

T.C.
ERCIYES ÜNİVERSİTESİ
BİLİMSEL ARAŞTIRMA PROJELERİ
KOORDİNASYON BİRİMİ



PROJE BAŞLIĞI
EYLEMSİZLİK ALGILAYICILARI KULLANARAK
DÜŞMELERİN SEZİMİ VE AYIRT EDİLMESİ

Proje No:
FBA-11-3579

Proje Türü
Normal Araştırma

SONUÇ RAPORU

Proje Yürütücüsü:
Ahmet Turan Özdemir
Elektrik Elektronik Mühendisliği Bölümü

Kenan Danışman
Elektrik Elektronik Mühendisliği Bölümü
Billur Barshan
Bilkent Üniversitesi EEM Bölümü

Temmuz 2014

KAYSERİ

TEŐEKKÜR

Bu alıŐma, FBA-11-3579 proje numarasıyla Erciyes Üniversitesi Bilimsel AraŐtırma Projeleri Koordinasyon Birimi ve TÜBİTAK BİDEB 2218 Yurtii Doktora Sonrası AraŐtırma Burs Programı tarafından desteklenmiŐtir. Saėladıėı katkılardan ötürü öncelikle ERÜ BAP birimine teŐekkür ederiz. alıŐmanın devamlılıėı aısından saėladıėı destekten ötürü BİDEB'e teŐekkür ederiz. Son olarak deneylerimize katılan gönüllülere emekleri ve ayırdıkları zaman için teŐekkür ederiz.

İÇİNDEKİLER

	Sayfa No
ÖZET	5
ABSTRACT	6
1. GENEL BİLGİLER	7
2. GİRİŞ	8
3. GEREÇ VE YÖNTEM	12
4. BULGULAR	20
5. TARTIŞMA	23
6. SONUÇ	25
7. KAYNAKLAR	27

ÖZET

Düşmeler çok ciddi bir toplum sağlığı problemi ve bu risk gurubu içerisinde yer alan bireyler için bir yaşam tehdididir. Bu proje ile sensör birimlerinden oluşan ve vücudun 6 farklı bölgesine sabitlenerek giyilebilen bir otomatik düşme sezme sistemi geliştirilmiştir. Her bir sensör ünitesi her biri üç eksenli ivmelenme sensörü, jiroskop ve magnetometreden meydana gelmektedir. 14 gönüllü ile içerisinde 20 adet düşme ve 16 adet günlük aktivitenin bulunduğu standart bir hareket seti 5'er tekrar ile oluşturulmuş ve toplamda 2520 adet kayıttan oluşan bir ver tabanı oluşturulmuştur. Sınıflandırıcıların eğitim ve test süreçlerindeki hesaplamasal yüklerini azaltmak amacı ile göğüs bölgesindeki sensörden elde edilen toplan ivmelenme vektörünün maksimum olduğu noktanın öncesi ve sonrasındaki 2sn'lik kısmına yani 4sn'lik bir kayıta odaklanılmış, daha sonra bu kayıt dosyası üzerine öznelik çıkarım ve azaltım işlemleri uygulanmıştır. Düşme sezme ile ilgili çalışmaların çoğunda sensör çıkışlarının basit eşikleme temeline dayanan kural tabanlı yaklaşımlar kullanılmıştır. Bu çalışmada altı farklı sınıflandırıcı ile düşmeler günlük aktivitelerden başarılı bir şekilde ayrılmıştır. Bu sınıflandırıcılar k en yakın komşu (k-NN), en küçük kareler (LSM), Bayes karar kuralı (BDM), dinamik zaman bükme (DTW) ve yapay sinir ağı (ANN) sınıflandırıcılarıdır. Sınıflandırıcıların performans ve hesaplama yükleri karşılaştırılmış en iyi sonuçlar k-NN ve LSM sınıflandırıcıları ile alınmıştır, duyarlılık, özgüllük, hassasiyet kriterlerinin hepsi %99'un üzerinde bir başarımla elde edilmiştir. Bu sınıflandırıcılar ayrıca eğitim ve test aşamalarında makul bir hesaplama yükü taşırlar. Bizim yaklaşımımız verinin önceden tanımlanmayan bir süre boyunca, pek çok farklı hareketin ard arda yapılması sureti ile kaydedildiği gerçek düşme verilerine de uygulanabilir.

Anahtar Kelimeler: Düşme sezme, ataletsel algılayıcılar, ivme ölçer, jiroskop, magnetometre, sınıflandırma.

ABSTRACT

Falls are a serious public health problem and possibly life threatening for people in fall risk groups. We develop an automated fall detection system with wearable motion sensor units fitted to the subjects' body at six different positions. Each unit comprises three tri-axial devices (accelerometer, gyroscope, and magnetometer/compass). Fourteen volunteers perform a standardized set of movements including 20 voluntary falls and 16 activities of daily living (ADLs), resulting in a large dataset with 2520 trials. To reduce the computational complexity of training and testing the classifiers, we focus on the raw data for each sensor in a 4 s time window around the point of peak total acceleration of the waist sensor, and then perform feature extraction and reduction. Most earlier studies on fall detection employ rule-based approaches that rely on simple thresholding of the sensor outputs. We successfully distinguish falls from ADLs using six machine learning techniques (classifiers): the k-nearest neighbor (k-NN) classifier, least squares method (LSM), support vector machines (SVM), Bayesian decision making (BDM), dynamic time warping (DTW), and artificial neural networks (ANNs). We compare the performance and the computational complexity of the classifiers and achieve the best results with the k-NN classifier and LSM, with sensitivity, specificity, and accuracy all above 99%. These classifiers also have acceptable computational requirements for training and testing. Our approach would be applicable in real-world scenarios where data records of indeterminate length, containing multiple activities in sequence, are recorded.

Key Words: Fall detection, inertial sensors, accelerometer, gyroscope, magnetometer, classification.

GENEL BİLGİLER

Bu çalışmada içerisinde eylemsizlik ve manyetik algılayıcılar bulunan Xsens Technologies firmasına ait kablosuz 6 adet sensör grubundan oluşan giyilebilir bir set kullanılarak içlerinde 20 adet düşme ve 16 adet günlük aktivitenin yer aldığı bir dizi test 7 erkek ve 7 kadın gönüllüden oluşan bir deney grubu ile yürütülmüştür. Her bir gönüllü testleri 5 tekrardan oluşacak şekilde yapmış ve toplamda 2520 adet aktivite verisi oluşturulmuştur. Bu giyilebilir sensör grubunun her birinde 3 eksende ivmelenme, üç eksende jiroskop, 3 eksenle dünyanın manyetik alanı bilgisi ve barometrik atmosfer basıncı bilgilerini üreten sensörler bulunmaktadır. Ayrıca gönüllüler testleri yürütürken hareketler sonucu oluşan seslerin de kayıt edilmesi amacı ile bir kablosuz mikrofon kullanılmıştır. Ancak çalışma sonucunda barometrik basınç ve ses bilgilerinin aktivitelerin ayrıştırılmasında tanımlayıcı bilgiler elde etmediği tespit edilmiş ve sınıflandırma algoritmalarında bu veriler kullanılmamıştır. Çalışma sonucunda toplam 6 adet sınıflandırma algoritması başarılı şekilde çalışmaya uygulanmış ve herbirinden %95'in üzerinde doğruluklar elde edilerek düşmeler günlük aktivitelerden ayırt edilmiştir. Bu sınıflandırma algoritmaları en yakın komşu (k-nearest neighbor, k-NN) , en küçük kareler yöntemi (least squares method, LSM), destek vektör makineleri (support vector machines, SVM), Bayes karar kuralı (Bayesian decision making, BDM), dinamik zaman bükülmesi (dynamic time warping, DTW) ve yapay sinir ağları (artificial neural networks, ANNs) yöntemleridir.

6 adet sensörün düşme risk grubu içerisinde yer alan bireyler tarafından kullanılmasının zor olacağı için çalışma içerisinde ayrıca 5 sensörlü, 4 sensörlü, 3 sensörlü, 2 sensörlü ve tek sensörlü konfigürasyonlar incelenmiş ve bel bölgesinde yer alan tek bir sensör ile de sağlıklı sınıflandırma sonuçlarının elde edilebildiği gözlemlenmiştir. Bu çalışmaya ilişkin sonuçlar derlenmiş fakat henüz yayın haline dönüştürülmemiştir ilerleyen zaman içerisinde bu çalışma BAP desteğinden ötürü biriminizin katkısı belirtilerek yayınlanacaktır.

Tek sensör hem maliyetleri düşürmekte hem de sistemin daha kullanışlı olmasını sağlamaktadır. Üzerinde ivmelenme, jiroskop ve magnetometre sensörleri bulunan iPhone marka akıllı bir cep telefonu ile düşme eylemlerinin ayırt edilmesi çalışmaları başlatılmış ve 2 gönüllü ile 36 adet test ortalama 4 tekrardan yapılmıştır. Bu çalışma ile elde edilen veri seti

üzerindeki çalışmalarımız devam etmektedir. Bu kapsamda deney verilerinin toplandığı bir arayüz ve ivme eşiği üzerinden karar veren temel bir algoritma üretilmiştir.

Proje kapsamında önerilen çalışmaların tümü eksiksiz olarak tamamlanmıştır. Mobil telefon üzerindeki uygulama çalışır vaziyette olmasına karşın iyileştirmelere ihtiyaç duymaktadır. Projemiz sonuçlarına ulaşmıştır ancak daha iyileştirme çalışmaları devam edecek ve çalışma derinleştirilecektir. Bu proje çalışmasının en zor aşamasını gönüllülerin bulunması ve deneylerin sürdürülmesi kısmı oluşturmuştur. Çalışma kapsamında 14'ü Xsens MTw kiti ve 2'si Iphone olmak üzere 16 adet gönüllü tarafından oluşturulan verilerin elde edilmesi için 40'dan fazla gönüllü ile çalışılmıştır. Bu gönüllülerin büyük bir kısmı testleri yarıda bırakıp ayrılmış bir kısım gönüllü verisi ise testlerin yanlış yapılması veya hatalı kayıt tutulması gibi teknik sorunlar yüzünden kullanılamamıştır.

Proje sonucunda ataletsel ve magnetik algılayıcılar ile hareket sınıflandırma konusunda bilgi birikimi geliştirilmiş ve çalışmanın sonucunda SCIE ile taranan bir yayın çıkarılmıştır. Şu anda bel bölgesine bağlı tek bir MTw sensör ile %95'in üzerinde doğruluk ile düşme sezme yapan bir algoritma geliştirilmiştir. Ayrıca aynı bölgede yer alan bir Iphone telefon ile hem deney verilerin tutulduğu hem de düşme tespiti yapan birer uygulama oluşturulmuştur. Sonuç olarak proje önerisinde verilen amaçlara ulaşılmıştır.

GİRİŞ

Dünyanın yaşlanan nüfusuyla birlikte, yaşlıların sağlığını korumaya ve durumlarını gözlemleye dönük teknolojiler, literatürde çoklu disiplinli araştırmalarda dikkat çekici bir şekilde artmaya başlamıştır [1,2]. Hızla gelişen teknoloji, gezici ve kablosuz aygıtları günlük yaşamın bir parçası haline getirmiştir. Bu teknolojilerin önemli bir yönü, basit günlük yaşam aktivitelerini (Activities of Daily Living, ADLs) tanımlama, yorumlama ve görüntüleme işlemlerini gerçekleştirebilmesidir. Bu aktivitelerden bazıları, ayakta durma, oturma, uzanma, yürüme, merdiven çıkma, inme ve en önemlisi düşme durumudur. İnsan vücudunda meydana gelen hızlı ağırlık merkezi yer değiştirmesi dengenin bozulmasıyla sonuçlanır ve düşme gerçekleşir. Dünya sağlık örgütü düşmeleri beklenmedik anda istemsiz ve kontrolsüz gerçekleşen ve yerde uzanma ile sonuçlanan olaylar olarak tanımlamaktadır [3].

Düşmeler genellikle günlük aktiviteleri gerçekleştirirken meydana geldiğinden ADL'ler ile aynı yapıya sahip olduğu düşünülmelidir. Düşmeler özellikle 65 yaş üzeri yetişkinler için bir halk sağlığı problemi ve ciddi bir sağlık tehdididir [4]. İstatistiklere göre 65 yaş ve üzeri her üç yetişkinden biri yılda en az bir düşme olayı yaşamaktadır. Bunun yanında çocuklar, işçiler, atletler ile görme, denge, yürüyüş, ortopedik, sinirsel ve psikolojik kusuru bulunan hastalar da düşmelere maruz kalmaktadır. Düşmelerin ana faktörlerini yaşlanma, zihinsel bozulma, sinirsel ve ortopedik hastalıklar, görme ve denge bozuklukları oluşturmaktadır. Yan faktörler ise ilaç kullanımı, kaygan yüzey, zayıf aydınlatma, sabit olmayan halılar, kuvvet kenarları, tuvaletler, elektrik ve güç kabloları, düzensiz yayılmış eşyalar ve merdivenlerdeki engellerdir [5]. Bazı yan faktörler gerekli önlemler alınarak kaldırılabilirken ana faktörler kolayca kaldırılamaz ve tamamiyle önlenemez. Düşme ciddi sağlık problemleri ve maliyetli sonuçlar doğurabileceğinden dolayı ve sağlık harcamalarını azaltabilmek için düşme eyleminin güvenli bir biçimde ve zamanında tespit edilmesi gerekmektedir. Kesin, güvenilir ve sağlıklı gerçek zamanlı çalışan düşme tespit algoritmaları bir zorunluluktur.

Risk grubunda yer alan insanların durumlarını görüntüleme işlemi özel hayatlarına, bağımsızlıklarına müdahale etmeden ve yaşam kalitelerini azaltmadan gerçekleştirilmelidir. Kullanıcı tarafından çalıştırılan (kullanıcı bildireli) düşme tespit sistemleri, kolay kullanıma sahip değildir. Düşme tespit sistemleri tamamiyle otomatik olmalı ve güvenilirliğin artırılabilmesi için bir çok kaynaktan sensör bilgisi ile beslenmelidir. Bu sistemlerin genel yaklaşımı kamera, akustik, basınç, titreşim, güç, kızılötesi, lazer, RFID etiketler gibi sensörleri yaşam alanlarına sabitlemek biçimindedir [6,7]. Akıllı yaşam alanları denilen bu ortamlar genellikle bir veya birkaç sensörün yüksek kurulum ücretleri karşılığında birleştirilmesi ile oluşturulurlar [8]. Bu alanlardaki diğer insanlar veya evcil hayvanlar bu sistemleri harekete geçirebilir ve bu durum yanlış alarmlara sebep olabilmektedir. Bu yaklaşımın en önemli avantajı risk taşıyan kişi üzerinde sensör veya cihaz taşımak zorunda değildir. Bu yaklaşım kullanıcının yaşam alanının binanın yalnızca bazı bölümleri ile sınırlı olduğu durumlarda kabul edilebilir yöntemdir. Bununla birlikte aktivitelerin başka alanlarda gerçekleştirildiği zamanlarda veya bir yerden diğer bir yere gidiş söz konusu olduğunda (araç kullanımı, alışveriş, işe gidiş geliş gibi) bu yaklaşım uygun değildir. Sabitlenmiş sensörler tarafından takip edilen sınırlandırılmış bir çevre, kullanıcının hareket alanını kısıtlamaya zorlamaktadır. Düşme risk grubundaki insanların durumunun görüntülenmesi çalışmaları, başlangıçta bu yaklaşımla gerçekleştirilmesine rağmen, artık pek çok avantajı olan giyilebilir sensörlerin

ticari olarak bulunması, mobil düşme sezme sistemlerinin gelişmesine ön ayak olmuştur. Çoklu hareket sensörlerinden elde edilen tek boyutlu sinyallerin işlenmesi kamera gibi verilerin işlenmesinden daha kolay ve direkt olarak üç boyutlu hareket bilgisini sağlamaktadır. Serbest görüş açısına ihtiyaç duyan görsel hareket yakalama sistemlerinden farklı olarak giyilebilir sensörler, objelerin içerisinde veya arkasında kesintisiz olarak kullanılabilir. Giyilebilir sensörler hafif, rahat ve kolay taşınabilir olduklarından dolayı kısıtlı bir alanda kullanılmak zorunda değildir. Ayrıca bu sistemler bina içerisinde ve dışarıda, birbirini takip eden ardışıl (kendiliğinden gelişen random) aktivitelerin tanımlanmasında kullanılabilir. Gerekli altyapı ve bununla ilgili fiyat, akıllı çevre sistemlerine göre çok düşük olmakla birlikte, kameralar gibi özel yaşamı da ihlal etmezler. Ayrıca bu tür sensör sistemleri akustik sensörlerden farklı olarak ortam gürültülerinden de etkilenmezler. Giyilebilir sensörler otomatik düşme tespit sistemlerinin geliştirilmesi için uygundur. Bu çalışmada, günlük yaşam aktivitelerini gerçekleştirirken meydana gelebilecek düşmelerin sağlıklı ve kesin tespiti sağlanabilmesi ve sınıflandırılması için bu yaklaşımı (giyilebilir sensörlerden oluşan hareket verisi sağlama yöntemi) izledik. Bu tür yapılar ile düşme tespiti [9, 10] nolu çalışmalarda incelenmiştir. Bu alandaki ilk çalışmalar kısıtlı bir ölçekte ve sistematik değildi. Araştırmacılar arasında ortak bir zeminin bulunmaması yayınların sonuçlarının kıyaslanmasını, sentezlenmesini ve yaygın etkiye sahip çözümlerin oluşturulmasını engellemektedir. Literatürdeki çalışmalara bakıldığında sensörlerin konfigürasyonu, çalışmada yer alan gönüllü sayısı ve karakteristiği, incelenen düşme biçimi ve aktiviteler, özellik çıkarım teknikleri ve elde edilen dataların işleme biçimi farklıdır [11-14]. Bir çok çalışmada gönüllü (taklit edilen) düşmeler üzerinden araştırma gerçekleştirdiğinden, ancak çok kısıtlı sayıda istemsiz (gerçek) düşme kaydedilmiştir [15-17]. İstemsiz düşmelerin incelenmesi zor ve zaman alıcı bir işlemdir [16]. Az sayıdaki kaydedilmiş gerçek düşme ise nadir görülen hastalıklara sahip kişilerden elde edilmiştir ki bu çalışmalar ile elde edilen düşme sezme yöntemi bütün risk gruplarına genelleştirilemezler.

Bir çalışmada düşmeleri de kapsayan altı aktiviteyi ayırt etmek için kızılötesi hareket sensörlerinden elde edilen verinin makine öğrenme teknikleri yorumlandığı bir düşme sezme sistemi geliştirilmiştir [18]. Vektör destek makinelerini (Support Vector Machine, SVM) yöntemi ile düşme sezme çalışmaları [19, 20] belirtilmiştir. Güncel çalışmalarda, bilgisayar tabanlı normal RGB renk bilgisi ile derinlik haritasını birleştiren, kameralı düşme tanımlama sistemleri önerilmiştir. Bu birleşim sayesinde derinlik haritasının hataları azaltılıp, sahne ile

ilgili daha fazla bilgi sağlanması ile daha başarılı düşme sezme işlemi yapılmıştır. Elde edilen veriye SVM uygulanarak düşmeler tanımlanıp günlük yaşam aktivitelerinden %95 üzeri doğruluk ile ayırıt ve tespit edilmiştir.

Sağlıklı ve güvenilir düşme tespitinin gerçekleştirilmesi ve farklı çalışmalar ile kıyaslama yapılabilmesi için, standartlaştırılmış deneysel prosedürlerden elde edilen açık (ortak kullanıma açık) datasetleri gereklidir. Bu alanda düşme deneylerini anahatlarını tanımlayan üç çalışma tespit ettik [21-23] ancak literatürde sadece bir çalışmanın standart veri seti oluşturarak sonuçlar ürettiğini gördük [8]. [23] nolu çalışmada literatürde düşmeler için açık bir veri tabanı olmadığı ve deneylerde kullanılacak düşmelerin yapısı ve karakteristiğinin tanımlanmadığı ifade edilmiştir.

Düşme sezme alanında bazı patent ve ticari cihazlar bulunmasına rağmen, bu cihazlardan elde edilen sonuçlar tatmin edici seviyede değildir [22]. Bunun temel sebebi ise cihazlardaki yüksek yanlış alarm sayısı, yüksek başlangıç ve bakım giderleri ve ergonomi problemleridir. Giyilebilir düşme tespit sistemlerinin eleştirilen yönleri ise kullanıcıların bu sensörleri giymeyi unutması, ihmal etmesi veya giymek istememeleridir. Eğer bu sensörlere batarya aracılığıyla güç veriliyorsa bunların zaman zaman şarj edilmesi ve gerektiğinde değiştirilmeleri icap etmektedir. Ayrıca MEMS (Micro Electro Mechanical Sensors) teknolojisinin gelişimi ile birlikte, bu cihazlar küçülmeye başlamış, kapsamı genişlemiş ve ucuzlamıştır. Bunlar kolaylıkla alarm sistemlerine veya insanların taşıdığı aksesuarlara entegre edilebilir durumdadır. Hafif olmaları, az güç tüketmeleri ve kablosuz kullanıma uygun olmaları, taşınabilir olmama ve rahatsız edicilik gibi dezavantajları ortadan kaldırmaktadır. Bununda ötesinde gömülü ivme ölçer bulunduran akıllı telefonlar, düşme tespit algoritmalarının uygulanması için uygundur [24-26].

Bu çalışma günlük yaşam aktivitelerini (ADL) gerçekleştirirken meydana gelebilecek olan düşmeleri (FALL) sağlıklı ve kesin bir biçimde giyilebilir sensörlerle ve makine öğrenme teknikleri aracılığıyla tespit etmeyi amaçlamaktadır. Sensör eşik değerlerine dayanan (bu alandaki ilk çalışmalarda yapıldığı gibi) basit kural tabanlı algoritmalar yerine, toplam ivmelenmenin tavan yaptığı noktalardaki kaydedilmiş sinyallerin özelliklerini kullandık. [23]'deki çalışma referans alınarak algoritmaların geliştirilebilmesi amacıyla, yeterli

miktardaki veriyi elde edebilmek için çalışmamızı istemli (taklit edilen) düşmelerle sınırlandırdık.

Bu çalışmanın geri kalanı şu şekilde organize edilmiştir: Gereç yöntem kısmında, verilerin elde edilmesi açıklanmış ve kısaca altı makine öğrenme tekniğine değinilmiştir. Bulgular kısmında, aynı tekniklerin performans ve hesaplama gereksinimlerini kıyasladık. Tartışma bölümünde sonuçlar yorumlanmış ve Sonuç kısmında ise elde edilen neticeler belirtilip çalışmaların hangi doğrultuda ilerlemesi gerektiği açıklanmıştır.

GEREÇ VE YÖNTEM

2.1 Veri Kazanılması

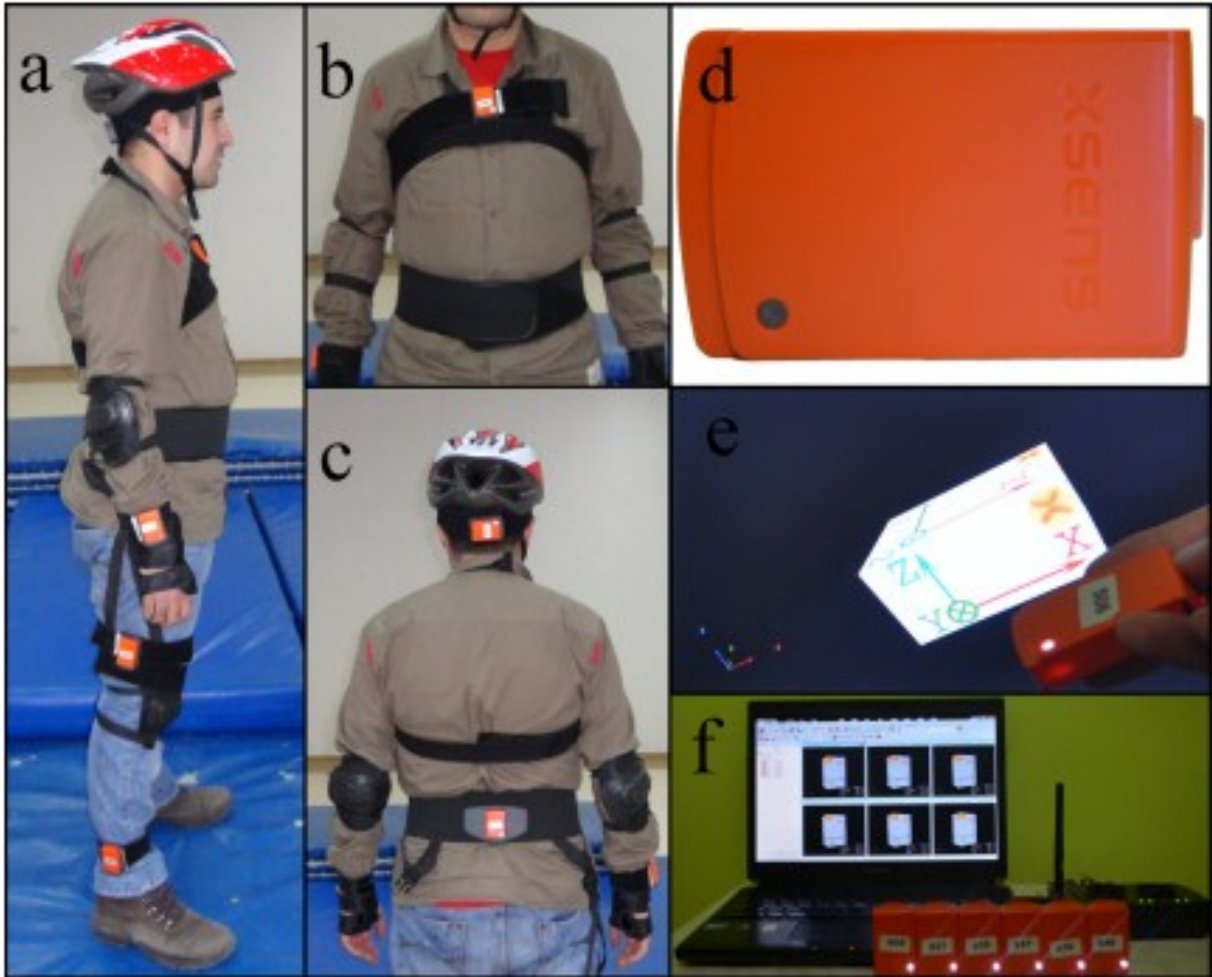
Xsens Technologies firması tarafından üretilmiş, MTw geliştirme kitinin bir parçası olan altı adet MTw sensör ünitesi kullanılmıştır [27]. Her bir ünite üç eksenli sensörlerden oluşmaktadır (ivme ölçer, jiroskop, manyetometre/pusula), bunlar sırasıyla $\pm 120\text{m/s}$, $\pm 1200^\circ/\text{s}$, ± 1.5 Gauss sahasındadır. Ayrıca sensör kiti içerisinde bu çalışmada kullanmadığımız 300-1100hPa sahasında çalışan atmosferik basınç ölçer de bulunmaktadır. Herbir gönüllü deneye başlamadan önce sensörler kalibre edilmiştir ve 25Hz frekansında ham data kazanılmış ve kaydedilmiştir. Üç düşey eksen boyunca (x,y,z) ivmelenme, dönüş hızı ve dünyanın manyetik alanının gücü herbir ünite için kaydedilmiştir. Ölçümler bir RF bağlantısı (ZigBee) aracılığıyla bilgisayara USB arayüzü ile bağlı olan Xsens Awinda istasyonu tarafından transfer edilmiştir.

2.2 Deneysel Prosedür

Düşme deneylerinin tasarımında [23]'de yer alan makalenin sağladığı anahatlarını takip ettik. Erciyes Üniversitesi Etik Kurulu Onayı ile yedi sağlıklı erkek gönüllü (24 ± 3 yaş, 67.5 ± 13.5 kg, 172 ± 12 cm) ve yedi sağlıklı kadın gönüllü (21.5 ± 2.5 yaş, 58.5 ± 11.5 kg, 169.5 ± 12.5 cm) kendilerine okutulan yazılı bir bilgilendirilmiş gönüllü olur formu ile çalışmaya dahil edilmiştir. Testler Erciyes Üniversitesi Klinik Araştırma Merkezinde gerçekleştirilmiştir. Altı adet sensör özel bağlantı aparatları ile gönüllünün baş, göğüs, bel, sağ bilek, sağ baldır, sağ ayak bileğine bağlanmıştır (Şekil 1). Kablolü sistemlerden farklı olarak kullandığımız kablosuz veri kazanımı sistemi sayesinde gönüllülerin testler boyunca daha doğal hareket etmesi sağlanmıştır. Gönüllüler kask, bileklik, diz ve dirsek koruyucu kullanmakta ve

aktiviteler sakatlıkları önlemek için yumuşak bir döşek (mat) üzerinde gerçekleştirilmektedir. Her bir test verisi ortalama 15 s uzunluğundadır.

Şekil 1. (a-c) altı MTw ünitesinin gönüllünün vücuduna yerleştirilmesi; **(d)** Tek MTw ünitesi, herbiri üç eksenli ihtiva eden cihaz üç farklı (ivme ölçer, jiroskop, manyetometre) sensör ve bir adet atmosferik basınç sensörü grubu; **(e)** MTw ünitesinin üç düşey eksenli; **(f)** Bilgisayar, Awinda istasyonu ve altı MTw ünitesi.



[23]'den uyarlanmış bir test seti, 20 düşme eyleminden ve 16 günlük yaşam aktivitesinden (Tablo 1) oluşmakta; 14 gönüllü herbir seti beş kez tekrarlamaktadır. Böylelikle yeterli çeşitlilikte aktiviteden oluşan bir veriseti elde edilmiştir, bu aktiviteler 1400 düşme (20 çeşit düşme \times 14 gönüllü \times 5 tekrar) ve 1120 günlük aktivite (16 ADL \times 14 gönüllü \times 5 tekrar), toplamda 2520 adet testten oluşmaktadır. Verisetimizde yer alan düşme olmayan eylemlerin çoğu kolaylıkla düşme ile karıştırılabilecek hareketlerden meydana gelmektedir. Böyle bir

verisetti düşme tespit testleri/geçerlilikleri ve sınıflandırma algoritmaları için kullanışlı ve güvenilirdir.

2.3 Öznitelik Seçme ve Boyut Azaltma

Bu alandaki ilk düşme tespit çalışmalarında basit ve hesaplama (karar) süresinin az olmasından dolayı genellikle sensörlerin (hızlanmalar, dönüş hızları gibi) çıkış seviyelerinin eşik değerlerinin kıyaslanması yöntemi kullanılmıştır. Bu yaklaşım bir çok farklı düşme tipinin bulunması ve her düşmenin doğasının farklı olmasından dolayı yeteri kadar sağlıklı ve güvenilir sonuçlar üretmektedir. Dahada ötesi günlük yaşam aktiviteleri kolaylıkla düşmelerle karıştırılabilir. Bu durum yanlış alarmlara neden olmaktadır. Bazı yavaş düşmeler ise ki bu durum daha tehlikelidir, kaçırılabilir. Daha sağlıklı sonuçlar üretmek için toplam ivmelenme vektörü (TAV) indeksi kullanılarak, kayıtlı sinyallerin detaylı öznitelikleri çıkarılmıştır.

$$TAV = \sqrt{A_x^2 + A_y^2 + A_z^2} \quad (1)$$

Burada A_x , A_y ve A_z sırasıyla x, y, z eksenlerinin ivmelenmelerini temsil etmektedir. Öncelikle bel bölgesinde bulunan ivme ölçerin her bir kayıt içerisinde maksimum TAV değerine karşılık gelen zaman indeksi tanımlanır. Daha sonra bu nokta etrafındaki iki saniyelik aralıklar alınır ($25 \text{ Hz} \times 2 \text{ s} = 50$ örnek). TAV maksimum değerinden önceki ve sonraki iki saniyelik 101 örneği içeren ($50 + \text{TAV indeks} + 50$) veri alınır kayıtların geri kalanı ihmal edilir. Bütün deney verisi bel bölgesindeki TAV indeksine göre aynı yöntem kullanılarak kısaltılır, böylelikle her bir sensör için deney başına 101×9 boyutlu bir veri matrisi elde edilir. Veri matrisi içerisindeki herbir veri kolonu $N \times 1$ boyutlu bir vektör olarak temsil edilir, $N=101$ iken $s = [s_1, s_2, \dots, s_N]^T$ 'dir. Bu matris içerisinde seçilen detaylı öznitelikler ise minimum, maksimum ve ortalama değerler, varyans, eğrilik, kurtosis, otokorolasyon dizisinin ilk 11 elemanı ve ayrık Fourier dönüşümünün (DFT) ilk beş değeri ile bunlara karşılık gelen genlik tepe değerleridir.

$$\begin{aligned} \text{mean}(s) &= \mu = \frac{1}{n} \sum_{i=1}^n d_i \\ \text{variance}(s) &= \sigma^2 = \frac{1}{n} \sum_{i=1}^n (d_i - \mu)^2 \\ \text{skewness}(s) &= \frac{1}{n\sigma^3} \sum_{i=1}^n (d_i - \mu)^3 \quad (2) \\ \text{kurtosis}(s) &= \frac{1}{n\sigma^4} \sum_{i=1}^n (d_i - \mu)^4 \\ \text{autocorrelation}(s) &= \frac{1}{n-\Delta} \sum_{i=0}^{n-\Delta-1} (d_i - \mu) - (d_{i-\Delta} - \mu) \\ &\Delta = 0, 1, \dots, n-1 \\ \text{DFT}q(s) &= \sum_{i=0}^{n-1} d_i e^{-j2\pi ki/n}, k = 0, 1, \dots, n-1 \end{aligned}$$

Burada, DFTq(s), N noktalı tek boyutlu DFT dönüşümünün q'üncü elemanıdır.


Toplamda 15,120 (36 hareket × 14 gönüllü × 5 tekrar × 6 sensör) kayıttan oluşan verisetinden öznitelik çıkartım işlemini gerçekleştirdik. Sensörlerin herbir ekseninden elde edilen ilk 5 özellik minimum, maksimum, ortalama, eğrilik ve kurtosis değerleridir. Her sensor ünitesinde 9 eksen bulunduğundan 45 özellik (9 eksen × 5 değer) elde edilmiştir. Otokorolasyon işleminden 99 adet öznitelik (9 eksen × 11 özellik) üretmektedir. DFT işleminden ise 5 frekans ve 5 genlik değeri ile toplamda 90 öznitelik (9 eksen × 10 değer) üretmektedir. Böylelikle herbir sensor ünitesinden 234 (45 + 99 + 90) adet öznitelik elde edilmiştir. Toplamda ise her bir deneme sonrasında 1404 × 1 (=234 öznitelik × 6 sensors) boyutlu bir öznitelik vektörü oluşmaktadır.

Table 1. Fall and non-fall actions (ADLs) considered in this study.

Fall Actions		
#	Label	Description
1	front-lying	from vertical falling forward to the floor
2	front-protecting-lying	from vertical falling forward to the floor with arm protection
3	front-knees	from vertical falling down on the knees
4	front-knees-lying	from vertical falling down on the knees and then lying on the floor
5	front-right	from vertical falling down on the floor, ending in right lateral position
6	front-left	from vertical falling down on the floor, ending in left lateral position
7	front-quick-recovery	from vertical falling on the floor and quick recovery
8	front-slow-recovery	from vertical falling on the floor and slow recovery
9	back-sitting	from vertical falling on the floor, ending sitting
10	back-lying	from vertical falling on the floor, ending lying
11	back-right	from vertical falling on the floor, ending lying in right lateral position
12	back-left	from vertical falling on the floor, ending lying in left lateral position
13	right-sideway	from vertical falling on the floor, ending lying
14	right-recovery	from vertical falling on the floor with subsequent recovery
15	left-sideway	from vertical falling on the floor, ending lying
16	left-recovery	from vertical falling on the floor with subsequent recovery
17	syncope	from standing falling on the floor following a vertical trajectory
18	syncope-wall	from standing falling down slowly slipping on a wall
19	podium	from vertical standing on a podium going on the floor
20	rolling-out-bed	from lying, rolling out of bed and going on the floor
Non-Fall Actions (ADLs)		
#	Label	Description
21	lying-bed	from vertical lying on the bed
22	rising-bed	from lying to sitting
23	sit-bed	from vertical to sitting with a certain acceleration onto a bed (soft surface)
24	sit-chair	from vertical to sitting with a certain acceleration onto a chair (hard surface)
25	sit-sofa	from vertical to sitting with a certain acceleration onto a sofa (soft surface)
26	sit-air	from vertical to sitting in the air exploiting the muscles of legs
27	walking-fw	walking forward
28	jogging	running
29	walking-bw	walking backward
30	bending	bending about 90 degrees
31	bending-pick-up	bending to pick up an object on the floor
32	stumble	stumbling with recovery
33	limp	walking with a limp
34	squatting-down	squatting, then standing up
35	trip-over	bending while walking and then continuing walking
36	coughing-sneezing	coughing or sneezing

Bu öznelik veriseti oldukça büyük olduğundan (1404) ve bütün öznelikler düşmeler ile günlük yaşam aktivitelerini ayırt etmekte eşit oranda başarılı olmadığından, sınıflandırıcı testlerinin ve çalışmaların hesaplama karmaşıklığını azaltmak için 1404 olan öznelik sayısını $M=30$ 'a [28]'de yer alan Temel Bileşen Analizi (Principal Component Analysis, PCA) yöntemine göre azaltılmış ve 0 ile 1 arasında normalize edilmiştir. PCA, özneliklerin optimum lineer kombinasyonlarını bulan bir dönüşümdür. Öznelik vektörünün azaltılmış boyutları, Şekil 2a'da gösterildiği gibi 1404×1 adet öznelik vektörünün, kovaryans matrisin eigen değerlerinin gözlemlenmesi ile belirlenmiştir. İlk 30 temel bileşen toplam varyansının %72.38'ni temsil etmektedir (Şekil 2b). Transformasyon matrisi oluşturmak için 30×1 öznelik vektörü kullanılmıştır.

Figure 2. (a) All eigenvalues (1404) and (b) the first 50 eigenvalues of the covariance matrix sorted in descending order.



2.4 Makine Öğrenme Teknikleri Kullanılarak Sınıflandırma

Güvenilir bir düşme tespit sisteminin iyi tasarlanmış, hızlı, etkili ve ikili sistemde (binary) düşme olayının olup olmadığına karar vereceğinden sağlıklı algoritmalara sahip olması gerekmektedir. Bir sınıflandırıcının başarımı aşağıdaki kriterler uyarınca hesaplanır:

Sensitivity (Se) düşme tespiti için sistem kapasitesidir ve toplam düşmeler içindeki doğru pozitif (TP, true positive) değerlerin oranına tekabül etmektedir:

$$Se = \frac{TP}{TP + FN} \times 100 \quad (3)$$

Specificity (Sp) düşme oluştuğu anda tespit eden sistemin kapasitesidir:

$$Sp = \frac{TN}{TN + FN} \times 100 \quad (4)$$

Doğruluk (Acc) düşme ve düşme olmayan eylemler arasındaki kesin ayrıma tekabül etmektedir:

$$Acc = \frac{TP + TN}{TP + FN + TN + FP} \times 100 \quad (5)$$

Burada TP (düşme gerçekleşir; algoritma tespit eder), TN (düşme gerçekleşmez; algoritma tespit etmez), FP (düşme gerçekleşmez fakat algoritma düşme rapor eder), ve FN (düşme gerçekleşir fakat algoritma kaçırır) sırasıyla gerçek pozitif ve negatif, yanlış pozitif ve negatif olan sayılardır. Sensitivity ile specificity arasında ters bir ilişki bulunmaktadır. Örneğin, tek bir seviye değerine sahip olan bir algortmada, seviye değeri düştükçe FN değeri düşer ve algoritmanın duyarlılığı artmar. Diğer taraftan, FP oranı artarken ve specificity azalmaktadır. Seviye değeri arttıkça, tam zıt durum gerçekleşir: sensitivity azalırken specificity artar. Bu tanımlamalara dayanarak FP ve FN oranı şu şekilde elde edilebilir:

$$FP \text{ ratio} = 1 - Sp$$

$$FN \text{ ratio} = 1 - Se$$

Bu çalışmada, düşmeleri günlük yaşam aktiviteleriyle birlikte düşündük çünkü, düşmeler genellikle günlük aktiviteleri gerçekleştirilirken beklenmeden oluşur. İdeal bir düşme tespit sistemi özellikle yüksek ivmelenme ihtiva eden (şıçrayış, ani oturuş gibi) günlük yaşam aktivitelerinden düşmeleri ayırt edebilmelidir. Algoritmalar yeteri kadar sağlıklı, zeki ve FP ve FN'leri minimize etmek için duyarlı olmalıdır. Yanlış alarmlara, yanlış sınıflandırılmış (günlük aktivite düşme olarak yorumlanmış) günlük yaşam aktiviteleri sebep olmaktadır. Bununla birlikte düşmeler yanlışlıkla günlük yaşam aktivitesi olarak sınıflandırılmamalıdır. FN'ler, kaçırılmış düşmeleri ifade eder, düşme sonucunda fiziksel veya zihinsel bozukluk gerçekleştiğinde kullanıcı müdahalesi gerçekleştiremeyeceğinden bu durumdan kaçınılmalıdır. Yani düşmelere bağlı bilinç kaybı veya bilinç kayıplarına bağlı düşmelerde kişi durumunu bildiremez. Örneğin, uzun süreli hareketsizlikler (düşme ile sonuçlanmış durumlarda da olabileceği gibi) uyuma ile veya dinlenme ile karıştırılabilir.

Bu çalışmada altı makine öğrenme tekniği kullanılarak düşmeler gerçek yaşam aktivitelerinden ayıt ediliyor ve performansları sensitivite, specificity, doğruluk ve işlemsel karmaşıklığa göre kıyaslanıyor. Çalışma ve testlerde verisetini p=10 olmak üzere eşit parçalar halinde rasgele 10 parçaya böldük. Bu parçalardan p-1 tanesini eğitimlerde kullandık ve kalan parçayı ise test için ayırdık. Sonuçları doğrulamak ve veriseti içindeki bütü kayıtların değerlendirmeye tabii tutulmasını sağlamak amacı ile bu işlemlerin tümü 10 defa tekrar edilmiştir.

2.4.1 k En Yakın Komşuluk Yöntemi (k-NN)

k-NN yönteminde verilen bir nesne en yakın eğitim nesnelere göre sınıflandırılır [28]. Sınıf kararı k adet komşuluk içerisinde en yüksek oranı gerçekleştiren komşuluk ile yapılır burada $k > 0$ durumu geçerlidir. k -NN algoritmasında standart bir k değeri bulunmamaktadır çünkü bu değer lokal veriye bağlıdır. Küçük k değerleri varyansı arttıracığından sonuçlar daha az stabil olmakta, büyük k değerleri ise biası artırıp duyarlılığı azaltmaktadır. Bunların yanında uygun olan k değerinin seçimi verisetine bağlıdır. Bu çalışmada kullandığımız verisetimize ile deneysel olarak $k=7$ olarak belirledik.

2.4.2 En Küçük Kareler Yöntemi (LSM)

LSM'de iki ortalama referans vektörü düşmeler ve günlük yaşam aktivitelerine tekabül eden iki sınıf için hesaplandı [28]. Verilen test vektörü $x = [x_1, \dots, x_m]^T$ referans vektörü ile kıyaslanmış $r_i = [r_{i1}, \dots, r_{im}]^T$, $i=1,2$ ve ikisi arasındaki karelerinin farkının toplamı alınarak:

$$E_i^2 = \sum_{m=1}^M (x_m - r_{im})^2$$

sınıf kararı E_i^2 değerinin minimize edilmesi ile bulunmuştur.

2.4.3 Destek Vektör Makinesi (SVM)

Başlangıç katsayı seti ve kernel modeli SVM'lerin çıkışlarının sınıflandırmasını etkilemektedir. Eğitim verisi $(x_j, l_j)_{j=1, \dots, J}$ J uzunluğundadır $x_j \in \mathbb{R}^N$, iki sınıf için (düşme ve ADLs) sınıf etiketi ise $l_j \in \{1, -1\}$ aralığındadır. MATLAB'da LIBSVM adı verilen bir toolboxda yer alan SVM kütüphanesinden radyal tabanlı bir kernel fonksiyonu kullandık $K(x, x_j) = e^{-\gamma \|x - x_j\|^2}$, burada $\gamma=0.2$ dir.

2.4.4. Bayes Karar Kuralı (BDM)

BDM istatistiksel örüt sınıflandırmasında kullanılan sağlıklı sonuçlar üreten ve çok tercih edilen bir yaklaşımdır. BDM'de olasılık için, parametreleri μ 'nın ortalaması olan ve her bir sınıf için çalışma matris C 'nin kovaryansı olan, normal yoğunluklu diskriminant fonksiyonunu kullandık. bunlar iki sınıfın ve her katmanın sabitine göre elde edilen çalışma kayıtlarından hesaplanmıştır. Verilen bir vektör x daha yüksek olasılığa sahip bir sınıfa atanma biçimi aşağıdaki gibi hesaplanmıştır [28]:

$$\mathcal{L}_{(\text{class } i)} = -\frac{1}{2} \{(\mathbf{x} - \boldsymbol{\mu}_i)^T \mathbf{C}_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) + \log[\det(\mathbf{C}_i)]\} \quad i = 1, 2 \quad (7)$$

2.4.5. Dinamik Zaman Bükülmesi (DTW)

DTW ard arda iki zaman arasında, hızda veya zamanda meydana gelebilecek değişimlerin benzerlik ölçümünü sağlar [30]. Sıralamalar, test vektörü ile depolanmış referans vektörü arasındaki en az yoğunluklu çarpım yolunu bulmak için zamanda nonlineer olarak çarpılmaktadır. Genellikle, Euclidean uzaklığı test vektörü ile referans vektörü arasında elementler arası yoğunluğu bulmak için kullanılır. DTW, farklı konuşma hızlarından ses tanımlama işlemlerinde, imza tanımlama, ECG sinyal sınıflandırma, parmak izi doğrulama, tarihsel dökümanlarda el yazısı kelimelere odaklanma işlemlerinde kullanılmaktadır. Burada, DTW hareket sensörlerindeki sinyallerden çıkarılan farklı aktiviterden elde edilen öznelik vektörlerinin sınıflandırılmasında kullanılmıştır.

2.4.6. Yapay Sinir Ağları (ANNs)

ANN'ler girişleri yoğun bağlantılar üzerinden alan bağımsız işlem üniteleri setinden oluşmaktadır [31]. Bu çalışmada giriş ve gizli katmanında 30, çıkış katmanında ise tek nöron bulunan 3 katmanlı bir ANN gerçekleştirdik. Gizli katmanda sigmoid aktivite fonksiyonunu kullandık. Çıkış nöronunda sınıf kararını aşağıdaki kurala göre gerçekleştiren purelin lineer fonksiyonunu kullandık:

eğer $\text{OUT} \geq 0.5$ ise ADL, değilse FALL

MATLAB ortamında Neural Networks Toolbox aracılığıyla Levenberg-Marquardt algoritması kullanarak bir ANN oluşturulmuştur.

BULGULAR

Bu çalışma için kullanılan çerçeve özne bağımsızdır; her özne için ayrı sınıflandırıcı tasarlamak yerine, sınıflandırıcılar bütün verisetine uygulanmıştır. Tablo 2'de altı farklı sınıflandırıcının sonuçlarının toplu olarak kıyaslaması verilmiştir. k -NN sınıflandırıcısı en yüksek doğruluğu vermektedir (%99.91), daha sonra sırasıyla LSM, SVM, BDM, DTW ve ANN gelmektedir. k -NN yöntemi %100 sensitiviteye sahiptir ve bu oran düşmelerin kesinlikle kaçırılmadığını göstermektedir. Bununla birlikte 2520 deneme ve 10 turdan (Tablo 3) oluşan çalışmada üç adet ADL yanlış sınıflandırılmıştır. Sınıflandırıcıların 10 turluk ortalama

doğrulukları ve standart farkları Tablo 3’de verilmiştir. k -NN ve LSM sınıflandırıcıları düşmeleri hiç kaçırmadığından bunların güvenilir sınıflandırıcılar olduğunu düşünüyoruz. Sınıflandırıcıların ROC eğrileri Şekil 3’te verilmiştir.

Figure 3. ROC curves for some of the classifiers.




Table 2. Comparison of the results and the computational requirements of the six machine learning techniques in terms of the training and testing times for a single fold (P: positive, N: negative).

	k-NN		LSM		SVM		BDM		DTW		ANN	
Confusion Matrices												
	P	N	P	N	P	N	P	N	P	N	P	N
True P	1400	0	1400	0	1393.9	6.1	1398	2	1381.4	18.6	1364.6	35.4
True N	2.3	1117.7	8.7	1111.3	7	1113	16.7	1103.3	35.5	1084.5	73.5	1046.5
Se (%)	100		100		99.56		99.86		98.67		97.47	
Sp (%)	99.79		99.22		99.38		98.51		96.83		93.44	
Ace (%)	99.91		99.65		99.48		99.26		97.85		95.68	
Computational Time (ms)												
Training	318.2		2.2		893.7		1.9		2.5		10,089.0	
Test	76.6		32.7		16.2		72.6		33,816.6		13.5	

Table 3. Classifier results over 10 successive rounds. AVG: average, STD: standard deviation (continued).

Run	1	2	3	4	5	6	7	8	9	10	AVG	STD
<i>Se</i> (%)	100	100	100	100	100	100	100	100	100	100	100	0
<i>Sp</i> (%)	99.73	99.82	99.82	99.73	99.73	99.82	99.82	99.82	99.82	99.82	99.79	0.0431
<i>Acc</i> (%)	99.88	99.92	99.92	99.88	99.88	99.92	99.92	99.92	99.92	99.92	99.91	0.0192
TN	1117	1118	1118	1117	1117	1118	1118	1118	1118	1118	1117.7	0.4830
FP	3	2	2	3	3	2	2	2	2	2	2.3	0.4830
TP	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	0
FN	0	0	0	0	0	0	0	0	0	0	0	0

(a) *k*-NN

Run	1	2	3	4	5	6	7	8	9	10	AVG	STD
<i>Se</i> (%)	100	100	100	100	100	100	100	100	100	100	100	0
<i>Sp</i> (%)	99.29	99.29	99.20	99.20	99.20	99.11	99.11	99.38	99.20	99.29	99.22	0.0847
<i>Acc</i> (%)	99.68	99.68	99.64	99.64	99.64	99.60	99.60	99.72	99.64	99.68	99.65	0.0376
TN	1112	1112	1111	1111	1111	1110	1110	1113	1111	1112	1111.3	0.9487
FP	8	8	9	9	9	10	10	7	9	8	8.7	0.9487
TP	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	0
FN	0	0	0	0	0	0	0	0	0	0	0	0

(b) LSM

Run	1	2	3	4	5	6	7	8	9	10	AVG	STD
<i>Se</i> (%)	99.64	99.50	99.64	99.57	99.50	99.57	99.50	99.50	99.57	99.64	99.56	0.0625
<i>Sp</i> (%)	99.46	99.29	98.93	99.46	99.46	99.55	99.29	99.55	99.29	99.46	99.38	0.1882
<i>Acc</i> (%)	99.56	99.40	99.33	99.52	99.48	99.56	99.40	99.52	99.44	99.56	99.48	0.0825
TN	1114	1112	1108	1114	1114	1115	1112	1115	1112	1114	1113	2.1082
FP	6	8	12	6	6	5	8	5	8	6	7	2.1082
TP	1395	1393	1395	1394	1393	1394	1393	1393	1394	1395	1393.9	0.8756
FN	5	7	5	6	7	6	7	7	6	5	6.1	0.8756

(c) SVM

Run	1	2	3	4	5	6	7	8	9	10	AVG	STD
<i>Se</i> (%)	99.86	99.86	99.86	99.86	99.86	99.86	99.86	99.86	99.86	99.86	99.86	0
<i>Sp</i> (%)	98.57	98.57	98.48	99.48	98.39	98.57	98.48	98.57	98.48	98.48	98.51	0.0603
<i>Acc</i> (%)	99.29	99.29	99.25	99.25	99.21	99.29	99.25	99.29	99.25	99.25	99.26	0.0268
TN	1104	1104	1103	1103	1102	1104	1103	1104	1103	1103	1103.3	0.6749
FP	16	16	17	17	18	16	17	16	17	17	16.7	0.6749
TP	1398	1398	1398	1398	1398	1398	1398	1398	1398	1398	1398	0
FN	2	2	2	2	2	2	2	2	2	2	2	0

(d) BDM

Table 3. Cont.

Run	1	2	3	4	5	6	7	8	9	10	AVG	STD
Se (%)	98.71	98.71	98.79	98.79	98.57	98.64	98.79	98.43	98.50	98.79	98.67	0.1313
Sp (%)	97.79	97.96	97.23	97.14	96.61	97.23	96.96	96.61	96.25	96.52	96.83	0.3321
Acc (%)	97.86	97.94	98.10	98.06	97.70	98.02	97.98	97.62	97.50	97.78	97.85	0.1992
TN	1084	1086	1089	1088	1182	1089	1086	1082	1078	1081	1084.5	3.7193
FP	36	34	31	32	38	31	34	38	42	39	35.5	3.7193
TP	1382	1382	1383	1383	1380	1381	1383	1378	1379	1383	1381.4	1.8379
FN	18	18	17	17	20	19	17	22	21	17	18.6	1.8379

(e) DTW

Run	1	2	3	4	5	6	7	8	9	10	AVG	STD
Se (%)	97.64	97.93	96.57	98.00	97.29	97.50	97.86	97.00	97.21	97.71	97.47	0.4545
Sp (%)	93.39	93.21	94.11	93.75	92.86	93.57	93.84	94.38	92.86	92.41	93.44	0.6132
Acc (%)	95.73	95.83	95.48	96.11	95.32	95.75	96.07	95.83	95.28	95.36	95.68	0.3048
TN	1046	1044	1054	1050	1040	1048	1051	1057	1040	1035	1046.5	6.8678
FP	74	76	66	70	80	72	69	63	80	85	73.5	6.8678
TP	1367	1371	1352	1372	1362	1365	1370	1358	1361	1368	1364.6	6.3631
FN	33	29	48	28	38	35	30	42	39	32	35.4	6.3631

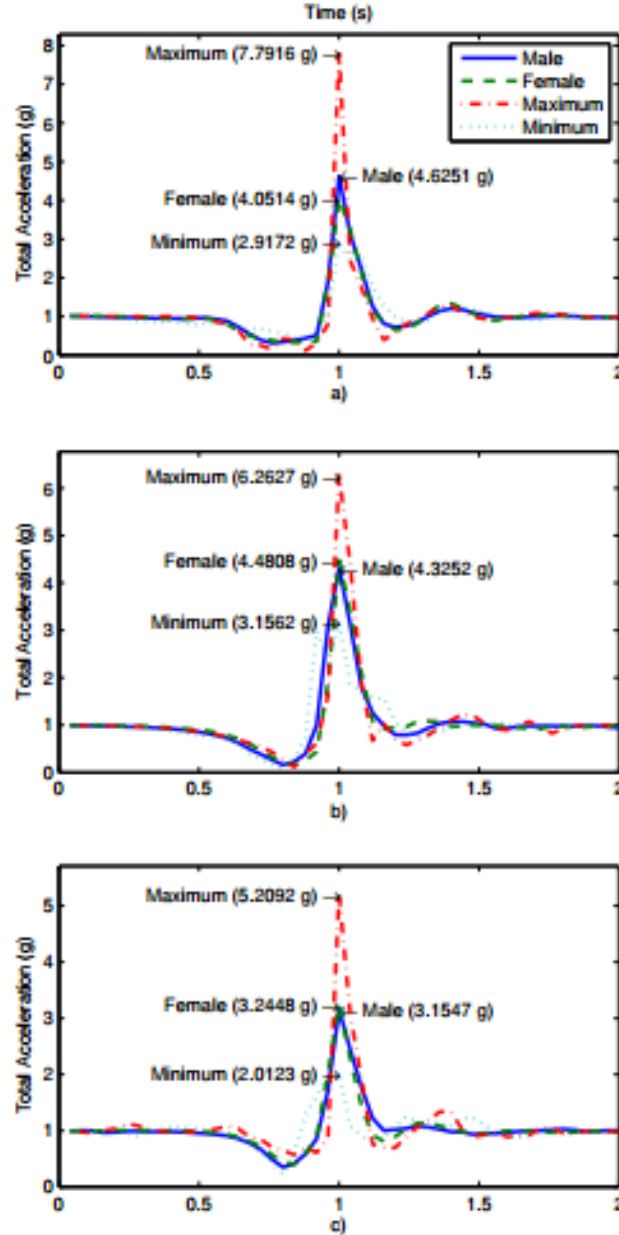
(f) ANN

252 öznitelik vektöründen oluşan verisetinin altı makine öğrenme yöntemi tarafından sınıflandırılması sonuçları ve bu algoritmaların hesaplama gereksinimlerini Tablo 2’de 2 sıra halinde verilmiştir. 4 GB RAM, 2.67 GHz, 64 bit Intel CORE i5 bir Windows 7 bilgisayarda MATLAB 7.7.0 ortamı kullanarak algoritmaları gerçekleştirdik. Gerekli olan eğitim süreleri baz alındığında sınıflandırıcılar BDM, LSM, DTW, k-NN, SVM ve ANN olarak artan zaman sıralamasında yer almaktadır. Test süreleri baz alındığında ise sıralama ANN, SVM, LSM, BDM, k-NN ve DTW şeklinde olmaktadır.

TARTIŞMA

Standartlaştırılmış açık erişimli verisetleri araştırmacılara kendi çalışmalarının sonuçlarını başkalarıyla kıyaslama imkanı sunmaktadır. Gönüllülerin çeşitliliği, aktivitelerin sahası ve denemelerin sayısı veriseti oluştururken önemli faktörlerdendir. Kısıtlı sayıdaki aktivite, küçük sayıdaki gönüllü tarafından gerçekleştirildiğinde algoritmalarından yüksek doğruluk elde etmek mümkündür. Fakat bu performans aktivite sayısı genişletildiğinde veya yeni gönüllüler teste dahil olduğunda sürdürülemez. Literatürde çok yüksek sensitivite ve spesifitede (%100) çalışmalar bulunmasına [32,33] rağmen, algoritma performansı gerçek koşullarda ve yeni kullanıcılarla denendiğinde başarımları dramatik bir şekilde düşmektedir. Çok sayıda ümit verici akademik çalışma bulunmasına rağmen markette son kullanıcı için satışa sunulabilir güvenlikte ürünler olmamasının sebebidir.

Figure 4. Total acceleration of the waist sensor during the fall actions: (a) back sitting; (b) back lying; and (c) rolling out of bed. The average total acceleration for female/male volunteers and the overall minimum/maximum total acceleration values that occurred during the experiments are shown.



Verisetimizde yer alan ve bu çalışmada kaydettiğimiz ADL'ler, gerçek yaşamda gerçekleşen ADL'lerin bir alt grubudur ve düşmelerle kolaylıkla karıştırılabilecek özellikle güçlü etkiler barındırmaktadır. Lablarda kaydedilmiş ADL'ler ve düşmeler ile doğal ortamda gerçekleşenler arasında bazı farklılıklar bulunmaktadır. Bu çalışmada elde edilen gönüllü düşmelerin ortalama ve tepe ivmelenme değerleri ile [17]'de kaydedilmiş yaşlıların gerçek

düşmelerini kıyasladık. Şekil 4 bel sensöründen alınan deneylerimizde kaydedilmiş örnek sinyalleri ile yine aynı bölgede bulunan ve gerçek düşmelerin kayıt edildiği bir çalışmadan elde edilen sonuçları grafiksel olarak göstermektedir. Geriye oturma, sırtüstü uzanma, yataktan yuvarlanıp düşme (Tablo 1; düşme eylemi sırasıyla 9, 10 ve 20) kayıtları, kadın ve erkek gönüllülerin gerçekleştirdiği herbiri 35 adet (=7 gönüllü, 5 tekrar) düşme eylemi için ortalama değerler ve toplam ivmelenmelerin maksimum ve minimum değerleri gösterilmiştir. Minimum ve maksimum değerler bütün kayıtlar üzerinden belirlenmiştir ve kadın veya erkek gönüllülerden herhangi birine aittir. İlgili düşme tipine göre, istemli düşmelerden kaydettiğimiz sinyal özellikleri ile gerçek düşmelerden elde edilen verilerin doğası birbiri ile uyumludur. Her düşme tipinde (istemli ve istemsiz) maksimum değerden minimum değere ortalama etki süresi yaklaşık 0.2 s'dir. Böylelikle deneysel kayıtlarımızın bağımsız yürütülmüş bir çalışmada kaydedilmiş istemsiz düşmeler ile uyumlu olduğu görülmüştür.

Çoklu aktivitelerin yer aldığı ve süresi (uzunluğu) belirli olmayan sürekli data aktarımı ile kayıt gerçekleştirildiği çalışmamız algoritmalarımızın gerçek dünya koşullarına uygulanabilir olmasını sağlamak adına avantaj sunmaktadır. Bir veri akışı içerisinde ADL'ler arasında bir düşme yer alıyorsa çoklu ivmelenme tepe noktaları kolaylıkla tanımlanabilir. Bu sinyal zaman ekseninde her bir tepe noktasında makine öğrenme teknikleri ile işlenebilir ve gerçek bir düşme olup olmadığı değerlendirilir. Gerçek dünya koşullarında, laboratuvar koşullarına nazaran sistemimizin doğruluğunda çok az bir kayıp olacağını düşünmekteyiz.

Oluşturduğumuz algoritmalar kolaylıkla taşınabilir aygıtlara gömülebilir veya telefon hattına dahil olabilen vücutta taşınan aksesuarlara bağlanabilir [34]. Bu özellik güvenilirliğin, bağımsızlığın ve düşme risk grubunda yer alanların yaşam kalitesinin artmasını sağlayacak ve düşme sonucu oluşan maddi külfetin azaltılması ile ekonomiye katkıda bulunacaktır. Bu bakımdan tıp dünyasından çalışmamıza ilgi olacağı düşünülmektedir.

SONUÇ

Düşmeler ile ADL'leri ayırtmak için önerilen standart deneysel prosedürleri kullanarak elde edilmiş bir veriseti üzerinde, makine öğrenme teknikleri tabanlı altı sınıflandırıcı kullandık. Aynı veriseti tabanlı farklı makine öğrenme tekniklerinin performanslarını ve işlemsel gerekliliklerini kıyasladık ve hepsinden %95'in üzerinde doğruluklar elde ettik. Sonuçların tekrarlanabilirliği açısından her bir algoritma 10 defa oluşturuldu ve her defasında yakın

sonular alınarak algoritma kararlılıkları ispat edildi. LSM ve k -NN yöntemleri hiç bir düşmeyi kaırmamakta oldukları için güvenilir sınıflandırıcılar oldukları gösterildi. Sınıflandırıcılar eğitim ve testler için kabul edilebilir ölçüde hesaplama gereksinimlerine ihtiyaç duyduklarından gerçek zamanlı uygulamalar için uygundur. Kapsamlı düşme deneyleri için standartlaştırılmış deneysel prosedürler kullanmamız alışmamızı literatürde örnek bir uygulama haline getirmiştir. alışmamızı başka arařtımacıların algoritmalarıyla kıyaslamayı mümkün hale getirmek için verisetimizi University of Irvine Machine Learning Repository’nde halka açık hale getirmeyi amaçlamaktayız [35]. Günlük ve spor aktiviteleri datasetimiz halen aynı sayfada erişebilir durumdadır [36]. řu anda devam eden bir başka alışmamızda altı sensör ünitesinden hangisinin ve hangi eksenin düşme tespiti için kullanışlı olduğunu arařtırıyoruz [37]. Devam eden alışmamızda, bel civarında giyilebilen bir mobil cihaz (akıllı telefon gibi) üzerinde gömülü olarak kořan bir düşme sezme algoritması geliştirilmektedir. Bu amaçla yapılan alışmalarımız neticesinde iki adet Iphone uygulaması geliştirilmiştir. Bunlar test veri toplama ve düşe sezme uygulamalarıdır. řekil 5’te düşme sezme uygulamasına ait ekran görüntüleri verilmiştir.

řekil 4: Düşme sezme programı



Proje sonucunda hedeflenen amaçlara ulaşılmış ve devam edecek çalışmalar ile daha kapsamlı sonuçların eldesi mümkün kılınacaktır. Akıllı telefon üzerindeki düşme sezma algoritmasının daha kararlı hale getirilmesi için çalışmalar devam etmektedir. Bu proje sayesinde ataletsel ve manyetik algılayıcılar ile düşmelerin sezimi üzerine bilgi birikimi sağlanmış ve bundan sonra proje tez çalışmaları ile genişletilecektir.

KAYNAKLAR

1. Rodríguez-Martín, D.; Pérez-López, C.; Samà, A.; Cabestany, J.; Català, A.A. Wearable inertial measurement unit for long-term monitoring in the dependency care area. *Sensors* 2013, 13, 14079–14104.
2. Ludwig, W.; Wolf, K.-H.; Duwenkamp, C.; Gusew, N.; Hellrung, N.; Marschollek, M.; Wagner, M.; Haux, R. Health-enabling technologies for the elderly—an overview of services based on a literature review. *Comput. Meth. Prog. Biomed.* 2012, 106, 70–78.
3. World Health Organization. Available online: http://www.who.int/violence_injury_prevention/other_injury/falls/en/ (accessed on 15 June 2014).
4. Zakaria, N.A.; Kuwae, Y.; Tamura, T.; Minato, K.; Kanaya, S. Quantitative analysis of fall risk using TUG test. *Comput. Meth. Biomech. Biomed. Eng.* 2013, doi:10.1080/10255842.2013.805211.
5. Bianchi, F.; Redmond, S.J.; Narayanan, M.R.; Cerutti, S.; Lovell, N.H. Barometric pressure and triaxial accelerometry-based falls event detection. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2010, 18, 619–627.
6. Doukas, C.N.; Maglogiannis, I. Emergency fall incidents detection in assisted living environments utilizing motion, sound and visual perceptual components. *IEEE Trans. Inf. Technol. B.* 2011, 15, 277–289.
7. Roetenberg, D.; Slycke, P.J.; Veltink, P.H. Ambulatory position and orientation tracking fusing magnetic and inertial sensing. *IEEE Trans. Bio-Med. Eng.* 2007, 54, 883–890.
8. Rimminen, H.; Lindström, J.; Linnavuo, M.; Sepponen, R. Detection of falls among the elderly by a floor sensor using the electric near field. *IEEE Trans. Inf. Technol. B.* 2010, 14, 1475–1476.
9. Mubashir, M.; Shao, L.; Seed, L. A survey on fall detection: Principles and approaches. *Neurocomputing* 2013, 100, 144–152.

10. Yang, C.-C.; Hsu, Y.-L. A review of accelerometry-based wearable motion detectors for physical activity monitoring. *Sensors* 2010, 10, 7772–7788.
11. Malhi, K.; Mukhopadhyay, S.C.; Schnepfer, J.; Haefke, M.; Ewald, H. A Zigbee-based wearable physiological parameters monitoring system. *IEEE Sens. J.* 2012, 12, 423–430.
12. Aziz, O.; Robinovitch, S.N. An analysis of the accuracy of wearable sensors for classifying the causes of falls in humans. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2011, 19, 670–676.
13. Mariani, B.; Rochat, S.; Büla, C.J.; Aminian, K. Heel and toe clearance estimation for gait analysis using wireless inertial sensors. *IEEE Trans. Biomed. Eng.* 2012, 59, 3162–3168.
14. Zhang, M.; Sawchuk, A.A. Human daily activity recognition with sparse representation using wearable sensors. *IEEE J. Biomed. Health Inform.* 2013, 17, 553–560.
15. Bagalà, F.; Becker, C.; Cappello, A.; Chiari, L.; Aminian, K.; Hausdorff, J.M.; Zijlstra, W.; Klenk, J. Evaluation of accelerometer-based fall detection algorithms on real-world falls. *PLoS One* 2012, 7, e37062.
16. Klenk, J.; Becker, C.; Lieken, F.; Nicolai, S.; Maetzler, W.; Alt, W.; Zijlstra, W.; Hausdorff, J.M.; van Lummel, R.C.; Chiari, L.; Lindemann, U. Comparison of acceleration signals of simulated and real-world backward falls. *Med. Eng. Phys.* 2011, 33, 368–373.
17. Kangas, M.; Vikman, I.; Nyberg, L.; Korpelainen, R.; Lindblom, J.; Jämsä, T. Comparison of real-life accidental falls in older people with experimental falls in middle-aged test subjects. *Gait Posture* 2012, 35, 500–505.
18. Luštrek, M.; Kaluža, B. Fall detection and activity recognition with machine learning. *Informatica* 2009, 33, 205–212.
19. Liu, S.-H.; Cheng, W.-C. Fall detection with the support vector machine during scripted and continuous unscripted activities. *Sensors* 2012, 12, 12301–12316.
20. Dubey, R.; Ni, B.; Moulin, P. A depth camera based fall recognition system for the elderly. *Image Anal. Recognit., Lect. Notes Comput. Sci.* 2012, 7325, 106–113.
21. Noury, N.; Fleury, A.; Rumeau, P.; Bourke, A.K.; Laighin, G.O.; Rialle, V.; Lundy, J.E. Fall detection—principles and methods. In *Proceedings of the 29th Annual International Conference of the IEEE EMBS, Lyon, France, 23–26 August 2007*; pp. 1663–1666.

22. Noury, N.; Rumeau, P.; Bourke, A.K.; ÓLaighin, G.; Lundy, J.E. A proposal for the classification and evaluation of fall detectors. *IRBM* 2008, 29, 340–349.
23. Abbate, S.; Avvenuti, M.; Corsini, P.; Vecchio, A.; Light, J. Monitoring of Human Movements for Fall Detection and Activities Recognition in Elderly Care Using Wireless Sensor Network: A Survey. In *Application-Centric Design Book*, 1st ed.; InTech: Rijeka, Croatia, 2010; Chapter 9, pp. 147–166.
24. Kwapisz, J.R.; Weiss, G.M.; Moore, S.A. Activity recognition using cell phone accelerometers. *ACM SIGKDD Explor. Newsl.* 2010, 12, 74–82.
25. Dai, J.; Bai, X.; Yang, Z.; Shen, Z.; Xuan, D. Mobile phone-based pervasive fall detection. *Pers. Ubiquitous Comput.* 2010, 14, 633–643.
26. Lee, R.Y.W.; Carlisle, A.J. Detection of falls using accelerometers and mobile phone technology. *Age Aging* 2011, 40, 690–696.
27. MTw User Manual and Technical Documentation; Xsens Technologies B.V.: Enschede, The Netherlands, 2014. Available online: <http://www.xsens.com> (accessed on 15 June 2014).
28. Duda, R.O.; Hart, P.E.; Stork, D.G. *Pattern Classification*, 2nd ed.; John Wiley & Sons, Inc.: New York, NY, USA, 2001.
29. Chang, C.-C.; Lin, C.-J. LIBSVM: A library for support vector machines. *ACM Trans. Intell. Syst. Technol.* 2011, 2, Article No: 27.
30. Keogh, E.; Ratanamahatana, C.A. Exact indexing of dynamic time warping. *Knowl. Inf. Syst.* 2005, 7, 358–386.
31. Haykin, S. *Neural Networks and Learning Machines*; Prentice Hall: Upper Saddle River, NJ, USA, 2009.
32. Liu, J.; Lockhart, T.E. Automatic individual calibration in fall detection—an integrative ambulatory measurement framework. *Comput. Meth. Biomech. Biomed. Eng.* 2013, 16, 504–510.
33. Bourke, A.K.; van de Ven, P.; Gamble, M.; O’Connor, R.; Murphy, K.; Bogan, E.; McQuade, E.; Finucane, P.; ÓLaighin, G.; Nelson, J. Evaluation of waist-mounted tri-axial accelerometer based fall-detection algorithms during scripted and continuous unscripted activities. *J. Biomech.* 2010, 43, 3051–3057.

34. Chang, S.-Y.; Lai, C.-F.; Chao, H.-C.J.; Park, J.H.; Huang, Y.-M. An environmental-adaptive fall detection system on mobile device. *J. Med. Syst.* 2011, 35, 1299–1312.
35. University of Irvine Machine Learning Repository. Available online: <http://archive.ics.uci.edu/ml/> (accessed on 15 June 2014).
36. Barshan, B.; Altun, K. Daily and Sports Activities Dataset, University of California Irvine Machine Learning Repository, University of California, Irvine, School of Information and Computer Sciences, 2013. Available online: <http://archive.ics.uci.edu/ml/datasets/Daily+and+Sports+Activities> (accessed on 15 June 2014).
37. Dobrucalı, O.; Barshan, B. Sensor-Activity Relevance in Human Activity Recognition with Wearable Motion Sensors and Mutual Information Criterion. In *Information Sciences and Systems 2013, Proceedings of the 28th International Symposium on Computer and Information Sciences*, Paris, France, 28–29 October 2013; Gelenbe, E., Lent, R., Eds.; Springer International Publishing: Cham, Switzerland, 2013; pp. 285–294.