



Recognition of Human Activities Using Machine Learning Methods on Smart Sensor Data

Serdar Asarkaya^{1,a}, Emre Ünsal^{2,b*}

¹ Defence Technology Programme, Institute of Graduate Studies, Sivas University of Science and Technology, Sivas, Türkiye.

²Department of Software Engineering, Faculty of Technology, Sivas Cumhuriyet University, Sivas, Türkiye.

*Corresponding author

Research Article

History

Received: 28/04/2022

Accepted: 24/05/2022

ABSTRACT

As a result of the developments in smart sensor technologies and the decrease in price of wearable devices, internet-based studies for the recognition of daily human activities by using sensor data obtained from these devices is an important research topic today. The recognition of human activities can contribute to the solution of activity-related problems in areas such as health, patient follow-up and safety. This study aims to recognize human activities using machine learning methods on data obtained from smart sensors. In this study, models were created with Decision Tree, OneVsOne and Multilayer Perceptron classifiers, and training and testing stages were carried out with the data set containing the activities. When 75% and 90% of the data set were separated as training data, the results obtained in the applications were compared and it was seen that the best result was achieved with 90% training data using the Multi-Layer Perceptron model. With the Multilayer Perceptron Model, 100% classification success was achieved in walking, walking downstairs and laying activities, 95% in standing activity, 89% in walking upstairs activity and 83% in sitting activity.

Keywords:

Keywords: Internet of Things, Smart Sensors, Machine Learning, Artificial Intelligence

Akıllı Sensör Verileri Üzerinde Makine Öğrenmesi Yöntemleri Kullanılarak İnsan Aktivitelerinin Tanımlanması

Süreç

Geliş: 28/04/2022

Kabul: 24/05/2022

Öz

Akıllı sensör teknolojilerindeki gelişmeler ve giyilebilir cihazların maliyetlerinin düşmesi sonucunda bu cihazlardan elde edilen sensör verileri kullanarak günlük insan aktivitelerinin tanımlanmasına yönelik nesnelere interneti tabanlı çalışmalar günümüzde önemli bir araştırma konusudur. İnsan aktivitelerinin tanımlanması sağlık, hasta takibi ve güvenlik gibi alanlarda aktiviteye bağlı sorunların çözümüne katkı sağlayabilmektedir. Bu çalışma, akıllı sensörlerden elde edilen veriler üzerinde makine öğrenmesi yöntemlerini kullanarak insan aktivitelerinin tanımlanmasını amaçlamaktadır. Çalışmada Karar Ağacı, OneVsOne ve Çok Katmanlı Algılayıcı sınıflandırıcıları ile modeller oluşturulmuş ve aktiviteleri içeren veri seti ile eğitim ve test aşamaları gerçekleştirilmiştir. Veri setinin %75'i ve %90'ı eğitim verisi olarak ayrıldığında yapılan uygulamalarda elde edilen sonuçlar karşılaştırılmış ve en iyi sonuç Çok Katmanlı Algılayıcı modeli kullanılarak %90 eğitim verisiyle ulaşıldığı görülmüştür. Çok katmanlı algılayıcı modeliyle yürüme, inme, uzanma aktivitelerinde %100, bekleme aktivitesinde %95, tırmanma aktivitesinde %89 ve oturma aktivitesinde %83 sınıflandırma başarısı elde edilmiştir.

Anahtar Kelimeler: Nesnelere İnterneti, Akıllı Sensörler, Makine Öğrenmesi, Yapay Zeka

License



This work is licensed under Creative Commons Attribution 4.0 International License

190102028@sivas.edu.tr

<https://orcid.org/0000-0002-4790-1709>

eunsal@cumhuriyet.edu.tr

<https://orcid.org/0000-0001-6042-0742>

How to Cite: Asarkaya S, Ünsal E. (2022) Recognition of Human Activities Using Machine Learning Methods on Smart Sensor Data, Journal of Science and Technology, 1(1):9-14, 2022 .

Giriş

Günümüzde nesnelere interneti (IoT), bilgi teknolojileri alanında çok geniş ve farklı alanlarda uygulamalar geliştirilebilmesinin yolunu açmıştır. Geçmişte yapılan çalışmalar incelendiğinde sağlık (Kaur, Kumar, & Kumar, 2019), çevre (Ma, ve diğerleri, 2020), güvenlik (Sakacı, 2018), akıllı şehirler (Abaklıoğlu, 2019) gibi birçok alanda IoT uygulamalarının yer aldığı görülmektedir.

IoT teknolojileri akıllı ortamlar yaratarak dünyamızı etkilemeye devam ederken, gücünü sensörlerden aldığı söylenebilir. (Sehrawat & Gill, 2019). Akıllı ve duyuşal sistemlerin geliştirilmesinde rol alan sensörlerle ve mobil cihazlarla büyük miktarlarda IoT verileri elde edilebilmektedir (Mourtzis, Vlachou, & Milas, 2016)

Mobil veya giyilebilir cihazlarda bulunan sensörlerin sağladığı verilerle, insan aktivitelerini tanıyan sistemler, yaşlı bakım desteği, fitness izleme ve bilişsel yardım gibi sağlık uygulamaları genişletilebilmektedir (Choudhury, ve diğerleri, 2008). İnsan motor aktivitelerinin izlenmesi, hastalık takibi, klinik teşhise yardımcı sistemler geliştirilirken ivmeölçer, jiroskop gibi mobil sistemler üzerinde bulunan sensörlerden yararlanılabilmektedir (Muscolo, Conforto, Schmid, Caselli, & D'Alessio, 2007). (Su & Ji, 2014)' e göre sensörler günlük yaşamın çeşitli yönlerini ölçmek için zengin bir veri kaynağı olduğundan, insan aktivitelerini tanıma işleminin bu uygulamaların arkasındaki temel yapı taşlarından biri olduğu söylenebilir.

Bir başka çalışmada (Ferrari, Micucci, Mobilio, & Napoletano, 2021), son yıllarda aktivite tanıma yönelik araştırmaların artmasının en önemli nedenlerinin, hareket algılayan sensörlerle donatılmış mobil cihazların yaygınlaşması ve daha düşük donanım maliyetleri olduğu belirtilerek, akıllı telefonların kullanılmasının gözetim, sağlık ve iletim gibi çeşitli uygulama bağlamlarında fırsatlar yarattığı vurgulanmıştır.

Bu çalışmada, makine öğrenmesi yöntemleri kullanarak akıllı telefon sensör verileri ile aktivite tanınması araştırılmıştır. Çalışmada iki farklı makine öğrenmesi sınıflandırma algoritması ve bir yapay sinir ağı modeli kullanılmıştır. Çalışmanın 2.bölümünde materyal ve metod, 3.bölümde ise bulgular ve tartışmaya yer verilmiştir.

Materyal ve Metod

Veri Seti

Çalışmada UCI Machine Learning Repository sayfasından indirilen Human Activity Recognition veri seti kullanılmıştır (Ortiz, Anguita, Ghio, Oneto, & Parra, 2012). Veri seti içerisinde yürüme, tırmanma, inme, oturma, bekleme ve uzanma aktivitelerine ait 7352 adet kayıt bulunmaktadır. Her bir aktivite bir sınıf olarak etiketlenmiştir. Sensör verileri belirli zaman dilimlerinde 50 Hz'lik sabit hızda yakalanmıştır. Verilerde gürültü gidermek amacıyla medyan filtre ve köşe frekansı 20 Hz olan 3.dereceden düşük geçişli Butterworth filtresi kullanılmıştır. Jiroskop ve ivmeölçer sensörlerinden gelen üç açılı sinyaller Tablo 1'de gösterilen fonksiyonlarla özelliklere dönüştürülmüştür. Sinyallerin ortalaması hesaplanarak elde edilen ek vektörler özelliklere eklenmiştir.

Tablo 1. Özellik çıkarmada kullanılan fonksiyonlar

Table 1. Functions used in feature extraction

Mean	Std	Mad	Max
Min	Sma	Energy	Iqr
Entropy	arCoeff	Correlation	maxInds
meanFreq	Skewness	Kurtosis	bandsEnergy
Angle			

Dosya.xlsx formatındadır ve sensör verilerinden oluşturulmuş, özellik olarak kullanılacak 561 sütun bulunmaktadır.

Veri Ön İşleme

Veri seti içinde eksik değer bulunmamaktadır. Sınıflar 'Yürüme-1', 'Tırmanma-2', 'İnme-3', 'Oturma-4', 'Bekleme-5', 'Uzanma-6' olmak üzere etiketlenmiştir. Veri seti içinde özellik değerleri nümeriktir. Uygulamalar yapılırken özellik değerlerini [0,1] aralığına ölçeklendirmek için sklearn kütüphanesinde bulunan MinMaxScaler yönteminden yararlanılmıştır (sklearn, 2021). Ölçeklendirmenin amacı daha doğru sonuçları daha hızlı bir şekilde elde edebilmektir. Sonraki aşamada özellik seçim işlemi gerçekleştirilmiş ve özelliklerden sınıflandırma işleminde ağırlık değeri yüksek olanlar seçilmiştir. Özellik seçiminde eşik değeri 0,001 değeri seçilmiş ve bu değeri aşmayan özellikler eğitim ve test süreçlerinde kullanılmamıştır.

Sınıflandırma

Bu bölümde yapılan uygulamalarda kullanılan OneVsOne, Karar Ağacı ve Çok Katmanlı Algılayıcı sınıflandırıcıları ile ilgili bilgiler verilmiştir.


OneVsOne Sınıflandırıcı

Sınıf çifti başına bir sınıflandırıcı oluşturarak, tahmin zamanında en çok oyu alan sınıfı seçerek ikili sınıflandırıcılar tarafından hesaplanan ikili sınıflandırma güven düzeylerini toplama yoluyla en yüksek toplam sınıflandırma güvenine sahip sınıfı seçen bir algoritma olduğu söylenebilir (scikit-learn, 2020). Algoritmanın ikili sınıflandırıcıların çoklu sınıflandırıcılar olarak çalışmasını sağlayan bir yöntem olduğu belirtilmektedir (Verma, 2022). OneVsOne sınıflandırıcısının ikili sınıflandırma yapısı Şekil 1'de gösterilmiştir.


OneVsOne Sınıflandırıcısında karşılaşılan problemin, ikili sınıflandırıcıların optimal olmasına rağmen, elde edilen kombinasyonun global olarak optimum olmasının gerekmediği öne sürülmüştür (Galar, Barrenechea, Fernandez, & Herrera, 2014).

Karar Ağacı


Ağaç tabanlı algoritmaların hem sınıflandırma hem de regresyon için ilgili parametrik olmayan ve denetimli yöntemlerin öne çıkan bir üyesi olduğu söylenebilir (Kurama, 2020). Bir karar ağacının, kök düğümden başlayan herhangi bir yolun, yaprak düğümde bir boolean sonuç elde edilene kadar bir veri ayırma dizisi ile tanımlandığı ağaç tabanlı bir teknik olduğu belirtilmiştir (Jijo & Abdulazeez, 2021). Verilerin kök düğümden başlayarak yaprak düğümlerde ayrıştırılma süreci Şekil 2'de gösterilmiştir.




Şekil 1 OneVsOne sınıflandırıcı
Figure 1. OneVsOne classifier




Şekil 2 Karar Ağacı
Figure 2. Decision Tree




Şekil 3 Çok Katmanlı Algılayıcı
Figure 3. Multi-layer Perceptron



Şekil 4 OneVsOne sınıflandırıcı çapraz doğrulama sonuçları
Figure 4. OneVsOne classifier cross validation results



Şekil 5 Karar Ağacı sınıflandırıcı çapraz doğrulama sonuçları
Figure 5. Decision Tree classifier cross validation results



Şekil 6 Çok katmanlı algılayıcı çapraz doğrulama sonuçları
Figure 6. Multi-layer Perceptron cross validation results

Her yaprağın, en uygun hedef değeri temsil eden bir sınıfa atanabildiği ve alternatif olarak yaprağın, hedef özelliğın belirli bir değere sahip olma olasılığın gösteren bir olasılık vektörü tutabildiği vurgulanmıştır (Rokach & Maimon, 2005).

Çok Katmanlı Algılayıcı

(Noriega, 2005)' e göre çok katmanlı algılayıcı, örüntü tanıma ve enterpolasyon dahil olmak üzere bir dizi farklı sorunun çözümü için yaygın olarak kullanılan bir yapay sinir ağı örneği olarak kabul edilebilir. Çok katmanlı yapay sinir ağlarının, derin öğrenmenin ayrılmaz bir parçası olarak temellerini oluşturduğu öne sürülmektedir (Simplilearn, 2022). Şekil 3'te üç girişten oluşan giriş katmanı, dört nörondan oluşan bir gizli katman ve bir çıkıştan oluşan örnek çok katmanlı algılayıcı modeli gösterilmiştir.

Sınıflandırma problemlerinin çözümünde kullanılabilen çok katmanlı algılayıcılar, giriş ve çıkış katmanları ile birlikte istenilen sayıda nörondan oluşan birden çok gizli katmanları da içerebilmektedirler (Chai, ve diğerleri, 2021).

Bulgular ve Tartışma

Çalışmada aktivite tanınması amacıyla OneVsOne, karar ağacı ve çok katmanlı algılayıcı sınıflandırıcıları kullanılmıştır. Çok katmanlı algılayıcı modelinde iterasyon sayısı 1000, solver parametresi 'sgd' ve aktivasyon fonksiyonu 'relu' olarak seçilmiştir. Her sınıflandırıcı modeli için iki farklı uygulama yapılmış, ilk uygulamada veri setinin %90'ı model eğitimi %10'u test verisi, ikinci uygulamada ise %75'i model eğitimi %25'i test verisi olarak ayrılmıştır. Sınıflandırıcı modellerin performanslarının izlenmesi amacıyla çapraz doğrulama yöntemi uygulanarak veri seti

10 parçaya bölünmüş ve modellerden elde edilen doğrulama sonuçları izlenmiştir.

Tablo 2 OneVsOne sınıflandırıcı test sonuçları

Table 2. OneVsOne classifier test results

%75 Eğitim %25 Test verisi %75 Train %25 Test Data							%90 Eğitim %10 Test verisi %90 Train %10 Test Data						
1	0,88	0,0	0,12	0,0	0,0	0,0	1	1,0	0,0	0,0	0,0	0,0	0,0
2	0,15	0,51	0,31	0,0	0,0	0,034	2	0,13	0,83	0,032	0,0	0,0	0,0
3	0,0	0,0	1,0	0,0	0,0	0,0	3	0,0	0,0	1,0	0,0	0,0	0,0
4	0,0	0,006	0,003	0,95	0,02	0,017	4	0,0	0,014	0,0	0,71	0,28	0,0
5	0,0	0,0	0,0	0,51	0,49	0,0	5	0,006	0,0	0,0	0,045	0,95	0,0
6	0,0	0,0	0,0	0,0	0,0	1,0	6	0,0	0,0	0,0	0,0	0,0	1,0
	1	2	3	4	5	6		1	2	3	4	5	6

Tablo 3 Karar Ağacı sınıflandırıcı test sonuçları

Table 3. Decision Tree classifier test results

%75 Eğitim %25 Test verisi %75 Train %25 Test Data							%90 Eğitim %10 Test verisi %90 Train %10 Test Data						
1	0,74	0,066	0,19	0,0	0,0	0,0	1	0,54	0,41	0,048	0,0	0,0	0,0
2	0,14	0,52	0,34	0,0	0,0	0,0	2	0,11	0,76	0,13	0,0	0,0	0,0
3	0,05	0,05	0,9	0,0	0,0	0,0	3	0,069	0,2	0,74	0,0	0,0	0,0
4	0,003	0,003	0,0	0,85	0,14	0,0	4	0,0	0,0	0,0	0,66	0,34	0,0
5	0,003	0,0	0,0	0,71	0,28	0,0	5	0,007	0,0	0,0	0,35	0,64	0,0
6	0,0	0,0	0,0	0,0	0,0	1,0	6	0,0	0,0	0,0	0,0	0,0	1,0
	1	2	3	4	5	6		1	2	3	4	5	6

Tablo 4 Çok katmanlı algılayıcı sınıflandırıcı test sonuçları

Table 4. Multi-layer perceptron classifier test results

%75 Eğitim %25 Test verisi %75 Train %25 Test Data							%90 Eğitim %10 Test verisi %90 Train %10 Test Data						
1	0,9	0,0	0,097	0,0	0,0	0,0	1	1,0	0,0	0,0	0,0	0,0	0,0
2	0,03	0,83	0,14	0,0	0,0	0,0	2	0,11	0,89	0,0	0,0	0,0	0,0
3	0,0	0,0	1,0	0,0	0,0	0,0	3	0,0	0,0	1,0	0,0	0,0	0,0
4	0,0	0,006	0,0	0,98	0,0	0,01	4	0,0	0,0	0,0	0,83	0,17	0,0
5	0,0	0,0	0,0	0,79	0,21	0,0	5	0,0	0,0	0,0	0,046	0,95	0,0
6	0,0	0,0	0,0	0,0	0,0	1,0	6	0,0	0,0	0,0	0,0	0,0	1,0
	1	2	3	4	5	6		1	2	3	4	5	6

Şekil 4'e göre OneVsOne sınıflandırıcısı ile yapılan uygulamada çapraz doğrulama ile en yüksek doğruluk oranı %10 test verisi ile %98,6 ile elde edilmiştir. Model eğitimi sırasında en düşük doğruluk oranı %96,8 ile %10 test verisiyle elde edilmiştir. Şekil 5'de karar ağacı sınıflandırıcısı ile elde edilen çapraz doğrulama sonuçlarına göre en yüksek doğruluk değeri %96,8 ile %25 test verisinde elde edilmiştir. Şekil 6'te çok katmanlı algılayıcı modeli ile çapraz doğrulama sonucu elde edilen doğruluk değerlerinde %10 test verisi ile en yüksek %97,4'lük doğruluk oranı ile görülmektedir.

Elde edilen doğrulama oranlarının birbirine yakın değerler olması, modeller ile elde edilen aktivite tanıma sonuçlarının tutarlı olduğunu göstermektedir.

Tablo 2' e göre en iyi sonuçların veri seti %90 eğitim %10 test olarak bölündüğünde elde edildiği görülmektedir. Bu durumda yürüme, inme ve uzanma aktivitelerinin tamamının model tarafından doğru tahmin edildiği görülmüştür. Tırmanma aktivitesinin %83'ü doğru tahmin edilirken aktivitenin %13'ü yürüme aktivitesi olarak sınıflandırılmıştır.

Tablo 3'de görüldüğü üzere karar ağacı ile oluşturulan modelde, veri setinin %75 ve %90 eğitim amaçlı bölünmesiyle ortaya çıkan sonuçlarda yalnızca uzanma

aktivitesinin tamamı doğru sınıflandırılmıştır. İki farklı uygulama yapılırken model her bir uygulamada farklı sınıflarda başarı sağlamıştır. Örneğin yapılan ilk uygulamada yürüme aktivitesini %74 doğru tahmin ederken ikinci uygulamada %54 doğruluk oranı elde edildiği görülmektedir. En düşük başarı oranının %75 eğitim verisi ile bekleme aktivitesinde elde edildiği, aktivitenin %71'inin oturma aktivitesi olarak tahmin edildiği görülmektedir. İki aktivitenin vücut pozisyonu değişmeksizin benzer şekilde hareketsizlik içermesi bu duruma neden olmuş olabilir.

Tablo 4'e göre çok katmanlı algılayıcı ile oluşturulan model, yapılan ikinci uygulamada veri setinin %90'ı ile eğitildiğinde aktivite tanımadaki daha başarılı olduğu görülmektedir. Bunun nedeninin modelin daha fazla örnekle eğitilmesi olduğu söylenebilir. Bu durumda model yürüme, inme, uzanma aktivitelerinin tamamını doğru tahmin etmiştir.

İki farklı makine öğrenmesi modeli ve bir derin öğrenme modeli ile yapılan uygulamalarda en iyi sonuçların çok katmanlı algılayıcı algoritması kullanılarak oluşturulan modelde %90 eğitim verisi ile elde edildiği görülmektedir. Yöntemlerin bir veri setiyle kullanılması çalışmanın sınırlılıklarındandır. (Anguita, Ghio, Oneto,

Parra, & Ortiz, 2012) aynı veri setini kullanarak yaptıkları aktivite tanıma yönelik çalışmada, Multi Class Support Vector Machine (MC-SVM) ve Multi Class Hardware Friendly Support Vector Machine (MC-HF-SVM) modellerini kullanarak, yalnızca uzanma aktivitesinde %100'lük başarı oranı elde ederken, en düşük başarı oranını tırmanma aktivitesinde %69,8 oranıyla elde etmişlerdir.

(Abidine & Fergani, 2021) akıllı telefon sensör verileri ile aktivite tanıma yönelik yaptıkları çalışmada yöntem önerisinde bulunmuşlar ve farklı veri setleri üzerinde test etmişlerdir. Aktivite tanıma en yüksek doğruluk oranını %99 ile uzanma aktivitesinde, en düşük doğruluk oranını %66,1 ile tırmanma aktivitesinde elde etmişlerdir.

Sonuç

Akıllı cihazların günümüzde kolay ulaşılabilir olması ve taşıdıkları sensörlerden anlık veri akışının sağlanabilmesi aktivite tanıma çalışmalarına olanak sağlamaktadır. İnsan aktivitelerinin gerçek zamanlı olarak tanımlanması, aktiviteleri takip edilmesi gereken hastaların izlenmesi, güvenlik vb. alanlarda günlük problemlerin çözümüne katkı sağlayabilecektir.

Bu çalışmada akıllı telefon sensör verilerini kullanarak 6 farklı insan aktivitesinin sınıflandırılması konusunda, makine öğrenmesi yöntemlerini kullanarak farklı eğitim ve test veri oranlarıyla uygulamalar yaptık. En iyi çapraz doğruluk oranı %97,4'ile %90'luk eğitim %10'luk test verisi kullanılarak çok katmanlı algılayıcı modeliyle elde edilmiştir. Farklı katman ve nöron sayısına sahip geliştirilebilir derin öğrenme modelleri, daha fazla veriyle eğitildiğinde daha yüksek başarı oranlarının elde edilebileceği düşünülmektedir. Gelecekte yapılacak çalışmalarda hareket algılayan sensörlerin vücuttaki pozisyonları değiştirilerek daha fazla veriyle farklı makine öğrenmesi modelleriyle araştırma çalışmaları gerçekleştirilebilir.

Kaynakça

- Abakloğlu, M. (2019). *The importance of internet (IOT) technology for smartcity and objects for the future cities*. İstanbul: Ulusal Tez Merkezi.
- Abidine, M. B., & Fergani, B. (2021). Activity Recognition From Smartphone Data Using WSVM-HMM Classification. *International Journal of E-Health and Medical Communications*, 20.
- Anguita, D., Ghio, A., Oneto, L., Parra, X., & Ortiz, J. (2012). Human Activity Recognition on Smartphones using a Multiclass Hardware-Friendly Support Vector Machine. *Ambient Assisted Living and Home Care*, 7657. doi:https://doi.org/10.1007/978-3-642-35395-6_30
- Chai, S. S., Cheah, L. W., Goh, K. L., Chang, Y. R., Sim, K. Y., & Chin, K. O. (2021). A Multilayer Perceptron Neural Network Model to Classify Hypertension in Adolescents Using Anthropometric Measurements: A Cross-Sectional Study in Sarawak. *Computational and Mathematical Methods in Medicine*, 11. doi:10.1155/2021/2794888
- Choudhury, T., Consolvo, S., Harrison, B., Hightower, J., LaMarca, A., & LeGrand, L. (2008). The Mobile Sensing Platform: An

- Embedded Activity Recognition System. *IEEE Pervasive Computing*, 32-41. doi:10.1109/MPRV.2008.39
- Ferrari, A., Micucci, D., Mobilio, M., & Napoletano, P. (2021). Trends in human activity recognition using smartphones. *Journal of Reliable Intelligent Environments*, 189-213. doi:10.1007/s40860-021-00147-0
- Galar, M., Barrenechea, E., Fernandez, A., & Herrera, F. (2014). Enhancing difficult classes in one-vs-one classifier fusion strategy using restricted equivalence functions. *FUSION 2014 - 17th International Conference on Information Fusion*. . Salamanca: ResearchGate.
- Jijo, B. T., & Abdulazeez, A. M. (2021). Classification Based on Decision Tree Algorithm for Machine Learning. *Journal of Applied Science and Technology Trends*, 20-28. doi:10.38094/jastt20165
- Kaur, P., Kumar, R., & Kumar, M. (2019). A healthcare monitoring system using random forest and internet of things (IoT). *Multimedia Tools and Applications*, 19905-19916. doi:10.1007/s11042-019-7327-8
- Kurama, V. (2020, 1 1). *A Complete Guide to Decision Trees*. 4 18, 2022 tarihinde <https://blog.paperspace.com/>: <https://blog.paperspace.com/decision-trees/> adresinden alındı
- Ma, J., Cheng, J., Ding, Y., Lin, C., Jiang, F., Wang, M., & Zhai, C. (2020). Transfer learning for long-interval consecutive missing values imputation without external features in air pollution time series. *Advanced Engineering Informatics*, 101092. doi:10.1016/j.aei.2020.101092
- Mourtzis, D., Vlachou, E., & Milas, N. (2016). Industrial Big Data as a Result of IoT Adoption in Manufacturing. *Procedia CIRP*, 290-295. doi:10.1016/j.procir.2016.07.038
- Muscillo, R., Conforto, S., Schmid, M., Caselli, P., & D'Alessio, T. (2007). Classification of Motor Activities through Derivative Dynamic Time Warping applied on Accelerometer Data. *IEEE Engineering in Medicine and Biology Society. Conference* (s. 4930-3). PubMed. doi:10.1109/IEMBS.2007.4353446
- Noriega, L. (2005, 11 17). *Multilayer Perceptron Tutorial*. 4 19, 2022 tarihinde <http://citeseerx.ist.psu.edu/>: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.608.2530&rep=rep1&type=pdf> adresinden alındı
- Ortiz, J., Anguita, D., Ghio, A., Oneto, L., & Parra, X. (2012, 10 12). *Human Activity Recognition Using Smartphones Dataset*. 4 16, 2022 tarihinde UCI Machine Learning Repository: <https://archive.ics.uci.edu/ml/datasets/human+activity+recognition+using+smartphones> adresinden alındı
- Rokach, L., & Maimon, O. (2005, 1 1). *Decision Trees*. doi:10.1007/0-387-25465-X_9
- Sakacı, B. (2018). *Askeri Personel İçin Akıllı Kıyafet Tasarımı*. İstanbul: Yıldız Teknik Üniversitesi.
- scikit-learn. (2020, 1 1). *Multiclass and multioutput algorithms*. 4 20, 2022 tarihinde [scikit-learn.org: https://scikit-learn.org/stable/modules/multiclass.html#multiclass-classification](https://scikit-learn.org/stable/modules/multiclass.html#multiclass-classification) adresinden alındı
- Sehrawat, D., & Gill, N. S. (2019). Smart Sensors: Analysis of Different Types of IoT Sensors. *3rd International Conference on Trends in Electronics and Informatics (ICOEI)* (s. 523-528). Tirunelveli, India: IEEE. doi:10.1109/ICOEI.2019.8862778
- Simplilearn. (2022, 2 21). *An Overview on Multilayer Perceptron (MLP)*. 4 20, 2022 tarihinde <https://www.simplilearn.com/>: <https://www.simplilearn.com/tutorials/deep-learning-tutorial/multilayer-perceptron> adresinden alındı
- sklearn. (2021). *sklearn.preprocessing.MinMaxScaler*. 4 22, 2022 tarihinde [scikit-learn.org: https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html](https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html) adresinden alındı

- Su, X., & Ji, P. (2014). Activity Recognition with Smartphone Sensors. *TSINGHUA SCIENCE AND TECHNOLOGY*, 235-349. doi:10.1109/TST.2014.6838194
- Verma, Y. (2022, 4 7). *One vs One, One vs Rest with SVM for multi-class classification*. 4 20, 2022 tarihinde analyticsindiamag.com: <https://analyticsindiamag.com/one-vs-one-one-vs-rest-with-svm-for-multi-class-classification/> adresinden alındı