

Astronomi Alanında Yaygın Kullanılan Makina Öğrenmesi ve Uygulamalarına Örnekler

Mustafa Özkan¹ , Cenk Kayhan² *

¹Enformatik Anabilim Dalı, Fen Bilimleri Enstitüsü, Ankara Üniversitesi, Ankara, Türkiye

²Astronomi ve Uzay Bilimleri Bölümü, Fen Fakültesi, Erciyes Üniversitesi, Kayseri, Türkiye

Accepted: April 19, 2021. Revised: April 7, 2021. Received: March 12, 2021.

Özet

Gelişen teknoloji ile birlikte astronomi alanında veri toplama araçlarının çeşitliliği ve kapasitesi de gelişti. Toplanan veri miktarının artması ile birlikte bu alandaki veri madenciliği, büyük veri uygulamaları, makine öğrenmesi ve yapay zeka uygulamalarının sayısı her geçen gün artıyor. Astronomi alanındaki hesaplamalarda da en önemli kısım verinin yapısının ortaya çıkarılması ve değerlendirilmesidir. Makine öğrenmesi günümüzde bu hesaplamalarda ön plana çıkarak önemli bir uygulama alanı bulunuyor. Bu alanda kullanılan en yaygın makine öğrenmesi yöntemleri denetimli öğrenmede Destek Vektör Makineleri (*Support Vector Machines*), Rastgele Orman (*Random Forests*) ve Yapay Sinir Ağları (*Artificial Neural Network*) iken denetimsiz öğrenmede Kendi Kendine Sınıflandırma/Düzenleme Haritası (*Self-Classifying/Organizing Map*), Temel Bileşen Çözümlemesi (*Principal Component Analysis*)'dir. Birbirinden farklı makine öğrenmesi yöntemleri gök cisimlerinin sınıflandırılmasından, gözlemsel özelliklerinin değerlendirilmesine ve modellerle uyum değerlendirmesine kadar birden fazla alt başlıkta uygulama buluyor. Bunlar arasında ön plana çıkan çarpıcı örnekler; gökadalara sınıflandırılması, güneş fiziği araştırmaları, değişen yıldız türlerinin belirlenmesi, yeni gezegen keşifleri ve yıldızların temel parametrelerinin belirlenmesiyle yıldız iç yapı ve evrimlerinin ortaya çıkarılması ve modellenmesi üzerinedir. Bu çalışma astroinformatik ve astroistatistik alanında Türkçe kaynak oluşturmak adına son beş yıl içerisinde astronomi alanında güncel yazılmış makalelerden bir derleme sunmaktadır.

Abstract

With the developing technology, the variety and capacity of data collection tools in astronomy have also improved. With the increase in the amount of data collected, the number of data mining, big data applications, machine learning and artificial intelligence applications in this field is increasing day by day. The most important part in the calculations in astronomy is revealing and evaluating the structure of the data. Machine learning stands out in these calculations and has an important application area nowadays. The most common supervised and unsupervised machine learning methods used in astronomy are Support Vector Machines, Random Forests and also Artificial Neural Network for supervised learning and Self-Classifying/Organizing Map, Principal Component Analysis for unsupervised learning methods, respectively. Different machine learning methods find applications in more than one subsections, from the classification of celestial objects, to the evaluation of their observational properties, and to the evaluation of their models. Striking applications among these are; classification of galaxies, determination of variable stars, solar physics researches, exoplanet discoveries, and revealing of stellar parameters and modelling of stellar interior structure and evolution. This study presents a compilation of recent articles in astronomy in the last five years to create a Turkish material in astroinformatics and astrostatistics.

Anahtar Kelimeler: methods: statistical – methods: data analysis – software: data analysis

1 Giriş

Çağlar boyunca gökyüzünü merak eden insanlar, karanlık gecelerde gökyüzünde ışık saçan gök cisimlerini gözlemeye çalıştı. İlk başta oldukça parlak gök cisimlerini gözleyip aklında tutarak onları bulunduğu topluluğa aktardı. Zamanla bu alandaki bilgi birikimi artan insanlar, daha farklı cisimleri öğrenme ve bu gök cisimlerinin ışık değişimi gibi davranışlarını anlamaya kadar ilerledi. Teleskobun keşfi ve göz dışında veri kaydeden aygıtların gelişmesiyle bir anda gözlenen gök cisimi sayısı arttı. Bu gök cisimlerinin neler olduğunu çözümlmek ise zamanla biriken veri sayesinde oldu. Teleskop ve aygıt teknolojisinin gelişmesi ile birlikte toplanan veri miktarı her geçen gün artıyor. Günümüzde astronomi alanında yapılan gözlemler sonucunda toplanan veri miktarı, geçtiğimiz yüzyıllar boyunca toplanan veriden çok daha

fazladır (Garofalo et al. 2017; Reis et al. 2021). İnşa edilen (örneğin; Vera Rubin Gözlemevi adıyla bilinen *Large Synoptic Survey Telescope*, *LSST: 2020 Tyson & Angel (2001)*) veya inşası devam eden (Ör. *Extremely Large Telescope*, *E-ELT: 2025 Vernin et al. (2011)*; *Doğu Anadolu Gözlemevi*, *DAG: 2023 Yeşilyaprak & Yerli (2013)*; vb.) büyük teleskop projeleriyle birlikte toplanacak olan verinin miktarı ise günümüz tahminlerini geride bırakacak gibi görünüyor (Çizelge 1).

Veri toplayan araçların gelişmesiyle birlikte astronomi alanındaki veri miktarı oldukça arttı. Işığın dalga - parçacık özelliklerini ayrı ayrı kullanan farklı dalga boylarında uygulanan gözlemsel yöntemler, elde edilen verilerin çeşitlenmesini sağladı. Bu nedenle bu alandaki veri madenciliği, büyük veri uygulamaları, makine öğrenmesi ve yapay zeka uygulamalarının sayısı her geçen gün artıyor. Bu alanda kullanılan uygulamalarla birlikte geliştirilen yöntemler ise astroinformatik ana başlığı altında toplanıyor (Borne 2010). Astroinformatik olarak ad-

* cenkkayhan@erciyes.edu.tr

Çizelge 1. Astronomi alanındaki büyük gözlem projeleriyle elde edilen/edilecek verinin yapı gösterimi (Garofalo et al. 2017; Kremer et al. 2017).

Teleskop		Veri Boyutu	Verinin Günlük Aktarım Miktarı	Veri Çeşitliliği
Sloan Sayısal Gökyüzü Taraması	(SDSS)	50 TB	200 GB	Görüntü, sınıflandırma, kırmızıya kayma verileri
Gaia Uzay Teleskobu	(GAIA)	100 TB	50 GB	100'den fazla temel parametre
Geniş Alan Tarama Teleskobu ve Hızlı Cevap Sistemi	(Pan-STARRS)	5 PB	5 TB	Görüntü ve sınıflandırma verileri
Vera Rubin Gözlemevi	(LSST)	60 PB	10 TB	Görüntü ve sınıflandırma verileri
Kilometre Kare Dizgesi	(SKA)	3 ZB	150 TB	Görüntü, sınıflandırma, kırmızıya kayma verileri

landırılan yeni bir disiplin olan bu alanda verinin oluşturulması, tanınması ve desteklenmesi gerçekleştirilir. Astroenformatik temel anlamda doğal olarak kendiliğinden dağılan verinin sınıflandırılması, tanımlanması, astronomik açıdan indirgenmesi, veri madenciliği ile uygulamalar barındırması, makine öğrenmesi ile birlikte görselleştirilip istatistiksel yöntemlere uyarlanmasını ifade eder (Borne 2010; Feigelson et al. 2021). Astroenformatiğin ana konularından biri olan astroistatistik ise elde edilen bilimsel verinin değerlendirilmesi ve kuramsal modellerle karşılaştırılmasını sağlar. Değerlendirme yapılırken istatistik biliminin sağladığı yöntemleri kullanır. Model ile kıyaslamada ise bilimsel sorunun ortaya konulmuş olması ve kıyaslanacak niceliklerin istatistiksel bilgilerine ihtiyaç duyar (Feigelson & Babu 2012).

Astroenformatik içerisinde en çok kullanılan veri analiz yöntemi ise makine öğrenmesidir. Makine öğrenmesi en basit tanımıyla karmaşık veri setlerinden ayırt edilmesi zor kılıpların tespit edilerek çeşitli istatistiksel, olasılıksal ve optimizasyon tekniklerinin uygulandığı yapay zekanın bir dalıdır (Cruz & Wishart 2006). Örneğin gökada oluşum ve evriminden yıldızların sınıflandırılmasına kadar birçok farklı alanda makine öğrenmesi uygulamaları gerçekleştirilir.

Bu çalışma astroenformatik ve astroistatistik alanında Türkçe kaynak oluşturmak adına son beş yıl içerisinde astronomi alanında güncel yazılmış makalelerden bir derleme sunması amacıyla hazırlandı. Bölüm 2'de astronomik verinin tanımı ve içeriği ile son beş yıl içerisinde ağırlıklı olarak kullanılan makine öğrenmesi yöntem ve modelleri sunuldu. Astronomi alanındaki makine öğrenme uygulamaları ile ilgili ayrıntılar ve son beş yılda yapılan çeşitli uygulama örnekleri ise Bölüm 3'de yer alıyor.

2 Astronomik Veri ve Yaygın Kullanılan Makine Öğrenmeleri

Astronomik veri olarak tanımlanan veriler gök cisimlerinin bünyesel temel parametreleri, gözlem yoluyla elde edilen gözlemsel/deneySEL nicelikleri ve sınıflandırma verileridir (Samet 1990). Gözlemsel yolla elde edilen veriler sürekli veya değişken veri olarak adlandırılarak düzenli olarak belirli bir aralıkta kayıt edilen gerçek sayılardan ve ölçüm hatalarından oluşan veri dizileridir (Way et al. 2012). Gök cisimlerinin bünyesel temel parametreleri ise sıra değeri olarak tanımlanan belirli bir düzen barındıran ancak kesikli verilerden oluşur. Örneğin yıldızlardaki tayf sınıflaması buna uygun bir örnektir (Borne 2010). Sınıflandırma verileri ise daha çok sayısal değer yerine isimlendirme gibi sıfat içerir. Gökadaların sarmal, eliptik veya düzensiz olarak sınıflandırılması bu duruma basit olarak örnek verilebilir (Lupton et al. 2001).

Verilerin değerlendirilmesinde kullanılan makine öğrenme

yöntemleri denetimli öğrenme (*bir insan tarafından veriye öğretilme ya da model yoluyla verinin kavranması*) ve denetimsiz öğrenme (*herhangi bir öğretilme durumu olmadan algoritmanın kendi kendine veriyi keşfetmesi*) şeklinde iki ana sınıfa ayrılır. Bu yöntemlerden ilki tanımlamaya ve betimlemeye dayanırken diğeri daha çok öngörü üzerinden değerlendirme yapar. Denetimli öğrenmede güvenilirlik oranı yapılan öğrenme üzerinden gerçekleşir. Ancak denetimsiz öğrenmede algoritmanın kendisi veriyi keşfedeceğinden güvenilirlik veri kalitesi ile sınırlıdır (Saha et al. 2015). Bu iki ana sınıfın dışında geçiş sınıfı olarak adlandırılan ve temelde iki ana yöntemin parçalarından oluşan yarı-denetimli makine öğrenmesi ve tamamen denetimden uzak ayrı bir sınıf olarak da pekiştirmeli öğrenme (*Reinforcement Learning*) bulunur (Schwartz 2014).

Son beş yıl içinde yapılan çalışmalar tarandığında pekiştirmeli öğrenme ve yarı-denetimli öğrenmenin astronomi araştırmalarında yaygın olarak kullanılmadığı fark edildi. Bununla birlikte bu iki öğrenme ayrımına bu tür çalışmada yer almamaktadır. Astronomi alanında bu tür uygulama yapmak isteyenler için yarı-denetimli makine öğrenmesi ve pekiştirmeli makine öğrenmesinin ayrıntıları için (Albalade & Minker 2013; Jo 2021) incelenebilir.

Denetimli makine öğrenmesinde en yaygın kullanılan algoritmalar: Yapay Sinir Ağları (*Artificial Neural Network*), Naif Bayes (*Naive Bayes*), Karar Ağacı (*Decision Tree*), Doğrusal ve taşınimsal bağlantım (*Linear and Logistic regression*), Kesikli Doğrusal Çözümleme (*Linear Discriminant Analysis*), K En Yakın Komşuluğu (*K Nearest Neighbour*), Rastgele Orman (*Random Forests*), ve Destek Vektör Makineleri (*Support Vector Machines*)'dir (Yang 2019).

Yapay sinir ağları, insan beynini taklit eden yapısıyla önemli makine öğrenmesi algoritmaları arasında yer alır. Burada sinir olarak betimlenen, modelde matematik işleme karşılık gelir ve girdi verisine bağlı bir niceliği işler (Gurney 1995). Astronomi alanı dahil birçok çalışma alanında kullanılır (Warner & Misra 1996). Aynı zamanda Yapay Sinir Ağları denetimsiz öğrenmeye de dönüştürülebilir ve Evrimsel Sinir Ağları (*Evolutionary Neural Network*) olarak adlandırılır. Evrimsel ve Yapay Sinir Ağları 10'dan fazla alt alana ayrılır. Bu alt başlıklardan Kıvrımsal Sinir Ağı (*Convolution Neural Network*), Derin Sinir Ağı (*Deep Neuron Network*) ve Çekişmeli Sinir Ağı (*Generative Ad-versarial Network*) en sık kullanılanlar arasındadır (Aggarwal 2018).

Naif Bayes (*Naive Bayes*), doğrusal ve taşınimsal bağlantım, Bayes ve klasik istatistik analizde kullanılan yöntemler arasında yer alıp benzer şekilde denetimli makine öğrenmesinde de uygulama alanı bulur (Lim 2020). Naif Bayes, Bayesian kuramının temel alan bir yöntemdir. Genellikle verinin genel bir eğiliminin olduğu az veri kümelerinde etkilidir (Bhatia 2019). Doğrusal ve taşınimsal bağlantım ise daha çok model ve gözlem pa-

rameterlerinin en uyumlu olduğu ortak değerleri bulmada, güvenilirlik saptamalarında ve modelin denetlenmesinde kullanılır (Ivezic et al. 2019).

K En Yakın Komşuluğu Yöntemi, Kesikli Doğrusal Çözümleme, Karar Ağacı, Rastgele Orman ve Destek Vektör Makinesi sınıflandırma temelli algoritmalar içerir. K En Yakın Komşuluğu ve Kesikli Doğrusal Çözümleme, veri noktalarını birbiri arasındaki Öklidyen temelli yakınlıklara ve aynı zamanda tüm veri grubunun ortak noktasına göre aitlik taraması yapar (Zhu & Nandi 2014). Görüntü tanımlama sınıflamasında en çok tercih edilen yöntemler arasında yer alır (Barber 2012). Karar Ağacı ise bir öngörü modeli olup adım adım ilerleyerek verilen değişkenleri ilgili kısıtlamalara göre denetleyip eleyerek sonuca ulaşır. Birden fazla birbiriyle ilişkisi olmayan "karar ağaç" topluluğundan ise Rastgele Orman oluşur (Breiman 2001). Karar Ağacı ve Rastgele Orman yaygın olarak sınıflandırmada kullanılsa da aynı zamanda bağlanım hesaplarında da tercih edilir. Destek Vektör Makinesi ise ayrıık iki veri dizisi arasındaki belirgin ayrımı ortaya çıkarmaya yarayan bir öğrenme biçimidir (Vapnik 1963). Burada işlem vektör uzayında gerçekleştirilir.

Denetimsiz makine öğrenmesi ise kullanılma amacına göre üç grupta toplanır. Bu algoritmalar denetimli öğrenmede de benzer şekilde kümeleme yapmaya yarayan modeller ile ayrııklık saptama ve gizil değişkenleri bulma üzerinedir (Albalate & Minker 2013). Bu biçimdeki en yaygın makine öğrenmesi algoritmaları şu şekildedir: Kendi Kendine Sınıflandırma/Düzenleme Haritası (Self-Classification/Organizing Map), Kalıtımsal Algoritma (Genetic Algorithm) ve Temel Bileşen Çözümlemesi (Principal Component Analysis).

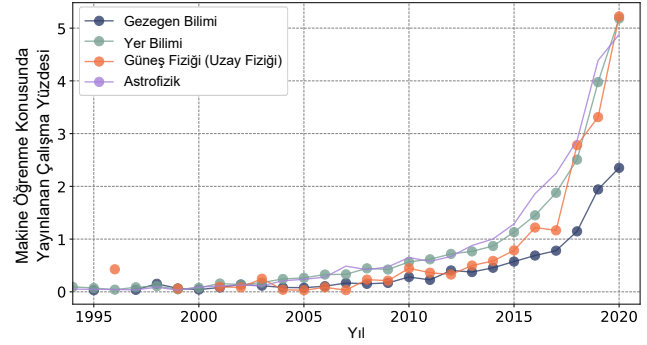
Kendi Kendine Sınıflandırma/Düzenleme Haritası (Self-Classifying/Organizing Map) algoritması, Yapay Sinir Ağ modellerini temel alan bir yapıda olup etiketsiz yani tanımlanmamış verinin kendi başına kısacası denetimsiz öğrenme ile iki ve daha az boyutlu yapıya indirgeme yapılarak benzerliklerin haritalanmasına dayanır (Kanevski et al. 2009). Adından da anlaşılacağı üzere özellikle sınıflandırma çalışmalarında sıklıkla kullanılır.

Kalıtımsal Algoritma (Genetic Algorithm) kalıtımsal evrim modeline benzer biçimde doğal seçim ile yani deneme-eleme yoluyla en iyi çözümü bulmayı amaçlar. Bu aşamada verinin başlangıçtaki dağılımı, aralarındaki uyum işlevi, seçim, geçiş aşaması ve ardından evrilmeye aşamalarını sırasıyla izler ve en iyi çözümü bulana kadar sürekli devam eder. Rastgele bir süreç olduğu için özellikle varsayımlardan kaynaklı eğilimlerden uzaklaşmak için tercih edilir (Vose 1999).

Temel Bileşen Çözümlemesi (Principal Component Analysis) boyut indirgemede kullanılan, parametreye ihtiyaç duymayan bir algoritmadan oluşur ve denetimsiz öğrenme olduğu için veriyi kendi keşfederek herhangi bir başlangıç noktası verilmesine ihtiyaç duymaz (Syms 2008). Bu modelin en iyi yanlarından biri gürültülü veri dizilerinde etkili bir çözüm sunmasıdır (Ivezic et al. 2019).

3 Astronomideki Yaygın Makine Öğrenmesi Uygulamaları

Astronomi alanındaki makine öğrenmesi konuları ve araçları diğer bilim dallarına kıyasla daha fazla çeşitlenerek birden fazla alt dala ayrıldı (Şekil 1). Astronomi alanında makine öğrenmesi kullanılarak yalnızca son beş yılda 3000'e yakın çalışma hakemli ve hakemsiz dergilerde yayınlanarak toplamda 17000'e yakın atıf aldı (bkz. NASA ADS veri tabanı; abs:"machine learning" and year:2015-2021 and collection:"astronomy" biçiminde aratıldığında çıkan kaynak sayıları). Bu duruma astronomideki veri miktarı ve çeşitliliğinin çok önemli boyutlara ulaşmasına



Şekil 1. Yıllara göre astronomi alanındaki makine öğrenmesi konulu yayınların dağılım yüzdesi (Azari et al. 2020, Fig.1'den Türkçeye çevrildi). 2000 öncesinde yalnızca birkaç konu çalışılırken son 15 yılda çeşitlilik ve yayın sayısındaki farkların ön plana çıktığı görülmüştür.

neden oldu. Özellikle veri sayısındaki artış sonucunda bu verilerin değerlendirilmesi için yapılacak hesaplamaların basit görev şeklinde verilememesinin bu konudaki payı büyüktür. Bunun yanı sıra kimi zaman modellerin verinin bir kısmından yalıtılmış olması ve çoklu görev seçeneklerinin kısıtlı olması da makine öğrenmesi konularına yönelmede etkilidir (Vilalta 2018; Surana et al. 2021). Bu nedenle var olan sorunun çözülmesi ya da bilimsel yöntemin uygulanmasındaki hesaplamaların ayrıntılandırılması gereklidir. Hesaplama işleminde en önemli kısım verinin yapısının ortaya çıkarılması ve değerlendirilmesidir. Bu nedenle makine öğrenmesi astronomi alanında birçok uygulama alanı bulmakla birlikte çoklu alt dallara ayrılır.

Kullanılan en yaygın makine öğrenme modellerinin başında Yapay ve Evrimsel Sinir Ağları gelir (Baron 2019). Yapay ve Evrimsel Sinir Ağları (Taylor & Diaz 2007; Škoda & Adam 2020) astronomi alanında bir gözlem yöntemi olan uyarlamalı (adaptif) optikten (örneğin, Swanson et al. 2021) kuramsal gökda sınıflandırmasına (örneğin, Scaife & Porter 2021) kadar gözlem ve kuramda geniş bir yelpazede kendine uygulama alanı bulunur (Lahav 1994). Alt başlıklarının astronomideki uygulamalarına Kıvrımsal Sinir Ağı için Chifu & Gafeira (2021); Jaeger et al. (2021); Gafeira et al. (2021); Khachatryan (2021); Leicht et al. (2021); Becker et al. (2021), Derin Sinir Ağı için Busca & Balland (2018); Caldeira et al. (2019); Gómez et al. (2020); Jia et al. (2020); Morawski et al. (2021) ve Çekişmeli Sinir Ağı için ise Guo et al. (2019); Reiman & Göhre (2019); Rissaki et al. (2020); Gan et al. (2021) örnek olarak verilebilir.

Genellikle sınıflandırma temelli algoritmaların astronomideki uygulamaları Kesikli Doğrusal Çözümleme için Sayres et al. (2011); Saha et al. (2015); Manning et al. (2016); Süveges et al. (2017); Rácz et al. (2018); Akras et al. (2019); de Diego et al. (2020); Nevin et al. (2021), K En Yakın Komşuluğu için Kügler et al. (2015); Gao (2016); Luken et al. (2019); Chan & Stott (2021); Curran et al. (2021), Rastgele Orman için Farrell et al. (2015); Huang et al. (2016); Liu et al. (2017); Plewa (2018); Torres et al. (2019); Hernandez Vivanco et al. (2020); Mucsh et al. (2021), Destek Vektör Makinaları için ise Boucheron et al. (2015); Marton et al. (2016); Hartley et al. (2017); Wang et al. (2021); Poliszczuk et al. (2019); Zhang et al. (2020); Ahmadzadeh et al. (2021) incelenebilir.

İstatistiksel analiz ve kümeleme kullanılan uygulamalar için ise Naif Bayes için Broos et al. (2011); du Buisson et al. (2015); Lochner et al. (2016); Vavilova et al. (2017); Arsioli &

Çizelge 2. Son beş yıl içerisinde yaygın olarak kullanılan makine öğrenmesinin astronomi alanındaki Araştırma Alanları, Makine Öğrenmesi Türü (Denetimli Öğrenme - DÖ ve Denetimsiz Öğrenme - DsÖ) ve Modelleri.

Araştırma Alanları	Tür	Model	Kaynak
Uzaklık Ölçümü (yıldız, kuazar, vb.)	DÖ	Doğrusal Regresyon K En Yakın Komşuluğu Yapay Sinir Ağı	Elliott et al. (2016) Gomes et al. (2018) Elyiv et al. (2020)
Yıldız Temel Parametreleri (Kütle, Sıcaklık, vb)	DÖ	Rastgele Orman Kıvrımsal Sinir Ağı Derin Sinir Ağı	Jin-Meng et al. (2021); Lu et al. (2021) Fabbro et al. (2018); Sedaghat et al. (2021) Pan & Li (2016); Li et al. (2017)
Yıldız İç Yapısı ve Evrimi	DÖ DsÖ	Rastgele Orman Yapay Sinir Ağı Kalıtımsal Algoritma	Breton et al. (2019) Sharma et al. (2020) Macdonald et al. (2017); Vargas et al. (2021)
Küme Üyelik/Nüfus Çalışmaları	DÖ	K En Yakın Komşuluğu Rastgele Orman	Peña Ramírez et al. (2021); Agarwal et al. (2021) Gao (2018); Jadhav et al. (2021)
Sıkışık Gök cisimlerinin Oluşum ve Evrimi	DÖ	Taşınımsal Bağlanım Rastgele Orman	Mahabal et al. (2017); Huppenkothen et al. (2017) Wang et al. (2019); Singh & Pathak (2020)
Gökada Astronomisi ve Evrimi	DÖ DsÖ	Destek Vektör Makineleri Yapay Sinir Ağı Karar Ağaçları Rastgele Orman Kalıtımsal Algoritma	Jones & Singal (2017); Barchi et al. (2017) Bluck et al. (2020); Baxter et al. (2021) Barchi et al. (2020); Teimoorinia et al. (2021b) Yesuf et al. (2020); Mucesh et al. (2021) Oehm et al. (2017); Han et al. (2021)
Çoklu Dalgaboyu Gözlemleri	DÖ	Karar Destek Makineleri	An et al. (2019); Cohn & Battaglia (2020)
Gezegenli Sistemlerin Özellikleri	DsÖ DÖ	Çekişmeli Sinir Ağı Kıvrımsal Sinir Ağları	Zingales & Waldmann (2018) Osborn et al. (2020); Rao et al. (2021)
Yıldız ve Gezegen Oluşumu	DÖ	Rastgele Orman Kıvrımsal Sinir Ağları	Bellinger et al. (2016); Delli Veneri et al. (2018) Kounkel & Covey (2019); Wells & Norman (2020)
Evrenin Yapısı ve Oluşumu	DÖ	Kıvrımsal Sinir Ağları Yapay Sinir Ağları	Schmelzle et al. (2017); La Plante & Ntampaka (2019) Wang et al. (2021)
Işık Eğrisi Analizi	DÖ DsÖ	Yapay Sinir Ağları Kıvrımsal Sinir Ağları Kalıtımsal Algoritma	Cheng et al. (2020a); Bellinger et al. (2020) Alshehhi et al. (2020); Olmschenk et al. (2021) Carpintero & Melita (2018); Csizmadia (2020)
Gökyüzündeki Anlık Gelişen Olayların Yakalanması ve Takibi	DÖ	Kıvrımsal Sinir Ağları Naif Bayes	Gómez et al. (2020); Agarwal et al. (2020); Ruhe et al. (2021) du Buisson et al. (2015)
Değişen Yıldızların Saptanması	DÖ DsÖ	Kesikli Doğrusal Çözümleme Rastgele Orman Kendi Kendine Sınıflama Haritası Temel Bileşen Çözümlemesi	Süveges et al. (2017) Pawlak et al. (2019) Armstrong et al. (2016); Pérez-Galarce et al. (2021) Süveges et al. (2017); Eyer et al. (2019)
Titreşen ve Zonklayan Yıldızların Analizi	DÖ	Rastgele Orman Yapay ve Kıvrımsal Sinir Ağları	Bugnet et al. (2018); Le Saux et al. (2019) Hon et al. (2017); Hendriks & Aerts (2019)
Çekimsel Dalgaların Sınıflandırılması	DÖ DsÖ	Yapay Sinir Ağları Çekişmeli Sinir Ağı	Vretinaris et al. (2020); Yang (2021) Wong et al. (2020); McGinn et al. (2021)
Gözlemsel Veri Madenciliği	DÖ DsÖ	Karar Ağaçları Taşınımsal Bağlanım Destek Vektör Makineleri Kendi Kendine Sınıflandırma Haritası	Norris (2017); Niederhausen (2018) Beitia-Antero et al. (2018) Solarz et al. (2020); Dorn-Wallenstein et al. (2021) Galvin et al. (2020); Teimoorinia et al. (2021a)
Güneş Fiziği	DÖ DsÖ	Yapay Sinir Ağları Taşınımsal Bağlanım Çekişmeli Sinir Ağı Temel Bileşen Çözümlemesi Kendi Kendine Sınıflandırma Haritası Kalıtımsal Algoritma	Shin et al. (2016); Keese et al. (2020) Domijan et al. (2019); Korsós et al. (2021) Shin et al. (2020); Yu et al. (2021) Papaioannou et al. (2018); Takalo (2021) Amaya et al. (2020); Schilliro & Romano (2021b) Yang et al. (2018); Kawai & Imada (2021)
Güneş Sistemi Araştırmaları (Asteroitler, Kuyruklu yıldızlar vb.)	DÖ	Destek Vektör Makineleri Yapay Sinir Ağları Rastgele Orman	Bellutta (2017); Roberts et al. (2020) Hefe et al. (2020); Carruba et al. (2021) Huang et al. (2017); Garton et al. (2021)

Dedin (2020), Karar Ağacı için (Golob et al. 2021), Doğrusal ve taşınimsal bağlanım için ise Saz Parkinson et al. (2016); Smirnov & Markov (2017); Beitia-Antero et al. (2018); Miettinen (2018); Nauman & Nättälä (2019); Cheng et al. (2020b); Kodikara & McHenry (2020); Korsós et al. (2021) örnek olarak verilebilir.

Denetimli öğrenmeye kıyasla astronomi alanında daha az uygulama barındıran denetimsiz öğrenme uygulamaları örnekleri ise Kendi Kendine Sınıflandırma/Düzenleme Haritası için Carrasco Kind & Brunner (2014); Speagle & Eisenstein (2017); Rahmani et al. (2018); Longo et al. (2019); Karafistan & Gemikonaklı (2020); Schilliro & Romano (2021a), Kalıtsal Algoritma için Hogan et al. (2015); Heinis et al. (2016); Carpintero & Melita (2018); Tárano et al. (2019); Dai et al. (2020); Nayak & Saha (2021) ve Temel Bileşen Çözümlemesi için Cerqueira et al. (2015); Peth et al. (2016); Modak et al. (2017); Gallant et al. (2018); Damiano et al. (2019); Okoda et al. (2020); Navarete et al. (2021) önemli çalışmalar arasında yer alır.

Makine öğrenmesinin astronomi alanındaki uygulamalarında kullanılan gökcisimleri ve araştırma alanlarına yönelik bilgiler yakın bir zamanda Siemiginowska et al. (2019) tarafından güncel olarak derlendi. Bu çalışma kapsamında Siemiginowska et al. (2019) tarafından sunulan çizelge temel alınarak, son beş yılda yapılan çalışmalar ile birlikte, geniş bir ölçekte tarama yapılarak Çizelge 2'de astronomi araştırma alanları, makine öğrenmesi türü ve model/algoritmaları birlikte sunuldu.

4 Sonuç

Günümüzde makine öğrenmesi algoritmaları sayesinde veri değerlendirmeleri birçok alanda arttı. Veri miktarı ve çeşitliliğinin çok olduğu astronomi alanı ise makine öğrenme uygulamaları için iyi bir deneme/uygulama alanı haline geldi. Astronomi alanındaki veri içeriği gökcisimlerinin türleri, gözlem yöntemine göre değişen gözlemsel parametreleri ve kuramlar sonucunda oluşan temel parametreleridir. Bu niceliklerin birbiriyle doğrudan ilişkisi olmakla birlikte sınıflandırmada birden fazla parametre birlikte değerlendirilmelidir. Parametrelerin kendi içlerinde tutarlılıkları ile var olan koşullara ve gözlem yöntemlerine göre yapıları da değişir. Bu nedenle ayırım ya da değerlendirme yapılırken parametrelerin değişimi de göz önüne alınmalıdır. Sonuç olarak, astronomi alanında elde edilen veri durgun bir yapının aksine dinamik yapıdadır. Bundan dolayı hesaplamalı işlemlerde özellikle öğrenilmiş verinin de dinamik bir yapıya büründürülmesi gerekir. Modeller yardımıyla oluşturulan ve öğretilen veri daha sonra farklı değişkenlerle karıştırılır. Böylece ortaya öğrenilmiş veri ile terbiye edilen daha bilgili bir öğrenme yöntemi ortaya çıkar. Bu durumda kullanılacak denetimli ve denetimsiz öğrenmede bazı farklılar olacaktır. Özellikle denetimsiz öğrenmede kapsamlı görevler herhangi bir veri tanımı/etiketi yapılmadan rahatlıkla verilebilirken denetimli öğrenmeye kıyasla oldukça karmaşık bir algoritma yapısı olması ve denetimli öğrenmeden güvenilirlik açısından daha belirsiz sonuçlar vermesi nedeniyle uygulama olanağı kısıtlı kalmaktadır. Denetimli öğrenme ise veri tanımlaması/etiketlenmesinin mümkün olmadığı karmaşık veri dizilerinde verilen görevi yerine getirememesi ve çok daha fazla hesaplama zamanı içermesi açısından bazı olumsuzluklara sahiptir. Ancak daha güvenilir olması ve aynı zamanda denetlenebilir olması bakımından çok fazla tercih edilir.

Günümüzde makine öğrenmesi kullanılarak elde edilen sonuçların daha çok genel modellerle gerçekleştirildiğini vurgula-

mak isteriz. Bu nedenle elde edilen sonuçların makine öğrenmesi dışında oluşturulan diğer modellerle (evrimsel kodlar, simülasyonlar vb.) ve astrofiziksel ilişkilerle denetlenmesi gerekmektedir. Makine öğrenmesi bir diğer yandan bu tür modellerin de gelişmesine katkı sağlayacaktır. Makine öğrenmesinin en önemli katkılarının şüphesiz olarak büyük verinin sınıflanması ya da modellenmesinde önemli bir zaman kazandırması ve insan hatası gibi sonucu olumsuz etkileyecek süreçleri gidermesi olduğu unutulmamalıdır. Sonuç olarak, makine öğrenmesi bilimsel üretim yapacak bir yapı değil aksine bilimsel çalışmalarda kullanılacak bir araçtır.

Birbirinden farklı makine öğrenmesi yöntemleri gök cisimlerinin sınıflandırılmasından, gözlemsel özelliklerinin değerlendirilmesine ve hatta modellerle uyum değerlendirmesine kadar birden fazla alt başlıkta uygulama buluyor. Bunlar arasında ön plana çıkan çarpıcı örnekler gökadalara sınıflandırılması, güneş fiziği araştırmaları, değişen yıldız türlerinin belirlenmesi, yeni gezegen keşifleri ve yıldızların temel parametrelerinin belirlenmesiyle yıldız iç yapı ve evrimlerinin ortaya çıkarılması ve modellenmesi üzerinedir. Son beş yıl içerisinde yapılan çalışmalar incelendiğinde en çok kullanılan denetimli ve denetimsiz makine öğrenmesi algoritmaları ise Yapay ve Evrimsel Sinir Ağları, Rastgele Orman ve Kendi kendine Sınıflandırma/Düzenleme Haritasıdır. Bunların astronomi alanında en çok kullanıldığı uygulama ise sınıflandırma çalışmalarıdır.

Makine öğrenmesi ile ilgilenenlerin yoğun veriye ihtiyaç duyduğu bilinir. Yakın gelecekte inşa edilecek/faaliyete geçecek birçok farklı dalgaboyunda gözlem yapma yeteneğine sahip olacak yerleşik ve uzay teleskopları sayesinde şimdiye kadar görülmemiş ölçekte verinin alınacağı bekleniyor. Bu açıdan astronomi alanı makine öğrenmesinin ihtiyacı olan yoğun veriyi fazlasıyla karşılayacaktır. Bu bakımdan astronomi ile makine öğrenmesi iyi bir uyum içinde birbirini tamamlayan alanlar gibi görünür. Bu birliktelik sonucunda ileride önemli gelişmelerin olacağı kaçınılmazdır. Özellikle son on yıldaki bilgisayar teknolojilerindeki gelişmeler hem yazılım hem de işlem gücündeki ciddi artış bu durumu daha da ivmelendirecektir. Bu nedenle bu alana yönelecek gökbilimcilerin ve makine öğrenmesi uygulayıcılarının önemli kazançları olacağını düşünüyoruz.

Bu çalışma ile hesaplamalı bir bilim dalı olan astronomi alanındaki makine öğrenmesi uygulamaları üzerinde duruldu. Konunun kapsamı bakımından son beş yılda yapılan çalışmalar odağa alındı. Çalışmalar ve makine öğrenmesi ile ilgili genel bir özet verilerek bu alanda dilimize bir metin kazandırılması amaçlandı.

Teşekkür ve Bilgilendirme

Bu çalışmada kullanılan makine öğrenmesi ile ilgili terim ve kavramların Türkçe karşılıkları Türkiye Bilişim Derneği tarafından hazırlanan **Bilişimde Özenli Türkçe Çevrimiçi Sözlüğünden** alındı. Bu sözlüğün seçilme nedeni ise güncel olması ve genel olarak bilişim alanında çalışma yapanların yaygın bir biçimde kaynak olarak kullanmasıdır. Bu çalışma yapılırken kullanılan sözlüğün son güncellemesi 8 Mart 2021 tarihinde yapılmıştır.

Çalışmanın daha düzenli ve daha anlaşılır bir yapıya kavuşması konusunda hakemlerin katkılarına ve yönlendirmelerine teşekkür ederiz.

Bu çalışmayı, lisans eğitimi alırken bize sabırla bilgisayar ve kodlama öğreten, yakın bir zamanda ansızın kaybettiğimiz değerli hocamız Ahmet Devlen'e adıyoruz.

Kaynaklar

- Agarwal D., Aggarwal K., Burke-Spolaor S., Lorimer D. R., Garver-Daniels N., 2020, *MNRAS*, 497, 1661
- Agarwal M., Rao K. K., Vaidya K., Bhattacharya S., 2021, *MNRAS*, 502, 2582
- Aggarwal C. C., 2018, *Neural Networks and Deep Learning: Textbook*. Springer Nature Press, pp 1–52, doi:10.1007/978-3-319-94463-0
- Ahmadzadeh A., Aydin B., Georgoulis M. K., Kempton D. J., Mahajan S. S., Angryk R. A., 2021, preprint, (arXiv:2103.07542), ADS
- Akras S., Leal-Ferreira M. L., Guzman-Ramirez L., Ramos-Larios G., 2019, *MNRAS*, 483, 5077
- Albalade C. C., Minker W., 2013, *Semi-Supervised and Unsupervised Machine Learning*. John Wiley and Sons, Ltd, pp 1–14, doi:https://doi.org/10.1002/9781118557693.ch1
- Alshehhi R., Rodenbeck K., Gizon L., Sreenivasan K. R., 2020, *A&A*, 640, A41
- Amaya J., Dupuis R., Innocenti M. E., Lapenta G., 2020, *Frontiers in Astronomy and Space Sciences*, 7, 66
- An F. X., et al., 2019, *ApJ*, 886, 48
- Armstrong D. J., et al., 2016, *MNRAS*, 456, 2260
- Arsioli B., Dedin P., 2020, *MNRAS*, 498, 1750
- Azari A. R., et al., 2020, preprint, (arXiv:2007.15129), ADS
- Barber D., 2012, *Bayesian Reasoning and Machine Learning*. Cambridge University Press, doi:10.1017/CBO9780511804779
- Barchi P. H., da Costa F. G., Sautter R., Moura T. C., Stalder D. H., Rosa R. R., de Carvalho R. R., 2017, preprint, (arXiv:1705.06818), ADS
- Barchi P. H., et al., 2020, *Astronomy and Computing*, 30, 100334
- Baron D., 2019, preprint, (arXiv:1904.07248), ADS
- Baxter D. C., Cooper M. C., Fillingham S. P., 2021, *MNRAS*, 503, 1636
- Becker B., Vaccari M., Prescott M., Grobler T., 2021, *MNRAS*, 503, 1828
- Beitia-Antero L., Yáñez J., de Castro A. I. G., 2018, *Experimental Astronomy*, 45, 379
- Bellinger E. P., Angelou G. C., Hekker S., Basu S., Ball W. H., Guggenberger E., 2016, *ApJ*, 830, 31
- Bellinger E. P., Kanbur S. M., Bhardwaj A., Marconi M., 2020, *MNRAS*, 491, 4752
- Bellutta D., 2017, preprint, (arXiv:1706.08915), ADS
- Bhatia P., 2019, *Data Mining and Data Warehousing: Principles and Practical Techniques*. Cambridge University Press
- Bluck A. F. L., Maiolino R., Sánchez S. F., Ellison S. L., Thorp M. D., Piotrowska J. M., Teimoorinia H., Bundy K. A., 2020, *MNRAS*, 492, 96
- Borne K. D., 2010, *Earth Science Informatics*, 3, 5
- Boucheron L. E., Al-Ghraibah A., McAteer R. T. J., 2015, *ApJ*, 812, 51
- Breiman L., 2001, *Machine Learning*, 45, 5
- Breton S. N., Bugnet L., Santos A. R. G., Le Saux A., Mathur S., Pallé P. L., García R. A., 2019, in Di Matteo P., Creevey O., Crida A., Kordopatis G., Malzac J., Marquette J. B., N'Diaye M., Venot O., eds, SF2A-2019: Proceedings of the Annual meeting of the French Society of Astronomy and Astrophysics. p. Di (arXiv:1906.09609)
- Broos P. S., Getman K. V., Povich M. S., Townsley L. K., Feigelson E. D., Garmire G. P., 2011, *ApJS*, 194, 4
- Bugnet L., García R. A., Davies G. R., Mathur S., Corsaro E., Hall O. J., Rendle B. M., 2018, *A&A*, 620, A38
- Busca N., Balland C., 2018, preprint, (arXiv:1808.09955), ADS
- Caldeira J., Wu W. L. K., Nord B., Avestruz C., Trivedi S., Story K. T., 2019, *Astronomy and Computing*, 28, 100307
- Carpintero D. D., Melita M., 2018, *A&A*, 620, A88
- Carrasco Kind M., Brunner R. J., 2014, *MNRAS*, 438, 3409
- Carruba V., Aljbaae S., Domingos R. C., Barletta W., 2021, *MNRAS*, 504, 692
- Cerqueira A. H., Reyes-Iturbide J., De Colle F., Vasconcelos M. J., 2015, *AJ*, 150, 45
- Chan M. C., Stott J. P., 2021, *MNRAS*, 503, 6078
- Cheng Q.-B., Feng C.-J., Zhai X.-H., Li X.-Z., 2020a, preprint, (arXiv:2004.04382), ADS
- Cheng T.-Y., et al., 2020b, *MNRAS*, 493, 4209
- Chifu I., Gafeira R., 2021, *ApJ*, 910, L10
- Cohn J. D., Battaglia N., 2020, *MNRAS*, 491, 1575
- Cruz J. A., Wishart D. S., 2006, *Cancer Informatics*, 2, 117693510600200030
- Csizmadia S., 2020, *MNRAS*, 496, 4442
- Curran S. J., Moss J. P., Perrott Y. C., 2021, *MNRAS*, 503, 2639
- Dai X., Wang H., Inhester B., 2020, *ApJ*, 896, 155
- Damiano M., Micela G., Tinetti G., 2019, *ApJ*, 878, 153
- Delli Veneri M., Cavuoti S., Brescia M., Riccio G., Longo G., 2018, preprint, (arXiv:1805.06338), ADS
- Domijan K., Bloomfield D. S., Pitié F., 2019, *Sol. Phys.*, 294, 6
- Dorn-Wallenstein T. Z., Davenport J. R. A., Huppenkothen D., Levesque E. M., 2021, preprint, (arXiv:2102.02829), ADS
- Elliott J., de Souza R. S., Krone-Martins A., Cameron E., Ishida E. E. O., Hilbe J., 2016, in Napolitano N. R., Longo G., Marconi M., Paolillo M., Iodice E., eds, *Astrophysics and Space Science Proceedings Vol. 42, The Universe of Digital Sky Surveys*. p. 91 (arXiv:1507.01293), doi:10.1007/978-3-319-19330-413
- Elyiv A. A., Melnyk O. V., Vavilova I. B., Dobrycheva D. V., Karachentseva V. E., 2020, *A&A*, 635, A124
- Eyer L., Süveges M., De Ridder J., Regibo S., Mowlavi N., Holl B., Rimoldini L., Bouchy F., 2019, *PASP*, 131, 088001
- Fabbro S., Venn K. A., O'Briain T., Bialek S., Kielty C. L., Jahandar F., Monty S., 2018, *MNRAS*, 475, 2978
- Farrell S. A., Murphy T., Lo K. K., 2015, *ApJ*, 813, 28
- Feigelson E. D., Babu G. J., 2012, *Modern Statistical Methods for Astronomy With R Applications*. Cambridge University Press
- Feigelson E. D., de Souza R. S., Ishida E. E. O., Jogesh Babu G., 2021, *Annual Review of Statistics and Its Application*, 8, 493
- Gafeira R., Orozco Suárez D., Milic I., Quintero Noda C., Ruiz Cobo B., Uitenbroek H., 2021, preprint, (arXiv:2103.09651), ADS
- Gallant D., Gallo L. C., Parker M. L., 2018, *MNRAS*, 480, 1999
- Galvin T. J., et al., 2020, *MNRAS*, 497, 2730
- Gan F. K., Bekki K., Hashemizadeh A., 2021, preprint, (arXiv:2103.09711), ADS
- Gao X.-H., 2016, *Research in Astronomy and Astrophysics*, 16, 184
- Gao X.-H., 2018, *Ap&SS*, 363, 232
- Garofalo M., Botta A., Ventre G., 2017, in Brescia M., Djorgovski S. G., Feigelson E. D., Longo G., Cavuoti S., eds, *Proceedings of the International Astronomical Union, IAU Symposium Vol. 325, Astroinformatics*. pp 345–348 (arXiv:1703.05084), doi:10.1017/S1743921316012813
- Garton T. M., Jackman C. M., Smith A. W., Yeakel K. L., Maloney S. A., Vandegriff J., 2021, *Frontiers in Astronomy and Space Sciences*, 7, 104
- Glob A., Sawicki M., Goulding A. D., Coupon J., 2021, *MNRAS*, 503, 4136
- Gomes Z., Jarvis M. J., Almosallam I. A., Roberts S. J., 2018, *MNRAS*, 475, 331
- Gómez C., Neira M., Hernández Hoyos M., Arbeláez P., Forero-Romero J. E., 2020, *MNRAS*, 499, 3130
- Guo P., et al., 2019, *MNRAS*, 490, 5424
- Gurney K., 1995, *Introduction to Neural Networks*. UCL Press, p. 235
- Han B., Qiao L.-N., Chen J.-L., Zhang X.-D., Zhang Y.-X., Zhao Y.-H., 2021, *Research in Astronomy and Astrophysics*, 21, 017
- Hartley P., Flamary R., Jackson N., Tagore A. S., Metcalf R. B., 2017, *MNRAS*, 471, 3378
- Hefele J. D., Bortolussi F., Portegies Zwart S., 2020, *A&A*, 634, A45
- Heinis S., et al., 2016, *ApJ*, 821, 86
- Hendriks L., Aerts C., 2019, *PASP*, 131, 108001

- Hernandez Vivanco F., Smith R., Thrane E., Lasky P. D., 2020, *MNRAS*, 499, 5972
- Hogan R., Fairbairn M., Seeburn N., 2015, *MNRAS*, 449, 2040
- Hon M., Stello D., Yu J., 2017, *MNRAS*, 469, 4578
- Huang C., Ma Y. H., Zhao H. B., Lu X. P., 2016, *Acta Astronomica Sinica*, 57, 526, [ADS](#)
- Huang C., Ma Y.-h., Zhao H.-b., Lu X.-p., 2017, *Chinese Astron. Astrophys.*, 41, 549
- Huppenkothen D., Heil L. M., Hogg D. W., Mueller A., 2017, *MNRAS*, 466, 2364
- Ivezic Z., Connolly A. J., VanderPlas J. T., Gray A., 2019, *Statistics, Data Mining, and Machine Learning in Astronomy: A Practical Python Guide for the Analysis of Survey Data*, Updated Edition. Princeton University Press, p. 560
- Jadhav V. V., Pennock C. M., Subramaniam A., Sagar R., Nayak P. K., 2021, *MNRAS*, 503, 236
- Jaeger L., et al., 2021, preprint, ([arXiv:2103.09673](#)), [ADS](#)
- Jia P., Liu Q., Sun Y., 2020, *AJ*, 159, 212
- Jin-Meng Y., Xiao-Qing W., min Z., 2021, *New Astron.*, 86, 101568
- Jo T., 2021, *Machine Learning Foundations - Supervised, Unsupervised and Advanced Learning*. Springer Nature Press, p. 391, [doi:10.1007/978-3-030-65900-4](#)
- Jones E., Singal J., 2017, *A&A*, 600, A113
- Kanevski M., Pozdnoukhov A., Pozdnoukhov A., Timonin V., 2009, *Machine Learning for Spatial Environmental Data: Theory Applications and Software*. EPFL Press dist. by CRC Press, pp 218–238
- Karafistan A., Gemikonakli E., 2020, *Astronomische Nachrichten*, 341, 471
- Kawai T., Imada S., 2021, *ApJ*, 906, 2
- Keese A. M., Pinto V., Coughlan M., Lennox C., Mahmud M. S., Connor H. K., 2020, *Frontiers in Astronomy and Space Sciences*, 7, 72
- Khachatryan H. G., 2021, preprint, ([arXiv:2104.01014](#)), [ADS](#)
- Kodikara G. R. L., McHenry L. J., 2020, *Icarus*, 345, 113719
- Korsós M. B., Erdélyi R., Liu J., Morgan H., 2021, *Frontiers in Astronomy and Space Sciences*, 7, 113
- Kounkel M., Covey K., 2019, *AJ*, 158, 122
- Kremer J., Stensbo-Smidt K., Gieseke F., Steenstrup Pedersen K., Igel C., 2017, preprint, ([arXiv:1704.04650](#)), [ADS](#)
- Kügler S. D., Polsterer K., Hoecker M., 2015, *A&A*, 576, A132
- La Plante P., Ntampaka M., 2019, *ApJ*, 880, 110
- Lahav O., 1994, *Vistas in Astronomy*, 38, 251
- Le Saux A., Bugnet L., Mathur S., Breton S. N., García R. A., 2019, in Di Matteo P., Creevey O., Crida A., Kordopatis G., Malzac J., Marquette J. B., N'Diaye M., Venot O., eds, *SF2A-2019: Proceedings of the Annual meeting of the French Society of Astronomy and Astrophysics*. p. Di ([arXiv:1906.09611](#))
- Leicht O., Baldauf T., Fergusson J., Shellard P., 2021, *MNRAS*, 503, 2137
- Li X.-R., Pan R.-Y., Duan F.-Q., 2017, *Research in Astronomy and Astrophysics*, 17, 036
- Lim H., 2020, in Tallon-Ballesteros A. J., Chen C., eds, *Frontiers in Artificial Intelligence and Applications Vol. 332, Machine Learning and Artificial Intelligence*. IOS Press, pp 146–151, [doi:10.3233/FAIA200776](#)
- Liu C., Deng N., Wang J. T. L., Wang H., 2017, *ApJ*, 843, 104
- Lochner M., McEwen J. D., Peiris H. V., Lahav O., Winter M. K., 2016, *ApJS*, 225, 31
- Longo G., Merényi E., Tiño P., 2019, *PASP*, 131, 100101
- Lu Y. L., Angus R., Curtis J. L., David T. J., Kiman R., 2021, *AJ*, 161, 189
- Luken K. J., Norris R. P., Park L. A. F., 2019, *PASP*, 131, 108003
- Lupton R., Gunn J. E., Ivezić Z., Knapp G. R., Kent S., 2001, in Harnden F. R. J., Primini F. A., Payne H. E., eds, *Astronomical Society of the Pacific Conference Series Vol. 238, Astronomical Data Analysis Software and Systems X*. p. 269 ([arXiv:astro-ph/0101420](#))
- Macdonald D., De Marco O., Lagadec E., Ma J., Chesneau O., 2017, preprint, ([arXiv:1705.00120](#)), [ADS](#)
- Mahabal A., Sheth K., Gieseke F., Pai A., Djorgovski S. G., Drake A., Graham M., the CSS/CRTS/PTF Collaboration 2017, preprint, ([arXiv:1709.06257](#)), [ADS](#)
- Manning E. M., Holland B. R., Ellingsen S. P., Breen S. L., Chen X., Humphries M., 2016, *Publ. Astron. Soc. Australia*, 33, e015
- Marton G., Tóth L. V., Paladini R., Kun M., Zahorecz S., McGehee P., Kiss C., 2016, *MNRAS*, 458, 3479
- McGinn J., Messenger C., Heng I. S., Williams M. J., 2021, preprint, ([arXiv:2103.01641](#)), [ADS](#)
- Miettinen O., 2018, *Ap&SS*, 363, 197
- Modak S., Chattopadhyay A. K., Chattopadhyay T., 2017, preprint, ([arXiv:1703.05532](#)), [ADS](#)
- Morawski F., Bejger M., Cuoco E., Petre L., 2021, preprint, ([arXiv:2103.07688](#)), [ADS](#)
- Mucesh S., et al., 2021, *MNRAS*, 502, 2770
- Nauman F., Nättälä J., 2019, *A&A*, 629, A89
- Navarete F., Damineli A., Steiner J. E., Blum R. D., 2021, *MNRAS*, 503, 270
- Nayak P., Saha R., 2021, preprint, ([arXiv:2102.06569](#)), [ADS](#)
- Nevin R., et al., 2021, preprint, ([arXiv:2102.02208](#)), [ADS](#)
- Niederhausen H., 2018, PhD thesis, State University of New York at Stony Brook
- Norris R. P., 2017, *Publ. Astron. Soc. Australia*, 34, e007
- Oehm W., Thies I., Kroupa P., 2017, *MNRAS*, 467, 273
- Okoda Y., Oya Y., Sakai N., Watanabe Y., Yamamoto S., 2020, *ApJ*, 900, 40
- Olmschenk G., et al., 2021, preprint, ([arXiv:2101.10919](#)), [ADS](#)
- Osborn H. P., et al., 2020, *A&A*, 633, A53
- Pan R. Y., Li X. R., 2016, *Acta Astronomica Sinica*, 57, 379, [ADS](#)
- Papaioannou A., et al., 2018, *Sol. Phys.*, 293, 100
- Pawlak M., et al., 2019, *MNRAS*, 487, 5932
- Peña Ramírez K., González-Fernández C., Chené A. N., Ramírez Alegría S., 2021, *MNRAS*, 503, 1864
- Pérez-Galarce F., Pichara K., Huijse P., Catelan M., Mery D., 2021, *MNRAS*, 503, 484
- Peth M. A., et al., 2016, *MNRAS*, 458, 963
- Plewa P. M., 2018, *MNRAS*, 476, 3974
- Poliszczuk A., et al., 2019, *PASJ*, 71, 65
- Rácz I. I., Balázs L. G., Horvath I., Tóth L. V., Bagoly Z., 2018, *MNRAS*, 475, 306
- Rahmani S., Teimoorinia H., Barmby P., 2018, *MNRAS*, 478, 4416
- Rao S., Mahabal A., Rao N., Raghavendra C., 2021, *MNRAS*, 502, 2845
- Reiman D. M., Göhre B. E., 2019, *MNRAS*, 485, 2617
- Reis I., Rotman M., Poznanski D., Prochaska J. X., Wolf L., 2021, *Astronomy and Computing*, 34, 100437
- Rissaki A., Pavlou O., Fotakis D., Papadopoulos V., Efstathiou A., 2020, preprint, ([arXiv:2012.06331](#)), [ADS](#)
- Roberts D. A., Karimabadi H., Sipes T., Ko Y.-K., Lepri S., 2020, *ApJ*, 889, 153
- Ruhe D., Kuiack M., Rowlinson A., Wijers R., Forré P., 2021, preprint, ([arXiv:2103.15418](#)), [ADS](#)
- Saha S., Agrawal S., R M., Bora K., Routh S., Narasimhamurthy A., 2015, preprint, ([arXiv:1504.07865](#)), [ADS](#)
- Samet H., 1990, *The Design and Analysis of Spatial Data Structures*. Addison-Wesley Longman Publishing Co., Inc., USA
- Sayres C. C., Subasavage J. P., Bergeron P., Davenport J. R. A., AISayyad Y., 2011, in *American Astronomical Society Meeting Abstracts #217*. p. 341.01
- Saz Parkinson P. M., Xu H., Yu P. L. H., Salvetti D., Marelli M., Falcone A. D., 2016, *ApJ*, 820, 8
- Scaife A. M. M., Porter F., 2021, *MNRAS*, 503, 2369
- Schilliro F., Romano P., 2021a, *MNRAS*, 503, 2676
- Schilliro F., Romano P., 2021b, *MNRAS*, 503, 2676
- Schmelzle J., Lucchi A., Kacprzak T., Amara A., Sgier R., Réfrégier A., Hofmann T., 2017, preprint, ([arXiv:1707.05167](#)), [ADS](#)

- Schwartz H. M., 2014, Multi-Agent Machine Learning: A Reinforcement Approach. John Wiley and Sons C.
- Sedaghat N., Romaniello M., Carrick J. E., Pineau F.-X., 2021, *MNRAS*, 501, 6026
- Sharma K., et al., 2020, *MNRAS*, 496, 5002
- Shin S., Lee J.-Y., Moon Y.-J., Chu H., Park J., 2016, *Sol. Phys.*, 291, 897
- Shin G., Moon Y.-J., Park E., Jeong H., Lee H., Bae S.-H., 2020, *ApJ*, 895, L16
- Siemiginowska A., et al., 2019, *BAAS*, 51, 355, *ADS*
- Singh A., Pathak K. N., 2020, preprint, ([arXiv:2011.14388](https://arxiv.org/abs/2011.14388)), *ADS*
- Smirnov E. A., Markov A. B., 2017, *MNRAS*, 469, 2024
- Solarz A., et al., 2020, *A&A*, 642, A103
- Speagle J. S., Eisenstein D. J., 2017, *MNRAS*, 469, 1186
- Surana S., Wadadekar Y., Oberoi D., 2021, preprint, ([arXiv:2102.12712](https://arxiv.org/abs/2102.12712)), *ADS*
- Süveges M., et al., 2017, *A&A*, 603, A117
- Swanson R., Lamb M., Correia C. M., Sivanandam S., Kutulakos K., 2021, *MNRAS*, 503, 2944
- Syms C., 2008, in Jørgensen S. E., Fath B. D., eds., Encyclopedia of Ecology. Academic Press, Oxford, pp 2940–2949, [doi:10.1016/B978-008045405-4.00538-3](https://doi.org/10.1016/B978-008045405-4.00538-3)
- Takalo J., 2021, preprint, ([arXiv:2103.16862](https://arxiv.org/abs/2103.16862)), *ADS*
- Tárano A. M., Wheeler L. F., Close S., Mathias D. L., 2019, *Icarus*, 329, 270
- Taylor M., Diaz A. I., 2007, in Vallenari A., Tantaló R., Portinari L., Moretti A., eds, Astronomical Society of the Pacific Conference Series Vol. 374, From Stars to Galaxies: Building the Pieces to Build Up the Universe. p. 105 ([arXiv:0709.2990](https://arxiv.org/abs/0709.2990))
- Teimoorinia H., Shishehchi S., Tazwar A., Lin P., Archinuk F., Gwyn S. D. J., Kavelaars J. J., 2021a, *AJ*, 161, 227
- Teimoorinia H., Jalilkhany M., Scudder J. M., Jensen J., Ellison S. L., 2021b, *MNRAS*, 503, 1082
- Torres S., Cantero C., Rebassa-Mansergas A., Skorobogatov G., Jiménez-Esteban F. M., Solano E., 2019, *MNRAS*, 485, 5573
- Tyson A., Angel R., 2001, in Clowes R., Adamson A., Bromage G., eds, Astronomical Society of the Pacific Conference Series Vol. 232, The New Era of Wide Field Astronomy. p. 347
- Vapnik V., 1963, *Automation and Remote Control*, 24, 774
- Vargas F., De Colle F., Brethauer D., Margutti R., Bernal C. G., 2021, preprint, ([arXiv:2102.12581](https://arxiv.org/abs/2102.12581)), *ADS*
- Vavilova I. B., Dobrycheva D. V., Vasylenko M. Y., Elyiv A. A., Melnyk O. V., Khramtsov V., 2017, preprint, ([arXiv:1712.08955](https://arxiv.org/abs/1712.08955)), *ADS*
- Vernin J., et al., 2011, *PASP*, 123, 1334
- Vilalta R., 2018, in Journal of Physics Conference Series. p. 052014 ([arXiv:1812.10403](https://arxiv.org/abs/1812.10403)), [doi:10.1088/1742-6596/1085/5/052014](https://doi.org/10.1088/1742-6596/1085/5/052014)
- Vose M. D., 1999, *The Simple Genetic Algorithm Foundations and Theory*. MIT Press
- Vretinakis S., Stergioulas N., Bauswein A., 2020, *Phys. Rev. D*, 101, 084039
- Wang Y., Pan Z., Zheng J., Qian L., Li M., 2019, *Ap&SS*, 364, 139
- Wang G.-J., Ma X.-J., Xia J.-Q., 2021, *MNRAS*, 501, 5714
- Warner B., Misra M., 1996, *The American Statistician*, 50, 284
- Way M., Scargle J., Ali K., Srivastava S., 2012, *Advances in Machine Learning and Data Mining for Astronomy*. Chapman and Hall/CRC Press
- Wells A. I., Norman M. L., 2020, preprint, ([arXiv:2011.01358](https://arxiv.org/abs/2011.01358)), *ADS*
- Wong K. W. K., Contardo G., Ho S., 2020, *Phys. Rev. D*, 101, 123005
- Yang X.-S., 2019, in , Introduction to Algorithms for Data Mining and Machine Learning. Academic Press, pp 91–108, [doi:10.1016/B978-0-12-817216-2.00012-0](https://doi.org/10.1016/B978-0-12-817216-2.00012-0)
- Yang T., 2021, preprint, ([arXiv:2103.01923](https://arxiv.org/abs/2103.01923)), *ADS*
- Yang Y., Yang H., Bai X., Zhou H., Feng S., Liang B., 2018, *PASP*, 130, 104503
- Yesuf H. M., Faber S. M., Koo D. C., Woo J., Primack J. R., Luo Y., 2020, *ApJ*, 889, 14
- Yeşilyaprak C., Yerli S., 2013, in Başal M., ed., Türkiye'deki Teleskoplarla Bilim Sempozyumu. pp 137–139
- Yu X., Xu L., Yan Y., 2021, *Sol. Phys.*, 296, 56
- Zhang S., et al., 2020, *ApJS*, 248, 15
- Zhu Z., Nandi A., 2014, *Machine Learning for Modulation Classification*. John Wiley and Sons, Ltd, pp 81–95, [doi:10.1002/9781118906507.ch6](https://doi.org/10.1002/9781118906507.ch6)
- Zingales T., Waldmann I. P., 2018, *AJ*, 156, 268
- de Diego J. A., et al., 2020, *A&A*, 638, A134
- du Buisson L., Sivanandam N., Bassett B. A., Smith M., 2015, *MNRAS*, 454, 2026
- Škoda P., Adam F., 2020, *Knowledge Discovery in Big Data from Astronomy and Earth Observation*. Elsevier

Access:M21-0102: *Turkish J.A&A* — Vol.2, Issue 1.