) grubundan 6 adet hareket tanımlanmıştır. Bu temel hareketler; ayakta durma, yere uzanma ve oturma hareketlerini içeren üç statik ve yürüme, merdiven inme, merdiven çıkma hareketlerini içeren üç dinamik hareketten oluşmaktadır [5]. Sistemin basitçe gösterimi Şekil 1'de yer almaktadır. Tanımlanan hareketler 1'den 6'ya kadar numaralandırılmış olup sırasıyla yürüme, merdiven çıkma, merdiven inme, oturma, ayakta durma ve uzanma olarak belirlenmiştir.



Şekil 2: (a) deneylerde kullanılan akıllı telefon ve kemerli kılıfı (b) Algılayıcının eksen takımı [2].

2.2. Giyilebilir Algılayıcı olarak Akıllı Telefon


Hareket algılamada en çok kullanılan ivmeölçer ve jiroskop algılayıcıları günümüzde akıllı telefonların içinde oldukça küçük yapıda bulunmaktadır. Ayrıca telefonlar günlük hayatta da kullanıcıyı rahatsız etmeden kullanıldığından bu çalışma için oldukça elverişlidir. Telefonun yerleştirildiği yere göre (bel, gömlek cebi, pantolon cebi vb.) eksen takımı atanması gerekmektedir. Bu çalışmada telefonun konumu ve eksen takımı Şekil 2'de gösterilmektedir.

Kullanılan akıllı telefonda 3-eksenli ivmeölçer ve 3-eksenli jiroskopun bir arada yer aldığı açısal ölçüm algılayıcısı bulunmaktadır. İvmeölçer hareketin doğrusal ivme değerini ölçerken jiroskop eksen etrafında dönmelerden kaynaklı açısal hızları ölçmektedir.

2.3. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin öğrenme ve uygulama özelliğini modellemeyi amaçlayan bir makine öğrenmesi yöntemidir. Makine öğrenmesi 4 temel gruba ayrılmaktadır: Denetimli öğrenme, yarı denetimli öğrenme, denetimsiz öğrenme ve destekli öğrenme. Literatürde ikili karar ağaçları, K-en yakın komşular (k-NN), destek vektör makineleri (SVM), Naive Bayes sınıflandırıcıları, Gizli Markov Modelleri (HMM) ve yapay sinir ağları (ANN) gibi metotlarla insan hareket algılama sistemleri uygulanmıştır [1]. Bu çalışmada denetimli öğrenme yöntemi olan yapay sinir ağları metodu uygulanmıştır.

Yapay sinir ağı denetimli öğrenme biçimi olduğundan öncelikle ağı eğitilmelidir. Toplanan verilerin bir kısmı ağı eğitmek için kullanılırken bir kısmı da doğrulama için kullanılmaktadır. Şekil 3'te sistem için yapay sinir ağının çalışma şekli şematik olarak gösterilmektedir.



Şekil 3: Yapay sinir ağının çalışma şeması.

3. Yapay Sinir Ağı Modeli

3.1. Verilerin Elde Edilmesi


Bu veriler Kaliforniya Irvine Üniversitesi bünyesinde bulunan Makine Öğrenmesi Veri Deposundan alınmıştır [6]. Araştırmacılar verileri şu prosedür ışığında elde ettiklerini belirtmişlerdir. Öncelikli olarak telefon verilerinden hareket tahmini yapılabilmesi için 30 gönüllünün Şekil 1’de gösterilen kılıflı kemeri beline takarak 6 hareketi yapması istenmiştir. Yapılan hareketlerin video kaydı alınmıştır. Telefonun içinde bulunan ivmeölçer ve jiroskop verileri ile video kaydı verileri eşleştirilerek oluşturulan sistemde kullanılacak girdi ve çıktılar elde edilmiştir. İvmeölçerden toplanan veriler ilk olarak gövde ve yer çekimi ivmeleri olarak ayrılmıştır. Ayrıştırılan veriler süzgeçten geçirildikten sonra 50 Hz. örnekleme frekansında, zaman ve frekans bölgesi değişkenlerine ayrılmıştır. Çeşitli matematiksel fonksiyonlar kullanılarak zaman ve frekans değişken özellikleri içeren 561 vektör oluşturulmuştur. Vektör değerleri normalize edilerek $[-1,1]$ aralığında sınırlandırılmıştır. Toplanan verilerin %70’i öğrenme, %30’u ise doğrulama için ayrılmıştır.

3.2. Ağ Yapısı

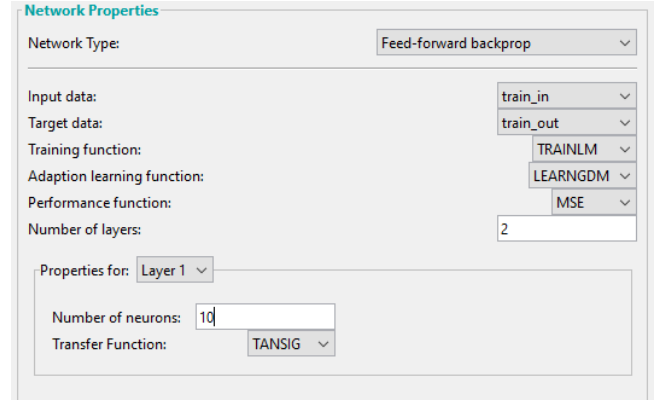
Toplanan veriler belirli girdilere karşılık belirli çıktılar olacak şekilde elde edilir. Yapay sinir ağı denetimli öğrenme metodu olduğu için bu şekilde elde edilen veriler ağı eğitilmesi için gereklidir. Öğrenme için 7352, test için 2947 veri işlenmiştir. Tüm araştırmacılara açık olan bu veri seti, ham verilerin filtreleme, normalize etme gibi ön işlemlerden geçirildikten sonra belirlenen fonksiyonlara göre özellik çıkarma işlemi yapılarak 561×7352 matris haline getirilmiştir [6]. Bu vektörler ağı girdi setini oluşturmaktadır. Çıktı seti ise belirlenen 6 hareketin deneylerde yapılışına göre elde edilmiştir.

Ağ, girdilerin rastgele ağırlıklarla kuvvetlendirilip bias eklenerek toplanmasıyla daha önce elde edilen çıktılara ulaşmaya çalışır. Bu şekilde ağ eğitilmektedir. Eğitilen ağda elde edilen ağırlıklar test verileri ile ağı sisteme uygulanmasını sağlamaktadır. MATLAB® benzetim ortamında oluşturulan yapay sinir ağı modeli Şekil 4’te verilmiştir.

Bu çalışmada ağ yapısında 2 adet katman bulunmaktadır. Birinci katman gizli katman, ikinci katman ise çıkış katmanıdır. İlk katmanda 5 adet nöron vardır. Öğrenme algoritması olarak ileri beslemeli geri yayılım yöntemi seçilmiştir. Aktivasyon fonksiyonu olarak hiperbolik tanjant sigmoid fonksiyonu seçilmiştir. Şekil 5’te ağı özelliklerinin seçildiği programın arayüzü gösterilmektedir.



Şekil 4: Sistemin yapay sinir ağı yapısı

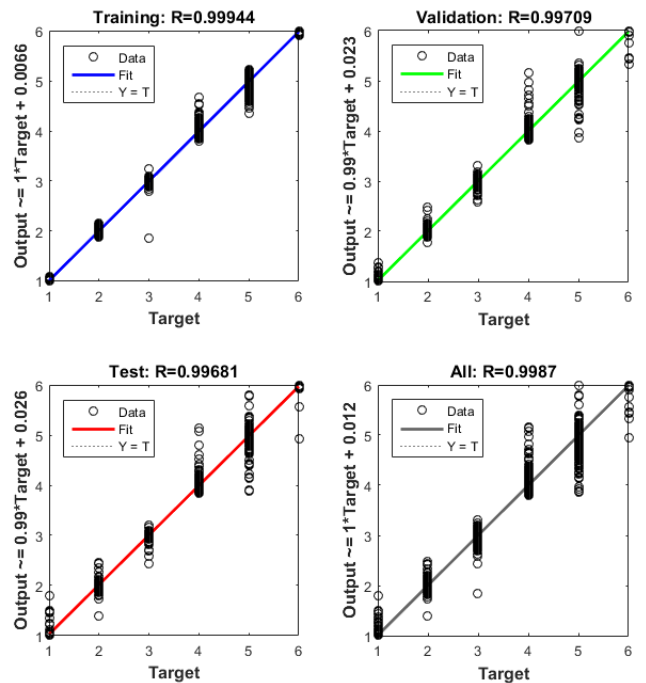


Şekil 5: Ağ özellikleri

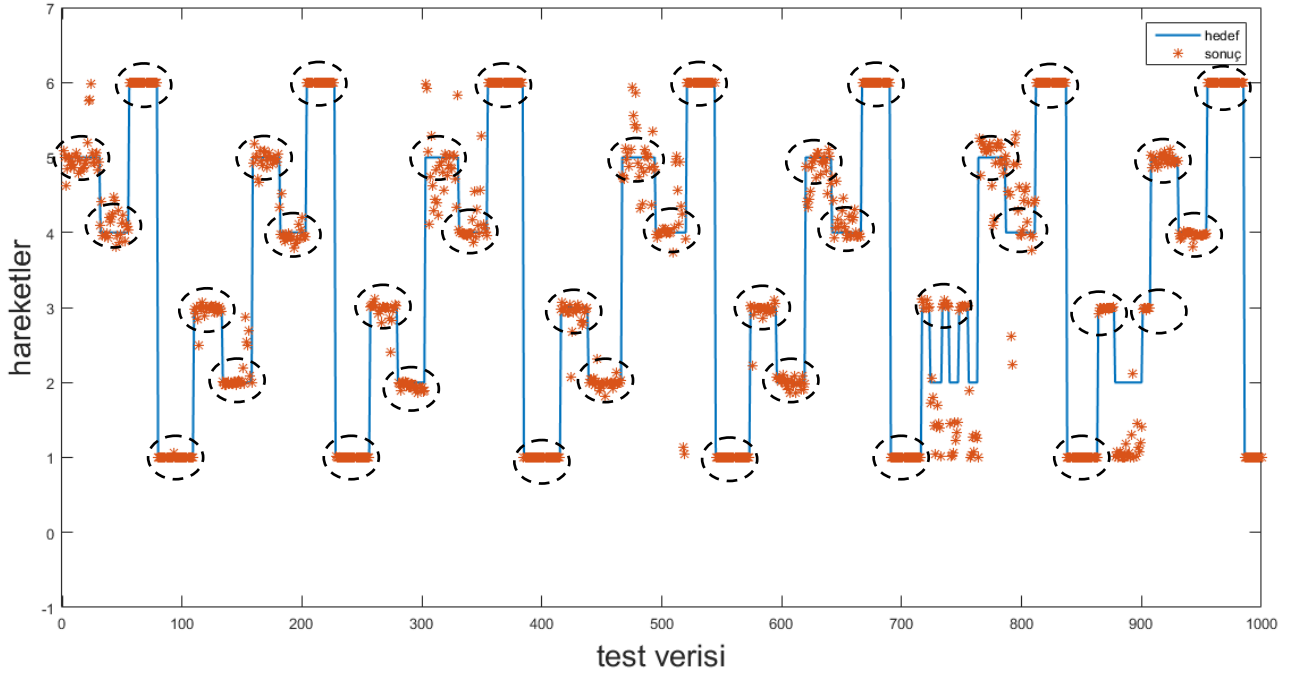
4. Sonuç

MATLAB® programında Yapay Sinir Ağları araç kutusu verilerin eğitilmesi ve test edilmesi için gereken ağ yapısının oluşturulmasına olanak sağlamıştır. Ağı eğitilmesi sonucu elde edilen sonuçlar Şekil 6’da verilmiştir. Öğrenme aşamasında başarı oranı %99,87 olarak hesaplanmıştır.

Test aşamasında ise elde edilen sonuç Şekil 7’de gösterilmektedir. Bu grafikte, eğitim aşamasından farklı bir veri seti eğitilen sisteme girdi olarak alınarak elde edilen çıktı ile bu veri seti için belirli olan çıktı setiyle karşılaştırma sonucu görülmektedir. Sistemin girdi ile elde edilen çıktıları “sonuç”, belirli çıktılar ise “hedef” olarak adlandırılmıştır. Bu çıktıların karşılıkları ise 1’den 6’ya kadar numaralandırılan insan hareketleridir.



Şekil 6: Öğrenme çıktısı



Şekil 7: Eğitilen sistemin test sonucu.

Tablo 1 : Hata matrisi.

| Sonuç \ Hedef | Yürüme | Merdiven Çıkma | Merdiven İnme | Oturma | Ayakta Durma | Uzanma | Duyarlılık |
|----------------|--------|----------------|---------------|--------|--------------|--------|------------|
| Yürüme | 478 | 58 | 2 | 2 | 1 | 0 | 88 % |
| Merdiven çıkma | 18 | 407 | 30 | 1 | 0 | 0 | 89 % |
| Merdiven inme | 0 | 6 | 388 | 1 | 0 | 0 | 98 % |
| Oturma | 0 | 0 | 0 | 436 | 31 | 0 | 93 % |
| Ayakta durma | 0 | 0 | 0 | 51 | 480 | 0 | 90 % |
| Uzanma | 0 | 0 | 0 | 0 | 20 | 537 | 96 % |
| Hassasiyet | 96 % | 86 % | 92 % | 89 % | 90 % | 100 % | 93 % |

Şekil 7’de “hedef” çıktıları olan hareketler sürekli olarak çizdirilmiştir. Sürekli grafiğin üzerinde noktasal (yıldız şeklinde) olarak çizdirilen “sonuç” çıktılarıdır. Grafikte hedef ile sonuç çıktılarının örtüştüğü kısımlar kesikli çizgilerden oluşan yuvarlaklar içerisinde belirtilmiştir. Burada yürüme (1) ve uzanma (2) hareketlerinin neredeyse birebir örtüştüğü gözlenmektedir. Aynı zamanda hareketlerin gerçekleştirilme sürelerinin de hareketin kestiriminde doğruluk payını etkilediğini 700-800 veri sayısı aralığında gözlemleyebiliriz. “Hedef” verileri önceden eğitilen verilerin çıktıları, “sonuç” verileri ise eğitilen sistemin test verileri çıktılarıdır.

Şekil 7’de verilen grafiğin sayısal olarak ifadesi hata matrisi olarak Tablo 1’de ifade edilmiştir. Tablo 1’de satırlarda yer alan hareket sayıları test edilen sistemin çıktılarıdır, sütunlarda yer alan hareket sayıları ise önceden tahmin edilen test çıktılarıdır. Hata matrisinin köşegeninde yer alan sayılar ise doğru olarak tahmin edilen hareket sayılarını göstermektedir. Köşegenin en son değeri ise bu sistemin doğruluk oranını ifade etmektedir. Buna göre sistem 93 % oranında doğru hareket tahmininde bulunmuştur. Bu değer aynı zamanda yapay sinir ağı ile tasarlanan bu sınıflandırma sisteminin başarı oranını göstermektedir. Bu oran daha önce yapılan çalışmaya oldukça yakındır. Ağın eğitimi sonucunda kabul edilebilir başarı oranı elde edilmiştir.

Kaynakça

- [1] J.L. Reyes-Ortiz, A. Ghio, D. Anguita, X. Parra, J.Cabestany, A. Catala, “Human Activity and Motion Disorder Recognition: Towards Smarter Interactive Cognitive Environments”, *Computational Intelligence and Machine Learning*, ESANN 2013.
- [2] Jorge Luis Reyes Ortiz, “Smartphone-Based Human Activity Recognition”, *Universitat Politècnica de Catalunya*, PhD. Thesis.
- [3] J.L. Reyes-Ortiz, L. Oneto, A. Ghio, A. Sama, D. Anguita, X. Parra, “Human Activity Recognition on Smartphones with Awareness of Basic Activities and Postural Transitions”, *Artificial Neural Networks and Machine Learning*, ICANN 2014. (pt)
- [4] Davide Anguita, Alessandro Ghio, Luca Oneto, Xavier Parra and Jorge L. Reyes-Ortiz, "A Public Domain Dataset for Human Activity Recognition Using Smartphones", *21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, ESANN 2013. Bruges, Belgium 24-26 April 2013.(ka)
- [5] J.L. Reyes-Ortiz, L. Oneto, A. Sama, X. Parra, D. Anguita, “Transition-Aware Human Activity Recognition Using Smartphones”, *Neurocomputing*, Springer 2015.
- [6] <https://archive.ics.uci.edu/ml/datasets/human+activity+recognition+using+smartphones>
- [7] Y. Kwon, K. Kang, C. Bae, “Unsupervised learning for human activity recognition using smartphone” *Expert System with Applications*, 2014.
- [8] D. Anguita, A. Ghio, L. Oneto, X. Parra, J.L. Reyes-Ortiz, “Human Activity Recognition on Smartphones using a Multiclass Hardware-Friendly Support Vector Machine”, *International Workshop of Ambient Assisted Living*, IWAAL 2012.
- [9] M. A. Awan, Z. Guangbin, C. G. Kim, S. D. Kim, “Human Activity Recognition in WSN: A Comparative Study”, *International Journal of Networked and Distributed Computing*, Vol. 2, No. 4, October 2014.
- [10] A. Reiss, G. Hendeb, D. Stricker, “A competitive Approach for Human Activity Recognition on Smartphones”, *Computational Intelligence and Machine Learning*, ESANN 2013.
- [11] H. Fang, L. He, H. Si, P. Liu, X. Xie, “Human activity recognition based on feature selection in smart home using back-propagation algorithm”, *ISA Transactions*, Elsevier 2014.