

Yapay Zekâ Uyumlu Algoritmalarla Öğrencilerin LGS Puanı Tahmini ve Modellenmesi

Mehmet Bilal ER¹, Hasan Celal BALIKÇI², Mustafa ALPSÜLÜN³, Zehra
BOZDAĞ KARAKEÇİ⁴, Ahmet YILDIZ⁵, Ahat TEZCAN⁶, Neslihan TANCI
YILDIRIM⁷

¹ Harran Üniversitesi, Siverek MYO, Şanlıurfa, Türkiye, bilal.er@harran.edu.tr, 0000-0002-2074-1776

² Harran Üniversitesi, Siverek MYO, Şanlıurfa, Türkiye, hcelal@harran.edu.tr, 0000-0002-1539-1863

³ Harran Üniversitesi, Siverek MYO, Şanlıurfa, Türkiye, musalp@harran.edu.tr, 0000-0003-2928-218X

⁴ Harran Üniversitesi, Siverek MYO, Şanlıurfa, Türkiye, zbozdog@harran.edu.tr, 0000-0002-1119-5275

⁵ Harran Üniversitesi, Siverek MYO, Şanlıurfa, Türkiye, ahmet.yildiz@harran.edu.tr, 0000-0003-3992-2240

⁶ Harran Üniversitesi, Siverek MYO, Şanlıurfa, Türkiye, ahattezcan@harran.edu.tr, 0000-0001-8072-4495

⁷ Harran Üniversitesi, Siverek MYO, Şanlıurfa, Türkiye, neslihintanci@harran.edu.tr, 0000-0002-3477-4384

Öz

Liselere Giriş Sınavı (LGS) ortaokul 8. sınıf öğrencilerinin girdikleri ve aldıkları puanlara göre okuyacakları liseleri belirlemektedir. Bu sınav ile öğrencinin eğitim öğretim becerileri sınanmaktadır. Öğrencilerin sınav başarısını, öğrencinin sosyal-ekonomik durumu, aile ortamı, ebeveyn eğitim durumu, cinsiyeti ve önceki yıllara ait eğitim verilerinde gibi faktörler etkilemektedir. Bu faktörlerin sınav başarısındaki etkilerinin araştırılması, mevcut durumun tahmin edilebilmesi, gelecek dönemlerdeki öğrenci başarısını iyileştirmede çok önemlidir. Bu amaçla ortaokul öğrenci bilgileri güncel makine öğrenme yöntemleri kullanılarak analiz edilmiştir. Öğrencilerin sınav performansını etkileyen faktörler ön plana çıkarılmıştır. Aynı zamanda öğrencinin sınav performans tahmini yapılmıştır. Çalışmamızın sonuçları alanda daha önce yapılan araştırma sonuçlarını desteklemektedir. Çeşitli optimizasyon yöntemleri kullanarak sınav performansını etkileyen ortak faktörler tespit edilmiştir. Bunlar; ortaokul öğrencisinin yıllara göre okul puan ortalaması, aile gelir durumu, kardeş sayısı ve sıralaması ve özürsüz devamsızlık sayısıdır. Devamında birden fazla makine öğrenme yöntemi kullanılarak öğrenci sınav performans tahmini yapılmıştır. Yapılan deneylerde optimizasyon algoritması olan Guguk Kuşu Arama Algoritmaları (GKAA) ile seçilen etkin faktörler, Destek

Vektör Regresyonu analizi ile 0.866 (R2 doğruluk) sınav başarı tahminin skoru elde edilmiştir. Aynı zamanda sınav performansında kardeş sıralamasının etkisi gözlenmiş, ileri çalışmalar için hedefler belirlenmiştir.

Anahtar Kelimeler

LGS Puan Tahmini, Makine Öğrenmesi, Eğitimde Yapay Zekâ

Atıf Bilgisi

Er, M. B. & Balıkçı, H. C. & Alp, M. & Bozdağ Karakeçi, Z. & Yıldız, A. & Tezcan, A. & Tancı Yıldırım, N. (2023). Yapay Zekâ Uyumlu Algoritmalarla Öğrencilerin LGS Puanı Tahmini ve Modellenmesi. *Necmettin Erbakan Üniversitesi Ereğli Eğitim Fakültesi Dergisi*, 5(2). 377-402. <https://doi.org/10.51119/ereegf.2023.61>

Geliş Tarihi	24.07.2023
Kabul Tarihi	24.10.2023
Yayın Tarihi	31.12.2023
Etik Beyan	Bu çalışmanın hazırlanma sürecinde bilimsel ve etik ilkelere uyulduğu ve yararlanılan tüm çalışmaların kaynakçada belirtildiği beyan olunur.
Bilgilendirme	Yok.
Benzerlik Taraması	Yapıldı – Turnitin
Etik Bildirim	hcelal@harran.edu.tr
Çıkar Çatışması	Çıkar çatışması beyan edilmemiştir. Yazar Katkıları: Yazar 1: %20-Araştırma tasarımı, yöntem, analiz, bulgu ve sonuçlar, Yazar 2: %20-Araştırma tasarımı, yöntem, analiz, bulgu ve sonuçlar, Yazar 3: %20- Araştırma tasarımı, yöntem, analiz, bulgu ve sonuçlar, Yazar 4: %10-Araştırma tasarımı, literatür tarama, Yazar 5: %10-Araştırma tasarımı, literatür tarama, Yazar 6: %10-Araştırma tasarımı, literatür tarama, Yazar 7: %10-Araştırma tasarımı, literatür tarama.
Yazar Katkı Oranı	
Finansman	Bu araştırmayı desteklemek için dış fon kullanılmamıştır.
Telif Hakkı & Lisans	Yazarlar dergide yayınlanan çalışmalarının telif hakkına sahiptirler ve çalışmaları CC BY-NC 4.0 lisansı altında yayımlanmaktadır.

LGS Score Prediction and Modeling of Students with Artificial Intelligence Compatible Algorithms

Mehmet Bilal ER¹, Hasan Celal BALIKÇI², Mustafa ALPSÜLÜN³,
Zehra BOZDAĞ⁴, Ahmet YILDIZ⁵, Ahat TEZCAN⁶, Neslihan TANCI YILDIRIM⁷

¹ Harran University, Siverek VS, Şanlıurfa, Türkiye, bilal.er@harran.edu.tr, 0000-0002-2074-1776

² Harran University, Siverek VS, Şanlıurfa, Türkiye, hcelal@harran.edu.tr, 0000-0002-1539-1863

³ Harran University, Siverek VS, Şanlıurfa, Türkiye, musalp@harran.edu.tr, 0000-0003-2928-218X

⁴ Harran University, Siverek VS, Şanlıurfa, Türkiye, zbozdog@harran.edu.tr, 0000-0002-1119-5275

⁵ Harran University, Siverek VS, Şanlıurfa, Türkiye, ahmet.yildiz@harran.edu.tr, 0000-0003-3992-2240

⁶ Harran University, Siverek VS, Şanlıurfa, Türkiye, ahattezcan@harran.edu.tr, 0000-0001-8072-4495

⁷ Harran University, Siverek VS, Şanlıurfa, Türkiye, neslihintanci@harran.edu.tr, 0000-0002-3477-4384

Abstract

The high school entrance exam (LGS) determines the high schools that 8th grade students will attend based on their scores. With this exam, students' education and training skills are tested. The exam success of students is influenced by factors such as social-economic status, family environment, parental education status, gender and educational data from previous years. It is very important to investigate the effects of these factors on exam success, to predict the current situation and to improve student success in future periods. For this purpose, secondary school student information was analyzed using current machine learning methods. Factors affecting students' exam performance were highlighted. At the same time, the student's exam performance was predicted. The results of our study support the results of previous research in the field. Using various optimization methods, common factors affecting exam performance were identified. These are the average school score of the secondary school student by years, family income status, number and ranking of siblings, and the number of unexcused absences. Subsequently, multiple machine learning methods were used to predict student exam performance. In the experiments, the effective factors were selected with the optimization algorithm Cuckoo's Nest Search Algorithms (CGSA) and a score of 0.866

(R2 accuracy) was obtained with Support Vector Regression analysis. At the same time, the effect of sibling ranking on exam performance was observed and targets for further studies were determined.

Keywords

LGS Score Prediction, Machine Learning, Artificial Intelligence in Education

Citation

Er, M. B., Balıkcı, H. C., Alp, M., Bozdağ Karakeçi, Z., Yıldız, A., Tezcan, A., & Tancı Yıldırım, N. (2023). LGS Score Prediction and Modeling of Students with Artificial Intelligence Compatible Algorithms. *Journal of Necmettin Erbakan University Ereğli Faculty of Education*, 5(2), 377-402. <https://doi.org/10.51119/ereegf.2023.61>

Date of Submission	24.07.2023
Date of Acceptance	24.10.2023
Date of Publication	31.12.2023
Ethical Statement	It is declared that scientific and ethical principles have been followed while carrying out and writing this study and that all the sources used have been properly cited.
Acknowledgements	No.
Plagiarism Checks	Yes - Turnitin
Conflicts of Interest	The author(s) has no conflict of interest to declare.
Author Contributions	Author Contributions: Author 1: 20%-Research design, method, analysis, findings and conclusions, Author 2: 20%-Research design, method, analysis, findings and results, Author 3: 20%- Research design, method, analysis, findings and results, Author 4: 10%-Research design, literature review, Author 5: 10%-Research design, literature review, Author 6: 10%-Research design, literature review, Author 7: 10%-Research design, Literature review.
Complaints	hcelal@harran.edu.tr
Grant Support	The author(s) acknowledge that they received no external funding in support of this research.
Copyright & License	Authors publishing with the journal retain the copyright to their work licensed under the CC BY-NC 4.0.

Extended Abstract

Introduction: The High School Entrance Examination (LGS) is a system in Turkey that regulates 8th grade students' transition to secondary education. A central exam is held to rank students and place them in their desired high schools (Yüzüak & Arslan, 2021). The ranking of the success of LGS determines which high school students are placed in. High school placement is based on quotas and student preferences. Grades from secondary schools were also considered (MEB, 2018). Thus, students should prepare for the LGS and strive for good grades. The factors influencing student success in LGS include socioeconomic level, academic abilities, gender, technical skills, in-school/out-of-school characteristics, exam stress, sleep quality, rhythmic ability, and study attitudes (Yavuz et al., 2016; Adnan & Boz-Yaman, 2017; Aşkar, 2021; Polat & Bilen, 2022; Sarioğlan et al., 2021; Filiz & Kaya, 2021; Yıldız & Yoncalik, 2019).

Planning the exam preparation process is essential for students' success. Developing information technologies can help to develop solutions for predicting student success. Artificial Intelligence (AI) can predict student success using variables. When studies in this field are examined, it has been observed that course grades during the semester, parents' educational status, years of school enrollment, and demographic variables come to the fore (Kruzicevic et al., 2012; Christian et al., 2020) as predictors of students' academic success and performance (Dayıoğlu and Türüt-Aşık, 2007; Kruzicevic et al., 2012; Cascio and Schanzenbach, 2016; Pettersson et al., 2020; Christian et al., 2020; Bahar, 2013; Rohling et al., 2017; Whitney et al., 2023). By incorporating these variables into an AI model, a predictive model for LGS scores can be developed.

This study aimed to estimate the LGS scores of students and determine the variables that affect their scores, using data obtained from the E-School system and AI technologies.

Materials and Methods: A dataset of 8th grade students' LGS scores was created to train and test the machine learning methods. The data were obtained from the e-school system with the necessary permission. Particle Swarm Optimization (PSO), Firefly Algorithm (FA), and Cuckoo Search Algorithms (CSA) from meta-heuristic optimization algorithms were used to select the most efficient features from the dataset. Support Vector Regression (SVR), Gaussian Process Regression (GPR) and Decision Tree Regression (DTR) were used to estimate LGS scores.

Findings: The optimization algorithms identified the most important and effective features of the dataset. Each algorithm was applied to the dataset to determine the best performing algorithm. Random data from these datasets

were used for training and testing. Two experiments were conducted to assess the effect of data size on network performance. First, 70% of the data were used for training, and 30% for testing. Second, 80% of the data were allocated for training and 20% for testing.

Machine learning methods were applied to the initial two setups without the use of optimization algorithms. In the first experiment, DTR achieved the highest R2 score of 0.704, indicating superior performance, with an approaching R2 of 1 and MSE near 0. In the second experiment, SVR yielded the highest R2 value of 0.707. Optimal results emerged when full SVR was used, excluding feature selection.

First, the PSO algorithm was applied to the dataset and the number of features was reduced from 29 to 15. The model results applied after the number of features decreased by 15, and as a result of the first experiment, the highest result was obtained with GPR, with an R2 score of 0.854. Second test result: The SVR model had the highest result with an R2 score of 0.849.

After applying the FA, the number of features in the dataset was reduced from 29 to 12. The highest result was obtained with SVR, with an R2 score of 0.859, because of the first trial. The second test showed that GPR had the highest result, with an R2 score of 0.844.

The number of features in the dataset, which was 29, was reduced to 14 after applying the last CSA optimization. In the first experiment, the highest result was obtained with the DTR with an R2 score of 0.819. The second test showed that SVR had the highest result, with an R2 score of 0.866.

In conclusion, a common feature set was obtained from the PSO, FA, and CSA optimization algorithms.

- 6th, 7th and 8th grade average
- Family income status
- Siblings Number
- Sibling Ranking
- Number of days without excused absences.

Discussion: This study examined factors such as GPA, family income, siblings, sibling rank, and unexcused absences affecting high school entrance exam results. The GPA, which indicates academic performance, is a crucial variable. Our study used 6th to 8th grade averages from the three optimization algorithms. The prediction model performed better with grade-point average feature sets. The GKAA and SVR models achieved R2 scores of 0.866 using these feature sets. Family income affects students' educational abilities and test

scores. We used three algorithms to include the family income status in our feature set, thus enhancing the performance of our prediction models. With family income as a feature, the PSO and SVR models produced MSEs of 0.680. Steelman et al. (2002) debated the impact of sibling count on exam results reported that students with many siblings had lower exam scores. Gibbs et al. (2016) suggested resource sharing and distractions in large families could hinder exam preparation.

Some research suggests that sibling count does not impact exam performance (Pontes et al., 2016); however, more investigation is required. Sibling ranking was also observed in the optimization algorithms. Our prediction models were improved for feature clusters with sibling counts and rankings, with an average R2 score of 0.827. Unexcused absences significantly affected high school entrance exam results, improving our prediction models' performance, with an R2 score of 0.859 for the ABA and SVR models.

Conclusion and Suggestions: Drawing from the existing literature, this study examined factors affecting high school entrance exam scores, including grade point average, family income, number of siblings, sibling rank, and unexcused absences. Our study suggests that education policymakers and school administrators should consider the following:

Schools should provide programs and resources to help students succeed academically. Guidelines on study habits, learning strategies, and time management should be provided. Low-income students should have access to educational materials and tutoring. Administrators and their families should encourage regular attendance. Policies and awareness campaigns should aim to reduce absenteeism. Further research is needed to understand the effect of sibling number and rank on exam performance.

Giriş

Liselere Geçiş Sınavı (LGS), Türkiye'deki 8. Sınıf öğrencilerinin ortaöğretime geçiş sürecini düzenleyen sisteminin bir parçasıdır. Bu sistem bağlamında öğrencilerin nitelikli liselere yerleşebilmeleri için merkezi bir sınav yapılmaktadır (Yüzüak & Arslan, 2021). Bu sınav, Türkçe, matematik, fen bilimleri, sosyal bilgiler, yabancı dil ile din kültürü ve ahlak bilgisi derslerinin sorularından oluşmaktadır (Dilekçi, 2023). LGS sonucunda, öğrencilerin başarı sıralaması belirlenir ve bu sıralamaya göre öğrencilerin tercih ettikleri liselere yerleştirme yapılır. Liselere yerleştirme, öğrencilerin tercih ettikleri okul kontenjanları ve başarı sıralamalarına göre gerçekleştirilir. LGS'nin yanı sıra, öğrencilerin ortaokul dönemi boyunca aldıkları başarı notları da yerleştirme sürecinde dikkate alınır (MEB, 2018). Bu nedenle, öğrencilerin hem LGS'ye hazırlık yapmaları hem de derslerinde başarılı olmaları önemlidir. LGS, öğrencilere farklı türdeki liseleri tercih etme imkânı sunar. Örneğin, fen liseleri, sosyal bilimler liseleri, Anadolu liseleri, meslek liseleri gibi çeşitli liseler arasından tercih yapabilirler (Çakmak, 2023; Yüzüak & Arslan, 2021).

LGS'nin amacı, öğrencilerin nitelikli liselere yerleşmelerini sağlamak ve eğitimde nitelik farklılıklarını azaltmaktır (Yüzüak & Arslan, 2021). Bu nedenle ilköğretimin ikinci kademesi olan ortaokullarda öğrenim gören öğrenciler nitelikli ortaöğretim kurumlarına dahil olabilmek için sınava girmek zorundadırlar. Araştırmalar, LGS'nin öğretmenlerin ders müfredatını etkilediğini ve öğrencilerin dil becerilerine odaklanmalarına neden olduğunu göstermektedir (Dilekçi, 2023). Bu sınavlar, öğrencilerin genel başarılarını ve belirli derslerdeki başarılarını öngören değişkenleri araştıran çalışmalara konu olmuştur (Gökcan & Aktan, 2018). Söz konusu çalışmalar öğrencilerin başarılarına etki eden çeşitli faktörleri tespit etmiştir.

LGS'ye giren öğrencilerin başarısını etkileyen faktörler temel olarak sosyoekonomik düzey, akademik yetenekler, cinsiyet, teknik beceriler, okul içi ve okul dışı özellikler, sınav stresi, uyku kalitesi, ritmik yetenek ve çalışma tutumları şeklinde sıralanabilir (Yavuz vd., 2016; Koğar, 2015; Adnan & Boz-Yaman, 2017; Aşkar, 2021; Polat & Bilen, 2022; Yüzüak & Arslan, 2021; Sarioğlan vd., 2021; Filiz & Kaya, 2021; Yıldız & Yoncalık, 2019). Bu faktörler arasından bazı faktörler ön plana çıkmaktadır. Öğrencilerin sosyoekonomik düzeyi, akademik başarılarını önemli düzeyde etkilemektedir (Yavuz vd., 2016). Aynı şekilde cinsiyet, öğrencilerin teknik beceriler ve motivasyonları açısından farklılık oluşturabilecek bir faktördür (Adnan & Boz-Yaman, 2017). Bunun yanında öğrencilerin uyku kalitesi, ritmik yetenekleri ve çalışma tutumları da akademik başarılarını etkileyebileceği (Filiz & Kaya, 2021; Yıldız & Yoncalık, 2019) gibi okul içi ve okul dışı durumların da öğrencilerin başarıları üzerinde etkisi olduğu bilinmektedir (Aşkar, 2021).

Öğrencilerin akademik yaşamlarını bu derecede etkileyen bir sınava hazırlık sürecinin doğru planlaması da önem taşımaktadır. Bu nedenle gelişen bilişim teknolojilerinin bu alanda kullanılması öğrenci başarılarının tahmin edilerek çözümler geliştirebilme kapasitesi görülmektedir. Bilişim teknolojileri alanı içerisinde yer alan yapay zekâ teknolojileri ile belli değişkenler kullanarak öğrencilerin başarılarını tahmin etmek mümkün olmaktadır. Öğrencilerin merkezi sınavlardaki başarılarına etki eden faktörleri inceleyen çalışmaların sonuçlarına bakıldığında; dönem içerisindeki ders notları, ebeveynlerin eğitim durumları, okula kayıt yılları ve demogarik değişkenlerin öğrencilerin akademik başarı ve performanslarının yordayıcıları (Kruzicevic vd., 2012; Christian vd., 2020) olarak ön plana çıktıkları görülmüştür (Dayıoğlu ve Türüt-Aşık, 2007; Kruzicevic vd., 2012; Cascio ve Schanzenbach, 2016; Pettersson vd., 2020; Christian vd., 2020; Bahar, 2013; Rohling vd., 2017; Whitney vd., 2023). Yukarıda sözü edilen değişkenleri bir yapay zekâ modeline dahil ederek, LGS puanları için öngörücü bir model geliştirme imkânı görülmektedir. Bu bağlamda bu araştırmada E-Okul sistemi üzerinden alınan veriler ile Yapay Zekâ teknolojileri kullanılarak öğrencilerin LGS puanlarının tahmin edilmesi ve öğrencilerin puanlarını etkileyen değişkenlerin belirlenmesi amaçlanmaktadır.

Yöntem

Bu araştırma, optimizasyon ve makine öğrenme yöntemlerinin kullanılarak ortaokul öğrencilerinin LGS puanlarını etkileyen faktörlerin belirlenmesi ve ortaokul öğrencilerinin başarı düzeylerinin tahmin edilmesi amacıyla gerçekleştirilmiştir.

Veri Seti

Bu araştırmada, bir ortaokulun e-okul siteminden okul müdürü aracılığı ile alınan veriler kullanılarak 8. Sınıf öğrencilerin LGS puanlarını tahmin eden modeller oluşturulmuştur. Veri setinde toplam 29 özellik ve 445 satırlık örnek bulunmaktadır. Veri kümesi niteliklerinin detayları ve aralıkları Tablo 1'de verilmiştir.

Tablo 1.*Veri Setindeki Özellikler*

No.	Özellik Adı	Aralık
1	Doğum tarihi	(13-17)
2	Cinsiyet	(Erkek=1, Kadın=0)
3	Kiminle Oturuyor	(Aile=0, Anne=1, Baba=2)
4	Oturduğu ev kiramı	(Hayır=0, Evet=1)
5	Ev ne ile ısıtılıyor	(Soba=0, Isıtıcı=1, Kalorifer=2)
6	Okula nasıl geliyor	(Yürüyerek=0, Servis=1, Aile=2,
7	Geçirdiği Kaza	(Yok=0, Evet=1)
8	Geçirdiği Ameliyat	(Yok=0, Evet=1)
9	Sürekli Hastalığı	(Yok=0, Evet=1)
10	Aile Gelir Durumu	(Çok düşük=0, Düşük=1, iyi=2,
11	Anne/baba birlikte mi ayrımı	(Ayrı=0, Birlikte=1)
12	Anne sağ mı	(Hayır=0, Evet=1)
13	Anne doğum tarihi	-
14	Anne eğitim durumu	(Okuma yazma bilmiyor=0, ilkokul=1, ortaokul=2, lise =3, Üniversite=4)
15	Anne mesleği	(Ev Hanımı=0, Çalışıyor=1)
16	Baba Sağ mı	(Hayır=0, Evet=1)
17	Baba doğum tarihi	-
18	Baba Çalışıyor mu?	(Hayır=0, Evet=1)
19	Baba eğitim durumu	(Okuma yazma bilmiyor=0, ilkokul=1, ortaokul=2, lise =3, Üniversite=4)
20	Kardeş Sayısı	(0-10)
21	Kardeş Sıralaması	(1-10)
22	Mevsimlik işçi mi	(Hayır=0, Evet=1)
23	Burs durumu	(Yok=0, Var=1)
24	Özürü devamsızlık sayısı	(0-30)
25	Özürsüz devamsızlık sayısı	(0-30)
26	5. sınıf ortalaması	(0-100)
27	6. ortalaması	(0-100)
28	7 sınıf ortalaması	(0-100)
29	8. Sınıf ortalaması	(0-100)

Verilerin Analizinde Kullanılan Yöntemler

Veri setinden en etkin özellikleri seçmek için Meta-sezgisel optimizasyon algoritmalarından Parçacık Sürü Optimizasyonu, Ateşböceği Algoritması ve Guguk Kuşu Arama algoritmaları kullanılmıştır. Seçilen en etkin özellikler ile LGS puanlarını tahmin etmek için ise Destek Vektör Regresyonu, Gauss Süreç Regresyonu ve Karar Ağacı ile Regresyonu kullanılmıştır.

Özellik Seçimi Algoritmaları

Özellik seçimi, regresyon problemlerinde başarıyı arttıran önemli adımlardan biridir. Özellik sayısının fazla olması regresyon problemleri için model oluşturmayı zorlaştırmaktadır ve performansını önemli ölçüde düşmesine neden olmaktadır (Özsağlam ve Çunkaş, 2008; Çavuşlu, vd.,2010). Ayrıca bazı özellikler gereksiz ve hatta yanıltıcı olduğu için sınıflandırmadaki doğruluk oranı azalmaktadır. Bu dezavantajlardan dolayı veri setlerinden çıkarılan özellik sayısını azaltmak için özellik seçimi algoritmalarına ihtiyaç vardır. Bu çalışmada meta-sezgisel optimizasyon algoritmaları ile özellik seçim işlemi gerçekleştirilmiştir. Meta-sezgisel optimizasyon algoritmalarının en önemli avantajlarından biri de yerel optimum noktalara takılmadan global sonuca ulaşabilme yeteneğidir. Özellik seçimi yöntemi olarak, Parçacık Sürü Optimizasyonu, Ateşböceği Algoritması ve Guguk Kuşu Arama Algoritması olmak üzere üç farklı optimizasyon algoritması kullanılmaktadır. Bu optimizasyon yöntemleri sayesinde regresyon tahmin modellerine en iyi sonucu veren özellik kümelerinin verilmesi hedeflenmiştir. Kullanılan üç farklı meta-sezgisel yöntemler ile hem az sayıda özellik hem de en iyi tahmin sonucunu veren özellikler aranmıştır.

Çalışmada kullanılan optimizasyon yöntemleri;

- Parçacık Sürü Optimizasyonu
- Ateş Böceği Algoritması (ABA)
- Guguk Kuşu Arama Algoritması (GKAA) dır.

Regresyon Yöntemleri

Regresyon yöntemleri mühendislik, fizik ve eğitim alanlarında oldukça yaygın kullanılıp etkin sonuçlar vermektedir (Isik, 2022; Işık, Işık ve Toktamış, 2021). Bu çalışmada seçilen en etkin özellikler ile LGS puanlarını tahmin etmek için kullanılan regresyon yöntemleri;

- Destek Vektör Regresyonu
- Gauss Süreç Regresyonu
- Karar Ağacı ile Regresyon

Verilerin Analizi

Modelin performansı Ortalama kare hata (MSE), Kök ortalama kare hata (RMSE), Ortalama mutlak hata (MAE) ve R2 Skoru kullanılarak test edilmiştir. Bu performans ölçütlerinin denklemleri, sırasıyla 1-4 verilmiştir.

$$MSE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} (y_i - \hat{y}_i)^2 \quad (1)$$

$$RMSE(y, \hat{y}) = \sqrt{MSE(y, \hat{y})} \quad (2)$$

$$MAE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} |y_i - \hat{y}_i| \quad (3)$$

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^{n-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{n-1} (y_i - \bar{y})^2} \quad (4)$$

Bulgular

Çalışmadaki tahmin modelleri MATLAB yazılımının ilgili araç ve kütüphaneleri kullanılarak geliştirilmiştir. 445 örnek içeren veri seti, test ve eğitim için ayrılmıştır. Veri setinden en etkin özellikleri seçmek için Meta-sezgisel optimizasyon algoritmalarından Parçacık Sürü Optimizasyonu, Ateşböceği Algoritması ve Guguk Kuşu Arama algoritmaları kullanılmıştır. Tahmin modelleri olarak ise Destek Vektör Regresyonu, Gauss Süreç Regresyonu ve Karar Ağacı ile Regresyonu kullanılmıştır. Geliştirilen tüm modellerin tahmin performansları MSE, RMSE, MAE ve R2 score kullanılarak hesaplanmıştır. Tahmin modellerinin doğruluğu, parametrelerin seçimine karşı çok hassastır ve literatürde hiper parametre optimizasyonu ile ilgili çalışmalar mevcuttur fakat bu parametrelerin istenen değerlerini elde etmek için matematiksel bir model yoktur. Bu çalışmada Destek Vektör Regresyonu, Gauss Süreç Regresyonu ve Karar Ağacı ile Regresyonu tahmin modelleri için farklı hiper parametreler denenmiş ve en iyi sonuçları veren parametreler seçilmiştir. Her bir modele ait en iyi sonucu veren parametreler Tablo 2-4'te verilmiştir.

Tablo 2.

Destek Vektör Regresyonu için Parametreler

Model	Parametre	Değer Aralığı	Çekirdek Fonksiyonu	Kernel Ölçeği
Destek Vektör Regresyonu	C	[0.1, 5000]	Gaussian	0.27
	ϵ	[0.0001, 100]		
	γ	[0.001, 50]		

Tablo 3.*Gauss Süreç Regresyonu için Parametreler*

Model	Standart Sapma	Çekirdek Fonksiyonu	Kernel Ölçeği
Gauss Süreç Regresyonu	0.16	Rational Quadratic	0.27

Tablo 4.*Karar Ağacı için Parametreler*

Model	Parametre	Değer Aralığı	Çekirdek Fonksiyonu	Kernel Ölçeği
Karar Ağacı	ϵ Min.Yaprak Boyutu:	0.021 12	Quadratic	0.27

Önerilen modelin uygulaması Intel Boxed Core i7-12900KS işlemci ve GeForce GTX3090 8GB ekran kartı özelliklerine sahip bir donanım kullanılarak yapılmıştır. Deney sonuçları hem özellik seçimi ile hem de özellik seçimi olmadan ayrı ayrı detaylı olarak verilmiştir. Özellik seçimi için kullanılan optimizasyon algoritmalarının performansını ölçmek için her optimizasyon algoritması veri seti üzerinde 10 kez denenmiştir. Veri setlerinden rastgele seçilen verilerin bir kısmı eğitim için bir kısmı da test için kullanılmıştır. Eğitim ve test için ayrılan verilerin boyutunun ağın performansı üzerindeki etkisini belirlemek amacıyla, bu veriler 2 farklı şekilde bölünmüştür. İlk deneyde, verilerin %70'i eğitim için ve %30'ı test için kullanılmış; ikinci deneyde, verilerin %80'i eğitim için ve %20'si test için kullanılmıştır.


LGS puanlarının tahmini için özellik seçimi uygulamadan elde edilen deney sonuçları Tablo 5'te verilmiştir. Tablo 5'teki sonuçlara göre veri setinin test ve eğitim için sırası ile %70- %30 oranında bölünmesi sonucu Destek Vektör Regresyonu modeli ile 0.691, Gauss Süreç Regresyonu ile 0.683 ve Karar Ağacı ile 0.704'lük R2 skoru elde edilmiştir. R2 değerinin 1'e yaklaşırken MSE değerinin 0'a yaklaştığı göz önüne alındığında modeller arasında en başarılı sonuç karar ağacından elde edilmiştir. Veri setinin test ve eğitim için sırası ile %80- %20 oranında bölünmesi sonucu Destek Vektör Regresyonu modeli ile 0.707, Gauss Süreç Regresyonu ile 0.701 ve Karar Ağacı ile 0.703'lük R2 skoru elde edilmiştir. R2 skoru 1'e yaklaşırken MSE değerinin 0'a yaklaştığı göz önüne alındığında modeller arasında en başarılı sonuç Destek Vektör Regresyonundan

elde edilmiştir. Özellik seçimi olmadan en iyi performans gösteren Destek Vektör Regresyonu ile elde edilen tahmin modeli Şekil 1’de verilmiştir.

Tablo 5.

Özellik Seçimi Olmadan Elde Edilen Sonuçlar

Model		Verinin Bölünme Oranı (Test- Eğitim)	MSE	RMSE	MAE	R ²
Destek Regresyonu	Vektör	%70- %30	0.941	0.304	0.232	0.691
Gauss Regresyonu	Süreç	%70- %30	0.947	0.307	0.226	0.683
Karar Ağacı		%70- %30	0.924	0.293	0.211	0.704
Destek Regresyonu	Vektör	%80- %20	0.805	0.272	0.206	0.707
Gauss Regresyonu	Süreç	%80- %20	0.891	0.246	0.200	0.701
Karar Ağacı		%80- %20	0.889	0.257	0.202	0.703



Şekil 1.

Özellik Seçimi Olmadan Destek Vektör Regresyonu ile Elde Tahmin Modeli


PSO uygulandıktan sonra veri setindeki 29 olan özellik sayısı 15’e düşürülmüştür. PSO ile seçilen özellikler;

- Doğum tarihi
- Oturduğu ev kiramı
- Aile Gelir Durumu
- Anne sağ mı
- Anne eğitim durumu
- Anne mesleği
- Baba doğum tarihi
- Baba çalışıyor mu
- Kardeş Sayısı
- Kardeş Sıralaması
- Özürsüz devamsızlık sayısı
- 5. sınıf ortalaması
- 6. Sınıf ortalaması
- 7 sınıf ortalaması
- 8. Sınıf ortalaması

PSO ile özellik seçimi uygulandıktan sonra elde edilen sonuçlar Tablo 6'da verilmiştir. Tablo 6'daki sonuçlara göre veri setinin test ve eğitim için sırası ile %70- %30 oranında bölünmesi sonucu Destek Vektör Regresyonu modeli ile 0.828, Gauss Süreç Regresyonu ile 0.854 ve Karar Ağacı ile 0.831'lik R2 skoru elde edilmiştir. R2 değerinin 1'e yaklaşıırken MSE değerinin 0'a yaklaştığı göz önüne alındığında modeller arasında en başarılı Gauss Süreç Regresyonu ile elde edilmiştir. Veri setinin test ve eğitim için sırası ile %80- %20 oranında bölünmesi sonucu Destek Vektör Regresyonu modeli ile 0.849, Gauss Süreç Regresyonu ile 0.803 ve Karar Ağacı ile 0.846'lık R2 skoru elde edilmiştir. R2 skoru 1'e yaklaşıırken MSE değerinin 0'a yaklaştığı göz önüne alındığında modeller arasında en başarılı sonuç Destek Vektör Regresyonundan elde edilmiştir. PSO özellik seçimi ile en iyi performans gösteren Destek Vektör Regresyonu ile elde edilen tahmin modeli Şekil 2'de verilmiştir.

Tablo 6.*PSO Özellik Seçimi Uygulandıktan Sonra Elde Edilen Sonuçlar*

Özellik Seçimi	Model	Verinin Bölünme Oranı (Test-Eğitim)	MSE	RMSE	MAE	R ²
PSO	Destek Vektör	%70- %30	0.703	0.207	0.181	0.828
	Gauss Süreç	%70- %30	0.701	0.200	0.190	0.854
	Karar Ağacı	%70- %30	0.709	0.202	0.188	0.831
	Destek Vektör	%80- %20	0.680	0.209	0.186	0.849
	Gauss Süreç	%80- %20	0.699	0.200	0.191	0.803
	Karar Ağacı	%80- %20	0.696	0.204	0.188	0.846

**Şekil 2.***Destek Vektör Regresyonu ve PSO Özellik seçimi ile Elde Tahmin Modeli*

ABA uygulandıktan sonra veri setindeki 29 olan özellik sayısı 12'ye düşürülmüştür. ABA ile seçilen özellikler;

- Kiminle Oturuyor
- Oturduğu ev kiramı
- Ev ne ile ısınyor
- Aile Gelir Durumu


- Kardeş Sayısı
- Kardeş Sıralaması
- Özürlü devamsızlık sayısı
- Özürsüz devamsızlık sayısı
- 5. sınıf ortalaması
- 6. sınıf ortalaması
- 7. sınıf ortalaması
- 8. Sınıf ortalaması

ABA ile özellik seçimi uygulandıktan sonra elde edilen sonuçlar Tablo 7’de verilmiştir. Tablo 7’deki sonuçlara göre veri setinin test ve eğitim için sırası ile %70- %30 oranında bölünmesi sonucu Destek Vektör Regresyonu modeli ile 0.859, Gauss Süreç Regresyonu ile 0.810 ve Karar Ağacı ile 0.824’lük R2 skoru elde edilmiştir. R2 değerinin 1’e yaklaşırken MSE değerinin 0’a yaklaştığı göz önüne alındığında modeller arasında en başarılı sonuç Destek Vektör Regresyonu ile elde edilmiştir. Veri setinin test ve eğitim için sırası ile %80- %20 oranında bölünmesi sonucu Destek Vektör Regresyonu modeli ile 0.843, Gauss Süreç Regresyonu ile 0.844 ve Karar Ağacı ile 0.826’lık R2 skoru elde edilmiştir. R2 skoru 1’e yaklaşırken MSE değerinin 0’a yaklaştığı göz önüne alındığında modeller arasında en başarılı sonuç Gauss Süreç Regresyonu Regresyonundan elde edilmiştir. ABA özellik seçimi ile en iyi performans gösteren Destek Vektör Regresyonu ile elde edilen tahmin modeli Şekil 3’te verilmiştir.

Tablo 7.

ABA Özellik Seçimi Yapıldıktan Sonra Elde Edilen Sonuçlar

Özellik Seçimi	Model	Verinin Bölünme Oranı (Test-Eğitim)	MSE	RMSE	MAE	R ²
ABA	Destek Vektör	%70- %30	0.706	0.209	0.194	0.859
	Gauss Süreç	%70- %30	0.709	0.202	0.180	0.810
	Karar Ağacı	%70- %30	0.710	0.206	0.187	0.824
	Destek Vektör	%80- %20	0.690	0.203	0.190	0.843
	Gauss Süreç	%80- %20	0.680	0.202	0.189	0.844
	Karar Ağacı	%80- %20	0.696	0.204	0.193	0.826



Şekil 3.

Destek Vektör Regresyonu ve ABA Özellik seçimi ile Elde Tahmin Modeli

GKAA uygulandıktan sonra veri setindeki 29 olan özellik sayısı 14'e düşürülmüştür. GKAA ile seçilen özellikler;

- Cinsiyet
- Oturduğu ev kiramı
- Ev ne ile ısınyor
- Okula nasıl geliyor
- Aile gelir durumu
- Baba doğum tarihi
- Baba Çalışıyor mu
- Baba eğitim durumu
- Kardeş Sayısı
- Kardeş Sıralaması
- Özürsüz devamsızlık sayısı
- 6. sınıf ortalaması
- 7 sınıf ortalaması

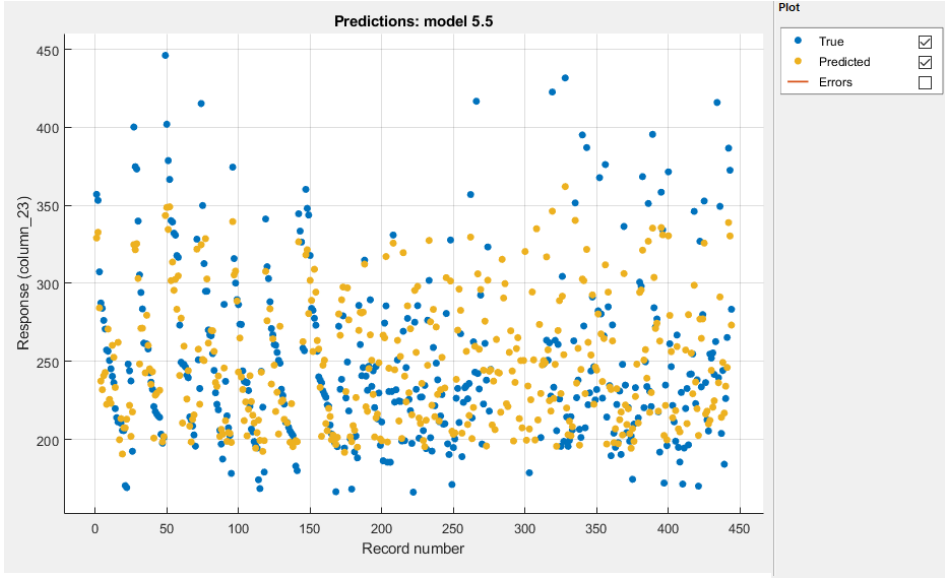
- 8. Sınıf ortalaması

GKAA ile özellik seçimi uygulandıktan sonra elde edilen sonuçlar Tablo 8'de verilmiştir. Tablo 8'deki sonuçlara göre veri setinin test ve eğitim için sırası ile %70- %30 oranında bölünmesi sonucu Destek Vektör Regresyonu modeli ile 0.813, Gauss Süreç Regresyonu ile 0.815 ve Karar Ağacı ile 0.819'lık R2 skoru elde edilmiştir. R2 değerinin 1'e yaklaşırken MSE değerinin 0'a yaklaştığı göz önüne alındığında modeller arasında en başarılı sonuç Karar Ağacı ile elde edilmiştir. Veri setinin test ve eğitim için sırası ile %80- %20 oranında bölünmesi sonucu Destek Vektör Regresyonu modeli ile 0.866, Gauss Süreç Regresyonu ile 0.860 ve Karar Ağacı ile 0.831'lik R2 skoru elde edilmiştir. R2 skoru 1'e yaklaşırken MSE değerinin 0'a yaklaştığı göz önüne alındığında modeller arasında en başarılı sonuç Destek Vektör Regresyonundan elde edilmiştir. GKAA özellik seçimi ile en iyi performans gösteren Destek Vektör Regresyonu ile elde edilen tahmin modeli Şekil 4'te verilmiştir.

Tablo 8.

GKAA Özellik Seçimi Yapıldıktan Sonra Elde Edilen Sonuçlar

Özellik Seçimi	Model	Verinin Bölünme Oranı (Test-Eğitim)	MSE	RMSE	MAE	R2
GKAA	Destek Vektör Regresyonu	%70- %30	0.701	0.201	0.186	0.813
	Gauss Süreç Regresyonu	%70- %30	0.703	0.208	0.183	0.815
	Karar Ağacı	%70- %30	0.700	0.211	0.192	0.819
	Destek Vektör Regresyonu	%80- %20	0.698	0.202	0.188	0.866
	Gauss Süreç Regresyonu	%80- %20	0.688	0.201	0.182	0.860
	Karar Ağacı	%80- %20	0.693	0.204	0.185	0.831



Şekil 4.

Destek Vektör Regresyonu ve GKAA Özellik seçimi ile Elde Tahmin Modeli

PSO, ABA ve GKAA her 3 optimizasyon algoritmalarından elde edilen ortak özellik kümesi;

- 6. sınıf ortalaması
- 7. sınıf ortalaması
- 8. Sınıf ortalaması
- Aile gelir durumu
- Kardeş Sayısı
- Kardeş Sıralaması
- Özürsüz devamsızlık sayısı şeklindedir.

Tartışma ve Öneriler

Bu araştırma, liselere giriş sınavı sonuçları üzerinde etkili olan değişkenleri ayrıntılı bir şekilde incelemeyi amaçlamıştır. Okul ortalaması, aile gelir durumu, kardeş sayısı, kardeş sıralaması ve özürsüz devamsızlık sayısı gibi değişkenlerin (faktörler) sınav sonuçları üzerindeki etkileri, literatürde yer alan araştırmalar ışığında tartışılmıştır.

Okul ortalaması, bir öğrencinin akademik performansını yansıtan önemli

bir deęiřkendir. Yüksek bir okul ortalaması, öğrencinin derslerdeki başarısını ve sınavlardaki performansını olumlu yönde etkiler. Literatürde yapılan çalışmalar, okul ortalamasının öğrencilerin sınavlarda başarı gösterme olasılığını artırdığını göstermektedir (Kruzicevic vd., 2012; Christian vd., 2020). Çalışmamızda PSO, ABA ve GKAA her 3 optimizasyon algoritmalarından elde edilen ortak özellik kümesi içerisinde 6. Sınıf, 7. Sınıf ve 8. Sınıf ortalamaları vardır. Okul ortalamalarının olduğu özellik kümeleri ile tahmin modellerimizin başarımı genellikle artmıştır. Okul ortalamalarının da olduğu özellik kümeleri kullanılarak GKAA ve Destek Vektör Regresyonu modeli ile 0.866 R2 skoru elde edilmiştir.

Aile gelir durumu, öğrencilerin eğitimine ve sınav performansına doğrudan bir etkiye sahiptir. Yüksek bir aile gelir düzeyi, öğrencilere daha iyi eğitim kaynaklarına ve destek hizmetlerine erişme imkânı sunar. Literatürde yapılan çalışmalar, yüksek gelir düzeyine sahip öğrencilerin genellikle daha yüksek sınav puanları elde ettiklerini göstermektedir (Yavuz vd., 2016; Dilekçi, 2023). Aile gelir düzeyinin sınav sonuçları üzerinde belirleyici bir faktör olduğunu göstermektedir. Eşitsizliklerin azaltılması ve düşük gelirli öğrencilerin desteklenmesi, eğitim politikalarının önemli bir hedefi olmalıdır (Rothstein, 2004). Çalışmamızda PSO, ABA ve GKAA her 3 optimizasyon algoritmalarından elde edilen ortak özellik kümesi içerisinde aile gelir durumu vardır. İçerisinde aile gelir durumu olduğu özellik kümeleri ile tahmin modellerimizin başarımı genellikle artmıştır. Aile gelir durumunun da olduğu özellik kümeleri kullanılarak PSO ve Destek Vektör Regresyonu modeli ile 0.680 MSE elde edilmiştir.

Kardeş sayısı, sınav performansı üzerindeki etkisi tartışmalı bir konudur. Bazı arařtırmalar, birden fazla kardeři olan öğrencilerin sınavlarda daha düşük başarı gösterme eğiliminde olduğunu ortaya koymuştur (Steelman vd., 2002). Birden fazla kardeşin olduğu bir ailede, kaynakların paylaşılması ve aile içi dikkatin dağılması öğrencilerin sınavlara hazırlanmasını zorlaştırabilir (Gibbs vd., 2016). Öte yandan, bazı çalışmalar kardeş sayısının sınav sonuçları üzerinde önemsiz bir etkiye sahip olduğunu bulmuştur (Pontes vd., 2016). Bu konudaki tartışmalar devam etmekte ve daha fazla arařtırma yapılması gerekmektedir.

PSO, ABA ve GKAA her 3 optimizasyon algoritmalarından elde edilen ortak özellik kümesi içerisinde kardeş sayısının yanı sıra kardeş sıralaması özellięi bulunmaktadır. Kardeş sayısının öğrenci performansına etkisi hakkında çalışmalar bulunmasına rağmen kardeş sıralamasının sınav performansına etkisi yeni bir çalışma alanı doğurmaktadır. Yapılan arařtırmalarda bu konu hakkında sınırlı çalışmalar mevcuttur (Steelman vd., 2002). Gelecekteki çalışmalarımızda bu konu hakkında detaylı bir çalışma yapılması hedeflenmektedir. Deney sonuçlarını incelediğimizde kardeş sayısı ve kardeş sıralamasının olduğu özellik kümeleri tahmin modellerimizin başarımı artmıştır, ortalama R2 skoru 0.827'dir.

Son olarak özürsüz devamsızlık sayısı, liselere giriş sınavı sonuçları üzerinde önemli bir etkiye sahip olduğu gözlenmiştir. Eğitime düzenli devam etmek, derslere katılmak ve derste aktif olmak, öğrencilerin sınav başarı potansiyellerini artırmaktadır. Literatürdeki çalışmalar, düşük özürsüz devamsızlık sayısına sahip öğrencilerin daha yüksek sınav puanları elde ettiklerini göstermektedir (Gottfried, 2010). Çalışmamızda PSO, ABA ve GKAA her 3 optimizasyon algoritmalarından elde edilen ortak özellik kümesi içerisinde özürsüz devamsızlık sayısı vardır. Bu özellikler tahmin modellerimizin başarımı artmıştır, ABA ve Destek Vektör Regresyonu modeli ile 0.859 R2 skoru elde edilmiştir.

Sonuç olarak, bu araştırma, liselere giriş sınavı sonuçlarını etkileyen değişkenleri literatürün ışığında ayrıntılı bir şekilde incelemiştir. Okul ortalaması, aile gelir durumu, kardeş sayısı, kardeş sıralaması ve özürsüz devamsızlık sayısı gibi faktörlerin sınav performansı üzerindeki etkileri gözlemlenmiş ve tartışılmıştır. Bu bulgular, eğitim politikalarının ve destek programlarının, bu değişkenlere odaklanarak öğrencilerin başarı potansiyellerini artırma amacını taşıması gerektiğini vurgulamaktadır. Ayrıca, kardeş sayısı ve kardeş sıralaması gibi faktörlerin etkisi üzerine daha fazla araştırma yapılması gerekmektedir. Gelecekteki çalışmalarımızı kardeş sayısı ve sıralamasının üzerine yoğunlaştırarak sınav performansı etkisi araştırılacaktır.

Çalışmamızın sonunda elde edilen bulgular ışığında, eğitim politika yapıcılarının ve okul yönetimlerinin aşağıdaki maddeleri dikkate almaları önerilir:

- Öğrenci başarısını artırmak için okullar, öğrencilerin akademik gelişimini destekleyen programlar ve kaynakları sunmalıdır. Öğrencilere, ders çalışma alışkanlıkları, öğrenme stratejileri ve zaman yönetimi gibi konularda rehberlik sağlamak önemlidir.
- Düşük gelirli ailelere sahip öğrencilere destek programları sunulmalıdır. Bu programlar, maddi kaynakların sınırlı olduğu durumlarda bile öğrencilere eğitim materyalleri, derslerde destek ve özel ders imkânı sağlayabilir. Bu şekilde, eşitsizliklerin azaltılması ve fırsat eşitliğinin sağlanması hedeflenmelidir.
- Okullar ve aileler, öğrencilerin düzenli devamını teşvik etmelidir. Devamsızlığın azaltılması için etkin politikalar ve bilinçlendirme çalışmaları yapılmalıdır. Ayrıca, öğrencilerin devam etme sorunlarına yönelik destek hizmetleri sunulmalı ve bu konuda iş birliği yapılmalıdır.
- Kardeş sayısı ve kardeş sıralamasının sınav performansı üzerindeki etkisini daha iyi anlamak için daha fazla araştırma yapılmalıdır. Bu konuda yapılan çalışmaların sayısı artırılmalı ve farklı sosyoekonomik gruplardan örneklem alınmalıdır.

Kaynakça | References

- Adnan, M., & Boz-Yaman, B. (2017). Mühendislik öğrencilerinin e-öğrenmeye dair hazır bulunuşluk ve memnuniyet düzeyleri. *Turkish Journal of Computer and Mathematics Education (Turcomat)*, 2(8), 218-218. <https://doi.org/10.16949/turkbilmat.280165>
- Aşkar, P. (2021). Determinants of academic achievement in Turkey. *J ECS*. <https://doi.org/10.26650/jecs2021-934211>
- Bahar, M. (2013). Impact of studying foreign language preparation class on academic achievement in Turkish Public and Private Selective Schools. *Journal of Language Teaching and Research*, 6(4). <https://doi.org/10.4304/jltr.4.6.1200-1207>
- Cascio, E., & Schanzenbach, D. (2016). First in the class? Age and the education production function. *Education Finance and Policy*, 3(11), 225-250. https://doi.org/10.1162/edfp_a_00191
- Christian, D., Stuckey, A., Boykin, A., & Adams, J. (2020). Predicting college enrollment of graduating high school seniors: How accurate is self-report?. *Professional School Counseling*, 1_part_3(23), 2156759X2090351. <https://doi.org/10.1177/2156759x20903512>
- Çakmak, Z., & Yiğen, V. (2023). Liselere giriş sınavına sosyal bilgiler öğretmenlerinin görüşleri doğrultusunda bakış: T.C. İnkılâp Tarihi ve Atatürkçülük dersi örneği. *Journal of Innovative Research in Social Studies*, 1(6), 19-36. <https://doi.org/10.47503/jirss.1298418>
- Çavuşlu, M. A., Karakuzu, C. & Şahin, S. (2010). Parçacık sürü optimizasyonu algoritması ile yapay sinir ağı eğitiminin FPGA üzerinde donanımsal gerçekleştirilmesi. *Politeknik Dergisi*, 13(2), 83-92. Retrieved from <https://dergipark.org.tr/en/pub/politeknik/issue/33053/367865>
- Dayıoğlu, M., & Türüt-Aşık, S. (2007). Gender differences in academic performance in a large public university in Turkey. *High Educ*, 2(53), 255-277. <https://doi.org/10.1007/s10734-005-2464-6>
- Dilekçi, A., Karatay, H., & Koçyiğit, S. (2023). High school entrance exam Turkish questions and opinions of Turkish teachers about the exam. *Uludağ Üniversitesi Eğitim Fakültesi Dergisi*. <https://doi.org/10.19171/uefad.1264535>
- Filiz, B., & Kaya, D. (2021). Spor bilimleri fakültesi öğrencilerinin uyku kalitesi ve internet bağımlılıklarının akademik başarılarına etkisi. *Ankara Üniversitesi Beden Eğitimi ve Spor Yüksekokulu Spormetre Beden Eğitimi ve Spor Bilimleri Dergisi*, 51-60. <https://doi.org/10.33689/spormetre.730516>

- Gibbs, B. G., Workman, J., & Downey, D. B. (2016). The (conditional) resource dilution model: State- and community-level modifications. *Demography*, 3(53), 723-748. <https://doi.org/10.1007/s13524-016-0471-0>
- Gottfried, M. A. (2010). Evaluating the relationship between student attendance and achievement in urban elementary and middle schools. *American Educational Research Journal*, 2(47), 434-465. <https://doi.org/10.3102/0002831209350494>
- Gökcan, M., & Aktan, D. (2018). Investigation of the variables related to Teog english achievement using language acquisition theory of krashen. *Pegegog*, 3(8), 531-566. <https://doi.org/10.14527/pegegog.2018.021>
- Isik, E. (2022). Thermoluminescence characteristics of calcite with a Gaussian process regression model of machine learning. *Luminescence*, 37(8), 1321-1327. <https://doi.org/10.1002/bio.4298>
- Işık, İ., Işık, E. And Toktamış, H. "Dose and fading time estimation of glass ceramic by using artificial neural network method", Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, vol. 12, no. 1, pp. 47-52, Jan. 2021, <https://doi:10.24012/dumf.703171>
- Koğar, H. (2015). Examination of factors affecting pisa 2012 mathematical literacy through mediation model. *EB*, 179(40). <https://doi.org/10.15390/eb.2015.4445>
- Kruzicevic, S., Barisic, K., Banozic, A., Esteban, C., Sapunar, D., & Puljak, L. (2012). Predictors of attrition and academic success of medical students: A 30-year retrospective study. *Plos One*, 6(7), e39144. <https://doi.org/10.1371/journal.pone.0039144>
- MEB. (2018). Millî Eğitim Bakanlığı ortaöğretime geçiş yönergesi. https://www.meb.gov.tr/meb_iys_dosyalar/2018_03/26191912_yone_rge.pdf
- Özsağlam, M. Y. & Çunkaş, M. (2008). Optimizasyon problemlerinin çözümü için parçaçık sürü optimizasyonu algoritması. *Politeknik Dergisi*, 11(4), 299-305. Retrieved from <https://dergipark.org.tr/en/pub/politeknik/issue/33033/367241>
- Pettersson, E., Larsson, H., D'Onofrio, B., Bölte, S., & Lichtenstein, P. (2020). The general factor of psychopathology: A comparison with the general factor of intelligence with respect to magnitude and predictive validity. *World Psychiatry*, 2(19), 206-213. <https://doi.org/10.1002/wps.20763>
- Polat, M., & Bilen, E. (2022). Evaluation of cognitive process dimension of Teog and Lgs central exam science questions with revised bloom taxonomy.

Türkiye Kimya Derneği Dergisi Kısım C Kimya Eğitimi, 1(7), 45-72.
<https://doi.org/10.37995/jotcsc.1041329>

- Pontes, T., Silva, B., Sousa, J., Almeida, P., Davis, J., & Polatajko, H. (2016). Measuring children activity repertoire: Is the paediatric activity card sort a good tool for Brazilian therapists?. *Cad. Ter. Ocup. UFSCar*, 3(24), 435-445. <https://doi.org/10.4322/0104-4931.ctoao0754>
- Rothstein, R.,. Class and schools: Using social, economic, and educational reform to close the black–white achievement Gap, *Economic Policy Institute (Bulgaria)*. Retrieved Jul 18, 2023, from <https://policycommons.net/artifacts/1412001/class-and-schools/2026264/> on. CID: 20.500.12592/dg3d6c.
- Rohling, M., Langhinrichsen-Rohling, J., & Axelrod, B. (2017). Mild traumatic brain injury. In *APA handbook of forensic neuropsychology*. (pp. 147–200). American Psychological Association. <https://doi.org/10.1037/0000032-007>
- Sariođlan, A., Dolu, G., & Sevim, N. (2021). Analysis of science questions in eighth grade central exams according to cognitive fields of timss-2019. *E-Kafkas Eğitim Arařtırmaları Dergisi*, 3(8), 514-533. <https://doi.org/10.30900/kafkasegt.973021>
- Stelman, L. C., Powell, B. A., Werum, R. E., & Carter, S. L. (2002). Reconsidering the effects of sibling configuration: Recent advances and challenges. *Annu. Rev. Sociol.*, 1(28), 243-269. <https://doi.org/10.1146/annurev.soc.28.111301.093304>
- Whitney, H., Li, H., Drukker, K., Reeve, M., & Giger, M. (2023). Investigation of demographic implicit discrimination and disparate impact in chest radiography image-based AI for Covid-19 severity prediction. *Proc.SPIE12467, Medical Imaging 2023: Image Perception, Observer Performance, and Technology Assessment*. <https://doi.org/10.1117/12.2654076>
- Yavuz, S., Odabař, M., & Özdemir, A. (2016). Öğrencilerin sosyoekonomik düzeylerinin Teog matematik başarısına etkisi. *EPOD*, 1(7). <https://doi.org/10.21031/epod.86531>
- Yildiz, H., & Yoncalik, O. (2019). Ritmik yetenek ile akademik başarı arasındaki ilişki. *Opus Uluslararası Toplum Arařtırmaları Dergisi*. <https://doi.org/10.26466/opus.626271>
- Yüzüak, A. V., & Arslan, T. (2021). Science teachers views about high school entrance exam. *Abant İzzet Baysal Üniversitesi Eğitim Fakültesi Dergisi*, 3(21),805-819.<https://doi.org/10.17240/aibuefd.2021.21.64908->

[847653](#)