



Araştırma Makalesi

## Ortaöğretimde Öğrenim Gören Öğrenci Performanslarının Veri Madenciliği Yöntemleri İle Tahmin Edilmesi

Senem Hazel Başer\*<sup>1</sup>, Onur Hökelekli<sup>1</sup>, Kemal Adem<sup>1</sup>

<sup>1</sup>Aksaray Üniversitesi, Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri, Aksaray, Türkiye

**Anahtar Kelimeler:**  
Öğrenci performansı  
Veri madenciliği  
Sınıflandırma  
OneR

### ÖZ

İnsanların günlük yaşantılarında sergiledikleri davranışlarının analizi sürecinin gerçekleştirilmesi sonrasında belli metodolojiler ve sınıflandırma yöntemleri kullanılarak, kendi başına öğrenme ve ölçümler yapabilmeye veri madenciliği yöntemleri ile insan beyninin öğrenmeye olan eğilimi ve sistematik benzer paradigmlar üretilmeye çalışılmaktadır. Bu yöntemler kullanılarak eğitim, öğrenme, karar verme süreçlerinin bir makineye uygulanabilmesi amaçlanmaktadır. Bu doğrultuda analizi gerçekleştirilen veri kümesi UC Irvine Machine Learning Repository veri tabanından elde edilmiştir. Söz konusu içeriği oluşturan okul raporları ve anketlerden elde edilen veri üzerinde 31 öznitelikten oluşan veri kümesi kullanılmıştır. Veri içeriğindeki öznitelikler öğrencinin; notları, demografik öğeleri, sosyal ve okul faaliyetlerini kapsamaktadır. Bu kapsamda gerçekleştirilen çalışmada Iterative Classifier, OneR, LogitBoost ve Yapay Sinir Ağı veri madenciliği yöntemleri ile analizler gerçekleştirilmiştir. En başarılı yöntem OneR veri madenciliği yöntemi olmuştur ve bu yöntem ile 5, 7 ve 10 fold çapraz geçerlilik deneyleri yapılarak bu sonuçların ortalamalarına bakıldığında doğruluk değerinin %92.15; duyarlılık değerinin %96; özgüllük değerinin %86.6 olduğu görülmektedir.

## Predicting the Performance of Students Studying in Secondary Education Using Data Mining Methods

**Keywords:**  
Student performance  
Data mining  
Classification  
OneR

### ABSTRACT

After the process of analyzing the behaviors of people in their daily lives, by using certain methodologies and classification methods, it is tried to produce paradigms similar to the human brain's inclination and systematics with data mining methods that can make learning and measurements on its own. Using these methods, it is aimed to apply training, learning, and decision making processes to a machine. The data set analyzed accordingly was obtained from the UC Irvine Machine Learning Repository database. A data set consisting of 31 attributes was used on the data obtained from school reports and questionnaires that constitute the content in question. Attributes in the content of the student; notes, demographic items, social and school activities. In this study, analyzes were carried out with Iterative Classifier, OneR, LogitBoost and Artificial Neural Network data mining methods. The most successful method was the OneR data mining method, and with this method, 5, 7 and 10 fold cross-validation experiments were performed. As a result of the experiments, it is seen that 92.15% of the accuracy value; 96% of the sensitivity value; 86.6% of the specificity value.

\*Sorumlu Yazar

\*(senem.hazel.baser@asu.edu.tr) ORCID ID 0000-0002-1223-1901  
(onur.hokelekli@asu.edu.tr) ORCID ID 0000-0002-9376-9024  
(kemaladem@aksaray.edu.tr) ORCID ID 0000-0002-3752-7354

e-ISSN: XXXXXXXXXXXX

Geliş Tarihi: 13/03/2020; Kabul Tarihi:01/05/2020

Bilgisayar Bilimleri ve Teknolojileri Dergisi

## 1. GİRİŞ

Başarı kavramı en temel anlamıyla belli hedefler doğrultusunda gerçekleştirilen özverili çalışmalar sonucunda istenilen sonuçların elde edilmesi olarak tanımlanabilir. Öğrencilerin başarılarını ve performanslarını etkileyen faktörler vardır. Değişik yaşamları olan kişilerin ortak bir sınıf içerisinde eğitim alması, kişilerin farklılıklarına dikkat edilmemesine neden olmuştur. Fakat aynı sınıfta birbiriyle eşit olarak görülen öğrencilerin bilgi edinme ve öğrenme yolları birbirinden farklıdır. Bu durumu kanıtlayan durum da aynı sınıfta aynı eğitimi gören öğrencilerin başarılarının değişkenlik göstermesidir. Sınıf ortamında öğrencilerin başarısını ve öğrenmelerini etkileyen çeşitli faktörler mevcuttur (Arslan ve Babadoğan, 2005). Öğrenciler arasındaki farklılıklar ve performansları üzerine yapılan çalışmalar ve geliştirilen metodolojilerin artması, gelecekte eğitimdeki başarı düzeylerinde yukarı yönlü bir eğilim potansiyeli sunmaktadır.

Literatür taraması sonucunda öğrenci performansını etkileyen temel ölçütler; bireyin geçmişte aldığı eğitimin kalitesi, ebeveynlerin aldıkları eğitim düzeyleri, ailenin aylık ortalama gelir düzeyi, öğrencilerin devam etmekte oldukları bölüm, okul ortamında oluşan çevrenin verdiği memnuniyet duygusu ve bireyin mevcut psikolojik durumu olduğuna yönelik fikir birliği vurgulanmıştır. Literatür incelemesinde öğrenci performansını tahminleme üzerine ilk çalışma 1994 yılında Nagin Gorr ve Szcypula tarafından yapılmıştır. Bu çalışmada öğrencilerin aldıkları notların ortalamalarının tahminlenmesinde Doğrusal Regresyon ve Çoklu Regresyon Analizi ile Yapay Sinir Ağları (YSA) analizinin karşılaştırılması yapılmıştır. Elde edilen sonuçlar değerlendirildiğinde YSA yönteminin kullanılmasıyla yapılan tahminlemenin daha isabetli sonuçlar ürettiği tespit edilmiştir. Başka bir çalışmada ise Subbanarasimha, Arizeb ve Anandarajanb (2000), belirli bir grup öğrencinin elde ettikleri başarının akademik performans düzeylerinin tahmininin yapılmasında Regresyon yöntemleri ile YSA yöntemlerinin karşılaştırılması için iki farklı değişkenli veri kümesi kullanılmıştır. Buradan elde edilen sonuçlarda YSA tahminleme tekniklerinin bu veri kümesi üzerinde daha iyi değerler ürettiği sonucuna varılmıştır. Tosun (2007), öğrenci performansı üzerine yaptığı çalışmada Karar Ağaçları ve YSA yöntemlerini ele almıştır. Karar Ağaçları baz alındığında %86 oranında başarı elde ederken aynı veri kümesi üzerinde YSA kullanıldığında %92 oranında başarı sağlanmıştır. Literatürde öğrencilerin akademik performansını üzerine gerçekleştirilen güncel çalışmalar incelendiğinde; Aydemir, E. (2019), Türkiye’de bir üniversitede öğrenim gören öğrencilerin yabancı dil dersindeki geçer notlarının YSA ve bazı sınıflama metodları ile tahminleme

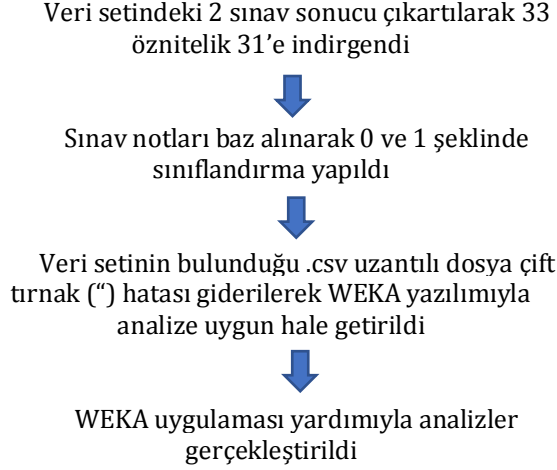
modelleri oluşturulmuş ve bu metodların karşılaştırılması yapılmıştır. Bu çalışmada veriler eğitim ve test olarak ayrıştırılarak sınımlar yapılmış ve sınıma metodları arasında Bagging yönteminde 1.22 ortalama mutlak hata ve 0.80 korelasyon katsayısı ile en başarılı tahminler üretildiği görülmüştür. Güncel diğer bir çalışma; Güre, Kayri ve Erdoğan (2020), matematik okuryazarlığını etkileyen unsurları tespit etmek için veri madenciliği metodlarından Rastgele Orman ve Çok Katmanlı Algılayıcı yöntemlerinin tahminleme becerilerini karşılaştırılmıştır. Yapılan testler ile öğrencilerin aldıkları puanların analizi neticesinde Rastgele Orman metodunun daha az hata ile tahminleme yaptığı görülmüştür. Tahminleme performansı yüksek olan metod çıktıları matematik okuryazarlığına etki eden unsurlar olarak kabul görülmüştür. Başka bir çalışma, Altun, Kayıkcı ve İrmak (2019), tarafından yapılan bir araştırmadır. Çalışmada sınıf öğretmenliği öğrencilerinin vize sınav puanlarının dikkate alınarak final notlarının tahminlenmesi amaçlanmıştır. Bu doğrultuda analizi gerçekleştirilen veriler, Çoklu Doğrusal Regresyon ve YSA yöntemleri karşılaştırılmıştır. Değerlendirme çıktılarında regresyon analizi %94.30 başarı sağlarken YSA ile %94.43 başarı elde edilmiş, öğrenci başarısını tahminlemede birbirine yakın sonuçlar verdiği görülmüştür.

Bu çalışmada ortaöğretimde öğrenci başarı ölçütünün belirlenmesinde bireysel ve demografik faktörlere bağlı sınıflandırmalar için pek çok veri madenciliği yöntemi ile deney yapılmıştır. Deneyler içerisinde en başarılı olan yöntemler Iterative Classifier Optimizer, OneR, LogitBoost ve YSA yöntemleri olmuştur. Analiz için UCI üzerinden edinilen Student Performance Dataset kullanılmıştır. Bu veri seti ile yapılan ilk veri madenciliği çalışmaları kümeleme algoritmaları ile gerçekleştirilmiştir. Literatür incelendiğinde ilerleyen çalışmalarda farklı algoritmalar kullanılarak sınıflandırma analizleri de yapılmıştır. Bu çalışmada veri seti sınıflama algoritmalarının kullanılmasına uygun hale getirilerek veri madenciliği çalışmaları yapılmıştır. Verilerin düzenlenmesi sonrasında yapılan analizlerde yüksek başarı oranlarına ulaşılmıştır. Yapılan deneyler sonucunda en başarılı yöntem diğer veri madenciliği algoritmalarından daha yüksek sonuçlar vererek OneR yöntemi olmuştur.

## 2. YÖNTEM

Öğrenci başarı düzeylerini veri madenciliği tekniklerini kullanarak sınıflandırmak için UC Irvine Machine Learning Repository (UCI) üzerinden elde edilen Student Performance Dataset içerisindeki veriler, 395 öğrenci (187’si Erkek, 208’i kız) ve 33 öznelikten oluşmaktadır (Cortez, ve Silva, 2008). Bu 33 öznelik içerisinde bulunan öğrencilerin matematik dersine ait 3 sınav sonucu yer almaktadır. Veri setinin edinildiği web sitesi

üzerinden edinilen bilgiye göre en anlamlı sınav sonucunun 3. sınav sonucu olduğu kanısına varılmıştır. Bu sebeple sonuçlardan yalnızca son sınav notları baz alınarak sınıflandırma gerçekleştirildi. 0-20 aralığında değerlendirilen sınav sonuçları için 0-10 aralığında puana sahip olan öğrenciler için "0" sınıfı ile başarısız, 11-20 aralığında sınav notu olan öğrenciler için ise "1" sınıfı ile başarılı olarak sınıflandırıldı.



Çalışmada kullanılan veri madenciliği yöntemlerinin ayrıntıları aşağıda verilmiştir.

### 2.1. Iterative Classifier Optimizer

Iterative Classifier Optimizer algoritması, ilk kaydın sınıflandırmasından elde edilen hataları geri besleyerek daha fazla yineleme için değiştirmektedir. Bu algoritma nöron ağı gibi çalışır ve bu nedenle beynin sinir yapısı ile karşılaştırılabilir. Bu yöntemde kayıtlar ağa dağıtılır. Tüm giriş örnekleri sunulduktan sonra süreç tekrarlanır ve bu nedenle bu algoritma YSA'nın kilit bir özelliğidir. Sinir ağını yapılandırarak belirli bir uygulama için eğitilebilir. Öğrenme başlangıç ağırlıklarını rastgele seçerek başlar (Manikandan ve ark., 2018).

### 2.2. OneR

Holte (1993), tarafından önerilen OneR yöntemi, karar ağacını öğrenir. Temelde bu yaklaşım hata tabanlı kural çıkarım anlayışına dayanır. Sınıflandırmanın doğru sonuçlara yaklaşması için iyileştirmeler yapar. Hata oranı en az olan ve sınıflandırmada farkı ortaya koyacak en iyi kriteri seçer. Yalnızca tek özelliğe odaklandığı için OneR yüzeysel bir yaklaşım olarak görülmektedir (Uzun, 2005). OneR algoritması (Holte, 1993) aşağıdaki gibi bir mantıkla çalışır: Her bir özellik için,

- 1.Özelliğin her bir değeri için, aşağıdaki gibi bir kural oluştur.
- 2.Her bir sınıfın ne kadar görüldüğünü say.
3. En sık görülen sınıfı bul.

- 4.Oluşturulan kuralı tanımla, bu özellik değeri ile sınıflandır.
- 5.Kuralların hata oranını hesapla.
- 6.Kuralları en küçük hata oranı ile seç.


Yukarıda verilen algoritma adımları ile veri kümelerine OneR veri madenciliği yöntemi uygulanmaktadır.

### 2.3. LogitBoost

LogitBoost, boosting algoritmalarının içinde yer alır. AdaBoost'ta yaşanan sorunlara çözüm sunmak için geliştirilmiştir ki bu sorunlar yoğun verilerden ortaya çıkan aşırı öğrenme (overfitting) sorunlarıdır. Bu algoritma, bahsedilen problemi gidermek için doğrusal olarak eğitimdeki hataları indirmektedir. Böylelikle genelleme seviyesini yükseltmektedir. Neticede LogitBoost algoritması, lojistik kayıp fonksiyonunu kullanır ve aşırı öğrenme problemini ortaya çıkaran verilerin ağırlığını artırarak bu soruna çözüm üretmeye çalışmaktadır (Aydın ve Arslan, 2017).

### 2.4. Yapay Sinir Ağları

YSA, nöronlar veya düğümler olarak adlandırılan bir dizi birbirine bağlı basit işleme elemanlarından oluşan biyolojik sinir ağlarından esinlenen hesaplama modelidir. Düğümler, Şekil 1'deki gibi girdi katmanı, gizli katman ve çıktı katmanından oluşur. Her nöron(düğüm), önceki katman nöronlarından veya harici bir kaynaktan bir dizi veri alır, bir aktivasyon fonksiyonu kullanarak yerel olarak dönüştürür ve sonucu bir sonraki düğüme gönderir (Osborn ve ark., 2011).



Şekil 1. YSA çalışma yapısı

Bulduğu ortama uyum sağlayabilen, örnekleri kullanarak öğrenebilen, eksik verilere rağmen çalışabilen bir algoritmadır. Sınıflandırma, örüntü tanıma, sinyal filtreleme, veri sıkıştırma ve optimizasyon gibi çalışmalarda YSA en başarılı yöntemler arasında yer almaktadır. Veri madenciliği, yön belirleme, parmak izi tanıma, malzeme analizi, kalite kontrol, tıbbi analizler gibi

pek çok alanda günlük hayatta karşılaşılabilecek başarılı çalışmalar bulunmaktadır (Öztemel, 2003).

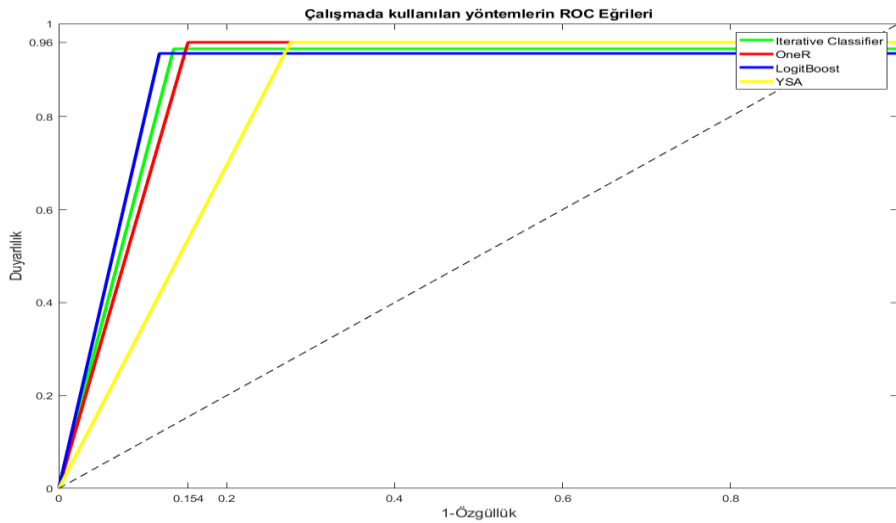
### 3. BULGULAR

Bu çalışmada kullanılan veri seti üzerinde Intel Core i7-4720 HQ işlemciye ve 12 GB belleğe sahip bilgisayar aracılığıyla Weka (URL-1) yazılımı kullanılarak çeşitli veri madenciliği yöntemleri denenmiştir. 3 farklı yöntem ve objektif olarak değerlendirme yapılabilmesi adına her yöntem için 3 ayrı fold değeri ile analizler gerçekleştirilmiştir. Veri madenciliği yöntemleri ile oluşturulan modellerin değerlendirme ölçütü olarak doğruluk, özgüllük ve duyarlılık değerleri kullanılmıştır. Ayrıntılar Tablo 1'de verilmiştir.

**Tablo 1.** Analiz sonuçları

Sınıflandırma Algoritmaları	Fold	Duyarlılık	Özgüllük	Doğruluk
Iterative Classifier Optimizer	5	%96	%86	%92.41
	7	%94	%87	%91.90
	10	%94	%86	%91.39
	Ort.	%94.6	%86.3	%91.9
OneR	5	%96	%84	%92.15
	7	%96	%86	%92.15
	10	%96	%84	%92.15
	Ort.	%96	%84.6	%92.15
LogitBoost	5	%94	%88	%92.15
	7	%93	%88	%91.90
	10	%94	%88	%91.89
	Ort.	%93.6	%88	%91.98
YSA	5	%96.4	%76.6	%89.11
	7	%95.6	%69.6	%86.07
	10	%96	%71	%86.8
	Ort.	%96	%72.4	%87,32

Gerçekleştirilen analizlerin ROC eğrisi Şekil 2'de verilmiştir.



**Şekil 2.** Kullanılan yöntemlerin ROC eğrileri

Veri madenciliği yöntemleri ile oluşturulan modellerin değerlendirme ölçütü olarak doğruluk, özgüllük ve duyarlılık değerleri kullanılmıştır. Veri kümesi üzerinde 5, 7 ve 10 fold değerleri kullanılarak ölçütler için en iyi sonuçlara ulaşılmaya çalışılmıştır. Kullanılan veri kümesi üzerinde yapılan ilk analizler neticesinde doğruluk değerine bakıldığında en iyi performans Iterative Classifier Optimizer (5 fold) ile sağlanmıştır.

Iterative Classifier Optimizer yöntemiyle 5, 7 ve 10 fold için elde edilen sonuçlara bakıldığında en yüksek değerler 5 fold ile elde edilmiştir. OneR yöntemi incelendiğinde ise değerlendirme ölçütlerinde en iyi sonuçları 7 fold vermiştir. LogitBoost yönteminde 5 fold ile yapılan deneyler sonucu en yüksek değerler elde edilmiştir. YSA algoritması ile yapılan analizler neticesinde en yüksek başarı oranı 5 fold ile yapılan deneylerle elde edilmiştir.

Deneylerin gerçekleştirildiği 3 ayrı fold değeri için ortaya çıkan değerlendirme ölçütlerinin her bir yöntem için ortalaması alınmıştır. Bu sonuçlara göre doğruluk değeri için en iyi ortalamanın OneR yönteminde olduğu görülmektedir. Duyarlılık için ortalamalar bazında değerlendirildiğinde en iyi sonucun yine OneR yönteminde olduğunu, özgüllük değerlerinde ortalamalara bakıldığında ise en iyi sonucu LogitBoost yöntemi vermektedir.

Tüm değerlerin ortalamaları baz alındığında özgüllük değeri diğer algoritmalara göre düşük performans gösterse de yaklaşık %2'lik bir farktan bahsedildiği için göz ardı edilebilir ve bu veri seti için en başarılı yöntem olarak OneR önerilmektedir.

#### 4. SONUÇLAR

Öğrenciler yaşamlarının belli dönemlerinde zamanlarının büyük bir çoğunluğunu okul ortamlarında harcamaktadır. Bu süreçte öğrenim hayatlarını etkileyen, karşılaştıkları pek çok olumsuz faktör bulunmaktadır; yeni ortamın getirdiği uyum sorunu, alınan derslerdeki başarısızlıklar, öğretmenler ile ilgili sorunlar, arkadaş çevresi ile ilgili sorunlar, ebeveyn ortamından kaynaklı sorunlar vb. durumlar günümüzde öğrencilerin başarı düzeylerinin belirlenmesinde ana etkenler arasında görülmektedir. Literatür araştırmalarında bu problemin tespit ve çözümlenmesi hususunda birçok YSA ve veri madenciliği çalışmalarının yapıldığı görülmektedir. Bu araştırmada, ortaöğretimdeki öğrencilerin karşılaştıkları sorunların, öğrencinin başarı performansına olumsuz etki eden ana faktörlerin belirlenmesi amaçlanmaktadır. Söz konusu araştırma ortaöğretimde öğrenim gören öğrencilerin başarı düzeylerini etkileyen etmenlerin neler olduğunu ortaya koyması bakımından önem teşkil etmektedir. Çalışmada literatüre kıyasla farklı sınıflandırma algoritmaları kullanılarak analizler gerçekleştirilmiştir. Öğrencinin başarı düzeyinin sınıflandırılması için Iterative Classifier Optimizer, OneR ve LogitBoost ile YSA yöntemleri uygulanmış ve OneR veri madenciliği yönteminin diğer yöntemlere kıyasla daha olumlu sonuçlar sergilediği tespit edilmiştir. Öğrencinin başarı düzeyinin arttırılmasında göz önünde bulundurulması gereken nokta, performans etki eden ana faktörler öncelikle tespit ve teşhis edilmeli, ardından gerekli iyileştirmelerin yapılması önerilmektedir. Bu sayede, performansın gerektirdiği salt faktörler belirlenebilir ve öğrenci başarı eğilimleri farklı konularda yoğunlaştırılabilir. Gelecek çalışmalarda, daha farklı veri madenciliği yöntemleriyle deneyler gerçekleştirilebileceği gibi öğrenci başarısını etkileyen faktörler arasından en etkililerini tespit etmek için analizler gerçekleştirilebilir.

#### KAYNAKÇA

- Altun, M., KAYIKÇI, K., & Irmak, S. (2019). Sınıf Öğretmenliği Öğrencilerinin Mezuniyet Notlarının Regresyon Analizi ve Yapay Sinir Ağları Yöntemleriyle Tahmini/Estimation of Graduation Grades of Primary Education Students by Using Regression Analysis and Artificial Neural Networks. *e-Uluslararası Eğitim Araştırmaları Dergisi*, 10(3), 29-43.
- Arslan B., & Babadoğan, C. (2005). İlköğretim 7. ve 8. sınıf öğrencilerinin öğrenme stillerinin akademik başarı düzeyi, cinsiyet ve yaş ile ilişkisi. *Eurasian Journal of Educational Research*, 31, 35-48.

- Aydemir, E. (2019). Ders Geçme Notlarının Veri Madenciliği Yöntemleriyle Tahmin Edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (15), 70-76.
- Aydın, F., & Aslan, Z. (2017). Yapay Öğrenme Yöntemleri ve Dalgacık Dönüşümü Kullanılarak Nöro Dejeneratif Hastalıkların Teşhisi. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 32(3).
- Alves, E. T. A., Frucht, L. C., Souza, M. N., & Nóbrega, A. F. A. (2012, March). Iterative optimization algorithm- An alternative clustering tool for biological analysis using flow cytometry data. *In 2012 Pan American Health Care Exchanges* (pp. 66-70). IEEE.
- Cortez, P., & Silva, A. M. G. (2008). Using data mining to predict secondary school student performance. *In the Proceedings of 5th Annual Future Business Technology Conference*, Porto, Portugal, 5-12.
- Daş, B., & Türkoğlu, İ. (2014). DNA dizilimlerinin sınıflandırılmasında karar ağacı algoritmalarının karşılaştırılması. *Elektrik-elektronik-bilgisayar ve Biyomedikal Mühendisliği Sempozyumu (ELECO 2014)*, 381-383.
- Gorr, W. Lç, Nagin, D., & Szczyppula, J. (1994). Comparative study of artificial neural network and statistical models for predicting student grade point averages. *International Journal of Forecasting*, 10(1), 17-34.
- Güre, Ö. B., Kayri, M., & Erdoğan, F. (2020). PISA 2015 Matematik Okuryazarlığını Etkileyen Faktörlerin Eğitsel Veri Madenciliği ile Çözülmesi. *Eğitim ve Bilim*.
- Holte, R. C. (1993). Very simple classification rules perform well on most commonly used datasets. *Machine learning*, 11(1), 63-90.
- İstenmeyen Elektronik Posta (Spam) tespitinde karar ağaç algoritmalarının performans kıyaslaması. *Journal of Internet Applications & Management/İnternet Uygulamaları ve Yönetim Dergisi*, 5(2).
- Manikandan, G., Aravind, V., & Anitha, B. (2018). A Survey to Identify an Efficient Classification Algorithm for Heart Disease Prediction. *International Journal of Pure and Applied Mathematics*, 119(2), 13337-13345.
- Osborn, J., Francisco Javier De, C. J., Guzman, D., Butterley, T., Myers, R., Guesalaga, A., & Laine, J. (2011). *Using artificial neural networks for open-loop tomography*. Ithaca: Cornell

University Library, arXiv.org.  
doi:http://dx.doi.org/10.1364/OE.20.002420

Öztemel, E. (2003). Yapay sinir ağları. *PapatyaYayincilik, İstanbul.*

Subba Narasimha, P. N., Arinze, B., & Anandarajan, M. (2000). The predictive accuracy of artificial neural network and multiple regression in the case of skewed data. *Exploration of some issues. Expert systems with Applications*, 19(2), 117-123.

Tosun, S. (2007). *Sınıflandırmada yapay sinir ağları ve karar ağaçları karşılaştırması: öğrenci başarıları üzerine bir uygulama.* (Yayımlanmamış yüksek lisans tezi). İstanbul Teknik Üniversitesi/Fen Bilimleri Enstitüsü, İstanbul.

Uzun, Y. (2005). *Tıbbi veriler üzerinde makine öğrenme algoritmaları ve bulanık mantık ile kurallar öğrenme.* (Yayımlanmamış yüksek lisans tezi). Selçuk Üniversitesi/Fen Bilimleri Enstitüsü, Konya.

URL-1:[https://waikato.github.io/weka-wiki/citing\\_weka/](https://waikato.github.io/weka-wiki/citing_weka/) [Erişim Tarihi: 23.04.2020]