

DOĞU ANADOLU GÖZLEMEVİ TELESKOBU İÇİN ASTRONOMİK GÖZLEM TÜRÜ BELİRLENMESİ

DETERMINATION OF THE ASTRONOMIC OBSERVATION TYPE FOR THE EASTERN
ANATOLIA OBSERVATORY TELESCOPE

Ömer YAVUZ*
Ersin KARAMAN**
Cahit YEŞİLYAPRAK***

Öz

Bu çalışmada Doğu Anadolu Gözlemevi'nin yerel özellikleri ve mevcut gözlem şartları dikkate alınarak belirlenen astronomik gözlem türünün tahmin edilmesi amaçlanmaktadır. Bu amaç doğrultusunda öncelikle eğitim setini oluşturulan veriler, uzman görüşü doğrultusunda etiketlenmiştir. Sonrasında iki sınıf ve dört sınıflı veriler üzerinde dört farklı algoritma kullanılarak tahminler yapılmıştır. Çalışma sonucunda, her bir güne ait veriler için uygun gözlem türü tahmin edilerek makine öğrenmesi algoritmalarının performansı ölçülmüştür. Yapılan tahminlerde iki sınıflı veriler için algoritmaların %95'in üzerinde başarımlar sağladığı görülmüş de dört sınıflı veriler üzerinde Naive Bayes ve K En Yakın Komşu algoritmalarının başarımlarında düşüş görülmüştür. Sonuç olarak yapılan tahmin çalışmalarının gözlemevlerinin etkili ve verimli kullanımına yönelik katkı sağlayacağı düşünülmektedir.

Anahtar Kelimeler: Astronomik Gözlem Türü, Doğu Anadolu Gözlemevi, Makine Öğrenmesi.

Abstract

In this study, it is aimed to estimate the type of astronomical observation determined by considering the local characteristics and current observation conditions of the Eastern Anatolia Observatory. For this purpose, first of all, the data that created the training set were labeled in line with the expert opinion. Afterwards, predictions were made on two-class and four-class data using four different algorithms. As a result of the study, the performance of machine learning algorithms was measured by estimating the appropriate observation type for the data of each day. Although it is seen that the algorithms provide over 95% performance for two-class data, the performance of Naive Bayes and K Nearest Neighbor algorithms has decreased on four-class data. As a result, it is thought that the estimation studies will contribute to the effective and efficient use of observatories.

Keywords: Astronomical Observation Type, Eastern Anatolia Observatory, Machine Learning.

* Arş. Gör., Karadeniz Teknik Üniversitesi İİBF Yönetim Bilişim Sistemleri Bölümü, omercagriyavuz@ktu.edu.tr

** Doç. Dr., Ankara Hacı Bayram Veli Üniversitesi İİBF Yönetim Bilişim Sistemleri Bölümü, ersin.karaman@hbv.edu.tr

*** Prof. Dr., Atatürk Üniversitesi Fen Fakültesi Astronomi ve Uzay Bilimleri Bölümü, cahity@atauni.edu.tr

1. GİRİŞ

2012 yılı itibarıyla Atatürk Üniversitesi Astrofizik Araştırma ve Uygulama Merkezi bünyesinde yürütülen ve ilk aşamasında gözlemevi kurulmasının amaçlandığı Doğu Anadolu Gözlemevi (DAG) projesiyle Türkiye'deki en büyük çaplı gözlemevi kurulumuna yönelik çalışmalar devam etmektedir. Bu amaç çerçevesinde Doğu Anadolu Gözlemevi projesinin yürütüldüğü ATASAM uzay bilimleri konusunda çeşitli kurumlarla iş birliği sağlamaktadır. Meteosat uydu verileri ve gözlemevi yerleşkesinden alınan yerel meteorolojik gözlem verileriyle birlikte atmosferik ve sismik gözlem araçlarından da ATASAM iş birliğiyle çeşitli gözlem verileri elde edilmektedir. Bu tür gözlem verilerinin paylaşımı yaygınlaşmakta ve astronomik gözlem verilere erişim kolaylaşmaktadır. Ancak bu verilerin temizlenmesi, işlenmesi, anlamlandırılmasına yönelik uygulamalarda çeşitli zorluklar yaşanmaktadır. Geleneksel programlama yöntemlerinden ziyade yapay zekâ uygulamalarında kullanılan makine öğrenmesi algoritmalarıyla verilerin işlenme hızı artış göstermektedir. Bu artış ile birlikte Yapay Zekâ disiplini de ilerleme kaydetmektedir (Boffin, Jerabkova, Mérand ve Stoehr, 2019). Bu tekniklerle artan verilerin işlenerek karar almaya yardımcı uygulamaların geliştirilmesi ve uygulanmasıyla süreçlerin kolaylaştırılmasıyla birlikte otomatikleştirilmesi amaçlanmaktadır.

Astronomik gözlem türü; sıcaklık, nem, rüzgâr, bulut, görüş gibi kriterlere göre değişiklik göstermektedir. Gözlemevlerinde kullanılan gözlemsel aletler de gözlem türü açısından farklılık göstermektedir. Mevcut durumda farklı amaçlarla yapılan gözlemler uzman değerlendirmeleri doğrultusunda yapılmaktadır. Gözlemevindeki koşullar dikkate alınarak uygun gözlem türünün önceden tahmin edilmesi ve çok kanaldan elde edilen verilerin analiz edilerek gözlemcilerin yönlendirilebilmesi, Türkiye'nin en büyük temel bilim projelerinden biri olan Doğu Anadolu Gözlemevi (DAG) projesinin tamamlanması ile birlikte kurulumu tamamlanacak olan teleskobun bilim dünyasına daha etkili ve verimli bir şekilde hizmet vermesi açısından önem arz etmektedir. Bu bağlamda gözlem türünün tahmin edilmesi ve sınıflandırma problemlerinin çözümünde makine öğrenmesi algoritmalarının kullanımının sürece katkı sağlayacağı öngörülmektedir.

Alanyazında astronomik gözlem verileri üzerinden makine öğrenmesi algoritmaları kullanılarak yağış miktarının tahmin edildiği çalışmalara sıklıkla rastlanmaktadır. Örnek bir çalışmada ortalama sıcaklık, çiy noktası sıcaklığı, nem, deniz seviyesi basıncı ve rüzgâr hızı olmak üzere beş faktöre ait 2245 kayıtlık veri seti, 280 örnek üzerinde Karar Ağacı, Naive Bayes, Örüntü Tanıma Sinir Ağı, K En Yakın Komşu algoritması ile test edilmiştir. Çalışma sonucunda K En Yakın Komşu algoritması için %80.7, Karar Ağacı için %80.3 ve Naive Bayes algoritması için de %78.9 başarımler elde edilmiştir (Gupta ve Ghose, 2015). Benzer bir çalışmada yağış, akış ve sıcaklık verilerinden oluşan 731 günlük veri setine Destek Vektör Makineleri ve Karar Ağacı algoritmalarıyla yağış akış ilişkisinin tahmin edilmesi amaçlanmıştır. Çalışma sonucunda Karar Ağacı modellerinin Destek Vektör Makineleri modellerine göre daha iyi performans gösterdiği vurgulanmıştır (Demirci, 2019). Yağış tahminlerinde kullanılan veri setlerinden farklı olarak gece başına 30TB'lık görüntü üretmesi beklenen Büyük Sinoptik Tarama Teleskobu'ndan alınan verilerin işlenmesi ve analizinde karşılaşılan zorluklar da makine öğrenmesi algoritmaları kullanımına olan ihtiyacı artırmaktadır. Bu ihtiyaç doğrultusunda Stensbo-Smidt vd. (2013) çalışmalarında yüksek boyutlu görüntülerden oluşan veri seti ile K En Yakın

Komşu algoritması kullanılarak düşük kırmızıya kaymalı galaksilerin renklerinden belirli bir yıldız oluşum oranını tahmin etmeyi amaçlamışlardır. Çalışma kapsamında kullanılan algoritmanın son teknoloji astronomik modele göre daha iyi performans gösterdiği belirtilmiştir (Stensbo-Smidt, Igel, Zirm, Pedersen, 2013). Benzer bir çalışmada da çoklu dalga boyu verilerinden öznitelik seçmek için Relief isimli bir filtre yaklaşımı uygulanmıştır. Sonrasında nesneleri alt kümeleriyle sınıflandırmak ve öznitelik ağırlıklarını karşılaştırmak amacıyla Naive Bayes algoritması kullanılmıştır. Çalışma sonucunda Naive Bayes algoritmasının aktif galaktik çekirdek adaylarını seçmek için etkili olduğu belirtilmiştir (Zhang, Luo ve Zhao, 2004). Astroitlere ait çok sayıda gözlem verisi için sınıflandırma işleminde temel bileşen analizi yönteminin yetersiz olduğu vurgulanarak diğer çalışmalardan farklı olarak birden fazla ağacın birleşimine dayanan Rastgele Orman algoritması kullanılmıştır. Sekiz farklı sınıfa ayrılan asteroitlerin sınıflandırılmasının amaçlandığı çalışmada mevcut sınıflandırma sonuçlarıyla karşılaştırılmak üzere sekiz asteroit türünün yansıma spektrumları çizilmiş ve sonuçların tutarlılığı vurgulanmıştır. Çalışma sonucunda artan asteroit gözlem verilerinin hızlı bir şekilde sınıflandırılmasında rastgele orman algoritmasının uygulanabilirliği ortaya konulmuştur. (Huang, Ma, Zhao ve Lu, 2016). Benzer şekilde Rastgele Orman algoritması kullanılarak yapılan başka bir çalışmada da ekvatorial koordinatlar, ıraklık açısı, uygun hareket bileşenleri ve fotometrik büyüklükler analiz edilerek %85.3 başarımla elde edilmiştir (Torres, Cantero, Rebassa-Mansergas, Skorobogatov, Jimenez-Esteban, Solano, 2019).

2 YÖNTEM

2.1. Verilerin Toplanması

Çalışma kapsamında eğitim veri setinin oluşturulması amacıyla 14 öz nitelikten oluşan ve 2012-2019 yılları arası günlük gözlem verileri içeren veri seti ATASAM'dan alınmıştır. Elde edilen verilerin sınıflandırılması için Naive Bayes, K En Yakın Komşu, Karar Ağacı ve Rastgele Orman algoritması kullanılmıştır. Yapılan uygulamalarda yüksek başarımlar elde edilmiştir. Sonrasında DAG teleskobunun bulunduğu bölgenin yerel özellikleri ve mevcut gözlem şartları dikkate alınarak gözlem türünün tahmin edilmesi amaçlanarak uzman görüşü alınmıştır. Yapılan görüşmelerde uzmanlara yöneltilen sorular aşağıda sunulmuştur.

1. DAG dikkate alınarak yapılabilecek gözlem türleri nelerdir? (Çıkış değerleri)
2. Astronomik gözlem türüne etki eden faktörler nelerdir? (Giriş değerleri)
3. Her bir gözlem türü için faktörlerin değer aralığı nasıl olmalıdır? (Etiketleme)


Çalışma kapsamında ele alınan gözlem türleri çıkış değerlerini, gözlem türüne etki eden faktörler ise giriş değerlerini ifade etmektedir. ATASAM'dan alınan veri setinde sıcaklık, su buharı ve rüzgâr değerleri bulunurken diğer faktörlere yönelik gözlem verileri bulunmamaktadır. Bu bağlamda günlük olarak değişiklik gösterebilen nem, astronomik görüş (seeing) ve ACI (bulutluluk) değerlerine yönelik anlamlı veri üretilmiştir. Veri üretilirken mevcut değerlerin diğer öz niteliklere göre değişimi dikkate alınmıştır. Ek olarak “nem” değerleri gün içerisinde çeşitlilik gösterebildiğinde 0-80 değerleri arasında rastgele veri üretilerek ilgili sütuna atanmıştır.

2.2. Verilerin Etiketlenmesi

Kullanılan eğitim setinde yer alan veri setinde her bir güne ait gözlem verilerinin uzman görüşü doğrultusunda etiketlenmesi planlansa da uzman görüşü doğrultusunda oluşturulan kural tabanı ile verilerin daha kısa sürede etiketlenmesi sağlanmıştır. Etiketlenen veriler rastgele seçme yöntemi ile yine uzman görüşü alınarak doğrulanmıştır. Bu yöntemin seçilmesi fazla sayıda verinin kullanılmasını sağlamaktadır. Etiketleme amacıyla oluşturulan kurallar ve ağaç yapısı aşağıda verilmiştir. Bu karar ağacı, öncelikle IR (kızılötesi) gözlem yapacak DAG için düzenlenmiş olup; en iyi ve uygun atmosferik koşullarda IR gözlemleri öncelemek amacıyla planlanmıştır. IR gözlem yapılan gecelerde görünür (Visible) gözlemler de yapılabilir ama öncelik IR gözlemlere ayrılmıştır.

Tablo 1. Kural Tabanı

KURAL TABANI
if (ACI is "1") AND (NEM < 40) AND (PWV <= 6) THEN GÖZLEM_TÜRÜ is "IR Spectrum"
if (ACI is "1") AND (NEM < 40) AND (PWV > 6) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "1") AND (NEM >= 40) AND (Seeing <= 1,5) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "1") AND (NEM >= 40) AND (Seeing > 1,5) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "2") AND (NEM < 40) AND (PWV <= 3) THEN GÖZLEM_TÜRÜ is "IR Fotometrik"
if (ACI is "2") AND (NEM < 40) AND (3 < PWV < 6) THEN GÖZLEM_TÜRÜ is "IR Spectrum"
if (ACI is "2") AND (NEM < 40) AND (PWV > 6) AND (Seeing <= 1,5) THEN GÖZLEM_TÜRÜ is "VI Fotometrik"
if (ACI is "2") AND (NEM < 40) AND (PWV > 6) AND (Seeing > 1,5) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "2") AND (NEM > 40) AND (Seeing > 1,5) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "0") OR (NEM > 80) OR (RUZGAR>20) OR (Seeing > 3) OR (Sıcaklık < - 25) GÖZLEM_TÜRÜ is "Gözlem Yok"



Şekil 1. Karar Ağacı

2.3. Naive Bayes Algoritması

Naive Bayes algoritmasında öncelikle eğitim veri seti üzerinden öğrenme gerçekleştirilir. Sonrasında yapılan hesaplama ile olasılığı en yüksek olan değer ilgili sınıfa atanır. Bu hesaplama işlemi formül yardımıyla yapılır (Chandra ve Gupta, 2011'den aktaran Sağbaş ve Ballı, 2016).

$$P(A/B) = \frac{P(B/A) * P(A)}{P(B)}$$

Yukarıdaki formülde:

- $P(A/B)$, B durumunda A'nın gerçekleşme olasılığını,
- $P(B/A)$, A durumunda B'nin gerçekleşme olasılığını,
- $P(A)$, A'nın gerçekleşme olasılığını,
- $P(B)$, B'nin gerçekleşme olasılığını ifade eder (Zobu, 2019).

2.4. K En Yakın Komşu Algoritması

Cover ve Hart tarafından 1967 yılında geliştirilen ve doğrusal olmayan sınıflandırma algoritmalarından biri olan KNN, temelde Öklid uzaklık ölçümlerine dayanır. Burada K değeri en yakın komşuların sayısını ifade eder (Cover ve Hart, 1967). Yeni bir değer için atama işlemi yapılırken K kadar en yakın komşuya olan uzaklık hesaplanır ve yakın olan sınıfa atama yapılır.

2.5. Karar Ağacı Algoritması

Girdi değişkenlerinin birden fazla homojen kümeye bölünmesine dayalı bir makine öğrenmesi algoritması türü olan karar ağaçlarının kullanımı oldukça basittir. Ayrıca istatistiksel bilgi ve analitik altyapı gerektirmemesi kullanıcılara çeşitli avantajlar sunmaktadır. Ek olarak makine öğrenmesi uygulamalarının temelinde bulunan veri ön işleme ve veri temizleme işlemlerini kolaylaştırarak eksik ve aykırı değerlerden etkilenme oranını en alt seviyeye düşürür. (Sullivan, 2017).

2.6. Rastgele Orman Algoritması

Temelde bir vektörün değerlerine bağlı olarak oluşturulan karar ağaçlarının birleşimine dayanan Rastgele Orman algoritması, Breiman (2001) tarafından geliştirilmiştir. Eğitim seti üzerinde her bir ağaç için rastgele seçimler yapılır ve her bir ağacın bağımsız sınıflandırma yapması sağlanır. Sonrasında her bir ağacın yaptığı sınıflandırma değeri bir oy olarak atanır ve sonuç olarak en çok tekrarlanan değer sonuç olarak kabul edilerek atama gerçekleşir. Karar ağaçları birleştirilerek oluşturulan bu orman yapısı ile sınıflandırma problemlerinde daha yüksek başarımın elde edilmesi amaçlanmaktadır (Ercire, 2019).

3. BULGULAR

Çalışma kapsamında teleskopların etkin ve verimli kullanımına katkı sağlamak amacıyla astronomik gözlem kalitesinin Naive Bayes, K en Yakın Komşu, Karar Ağacı ve Rastgele Orman

algoritmalarıyla tahmin edilmesi amaçlanmaktadır. Oluşturulan eğitim setinde yer alan giriş değerleri aşağıda Tablo 2’ de verilmiştir.

Tablo 2. Giriş Değerleri

ACI (Bulutluluk)
H (Nem)
P (PWV)
S (Seeing)
T (Sıcaklık)
Rüzgar

Çıkış değerleri ise iki sınıf için:

- VI (Visible),
- IR (InfraRed),

Dört sınıf için:

- VI Spectrum,
- IR Spectrum,
- VI Photometry,
- IR Photometry şeklinde belirlenmiştir.

İki sınıf için yapılan ilk uygulamada değerler VI = 1, IR = 2 şeklinde, ikinci uygulamada ise VI Spectrum = 1, IR Spectrum = 2, VI Photometry = 3, IR Photometry = 4 şeklinde düzenlenmiştir. Ayrıca veri setinde yer alan verilerin %70’i eğitim için %30’u da test için kullanılmıştır. Tahminler yapılırken veri setinde yer alan çeşitli aylara ait değerler dikkate alınmıştır. Ek olarak kural tabanında da belirtilen ACI değerinin 0, nem oranının 80’den büyük, rüzgar değerinin 20’den büyük, astronomik görüş değerinin 3’den büyük ve sıcaklığı - 25 den küçük olduğu durumlarda gözlem yapılamamaktadır. Bu durum göz önünde bulundurularak gözlem yapılması mümkün olmayan günler eğitim setinden çıkarılmıştır.

İki sınıfa ayrılmış olan veri setinde farklı aylarda gözlem türünün değişiminin gözlemlenmesi amaçlanarak bir yıllık veriler dikkate alınmıştır. İlk uygulamada her bir algoritma için elde edilen başarımlar oranları aşağıda Tablo 3’ de verilmiştir.

Tablo 3. İki Sınıf için Başarım Oranları

Algoritma	Başarım Oranı
Naive Bayes	0.956
K En Yakın Komşu	0.982
Karar Ağacı	0.99
Rastgele Orman	0.99

İki sınıf için yapılan uygulamada 53 gün için gözlem yapılması mümkün olmadığından toplamda 312 gün ele alınmıştır. 261 gün için “VI (1)”, 51 gün için de “IR (2)” değeri elde edilmiştir.

Gözlem türünün 01.01.2012 ve 20.03.2013 tarihleri arasında hemen hemen eşit dağılım gösterdiği gözlemlenirken, diğer aylarda büyük çoğunlukla “VI (1)” değeri elde edilmiştir. Ek olarak aralık ayının son iki haftasında “IR (2)” değerleri ağırlık göstermektedir. Elde edilen sonuç değerleri karşılaştırıldığında Naive Bayes algoritması için 5, KNN için de 6 günün farklılık gösterdiği gözlemlenmiştir.

Tablo 4. Dört Sınıf için Başarım Oranları

Algoritma	Başarım Oranı
Naive Bayes	0.787
K En Yakın Komşu	0.751
Karar Ağacı	0.997
Rastgele Orman	0.991

Dört sınıf içerisinde yer alan veri setinde 126 değerin VI Spectrum, 56 değerin IR Spectrum, 10 değerin VI Photometry, 120 gün için de IR Photometry değeri elde edilmiştir. Elde edilen veriler içerisinde düşük sayıda olan “VI Photometry” gözlem türüne ait günlerin kış aylarında bulunduğu görülmüştür. Tahmin edilen değerler incelendiğinde K En Yakın Komşu algoritması için 75 değerin farklılık gösterdiği görülmüştür. Naive Bayes algoritması için ise 60 değerin farklılık gösterdiği görülmüştür. Farklılık gösteren gözlem türünün KNN için büyük çoğunlukla IR Photometry, Naive Bayes için de IR Spectrum gözlem türüne ait günlerde görüldüğü gözlemlenmiştir.

4. TARTIŞMA ve SONUÇ

VI ve IR olmak üzere iki çıkış değerinden oluşan veri seti ile yapılan uygulamalarda elde edilen başarımlar oranları, literatürde yer alan benzer çalışmalara göre yüksek performans göstermektedir. Ancak iki çıkış değeri ile yapılan uygulamalar ve dört çıkış değeri ile uygulamalar karşılaştırıldığında Naive Bayes ve K En Yakın Komşu algoritmasının başarımlarının düşüş gösterdiği görülmüştür. Ancak ağaç yapısına dayalı olan algoritmaların sınıf sayısı değişikliğinde ciddi bir farklılık göstermediği görülmüştür. Özellikle Karar Ağacı algoritmasından iki sınıf için 0.998, dört sınıf için 0.997 başarımlar elde edilmiştir. Buna bağlı olarak sınıf sayısından en az etkilenen algoritmanın Karar Ağacı olduğu söylenebilir. Dört sınıf ile yapılan uygulamalarda özellikle Naive Bayes algoritmasının “IR Spectrum” gözlem türüne sahip günlerde eksiklik gösterdiği görülmüştür.

Önceki çalışmada (Yavuz ve Karaman, 2020) 12 nitelikten oluşan veri setinde çıkış değerleri kümeleme algoritmalarından olan K Ortalama yöntemiyle yapılmış ve tahmin için Naive Bayes, KNN algoritmaları kullanılmıştır. Bu bağlamda gözlem verilerinin tahmininde makine öğrenmesi algoritmalarının uygulanabilirliğini ortaya koymak amaçlanmıştır. Gözlem türlerini ortaya koymak amaçlanarak K Ortalama yöntemiyle 1, 2, 3, 4 olmak üzere temsili değerler üretilmiştir. Bu değerler gerçek gözlem türlerini ifade etmemektedir. Bu çalışmada farklı olarak gözlem türünün etiketlenmesi amacıyla uzman görüşüne başvurulmuştur. Her bir güne ait gözlem verileri uzman görüşü doğrultusunda oluşturulan kural tabanı ile etiketlenmiştir. Ayrıca Doğu Anadolu Gözlemevi

projesi kapsamında inşa edilen teleskobun verimliliğini artırmak amaçlanarak 1, 2, 3, 4 olmak üzere sayısal değerlere sahip gözlem türleri ele alınmıştır. Tahmin edilen 1 değeri VI Spectrum, 2 değeri IR Spectrum, 3 değeri VI Fotometrik, 4 değeri IR Fotometrik gözlem türünü ifade etmektedir. Bu gözlem türleri de yine uzman görüşü doğrultusunda belirlenmiştir. Kurallara bağlı yapılan etiketleme işlemiyle bu alanda hâsıl olan anlamlı veri seti ihtiyacının giderilmesi ve çeşitli eğitim veri setlerinin oluşturulması sağlanabilir.

Son olarak yapılan uygulamalarda elde edilen başarımların değerleri, geleceğe yönelik tahminlere ihtiyaç duyulan çalışmalarda makine öğrenmesi algoritmalarının uygulanabilirliğini ortaya koymaktadır. Doğu Anadolu Gözlemevi'nin bulunduğu yerel gözlem değerleri kullanılarak yapılan tahmin çalışmalarıyla teleskobun bilim dünyasında etkili ve verimli kullanımına yönelik yapılacak çalışmalara katkı sağlayabilecektir.

KAYNAKLAR

- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Boffin, H. M., Jerabkova, T., Mérand, A., & Stoeck, F. (2019). Report on the ESO Workshop "Artificial Intelligence in Astronomy". *Msngr*, 178, 61-63.
- Chandra, B., ve Gupta, M. (2011). Robust approach for estimating probabilities in Naïve-Bayes Classifier for gene expression data. *Expert Systems with Applications*, 38(3), 1293-1298.
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.
- Demirci, M. (2019). Destek Vektör Makineleri ve M5 Karar Ağacı Yöntemleri Kullanılarak Yağış Akışı İlişkisinin Tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(3), 1113-1124.
- Ercire, M. (2019). Kısa Süreli Güç Kalitesi Bozulmalarının Dalgacık Analizi ve Rastgele Orman Yöntemi ile Sınıflandırılması. Yüksek Lisans Tezi. Fen Bilimleri Enstitüsü, Kütahya Dumlupınar Üniversitesi, Türkiye.
- Gupta, D., & Ghose, U. (2015). A comparative study of classification algorithms for forecasting rainfall. In 2015 4th International Conference on Reliability, Infocom Technologies and Optimization (ICRITO)(trends and future directions) (pp. 1-6). IEEE.
- Huang, C., Ma, Y. H., Zhao, H. B., & Lu, X. P. (2016). Spectral Classification of Asteroids by Random Forest. *Acta Astronomica Sinica*, 57(5), 526-533.
- Sağbaş, E. A., & Ballı, S. (2016). İnsan Aktivitelerinin Bilek Hareketleri Kullanılarak Tahmin Edilmesi. *Akıllı Teknoloji & Akıllı Yönetim*, 52.
- Stensbo-Smidt, K., Igel, C., Zirm, A., & Pedersen, K. S. (2013). Nearest neighbour regression outperforms model-based prediction of specific star formation rate. In 2013 IEEE international conference on big data (pp. 141-144). IEEE.
- Sullivan, W. (2017). *Machine Learning For Beginners Guide Algorithms: Supervised & Unsupervised Learning. Decision Tree & Random Forest Introduction*. Healthy Pragmatic Solutions Inc.
- Torres, S., Cantero, C., Rebassa-Mansergas, A., Skorobogatov, G., Jiménez-Esteban, F. M., & Solano, E. (2019). Random Forest identification of the thin disc, thick disc, and halo Gaia-DR2 white dwarf population. *Monthly Notices of the Royal Astronomical Society*, 485(4), 5573-5589.



- Yavuz, Ö. Ç., & Karaman, E. Astronomik Gözlem Kalitesi Tahmininde Makine Öğrenmesi Algoritmalarının Kullanımı. Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi, 5(1), 12-19.
- Zhang, Y. X., Luo, A. L., & Zhao, Y. H. (2004, September). An automated classification algorithm for multiwavelength data. In Optimizing Scientific Return for Astronomy through Information Technologies (Vol. 5493, pp. 483-490). International Society for Optics and Photonics.



MARMARA
ÜNİVERSİTESİ