



ULAŞIM TÜRÜ TANIMADA ENERJİ KISITLI CİHAZLAR İÇİN AYIRT EDİCİ ÖZELLİKLER

Fethiye YASLI¹, M. Amaç GÜVENSAN^{1*}

¹ Yıldız Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye

Anahtar Kelimeler

*Ulaşım türü,
Sınıflandırma,
Akıllı telefon,
Zaman alanı,
Frekans alanı,
Ayırt edici öznelikler,
Enerji verimli.*

Öz

Bireysel ulaşım şekli, trafik planlama ve insan sağlığı araştırmalarında önemli bir etkiye sahiptir. Kişilerin ulaşım alışkanlıkları analiz edilerek şehirlerde yeni hatların planlaması çok daha verimli bir şekilde yapılabilir. Bu alışkanlıkları tespit etmenin yollarından bir tanesi de kişilerin kullandıkları akıllı telefonlar veya saatler üzerinden toplanan algılayıcı verilerinin işlenerek ulaşım türü tespiti yapılmasıdır. Akıllı telefonların ve saatlerin hayatımıza girmesiyle, ulaşım türü belirleme üzerine yapılan çalışmalar artmıştır. Öte yandan, bu cihazların enerji kısıtları olması sebebiyle ulaşım türü tanıma uygulamalarının mümkün olduğunca az enerji tüketmesi istenmektedir. Bu nedenle ulaşım türü tanımda kullanılan öznelikler oldukça önemlidir. Bu çalışmada akıllı telefon üzerinde bulunan ivme ölçer, jiroskop, mıknatıs ölçer ve yön algılayıcıları kullanılarak toplanan ham veriden zaman ve frekans alanında öznelikler elde edilmiştir. Öznelikler, Zaman, Frekans, Zaman+Frekans tiplerine göre ayrılarak, farklı sınıflandırma algoritmaları üzerindeki başarıya etkileri incelenmiştir. Sınıflandırma algoritması olarak J48, Rastgele Orman (Random Forest), Destek Vektör Makineleri (SVM), En Yakın k Komşuluk (k-NN) ve Çok Katmanlı Algılayıcı algoritmaları kullanılmıştır. Yapılan testler sonucunda en başarılı algoritma %95,06 ile Rastgele Orman algoritması olurken, Zaman+Frekans alanında elde edilen özneliklerin Zaman alanındaki özneliklere göre sadece %0,5 daha iyi sonuç ürettiği görülmüştür.

DISCRIMINATIVE FEATURES FOR ENERGY-CONSTRAINED DEVICES ON TRANSPORTATION MODE DETECTION

Keywords

*Transportation type,
Classification,
Smartphone,
Time-domain,
Frequency-domain,
Discriminative features,
Energy efficient.*

Abstract

Personal transportation form has a substantial impact on traffic planning and human health. Analyzing transportation preferences/habits of people could result in planning new public routes in a more efficient manner. One of the ways to detect such habits is to process the data collected from the sensors located on smartphones and smart watches. Thus, the widespread usage of these type devices makes the way for more publication about transport mode detection. On the other hand, due to their energy-constrained architecture, mobile applications about transport mode detection should be designed taking energy consumption into consideration. Therefore, the selected features for transport mode detection are quite critical. In this study, time-domain and frequency domain features are extracted from the data collected from accelerometer, gyroscope, magnetometer and orientation sensor. The impact of time-domain features, frequency-domain features and time-frequency domain features on success rate are compared using 5 different classification algorithms including J48, Random Forest, Support Vector Machines (SVM), k Nearest Neighbor (k-NN) and Multi-Layer Perceptron. Test results show that Random Forest algorithm outperforms the rest with a success rate of 95.06%, whereas exploiting both time and frequency features increases the classification rate only by 0.5% compared to using only time-domain features.

Alıntı / Cite

Yaslı, F., Güvensan, M.A., (2019). Ulaşım Türü Tanımda Enerji Kısıtlı Cihazlar İçin Ayırt Edici Özellikler, Mühendislik Bilimleri ve Tasarım Dergisi, 7(1), 90-102.

* İlgili yazar / Corresponding author: amac@yildiz.edu.tr, +90-212-383-5765

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process	
F. Yaslı, 0000-0002-2430-4303	Başvuru Tarihi / Submission Date	31.05.2018
M. A. Güvensan, 0000-0002-2728-8900	Revizyon Tarihi / Revision Date	26.11.2018
	Kabul Tarihi / Accepted Date	04.12.2018
	Yayın Tarihi / Published Date	25.03.2019

1. Giriş

Akıllı telefonların hayatımıza girmesiyle, telefonu kullanan kişiler hakkında bilgi edinmek, mekândan bağımsız olarak, kolay bir hale gelmiştir. Akıllı telefon üzerinde bulunan algılayıcılar kullanılarak telefon kullanıcısı hakkında veri toplanabilmekte ve bu veriler işlenerek sağlık, ev, spor, ulaşım ile ilgili uygulamalar geliştirilebilmektedir.

Günümüzde seyahat eden kişilere, ulaşım araçlarını kullanan insan yoğunluğuna göre ulaşım şekli öneren sistemler üzerinde çalışılmaktadır. Ayrıca insanların sık kullandığı ulaşım türü belirlenerek, hareket etmeyi arttırıcı ulaşım türü önerisi yapan sağlık odaklı sistemlerin geliştirilmesi mümkün hale gelmiştir. İnsanların tercih ettiği seyahat türlerinin tespit edilmesi, ulaşım ağları ile ilgili planlamaları olumlu yönde etkilemekte ve etkin şehircilik çalışmaları yapılmasına olanak sağlamaktadır.

Bu çalışmada akıllı telefon yardımı ile ulaşım türü tanımda başarıyı arttıracak öznelikler incelenmiş ve başarıya etkileri ortaya konmuştur. Çalışma sırasında akıllı telefon üzerindeki ivme ölçer, jiroskop, mıknatis ölçer ve yön algılayıcıları kullanılmıştır. Algılayıcılar kullanılarak elde edilen ham veri üzerinde kayan pencere gezdirilerek zaman ve frekans alanında öznelikler çıkartılmıştır. Öznelikler Zaman, Frekans, Zaman+Frekans tiplerine göre gruplanarak, sınıflandırma algoritmaları üzerindeki başarıları karşılaştırılmıştır. Sınıflandırma algoritması olarak J48, Rastgele Orman, Destek Vektör Makineleri, En Yakın k Komşuluk ve Çok Katmanlı Algılayıcı algoritmaları kullanılmıştır.

Bu çalışmada frekans ve zaman alanındaki öznelikler birlikte değerlendirilerek sınıflandırmadaki tahmin etme başarıları karşılaştırılmıştır ve aşağıdaki katkılar sağlanmıştır:

- Ulaşım türü tanıma için zaman ve frekans alanındaki ayırt edici öznelikler belirlenmiş ve başarıya etkileri incelenmiştir.
- Ulaşım türü tanıma için en başarılı sınıflandırma algoritması tespit edilmiştir.
- Sınıflandırma işleminde birbiri ile karıştırılan ulaşım türleri ortaya konmuştur.

Çalışmanın ikinci bölümünde seyahat türü tespiti ile ilgili önceki araştırma ve uygulamalara değinilmiştir. Üçüncü bölümde ise çalışma için kullanılan ham verinin öznelikleri ve ön işleme adımları açıklanmıştır. 4. Bölümde deneysel sonuçlar sunulmuş ve değerlendirilmiştir. Son bölümde ise çalışmanın

çıktıları yorumlanmış ve gelecek çalışmalardan bahsedilmiştir.

2. Bilimsel Yazın Taraması

Ulaşım türü belirleme ile ilgili birçok kaynak bulunmaktadır. Bu kaynaklarda verinin toplanmasında ham veri, GPS, ivme ölçer, jiroskop, mıknatis ölçer, barometre gibi çeşitli algılayıcılar kullanılarak incelemeler yapılmış ve başarılı sonuçlar alınmıştır. Nikolic ve Bierlaire (2017) tarafından yapılan çalışmada akıllı telefon verilerini temel alan ulaşım türü algılama yaklaşımları gözden geçirilmektedir. Çalışmada ele alınan yaklaşımlar, kullanılan giriş verilerinin türü ve sayısı, kabul edilen ulaşım türü kategorileri ve sınıflandırma için kullanılan algoritmalar bakımından farklılık göstermektedir. Ne kadar fazla veri kullanılırsa doğruluğun da o oranda artacağı vurgulanmıştır.

Waga vd. (2012), Widhalm vd. (2012), Xiao vd. (2017), Das ve Winter (2016), Ballı ve Sağbaşı (2016) tarafından yapılan ulaşım türü tespit çalışmalarında GPS verisi kullanarak yeni öznelikler çıkartılmış ve tahmin etme gücü yüksek sonuçlar elde edilmiştir. Ancak enerji tüketimi fazla olduğu için bir çok çalışmada GPS algılayıcısı yerine ivme ölçer, jiroskop vb. az enerji tüketen algılayıcılar tercih edilmiştir. Bu çalışmalarda ham veriden öznelik çıkartılması sırasında her çalışma kendi belirlediği zaman ve/veya frekans alanındaki farklı öznelikleri tercih etmişlerdir. Ancak yaptığımız literatür araştırması sırasında bu özneliklerin başarıya etkilerinin karşılaştırılması olarak incelenmediği görülmüştür.

Bedogni vd. (2016) yaptıkları çalışmada GPS verisi yerine, ivme ölçer ve jiroskop kullanılarak sınıflandırmada benzer bir başarının elde edildiğini gözlemiştir. Veri kümesinde durma, yürüme, araba, tren, bisiklet, şehir içi otobüs, şehirler arası otobüs ulaşım türü sınıf etiketleri kullanılmıştır. Sınıflandırma algoritması olarak, Rastgele Orman, Karar Tablosu, Bayes Ağları, Rastgele Ağaç, Destek Vektör Makinesi ve Naïve Bayes algoritmaları kullanılıp karşılaştırılmıştır. En yüksek başarı Rastgele Orman yöntemiyle elde edilmiştir. Byon ve Liang (2014) tarafından yapılan çalışmada ulaşım türü tanıma için mobil telefonlarda bulunan ivme ölçer, mıknatis ölçer verileri kullanılmıştır. Ulaşım türü tahmin etme sonuçlarının, geleneksel GPS verisi kullanan sınıflandırma sonuçlarına göre daha yüksek oranda doğruluk sağladığı gözlemlenmiştir. Ham veriden zaman alanında öznelikler çıkarılmıştır. Destek Vektör Makinesi yöntemi kullanılarak yapılan sınıflandırmada %96,31 başarı elde edilmiştir. Öte

yandan, incelenen birçok çalışmada (Jahangiri ve Rakha 2015) en yüksek başarıyı Rastgele Orman yönteminin verdiği gözlemlenmiştir.

Ulaşım türü tanıma yapılan önemli sayıda çalışmada ağırlıklı olarak zaman (Sonderon 2016, Cardoso vd. 2016, Su vd. 2016) öznitelikleri kullanılmıştır. Ancak sadece frekans alanında öznitelikler kullanan ve hem zaman hem frekans alanında hesaplamalar ile elde edilen özniteliklerden (Fang vd. 2016, Zhou vd. 2016) oluşan veri kümesi kullanan çalışmalar da mevcuttur.

Bedogni vd. (2016) tarafından yapılan çalışmada ulaşım türü tanıma için ham veriden FFT (Hızlı Fourier Dönüşümü) dönüşümü ile frekans alanında öznitelikler elde edilerek kullanılmıştır. Bago ve Intille (2004) tarafından yapılan çalışmada ivme ölçer algılayıcısından elde edilen ham veri üzerinde kayan pencere %50 örtüşme ile gezdirilerek frekans alanında dc bileşeni, enerji ve bilgi değeri öznitelikleri kullanılmıştır. Bisiklet sürme ve koşma aktivite türlerinde enerji değeri benzer çıkabileceği için ayrıca bilgi değeri özelliği de hesaplanmıştır. Öznitelikler üzerinde Karar Ağacı sınıflandırma algoritması uygulanarak %80 başarı elde edilmiştir. Bu çalışma gelecekteki çalışmalar için FFT sonucu elde edilen frekans alanındaki öznitelikleri kullanmayı ve Karar Ağacı sınıflandırma algoritmasının kullanılmasını tavsiye etmiştir. Hemminki vd. (2013) tarafından yapılan çalışmada ivme ölçer algılayıcı verisi kullanılarak ulaşım türü sınıflandırması yapılmıştır ve yazarlar hem zaman hem de frekans alanında öznitelikler kullanarak kendinden önceki çalışmalara göre %20 oranında tahmin etme doğruluğunu arttırdıklarını belirtmişlerdir. Zaman alanından frekans alanına dönüşüm için Hızlı Fourier Dönüşümü kullanılmışlardır. Zaman alanında ortalama, varyans, kurtosis, korelasyon matematiksel yöntemleri kullanılarak öznitelikler çıkartılırken; frekans alanında ise enerji, ilk 6 FFT katsayısı ve FFT katsayıları toplamı kullanılarak öznitelikler çıkartılmıştır. Yan vd. (2012) tarafından yapılan çalışmada aktivite (oturma, kalkma, yürüme vs.) tanıma veri kümesinde yapılan sınıflandırmada örnekleme frekansı ve öznitelik seçiminin mobil cihazdaki enerji tüketimine etkisi zaman ve frekans alanındaki özellikler kullanılarak incelenmiştir. Fang vd. (2017) tarafından yapılan çalışmada mobil telefon üzerindeki ivme ölçer, mıknatıs ölçer ve jiroskop algılayıcıları durma, yürüme, koşma, bisiklet ve motorlu araç kullanımı esnasında elde edilen veri üzerinde derin öğrenme yöntemi kullanılarak tahmin etme yapılmıştır. Elde edilen ham veriden öznitelik çıkartılırken FFT dönüşümü yapılmış ve en yüksek FFT değeri ve en yüksek iki FFT değeri arasındaki fark öznitelik olarak belirlenen veri kümesi de kullanılmıştır. Shafique ve Hato (2016) tarafından yapılan çalışmada akıllı telefon üzerindeki algılayıcılar kullanılarak elde edilen verinin değişik frekanslarda toplanmasının etkisi incelenmiştir. Sık frekanslarda toplanan veri, çalışma süresini ve doğruluğu

arttırmaktadır fakat çalışma süresinin artması istenen bir durum olmadığından uygun frekans aralığının belirlenmesinin önemi vurgulanmıştır. Lan vd. (2016) tarafından yapılan çalışmada giyilebilir cihaz kullanımında üretilen voltaj miktarı kullanılarak elde edilen veri üzerinde ulaşım türü sınıflandırması yapılmıştır. GPS ve ivme ölçer kullanımının giyilebilir cihazlardaki batarya tüketiminin fazla olmasına sebep olduğu vurgulanmıştır. Sınıflandırmasında %85 başarı elde edilmiştir. Biebl vd. (2016) tarafından yapılan çalışmada gezi bölütleme, bulanık kural modu algılama ve tutarlılık kontrollerinden oluşan akıllı telefon verilerinden ulaşım türünün saptanması için üç adımlı bir algoritma kullanılmaktadır. Kırsal yollar için %75'lik bir başarı elde edilirken genel şehir yolları için %98'lik bir başarı elde edilmiştir.

Figo vd. (2010) tarafından yapılan çalışmada ivme ölçerden toplanan ham veri kullanılarak hem zaman alanında hem de frekans alanında veri kümesi öznitelikleri çıkartılmıştır. Zaman alanındaki veriyi frekans alanına çevirmek için Hızlı Fourier Dönüşümü (FFT) kullanılmıştır. Ayrıca bu çalışmada zaman ve frekans alanından çıkarılabilecek öznitelikler ayrıntılı bir şekilde anlatılmıştır. Bu çalışmada; zaman alanında kullanılabilecek ortalama, medyan, varyans, standart sapma ve korelasyon gibi istatistiksel özniteliklerin ve frekans alanında kullanılabilecek DC bileşeni, FFT kat sayıları toplamı, baskın frekans, enerji ve entropi gibi özniteliklerin aktivite tanımda önemli etkisi olduğu belirtilmiştir. Çalışma sonucunda; frekans alanındaki özniteliklerin, zaman alanı özniteliklerine göre aktiviteyi daha yüksek doğrulukta tahmin ettiği gözlemlenmiştir. Buna rağmen zaman alanındaki tahmin gücü yüksek özniteliklerin bir kısmının, frekans alanındaki bazı özniteliklerden daha yüksek doğrulukta aktiviteyi tahmin ettiği gözlemlenmiştir.

Ulaşım türü tanıma konusunda daha önce yapılan çalışmalar, kullanılan algılayıcı tipi, algılayıcıdan veri toplama frekansı, elde edilen ham veriden öznitelik çıkartım şekli açısından farklılıklar ve karşılaştırmalar içermektedir. Ham veriden öznitelik çıkartımı yapılırken frekans ve zaman alanında öznitelikler çıkartılmıştır. Sadece frekans alanı, zaman alanı veya hem zaman hem frekans alanı kullanılarak öznitelik çıkartma işlemi önceki çalışmalarda kullanılmıştır. Literatürde öznitelik çıkartılırken kullanılan alan tipinin başarıya etkisi için yapılan bir çalışma gözlemlenmemiştir. Bu çalışmada ham veriden öznitelik çıkartırken kullanılan alan tiplerinin (zaman, frekans, zaman+frekans) sınıflandırmaya etkisi incelenmiştir.

3. Ulaşım Türü Tanımda Öznitelik Seçimi

Bu kısımda veri kümesinin toplanma ve ön işlemden geçirilerek zaman ve frekans alanındaki öznitelik çıkarma aşamalarından bahsedilmektedir. Zaman, frekans ve hem zaman hem frekans alanında tahmin etme gücü yüksek 20 öznitelik verilmiştir.

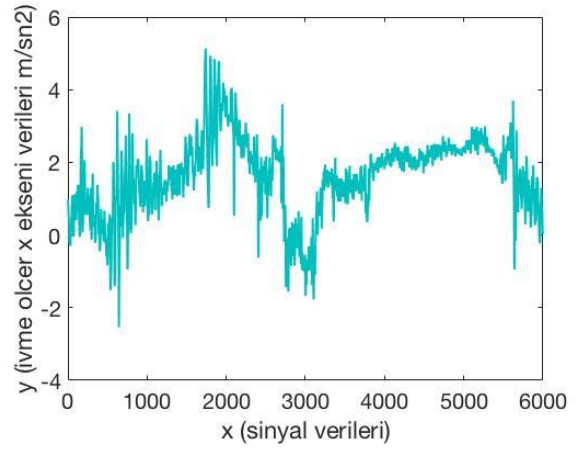
3.1. Ulaşım Türü Tanımda Zaman ve Frekans Alanlarında Kullanılan Öznitelikler

Bu çalışmada akıllı telefon kullanıcısının hangi ulaşım türünü kullandığının belirlenmesi hedeflenmiştir. Bu amaçla Android akıllı telefon üzerinde bulunan bir uygulama ile ulaşım anındaki kullanıcı verisi toplanmıştır. Uygulama akıllı telefon üzerindeki ivme ölçer, jiroskop, mıknatıs ölçer donanım algılayıcılarını kullanmaktadır. Ayrıca ivme ölçer ve mıknatıs ölçer algılayıcılarının birleştirilmesiyle akıllı telefonun yön, yalpalanma, yuvarlanma açıları da hesaplanmıştır. Uygulama, algılayıcı sinyallerini 100 Hz örnekleme frekansı ile 10 milisaniye aralıklarla toplamaktadır. Ham veride bulunan veri öznitelikleri Tablo 1'de listelenmektedir.


Şekil 1, Şekil 2, Şekil 3, Şekil 4, Şekil 5, Şekil 6, Şekil 7 ve Şekil 8'de sırasıyla Araba, Otobüs, Metrobüs, Metro_H, Metro_K, Tramvay, Minibüs, Marmaray ulaşım türleri için ivme ölçerin X eksenindeki; 1 dakika içerisinde elde edilen, 6000 sinyal değerlerini göstermektedir. Ulaşım türleri arasındaki ayrımın daha net gözükmesi sebebiyle X eksenindeki sinyal verileri kullanılmıştır.

Elde edilen ham veri üzerinden anlamlı öznitelikler çıkarabilmek için veri üzerinde kayan pencere gezdirilerek zaman ve frekans alanında yeni öznitelikler çıkarılmıştır. Guvensan vd. (2017) çalışmasında ulaşım türü belirlenmesi için pencere boyutunun 1 dakika olarak alınması tavsiye edilmektedir. Bu çalışmada da kayan pencere uzunluğu 1 dakika olacak şekilde kullanılmıştır. Bu durumda her bir kayan pencere 60 saniye uzunluğunda olmalıdır. Veri 10 milisaniye aralıklarla toplandığı için her bir kayan pencerede 6000 adet veri bulunmaktadır. Pencere başlangıcı ve bitiminde veri kaybı yaşanmaması adına, arka arkaya gelen pencereler %50 üst üste gelecek şekilde veri üzerinde kaydırılmıştır.

Her bir kayan pencerede bulunan 6000 veri için zaman alanında kullanılan hesaplama türleri ve formülleri Tablo 2'de verilirken frekans alanında kullanılan hesaplama türleri ve formülleri Tablo 3'te verilmiştir. İlgili tablolarda verilen sembollerden N; bir kayan penceredeki eleman sayısını, x; zaman alanında kayan pencerede bulunan elemanları, μ ; kayan pencerede bulunan elemanların ortalamasını, f; frekans alanındaki kayan pencerede bulunan FFT katsayılarını göstermektedir.




Şekil 1. Araba ulaşım türü için ivme ölçer X sinyali




Şekil 2. Otobüs ulaşım türü için ivme ölçer X sinyali


Veri üzerindeki her bir sütun için kayan pencere uygulanması ve her bir kayan pencerede zaman ve frekans alanında hesaplama yapılması sonucu veri kümesinden 156 adet yeni öznitelik elde edilmiştir. 12 farklı eksen üzerinden zaman ve frekans alanında 13 hesaplama türü kullanılarak $12 \times 13 = 156$ adet öznitelik çıkarılmıştır. Bu özniteliklerin 60 tanesi frekans alanında, 96 tanesi zaman alanında elde edilmiştir.




Şekil 3. Metrobüs ulaşım türü için ivme ölçer X sinyali




Şekil 4. Metro_H ulaşım türü için ivme ölçer X sinyali




Şekil 7. Minibüs ulaşım türü için ivme ölçer X sinyali



Şekil 5. Metro_K ulaşım türü için ivme ölçer X sinyali



Şekil 8. Marmaray ulaşım türü için ivme ölçer X sinyali



Şekil 6. Tramvay ulaşım türü için ivme ölçer X sinyali

Tablo 1. Zaman Alanındaki Hesaplama Türleri

ZAMAN ALANINDAKİ HESAPLAMA TÜRLERİ	
Ortalama	$\frac{\sum_{i=1}^N x_i}{N} \quad i = 1, 2, \dots, N$
Medyan	N tek ise sıralı dizide; $\frac{N+1}{2}$ sıralı eleman N çift ise sıralı dizide; $\frac{N}{2}$ sıralı eleman
Varyans	$\frac{\sum_{i=1}^N (x_i - \mu)^2}{N-1} \quad i = 1, 2, \dots, N$
Standart Sapma	$\sqrt{\text{Varyans}}$
Maksimum Değer	$\max(x_i) \quad i = 1, 2, \dots, N$
Minimum Değer	$\min(x_i) \quad i = 1, 2, \dots, N$
Maksimum ve Minimum Değer Arası Fark	$\max(x_i) - \min(x_i) \quad i = 1, 2, \dots, N$
Kare Ortalamalarının Kökü (RMS)	$\sqrt{\frac{\sum_{i=1}^N x_i^2}{N}} \quad i = 1, 2, \dots, N$

Tablo 2. Frekans Alanında Hesaplama Türleri

FREKANS ALANINDAKİ HESAPLAMA TÜRLERİ	
FFT Katsayıları Ortalaması	$\frac{\sum_{i=1}^N f_i}{N} \quad i = 1, 2, \dots, N$
FFT Katsayıları Toplamı	$\sum_{i=1}^N f_i \quad i = 1, 2, \dots, N$
İlk FFT Katsayı Değeri	f_1
FFT Katsayıları Enerjisi	$\frac{\sum_{i=1}^N f_i^2}{N} \quad i = 1, 2, \dots, N$
FFT Katsayıları Bilgi Değeri (Entropi)	$-\sum_{i=1}^N f_i (\log_2 f_i) \quad i = 1, 2, \dots, N$

Tahmin etme gücü yüksek öznelilikler Bilgi Kazanımı algoritması yardımıyla bulunmuştur. Bilgi Kazanımı entropiye dayalı öznelilik seçim yöntemidir. Entropi, bir sistemdeki düzensizliğin ya da belirsizliğin ölçüsüdür. Entropi 0 ve 1 aralığında değerler alır ve 1 değerine yaklaştıkça belirsizlik artar. Yüksek entropiye sahip veri daha çok bilgi içerir. Bilgi Kazanımı yöntemi, en ayırt edici özelliği belirlemek için kullanılır ve veri kümesindeki her bir öznelilik için ölçülür. (Aktas, 2015)

Tablo 4'te zaman ve frekans alanında tahmin etme gücü yüksek ilk 20 öznelilik verilirken, Tablo 5'te sadece frekans alanında tahmin etme gücü yüksek ilk 20 öznelilik, Tablo 6 da ise sadece zaman alanında tahmin etme gücü yüksek ilk 20 öznelilik verilmiştir. Tablo 4'te Zaman + Frekans alanında tahmin etme gücü yüksek öznelilikler incelendiğinde ivme ölçer algılayıcısının, yuvarlanma ve yalpalanma açısının tahmin etmede önemli katkılarına olduğu gözlemlenmiştir. Hesaplama türü olarak ise Bilgi Değeri ve Enerji öznelilikleri tahmin etme gücünü yükseltmektedir.

Tablo 4. Zaman + Frekans Alanında Tahmin Etme Gücü Yüksek Öznelilikler

ALGILAYICI	EKSEN	HESAPLAMA TÜRÜ	HESAPLAMA ALANI
İvme Ölçer	x	Bilgi Değeri	Frekans
İvme Ölçer	z	Medyan	Zaman
Yuvarlanma Açısı	-	FFT İlk katsayı değeri	Frekans
Yuvarlanma Açısı	-	Medyan	Zaman
İvme Ölçer	y	Medyan	Zaman
İvme Ölçer	y	Ortalama	Zaman
Yuvarlanma Açısı	-	Enerji	Frekans
Yön Açısı	-	Bilgi Değeri	Frekans
Yalpalanma Açısı	-	FFT ilk katsayı değeri	Frekans
Mıknatıs Ölçer	z	Enerji	Frekans
Jiroskop	x	Varyans	Zaman
İvme Ölçer	x	Ortalama	Zaman
Yalpalanma Açısı	-	Ortalama	Zaman
İvme Ölçer	z	Varyans	Zaman

İvme Ölçer	x	Standart Sapma	Zaman
Jiroskop	y	Bilgi Değeri	Frekans
Yalpalanma Açısı	-	Bilgi Değeri	Frekans
Mıknatıs Ölçer	x	Bilgi Değeri	Frekans
Mıknatıs Ölçer	z	Medyan	Zaman
İvme Ölçer	x	Varyans	Zaman

Tablo 5'te Frekans alanında tahmin etme gücü yüksek öznelilikler incelendiğinde ivme ölçer algılayıcısının, yuvarlanma, yön ve yalpalanma açısının tahmin etmede önemli katkılarına olduğu görülmüştür. Frekans alanında Bilgi Değeri, Enerji ve FFT ilk katsayı hesaplama türleri kullanılarak elde edilen öznelilikler tahmin etme gücünü yükseltmektedir.

Tablo 6'da Zaman alanında tahmin etme gücü yüksek öznelilikler incelendiğinde ivme ölçer algılayıcısının tahmin etmede önemli katkılarına olduğu gözlemlenmiştir. Hesaplama türü olarak ise Medyan, Ortalama ve Varyans öznelilikleri tahmin etme gücünü yükseltmektedir.

Tablo 5. Frekans Alanında Tahmin Etme Gücü Yüksek Öznelilikler

ALGILAYICI	EKSEN	HESAPLAMA TÜRÜ	HESAPLAMA ALANI
İvme Ölçer	x	Bilgi Değeri	Frekans
Yuvarlanma Açısı	-	FFT İlk katsayı değeri	Frekans
Yuvarlanma Açısı	-	Enerji	Frekans
Yön Açısı	-	Bilgi Değeri	Frekans
Yalpalanma Açısı	-	FFT ilk katsayı değeri	Frekans
Mıknatıs Ölçer	z	Enerji	Frekans
Jiroskop	y	Bilgi Değeri	Frekans
Yalpalanma Açısı	-	Bilgi Değeri	Frekans
Mıknatıs Ölçer	x	Bilgi Değeri	Frekans
Mıknatıs Ölçer	y	Bilgi Değeri	Frekans
Jiroskop	x	Bilgi Değeri	Frekans
Yalpalanma Açısı	-	Enerji	Frekans
Jiroskop	z	Enerji	Frekans
Jiroskop	x	Enerji	Frekans
İvme Ölçer	z	Enerji	Frekans
İvme Ölçer	y	Ortalama	Frekans
Yalpalanma Açısı	-	Ortalama	Frekans
Jiroskop	y	Ortalama	Frekans
Mıknatıs Ölçer	x	Enerji	Frekans
İvme Ölçer	x	Bilgi Değeri	Frekans

Tablo 6. Zaman Alanında Tahmin Etme Gücü Yüksek Öznitelikler

ALGILAYICI	EKSEN	HESAPLAMA TÜRÜ	HESAPLAMA ALANI
İvme Ölçer	z	Medyan	Zaman
Yuvarlanma Açısı	-	Medyan	Zaman
İvme Ölçer	y	Ortalama	Zaman
Jiroskop	x	Varyans	Zaman
Yalpalanma Açısı	-	Ortalama	Zaman
İvme Ölçer	x	Ortalama	Zaman
İvme Ölçer	z	Varyans	Zaman
İvme Ölçer	x	Standart Sapma	Zaman
İvme Ölçer	x	Varyans	Zaman
Mıknatis Ölçer	z	Medyan	Zaman
Jiroskop	y	Standart Sapma	Zaman
İvme Ölçer	y	Maksimum	Zaman
Jiroskop	x	Standart Sapma	Zaman
Mıknatis Ölçer	z	Ortalama	Zaman
Yön Açısı	-	Kare Ortalamalarının Kök değeri	Zaman
Yalpalanma Açısı	-	Kare Ortalamalarının Kök değeri	Zaman
Mıknatis Ölçer	x	Medyan	Zaman
İvme Ölçer	y	Standart Sapma	Zaman
Yön Açısı	-	Varyans	Zaman
İvme Ölçer	z	Medyan	Zaman

4. Araştırma Bulguları

Bu kısımda veri kümesine uygulanan sınıflandırma algoritmaları hakkında kısa bilgiler, elde edilen başarı sonuçları ve karmaşıklık matrisleri verilmektedir. Zaman ve frekans alanına ait öznitelikler doğruluk (accuracy), kesinlik (precision), hassasiyet (recall) olmak üzere üç farklı parametre ile değerlendirilmiştir. Veri kümesinin %70'i ile eğitim, %30'u ile test işlemleri gerçekleştirilmiştir.

4.1. Çalışmada Kullanılan Algoritmalar

Çalışmada kullanılan sınıflandırma yöntemleri; bilimsel yazım taramasında gözlemlenen ulaşım türü tanıma alanında yüksek başarı veren algoritmalar arasından tercih edilmiştir.

En Yakın k Komşuluk Yöntemi

En Yakın k Komşuluk yöntemi, sınıflandırma problemini çözen denetimli öğrenme yöntemleri arasında yer alır. Yöntemde; sınıflandırma yapılacak verilerin öğrenme kümesindeki normal davranış verilerine benzerlikleri hesaplanarak; en yakın olduğu düşünülen k verinin ortalamasıyla, belirlenen eşik değere göre sınıflara atamaları yapılır. Önemli olan, her bir sınıfın özniteliklerinin önceden net bir şekilde belirlenmiş olmasıdır. Yöntemin performansını k en yakın komşu sayısı, eşik değer, benzerlik ölçümü ve öğrenme kümesindeki normal davranışların yeterli

sayıda olması kriterleri etkilemektedir. (Çalışkan, 2008) Bu yöntemin eğitim karmaşıklığı bulunmasa da özellikle veri kümesinin boyutu büyüdüğünde test karmaşıklığı doğru orantılı artmaktadır. Özellikle sayısının fazla olması durumunda hesaplanan uzaklık mesafeleri artmakta ve yüksek maliyet oluşturmaktadır.

Siirtola ve Röning (2012), Jahangiri ve Rakha (2015) tarafından yapılan ulaşım türü tespit çalışmalarında En Yakın k Komşu yönteminin kullanıldığı ve başarılı sonuçlar verdiği belirtilmiştir.

Rastgele Orman Yöntemi

Rastgele Orman, bir sınıflandırıcı yerine birden çok sınıflandırıcı üreten ve sonrasında onların tahminlerinden alınan oylar ile yeni veriyi sınıflandıran öğrenme algoritmasıdır ve kaybolan verilerin tahmin edilmesinde etkili bir metottur. (Radenković, 2015). Hem aktivite tanıma hem de ulaşım türü tanıma da sıklıkla kullanılmakta ve ağaç yapısına uygun olan bu tür problemler için en iyi çözümü sunmaktadır.

Jahangiri ve Rakha (2015) tarafından yapılan çalışmada ulaşım türü tanıma en yüksek başarı Rastgele Orman yöntemi ile elde edilmiştir. Su vd. (2015) tarafından yapılan çalışmada da Rastgele Orman yönteminin ulaşım türü tanıma başarılı sonuçlar verdiği belirtilmiştir.

Çok Katmanlı Algılayıcı

Çok katmanlı yapay sinir ağları modeli Rumelhart ve arkadaşları tarafından geliştirilmiştir. Bu modele hata yayma modeli veya geri yayılım modeli de denilmektedir. Çok katmanlı yapay sinir ağları modelinde geriye yayılım algoritması kullanılmaktadır (Karaatlı, 2012).

Byon ve Liang (2014) tarafından yapılan çalışmada ulaşım türü tanıma için yapay sinir ağları kullanılmıştır. Fang vd. (2017) tarafından yapılan çalışmada derin yapay sinir ağları, karar ağaçları, en yakın k komşu, destek vektör makinesi sınıflandırma yöntemleri kullanılmış ve başarılı sonuçlar elde edildiği gözlemlenmiştir. Ancak çok katmanlı algılayıcıların derin öğrenme kadar başarılı sonuçlar üretmediği ortaya konmuştur.

Destek Vektör Makinesi

Destek vektör makinesi, sınıflandırma ve regresyon analizinde kullanılan, verileri analiz eden ve örneklerden öğrenen denetimli bir öğrenme yöntemidir. Destek vektör makinesi ile ilgili ilk çalışmalar sınıflandırma alanı ile ilgili olmasına rağmen, daha sonraki çalışmalarda özellikle zaman serilerinin tahmini ve regresyon uygulamalarında çok iyi sonuçlar elde edildiği görülmüştür. (Bilişik, 2011)

Xia vd. (2014) ve Jahangiri ve Rakha (2015) tarafından yapılan çalışmalarda ulaşım türü tespiti için Destek Vektör Makinesi yönteminin kullanıldığı ve başarılı sonuç elde edildiği gözlemlenmiştir.

4.2. Deneysel Sonuçlar

Çalışmada kullanılan veri kümesi 8 farklı kişi tarafından farklı tipteki Android telefonlar aracılığı ile İstanbul il sınırları içerisinde toplanmıştır. Otobüs için toplamda 262 dakika, Metro Kirazlı (Yer Üstü Metrosu) için 239 dakika, Marmaray için (Tren) 219 dakika, Metro Haciosman (Yer Altı Metrosu) için 204 dakika, Tramvay için 222 dakika, Araba için 217 dakika, Minibüs için 180 dakika, Metrobüs için 212 dakika olmak üzere toplamda 8 farklı ulaşım türü için 1755 dakika veri toplanmıştır. %50 örtüşen pencere ile taranan veri kümesinden toplam 2634 adet örnek veri elde edilmiştir. Ulaşım türlerine ait veri dağılımı Tablo 7'de gösterilmektedir.

Tablo 7. Ulaşım Türlerinde Örnek Veri Dağılımı

ULAŞIM TÜRÜ	ÖRNEK SAYISI
Otobüs	393
Metro (Yer Üstü)	259
Marmaray	329
Metro (Yer Altı)	306
Tramvay	333
Araba	326
Minibüs	270
Metrobüs	318

Çalışmada kullanılan sınıflandırma algoritmaları macOS High Sierra 10.13.3 sürümlü işletim sistemi kullanan 1.6 Ghz Intel Core i5 işlemcili, 8 GB DDR3 bellek içeren bilgisayarda; Weka 3.8.1 veri madenciliği yazılımı kullanılarak çalıştırılmıştır. Elde edilen sonuçlar özellikle en iyi sonuç veren Rastgele Orman Yöntemi'nin gerçek zamanlı olarak çalışabileceğini göstermiştir.

Çalışmada ham veriden öznitelik elde etmek için zaman ve frekans alanlarında hesaplamalar yapılmıştır. Hem zaman hem frekans alanında elde edilen öznitelikler kullanılarak yapılan sınıflandırmada en yüksek başarı yüzdeleri; Rastgele Orman %95,06, Çok Katmanlı Algılayıcı %92,53, k-NN %92,03, Destek Vektör Makineleri %87,59 ve J48 %86,33 olarak elde edilmiştir. Öznitelik sayısı 50 ve üzerindeki algoritma başarı oranları sabit bir şekilde ilerlemiştir. Şekil 9'da görülmektedir.

Sadece frekans alanında elde edilen öznitelikler kullanılarak yapılan sınıflandırmada en yüksek başarı yüzdeleri; Rastgele Orman %93,29, Çok Katmanlı Algılayıcı %89,75, k-NN %88,10, J48 %83,67 ve Destek Vektör Makinesi %77,09 olarak elde edilmiştir.

Destek Vektör Makineleri dışında öznitelik sayısı 20 ve üzerindeki algoritma başarı oranları sabit bir şekilde ilerlemektedir. Frekans alanında elde edilen öznitelik sayılarına göre sınıflandırma başarıları Şekil 10'da gözlemlenmektedir.

Sadece zaman alanında elde edilen öznitelikler kullanılarak yapılan sınıflandırmada en yüksek başarı yüzdeleri; Rastgele Orman %94,56, kNN %92,91, Çok Katmanlı Algılayıcı %90,63, J48 %87,59 ve Destek Vektör Makineleri %80,89 olarak elde edilmiştir. Öznitelik sayısı 40 ve üzerindeki algoritma başarı oranları sabit bir şekilde ilerlemektedir. Zaman alanında elde edilen öznitelik sayılarına göre sınıflandırma başarıları Şekil 11'de gözlemlenmektedir.

Zaman ve frekans özniteliklerinin birlikte bulunduğu veri kümesinde en yüksek başarı Rastgele Orman yöntemi ile 156 öznitelik ile %95,06 olarak elde edilmiştir, karmaşıklık matrisi Tablo 8'de görülmektedir. Sınıflandırma esnasında Marmaray ve Tramvay, Metro ve Tramvay, Metrobüs ve Araba ikilileri gibi hareket karakteristikleri birbirine benzeyen ulaşım türlerinin yanlış tahmin edildiği gözlemlenmiştir.

Frekans özniteliklerinin bulunduğu veri kümesinde en yüksek başarı Rastgele Orman yöntemi kullanılarak 50 öznitelik ile %93,29 olarak elde edilmiştir. Kesinlik ve Hassasiyet değerlerinin de yer aldığı karmaşıklık matrisi Tablo 9'da verilmiştir. Sınıflandırma esnasında Marmaray ve Tramvay, Metro ve Marmaray, Metrobüs ve Minibüs ikilileri olacak şekilde yanlış tahmin etmeye sebep olmuş veriler bulunmaktadır.

Tablo 8. Zaman ve Frekans Alanı Öznitelikleri Birlikte Kullanılarak Rastgele Orman Algoritması ile Yapılan Sınıflandırma Sonucu Gözlenen Karmaşıklık Matrisi

	A	B	C	D	E	F	G	H	Hassasiyet
A	119	2	0	1	1	0	0	2	%95,2
B	1	109	0	0	4	1	0	1	%93,96
C	0	0	91	0	3	0	0	6	%91
D	0	1	3	88	0	0	0	1	%94,62
E	1	1	0	0	79	1	0	0	%96,34
F	0	0	0	0	1	94	0	3	%95,91
G	1	1	0	0	0	0	80	2	%95,23
H	1	0	0	0	0	0	0	91	%98,91
Kesinlik	%96,74	%95,61	%96,88	%98,87	%89,77	%97,91	%100	%85,88	

A: Otobüs, B: Metro (Yer Üstü), C: Marmaray, D: Metro (Yer Altı), E: Tramvay, F: Araba, G: Minibüs, H: Metrobüs

Tablo 9. Frekans Alanı Öznitelikleri Kullanılarak Rastgele Orman Algoritması ile Yapılan Sınıflandırma Sonucu Gözlenen Karmaşıklık Matrisi


	A	B	C	D	E	F	G	H	Hassasiyet
A	121	0	0	2	0	0	0	2	%96,8
B	1	111	1	0	2	0	0	1	%95,68
C	0	0	92	1	2	0	0	5	%92
D	0	3	2	86	1	0	0	1	%92,47
E	0	1	0	0	77	1	1	2	%93,9
F	2	5	0	0	1	88	0	2	%89,79
G	0	5	0	0	2	0	74	3	%88,09
H	3	0	0	0	1	0	0	88	%95,65
Kesinlik	%95,27	%88,8	%96	%96,84	%89,53	%98,87	%98,66	%84,61	

A: Otobüs, B: Metro (Yer Üstü), C: Marmaray, D: Metro (Yer Altı), E: Tramvay, F: Araba, G: Minibüs, H: Metrobüs

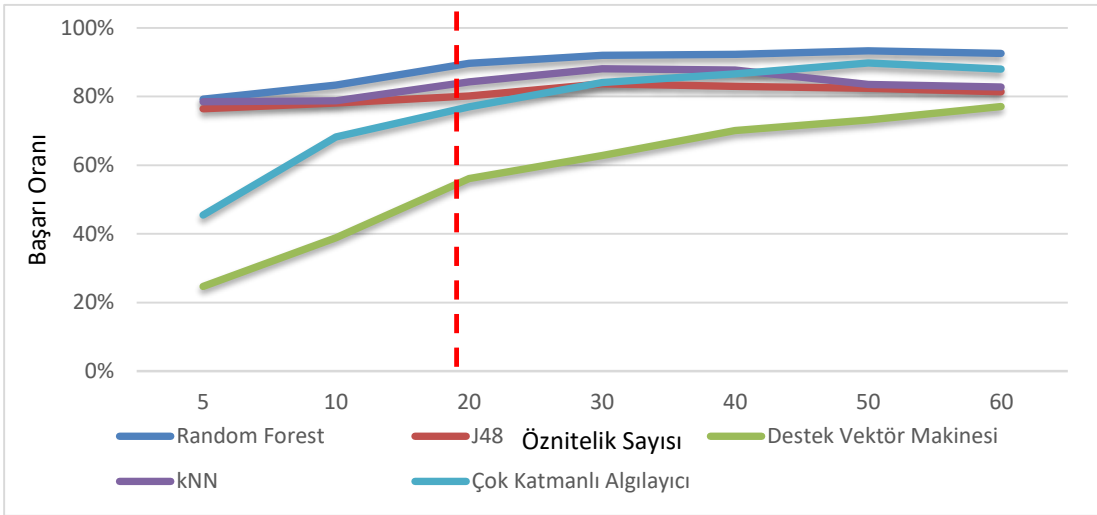
Tablo 10. Zaman Alanı Öznitelikleri Kullanılarak Rastgele Orman Algoritması ile Yapılan Sınıflandırma Sonucu Gözlenen Karmaşıklık Matrisi

	A	B	C	D	E	F	G	H	Hassasiyet
A	94	0	4	0	1	0	0	0	%94,94
B	0	96	6	1	1	0	0	2	%90,56
C	2	2	120	0	0	0	1	0	%96
D	1	3	0	87	1	0	0	0	%94,56
E	1	5	0	0	91	0	0	0	%93,81
F	2	0	0	0	4	88	0	2	%91,66
G	2	0	0	0	0	0	77	1	%96,25
H	0	0	1	0	0	0	0	94	%98,94
Kesinlik	%92,15	%90,56	%91,6	%98,86	%92,85	%100	%98,71	%94,94	

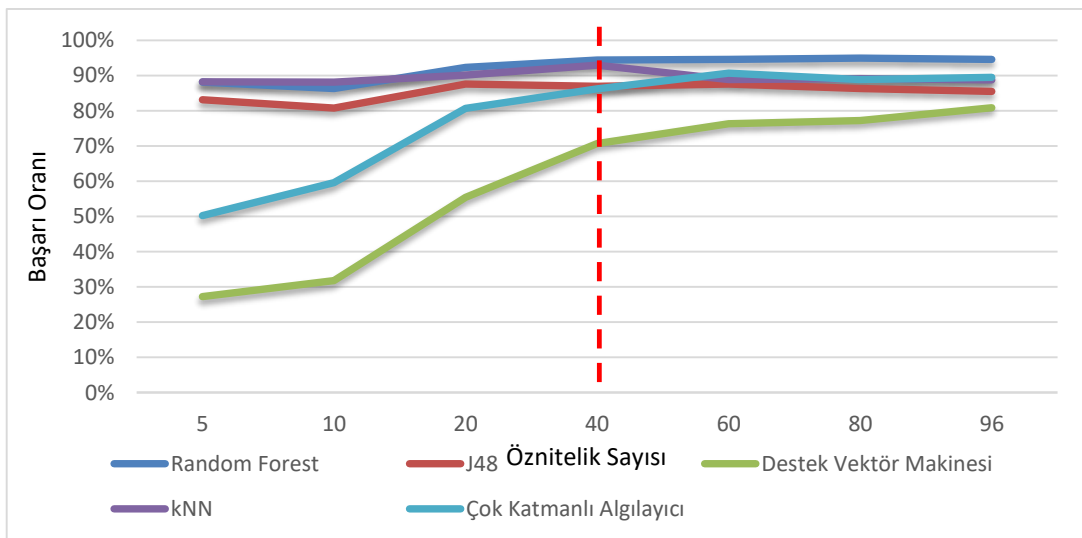
A: Otobüs, B: Metro (Yer Üstü), C: Marmaray, D: Metro (Yer Altı), E: Tramvay, F: Araba, G: Minibüs, H: Metrobüs



Şekil 9. Zaman + Frekans alanında kullanılan öznelik sayısına göre algoritmalarda elde edilen başarı yüzdeleri



Şekil 10. Frekans alanında kullanılan öznelik sayısına göre algoritmalarda elde edilen başarı yüzdeleri



Şekil 11. Zaman alanında kullanılan öznelik sayısına göre algoritmalarda elde edilen başarı yüzdeleri

Zaman özniteliklerinin bulunduğu veri kümesinde en yüksek başarı Rastgele Orman yöntemi kullanılarak 96 öznitelik ile %94,56 olarak elde edilmiştir. Karmaşıklık matrisi Tablo 10'de görülmektedir. Sınıflandırma esnasında Metro ve Otobüs, Metro ve Tramvay, Metro_K ve Metro_H ikilileri birbirlerine benzetilmiştir.

Raylı ulaşım türlerinin ve tekerlekli araç ile olan ulaşım türlerinin kendi aralarında karışarak sınıflandırmada düşüğe olsa yanlışlığa sebep olduğu gözlemlenmiştir.

5. Sonuç ve Tartışma

Bu çalışmada akıllı telefon algılayıcılarından toplanan veriler kullanılarak ulaşım türü tanıma için öznitelik alanlarının başarıya katkısı incelenmiştir. Tablo 12'de algoritma ve öznitelik alanlarına göre en yüksek başarı sonuçları karşılaştırmalı olarak verilmiştir. En yüksek başarı hem zaman hem frekans alanındaki özniteliklerin kullanılması ile Rastgele Orman algoritması çalıştırılarak %95,06 olarak elde edilmiştir. Sadece zaman özniteliklerinin kullanılması ile Rastgele Orman algoritması ile %94,56 oranında başarı elde edilmiştir. Frekans türündeki özniteliklerin eklenmesi başarıya ancak %0,5 oranında katkı sağlayabilmiştir. Frekans özniteliklerinin hesaplanması uygulamaya fazladan işlem yükü getireceği için akıllı telefon, akıllı saat vb. enerji kısıtlı cihazlarda sadece zaman alanında hesaplama yaparak sınıflandırma yapılması bu sonuçlar doğrultusunda önerilmektedir.

Tablo 12. Algoritma ve Öznitelik Alanlarına Göre En Yüksek Başarı Sonuçları

	ZAMAN + FREKANS	FREKANS	ZAMAN
RASTGELE ORMAN	%95,06	%93,29	%94,56
ÇOK KATMANLI ALGILAYICI	%92,53	%89,75	%90,63
k-NN	%92,03	%88,10	%92,91
J48	%86,33	%83,67	%87,59
DESTEK VEKTÖR MAKİNESİ	%87,59	%77,09	%80,89

Zaman + Frekans alanında tahmin etme gücü yüksek öznitelikler incelendiğinde ivme ölçer algılayıcısının, yuvarlanma ve yalpalanma açısının tahmin etmede önemli katkıların olduğu gözlemlenmiştir. Hesaplama türü olarak ise Bilgi Değeri ve Enerji sonuçları tahmin etme gücünü yükseltmektedir. Frekans alanında tahmin etme gücü yüksek öznitelikler incelendiğinde ivme ölçer algılayıcısının, yuvarlanma, yön ve yalpalanma açısının tahmin etmede önemli katkıların olduğu gözlemlenmiştir.

Hesaplama türü olarak ise Bilgi Değeri, Enerji ve FFT ilk katsayı değeri sonuçları tahmin etme gücünü yükseltmektedir. Zaman alanında tahmin etme gücü yüksek öznitelikler incelendiğinde ivme ölçer algılayıcısının tahmin etmede önemli katkıların olduğu gözlemlenmiştir. Hesaplama türü olarak ise Medyan, Ortalama ve Varyans değeri sonuçlarının tahmin etme gücünü yükselttiği gözlemlenmiştir.

Ulaşım türü tespiti çalışmalarında genellikle uçak, vapur, teleferik, helikopter, küçük tekne, balon vb. türler veri kümelerinde bulunmamaktadır. Bu sınıflar için veri toplamak veri çeşitliliğinin artmasına katkı sağlayacak ve gerçek hayattaki tüm ulaşım türlerinin değerlendirilmesine yardımcı olacaktır.

Conflict of Interest / Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

No conflict of interest was declared by the authors.

Kaynaklar

- Waga, K., Tabarcea, A., Chen, M., & Franti, P. (2012, October). Detecting movement type by route segmentation and classification. In *Collaborative computing: networking, applications and worksharing (CollaborateCom), 2012 8th International Conference on* (pp. 508-513). IEEE.
- Widhalm, P., Nitsche, P., & Brändie, N. (2012, November). Transport mode detection with realistic smartphone sensor data. In *Pattern Recognition (ICPR), 2012 21st International Conference on* (pp. 573-576). IEEE.
- Xiao, Z., Wang, Y., Fu, K., & Wu, F. (2017). Identifying different transportation modes from trajectory data using tree-based ensemble classifiers. *ISPRS International Journal of Geo-Information*, 6(2), 57.
- Su, H. X., Caceres, H., & He, Q. (2015). Travel mode identification with smartphones. *Sensors*, 15, 16.
- Das, R. D., & Winter, S. (2016). Detecting urban transport modes using a hybrid knowledge driven framework from GPS trajectory. *ISPRS International Journal of Geo-Information*, 5(11), 207.
- Ballı, S., Sağbaş, E. A. (2016), Akıllı telefon algılayıcıları ve makine öğrenmesi kullanılarak ulaşım türü tespiti, Pamukkale Univ Muh Bilim Dergisi, 22(5), 376-383.
- Bedogni, L., Di Felice, M., & Bononi, L. (2016). Context-aware Android applications through transportation mode detection

- techniques. *Wireless Communications and Mobile Computing*, 16(16), 2523-2541.
- Siirtola, P., & Röning, J. (2012). Recognizing human activities user-independently on smartphones based on accelerometer data. *IJIMAI*, 1(5), 38-45.
- Byon, Y., Liang, S. (2014), Real-Time Transportation Mode Detection Using Smartphones^[1] and Artificial Neural Networks: Performance Comparisons Between Smartphones and Conventional Global Positioning System Sensors. *Journal of Intelligent Transportation Systems*, 18(3), 264-272.
- Jahangiri, A., & Rakha, H. A. (2015). Applying machine learning techniques to transportation mode recognition using mobile phone sensor data. *IEEE transactions on intelligent transportation systems*, 16(5), 2406-2417.
- Sonderon, T. (2016), Detection of Transportation Mode Solely Using Smartphones.
- Cardoso, N., Madureira, J., & Pereira, N. (2016, September). Smartphone-based transport mode detection for elderly care. In *e-Health Networking, Applications and Services (Healthcom), 2016 IEEE 18th International Conference on* (pp. 1-6). IEEE.
- Su, X., Caceres, H., Tong, H., & He, Q. (2016). Online travel mode identification using smartphones with battery saving considerations. *IEEE Transactions on Intelligent Transportation Systems*, 17(10), 2921-2934.
- Hemminki, S., Nurmi, P., & Tarkoma, S. (2013, November). Accelerometer-based transportation mode detection on smartphones. In *Proceedings of the 11th ACM Conference on Embedded Networked Sensor Systems* (p. 13). ACM.
- Yan, Z., Subbaraju, V., Chakraborty, D., Misra, A., & Aberer, K. (2012, June). Energy-efficient continuous activity recognition on mobile phones: An activity-adaptive approach. In *Wearable Computers (ISWC), 2012 16th International Symposium on* (pp. 17-24). IEEE.
- Xia, H., Qiao, Y., Jian, J., & Chang, Y. (2014). Using smart phone sensors to detect transportation modes. *Sensors*, 14(11), 20843-20865.
- Zhou, X., Yu, W., & Sullivan, W. C. (2016). Making pervasive sensing possible: Effective travel mode sensing based on smartphones. *Computers, Environment and Urban Systems*, 58, 52-59.
- Fang, S. H., Liao, H. H., Fei, Y. X., Chen, K. H., Huang, J. W., Lu, Y. D., & Tsao, Y. (2016). Transportation modes classification using sensors on smartphones. *Sensors*, 16(8), 1324.
- Fang, S. H., Fei, Y. X., Xu, Z., & Tsao, Y. (2017). Learning Transportation Modes From Smartphone Sensors Based on Deep Neural Network. *IEEE Sensors Journal*, 17(18), 6111-6118.
- Shin, D., Aliaga, D., Tunçer, B., Arisona, S. M., Kim, S., Zünd, D., & Schmitt, G. (2015). Urban sensing: Using smartphones for transportation mode classification. *Computers, Environment and Urban Systems*, 53, 76-86.
- Shafique, M. A., & Hato, E. (2016). Travel mode detection with varying smartphone data collection frequencies. *Sensors*, 16(5), 716.
- Lan, G., Xu, W., Khalifa, S., Hassan, M., & Hu, W. (2016, March). Transportation mode detection using kinetic energy harvesting wearables. In *Pervasive Computing and Communication Workshops (PerCom Workshops), 2016 IEEE International Conference on* (pp. 1-4). IEEE.
- Nikolic, M., & Bierlaire, M. (2017). Review of transportation mode detection approaches based on smartphone data. In *17th Swiss Transport Research Conference* (No. EPFL-CONF-229181).
- Figo, D., Diniz, P. C., Ferreira, D. R., & Cardoso, J. M. (2010). Preprocessing techniques for context recognition from accelerometer data. *Personal and Ubiquitous Computing*, 14(7), 645-662.
- Guvensan, M. A., Dusun, B., Can, B., & Turkmen, H. (2017). A Novel Segment-Based Approach for Improving Classification Performance of Transport Mode Detection. *Sensors*, 18(1), 87.
- Aktas, M. S., & Kalıpsız, O. (2015, September). Veri Madenciliğinde Öznitelik Seçim Tekniklerinin Bankacılık Verisine Uygulanması Üzerine Araştırma ve Karşılaştırmalı Uygulama. In *Proceedings of the 9th Turkish National Software Engineering Symposium (UYMS 2015)*, Yasar University, Izmir, Turkey.
- Çalışkan, S. K., & Soğukpınar, İ. (2008). KxKNN: K-Means ve K En Yakın Komşu Yöntemleri İle Ağlarda Nüfuz Tespiti. *EMO Yayınları*, 120-24.
- Radenković P., Random Forest, University Of Belgrade, 2015.
- Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.

Bilişik, M. T. (2011). Destek Vektör Makinesi, Çoklu Regresyon Ve Doğrusal Olmayan Programlama İle Perakendecilik Sektöründe Gelir Yönetimi İçin Dinamik Fiyatlandırma.