

# DÜŞME TESPİTİ İÇİN SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI A COMPARATIVE STUDY OF CLASSIFICATION METHODS FOR FALL DETECTION

Bahadır Çatalbaş  
Elektrik ve Elektronik Mühendisliği Bölümü  
Bilkent Üniversitesi  
cbahadir@ee.bilkent.edu.tr

Görkem Seçer  
Bilgisayar Mühendisliği Bölümü  
Ortadoğu Teknik Üniversitesi  
gorkem.secer@ceng.metu.edu.tr

Burak Yücesoy  
Bilgisayar Mühendisliği Bölümü  
Bilkent Üniversitesi  
b\_yucesoy@ug.bilkent.edu.tr

Murat Aslan  
Elektrik ve Elektronik Mühendisliği Bölümü  
Bilkent Üniversitesi  
t\_aslan@ug.bilkent.edu.tr

**Özetçe** —Bu bildiride giyilebilir yapıda olan ve üç boyutlu ölçüm alabilen bir ivmeölçerin çıktılarını kullanarak düşme tespiti yapan farklı algoritmaların karşılaştırılması yapılmıştır. Karşılaştırma amacıyla destek vektör makineleri, yapay sinir ağları ile elde edilen sınıflandırıcılar ve kural bazlı bir sınıflandırıcı kullanılmıştır. Sınıflandırıcıların tasarlanması ve doğrulanması amacıyla 7 farklı denekten üçer defa düşme ve düşme dışındaki günlük aktivitelere ilişkin ivmeölçer verileri toplanmıştır. Yapılan karşılaştırma sonucunda tespit doğruluğu en yüksek algoritmanın %87,76 ile destek vektör makineleri olduğu bulunmuştur. En yüksek düşme tespit oranı da %90,91 olarak kural bazlı sınıflandırıcı kullanımıyla elde edilmiştir. En yüksek özgüllük oranı %89,47 ile yine destek vektör makineleri ile elde edilmiştir.

**Anahtar Kelimeler**—*düşme tespiti, destek vektör makinesi, yapay sinir ağları, ivmeölçer*

**Abstract**—A comparative study of various fall detection algorithms based upon measurements of a wearable tri-axial accelerometer unit is presented in this paper. Least squares support vector machine, neural network and rule-based classifiers are evaluated in the scope of this paper. Training and testing data sets, which are necessary for design and testing of the classifiers, respectively, are collected from 7 people. Each subject exercised simulated falls and other daily life activities such as walking, sitting etc. Among three methods, support vector machine-based classifier is found to be superior in terms of both correct detection and false alarm ratio as 87.76% precision and 89.47% specificity. Meanwhile, best sensitivity is achieved with rule-based classifiers.

**Keywords**—*fall detection, support vector machines, neural networks, accelerometer*

## I. GİRİŞ

Düşme, özellikle yaşlı insanlarda ciddi sağlık problemlerine (inme, şuur kaybı, kanama vb.) yol açabilecek bir olaydır. Yalnız yaşayan insanlara bu gibi durumlarda gerekli acil sağlık müdahalesinin yapılması çoğu zaman gecikmektedir. Bu nedenle, düşmenin otomatik olarak tespit edilerek acil yardım çağrılması önemli bir konudur [1].

Düşme tespiti için hareketi algılayabilen farklı tipte sensör sistemleri kullanılmaktadır. Bunlardan, en yaygın olarak kullanılan ikisi görüntü ve giyilebilir tipte ivmeölçer tabanlı sistemlerdir [2]. Görüntü tabanlı sistemler genellikle insan vücudunun düşme sonrasında aldığı şekil üzerinden düşme tespiti yapmaya çalışmaktadırlar [3], [4]. Her ne kadar bu sistemlerin başarı oranları %90'lar mertebesinde olsa da yalnızca kamera sisteminin kurulduğu ortamlarda kullanılabilir oldukları ve birkaç kamera gerektirmeleri sebebiyle pahalı oldukları için pratikte çok fazla uygulama şansı bulmamaktadırlar.

Giyilebilir tipte ivmeölçer tabanlı sistemler ise MEMS teknolojisindeki gelişmeler sonucu ivmeölçerlerin küçülüp ucuzlamasıyla yaygınlaşmıştır. Bu tip sensörler cep telefonlarında dahi bulunmaktadır. Bu teknolojinin giyilebilir olması bu sensörlerin birçok pratik uygulamada kullanılabilir olmasına imkan tanımıştır. İvmeölçerlerin vücutun neresine takılması gerektiği incelenerek en ergonomik ve en yüksek başarı oranı sağlayan yerin bel çevresi olduğu saptanmıştır [5]. Bu bağlamda, farklı algoritmalar geliştirilmiştir. Geliştirilen algoritmaların büyük çoğunluğu kural bazlı sınıflandırıcılardır [6], [7]. Bu tip algoritmalar kullanılarak yaklaşık %85'in üzerinde başarı oranı elde edilebiliyor olsa da herhangi bir istatistiksel tabanı olmayan bu tip algoritmaların en büyük problemi verdikleri yanlış alarmlardır [8]. Düşme detektörlerinin pratik kullanımını verimsiz kılacak en önemli faktörlerden olan yanlış alarmlar, sezgisel mantık yürütmelerle kısıtlı veri setleri üzerinden tasarlanan kural bazlı algoritmaların değişken koşullarda (örn. sensörün farklı kişiler tarafından kullanıl-



Şekil 1: Deneklerin beline bağlanan sensörün görüntüsü.

ması)yaşayacakları en büyük problemlerden biri olacaktır. Bu nedenle, istatistiksel bir detektör tasarlanmayacaksa bile mevcut eğitici veri setini en iyi şekilde kullanarak gürbüz bir algoritma tasarlanması gerekmektedir ki bu da destek vektör makineleri gibi sınıflayıcılarla sağlanabilir [9].

Bu bildiriye, kural bazlı sınıflandırıcı ile yapay sinir ağları ve destek vektör makineleri tabanlı doğrusal sınıflandırıcılar karşılaştırılmıştır. Bölüm II'de düşme veritabanının nasıl oluşturulduğu anlatılmıştır. Bölüm III'te problem tanımlanarak, sınıflandırıcılar için değerlendirme ölçütleri verilmiştir. Bölüm IV'te sınıflandırıcıların nasıl tasarlandığı anlatılmış ve başarımlar anlamında karşılaştırmaları yapılmıştır.

## II. VERİTABANI OLUŞTURULMASI

Bu bildiriye kullanılan düşme tespit algoritmalarının başarımlarını kıyaslamak için yaşları 18-30 arasında değişen 7 denekten veri toplanmıştır. Şekil 1'de gösterildiği gibi deneklerin beline 3 eksenli ölçüm alabilen bir ivmeölçer bağlanmış ve bu ölçerden 256 Hz örnekleme frekansında veri toplanmıştır. Örnekleme frekansı Şekil 2 üzerinde gösterilen düşme profili ve literatürde yapılan diğer çalışmalar [8] incelenerek belirlenmiştir.

Düşme detektörü için tüm hareketler düşme hareketleri ve günlük genel hareketler olarak ikiye ayrılmaktadır. Bu göz önüne alınarak deneklerden her iki hareket çeşidine ilişkin aktiviteler yapmaları istenmiştir. Deneklerin gerçekten düşmesini beklemek uzun zaman gerektireceği için denekler bilinçli bir şekilde düşmüştür. Toplamda sekiz farklı düşme hareketine ilişkin veri toplanmıştır. Günlük genel hareketler için de veritabanının kapsamlı olması için üçü düşerken toplanma hareketi olmak üzere toplam 29 farklı aktivite denekler tarafından yapılmıştır. Özetle, deneyler kapsamında oluşturulan veritabanı sekiz düşme, üç düşerken toplanma ve 26 farklı günlük genel hareketten oluşmaktadır. Her hareket denekler tarafından üç kez tekrarlanmıştır. Deneyler sırasında deneklerin yaralanmaması için düşme hareketleri 6 cm kalınlığında süngerler üzerinde gerçekleştirilmiştir. Tüm hareketler Tablo I de detaylı olarak verilmiştir. Sınıflandırıcılar tasarlanırken veritabanı eğitici grup ve test grubu olarak ikiye bölünmüştür. Bundan sonraki bölümlerde, düşme hareketleri seti  $D$ , günlük genel hareketler seti  $G$  ve tüm aktiviteler seti  $E$  ile sembolize edilecektir. Burada,  $E = D \cup G$  ve  $D \cap G = \emptyset$ 'dir.

Tablo I'de verilen hareketler 3 eksenli ivmeölçerin aldığı ölçümlerden oluşturulan ivme şiddet vektörü ile temsil edilecektir. İvmeölçerin x, y, ve z eksenlerindeki ölçümleri sırasıyla  $a_x$ ,  $a_y$ , ve  $a_z$  ile gösterilirse, herhangi bir  $t$  anındaki ivme şiddeti,  $\bar{a}(t)$ , şu şekilde hesaplanabilir

Tablo I: Denekler tarafından gerçekleştirilen hareketler.

Hareket Grubu	Hareket	Gereken Tespit
Günlük Hareketler	Sabit durmak	Olumsuz
Günlük Hareketler	Yürümek	Olumsuz
Günlük Hareketler	Zıplamak	Olumsuz
Günlük Hareketler	Yerden bir şey alıp kalkmak	Olumsuz
Günlük Hareketler	Eğilmek	Olumsuz
Günlük Hareketler	Eğilmişken doğrulmak	Olumsuz
Günlük Hareketler	Çömelmek	Olumsuz
Günlük Hareketler	Çömelmişken kalkmak	Olumsuz
Günlük Hareketler	Secde etmek	Olumsuz
Günlük Hareketler	Secdeden kalkmak	Olumsuz
Günlük Hareketler	Yere oturmak	Olumsuz
Günlük Hareketler	Yerden kalkmak	Olumsuz
Günlük Hareketler	Merdiven çıkmak	Olumsuz
Günlük Hareketler	Merdivenden inmek	Olumsuz
Günlük Hareketler	Asansörle yukarı çıkmak	Olumsuz
Günlük Hareketler	Asansörle aşağı inmek	Olumsuz
Günlük Hareketler	Sandalyeye oturmak	Olumsuz
Günlük Hareketler	Sandalyeden kalkmak	Olumsuz
Günlük Hareketler	Koltuktan kalkmak	Olumsuz
Yatış Hareketleri	Yatağa sırtüstü uzanmak	Olumsuz
Yatış Hareketleri	Sırtüstü yatarken kalkmak	Olumsuz
Yatış Hareketleri	Yatağa yüzüstü uzanmak	Olumsuz
Yatış Hareketleri	Yüzüstü yatarken kalkmak	Olumsuz
Yatış Hareketleri	Yatağa yan uzanmak	Olumsuz
Yatış Hareketleri	Yan yatarken kalkmak	Olumsuz
İleriye Düşüş	Dizüstü düşmek	Olumlu
İleriye Düşüş	Kollarla korunarak düşmek	Olumlu
İleriye Düşüş	Tüm vücutla düşmek	Olumlu
İleriye Düşüş	Yan düşmek	Olumlu
İleriye Düşüş	İleriye düşerken toparlanmak	Olumsuz
Geriyeye Düşüş	Düşerek oturmak	Olumlu
Geriyeye Düşüş	Sırtüstü düşmek	Olumlu
Geriyeye Düşüş	Geriyeye düşerken yan düşmek	Olumlu
Geriyeye Düşüş	Geriyeye düşerken toparlanmak	Olumsuz
Yana Düşüş	Yana düşmek	Olumlu
Yana Düşüş	Yana düşerken toparlanmak	Olumsuz

$$\bar{a}_t = \sqrt{a_x(t)^2 + a_y(t)^2 + a_z(t)^2}. \quad (1)$$

256 Hz olarak seçilen örnekleme frekansına tekabül eden örnekleme periyodu  $\Delta T$  ile gösterilirse, sınıflandırılacak tüm hareketlere için hareket boyunca ölçülen ivme şiddeti vektörü  $A = [\dots \bar{a}_{t-\Delta T} \bar{a}_t \bar{a}_{t+\Delta T} \dots]$  şeklinde gösterilebilir. Bu vektörün uzunluğu düşme hareketlerinin süresine göre belirlenip sabit olarak seçilmiştir. Burada dikkat edilmesi gereken önemli noktalardan biri  $A$  oluşturulurken ivmeölçerlerin doğrudan ham ölçümlerinin kullanılıyor olmasıdır. Bu nedenle, herhangi bir  $t$  anında ivmeölçer hareketsiz duruyorken dahi  $\bar{a}_t \approx 9.81$ 'dir.

## III. PERFORMANS ÖLÇÜTLERİ

Bilindiği gibi sınıflandırıcıların performansı doğruluk, hassasiyet ve özgüllük kriterlerince belirlenir. Doğruluk, tüm hareket sınıflandırmalarının hangi oranda doğru olduğudur. Hassasiyet gerçekleşen düşme olaylarının hangi oranda düşme olarak tespit edildiğidir. Özgüllük düşme haricindeki olayların hangi oranda düşme harici olay olarak tespit edildiğidir. Düşme detektörünün düşme olayını düşme ya da günlük genel hareketlerin düşme harici olay olarak sınıflandırması doğru sınıflandırmaya tersi durumlar da yanlış sınıflandırmaya belirtilir.

Verilen bir  $u$  hareketinin, düşme hareketi olması  $H_1$  :  $u \in D$  hipotezi, günlük genel hareket olması  $H_0$  :  $u \in G$  hipotezi ile ve bu hareket boyunca ivmeölçer tarafından ölçülen ivme verilerinin oluşturduğu set  $A_u \subseteq \mathbb{R}$  ile gösterilebilir.

Bu durumda, düşme detektörü  $\delta(u) : A_u \rightarrow \{0, 1\}$  şeklinde tanımlanabilir. Burada, 0 ve 1 tüm ikili sınıflandırıcılarda olduğu gibi verilen bir hareket için detektörün  $H_0$  ve  $H_1$  hipotezlerini doğru olarak seçmesine karşılık gelmektedir. Bir diğer deyişle, eğer  $\delta(u) = 1$  ise detektör  $u \in D$ , eğer  $\delta(u) = 0$  ise detektör  $u \in G$  olduğuna karar verir. Tanımlanan bu  $u$  hareketinin gerçekte hangi sete ait olduğuna göre dört farklı durum ortaya çıkmaktadır. Bu durumlar Tablo II'de verilen karışıklık matrisinde gösterilmektedir.

Tablo II: Düşme detektörü tarafından verilen karar ile gerçek harekete ilişkin karışıklık matrisi.

	$H_1$ doğru	$H_0$ doğru
$H_1$ seçildi	Doğru pozitif	Yanlış pozitif
$H_0$ seçildi	Yanlış negatif	Doğru negatif

Tanımlı  $N$  aktivite için doğru pozitif olanların sayısı  $N_d^+$ , yanlış pozitif olanların sayısı  $N_y^+$ , yanlış negatif olanların sayısı  $N_y^-$  ve doğru negatif olanların sayısı  $N_d^-$  ile gösterilirse, düşme tespit detektörünün performans ölçütü olarak belirlenen doğruluk, hassasiyet ve özgüllük şu şekilde ifade edilebilir:

$$\text{Doğruluk} = \frac{N_d^+ + N_d^-}{N}, \quad (2)$$

$$\text{Hassasiyet} = \frac{N_d^+}{N_d^+ + N_y^+}, \quad (3)$$

$$\text{Özgüllük} = \frac{N_d^-}{N_d^- + N_y^-}, \quad (4)$$

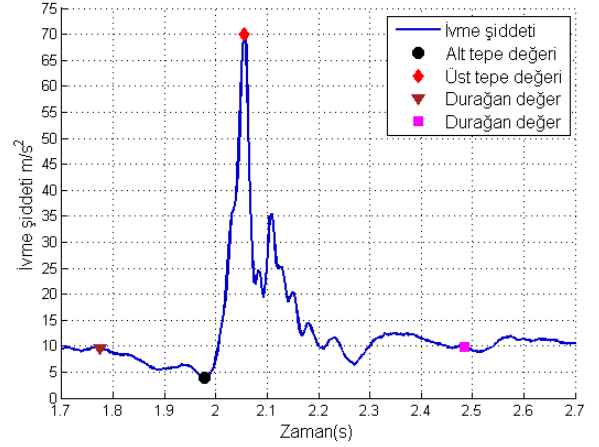
Bundan sonraki bölümde anlatılan sınıflandırma metotları karşılaştırılırken Denklem 2-4'de tanımlanan kriterler kullanılacaktır. İyi bir sınıflandırıcının yüksek Doğruluk, Hassasiyet ve Özgüllük oranlarına sahip olması beklenir.

#### IV. SINIFLANDIRMA METOTLARI

Düşme detektörü olarak destek vektör makineleri, yapay sinir ağları ve kural bazlı ikili sınıflandırıcılar kullanılmıştır. İkili sınıflandırıcıların tasarlanabilmesi için öznitelik vektörü elemanlarının belirlenmesi gerekmektedir.

##### A. Öznitelik vektörünün seçimi

Kullanılan sınıflandırma metotları  $A$  vektörünün elemanlarının tanımladığı  $t-\bar{a}_t$  eğrisinin özniteliklerine bakarak karar verir. Öznitelik elemanlarının seçimine yalnızca matematiksel olarak  $A$  vektörünün yapısını incelenerek karar verilebileceği gibi düşme olayının fiziksel olarak dayandığı temel prensipler göz önüne alınarak da sezgisel bir yaklaşımla da bulunulabilir. Bu çalışmada, öznitelik vektörü sezgisel olarak belirlenmiştir. Bu bağlamda düşme olayının fiziksel olarak nasıl gerçekleştiği irdelenmiştir: Düşme iki bölümden oluşan bir harekettir. Düşme hareketinin ilk bölümü doğası gereği serbest düşme benzeri bir hareketin gözlemlendiği bölümdür. Düşme hareketinin ikinci bölümü ise düşen insanı yaralayabilen yüksek ivmeli bir çarpmanın gözlemlendiği bölümdür. Düşmenin ilk bölümünde serbest düşmede olduğu gibi ivme sensörü üzerindeki toplam ivmenin büyüklüğü azalır ve toplam



Şekil 2: Bir düşmede gözlenen alt ve üst ivme değerleri

ivme değerinde alt tepe değeri denilen minimum ivme değeri gözlemlenir. Düşmenin ikinci bölümünde çarpmanın etkisiyle ivme sensörü üzerindeki toplam ivmenin büyüklüğü yükselir ve toplam ivme değerinde üst tepe değeri denilen maksimum ivme değeri gözlemlenir. Şekil 2'de düşme olayının bu iki fazı ivmeölçerinin ölçümleri üzerinden alt ve üst ivme değerleriyle birlikte gösterilmiştir. Buradan yola çıkarak, bu çalışmada öznitelik vektörü olarak ivmenin alt ve üst tepe değerleri kullanılmıştır. Her ne kadar, algoritmaların tasarımı açısından bu bildiri kapsamında basitlik ön planda tutulsa da daha büyük uzunlukta bir öznitelik vektörü kullanılarak sınıflandırıcıların daha başarılı olması mümkündür.

##### B. Kural bazlı sınıflandırıcı eşik değeri seçimi

Eğitici veriler üzerinde yapılan eşik değeri seçimi sonucu üst tepe değeri  $37,2 \text{ m/s}^2$  alt tepe değeri de  $5,3 \text{ m/s}^2$  olarak belirlenmiştir. Sınıflandırıcı ivme şiddeti eğrisinde alt tepe değerinden daha düşük ve üst tepe değerinden daha büyük bölümleri olan bir ivme şiddeti eğrisine rastlarsa bu hareketi düşme olarak sınıflandırmaktadır.

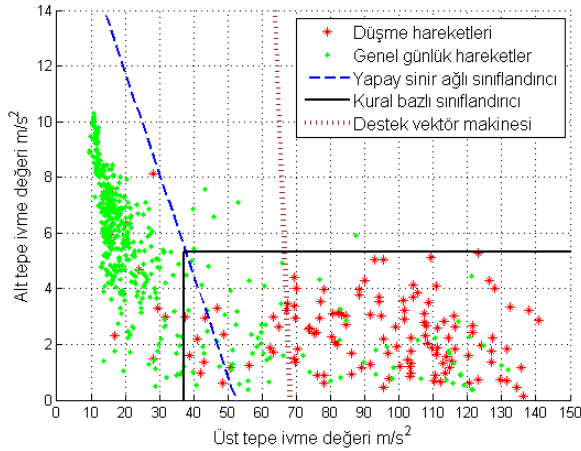
##### C. Destek vektör makineleri kullanan sınıflandırıcı

Destek vektör makineleri kullanan sınıflandırıcı ile maksimum doğruluk oranı elde edilmeye çalışılmıştır. Ayrıca destek vektör makinesi sınıflandırma doğrusunu belirlerken günlük genel hareketler grubunu, düşme hareketleri grubundan en uygun şekilde ayıracak doğruyu belirlemiştir. Böylece destek vektör makineleri kullanan sınıflandırıcı Tablo IV'de görüldüğü gibi hem eğitici veri grubu üzerinde hem de test veri grubu üzerinde en yüksek doğruluk oranına ulaşmıştır.

##### D. Yapay sinir ağları kullanan sınıflandırıcı

Yapay sinir ağı kullanan sınıflandırıcı ile maksimum doğruluk oranı elde edilmeye çalışılmıştır. Kullanılan sinir ağı tek katmanlıdır. Sinir ağının katsayılarının bulunmasında perceptron öğrenme kuralı kullanılmıştır.

## V. SONUÇLAR



Şekil 3: Destek vektör makinelerinin, yapay sinir ağlarının ve kural bazlı ikili sınıflandırıcıların sınıflandırma eğrileri

## E. Metotların karşılaştırılması

Destek vektör makineleri, yapay sinir ağları ile elde edilen sınıflandırıcı ve kural bazlı ikili sınıflandırıcı kullanılarak gerçekleştirilen testler sonucunda Tablo III ve Tablo IV'deki sonuçlar elde edilmiştir. Sınıflandırıcıların sınıflandırma eğrileri Şekil 3'de verilmiştir. Tespit doğruluğu kriterinde hem eğitici veri grubu üzerinde hem de test veri grubu üzerinde en iyi sonuçlar destek vektör makineleri sağlamıştır. Hassasiyet kriterinde hem eğitici veri grubu üzerinde hem de test veri grubu üzerinde en iyi sonuçlar kural bazlı ikili sınıflandırıcı sağlamıştır. Özgüllük kriterinde de hem eğitici veri grubu üzerinde hem de test veri grubu üzerinde en iyi sonuçları destek vektör makineleri sağlamıştır. Kriterlere göre en başarılı sınıflandırıcı destek vektör makineleri ve en başarısız sınıflandırıcı da yapay sinir ağları olarak belirlenmiştir. Her ne kadar sıralama bu şekilde de olsa genel manada üç algoritmanın da performansı birbirine yakındır. Yapay sinir ağları ile elde edilen sınıflandırıcı en düşük doğruluk oranına sahip olsa da birbirine yakın doğruluk, hassasiyet ve özgüllük oranlarına sahiptir. Üç algoritmada da doğru tespit oranı %84'ün, hassasiyet oranı %81'in ve özgüllük %84'ün üstündedir. Bu oranların ışığında kısıtlı öznelik sayısına rağmen üç algoritmanın da başarılı bir şekilde düşme tespiti yaptığını ulaşılabılır.

Tablo III: Eğitici veriler üzerinde sınıflandırma başarısı

	Doğruluk	Hassasiyet	Özgüllük
Destek vektör makinesi	%89,84	%78,52	%92,93
Yapay sinir ağları	%85,40	%84,44	%84,67
Kural bazlı sınıflandırıcı	%86,19	%89,63	%85,25

Tablo IV: Test veri grubu üzerinde sınıflandırma başarısı

	Doğruluk	Hassasiyet	Özgüllük
Destek vektör makinaları	%87,76	%81,81	%89,47
Yapay sinir ağları	%84,35	%84,85	%84,21
Kural bazlı sınıflandırıcı	%86,40	%90,91	%85,09

Bu çalışmada düşme tespiti için destek vektör makineleri, yapay sinir ağları ile elde edilen sınıflandırıcı ve kural bazlı sınıflandırıcı algoritmaları karşılaştırılmıştır. Yapılan karşılaştırma sonucunda en başarılı algoritma destek vektör makineleri çıkarken, en başarısız algoritma yapay sinir ağları ile elde edilen sınıflandırıcı olmuştur ancak üç algoritmanın da birbirine yakın sonuçlar verdiği gözlemlenmiştir. Bu durumun sebebi düşük sayıda özneliğe bakılması ve destek vektör makineleri ve yapay sinir ağları ile doğrusal sınıflandırıcı üretilmesidir. Daha kompleks destek vektör makineleri ve yapay sinir ağları kullanımı ile ve yüksek sayıda özneliğe bakılması sonucu algoritmalar arasındaki doğruluk farklarının ve doğruluk oranlarının artması beklenmektedir. Ancak, denekler düşmeleri 6 cm kalınlığındaki süngerlerin üzerinde kontrollü bir şekilde gerçekleştirdikleri için alınan algılayıcı ölçümlerinin gerçek düşmeleri bire bir yansıtmadığı düşünülmektedir. Ayrıca, deneklerin yaşlarının 18-30 aralığında olması çalışmanın asıl hedefi olan yaşlıların düşmelerinin tespit edilmesini olumsuz yönde etkileyecektir. Daha tanımlayıcı öznelikler ve daha kompleks sınıflandırma algoritmaları kullanılarak bu dezavantajların büyük ölçüde kompanse edilebileceği beklenmektedir.

## KAYNAKÇA

- [1] N. Noury, P. Rumeau, A. K. Bourke, G. O'Laughlin, and J. E. Lundy, "A proposal for the classification and evaluation of fall detectors," *IRBM*, vol. 6, pp. 340–349, December 2008.
- [2] M. Mubashir, L. Shao, and L. Seed, "A survey on fall detection: Principles and approaches," *Neurocomputing*, vol. 100, pp. 144–152, January 2013.
- [3] T. Lee and A. Mihailidis, "An intelligent emergency response system: preliminary development and testing of automated fall detection," *Journal of Telemedicine and Telecare*, June 2005.
- [4] C. Rougier, J. Meunier, A. St-Arnaud, and J. Rousseau, "Robust video surveillance for fall detection based on human shape deformation," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 21, pp. 611–622, May 2011.
- [5] M. Kangas, A. Konttila, P. Lindgren, I. Winblad, and T. Jamsa, "Comparison of low-complexity fall detection algorithm for body attached accelerometers," *Gait Posture*, vol. 28, pp. 285–291, January 2008.
- [6] M. Kangas, A. Konttila, I. Winblad, and T. Jamsa, "Determination of simple thresholds for accelerometry-based parameters for fall detection," in *Proc. of the 29th Annual International Conference on Engineering in Medicine and Biology Society*, year = 2007,.
- [7] A. K. Bourke, J. V. O'Brien, and G. M. Lyons, "Evaluation of a threshold-based tri-axial accelerometer fall detection algorithm," *Gait Posture*, vol. 26, pp. 194–199, July 2007.
- [8] F. Bagala, C. Becker, A. Cappello, L. Chiari, K. Aminian, J. M. Hausdorff, W. Zijlstra, and J. Klenk, "Evaluation of accelerometer based fall detection algorithm on real-world falls," *PLoS ONE*, vol. 7, May 2012.
- [9] M. Lustrek and B. Kaluza, "Fall detection and activity recognition with machine learning," *Informatica*, vol. 33, pp. 205–212, 2009.