



Derin Öğrenme ve Transfer Öğrenme Yöntemleri Kullanarak Değişen Yıldızlarda Sınıflandırma*

Emrullah KUŞTAŞI^{1*}, Mete YAĞANOĞLU²

¹Atatürk Üniversitesi, TÜRKİYE

²Atatürk Üniversitesi, TÜRKİYE

Doi: 10.55024/buyasambid.1501877

MAKALE BİLGİSİ

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 15.06.2024

Düzeltilme tarihi: 01.07.2024

Kabul tarihi: 02.07.2024

Yayın tarihi: 07.07.2024

Anahatar Kelimeler:

Yapay Zekâ, Makine Öğrenmesi,

Derin Öğrenme, Transfer

Öğrenme, Astrofizik,

Astroenformatik

*¹ Emrullah KUŞTAŞI

E-mail address:

emrullahkustasi@gmail.com

Orcid: 0009-0008-4962-9623

² Mete YAĞANOĞLU

E-mail address:

yaganoglu@atauni.edu.tr

Orcid: 0000-0003-3045-169X

ÖZET

Değişen yıldızların sınıflandırılması, geleneksel yöntemlerle bazen zorlu bir süreç olabilir. Gökbilimcilerin, genellikle yıldızların parlaklık eğrilerini ve diğer fiziksel özelliklerini analiz ederek sınıflandırma yaptıkları süreç, zaman alıcı ve zahmetli olabilir. Transfer öğrenimi yaklaşımı, bu noktada önemli bir rol oynayabilir. Bu çalışma ile gökbilimcilerin yıldız sınıflandırması yaparken daha az sayıda veri etiketlemesi yaparak, çalışmalarını yapmalarını sağlayıp, zaman alıcı ve zahmetli bir sürecin kısaltılması amaçlanmıştır. Transfer öğrenme için bir derin sinir ağı eğitilmiş ve bu modelin performansı diğer makine öğrenmesi yöntemleriyle de karşılaştırılmıştır. Model eğitiminde kullanılan veri setleri, CoRoT hedefleri için yapılan çalışmalardan elde edilmiş veri setleridir. Bu veri setleri CoRoT hedeflerinin ışık eğrileriyle yapılan hesaplamalarından oluşur. Transfer öğrenme için eğitilen temel model metrikleri incelendiğinde doğruluk, duyarlılık, hassasiyet ve f1-skor değerlerinin %94 olduğu bulunmuştur. Değişen yıldızların sınıflandırılmasında transfer öğrenimi yaklaşımı kullanıldığında, daha önce sınıflandırılmış yıldızların bilgileri ve özellikleri yeni yıldızların sınıflandırılmasında kullanılabilir. Çalışmadan elde edilen temel modelin astronomi alanında farklı problemler ve farklı veri setleri için yeniden kullanılabilir olması ve bu alanda çalışan araştırmacılara katkı sağlaması beklenmektedir.

2024 Batman Üniversitesi. Her hakkı saklıdır.

*Bu makale 2-4 Mayıs 2024 tarihleri arasında Batman Üniversitesi'nde düzenlenen Uluslararası Bilişim Kongresi'nde 2024 (IIC2024) sunulan 'Derin Öğrenme ve Transfer Öğrenme Yöntemleri Kullanarak Değişen Yıldızlarda Sınıflandırma' isimli bildiriden türetilmiştir

Classification Of Variable Stars Using Deep Learning and Transfer Learning Methods

Emrullah KUŞTAŞI^{1*}, Mete YAĞANOĞLU²

¹Atatürk University, TURKEY

²Atatürk University, TURKEY

Doi: 10.55024/buyasambid.1501877

ARTICLE INFO

Article Type: Research Article

Article history:

Received: 15.06.2024

Received in revised form:
01.07.2024

Accepted: 02.07.2024

Available online: 07.07.2024

Keywords:

Artificial Intelligence, Machine Learning, Deep Learning, Transfer Learning, Astrophysics, Astroinformatics.

¹ Emrullah KUŞTAŞI

E-mail address:

emrullahkustasi@gmail.com

Orcid: 0009-0008-4962-9623

² Mete YAĞANOĞLU

E-mail address:

yaganoglu@atauni.edu.tr

Orcid: 0000-0003-3045-169X

ABSTRACT

Classifying variable stars can sometimes be a challenging process using traditional methods. The process by which astronomers classify stars, often by analyzing their brightness curves and other physical properties, can be time-consuming and laborious. The transfer learning approach can play an important role at this point. This study aims to shorten a time-consuming and laborious process by enabling astronomers to do their work by labeling fewer data while classifying stars. A deep neural network was trained for transfer learning and the performance of this model was compared with other machine learning methods. The data sets used in model training are data sets obtained from studies conducted for CoRoT targets. These data sets consist of calculations made with the light curves of CoRoT targets. When the basic model metrics trained for transfer learning were examined, it was found that the accuracy, precision, recall and f1-score values were 94%. When transfer learning approach is used to classify variable stars, the information and properties of previously classified stars can be used to classify new stars. It is expected that the basic model obtained from the study will be reusable for different problems and different data sets in the field of astronomy and will contribute to researchers working in this field.

2024 Batman University. All rights reserved

1. GİRİŞ

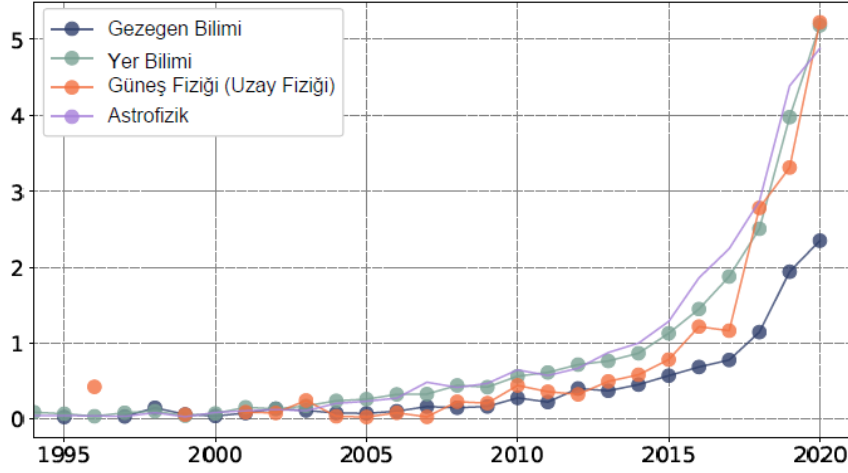
Astronomi alanında gözlem yeteneklerimizin gelişmesi, beraberinde büyük boyutlarda verinin ortaya çıkmasına sebep olmuştur. Bu büyük boyutlu verilerin işlenmesi, bilgiye dönüştürülmesi bilgisayar algoritmalarının kullanımını zorunlu kılmıştır. Toplanan veri miktarının artmasıyla birlikte bu alandaki veri madenciliği, büyük veri uygulamaları, makine öğrenmesi ve yapay zekâ uygulamalarının sayısı her geçen gün artmaktadır (Özkan ve Kayhan, 2021).

Değişen yıldızların sınıflandırılması, geleneksel yöntemlerle bazen zorlu bir süreç olabilir. Gökbilimciler, genellikle yıldızların parlaklık eğrilerini ve diğer fiziksel özelliklerini analiz ederek sınıflandırma yaparlar. Ancak, bu süreç zaman alıcı ve zahmetli olabilir. Bu aşamada gökbilimciler çeşitli makine öğrenmesi algoritmalarından da faydalanabilirler.

Özkan ve Kayhan (2021) çalışmalarında astronomi alanında makine öğrenmesi kullanılarak son beş yılda içerisinde 3000'e yakın çalışmanın yapıldığını, çalışmaların hakemli ve hakemsiz dergilerde yayınlanarak toplamda 17000'e yakın atıf aldığını belirtmişlerdir. Azari vd. (2020) çalışmalarına göre astronomide makine öğrenmesi içerikli yayınların yüzdelik dağılımları Şekil 1'de gösterilmiştir. Şekilde NASA (National Aeronautics and Space Administration) SMD (Bilim Misyonu Direktörlüğü) konuları genelinde makine öğreniminin yıllık dağılımları görülürken 2018'de Güneş fiziğine ait yayınların yer bilimlerine ait yayınlardan daha fazla olduğu görülmektedir. Bu durum astronomi alanında makine öğrenmesi algoritmaları kullanımının giderek ne kadar yaygınlaşacağına bir göstergesidir.

Makine öğrenmesi ve sinir ağları algoritmalarının sıklıkla kullanıldığı bu alanda, kullanılan modellerin eğitimi de bu algoritmaların önemli bir aşamasını oluşturmaktadır. Eğitim sürecinde veri setleri, parametre seçimleri, veri ön işleme gibi işlemler modellerin genel performansını doğrudan etkilediğinden, eğitim aşamasının önemi bir kat daha artmaktadır.

Eğitim için yeterli sayıda etiketli veri toplamak, özellikle yeni bir araştırmada ilk aşamalarda zordur (Kim vd., 2021). Bu çalışma ile gökbilimcilerin yıldız sınıflandırması yaparken modellerin eğitiminde karşılaştıkları problemlerin en aza indirgenmesi, daha az sayıda veri etiketlemesi yaparak, zaman alıcı ve zahmetli bir sürecin kısaltılması amaçlanmıştır.



Şekil 1. Astronomide makine öğrenmesi konulu yayınlar (Azari vd.,2020)

Jin-Meng vd. (2021) yıldızların yüzey sıcaklıklarını tespit için rastgele orman algoritması kullanmışlardır. APOGEE (Apache Point Observatory Galactic Evolution Experiment) ve LAMOST (Large Sky Area Multi-Object Fiber Spectroscopic Telescope) veri setlerini kullanarak modellerini eğitmiş, APOGEE'de yaklaşık %94 LAMOST'ta yaklaşık %90 başarı elde etmişlerdir.

Brenton vd. (2019) NASA misyonu Kepler tarafından gözlemlenen güneş benzeri yıldızların yüzey dönüş sürelerini ölçmekle ilgilenmiş, yıldız yaşının yüzey dönüş periyodundan bulmaya çalışmışlardır. Çalışmalarının iki farklı adımında döndürücü sınıflandırması için %89, döndürme periyodunun bulunmasında %97 gibi doğruluk değeri bulmuşlardır. Rastgele orman sınıflandırıcılarının, yıldız dönme özelliklerini incelemek için mükemmel bir araç olduklarını ve büyük veri kümeleriyle başa çıkmalarına olanak sağladıklarını belirtmişlerdir.

Saux vd. (2019) NASA'nın Kepler uydusu K2'nin ikinci görevinde elde ettiği verilerle yıldızları sınıflandırmaya çalışmışlardır. Bu çalışmada, rastgele orman makine öğrenimi tekniği ile titreşen K2 yıldızlarını otomatik olarak sınıflandırmak için bir yöntem sunmuşlardır. Yöntem yıldızları dört sınıfa ayırmaktadır: kırmızı dev (RG), ana dizi Güneş benzeri yıldızlar (SL), klasik pulsatörler (PULS) ve diğerleri. Yıldızların %80'inden fazlası için doğru sınıflandırma yapmışlardır.

Kim vd. (2021) çalışmalarında OGLE (Optical Gravitational Lensing Experiment) (Udalski vd., 1997) ve EROS-2 (Expérience pour la Recherche d'Objets Sombres) (Tisserand vd., 2007) olmak üzere iki farklı araştırmadan elde edilen değişken kaynakların tek bantlı ışık eğrilerinden oluşan veri setleri kullanarak bir yapay sinir ağı eğitmişlerdir. Modeli transfer aktarım yöntemiyle farklı veri setleri üzerinde başarılı bir şekilde çalıştırabildiklerini ifade etmişlerdir.

Sarro vd. (2013) çalışmalarında yüksek çözünürlüklü spektrumlardan türetilen temel parametreleri kullanarak otomatik yıldız değişkenliği sınıflandırması için geliştirilmiş bir yöntem sunmuşlardır. Teff ve logg değerlerini, 6832 CoRoT hedefi için Giraffe spektrumlarından elde etmişlerdir.

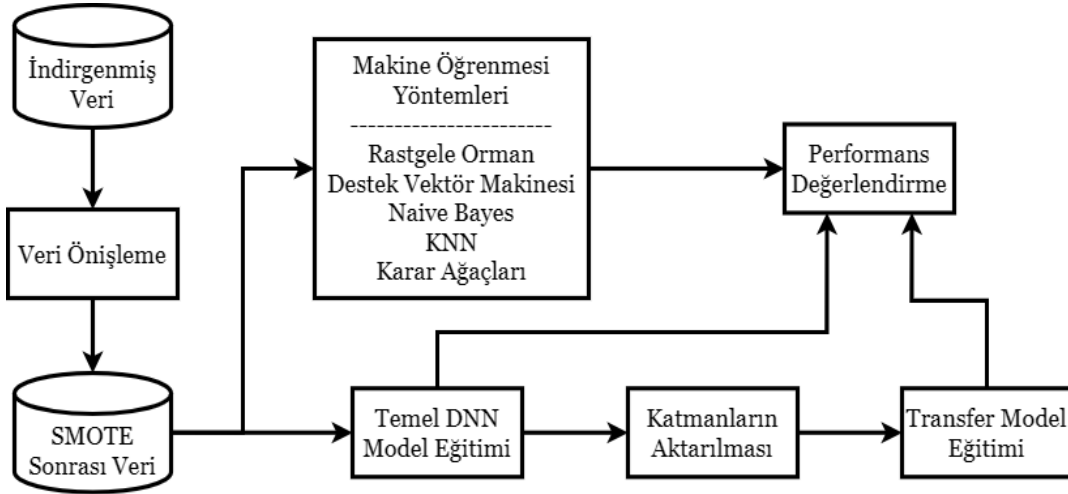
Rimoldini vd. (2012) periyodik, periyodik olmayan ve düzensiz ışık değişimleri sergileyen yıldızların otomatik sınıflandırması için HIPPARCOS verisini kullanmışlardır. Rastgele orman ve Bayesian ağları yöntemlerini kullanarak genel yanlış sınıflandırma oranlarının %12'nin altında

gerçekleştiğini ve literatürde belirsiz veya eksik türlere sahip 6051 HIPPARCOS değişkeni için tür tahmininde uygulandığını belirtmişlerdir.

Hon vd. (2017) katlanmış titreşim spektrumlarının görüntülerinden bu görsel özellikleri otomatik olarak öğrenmek için denetimli öğrenme ile 1D evrişimli sinir ağı eğitmişlerdir. Kepler kırmızı devlerinde eğitim ve test yaparak, helyum yanma işlemi gören kırmızı devleri, kırmızı dev koldan yükselenlerden %99'a varan bir doğrulukla ayırmayı başarmışlardır.

2.YÖNTEM

Bu çalışmada astronomi araştırmaları neticesinde açılan verilerden yapılmış çalışmalardan elde edilen veri setleri kullanılmıştır. Şekil 2'de görüldüğü gibi veri seti makine öğrenmesine uygun bir hale getirilmesi için ön işlemlerden geçirilmiş ve DNN (Derin sinir ağları) dahil olmak üzere çeşitli makine öğrenmesi yöntemleri ile modeller eğitilerek performansları değerlendirilmiştir.



Şekil 1. Çalışmanın akış diyagramı

2.1. Veri Seti

CoRoT (Convection, Rotation and planetary Transits), Avrupa Uzay Ajansı (ESA) tarafından geliştirilen bir uzay teleskopu projesidir. CoRoT, yıldızların iç yapılarını, dönüş hızlarını ve gezegen geçişlerini incelemek amacıyla 2006 yılında fırlatılmıştır. CoRoT, uzaydan yıldızları sürekli olarak gözlemleyerek, yıldızların ışık eğrisindeki değişimleri ve gezegenlerin yıldız önünden geçişlerini tespit eder. Bu bilgiler, yıldızların iç yapısını, dönme hızlarını, yerleşik manyetik alanlarını ve gezegenlerin boyutlarını ve yörüngelerini belirlemek için kullanılır.

Bu çalışmada test edilen makine öğrenmesi yöntemleri ve yapay sinir ağları eğitiminde, Corot hedefleri için elde edilen ışık eğrilerinden çıkarılan verilerle oluşturulmuş, Sarro vd. (2013) çalışmalarından elde edilen veri seti kullanılmıştır. Yine transfer öğrenimi testi için Dubath vd. (2011) HIPPARCOS veri seti için yaptıkları çalışma ile üretilen veri seti kullanılmıştır. Bu çalışmada kullanılan veri setleri CDS tarafından sunulan lisans altında kullanılmıştır. Bu lisans, veri setinin ticari olmayan kullanımına kaynak ve lisans bilgilerinin uygun şekilde belirtilmesi şartı ile izin vermektedir.

Veri seti VLT'deki Giraffe spektrografı ile gözlemlenen CoRoT hedeflerini sınıflandırmada kullanılan hem fotometrik zaman serisinden türetilen hem de spektrumlardan türetilen fiziksel parametreleri içerir. Veri setinde yaklaşık 10100 kayıt bulunmaktadır. Ön deneylerde veri setindeki bazı sınıflara ait örnek sayıları çok düşük olduğu için, modeli aşırı uyum problemine götürdüğü görülmüştür. Bu sebeple bu sınıflar veri setinden atılmıştır.

2.2. Veri Ön işleme

Veri ön işleme süreci, sınıflandırma algoritmalarından daha doğru sonuçlar alınması ve daha iyi performans göstermesi amacıyla veri setindeki uygunsuzlukları gidermek için gerekli bir çalışmadır.

Bu aşamada eksik veriler giderilir, hatalı veriler düzeltilir, tekrarlanan kayıtlar silinebilir, sınıflandırmada anlamsız alanlar atılabilir. Bu çalışmadaki veri setindeki en büyük problem veri setinin dengesizliğidir. Bu problemin çözümü için sentetik kayıtlar oluşturularak dengesizliğin giderilebileceği düşünülmüştür.

Dengesiz sınıf dağılımı, yüksek doğruluk değerlerine ulaşmayı engelleyen önemli bir sorundur. Bu soruna çözüm olarak Chawla (2002) tarafından tanıtılan SMOTE (Synthetic Minority Over-sampling Technique) kullanılmıştır. İstatistiksel bir yöntem olan SMOTE azınlık sınıfının örnek sayısını artırarak sınıf dengesini sağlamayı amaçlamaktadır.

2.3. Öznitelikler

Vmag: Yıldızın görünür parlaklığıdır. Görünür büyüklük ölçümüne fotometri denir. Fotometri ise fotometrik sistemlere ait çeşitli filtrelerle birlikte yapılır. Görünür parlaklık değeri kendi ışımaya gücüyle ve dünyaya olan uzaklığıyla alakalıdır.

Nu1, Nu2: Yıldızların dönme periyotlarıdır. Yıldızların dönme periyotları, çeşitli faktörlere bağlı olarak değişebilir. Özellikle, yıldızın kütlesi, boyutu ve yaşına bağlı olarak değişen dönme hızları gözlemlenir. Genç yıldızlar genellikle hızlı dönerken, yaşlı yıldızlar daha yavaş dönebilirler. Bu dönme hızları, yıldızın manyetik alanını, yüzey aktivitelerini ve yıldız lekelerini de etkiler.

A11, A21: Yıldız periyotlarının fourrier serisindeki ilk terimin genliğidir. Fourier serisi dönüşümü, bir periyodik fonksiyonun bir dizi sinüs ve kosinüs fonksiyonu toplamına dönüştürülmesi işlemidir. Bu dönüşüm, bir fonksiyonun periyodik bir şekilde genişletilmesi ve daha sonra bu genişletilmiş fonksiyonun sinüs ve kosinüs terimlerine ayrılmasıyla gerçekleştirilir.

Teff1, Teff2: Yıldızın etkin sıcaklığıdır. Yıldızların iç bölgelerindeki termonükleer reaksiyonlar sonucu oluşan enerji, yıldızın yüzeyine ulaşırken kayıp yaşar, bu nedenle yüzey sıcaklığı ile etkin sıcaklık arasında farklar olur. Etkin sıcaklık, bir yıldızın elektromanyetik radyasyonunun hangi dalga boylarında yoğunlaştığını belirlemek için kullanılır. Bir yıldızın etkin sıcaklığı, spektral sınıfını belirlemede ve yıldızın evrimini anlamada önemli bir gösterge olarak kabul edilir.

2.4. Makine Öğrenmesi Yöntemleri

Makine öğrenimi, bilgisayarların geçmiş örneklerden öğrenmesine ve büyük, gürültülü veya karmaşık veri kümelerinden ayırt edilmesi zor kalıpları algılamasına olanak tanıyan çeşitli istatistiksel, olasılıksal ve optimizasyon tekniklerini kullanan bir yapay zekâ dalıdır (Cruz ve Wishart, 2006). Bu çalışmada sadece transfer aktarımı için yalnızca bir DNN eğitilmemiş aynı zamanda bu DNN modelin çeşitli makine öğrenmesi yöntemleriyle de performansları karşılaştırılmıştır.

Makine öğrenmesi modellerinde hiperparametreler, modelin yapılandırılmasını ve eğitimini yönlendiren ayarlamalardır. Bağımlı ve bağımsız değişkenler arasındaki ilişkiyi temsil eden matematiksel fonksiyonlara bağlıdır. Bir regresyon formülündeki bir sabit değer, KNN (K-en yakın komşular) algoritmasındaki komşuluk sayısı, SVM (Destek vektör makinesi) yöntemindeki düzgünleştirme katsayısı gibi değerler uygulanan yöntem için birer hiperparametredir. Her bir problem için bu değerler değişebilir. Hiperparametre ayarı, bir yöntem için modelin performansını olumlu veya olumsuz yönde değiştirir. Makine öğrenmesi çalışmalarında her zaman modelin performansını üst düzeye çıkaracak olan parametreler tespit edilmeye çalışılır. Bu çalışmada hiperparametreler her bir modelde de en iyi metrikleri vermesi için tespit edilmiştir.

Karar Ağaçları

Temel yaklaşım, örneklerden aşamalı olmayan öğrenmedir. Sistemler, bir sınıflandırma göreviyle ilgili bir dizi durumla sunulur ve örneklerin verildiği belirli sıraya göre değil, örneklerdeki frekans bilgilerine göre yukarıdan aşağıya bir karar ağacı geliştirir (Quinlan, 1986). Bu ağaçlar, veri setindeki bilgileri en iyi şekilde bölecek ve genelleme yeteneği yüksek modeller oluşturacak şekilde eğitilirler.

Ağaç yapısı yapraklar ve karar düğümlerinden oluşur. Kökten başlayarak her karar düğümü girdiye bir bölme sınaması uygular ve sonuca göre dallardan biri alınır. Bir yaprağa ulaşıldığında arama durur. Burada örneğin hangi sınıfa ait olduğuna karar verilir.

Karar ağacı kurallardan oluşan bir kural tabanına dönüştürülebilir ve kuralların yorumlanmasını kolaylaştırır. Kara ağacı öğrenmesi parametrik değildir, böylece ağaç ihtiyaç duyulduğunda büyür (Alpaydın, 2019). Bu gibi durumlar karar ağaçlarının avantajları arasında yer alır.

Rastgele Orman

Rastgele ormanlar, birçok karar ağacının bir araya gelerek oluşturduğu bir ensemble (topluluk) yöntemidir. Her bir karar ağacı, farklı bir alt veri kümesi ve özellik kümesiyle eğitilir. Böylece, genellikle daha güçlü, daha kararlı ve daha az aşırı öğrenmeye eğilimli modeller üretilir.

Rastgele orman algoritmasına göre ilk olarak eğitim verisinden örnekler alınarak farklı alt kümeler oluşturulur. Her bir alt küme için bir karar ağacı oluşturulur. Bu süreçte her düğüm için rastgele bir özellik alt kümesi kullanılır. Bu durum aşırı uyum riskini azaltır. Sonraki aşamada tahmin edilen her bir hedef için oylar hesaplanır ve en yüksek oyu alan tahmin seçilir.

Rastgele orman algoritması hem regresyon hem de sınıflandırma problemlerinde kullanılabilir. Bu algoritma aşırı uyum problemini önlemektedir. Ayrıca mevcut özellikler arasından en önemli özelliği tanımlamak için de kullanılabilir (Çebi, 2020). Bu özellikler rastgele orman algoritmasının avantajları olarak gösterilir.

K-En Yakın Komşular (KNN)

Makine öğrenmesinde, sınıflandırma ve regresyon problemlerini çözmek için kullanılan basit ve etkili bir algoritmadır. Temel yaklaşım, bir veri noktasını etiketlemek veya tahmin etmek için, ona en yakın olan k komşusunun etiketlerini veya değerlerini kullanmaktır. En yakın noktalar bulunurken öklit, manhattan ve minkowski uzaklık değerlerine bakılır.

KNN algoritması uygulanması kolay bir algoritmaya sahip olması, sınıflandırma ve regresyon için kullanılabilmesi avantajları olarak görülmektedir. Ancak, bağımsız değişkenlerinin artmasıyla birlikte yavaşlaması, yüksek hafıza ihtiyacı, örnek sayısının artmasına paralel olarak tahmin süresinin artması dezavantajları olarak karşımıza çıkmaktadır (Atıcı, 2022).

Destek Vektör Makinesi

Makine kavramsal olarak şu fikri uygular: giriş vektörleri, çok yüksek boyutlu bir özellik uzayına doğrusal olmayan bir şekilde eşlenir. Bu özellik uzayında doğrusal bir karar yüzeyi oluşturulur. Karar yüzeyinin özellikleri, makinenin yüksek genelleme yeteneği kazanmasını sağlar (Cortes, 1995). Destek vektör makinesi, veri noktaları arasındaki en büyük marjı (mesafe) maksimize etmeye çalışarak noktaları birbirinden en iyi şekilde ayıran, bir karar sınırı belirler. Veri doğrusal olarak ayrılabilirse bir hiper düzlem bulur, eğer veri doğrusal ayrılmıyorsa veriyi çok boyutlu özellik uzayına dönüştürerek doğrusal ayrıştırılabilir hale getirir.

Naive Bayes

Naive Bayes sınıflandırıcı, olasılığa dayalı bir makine öğrenimi sınıflandırma algoritmasıdır ve Bayes teoremini esas alır. Sınıflandırıcı bir eleman için her durumun olasılığını hesaplar ve olasılık değeri en yüksek olana göre sınıflandırır (Hatipoğlu 2023). Test kümesindeki bir veri eğitim kümesinde gözlemlenemiyorsa tahmin yapmaz. Bayes sınıflandırıcı, her özneliğin birbirinden koşulsal bağımsız olduğu ve öğrenilmek istenen kavramın tüm bu özneliklere koşulsal bağlı olduğu bir Bayes ağı olarak da düşünülebilir (Anonim, 2023).

2.5. Derin Öğrenme

Yapay sinir ağları biyolojik canlılardaki sinir ağlarından esinlenerek geliştirilmiş matematiksel model ve algoritmalarından oluşan yapay zekanın alt dalıdır. Yapay sinir ağları tahmin modelleri geliştirmek için oluşturulmuş istatistiksel bir yaklaşımdır (Staub vd.,2015). İlk yapay sinir ağı modeli 1943 yılında Warren McCulloch ve Walter Pitts tarafından geliştirilmiştir.

Derin öğrenme, yapay sinir ağları ve benzeri makine öğrenme algoritmalarını içeren bir alanı kapsar, bu algoritmalarda birden fazla gizli katman bulunur. Yani, birbirine bağlı çok katmanlı bir yapay sinir ağı kullanılarak bilgisayarın mevcut verilerden yeni veriler elde etmesini sağlayan bir çalışma alanıdır. Hinton vd. (2006) çalışmalarında, derin öğrenme (Deep Convolutional Neural Network) adı verilen yeni bir yaklaşımı ortaya koymuştur ve çalışmalarıyla yapay sinir ağlarına yeni bir perspektif kazandırmıştır.

Derin öğrenme, gözetimli, yarı gözetimli veya gözetimsiz bir şekilde gerçekleştirilebilir. Ayrıca, pekiştirmeli öğrenme yaklaşımı da derin yapay sinir ağları ile başarılı bir şekilde uygulanabilir (Doğan ve Türkoğlu, 2019).

Temel bir sinir ağı, girdi ve çıktı katmanları arasında bir veya iki gizli katman içerebilirken, derin öğrenme ağları, düzinelerce hatta yüzlerce katmana sahip olabilir. Bu fark, modelin karmaşıklığını ve öğrenme kapasitesini artırma potansiyelini temsil eder. Ancak, daha fazla katman eklemek aynı zamanda daha fazla parametre ve hesaplama kaynağı gerektirir.

Derin öğrenme, sinir ağı katmanları aracılığıyla ham verileri alır ve bu bilgileri sınıflandırır. Örneğin, bir sinir ağı kuş görüntüleriyle eğitildiğinde, kuşları tanımak için kullanılabilir. Daha fazla katman eklemek, örneğin güvercini kartaldan ayırt etmek gibi daha kesin sınıflandırmalar elde etmeye yardımcı olabilir. Ancak, bu ekstra karmaşıklık daha fazla veri ve hesaplama gücü gerektirebilir.

Her bir katman, ağı öğrenme sürecine katkıda bulunur. Girdi katmanı, ham verileri alır; gizli katmanlar, bu verileri daha soyut ve yüksek düzeyli özelliklere dönüştürmekten sorumludur; çıktı katmanı, bu özellikleri belirli bir sınıfa veya değere atar. Daha fazla gizli katman eklemek, ağı daha karmaşık ve özelleştirilmiş özellikler öğrenmesine olanak tanır, ancak aynı zamanda eğitim sürecini zorlaştırabilir.

Derin öğrenme modellerindeki katmanlar, bilgiyi önceki katmanlardan alarak ve ardından bu bilgileri bir sonraki katmana ileterek modelin mimarisini oluşturan temel yapı taşlarıdır.

Giriş katmanı, ham girdi verilerini alır ve önceden tanımlanmış filtrelerle ön işleme yaparak, orijinal görüntüye ek bilgiler ekler ya da orijinal veri matrisini düzleştirerek model girişine uygun hale getirir.

Aktivasyon katmanı çıktıların belirli bir aralığa sınırlanması veya belirli bir formu alması için kullanılan bir matematiksel işlemler setidir. Bu katman, ağı öğrenme kapasitesini artırmak, modelin doğrusallık dışında öğrenmesini sağlamak ve ağı daha karmaşık örüntüleri öğrenmesine yardımcı olmak amacıyla kullanılır. Sık kullanılan bir aktivasyon fonksiyonu, rectified linear unit (ReLU) fonksiyonudur. ReLU, $f(x)=\max(0,x)$ şeklinde ifade edilir ve giriş değeri negatifse sıfır, pozitifse kendisi olarak çıktı üretir. Bu, doğrusallık olmayan bir özellik ekleyerek ve ağı daha karmaşık örüntüler öğrenmesine yardımcı olarak ağı performansını artırabilir. RELU'dan farklı olarak sigmoid, tanh ve softmax gibi fonksiyonlar da bulunur.

Dropout, yapay sinir ağlarında kullanılan bir regülerleme tekniğidir ve ağı ezberlenmesini önlemek için tasarlanmıştır. Ezberleme (overfitting), bir modelin eğitim verilerine aşırı derecede uyum sağlaması, ancak yeni ve görülmemiş verilere genellenme yeteneğinin düşük olması durumunu ifade eder. Dropout katmanında, eğitim sırasında rastgele seçilen nöronlar (veya düğümleri) belli bir olasılıkla devre dışı bırakılır. Yani, her eğitim örneğini işlerken, her bir nöronun devre dışı bırakılma olasılığı vardır. Bu devre dışı bırakılan nöronlar, o eğitim adımında modelin öğrenme sürecine katılmazlar.

Tam bağlı katman, bir önceki katmandaki tüm nöronlarla bağlantılıdır, yani her bir çıkış nöronu, giriş katmanındaki tüm nöronlarla ilişkilidir. Aynı zamanda yoğun katman olarak da adlandırılır. Tam

bağlı katmanın temel amacı, önceki katmanlardan gelen özellikleri kullanarak final sınıflandırmayı gerçekleştirmektir ve geriye yayılım algoritması ile eğitilirler.

Bu katmanlar, derin öğrenme modellerinde farklı işlevlere sahiptir ve birlikte çalışarak karmaşık veri setlerinden anlam çıkarılmasını sağlar. Her katmanın özel rolü, modelin genel performansını etkiler.

Hata fonksiyonları, bir modelin tahminlerinin gerçek değerlere olan uzaklığını ölçerek eğitim sırasında optimize edilmesi gereken bir metrik sunar. Bu fonksiyonlar, modelin performansını değerlendirmek ve geliştirmek adına kritik öneme sahiptir (Fortuner, 2023).

Öğrenme oranı (learning rate), bir makine öğrenimi modelinin, eğitim sırasında ağırlıklarını ve bias'larını güncellerken kullanılan bir hiperparametredir. Gradyan inişi (gradient descent) gibi optimizasyon algoritmalarında, her güncelleme adımının boyutunu kontrol etmek için kullanılır. Öğrenme oranı, her eğitim iterasyonunda güncellenen parametre değerlerine çarpan bir ölçekleme faktörüdür. Bu oranın değeri genellikle 0 ile 1 arasındadır. Öğrenme oranının seçimi, modelin hızlı ve etkili bir şekilde öğrenmesini etkileyen önemli bir faktördür.


Yüksek öğrenme oranında modelin hızlı bir şekilde öğrenmesine neden olur. Ancak bu durum geçebileceği minimum noktaları atlmasına ve istikrarlı bir şekilde yaklaşmaktansa uzaklaşmasına sebep olabilir. Bu durumda, modelin ağırlıkları ve bias'ları çok hızlı bir şekilde güncellenir, bu da bir optimizasyon probleminin çözümüne ulaşamamasına neden olabilir (Eğrioğlu vd., 2020).

Düşük öğrenme oranında modelin daha istikrarlı bir şekilde öğrenmesine neden olur. Bu durumda da daha yavaş bir öğrenme hızına sahip olur. Bu durumda, modelin minimuma yaklaşması daha stabil olabilir, ancak bu da eğitim sürecinin daha uzun sürmesine neden olabilir.

Optimal öğrenme oranı, spesifik bir problem ve veri seti için ampirik olarak belirlenir. Genellikle, eğitim sürecinin başlarında farklı öğrenme oranları denemek ve modelin performansını gözlemlemek yararlı olabilir. En iyi öğrenme oranını bulmak, grid search veya random search gibi yöntemlerle gerçekleştirilir.

Optimizasyon algoritmaları derin öğrenme modellerinin öğrenme sürecini yönlendiren stratejilerdir. Bu algoritmalar, modelin parametrelerini ağırlıklar ve bias'larını güncelleyerek, hata fonksiyonunu minimize etmeyi hedefler. Bu süreç, modelin gerçek değerlerle tahminleri arasındaki farkı en aza indirerek, daha doğru ve genelleştirilebilir tahminler elde etmesi için gerçekleştirilir.

Optimizasyon algoritmaları, ağı eğitirken hatayı azaltma amacını taşır ve genellikle gradyan inişi (gradient descent) veya türevlerini kullanarak hata fonksiyonunun minimum noktasına doğru ilerlemesini sağlar. Bu algoritmalar, belirli bir öğrenme oranını (learning rate) ve diğer hiperparametreleri ayarlayarak, modelin başarıyla öğrenmesini sağlamak için çeşitli stratejiler kullanır. Modelin doğruluğunu ve genelleme yeteneğini artırmak amacıyla kullanılan optimizasyon algoritmaları, makine öğrenimi uygulamalarında temel bir rol oynar (Eğrioğlu vd., 2020). Gradyan inişi, stokastik gradyan inişi, momentum, Adagrad, RMSprop, Adam ve AdaDelta gibi çeşitli optimizasyon algoritmaları, farklı problem tiplerine ve veri setlerine göre uygun olanı seçme esnekliği sunar.



Şekil 2. DNN Model

Bu çalışmada oluşturulan modelde Şekil 3'deki gibi bir giriş katmanı, üç gizli katman ve bir çıkış katmanı kullanılmıştır. İlk gizli katmanda 64, ikinci katmanda 128 ve üçüncü katmanda 576 nöron kullanılmıştır. Aktivasyon fonksiyonu gizli katmanlarda RELU, son katmanda Softmax seçilmiştir. Optimizasyon algoritması olarak Nadam kullanılmıştır.

2.6. Transfer Öğrenme

Transfer öğrenme makine öğrenmesi yöntemlerinin de aynı bizim gibi bir problemi çözerken elde ettiği bilgiyi saklayıp, başka bir problem ile karşılaştığında o bilgiyi kullanmasıdır. Öğrenme aktarımı ile önceki bilgiler kullanılarak daha az eğitim verisi ile daha yüksek başarı gösteren ve daha hızlı öğrenen modeller elde edilir (Yiğit ve Yeğin, 2023).

Çalışmada önceden eğitilen modele temel model, aktarım yapılacak modele ise transfer model adı verilmiştir.

Problem çözümü için bilgi aktarımı yaparken, kaynak ve hedef veri setlerine bağlı olarak farklı problemler ortaya çıkmaktadır. Çünkü her farklı veri seti kendine özgü bir iz taşır.

Sınıf sayısı ve sınıf türleri ilk problemidir. Temel modelin eğitiminde kullanılan veri setindeki sınıf sayısı ile transfer modelde kullanılacak veri setindeki sınıf sayısı farklı olabilir. Daha da önemlisi sınıf türlerinin farklı olmasıdır.

İkinci büyük problem ise farklı özelliklerdir. Astronomi alanında kendine özgü her bir araştırmada objelerin değerlendirilmesinde kullanılan parametreler farklı olabilir. Örneğin değişen yıldız sınıflandırmasında kullanılan değişim genliği, ışık eğrisi biçimi, tayf türü, yüzey çekim ivmesi gibi parametrelerden bazıları bir çalışmada kullanılırken bir diğer çalışmada kullanılmayabilir. Üstelik filtre dalga boyları, büyüklük aralıkları gibi özelliklerde farklı olabilir. Bu gibi sorunların üstesinden gelmek için katmanları dondurmak ve katmanların ağırlıklarını yeniden optimize etmek gibi çözümler kullanılmalıdır.

Çalışmada önceden eğittiğimiz DNN model burada kullanmıştır. Yeni veri seti model eğitimi için uygun hale getirildikten sonra önceden eğitilmiş modelden bilgi aktarımı için bazı katmanlar yeni modele eklenerek ince ayar yapılmıştır.

Bu çalışmada temel modelden giriş katmanı ve gizli katmanlar alınmış çıkış katmanı alınmamıştır. Bu katmanların önüne transfer modelin veri setine uygun olacak yeni bir giriş katmanı eklenmiş, modelin çıkışına ise bağımlı değişkenin farklı sınıflarına uygun olacak yeni bir softmax çıkış katmanı eklenmiştir. Ayrıca ön deneylerde eğitim-validasyon-doğruluk grafiklerinden transfer modelin aşırı uyum sorununa gittiği görüldüğünden, katmanlar arasına dropout katmanları eklenmiştir.

3. BULGULAR


Çalışmada makine öğrenmesi modelleri ve temel model eğitimi için veri setinin %80'i eğitim, %20'si test için kullanılırken, transfer modelde veri setinin %20'si eğitim, %80'i test için kullanılmıştır. Modellerin performansı karmaşıklık matrisi ile elde edilen metriklerle ortaya konmuştur.

Karmaşıklık matrisi sınıflandırma modelinin performansını değerlendirmek için kullanılan bir metriktir. Gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi gösteren bir matristir. Her bir hücre, gerçek sınıf ve tahmin edilen sınıf kombinasyonlarına göre örnek sayılarını içerir. Bu matris, modelin hangi sınıfları ne kadar doğru sınıflandırdığını ve hangi hataların yapıldığını gösterir.

Tablo 1. Temel Model Metrikleri

Sınıf	Hassasiyet	Duyarlılık	F1-Score
ACT	0.84	0.82	0.83
BCEP	1.00	1.00	1.00
DSCUT	0.98	0.99	0.98
ECL	0.99	0.98	0.98
ELL	1.00	1.00	1.00
GDOR	0.98	0.99	0.98
MISC	0.83	0.75	0.79
ROT	0.84	0.94	0.89
SPB	1.00	1.00	1.00

Temel DNN modele ait karmaşıklık matrisi Şekil 4’de gösterilmiştir. Şekle incelendiğinde modelin ACT ve MISC sınıflarında kayda değer sayıda hatalı sonuçlar ürettiği görülmektedir. Yönteme ait doğruluk değeri %94 iken diğer metrikler Tablo 1’de verilmiştir. Tabloya göre modelin, ACT, MISC ve ROT sınıfları haricinde yüksek bir sınıflandırma performansı verdiği görülmektedir.



Şekil 4. Temel model karmaşıklık matrisi

3.1. Performans Metrikleri

Karmaşıklık matrisi kullanılarak hesaplanan metrikler bu kısımda verilmiştir. Tablo 2’de metrikler için formüller verilmiştir.

Doğruluk (Accuracy): Doğru olarak sınıflandırılan örneklerin oranıdır. Modelin doğru olarak sınıflandırdığı örnek sayısının, toplam örnek sayısına oranıdır.

Hassasiyet (Precision): Belirli bir sınıf için doğru tahmin edilen örnek sayısının, doğru veya yanlış bu sınıf cinsinde tahmin edilen örnek sayısına oranıdır. İki sınıflı bir problemde gerçek pozitiflerin toplam gerçek pozitif örnek sayısına oranıdır.

Duyarlılık (Recall): Bir sınıf için doğru tahmin edilen örnek sayısının, sınıfın örnek sayısına oranıdır.


F1-Score: Hassasiyet ve duyarlılığın harmonik ortalamasıdır. Özellikle dengesiz veri setlerini değerlendirmek için önemli bir parametredir.

Özgüllük (Specificity): İki sınıflı bir problem için gerçek negatiflerin, toplam negatif tahminlere oranıdır.


Tablo 2. Metrik formülleri

Metrik	Formül
Doğruluk	$\frac{TP + TN}{TP + FP + TN + FN}$
Hassasiyet	$\frac{TP}{TP + FP}$
Duyarlılık	$\frac{TP}{TP + FN}$
F1- Score	$2 \frac{Hassasiyet * Duyarlılık}{Hassasiyet + Duyarlılık}$
Özgüllük	$\frac{TN}{TN + FP}$

ROC Eğrisi: Modelin TPR ve FPR özellikleri arasındaki ilişkiyi gösterir ve sınıflandırma problemlerinde kullanılan bir performans metriğidir. ROC eğrisi, farklı bir eşik değeri kullanıldığında modelin ürettiği TPR ve FPR değerlerini çizgisel olarak gösterir. Eşik değeri, sınıflandırma problemleri için olasılık değerlerine göre ne şekilde bir sınıflandırma yapılması gerektiğinin bir kriteridir (Anonim, 2024). ROC eğrisi, ideal bir sınıflandırıcı için sol üst köşeden geçer. Bu nokta hem true positive (TP) hem de true negative (TN) oranlarının yüksek olduğu noktadır. Şekil 5'te temel model için One-vs-Rest yöntemi ile çizdirilen ROC eğrisi verilmiştir. Şekilde tüm sınıflar için eğri sol üst köşeye yakındır. Bu durum modelin iyi bir sınıflandırma performansı gösterdiğini ifade eder.

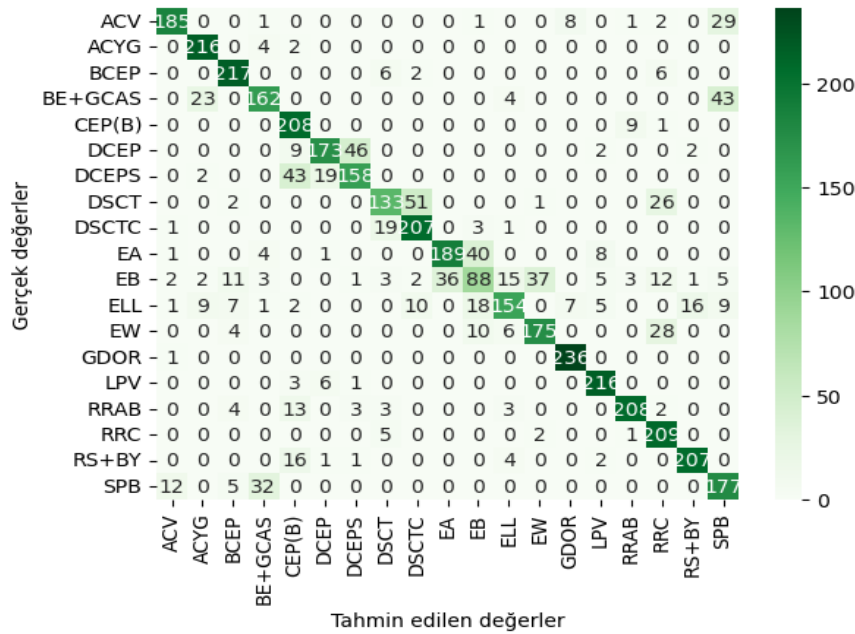


Şekil 3. Temel model ROC eğrisi



Şekil 4. Temel modelin eğitim-validasyon-doğruluk grafiği

Modelin aşırı uyum problemine uğrayıp uğramadığı ve genel performansı hakkında bilgi edinmek için Eğitim-Doğrulama grafiklerine bakılabilir. Şekil 6’da temel modelin eğitim-validasyon-doğruluk grafiği verilmiştir. Grafik incelendiğinde modelin %90’lık başarı seviyesine ulaşması yaklaşık 100 devirde olmuştur ve modelin aşırı uyuma gitmediği de gözlemlenebilir.




Şekil 5. Transfer model karmaşıklık matrisi

Transfer modele ait karmaşıklık matrisi Şekil 7’de verilmiştir. Şekil incelendiğinde modelin DCEPS, BE+GCAS, ELL, SPB türünde çok sayıda hatalı tahminler yaptığı görülmektedir. Yönteme ait doğruluk değeri %84 iken diğer metrikler Tablo 3’de verilmiştir. Tablo incelendiğinde sınıflandırıcının, en yüksek RRAB sınıfında, en düşük EB ve SPB sınıfı yıldızlar için sınıflandırma performansı gösterdiği görülür.

Tablo 3. Transfer model metrikleri


Sınıf	Hassasiyet	Duyarlılık	F1-Score
ACV	0.91	0.74	0.81
ACYG	0.82	0.97	0.89
BCEP	0.91	0.93	0.92
BE+GCAS	0.73	0.75	0.74
CEP (B)	0.86	0.96	0.90

DCEP	0.86	0.77	0.81
DCEPS	0.77	0.86	0.82
DSCT	0.76	0.77	0.77
DSCRC	0.77	0.84	0.80
EA	0.92	0.76	0.83
EB	0.63	0.51	0.56
ELL	0.75	0.71	0.73
EW	0.84	0.87	0.85
GDOR	0.95	0.98	0.96
LPV	0.94	0.96	0.95
RRAB	0.99	0.86	0.92
RRC	0.84	1.00	0.92
RS+BY	0.95	0.91	0.93
SPB	0.72	0.77	0.74



Şekil 6. Transfer model ROC eğrisi

Şekil 8’de transfer model için One-vs-Rest yöntemi ile çizdirilen ROC eğrisi verilmiştir. Şekilde EB sınıfı hariç diğer tüm sınıflar için eğri sol üst köşeye yakındır. Bu durum modelin EB sınıfı için düşük bir sınıflandırma performansı gösterdiğini, diğer sınıflar için iyi bir sınıflandırıcı performansı gösterdiğini ifade eder.



Şekil 7. Transfer model eğitim-validasyon-doğruluk grafiği

Transfer modelin aşırı uyum problemine uğrayıp uğramadığı ve genel performansı hakkında bilgi edinmek için eğitim-validasyon-doğrulama grafiğine bakılır. Şekil 9'da temel modelin eğitim-validasyon-doğruluk grafiği verilmiştir. Grafik incelendiğinde modelin en yüksek başarı seviyesine ulaşması yaklaşık 175 devirde olmuştur ve modelin aşırı uyuma gitmemiştir.

Tablo 4. Çalışmada kullanılan yöntemlere ait metrikler

Sınıflandırıcı	Doğruluk	Hassasiyet	Duyarlılık	F1-Score
Rastgele orman	0.97	0.97	0.97	0.97
Destek vektör makinesi	0.87	0.87	0.87	0.87
Naive Bayes	0.66	0.72	0.72	0.72
KNN	0.95	0.95	0.95	0.95
Karar ağaçları	0.95	0.95	0.95	0.95
Temel DNN model	0.94	0.94	0.94	0.94
Transfer model	0.84	0.84	0.84	0.84

Makine öğrenmesi yöntemleri, temel model ve transfer model dahil olmak üzere çalışmada kullanılan tüm yöntemlere ait metrikler Tablo 4'te verilmiştir. Tablo incelendiğinde, bu alanda daha önceden yapılan diğer çalışmalara paralel sonuçlar elde edildiği, rastgele orman yönteminin, en yüksek değerleri verdiği, Bayes sınıflandırıcısının ise en kötü değerleri verdiği görülür.

4. TARTIŞMA

Bu çalışmada, değişen yıldız sınıflandırmasında transfer öğrenme yönteminin etkinliği değerlendirilirken, aynı zamanda diğer makine öğrenmesi yöntemlerinin bu alandaki performansları da test edilmiştir.

Seçilen veri seti astronomi alanındaki bir araştırmadan elde edilen veri setidir. Bu kaynak araştırma yapılırken temel parametreler araştırmacı tarafından seçildiği için, yeniden öznitelik seçimi yapılmamıştır. Eğitim için kullanılan veri seti doğrudan uzay araştırmalarından değil, bir uzay araştırması için yapılmış çalışmadan elde edilen veri setidir. Bu durum hem öznitelik seçimi yaparken hem de yıldız sınıflandırmasında etkin olmayan özniteliklerin hiç ortaya gelmemesi ile, eğitim aşamasının kısa sürede tamamlanmasına avantaj sağlamıştır.

Makine öğrenmesi yöntemlerinden elden elde edilen sonuçlara göre en iyi performansı %97'lik bir doğruluk değeri ile rastgele orman yöntemi gösterirken, en düşük performansı %65 ile Naive Bayes göstermiştir. Veri seti başta dengesiz olduğu için doğruluk değeri tek değerlendirilen metrik olmamıştır.

ROC eğrileri incelendiğinde bazı sınıfların BSEP, ELL ve SBP gibi sınıflarda modellerin çok yüksek performans gösterdiği görülmektedir. Bunun sebebi diğer sınıf türlerindeki örnek sayısının çok olmasına karşın bu türdeki kayıt sayısı oldukça azdır. SMOTE uygulanırken bu sınıflara ait kayıtlar çoğaltıldığı için eğitim ve test olarak bölünen veride değer olarak birbirine yakın değerli kayıtların bölündüğü tahmin edilebilir. Bu durum doğruluk haricinde diğer metrikleri de üst seviyede tutmaktadır.

Metrikler incelendiğinde tüm modellerin MISC sınıfında performanslarının çok düştüğü görülmüştür. Bu sınıf özünde diğer sınıflara uymayan, belirli bir sınıfa dahil edilemeyen yıldızlar için kullanılan bir sınıftır. Bu sebeple problemin bu çalışmadaki modellere veya farklı çalışmalara özgü olmayıp genel bir problem olduğu ortadadır.

Transfer aktarımı için eğitilen temel model metrikleri incelendiğinde doğruluk değerinin %94 olduğu görülür. Tartışılan problemlerin diğer yöntemlerde olduğu gibi transfer model için de geçerli olduğu görülmektedir.

Çalışmanın odak noktası olan transfer öğrenimi için farklı bir veri setinin model üzerinde denenmesi mümkün olabilir. Bu çalışmada Dubath vd. (2011) çalışmasından alınan veri seti örnek olarak seçilmiştir. Model metriklerine bakıldığında doğruluk oranının %84 olduğu görülür. Farklı veri setleri ile model performansı yeniden değerlendirilebilir.

5. SONUÇ

Astronomi alanında önceki çalışmalarda veri setleri, yöntemler, problemler farklı olmakla birlikte, metrikler yaklaşık olarak %87 ile %95 arasında değişmektedir. Bu çalışma daha önceki yapılan çalışmalar ile kıyaslandığında metrikler Tablo 5’de görüldüğü gibi, diğerlerine benzer sonuçlar üretmiştir.

Ağırlıklı olarak rastgele orman ve çeşitli makine öğrenmesi yöntemlerinin tercih edildiği diğer çalışmalara kıyasla, bu çalışmada bir DNN model kullanılması, model katmanlarını araştırmacıların kendi çalışmalarına dahil etmesini kolaylaştıracaktır. Ancak araştırmacıların katman aktarımı yaparken hedef veri setindeki sınıf sayısı, sınıf türleri, farklı özellikler gibi durumlara dikkat etmesi gerekmektedir. Ayrıca oluşturulacak yeni modelin eğitiminde aşırı uyum problemine gidip gitmediği kontrol edilmeli, gerekirse dropout katmanı ekleme gibi çözüm yollarına başvurulmalıdır.

Tablo 4. Çalışmanın benzer çalışmalarla karşılaştırılması

Çalışma	Yıl	Açıklama	Sonuç
Jin Meng vd.	2021	Yıldızların yüzey sıcaklıkları tespiti için rastgele orman sınıflandırıcısı	0.90-0.94 (ACC)
Brenton vd.	2019	Yıldızların yüzey dönüş sürelerini tespiti için Rasgele Orman sınıflandırıcısı	0.87 (ACC)
Saux vd.	2019	Kepler K2 görevi yıldız sınıflandırma için rastgele orman sınıflandırıcısı	0.80 (ACC)
Kim vd.	2021	Eğitim için OGLE ve EROS-2 veri setleri kullanarak DNN model	0.94 (MCC)
Dubath vd.	2011	HIPPARCOS hedefleri için rastgele orman sınıflandırıcısı	0.90-1.00 (ACC)
Rimoldini vd.	2012	HIPPARCOS verisi ile yıldızların sınıflandırılması için rastgele orman ve Bayesian ağları	0.88 (ACC)
Hon vd.	2017	Zonklayan yıldızların sınıflandırılması için Evrişimli sinir ağı	0.99 (ACC)
Bu çalışma	2023	Değişen yıldızların sınıflandırılması için DNN model	0.94 (ACC)

Gökbilimcilerin, genellikle yıldızların parlaklık eğrilerini ve diğer fiziksel özelliklerini analiz ederek sınıflandırma yaptıkları süreç zaman alıcı ve zahmetli olabilir. Transfer öğrenimi yaklaşımı, bu noktada önemli bir rol oynayarak bu süreçleri kısaltabilir.

Değişen yıldızların sınıflandırılmasında transfer öğrenimi yaklaşımı kullanıldığında, daha önce sınıflandırılmış yıldızların bilgileri ve özellikleri yeni yıldızların sınıflandırılmasında kullanılabilir. Bu, gökbilimcilerin yeni yıldızları sınıflandırmak için daha az bir çaba ile az bir veri etiketlemesini gerektirecek ve süreci hızlandıracaktır.

6. KAYNAKÇA

Alpaydın, E. (2019). Makine öğrenmesi. İstanbul: *Ufuk açan yayınlar*.

Anonim, (2023). Naive Bayes, https://tr.wikipedia.org/wiki/Naive_Bayes_sınıflandırıcısı. Erişim tarihi: 03.09.2023.

- Anonim, (2024). ROC ve AUC eğrileri, <https://devreyakan.com/roc-ve-auc-egri-leri>. Erişim Tarihi:06.02.2024.
- Atıcı, A. (2022). <https://medium.com/machine-learning-türkiye/knn-k-en-yakın-komşu-7a037f056116>. (28.05.2024)
- Azari, A. R., Biersteker, J. B., Dewey, R. M., Doran, G., Forsberg, E. J., Harris, C. D., ve Himes, M. D. (2020). Integrating Machine Learning for Planetary Science: Perspectives for the Next Decade. *NRC Planetary Science and Astrobiology*. <https://doi.org/10.48550/arXiv.2007.15129>
- Breton, S., Bugnet, L., Santos, A., Saux, A. L., Mathur, S., Palle, P., ve Garcia, R. (2019). Determining surface rotation periods of solar-like stars observed by the kepler mission using machine learning techniques. *Societ'e Francaise d'Astronomie et d'Astrophysique*. <https://doi.org/10.48550/arXiv.1906.09609>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., ve Kegelmeyer, W. P. (2022). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*. <https://doi.org/10.1613/jair.953>
- Cortes, C. V. (1995). Support-vector networks. *Mach Learn*. <http://dx.doi.org/10.1007/BF00994018>
- Cruz, J. A., ve Wishart, D. S. (2006). Applications of machine learning in cancer prediction and prognosis. *Cancer informatics*. <https://doi.org/10.1177/117693510600200030>
- Çebi, C. (2020). <https://medium.com/@cemthecebi/rastgele-orman-algoritması-1600ca4f4784>. 28.05.2024
- Doğan, F., ve Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*. <https://doi.org/10.24012/dumf.411130>
- Dubath, P., Rimoldini, L., Süveges, M., Blomme, J., López, M., Sarro, L. M., ve Eyer, L. (2011). Random forest automated supervised classification of Hipparcos periodic variable stars. *Monthly Notices of the Royal Astronomical Society*. <https://doi.org/10.1111/j.1365-2966.2011.18575.x>
- Eğrioğlu, E., Yolcu, U., ve Baş, E. (2020) Yapay Sinir Ağları- Öngörü ve Tahmin Uygulamaları. *Nobel Akademik Yayıncılık*.
- Fortuner, B. Loss Functions. https://github.com/bfortuner/ml-glossary/blob/master/docs/loss_functions.rst. Erişim Tarihi: 27.09.2023
- Hatipoğlu, E. (2023) <https://medium.com/@ekrem.hatipoglu/machine-learning-classification-naive-bayes-part-11-4a10cd3452b4>. Erişim tarihi: 29.08.2023
- Hinton, G. E., ve Salakhutdinov, R. R. (2006) Reducing the dimensionality of data with neural networks. *Science*. <https://doi.org/10.1126/science.1127647>
- Hon, M., Stello, D., ve Yu, J. (2017). Deep learning classification in asteroseismology. *Monthly Notices of the Royal Astronomical Society*. <https://doi.org/10.1093/mnras/stx1174>
- Jin-Meng, Y., Xiao-Qing, W., ve min, Z. (2021). The regression of effective temperatures in APOGEE and LAMOST. *New Astronomy*. <https://doi.org/10.1016/j.newast.2020.101568>
- Kim, D.W., Yeo, D., Bailer-Jones, C. A., ve Lee, G. (2021). Deep Transfer Learning for Classification of Variable Sources. *Astronomy & Astrophysics*. <https://doi.org/10.48550/arXiv.2106.00187>
- Ochsenbein F. vd. The VizieR database of astronomical catalogues. <https://doi.org/10.26093/cds/vizieR>
- Quinlan, J. (1986). Induction of decision trees. *Machine Learning*. <https://doi.org/10.1007/BF00116251>
- Özkan, M., & Kayhan, C. (2021) Astronomi Alanında Makine Öğrenmesi Uygulamaları. *Turkish Journal of Astronomy and Astrophysics*.
- Rimoldini, L., Dubath, P., Süveges, M., López, M., Sarro, L. M., Blomme, J., ve Eyer, L. (2012). Automated classification of Hipparcos unsolved variables. *Monthly Notices of the Royal Astronomical Society*. <https://doi.org/10.48550/arXiv.1301.1545>
- Sarro, L. M., Debosscher, J., Neiner, C., Bello-Garcia, A., González-Marcos, A., Prendes-Gero, B., ve Batz, B. D. (2013). Improved variability classification of CoRoT targets with Giraffe spectra. *Astronomy & Astrophysics*. <https://doi.org/10.26093/cds/vizieR.35500120>

- Saux, A. L., Bugnet, L., Mathur, S., Breton, S. N., ve Garcia, R. A. (2019). Automatic classification of k2 pulsating stars using machine learning techniques. *Societe Francaise d'Astronomie et d'Astrophysique*. <https://doi.org/10.48550/arXiv.1906.09611>
- Staub, S., Karaman, E., Kaya, S., Karapınar, H., ve Güven, E. (2015). Artificial Neural Network and Agility. *Procedia - Social and Behavioral Sciences*. <https://doi.org/10.1016/j.sbspro.2015.06.448>
- Tisserand, P., Le Guillou, L., Afonso, C., Albert, J. N., Andersen, J., Ansari, R., ve Vigroux, L. (2007). Limits on the Macho Content of the Galactic Halo from the EROS-2 Survey of the Magellanic Clouds. *Astronomy & Astrophysics*. 469(2), 387-404.
- Udalski, A., M. Kubiak, ve M. Szymanski. (1997). Optical Gravitational Lensing Experiment. OGLE-2--the Second Phase of the OGLE Project. *Acta Astronomica*. 47,319-344.
- Yiğit, G., ve Yeğin, M. N. (2020). Öğrenme Aktarımı/Transfer Learning. <https://medium.com/novaresearchlab/öğrenme-aktarımı-transfer-learning-c0b8126965c4>. Erişim Tarihi: 19.08.2023

TEŞEKKÜR

Bu araştırmada Vizier katalog erişim aracı CDS'den yararlanılmıştır. Strasbourg, Fransa (DOI:10.26093/cds /vizier).

Astronomi alanında desteklerinden dolayı değerli hocamız Dr. Onur ŞATIR ve bilgisinden sıklıkla istifade ettiğimiz astronom Alperen Furkan EKSİLMEZ'e teşekkürlerimizi sunarız.