

Banyo Duş Ortamı Güvenlik Takip Sistemi

Safety Tracking System for Bathroom Shower Environment

Eren Ölmez*, Mehmet Oktay Özsoy*, Ramil Jabiyev*, Beren Ansen*, Umut Eren Aktürk*, Ege Bora Oral*, Can Soygür*, Billur Barshan*, Mehmet Alper Kutay*, Yasemin Afacan†

*Elektrik ve Elektronik Mühendisliği Bölümü, Bilkent Üniversitesi, Ankara, Türkiye

†İç Mimarlık ve Çevre Tasarımı Bölümü, Bilkent Üniversitesi, Ankara, Türkiye

eren.olmez152@gmail.com, metay_ozsoy@hotmail.com, ramiljabiyev2019@gmail.com, berenansen@hotmail.com, eren.akturk@bilkent.edu.tr, egebora2000@gmail.com, cansoygur@gmail.com, billur@ee.bilkent.edu.tr, kutay@ee.bilkent.edu.tr, yasemine@bilkent.edu.tr

Özetçe —Bu çalışmada, banyoların duş bölümlerinde gerçekleşen ve özellikle yaşlı bireyler için ölümcül nitelikte olabilen düşme kazalarına çözüm getirilmesi amaçlanmıştır. Çalışma kapsamında, banyo duş ortamında gerçekleşen düşmeleri saptayarak gerekli acil durum senaryolarını yürürlüğe alabilen bir sistem geliştirilmiştir. Bu amaçla, radar sensörleri ile IMU'lardan oluşan bir sistem kurulmuş ve makine öğrenmesine dayalı %96.5 doğruluk oranı veren düşme tespit algoritması geliştirilmiştir. Duşakabin kapısı ve duş başlığının hareketlilik durumu, düşmenin saptanmasında destekleyici olarak kullanılmakta olup düşme tespit edilmesi durumunda yapılacak uyarılar IoT üzerinden gerekli noktalara iletilmektedir.

Anahtar Kelimeler—Yaşlı birey düşmeleri, düşme tespiti, radar sensörü, ataletsel ölçüm birimi (IMU), nesnelerin interneti (IoT).

Abstract—This study is aimed at recognizing fall incidents that occur in the bathroom shower area. Bathroom falls are one of the primary reasons for injuries (which can be fatal), especially for the elderly. For that reason, a system that can detect bathroom falls and trigger necessary emergency scenarios is implemented. To that end, a system comprising radar sensors and IMUs is implemented. The information regarding the door and the shower head is used in a supportive way for fall detection. If a fall is detected, fall occurrence warning is sent to the necessary destinations through IoT.

Keywords—Elderly falls, fall detection, radar sensor, Inertial Measurement Unit (IMU), Internet of Things (IoT).

I. GİRİŞ

Geriatrik banyolar, günümüzde giderek önem kazanan ve önümüzdeki yıllarda da önemi artması beklenen bir araştırma konusudur. Dünya Sağlık Örgütü'ne göre her yıl 65 yaş üstü kişilerin %28–35'i düşmektedir [1]. Düşmeye bağlı olarak ortaya çıkan yaralanmalar ağrı, sakatlık ve bazı durumlarda ölüme dahi yol açabilmektedir. Ev içi düşmelerin en yaygın olarak gerçekleştiği yer ise banyo ortamıdır [2]. Bu bilgiler ışığında, banyo duş ortamında gerçekleşen düşmeleri olabildiğince hızlı saptamanın önemi anlaşılmaktadır.

II. İLGİLİ ÇALIŞMALAR

Düşme tespiti için CMOS görüntü sensörleri (video kameraları gibi) yaygın olarak kullanılmaktadır. Bu cihazlar ile düşmeler, görüntü işleme teknikleri kullanılarak saptanabilir [3], [4]. Görüntü işlemeye dayalı düşme tespit sistemlerinin başlıca dezavantajı loş ışıkta veya oklüzyon durumunda çalışmalarının zorluğudur [4], [5]. Mahremiyet ihlali nedeniyle de banyo ortamında video kamera kullanımı tercih

edilmemektedir [3], [4]. Kızılötesi sensörler kullanıldığında ise banyo ortamındaki buhar, sinyallerde önemli zayıflamaya yol açarak düşmenin saptanmasını zorlaştırmaktadır [4], [5]. Aynı amaç için mikrofon dizilimi kullanıldığında, zemine çarpıp yansıyan akustik sinyallerden yararlanılır. Akustik cihazların dezavantajı, çok yollu yansımaların az olduğu ortamlar gerektirmeleridir [4].

Bir başka seçenek de üç-eksenli ivmeölçer ve jiroskoplar (dönüölçerler), kızılötesi sensörler, optik kalp hızı sensörleri barındıran akıllı bileklikler gibi giyilebilir sensörler olup bu tip sensörlerle düşme algılamasına ek olarak düşme sonrasında önemli olan nabız, nefes, sıcaklık gibi harici hayati belirtiler de izlenebilir. Ancak, giyilebilir sensörlerin başlıca dezavantajlarından biri kısa pil ömürleridir [5]. Bir başka sorun ise unutkanlık ve ihmal sonucu bu cihazların devamlı giyilememe/takılamama olasılığı ya da yanlış biçimde kullanımıdır [5], [6].

Sürekli dalga (CW) radarları da insanları ve diğer nesneleri ayırt edebilmektedir [7]. Vücudun farklı bölümlerinin hareket ederken oluşturduğu radar imzaları ayırt edici olup düşmeler yüksek doğrulukla saptanabilmektedir [8]. Düşen kişinin hareketi, radarda harekete karşılık gelen bir frekans kaymasına neden olur. Böylelikle düşmeler, radar sinyallerinin ayrıntılı analizi ile saptanabilir [9]. Olası bir problem, radarın insan düşmeleri dışında diğer insan veya nesne hareketlerine de duyarlı olmasıdır (kargaşa gibi) [3].

Bu çalışmada banyo duş ortamındaki düşmeleri algılayabilen akıllı bir sistem geliştirilmesi hedeflenmiştir. Geliştirilen sistem, radar sensörleri ile IMU'lardan oluşmaktadır. Yüksek menzil çözünürlüğü, asgari mahremiyet ihlali, loş ışıkta ve banyo gibi nemli, buharlı ve gürültülü ortamlarda sorunsuz çalışması gibi özelliklerinden dolayı yüksek çözünürlüklü radar sensör kullanımı tercih edilmiştir [4]. Sistem, gerçek zamanlı olarak radar verilerini işleyerek gerekli öznelilikleri çıkardıktan sonra makine öğrenmesi algoritmaları kullanarak düşmeleri saptamaktadır. Düşmenin saptanmasında, kapı ve duş başlığının hareketlilik durumu da destekleyici olarak kullanılmakta olup düşme tespit edildiğine dair uyarı sinyali IoT üzerinden ilgili noktalara iletilmektedir.

Radar sensörü kullanıldığında önemli bir konu, sinyal işleme yöntemi seçimidir. Literatürdeki banyo duş ortamı çalışmalarının aksine, bu çalışmada kısa zaman Fourier dönüşümü (STFT) yerine dalgacık dönüşümü (WT) kullanılmıştır [10]. Bu çalışmanın banyo ortamındaki diğer çalışmalardan bir diğer farkı ise çalışmada kurulan düşme tespit sisteminin gerçek zamanlı olarak çalışabilmesidir [10].

Bu çalışmanın başlıca katkıları, (i) düşme tespit sisteminin donanımsal olarak kurulup banyo duş ortamında gerçek

zamanlı çalıştırılması, (ii) radar ve IMU sensörlerinin birlikte kullanımı, (iii) düşakabin kapısı ve düş başlığı hareketlilik durumlarının düşme tespitinde destekleyici olarak kullanımı ve (iv) geliştirilen algoritmanın %96.5 doğruluk oranı vermesidir [6].

III. DENEYSEL DÜZENEK

Kurulan sistemde bileşenler arası iletişimi ve sistemin kontrolünü sağlamak için Raspberry Pi 4 Model B 8 GB tek kart bilgisayar kullanılmıştır. Infineon Sense2Gol radarı, düşme tespiti amacıyla Doppler frekans verilerinin toplanması için kullanılırken MR24FDB1 Düşme Saptama Modülü, yine Doppler frekans verileri ile kendi modülü üzerinden olası düşmelerin tespiti için sisteme entegre edilmiştir. Her iki radar sensörü de 24 GHz frekans bandında çalışmaktadır. MR24FDB1 sensörü, Sense2Gol radar sensörü kadar gürbüz çalışmadığı ve verdiği doğruluk oranları beklentinin altında kaldığı için verileri bu çalışmada kullanılmamıştır. 3DM-GX2 IMU ise düşakabin kapısının ve düş başlığının hareketliliğini saptamakta kullanılmış, kayar ve döner tip kapılar ile deneyler gerçekleştirilmiştir. IoT programlama aracı olarak Node-RED kullanılmıştır. Düşme durumunda gerekli mercilere e-posta gönderilmesi için SMTP protokolünden, kısa mesaj (SMS) ve aramalar için Twilio servisinden yararlanılmıştır.

IV. YÖNTEM

A. Verilerin Kaydedilmesi

Sense2Gol radar sensöründen elde edilen ham veriler, dördü düşme, dördü de banyo ortamında gerçekleşmesi muhtemel olan oturup kalkma ve eğilip kalkma gibi eylemler olmak üzere sekiz farklı aktivitenin gerçekleştirildiği on saniyelik zaman pencereleri halinde kaydedilmiştir. 130'u düşme, 110'u ise diğer aktiviteler olmak üzere toplamda 240 örneklemeden oluşan bir veri kümesi elde edilmiştir.¹

B. Sinyal İşleme

Elde edilen verileri kaydettikten sonra, bunlardan ayırt edici öznitelikler çıkararak düşmeleri yüksek doğrulukla saptayabilmek için öncelikle STFT yöntemi denenmiştir. STFT ile dönüştürülen verilere Power Burst Curve (PBC) ve imge bölütleme işlemleri uygulanarak çıkarılan öznitelikler, düşme ile düşme olmayan eylemler arasında yeterli bir ayırışma sağlayamamıştır. Bunun nedeni, STFT'nin hem zaman hem de frekans alanlarında sabit bir çözünürlüğünün olması, bunun da düşme gibi durağan olmayan sinyaller için bir kısıtlama oluşturmasıdır. Daha iyi zaman-frekans yerelleştirme ve durağan olmayan öznitelikleri yakalama özelliği nedeniyle sinyal işleme yöntemi olarak WT tercih edilmiştir [4]. Böylelikle, elde edilen sonuçlar önemli miktarda iyileşmiştir. Bir zaman serisi sinyalinin sürekli dalgacık dönüşüm (CWT) formülü aşağıda verilmiştir [11]:

$$WT(t, s) = \int_{-\infty}^{\infty} x(\tau) \bar{\psi}_{t,s}(\tau) d\tau, \quad s, t \in \mathbb{R}, \quad s \neq 0 \quad (1)$$

Denklem (1)'de $x(\tau)$, integrali alınabilir herhangi bir zaman serisi sinyali olabilir. Yapılan çalışmada bu sinyal, radar sensöründen bir zaman penceresi boyunca elde edilen verilerden oluşmaktadır. $\psi_{t,s}(\tau)$ ise dalgacık fonksiyonunun zaman ve ölçek çarpımı açısından genel halidir:

$$\psi_{t,s}(\tau) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{\tau - t}{s}\right), \quad s, t \in \mathbb{R}, \quad s \neq 0 \quad (2)$$

Denklem (2)'de s dalgacığın genişliğini kontrol eden ölçek çarpımına, t zamanı kontrol eden dönüşüm parametresine, ψ ise dalgacık fonksiyonu olarak yaygın şekilde kullanılan ve aşağıda formülü verilen Morlet fonksiyonuna karşılık gelmektedir [11]:

$$\psi(\sigma) = \pi^{-\frac{1}{4}} e^{j\omega_0\sigma} e^{-\frac{\sigma^2}{2}} \quad (3)$$

Buradaki $e^{j\omega_0\sigma}$ terimi, frekansı ω_0 olan sinüzoidal bir sinyal, $e^{-\frac{\sigma^2}{2}}$ ise normal (Gauss) dağılım fonksiyonu olmakta ve Morlet fonksiyonu, bu iki fonksiyonun çarpımına karşılık gelmektedir. Dalgacık açılal frekans değeri olan ω_0 , bazı çalışmalarda 6 rad/s olarak kullanılmıştır [11]. Bu değerin seçilmesinin nedeni, s değeri ile, Şekil 1'in y eksenindeki frekans değerlerini tanımlayan f değeri arasındaki ters oran katsayısının yaklaşık bir olarak bulunmasıdır [11]:

$$f = \frac{\omega_0}{2\pi s} = \frac{6}{2\pi s} \approx \frac{1}{s} \quad (4)$$

Şekil 1'deki x eksenini ise Denklem (1)'de tanımlanmış olan t 'yi yansıtmaktadır. Dolayısıyla, sinyalin CWT uygulanmış hali olan $WT(t, s)$, zaman penceresindeki her zaman anı t ve her frekans değeri f için zaman-frekans bilgisi taşıyan $WT(t, f)$ fonksiyonu olarak tanımlanabilir.

C. Öznitelik Çıkarımı

Ham verilere WT uygulanarak elde edilen skalogramlardan üç farklı öznitelik elde edilmiştir:


1) *Enerji*: On saniyelik penceredeki sinyalin her bir zaman anındaki enerji değeri aşağıdaki şekilde saptanmıştır:

$$\mathcal{E}(t) = \sum_{f \in [f_1, f_2]} WT(t, f)^2 \quad (5)$$

Denklem (5)'teki (f_1, f_2) frekans aralığı, düşme eylemini karakterize ettiği tespit edilen (240 Hz, 480 Hz) frekans aralığı olarak seçilmiştir. $WT(t, f)$ ise zaman anı t ve frekans f için elde edilen dalgacık değeridir. Aşağıdaki denklemde birinci özniteliğin formülü verilmiştir:

$$f_1 = \sum_{t \in [t_0 - 1, t_0 + 1]} \mathcal{E}(t), \quad t_0 = \arg \max_t [\mathcal{E}(t)] \quad (6)$$

En yüksek enerji değeri ve bu değere karşılık gelen zaman anı (t_0) seçilerek, bu zaman anını merkezi olarak kapsayan iki saniyelik bir zaman penceresindeki tüm anların enerji değerleri toplanmış ve böylece ilk öznitelik elde edilmiştir. Bunu yapmaktaki amaç, düşmenin gerçekleştiği anı saptayıp düşme eyleminin başladığı ve bittiği anları da içinde barındıran bir zaman aralığındaki düşme karakteristiklerini yansıtan bir öznitelik elde etmektir. Şekil 1'de, kaydedilen 10 saniyelik pencerelerden birinin skalogramı verilmiştir:



Şekil 1: Düşme eylemi kapsayan zaman penceresinin skalogramı.

¹<https://github.com/erenolmez/BEST>

2) *En Yüksek Frekans*: İkinci öznitelik olan en yüksek frekans şu şekilde elde edilmektedir:

$$f_2 = \max_t \{ \max_f [f \mid WT(t, f) > \eta] \} \quad (7)$$

Denklemdaki η , radarın hareket algıladığı minimum eşik değeri olup diğer semboller Denklem (5)'te tanımlandığı gibidir. Böyle bir öznitelik seçilmesinin ardındaki neden, aktiviteler arasındaki frekans farklarıyla açıklanabilir. Düşmeler, ani olarak gerçekleştiği için diğer aktivitelere göre daha yüksek frekanslar içermektedir. Buna göre, düşme gerçekleşen bir zaman penceresindeki en düşük yoğunlukta olan dalgacık değerlerine sahip frekans değerleri arasından en yüksek olan, düşme gerçekleşmeyen bir zaman penceresindeki aynı değere göre daha yüksek olması beklenmektedir. Bu yüzden de bu frekans değerinin, düşmeleri diğer aktivitelere ayırt edici bir öznitelik olduğu değerlendirilmektedir.


3) *En Yoğun Frekans*: Benzer şekilde, üçüncü öznitelik olan en yoğun frekans da skalogramdan elde edilmiştir:

$$f_3 = \max_t \{ \arg \max_f [WT(t, f)] \} \quad (8)$$

Denklemdaki bütün değişkenler ve semboller Denklem (5)'te tanımlandığı gibidir. İkinci öznitelikte olduğu gibi düşme içeren zaman pencerelerinde, bu frekansın diğer aktivitelerdeki frekanslardan daha yüksek olması beklendiği için bu öznitelik seçilmiştir.

D. Ataletsel Ölçüm Birimi (IMU)

Deneylerden elde edilen veriler incelendiğinde, kayar kapıların hareketlilik durumunu belirlemek için manyetometre ölçümlerinin kullanılabilirliği sonucuna varılmıştır. Şekil 2'de daire içine alınan bölgelerden görülebileceği üzere, manyetometre ölçümleri için basit eşikleme yöntemi kullanılabilir (üst ve alt eşikler için 0.55 Gauss ve -0.05 Gauss). Döner kapılar içinse, kapının hareketlilik durumu, açısal hız verilerinin dalgalanmasından anlaşılabilmektedir.



Şekil 2: Zamana (s) karşın x , y ve z eksenlerindeki doğrusal ivme [$g = 9.80665 \text{ (m/s}^2\text{)}$], açısal hız (rad/s), manyetik alan (Gauss) değerleri.

E. Makine Öğrenmesi

Radar sensöründen elde edilen ham veriden çıkarılan öznitelikler, makine öğrenmesi algoritmasına beslenmiştir. Çalışmanın ilk aşamalarında makine öğrenmesi algoritması olarak yoğun yapay sinir ağı (DNN) ve destek vektör makineleri (SVM) kullanılmıştır. Fakat çalışmanın ilerleyen süreçlerinde çalışma isterlerine daha uygun olduğu için k -en yakın komşu algoritması (k -NN) kullanılmıştır.

Düşmeleri olabildiğince hızlı saptamanın hayati önemi nedeniyle makine öğrenmesi algoritmaları gerçek zamanlı olarak karar verebilmelidir. Ayrıca, makine öğrenme algoritmasının üzerinde koşacağı sistemin Raspberry Pi 4 gibi

görece düşük sistem özelliklerine sahip olduğu dikkate alındığında algoritmanın zaman karmaşıklığının minimum düzeyde tutulması önem arz etmektedir. Verilen özniteliklerin sayısı d ve toplam veri sayısı n olduğunda çekirdekli SVM algoritmasının zaman karmaşıklığı $O(dn^2)$ mertebesindedir. DNN algoritmasının zaman karmaşıklığı, kullanılan katman sayısına göre değişebilir de istenilen sonuçları veren çok katmanlı bir DNN'nin zaman karmaşıklığı oldukça fazla olabilmektedir. Tüm bunların yanında k -NN algoritmasının çıkarım yaparkenki zaman karmaşıklığı $O(dn)$ 'dir. Bu nedenle k -NN algoritması tercih edilmiştir. Kullanılan k -NN, esasen ağırlıklı k -en yakın komşu algoritması olarak bilinen modifiye edilmiş bir k -NN algoritmasıdır. Bu algorithmada, k -NN'den farklı olarak komşu noktalar, hedef veri noktasının uzaklıklarına bağlı bir katsayı alır ve bu katsayıların ağırlıklı toplamı, tahmin edilen etiketi belirlemede kullanılır.

V. DENEYSEL ORTAM

Hazırlanan sistemin son halinin bir laboratuvar ortamında denenmesi ve sunumu amacıyla, Eczacıbaşı VitrA Kullanıcı Deneyim Laboratuvarı'nda sistemin bir örneği kurulmuştur. Bu modelde, sistemin belirlenen tüm bileşenleri, banyo içerisinde önceden belirlenmiş konumlarına yerleştirilmiş ve deneyleri gerçekleştiren kişinin güvenliği göz önünde bulundurularak kask ve dizlik gibi koruyucu malzemelerin de kullanıldığı bir deney ortamı oluşturulmuştur.



Şekil 3: Eczacıbaşı VitrA Kullanıcı Deneyim Laboratuvarı'nda kurulan sistem ve deneylerden bir görüntü.


Şekil 3'te görülebileceği üzere Sense2Gol sensörü, MR24FDB1 Düşme Saptama Modülü ve IMU, sırasıyla kullanıcının karşısındaki duvara, kullanıcının bulunduğu alanı kapsayacak biçimde tavana ve duşakabinin kayar kapısına yerleştirilmiştir. Bileşenler, Raspberry Pi 4'e bağlanmış olup, hazırlanan IoT sistemi, bileşen iletişimi ve makine öğrenme modülleri aracılığıyla çalışır duruma getirilmiştir. Bu deneylere ek olarak, farklı bir ortamda IMU sensörü duş başlığının üzerine takılarak da deneyler gerçekleştirilmiştir.

VI. BAŞARIM

Gerçekleştirilen gerçek zamanlı testlerden elde edilen veri noktaları, bir üç-boyutlu (3-B) saçılma diyagramı üzerinde dağıtılmış ve sistemin başarımı değerlendirilmiştir (Şekil 4). Şekil üzerinde de görülebileceği üzere, düşme olan ve olmayan eylemler birbirlerinden ayrı olarak kümelendiği için seçilen üç özniteliğin düşme karakteristiklerini saptamada başarılı olduğu gösterilmiştir.


Toplanan veri noktalarından oluşturulan veri kümesi kullanılarak makine öğrenmesi algoritması eğitilmiş ve yine aynı veri kümesinden doğrulama amaçlı kullanılmak üzere oluşturulan test kümesi üzerinde algoritmanın başarımı değerlendirilmiştir. Veri kümesi tam dengeli olmadığı için seyrek örnekleme yapılarak dengeli hale getirilmiş ve daha sonra 10-katlamalı çapraz geçerlilik sınavından yararlanılmıştır.

Seçilen Özniteliklere göre Verilerin 3-B Saçılma Diyagramı



Şekil 4: Veri kümesinin 3-B saçılma diyagramı.

Başarım değerlendirmesi sonucunda karışıklık matrisi oluşturulmuş ve algoritmanın doğruluk oranı 96.5 ± 2.3 olarak elde edilmiştir (Şekil 5). Raspberry Pi 4 ile yapılan gerçek zamanlı deneyler sonucunda öznitelik çıkarımı 2.9–3.1 s ve sonrasında k -NN'in bir tahminde bulunması ise yaklaşık 1 ms sürmüştür. Bu süre, gerçek zamanlı saptama için yeterli olarak değerlendirilmiştir.



Şekil 5: Karışıklık matrisi.

VII. SONUÇ

Çalışmanın amacı, 24 GHz radar sensörü ile IMU sensörleri kullanarak ve farklı makine öğrenme yöntemleri denenerek gerçekleştirilmiştir. Bu yöntemlerden elde edilen sonuç ve başarımlar değerlendirilerek yola çıkılarak, çalışma için en etkin olan seçenek (k -NN) belirlenmiştir. Sistem sayesinde, gerçek düşmeler, düşme benzeri hareketlerden ayırt edilebildiği gibi banyo duşakabin kapısı ve duş başlığı gibi çevresel elemanların hareketlilik durumları da tespit edilebilmekte ve düşmenin saptanmasında destekleyici olarak kullanılmaktadır. Radar sensörü, IMU ve makine öğrenmesinin bir arada kullanıldığı bu sistemden gerçek zamanlı olarak elde edilen saptamalara bağlı olarak, düşme gerçekleşmesi durumunda yapılacak uyarı ve gerekli iletişimin sağlanması için IoT üzerinden gerçekleştirilen SMS, telefon araması ve e-posta servislerinden yararlanılmıştır.

VIII. TARTIŞMA VE GELECEĞE YÖNELİK PLANLAR

Bu çalışmanın kısıtlarından biri, henüz yeterli büyüklükte bir veri seti oluşturulamamış olmasıdır. Kayıt sayısının artırılmasının düşme tespiti başarımını yükseltmesi beklenmektedir. Bunun yanı sıra, tek bir radar sensörü kullanıldığı için sistem yeterince gürbüz bir şekilde çalışmamaktadır. Düşme tespit algoritmasının etkinliği, düşen kişinin konumuna ve düşme açısına göre değişebilmektedir. Birden fazla radar sensöründen elde edilen veri kullanılarak yapılan düşme tespit çalışmalarının daha etkin ve gürbüz sonuçlar verdiği ortaya konulmuştur [5], [10], [12]. Birbirine göre dik açıyla konumlanmış iki radar sensöründen eş zamanlı şekilde kaydedilen verilerin iki girdili bir makine öğrenmesi modeline beslenmesinin, düşme tespit sisteminin gürbüzlüğünü ve doğruluğunu artırması beklenmektedir [12].

İzlenebilecek bir başka yol ise öznitelik çıkarmayıp, imgeleri herhangi bir işlemle geçirmeden evrimsel sinir

ağına (CNN) girdi olarak vermektir. Bu amaçla *You Only Look Once* (YOLO) gibi algoritmalar kullanılabilir [13]. Çalışmanın geleceğe yönelik bir başka açılımı da yanlış pozitif sayısını azaltmaya yönelik yöntem geliştirmektir. Örneğin, uzaklık sensörleri kullanılarak, uzun süre hareket olmadığında bunu belirten bir öznitelik oluşturulabilir.

IoT uyumluluğu nedeniyle sistem, yaşlı güvenliği için tasarlanmış bir geriatrik ev ekosistemine banyo bileşeni olarak entegre edilebilir. Bu çalışmanın gelecekteki bir başka uygulama alanı da hastanelerdir. Hastanelerde yardım çağırmak için kullanılan düğmeler bazı hayati durumlarda işe yaramayabilir. Böyle bir sistem, hastalar için daha güvenli bir ortam yaratarak hastanelerde gerekli olan insan işgücünü azaltabilir. Tam olarak aynı bileşenler ve yöntemler kullanılsa da bu çalışmanın arkasındaki fikir ve yöntemlerin gelecekteki yaşlı güvenliğine yönelik akademik ve endüstriyel projeler için yol gösterici olabileceğine inanıyoruz.

IX. TEŞEKKÜR

Bu çalışma, Bilkent Üniversitesi Sanayi Odaklı Bitirme Projeleri kapsamında, Bilkent Üniversitesi ve Eczacıbaşı Vitra işbirliği ile yürütülmüştür. Akıllı ürünler, banyoda düşme tespiti ve kaynak planlaması konularında verimli tartışmalar için Fatih Gerenli ve Hakan Bozcu'ya, projeye sağladığı idari katkılar için Yeşim Gülseren'e ve ayrıca Göktuğ Sami Yavuz ve Batuhan Uykulu'ya teşekkür ederiz.

KAYNAKLAR

- [1] "The 2015 Revision of the UN's World Population Projections," *Popul. Dev. Rev.*, vol. 41, no. 3, pp. 557–561, Sep. 2015.
- [2] T. Rosen, K. A. Mack, R. K. Noonan, "Slipping and tripping: fall injuries in adults associated with rugs and carpets," *J. Inj. Violence Res.*, vol. 5, no. 1, pp. 61–69, Jan. 2013, PMID: 22868399.
- [3] S. Matsuguma, A. Kajiwaru, "Bathroom accident detection with 79GHz-band millimeter wave sensor," *IEEE Sens. Appl. Symp. (SAS)*, 2019, <https://doi.org/10.1109/SAS.2019.8706084>.
- [4] B. Y. Su, K. C. Ho, M. J. Rantz, M. Skubic, "Doppler radar fall activity detection using the wavelet transform," *IEEE Trans. Biomed. Eng.*, vol. 62, no. 3, pp. 865–875, Mar. 2015, <https://doi.org/10.1109/TBME.2014.2367038>.
- [5] A. Singh, S. U. Rehman, S. Yongchareon, P. H. J. Chong, "Sensor technologies for fall detection systems: A review," *IEEE Sens. J.*, vol. 20, no. 13, pp. 6889–6919, Jul. 2020, <https://doi.org/10.1109/JSEN.2020.2976554>.
- [6] E. Ölmez, M. Ö. Özsoy, R. Jabiye, B. Ansen, U. E. Aktürk, E. B. Oral, "RF/Mikrodalga Güvenlik Sensör Sistemi," Sonuç Raporu, Endüstri Odaklı Bitirme Projesi (EEE 493/494), Bilkent Üniversitesi, Elektrik ve Elektronik Mühendisliği Bölümü, Haziran 2023.
- [7] O. Postolache et al., "Multi-usage of microwave Doppler radar in pervasive healthcare systems for elderly," *IEEE Instrum. Meas. Technol. Conf.*, 2011, <https://doi.org/10.1109/IMTC.2011.5944313>.
- [8] J. L. Geisheimer, W. S. Marshall, E. Grenaker, "A continuous-wave (CW) radar for gait analysis," *Proc. The Thirty-Fifth Asilomar Conf. Signals, Syst. & Comput.*, 2001, vol. 1, pp. 834–838, <https://doi.org/10.1109/ACSSC.2001.987041>.
- [9] L. Liu, M. Popescu, M. Skubic, M. Rantz, P. Cuddihy, "An automatic in-home fall detection system using Doppler radar signatures," *J. Ambient Intell. Smart Environ.*, vol. 8, no. 4, pp. 453–466, Jul. 2016, <https://doi.org/10.3233/AIS-160388>.
- [10] E. Ramanujam, P. Thinakaran, K. Shankar, "A review on fall detection systems in bathrooms: challenges and opportunities," *Multimed. Tools Appl.*, Jan. 2024, <https://doi.org/10.1007/s11042-023-18088-6>.
- [11] L. Aguiar-Conraria, M. J. Soares, "The continuous wavelet transform: Moving beyond uni- and bivariate analysis," *J. Econ. Surv.*, vol. 28, no. 2, pp. 344–375, Apr. 2014, <https://doi.org/10.1111/joes.12012>.
- [12] K. Saho, S. Hayashi, M. Tsuyama, L. Meng, M. Masugi, "Machine learning-based classification of human behaviors and falls in rest-room via dual Doppler radar measurements," *Sensors*, vol. 22, article no. 1721, Feb. 2022, <https://doi.org/10.3390/s22051721>.
- [13] M. Lamane, M. Tabaa, A. Klilou, "Classification of targets detected by mmWave radar using YOLOv5," *Procedia Comput. Sci.*, 2022, vol. 203, pp. 426–431, <https://doi.org/10.1016/j.procs.2022.07.056>.