

Makine Öğrenmesi Kullanarak Öğrencilerin Özelliklerine Göre Matematik Dersindeki Başarı Durumunun Tahmin Edilmesi

Muhammet Semih KELEŞ^{1*}, Ayşegül ALAYBEYOĞLU²

¹Yazılım Mühendisliği / Fen Bilimleri Enstitüsü, İzmir Kâtip Çelebi Üniversitesi, Türkiye

²Yazılım Mühendisliği / Fen Bilimleri Enstitüsü, İzmir Kâtip Çelebi Üniversitesi, Türkiye

Email of corresponding author: semihkeles1997@hotmail.com

(Received: 22 February 2024, Accepted: 08 March 2024)

(4th International Artificial Intelligence and Data Science Congress ICADA 2024, March 14-15, 2024)

ATIF/REFERENCE: Keleş, M. S. & Alabeyoğlu, A. (2024). Makine Öğrenmesi Kullanarak Öğrencilerin Özelliklerine Göre Matematik Dersindeki Başarı Durumunun Tahmin Edilmesi. *International Journal of Advanced Natural Sciences and Engineering Researches*, 8(2), 28-35.

Özet – Bu çalışmanın amacı öğrencilerin özelliklerine, tercihlerine ve ebeveyn eğitim durumlarına bakarak matematik dersindeki başarı durumunu tahmin etmektir. İlgili çalışmada 1000 öğrencinin cinsiyet, etnik grup, ebeveyn eğitim durumu, öğle yemeği tercihi, sınava hazırlık durumu, okuma skoru, yazma skoru ve matematik skoru öznitelikleri kullanılmıştır. Verilerin %70'i eğitim, %30'u ise test için ayrılmıştır. Matematik skoru için 60 ve üstü 'Başarılı', altı ise 'Başarısız' olarak kabul edilmiştir. Tahmin sürecinde KNN, Logistic Regression, Naive Bayes ve Decision Tree algoritmaları kullanılmıştır. Her bir algoritma için ayrı ayrı Confusion Matrix'ler oluşturulmuş ve Accuracy, Precision ve F1 skorları hesaplanmıştır. Eğitilen verilerden alınan sonuçlara göre (300 veri) KNN algoritması için True Positive (TP) değeri 61, True Negative değeri (TN) 187, False Positive (FP) değeri 15 ve False Negative değeri (FN) 37 olarak; Naive Bayes algoritması için TP değeri 76, TN değeri 175, FP değeri 15 ve FN değeri 22 olarak; Logistic Regression algoritması için TP değeri 78, TN değeri 187, FP değeri 15 ve FN değeri 20 olarak; Decision Tree algoritması için ise TP değeri 86, TN değeri 182, FP değeri 20 ve FN değeri 12 olarak bulunmuştur. Ayrıca elde edilen F1 skorlarına bakıldığında KNN için 0.8201, Naive Bayes için 0.8376, Logistic Regression için 0.8825 ve Decision Tree için ise 0.8943 değerleri bulunmuştur. Bu sonuçlar ışığında eğitilen algoritmalar arasında en iyi sonuçları veren algoritmalar sıralaması Decision Tree > Logistic Regression > Naive Bayes > KNN şeklindedir.

Anahtar Kelimeler – Makine Öğrenmesi, Yapay Zekâ, Matematik, Öğrenci Başarı Durumu, Başarı Durumu Tahmini

I. GİRİŞ

Bu çalışma makine öğrenmesi kullanarak 1000 öğrencinin; cinsiyet, etnik grup, ebeveyn eğitim durumu, öğle yemeği tercihi, sınava hazırlık durumu, matematik skoru, okuma ve yazma skoru bilgileri ile öğrencinin cinsiyet, etnik grup, ebeveyn öğrenim durumu, öğle yemeği tercihi, ön testi tamamlama durumu, okuma ve yazma skorlarının matematik dersindeki başarı durumuna olan etkisi incelemek üzerine gerçekleştirilmiştir. İlgili çalışmada amaç seçilen özniteliklerin öğrencinin matematik skoru, dersindeki başarısını tahmin etmek ve buna bağlı olarak elde edilen sonuçlar neticesinde yeni bir öğrencinin özelliklerine ve skorlarına bakarak bu öğrencinin ilgili şartlardaki matematik dersinde başarılı olup olmayacağını tahmin etmektir. Başarı eşik notu 60 olarak belirlenmiş olup mevcut verilerdeki matematik skoru 60 ve 60'ın üzerinde olan öğrenci "Başarılı", 60'tan düşük olan öğrenciler 'Başarısız' olarak

nitelendirilmiştir. Araştırmada Makine Öğrenmesinin Denetimli Öğrenme (Supervised Learning) modeli, tekniklerinden Sınıflandırma (Classification) tekniğinin, "Başarılı/Başarısız" sonuçları olmak üzere 2 farklı tahmin seçeneği olduğundan İkili Sınıflandırma (Binary Classification) çeşidi seçilmiştir. Algoritma olarak ise; sınıflandırma işlemlerinde en çok kullanılan supervised learning yöntemlerinden biri olan KNN (K-En Yakın Komşu), Logistic Regression (Lojistik Regresyon), Navie Bayes ve Decision Tree (Karar Ağacı) algoritmaları kullanılmıştır.

II. LİTERATÜR TARAMASI

"Gelişmiş ve gelişmekte olan ülkeler örgün ve yaygın eğitim kurumları aracılığıyla vatandaşlarına 21.yüzyılın gerektirdiği becerileri kazandırma hedefindedirler. Bu hedefe erişebilmek ve sahip oldukları insan gücünü çağın gerektirdiği niteliklerle donatabilmek için belirli periyotlarla uluslararası düzeyde gerçekleştirilen değerlendirme sınavlarına katılmaktadırlar" (Kamens ve McNeely, 2010, s. 5) [1] (Karalı, Coşanay, Aydemir, 2019) [2]. "Akademik başarı etkileyen birçok faktör bulunmaktadır. Ailenin sosyo-ekonomik durumu, eğitim anlayışı, çocuklara yönelik tutum ve davranışları (Çelenk, 2003; Şama ve Tarım, 2007; Savaşçı, 2010) [3]-[4]-[5] öğrencinin bilişsel-duyuşsal ve sosyal gelişimi, motivasyon düzeyi ve okula yönelik algısı (Atılğan, 1998; Eymur ve Geban, 2011) [6]-[7] okulun fiziki yapısı ve okul iklimi, öğretmenlerin öğrencilere yönelik tutumu ve mesleki yeterlikleri (Demir, 2009; Kurt ve Çalık, 2010) [8], [9] bu faktörlerin başında gelmektedir." (Karalı, Coşanay, Aydemir, 2019) [2]. Türkiye'de her geçen gün eğitim alanında yenilikler yapılmakta ve eğitim kalitesinin artması amaçlanmaktadır. Ancak ulusal ve uluslararası sınavlara giren öğrencilerin akademik başarılarının çok da yüksek olmadığı görülmektedir. "Türkiye'nin TIMSS sınavlarında ufak artışlar göstermesine karşın her sınavda uluslararası ortalamanın altında kaldığını göstermiştir." (Bütüner, 2017) [10] Bununla beraber yapılan çalışmalar ortaokullarda görev yapan öğretmenlerin de öğrencilerinin PISA ve TIMSS sınavlarına göre başarılarının düşük olduğunu belirtmişlerdir. [11] Tüm bu çalışmalar göstermektedir ki öğrencilerin başarı durumları eğitime bağlı olabileceği gibi sosyal, kültürel ve okulun fiziki durumlarına da bağlı olabilmektedir. Bu çalışma ile öğrencilerin demografik özelliklerinin, ebeveyn eğitim durumlarının, beslenme durumlarının, teste ön hazırlığı tamamlama durumlarının, okuma ve yazma skorlarının; matematik dersindeki başarı durumuna olan etkileri incelenmeye çalışılmaktadır. Amaç ilgili öğrencilerin belirli özelliklere göre matematik dersindeki başarı durumunu tahmin etmektir.

III. MATERYAL VE YÖNTEM

A. Kısaltmalar

Tablo 1. Kısaltmalar

TP	True Positive	Pozitif değeri doğru bir şekilde etiketlemek
TN	True Negative	Negatif değeri doğru bir şekilde etiketlemek
FP	False Positive	Negatif değeri hatalı şekilde etiketlemek
FN	False Negative	Pozitif değeri hatalı şekilde etiketlemek
OHE	One Hot Encoder	İlgili değerleri Binary sistemi ile etiketlemek
LE	Label Encoder	İlgili değerleri 1-2-3 şeklinde sıralı şekilde etiketlemek

B. Veri Seti (Data Set)

Bu çalışmada kullanılan veri seti, öğrenciler tarafından çeşitli konularda güvence altına alınan notlardan oluşmaktadır. İlgili veri setinde cinsiyet, etnik grup, ebeveyn eğitim durumu, öğle yemeği tercih durumu, ön test tamamlama durumu, matematik skoru, okuma skoru ve yazma skoru öznitelikleri *Tablo 1*'de gösterilmektedir.

Tablo 2. Eğitim veri seti öznitelikleri ve açıklamaları

OHE	Cinsiyet	Male / Female
OHE	Etnik Grup	Group A, Group B, Group C, Group D, Group E
LE	Ebeveyn Eğitim Durumu	High School, Associate's Degree, Bachelor's Degree, Master's Degree
OHE	Öğle Yemeği Tercih Durumu	Standard, Free, Reduced
LE	Ön Test Tamamlama Durumu	Completed, None
-	Matematik Skoru	0-100 arası numerik değer
-	Okuma Skoru	0-100 arası numerik değer
-	Yazma Skoru	0-100 arası numerik değer

Öğrencilerin derslerindeki başarı durumu ve puan ölçeği ise *Tablo 3* 'te gösterilmektedir.

Tablo 3. Öğrencilerin derslerindeki başarı durumu ve puan ölçeği

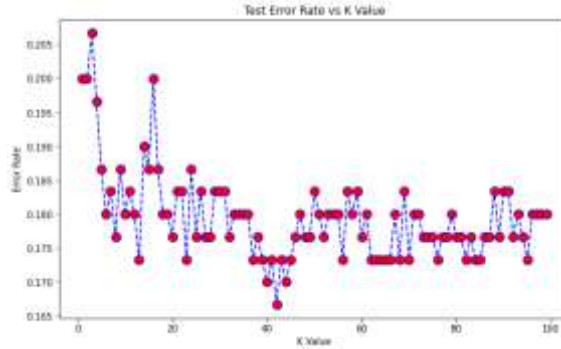
Başarı Skoru	Etiket
≥ 60	Başarılı
< 60	Başarısız

C. Deneylerde Kullanılan Algoritmalar

- **K-En Yakın Komşu Algoritması (K-Nearest Neighbour KNN Algorithm)**

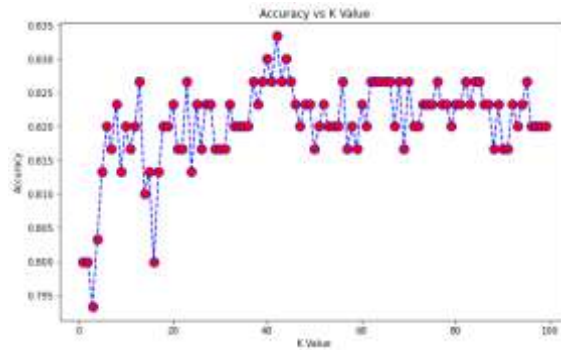
Sınıflandırma ve regresyon işlemlerinde kullanılabilen ve sıklıkla tercih edilen algoritmalarından biridir. Özniteliklerin birbirlerine olan uzaklıklarının Öklid işlemi ile hesaplanması ile isminde de geçen K parametresi ile en yakın K sayıdaki örneğe bakarak sınıflandırma işleminin yapıldığı algoritmadır. [12]-[13] İşlemin sonunda örneğimiz, K parametresi kadar örneğin içerisinde bulunulduğu sınıfa giriyor ise KNN algoritması çoğunluğun bulunduğu etiketi vermektedir. Örneğin K parametresi 3 verilmiş ve işlemin sonunda ulaşılmış örneklerin sınıf etiketleri "Başarılı", "Başarılı" ve "Başarısız" ise KNN algoritması etiketlemek istediğimiz örneği "Başarılı" etiketi ile etiketleyecektir. Özellikle sınıflandırma işlemlerinde genellikle K değeri tek sayı olarak seçilmektedir. Bunun sebebi işlemin sonunda elde edilecek etiketlerin yarı yarıya olma durumunu engellemektir. Örneğin K değerinin 4 seçilme durumunda ve işlemin sonunda "Başarılı", "Başarılı", "Başarısız" ve "Başarısız" etiketlerine sahip örneklerin getirilmesi sonucunda KNN algoritması sağlıklı bir etiketleme işlemi yapamayacaktır. Regresyon işleminde de aynı işlemler yapıp K kadar örneğin ortalaması hesaplanmaktadır. İlgili örnek için KNN algoritması hazırlanırken öncelikle

uygun K değeri bulunmalıdır. Bunun için farklı K değerleri ile model eğitilmiş ve grafiğe dönüştürülmüştür. (Grafik KNN1) İlgili tabloda K değerleri ile hata oranları karşılaştırılmıştır.



Şekil 1. KNN1

Grafikten de anlaşıldığı üzere hata oranı en düşük K değeri 40-45 aralığında görülmektedir. Yapılan çalışmada da en uygun K değeri 41 olarak bulunmuştur. Aynı şekilde farklı K değerleri üzerinden Accuracy değerleri hesaplanmış olup en uygun K değeri yine 41 olarak bulunmuştur. (Grafik KNN2) K = 41 için Accuracy değeri 0.8266 olarak bulunmuştur.



Şekil 2. KNN2

İlgili değerlerden yola çıkarak K'nın en uygun değeri 41 olarak bulunmuş olup K=41 için model eğitilmiştir. Bu değerle model eğitildiğinde hata oranı 0.1666, Accuracy değeri ise 0.8266 olarak bulunmuştur.

Ancak Accuracy değeri her zaman tek başına yeterli olamayabilmektedir. Çünkü Accuracy değeri doğru olarak yapılan tahminlerin tüm tahminlere oranını almaktadır. Dolayısıyla elde edilen sonuçlar yanıltıcı olabilmektedir. Accuracy değeri ile Precision ve Recall değerlerinin de hesaplanması gerekir. Daha sonra tüm bu değerlerin harmonik ortalaması alınmalıdır. Precision (Kesinlik) değeri pozitif olarak tahmin edilen değerlerin gerçekten kaç adedinin pozitif olduğunu hesaplamak için kullanılmaktadır. Recall (Duyarlılık) değeri ise pozitif tahin edilmesi gereken değerlerin ne kadarının pozitif olarak tahmin edildiğini göstermektedir. Daha sonra elde edilen Precision ve Recall değerlerinin harmonik ortalaması alınmalıdır. Bunun sebebi veri setindeki uç durumların göz ardı edilmemesi gerektiğindedir. Harmonik ortalama ise F1 Score ile hesaplanabilmektedir.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$F_1 = \frac{Precision * Recall}{Precision + Recall}$$

K'nın en uygun değeri olan 41 için hesaplanan Precision skoru 0.8243, Recall skoru 0.8266 ve F1 skoru ise 0.8201 olarak bulunmuştur. İlgili sonuçlar Confusion Matrix ile grafikleştirilmiş ve ortaya *Grafik KNN3* grafiği çıkmıştır. Bu sonuçlarla görüldüğü üzere üretilen modelin; 'Başarılı' etiketine sahip 61 öğrenciyi (TP) ve 'Başarısız' olan 15 öğrenciyi (FP) 'Başarılı' etiketi ile; 'Başarılı' etiketine sahip 37 öğrenciyi (FN) ve 'Başarısız' etiketine sahip 187 öğrenciyi (TN) ise 'Başarısız' etiketi ile etiketlemiştir.



Şekil 3. KNN3

- **Naive Bayes Algoritması**

Genellikle metin sınıflandırma projelerinde kullanılan Naive Bayes algoritması supervised (denetimli) öğrenme modeli ile gerçekleşen bir sınıflandırma algoritmasıdır. Bağımsız değişkenin, bağımlı değişken üzerindeki etkilerine göre istatistik ve olasılık temellerine göre yeni bir durumu sınıflandırma işlemidir.

Durumların olasılık değerlerinin hesaplandığı formül:

$$X = [x_1, x_2, x_3, \dots, x_n]$$

$$C = [c_1, c_2, c_3, \dots, c_n]$$

$$P(C_i/x) = \frac{p(x/C_i)}{P(x)}$$

Yeni durum ise $argmax_{c_i} P(x/c_i)P(c_i)$ formülü kullanılarak hesaplanan en yüksek olasılık değerinin sınıfına atanır. [13]

İlgili örnek için Naive Bayes algoritması kullanıldığında elde edilen Accuracy değeri 0.8366, Precision değeri 0.8391, Recall değeri 0.8366 ve F1 skoru ise 0.8376 olarak bulunmuştur. Oluşturulan Confusion Matrix ile (*Grafik NBI*) de modelin 'Başarılı' etiketine sahip 76 öğrenciyi (TP) ve 'Başarısız' etiketine sahip 27 öğrenciyi (FP) 'Başarılı' etiketi ile; 'Başarılı' etiketine sahip 22 öğrenciyi (FN) ve 'Başarısız' etiketine sahip 175 öğrenciyi (TN) 'Başarısız' etiketi ile etiketlediği görülmektedir.

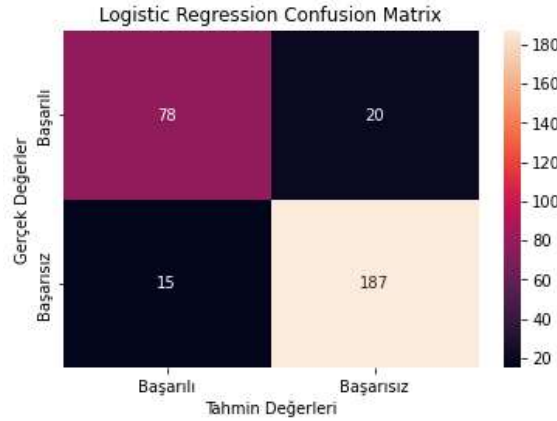


Şekil 4. NB1

- **Lojistik Regresyon (Logistic Regression)**

Lojistik Regresyonda bağımlı ve bağımsız değişken arasında en az değişken ile en iyi uyum sağlamak amaçlanmaktadır. Lojistik Regresyon, bir sınıfı tahmin edebilmek için bağımsız çoklu değişkenlerin etkisini hesaplamaktadır. [15]

İlgili örnek için Lojistik Regresyon kullanıldığında elde edilen Accuracy değeri 0.8833, Precision değeri 0.8822, Recall değeri 0.8833 ve F1 skoru ise 0.8825 olarak bulunmuştur. Elde edilen sonuçlarla oluşturulan Confusion Matrix ile (*Grafik LR1*) de ilgili örnekler için modelin 'Başarılı' etiketine sahip 78 öğrenciyi (TP) ve 'Başarısız' etiketine sahip 15 öğrenciyi (FP) 'Başarılı' etiketi ile etiketlediği; 'Başarılı' etiketine sahip 20 öğrenciyi (FN) ve 'Başarısız' etiketine sahip 187 öğrenciyi (TN) de 'Başarısız' etiketi ile etiketlediği görülmektedir.



Şekil 5. LR1

- **Karar Ağacı (Decision Tree)**

Karar Ağacı isminden de anlaşılacağı üzere ağaç biçiminde bir yapı oluşturularak karar verme işleminin yapıldığı bir yapıdır. Karar ağaçlarında karar düğümleri (decision nodes) ve yaprak düğümleri (leaf nodes) bulunmaktadır. Karar düğümleri; karar verme, sınıflandırma yapma, tahmin etme gibi işlemleri gerçekleştirirken yaprak düğümleri ise bu kararların tutulduğu yerdir. Ağacın başı kök düğüm (root node) olarak isimlendirilir ve karara bağlanmak için kök düğümden yaprak düğümlere doğru belli bir yol izlenmektedir. [15]

İlgili örnek için oluşturulan karar ağacında elde edilen Accuracy değeri 0.8933, Precision değeri 0.8967, Recall değeri 0.8933 ve F1 skoru ise 0.8943 olarak bulunmuştur. Oluşturulan Confusion Matrix ile (*Grafik DT1*) de modelin 'Başarılı' etiketine sahip 86 öğrenciyi (TP) ve 'Başarısız' etiketine

sahip 20 öğrenciyi (FP) 'Başarısız' etiketi ile; 'Başarılı' etiketine sahip 12 öğrenciyi (FN) ve 'Başarısız' etiketine sahip 182 öğrenciyi (TN) 'Başarısız' etiketi ile etiketlediği görülmektedir.



Şekil 5. DT1

D. Öznitelik Seçimi (Feature Selection)

Bir öğrencinin ders başarısını etkileyen birçok etken bulunmaktadır. Bu etkenlerin (özniteliklerin) seçimi doğru yapılmalıdır. Bu etkenler aynı zamanda ölçülebilen faktörlerdir. Burada önemli olan bu etkenlerin öğrencinin başarısına ne kadar etkisinin olduğunun bilinmesi/öğrenilmesidir. Bu etkenlerin tümüne aynı anda bakmak yerine ayrı ayrı bakmak hem regresyon hem de sınıflandırma yöntemlerinin tahmin edilebilmesini kolaylaştırabilir. Bu çalışmada ayrı ayrı olacak şekilde önce öğrencinin cinsiyetinin, daha sonra sırasıyla etnik grubunun, ebeveyn eğitim durumunun, öğle yemeği tercih durumunun ve ön testi tamamlama durumunun; matematik, okuma ve yazma skoruna etkisi; daha sonra ise matematik skorunun okuma ve yazma skoruna etkisi, daha sonra okuma skorunun matematik ve yazma skoruna etkisi; en son ise yazma skorunun matematik ve okuma skoruna etkisi incelenecektir.

IV. SONUÇLAR VE TARTIŞMA

Bir öğrencinin başarılı ya da başarısız olmasını etkileyen birçok etken bulunmaktadır. İlgili çalışmada ise öğrencilerin cinsiyetleri, etnik kökenleri (Grup A, Grup B, Grup C, Grup D ve Grup E şeklinde), ebeveynlerinin eğitim durumu, öğle yemeğini yeme durumları, ön testi tamamlama durumları, yazma ve okuma skorları olmak üzere 7 öznitelik ve 1000 örnek kullanılmıştır. İlgili örnekler %70'i (700 örnek) eğitim ve %30'u (300 örnek) test olmak üzere ayrılmıştır. Eğitim veri seti için KNN, Naive Bayes, Lojistik Regresyon ve Karar Ağacı modelleri kullanılmıştır. Bu doğrultuda her model için Accuracy, Precision, Recall ve F1 skorları hesaplanmıştır. Yine her örnek için Confusion Matrix oluşturulmuştur.

İlgili veri seti ile geliştirilen KNN, Naive Bayes, Logistic Regression ve Decision Tree algoritmaları ile ilgili elde edilen TP, FP, Accuracy, Precision, Recall ve F1 skorları *Tablo S1* ve *Tablo S2*'de gösterilmektedir.

Tablo 4. S1

	TP	TN	FP	FN
KNN	61	187	15	37
Naive Bayes	76	175	27	22
Logistic Regression	78	187	15	20
Decision Tree	86	182	20	12

Tablo 5. S2

	Accuracy	Precision	Recall	F1
KNN	0.8266	0.8243	0.8266	0.8201
Naive Bayes	0.8366	0.8391	0.8366	0.8367
Logistic Regression	0.8833	0.8822	0.8833	0.8825
Decision Tree	0.8933	0.8967	0.8933	0.8943

Tüm bu sonuçlar ışığında F1 skorlarının Precision ve Recall değerlerinin harmonik ortalamasını verdiği de düşünüldüğünde en iyi algoritma seçiminde F1 skor değerinin karar vericiliğinin en yüksek olduğu düşünülebilir. İlgili sonuçlar incelendiğinde ise en yüksek F1 skorunun 0.8943 ile Karar Ağacı (Decision Tree) modeline ait olduğu görülmektedir. Dolayısıyla bu çalışmada en iyi sonucun Karar Ağacı modeli ile alındığı söylenebilir. Yapılan deneyde kullanılan algoritmaların sıralanması istendiğinde ise ilgili sıralama; Karar Ağacı > Lojistik Regresyon > Naive Bayes > KNN şeklinde olacaktır.

KAYNAKLAR

- [1] D. H. Kamens and C. L. McNeely, "Globalization and the growth of international educational testing and national assessment," *Comparative Education Review*, vol. 54, pp. 5–25, feb 2010.
- [2] Y. KARALI, G. COŞANAY, and H. AYDEMİR "İlkokul 4. sınıf düzeyi öğrencilerin timss 2019 sonuçlarına göre fen başarı puanlarının okul iklimi değişkeni açısından incelenmesi investigation of science achievement scores of primary school 4th grade students according to timss 2019 results in terms of school climate variable,"
- [3] S. Çelenk, "Okul başarısının Ön koşulu: Okul aile dayanışması" *İlköğretim Online*, vol. 2, no. 2, pp. –, 2003.
- [4] E. Şama and K. Tarım, "Öğretmenlerin başarısız olarak algıladıkları öğrencilere yönelik tutum ve davranışları" *Journal of Turkish Educational Sciences*, vol. 5, no. 1, 2007.
- [5] H. S. Savaşçı, "Sosyoekonomik değişkenlerin ve okulun eğitim kaynaklarının ilköğretim 7. sınıf öğrencilerinin akademik başarı düzeyleri ile ilişki durumu" Master's thesis, Sosyal Bilimler Enstitüsü, 2010.
- [6] M. Atılğan, "Üniversite öğrencilerinin ders çalışma alışkanlıkları ile akademik başarılarının karşılaştırılması," Gaziantep Üniversitesi, Sosyal Bilimler Enstitüsü, Gaziantep, 1998.
- [7] G. Eymur and Ö. Geban, "Kimya öğretmeni adaylarının motivasyon ve akademik başarıları arasındaki ilişkinin incelenmesi" *Eğitim ve Bilim*, vol. 36, no. 161, 2011.
- [8] C. Engin-Demir, "Factors influencing the academic achievement of the turkish urban poor," *International Journal of Educational Development*, vol. 29, no. 1, pp. 17–29, 2009.
- [9] T. Kurt and T. Çalık, "Okul iklimi ölçeğinin (oiö) geliştirilmesi" *Eğitim ve Bilim*, vol. 35, no. 157, 2010.
- [10] S. O. Bütüner and M. Güler, "Gerçeklerle yüzleşme: Türkiye'nin timss matematik başarıları Üzerine bir Çalışma," 2017.
- [11] K. Bozdoğan and M. Yıldırım, "Türk Öğrencilerin uluslararası sınavlardaki fen başarıları ile ilgili Öğretmen görüşlerinin İncelenmesi" *Uluslararası Beşeri Bilimler ve Eğitim Dergisi*, vol. 6, no. 14, pp. 491–515, 2020.
- [12] Y. Özkan and V. M. Yöntemleri, "Papatya yayıncılık eğitim" İstanbul, Mayıs-2008, 2013.
- [13] M. Aydoğan and A. Karcı, "Meslek yüksekokulu öğrencilerinin başarı performanslarının makine öğrenmesi yöntemleri ile analizi" in *International Symposium on Multidisciplinary Studies and Innovative Technologies*, 2018.
- [14] I. H. M. Paris, L. S. Affendey, and N. Mustapha, "Improving academic performance prediction using voting technique in data mining," *International Journal of Computer and Information Engineering*, vol. 4, no. 2, pp. 306–309, 2010.
- [15] S. R. Safavian and D. Landgrebe, "A survey of decision tree classifier methodology" *IEEE transactions on systems, man, and cybernetics*, vol. 21, no. 3, pp. 660–674, 1991.