



Denetimsiz Anomali Tespiti Yaklaşımı ile Düşme Algılama

Abdullah Talha SÖZER^{1*}

¹Karabük Üniversitesi, Elektrik – Elektronik Mühendisliği, Karabük
(ORCID: [0000-0002-7855-6119](https://orcid.org/0000-0002-7855-6119))



Anahtar kelimeler:

Düşme tespiti,
Anomali tespiti, Gauss
karışım modeli.

Öz

Yaşlı nüfusunun hızla artması ve yaşlılığa bağlı olarak karşılaşılan fiziksel, duyuşsal ve bilişsel gerilemeler, düşmeyi her geçen gün büyüyen bir problem olarak karşımıza çıkarmakta ve düşme tespiti çalışmalarının hız kazanmasına sebep olmaktadır. Günlük aktivitelerin düşmeden ayırt edilmesinden ibaret olan düşme tespiti probleminde, denetimli öğrenme yaklaşımları kullanılmasına rağmen, düşmenin nadir rastlanan ve çok farklı biçimlerde karşılaşılabilen bir olay olması genel bir model elde edilmesine izin vermemektedir. Bu çalışmada denetimsiz anomali tespiti ile düşmenin belirlenmesi önerilmektedir. Denetimsiz öğrenme modelinin elde edilmesinde ve model vasıtasıyla düşmenin tespitinde 35 tip düşme ve 44 tip günlük aktiviteye sahip kapsamlı bir veri setinden faydalanılmıştır. Denetimsiz öğrenme yöntemi olan Gauss karışım modelinin eğitiminde, günlük aktivitelerden toplanan 3-eksen ivmeölçer sinyallerinden elde edilen öznitelikler kullanılmıştır. Test aşamasında model, düşme ve günlük aktivite verileri ile karşılaşmış, modele göre olasılığı çok düşük olan veriler anomali, dolayısıyla düşme olarak kabul edilmiştir. Testlerde düşmeler %91 civarında doğru olarak tespit edilmiş ve elde edilen sonuçlar literatür ile karşılaştırılmıştır. Sonuçlar düşmenin anomali tespiti yaklaşımları ile belirlenebileceğini ve makine öğrenmesi modelinin elde edilmesi için yalnız günlük aktivite verilerinin yeterli olduğu yaklaşımını doğrulamaktadır.

Fall Detection Using Unsupervised Anomaly Detection Approach

Keywords: Fall detection,
Anomaly detection, Gaussian
mixture model.

Abstract

The rapid increase in the elderly population and the physical, sensory, and cognitive declines encountered due to old age cause falling as a growing problem day by day and induce fall detection studies to accelerate. Although supervised learning approaches are used in the fall detection problem, which consists of distinguishing daily activities from falling, it does not allow obtaining a general model because falling is a rare event that can be encountered in many different ways. This study proposes determining the fall with unsupervised anomaly detection. A comprehensive data set with 35 types of falls and 44 types of daily activities was used to obtain the unsupervised learning model and to detect falls through the model. In the training of the Gaussian mixture model, which is an unsupervised learning method, features obtained from 3-axis accelerometer signals collected from daily activities were used. During the test phase, the model was subject to fall and daily activity data, and the data with very low probabilities according to the model were accepted as anomalies, therefore falling. In the tests, the falls were detected with an accuracy of around 90.5% and the results were compared with other studies. The results confirm that the fall can be detected by anomaly detection approaches and that only daily activity data is sufficient to obtain the machine learning model.

*Sorumlu yazar: talhasozer@karabuk.edu.tr

Geliş Tarihi: 20.09.2021, Kabul Tarihi: 22.02.2022

1. Giriş

Dünya sağlık örgütü, düşmeyi, bir kişinin vücut pozisyonunun mevcut konumundan zemin gibi daha alçak bir konuma istemsiz olarak yer değiştirmesi olarak tanımlamaktadır. Her yıl düşmenin, 684 bin ölüme sebep olduğu ve bu rakamın kaza sebebi ile ölümden trafik kazalarından sonraki en büyük rakam olduğu bildirilmektedir. Bununla birlikte ölüme sebep olan düşmeler hariç tıbbi müdahale gerektiren 37,3 milyon ağır düşme meydana gelmekte, kalıcı hasarlar bırakabilmektedir [1]. Ayrıca düşme sonrası uygulanan tedaviler en masraflı tıbbi müdahaleler arasındadır [2]. Düşmenin ve ağır sonuçlara sebep olma riskinin yaşlı insanlarda daha fazla olduğu ve dünya genelinde yaşlı nüfusunun arttığı göz önüne alındığında düşme büyüyen bir problem olarak karşımıza çıkmaktadır.

Dünya nüfusunun %12'si, yaşı 60'ı aşkın bireyler tarafından teşkil edilmektedir ve bu oranın 2030 yılına gelindiğinde %16, 2050 yılında ise %22 ulaşması öngörülmektedir [3]. Türkiye'de ise nüfusumuzun %9,5'ini 65 yaş üstü bireyler oluşturmakta, bu rakamın 2030 da %12,9 ve 2050'de %19,5 olması beklenmektedir [4]. Yaşlanma ile karşılaşılan fiziksel, duyuşsal ve bilişsel değişiklikler, düşme ihtimalini artırmaktadır. Yaşlı bireylerde düşmeden kaynaklanan ciddi yaralanma veya ölüm olayına sıklıkla rastlanmaktadır. Örneğin, Amerika Birleşik Devletleri'nde düşen yaşlıların %20-30'u, morluklar, kalça kırıkları veya kafa travması gibi orta ila şiddetli yaralanmalardan muzdariptir [1]. 65 yaş ve üstü bireylerin %28'i ve 70 yaş ve üstü bireylerin %32'si her yıl düşmektedir ve ölümcül düşmelerin en fazla olduğu grup yaşlı bireylerdir [5].

Düşme hadisesini bu kadar tehlikeli bir hale getiren düşmeden sonra yerde kalış süresidir. Yaralanma ile sonuçlanan 313 düşmeden 148'inde bireyin düşmenin ardından ayağa kalkamadığı ve bunun dehidrasyon ve hipotermi gibi olumsuz sonuçlara yol açabildiği bildirilmektedir. Düşme sonrası uzun süre yerde kalan yaşlıların yarısının 6 ay içinde öldüğü gözlemlenmiştir [5]. Bu ciddi sağlık tehdidinin üstesinden gelmek için, otomatik düşme algılama ve alarm işlevlerine sahip sistemler üzerine yoğun çalışmalar yürütülmektedir. Otomatik düşme algılama sistemleri, düşmeleri tespit edip hastaneyi/ hasta bakıcıları anında uyarılmaktadır [6]–[10]. Bu sistemler, düşme ile tıbbi müdahale arasındaki süreyi azaltarak düşmeler ve uzun süre yerde kalma ile ilgili sağlık komplikasyonlarını en aza indirebilir.

Sistemler, kullanılan sensörlere göre, giyilebilir tabanlı, ortam tabanlı olmak üzere iki sınıfta değerlendirilebilir. Ortam tabanlı yaklaşımda kamera, kızıl ötesi kamera, Kinect sensör, hareket sensörü, radar sensörü, basınç ve titreşim sensörleri vasıtası ile düşme tespit edilmeye çalışılmaktadır [2], [11], [12]. Ortam tabanlı yaklaşımlarda, düşme ile günlük hareket oldukça başarılı bir şekilde ayırt edilebilmesine rağmen bu sistemlerin belirli ortam ile sınırlı olması, maliyet, bireylerde sürekli izleniyor izlenimi uyandırması ve mahremiyet kaygısı gibi olumsuz yanları vardır. Giyilebilir tabanlı yaklaşımda, elbiseye/vücuda yerleştirilen sensörler ile ivme, basınç, yön, manyetik alan [13] gibi değişikliklerin yanısıra kalp atış hızı [7] gibi fizyolojik değişiklikler de ölçülerek günlük hareket ile düşme ayırt edilmektedir. Cihazın kullanılabilirliği göz önüne alınarak sensörler çoğunlukla bilek, bel ve boyuna takılmaktadır. Düşme tespitinde en sık kullanılan sensör olan 3 eksenli ivmeölçer, az güç tüketimi sayesinde giyilebilir cihazın kullanılabilirliğini artırmaktadır.

Düşme tespiti çalışmaları, büyük çoğunlukla düşme simülasyonları ve günlük aktiviteler esnasında toplanan veriler ile yürütülmektedir. Bu çalışmada, önceki çalışmalardan farklı olarak halihazırdaki en kapsamlı düşme veri tabanı olan, 15 denek ile 35 tip düşme ve 44 tip günlük aktivite gerçekleştirilerek oluşturulan FallAID [13] veri setindeki belden toplanan 3 eksen ivmeölçer sinyalleri kullanılarak denetimsiz öğrenme temelli anomali tespit yöntemi ile düşmeler tespit edilmiştir. Gauss karışım modelinin (GMM) kullanıldığı bu çalışmada düşme durumları %91 oranında doğru olarak tespit edilmiştir ve elde edilen sonuçlar literatür ile karşılaştırılmıştır. Böylece, düşme olayının anomali olarak değerlendirilebileceği ve anomali tespiti yöntemlerinin düşme algılama çalışmalarında kullanılabileceği gösterilmiştir. Ayrıca hangi tip günlük aktivitelerin düşme olarak tespit edildiği detaylı olarak incelenmiş ve seçilen bazı günlük aktivite tipleri ile deneyler tekrarlanmıştır. Böylece düşme tespit sistemlerinin performansını arttırabilmek için belirli tip aktivitelerin üzerinde odaklanılabileceği gösterilmiştir.

Bölüm 2'de ilgili çalışmalar sunulacaktır. Bölüm 3'te kullanılan veri seti, sensör sinyallerinin ön işleme, kullanılan öznitelikler, GMM yöntemi ve tespit sonuçlarını değerlendirme kriteri üzerinde durulacaktır. Bölüm 4'te deneysel sonuçlara yer verilecektir. Bölüm 5'te sonuçlar ve düşme tespiti problemindeki çalışmalar ve eksiklikler

tartışılacaktır. Bölüm 6'da bazı öneriler ile çalışma sonlandırılacaktır.

2. İlgili Çalışmalar

Düşme olayının günlük aktivitelere kıyasla nadir rastlanan bir durum olması, araştırmacıları düşme simülasyonları ile veri toplamaya sevk etmektedir. Literatürde birçok düşme veri setine rastlanmaktadır. Ancak düşmelerin sebebi, şekli, yönü, düşme sonrası eylem gibi durumları tanımlayan genel kabul görmüş kurallar bulunmaması sebebiyle veri setlerindeki düşmeler ve sayıları çok farklı olabilmektedir. Bununla beraber veri setlerinin barındırdığı günlük aktivite tipleri ve sayısı da farklılık göstermektedir. Örneğin halka açık bir veri tabanı olan MobiAct, 9 tip günlük aktivite ve 4 tip düşme içermektedir [14]. SisFall veri seti, 19 tip günlük aktivite ve 15 tip düşme gerçekleştirilirken yapılan ölçümler ile oluşturulmuştur [15]. ASLH veri seti, 16 tip günlük aktivite ve 20 tip düşme barındırır [16]. UMAFall veri seti ise 8 tip günlük aktivite ve 3 tip düşmeye ait verilerden oluşmaktadır [17]. Seçilen düşme ve günlük aktivitelerin sayısı ve biçimsel farklılığı, geliştirilen düşme tespit yönteminin doğru sınanmasında baş rol oynamaktadır. Bu sebeple, çalışmada, diğer veri setlerine kıyasla yüksek sayıda günlük aktivite ve düşme tipleri barındıran ve düşmenin yönü, sonrası gibi durumları göz önünde bulunduran FallAIID veri seti kullanılarak, önerilen düşme tespit yöntemi değerlendirilmiştir.

Düşmenin tespiti, sensör verilerinin bir eşik ile kıyaslanması [9] veya denetimli/denetimsiz makine öğrenmesi yöntemleriyle [18] ile gerçekleştirilmektedir. Destek vektör makinesi (SVM) [19] k-en yakın komşular (KNN) [20], ileri beslemeli sinir ağı (NN) [21], derin öğrenme mimarileri [22], [23] denetimli öğrenme ile düşme tespitinde kullanılmıştır. Denetimli öğrenme ile, düşme tespitinde kullanılacak modeller elde edilebilmesine rağmen; düşmenin çok çeşitli olabilmesi (kayma, takılma, yana düşme, düşerken dönme...), ve bireylerin hareket biçimleri boy, kilo, yaş, cinsiyet, vücut biçimi... gibi sayısız etken ile değişmesi sebebi ile genel geçer bir eğitim modeline ulaşılması zordur. Denetimsiz anomali tespiti yaklaşımları bu engellere karşı farklı bir çözüm önerir.

Bir anomali, beklenen, alışılmış olandan farklı durum ve verilerdir. Düşme olayı günlük aktivitelere nazaran nadir rastlanan bir durumdur ve düşme olayının ürettiği sensör verilerinin günlük aktivite verilerinden farklı olması beklenir. Bu

durumda denetimsiz anomali tespiti yaklaşımı ile eğitim modelleri günlük aktivite verileri kullanılarak eğitilir ve modele göre anomali olduğu tespit edilen veriler düşmelere karşılık gelmektedir [7], [24], [25]. Düşme tespitinde, denetimsiz anomali algılama yaklaşımının denetimli öğrenmeye kıyasla sağladığı üstünlüklerden biri, eğitim modelinin yalnızca kolayca elde edilebilen günlük aktivite verileri gerektirmesidir. Böylece eğitim aşamasında düşme verileri kullanılmadığından, çok çeşitli düşme biçimlerinin dikkate alınmasına gerek yoktur. Bu artılarıyla denetimsiz anomali tespiti yaklaşımının uygulanabilirliği yüksektir. Literatürde oto kodlayıcı (autoencoder), tek sınıf KNN, tek sınıf SVM, GMM, Parzen olasılıksal NN gibi yöntemler ile düşme tespiti yapılmıştır [26]. GMM hızlı bir algoritmadır ve örneklerin anormallik derecesini hesaplamak için kullanılabilen istatistiksel çıkarımlar sağlar [27].

Young-Hoon ve arkadaşları ivmeölçer ve nabız sensörü verilerini beraber kullanarak GMM temelli denetimsiz makine öğrenimi yaklaşımı ile düşme tespiti gerçekleştirmişlerdir [7]. 6 tip düşme ve 13 tip günlük aktivite ile test ettikleri yöntemlerinin düşmeleri başarılı bir şekilde tespit edebildiklerini göstermiştir.

Lin Chen ve arkadaşları, bir düşme tespit çözümünün kullanım kolaylığını göz önüne alarak, akıllı saat üzerinde çalışan denetimsiz anomali tespiti yaklaşımı önermişlerdir [28]. Dışbükey gövde (convex hull) temelli tek sınıf sınıflandırmanın tercih edildiği çalışmalarında, geliştirilen yöntem 16 tip günlük aktivite ve 13 tip düşme ile test edilmiştir. Önerilen yöntem, denetimli öğrenme temelli düşme tespiti yöntemleri ile kıyaslanmış ve daha yüksek performans sağladığı bildirilmiştir.

Denetimsiz anomali tespiti yaklaşımı ile düşmelerin belirlenmesi ile ilgili en kapsamlı çalışma José ve arkadaşları tarafından gerçekleştirilmiştir [26]. İçlerinde GMM'nin de bulunduğu birden fazla denetimsiz makine öğrenimi yönteminin düşme tespitindeki başarısını farklı veri setleri üzerinde test etmişlerdir. Çalışmalarında eğitim esnasında düşmelere ihtiyaç duymayan bu yöntemlerin düşme tespiti performanslarının, denetimli makine öğrenimi yöntemlerine oldukça yakın olduğunu göstermişlerdir. Bununla beraber, bu denetimsiz öğrenme yöntemlerinin, eğitim esnasında karşılaşmadıkları günlük aktivite tiplerini kolaylıkla anomali olarak kabul edebildiğini dolayısıyla eğitim setinin kapsamlı olması gerektiğini belirtmişlerdir.


3. Materyal ve Yöntem

Bu bölümde kullanılan veri seti, ön işleme adımları ve anomali tespit yöntemi açıklanacaktır.

3.1 Veri seti

Düşme tespiti probleminde kullanılabilen halka açık birçok veri seti vardır. Bu veri setlerinde kullanılan sensörler, ölçüm noktaları, denek sayısı, günlük aktivite ve düşme tipi sayıları farklılık göstermektedir. Bu çalışmada kullanılan FallAIID veri seti, şu ana kadar geliştirilen en kapsamlı veri setidir. 35 tip düşme simülasyonuna ve 44 tip günlük aktiviteye karşılık gelen sinyalleri

barındırmaktadır. Veri seti, 15 denek ile bel, boyun ve bilekten ivmeölçer, jiroskop, barometre ve manyetometre ile alınan 20 saniyelik sinyaller ile oluşturulmuştur (Şekil 1). Günlük aktiviteler yürüme gibi düşmeden kolayca ayırt edilebilen periyodik hareketleri kapsadığı gibi çömelme, yatağa uzanma gibi düşmeye benzeyen geçici hareketleri de kapsamaktadır. Bununla birlikte denekler, alışık olmadıkları günlük aktiviteleri gerçekleştirmemiş ve rahat hissetmedikleri ölçüm noktalarını kabul etmemiştir. Bu sebeple deneklerin kullandığı cihazlar, ölçüm noktaları ve tercih ettiği düşme günlük aktivite tipleri farklılık arz etmektedir. Bu veri toplama prosedürleri, düşme tespit sisteminin performansının güvenilirliğini artırmaktadır.



Şekil 1. FallAIID ölçüm noktaları, ölçüm cihazı ve sinyaller ([13]'den alınarak düzenlenmiştir).

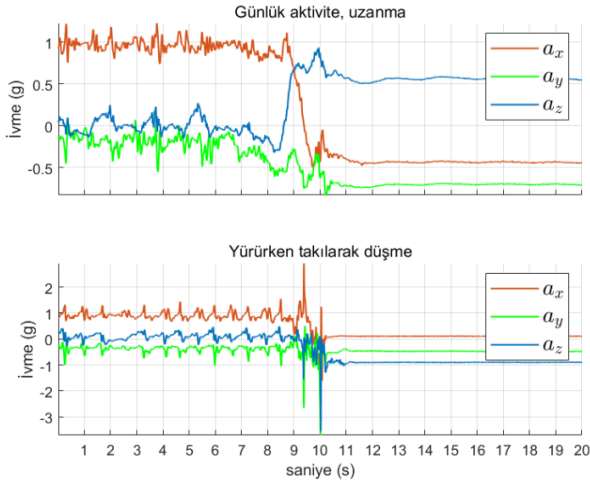
Ekteki Tablo 5'de günlük aktiviteler ve düşme tipleri gösterilmiştir. Günlük aktiviteler veri setini oluşturan araştırmacılar tarafından periyodik, kısmen periyodik ve geçici tip olarak sınıflandırılmıştır. Tabloda belden alınan ivme ölçer sinyallerinin karşılık geldiği günlük aktiviteler (35 tip) ve ayağa kalkma gibi geçici günlük aktiviteler (10 tip) işaretlenmiştir.

3.2 Ön-işleme ve öznelilikler

Farklı sensör tiplerinin eş zamanlı kullanılması ile daha başarılı düşme tespit sistemleri geliştirilmesine rağmen, az güç tüketimi sayesinde ivmeölçer kullanılabilirlik hususunda avantaj sağlamaktadır. Bireyin cihazı yatak, banyo gibi her ortamda kullanması arzu edildiğinde, veri toplama noktası için bilek ön plana çıkmaktadır. Ancak bileğin daha hareketli bir bölge olması sinyaldeki gürültü ve istenmeyen bileşenlerin artmasına sebep olmakta düşmenin tespitini zorlaştırmaktadır. Bu

durumlar göz önüne alınarak çalışmada düşme tespiti için belden toplanan 3-eksen ivmeölçer sinyalleri tercih edilmiştir. Şekil 2'de uzanma ve yürürken takılarak düşme olayları esnasında elde edilen 3-eksen ivmeölçer sinyalleri (a_x, a_y, a_z) gösterilmiştir.

3-eksen ivmeölçer tarafından üretilen sinyaller vücut hareketi bileşenleriyle beraber yerçekimi ivmesinin sebep olduğu bileşenlere de sahip olduğu için, yerçekimi ivmesinin sebep olduğu bileşenlerin sadece düşük frekansa sahip olduğu varsayılarak, 0,3 Hz. yüksek geçiren FIR filtre ile yerçekimi ivmesi bileşenleri süzölmüştür.



Şekil 2. Günlük aktivite ve düşme ile elde edilen 3-eksen ivmeölçer sinyalleri.

Günlük aktivite ve düşmeleri temsil eden öznitelikler için, düşme tespitinde sıklıkla tercih edilen, sinyalin zaman bölgesi ve enerji dağılımı özelliklerinden faydalanılmıştır [5], [7]. İvmeölçerin ürettiği her bir sinyalden Tablo 1'de görülen öznitelikler elde edilmiştir. Böylece düşme tespiti için 33 adet öznitelik hesaplanmıştır.

Tablo 1. Düşme tespitinde kullanılan öznitelikler

a_x, a_y, a_z 'nin ortalama değerleri (mean)
a_x, a_y, a_z 'nin ortanca değerleri (median)
a_x, a_y, a_z 'nin en büyük değerleri (max)
a_x, a_y, a_z 'nin standart sapmaları (std)
a_x, a_y, a_z 'nin aralığı (range)
a_x, a_y, a_z 'nin ortalama sapmaları (mad)
a_x, a_y, a_z 'nin basıklık değerleri (kurtosis)
a_x, a_y, a_z 'nin çarpıklık değerleri (skewness)
a_x, a_y, a_z 'nin spektral entropi değerleri
a_x, a_y, a_z 'nin enerjileri (tde)
a_x, a_y, a_z 'nin genlik alanı değerleri (sma)

3.3. Gauss karışım modeli ve anomali tespiti

Karışım modeli, alt kümelerden oluşan genel bir topluluğu ifade eden istatistiksel bir modeldir. Bu alt kümelerdeki gözlemlerin olasılık dağılımı normal dağılım olduğunda model Gauss karışım modeli adını alır [27]. K adet alt kümeye sahip tek boyutlu GMM denklem 1'de verilmiştir.

$$p(x) = \sum_{i=1}^K \phi_i N(x|\mu_i, \sigma_i) \quad (1)$$

$$N(x|\mu_i, \sigma_i) = \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{(x-\mu_i)^2}{2\sigma_i^2}}, \quad \sum_{i=1}^K \phi_i = 1$$



Burada N , x gözleminin alt kümelere ait olasılık değeri, ϕ_i , μ_i , σ_i sırasıyla i . alt kümenin ağırlığı, ortalaması ve varyansdır. 3a'da 3 alt kümeye ait tek boyutlu karışım modelinin dağılımı görülmektedir. K adet alt kümeye sahip çok boyutlu GMM ise denklem 2 ile ifade edilir.

$$p(x) = \sum_{i=1}^K \phi_i N(x|\mu_i, \Sigma_i)$$

$$N(x|\mu_i, \Sigma_i) = \frac{1}{\sqrt{(2\pi)^K |\Sigma_i|}} e^{-\frac{1}{2}(x-\mu_i)^T \Sigma_i^{-1} (x-\mu_i)}, \quad (2)$$

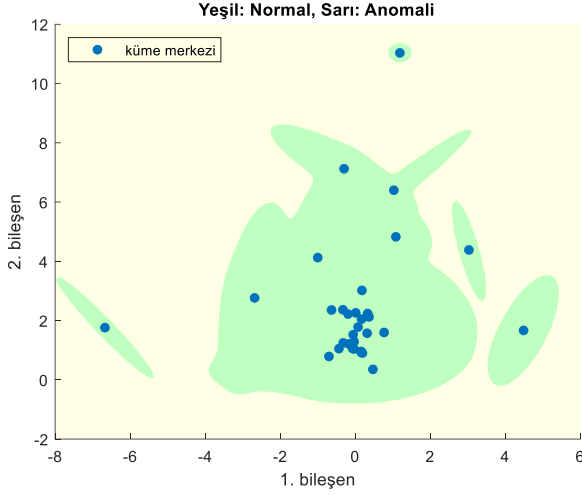
$$\sum_{i=1}^K \phi_i = 1$$

Burada μ_i ortalama vektörünü, Σ_i kovaryans matrisini ve ϕ_i küme ağırlığını ifade etmektedir. Topluluktaki gözlemlerin beklenen değerini en yüksek yapan alt küme parametrelerinin (ortalama, kovaryans ve ağırlık değerleri) hesaplanmasında beklenti maksimizasyonu (Expectation-maximization) algoritması tercih edilmektedir. Böylece denetimsiz olarak GMM oluşturulmuş, değer vektörleri K adet kümeye paylaştırılmış olur.



Şekil 3. Tek boyutlu GMM'nin dağılımı. Mavi ile alt kümelerin ağırlıklandırılmış ($\phi_1 = \phi_2 = \phi_3 = 1/3$) dağılımı, kırmızı ile karışım modelinin dağılımı gösterilmiştir. b) İki adet alt kümeye sahip 2 boyutlu GMM.

Bir anomali, nadir rastlanan, alışılmış olandan farklı verilerdir. Elde edilen GMM'ye göre, test edilen verinin olasılığı çok düşük, bu veri ile karşılaşılma ihtimali zayıf olduğunda bu veri anomali olarak kabul edilir. 3b' de 2 adet alt kümeyle sahip 2 boyutlu GMM ve anomali olarak kabul edilebilecek bir veri görünmektedir.



Şekil 4. İki bileşenli GMM ile anomali tespiti yaklaşımı.

Bu çalışmada GMM ile düşme tespiti gerçekleştirilebilmek için, K adet alt kümeyle sahip, elde edilen özneliklerin adedi olan 33 boyutlu model üretilmiştir. Burada alt küme sayısı K , Bulgular bölümünde bahsedilecek olan günlük aktivite tipi sayısıdır. Model, test aşamasında karşılaştığı olayların, her bir alt kümeyle dahil olma olasılığını hesaplar. Alt kümelere dahil olabilmesi için gereken eşik değere ulaşamayan olaylar anomali, dolayısıyla düşme kabul edilmiştir. Bu eşik değeri, modelin oluşturulması esnasında eğitim verilerinin %1'i anomali olduğu farz edilerek belirlenmiştir. Düşme tespit yaklaşımını görselleştirmek için Şekil 'te, yalnız iki bileşen ile elde edilen modelin anomali sınırları ve küme merkezleri sunulmuştur. Test edilen bir veri, sarı bölgeye düştüğünde veri anomali olarak kabul edilmektedir.

3.4. Değerlendirme kriteri

Düşme tespiti sistemlerinin performansı doğruluk, duyarlılık ve özgüllük ve doğruluk kriterleri ile değerlendirilebilir

$$Duyarluluk = \frac{DP}{DP + YN} \quad (3)$$

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (4)$$

$$\text{Doğruluk} = \frac{Duyarluluk}{2} + \frac{\text{Özgüllük}}{2} \quad (5)$$

Burada; DP düşmenin tespit edilebilmesini, YN düşmenin tespit edilememesini, DN günlük aktivitenin tespit edilebilmesini, YP ise günlük aktivitenin tespit edilememesini ifade eder. Bu durumda duyarlılık kriteri, düşmelerin ne kadar doğru tespit edilebildiğini vurgularken özgüllük ise sistemin günlük aktivite tespitindeki başarısı ile; farklı bir ifade ile düşme tespit sisteminin hatalı düşme alarmlarından kaçınması ile ilişkilidir.

Düşme tespiti sistemlerinde günlük aktivite ve düşme verilerinin sayısında dengesizlik olabileceği, karşılaşılan günlük aktivite verileri daha çok olacağı için sistem doğruluğu, duyarlılık ve özgüllük değerlerinden faydalanılarak hesaplanabilir.

4. Bulgular

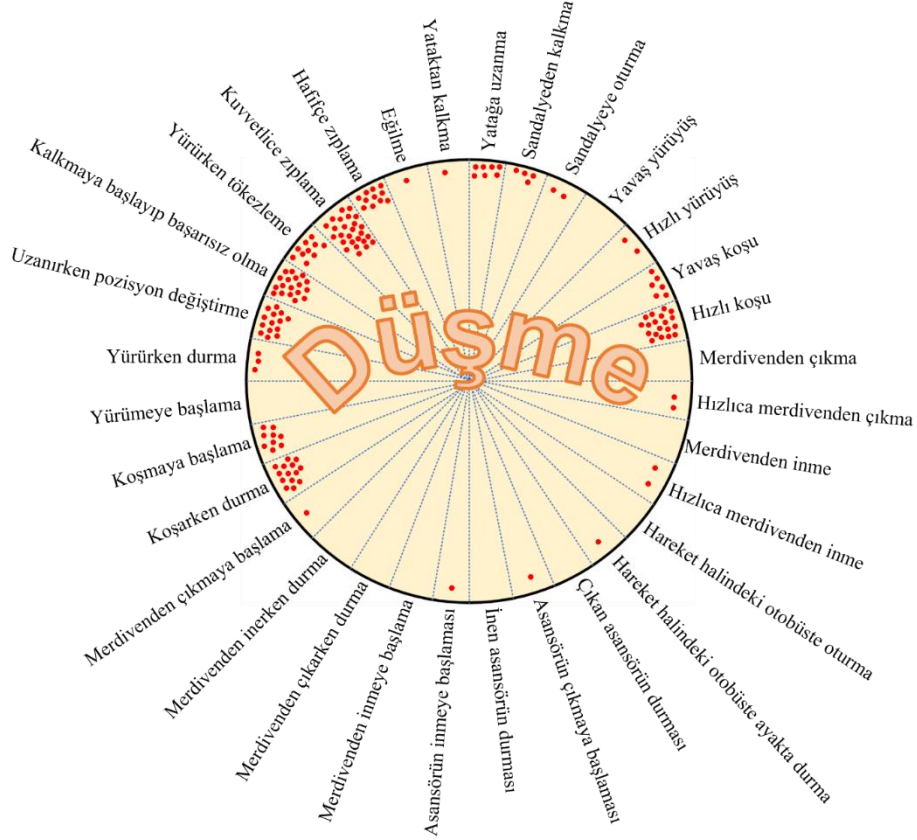
Önerilen yöntemin performansı, tüm tiplerdeki günlük aktivite ve sadece geçici tip günlük aktivite verilerinin kullanıldığı deneyler ile incelenmiştir. Deneylerde birini dışarda bırak çapraz doğrulama (Leave-one-subject-out cross validation) yaklaşımı kullanılmıştır. Bir denek hariç tüm deneklerdeki günlük aktivite verileri ile model eğitilmiş, dışarıda bırakılan denekin günlük aktivite ve düşme verileri ile model test edilmiştir.

Tablo 2. GMM ile tüm günlük aktivite tipleri kullanılan deneylerde elde edilen düşme tespiti sonucu. Tablodaki – simgesi denekte ivmeölçer ile belden alınan günlük aktivite veya düşme verisi olmadığını gösterir.

	Duyarluluk (%)	Özgüllük (%)	Doğruluk (%)
Denek 1	95,5	100,0	97,7
Denek 2	95,2	82,9	89,0
Denek 3	91,9	100,0	96,0
Denek 4	93,8	–	93,8
Denek 5	84,6	94,1	89,4
Denek 7	80,3	94,0	87,2
Denek 8	88,2	87,5	87,8
Denek 9	91,4	93,5	92,5
Denek 10	90,1	–	90,1
Denek 11	89,9	94,7	92,3
Denek 12	87,2	93,5	90,4
Denek 13	84,2	87,3	85,8
Denek 14	88,9	–	88,9
Denek 15	–	100	100
Ortalama	89	93,6	91,3

Tüm tiplerdeki günlük aktivite verilerinin kullanıldığı deneylerde, 32 alt kümeye sahip GMM eğitilmiştir. Elde edilen test sonuçları Tablo 2’de sunulmuştur. 14 denek ile yapılan deneylerde (6. deneğe ait belden ivmeölçer verisi

bulunmamaktadır) ortalama %89 duyarlılık, %93,6 özgüllük ve %91,3 doğruluk değerlerine ulaşılmıştır. Şekil ’de ise hangi günlük aktivitelerin ne sıklıkla düşme olarak belirlendiği görülmektedir.



Şekil 5. Hatalı tespit edilen günlük aktiviteler. Burada kırmızı noktalar hatalı tespit edilen günlük aktivitelerin sayısını göstermektedir.

Sadece geçici ti günlük aktivite verilerinin kullanıldığı deneylerde ise GMM 10 adet alt kümeye sahiptir. Elde edilen sonuçlar Tablo 3’de görülmektedir. 14 denek ile yapılan deneylerde ortalama %91,7 duyarlılık, %85,4 özgüllük ve %88,6 doğruluk değerlerine ulaşılmıştır. Yalnızca düşmeyi andıran günlük aktivitelerin kullanılması özgüllük sonuçlarının düşmesine sebep olmuştur. Başka bir deyişle günlük aktivitelerin düşme olarak tespiti, hatalı düşme alarmlarının sayısı artmıştır.

Tablo 3. GMM ile geçici günlük aktivite tipleri kullanılan deneylerde elde edilen düşme tespiti sonucu. Tablodaki – simgesi denekte ivmeölçer ile belden alınan günlük aktivite veya düşme verisi olmadığını gösterir.

	Duyarlılık (%)	Özgüllük (%)	Doğruluk (%)
Denek 1	97,4	96,4	96,9
Denek 2	94,3	63,4	78,9
Denek 3	92,0	91,9	92,0
Denek 4	93,9	–	93,9
Denek 5	95,0	64,7	79,9
Denek 7	78,3	92,5	85,4
Denek 8	92,9	81,3	87,1
Denek 9	94,4	90,3	92,4
Denek 10	98,0	–	98,0
Denek 11	92,9	84,2	88,5
Denek 12	88,3	96,8	92,6
Denek 13	90,1	73,0	81,6
Denek 14	91,7	–	91,7
Denek 15	–	95,3	95,3
Ortalama	91,7	85,4	88,6

5. Tartışma

Deneysel sonuçlarda görüldüğü gibi GMM ile düşmeler %91 civarında doğru olarak tespit edilmiştir. Tablo 4’de elde edilen sonuç ile literatürdeki FallAİD veri setinde denetimli öğrenme ile elde edilen sonuçlar görülmektedir. Önerilen metot ile denetimli öğrenme temelli düşme tespit sonuçlarına benzer tespit doğruluğu elde edilmiştir. Yalnız günlük aktivite verileri kullanılarak eğitilen model ile elde edilen sonuçların, düşme ve günlük aktivite verileri ile eğitilen modele yakın sonuçlar vermesi, düşme tespiti için yalnız günlük aktivite verilerinin yeterli olduğu yaklaşımını desteklemektedir [7]. Düşme tespit sistemlerinin geliştirilmesinde yalnız günlük aktivite verilerinin kullanımı, yapay veya gerçek düşme verilerine ihtiyaç bırakmamakta, veri toplama adımını kolaylaştırmaktadır. Günlük aktivite verilerinin yeterliliği; “her ne kadar günlük aktiviteler sonucu ortaya çıkacak veriler, bireyler arasında çok değişiklik gösterecek olsa bile, bireylerdeki sıklıkla gerçekleştirilen aktivitelerin aynı/benzer olması sebebiyle, günlük aktivitelerden elde edilen veriler düşmelere kıyasla daha düzenli bir yapı sergiler” yaklaşımı ile açıklanabilir.

Tablo 4. FallAİD veri setinde önerilen yöntem ile denetimli öğrenme yöntemlerinin karşılaştırılması.

	Metot	Doğruluk
Önerilen	GMM	%91,3
Majd Saleh [13]	SVM	%85,9
Majd Saleh [13]	Derin Evrimsel NN	%93,1
Majd Saleh [13]	KNN	%89,7

Bu çalışmada, önerilen metot, her tipten günlük aktiviteler ile değerlendirilmesinin yanısıra yalnızca geçici tip günlük aktiviteler ile de değerlendirilmiştir. Bireylerin gerçekleştirdiği birçok günlük aktivite periyodik yapıdadır veya periyodik kısımlar içermektedir. Yürüme, merdiven çıkma, el sallama vb. gibi hareketler periyodik hareketlerdir. Ancak bireyin düşmesi ise anlık ortaya çıkan bir olaydır. Dolayısıyla periyodik günlük hareketler kolaylıkla düşme olayından ayırt edilebilirken geçici günlük aktiviteler ise düşme ile karışabilmektedir. Şekil ve Tablo 3’de bu durum açıkça görülmektedir. Bu ve benzeri tipteki olayların doğru tespiti için farklı özneliklerin geliştirilmesi çözüm olabilir.

Bir kısım günlük aktivite ve düşme tiplerinin kolaylıkla tespit edilirken -ki bu kısım gün boyu sıklıkla icra edilen periyodik hareketlerdir- bir kısmının ise sıklıkla hatalı tespit edilmesi, düşme tespit sistemlerinin

performansının tüm günlük aktivite ve düşmeler kullanılarak hesaplanan duyarlılık, özgüllük ve ortalama kriterlerine ek değerlendirme kriterlerine ihtiyaç duyduğunu göstermektedir. Günlük aktivite düşme tiplerinin üzerinde anlaşmaya varılmış bir taksonomisi yoktur, ancak bazı günlük aktivitelerin düşmeye yakın olarak etiketlenmesi ve bazı düşmelerin günlük aktiviteye yakın olarak etiketlenmesi ve bu sınıfların performansının ayrı ayrı hesaplanması genel sistem performansını daha fazla yansıtacaktır.

Düşme tespiti çalışmaları yaklaşık yirmi yıldır devam etmesine ve son yıllarda hız kazanmasına rağmen halen araştırmalara ihtiyaç duyan bir çalışma alanı olarak kabul edilmektedir. Eş zamanlı olarak çeşitli sensörlerin kullanılması, eşikleme ile tespit yöntemlerinin yerini makine öğrenmesi yaklaşımlarına bırakmasına rağmen tatmin edici bir veri seti olmaması düşme tespit probleminin aktifliğinin devam etme sebeplerinden biridir [10]. Tespit sistemlerinin hedef kitlesi yaşlı bireyler olmasına rağmen veri setleri ancak genç bireylerden, düşme senaryoları ile elde edilen verilerden oluşmaktadır. Yaşlı bireylerden gerçek düşme verilerinin elde edilmesi çok zor olması, düşme tespiti için yalnızca günlük aktivite verilerine ihtiyaç duyan anomali tespiti yöntemlerini desteklemektedir. Ayrıca yaşlı bireylerin günlük aktiviteleri yavaş, düşmenin ise kinematikleri tamamen farklı, ani ve hızlı bir eylem olması, düşmenin yaşlılarda anomali yaklaşımı ile tespitini kolaylaştıracağı öngörülebilir.

6. Sonuç

Bu çalışmada denetimsiz anomali yaklaşımı ile düşme tespiti için GMM temelli bir yöntem önerilmiş ve yöntem en kapsamlı veri seti FallAİD üzerinde test edilmiş ve sonuçlar literatürdeki denetimli öğrenme yöntemleri ile kıyaslanmıştır. Sonuç olarak, anomali yaklaşımı, düşme tespiti problemi için umut verici bir çözüm sunmaktadır. Farklı anomali tespit yöntemlerinin aynı ve geniş bir veri setinde incelenerek probleme uygun yöntem belirlenebilir. Ayrıca düşme ve günlük aktivite arasındaki farkları daha iyi betimleyen özneliklerin tanımlanması anomali yaklaşımının başarısını artıracaktır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

References

- [1] World Health Organization, “Falls.” [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/falls>. [Accessed: 12-Jun-2021].
- [2] R. Rajagopalan, I. Litvan, and T. P. Jung, “Fall prediction and prevention systems: Recent trends, challenges, and future research directions,” *Sensors (Switzerland)*, vol. 17, no. 11, p. 2509, Nov. 2017.
- [3] United Nations, “World Population Ageing 2019.” [Online]. Available: <https://www.un.org/en/development/desa/population/publications/pdf/ageing/WorldPopulationAgeing2019-Highlights.pdf>. [Accessed: 13-Jun-2021].
- [4] Türkiye İstatistik Kurumu, “İstatistiklerle Yaşlılar, 2020.” [Online]. Available: <https://data.tuik.gov.tr/Bulten/Index?p=İstatistiklerle-Yaşlılar-2020-37227>. [Accessed: 13-Jun-2021].
- [5] K.-C. Liu, C.-Y. Hsieh, H.-Y. Huang, S. J.-P. Hsu, and C.-T. Chan, “An Analysis of Segmentation Approaches and Window Sizes in Wearable-Based Critical Fall Detection Systems With Machine Learning Models,” *IEEE Sens. J.*, vol. 20, no. 6, pp. 3303–3313, Mar. 2020.
- [6] O. Kerdjadj, N. Ramzan, K. Ghanem, A. Amira, and F. Chouireb, “Fall detection and human activity classification using wearable sensors and compressed sensing,” *J. Ambient Intell. Humaniz. Comput.*, vol. 11, no. 1, pp. 349–361, 2020.
- [7] Y.-H. Nho, J. G. Lim, and D.-S. Kwon, “Cluster-Analysis-Based User-Adaptive Fall Detection Using Fusion of Heart Rate Sensor and Accelerometer in a Wearable Device,” *IEEE Access*, vol. 8, pp. 40389–40401, 2020.
- [8] M. Saleh and R. L. B. Jeannes, “Elderly Fall Detection Using Wearable Sensors: A Low Cost Highly Accurate Algorithm,” *IEEE Sens. J.*, vol. 19, no. 8, pp. 3156–3164, 2019.
- [9] C. Wang *et al.*, “Low-Power Fall Detector Using Triaxial Accelerometry and Barometric Pressure Sensing,” *IEEE Trans. Ind. Informatics*, vol. 12, no. 6, pp. 2302–2311, 2016.
- [10] X. Wang, J. Ellul, and G. Azzopardi, “Elderly Fall Detection Systems: A Literature Survey,” *Front. Robot. AI*, vol. 7, Jun. 2020.
- [11] Y. M. Galvao, L. Portela, J. Ferreira, P. Barros, O. A. De Araujo Fagundes, and B. J. T. Fernandes, “A Framework for Anomaly Identification Applied on Fall Detection,” *IEEE Access*, vol. 9, pp. 77264–77274, 2021.
- [12] J. Nogas, S. S. Khan, and A. Mihailidis, “DeepFall: Non-Invasive Fall Detection with Deep Spatio-Temporal Convolutional Autoencoders,” *J. Healthc. Informatics Res.*, vol. 4, no. 1, pp. 50–70, 2020.
- [13] M. Saleh, M. Abbas, and R. B. Le Jeannes, “FallAllD: An Open Dataset of Human Falls and Activities of Daily Living for Classical and Deep Learning Applications,” *IEEE Sens. J.*, vol. 21, no. 2, pp. 1849–1858, Jan. 2021.
- [14] G. Vavoulas, C. Chatzaki, T. Malliotakis, M. Pedititis, and M. Tsiknakis, “The MobiAct dataset: Recognition of activities of daily living using smartphones,” *ICT4AWE 2016 - 2nd Int. Conf. Inf. Commun. Technol. Ageing Well e-Health, Proc.*, pp. 143–151, 2016.
- [15] A. Sucerquia, J. D. López, and J. F. Vargas-Bonilla, “SisFall: A fall and movement dataset,” *Sensors (Switzerland)*, vol. 17, no. 1, 2017.
- [16] A. T. Özdemir, “An analysis on sensor locations of the human body for wearable fall detection devices: Principles and practice,” *Sensors (Switzerland)*, vol. 16, no. 8, 2016.
- [17] E. Casilari, J. A. Santoyo-Ramón, and J. M. Cano-García, “UMAFall: A Multisensor Dataset for the Research on Automatic Fall Detection,” *Procedia Comput. Sci.*, vol. 110, pp. 32–39, 2017.
- [18] S. Usmani, A. Saboor, M. Haris, M. A. Khan, and H. Park, “Latest Research Trends in Fall Detection and Prevention Using Machine Learning: A Systematic Review,” *Sensors*, vol. 21, no. 15, p. 5134, Jul. 2021.
- [19] W. Xiong *et al.*, “Accurate Fall Detection Algorithm Based on SBPSO-SVM Classifier,” *ACM Int. Conf. Proceeding Ser.*, pp. 83–86, 2018.
- [20] F. Hussain, F. Hussain, M. Ehatisham-Ul-Haq, and M. A. Azam, “Activity-Aware Fall Detection and Recognition Based on Wearable Sensors,” *IEEE Sens. J.*, vol. 19, no. 12, pp. 4528–4536, 2019.
- [21] E. Casilari-Pérez and F. García-Lagos, “A comprehensive study on the use of artificial neural networks in wearable fall detection systems,” *Expert Syst. Appl.*, vol. 138, 2019.
- [22] X. Wu, Y. Zheng, C.-H. Chu, L. Cheng, and J. Kim, “Applying deep learning technology for automatic fall detection using mobile sensors,” *Biomed. Signal Process. Control*, vol. 72, p. 103355, Feb. 2022.

- [23] M. M. Islam *et al.*, “Deep Learning Based Systems Developed for Fall Detection: A Review,” *IEEE Access*, vol. 8, pp. 166117–166137, 2020.
- [24] S. S. Khan and B. Taati, “Detecting unseen falls from wearable devices using channel-wise ensemble of autoencoders,” *Expert Syst. Appl.*, vol. 87, pp. 280–290, 2017.
- [25] S. Zhao, W. Li, and J. Cao, “A user-adaptive algorithm for activity recognition based on K-means clustering, local outlier factor, and multivariate gaussian distribution,” *Sensors (Switzerland)*, vol. 18, no. 6, 2018.
- [26] J. A. Santoyo-Ramón, E. Casilari, and J. M. Cano-García, “A study of one-class classification algorithms for wearable fall sensors,” *Biosensors*, vol. 11, no. 8, 2021.
- [27] L. Li, R. J. Hansman, R. Palacios, and R. Welsch, “Anomaly detection via a Gaussian Mixture Model for flight operation and safety monitoring,” *Transp. Res. Part C Emerg. Technol.*, vol. 64, pp. 45–57, Mar. 2016.
- [28] L. Chen, R. Li, H. Zhang, L. Tian, and N. Chen, “Intelligent fall detection method based on accelerometer data from a wrist-worn smart watch,” *Measurement*, vol. 140, pp. 215–226, Jul. 2019.

EK**Tablo 5.** FallAID veri setindeki günlük aktivite ve düşme tipleri. Belden alınan verilerin karşılık geldiği günlük aktiviteler ^b işareti ile gösterilmiştir. Geçici tip günlük aktiviteler italik yazılmıştır.

Günlük aktivite tipleri		Düşme tipleri				
		Düşme öncesi eylem	Düşme sebebi	Düşme yönü	Dönerek düşme	Düşme sonrası kalkma
^b Yavaş yürüyüş	<i>Tek sefer alkışlama</i>	Yürüyüş	Takılma	İleri	Hayır	Hayır
^b Hızlı yürüyüş	<i>El kaldırma</i>	Yürüyüş	Takılma	İleri	Hayır	Evet
^b Yavaş koşu	<i>El idirme</i>	Yürüyüş	Kayma	İleri	Hayır	Hayır
^b Hızlı koşu	<i>Elini kaldırıp hemen indirme</i>	Yürüyüş	Kayma	İleri	Hayır	Evet
^b Yavaşça merdivenden çıkma	<i>Masaya el ile vurma</i>	Yürüyüş	Kayma	İleri	Evet	Hayır
^b Hızlıca merdivenden çıkma	^b Yürürken durma	Yürüyüş	Kayma	İleri	Evet	Evet
^b Yavaşça merdivenden inme	^b Yürümeye başlama	Yürüyüş	Kayma	Geri	Hayır	Hayır
^b Hızlıca merdivenden inme	^b Koşmaya başlama	Yürüyüş	Kayma	Geri	Hayır	Evet
Alkışlama	^b Koşarken durma	Yürüyüş	Kayma	Geri	Evet	Hayır
El sallama	Alkışlamaya başlama	Yürüyüş	Kayma	Geri	Evet	Evet
El sıkışma	Alkışlarken durma	Yürüyüş	Baygınlık	Geri	Hayır	Hayır
^b Sandalyeye oturma	El sallamaya başlama	Yürüyüş	Baygınlık	Geri	Hayır	Hayır
^b Sandalyeden kalkma	El sallarken durma	Yürüyüş	Baygınlık	Yana	Hayır	Hayır
^b Kalkmaya başlayıp başarısız olma	^b Merdivenden çıkmaya başlama	Yürüyüş	Baygınlık	İleri	Hayır	Hayır
^b Yatağa uzanma	^b Merdivenden çıkarken durma	Oturma/yatma girişimi	Denge kaybı	İleri	Hayır	Hayır
^b Yataktan kalkma	^b Merdivenden inmeye başlama	Oturma/yatma girişimi	Denge kaybı	İleri	Hayır	Evet
^b Uzanırken pozisyon değiştirme	^b Merdivenden inerken durma	Oturma/yatma girişimi	Denge kaybı	Geri	Hayır	Hayır
^b Yürürken tökeleme	^b Asansörün inmeye başlaması	Oturma/yatma girişimi	Denge kaybı	Geri	Hayır	Evet
^b Haşifçe zıplama	^b İnen asansörün durması	Oturma/yatma girişimi	Denge kaybı	Yana	Hayır	Hayır
^b Kuvvetlice zıplama	^b Asansörün çıkmaya başlaması	Oturma/yatma girişimi	Denge kaybı	Yana	Hayır	Evet
^b Eğilme	^b Çıkan asansörün durması	Koşu	Takılma	İleri	Hayır	Hayır
^b Hareket halindeki otobüste oturma	^b Hareket halindeki otobüste ayakta durma	Koşu	Takılma	İleri	Hayır	Evet
		Koşu	Kayma	İleri	Hayır	Hayır
		Koşu	Kayma	İleri	Hayır	Evet
		Koşu	Kayma	İleri	Evet	Hayır
		Koşu	Kayma	İleri	Evet	Evet
		Yatış	Yatarken dönme	Yana	Hayır	Hayır
		Yatış	Yatarken dönme	Yana	Hayır	Evet
		Sandalyede oturuş	Baygınlık	İleri	Hayır	Hayır
		Sandalyede oturuş	Baygınlık	Geri	Hayır	Hayır
		Sandalyede oturuş	Baygınlık	Yana	Hayır	Hayır
		Ayakta bekleyiş	Baygınlık	İleri	Hayır	Hayır
		Ayakta bekleyiş	Baygınlık	Geri	Hayır	Hayır
		Ayakta bekleyiş	Baygınlık	Yana	Hayır	Hayır
		Ayakta bekleyiş	Baygınlık	Dik	Hayır	Hayır