

# Aktivite Tanımda Yapay Sinir Ağları ve Genetik Programlama Yöntemlerinin Karşılaştırılması

## Comparison of Artificial Neural Networks and Genetic Programming Methods For Activity Recognition

Çağatay Berke Erdaş, Tunç Aşuroğlu\*, Koray Açıcı, Hasan Oğul  
Bilgisayar Mühendisliği Bölümü, Başkent Üniversitesi, Ankara, Türkiye  
{berdas, tuncasuroglu, korayacici, hogul}@baskent.edu.tr

**Özetçe—** Giyilebilir sensörlerin yaygınlaşmasıyla beraber sensörlerden elde edilen ham verilerin işlenmesiyle aktivite tanıma problemine getirilen çözümler yaygınlaşmaya başlamıştır. Bu bağlamda literatürde çeşitli uygulamalar olmakla beraber, bu çalışmada aktivite tanımda popüler olarak kullanılan yapay sinir ağı yöntemleri (ANN, RBFNN) ve genetik programlama (GP) yönteminin ivmeölçer verisinden çıkarılan zaman, frekans ve dalgacık (wavelet) öznitelikleri üzerinden performans karşılaştırılması hedef alınmıştır. Bahsi geçen çalışma kapsamında alınan sonuçlara bakıldığında, ulaşılan en başarılı sınıflandırma performansı zaman öznitelikleri kullanılarak, çok katmanlı perseptronun ara katmanında 31 nöron kullanılması ile %75.09 olarak elde edilmiştir.

**Anahtar Kelimeler—**yapay sinir ağları; genetik programlama; aktivite tanıma; sensör.

**Abstract—** With the widespread use of wearable sensors, the processing of raw data obtained from sensors has led to widely-used solutions to the problem of activity recognition. In this context, it is aimed to compare the performance of artificial neural network methods (ANN, RBFNN) and genetic programming (GP) methods over time, frequency and wavelet features extracted from the accelerometer data. The most successful classification performance achieved was 75.09% using 31 neurons in the hidden layer of the multilayer perceptron, using time attributes.

**Keywords—**artificial neural networks; genetic programming; activity recognition; sensor.

### I. GİRİŞ

Giyilebilir sensörlerin yaygınlaşmasıyla beraber sensörlerden elde edilen ham verilerin işlenmesiyle aktivite tanıma problemine getirilen çözümler yaygınlaşmaya başlamıştır. Her aktivite bireye özgü olduğundan ve

aktivite izleme yöntemlerinin çeşitliliğinden dolayı aktivite tanıma problemi, araştırmacıların ilgisini çekmeye devam etmektedir. Aktivite tanıma gerçek hayatta da kendine bir çok uygulamada yer bulmaktadır. Bu alanlara örnek olarak uzaktan hasta takibi verilebilir. Hasta giyilebilir sensörler ile evinde günlük yaşamına devam edebilir. Böylelikle sıklıkla hastaneye veya kontrole gitmek zorunda olan hastalar için uzaktan izleme sağlanarak hastanın aktivite tespitleri yerinde yapılabilir.

Aktivite tanıma probleminin çözümünde bir çok yaklaşım bulunmaktadır. Yapay sinir ağları ve genetik programlama kullanan yaklaşımlar bu problemin çözümüne katkı sunmaya devam etmektedir. Fang ve He akıllı evlerde kullanılmak üzere geri beslemeli yapay sinir ağı tasarlayarak aktivite tanıma problemi üzerine çalışmışlardır [1]. Toplam 10 aktivite üzerinden elde ettikleri doğruluk değerlerini raporlamışlardır. Yapay sinir ağındaki gizli katmanda kullanılacak nöron sayısı için deneyler gerçekleştirmişlerdir. Rodrigues ve Mestria aktivite tanımlama problemi için Bayes ağı ve yapay sinir ağı kullanarak deneyler yapmışlar ve sonuçları karşılaştırmışlardır [2]. Bayes ağının yapay sinir ağına göre daha yavaş çalıştığını fakat daha yüksek doğruluk değerlerine ulaştığını ortaya koymuşlardır. Mehr vd. yapay sinir ağı kullanarak akıllı evlerde aktivite tanıma üzerine çalışmışlardır [3]. Yapay sinir ağının eğitimi aşamasında üç farklı öğrenme algoritması kullanarak deneyler yapmışlar ve sonuç olarak Levenberg-Marquardt algoritmasının diğerlerine üstün geldiğini raporlamışlardır. Zeng ve Wang yürüyüş şekli tanıma üzerine yaptıkları çalışmada radyal tabanlı fonksiyon (RBF) sinir ağı kullanmışlardır [4]. En düşük hata prensibine göre, eğitimde kullanılan yürüyüş örüntülerinden birine olan benzerlik sayesinde test yürüyüş örüntüsünün tanınmasını gerçekleştirmişlerdir. Sood ve Bhooshan, EEG sinyallerini kullanarak nöbet tespiti çalışması yapmışlardır. Çalışmada yapay sinir ağları, destek vektör makineleri ve Bayes gibi

çeşitli sınıflandırıcılar kullanmışlardır. Yapay sinir ağı ve destek vektör makinelerinin diğer sınıflandırıcılara göre daha iyi sonuç verdiğini raporlamışlardır [5]. Xie vd. akıllı telefonların sensör girdilerini kullanarak bir veri kümesi hazırlamışlardır [6]. Bu veri kümesini kullanarak aktivite tanıma problemi üzerinde çalışmışlardır. Geleneksel makine öğrenme yöntemleri yerine genetik programlama yaklaşımıyla problemi çözmeye çalışmışlardır. Bhardwaj vd. sara nöbetlerinin tespiti için yeni bir genetik programlama yaklaşımı önermişlerdir [7]. Bunun için EEG sinyallerini sınıflandırmışlardır. Genetik programlamanın karmaşıklığını azaltmak için yeni bir dinamik uygunluk fonksiyonu önermişlerdir. Önerilen yöntemin performansı mevcut makine öğrenme yöntemlerinin performansı ile karşılaştırılarak detaylı bir biçimde verilmiştir. Aktivite tanıma probleminde ham verilerden elde edilen özneliklerin boyutunu azaltmak için genetik programlamaya başvuran çalışmalar da mevcuttur [8].

Bu çalışmada amacımız, aktivite tanıma popüler olarak kullanılan yapay sinir ağı yöntemleri (ANN, RBFNN) ve genetik programlama yönteminin ivmeölçer verisinden çıkarılan zaman, frekans ve dalgacık (wavelet) öznelikleri üzerinden performans karşılaştırılmasının yapılmasıdır. En yüksek doğruluk değerinin çok katmanlı perseptron (MLP) yapay sinir ağı ile zaman öznelikleri kullanılarak elde edildiği gözlemlenmiştir.

## II. YÖNTEMLER

### A. Sınıflandırma Yöntemleri

Aktivite tanıma kullanılmak üzere çalışmamızda üç sınıflandırma yöntemi kullanılmıştır. Bunlardan ilk ikisi yapay sinir ağları kategorisinde bulunan çok katmanlı perseptron (Multi Layer Perceptron, MLP) ve radyal tabanlı fonksiyon sinir ağıdır (RBFNN). Üçüncü yöntem ise genetik programlamadır (GP). GP'nin sinir ağları tabanlı makine öğrenme yöntemlerinden farkı evrimsel algoritma yaklaşımını kullanmasıdır. Bu sayede sınırlı sayıdaki kullanıcı girdisi ile matematiksel modeli oluşturmaya çalışmaktadır.

1) *Çok katmanlı perseptron (MLP)*: En az bir gizli katmandan oluşan yapay sinir ağıdır. Birçok problemin çözümünde tek gizli katmanın kullanımı yeterli olmaktadır. Perseptronlar (biyolojik olarak nöron) bir yapay sinir ağının temel birimi olup birçok girdiye ve tek çıktıya sahip olan karar verme birimleridir [9]. Perseptron, girdi vektörü ile bağlantılarının ağırlıklarının nokta çarpımlarını toplar ve bir bias değeri ekler. Elde edilen toplam sinyal çoğunlukla doğrusal olmayan bir fonksiyon (log-sigmoid vb.) tarafından dönüştürülür. MLP'de giriş, gizli ve çıkış olmak üzere üç katman bulunmaktadır. Girdi ve çıktı vektörleri arasındaki doğrusal olmayan ilişkiler doğrusal olmayan transfer fonksiyonları yardımıyla öğrenilir. Giriş katmanındaki düğümler gizli katmandaki nöronlara bir örneği temsil eden öznelik vektörünün değerlerini iletir. Gizli katmanda ağırlık vektörü ile girdi

vektörü kullanılarak yukarıda bahsedilen matematiksel işlemler yapılır. Çıkış katmanında ise verilen problemdeki sınıf sayısı kadar nöron bulunur ve örneğin hangi sınıfa atanacağı bu katmanda belirlenir. Ağın eğitilmesi çıkış katmanındaki nöronların çıktılarıyla beklenen (hedef) değerlerin arasındaki farkın minimize edilmesine dayanır. Fark değerleri ağıdaki ağırlıkların güncellenmesinde kullanılır. Bu işleme hatanın geri-yayılımı denir. Levenberg-Marquardt en çok bilinen ve kullanılan geri-yayılım öğrenme algoritmalarından birisidir.

2) *Radyal tabanlı fonksiyon sinir ağı (RBFNN)*: Üç katmandan (giriş, gizli ve çıkış) oluşan yapay sinir ağıdır. MLP'den farkı, girdi vektörüyle nöronun ağırlık vektörü arasında yapılan nokta çarpımı yerine girdi vektörünün Gauss RBF birimlerine (nöron) olan uzaklığının (Öklid) hesaplanmasıdır. Her bir RBF nöronu küme veya prototip olarak da adlandırılır. Eğitim kümesi üzerinde k-means kümeleme uygulanarak k adet küme elde edilir ve bu kümeler RBF nöronu olarak kullanılır. Gizli katmanda girdi vektörünün her RBF nöronunun merkez vektörüne olan uzaklığı hesaplanır. RBF nöronu aktivasyon fonksiyonu olarak Gauss fonksiyonu kullanır. Her küme için kullanılan Gauss fonksiyonun yayılım parametresine göre eğrinin şekli değişir. Gizli katmandaki her RBF nöronunun çıktısı ağırlıklandırılarak çıkış katmanına iletilir. Burada gizli katmandan gelen çıktılar doğrusal olarak birleştirilerek RBF ağının çıktısı oluşturulur [10].

3) *Genetik programlama (GP)*: Genetik Programlama (GP) fikri ilk olarak Koza tarafından 1992 yılında ortaya atılmıştır [11]. GP, evrimsel hesaplama olarak bilinen ve neo-Darwinci evrim teorisinin temel ilkelerinden bazılarını dayanılarak tasarlanmış, Global arama ve optimizasyon algoritmalarının geliştirilmesi ile uğraşan geniş bir araştırma alanına ait bir yöntemdir [12]. Fakat GP yaklaşımı bazı anahtar noktalarda evrimsel hesaplama yöntemlerinden farklılık göstermektedir. GP, gözetimli öğrenme yöntemini kullanarak otomatik bir şekilde problemleri çözmeye çalışır. Diğer bir deyişle, GP 'nın amacı bir takım bağımsız değişkenler (girdiler) ve bağımlı değişkenler (çıktılar) arasındaki ilişkiyi ortaya çıkarmaya çalışan bazı hesaplama biçimlerini gerçekleştiren ifadeleri geliştirirerek sonuca ulaşmaya çalışır. Bir çok evrimsel hesaplama yöntemleri (Örn: genetik algoritma) fonksiyon optimizasyonu sürecine odaklanmaktadır. GP ise bir problemin model yapısını bulmayı amaçlamaktadır.

GP beş adımdan oluşmaktadır;

- Aday çözümlerden rasgele kümeler seçilir (popülasyon).
- Her bir çözümün probleme özgü uygunluk fonksiyonu (fitness function) ile kalitesi ölçülür.
- Yeni çözümlerin (çocukların) oluşturulabilmesi için skolasik seçim mekanizması ile olasılıksal bir biçimde ebeveynler seçilir.

- Skolastik arama operatörleri olan Mutasyon ve Çaprazlama (Crossover) her iterasyonda daha iyi sonuçlar üretilebilmesi için kullanılır. Bu operatörlerde girdi seçilen ebeveynler, çıktı ise bu ebeveynlerin çocuklarıdır.
- Bu süreç iteratif olarak tekrarlanır (her bir iterasyon bir nesildir (generation)). Belirlenen durma kriteri sağlanana kadar süreç devam eder. Yöntemde kullanılan durma kriteri maksimum hesaplamsal çaba ölçütü olabilir, bu ölçüt toplam nesil sayısı veya uygunluk fonksiyonunun toplam değerlendirme sayısıdır.

GP yönteminin temel adımları şekil 1 ile verilmiştir.

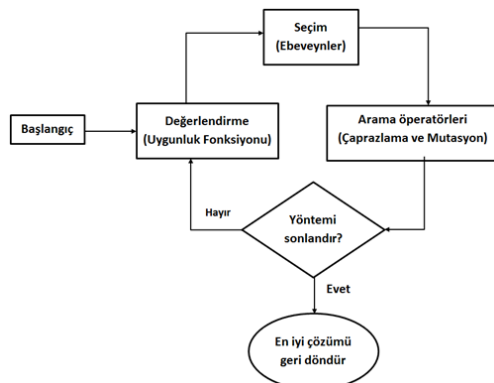
#### B. Öznitelik Çıkarımı

Sinyali temsil eden öznitelik vektörü oluşturulurken zaman, frekans [13] ve dalgacık öznitelikleri [14] ham veriden çıkartılmıştır.

Zaman öznitelikleri her bir eksenden çıkarılan ve eksenler arasındaki ilişkiyi inceleyen öznitelikler olmak üzere iki ayrı grupta incelenebilir. Her bir eksenden (x, y, z) çıkarılan öznitelikler; ortalama, varyans, standart sapma, medyan gibi değerleri içermektedir. Buna ek olarak, eksenler arasındaki ilişkiyi de kullanmak için eksenlerinin ikili kombinasyonlarına, çapraz korelasyon uygulanarak toplam 55 öznitelik elde edilmiştir.

Frekans öznitelikleri ise enerji, bilgi entropisi ve baskın frekans gibi değerlerden oluşmaktadır. Üç eksen için toplamda 18 öznitelik elde edilmiştir.

Dalgacık özniteliklerini elde edebilmek için zaman-uzayından dalgacık-uzayına dönüşüm (discrete wavelet transform) yapılmaktadır. Toplamda 36 öznitelik elde edilmiştir.



Şekil 1. GP Temel Adımları

### III. SONUÇLAR

#### A. Veri Kümesi ve DeneySEL Kurulum

Seçilen sınıflandırma algoritmalarının uygulanması için, [15] tarafından halka açık şekilde sunulan veri kümesi kullanılmıştır. Bahsi geçen veri kümesi, katılımcıların göğsüne yerleştirilen bir telefonun içindeki ivmeölçer tarafından toplanmıştır. Toplanan bu ivmeölçer sinyalleri, toplamda 15 katılımcının; bilgisayar ile çalışma, ayağa kalkma, yürüme ve merdiven çıkma/inme, ayakta durma, yürüme, merdiven çıkma/inme, konuşurken yürüme ve ayakta dururken konuşma olmak üzere toplamda yedi farklı aktivite yapması ile elde edilmiştir. İvmeölçerin çalışma frekansı 52 Hz olmak üzere 3 boyutta (x,y,z) veri toplamaktadır. Aktiviteler ve sahip oldukları örnek sayıları Tablo I'de verilmiştir.

Veri kümesi, her bir ivmeölçer bileşeninin ortalama değeri 0 ve standart sapması 1 olacak şekilde normalize edilmiştir.

Çalışma kapsamında yapılan tüm sınıflandırma işlemlerinde, 10 kat çapraz geçerleme (10 fold cross validation) yöntemi kullanılmıştır. Bahsi geçen bu yöntemde veri kümesi, on eşit parçaya bölünür. Bu parçalardan her biri, sınıflandırma yöntemi tarafından test için, kalan dokuz parça aynı sınıflandırma yöntemi tarafından eğitim için kullanılır. Her bir parça test için kullanılabilece kadar süreç devam eder ve bu on parça için elde edilen sonuçların ortalaması, sınıflandırma yönteminin o veri kümesi için elde ettiği nihai sonuç olarak kabul edilir.

Çalışmada kullanılan sınıflandırıcıların başarımını ölçmek için toplam doğruluk (overall accuracy) kullanılmıştır. TP, FP, TN ve FN sırasıyla doğru pozitif, yanlış pozitif, doğru negatif ve yanlış negatifleri temsil etmek üzere toplam doğruluk ölçütünün formülü aşağıdaki gibidir (1).

$$\text{Toplam Doğruluk} = \frac{TP+TN}{TP+FP+TN+FN} * 100 \quad (1)$$

Aktivite	Örnek Sayısı
Bilgisayar ile çalışma	608667
Ayağa kalkma, yürüme ve merdiven çıkma/inme	47878
Ayakta durma	216737
Yürüme	357064
Merdiven çıkma/inme	51498
Konuşurken yürüme	47770
Ayakta dururken konuşma	593563

Tablo I. Veri kümesindeki aktiviteler ve örnek sayıları

### B. Sınıflandırma Performansı

MLP, RBFNN ve GP sınıflandırıcıları kullanılarak zaman, frekans ve dalgacık öznitelikleri üzerinden sınıflandırma performansları toplam doğruluk ölçütü ile Tablo II'de verilmiştir. Yapay sinir ağları ailesine ait olan MLP ve RBFNN için farklı nöron sayıları ile deneyler yapılmış ve sonuçlar karşılaştırılmıştır. MLP için en yüksek toplam doğruluk değeri frekans öznitelikleri kullanılarak nöron sayısı 5 olarak seçildiğinde %69.32 olarak elde edilmiştir. RBFNN için en yüksek toplam doğruluk değeri yine frekans öznitelikleri kullanılarak nöron sayısı 5 olarak seçildiğinde %64.26 ile elde edilmiştir. Evrimsel algortima kullanan GP'de ise en yüksek doğruluk değerine frekans öznitelikleri üzerinden %59.87 ile ulaşılmıştır. GP için çaprazlama oranı 0.9, mutasyon oranı ise 0.07 olarak seçilmiştir. Zaman öznitelikleri kullanıldığında sonuçların her üç sınıflandırıcı için de frekans öznitelikleri kullanılarak elde edilen sonuçlara yakın olduğu gözlemlenmiştir (%68.76, %61.58 ve %59.05). En düşük sonuçların ise her üç sınıflandırıcı için de dalgacık öznitelikleri kullanıldığında elde edildiği görülmüştür.

En yüksek doğruluk oranı gizli katmanında 5 nöron bulunan MLP ile elde edildiğinden bu yöntemin performansını iyileştirmek için nöron sayısı (2)'de belirtildiği gibi bulunmuştur [16].

$$\text{nöron sayısı} = \frac{\text{öznitelik sayısı} + \text{sınıf sayısı}}{2} \quad (2)$$

Buna göre zaman, frekans ve dalgacık öznitelikleri için gizli katmanda gerekli nöron sayısı sırasıyla 31, 13 ve 22 olarak bulunmuştur. Sonuçlar Tablo III'de verilmiştir. En yüksek toplam doğruluk değerine zaman öznitelikleri üzerinden 31 nöron ile ulaşıldığı görülmektedir.

Sınıflandırıcı	Nöron sayısı	Zaman	Frekans	Dalgacık
MLP	1	59.70	61.79	45.55
MLP	2	64.53	63.36	46.36
MLP	3	67.37	65.79	49.60
MLP	4	69.05	68.02	50.25
<b>MLP</b>	<b>5</b>	<b>68.76</b>	<b>69.32</b>	<b>50.49</b>
RBFNN	1	57.19	58.34	45.53
RBFNN	2	58.47	59.63	49.30
RBFNN	3	60.89	60.19	50.60
RBFNN	4	60.45	62.43	50.44
RBFNN	5	61.58	64.26	50.75
GP	-	59.05	59.87	38.81

Tablo II. Sınıflandırma performansı (%)

Nöron sayısı	Zaman	Frekans	Dalgacık
1	59.70	61.79	45.55
2	64.53	63.36	46.36
3	67.37	65.79	49.60
4	69.05	68.02	50.25
5	68.76	69.32	<b>50.49</b>
<b>(31, 13, 22)</b>	<b>75.09</b>	<b>70.80</b>	50.33

Tablo III. Farklı nöron sayıları için MLP sınıflandırma performansı (%)

### IV. TARTIŞMA

Sınıflandırma sonuçlarına göre en yüksek performansın MLP sınıflandırıcısı ile alındığı görülmektedir. Gizli katmanda bulunan nöron sayısının değiştirilmesi MLP'nin mevcut sınıflandırıcılar arasındaki başarısını etkilememektedir. Nöron sayısının öznitelik ve sınıf sayısına göre belirlenmesinin mevcut performansı daha da artırdığı rahatlıkla söylenebilir. Çıkarılan öznitelik grupları arasından en yüksek sınıflandırma performansına zaman öznitelik grubuyla erişildiği görülmektedir. Buna ek olarak frekans öznitelik grubu kullanıldığında da sistemin başarılı sonuçlar ürettiği söylenebilir. Dalgacık öznitelik grubunun her sınıflandırıcı altında sistemin en düşük sonuçları ürettiği gözlemlendiğinden aktiviteleri ayırt etmede zayıf kaldığı ortaya atılabilir.

### TEŞEKKÜR

Bu çalışma 115E451 proje numarası altında Türkiye Bilimsel Ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından desteklenmiştir.

### KAYNAKÇA

- [1] H. Fang, L. He, "BP Neural Network for Human Activity Recognition in Smart Home," *International Conference on Computer Science and Service System*, August 11-13, Nanjing/China, 2012.
- [2] L. M. Rodrigues, M. Mestria, "Classification Methods based on Bayes and Neural Networks for Human Activity Recognition," *12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, August 13-15, Changsha/China, 2016.
- [3] H. D. Mehr, H. Polat, A. Çetin, "Resident Activity Recognition in Smart Homes by Using Artificial Neural Networks," *4th International Smart Grid Congress and Fair (ICSG)*, April 20-21, Istanbul/Turkey, 2016.
- [4] W. Zeng, C. Wang, "Human gait recognition via deterministic learning," *Neural Networks*, 35, 92-102, 2012.
- [5] M. Sood, S. V. Bhooshan, "Automatic Processing of EEG signals for Seizure Detection using Soft Computing Techniques," *International Conference on Recent Advances and Innovations in Engineering*, May 09-11, Jaipur/India, 2014.
- [6] F. Xie, A. Song, V. Ciesielski, "Genetic Programming Based Activity Recognition on A Smartphone Sensory Data Benchmark," *Congress on Evolutionary Computation (CEC)*, July 6-11, Beijing/China, 2014.

- [7] A. Bhardwaj, A. Tiwari, R. Krishna, V. Varma, "A novel genetic programming approach forepileptic seizure detection," *Computer Methods And Programs In BioMedicine*, 124, 2-18, 2016.
- [8] X. Zou, B. Bhanu, "Human Activity Classification Based on Gait Energy Image and Coevolutionary Genetic Programming," *18th International Conference on Pattern Recognition*, August 20-24, Hong Kong/China, 2006.
- [9] M. Janidarmian, A. R. Fekr, K. Radecka, Z. Zilic, "A Comprehensive Analysis on Wearable Acceleration Sensors in Human Activity Recognition," *Sensors*, 17(3), E529, 2017.
- [10] T. Kurban, E. Beşdok, "A Comparison of RBF Neural Network Training Algorithms for Inertial Sensor Based Terrain Classification," *Sensors*, 9(8), 6312-6329, 2009.
- [11] J.R. Koza, "Genetic Programming on the Programming of Computers by Means of Natural Selection," *MIT Press*, Cambridge, MA, USA, 1992.
- [12] J. E. Zárate, L. Trujillo, S. de Lara, M. Castelli, E. Z-Flores, L. Munoz, A. Popovic, "Automatic Modeling of a Gas Turbine Using Genetic Programming: An Experimental Study", *Applied Soft Computing*, 50, 212-222, 2017.
- [13] D. Figo, P. C. Diniz, D. R. Ferreira, J. M. P. Cardoso, "Preprocessing techniques for context recognition from accelerometer data," *Personal and Ubiquitous Computing*, 14(7), 645-662, 2010.
- [14] L. Tamura, M. Sekine, M. Ogawa, T. Togawa, Y. Fukui, "Classification of acceleration waveforms during walking by wavelet transform," *Methods of Information in Medicine*, 36, 356-359, 1997.
- [15] P. Casale, O. Pujol, P. Radeva "Activity Recognition from Accelerometer Data Using Wearable Device," *Personal and Ubiquitous Computing*, 6669, 289-296, 2011.
- [16] S. Sebastian, J. J. Puthiyidam, "Evaluating Students Performance by Artificial Neural Network using WEKA," *International Journal of Computer Applications*, 119(23), 36-39, 2015.