


Akıllı telefon ve giyilebilir cihazlarla aktivite tanıma: Klasik yaklaşımlar, yeni çözümler

Activity recognition using smartphones and wearable devices: Traditional approaches, new solutions

Jemshit ISKANDEROV¹ , Mehmet Amaç GÜVENSAN^{2*} 

^{1,2}Bilgisayar Mühendisliği Bölümü, Elektrik-Elektronik Fakültesi, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.
jemshit@mail.com, amac@yildiz.edu.tr

Geliş Tarihi/Received: 25.12.2017, Kabul Tarihi/Accepted: 02.07.2018
* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2018.84758
Derleme Makalesi/Review Article

Öz

Son yıllarda özellikle akıllı telefonların ve giyilebilir cihazların gelişmesiyle birlikte aktivite tanıma alanındaki çalışmalar hız kazanmıştır. Aktiviteler temel olarak yürüme, koşma gibi basit aktiviteler ve yemek yeme, uyuma, diş fırçalama gibi karışık aktiviteler olmak üzere ikiye ayrılmaktadır. Bu derleme çalışmasında aktivite tanıma konusu ile ilgili makaleler değerlendirilmiş ve aktivite tanıma kullanılan sensörler, aktivite çeşitleri, uygulama alanları, aktivite tanıma için kullanılan cihazlar, veri toplama işlemi, eğitim yöntemleri, sınıflandırma algoritmaları ve kaynak tüketimi konuları detaylı olarak incelenmiştir. Yapılmış çalışmaların mevcut durumu ortaya konmuş ve kullanılan farklı yöntemler karşılaştırılmıştır. Daha sonra açık veri setleri paylaşılmış ve literatürdeki derin öğrenme yöntemleri kullanan yenilikçi çözümlerden bahsedilmiştir. Son olarak, bu alanda hala açık olan noktalardan bahsedilmiş ve ileride çalışma yapılabilecek konular önerilmiştir.

Anahtar kelimeler: Aktivite tanıma, Akıllı telefon, Giyilebilir cihaz, Derin öğrenme, Veri seti, Derleme

Abstract

In recent years, the research on activity recognition has gained speed especially with the development of smart phones and wearable devices. Activities could be categorized into two main groups. simple activities such as walking, running and complex activities such as eating, sleeping, brushing teeth. In this survey paper, articles about activity recognition are examined thoroughly. Sensors and devices used in activity recognition, types of daily activities, application areas, data collection process, training methods, classification algorithms and resource consumption are mentioned in details. The state of the art is elaborated and the existing methods are compared to each other. Later, open data sets are mentioned and studies offering innovative solutions using latest approaches such as deep learning methods are introduced. Finally, still open issues on this area are presented and future work has been discussed.

Keywords: Activity recognition, Smartphone, Wearable device, Deep learning, Dataset, Survey

1 Giriş

Akıllı telefon insanların hayatına yıllar önce girmiş ve birçok kolaylık sağlamıştır. Piyasada birçok akıllı telefon üreticisi ve işletim sistemi mevcuttur. 2016 yılının üçüncü çeyreğinde akıllı telefon işletim sistemlerinin marketteki pay dağılımları Android %86.8, iOS %12.5, Windows Phone %0.3 olarak belirlenmiştir [1]. Akıllı telefonların hayatımıza kolaylık sağlamlarının nedenlerinden biri entegre edilmiş sensörleri olması ve bu sensörlerin oluşturduğu uygulama alanlarıdır. Marketteki akıllı telefonların %99.3 [1] bölümünü oluşturan Android ve iOS işletim sistemi bulunan telefonlarda ivme ölçer, jiroskop, yakınlık ölçer, GPS, barometre, miknatis ölçer vb. çeşitli sensörler bulunmaktadır.

Akıllı telefonlar ile birlikte gelişen bir diğer önemli teknoloji ürünü ise giyilebilir cihazlardır. Giyilebilir cihazlar, kişinin spor aktivitelerini takip edebilen, sağlık durumunu izleyebilen, akıllı saat, eldiven, gözlük vb. cihazlardır. Bu cihazların üzerinde de ivmeölçer, jiroskop, kalp atış hızı ölçer gibi sensörler bulunmaktadır.

Akıllı telefon, akıllı saat ve diğer giyilebilir cihazların günlük kullanım süresi 2010 senesinde 0.4 sa. iken 2015 senesinde 2.8 sa.'te ulaşmıştır [2]. Bu cihazların kullanıldığı alanlardan birisi de aktivite tanımadır. Aktivite tanıma, kişinin yürüme, oturma, koşma gibi günlük aktivitelerinin bazı cihaz ve sensörler kullanılarak otomatik tanınması olarak nitelendirilmektedir. Aktivite tanıma çalışmaları 1980'li

yıllarda başlasa da sensörlerin, giyilebilir cihazların ve akıllı telefonların gelişmesiyle önemli derecede hız kazanmıştır. Aktivite tanıma için daha önce görüntü bazlı yöntemler kullanılsa da [3],[4], günümüzde sensör kullanarak bu işlemi yapmak daha tercih edilir olmuştur. Görüntü bazlı yöntemlerde, kullanıcının devamlı kamera ile görüntülenmesi ve hareketlerinin gerçek zamanlı izlenmesi gerekmektedir. Bu yöntem taşınabilirlik, kullanıcı mahremiyeti, fiyat ve uygulanabilirlik açısından cazip değildir. Basit sensörlerin kullanılması aktivite tanıma için kamera kullanımının meydana getirdiği dezavantajları azaltmaktadır. Aktivite tanıma için kullanılan sensörleri iki farklı sınıf altında toplayabiliriz. Dışarıya monte edilen *harici sensörler* ve taşınabilir cihazların içine entegre edilebilen *dahili sensörler*. Harici sensörler (pasif kızıl ötesi sensörü, mikrofon, termal kameralar), aynı kameralar gibi, ortamda sabit yerlerde konumlanır ve kullanıcının hareketlerini inceler. Bu yöntemin kullanım alanları için akıllı evler, akıllı ofisler vb. genellikle kapalı alanlar [5],[6] örnek olarak verilebilir. Cihazlardaki dahili sensörler ise aktivite tanımayı, diğer yöntemlere göre, daha kolay ve uygulanabilir hale getirmiştir. Kullanıcılar akıllı telefonları, akıllı saatleri ve giyilebilir cihazları hep yanlarında taşıdıkları için, bu cihazlardaki dahili sensörleri aktivite tanıma için kullanmak çok uygundur. Yapılan çalışmalarda çoğunlukla ivmeölçer, jiroskop ve GPS sensörleri kullanılmıştır. Bu yöntem kullanışlı ve verimli olmasının yanında pil tüketimi,

kişiselleştirilmiş aktivite tanıma gibi zorlukları beraberinde getirmektedir.

Aktivite tanıma uygulamaları özellikle sağlık hizmetlerinde [7] [8] ve akıllı ortamlarda [6] kullanılmaktadır. Bu makalede aktivite tanıma alanında yapılmış çalışmalar incelenmiştir. Bu çalışmanın amacı literatürdeki mevcut çalışmaları değerlendirirken geleneksel yöntemler ve yeni yaklaşımlar arasındaki benzerlikleri ve farkları ortaya koymaktır. Karşılaşılan zorluklar ve çözümler incelendikten sonra çalışmaların mevcut durumu gösterilmektedir. Daha sonra bu konuda gelecekte yapılabilecek çalışma fırsatlarından bahsedilmektedir.

Literatürde aktivite tanıma alanında yapılan çalışmaların inceleyen ve değerlendirme yapan birkaç derleme çalışması bulunmaktadır. Bunlardan en detaylı inceleme yapanlardan birisi [9] çalışmasıdır. Bu derlemede aktivite tanıma yapan makaleler incelenmiş ve mevcut çalışmalar cihaz, sınıflandırma algoritması, eğitim yöntemi, tanınan aktiviteler, kullanılan özellikler, kullanılan sensörler, kaynak tüketimi, gerçek zamanlı geribildirim, cihaz oryantasyon ve konumdan bağımsız aktivite tanıma, örnekleme frekansı gibi çok farklı açılardan karşılaştırılmıştır. Bir diğer derleme çalışmaları [10] ve [11] ise kullanılan sensörler, özellikler ve sınıflandırma algoritmaları, cihaz oryantasyon ve konumunun etkileri [10] gibi farklı açılardan inceleme ve değerlendirme yapmıştır. Bu derlemelerin odak noktaları sadece akıllı telefonlardır. Derleme [12]'de ise sadece giyilebilir cihazlarla aktivite tanıma yapan makaleler incelenmiş ve harici sensörler, örnekleme frekansı, sınıflandırma algoritmaları gibi açılardan değerlendirme yapılmıştır. Derleme [13], makalelerdeki aktivite tanıma için kullanılan yaklaşımları değerlendirmiş ve bunları çıkarma esaslı (mining based), mantık esaslı (logic based) ve ontoloji esaslı (ontology based) diye ayırmıştır. Basit aktivitelerin yanında karışık aktiviteleri de ele almıştır. Derleme [14] ise makaleleri sadece sınıflandırma algoritmalarına göre değerlendirmiştir ve diğerlerine göre dar kapsamlı bir çalışmadır.

Yapılan derleme çalışmalarından farklı olarak, bu makalede sadece akıllı telefonlarla değil, giyilebilir cihazlarla da aktivite tanıma yapan makaleler incelenmektedir. Bu makalede çoğu derlemede eksik olan cihaz oryantasyonu ve konumdan bağımsızlık, veri toplamanın hangi cihazlarla, kişilerle nasıl yapıldığı ve kişilerin özellikleri, kullanılan araçlar, eğitim için kullanılan pencere boyutu, elde edilen sonuçlar ve sonuç hesaplamak için kullanılan metrikler, kaynak tüketimi açılarından değerlendirmeler yapılmıştır. Bu derleme çalışması sonucunda şu katkılarda bulunmaktadır:

- Akıllı telefonlarla giyilebilir cihazların aktivite tanımda kullanılmasının beraber incelenmesi,
- Aktivite tanıma işlemi için kullanılan pencere boyutu, örnekleme frekansı ve sınıflandırma algoritma çeşitliliklerinin incelenmesi,
- Aktivite tanıma işlemi için veri toplama sırasında tercih edilen cihaz oryantasyon ve konum bilgileri,
- Aktivite tanımda açık veri setlerinin listesi,
- Aktivite tanıma üzerine yapılan derin öğrenme çalışmalarının incelenmesi ve sunulması.

Makalenin geri kalan yapısı şu şekildedir: 2. bölümde aktivite tanıma problemi, 3. bölümde dahili sensör kullanarak aktivite tanıma için uygulanan genel yöntemler, 4. bölümde zorluklar,

sorunlar ve uygulanan çözümler, 5. bölümde aktivite tanıma çalışmalarında kullanılan açık veri setleri, 6. bölümde klasik çözümler, 7. bölümde yeni nesil çözümler ve son bölümde ise açık noktalar ve gelecek için çalışma fırsatları anlatılmaktadır.

2 Aktivite tanıma

Aktivite tanıma üzerine çalışan araştırmacılar, kullanıcının yürüme, koşma gibi fiziksel aktivitelerinin yanı sıra yemek yeme, araba kullanma, yemek pişirme gibi karışık aktivitelerini tanıma üzerine odaklanmışlardır. Tanıma işlemi için temel olarak Şekil 1'de verilen görüntü bazlı veya sensör bazlı yaklaşımlar tercih edilir.

Uygulanabilirliği, fiyat problemi olmaması ve günlük hayatta kullanılan akıllı telefonlarda mevcut olması sebebiyle dahili sensörler aktivite tanıma için tercih edilmektedir. Görüntü bazlı [4] ve harici sensör [5] kullanılarak aktivite tanıması yapan çalışmalar bu makalenin kapsamı dışındadır.



Şekil 1: Aktivite tanıma için kullanılan yaklaşımlar.

2.1 Sensörler

Akıllı telefon ve giyilebilir cihazlarda birçok dahili sensör mevcuttur. Akıllı telefonlardaki sensörleri şu şekilde sıralayabiliriz [15]: ivme ölçer (accelerometer), jiroskop (gyroscope), mıknatıs ölçer (magnetometer) [20], yakınlık algılayıcı (proximity sensor) [22], ışık sensörü (light sensor) [22], basınçölçer (barometer), ısı ölçer (thermometer), nemlilik sensörü (air humidity sensor), adım sayıcı (pedometer), kalp atış hızı ölçer (heart rate monitor), parmak izi sensörü (fingerprint sensor), G sensör, GPS, mikrofon (microphone), kamera (camera), pusula (compass), bluetooth, NFC. Giyilebilir cihazlardaki sensörleri de şu şekilde sıralayabiliriz [16]: ivme ölçer, jiroskop, mıknatıs ölçer, GPS, kalp atış hızı ölçer, sıcaklık sensörü (temperature sensor). Bu sensörlerin içinde aktivite tanıma için sıkça kullanılan sensörler ivmeölçer, jiroskop, mıknatıs ölçer, GPS ve mikrofondur.

İvmeölçer x, y ve z olmak üzere 3 eksende cihazın (dolayısıyla kişinin) ivmesini ölçer. Bu sensör yardımı ile kişinin yürüme, koşma, oturma gibi farklı aktivitelerine ait örüntüleri çıkarmak mümkündür. Bunun getirdiği zorluk ise telefonun konumuna ve oryantasyonuna bağlı olmadan aktivite tanımadır. Bazı çalışmalar, [17]-[20] gibi, telefon oryantasyonundan bağımsız aktivite tanıma çalışması yapmıştır ve %91.5±5.5 civarı oranında doğruluk elde edebilmişlerdir. [17],[18] gibi çalışmalar cihaz konumundan (pantolon cebi, bel, tişört cebi gibi) bağımsız aktivite tanıma yapabilmektedir.

Yapılan çalışmalarda, cihaz oryantasyon ve konumdan bağımsız aktivite tanıma için özellikle iki yöntem tercih edilmiştir. Biri oryantasyondan bağımsız ivmeölçer sensör veri özelliklerini kullanmak [17],[19], diğeri ise ivme ölçer ile jiroskop ve mıknatıs ölçeri beraber kullanmaktır [18],[20]. Jiroskop x, y ve z eksenleri etrafında telefonun dönüşünü ölçer.

Jiroskop sensörü kullanarak telefonun oryantasyonunu da hesaba katmak mümkün hale gelmektedir.

GPS sensörü kullanıcının konumunu bulmaya yardım eder ve neredeyse tüm akıllı telefonlarda mevcuttur. GPS sensörü yardımı ile kullanıcının çevresi, konumu hesaba katıldığında yapılabilecek aktiviteler sınırlı hale geldiği için daha iyi tanıma başarısı elde etmek mümkün hale gelmektedir. GPS sensörü kullanımının getirdiği dezavantajlar ise iç mekânlarda kullanılamaması ve enerji tüketiminin yüksek olmasıdır. İncelediğimiz çalışmalardan sadece [21]'de GPS sensörü kullanılmıştır.

Jiroskop ve manyetometre gibi ek sensör kullanımının, sadece ivmeölçer sensörü kullanarak elde edilen tanıma başarılarından daha iyi sonuç verdiği gözlemlenmiştir [22].

2.2 Aktiviteler

Aktivite tanıma problemindeki aktiviteleri *basit* ve *karışık* olmak üzere ikiye ayırabiliriz. Bunları aksiyon ve aktivite diye ayıran çalışmalar da vardır [23]. Basit aktiviteler yürüme, oturma, koşma gibi belirli aksiyonlardan oluşmaktadır. Karışık aktiviteler ise birçok basit aktivitenin bileşiminden oluşur. Örneğin yemek pişirme karışık aktivitesi yürüme, ayakta durma, eğilme gibi basit aktivitelerden oluşmaktadır. İncelenen çalışmalarda tanımlanan basit aktiviteler şunlardır: *yürüme, tempolu koşma (jogging), merdiven çıkma, düşme, merdiven inme, oturma, ayakta durma, koşma, yatma, zıplama, yavaş yürüme, oturarak rahatlatma (sit relax), yürüyen merdiven ile çıkma, yürüyen merdiven ile inme, asansör ile çıkma, asansör ile inme, bisiklet sürme, araba sürme, telefon kullanıcıda değil, telefonu tutma, gezinme (strolling), yukarı tırmanma (climb up), aşağı inme (climb down), motosiklet ile hareket (moving by motorbike), araba ile hareket (moving by car), tren ile hareket (moving by train)*. Çalışmalarda tanımlanan karışık aktiviteleri de şu şekilde sıralayabiliriz: *yemek pişirme, temizlik yapma, ilaç kullanma, süpürme, elleri yıkama, bitki sulama, uyuma, yeme, kişisel bakım, çalışma, ders çalışma, ev işi, sosyalleşme, spor, hobi, iletişim araçları (mass media), yolculuk (travelling), tahtaya yazma, kişisel bilgisayar kullanma, projektör kullanma, ders anlatma, oynama, dış fırçalama, banyo yapma, yüz yüze görüşme, görüntülü konferans, telefon konferans, anlık mesajlaşma, alışveriş yapma, otobüse binme*.

2.2.1 Basit aktiviteler

Basit aktiviteler tanınması daha kolay olanlardır ve çalışmalarda en çok ilgi görenlerdir. Çalışmaların çoğu yürüme, koşma, oturma, merdiven çıkma ve merdiven inme gibi aktiviteleri tanıma üzerine yoğunlaşmışlardır. Bu aktiviteler için en iyi elde edilen doğruluk oranı ise ivmeölçer, jiroskop ve miknatis ölçer kullanarak %97'dir [20]. Sadece ivme ölçer ile elde edilen en iyi doğruluk oranı ise %95.8'dir [19]. Sıkça karıştırılan aktivitelere örnek olarak merdiven inme ve merdiven çıkma gösterilebilir [24]. Makale [9] buna çözüm olarak basınçölçer sensörünün kullanılmasını tavsiye etmektedir.

2.2.2 Karışık aktiviteler

Karışık aktiviteler, basit aktivitelerden oluşmaktadır ve tanımları daha zordur. Genellikle sadece ivmeölçer sensörü kullanılarak tanınmaları mümkün değildir. Karışık aktivite tanımak için kullanıcının kendi hareketlerini takip eden sensörlerin dışında çevresi hakkında bilgi veren GPS, mikrofon ve/veya benzer sensörler de gerekmektedir. Makale [21]

ivmeölçer ve GPS kullanarak %93.44 doğruluk oranı elde etmiştir.

2.3 Uygulama alanları

Aktivite tanıma uygulamalarının kullanılabilir alanları başta sağlık hizmetleri olmak üzere akıllı ortam, güvenlik ve benzerleridir [13]. Akıllı ev, akıllı ofis, akıllı sınıf gibi ortamlarda [5],[6] potansiyel kullanım senaryoları şunlar olabilir: evden çıkıldığı tespit edildiğinde klimanın kapatılması, odada bir süre hareket algılanmazsa ışıkların kapatılması veya kişinin uyuduğu tespit edilirse televizyonun kapatılması. Aktivite tanıma, sağlık alanında [7],[8] aktivite izleme (activity tracking), yardımcı yaşam (assistive living) [25] ve sağlık denetleme (well-being monitored) [26] uygulamalarında kullanılabilir. Bu alanda kullanım senaryoları evde yaşlının/çocuğun düşme tespiti veya masada uzun süre hareketsiz oturulması durumunda hatırlatma yapılması olabilir.

İssız bölgelerde meydana gelebilecek araç çarpmaları, bayılmalar kişinin yere düşmesine [83] ve zamanında yardım gelmediği için kalıcı hasarlara veya ölümüne yol açabilir. Bu nedenle akıllı telefon yardımı ile kişinin düştüğünün ve hareketsiz kaldığının anlaşılması ilgili otoritelere ve/veya kişinin yakınlarına haber verilmesi can kaybını önlemek açısından oldukça önemlidir. Bununla birlikte aktivite tanıma yöntemleri kişilerin ulaşım türlerinin tespit edilmesini [82] mümkün kılmaktadır. Bu sayede büyük şehirlerde şehrin hareketliliği incelenerek yeni ulaşım güzergâhlarının oluşturulması, kalabalık/ıssız bölgelerde güvenlik önlemlerinin alınması sağlanabilir.

Özellikle akıllı saatlerin yaygınlaşması ve birden fazla algılayıcı türünün aynı anda kullanılması ile birlikte karmaşık aktivitelerin [84]'te izlenmesi ve algılanması mümkün hale gelmiştir. Dış fırçalanması, evde temizlik yapılması, bulaşık ve çamaşır yıkanması, araba kullanılması, arabaya binme ve inme durumlarının tespiti sayesinde kişilerin gün içerisinde buldukları durumu anlama ve bu durumlar özelinde çözüm üretimi istenmektedir. Örneğin kişinin arabayı park ettikten sonra araçtan inmesi ve tekrardan aracını alarak yola devam ettiği zaman aralığında aracın park halinde olduğu otomatik olarak tespit edilebilir [85]. Ev temizliği yapan şirketlerin çalışanlarının ev içerisinde yaptığı işlerin analiz edilmesi karmaşık aktivitelerin tanınması ile mümkün hale gelebilecektir. Ev içerisindeki ütü, bulaşık yıkama, yer süpürme, cam silme vb. detaylı aktiviteler takip edilip kayıt altına alınabilecektir [86]. Öte yandan detaylı aktivite takibi hastaların egzersizlerini yapıp yapmadıklarını, ne kadar süre çalıştıklarını, yürüyüş sürelerini ve tempolarını izlemek açısından oldukça önemlidir.

3 Aktivite tanıma için genel yöntem

Akıllı telefonlardaki ve giyilebilir cihazlardaki dahili sensörleri kullanarak aktivite tanıma için izlenen adımlar genelde benzer yapıdadır. Adımları sırasıyla şu şekilde yazabiliriz: sensörlerden ham verinin toplanması, verinin (ön) işlenmesi, veriden önemli özelliklerin çıkartılması, veriyle eğitim yapılması ve sınıflandırma.

3.1 Aktivite tanıma mimarileri

Aktivite tanıma, telefon, giyilebilir cihazlar [27] ve/veya sunucu üzerinde verinin çevrimiçi/çevrimdışı işlenmesi sonucunda gerçekleşir. İncelenen makalelerden çoğu sunucu olmaksızın aktivite tanıma yapmaktadır. Eğitilmiş model telefona yüklenir,

gerçek zamanlı olarak sensör verileri okunur, işlenir, özellik çıkartılır ve sınıflandırma yerelde (in-situ processing) yapılır. Sunucunun kullanıldığı çalışmalarda ise sunucuyu veri toplama [24], veri işleme [21] veya sınıflandırma yapmak [21] için kullanılmaktadırlar. Kaynak tüketici işlemlerin yükünü sunucuya devretmek avantajlı olsa da sürekli ağ erişimine ihtiyaç duymak büyük bir dezavantajdır. Diğer yandan sadece veri toplama aşamasında, farklı kişilerden ve cihazlardan toplanan verilerin ortak sunucuya yüklenmesi veri toplama işini kolaylaştırmaktadır [24]. Ancak, toplanan verilerin boyutu çok büyük ise verinin USB/Bluetooth vb. çevrimdışı yöntemlerle merkezi sunucuya aktarılması daha uygun olacaktır [28],[20].

3.2 Platformlar

Bu çalışmada platformlar iki şekilde ele alınmıştır. Bunlar veri toplanırken kullanılan cihazın platformu ve eğitilmiş modelin test edildiği cihazın platformudur.

Veri toplanırken çoğu makalede Android işletim sistemi çalıştıran telefonlar [18],[21] olmak üzere, üzerinde Symbian çalışan Nokia N95 [29], iOS işletim sistemi bulunan iPhone akıllı telefonları [17] ve bazı giyilebilir cihazlar [30] kullanılmıştır. Android cihazların daha çok tercih edilmesinin sebepleri arasında ücretsiz olmaları, piyasada yaygın bulunmaları, kolay programlanabilir olmaları ve uygulamaların arka plan servisi olarak çalıştırılabilmeleri gösterilebilir [24]. Akıllı telefonlarda veri toplamak için tercih edilen yöntem telefona özel uygulama yazılmasıdır. Uygulama, aktiviteye başlamadan önce hangi sensörlerin kullanılacağına, örnekleme frekansının seçilmesine, hangi aktivite yapılacağına seçilmesine olanak sağlamaktadır [18],[20],[24], [28],[31],[32]. Giyilebilir cihazlarda veri toplamak için kullanılan bir yöntem ise sensör verilerinin cihazda yerel tutulması ve daha sonra kablo ile bilgisayara aktarılmasıdır.

3.3 Veri toplama

Platform ve mimari seçildikten sonraki adım sensörlerden ham verinin toplanmasıdır. Veriler ilgili cihazın üzerinde belirlenen sensörlerden alındıktan sonra eğer aktivite tanıma modeli telefonun kendisinde çevrimiçi eğitilecekse (online training) veriler yerel hafızada tutulabilir [31]. Eğer aktivite tanıma modeli telefon dışında başka ortamda (bilgisayar gibi) çevrimdışı eğitilecekse (offline training) sunucuya aktarılır.

Veri toplanırken bir diğer önemli seçim örnekleme frekansındır. Örnekleme frekansı saniyede verinin toplanma hızıdır. İncelenen makalelerin çoğu sabit örnekleme frekansı seçmiştir ve çok azı ise [18],[33] dinamik olarak örnekleme frekansı kullanmayı önermiştir. Tablo 1'de hangi çalışmanın hangi örnekleme frekansını seçtiği görülmektedir. Örnekleme hızının yüksek olmasının doğruluğu olumlu etkilediği ama enerji tüketimini olumsuz etkilediği makale [33]'te vurgulanmıştır.

Toplanan verilerin sayısının ve çeşitliliğinin de eğitim için önemi vardır. Eğitim verisinin çok olmasının ve çeşitliliğinin fazla olmasının doğruluğu olumlu yönde etkilediği makale [29] ve [31]'de belirtilmiştir. Makale [29]'da deney sonrasında bulunan sonuca göre 100 eğitim verisine kadar doğruluk artmıştır ve ondan sonra ise sabit kalmıştır.

Karışık aktivite tanıma için, fiziksel sensör verileri dışında zaman-aktivite bilgilerini içeren anket verilerinin kullanılmasının olumlu etkileri olduğu makale [30]'da belirtilmiştir. Bu çalışmada yemek yeme, sosyalleşme, hobi gibi karışık aktivite tanıma sonuçlarında, sadece sensör verisi

kullanarak bulunan kesinlikten, %25, %18 ve %6 daha iyi kesinlik elde edilmiştir. Ama zaman-aktivite anket verisini kullanmanın olumlu etkisi aktiviteye göre değişmektedir ve sadece bazı aktiviteler için kesinlik konusunda olumlu etki yarattığı görülmüştür.

Tablo 1: Kullanılan örnekleme frekansları.

Örnekleme frekansı	Kullanan makaleler
12 Hz/s	[23]
16 Hz/s	[21]
20 Hz/s	[24],[36]
25 Hz/s	[8]
32 Hz/s	[29],[32],[36]
40 Hz/s	[19]
50 Hz/s	[17],[34],[35],[37],[38]
100 Hz/s	[20],[33],[34],[39]
32 örnek/dakika (0.5 Hz/s)	[30]
Uyarlamalı örnekleme (adaptive sampling)	[7],[18],[33]
M/D	[22],[28],[31],[40],[41]

Not: M/D = Mevcut değil.

Tablo 1 incelendiğinde karışık aktivite tanıma yapan çalışmaların daha düşük frekansta veri topladıkları görülebilir [21],[23],[30]. Karışık aktiviteleri tanıyabilmek için uzun aralıklı (büyük pencere boyutu) sensör verisinin incelenmesi gerekmektedir. Dolayısıyla uzun süreli verilerle karışık aktivite tanıma için eğitim yapıldığında, örnekleme frekansının düşük olmasının sonucu çok olumsuz etkilemediği sonucuna varılabilir. Düşük frekans kullanan [21] ve [23] numaralı çalışmalar en iyi karışık aktivite tanıma başarısına ulaşan çalışmalardır. Diğer yandan, yüksek frekansta veri toplayan çalışmalar en iyi basit aktivite tanıma başarısını elde eden çalışmalardır [20],[34],[35]. Basit aktivitelerin çoğu kısa süreli aksiyonlardan oluştuğu için küçük pencere boyutu tercih edilir. Verilerin toplanma frekansı ne kadar yüksekse o kadar iyi doğruluk elde edilebilmektedir.

3.4 Özellik çıkartma

Veriler toplandıktan sonra verinin tamamını aktivite tanıma için kullanmak yerine, sadece önemli özelliklerini çıkartıp onun üzerinde işlem yapmak hız ve enerji tüketimi açısından önemlidir. Makale [21]'de bulunan sonuca göre 15 özellik kullanıldığında algoritmanın çalışma süresi 20 ms'den az olmaktadır. 150 özellik kullanıldığında ise 50 ms civarında gerçekleşmektedir. Makale [33]'te özellik sayısını azaltmanın enerji kullanımını azalttığı, ayırt edici özellik sayısını arttırmanın ise doğruluğu arttırdığı makale [34]'te söylenmektedir.

Özellikler temel olarak zaman alanında (time domain) ve/veya frekans alanında (frequency domain) elde edilmektedir [87]. Zaman alanındaki özellikler sensör eksen verilerinin zamana göre değişiminden oluşur. Çalışmalarda kullanılan bazı zaman alanındaki özellikler şunlardır: ortalama (average ve/veya mean), standart sapma (standard deviation), ortalama mutlak fark (average absolute difference), değişiklik (variance), standart değişiklik (standard variance), eğiklik (skew), basıklık (kurtosis), dağıntı (entropy), ortak değişiklik (covariance), minimum değer, maksimum değer, mutlak minimum değer, mutlak maksimum değer, kare ortalamalarının kökü (root mean square). Frekans alanında kullanılacak bazı özellikleri ise şu şekilde sıralayabiliriz: hızlı fourier dönüşümü (fast fourier transform) katsayıları, FFT katsayıları ortalaması, FFT katsayıları toplamı, ilk FFT katsayı değeri, FFT katsayıları enerjisi, FFT katsayıları bilgi değeri, spektral etekler (spectral

roll-off), spectral flux. Çalışmaların çoğu, zaman alanındaki özellikleri kullanmıştır. Frekans alanında özellikleri bulmanın sayısal anlamda daha karışık olduğu makale [22] ve [32]'de vurgulanmıştır. Tablo 2'de, incelenen makalelerin kullandığı özellik alanları gösterilmiştir. Bazı makalelerin hem zaman alanındaki hem de frekans alanındaki özellikleri kullandığı görülmektedir. Makale [33]'e göre 50 Hz'de toplanmış sadece zaman alanındaki özellikleri kullanmak yerine 16 Hz'de toplanmış zaman ve frekans alanındaki özelliklerin bileşimini kullanmak daha fazla enerji tüketir. Hangi makalenin hangi özelliği çıkartıp kullandığı bu çalışmanın kapsamı dışındadır. Makale [19]'da ivmeölçerin x ve z eksenlerinden çıkartılmış özelliklerin doğruluğu daha çok etkilediği belirtilmiştir.

Tablo 2: Kullanılan özellik alanları.

Zaman	Frekans	M/D
[7],[8], [17],[18], [19],[20],[21], [22],[24],[28], [29],[32],[33], [34],[35],[37], [38],[39],[41]	[8],[20],[22], [29],[33], [34],[35],[37], [38],[39]	[23],[31],[30], [36],[40]

Karışık aktivite tanıma çalışmalarından hiç birisi frekans alanında özellik kullanmamıştır. Sadece basit aktivite tanıma çalışmaları frekans alanındaki özellikleri kullanmışlardır. Frekans alanındaki özellikler hiçbir makale tarafından tek başına kullanılmamıştır, zaman alanındaki özelliklerle beraber kullanılmıştır.

Seçilen alanda özelliklerin çıkartılması için veriyi belirli süreli pencerelere ayırmak gerekir. Bu yöntem literatürde kayan pencere tekniği (sliding window technique) [42],[43] olarak adlandırılmaktadır. Çoğu çalışma %50 oranda pencereleri örtüştürse de makale [22] bunun doğruluğa çok etkisinin olmadığını yazmaktadır. Pencere boyutunun, basit aktivite tanıma doğruluğuna çok az etki ettiği makale [18]'de belirtilmiştir. Dolayısıyla küçük pencere boyutu ile başlayıp aktiviteye göre dinamik pencere boyutu seçmek önerilmiştir. İncelenen makalelerdeki kullanılan çeşitli pencere boyutları Tablo 3'te gösterilmiştir.

Tablo 3: Kullanılan pencere boyutları.

Pencere Boyutu	Kullanan Makaleler
1 s	[17],[18],[21],[36],[38]
2 s	[18],[29]
2.56 s	[20],[34],[35],[37]
3 s	[22]
4 s	[18],[36]
5 s	[8]
7.5 s	[19]
8 s	[18],[32]
10 s	[7],[24]
12 s	[18]
16 s	[18]
60 s	[23]
3600 s	[23]
M/D	[28],[30],[31],[33],[39],[40],[41]

Karışık aktivite tanımadaki veriyi pencerelere ayırarak özellik çıkartmak yerine veriyi bölmeden özellik çıkartarak işlem yapıldığında doğruluğun olumlu (%26 daha iyi) etkilendiği makale [18]'de vurgulanmaktadır. Ancak ilgili makalede bütün veri kullanımının nasıl yapıldığının detayı verilmemiştir.

Tablo 3 incelendiğinde karışık aktivite tanıma yapan çalışmaların daha uzun pencere boyutu kullandıkları

görülebiliyor [18],[23]. Karışık aktiviteler genelde birkaç basit aktiviteden oluştuğu için büyük pencere boyutundaki verinin incelenmesi gerekmektedir. Basit aktiviteleri tanımak için çalışmalar küçük pencere boyutu kullanmışlardır. En çok 1 saniye ve 2.56 sn. uzunluğundaki pencere boyutları tercih edilmiştir. 2.56 sn.'lik pencere boyutu kullanan [34],[35],[37] numaralı çalışmalar 50 Hz örnekleme frekansı kullanmışlardır. Bu da saniyede 128 örnek ile eğitim yapılması veya basit aktivite tanımaya çalışılması anlamına gelir. [20] ve [34] numaralı çalışmalar 100 Hz örnekleme frekansı ile 2.56 sn.'lik pencere tercih etmişlerdir. Bu da saniyede 256 örnek üzerinde işlem yapmak anlamına gelir. Sonuç olarak, en iyi basit aktivite tanıması yapan çalışmaların saniyede işlem yaptığı örnek sayısının (125, 128, 200 256, 300) yüksek olduğu belirtilebilir [8],[19],[20],[24],[34].

3.5 Eğitim

Veriler toplanıp önemli özellikler çıkarıldıktan sonraki adım, aktivite tanıma modelini oluşturmak için eğitim yapmaktır. Eğitim için farklı algoritmalar ve eğitim yöntemleri kullanılabilir.

3.5.1 Sınıflandırma algoritmaları

Aktivite tanıma performansına etki eden en önemli etkenlerden birisi seçilen sınıflandırma algoritmasıdır. Sınıflandırma algoritmalarının açıklamaları ve karşılaştırılması bu makalenin kapsamı dışındadır. Sınıflandırma algoritma karşılaştırmasını incelemek için makale [28]'e bakılabilir. Bu çalışmada incelenen makalelerin kullandığı algoritmalar ise Tablo 4'te görülebilir. Burada en çok tercih edilen algoritmaların SVM(Support Vector Machines), Naive Bayes ve Decision Tree olduğunu görebiliriz.

Tablo 4: Kullanılan sınıflandırma algoritmaları.

Sınıflandırma Algoritması	Kullanan Makaleler
Bayesian Networks	[18],[21]
Naive Bayes	[18],[21],[22],[29],[31],[35], [38]
SVM	[7],[21],[29],[30],[32],[34],[37], [38],[39],[40]
3-NN	[17]
Decision Tree	[21],[22],[24],[29],[33],[38]
Decision Table	[18],[22]
Best-First Tree	[18]
K-Star	[18]
K-Medoid	[32]
kNN	[19],[20],[38],[41]
QDA	[19]
Logistic Regression	[7](Regularized Multinomial), [21](Multiclass),[24]
Multilayer Neural Network	[24]
K-Means Clustering	[29],[36]
HMM	[23]
ANN	[18](MLP),[23],[38],[41]
Sınıflandırma Kategorileri: bayes, functions, lazy, meta, misc, rules, trees	[28]
Ameva	[8]
Random Forest	[38]

3.5.2 Araçlar

Aktivite tanıma modelini eğitmek için bazı hazır araçlardan faydalanılabilir. Bu araçlarla veri dağılımı gözlemlenebilir ve hazır eğitim algoritması seçilip eğitim yapılabilir. Araçların karşılaştırılması bu çalışmanın kapsamı dışındadır. En çok tercih edilen araç Weka'dır [24],[21]. Weka'nın tercih edilme sebeplerinden birisi de çalışmalarda önerilen yöntemleri Weka'daki hazır yöntemler ile karşılaştırmaktır [36]. Daha az tercih edilen araç ise Matlab'dır [20],[35]. Çoğu makale kullandığı araçlardan bahsetmemiştir.

3.5.3 Eğitim yöntemleri

Aktivite tanımadaki iki çeşit eğitim yöntemini tercih etmişlerdir. Birisi çevrimiçi ve diğeri çevrimdışı eğitimidir. En çok kullanılan tercih modelin çevrimdışı bilgisayarda veya başka ortamda eğitilip sonra akıllı telefonda kullanılmasıdır. Çevrimiçi eğitim, modelin telefonda gerçek zamanlı eğitilmesidir.

Çevrimdışı eğitim [17],[24] modelin eğitime yükünü akıllı telefonda alıp başka cihaza taşır. Genellikle araçlar kullanılarak hazır algoritmalar ile eğitim yapılır. Eğitilen model daha sonra gerçek zamanlı aktivite tanıma uygulaması için akıllı telefonda kullanılır. Çevrimdışı eğitim yapmanın getirdiği dezavantaj ise yeni verilerin aktivite tanımadaki kullanılmıyor olmasıdır. Yürüme gibi bir aktiviteyi kullanıcılar farklı şekilde yapabilir ve bir kişinin yürüme verisiyle eğitilen model başka kişide normalden daha fazla hatalı sonuç üretebilir. Dolayısıyla bir kez eğitilen model bütün kullanıcılar için kullanıldığı ve hiç güncellenmediği için başarı oranı zaman içerisinde iyileştirilememektedir.

Çevrimiçi eğitim [31] ise modeli sürekli eğitir ve yeni verilerle güncel tutar. Bu şekilde kişiselleştirilmiş aktivite tanıma modeli elde edilmiş olur. Ama modeli sürekli güncellemek için kullanıcının hangi aktiviteyi yapıyor olduğunu uygulamaya elle girmesi gerekebilir. Ancak insan müdahalesini en aza indirmek için verinin içerisinde güvenilirlik seviyesine bağlı olarak önceki veri içerisindeki sınıflara en çok benzeyen veriler seçilerek yeni eğitim kümesi otomatik olarak güncellenebilir.

Kişiselleştirilmiş aktivite tanıma modeli [8],[36] hem çevrimiçi hem de çevrimdışı eğitim yöntemiyle elde edilebilir. Çevrimiçi eğitim yapıldığında oluşan model zaten kişiselleştirilmiş modeldir [31]. Çevrimdışı eğitilmiş modeli kişiselleştirilmiş modele çevirmek için ise farklı yöntemler kullanılmıştır. Bu yöntemleri detaylı incelemek için makale [29] ve [32]'ye bakılabilir.

3.6 Değerlendirme metrikleri

Model eğitildikten sonra çevrimdışı sınıflandırma yapılabilir veya akıllı telefonda bir uygulama üzerinde çalıştırılıp gerçek zamanlı test edilebilir. Sınıflandırma yapıldıktan sonra aktivite tanıma modelinin performansını ve hatasını ölçmek için bazı metrikler kullanılır. En çok kullanılan metrikler doğruluk (accuracy), kesinlik (precision) ve anımsamadır (recall). Bazı çalışmalar test aşamasında doğruluk matrisleri (confusion matrix) çizmiştir. Bu metriklerin hesaplanması (1), (2), (3) eşitliklerinde gösterildikleri gibidir [44]:

DP: Doğru Pozitif YP: Yanlış Pozitif

DN: Doğru Negatif YN: Yanlış Negatif

$$\text{Doğruluk} = (DP + DN) / (DP + DN + YP + YN) \quad (1)$$

$$\text{Kesinlik} = DP / (DP + YP) \quad (2)$$

$$\text{Anımsama} = DP / (DP + YN) \quad (3)$$

4 Zorluklar ve uygulanmış çözümler

İncelenen çalışmalarda aktivite tanıma işlemleri gerçekleştirilirken farklı zorluklar ve sorunlarla karşılaşmıştır. Bunlara karşı çözümler denenmiş ve uygulanmıştır. Bu sorunların önemli olanları kaynak tüketimi, karışık aktivite tanıma, aktivite tanıma yapan cihaz oryantasyonu, cihaz konumu ve aktivite tanıma modelinin kişisel aktivitelerle eğitilmesidir.

4.1 Kaynak tüketimi

Sadece enerji verimliliği üzerine odaklanmış makale [33] bu alanda kapsamlı bir çalışma yapmıştır. Verinin örnekleme frekansının artması [22],[33],[34] veya özellik sayısının artması [21],[33],[34] kaynak tüketimini olumsuz etkilemektedir. Zaman alanındaki özellikler için 16 Hz frekansta 2 saat boyunca veri toplamak ~150 joule enerji tüketirken 100 Hz frekansta aynı süre boyunca veri toplamak ~300 joule enerji tüketmektedir [33]. Makale [34]'te yapılan deneye göre, 30 dakika boyunca sabit 100 Hz frekansta, 128 uzunluğunda pencere boyutuyla veri toplanmış ve farklı özellik vektör boyutları için (dimensionality) deneme yapılmıştır. 28 vektör boyutu için 400 mWh güç tüketimi olurken 60 vektör boyutu için 1600 mWh güç tüketimi gerçekleşmiştir. Makale [37] daha az kaynak tüketen ve aynı zamanda benzer doğruluk sonucunu veren donanım dostu (hardware friendly) algoritma önermiştir. Makale [39] ise daha kısıtlı belleklerde çalışabilecek, mobil odaklı bir yöntem önermektedir. Frekans alanındaki özellikleri bulmanın sayısal anlamda daha karışık olduğu makale [32]'de vurgulanmıştır. Çalışma [22] kullanılan sensör sayısının kaynak tüketimine etkisinin olduğunu, sadece ivmeölçer kullanmanın başka sensörlerin birlikte kullanılmasından kaynak tüketimi (enerji, işlemci) açısından daha iyi olduğunu yazmıştır. Kaynak tüketimini etkileyen diğer faktör ise makale [34]'te belirtilen pencere boyutudur. Pencere boyutunun büyük olması kaynak tüketimini olumlu etkilemektedir.

4.2 Karışık aktiviteler

Karışık aktiviteler yemek pişirme, temizlik yapma, bitki sulama gibi birkaç basit aktivite veya hareketlerden oluşan aktivitelerdir. Karışık aktivitelerin tanınması basit aktivitelere göre daha zordur. İvmeölçer ve jiroskop kullanarak karışık aktivite tanıma yapan makale [18] %50 doğruluk elde etmiştir. Daha sonra veriyi pencerelere ayırarak özellik çıkartmak yerine veriyi bölmeden özellik çıkartıp işlem yaparak %78 doğruluk elde etmişlerdir.

Makale [23] ivmeölçer kullanarak, sadece karışık aktivite tanıma için ~%85 kesinlik elde etmiştir ancak testler bazı kabuller yapılarak gerçekleştirilmiştir. Karışık aktivitenin yürüme, ayakta durma, sonra tekrar yürüme gibi basit aktivite sırasının olduğunu düşünerek testi gerçekleştirmişlerdir. Gösterilen kesinlik sadece birkaç karışık aktivite içindir (alışveriş yapma ve otobüse binme) ve basit aktivite ile birlikte test edilmemiştir. Sonuç olarak GPS veya Wi-Fi gibi diğer sensörlerin karışık aktivite tanımadaki kullanılmasını önermiştir.

Makale [30] hem ivmeölçer hem de zaman-aktivite anket verisi kullanarak tüm aktiviteler için %28.01 ortalama kesinlik ve %28.38 ortalama anımsama elde etmiştir. Ama bazı karışık aktivitelerde, örneğin uyuma için %83.22 kesinlik ve %95.62

anımsama, çalışma için %56.38 kesinlik ve %48.74 anımsama elde etmişlerdir. Spor, bilgisayarda çalışma veya yolculuk için çok düşük sonuçlar elde edilmiştir. Sebebi ise bu bilgilerin zaman kullanımı anketlerinde yer almaması ve sadece sensör verisiyle aktivite tanınmaya çalışılmasıdır. Yeme, sosyalleşme ve hobi gibi aktiviteler için zaman-aktivite anket verisi kullanıldığında, sadece sensör verisi kullanarak bulunan kesinlikten, %25, %18 ve %6 daha iyi kesinlik elde edilmiştir.

Karışık aktivite tanımada en iyi sonuç elde eden makalelerden birisi [21]'dir. İvmeölçer ve GPS sensörleri kullanmışlar ve bunlarla birlikte ontoloji tabanlı yöntem tercih edilmiştir. Bu verilerin yanında bir de kişinin bir önceki zaman dilimindeki aktiviteleri de hesaba katılmış ve sonuç olarak %93.44 doğruluk elde edilmiştir.

4.3 Cihaz oryantasyonları

Cihaz oryantasyonu cihazın yatay, dikey ve farklı oryantasyonlarda duruyor olmasıdır. Cihazın oryantasyonu değişince aynı aktivite için aynı sensörden okunan veri eksenler bazında değişmektedir. Dolayısıyla bir oryantasyonda aktivite tanımlanabilirken başka oryantasyonda tanıma başarısız olabilir.

Oryantasyondan bağımsız aktivite tanıma yapabilmek için bazı yöntemlerin kullanılması gerekmektedir. Bu probleme bir yaklaşım oryantasyondan bağımsız sensör verileri kullanmaktır. Makale [19] ve [40] ivmeölçer sensörünün 3 ekseninden gelen verileri özel yöntemle birleştirmiş ve cihaz oryantasyonundan bağımsız veriler elde etmiştir. Makale [19] bunu yapabilmek için eksenlerden elde edilen verilerin karesinin toplamı (square summing) yöntemini kullanmıştır. Makale [38] yerçekimi esaslı özellikler çıkartmış ve bunu cihaz oryantasyonunu tespit etmek için kullanmıştır. Fakat bu yaklaşımla bazı oryantasyonlar belirlenememektedir. Makale [20]'nin yaklaşımı ise ivme ölçer verisinin vücut koordinat sistemini dünya koordinat sistemine çevirmektir. Diğer çalışma [18]'de, sadece ivme ölçer verisinin yanında, jiroskop sensörden elde edilen veriler kullanıldığında, oryantasyon problemi konusunda %10-12 iyileştirme sağlandığı belirtilmiştir. Çalışma [22] mıknatıs ölçer ve G sensörü kullanarak cihazın oryantasyonunu belirlemiş ve sınıflandırmada kullanmıştır. Tablo 5'te incelenen makalelerin kullandığı oryantasyonlar ve hangi makalelerin oryantasyondan bağımsız aktivite tanıma yapabildiği gösterilmiştir.

Tablo 5: Kullanılan cihaz oryantasyonları.

Cihaz Oryantasyonu	Kullanan Makaleler
Bağımsız	[8],[17]-[20],[22], [38],[40]
Dikey	[28],[32]
Ekran içe dönük	[7]
Ekran dışı dönük	[7],[28],[39]
	[21],[23],[24],[29]
M/D	[30],[31],[33],[34],[35], [36],[37],[41]

4.4 Cihaz konumları

Bir diğer karşılaşılan sorun ise cihazın vücuttaki konumudur. Cihaz cepte, elde, belde veya tişörtün cebinde yer alabilmektedir. Makale [17] sensör verileri üzerinde sinyal dönüştürme yapmıştır ve üç farklı cihaz pozisyonu ile aktivite tanıma testi yapmıştır. Test sonucunda bel konumunda duran cihazın daha iyi doğruluk (~%70) gösterdiği saptanmıştır. En kötü sonuç ise telefonun pantolon cebinde durduğu zamandır

[22]. Makale [18] jiroskoptan elde edilen verileri kullanarak cihaz konumundan bağımsız aktivite tanıma işlemi yapmıştır. Jiroskop ile benzer bir yöntemi [40] numaralı çalışma yapmıştır. Önce cihaz konumu tahmini yaparak daha sonra aktivite tanıma çalışmışlardır. Makale [22], önce cihazın konumu tahmin etmiş (ışık ve yakınlık sensörü kullanılarak), daha sonra o konuma karşılık gelen eğitilmiş sınıflandırma modeli kullanmıştır. Bu yöntem daha iyi doğruluk verse de biraz yavaş çalışmaktadır. Benzer bir şekilde makale [38] sadece ivmeölçer ile önce konum tespiti yapmış ve sonra aktivite sınıflandırması yapmıştır. Bu yaklaşımın konumdan bağımsız aktivite tanımadan %4 daha iyi olduğunu göstermiştir. En iyi doğruluk sonucu veren cihaz konumunun bacak (shin) olduğunu belirtmiştir. Tablo 6'da, incelenen makalelerin kullandığı konumlar ve hangi makalelerin cihazın vücuttaki konumundan bağımsız aktivite tanıma yapabildiği gösterilmiştir.

Tablo 6: Kullanılan cihaz konumları.

Cihaz konumları	Kullanan makaleler
Bağımsız	[17],[18],[22]
Pantolon ön cep	[7],[17],[19],[20],[21],[24], [29],[32],[40]
Pantolon arka cep	[34],[40]
Bel	[17],[35],[37],[38]
Tişört	[17],[28],[40]
El	[23],[28],[29]
Kol	[21],[29],[30],[38],[39]
Göğüs	[29],[38]
Ayak/Bacak	[38],[39]
Kalça	[38]
Çanta	[40]
Baş	[38]
M/D	[8],[31],[33],[36],[41]

4.5 Kişiselleştirilmiş aktivite tanıma

Kişilerin yaptığı aktivitelerin çoğu kişiye özel desenler içerir. Örneğin bir kişinin yürüme tarzı kendine özgüdür. Bunun aktivite tanımadaki önemi bir kişiyle eğitilmiş modelin başka kişide iyi sonuç veremeyebilir olmasıdır. Bazı aktivitelerde ise kişiye özel desen olmayabilir. Örneğin bisiklet kullanmada kişiler hep sabit, aynı ayak hareketleri yaparlar. Hem çevrimiçi hem de çevrimdışı eğitim yöntemi kullanıldığında, aktivite tanıma modeline kişiselleştirme yapılabilir. Bu şekilde, eğitilmiş model sürekli kişiye özel yeni verilerle güncellenir ve kişiye özel aktiviteleri daha iyi tanıyabilir.

Çevrimiçi eğitim yapıldığı zaman kişiselleştirilmiş model elde edilir. Makale [31] bu yöntemi kullanmıştır. Bu yöntemde eğitim yapmak için, aktiviteler yapılmadan önce uygulama yardımıyla hangi aktivite yapılacağı seçilmelidir.

Çevrimdışı eğitim yapılarak, daha sonra kişiye özel aktiviteler ile model güncellenebilir. Bu yöntemi kullanan makaleler [8] [29], [32] ve [36]'dir. Bu çalışmaların her biri farklı çözüm önermiş ve uygulamıştır, detaylar için makaleler incelenebilir. Makale [8]'in önerdiği yöntem otomatik yeni aktivite tanıma ve önerme işlemini de yapmaktadır.

5 Hazır veri setleri

Akıllı telefonlardaki, giyilebilir cihazlardaki sensörler ve diğer sensörler ile toplanan aktivite verilerini barındıran 12 veri seti bu bölümde tanıtılmaktadır. Her veri seti farklı yaş grubuna ait kişiler, farklı örnekleme frekansı ve farklı konumlardaki sensörler ile toplanmıştır. Yapılan literatür taraması

sonucunda sadece karışık aktivite verilerini bulunduran herhangi bir veri seti ile karşılaşılmamıştır.

5.1 WISDM actitracker [45]

Bu veri seti "Wireless Sensor Data Mining" (WISDM) Lab. tarafından oluşturulmuştur. Verileri toplamak için kendi yazdıkları Actitracker [46] Android uygulamasını kullanmışlardır. Kullandıkları Actitracker sistemi hakkında detaylı bilgi makale [47]'de bulunmaktadır. Veri setinde 6 basit aktivitenin sensör verisi bulunmaktadır. Toplam 2,980,765 etiketlenmiş ve 38,209,772 etiketlenmemiş ham veri örneği vardır. Aktiviteler ve onların toplam etiketlenmiş ham veri örnek sayısına oranı şu şekildedir: yürüme %42.1, tempolu koşma (jogging) %14.7, merdiven çıkma/inme (stairs) %1.9, oturma %22.3, ayakta durma %9.7, yatma %9.3. Ham verilerde 6 tane özellik bulunmaktadır. Ham verilerin yanında bir de WEKA programı kullanılarak dönüştürülmüş veriler bulunmaktadır. Veri dönüştürmenin (data transformation) nasıl yapıldığı makale [47]'de anlatılmaktadır. Veri setinde dönüştürülmüş ve 5.435 etiketlenmiş, 1,369,349 etiketlenmemiş örnek mevcuttur. Bu örneklerde toplam 46 tane özellik vardır.

5.2 WISDM activity prediction [48]

Bu veri seti "Wireless Sensor Data Mining" (WISDM) Lab. tarafından kontrollü ve laboratuvar koşullarında oluşturulmuştur. Veri seti makale [49]'da kullanılmıştır. Veri setinde 6 basit aktivitenin sensör verisi bulunmaktadır. Toplam 1,098,207 etiketlenmiş ham veri ve 5.424 etiketlenmiş ve dönüştürülmüş veri örneği vardır. Ham veride 6, dönüştürülmüş veride ise 46 özellik bulunmaktadır. Veri dönüştürmenin (data transformation) nasıl yapıldığı makale [47]'de yazmaktadır.

5.3 Skoda mini checkpoint [50],[51]

"Skoda mini checkpoint", araba tamir edilirken yapılan, 10 tane el hareketinden oluşan veri setidir. Tek kişi ile toplanan veri seti için sağ ve sol kolda ivmeölçer sensörleri kullanılmıştır. Her el hareketinden 70 örnek vardır.

5.4 SCUT-NAA [52],[53]

Bu veri seti ivmeölçer kullanılarak toplanan 10 tane aktiviteden oluşmaktadır. 34 erkek ve 10 kadın olmak üzere 44 kişinin yaptığı aktivitelerden 1.278 örnek bulunmaktadır. Yapılan aktiviteler şunlardır: *oturma ve dinlenme, yürüme, hızlı yürüme, geri yürüme, koşma, yerinde yürüme (step walk), zıplama, merdiven çıkma, merdiven inme ve bisiklet sürme*. İvmeölçer sensörler kişilerin tişört cebine, beline, pantolon cebine yerleştirilmiştir ve veriler 100 Hz frekansta toplanmıştır.

5.5 Heterogeneity human activity recognition [54]

"The Heterogeneity Human Activity Recognition" (HHAR) akıllı telefon ve akıllı saatlerde bulunan ivmeölçer, jiroskop sensörleriyle kişilerin aktivitelerinin kaydedildiği veri setidir. *Bisiklet sürme, oturma, ayakta durma, yürüme, merdiven çıkma ve merdiven inme* aktivitelerinden oluşan veri seti, 12 farklı cihaz (4 akıllı saat, 8 akıllı telefon) kullanılarak oluşturulmuştur. 9 kişi ile bu aktiviteler yapılarak veriler kaydedilmiştir ve veri setinde toplam 43,930,257 örnek ve 16 özellik mevcuttur.

5.6 Human activity recognition using smartphones [55]

Bu veri seti 30 kişinin beline taktığı akıllı telefon sensörleriyle aktivitelerin kaydedilmesi sonucu oluşturulmuştur. 10.299

örnek ve 561 özellik bulunmaktadır. Kişiler 19-48 yaş aralığındadır ve *yürüme, merdiven çıkma, merdiven inme, oturma, ayakta durma, yatma* olmak üzere toplam 6 aktivite yapmışlardır. İvmeölçer ve jiroskop sensör verileri 50 Hz frekansta toplanmıştır. Toplanan veriler üzerinde ön işleme yapılmış (gürültü filtresi) ve 2.56 saniyelik pencereler kullanılmıştır (%50 örtüşmeli).

5.7 OPPORTUNITY [56]

Opportunity veri seti farklı türdeki cihazlarda (wearable sensor, object sensor, ambient sensor) bulunan sensörlerden toplanan aktivite verilerinden oluşmaktadır. 4 kişinin toplam 5 aktivite, 13 aksiyon ve 17 el hareketi bulunmaktadır. 2.551 örnek ve 242 özelliği vardır.

5.8 Human activity recognition in ambient assisted living [57]

Bu veri seti yukarıda bahsedilen veri setinin [55] devamı şeklindedir. Toplam 5,744 örnek ve 561 özellik bulunmaktadır. Örnekler kişinin beline taktığı akıllı telefon ile ivmeölçer ve jiroskop sensörü kullanılarak toplanmıştır. Kişiler 22-79 yaş aralığında olup 30 kişi *ayakta durma, oturma, yatma, yürüme, merdiven çıkma ve merdiven inme* hareketlerini yapmıştır. Verinin toplanma frekansı 50 Hz'dir.

5.9 Smartphone Based Recognition of Human Activities and Postural Transitions [58]

Bu veri seti yukarıda bahsedilen veri setinin [55] genişletilmiş halidir. Yaşları 19-48 arasında olan 30 kişiden toplanan aktiviteleri bulunduran bu veri setinde toplam 10.929 örnek ve 561 özellik vardır. 3 tane durgun aktivite ve 3 tane de hareketli aktivite olmak üzere bu 6 aktivite yapılmıştır: *ayakta durma, oturma, yatma, yürüme, merdiven inme, merdiven çıkma*. Bu aktiviteler ek olarak, aktiviteler arasındaki geçiş hareketleri (postural transitions) de veri setinde yer almaktadır. Bu geçiş hareketleri şunlardır: *ayaktan dururken oturmak (stand to sit), otururken kalkmak (sit to stand), otururken yatmak (sit to lie), yatarken oturmak (lie to sit), ayakta dururken yatmak (stand to lie), yatarken ayakta durmak (lie to stand)*. İvmeölçer ve jiroskop sensör verileri bele takılı akıllı telefonla 50 Hz frekansında toplanmıştır. Toplanan veriler üzerinde ön işleme yapılmış (gürültü filtresi) ve 2.56 sn.'lik pencereler kullanılmıştır (%50 örtüşmeli).

5.10 Physical activity recognition using smartphone sensors [59]

Bu veri seti akıllı telefon ile toplanmış 6 aktiviteye ait sensör verilerini bulundurmaktadır. Yaşları 25-30 aralığında olan 4 kişi ile toplanmış veri setinde her kişi için 4 farklı konumda akıllı telefon yerleştirilmiştir. Bu noktalar pantolon cebi, kol, bel ve bilektir. Aktiviteler ise *yürüme, koşma, ayakta durma, oturma, merdiven inme ve merdiven çıkma*dır. Veriler 50 Hz frekansta ivmeölçer, jiroskop ve miknatis ölçer sensörleriyle toplanmıştır.

5.11 Sensors activity recognition [59]

Bu veri setinde 7 aktivite bulunmaktadır. Bu aktiviteler *yürüme, oturma, ayakta durma, tempolu koşma, bisiklet sürme, merdiven çıkma ve merdiven inme*dir. Yaşları 25-30 aralığında olan 10 erkek kişi tarafından toplanan veriler için her kişi 4 akıllı telefon ve 1 akıllı saat kullanmıştır. Bu akıllı telefonlar şu vücut konumlarına yerleştirilmiştir: pantolonun sel cebi, pantolonun sağ cebi, bel, sağ kol üstü. Akıllı saat ise bileğe takılmıştır.

Veriler 50 Hz frekansta ivmeölçer, jiroskop ve mıknatıs ölçer sensörleriyle toplanmıştır.

5.12 Hybrid reasoning for context aware activity recognition [60]

Bu veri seti yaşları 30-60 aralığında olan 3 erkek ve 3 kadın ile toplanmıştır. Veriler sol cebe ve sağ bileğe takılı ivmeölçer sensör ile kaydedilmiştir ve ek olarak GPS sensörü de kullanılmıştır. Veri setindeki 10 tane aktivite şunlardır: *diş fırçalama, yukarı tırmanma (climb up), aşağı inme (climb down), bisiklet sürme, tempolu koşu, ayakta durma, gezinme (strolling), merdiven inme, merdiven çıkma, tahtaya yazma*. Veriler 16 Hz frekansta toplanmıştır ve toplam 18.000 örnek vardır.

6 Klasik yöntemlerin başarıları

Yukarıda aktivite tanıma için kullanılan adımlardan ve yöntemlerden bahsedilmiştir. İncelenen makalelerin hangi aşamada ne seçim (örnekleme, özellik, algoritma) kullandığı gösterilmiştir. Daha sonra ise karşılaşılan zorluklar ve uygulanan çözümler anlatılmıştır. Bu bölümde aktivite sensör çeşitlerine göre elde edilen en iyi sonuçlardan bahsedilmektedir. Bu sonuçların hepsi Tablo 7'de karşılaştırmalı olarak listelenmiştir.

Tablo 7: Klasik yöntemler ve sonuçlar.

Makale	Sensörler	Aktiviteler	Veri Toplama	Platform	Değerlendirme Metrikleri	Sonuçlar
[24]	İvmeölçer	Yürüme, tempolu koşu (jogging), merdiven çıkma, merdiven inme, oturma, ayakta durma	29 kişi, Android kullanarak	Nokia N95	Doğruluk	MLP ile genel doğruluk %91.7. Merdiven çıkma ve inme aktivitelerinin sınıflandırma doğruluğu düşük. İkisini birleştirerek tek aktivite yapınca daha iyi, %77.6 doğruluk elde ediliyor
[21]	İvmeölçer, GPS	Basit: tempolu koşu (jogging), gezinme (strolling), aşağı inme (climb down), yürüme, merdiven inme, yukarı tırmanma (climb up), merdiven çıkma, ayakta durma, bisiklet sürme, motosiklet ile hareket (moving by motorbike), araba ile hareket (moving by car), tren ile hareket (moving by train)	6 kişi, yaş 30-60 aralığı, giyilebilir cihaz ve Android kullanarak	Android	Doğruluk	En iyi doğruluk COSAR-hist yöntemi ile elde edilmiş: %93.44
[29]	İvmeölçer	Karışık: sosyal (oynama), iletişim (yüz yüze görüşme, görüntülü konferans, telefon konferans, anlık mesajlaşma), diş fırçalama, banyo yapma, yeme, ders anlatma, tahtaya yazma, kişisel bilgisayar kullanma, projektör kullanma	10 kişi, Nokia N95 kullanarak	M/D	Ortalama, doğruluk (mean accuracy)	Önerilen yöntemi kullanmadan önce hesaplanan doğruluk %61.25±5.35, yöntem kullanarak hesaplanan doğruluk %82.16±6.24. Algoritmalara göre ortalama doğruluklar: DT %85.31, SVM %83.99, NBN %80.67
[17]	İvmeölçer	Yürüme, koşu, yatma, zıplama, oturma, ayakta durma	10 kişi, yaş 22-36 aralığı, iPhone kullanarak	iPhone	Doğruluk	Önerilen yöntemi kullanmadan önce hesaplanan doğruluk %80.55, yöntem kullanarak hesaplanan doğruluk %86.36

Tablo 7: Devamı.

Makale	Sensörler	Aktiviteler	Veri Toplama	Platform	Değerlendirm e Metrikleri	Sonuçlar
[23]	İvmeölçer	Basit: yürüme, koşu, merdiven çıkma, merdiven inme, ayakta durma Karışık: alışveriş yapma, otobüse binme	3 kişi, yaş 20-30 aralığı, Android kullanarak	Android	Kesinlik	Sadece karışık aktivite için ~%85 kesinlik
[37]	İvmeölçer, jiroskop	Yürüme, yatma, merdiven çıkma, merdiven inme, ayakta durma	30 kişi, yaş 19-48 aralığı, Android kullanarak	Android	Anımsama, kesinlik	Daha az "k" değeri ile aynı kesinlik elde ediliyor. MC-SVM (k=64) ile %89.3 ve MC-HF-SVM (k = 8) ile %89
[33]	İvmeölçer	Ayakta durma, koşma, yavaş yürüme, yürüme, oturup rahatlatma (sit relax), oturma, yürüyen merdiven ile çıkma, yürüyen merdiven ile inme, asansör ile çıkma, asansör ile inme, merdiven inme	4 kişi, Android kullanarak	Android	M/D	İdeal koşullar altında %50 enerji tasarrufu olurken, Android telefonu ile uygulama test edilince %20-25 enerji tasarrufu yapılmıştır.
[31]	İvmeölçer	M/D	M/D	Android	M/D	M/D
[18]	İvmeölçer, jiroskop	Basit: bisiklet sürme, merdiven çıkma, araba sürme, yatma, oturma, ayakta durma, koşma, yürüme, telefon kullanıcıda değil Karışık: Yemek pişirme, temizlik yapma, ilaç kullanma, süpürme, elleri yıkama, bitki sulama	10 kişi, Android kullanarak	Android	Doğruluk	Basit aktivite için en iyi doğruluk %90 (Naive Bayes algoritması hariç) Karışık aktiviteler için en iyi doğruluk %50
[19]	İvmeölçer	Yürüme, koşma, bisiklet sürme, araba sürme, ayakta durma	8 kişi, yaş 25-34 aralığı, ortalama boy 1.78 m, Nokia N8 (Symbian^3) kullanarak	Android	Doğruluk	QDA algoritması ile en iyi doğruluk %95.8, K-NN ile %93.9
[7]	İvmeölçer	Yürüme, ayakta durma, oturma, telefon kullanıcıda değil	18 (13 genç, 5 yaşlı) sağlıklı kişi, 8 hasta, Android kullanarak	M/D	Doğruluk	Tüm veri numuneleri kullanılarak, sağlıklı kişiler için %96.1 (SVM), %89.7 (SMLR), hasta kişiler için %92.2 (SVM), %84.7 (SMLR) doğruluk elde edilmiştir. Kişi bazlı çapraz geçerlilik veri numunesi kullanılarak, sağlıklı kişiler için %86.0 (SVM), %85.2 (SMLR), hasta kişiler için %75.1 (SVM), %76.0 (SMLR) doğruluk elde edilmiştir. Sağlıklı kişilerin verisi ile eğitilmiş model hasta kişiler ile test edildiğinde, %60.3 (SVM), %63.5 (SMLR) doğruluk elde edilmiştir.

Tablo 7: Devamı.

Makale	Sensörler	Aktiviteler	Veri Toplama	Platform	Değerlendirme Metrikleri	Sonuçlar
[30]	İvmeölçer (giyilebilir cihaz)	Karışık: uyuma, yeme, kişisel bakım, çalışma, ders çalışma, ev işi, sosyalleşme, spor, hobi, iletişim araçları (mass media), yolculuk (tavelling)	17 (12 erkek, 5 kadın) kişi, yaş 21-48 aralığı, SenseWear Armband kullanarak	M/D	Anımsama, kesinlik	Sadece sensör kullanarak hesaplanan kesinlik %20.42 ve hatırlama değeri %21.11. Sadece zaman-aktivite anket verisi kullanarak hesaplanan kesinlik %23.76 ve hatırlama değeri %17.4. Hem Sensör, zaman-aktivite anket verisi kullanarak hesaplanan kesinlik %28.01 ve hatırlama değeri %28.38
[20]	İvmeölçer, jiroskop, mıknatis ölçer	Koşma, yürüme, bisiklet sürme, ayakta durma, oturma	20 kişi, yaş 18-59 aralığı, Android kullanarak	Android	Doğruluk	En iyi elde edilen doğruluk %97 (lineer ivme, yer koordinat sistemi, yayılmış özellikler kullanılarak) SCUTT-NAA veri seti ile SVM algoritması kullanılarak %80 civarı doğruluk elde edilmiştir. Kişiselleştirilmemiş yöntemeye göre doğruluk %11 iyileştirildi
[32]	İvmeölçer	Yürüme, tempolu koşu, bisiklet sürme, merdiven çıkma, merdiven inme, koşma	M/D	Android	Doğruluk	
[28]	İvmeölçer	Yürüme, tempolu koşu (jogging), zıplama, oturma, ayakta durma	M/D, Android	M/D	Doğruluk	>%90
[39]	İvmeölçer (giyilebilir cihaz)	Yavaş yürüme, hızlı yürüme, göz atma (browsing), durmak ve tekrar devam etmek (stopping and starting), etrafa bakınmak (looking around), kararsız hareketler (erratic movements)	Nintendo Wiimote	HP iPAQ pocket PC (Windows Mobile 6)	Kesinlik	%80-%99 kesinlik
[22]	İvmeölçer, G sensör, ışık sensörü, mıknatis ölçer, jiroskop, yakınlık ölçer	Yavaş yürüme, hızlı yürüme, koşma, oturma, ayakta durma	16 (12 erkek, 4 kadın) kişi, yaş 23-50 aralığı	Android Nexus S	Doğruluk	Decision Tree algoritması ile en iyi sonuç %94 (tüm sensör ve özellikler kullanılarak).
[40]	İvmeölçer, jiroskop	Yürüme, koşma, merdiven çıkma, merdiven inme, ayakta durma, oturma	M/D	M/D	Doğruluk	3 farklı cihaz konumda aktivite tanıma için ortalama %92.5 doğruluk elde edilmiştir. Cihaz konumu tespiti için %97.82 doğruluk elde edilmiştir
[36]	İvmeölçer (akıllı telefon ve giyilebilir cihaz).	SPAD, WISDM, Opportunity veri setleri	SPAD, WISDM, Opportunity veri setleri, Android	Android	TP (toplam doğru sınıflandırılan sınıf)	WISDM veri seti %71.2, SPAD veri seti %97.21, Opportunity veri seti %68-%75 TP
[35]	İvmeölçer, jiroskop	Yürüme, yatma, merdiven çıkma, merdiven inme, ayakta durma, oturma	30 kişi, yaş 19-48 aralığı, Android kullanarak	M/D	Doğruluk	%94 doğruluk

Tablo 7: Devamı.

Makale	Sensörler	Aktiviteler	Veri Toplama	Platform	Değerlendirme Metrikleri	Sonuçlar
[41]	İvmeölçer	Yürüme, tempolu koşu, merdiven çıkma, merdiven inme, ayakta durma	WISDM veri seti, Android	M/D	Doğruluk	K-NN algoritması ile %94 doğruluk, ANN algoritması ile %92 doğruluk
[34]	İvmeölçer	Yürüme, koşma, merdiven çıkma, merdiven inme, ayakta durma, oturma	2 erkek kişi, yaş 28 ve 32, Android kullanarak	M/D	Doğruluk	Ortalama %92.17 doğruluk
[8]	İvmeölçer	Ayakta durma (immobile), yürüme, koşma, düşme, sürme, merdiven çıkma, merdiven inme, bisiklet sürme	30 kişi, yaş 19-48 aralığı. USC-HAD, WISDM, Shoaib veri setleri	M/D	Doğruluk	%95 doğruluk
[38]	İvmeölçer	Merdiven çıkma, merdiven inme, zıplama, yatma, ayakta durma, oturma, koşma, yürüme	15 kişi (8 erkek, 7 kadın), yaş 31.9±12.4	M/D	Doğruluk	Konum tespiti için %89 doğruluk, aktivite tanıma için RF algoritması ile %84 doğruluk

6.1 Basit aktivite tanıma

Basit aktivite tanımda elde edilen en iyi doğruluk değeri makale [20]'nin bulduğu %97 sonucudur. Kullandıkları sensörler ivmeölçer, jiroskop ve mknatis ölçerdir. Sadece ivme ölçer ve QDA algoritması kullanarak en iyi sonucu elde eden (%95.8) çalışma ise makale [19]'dur. Çalışma [8] ivmeölçer ile cihaz oryantasyondan bağımsız %95 doğruluk elde etmiştir. Makale [22] yedi sensör kullanarak ve Decision Tree algoritması ile cihaz oryantasyonundan ve konumdan bağımsız %94 doğruluk elde etmiştir. Aynı başarı oranını makale [35] ivmeölçer ve jiroskop kullanarak elde edebilmiştir. Makale [41] ise sadece ivmeölçer ve k-NN algoritması ile %94 doğruluk elde etmiştir. Bundan sonra sırasıyla makale [40] %92.5, makale [34] %92.17, makale [24] %91.7 doğruluk elde etmiştir. Makale [19] ve [20] iyi sonuç elde etmesinin yanında cihaz oryantasyonundan bağımsız aktivite tanıma yapabilmektedir. Makale [17] sadece ivmeölçer kullanarak hem cihaz oryantasyonundan hem de cihaz konumundan bağımsız aktivite tanıma yapmaktadır ve %86.36 doğruluk oranını elde etmiştir.

6.2 Karışık aktivite tanıma

Karışık aktivite tanımda en iyi sonuca ulaşan makale [21] %93.44 doğrulukla aktivite tanıma yapabilmektedir. Karışık ve basit aktiviteleri çok iyi oranda tanıyabilmesinin sebeplerinden birisi bağlam bilinçli (context aware) olmasıdır. Kişinin bulunduğu ortamı ve bağlamı anlamak için GPS sensörü kullanılmıştır. Bu çalışmanın diğer çalışmalarından en büyük farkı ontoloji tabanlı aktivite tanıma mimarisi kullanmasıdır. Konum bazlı ontolojik mantık yürütmede (ontological reasoning) aktivite, süre, aktiviteyi yapan kişi, konum, iletişim yolu ve eserler mevcuttur. İvmeölçer sensör verisi kullanarak makine öğrenmesi yöntemleriyle sınıflandırma yapılır ve olası aktiviteler bulunur. Daha sonra, bulunan sonuç listesini daraltmak için ontolojik mantık yürütme yöntemi kullanılır. Makalenin uyguladığı diğer yaklaşım ise aktiviteleri sadece anlık sensör verileriyle tanımayla çalışmak yerine bir önceki zamanda yapılan aktiviteleri de dikkate almaktır.

Makale [23] ivmeölçer kullanarak %85 civarında kesinlik ile sadece karışık aktivite tanıması yapabilmektedir.

7 Yeni nesil çözümler

Aktivite tanıma ve benzer problemlerde klasik yapay sinir ağları ve benzer makine öğrenmesi yöntemlerinin

denenmesiyle beraber son birkaç senede derin öğrenme yöntemleriyle çalışmalar yapılmaktadır. Derin öğrenme yöntemleri veya derin ağlar, yapay sinir ağlarının çeşidi olup daha karmaşık problemleri çözebilme kapasitesine sahip ağlardır. Klasik yapay sinir ağları birkaç katmandan (giriş katman, gizli katmanlar, çıkış katman) oluşur. Her katmanda girdi hakkında bir şeyler öğreniliyor ve bir sonraki katmanda girdinin daha karışık özellikleri çıkartılmaya çalışılır. Katmanlar ve katmanlardaki nöron sayısı arttıkça ağı eğitilmesi çok uzun sürebilirken derin ağların eğitilmesini engelleyen VGP (Vanishing Gradient Problem) problemi ortaya çıkabilmektedir. Bu sebeplerden dolayı yapay sinir ağları son on beş seneye kadar sınırlı problem alanlarında kullanılıyordu. Bilgisayarlardaki GPU teknolojisinin gelişmesi ağ eğitim süresi problemini çözmüştür ve bazı derin öğrenme yöntemlerindeki ilerleme VGP problemine çözüm getirmiştir.

Derin ağlar, görüntü tanıma, nesne tanıma ve doğal dil işleme gibi birçok alanda kullanılmaktadır. Aktivite tanıma alanında derin öğrenme yöntemleri ile son yıllarda çalışmalar yapılmıştır. Bu alanda derin öğrenme yöntemleri kullanmanın en büyük avantajı ham sensör verilerinden saklı kalmış önemli özelliklerin otomatik çıkartılabilmesidir. Aktivite tanıma için sensör verilerinden hangi özelliklerin kullanılacağını belirlemek için bilirkişiye ihtiyaç kalmamaktadır. Derin ağlarla cihaz konumdan ve oryantasyonundan bağımsız özellikler de çıkartılabilmektedir.

Derin ağların eğitim süresi çok uzun süreler alabildiği için süreyi kısaltmak adına güçlü donanımların kullanımına ihtiyaç duyulmaktadır. Dolayısıyla derin öğrenme ile eğitimin şu anki mobil cihaz donanımları üzerinde yapılması mümkün değildir. Sadece bilgisayar ortamında eğitilmiş hazır modeller telefon üzerinde gerçek zamanlı aktivite sınıflandırmak için kullanılabilir.

Derin öğrenme yöntemlerinin her birisinin farklı çalışma prensipleri vardır. İncelenmiş makaleler içerisinde daha çok tercih edilen ağ Konvolüsyonel Sinir Ağları (Convolutional Neural Network) olmuştur. Kullanılan derin öğrenme yöntemleri ve sonuçlar karşılaştırmalı olarak Tablo 8'de incelenmiştir.

7.1 Derin sinir ağları (Deep neural networks)

DNN ağları [61],[62] birden fazla gizli katmanı olan sinir ağlarıdır. Giriş katmanından itibaren daha derin katmanlara indikçe girdinin karışık özellikleri öğrenilebilmektedir. Makale

[63], 3 gizli katmanlı DNN ağı ile DT (Decision Tree) ve GMM (Gaussian Mixture Model) yöntemlerini karşılaştırmıştır. DNN hız ve enerji tüketimi açısından GMM yönteminden daha iyi sonuç üretmiştir. Karışık aktivitelerde %60'a yakın doğruluk elde edilmiş ve DT yönteminden %10 daha iyidir. Bir diğer bulunan sonuç ise sınıflandırılan aktivite sayısının sonuca önemli etkisinin olmamasıdır.

7.2 Konvolüsyonel sinir ağları (Convolutional neural networks)

CNN, özellikle görüntü tanıma alanında çok kullanılan derin öğrenme yöntemidir. Yann Lecun et al [64] tarafından ortaya atılan yöntemde birçok filtre ile görüntü üzerinde farklı desenler aranır. CNN eğitim yapmak için Backpropagation algoritması kullanır ve VGP mevcuttur. Bu problemi aşmak için RELU aktivasyon fonksiyonu kullanılmaktadır. Konvolüsyon katmanında görüntü üzerinde bulunan desenler çok fazla boyutlu olacağından daha sonra ortaklama katmanından (pooling layer) geçirilerek boyut küçültülür. CNN ağında birkaç ardışık konvolüsyon ve ortaklama katmanı olabilir. Ağın sonunda ise sınıflandırma yapmak için tam bağlantılı katman (fully connected layer) bulunmaktadır.

Makale [65]'in değerlendirmesinde CNN kullanmanın diğer derin öğrenme yöntemlerinden farklı iki avantajını belirtmiştir: yerel bağıllık (local dependency) ve ölçekleme değişmezliği (scale invariance). Yerel bağıllık resimdeki bir pikselin yanındaki piksellerle ilişkisi olduğu gibi aktivitenin belirli zamandaki sensör verisinin bir önceki ve/veya sonraki verilerle ilişkisinin olduğunu söyler. Ölçekleme değişmezliği ise

eğitim için kullanılan her resmin boyutlarının farklı olduğu gibi her kişinin, örneğin, yürüme aktivitesinin farklı şekilde ve hızda olabileceğidir. CNN derin öğrenme yöntemi bu iki faktörü yakalayabildiğinden aktivite tanıma alanında kullanıma çok uygun olduğu belirtilmiştir [65].

Makale [66] CNN katmanlarını artırmanın performansı olumlu yönde etkilediğini ve özelliklerin karmaşıklığını (complexity of features) azalttığını belirtmiştir. Dahası, performansı artırmak için özellik sayısını artırmak yerine bir katmandan diğer katmana geçen bilgilerin korunmasının daha önemli olduğu yazılmıştır.

Makale [67] özellik çıkartmak için farklı bir yaklaşım önermiştir. Sensör verileri alt alta koyularak sinyal resmi oluşturulmuştur ve Discrete Fourier Transform kullanılarak aktivite resmine çevrilmiştir. Daha sonra ise CNN ağı bu resimden özellikler çıkartmaktadır. Ağın sonuna SVM sınıflandırıcı katmanı eklenerek bu özelliklerle ilgili aktivite sınıflandırılmıştır. Bu yaklaşıma benzer bir yapı makale [68] tarafından uygulanmaktadır. Ham sensör verileri resme çevrildikten (spectogram) sonra özellikler çıkartılır. Makale [69] CNN ile her sensör için yerel bağımlılıkları bularak daha sonra bunları global özellik hiyerarşisine çevirmektedir. Makale [70]'te bulunan sonuca göre özellik sayısını artırmının performansa çok etkisi olmadığı belirtilmiştir.

Katman sayısını artırınca da 3 ve 4 katmanlı ağ arasında fark çok azdır. Makale [71]'de ise katman sayısını artırmının performansa faydasının olduğu ancak eğitim süresini de uzattığı yazılmaktadır.

Tablo 8: Yeni nesil yöntemler ve sonuçlar.

Makale	Sensörler	Derin Öğrenme Yöntemi	Kullanılan veri Setleri	Sonuçlar
[65]	İvmeölçer	CNN	Skoda, Opportunity, Actitracker	Doğruluk: %88.19 (Skoda), %76.83 (Opportunity), %96.88 (Actitracker)
[73]	İvmeölçer, jiroskop	MM-RBM, MM-DNN	UCI (Heterogeneity)	Doğruluk: MM-RBM %81, RBM %66, C4.5 %65, SVM %70, RF %75
[63]	İvmeölçer	DNN	ADL	
[78]	(Giyilebilir cihaz)	CNN, DNN, LSTM	Opprotunity, Pamap2, Daphnet Freezing Of Gait	Genel olarak RNN daha iyi
[79]	İvmeölçer	LSTM	WISDM	Doğruluk: %92.1
[66]	İvmeölçer, jiroskop	CNN	UCI (Human Activity Recognition Using Smartphones)	Doğruluk: ~%90
[67]	İvmeölçer, jiroskop (akıllı telefon, giyilebilir cihaz)	DCNN	UCI, USC, SHO	Doğruluk: UCI için %97.59, USC için %97.83, SHO için %99.93
[80]	İvmeölçer	CNN		Doğruluk: %93.8
[76]	M/D	DL-HMM, DBN	WISDM, Daphnet, Skoda	Doğruluk: WISDM için %98.23, Daphnet için %91.5, Skoda için %89.38
[81]	(Vücuda takılı sensörler)	DCNN	Opportunity, Hand Gesture	Doğruluk: Opportunity için en iyi %87.7, Hand Gesture için en iyi %96.0
[68]	İvmeölçer, jiroskop	CNN	ActiveMiles, WISDM, Daphnet, Skoda	Doğruluk: ActiveMiles için %95.1, WISDM için %98.2, Skoda için %95.9
[74]	(Giyilebilir cihaz)	RBM, MCMC		Belirlilik: Daphnet için %97.7
[69]	M/D	CNN, RNN		Doğruluk: El hareketi tanıma için %70-75, Seyahat ve Aktivite tanıma için %90-95, Bina İçi/ Bina Dışı algılama için %90-95
[70]	İvmeölçer, jiroskop	DCNN		Doğruluk: %90-95. Enerji: 200-250 mJ. Gecikme: 35-40 ms
[71]	İvmeölçer, jiroskop, mıknatıs ölçer (giyilebilir cihaz)	CNN, LSTM	Skoda, Opportunity	Doğruluk: %94-95
				F1 skor: Opportunity için aktivitelerde 0.93, el hareketi algılamada 0.866. Skoda için 0.958

7.3 Kısıtlı boltzmann makinesi (Restricted boltzmann machine)

RBM, Geoff Hinton tarafından bulunan [72] ve oto kodlayıcı (auto encoder) ailesine giren derin öğrenme yöntemidir. İki katmandan oluşan ağ, girdiyi alıp çıktı üretmeye çalışır ve daha sonra çıktığı alıp tekrar aynı girdiyi üretmeye çalışır. Bu şekilde veriyi tekrardan oluşturmaya çalışarak veriye ait önemli desenleri bulmaktadır.

RBM, makale [73] tarafından birkaç sensör verisinin birleşiminden özellikler çıkartılarak aktivite tanıma kullanılmıştır. Her sensör için farklı derinliklerde (katman) ağ kullanarak önce sensöre özel veriler üzerinde eğitim yapılır, daha sonra bunlar birleştirilerek eğitim gerçekleştirilir. İvmeölçer ve jiroskop sensörünün her biri için 2 gizli katmanlı ağ yapısı oluşturulmuş ve sonra tek gizli katman ile birleştirilmiştir. Makalede bulunan sonuçlardan birisi de *Multi Modal RBM* yönteminin giyilebilir cihazlarda kullanılmaya uygun olmasıdır.

Giyilebilir cihazlarda RBM ile aktivite tanıma ve seyahat türü tanıma yapan makale [74], sınıflandırma katmanı olarak MCMC (Markov Chain Monte Carlo) kullanmıştır. Giriş katmanında ön işlemeden geçen sensör verileri RBM ağına girdi olarak verilir ve özellikler çıkartılır. Daha sonra bu özellikler MCMC ağına kullanılarak sınıflandırma yapılır. Bulunan sonuçlara göre RBM ağına ne kadar fazla katman olursa, çalışma(test) süresi de o kadar uzun olmaktadır. 3 katmanlı RBM ağı 0.94 ms zamanda sonuçlanırken 25 katmanlı ağ 10.36 ms zamanda sonuçlanır. Bu makalede gösterilen 3 katmanlı RBM ağı ile seyahat türü, aktivite, el hareketi tanıma ve bina içi/bina dışı algılamaya yapmak 5 ms sürmektedir.

7.4 Derin inanç ağı (Deep belief network)

DBN, Geoff Hinton vd. [75] tarafından bulunmuştur ve oto kodlayıcı ailesine ait katman bazında (layer-wise) çalışan derin ağıdır. İkişer katmanlı eğitim yaparak her iki katmanı RBM ile eğitir ve sonraki iki katmana geçer. Bir önceki katmanın çıktısı sonraki katmana girdi olarak verilmektedir. Bu ağda VGP problemi yoktur.

Makale [76] sensör verilerini resme çevirerek (spectrogram) DBN ağına girdi olarak vermiştir. Buradan elde edilen özellikler HMM (Hidden Markov Model) ağına kullanılarak aktivite sınıflandırması yapılmıştır. Bu mimari hem derin öğrenme hem de HMM bulundurduğu için melez yaklaşım olarak kabul edilebilir. Makale [76] tarafından belirtilen önemli sonuçlardan birisi de her katmandaki nöron sayısının girdi sayısından (4 kat) fazla olmasının sonucu olumlu etkilediğidir.

7.5 Tekrarlayan sinir ağları (Recurrent neural network)

RNN [77], geri beslemeli sinir ağı, zamana bağlı değişen verileri olan problemleri çözmek için kullanılan ağıdır. Önceki çıktı sonraki adımda tekrar girdi ile beraber ağı besler ve hafıza oluşturur. Birkaç ağ art arda birleştirilip daha uzun hafızalı RNN oluşturulabilir ama bu VGP problemine yol açmaktadır. VGP problemini çözmek için GRU (Gated Recurrent Unit) veya LSTM (Long Short-Term Memory) gibi kapılı ağlar kullanılır.

Makale [78] aktivite verileri arasındaki yerel bağılıkları bulmak için LSTM (vanilla versiyonu) hücreleriyle RNN tasarlamıştır. LSTM ağına VGP problemi yoktur ve yüzlerce zaman adımı boyunca bilgiyi hafızada tutabilir. *Forward LSTM* ve *Bi-Directional LSTM* olmak üzere iki farklı çeşidini kullanmışlardır. *Forward LSTM* geçmiş bağlamı kullanarak

şimdiki girdiyi yorumlarken *Bi-Directional LSTM* hem geçmiş hem de gelecek bağlamı kullanarak şimdiki girdiyi yorumlar. Ağın girdileri ezberleyip kötü genelleme yapmasını önlemek için kopma (break) eklenmiştir. Bu düzenleme (regularization) ile belirli aralıklarda RNN ağına iç vaziyeti (state) sıfırlanır ve girdilerin ezberlenmesi engellenir.

Makale [78] RNN ağların kısa ve doğal sıralı aktivitelerde CNN ağına daha iyi olduğunu göstermiştir. Ama yürüme ve koşma gibi uzun, tekrar eden aktiviteler için CNN kullanmayı önermişlerdir. *Bi-Directional LSTM* yapısında performansa en çok etki eden parametrenin katmanlardaki nöron sayısı olduğu belirtilmiştir. Makale [79], iki LSTM katmanlı ağ oluşturmuş ve girdi olarak 3 boyutlu ivmeölçer verilerini kullanmıştır. Kayan pencere tekniği ile LSTM katmanına verilen girdilerden özellikler çıkartılarak sınıflandırma katmanına girdi olarak verilmiştir. Makale [69] ise CNN ile özellikleri bulduktan sonra geçici bağılıkları (temporal dependency) bulmak için RNN kullanmaktadır. Mobil cihaz için ağ karmaşıklığını azaltmak amaçlı GRU ile RNN ağı oluşturulmuştur. Makale [71] bellek hücrelerinden oluşan LSTM ağını, zamana bağlı problemdeki geçici bağılıkları bulmak için kullanmıştır.

8 Açık noktalar ve gelecek için çalışma fırsatları

Bu derleme çalışmasında aktivite tanıma işlemini yapan makalelerin güncel durumu gösterilmiştir. Önce aktivite tanıma giriş, kullanılan sensörler, basit ve karışık aktiviteler, kullanılan genel yöntem ve daha sonra da aktivite tanıma işlemindeki adımlar detaylı tartışılmıştır. Bu alandaki mevcut durum ortaya konulmuştur ve yapılan çalışmalar birçok açıdan karşılaştırılmıştır. Yeni nesil derin öğrenme tekniklerinin klasik yöntemlere göre başarısının, pil tüketiminin, model güncelleme alternatiflerinin, veri seti boyutlarının henüz ayrıntılı ve karşılaştırmalı olarak incelenmediği tespit edilmiştir.

Bir diğer açık nokta ise karışık aktiviteleri tanıma konusudur. Çok az aktivite tanıma çalışması karışık aktiviteler üzerinde çalışmış ve elde edilen sonuçlardan sadece bir tanesi olumludur. Karışık aktiviteyle birlikte diğer potansiyel çalışma alanı ise örtüşen aktivitelerdir [12]. Örneğin telefon ile konuşurken araba sürmek, yürürken müzik dinlemek, seyahat ederken film izlemek gibi. Karışık aktivitelerle benzer diğer konu ise tek kişilik aktivite tanımak yerine sosyal, toplu aktivite tanıma yapılmasıdır [12].

Makalelerde karşılaşılan sorunlardan bir tanesi cihaz oryantasyon ve konum problemidir. Çok az makale hem cihaz oryantasyonu hem de konumundan bağımsız aktivite tanıması yapmıştır. Günlük hayatta kişiler tarafından kullanılacak uygulamaya yapmak için bu konuya daha çok önem verilmesi gerekmektedir.

Sensör kullanımıyla ilgili potansiyel çalışma konusu ise dinamik sensör seçmektir. Tüm aktiviteleri tanımak için sabit, aynı sensörleri kullanmak yerine aktiviteye göre sensörü dinamik seçerek kullanmak olumlu sonuçlar verebilecektir.

Bugüne kadar yapılan çalışmalarda günlük aktivite tanıma ve ulaşım türü tespit [82] etme problemleri ayrı ayrı ele alınmıştır. Özellikle bir kişinin gün içerisindeki hareket bütünlüğünü bozmadan takip etmek için bu iki problemin birlikte alınması gerekmektedir.

Makale [12]'de bahsedilen önemli fırsat çalışmalarından birisi aktivite tanımının yanında bir de aktivite tahmini yapmaktır.

Geçmişteki tanımlanan aktivitelere bakılarak veya başka yöntemlerle gelecekte yapılabilecek aktiviteleri tanımak ve bu sonuç doğrultusunda kullanıcıya geribildirimler, yardımlar verebilmektir. Bu konu, sağlık olmak üzere birçok alanda ilgi görebilecek potansiyele sahiptir.

Aktivite tanıma konusu için ileride yapılabilecek diğer potansiyel çalışma ise sensör verileri dışında kişinin sosyal hayattaki bilgilerini de kullanmaktır. Bunlar kişinin sosyal hesaplarında paylaştığı (gezdiği, etiketlendiği) yerler, yaptığı sosyal aktiviteler, takvimindeki planlar ve buna benzer bilgiler olabilir. Bu verileri sensör verileriyle birleştirerek özellikler karışık aktivite tanıma konusunda çalışmalar yapılabilir.

İncelenen çoğu çalışma akıllı telefon ile aktivite tanıma yapmaktadır. Karışık aktiviteleri bağlam bilgisi olmadan sadece ivmeölçer ve akıllı telefon ile tanımak zordur. Ama bağlam bilgisi olmadan bazı karışık aktiviteleri akıllı saat ile tanımak daha kolay olabilir. Örneğin su içmek, bulaşık yıkamak gibi karışık aktiviteler kola takılı akıllı saat ile daha kolay tanımlanabilir. Bu nedenle akıllı saat ile karışık aktivite tanıma konusunda çalışmalar yapılması önerilmektedir.

9 Kaynaklar

- [1] IDC. "Smartphone OS Market Share, 2016 Q3". <http://www.idc.com/promo/smartphone-market-share/os> (09.05.2017).
- [2] McDonough, Michele. "Mobile Usage Statistics: Key Facts and Findings for Publishers". <https://blog.ezoic.com/mobile-usage-statistics-key-facts-and-findings-for-publishers> (09.05.2017).
- [3] Wikipedia. "Activity recognition". https://en.wikipedia.org/wiki/Activity_recognition (09.05.2017).
- [4] Zhang S, Wei Z, Nie J, Huang L, Wang S, Li Z. "A review on human activity recognition using vision-based method". *Journal of Healthcare Engineering*, Volume 2017, <https://doi.org/10.1155/2017/3090343>, 2017.
- [5] Huang RS, Chien BC. "Activity recognition on multi-sensor data streams using distinguishing sequential patterns". *International Symposium on Artificial Intelligence (JSAI2013)*, Toyama, Japan, 4-7 June 2013.
- [6] Yan S, Liao Y, Feng X, Liu Y. "Real time activity recognition on streaming sensor data for smart environments". *Progress in Informatics and Computing (PIC)*, Shanghai, China, 23-25 December 2016.
- [7] Albert MV, Toledo S, Shapiro M, Kording K. "Using mobile phones for activity recognition in Parkinson's patients". *Frontiers in Neurology*, 3(3), 158-164 2012.
- [8] Concepción MAA, Morillo LMS, García JAA, Abril LG. "Mobile activity recognition and fall detection system for elderly people using Ameva algorithm". *Pervasive and Mobile Computing*, 34(C), 3-13, 2017.
- [9] Shoaib M, Bosch S, Incel OD, Scholten H, Havinga PJM. "a survey of online activity recognition using mobile phones". *Sensors*, 15(1), 2059-2085, 2015.
- [10] Hoseini-Tabatabaei SA, Gluhak A, Tafazolli R. "A survey on smartphone based systems for opportunistic user context recognition". *ACM Computing Surveys*, 27, 45(3), 2013.
- [11] Incel OD, Kose M, Ersoy C. "A review and taxonomy of activity recognition on mobile phones". *BioNanoScience*, 3(2), 145-171, 2013.
- [12] Lara OD, Labrador MA. "A survey on human activity recognition using wearable sensors". *IEEE Communications Surveys & Tutorials*, 15(3), 1192-1209, 2013.
- [13] Chen L, Hoey J, Nugent C, Cook D, Yu Z. "Sensor-based activity recognition". *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 42(6), 790-808, 2012.
- [14] Kharat MV, Walse KH, Dharaskar RV. "Survey on soft computing approaches for human activity recognition". *International Journal of Science and Research*, 6(2), 1328-1334, 2015.
- [15] Nick. "Did You Know How Many Different Kinds of Sensors Go Inside a Smartphone?". http://www.phonearena.com/news/Did-you-know-how-many-different-kinds-of-sensors-go-inside-a-smartphone_id57885 (08.05.2017).
- [16] Anuva. "A Resource Guide To Wearable Device Sensors". <http://anuva.com/blog/a-resource-guide-to-wearable-device-sensors> (08.05.2017).
- [17] Henpraserttae A, Thiemjarus S, Marukatat S. "Accurate activity recognition using a mobile phone regardless of device orientation and location". *2011 International Conference on Body Sensor Networks*, Dallas, USA, 23-25 May 2011.
- [18] Dernbach S, Das B, Krishnan NC, Thomas BL, Cook DJ. "Simple and complex activity recognition through smart phones". *8th International Conference on Intelligent Environments*, Guanajuato, Mexico, 26-29 June 2012.
- [19] Siirtola P, Rönning J. "Recognizing human activities user-independently on smartphones based on accelerometer data". *International Journal of Interactive Multimedia and Artificial Intelligence*, 1(5), 38-45, 2012.
- [20] Ustev YE, Incel OD, Ersoy C. "User, Device and orientation independent human activity recognition on mobile phones: challenges and a proposal". *UbiComp'13 Adjunct*, Zurich, Switzerland, 08-12 September 2013.
- [21] Riboni D, Bettini C. "COSAR: hybrid reasoning for context-aware activity recognition". *Personal and Ubiquitous Computing*, 15(3), 271-289, 2011.
- [22] Martín H, Bernardos AM, Iglesias J, Casar JR. "Activity logging using lightweight classification techniques in mobile devices". *Personal and Ubiquitous Computing*, 17(4), 675-695, 2013.
- [23] Lee YS, Cho SB. "Activity recognition using hierarchical hidden markov models on a smartphone with 3d accelerometer". *International Conference on Hybrid Artificial Intelligence Systems*, Wroclaw, Poland, 23-25 May 2011.
- [24] Kwapisz JR, Weiss GM, Moore SA. "Activity recognition using cell phone accelerometers". *ACM SIGKDD Explorations Newsletter*, 12(2), 74-82, 2010.
- [25] Singla G, Cook DJ, Edgecombe MS. "Recognizing independent and joint activities among multiple residents in smart environments". *Ambient Intelligence and Humanized Computing Journal*, 1(1), 57-63, 2010.
- [26] Ni Q, Hernando ABG, de la Cruz IP. "The elderly's independent living in smart homes: a characterization of activities and sensing infrastructure survey to facilitate services development". *Sensors*, 15(5), 11312-11362, 2015.

- [27] Ballı A, Sağbaşı EA. "Akıllı saat algılayıcıları ile insan hareketlerinin sınıflandırılması". *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21(3), 980-990, 2017.
- [28] Ayu MA, Ismail SA, Matin AFA, Mantoro T. "A comparison study of classifier algorithms for mobile-phone's accelerometer based activity recognition". *Procedia Engineering*, 41, 224-229, 2012.
- [29] Zhao Z, Chen Y, Liu J, Shen Z, Liu M. "Cross-people mobile-phone based activity recognition". *IJCAI'11 Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence*, Barcelona, Spain, 16-22 July 2011.
- [30] Borazio M, Laerhoven KV. "Using time use with mobile sensor data: a road to practical mobile activity recognition?". *MUM 2013*, Luleå, Sweden, 02-05 December 2013.
- [31] Sousa PAC, Gaber MM, Krishnaswamy S, Gomes JB, Menasalvas E. "MARS: a personalised mobile activity recognition system". *14th International Conference on Mobile Data Management*, Bengaluru, India, 23-26 July 2012.
- [32] Vo QV, Hoang MT, Choi D. "Personalization in mobile activity recognition system using k-medoids clustering algorithm". *International Journal of Distributed Sensor Networks*, 9(7), 315841, 2013.
- [33] Yan Z, Subbaraju V, Chakraborty D, Misra A, Aberer K. "Energy-efficient continuous activity recognition on mobile phones: an activity-adaptive approach". *16th International Symposium on Wearable Computers*, Newcastle, UK, 18-22 June 2012.
- [34] Lee J, Kim J. "Energy-efficient real-time human activity recognition on smart mobile devices". *Mobile Information Systems*, 2016, 1-12, 2016.
- [35] Acharjee D, Mukherjee A, Mandal JK, Mukherjee N. "Activity recognition system using inbuilt sensors of smart mobile phone and minimizing feature vectors". *Microsystem Technologies*, 22(11), 2715-2722, 2016.
- [36] Abdallah ZA, Gaber MM, Srinivasan B, Krishnaswamy S. "Adaptive mobile activity recognition system with evolving data streams". *Neurocomputing*, 150(PA), 304-317, 2015.
- [37] Anguita D, Ghio A, Oneto L, Parra X, Reyes-Ortiz JL. "Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine". *International Workshop on Ambient Assisted Living*, Vitoria-Gasteiz, Spain, 3-5 December 2012.
- [38] Szttyler T, Stuckenschmidt H, Petrich W. "Position-aware activity recognition with wearable devices". *Pervasive and Mobile Computing*, 38(2), 281-295, 2017.
- [39] Peng JX, Ferguson S, Rafferty K, Kelly PD. "An efficient feature selection method for mobile devices with application to activity recognition". *Neurocomputing*, 74(17), 3543-3552, 2011.
- [40] Hsu HH, Chu CT, Zhou Y, Cheng Z. "Two-phase activity recognition with smartphone sensors". *Network-Based Information Systems*, Taipei, Taiwan, 2-4 September 2015.
- [41] Ignatov AD, Strijov VV. "Human activity recognition using quasiperiodic time series collected from a single tri-axial accelerometer". *Multimedia Tools and Applications*, 75(12), 7257-7270, 2016.
- [42] Banos O, Galvez JM, Damas M, Pomares H, Rojas I. "Window size impact in human activity recognition". *Sensors*, 14(4), 6474-6499, 2014.
- [43] Laguna JO, Olaya AG, Borrajo D. "A dynamic sliding window approach for activity recognition". *International Conference on User Modeling, Adaptation, and Personalization*, Girona, Spain, 11-15 July 2011.
- [44] Baratloo A, Hosseini M, Negida A, El Ashal G. "Part 1: simple definition and calculation of accuracy, sensitivity and specificity". *Emergency*, 3(2), 48-49, 2015.
- [45] WISDM Lab. "WISDM: Wireless Sensor Data Mining". <http://www.cis.fordham.edu/wisdm/dataset.php#actitracker> (20.08.2017).
- [46] Fordham CIS-WISDM. "Actitracker". <https://play.google.com/store/apps/details?id=edu.fordham.cis.wisdm.actitracker.client> (31.08.2017).
- [47] Lockhart JW, Weiss GM, Xue JC, Gallagher ST, Grosner AB, Pulickal TT. "Design considerations for the WISDM smart phone-based sensor mining architecture". *SensorKDD '11 5th International Workshop on Knowledge Discovery from Sensor Data*, San Diego, USA, 21 August 2011.
- [48] WISDM Lab. "WISDM: Wireless Sensor Data Mining". <http://www.cis.fordham.edu/wisdm/dataset.php#activityprediction> (20.08.2017).
- [49] Walse KH, Dharaskar RV, Thakare VM. "A study of human activity recognition using AdaBoost classifiers on WISDM dataset". *The Institute of Integrative Omics and Applied Biotechnology Journal*, 7(2), 68-76, 2016.
- [50] ETH Zurich Electronics Laboratory. "Activity Recognition Datasets". <http://www.ife.ee.ethz.ch/research/activity-recognition-datasets.html> (20.08.2017).
- [51] Melle F. "Human Activity Recognition with Mobile Sensors". <https://github.com/Fmelle/Human-activity-recognition> (20.08.2017).
- [52] Human-Computer Intelligent Interaction Lab. "A Brief Introduction of SCUT-NAA". <http://www.hcii-lab.net/data/SCUTNAA/EN/naa.html> (20.08.2017).
- [53] Xue Y, Jin L. "A naturalistic 3D acceleration-based activity dataset & benchmark evaluations". *Systems Man and Cybernetics*, Istanbul, Turkey, 10-13 October 2010.
- [54] UCI. "Heterogeneity Activity Recognition Data Set". <https://archive.ics.uci.edu/ml/datasets/Heterogeneity+Activity+Recognition> (20.08.2017).
- [55] UCI. "Human Activity Recognition Using Smartphones Data Set". <https://archive.ics.uci.edu/ml/datasets/Human+Activity+Recognition+Using+Smartphones> (20.08.2017).
- [56] UCI. "OPPORTUNITY Activity Recognition Data Set". <https://archive.ics.uci.edu/ml/datasets/opportunity+activity+recognition> (20.08.2017).
- [57] UCI. "Smartphone Dataset for Human Activity Recognition (HAR) in Ambient Assisted Living (AAL) Data Set". [https://archive.ics.uci.edu/ml/datasets/Smartphone+Dataset+for+Human+Activity+Recognition+\(HAR\)+in+Ambient+Assisted+Living+\(AAL\)](https://archive.ics.uci.edu/ml/datasets/Smartphone+Dataset+for+Human+Activity+Recognition+(HAR)+in+Ambient+Assisted+Living+(AAL)) (20.08.2017).
- [58] UCI. "Smartphone-Based Recognition of Human Activities and Postural Transitions Data Set". <https://archive.ics.uci.edu/ml/datasets/Smartphone-Based+Recognition+of+Human+Activities+and+Postural+Transitions> (20.08.2017).
- [59] Universiteit Twente. "Pervasive Systems Research Data Sets". <http://ps.cs.utwente.nl/Datasets.php> (20.08.2017).
- [60] EveryWare Lab. "Pal-SPOT Project". <http://everywarelab.di.unimi.it/palspot> (20.08.2017).
- [61] Liu W, Wang Z, Liu X, Zeng N, Liu Y, E. Alsaadi F. "A survey of deep neural network architectures and their applications". *Neurocomputing*, 234, 11-26, 2017.

- [62] Schmidhuber J. "Deep learning in neural networks: an overview". *Neural Networks*, 61, 85-117, 2015.
- [63] Lane ND, Georgiev P. "Can deep learning revolutionize mobile sensing?". *HotMobile '15 Proceedings of the 16th International Workshop on Mobile Computing Systems and Applications*, New Mexico, USA, 12-13 February 2015.
- [64] LeCun Y, Bottou L, Bengio Y, Haffner P. "Gradient-based learning applied to document recognition". *Proceedings of the IEEE*, 86(11), 2278-2324, 1998.
- [65] Zeng M, Nguyen LT, Yu B, Mengshoel OJ, Zhu J, Wu P, Zhang J. "Convolutional neural networks for human activity recognition using mobile sensors". *Mobile Computing, Applications and Services*, Austin, USA, 6-7 November 2014.
- [66] Ronao CA, Cho SB. "Evaluation of deep convolutional neural network architectures for human activity recognition with smartphone sensors". *Proceedings of the Korean Information Science Society*, 2015, 858-860, 2015.
- [67] Jiang W, Yin Z. "Human activity recognition using wearable sensors by deep convolutional neural networks". *MM '15 Proceedings of the 23rd ACM international conference on Multimedia*, Brisbane, Australia, 26-30 October 2015.
- [68] Ravi D, Wong C, Lo B, Yang GZ. "Deep learning for human activity recognition: a resource efficient implementation on low-power devices". *Wearable and Implantable Body Sensor Networks*, San Francisco, USA, 14-17 June 2016.
- [69] Yao S, Hu S, Zhao Y, Zhang A, Abdelzaher T. "DeepSense: a unified deep learning framework for time-series mobile sensing data processing". *WWW2017*, Perth, Australia, 3-7 April 2017.
- [70] Ronao CA, Cho SB. "Human activity recognition with smartphone sensors using deep learning neural networks". *Expert Systems with Applications: An International Journal*, 59(C), 235-244, 2016.
- [71] Ordóñez FJ, Roggen D. "Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition". *Sensors*, 16(1), 115, 2016.
- [72] Hinton GE, Salakhutdinov RR. "Reducing the dimensionality of data with neural networks". *Science*, 313(5786), 504-507, 2006.
- [73] Radu V, Lane ND, Bhattacharya S, Mascolo C, Marina MK, Kawsar F. "Towards multimodal deep learning for activity recognition on mobile devices". *UbiComp '16 Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct*, Heidelberg, Germany, 12-16 September 2016.
- [74] Lane ND, Bhattacharya S. "From smart to deep: robust activity recognition on smartwatches using deep learning". *The Second IEEE International Workshop on Sensing Systems and Applications Using Wrist Worn Smart Devices*, Sydney, Australia, 14-18 March 2016.
- [75] Hinton G, Osindero S, Teh YW. "A fast learning algorithm for deep belief nets". *Neural Computation*, 18(7), 1527-1554, 2006.
- [76] Abu Alsheikh M, Selim A, Niyato D, Doyle L, Lin S, Tan HP. "Deep activity recognition models with triaxial accelerometers". *The Workshops of the Thirtieth AAAI Conference on Artificial Intelligence*, Arizona, USA, 12-17 February 2016.
- [77] Lipton ZC, Berkowitz J, Elkan C. "A critical review of recurrent neural networks for sequence learning". *arXiv preprint arXiv:1506.00019*, 2015.
- [78] Hammerla NY, Halloran S, Plötz T. "Deep, convolutional, and recurrent models for human activity recognition using wearables". *IJCAI'16 Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence*, New York, USA, 09-15 July 2016.
- [79] Chen Y, Zhong K, Zhang J, Zhao X. "LSTM networks for mobile human activity recognition". *2016 International Conference on Artificial Intelligence: Technologies and Applications*, Bangkok, Thailand, 24-25 January 2016.
- [80] Chen Y, Xue Y. "A deep learning approach to human activity recognition based on single accelerometer". *Systems, Man, and Cybernetics*, Kowloon, China, 9-12 October 2015.
- [81] Yang JB, Nguyen MN, San PP, Li XL, Krishnaswamy S. "Deep convolutional neural networks on multichannel time series for human activity recognition". *IJCAI'15 Proceedings of the 24th International Conference on Artificial Intelligence*, Buenos Aires, Argentina, 25-31 July 2015.
- [82] Sağbaş EA, Ballı S. "Transportation mode detection by using smartphone sensors and machine learning". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 22(5), 376-383, 2016.
- [83] Casilari E, Luque R, Morón MJ. "Analysis of android device-based solutions for fall detection". *Sensors*, 15(8), 17827-17894, 2015.
- [84] Shoaib M, Bosch S, Incel OD, Scholten H, Havinga PJM. "Complex human activity recognition using smartphone and wrist-worn motion sensors". *Sensors*, 16(4), 426, 2016.
- [85] Salpietro R, Bedogni L, Felice MD, Bononi L. "Park here! a smart parking system based on smartphones' embedded sensors and short range Communication Technologies". *2015 IEEE 2nd World Forum on Internet of Things (WF-IoT)*, Milan, Italy, 14-16 December 2015.
- [86] Nef T, Urwyler P, Büchler M, Tarnanas I, Stucki R, Cazzoli D, Müri R, Mosimann U. "Evaluation of three state-of-the-art classifiers for recognition of activities of daily living from smart home ambient data". *Sensors*, 15(5), 11725-11740, 2015.
- [87] Su X, Tong H, Ji P. "Activity recognition with smartphone sensors". *Tsinghua Science and Technology*, 19(3), 235-249, 2014.