



www.turkishstudies.net/turkishstudies

Turkish Studies

eISSN: 1308-2140

Research Article / Araştırma Makalesi



ANKARA SCIENCE
UNIVERSITY

Prediction of University Students' Academic Achievement Using Machine Learning: An Explainable Artificial Intelligence Based Analysis *

Üniversite Öğrencilerinin Akademik Başarısının Makine Öğrenmesi ile Tahmini: Açıklanabilir Yapay Zekâ Temelli Bir Analiz

Murat Urfalıoğlu**

Abstract: This study aims to predict university students' academic achievement using machine learning methods and to interpret model predictions through explainable artificial intelligence (XAI). The dataset consists of survey data collected from 353 university students and is structured to include demographic, behavioral, academic, and environmental variables in a multidimensional manner. Through a feature construction process, variables were grouped under thematic dimensions, and the academic achievement variable was transformed into a binary classification problem. Logistic Regression (LR), Random Forest (RF), Support Vector Machines (SVM), and XGBoost (XGB) algorithms were employed. Model performance was evaluated using 5-fold cross-validation and a train-test split, and hyperparameter optimization was performed. According to the results, the RF model achieved the highest performance with 78% accuracy and an F1 score of 0.79, followed by the SVM model with 76% accuracy and an F1 score of 0.77. To ensure model interpretability, SHAP and LIME methods were used. SHAP analyses indicated that the most influential variables affecting academic achievement were grade level, academic engagement, environmental support, self-regulation, and academic motivation. LIME results supported these findings, demonstrating the consistency of the explanatory analyses. Consequently, academic achievement has a multidimensional and complex structure that can be analyzed more effectively using XAI methods.

The study has several limitations. The dataset is limited to a single institution and is based on self-reported data, which may restrict the generalizability of the findings. Additionally, transforming academic achievement into a binary classification problem may limit the depth of analysis. Furthermore, comprehensive psychometric validity and reliability analyses for the thematic composite variables were not conducted, which should be considered an important methodological limitation of the study. Future research should consider larger and

* Ethical approval for this research was granted by the Ethics Committee for Human Research in the Social Sciences at Bolu Abant İzzet Baysal University, pursuant to the decision adopted at its meeting No. 2026/03 held on March 30, 2026. *Araştırma için Bolu Abant İzzet Baysal Üniversitesi Sosyal Bilimlerde İnsan Araştırmaları Etik Kurulu'nun 30.03.2026 tarihinde 2026/03 sayılı toplantısında alınan kararla etik onay alınmıştır.*

** Asst. Prof. Dr., Bolu Abant İzzet Baysal University, Gerede Faculty of Applied Sciences, Department of Management Information Systems

Dr. Öğr. Üyesi, Bolu Abant İzzet Baysal Üniversitesi, Gerede Uygulamalı Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü

ORCID <https://orcid.org/0000-0002-2893-8135>

murat.urfalioglu@ibu.edu.tr

Cite as/ Atıf: Urfalıoğlu, M. (2026). Prediction of university students' academic achievement using machine learning: An explainable artificial intelligence based analysis / Üniversite öğrencilerinin akademik başarısının makine öğrenmesi ile tahmini: Açıklanabilir yapay zekâ temelli bir analiz. *Turkish Studies*, 21(Ö1), 3645-3711. [Special Issue Dedicated to Prof. Dr. Mahmut Özer]. Ankara Bilim University Publications. <https://dx.doi.org/10.7827/TurkishStudies.94239>

Received/Geliş: 03 May/Mayıs 2026

Accepted/Kabul: 15 September/Eylül 2026

Published/Yayın: 20 September/Eylül 2026

Checked by plagiarism software



more diverse samples, as well as longitudinal data, to examine changes in academic achievement over time. In conclusion, the integration of machine learning and XAI offers a comprehensive approach for both predicting and understanding academic achievement, thereby contributing to more transparent and data-driven decision-making processes in education.

Keywords: Machine learning, Classification, Academic Achievement, Explainable Artificial Intelligence, SHAP, LIME.

Öz: Bu çalışmada, üniversite öğrencilerinin akademik başarılarının makine öğrenmesi yöntemleri kullanılarak tahmin edilmesi ve model kararlarının açıklanabilir yapay zekâ yöntemleri ile yorumlanması amaçlanmıştır. Araştırma kapsamında, 353 üniversite öğrencisinden anket yöntemiyle elde edilen veriler kullanılmıştır. Veri seti; demografik, davranışsal, akademik ve çevresel değişkenleri içerecek şekilde çok boyutlu olarak yapılandırılmıştır. Öznitelik oluşturma süreci ile değişkenler tematik boyutlar altında birleştirilmiş ve akademik başarı değişkeni ikili sınıflandırma problemine dönüştürülmüştür. Çalışmada Lojistik Regresyon, Random Forest, Destek Vektör Makineleri ve XGBoost algoritmaları kullanılmıştır. Model performansları 5 katlı çapraz doğrulama ve eğitim-test ayrımı yöntemleri ile değerlendirilmiş, ayrıca Grid Search ve Optuna yöntemleri ile hiperparametre optimizasyonu gerçekleştirilmiştir. Elde edilen sonuçlara göre RF modeli %78 doğruluk ve 0.79 F1 skoru ile en yüksek performansı sergilerken, DVM modeli %76 doğruluk ve 0.77 F1 skoru ile onu takip etmiştir. Modelin açıklanabilirliğini sağlamak amacıyla SHAP ve LIME yöntemleri kullanılmıştır. SHAP analizleri, akademik başarı üzerinde en etkili değişkenlerin sınıf düzeyi, akademik katılım, çevresel destek, öz-düzenleme ve akademik motivasyon olduğunu göstermiştir. LIME sonuçları ise bu bulguları destekleyerek model kararlarının tutarlılığını ortaya koymuştur. Sonuç olarak, akademik başarının çok boyutlu ve karmaşık bir yapıya sahip olduğu ve bu yapının açıklanabilir yapay zekâ yöntemleri ile daha etkin biçimde analiz edilebileceği belirlenmiştir. Çalışmanın çeşitli sınırlılıkları bulunmaktadır. Veri seti tek bir kurumla sınırlıdır ve öz-bildirime dayalı verilerden oluşmaktadır; bu durum bulguların genellenebilirliğini sınırlayabilir. Ayrıca, akademik başarının ikili sınıflandırma problemine dönüştürülmesi analiz derinliğini sınırlandırabilir. Bunun yanı sıra, tematik bileşik değişkenler için kapsamlı psikometrik geçerlik ve güvenilirlik analizleri yapılmamıştır; bu durum çalışmanın önemli bir metodolojik sınırlılığı olarak değerlendirilmelidir. Gelecek araştırmalarda, akademik başarının zaman içerisindeki değişimini incelemek için daha büyük ve daha çeşitli örneklemeler ile boylamsal veriler dikkate alınmalıdır.

Sonuç olarak, makine öğrenmesi ve açıklanabilir yapay zekânın bütünleştirilmesi, akademik başarının hem tahmin edilmesi hem de anlaşılması için kapsamlı bir yaklaşım sunmakta; böylece eğitimde daha şeffaf ve veri odaklı karar verme süreçlerine katkı sağlamaktadır.

Anahtar Kelimeler: Makine öğrenmesi, sınıflandırma, akademik başarı, açıklanabilir yapay zekâ, SHAP, LIME.

Structured Abstract:

Academic achievement is widely regarded as a key indicator of educational quality, reflecting both student development and institutional effectiveness. However, academic achievement is not determined solely by cognitive abilities; rather, it emerges through the interaction of behavioral, psychological, and environmental factors. Traditional statistical approaches may be insufficient for modeling the complex and nonlinear structure of educational data. In this regard, machine learning (ML) approaches offer effective tools for identifying complex patterns and improving predictive performance. Nevertheless, many studies focusing on academic achievement prediction primarily emphasize model accuracy while providing limited explanation regarding how model predictions are formed. This limitation is particularly important in educational settings, where decision-making processes may have significant implications. Therefore, this study aims to predict university students' academic achievement using machine learning algorithms and to interpret model predictions through Explainable Artificial Intelligence (XAI) techniques. Accordingly, the study addresses the following research questions: (i) How do different ML algorithms perform in predicting academic achievement? (ii) To what extent does hyperparameter optimization influence model performance? (iii) Which variables have the greatest influence on academic achievement? and (iv) How do XAI methods contribute to the interpretation of model predictions?

Academic achievement is widely regarded as a multidimensional construct influenced by cognitive, behavioral, motivational, and environmental factors. The literature has demonstrated that variables such as academic engagement, self-regulation, motivation, and environmental support have significant effects on student success. Although the number of machine learning-based studies has increased, these studies have primarily focused on improving predictive accuracy and have not sufficiently explained how model predictions are generated. This issue is commonly referred to as the "black box" problem and limits the transparency and practical applicability of such models in educational practice. XAI methods, such as SHAP (SHapley Additive exPlanations) and LIME (Local Interpretable Model-agnostic Explanations), aim to address this limitation by providing both global and local explanations of model predictions. These approaches not only identify which variables are important but also reveal how these variables influence predictions. By integrating machine learning and XAI methods, this study aims to fill the gap in the literature in terms of both performance and interpretability.

The study is based on data collected from 353 university students through a survey. The dataset includes demographic, academic, behavioral, digital, and socio-economic variables. The sample was determined using a convenience sampling method and consists of students from a single faculty. Initially, 38 variables were collected and later reduced to 19 conceptual variables through thematic aggregation. However, after one-hot encoding procedures applied to nominal variables, the final number of features included in the machine learning models increased to 23. The dependent variable, academic achievement (Grade Point Average-GPA), was transformed into a binary classification problem using a threshold value of 70 (academically successful/academically unsuccessful). Logistic Regression (LR), Random Forest (RF), Support Vector Machines (SVM), and XGBoost (XGB) algorithms were employed in the study. Model performance was evaluated using 5-fold cross-validation and an 80/20 train-test split. Standardization was applied to scale-sensitive models. To improve model performance, hyperparameter optimization was conducted using Grid Search and Optuna, with the F1 score used as the primary evaluation metric. In addition, SHAP and LIME methods were applied to the best-performing model to analyze model predictions at both global and local levels.

The findings indicate that the RF model achieved the highest performance (Accuracy = 0.78, F1 = 0.79), followed by the SVM model (Accuracy = 0.76, F1 = 0.77). LR and XGB models demonstrated inferior predictive performance. Although RF and XGB models demonstrated very high performance on the training data, the decline in test performance suggests the presence of overfitting. Hyperparameter optimization improved the performance of all models, highlighting the importance of model tuning. Furthermore, nonlinear models appeared to be more successful in capturing the complex relationships embedded within the dataset. SHAP analyses revealed that the most influential variables affecting academic achievement were grade level, academic engagement, environmental support, self-regulation, and academic motivation. As academic engagement, motivation, and self-regulation increase, the probability of success also increases, whereas higher grade levels are associated with a decrease in success probability. SHAP and LIME analyses demonstrated that model predictions are shaped by the interaction of multiple variables rather than a single factor. The consistency

between the two methods supports the reliability of the findings. Overall, the results indicate that academic achievement is shaped by the combination of individual behaviors, learning processes, and environmental conditions.

The findings of this study suggest that academic achievement is a multidimensional construct that can be effectively modeled using machine learning methods. In particular, ensemble learning methods such as Random Forest were found to exhibit superior performance. Furthermore, the use of XAI methods improves the interpretability of model predictions, thereby addressing some of the limitations associated with traditional machine learning approaches.

The findings indicate that academic engagement, motivation, and self-regulation are key determinants of student success. Accordingly, educational institutions may consider developing supportive programs targeting these areas. In addition, improving students' environmental and socio-economic conditions may contribute to improving academic outcomes.

The study has several limitations. The dataset is limited to a single institution and is based on self-reported data, which may restrict the generalizability of the findings. Additionally, transforming academic achievement into a binary classification problem may limit the depth of analysis. Furthermore, comprehensive psychometric validity and reliability analyses for the thematic composite variables were not conducted, which should be considered an important methodological limitation of the study. Future research should consider larger and more diverse samples, as well as longitudinal data, to examine changes in academic achievement over time.

In conclusion, the integration of machine learning and XAI offers a comprehensive approach for both predicting and understanding academic achievement, thereby contributing to more transparent and data-driven decision-making processes in education.

Keywords: Machine learning, classification, academic achievement, explainable artificial intelligence, SHAP, LIME.

الملخص المنظم:

يُعدُّ التحصيل الأكاديمي على نطاق واسع مؤشراً محورياً لجودة التعليم، إذ يعكس في الوقت ذاته مستوى تطور الطلبة وفعالية المؤسسات التعليمية. غير أن التحصيل الأكاديمي لا يتحدد بالقدرات المعرفية وحدها، بل يتشكل من خلال التفاعل المعقد بين العوامل السلوكية والنفسية والبيئية. وفي هذا السياق، قد لا تكون الأساليب الإحصائية التقليدية كافية لنمذجة البنية المعقدة وغير أدوات تحليلية فعالة لاكتشاف الأنماط (Machine Learning, ML) الخطية للبيانات التعليمية، في حين توفر تقنيات تعلم الآلة المعقدة وتعزيز القدرة التنبؤية للنماذج. ومع ذلك، فقد ركزت غالبية الدراسات المعنية بالتنبؤ بالتحصيل الأكاديمي على تحسين دقة النماذج، مع إغفال اهتمام محدود لتفسير الكيفية التي تُنتج بها هذه النماذج تنبؤاتها. وتكتسب هذه المحدودية أهمية خاصة في البيئات التعليمية التي قد تترتب فيها على عمليات اتخاذ القرار آثار تربوية وإدارية بالغة الأهمية. وانطلاقاً من ذلك، تهدف هذه الدراسة إلى التنبؤ بالتحصيل الأكاديمي لطلبة الجامعة باستخدام خوارزميات تعلم الآلة، مع تفسير مخرجات النماذج بالاستعانة بتقنيات الذكاء وفي ضوء هذا الهدف، تسعى الدراسة إلى (1) كيف يختلف أداء خوارزميات تعلم الآلة في التنبؤ بالتحصيل الأكاديمي؟ (2) إلى أي مدى الإجابة عن الأسئلة البحثية الآتية: (3) ما المتغيرات الأكثر تأثيراً في (Hyperparameter Optimization) يؤثر تحسين المعلمات الفائقة في أداء النماذج؟ (4) كيف تسهم أساليب الذكاء الاصطناعي القابل للتفسير في توضيح آلية تكوين تنبؤات النماذج؟

ينظر الأدب العلمي إلى التحصيل الأكاديمي بوصفه بناءً متعدد الأبعاد يتأثر بعوامل معرفية وسلوكية ودافعية وبيئية. وقد أظهرت الدراسات السابقة أن متغيرات مثل الاندماج الأكاديمي، والتنظيم الذاتي، والدافعية، والدعم البيئي تؤدي أدواراً جوهرية في نجاح الطلبة. وعلى الرغم من التزايد الملحوظ في الدراسات المعتمدة على تعلم الآلة، فإن معظمها انصب على رفع كفاءة التنبؤ التي، «دون تقديم تفسيرات كافية للكيفية التي تُؤد بها النماذج قراراتها، وهو ما يُعرف بمشكلة «الصندوق الأسود» (Black Box)، تحد من شفافية النماذج وقابليتها للتطبيق العملي في المجال التربوي. وفي المقابل، تهدف أساليب الذكاء الاصطناعي القابل للتفسير إلى تجاوز هذه الإشكالية من خلال توفير تفسيرات شاملة على المستويين الكلي والمحلي لمخرجات النماذج، مثل SHAP (SHapley Additive exPlanations) و LIME (Local Interpretable Model-agnostic Explanations)، ولا تقتصر هذه الأساليب على تحديد المتغيرات الأكثر أهمية، بل تكشف أيضاً عن طبيعة إسهام كل متغير في تشكيل التنبؤات. ومن ثم، تسعى هذه الدراسة، من خلال الدمج بين تقنيات تعلم الآلة وأساليب الذكاء الاصطناعي القابل للتفسير، إلى سد فجوة معرفية تتعلق بجانب الأداء التنبؤي وقابلية التفسير في أن واحد.

اعتمدت الدراسة على بيانات جُمعت بواسطة استبانة طُبِّقت على 353 طالبًا جامعيًا. وتضمنت قاعدة البيانات متغيرات (Convenience) ديموغرافية وأكاديمية وسلوكية ورقمية واجتماعية-اقتصادية. واختيرت العينة وفق أسلوب العينة الملائمة واقتصرت على طلبة كلية واحدة. وقد جُمعت في المرحلة الأولى 38 متغيرًا، ثم جرى اختزالها إلى 19 متغيرًا، (Sampling) على المتغيرات الاسمية أدى إلى ارتفاع **One-Hot Encoding** مفاهيميًا من خلال التجميع الموضوعي. إلا أن تطبيق ترميز (GPA المعدل التراكمي) عدد السمات المستخدمة في نماذج تعلم الآلة إلى 23 سمة. وحُوِّل المتغير التابع، وهو التحصيل الأكاديمي إلى مسألة تصنيف ثنائي باستخدام قيمة حدية مقدارها 70 (ناجح أكاديميًا/غير ناجح أكاديميًا). واستُخدمت في الدراسة خوارزميات وآلات المتجهات الداعمة، (Random Forest, RF) والغابة العشوائية، (Logistic Regression, LR) الانحدار اللوجستي وقُِّم أداء النماذج باستخدام أسلوب التحقق المتقاطع خماسي. (XGBoost (XGB) و (Support Vector Machines, SVM) إلى جانب تقسيم البيانات بنسبة 80/20 إلى بيانات تدريب واختبار. كما طُبِّق توحيد (5-Fold Cross-Validation) الطيات على النماذج الحساسة لمقياس البيانات. ولتحسين الأداء، استُخدمت تقنيات تحسين المعلمات الفائقة (Standardization) القياس معيارًا رئيسًا للتقييم. وإضافةً إلى ذلك، طُبِّقت طريقتا **F1 Score** مع اعتماد مقياس **Optuna** و **Grid Search** بالاعتماد على على النموذج الأعلى أداءً لتحليل تنبؤاته على المستويين الكلي والمحلي **LIME** و **SHAP**.

أداءً (Accuracy = 0.78، F1 = 0.79) حقق أعلى مستويات الأداء (RF) أظهرت النتائج أن نموذج الغابة العشوائية (LR و XGB) في حين أظهر نموذجًا (SVM) (Accuracy = 0.76، F1 = 0.77) تلاه نموذج آلات المتجهات الداعمة أداءً مرتفعًا جدًا على بيانات التدريب، فإن انخفاض الأداء على بيانات RF و XGB تنبؤيًا أقل. وعلى الرغم من تحقيق نموذجي كما أسهم تحسين المعلمات الفائقة في رفع أداء جميع النماذج، مما (Overfitting) الاختبار يشير إلى وجود مشكلة فرط التكيف يؤكد الأهمية المنهجية لعمليات الضبط الأمثل للنماذج. وأظهرت النتائج كذلك أن النماذج غير الخطية كانت أكثر قدرة على النقاط: أن أكثر المتغيرات تأثيرًا في التحصيل الأكاديمي تمثلت في SHAP العلاقات المعقدة الكامنة في البيانات. وكشفت تحليلات المستوى الدراسي، والاندماج الأكاديمي، والدعم البيئي، والتنظيم الذاتي، والدافعية الأكاديمية. كما بينت النتائج أن ازدياد مستويات الاندماج الأكاديمي والدافعية والتنظيم الذاتي يؤدي إلى ارتفاع احتمالية النجاح، في حين يرتبط التقدم في المستوى الدراسي بانخفاض أن التنبؤات لا تعتمد على متغير منفرد، وإنما تتشكل من خلال LIME و SHAP احتمالية النجاح الأكاديمي. وأظهرت تحليلات، التفاعل المتزامن بين مجموعة من المتغيرات. كما عزز الاتساق بين نتائج الطريقتين موثوقية النتائج المستخلصة. وبوجه عام تؤكد النتائج أن التحصيل الأكاديمي يتحدد من خلال التفاعل بين السلوكيات الفردية، وعمليات التعلم، والظروف البيئية المحيطة بالطالب.

تشير نتائج الدراسة إلى أن التحصيل الأكاديمي يمثل بناءً متعدد الأبعاد يمكن نمذجته بكفاءة باستخدام تقنيات تعلم الآلة تحقق أداءً متفوقًا، (Random Forest) ولا سيما الغابة العشوائية، (Ensemble Learning) وأن نماذج التعلم التجميعي مقارنةً بالنماذج الأخرى. كما أن توظيف تقنيات الذكاء الاصطناعي القابل للتفسير يعزز قابلية تفسير مخرجات النماذج، ويسهم في تجاوز بعض القيود الملزمة لأساليب تعلم الآلة التقليدية.

وتبرز النتائج أن الاندماج الأكاديمي، والدافعية، والتنظيم الذاتي تمثل محددات رئيسة لنجاح الطلبة؛ وعليه، يمكن للمؤسسات التعليمية تطوير برامج داعمة تستهدف تعزيز هذه الجوانب. كما أن تحسين الظروف البيئية والاجتماعية-الاقتصادية للطلبة قد يسهم بصورة ملموسة في الارتقاء بمخرجاتهم الأكاديمية.

وتواجه الدراسة عددًا من القيود المنهجية؛ إذ اقتصرت مجتمع الدراسة على مؤسسة تعليمية واحدة، واعتمدت البيانات على التقارير الذاتية، الأمر الذي قد يحد من إمكانية تعميم النتائج. كما أن تحويل التحصيل الأكاديمي إلى مسألة تصنيف ثنائي قد يكون قد حدّ من عمق التحليل. فضلًا عن ذلك، لم تُجرَ تحليلات سيكومترية شاملة للتحقق من الصدق والثبات للمتغيرات المركبة الناتجة عن التجميع الموضوعي، وهو ما ينبغي اعتباره من أبرز القيود المنهجية للدراسة. وعليه، توصي الدراسة المستقبلية بالاعتماد على عينات أكبر وأكثر تنوعًا، واستخدام بيانات طولية تسمح بتتبع تطور التحصيل الأكاديمي عبر الزمن.

ختامًا، يبرهن الدمج بين تقنيات تعلم الآلة وأساليب الذكاء الاصطناعي القابل للتفسير على أنه إطار تحليلي متكامل لا يقتصر على تحسين القدرة التنبؤية للتحصيل الأكاديمي، بل يسهم أيضًا في فهم العوامل الكامنة وراء هذه التنبؤات، بما يعزز من شفافية عمليات اتخاذ القرار في المجال التعليمي، ويدعم تبني سياسات وممارسات تعليمية قائمة على الأدلة والبيانات.

SHAP، LIME، الكلمات المفتاحية: تعلم الآلة، التصنيف، التحصيل الأكاديمي، الذكاء الاصطناعي القابل للتفسير.

Résumé Structuré:

La réussite académique est largement considérée comme un indicateur fondamental de la qualité de l'enseignement, reflétant à la fois le développement des étudiants et l'efficacité des établissements d'enseignement supérieur. Toutefois, la réussite académique ne dépend pas exclusivement des capacités cognitives ; elle résulte plutôt de l'interaction complexe entre des facteurs comportementaux, psychologiques et environnementaux. Dans ce contexte, les approches statistiques traditionnelles peuvent s'avérer insuffisantes

pour modéliser la structure complexe et non linéaire des données éducatives. Les méthodes d'apprentissage automatique (Machine Learning, ML) offrent, à cet égard, des outils particulièrement performants pour identifier des schémas complexes et améliorer les performances prédictives. Néanmoins, la majorité des recherches consacrées à la prédiction de la réussite académique se sont principalement concentrées sur l'amélioration de la précision des modèles, tout en accordant une attention limitée à l'explication des mécanismes sous-jacents à la production de leurs prédictions. Cette limitation revêt une importance particulière dans les contextes éducatifs, où les processus décisionnels peuvent avoir des implications pédagogiques et institutionnelles majeures. En conséquence, la présente étude vise à prédire la réussite académique des étudiants universitaires au moyen d'algorithmes d'apprentissage automatique et à interpréter les prédictions des modèles grâce aux techniques d'Intelligence Artificielle Explicable (Explainable Artificial Intelligence, XAI). À cette fin, l'étude cherche à répondre aux questions de recherche suivantes : (i) quelles sont les performances comparatives des différents algorithmes d'apprentissage automatique dans la prédiction de la réussite académique ? (ii) dans quelle mesure l'optimisation des hyperparamètres influence-t-elle les performances des modèles ? (iii) quelles variables exercent l'influence la plus importante sur la réussite académique ? et (iv) dans quelle mesure les méthodes d'IA explicable contribuent-elles à l'interprétation des prédictions produites par les modèles ?

La réussite académique est généralement définie comme un construit multidimensionnel influencé par des facteurs cognitifs, comportementaux, motivationnels et environnementaux. Les travaux antérieurs ont démontré que des variables telles que l'engagement académique, l'autorégulation, la motivation et le soutien environnemental exercent une influence significative sur la réussite des étudiants. Bien que les études fondées sur l'apprentissage automatique se soient multipliées au cours des dernières années, elles se sont essentiellement focalisées sur l'amélioration des performances prédictives, sans expliquer de manière satisfaisante la manière dont les modèles génèrent leurs prédictions. Cette problématique est communément désignée sous le terme de « problème de la boîte noire » (black box), lequel limite la transparence ainsi que l'applicabilité pratique de ces modèles dans le domaine de l'éducation. Les approches d'Intelligence Artificielle Explicable, notamment **SHAP** (*SHapley Additive exPlanations*) et **LIME** (*Local Interpretable Model-agnostic Explanations*), ont précisément été développées afin de surmonter cette limite en fournissant des explications globales et locales des prédictions des modèles. Ces méthodes permettent non seulement d'identifier les variables les plus déterminantes, mais également d'explicitement la manière dont chacune d'entre elles contribue aux prédictions. En intégrant les approches d'apprentissage automatique aux méthodes d'IA explicable, la présente recherche ambitionne ainsi de combler une lacune importante de la littérature, tant du point de vue des performances prédictives que de l'interprétabilité des modèles.

L'étude repose sur des données recueillies auprès de **353 étudiants universitaires** au moyen d'un questionnaire. Le jeu de données comprend des variables démographiques, académiques, comportementales, numériques et socio-économiques. L'échantillon a été constitué selon une méthode d'échantillonnage de convenance et se limite aux étudiants d'une seule faculté. Dans un premier temps, **38 variables** ont été collectées, puis regroupées thématiquement afin d'être réduites à **19 variables conceptuelles**. Toutefois, l'application de la technique de codage **One-Hot Encoding** aux variables nominales a porté le nombre final de caractéristiques utilisées dans les modèles d'apprentissage automatique à **23 variables**. La variable dépendante, correspondant à la réussite académique (Grade Point Average – GPA), a été transformée en un problème de classification binaire au moyen d'un seuil fixé à **70** (étudiant en réussite / étudiant en échec académique). Les algorithmes de **Régression Logistique (Logistic Regression – LR)**, **Random Forest (RF)**, **Support Vector Machines (SVM)** et **XGBoost (XGB)** ont été mobilisés dans cette étude. Les performances des modèles ont été évaluées au moyen d'une validation croisée à **5 plis (5-fold cross-validation)**, complétée par une répartition des données selon un ratio **80/20** entre les ensembles d'apprentissage et de test. Une procédure de standardisation a été appliquée aux modèles sensibles à l'échelle des variables. Afin d'améliorer les performances prédictives, une optimisation des hyperparamètres a été réalisée à l'aide des méthodes **Grid Search** et **Optuna**, en retenant le **score F1** comme principal indicateur d'évaluation. Enfin, les méthodes **SHAP** et **LIME** ont été appliquées au modèle présentant les meilleures performances afin d'analyser les prédictions aussi bien au niveau global qu'au niveau local.

Les résultats montrent que le modèle **Random Forest (RF)** a obtenu les meilleures performances (**Accuracy = 0,78 ; F1 = 0,79**), suivi du modèle **Support Vector Machines (SVM)** (**Accuracy = 0,76 ; F1 = 0,77**). Les modèles **Logistic Regression (LR)** et **XGBoost (XGB)** ont, en revanche, présenté des performances prédictives relativement inférieures. Bien que les modèles **RF** et **XGB** aient atteint des performances très

élevées sur les données d'entraînement, la diminution observée sur les données de test suggère la présence d'un phénomène de **surapprentissage (overfitting)**. Par ailleurs, l'optimisation des hyperparamètres a amélioré les performances de l'ensemble des modèles, mettant ainsi en évidence l'importance du réglage optimal des paramètres. Les résultats indiquent également que les modèles non linéaires se révèlent plus efficaces pour capturer les relations complexes sous-jacentes aux données. Les analyses réalisées à l'aide de **SHAP** ont révélé que les variables exerçant l'influence la plus déterminante sur la réussite académique sont le **niveau d'études, l'engagement académique, le soutien environnemental, l'autorégulation et la motivation académique**. Une augmentation de l'engagement académique, de la motivation et de l'autorégulation accroît la probabilité de réussite, tandis qu'un niveau d'études plus avancé est associé à une diminution de cette probabilité. Les analyses **SHAP** et **LIME** montrent également que les prédictions des modèles résultent de l'interaction simultanée de multiples variables plutôt que de l'effet isolé d'un seul facteur. La cohérence observée entre les résultats obtenus par ces deux méthodes renforce la robustesse et la fiabilité des conclusions. Dans leur ensemble, les résultats démontrent que la réussite académique est façonnée par l'interaction des comportements individuels, des processus d'apprentissage et des conditions environnementales.

Les résultats de cette recherche montrent que la réussite académique constitue un construit multidimensionnel pouvant être modélisé avec efficacité au moyen des techniques d'apprentissage automatique. En particulier, les méthodes d'**apprentissage ensembliste (Ensemble Learning)**, notamment **Random Forest**, présentent des performances supérieures à celles des autres modèles évalués. En outre, l'intégration des méthodes d'**Intelligence Artificielle Explicable (XAI)** améliore considérablement l'interprétabilité des prédictions, contribuant ainsi à surmonter certaines des limites inhérentes aux approches traditionnelles d'apprentissage automatique.

Les analyses mettent en évidence que **l'engagement académique, la motivation et l'autorégulation** constituent les principaux déterminants de la réussite des étudiants. À cet égard, les établissements d'enseignement supérieur pourraient développer des programmes de soutien spécifiquement orientés vers le renforcement de ces dimensions. Par ailleurs, l'amélioration des conditions environnementales et socio-économiques des étudiants est susceptible de favoriser une progression significative de leurs performances académiques.

Cette étude présente néanmoins plusieurs limites. Premièrement, les données proviennent d'un seul établissement d'enseignement supérieur et reposent sur des déclarations auto-rapportées, ce qui peut limiter la généralisation des résultats. Deuxièmement, la transformation de la réussite académique en un problème de classification binaire est susceptible de réduire la profondeur analytique des résultats. En outre, aucune analyse psychométrique exhaustive de validité et de fidélité n'a été réalisée pour les variables composites obtenues par agrégation thématique, ce qui constitue une limitation méthodologique importante de l'étude. Les recherches futures devraient s'appuyer sur des échantillons plus vastes et plus diversifiés, ainsi que sur des données longitudinales, afin d'examiner l'évolution de la réussite académique dans le temps.

En conclusion, l'intégration des techniques d'**apprentissage automatique** et de l'**Intelligence Artificielle Explicable (XAI)** offre un cadre analytique complet permettant non seulement de prédire la réussite académique avec un niveau élevé de performance, mais également d'en comprendre les mécanismes sous-jacents. Cette approche favorise ainsi des processus décisionnels plus transparents, interprétables et fondés sur les données dans le domaine de l'éducation.

Mots-clés: apprentissage automatique, classification, réussite académique, intelligence artificielle explicable, SHAP, LIME.

Resumen Estructurado:

El rendimiento académico es ampliamente reconocido como un indicador fundamental de la calidad educativa, ya que refleja tanto el desarrollo integral del estudiantado como la eficacia de las instituciones de educación superior. Sin embargo, el rendimiento académico no está determinado exclusivamente por las capacidades cognitivas, sino que emerge como resultado de la interacción dinámica entre factores conductuales, psicológicos y ambientales. En este contexto, los enfoques estadísticos tradicionales pueden resultar insuficientes para modelizar la estructura compleja y no lineal de los datos educativos. En este sentido, las técnicas de **aprendizaje automático (Machine Learning, ML)** constituyen herramientas analíticas

eficaces para identificar patrones complejos y mejorar el rendimiento predictivo. No obstante, la mayor parte de las investigaciones orientadas a la predicción del rendimiento académico se ha centrado principalmente en maximizar la precisión de los modelos, prestando una atención limitada a la explicación de los mecanismos mediante los cuales dichos modelos generan sus predicciones. Esta limitación adquiere una relevancia especial en los contextos educativos, donde los procesos de toma de decisiones pueden tener importantes implicaciones pedagógicas e institucionales. En consecuencia, el presente estudio tiene como objetivo predecir el rendimiento académico de estudiantes universitarios mediante algoritmos de aprendizaje automático e interpretar las predicciones de los modelos utilizando técnicas de **Inteligencia Artificial Explicable (Explainable Artificial Intelligence, XAI)**. Con este propósito, la investigación aborda las siguientes preguntas: (i) ¿Cómo difieren los distintos algoritmos de aprendizaje automático en la predicción del rendimiento académico? (ii) ¿En qué medida influye la optimización de hiperparámetros en el desempeño de los modelos? (iii) ¿Qué variables ejercen la mayor influencia sobre el rendimiento académico? y (iv) ¿Cómo contribuyen los métodos de Inteligencia Artificial Explicable a la interpretación de las predicciones generadas por los modelos?

El rendimiento académico es concebido en la literatura científica como un constructo multidimensional influenciado por factores cognitivos, conductuales, motivacionales y ambientales. Numerosos estudios han demostrado que variables como el compromiso académico, la autorregulación, la motivación y el apoyo ambiental ejercen una influencia significativa sobre el éxito académico del estudiantado. Aunque el número de investigaciones basadas en aprendizaje automático ha aumentado considerablemente durante los últimos años, estas se han orientado principalmente hacia la mejora del rendimiento predictivo, sin explicar de manera suficiente cómo los modelos producen sus predicciones. Esta problemática se conoce comúnmente como el **problema de la “caja negra” (black box)**, el cual limita la transparencia y la aplicabilidad práctica de estos modelos en el ámbito educativo. En contraste, los métodos de **Inteligencia Artificial Explicable**, como **SHAP (SHapley Additive exPlanations)** y **LIME (Local Interpretable Model-agnostic Explanations)**, han sido desarrollados para superar esta limitación proporcionando explicaciones tanto globales como locales de las predicciones de los modelos. Estos enfoques no solo permiten identificar cuáles son las variables más relevantes, sino también comprender de qué manera dichas variables contribuyen a la generación de las predicciones. En consecuencia, mediante la integración de técnicas de aprendizaje automático y métodos de Inteligencia Artificial Explicable, el presente estudio pretende subsanar una importante laguna en la literatura, tanto desde la perspectiva del rendimiento predictivo como de la interpretabilidad de los modelos.

El estudio se fundamenta en datos recopilados mediante un cuestionario aplicado a **353 estudiantes universitarios**. El conjunto de datos comprende variables demográficas, académicas, conductuales, digitales y socioeconómicas. La muestra fue seleccionada mediante un procedimiento de **muestreo por conveniencia** y está compuesta por estudiantes pertenecientes a una única facultad. Inicialmente se recopilaron **38 variables**, las cuales fueron posteriormente reducidas a **19 variables conceptuales** mediante un proceso de agregación temática. No obstante, tras la aplicación del procedimiento de **One-Hot Encoding** a las variables nominales, el número final de características utilizadas en los modelos de aprendizaje automático ascendió a **23 variables**. La variable dependiente, correspondiente al rendimiento académico (**Grade Point Average, GPA**), fue transformada en un problema de **clasificación binaria** mediante el establecimiento de un valor umbral de **70** (estudiantes con rendimiento académico satisfactorio/estudiantes con rendimiento académico no satisfactorio). Para el desarrollo del estudio se emplearon los algoritmos de **Regresión Logística (Logistic Regression, LR)**, **Random Forest (RF)**, **Máquinas de Vectores de Soporte (Support Vector Machines, SVM)** y **XGBoost (XGB)**. El rendimiento de los modelos fue evaluado mediante **validación cruzada de cinco particiones (5-fold cross-validation)** y una división de los datos en una proporción **80/20** para entrenamiento y prueba. Asimismo, se aplicó un procedimiento de **estandarización** a los modelos sensibles a la escala de las variables. Con el propósito de optimizar el desempeño predictivo, se realizó una optimización de hiperparámetros utilizando los métodos **Grid Search** y **Optuna**, tomando como principal métrica de evaluación la **puntuación F1 (F1 Score)**. Finalmente, los métodos **SHAP** y **LIME** fueron aplicados al modelo con mejor desempeño para analizar las predicciones tanto a nivel global como local.

Los resultados muestran que el modelo **Random Forest (RF)** alcanzó el mejor desempeño (**Accuracy = 0.78; F1 = 0.79**), seguido por el modelo **Support Vector Machines (SVM)** (**Accuracy = 0.76; F1 = 0.77**). En contraste, los modelos de **Regresión Logística (LR)** y **XGBoost (XGB)** presentaron un rendimiento predictivo inferior. Aunque los modelos **RF** y **XGB** obtuvieron un desempeño muy elevado sobre los datos de entrenamiento, la disminución observada en el conjunto de prueba sugiere la presencia de **sobreajuste**

(**overfitting**). Asimismo, la optimización de los hiperparámetros mejoró el rendimiento de todos los modelos, lo que pone de manifiesto la importancia del ajuste óptimo de los parámetros para incrementar la capacidad predictiva. Los resultados también evidencian que los modelos no lineales fueron más eficaces para capturar las complejas relaciones subyacentes presentes en los datos. Los análisis realizados mediante **SHAP** revelaron que las variables con mayor influencia sobre el rendimiento académico fueron el **nivel de estudios**, el **compromiso académico**, el **apoyo ambiental**, la **autorregulación** y la **motivación académica**. El incremento del compromiso académico, la motivación y la autorregulación aumenta la probabilidad de éxito académico, mientras que un mayor nivel de estudios se asocia con una disminución de dicha probabilidad. Tanto los análisis de **SHAP** como los de **LIME** demostraron que las predicciones del modelo no dependen de un único factor, sino que se configuran a partir de la interacción simultánea de múltiples variables. La consistencia observada entre ambos métodos refuerza la robustez y la fiabilidad de los resultados obtenidos. En conjunto, los hallazgos indican que el rendimiento académico se configura mediante la interacción entre los comportamientos individuales, los procesos de aprendizaje y las condiciones ambientales.

Los resultados de la presente investigación ponen de manifiesto que el rendimiento académico constituye un **constructo multidimensional** susceptible de ser modelizado eficazmente mediante técnicas de aprendizaje automático. En particular, los métodos de **aprendizaje por conjuntos (Ensemble Learning)**, especialmente **Random Forest**, demostraron un desempeño superior en comparación con los demás algoritmos evaluados. Asimismo, la incorporación de métodos de **Inteligencia Artificial Explicable (XAI)** incrementa significativamente la interpretabilidad de las predicciones, contribuyendo a superar algunas de las limitaciones inherentes a los enfoques tradicionales de aprendizaje automático.

Los hallazgos evidencian que el **compromiso académico**, la **motivación** y la **autorregulación** constituyen los principales determinantes del éxito académico del estudiantado. En consecuencia, las instituciones de educación superior podrían diseñar e implementar programas de apoyo orientados específicamente al fortalecimiento de estas dimensiones. Del mismo modo, la mejora de las condiciones ambientales y socioeconómicas de los estudiantes podría contribuir de manera significativa al incremento de su rendimiento académico.

El estudio presenta diversas limitaciones metodológicas. En primer lugar, el conjunto de datos se limita a una única institución de educación superior y se basa en información autodeclarada, lo que puede restringir la capacidad de generalización de los resultados. En segundo lugar, la transformación del rendimiento académico en un problema de clasificación binaria puede haber reducido la profundidad analítica de la investigación. Además, no se realizaron análisis psicométricos exhaustivos de validez y fiabilidad sobre las variables compuestas obtenidas mediante agregación temática, circunstancia que debe considerarse una limitación metodológica relevante. En consecuencia, futuras investigaciones deberían incorporar muestras más amplias y heterogéneas, así como diseños longitudinales, con el fin de analizar la evolución del rendimiento académico a lo largo del tiempo.

En conclusión, la integración de las técnicas de **aprendizaje automático** con los métodos de **Inteligencia Artificial Explicable (XAI)** constituye un marco metodológico integral que no solo permite predecir el rendimiento académico con elevados niveles de precisión, sino también comprender los mecanismos que sustentan dichas predicciones. En este sentido, este enfoque contribuye al desarrollo de procesos de toma de decisiones más transparentes, interpretables y fundamentados en evidencia empírica dentro del ámbito educativo.

Palabras clave: aprendizaje automático; clasificación; rendimiento académico; inteligencia artificial explicable; SHAP; LIME.

结构化摘要:

学业成就 (Academic Achievement) 被广泛认为是衡量教育质量的重要指标, 它不仅反映学生的发展水平, 同时也是评价高等教育机构教育成效的重要依据。然而, 学业成就并非仅由认知能力决定, 而是在行为、心理及环境等多种因素相互作用下形成的复杂结果。传统统计分析方法在刻画教育数据复杂且非线性的结构特征方面往往存在一定局限, 而**机器学习 (Machine Learning, ML) 方法则能够有效识别复杂模式并提升预测性能。然而, 现有关于学业成就预测的大多数研究主要

关注模型预测精度，而对于模型如何生成预测结果的解释相对不足。这一局限在教育情境中尤为突出，因为教育决策通常会对学生发展及教育管理产生重要影响。因此，本研究旨在利用机器学习算法预测大学生学业成就，并借助可解释人工智能（Explainable Artificial Intelligence, XAI）**技术对模型预测结果进行解释。据此，本研究围绕以下四个研究问题展开：（1）不同机器学习算法在学业成就预测中的表现如何？（2）超参数优化（Hyperparameter Optimization）在多大程度上影响模型性能？（3）哪些变量对学业成就具有最显著的影响？（4）可解释人工智能方法如何促进机器学习模型预测结果的解释与理解？

现有研究普遍认为，学业成就是一个受认知、行为、动机及环境等多重因素共同影响的多维构念（multidimensional construct）。大量文献表明，学业投入（academic engagement）、自我调节（self-regulation）、**学习动机（motivation）以及环境支持（environmental support）**等变量均对学生学业成功具有显著影响。尽管近年来基于机器学习的相关研究数量不断增加，但其主要关注预测精度的提升，而较少深入解释模型预测形成的机制。这一问题通常被称为“黑箱（Black Box）问题”，限制了机器学习模型在教育实践中的透明性与实际应用价值。为克服这一局限，可解释人工智能（XAI）方法，如SHAP（SHapley Additive exPlanations）和LIME（Local Interpretable Model-agnostic Explanations），能够分别从全局（global）与局部（local）两个层面对模型预测结果进行解释。这些方法不仅能够识别影响预测结果的重要变量，而且能够揭示各变量对预测结果产生影响的具体方式。因此，本研究通过融合机器学习与可解释人工智能方法，旨在弥补现有研究在预测性能与模型可解释性两个方面的不足，为教育数据分析提供更加透明且具有解释力的分析框架。

本研究的数据来源于对353名大学生实施的问卷调查。数据集涵盖人口统计学变量、学业变量、行为变量、数字化变量以及社会经济变量。研究采用便利抽样（Convenience Sampling）方法，样本均来自同一学院。研究初期共收集38个变量，随后通过主题聚合（thematic aggregation）整合为19个概念变量。然而，在对名义变量实施独热编码（One-Hot Encoding）之后，用于机器学习模型训练的最终特征数量增加至23个。因变量——学业成就（平均绩点，Grade Point Average, GPA）——依据70分这一阈值转换为二元分类问题（学业成功/学业未成功）。研究采用了逻辑回归（Logistic Regression, LR）、随机森林（Random Forest, RF）、支持向量机（Support Vector Machines, SVM）以及极端梯度提升（XGBoost, XGB）四种机器学习算法。模型性能通过五折交叉验证（5-fold Cross-Validation）及80%训练集—20%测试集的数据划分方式进行评估。对于对数据尺度敏感的模型，研究实施了标准化（Standardization）处理。为进一步提升模型性能，研究采用Grid Search与Optuna两种超参数优化方法，并以F1值（F1 Score）作为主要评价指标。此外，对表现最佳的模型进一步应用SHAP与LIME方法，从全局和局部两个层面对模型预测结果进行了深入解释与分析。

研究结果表明，**随机森林（Random Forest, RF）模型取得了最佳预测性能（Accuracy = 0.78；F1 = 0.79），其次为支持向量机（Support Vector Machines, SVM）**模型（Accuracy = 0.76；F1 = 0.77）。相比之下，逻辑回归（Logistic Regression, LR）与XGBoost（XGB）模型的预测性能相对较低。尽管RF和XGB模型在训练集上均表现出极高的预测能力，但其在测试集上的性能下降表明模型存在一定程度的过拟合（Overfitting）现象。此外，超参数优化显著提升了所有模型的预测性能，进一步凸显了模型参数优化在提高预测能力方面的重要作用。研究结果还表明，相较于线性模型，非线性模型能够更加有效地捕捉数据中蕴含的复杂关系。SHAP分析结果显示，对学业成就影响最大的变量依次为：年级（grade level）、学业投入（academic engagement）、环境支持（environmental support）、自我调节（self-regulation）以及学业动机（academic motivation）。随着学业投入、学习动机和自我调节水平的提高，学生取得学业成功的概率显著增加；而较高的年级则与学业成功概率下降呈现相关关系。SHAP与LIME分析进一步表明，模型预测结果并非由单一因素决定，而是多种变量相互作用的综合结果。两种解释方法所得结果之间表现出较高的一致性，从而进一步增强了研究结论的可靠性。总体而言，研究结果表明，学业成就是个体行为、学习过程与环境条件共同作用的综合体现。

本研究结果进一步证明，**学业成就是一种多维构念 (multidimensional construct)**，能够借助机器学习方法实现有效建模。其中，以****随机森林 (Random Forest) 为代表的集成学习 (Ensemble Learning) 方法表现出最优的预测性能**。此外，引入可解释人工智能 (Explainable Artificial Intelligence, XAI) ****方法显著提升了模型预测结果的可解释性，从而在一定程度上克服了传统机器学习方法在模型透明性方面存在的不足。**

研究结果表明，**学业投入、学习动机以及自我调节能力**是影响学生学业成功的核心决定因素。因此，高等教育机构可考虑开发针对上述关键能力的支持性干预项目，以促进学生学业表现的持续提升。同时，改善学生所处的环境条件及社会经济状况，也有助于进一步提高其学业成绩。

本研究仍存在若干局限性。首先，研究数据仅来源于单一高等教育机构，且主要依赖学生自我报告数据，因此研究结论的普遍适用性受到一定限制。其次，将学业成就处理为二元分类问题，可能削弱了研究分析的深度。此外，本研究未对通过主题聚合形成的复合变量开展系统而全面的心理测量信度与效度检验，这应被视为本研究的重要方法学局限。未来研究应采用规模更大、来源更加多样化的样本，并结合纵向数据设计，以深入考察学业成就随时间变化的发展过程及其影响机制。

综上所述，**机器学习与**可解释人工智能 (XAI) **的有机融合**，为学业成就的预测与解释提供了一个兼具预测能力与理论解释力的综合分析框架。这不仅有助于深入理解影响学生学业表现的关键机制，而且能够促进教育领域更加透明、更加科学、更加基于数据证据的决策过程。

关键词：机器学习；分类；学业成就；可解释人工智能；SHAP；LIME。

Структурированная Аннотация:

Академическая успеваемость широко рассматривается как один из ключевых индикаторов качества образования, отражающий как уровень развития обучающихся, так и эффективность образовательных учреждений. Вместе с тем академическая успеваемость определяется не исключительно когнитивными способностями, а формируется в результате сложного взаимодействия поведенческих, психологических и средовых факторов. В этом контексте традиционные статистические методы нередко оказываются недостаточными для моделирования сложной и нелинейной структуры образовательных данных. В свою очередь, методы **машинного обучения (Machine Learning, ML)** предоставляют эффективный аналитический инструментарий для выявления сложных закономерностей и повышения точности прогнозирования. Однако большинство исследований, посвящённых прогнозированию академической успеваемости, сосредоточено преимущественно на повышении точности моделей, уделяя значительно меньше внимания объяснению механизмов формирования прогнозов. Данное ограничение приобретает особую значимость в образовательной сфере, где принимаемые решения могут иметь существенные педагогические и институциональные последствия. В связи с этим целью настоящего исследования является прогнозирование академической успеваемости студентов университета с использованием алгоритмов машинного обучения, а также интерпретация результатов прогнозирования посредством методов **объяснимого искусственного интеллекта (Explainable Artificial Intelligence, XAI)**. Для достижения поставленной цели исследование направлено на получение ответов на следующие вопросы: (i) каковы сравнительные результаты различных алгоритмов машинного обучения при прогнозировании академической успеваемости? (ii) в какой степени оптимизация гиперпараметров влияет на эффективность моделей? (iii) какие переменные оказывают наибольшее влияние на академическую успеваемость? и (iv) каким образом методы объяснимого искусственного интеллекта способствуют интерпретации прогнозов моделей?

В современной научной литературе академическая успеваемость рассматривается как **многомерный конструкт**, формирующийся под воздействием когнитивных, поведенческих, мотивационных и средовых факторов. Предыдущие исследования убедительно показали, что такие переменные, как **академическая вовлечённость (academic engagement)**, **саморегуляция (self-regulation)**, **мотивация** и **поддержка образовательной среды (environmental support)**, оказывают

существенное влияние на успешность студентов. Несмотря на стремительный рост числа исследований, основанных на применении методов машинного обучения, основное внимание в них уделяется повышению прогностической точности моделей, тогда как объяснение механизмов формирования прогнозов остаётся недостаточно разработанным. Данная проблема широко известна как проблема «чёрного ящика» (**Black Box**) и существенно ограничивает прозрачность моделей, а также возможности их практического применения в образовательной практике. Для преодоления данного ограничения были разработаны методы **объяснимого искусственного интеллекта (XAI)**, в частности **SHAP (SHapley Additive exPlanations)** и **LIME (Local Interpretable Model-agnostic Explanations)**, обеспечивающие интерпретацию прогнозов моделей как на глобальном, так и на локальном уровнях. Эти методы позволяют не только определить наиболее значимые переменные, но и раскрыть механизм их влияния на формирование прогнозов. Таким образом, интеграция методов машинного обучения и объяснимого искусственного интеллекта в настоящее исследование направлена на восполнение существующего пробела в научной литературе одновременно с точки зрения прогностической эффективности и интерпретируемости моделей.

Эмпирическую основу исследования составили данные, полученные в результате анкетного опроса **353 студентов университета**. Набор данных включал демографические, академические, поведенческие, цифровые и социально-экономические переменные. Выборка была сформирована с использованием метода **удобной выборки (Convenience Sampling)** и ограничивалась студентами одного факультета. На первоначальном этапе было собрано **38 переменных**, которые впоследствии посредством тематической агрегации были сведены к **19 концептуальным переменным**. Однако после применения процедуры **One-Hot Encoding** к номинативным признакам итоговое количество признаков, использованных в моделях машинного обучения, увеличилось до **23**. Зависимая переменная — **академическая успеваемость (Grade Point Average, GPA)** — была преобразована в задачу бинарной классификации с использованием порогового значения **70** (академически успешный / академически неуспешный студент). В исследовании были использованы алгоритмы **логистической регрессии (Logistic Regression, LR)**, **случайного леса (Random Forest, RF)**, **метода опорных векторов (Support Vector Machines, SVM)** и **XGBoost (XGB)**. Оценка эффективности моделей осуществлялась с применением **пятикратной перекрёстной проверки (5-fold Cross-Validation)** и разделения данных на обучающую и тестовую выборки в соотношении **80/20**. Для моделей, чувствительных к масштабу данных, была выполнена процедура стандартизации. С целью повышения эффективности моделей была проведена оптимизация гиперпараметров с использованием методов **Grid Search** и **Optuna**, при этом в качестве основного критерия оценки применялся показатель **F1-score**. Кроме того, к модели, продемонстрировавшей наилучшие результаты, были применены методы **SHAP** и **LIME**, что позволило провести интерпретацию прогнозов как на глобальном, так и на локальном уровнях.

Результаты исследования показали, что модель **Random Forest (RF)** продемонстрировала наилучшие показатели прогнозирования (**Accuracy = 0,78; F1 = 0,79**), за которой следовала модель **Support Vector Machines (SVM)** (**Accuracy = 0,76; F1 = 0,77**). В свою очередь, модели **Logistic Regression (LR)** и **XGBoost (XGB)** продемонстрировали сравнительно более низкую прогностическую эффективность. Несмотря на то что модели **RF** и **XGB** достигли чрезвычайно высоких результатов на обучающей выборке, снижение их эффективности на тестовой выборке свидетельствует о наличии эффекта **переобучения (overfitting)**. Кроме того, оптимизация гиперпараметров способствовала повышению эффективности всех исследуемых моделей, что подтверждает ключевую роль корректной настройки параметров в обеспечении высокой прогностической точности. Полученные результаты также свидетельствуют о том, что нелинейные модели значительно эффективнее отражают сложные взаимосвязи, присущие образовательным данным. Анализ, выполненный с использованием метода **SHAP**, показал, что наибольшее влияние на академическую успеваемость оказывают **уровень обучения, академическая вовлечённость, поддержка образовательной среды, саморегуляция и академическая мотивация**. Повышение уровня академической вовлечённости, мотивации и саморегуляции увеличивает вероятность достижения академической успешности, тогда как более высокий уровень обучения ассоциируется со снижением данной вероятности. Результаты анализа, полученные с применением методов **SHAP** и **LIME**, показали, что прогнозы моделей формируются не под воздействием одного отдельного фактора, а являются результатом комплексного взаимодействия множества переменных. Высокая степень согласованности результатов, полученных двумя

независимыми методами интерпретации, дополнительно подтверждает надёжность и устойчивость полученных выводов. В целом результаты исследования свидетельствуют о том, что академическая успеваемость определяется сложным взаимодействием индивидуального поведения, особенностей учебного процесса и характеристик образовательной среды.

Полученные результаты подтверждают, что **академическая успеваемость представляет собой многомерный конструкт**, который может быть эффективно смоделирован средствами методов машинного обучения. При этом методы **ансамблевого обучения (Ensemble Learning)**, прежде всего **Random Forest**, продемонстрировали наиболее высокую прогностическую эффективность среди исследованных алгоритмов. Кроме того, интеграция методов **объяснимого искусственного интеллекта (Explainable Artificial Intelligence, XAI)** существенно повышает интерпретируемость результатов прогнозирования, преодолевая одно из наиболее существенных ограничений традиционных моделей машинного обучения.

Результаты исследования свидетельствуют о том, что **академическая вовлечённость, мотивация и саморегуляция** являются ключевыми детерминантами академической успешности студентов. Следовательно, учреждения высшего образования могут разрабатывать и внедрять программы поддержки, направленные на развитие именно этих компетенций. Наряду с этим улучшение образовательной среды и социально-экономических условий студентов способно оказать существенное положительное влияние на повышение уровня их академической успеваемости.

Настоящее исследование имеет ряд методологических ограничений. Во-первых, используемый набор данных сформирован на основе информации, полученной лишь в одном высшем учебном заведении, и базируется преимущественно на самоотчётных данных респондентов, что ограничивает возможность широкого обобщения полученных результатов. Во-вторых, преобразование академической успеваемости в задачу бинарной классификации могло привести к снижению аналитической глубины исследования. Кроме того, агрегированные тематическим способом составные переменные не были подвергнуты всестороннему психометрическому анализу валидности и надёжности, что также следует рассматривать как существенное методологическое ограничение настоящего исследования. В связи с этим в дальнейших исследованиях целесообразно использовать более многочисленные и разнородные выборки, а также применять лонгитюдные исследовательские дизайны, позволяющие анализировать динамику академической успеваемости во времени.

Таким образом, интеграция методов **машинного обучения** с технологиями **объяснимого искусственного интеллекта (XAI)** формирует комплексную методологическую основу, которая позволяет не только с высокой точностью прогнозировать академическую успеваемость, но и раскрывать механизмы формирования соответствующих прогнозов. Следовательно, данный подход способен содействовать принятию более прозрачных, интерпретируемых и научно обоснованных решений в сфере образования.

Ключевые слова: машинное обучение; классификация; академическая успеваемость; объяснимый искусственный интеллект; SHAP; LIME.

संरचित सार:

शैक्षणिक उपलब्धि (Academic Achievement) को व्यापक रूप से शिक्षा की गुणवत्ता के एक प्रमुख संकेतक के रूप में स्वीकार किया जाता है, क्योंकि यह न केवल विद्यार्थियों के विकास स्तर को प्रतिबिंबित करती है, बल्कि उच्च शिक्षा संस्थानों की शैक्षिक प्रभावशीलता का भी एक महत्वपूर्ण मानदंड है। तथापि, शैक्षणिक उपलब्धि केवल संज्ञानात्मक क्षमताओं का परिणाम नहीं है, बल्कि यह व्यवहारिक, मनोवैज्ञानिक तथा पर्यावरणीय कारकों की जटिल अंतःक्रिया से निर्मित होने वाली बहुआयामी प्रक्रिया है। इस संदर्भ में, पारंपरिक सांख्यिकीय विधियाँ शिक्षा-संबंधी आँकड़ों की जटिल तथा गैर-रेखीय संरचना को पर्याप्त रूप से अभिव्यक्त करने में सीमित सिद्ध होती हैं। इसके विपरीत, **मशीन लर्निंग (Machine Learning, ML)** आधारित विधियाँ जटिल प्रतिरूपों (patterns) की पहचान करने तथा पूर्वानुमानात्मक क्षमता को बढ़ाने में अधिक प्रभावी सिद्ध हुई हैं। तथापि, शैक्षणिक उपलब्धि के पूर्वानुमान पर आधारित अधिकांश अध्ययन मुख्यतः मॉडल की भविष्यवाणी-सटीकता पर केंद्रित रहे हैं, जबकि भविष्यवाणियों के निर्माण-तंत्र की व्याख्या अपेक्षाकृत उपेक्षित रही है। शिक्षा के क्षेत्र में यह सीमा विशेष रूप से महत्वपूर्ण है, क्योंकि शैक्षिक निर्णय विद्यार्थियों तथा संस्थानों दोनों पर

दीर्घकालिक प्रभाव डालते हैं। इसी परिप्रेक्ष्य में, इस अध्ययन का उद्देश्य विश्वविद्यालय के विद्यार्थियों की शैक्षणिक उपलब्धि का पूर्वानुमान लगाने के लिए मशीन लर्निंग एल्गोरिद्मों का उपयोग करना तथा **व्याख्यायोग्य कृत्रिम बुद्धिमत्ता (Explainable Artificial Intelligence, XAI)** तकनीकों के माध्यम से इन पूर्वानुमानों की व्याख्या करना है। इस उद्देश्य की पूर्ति हेतु अध्ययन निम्नलिखित चार अनुसंधान प्रश्नों का समाधान प्रस्तुत करता है: (1) शैक्षणिक उपलब्धि के पूर्वानुमान में विभिन्न मशीन लर्निंग एल्गोरिद्मों का तुलनात्मक प्रदर्शन कैसा है? (2) हाइपरपैरामीटर अनुकूलन (Hyperparameter Optimization) मॉडल के प्रदर्शन को किस सीमा तक प्रभावित करता है? (3) कौन-से चर शैक्षणिक उपलब्धि पर सर्वाधिक प्रभाव डालते हैं? तथा (4) व्याख्यायोग्य कृत्रिम बुद्धिमत्ता की विधियाँ मशीन लर्निंग मॉडल के पूर्वानुमानों की व्याख्या एवं समझ को किस प्रकार सुदृढ़ करती हैं?

पूर्ववर्ती साहित्य में शैक्षणिक उपलब्धि को व्यापक रूप से एक **बहुआयामी संरचना (Multidimensional Construct)** के रूप में स्वीकार किया गया है, जो संज्ञानात्मक, व्यवहारिक, प्रेरणात्मक तथा पर्यावरणीय कारकों के संयुक्त प्रभाव से निर्मित होती है। अनेक अध्ययनों ने यह प्रदर्शित किया है कि **शैक्षणिक संलग्नता (Academic Engagement)**, **स्व-नियमन (Self-Regulation)**, **शैक्षणिक प्रेरणा (Academic Motivation)** तथा **पर्यावरणीय समर्थन (Environmental Support)** जैसे कारक विद्यार्थियों की शैक्षणिक सफलता के प्रमुख निर्धारक हैं। यद्यपि हाल के वर्षों में मशीन लर्निंग-आधारित अनुसंधानों की संख्या में उल्लेखनीय वृद्धि हुई है, फिर भी अधिकांश अध्ययन केवल पूर्वानुमान की सटीकता बढ़ाने तक सीमित रहे हैं तथा मॉडल के निर्णय-निर्माण की व्याख्या पर अपेक्षाकृत कम ध्यान दिया गया है। इस सीमा को सामान्यतः **"ब्लैक बॉक्स (Black Box) समस्या"** के रूप में जाना जाता है, जो शिक्षा क्षेत्र में मशीन लर्निंग मॉडलों की पारदर्शिता तथा व्यावहारिक उपयोगिता को सीमित करती है। इस समस्या के समाधान हेतु **व्याख्यायोग्य कृत्रिम बुद्धिमत्ता (XAI)** की विधियाँ, विशेषतः **SHAP (SHapley Additive exPlanations)** तथा **LIME (Local Interpretable Model-agnostic Explanations)**, वैश्विक (Global) एवं स्थानीय (Local) दोनों स्तरों पर मॉडल के निर्णयों की व्याख्या करने की क्षमता प्रदान करती हैं। ये विधियाँ न केवल उन चरों की पहचान करती हैं जो पूर्वानुमान को सर्वाधिक प्रभावित करते हैं, बल्कि यह भी स्पष्ट करती हैं कि प्रत्येक चर किस प्रकार अंतिम निर्णय में योगदान देता है। इस प्रकार, वर्तमान अध्ययन मशीन लर्निंग तथा व्याख्यायोग्य कृत्रिम बुद्धिमत्ता के समन्वित उपयोग के माध्यम से पूर्वानुमानात्मक प्रदर्शन एवं मॉडल की व्याख्यात्मकता के मध्य विद्यमान अनुसंधान-अंतर (Research Gap) को संबोधित करने का प्रयास करता है।

इस अध्ययन का डेटा **353 विश्वविद्यालयी विद्यार्थियों** से प्रश्नावली के माध्यम से संकलित किया गया। डेटासेट में जनसांख्यिकीय, शैक्षणिक, व्यवहारिक, डिजिटल तथा सामाजिक-आर्थिक चर सम्मिलित थे। अध्ययन में **सुविधाजनक नमूना चयन (Convenience Sampling)** विधि का उपयोग किया गया तथा प्रतिभागी एक ही संकाय से चयनित किए गए। प्रारम्भिक चरण में **38 चर** संकलित किए गए, जिन्हें विषयगत समेकन (Thematic Aggregation) की प्रक्रिया द्वारा **19 वैचारिक चरों (Conceptual Variables)** में रूपांतरित किया गया। तथापि, नाममात्र (Nominal) चरों पर **वन-हॉट एन्कोडिंग (One-Hot Encoding)** लागू किए जाने के पश्चात् मशीन लर्निंग मॉडलों में प्रयुक्त अंतिम विशेषताओं (Features) की संख्या बढ़कर **23** हो गई। आश्रित चर, अर्थात् **शैक्षणिक उपलब्धि (Grade Point Average, GPA)**, को **70** के कट-ऑफ मान के आधार पर द्विआधारी वर्गीकरण (Binary Classification) समस्या में परिवर्तित किया गया (सफल / असफल)। अध्ययन में **लॉजिस्टिक प्रतिगमन (Logistic Regression, LR)**, **रैंडम फ़ॉरेस्ट (Random Forest, RF)**, **सपोर्ट वेक्टर मशीन (Support Vector Machines, SVM)** तथा **XGBoost (XGB)** एल्गोरिद्मों का उपयोग किया गया। मॉडलों का मूल्यांकन **पाँच-गुणा क्रॉस-वैलिडेशन (5-fold Cross-Validation)** तथा **80% प्रशिक्षण-20% परीक्षण** डेटा-विभाजन पद्धति के माध्यम से किया गया। जिन मॉडलों की कार्यक्षमता डेटा के पैमाने पर निर्भर थी, उनके लिए मानकीकरण (Standardization) लागू किया गया। मॉडल के प्रदर्शन को और अधिक अनुकूल बनाने हेतु **Grid Search** तथा **Optuna** आधारित हाइपरपैरामीटर अनुकूलन विधियों का उपयोग किया गया, जबकि **F1-स्कोर (F1 Score)** को प्रमुख प्रदर्शन-मापक के रूप में अपनाया गया। इसके अतिरिक्त, सर्वाधिक सफल मॉडल पर **SHAP** तथा **LIME** तकनीकों का प्रयोग करके वैश्विक एवं स्थानीय दोनों स्तरों पर मॉडल की भविष्यवाणियों का विस्तृत व्याख्यात्मक विश्लेषण किया गया।

अध्ययन के परिणामों से स्पष्ट हुआ कि **रैंडम फ़ॉरेस्ट (Random Forest, RF)** मॉडल ने सर्वश्रेष्ठ पूर्वानुमानात्मक प्रदर्शन प्रदर्शित किया (**Accuracy = 0.78; F1 = 0.79**), जबकि इसके पश्चात् **सपोर्ट वेक्टर मशीन (Support Vector Machines, SVM)** मॉडल का स्थान रहा (**Accuracy = 0.76; F1 = 0.77**)। इसके विपरीत, **लॉजिस्टिक प्रतिगमन (Logistic Regression, LR)** तथा **XGBoost (XGB)** मॉडलों का प्रदर्शन तुलनात्मक रूप से निम्न पाया गया। यद्यपि **RF** तथा **XGB** मॉडलों ने प्रशिक्षण (Training) डेटा पर अत्यधिक उच्च प्रदर्शन प्रदर्शित किया, तथापि परीक्षण (Test) डेटा पर उनके प्रदर्शन में आई कमी ने **अतिअनुरूपण (Overfitting)** की उपस्थिति का संकेत दिया। इसके अतिरिक्त,

हाइपरपैरामीटर अनुकूलन ने सभी मॉडलों के प्रदर्शन में उल्लेखनीय सुधार किया, जिससे यह स्पष्ट हुआ कि मॉडल के उपयुक्त पैरामीटर विन्यास (Parameter Tuning) का पूर्वानुमानात्मक क्षमता को बढ़ाने में अत्यंत महत्वपूर्ण योगदान है। परिणामों से यह भी ज्ञात हुआ कि गैर-रेखीय (Non-linear) मॉडल, डेटा में निहित जटिल संबंधों को निरूपित करने में रेखिक मॉडलों की तुलना में अधिक प्रभावी हैं। SHAP विश्लेषण से यह निष्कर्ष प्राप्त हुआ कि **अध्ययन स्तर (Grade Level)**, **शैक्षणिक संलग्नता (Academic Engagement)**, **पर्यावरणीय समर्थन (Environmental Support)**, **स्व-नियमन (Self-Regulation)** तथा **शैक्षणिक प्रेरणा (Academic Motivation)** वे प्रमुख चर हैं, जिनका शैक्षणिक उपलब्धि पर सर्वाधिक प्रभाव पड़ता है। शैक्षणिक संलग्नता, प्रेरणा तथा स्व-नियमन में वृद्धि से विद्यार्थियों की शैक्षणिक सफलता की संभावना बढ़ती है, जबकि उच्च अध्ययन स्तर सफलता की संभावना में कमी के साथ संबद्ध पाया गया। SHAP तथा LIME दोनों विश्लेषणों ने यह प्रदर्शित किया कि मॉडल के पूर्वानुमान किसी एकल कारक पर आधारित नहीं होते, बल्कि अनेक चरों की पारस्परिक अंतःक्रिया का परिणाम होते हैं। दोनों व्याख्यात्मक विधियों से प्राप्त निष्कर्षों की उच्च स्तर की संगति अध्ययन के परिणामों की दृढ़ता एवं विश्वसनीयता को और अधिक सुदृढ़ करती है। समग्र रूप से, निष्कर्ष यह संकेत करते हैं कि शैक्षणिक उपलब्धि व्यक्तिगत व्यवहार, अधिगम प्रक्रियाओं तथा पर्यावरणीय परिस्थितियों की संयुक्त अंतःक्रिया से निर्मित होती है।

अध्ययन के निष्कर्ष यह प्रमाणित करते हैं कि **शैक्षणिक उपलब्धि एक बहुआयामी संरचना (Multidimensional Construct)** है, जिसका प्रभावी मॉडलन मशीन लर्निंग तकनीकों के माध्यम से किया जा सकता है। विशेष रूप से, **समष्टिगत अधिगम (Ensemble Learning)** पर आधारित विधियाँ, विशेषकर **रैंडम फ़ॉरेस्ट (Random Forest)**, परीक्षण किए गए अन्य एल्गोरिथ्मों की तुलना में श्रेष्ठ प्रदर्शन प्रदर्शित करती हैं। साथ ही, **व्याख्यायोग्य कृत्रिम बुद्धिमत्ता (Explainable Artificial Intelligence, XAI)** की विधियों का समावेशन मॉडल की व्याख्यात्मकता को उल्लेखनीय रूप से बढ़ाता है तथा पारंपरिक मशीन लर्निंग दृष्टिकोणों की प्रमुख सीमाओं में से एक को प्रभावी रूप से कम करता है।

अध्ययन के परिणामों से यह भी स्पष्ट हुआ कि **शैक्षणिक संलग्नता, प्रेरणा तथा स्व-नियमन** विद्यार्थियों की शैक्षणिक सफलता के सर्वाधिक महत्वपूर्ण निर्धारक हैं। अतः उच्च शिक्षा संस्थान इन आयामों को सुदृढ़ करने के उद्देश्य से लक्षित समर्थन कार्यक्रमों (Support Programs) का विकास एवं कार्यान्वयन कर सकते हैं। इसी प्रकार, विद्यार्थियों के पर्यावरणीय एवं सामाजिक-आर्थिक संसाधनों में सुधार भी उनकी शैक्षणिक उपलब्धि को उल्लेखनीय रूप से उन्नत कर सकता है।

वर्तमान अध्ययन की कुछ महत्वपूर्ण सीमाएँ भी हैं। प्रथम, प्रयुक्त डेटासेट केवल एक ही उच्च शिक्षा संस्थान से संकलित किया गया तथा यह मुख्यतः स्व-रिपोर्ट (Self-reported) आँकड़ों पर आधारित था; अतः परिणामों की सार्वभौमिकता (Generalizability) सीमित हो सकती है। द्वितीय, शैक्षणिक उपलब्धि को द्विआधारी वर्गीकरण समस्या में परिवर्तित करने से विश्लेषण की गहनता पर प्रतिकूल प्रभाव पड़ा हो सकता है। इसके अतिरिक्त, विषयगत समेकन द्वारा निर्मित संयुक्त चरों (Composite Variables) पर व्यापक मनोमितीय (Psychometric) वैधता एवं विश्वसनीयता विश्लेषण नहीं किया गया, जिसे इस अध्ययन की एक महत्वपूर्ण पद्धतिगत सीमा के रूप में स्वीकार किया जाना चाहिए। भविष्य के अध्ययनों में अधिक बड़े एवं विविधतापूर्ण नमूनों के साथ-साथ अनुदैर्ध्य (Longitudinal) अनुसंधान अभिकल्पों का उपयोग किया जाना चाहिए, ताकि समय के साथ शैक्षणिक उपलब्धि में होने वाले परिवर्तनों का अधिक व्यापक विश्लेषण किया जा सके।

अंततः, **मशीन लर्निंग तथा व्याख्यायोग्य कृत्रिम बुद्धिमत्ता (XAI)** का एकीकृत उपयोग ऐसा समग्र पद्धतिगत ढाँचा प्रस्तुत करता है, जो न केवल उच्च सटीकता के साथ शैक्षणिक उपलब्धि का पूर्वानुमान लगाने में सक्षम है, बल्कि उन अंतर्निहित तंत्रों की भी व्याख्या करता है जिनके आधार पर ये पूर्वानुमान निर्मित होते हैं। इस प्रकार, यह दृष्टिकोण शिक्षा के क्षेत्र में अधिक पारदर्शी, व्याख्यायोग्य तथा साक्ष्य-आधारित निर्णय-निर्माण प्रक्रियाओं को सुदृढ़ करने में महत्वपूर्ण योगदान प्रदान करता है।

कुंजी शब्द: मशीन लर्निंग; वर्गीकरण; शैक्षणिक उपलब्धि; व्याख्यायोग्य कृत्रिम बुद्धिमत्ता; SHAP; LIME.

Yapılandırılmış Özet:

Akademik başarı hem öğrenci gelişimini hem de kurumsal etkililiği yansıtan eğitim kalitesinin temel bir göstergesi olarak yaygın biçimde kabul edilmektedir. Ancak akademik başarı yalnızca bilişsel yetenekler tarafından belirlenmemekte; aksine davranışsal, psikolojik ve çevresel faktörlerin etkileşimi sonucunda ortaya

çıkılmaktadır. Geleneksel istatistiksel yaklaşımlar, eğitim verilerinin karmaşık ve doğrusal olmayan yapısını modellemede yetersiz kalabilmektedir. Bu bağlamda, makine öğrenmesi (ML) yaklaşımları karmaşık örüntülerin belirlenmesi ve tahmin performansının artırılması için etkili araçlar sunmaktadır. Bununla birlikte, akademik başarı tahminine odaklanan birçok çalışma, model tahminlerinin nasıl oluştuğuna ilişkin sınırlı açıklama sunarken öncelikli olarak model doğruluğunu vurgulamaktadır. Bu sınırlılık, karar verme süreçlerinin önemli sonuçlar doğurabileceği eğitim ortamlarında özellikle önemlidir. Bu nedenle, bu çalışmanın amacı üniversite öğrencilerinin akademik başarısını makine öğrenmesi algoritmaları kullanarak tahmin etmek ve model tahminlerini açıklanabilir yapay zekâ (XAI) yöntemleri aracılığıyla yorumlamaktır. Bu doğrultuda çalışma aşağıdaki araştırma sorularını ele almaktadır: (i) Farklı ML algoritmaları akademik başarıyı tahmin etmede nasıl performans göstermektedir? (ii) Hiperparametre optimizasyonu model performansını ne ölçüde etkilemektedir? (iii) Akademik başarıyı etkileyen en önemli değişkenler nelerdir? ve (iv) XAI yöntemleri model tahminlerinin yorumlanmasına nasıl katkı sağlamaktadır?

Akademik başarı, bilişsel, davranışsal, motivasyonel ve çevresel faktörlerden etkilenen çok boyutlu bir yapı olarak yaygın biçimde kabul edilmektedir. Literatür, akademik katılım, öz-düzenleme, motivasyon ve çevresel destek gibi değişkenlerin öğrenci başarısı üzerinde anlamlı etkileri olduğunu ortaya koymuştur. Makine öğrenmesi temelli çalışmaların sayısı artmış olsa da, bu çalışmalar öncelikli olarak tahmin doğruluğunu artırmaya odaklanmış ve model tahminlerinin nasıl üretildiğini yeterince açıklamamıştır. Bu durum, genellikle “kara kutu” problemi olarak adlandırılmakta ve bu tür modellerin eğitim uygulamalarındaki şeffaflığını ve pratik uygulanabilirliğini sınırlamaktadır. SHAP (SHapley Additive exPlanations) ve LIME (Local Interpretable Model-agnostic Explanations) gibi açıklanabilir yapay zekâ yöntemleri, model tahminlerine hem küresel hem de yerel açıklamalar sunarak bu sınırlılığı gidermeyi amaçlamaktadır. Bu yaklaşımlar yalnızca hangi değişkenlerin önemli olduğunu belirlemekle kalmaz, aynı zamanda bu değişkenlerin tahminleri nasıl etkilediğini de ortaya koyar. Bu çalışma, makine öğrenmesi ve açıklanabilir yapay zekâ yöntemlerini bütünleştirerek literatürde hem performans hem de yorumlanabilirlik açısından var olan boşluğu doldurmayı amaçlamaktadır.

Çalışma, 353 üniversite öğrencisinden anket yoluyla toplanan verilere dayanmaktadır. Veri seti demografik, akademik, davranışsal, dijital ve sosyo-ekonomik değişkenleri içermektedir. Örneklem, kolayda örnekleme yöntemiyle belirlenmiş olup tek bir fakültede öğrenim gören öğrencilerden oluşmaktadır. Başlangıçta 38 değişken toplanmış, daha sonra tematik birleştirme yoluyla 19 kavramsal değişkene indirgenmiştir. Ancak nominal değişkenlere uygulanan one-hot encoding işlemleri sonrasında, makine öğrenmesi modellerine dâhil edilen nihai öznitelik sayısı 23’e yükselmiştir. Bağımlı değişken olan akademik başarı (GNO), 70 eşik değeri kullanılarak ikili sınıflandırma problemine dönüştürülmüştür (akademik olarak başarılı/akademik olarak başarısız). Çalışmada Lojistik Regresyon (LR), Random Forest (RF), Destek Vektör Makineleri (DVM) ve XGBoost (XGB) algoritmaları kullanılmıştır. Model performansı, 5 katlı çapraz doğrulama ve %80/%20 eğitim-test ayrımı kullanılarak değerlendirilmiştir. Ölçek duyarlı modellere standardizasyon uygulanmıştır. Model performansını artırmak amacıyla Grid Search ve Optuna kullanılarak hiperparametre optimizasyonu gerçekleştirilmiş ve temel değerlendirme metriği olarak F1 skoru kullanılmıştır. Ayrıca, model tahminlerini hem küresel hem de yerel düzeyde analiz etmek amacıyla en iyi performans gösteren modele SHAP ve LIME yöntemleri uygulanmıştır.

Bulgular, RF modelinin en yüksek performansı elde ettiğini göstermektedir (Doğruluk = 0.78, F1 = 0.79). Bunu DVM modeli izlemiştir (Doğruluk = 0.76, F1 = 0.77). LR ve XGB modelleri ise daha düşük tahmin performansı sergilemiştir. RF ve XGB modelleri eğitim verisi üzerinde oldukça yüksek performans göstermiş olsa da test performansındaki düşüş aşırı öğrenmenin varlığına işaret etmektedir. Hiperparametre optimizasyonu tüm modellerin performansını artırmış ve model ayarlarının önemini ortaya koymuştur. Ayrıca, doğrusal olmayan modellerin veri setinde yer alan karmaşık ilişkileri yakalamada daha başarılı olduğu görülmüştür. SHAP analizleri, akademik başarıyı etkileyen en önemli değişkenlerin sınıf düzeyi, akademik katılım, çevresel destek, öz-düzenleme ve akademik motivasyon olduğunu ortaya koymuştur. Akademik katılım, motivasyon ve öz-düzenleme arttıkça başarı olasılığı da artarken, daha yüksek sınıf düzeyleri başarı olasılığındaki azalma ile ilişkilendirilmiştir. SHAP ve LIME analizleri, model tahminlerinin tek bir faktörden ziyade birden fazla değişkenin etkileşimiyle şekillendiğini göstermiştir. İki yöntem arasındaki tutarlılık, bulguların güvenilirliğini desteklemektedir. Genel olarak sonuçlar, akademik başarının bireysel davranışlar, öğrenme süreçleri ve çevresel koşulların birleşimiyle şekillendiğini göstermektedir.

Bu çalışmanın bulguları, akademik başarının makine öğrenmesi yöntemleri kullanılarak etkili biçimde modellenebilen çok boyutlu bir yapı olduğunu göstermektedir. Özellikle Random Forest gibi topluluk öğrenmesi yöntemlerinin üstün performans sergilediği belirlenmiştir. Ayrıca, açıklanabilir yapay zekâ yöntemlerinin kullanımı model tahminlerinin yorumlanabilirliğini artırmakta ve böylece geleneksel makine öğrenmesi yaklaşımlarıyla ilişkili bazı sınırlılıkları gidermektedir.

Bulgular, akademik katılım, motivasyon ve öz-düzenlemenin öğrenci başarısının temel belirleyicileri olduğunu göstermektedir. Bu doğrultuda, eğitim kurumları bu alanları hedefleyen destekleyici programlar geliştirmeyi değerlendirebilir. Ayrıca, öğrencilerin çevresel ve sosyo-ekonomik koşullarının iyileştirilmesi akademik çıktıların geliştirilmesine katkı sağlayabilir.

Çalışmanın çeşitli sınırlılıkları bulunmaktadır. Veri seti tek bir kurumla sınırlıdır ve öz-bildirime dayalı verilerden oluşmaktadır; bu durum bulguların genellenebilirliğini sınırlayabilir. Ayrıca, akademik başarının ikili sınıflandırma problemine dönüştürülmesi analiz derinliğini sınırlandırabilir. Bunun yanı sıra, tematik bileşik değişkenler için kapsamlı psikometrik geçerlik ve güvenilirlik analizleri yapılmamıştır; bu durum çalışmanın önemli bir metodolojik sınırlılığı olarak değerlendirilmelidir. Gelecek araştırmalarda, akademik başarının zaman içerisindeki değişimini incelemek için daha büyük ve daha çeşitli örneklemeler ile boylamsal veriler dikkate alınmalıdır.

Sonuç olarak, makine öğrenmesi ve açıklanabilir yapay zekânın bütünleştirilmesi, akademik başarının hem tahmin edilmesi hem de anlaşılması için kapsamlı bir yaklaşım sunmakta; böylece eğitimde daha şeffaf ve veri odaklı karar verme süreçlerine katkı sağlamaktadır.

Anahtar Kelimeler: Makine öğrenmesi, sınıflandırma, akademik başarı, açıklanabilir yapay zekâ, SHAP, LIME.

www.turkishstudies.net/turkishstudies**Turkish Studies**

eISSN: 1308-2140

**ANKARA SCIENCE
UNIVERSITY**

Prediction of University Students' Academic Achievement Using Machine Learning: An Explainable Artificial Intelligence Based Analysis

Introduction

Academic achievement is a critical measure that reflects the quality of the education system, student development, and institutional effectiveness, serving as one of the key performance indicators for educational institutions. In measuring academic achievement, general achievement test scores or overall grade point averages are typically considered. However, academic achievement is not limited to cognitive factors alone; it possesses a multidimensional structure shaped by the interaction of psychological and social variables (Karaağaç Cingöz et al., 2025). Therefore, a comprehensive analysis of the factors influencing academic achievement is of critical importance for educators and policymakers.

While traditional statistical methods are effective in explaining linear relationships between variables, they may be limited in modeling the multidimensional and nonlinear structure of today's educational data (Kyriazos & Poga, 2024). Nonlinear relationships play a critical role in understanding social behaviors and psychological processes. In this context, machine learning algorithms can uncover complex patterns within the data and provide high-accuracy predictions (Przybyś-Mańczak et al., 2023). In particular, machine learning algorithms such as Logistic Regression (LR), Random Forest (RF), Support Vector Machines (SVM), and XGBoost (XGB) are among the powerful methods widely used in academic achievement prediction studies.

In recent years, artificial intelligence applications have begun to be used in many different fields, such as education, healthcare, and agriculture (Sönmez & Zengin, 2023; Yıldız, 2025). Machine learning, a subfield of artificial intelligence, offers significant advantages in data-driven prediction processes. Accordingly, machine learning algorithms are widely used in the field of academic achievement prediction due to their ability to learn patterns from complex and multidimensional data structures and create predictive models (Guanin-Fajardo et al., 2024; Hashim et al., 2020; Metin, 2025; Nayak et al., 2023; Özdemir et al., 2026; Yağcı, 2022). Although there are numerous machine learning-based studies on academic achievement prediction in the literature, a significant portion of these studies focus on model performance and do not sufficiently explain how model decisions are formed. Indeed, a review study conducted by Boujmiraz et al. (2026), which comprehensively examined approaches used in predicting student academic achievement, indicates that only 14% of studies using black-box models incorporated Explainable Artificial Intelligence (XAI) techniques. This highlights the limited scope of interpretability. However, in high-stakes decision-making processes such as education, it is not enough to simply produce accurate predictions; understanding the factors underlying these predictions is also of great importance. This requirement has heightened the importance of XAI methods. Methods such as SHapley Additive exPlanations (SHAP) and Local Interpretable Model-agnostic Explanations (LIME) fill a significant gap in this field by enabling the interpretation of model decisions at both the global and local levels.

However, there are also studies in which XAI methods have been integrated into the modeling process for predicting academic achievement (Ahmed et al., 2025; Guevara-Reyes et al., 2025; Paul et al., 2025). These studies primarily model academic achievement through groups of variables at the academic, structural, and system levels. This study, however, aims to contribute methodologically and practically to the literature by analyzing the performance of machine learning models within a holistic framework using XAI methods, based on a unique survey-based dataset that encompasses demographic, behavioral, academic, and environmental factors influencing academic achievement. Additionally, a feature engineering process was applied to the data obtained through the survey, and variables were grouped under thematic dimensions to create a dataset for modeling. The academic achievement variable was adapted for classification problems, and students were categorized into two groups: "successful" and "unsuccessful."

One of the key contributions of this study is its focus on the interpretability of model results. XAI refers to a set of methods and approaches aimed at making the decisions of machine learning models understandable and interpretable by humans. In this study, the SHAP and LIME methods-two XAI methods-were employed. In this context, while the SHAP method was used to analyze the global and local effects of variables on the model, the LIME method was used to examine how individual predictions are formed at the local level. This approach allows the findings regarding academic achievement predictions to be evaluated not only in terms of performance but also in terms of interpretability.

In conclusion, the complex structure of the multidimensional factors influencing academic achievement makes it difficult to predict this success accurately and generalizably, as well as to understand the model's decisions. This study aims to produce high-performance predictions and reveal the underlying decision mechanisms of these predictions by addressing machine learning and XAI methods within a holistic framework using a unique dataset. In this regard, the study offers a comprehensive approach to the academic achievement prediction literature that addresses both performance and interpretability¹.

In line with this primary objective, we sought to answer the following sub-research questions regarding model performance and the interpretability of model decisions in the context of predicting academic achievement:

- How do different machine learning algorithms perform in predicting the academic achievement of university students?
- To what extent does hyperparameter optimization affect model performance?
- What are the most significant variables influencing academic achievement?
- How do XAI methods (SHAP and LIME) contribute to the interpretation of model decisions?

¹ Yapay zekâ ve üretken yapay zekâ uygulamalarının sosyal bilimler, eğitim, dil ve edebiyat, din bilimleri, iletişim, ekonomi ve diğer akademik disiplinlerde kullanımı; araştırma, veri analizi, içerik üretimi, öğretim ve öğrenme süreçlerine etkileri ile yapay zekânın sunduğu imkânlar, sınırlılıklar ve etik sorunları farklı açılardan ele alan örnek çalışmalar için ayrıca bk. Denizci et al. 2018, Baran 2022, Keleş & Keleş, 2018; Karadağ, 2025; Coşkun, 2025; Ahmed & Hamod, 2026; Arıcı & Karacı, 2013; Keleş & Keleş, 2017; Keleş et al., 2017; Bekil, 2018; Keleş, 2018; Serçemeli, 2018; Akyıldız & Akyıldız, 2020; Işık & Darı, 2023; Abdulrazagova et al., 2025; Arğın 2025; Tetik Küçükkelçi, 2025; Çakmak, 2025; Yıldırım Altun, 2025; Zın & Zın, 2025; Mazlum & Mazlum, 2025; Yıldız, 2025; Başar, 2025; Tuğcu, 2025; Özdemir, 2026; Çora et al., 2026; Büyükboyacı & Yozcu, 2026; Ardaturk, 2026; Arduç Kara, 2026; Ertan, 2026; Ahmed & Hamod, 2026; Efendioğlu, 2023; Çelik et al., 2025; Doğru & Hacımüftüoğlu, 2025; Koçakoğlu & Koçakoğlu, 2025; Ekinci, 2025; Sakin & Türk, 2025; Aşkun, 2024; Yener & Köse, 2023; Romya Bilgin & Küçükşabanoglu, 2023; Çark, 2020; Kanat, 2020; Altındış, 2020; Zenginaloğlu, 2026; Dalmış, 2026; Ölçer, 2025; Sarıbaş, 2025; Karakuş et al., 2025; Güzel, 2024; Kızıldağ, 2023; Odacıoğlu, 2022, Erdem-Demiryakan 2025, 2026, Civelek 2025, Günay 2025, Önen 2025, Özdemir 2025; Sandıkcı & Soy 2026; Arduç Kara 2026; Ertan 2026; Uygun 2026; Yılmaz 2025; Kan Çelik 2026; Bayat Arslan & Cuma 2026; Köksal & Zorlu Kale 2025; Varol 2025; Ahmed & Hamod 2026; Efendioğlu 2023; Sert 2026; Güçlütin 2026.

Method

Research Model

This study aims to predict the academic achievement of university students using machine learning methods and to interpret model decisions using XAI methods. The research model consists of data collection, feature engineering, model development, hyperparameter optimization, and explainability analysis.

As part of the study, features were first created based on the raw data obtained through the survey method. Conceptually similar variables were grouped under thematic dimensions to derive new variables.

In the first stage of the modeling process, models were evaluated using default parameters to assess the performance of machine learning algorithms, and five-fold cross-validation was applied to the dataset. This method reduces the risk of overfitting by dividing the dataset into different subsets and training and testing the model on each subset, thereby providing a more balanced measure of performance. This stage was conducted to determine the models' baseline performance levels and generalization tendencies on the dataset.

In the next step, the dataset was split into an 80% training set and a 20% test set to evaluate the models' performance more realistically. While the training dataset was used during the model's learning process, the test dataset was used to measure the model's performance on data it had not previously seen. Model performance was evaluated using 5-fold cross-validation during the training process. Final model performance results were reported on the independent test dataset. This approach is important for assessing the model's generalizability and reducing the risk of overfitting.

Subsequently, hyperparameter optimization was applied to improve model performance. In this context, the most suitable hyperparameter combinations for each model were determined using Grid Search and Optuna methods. The model yielding the highest performance was selected by comparing the results obtained during the optimization process.

In the final stage, XAI methods were applied to the selected model. In this context, the SHAP method was used to analyze the variable importance of the model at both the global and local levels, while the LIME method was used to examine how individual predictions are formed at the local level. In this way, not only the model's predictive performance but also its decision-making mechanism was comprehensively evaluated. The research model developed as part of this process is presented in Figure 1.




Figure 1. Research Model

In this study, data preprocessing, modeling, and analysis were performed using the Python programming language. The scikit-learn library was used to develop machine learning models, GridSearchCV and Optuna for hyperparameter optimization, XGBoost for XGBoost modeling, and the SHAP and LIME libraries for XAI analyses.

Dataset and Working Group

The dataset used in this study was obtained through a survey of university students and includes observations from a total of 353 participants. The study sample was selected using convenience sampling from among students enrolled at the Gerede Faculty of Applied Sciences at Bolu Abant İzzet Baysal University, due to the researcher's ease of access. Convenience sampling is a sampling method in which the researcher selects individuals who are the easiest to reach, most accessible, and readily available as the sample (Cohen et al., 2018). During the data collection process, a multidimensional structure encompassing students' demographic, academic, behavioral, digital, and socioeconomic characteristics was adopted. In this context, a dataset was created using data obtained through a 38-item questionnaire prepared by the researcher. The dataset includes demographic variables such as department, age, gender, grade level, parental education status, and type of residence, as well as variables reflecting behavioral and psychosocial characteristics related to students' academic processes. The variables included in the dataset were determined based on the findings of previous studies examining factors that influence academic achievement, such as motivation, self-regulation, academic engagement, study habits, parental education, and socioeconomic/environmental support (Credé & Kuncel, 2008; Fan & Chen, 2001; Richardson et al., 2012; Sirin, 2005; Tao et al., 2022). In constructing the thematic structures, conceptual frameworks shown in the literature to be associated with academic achievement were taken into account. Items representing similar behavioral, motivational, and environmental characteristics were grouped under the same theme. However, comprehensive validity and reliability analyses to assess the psychometric properties of these thematic structures were not conducted within the scope of this study. This should be considered one of the methodological limitations of the study regarding the validity and internal consistency of the composite variables created. Furthermore, the fact that the sample was limited to

a specific faculty at a single university and the use of convenience sampling should be regarded as a significant methodological constraint limiting the generalizability of the findings. The thematic structure and coded variables are presented in Table 1. New variables were created by calculating the arithmetic mean of the relevant items for each theme.

Table 1. Thematic Classification and Coding of Variables Affecting University Students' Academic Achievement

Theme	Coded Variable Name	Items (Observed Variables)
Academic Achievement	gno	Student's Grade Point Average (Grades of 70 and above are classified as passing; below 70 as failing)
Demographic Characteristics	department_1	Finance and Banking Department
	department_2	Marketing Department
	department_3	International Trade and Logistics Department
	age	Student's age
	gender	Student's gender
	grade_level	Student's grade level
	mother_education	Mother's education level
	father_education	Father's education level
	residence_type_1	Student lives at home
Self-Regulation	residence_type_2	Student lives in a dormitory
	residence_type_3	Student lives in other accommodations
	self_regulated_learning	I follow a regular weekly study schedule
		I review my lessons regularly
		I prepare for exams systematically.
		I can maintain my focus while studying.
		I review the material before class.
		I use my time effectively
		Academic progress is important to me.
Academic Motivation	academic_motivation	I believe what I learn is valuable for my future.
		I work toward my goals.
		I believe I can succeed when I put in the effort.
		I can find solutions when I face challenges.
		I ask for help with topics I don't understand.
		I use various resources to learn.
		I actively participate in class.
		Group work supports my learning.
		I attend classes regularly.
Active Learning Behaviors	active_learning	I come to class prepared.
		I can manage my academic stress.
		I feel balanced during exam periods.
		I get enough sleep.
		I use artificial intelligence tools in my learning process.
		I can easily access the digital tools needed for studying.
		My living conditions support my studying.
		My financial situation is sufficient to sustain my education.
		My transportation conditions support my class schedule.
Academic Engagement	academic_engagement	My study environment is suitable for productive studying.
		Weekly study time outside of class (hours).
Academic Well-Being	academic_wellbeing	
Digital Learning Access	digital_learning_access	
Environmental and Socioeconomic Support	environmental_support	
Academic Workload	study_effort	

Screen Time	screen_time	Weekly library/study hall usage time (hours).
Sleep Duration	sleep_duration	Daily screen time (hours).
Social Engagement	social_participation	Daily sleep duration (hours).
		I participate in social activities on campus.

As a result of feature engineering, the number of variables, initially observed as 38, was reduced through the use of thematic composite variables, resulting in a dataset consisting of a total of 19 variables, including the target variable (GNO). This number represents the number of conceptual variables. During the modeling process, the variables “department” and “residence_type,” which have a nominal structure, were converted using the one-hot encoding method, increasing the final number of features fed into the machine learning models to 23.

In this study, GPA, which represents students' academic achievement levels, was used as the dependent variable. However, to ensure compatibility with machine learning classification models, this variable was converted into a binary class. When determining the threshold value, the GPA average of the dataset (68.80) was taken into account, and it was decided to round this value to 70, which is the nearest whole number corresponding to the grading thresholds commonly used in educational systems. Thus, the target variable exhibited a balanced distribution, and the determined threshold value was established as both a reference point based on the data distribution and a meaningful success threshold in educational applications. Accordingly, students were classified as “successful” ($GPA \geq 70$) and “unsuccessful” ($GPA < 70$). This transformation ensured that a continuous variable was made suitable for classification problems. Additionally, given the relatively limited size of the dataset ($n=353$) and its survey-based structure, regression models for estimating continuous variables carry a higher risk of producing greater variance. Therefore, a classification approach was preferred to enhance the model's generalizability and achieve more balanced performance.

As a result, a dataset was created that holistically incorporates demographic, behavioral, and environmental dimensions, is thematically structured, includes a feature engineering process, and has been prepared for use with machine learning models.

Additionally, the necessary ethics committee approval for the survey used in this study was granted by the Social Sciences and Human Research Ethics Committee of Bolu Abant İzzet Baysal University at its meeting numbered 2026/03, and the application was deemed ethically appropriate (Protocol No: 2026/212). During the data collection process, participants were informed on a voluntary basis; no personal identification information was collected, and all data were anonymized. The data obtained were used solely for scientific research purposes.

Data Preprocessing Process

In order for machine learning models to produce accurate and reliable results, the dataset must be properly prepared prior to analysis. Accordingly, the dataset used in this study underwent a data preprocessing process.

Since some of the machine learning algorithms used in the study (e.g., SVM and LR) are sensitive to variable scales, a standardization process was applied to the dataset. In this context, the variables were scaled so that their mean is 0 and their standard deviation is 1. The scaling process was learned solely on the training data, and the same transformation parameters were applied to the test data.

As part of the data preprocessing process, the target variable was also appropriately encoded to prepare it for the model. The “failed” and “successful” classes of the target variable were represented as 0 and 1, respectively. The nominal variables “department” and “residence_type” were represented using one-hot encoding to prevent the creation of an artificial ordering relationship between categories. While the binary gender variable was included in the model using binary coding,

ordinal coding was preferred for the grade level, mother's education level, and father's education level variables-which contain a natural order-to preserve the sequential structure among categories. The other continuous variables were directly included in the model while preserving their existing numerical structures.

Machine Learning Models

In this study, four machine learning algorithms representing different modeling approaches were used to predict students' academic achievement. The models used are described below.

LR is primarily used to estimate the probability that a data sample belongs to a specific class. Its most common application is in "binary classification" problems, where the outcome is one of two possible states (Géron, 2019).

RF is an effective ensemble learning method that performs well in both regression and classification problems by combining a large number of decision trees into a collective structure (Breiman, 2001). The algorithm generates a large number of decision trees through bootstrap sampling (bagging) and random feature selection mechanisms. By combining the outputs of these trees, a model is obtained that offers higher accuracy and stronger generalization capabilities compared to a single decision tree.

SVM is a highly flexible and effective machine learning algorithm that can be used for both linear and nonlinear classification, regression, and outlier detection tasks. It stands out particularly for its high performance on small or medium-sized datasets with high complexity (Géron, 2019).

XGB is an optimized, widely used, and high-performance implementation of the Gradient Boosting algorithm, which is frequently employed in machine learning (Géron, 2019; Raschka et al., 2022).

The combined use of these algorithms has enabled a comprehensive analysis of both linear and nonlinear relationships and has made it possible to comparatively evaluate the factors influencing academic achievement from different modeling perspectives.

Hyperparameter Optimization

The performance of machine learning models depends not only on the algorithm used but also on the proper selection of the algorithms' hyperparameters. Hyperparameters are parameters that are not learned during the model training process but directly influence the model's behavior. Therefore, identifying appropriate hyperparameter combinations can significantly improve model performance.

In this study, two different methods-Grid Search and Optuna-were used together to optimize the hyperparameters of the machine learning algorithms employed.

The Grid Search method is a deterministic optimization approach that systematically evaluates all possible combinations within a predefined hyperparameter search space. In this method, each parameter combination is tested using a cross-validation process, and the set of parameters that yields the highest performance is selected. While the Grid Search method provides reliable results by covering the entire search space, its high computational cost-particularly when the number of parameters and their ranges are extensive-is considered a significant limitation.

Optuna is a modern, adaptive search algorithm developed for hyperparameter optimization. Similar to the Bayesian optimization approach, this method uses results from previous trials to select more promising hyperparameter combinations for subsequent trials. This makes the search process more efficient and enables better results to be obtained in a shorter time. One of Optuna's key advantages is its ability to reduce computational costs by minimizing unnecessary trials during the search process and enabling more effective exploration across large parameter spaces.

During the hyperparameter optimization process, the dataset was split into 80% training and 20% test data while preserving the class distribution ($\text{stratify} = y$). A 5-fold stratified K-fold cross-validation structure was used for all models ($n_splits = 5$, $\text{shuffle} = \text{True}$, $\text{random_state} = 42$), and the F1 score was used as the evaluation metric in hyperparameter optimization. In the Grid Search process, predefined parameter ranges were used for each model, while in the Optuna optimization, 15 trials ($n_trials = 15$) were conducted for each model. To ensure reproducibility in the study, the value $\text{random_state} = 42$ was used in the data splitting and modeling processes. In the final model selection, the model that achieved a higher F1 score on the test dataset was chosen between the Grid Search and Optuna methods. The hyperparameter ranges used in the hyperparameter optimization process are presented in Table 2.

Table 2. Hyperparameter Ranges Used in Grid Search and Optuna Processes

Model	Optimization Method	Hyperparameter	Range / Values
LR	Grid Search	C	[0.01, 0.1, 1, 10]
		class_weight	[None, balanced]
	Optuna	C	0.01-10 (logarithmic)
		class_weight	[None, balanced]
RF	Grid Search	n_estimators	[200, 300]
		max_depth	[None, 5, 10]
	Optuna	n_estimators	100-500
		max_depth	3-15
SVM	Grid Search	C	[0.1, 1, 10]
		kernel	[rbf, linear]
	Optuna	C	0.1-10 (logarithmic)
		kernel	[rbf, linear]
XGB	Grid Search	n_estimators	[200, 300]
		max_depth	[3, 5, 7]
		learning_rate	[0.01, 0.05, 0.1]
	Optuna	n_estimators	100-500
		max_depth	3-9
		learning_rate	0.01-0.20

Model Performance Metrics

The performance of the machine learning models developed in this study was analyzed using multiple evaluation metrics commonly employed in the literature for classification problems. Since evaluating model performance based on a single metric can lead to misleading results, multiple performance metrics that measure different aspects were considered together.

In this context, model performance was evaluated using accuracy, precision, recall, F1 score, and ROC-AUC (Receiver Operating Characteristic-Area Under Curve) metrics. Additionally, confusion matrices were examined for each model to analyze the distribution of correct and incorrect classifications.

Accuracy represents the proportion of correct classifications among the total observations. However, since it may not be a sufficient metric on its own when the class distribution is imbalanced, it was evaluated in conjunction with other metrics.

Precision indicates the proportion of students who are actually successful among those the model predicts as “successful.” This metric is important for reducing false positive errors.

Recall indicates the proportion of students who are actually successful that the model correctly identifies. This metric is of critical importance, particularly in ensuring that students with high potential for success are not overlooked.

The F1 score is the harmonic mean of precision and recall values and serves as an important metric for evaluating the model's overall performance in a balanced manner. In this study, the F1 score was used as the primary evaluation metric during the hyperparameter optimization process.

The ROC-AUC metric measures the model's ability to distinguish between classes at different threshold values.

The confusion matrix, on the other hand, provides a detailed view of the model's correct and incorrect classifications; it enables the analysis of the distribution of model errors through true positive, true negative, false positive, and false negative values.

Explainable Artificial Intelligence Analysis

In this study, the goal was not only to develop a machine learning model but also to ensure that the model's decision-making mechanisms are understandable and interpretable. To this end, XAI methods were applied to the model that delivered the highest performance. XAI refers to approaches that explain models' decision-making processes, highlight their strengths and weaknesses, and provide predictions regarding their future behavior (Gunning & Aha, 2019). In this study, two different approaches were used together to ensure the model's explainability: SHAP and LIME. These methods enable the analysis of model decisions at both the global and local levels.

The SHAP method calculates the contribution of each variable to the model output by using the Shapley values approach, which is based on game theory. This method enables model decisions to be interpreted transparently by fairly distributing the effect of each feature on the prediction (Mane et al., 2024). In this study, SHAP analysis was performed at two levels:

Global Explanation: The overall behavior of the model was analyzed to determine which variables were more influential on academic achievement. In this analysis, the mean absolute SHAP value of each variable was calculated, and a feature importance ranking was obtained.

Local Explanation: The predictions made by the model were analyzed based on individual observations. Thus, it was revealed why a particular student was classified as "successful" or "unsuccessful" and which variables affected this decision and in what direction.

The SHAP method was preferred as the main explainability method in this study because it provides a model-agnostic explanation and enables interpretation at both the global and local levels.

The LIME method aims to explain the prediction made by the model for a specific observation through a local linear model generated around that observation (Paul et al., 2025). This approach enables the local behavior of complex machine learning models to be interpreted through a simpler and more understandable model.

In this study, the LIME method was applied to selected individual observations, and it was analyzed which variables affected the model's prediction decisions and in what direction. The results obtained show the contribution of each variable to a specific observation through weight values.

The combined use of SHAP and LIME methods provides an answer not only to what prediction the model makes, but also to why it makes that prediction. In this context, comparing the SHAP and LIME results enables the consistency of the obtained explanations to be evaluated. This increases the reliability of the model and contributes to grounding the findings on a more robust basis. In addition, the use of XAI methods eliminates the "black-box" nature of machine learning models, allowing model decisions to become transparent and interpretable.

Findings

Descriptive Statistics

Within the scope of the research, the demographic characteristics of the participants were examined, and the frequency and percentage distributions related to these characteristics were calculated. The findings obtained are presented in Table 3.

Table 3. Demographic Characteristics of the Participants

Variable	Category	n	%
GPA (Achievement Status)	Successful	180	50.99
	Unsuccessful	173	49.01
Gender	Female	217	61.47
	Male	136	38.53
Department	Finance and Banking	157	44.48
	Marketing	93	26.35
	International Trade and Logistics	103	29.18
Grade Level	1st Year	151	42.78
	2nd Year	83	23.51
	3rd Year	58	16.43
	4th Year	61	17.28
Mother's Education	Primary School	137	38.81
	Middle School	82	23.23
	High School	91	25.78
	University	43	12.18
Father's Education	Primary School	111	31.44
	Middle School	73	20.68
	High School	113	32.01
	University	56	15.86
Type of Residence	Family Home	75	21.25
	Student Dormitory	212	60.06
	Other	66	18.70

Table 3 presents the demographic characteristics of the 353 students who participated in the study. When the academic achievement status of the participants is examined, it is observed that the distribution of successful (50.99%, n=180) and unsuccessful (49.01%, n=173) students is quite balanced. This finding enables more reliable comparisons between classes in the analyses.

In the dataset, "GPA" was used as the target variable. The balanced class distribution of the target variable (successful: 50.99%; unsuccessful: 49.01%) reduces the risk of bias due to class imbalance in the modeling process and allows performance metrics to be evaluated more reliably.

When the gender distribution is examined, it is observed that the majority of the participants were female students (61.47%, n=217), while male students were represented at a rate of 38.53% (n=136).

When examined by department, the highest participation was from the Department of Finance and Banking (44.48%, n=157), followed by International Trade and Logistics (29.18%, n=103) and Marketing (26.35%, n=93).

When the distribution by grade level is examined, it is seen that the majority of the participants consisted of first-year students (42.78%, n=151), with a gradual decrease toward the upper grade levels.

When parental education levels are evaluated, it is observed that the majority of mothers were primary school graduates (38.81%), followed by high school (25.78%) and middle school (23.23%) graduates. Similarly, fathers' education levels were concentrated mostly among high school (32.01%) and primary school (31.44%) graduates.

In terms of type of residence, it is observed that the majority of the participants stayed in student dormitories (60.06%, $n=212$), while 21.25% ($n=75$) lived with their families and 18.70% ($n=66$) stayed in other accommodation types.

Following the demographic characteristics, descriptive statistics for the continuous variables used in the study were analyzed. In this context, the mean and standard deviation values of the variables were calculated and presented in Table 4.

Table 4. Descriptive Statistics for Continuous Variables

Variable	Min	Max	Mean ($\bar{x}$)	SD
Age	17	27	19.90	1.74
Self-Regulation	1.00	5.00	3.25	0.88
Academic Motivation	1.80	5.00	4.17	0.68
Active Learning	1.00	5.00	3.73	0.73
Academic Engagement	1.00	5.00	3.76	0.76
Academic Well-Being	1.00	5.00	2.99	0.92
Digital Learning Access	2.50	5.00	4.26	0.61
Environmental Support	2.00	5.00	3.66	0.69
Study Effort	1.00	20.00	4.28	2.64
Screen Time (hours)	1	12	6.48	2.24
Sleep Duration (hours)	4	13	7.19	1.52
Social Participation	1	5	3.01	1.15

When Table 4 is examined, it is observed that the mean age of the participants was 19.90 ($SD=1.74$). When the variables related to learning processes are examined, the level of academic motivation is found to be high ($\bar{x}=4.17$, $SD=0.68$). Similarly, digital learning access also has a high mean value ($\bar{x}=4.26$, $SD=0.61$). Active learning ($\bar{x}=3.73$, $SD=0.73$), academic engagement ($\bar{x}=3.76$, $SD=0.76$), and environmental support ($\bar{x}=3.66$, $SD=0.69$) are observed to be at a moderate-to-high level. The level of self-regulation ($\bar{x}=3.25$, $SD=0.88$) is at a moderate level and shows relatively higher variability among individuals. The mean score of academic well-being ($\bar{x}=2.99$, $SD=0.92$) is lower compared to the other variables, indicating that students' psychological and academic well-being levels are relatively limited. When behavioral variables are examined, the mean study effort score is 4.28 ($SD=2.64$), showing a wide distribution. This finding indicates that students' study intensity is quite heterogeneous. While the mean screen time was found to be 6.48 hours per day ($SD=2.24$), the mean sleep duration was calculated as 7.19 hours ($SD=1.52$). These findings indicate that a considerable proportion of students have high screen usage. Finally, the level of social participation ($\bar{x}=3.01$, $SD=1.15$) is observed to be at a moderate level.

Comparison of Model Performances

In this study, the performances of the machine learning models developed to predict the academic achievement of university students were evaluated using accuracy, precision, recall, F1 score, and ROC-AUC metrics. In order to evaluate model performances independently of hyperparameter optimization, the algorithms were tested with their default parameter settings. In this context, 5-fold cross-validation was applied to the LR, RF, SVM, and XGB models, and the obtained performance results are presented in Table 5.

Table 5. 5-Fold Cross-Validation Results of the Models.

Model	Accuracy	Precision	Recall	F1 Score	ROC-AUC
SVM	0.69	0.71	0.68	0.69	0.75
RF	0.68	0.69	0.71	0.69	0.76
XGB	0.65	0.66	0.65	0.65	0.73
LR	0.65	0.65	0.68	0.66	0.72

When the findings obtained are examined, it is seen that the RF and SVM models exhibited higher performance compared to the other models. In particular, while the RF model provided the most balanced performance, it is noteworthy that the accuracy and precision values of the SVM model were relatively high. In contrast, the performances of the LR and XGB models were observed to be more limited.

In order to examine the generalizability levels of the models in more detail, the dataset was split into 80% training and 20% testing sets, and the models were evaluated based on this split. While the training dataset was used in the model learning process, the test dataset was used to measure the model's performance on previously unseen data. The findings obtained are presented in Table 6.

Table 6. Comparison of Model Performances on the Training and Test Datasets

Model	Accuracy		F1 Score		Precision		Recall		ROC-AUC	
	Training	Test	Training	Test	Training	Test	Training	Test	Training	Test
LR	0.69	0.64	0.71	0.64	0.69	0.65	0.72	0.63	0.76	0.76
RF	1.00	0.76	1.00	0.76	1.00	0.77	1.00	0.75	1.00	0.82
SVM	0.90	0.76	0.90	0.77	0.91	0.73	0.88	0.83	0.94	0.80
XGB	1.00	0.66	1.00	0.68	1.00	0.65	1.00	0.72	1.00	0.73

When Table 6 is examined, it is seen that the RF and XGB models achieved very high performance values on the training dataset (Accuracy = 1.00, F1 = 1.00); however, this performance decreased markedly on the test dataset. This finding indicates that these models overfitted the training data.

In contrast, the SVM model is observed to exhibit a more balanced structure between training and test performances. The relatively low performance of the LR model on both the training and test datasets indicates that the model could not adequately capture the complex and nonlinear relationships in the dataset.

Following the initial performances obtained with default parameters, hyperparameter optimization was applied to improve model performance. In this context, the dataset was split into 80% training and 20% testing sets. During the hyperparameter optimization process, 5-fold cross-validation was used, and the F1 score was taken as the main criterion for final model selection. Model performance was evaluated on previously unseen test data independently of the training process. This approach aims to increase the generalizability of the obtained results. In addition, Grid Search and Optuna methods were compared for hyperparameter optimization for each model. Accordingly, the method that provided the higher F1 score was preferred for the relevant model. The obtained results are presented in Table 7.

Table 7. Model Performances After Hyperparameter Optimization

Model	Method	Accuracy	F1 Score	Precision	Recall	ROC-AUC
RF	Grid Search	0.78	0.79	0.78	0.80	0.81
SVM	Optuna	0.76	0.77	0.74	0.80	0.80
XGB	Grid Search	0.73	0.72	0.75	0.69	0.77
LR	Grid Search	0.66	0.68	0.65	0.72	0.76

When Table 7 is examined, it is observed that the overall performance of the models increased. Among these models, the RF model stands out as exhibiting the highest overall performance. The RF model produced more successful results compared to the other models in terms of accuracy (0.78) and F1 score (0.79). In addition, the fact that the precision (0.78) and recall (0.80) values are quite close to each other indicates that the model provides a balanced performance in terms of both correctly predicting the positive class and capturing true positives. When the ROC-AUC values are examined, it is seen that the RF (0.81) and SVM (0.80) models exhibited the highest discriminative performance. The XGB (0.77) and LR (0.76) models, on the other hand, provided relatively lower performance. These findings indicate that the RF model is the most successful model not only in terms of overall performance but also in terms of its ability to distinguish between classes.

Although the SVM model lagged behind the RF model in terms of accuracy (0.76) and F1 score (0.77), its recall value (0.80) was the same as that of RF. This finding indicates that the SVM model is quite successful in capturing samples belonging to the positive class. However, its lower precision value (0.74) suggests that the model may have a higher tendency to produce false positives compared to the RF model. This finding suggests that the SVM model may be a potential alternative for applications in which detecting the positive class is prioritized.

The XGB model exhibited a moderate level of performance. Although its precision value (0.75) was relatively high, its lower recall value (0.69) indicates that the model acted more selectively and missed some true positive samples. This finding points to a possible increase in the false negative rate and suggests that it may constitute a limitation, particularly in applications where recall is important.

The LR model produced the lowest results across all performance metrics (Accuracy = 0.66, F1 = 0.68). This finding indicates that the relationships in the dataset could not be adequately represented through linear assumptions and that more complex, nonlinear models produced more successful results.

When accuracy and F1 score are considered together, it is concluded that the RF model provided the most balanced and highest performance, while the SVM model constituted a strong alternative, particularly in terms of recall. Accordingly, it is observed that the RF model stands out when overall classification performance is prioritized.

Following the comparison of model performances, the hyperparameter combinations that provided the highest performance for each algorithm were examined, and the related results are presented in Table 8.

Table 8. Optimized Model Hyperparameters

Model	Method	Hyperparameters
RF	Grid Search	max_depth = 5, n_estimators = 200
SVM	Optuna	C = 0.118, kernel = rbf
XGB	Grid Search	learning_rate = 0.01, max_depth = 3, n_estimators = 300
LR	Grid Search	C = 0.01, class_weight = balanced

Table 8 presents the hyperparameter values that provided the best performance for each model as a result of hyperparameter optimization based on the F1 score criterion. When Table 8 is examined, it is seen that Grid Search and Optuna methods were effective at different levels across different models. While the Grid Search method was preferred particularly for the RF and XGB models, a more flexible parameter search process was carried out with Optuna for the SVM model. The obtained parameter values reflect the most suitable configurations of the models specific to the dataset. However, when evaluated in general, the combined use of both methods contributed to a more comprehensive optimization of model performance.

After hyperparameter optimization, the RF model (0.78 accuracy, 0.79 F1 score, 0.81 ROC-AUC) was found to exhibit the highest and most balanced performance in predicting academic achievement.

Following the general evaluation of model performances, the confusion matrices of each algorithm obtained from the test data are presented in Table 9 in order to analyze the correct and incorrect classification patterns of the models in more detail.

Table 9. Confusion Matrix Results

Model	True Negative (TN)	False Positive (FP)	False Negative (FN)	True Positive (TP)
LR	21	14	10	26
RF	27	8	7	29
SVM	25	10	7	29
XGB	27	8	11	25

According to Table 9, the RF model provides the most balanced performance with low FP and FN values. Although SVM has a similar TP value, its error rates are slightly higher. While the XGB model tends to miss the positive class due to its high FN value, the LR model exhibits the lowest performance with the highest error rates.

SHAP Global Findings

In this study, the SHAP method was used to explain the decision mechanism of the RF model, which demonstrated the highest performance, at the global level. SHAP analysis makes it possible to analyze the feature importance ranking and the direction of effects by quantitatively revealing the contribution of each variable to the model predictions.

The SHAP findings obtained within this scope are presented in Figure 2. In Figure 2(a), the importance ranking of the variables according to their mean absolute SHAP values is presented, while Figure 2(b) shows the direction and distribution of the effects of the variables on the model output.




Figure 2. Global SHAP Explanation Results: (a) Feature Importance Ranking, (b) SHAP Summary Plot

When Figure 2(a) is examined, it is seen that the most influential variable in the model's prediction performance is grade level. This variable is followed by academic engagement, environmental support, self-regulation, and academic motivation, respectively.

The SHAP summary plot presented in Figure 2(b) reveals not only the importance levels of the variables but also the direction of their effects on the model output. In the plot, the red color represents high variable values, while the blue color represents low variable values. The concentration of blue points on the right and red points on the left along the grade level line indicates that lower grade levels affect the model output positively, whereas higher grade levels affect it negatively. Accordingly, the model evaluates students at lower grade levels as being closer to the “successful” class, while the tendency of the prediction to shift toward the “unsuccessful” class increases as grade level rises. This finding suggests that students in lower grade levels in the dataset may have a more advantageous profile in terms of academic achievement, or that factors such as academic workload, course difficulty, and performance pressure may have a decreasing effect on the probability of success as grade level increases. However, the possibility that this finding may involve bias arising from the sample structure should also be taken into consideration. The fact that a substantial proportion of the research sample consisted of first-year students (42.78%) may have caused the patterns belonging to this group to become more dominant during the model's learning process.

It is observed that high values of academic engagement, self-regulation, and academic motivation positively affect the model output, whereas low values decrease the probability of success. Some variables are observed to have a limited effect. In particular, the low SHAP values of variables such as digital learning access, age, and father's education level indicate that these variables contributed relatively less to the model decision-making process.

The SHAP analyses reveal that the model's decisions are largely shaped by students' academic behaviors, level of participation in learning processes, and environmental support factors. This finding indicates that academic achievement is closely associated not only with individual characteristics but also with the learning environment and behavioral factors.

SHAP Local Findings

Local explanations were obtained using the SHAP method in order to analyze the model's decision-making mechanism at the local level. In this context, three different observations were selected from the dataset: a typical successful student, a typical unsuccessful student, and a student close to the decision boundary. Thus, not only the model's decision-making process for a single observation but also the explanation patterns across different student profiles were evaluated comparatively.




Figure 3. Local Explanation Using a SHAP Waterfall Plot

The typical successful student shown in Figure 3(a) was correctly predicted by the model as belonging to the “successful” class, and the probability value for the “successful” class was calculated as 0.856. In this observation, academic engagement, self-regulation, academic motivation, environmental support, and academic well-being variables were found to make positive contributions, moving the student closer to the “successful” class. In particular, the high level of academic engagement constituted the most prominent positive effect in the model decision. In contrast, grade level and study effort variables were observed to produce limited negative contributions.

For the typical unsuccessful student shown in Figure 3(b), the model's predicted probability for the “successful” class was 0.277. In this observation, grade level, environmental support, study effort, and academic engagement variables made negative contributions and were influential in directing the student toward the “unsuccessful” class. In particular, the negative effect of grade level stands out as the main factor determining the model decision in this observation. However, mother's education level and digital learning access variables were observed to make limited positive contributions.

In Figure 3(c), the student close to the decision boundary was predicted by the model as belonging to the “successful” class, and the probability value for the “successful” class was calculated as 0.533. This value is quite close to the decision threshold of 0.50. While grade level and academic engagement variables contributed positively, sleep duration, academic motivation, environmental support, and screen time variables contributed negatively. In addition, variables related to departments were also observed to have a limited effect on the model output. This finding indicates that the student is positioned at a sensitive point between the successful and unsuccessful classes and that small changes may alter the model prediction.

Overall, it is observed that the model decisions in all three different observations were not based on a single variable, but were formed through the combined effects of multiple variables such as academic engagement, grade level, self-regulation, motivation, and environmental support. This

finding supports the multidimensional structure of academic achievement and shows that SHAP local explanations contribute to the interpretation of model decisions at the individual level.




Figure 4. Local Explanation Using a SHAP Force Plot

The SHAP force plot presented in Figure 4 shows, in a holistic structure, the direction in which the variables affect the model output for the same observation. In the plot, red-colored variables represent a positive effect on the prediction, whereas blue-colored variables represent a negative effect. Accordingly, grade level, academic engagement, and the department categories of International Trade and Logistics (department_3) and Finance and Banking (department_1) are observed to contribute positively, moving the observation closer to the “successful” class. In contrast, sleep duration, academic motivation, environmental support, and screen time are observed to contribute negatively, moving the observation closer to the “unsuccessful” class.

SHAP local analyses clearly reveal that the model’s decisions are formed as a result of multiple variable interactions. This finding indicates that academic achievement cannot be explained by a single factor and that individual and environmental variables should be evaluated together. In addition, although the model made a correct classification, the fact that the probability of success was close to the threshold value (0.53) indicates that this observation exhibits a profile close to the decision boundary and that small changes may alter the class prediction.

LIME Local Findings

The LIME method was applied in order to examine the model’s decision-making mechanism at the local level through a different XAI method. LIME analysis explains how the model’s decision for a specific observation is shaped within the relevant ranges of the variables using a local linear approach. In this context, the analysis was performed on the same three observations used in the SHAP analysis in order to ensure consistency. Thus, it became possible to comparatively evaluate the model decisions using different XAI methods. The LIME local explanation plot is presented in Figure 5.




Figure 5. LIME Local Explanation Plot

The LIME results presented in Figure 5 show the contributions of the variables to the model prediction for each observation. In the plot, green-colored variables represent effects that move the prediction closer to the “successful” class, while red-colored variables represent effects that direct it toward the “unsuccessful” class.

When the typical successful student shown in Figure 5(a) is examined, it is seen that academic engagement ($\text{academic_engagement} > 4.38$), self-regulated learning ($\text{self_regulated_learning} > 3.50$), and academic motivation ($\text{academic_motivation} > 4.55$) positively contributed to directing the student toward the “successful” class. In addition, variables such as the student’s living with family in terms of residence type ($\text{residence_type_1} \leq 0.00$), father’s education level ($\text{father_education} > 3.00$), sleep duration ($7.00 < \text{sleep_duration} \leq 8.00$), and social participation ($3.00 < \text{social_participation} \leq 4.00$) also contributed positively to the model. In contrast, high grade level ($\text{grade_level} > 3.00$), International Trade and Logistics department (department_3), and screen time ($\text{screen_time} \leq 5.00$) were observed to produce negative contributions. These findings indicate that academic engagement, self-regulation, and motivation were particularly decisive in directing the student toward the “successful” class.

For the typical unsuccessful student presented in Figure 5(b), the LIME results show that factors such as high grade level ($\text{grade_level} > 3.00$) and low academic engagement ($\text{academic_engagement} \leq 3.50$) affected the model prediction toward the “unsuccessful” class. In addition, moderate self-regulation ($2.83 < \text{self_regulated_learning} \leq 3.33$), low father’s education level ($\text{father_education} \leq 1.00$), and high study effort ($\text{study_effort} > 5.50$) were also observed to produce negative contributions. In contrast, the student’s living with family ($\text{residence_type_1} \leq 0.00$), International Trade and Logistics ($\text{department_3} \leq 0.00$), $0.00 < \text{Finance and Banking department} (\text{department_1}) \leq 1.00$, low mother’s education level ($\text{mother_education} \leq 1.00$), and low active learning level ($\text{active_learning} \leq 3.50$) were observed to make limited positive contributions to the model output. Overall, it is understood that high grade level and low academic engagement were the main factors determining the model decision in this observation.

When the LIME results for the student classified as “successful” and located close to the threshold value in Figure 5(c) are examined, it is seen that low grade level ($\text{grade_level} \leq 1.00$) and high academic engagement ($\text{academic_engagement} > 4.38$) were the strongest positive variables directing the student toward the “successful” class. In addition, International Trade and Logistics department ($\text{department_3} \leq 0.00$), the student’s living with family ($\text{residence_type_1} \leq 0.00$), $0.00 < \text{Finance and Banking department} (\text{department_1}) \leq 1.00$, and gender ≤ 0.00 also made limited positive contributions. In contrast, low sleep duration ($\text{sleep_duration} \leq 6.00$), low academic motivation ($\text{academic_motivation} \leq 4.00$), low self-regulation ($\text{self_regulated_learning} \leq 2.83$), and screen time ($\text{screen_time} \leq 5.00$) were observed to negatively affect the model output. These findings indicate that the student had a profile close to the decision boundary and that the positive and negative effects occurred at relatively similar levels.

Overall, the LIME analyses reveal that model decisions are shaped through specific variable ranges and show that similar variables stand out in a manner that supports the SHAP findings. This finding demonstrates that two different XAI methods produced consistent results and that the model’s local decision-making mechanism can be interpreted reliably.

Results and Discussion

This study aimed to predict the academic achievement of university students using machine learning methods and to interpret model decisions through XAI methods. The findings reveal that academic achievement has a multidimensional structure and that this structure can be modeled more effectively through nonlinear relationships.

When the performances of the machine learning models were compared, it was observed that the RF model exhibited higher performance than the other models after hyperparameter optimization. Following hyperparameter optimization, the RF model produced the most balanced results with 78% accuracy and an F1 score of 0.79. The Support Vector Machine (SVM) model followed the RF model with 76% accuracy and an F1 score of 0.77. In contrast, XGBoost (73% accuracy, 0.72 F1) and

Logistic Regression (66% accuracy, 0.68 F1) models were found to exhibit lower performance. In the literature, many studies on predicting academic achievement using machine learning report that tree-based algorithms exhibit strong and competitive performance, particularly in complex and large datasets (Guevara-Reyes et al., 2025; Saqr, 2024; Sun et al., 2026; Wang & Luo, 2024). These findings indicate that the relationships among the variables affecting academic achievement have a complex and interactive structure rather than a linear one.

The comparison of model performances on the training and test datasets showed that overfitting occurred in some models. In particular, although the RF and XGB models achieved 100% accuracy and F1 scores on the training dataset, their performances decreased to 76% and 66%, respectively, on the test dataset, indicating that these models overfitted the training data. In contrast, the SVM model exhibited a more balanced structure between training performance (90% accuracy) and test performance (76% accuracy), showing that the model was more stable in terms of generalizability. However, the final model selection was not based solely on the difference between training and test performance, but also on the optimized performance values obtained through cross-validation and the independent test dataset, as well as the balance of classification performance (the balance between precision and recall and the F1 score). In this context, the RF model's higher accuracy (0.78) and F1 score (0.79) on the test dataset, together with its more balanced precision-recall structure, indicate that the model provided higher predictive performance than the other models in the application context.

After hyperparameter optimization, an increase in performance was observed across all models. This finding indicates that appropriate hyperparameter selection has a significant effect on model performance (Dewi et al., 2025; Dhilsath & Samuel, 2021). The findings reveal that model performance in academic achievement prediction problems depends not only on algorithm selection but also on configuring the model specifically for the dataset.

Another dimension of the study is the detailed analysis of model results using XAI methods. SHAP analyses showed that the most influential variables in predicting academic achievement were grade level, academic engagement, environmental support, self-regulation, and academic motivation. These findings are consistent with previous studies emphasizing the determining role of variables such as engagement, study behaviors, and motivation on academic achievement (Ahmed et al., 2025; Alkan, 2026; Cleary & Kitsantas, 2017; Morosanova et al., 2022; Wang & Holcombe, 2010). This finding reveals that academic achievement is closely associated with students' active participation in learning processes and the environmental conditions in which they are situated.

SHAP summary plots revealed not only the importance levels of the variables but also the direction of their effects on the model output. In particular, an increase in grade level was found to have a negative effect on the probability of success. In contrast, high levels of academic engagement, self-regulation, and academic motivation were observed to have a positive effect on achievement. Some variables, such as digital learning access, age, and parental education level, were found to contribute relatively less to the model decision-making process.

Local-level SHAP and LIME analyses show that model decisions are shaped by the joint effects of variables across different student profiles. In the findings related to the typical successful student, academic engagement, self-regulation, academic motivation, environmental support, and academic well-being emerged as the main factors strengthening the prediction of success. In contrast, in the typical unsuccessful student observation, variables such as grade level, low academic engagement, and environmental support were found to direct the model decision toward the unsuccessful class. In the observation close to the decision boundary, the success probability was calculated as 0.533, indicating that the positive and negative variable contributions were at similar levels in this student profile. This finding reveals that, in some observations, model predictions are based on a delicate balance rather than a clear-cut distinction, and that small changes in variables

may affect the classification result. The fact that SHAP and LIME results point to similar variables supports the consistency of local explanations and increases the interpretability of the model's decision-making mechanism. In this context, the findings indicate that academic achievement can be explained not only by individual characteristics but also by the combined effects of multiple factors such as academic engagement, motivation, self-regulation, and environmental support.

The LIME analysis results also supported the SHAP findings and showed that similar variables were decisive in the model's decision-making process. The fact that both methods produced consistent results increases the interpretability of the model and the reliability of the findings obtained (Sathyan et al., 2022). This situation demonstrates that XAI methods eliminate the "black-box" nature of machine learning models and make decision-making processes more transparent (Rane et al., 2024; Samek et al., 2021).

Overall, it is seen that academic achievement cannot be explained by a single variable; rather, it is a complex structure that emerges as a result of the interaction of individual, behavioral, and environmental factors. This finding indicates that educational processes should be planned not only based on academic content but also by considering students' learning behaviors, motivation levels, and environmental conditions.

This study has several limitations. First, the dataset was obtained from students studying in a specific faculty of a single university. This situation may limit the generalizability of the findings. Since the survey method used in the data collection process was based on self-report, it may involve bias. In addition, the fact that comprehensive psychometric validity and reliability analyses were not conducted for the thematic composite variables used in the study should be considered one of the important methodological limitations regarding the measurement structure.

Furthermore, transforming the academic achievement variable into a binary class limits the more detailed analysis of achievement levels. The use of cross-sectional data in the study does not allow causal relationships between variables to be established. In addition, the overfitting problem observed in some models can be considered a limitation related to the size and structure of the dataset.

In future research, the generalizability of model results can be improved by collecting data from different universities and larger samples. In addition, longitudinal data can be used to examine changes over time in the factors affecting academic achievement.

In terms of educational practices, it is recommended that student support programs focus on areas such as academic engagement, self-regulation, and motivation, considering their determining role in achievement. In addition, improving students' environmental and socioeconomic conditions can be considered an important strategy for enhancing academic achievement.

Finally, the more widespread use of XAI methods in the field of machine learning will contribute not only to examining prediction accuracy but also to making decision-making processes more transparent and interpretable and to supporting data-driven decision-making.



www.turkishstudies.net/turkishstudies

Turkish Studies

eISSN: 1308-2140



ANKARA SCIENCE
UNIVERSITY

Üniversite Öğrencilerinin Akademik Başarısının Makine Öğrenmesi ile Tahmini: Açıklanabilir Yapay Zekâ Temelli Bir Analiz

Giriş

Akademik başarı, eğitim öğretim kurumlarının temel performans göstergelerinden biri olarak eğitim sisteminin kalitesini, öğrenci gelişimini ve kurumsal etkinliği yansıtan kritik bir ölçüttür. Akademik başarının ölçülmesinde, genel başarı testi puanları veya genel akademik ortalama göz önünde bulundurulmaktadır. Ancak akademik başarı, yalnızca bilişsel faktörlerle sınırlı olmayıp; psikolojik ve sosyal değişkenlerin etkileşimiyle şekillenen çok boyutlu yapıya sahiptir (Karaağaç Cingöz vd., 2025). Bu nedenle, akademik başarıyı etkileyen faktörlerin bütüncül biçimde analiz edilmesi, eğitimciler ve politika yapıcılar açısından kritik bir önem taşımaktadır.

Geleneksel istatistiksel yöntemler, değişkenler arasındaki doğrusal ilişkileri açıklamada etkili olmakla birlikte, günümüz eğitim verilerinin çok boyutlu ve doğrusal olmayan yapısını modellemede sınırlı kalabilmektedir (Kyriazos & Poga, 2024). Doğrusal olmayan ilişkiler, sosyal davranışların ve psikolojik süreçlerin anlaşılmasında kritik bir öneme sahiptir. Bu bağlamda makine öğrenmesi algoritmaları, veri içerisindeki karmaşık örüntüleri ortaya çıkarma ve yüksek doğrulukta tahminler sağlayabilmektedir (Przybyś-Mańczak vd., 2023). Özellikle Lojistik Regresyon (LR), Random Forest (RF), Destek Vektör Makineleri (DVM) ve XGBoost (XGB) gibi makine öğrenmesi algoritmaları, akademik başarı tahmini çalışmalarında yaygın olarak kullanılan güçlü yöntemler arasında yer almaktadır.

Son yıllarda yapay zekâ uygulamalarının eğitim, sağlık, tarım gibi birçok farklı alanda kullanılmaya başlandığı görülmektedir (Sönmez & Zengin, 2023; Yıldız, 2025). Yapay zekânın alt alanlarından biri olan makine öğrenmesi veri temelli tahmin süreçlerinde önemli avantajlar sağlamaktadır. Bu doğrultuda makine öğrenmesi algoritmaları, karmaşık ve çok boyutlu veri yapılarından örüntüler öğrenme ve tahminsel modeller oluşturma kapasiteleri sayesinde akademik başarı tahmini alanında yaygın olarak kullanılmaktadır (Guanin-Fajardo vd., 2024; Hashim vd., 2020; Metin, 2025; Nayak vd., 2023; Özdemir vd., 2026; Yağcı, 2022). Literatürde akademik başarı tahminine yönelik çok sayıda makine öğrenmesi temelli çalışma bulunmasına rağmen, bu çalışmaların büyük bir kısmı model performansına odaklanmakta ve model kararlarının nasıl oluştuğunu yeterince açıklamamaktadır. Nitekim, Boujmiraz ve ark. (2026) tarafından gerçekleştirilen ve öğrenci akademik başarı tahmininde kullanılan yaklaşımları bütüncül olarak inceleyen derleme çalışmasında, kara kutu modeller kullanan araştırmaların yalnızca %14'ünde açıklanabilir yapay zekâ (Explainable Artificial Intelligence-XAI) yöntemlerine yer verildiği belirtilmektedir. Bu durum, yorumlanabilirlik boyutunun sınırlı kaldığını ortaya koymaktadır. Oysa eğitim gibi yüksek etkili karar süreçlerinde yalnızca doğru tahminler üretmek yeterli olmayıp, bu tahminlerin hangi faktörlere dayandığının anlaşılması da büyük önem taşımaktadır. Bu gereklilik, açıklanabilir yapay zekâ yöntemlerinin önemini artırmıştır. SHapley Additive exPlanations (SHAP) ve Local Interpretable Model-agnostic Explanations (LIME) gibi yöntemler, model kararlarının hem

küresel hem de yerel düzeyde yorumlanmasına olanak tanıyarak bu alandaki önemli bir boşluğu doldurmaktadır.

Bununla birlikte, akademik başarının tahmininde açıklanabilir yapay zekâ yöntemlerinin modelleme sürecine entegre edildiği çalışmalar da bulunmaktadır (Ahmed vd., 2025; Guevara-Reyes vd., 2025; Paul vd., 2025). Bu çalışmalar akademik başarıyı çoğunlukla akademik, yapısal ve sistem düzeyindeki değişken grupları üzerinden modellemektedir. Bu çalışma ise, akademik başarıyı etkileyen demografik, davranışsal, akademik ve çevresel faktörleri birlikte kapsayan, anket temelli özgün bir veri seti üzerinden, makine öğrenmesi modellerinin performansını açıklanabilir yapay zekâ ile bütüncül bir çerçevede analiz ederek literatüre metodolojik ve uygulamalı katkı sunmayı amaçlamaktadır. Ayrıca anket yöntemiyle elde edilen veriler üzerinde öznitelik oluşturma süreci uygulanmış, değişkenler tematik boyutlar altında birleştirilerek modelleme için veri seti oluşturulmuştur. Akademik başarı değişkeni ise sınıflandırma problemlerine uygun hale getirilerek öğrenciler “başarılı” ve “başarısız” olarak ikili biçimde ele alınmıştır.

Çalışmanın temel katkılarından biri, model sonuçlarının açıklanabilirliğine odaklanmasıdır. Açıklanabilir yapay zekâ, makine öğrenmesi modellerinin kararlarının insanlar tarafından anlaşılabilir ve yorumlanabilir hale getirilmesini amaçlayan yöntem ve yaklaşımlar bütünüdür. Bu çalışmada açıklanabilir yapay zekâ yöntemlerinden SHAP ve LIME yöntemleri kullanılmıştır. Bu kapsamda SHAP yöntemi ile değişkenlerin model üzerindeki küresel ve yerel etkileri analiz edilirken, LIME yöntemi ile bireysel tahminlerin yerel düzeyde nasıl oluştuğu incelenmiştir. Bu yaklaşım, akademik başarı tahminine ilişkin bulguların yalnızca performans açısından değil, aynı zamanda yorumlanabilirlik açısından da değerlendirilmesine olanak sağlamaktadır.

Sonuç olarak, akademik başarıyı etkileyen çok boyutlu faktörlerin karmaşık yapısı, bu başarının doğru ve genellenebilir biçimde tahmin edilmesini ve model kararlarının anlaşılmasını zorlaştırmaktadır. Bu çalışma, makine öğrenmesi ve açıklanabilir yapay zekâ yöntemlerini bütüncül bir çerçevede ele alarak özgün veri seti üzerinden hem yüksek performanslı tahminler üretmeyi hem de bu tahminlerin altında yatan karar mekanizmalarını ortaya koymayı hedeflemektedir. Bu yönüyle çalışma, akademik başarı tahmini literatürüne performans ve yorumlanabilirliği birlikte ele alan bütüncül bir yaklaşım sunmaktadır².

Bu temel amaç doğrultusunda, akademik başarı tahminine ilişkin model performansı ve model kararlarının açıklanabilirliği bağlamında aşağıdaki alt araştırma sorularına yanıt aranmıştır:

- Farklı makine öğrenmesi algoritmaları, üniversite öğrencilerinin akademik başarılarını tahmin etmede nasıl bir performans göstermektedir?
- Hiperparametre optimizasyonu, model performansını ne ölçüde etkilemektedir?
- Akademik başarıyı etkileyen en önemli değişkenler nelerdir?

² Yapay zekâ ve üretken yapay zekâ uygulamalarının sosyal bilimler, eğitim, dil ve edebiyat, din bilimleri, iletişim, ekonomi ve diğer akademik disiplinlerde kullanımı; araştırma, veri analizi, içerik üretimi, öğretim ve öğrenme süreçlerine etkileri ile yapay zekânın sunduğu imkânlar, sınırlılıklar ve etik sorunları farklı açılardan ele alan örnek çalışmalar için ayrıca bk. Denizci et al. 2018, Baran 2022, Keleş & Keleş, 2018; Karadağ, 2025; Coşkun, 2025; Ahmed & Hamod, 2026; Arıcı & Karacı, 2013; Keleş & Keleş, 2017; Keleş et al., 2017; Bekil, 2018; Keleş, 2018; Serçemeli, 2018; Akyıldız & Akyıldız, 2020; Işık & Darı, 2023; Abdulrazagova et al., 2025; Arğın 2025; Tetik Küçükkelçi, 2025; Çakmak, 2025; Yıldırım Altun, 2025; Zana & Zana, 2025; Mazlum & Mazlum, 2025; Yıldız, 2025; Başar, 2025; Tuğcu, 2025; Özdemir, 2026; Çora et al., 2026; Büyükboyacı & Yozcu, 2026; Ardaturk, 2026; Arduç Kara, 2026; Ertan, 2026; Ahmed & Hamod, 2026; Efendioğlu, 2023; Çelik et al., 2025; Doğru & Hacımüftüoğlu, 2025; Koçakoğlu & Koçakoğlu, 2025; Ekinci, 2025; Sakin & Türk, 2025; Aşkun, 2024; Yener & Köse, 2023; Romya Bilgin & Küçükşabanoglu, 2023; Çark, 2020; Kanat, 2020; Altındış, 2020; Zenginaloğlu, 2026; Dalmış, 2026; Ölçer, 2025; Sarıbaş, 2025; Karakuş et al., 2025; Güzel, 2024; Kızıldağ, 2023; Odacıoğlu, 2022; Erdem-Demiryakan 2025, 2026, Civelek 2025, Günay 2025, Önen 2025, Özdemir 2025; Sandıkcı & Soy 2026; Arduç Kara 2026; Ertan 2026; Uygun 2026; Yılmaz 2025; Kan Çelik 2026; Bayat Arslan & Cuma 2026; Köksal & Zorlu Kale 2025; Varol 2025; Ahmed & Hamod 2026; Efendioğlu 2023; Sert 2026; Güçlüten 2026.

- Açıklanabilir yapay zekâ yöntemleri (SHAP ve LIME), model kararlarının yorumlanmasına nasıl katkı sağlamaktadır?

Yöntem

Araştırma Modeli

Bu çalışma, üniversite öğrencilerinin akademik başarı durumlarının makine öğrenmesi yöntemleri ile tahmin edilmesini ve model kararlarının açıklanabilir yapay zekâ yöntemleri ile yorumlanmasını amaçlamaktadır. Bu araştırma modeli; veri toplama, öznitelik oluşturma, model geliştirme, hiperparametre optimizasyonu ve açıklanabilirlik analizlerinden oluşmaktadır.

Araştırma kapsamında öncelikle anket yöntemi ile elde edilen ham veriler üzerinde öznitelik oluşturulmuştur. Kavramsal olarak benzer değişkenler tematik boyutlar altında birleştirilerek yeni değişkenler elde edilmiştir.


Modelleme sürecinin ilk aşamasında, makine öğrenmesi algoritmalarının performanslarını değerlendirmek amacıyla modeller varsayılan parametreler ile ele alınmış ve veri seti üzerinde 5 katlı çapraz doğrulama uygulanmıştır. Bu yöntem, veri setinin farklı alt kümelere bölünerek modelin her bir alt küme üzerinde eğitilip test edilmesini sağlayarak modelin aşırı öğrenme riskini azaltmakta ve daha dengeli bir performans ölçümü sunmaktadır. Bu aşama, modellerin veri seti üzerindeki temel performans düzeylerini ve genellenebilirlik eğilimlerini ortaya koymak amacıyla gerçekleştirilmiştir.

Bir sonraki aşamada, modellerin daha gerçekçi performanslarının değerlendirilebilmesi amacıyla veri seti %80 eğitim ve %20 test olacak şekilde ikiye ayrılmıştır. Eğitim veri seti modelin öğrenme sürecinde kullanılırken, test veri seti modelin daha önce görmediği veriler üzerindeki performansını ölçmek amacıyla kullanılmıştır. Model performansları, eğitim sürecinde 5 katlı çapraz doğrulama ile değerlendirilmiştir. Nihai model performansları ise bağımsız test veri seti üzerinde raporlanmıştır. Bu yaklaşım, modelin genellenebilirliğini değerlendirmek ve aşırı öğrenme riskini azaltmak açısından önem taşımaktadır.

Devamında, model performansını artırmak amacıyla hiperparametre optimizasyonu uygulanmıştır. Bu kapsamda Grid Search ve Optuna yöntemleri kullanılarak her model için en uygun hiperparametre kombinasyonları belirlenmiştir. Optimizasyon sürecinde elde edilen sonuçlar karşılaştırılarak en yüksek performansı sağlayan model seçilmiştir.

Son aşamada ise seçilen model üzerinde açıklanabilir yapay zekâ yöntemlerin uygulanmıştır. Bu kapsamda SHAP yöntemi ile modelin küresel ve yerel düzeyde değişken önemleri analiz edilmiş, LIME yöntemi ile bireysel tahminlerin yerel düzeyde nasıl oluştuğu incelenmiştir. Böylece modelin yalnızca tahmin performansı değil, aynı zamanda karar mekanizması da kapsamlı biçimde değerlendirilmiştir.

Bu süreç doğrultusunda oluşturulan araştırma modeli Şekil 1’de sunulmaktadır.



Şekil 1. Araştırma Modeli

Bu çalışmada veri ön işleme, modelleme ve analiz süreçleri Python programlama dili kullanılarak gerçekleştirilmiştir. Makine öğrenmesi modellerinin geliştirilmesinde scikit-learn, hiperparametre optimizasyonunda GridSearchCV ve Optuna, XGBoost modellemesinde XGBoost, açıklanabilir yapay zekâ analizlerinde ise SHAP ve LIME kütüphanelerinden yararlanılmıştır.

Veri Seti ve Çalışma Grubu

Bu çalışmada kullanılan veri seti, üniversite öğrencilerinden anket yöntemiyle elde edilmiş olup toplam 353 katılımcıya ait gözlemleri içermektedir. Araştırmanın örnekleme, araştırmacının erişim kolaylığı nedeniyle Bolu Abant İzzet Baysal Üniversitesi Gerede Uygulamalı Bilimler Fakültesi'nde öğrenim gören öğrenciler arasından kolayda örnekleme yöntemiyle seçilmiştir. Kolayda örnekleme, araştırmacının ulaşması en kolay, erişilebilir ve hazır olan bireyleri örneklem olarak seçtiği bir örnekleme yöntemidir (Cohen vd., 2018). Veri toplama sürecinde, öğrencilerin demografik, akademik, davranışsal, dijital ve sosyoekonomik özelliklerini kapsayan çok boyutlu bir yapı benimsenmiştir. Bu kapsamda, araştırmacı tarafından hazırlanan 38 soruluk anket aracılığıyla elde edilen verilerle veri seti oluşturulmuştur. Veri setinde bölüm, yaş, cinsiyet, sınıf düzeyi, ebeveyn eğitim durumu ve ikamet türü gibi demografik değişkenlerin yanı sıra, öğrencilerin akademik süreçlerine ilişkin davranışsal ve psikososyal özellikleri yansıtan değişkenler de yer almaktadır. Veri setinde yer alan değişkenler, akademik başarıyı etkileyen motivasyon, öz-düzenleme, akademik katılım, çalışma alışkanlıkları, ebeveyn eğitimi ve sosyoekonomik/çevresel destek gibi faktörleri inceleyen önceki araştırmaların bulgularına dayalı olarak belirlenmiştir (Credé & Kuncel, 2008; Fan & Chen, 2001; Richardson vd., 2012; Sirin, 2005; Tao vd., 2022). Tematik yapıların oluşturulmasında, literatürde akademik başarı ile ilişkili olduğu gösterilen kavramsal yapılar dikkate alınmıştır. Benzer davranışsal, motivasyonel ve çevresel özellikleri temsil eden maddeler aynı tema altında birleştirilmiştir. Ancak çalışma kapsamında bu tematik yapıların psikometrik özelliklerini değerlendirmeye yönelik kapsamlı geçerlik ve güvenilirlik analizleri gerçekleştirilmemiştir. Bu durum, oluşturulan bileşik değişkenlerin geçerliği ve iç tutarlılığı açısından çalışmanın metodolojik sınırlılıklarından biri olarak değerlendirilmelidir. Bununla birlikte, örneklemin tek bir üniversitenin belirli bir fakültesi ile sınırlı olması ve kolayda örnekleme yönteminin kullanılması, elde edilen

bulguların genellenebilirliğini sınırlayan önemli bir metodolojik kısıt olarak değerlendirilmelidir. Elde edilen tematik yapı ve kodlanmış değişkenler Tablo 1’de sunulmaktadır. Her bir tema için ilgili maddelerin aritmetik ortalaması alınarak yeni değişkenler oluşturulmuştur.

Tablo 1: Üniversite Öğrencilerinin Akademik Başarılarını Etkileyen Değişkenlerin Tematik Sınıflandırılması ve Kodlanması

Tema	Kodlanmış Değişken Adı	Maddeler (Gözlenen Değişkenler)
Akademik Başarı	gno	Öğrencinin Genel Not Ortalaması (70 ve üzeri başarılı, altı başarısız olarak sınıflandırılmıştır)
	department_1	Finans ve bankacılık bölümü
	department_2	Pazarlama bölümü
	department_3	Uluslararası ticaret ve lojistik bölümü
	age	Öğrencinin yaşı
Demografik Özellikler	gender	Öğrencinin cinsiyeti
	grade_level	Öğrencinin sınıf düzeyi
	mother_education	Annenin eğitim düzeyi
	father_education	Babanın eğitim düzeyi
	residence_type_1	Öğrencinin aile evinde barınması
	residence_type_2	Öğrencinin öğrenci yurdunda barınması
	residence_type_3	Öğrencinin diğer barınma yerleri
Öz-Düzenleme	self_regulated_learning	Haftalık düzenli bir çalışma planı yaparım. Ders tekrarlarını düzenli yaparım. Sınavlara planlı hazırlanırım. Ders çalışırken dikkatimi sürdürebilirim. Derse girmeden önce konuyu gözden geçiririm. Zamanımı planlı kullanırım.
Akademik Motivasyon	academic_motivation	Akademik olarak ilerlemek benim için önemlidir. Öğrendiklerimin geleceğim için değerli olduğunu düşünüyorum. Hedeflerim doğrultusunda çalışırım. Çaba gösterdiğimde başarılı olabileceğime inanırım.
Aktif Öğrenme Davranışları	active_learning	Zorlandığım durumlarda çözüm üretebilirim. Anlamadığım konularda yardım isterim. Öğrenmek için farklı kaynaklardan yararlanırım. Derslerde aktif katılım gösteririm. Grup çalışmaları öğrenmemi destekler.
Akademik Katılım	academic_engagement	Derslere düzenli devam ederim. Derslere hazırlıklı gelirim.
Akademik İyi Oluş	academic_wellbeing	Akademik stresimi yönetebiliyorum. Sınav dönemlerinde kendimi dengede hissedirim. Uyku düzenim yeterlidir.
Dijital Öğrenme Olanakları	digital_learning_access	Yapay zekâ araçlarını öğrenme sürecinde kullanırım. Ders çalışmak için gerekli dijital araçlara kolayca erişebilirim.
Çevresel ve Sosyoekonomik Destek	environmental_support	Barınma koşullarım ders çalışmamı destekler. Ekonomik durumum eğitim hayatımı sürdürebilmem için yeterlidir. Ulaşım koşullarım ders düzenimi destekler.
Akademik Çalışma Yoğunluğu	study_effort	Çalışma ortamım verimli ders çalışmaya uygundur. Haftalık ders dışı çalışma süresi(saat).
Ekran Kullanımı	screen_time	Haftalık kütüphane/etüt kullanım süresi(saat). Günlük ekran süresi (saat).

Uyku Süresi	sleep_duration	Günlük uyku süresi (saat).
Sosyal Katılım	social_participation	Üniversite/kampüs içi sosyal etkinliklere katılım.

Öznitelik oluşturma sonucunda, başlangıçta 38 olarak gözlenen değişken sayısı, tematik bileşik değişkenler aracılığıyla azaltılmış ve hedef değişken (GNO) dâhil olmak üzere toplam 19 değişkenden oluşan bir veri seti elde edilmiştir. Bu sayı kavramsal değişken sayısını ifade etmektedir. Modelleme sürecinde nominal yapıya sahip bölüm (department) ve ikamet türü (residence_type) değişkenleri one-hot encoding yöntemi ile dönüştürülmüş olup makine öğrenmesi modellerine giren nihai öznitelik sayısı 23'e yükselmiştir.

Bu çalışmada bağımlı değişken olarak öğrencilerin akademik başarı düzeyini temsil eden GNO kullanılmıştır. Ancak makine öğrenmesi sınıflandırma modellerine uygunluk sağlamak amacıyla bu değişken ikili sınıfa dönüştürülmüştür. Eşik değeri belirlenirken veri setine ait GNO ortalaması (68.80) dikkate alınmış ve bu değer eğitim sistemlerinde yaygın olarak kullanılan değerlendirme sınırlarına karşılık gelen en yakın tam sayı olan 70 puana yuvarlanması tercih edilmiştir. Böylece, hedef değişken dengeli bir dağılım göstermiş ve belirlenen eşik değeri hem veri dağılımına dayalı bir referans noktası hem de eğitim uygulamalarında anlamlı bir başarı sınırı olarak belirlenmiştir. Bu doğrultuda öğrenciler “başarılı” ($GNO \geq 70$) ve “başarısız” ($GNO < 70$) olarak sınıflandırılmıştır. Bu dönüşüm, sürekli bir değişkenin sınıflandırma problemlerine uygun hale getirilmesini sağlamıştır. Ayrıca, veri setinin görece sınırlı büyüklüğü ($n=353$) ve anket temelli yapısı dikkate alındığında, sürekli değişkenlerin tahminine yönelik regresyon modellerinin daha yüksek varyans üretme riski bulunmaktadır. Bu nedenle, modelin genellenebilirliğini artırmak ve daha dengeli performans elde etmek amacıyla sınıflandırma yaklaşımı tercih edilmiştir.

Sonuç olarak, demografik, davranışsal ve çevresel boyutları bütüncül biçimde içeren, tematik olarak yapılandırılmış ve öznitelik oluşturma süreci içeren ve makine öğrenmesi modellerine uygun hale getirilmiş bir veri seti oluşturulmuştur.

Ayrıca bu çalışmada kullanılan anket için gerekli etik kurul izni, Bolu Abant İzzet Baysal Üniversitesi Sosyal Bilimler İnsan Araştırmaları Etik Kurulu'nun 2026/03 sayılı toplantısında verilmiş olup başvuru etik açıdan uygun bulunmuştur (Protokol No: 2026/212). Veri toplama sürecinde katılımcılardan gönüllü katılım esasına dayalı olarak bilgilendirilmiş, katılımcıların kimlik bilgileri toplanmamış ve tüm veriler anonimleştirilmiştir. Elde edilen veriler yalnızca bilimsel araştırma amacıyla kullanılmıştır.

Veri Ön İşleme Süreci

Makine öğrenmesi modellerinin doğru ve güvenilir sonuçlar üretebilmesi için veri setinin analiz öncesinde uygun şekilde hazırlanması gerekmektedir. Bu doğrultuda, çalışmada kullanılan veri seti veri ön işleme sürecinden geçirilmiştir.

Çalışmada kullanılan makine öğrenmesi algoritmalarının bazıları (örneğin DVM ve LR) değişken ölçeklerine duyarlı olduğundan, veri setine standardizasyon işlemi uygulanmıştır. Bu kapsamda değişkenler, ortalaması 0 ve standart sapması 1 olacak şekilde ölçeklendirilmiştir. Ölçekleme işlemi yalnızca eğitim verisi üzerinde öğrenilmiş ve aynı dönüşüm parametreleri test verisine uygulanmıştır.

Veri ön işleme süreci kapsamında ayrıca hedef değişken uygun biçimde kodlanarak modele hazır hale getirilmiştir. Hedef değişkenin “başarısız” ve “başarılı” sınıfları sırasıyla 0 ve 1 olarak temsil edilmiştir. Nominal yapıya sahip bölüm (department) ve barınma türü (residence_type) değişkenleri, kategoriler arasında yapay bir sıralama ilişkisi oluşmasını önlemek amacıyla one-hot encoding yöntemi ile temsil edilmiştir. İkili yapıdaki cinsiyet (gender) değişkeni binary kodlama ile modele dâhil edilirken, doğal sıralama içeren sınıf düzeyi (grade_level), anne eğitim düzeyi (mother_education) ve baba eğitim düzeyi (father_education) değişkenlerinde kategoriler arasındaki

sıralı yapı korunarak ordinal kodlama tercih edilmiştir. Diğer sürekli değişkenler ise mevcut sayısal yapıları korunarak modele doğrudan dâhil edilmiştir.

Makine Öğrenmesi Modelleri

Bu çalışmada, öğrencilerin akademik başarı durumlarını tahmin etmek amacıyla farklı modelleme yaklaşımlarını temsil eden dört makine öğrenmesi algoritması kullanılmıştır. Kullanılan modeller aşağıda açıklanmıştır.

LR, temel olarak bir veri örneğinin belirli bir sınıfa ait olma olasılığını tahmin etmek için kullanılır. En yaygın kullanım alanı, sonucun iki olası durumdan biri olduğu "ikili sınıflandırma" problemleridir (Géron, 2019).

RF, çok sayıda karar ağacının kolektif bir yapıda birleşmesiyle çalışan hem regresyon hem de sınıflandırma problemlerinde yüksek performans gösteren etkili bir topluluk öğrenmesi (ensemble learning) yöntemidir (Breiman, 2001). Algoritma, bootstrap örnekleme (bagging) ve rastgele öz nitelik seçimi mekanizmaları sayesinde çok sayıda karar ağacı oluşturur. Bu ağaçların çıktıları birleştirilerek tek bir karar ağacına kıyasla daha yüksek doğruluk ve daha güçlü genelleme yeteneğine sahip bir model elde edilir.

DVM, hem lineer hem de lineer olmayan sınıflandırma, regresyon ve aykırı değer belirleme işlemlerinde kullanılabilen, oldukça esnek ve etkili bir makine öğrenmesi algoritmasıdır. Özellikle yüksek karmaşıklığa sahip, küçük veya orta büyüklükteki veri kümelerinde sergilediği yüksek performansla öne çıkar (Géron, 2019).

XGB, makine öğrenmesinde sıkça kullanılan Gradyan Artırma (Gradient Boosting) algoritmasının optimize edilmiş, popüler ve yüksek performanslı bir uygulamasıdır (Géron, 2019; Raschka vd., 2022).

Bu algoritmaların birlikte kullanılması hem doğrusal hem de doğrusal olmayan ilişkilerin kapsamlı biçimde analiz edilmesine olanak tanımış ve akademik başarıyı etkileyen faktörlerin farklı modelleme perspektifleri çerçevesinde karşılaştırmalı olarak değerlendirilmesini mümkün kılmıştır.

Hiperparametre Optimizasyonu

Makine öğrenmesi modellerinin performansı, yalnızca kullanılan algoritmaya değil, aynı zamanda bu algoritmalara ait hiperparametrelerin doğru şekilde belirlenmesine de bağlıdır. Hiperparametreler, model eğitim sürecinde öğrenilmeyen ancak modelin davranışını doğrudan etkileyen parametrelerdir. Bu nedenle, uygun hiperparametre kombinasyonlarının belirlenmesi model performansını önemli ölçüde artırabilmektedir.

Bu çalışmada, kullanılan makine öğrenmesi algoritmalarının hiperparametrelerini optimize etmek amacıyla Grid Search ve Optuna olmak üzere iki farklı yöntem birlikte kullanılmıştır.

Grid Search yöntemi, önceden tanımlanmış bir hiperparametre arama uzayı içerisindeki tüm olası kombinasyonları sistematik olarak değerlendiren deterministik bir optimizasyon yaklaşımıdır. Bu yöntemde, her bir parametre kombinasyonu çapraz doğrulama süreci ile test edilmekte ve en yüksek performansı sağlayan parametre seti seçilmektedir. Grid Search yöntemi, arama uzayının tamamını kapsamaması nedeniyle güvenilir sonuçlar sunmakla birlikte, özellikle parametre sayısının ve aralıklarının geniş olduğu durumlarda hesaplama maliyetinin yüksek olması önemli bir sınırlılık olarak değerlendirilmektedir.

Optuna, hiperparametre optimizasyonu için geliştirilmiş, modern ve adaptif bir arama algoritmasıdır. Bu yöntem, Bayesian optimizasyon yaklaşımına benzer şekilde, önceki denemelerden elde edilen sonuçları kullanarak sonraki denemelerde daha umut verici hiperparametre kombinasyonlarını seçmektedir. Böylece arama süreci daha verimli hale gelmekte ve daha kısa sürede daha iyi sonuçlar elde edilebilmektedir. Optuna'nın en önemli avantajlarından biri, arama

sürecinde gereksiz denemeleri azaltarak hesaplama maliyetini düşürmesi ve geniş parametre uzaylarında daha etkin bir keşif sağlamasıdır.

Hiperparametre optimizasyon sürecinde veri seti, sınıf dağılımı korunacak şekilde (stratify = y) %80 eğitim ve %20 test verisi olarak ayrılmıştır. Tüm modellerde 5 katlı Stratified K-Fold çapraz doğrulama yapısı kullanılmış olup (n_splits = 5, shuffle = True, random_state = 42), hiperparametre optimizasyonunda değerlendirme ölçütü olarak F1 skoru esas alınmıştır. Grid Search sürecinde her model için önceden tanımlanan parametre aralıkları kullanılırken, Optuna optimizasyonunda her model için 15 deneme (n_trials = 15) gerçekleştirilmiştir. Çalışmada tekrarlanabilirliği sağlamak amacıyla veri bölme ve modelleme süreçlerinde random_state = 42 değeri kullanılmıştır. Nihai model seçiminde ise Grid Search ve Optuna yöntemleri arasında test veri setinde daha yüksek F1 skoru elde eden model tercih edilmiştir. Hiperparametre optimizasyon sürecinde kullanılan hiperparametre aralıkları Tablo 2’de sunulmuştur.

Tablo 2: Grid Search ve Optuna Süreçlerinde Kullanılan Hiperparametre Aralıkları

Model	Optimizasyon Yöntemi	Hiperparametre	Aralık / Değerler
LR	Grid Search	C	[0.01, 0.1, 1, 10]
	Optuna	class_weight	[None, balanced]
RF	Grid Search	C	0.01-10 (logaritmik)
		class_weight	[None, balanced]
	Optuna	n_estimators	[200, 300]
		max_depth	[None, 5, 10]
DVM	Grid Search	n_estimators	100-500
		max_depth	3-15
	Optuna	C	[0.1, 1, 10]
		kernel	[rbf, linear]
XGB	Grid Search	C	0.1-10 (logaritmik)
		kernel	[rbf, linear]
		n_estimators	[200, 300]
	Optuna	max_depth	[3, 5, 7]
		learning_rate	[0.01, 0.05, 0.1]
		n_estimators	100-500
		max_depth	3-9
		learning_rate	0.01-0.20

Model Performans Ölçütleri

Bu çalışmada geliştirilen makine öğrenmesi modellerinin performansları, sınıflandırma problemleri için literatürde yaygın olarak kullanılan çoklu değerlendirme ölçütleri kullanılarak analiz edilmiştir. Model performansının tek bir ölçüte dayalı olarak değerlendirilmesi yanıltıcı sonuçlara yol açabileceğinden, farklı yönleri ölçen birden fazla performans metriği birlikte ele alınmıştır.

Bu kapsamda modellerin performansı doğruluk, kesinlik, duyarlılık, F1 skoru ve ROC-AUC (Receiver Operating Characteristic-Area Under Curve) ölçütleri kullanılarak değerlendirilmiştir. Ayrıca her bir model için karışıklık matrisleri (confusion matrix) incelenerek doğru ve hatalı sınıflandırmaların dağılımı analiz edilmiştir.

Doğruluk, modelin toplam gözlemler içerisindeki doğru sınıflandırma oranını ifade etmektedir. Ancak sınıf dağılımının dengesiz olduğu durumlarda tek başına yeterli bir ölçüt olmayabileceğinden, diğer metriklerle birlikte değerlendirilmiştir.

Kesinlik, modelin “başarılı” olarak tahmin ettiği öğrenciler arasında gerçekten başarılı olanların oranını göstermektedir. Bu ölçüt, yanlış pozitif (false positive) hataların azaltılması açısından önem taşımaktadır.

Duyarlılık, gerçekte başarılı olan öğrencilerin ne kadarının model tarafından doğru şekilde tespit edildiğini ifade etmektedir. Bu metrik, özellikle başarı potansiyeli yüksek öğrencilerin kaçırlmaması açısından kritik öneme sahiptir.

F1 skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalaması olup, modelin genel performansını dengeli bir şekilde değerlendiren önemli bir ölçüttür. Bu çalışmada hiperparametre optimizasyon sürecinde temel değerlendirme ölçütü olarak F1 skoru kullanılmıştır.

ROC-AUC metriği, modelin farklı eşik değerleri altında sınıflar arasındaki ayırt edicilik gücünü ölçmektedir.

Karışıklık matrisi ise modelin doğru ve hatalı sınıflandırmalarını detaylı biçimde göstermekte; doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerler üzerinden model hatalarının dağılımını analiz etmeye olanak tanımaktadır.

Açıklanabilir Yapay Zekâ Analizi

Bu çalışmada makine öğrenmesi modeli geliştirilmesinin yanı sıra modelin karar mekanizmalarının anlaşılabilir ve yorumlanabilir olması hedeflenmiştir. Bu doğrultuda, en yüksek performansı sağlayan model üzerinde açıklanabilir yapay zekâ yöntemleri uygulanmıştır. Açıklanabilir Yapay Zekâ, modellerin karar süreçlerini açıklayarak güçlü ve zayıf yönlerini ortaya koyan ve gelecekteki davranışlarına ilişkin öngörü sunan yaklaşımları ifade etmektedir (Gunning & Aha, 2019). Bu çalışmada modelin açıklanabilirliğini sağlamak amacıyla iki farklı yaklaşım birlikte kullanılmıştır: SHAP ve LIME. Bu yöntemler, model kararlarının hem küresel (global) hem de yerel (local) düzeyde analiz edilmesine olanak sağlamaktadır.

SHAP yöntemi, oyun teorisine dayanan Shapley değerleri yaklaşımını kullanarak her bir değişkenin model çıktısına olan katkısını hesaplamaktadır. Bu yöntem, her bir özneliğin tahmin üzerindeki etkisini adil bir şekilde dağıtarak model kararlarının şeffaf biçimde yorumlanmasını sağlamaktadır (Mane vd., 2024). Bu çalışmada SHAP analizi iki düzeyde gerçekleştirilmiştir:

Küresel Açıklama: Modelin genel davranışı analiz edilerek hangi değişkenlerin akademik başarı üzerinde daha etkili olduğu belirlenmiştir. Bu analizde, her bir değişkenin ortalama mutlak SHAP değeri hesaplanmış ve değişken önem sıralaması elde edilmiştir.

Yerel Açıklama: Tekil gözlemler üzerinden modelin verdiği tahminler analiz edilmiştir. Bu sayede belirli bir öğrencinin neden “başarılı” veya “başarısız” olarak sınıflandırıldığı, hangi değişkenlerin bu kararı ne yönde etkilediği ortaya konmuştur.

SHAP yöntemi, modelden bağımsız bir açıklama sunması ve hem küresel hem de yerel düzeyde yorumlama imkânı sağlaması nedeniyle bu çalışmada temel açıklanabilirlik yöntemi olarak tercih edilmiştir.

LIME yöntemi, modelin belirli bir gözlem için verdiği tahmini, o gözlem çevresinde oluşturulan yerel bir doğrusal model ile açıklamayı amaçlamaktadır (Paul vd., 2025). Bu yaklaşım, karmaşık makine öğrenmesi modellerinin yerel davranışlarını daha basit ve anlaşılır bir model üzerinden yorumlamaya olanak sağlamaktadır.

Bu çalışmada LIME yöntemi, seçilen bireysel gözlemler için uygulanmış ve modelin tahmin kararlarının hangi değişkenler tarafından ne yönde etkilendiği analiz edilmiştir. Elde edilen sonuçlar, her bir değişkenin belirli bir gözlem üzerindeki katkısını ağırlık (weight) değerleri ile göstermektedir.

SHAP ve LIME yöntemlerinin birlikte kullanılması, modelin yalnızca hangi tahmini yaptığı değil, aynı zamanda bu tahmini neden yaptığı sorusuna da yanıt vermektedir. Bu kapsamda SHAP ve LIME sonuçlarının karşılaştırılması, elde edilen açıklamaların tutarlılığının değerlendirilmesine olanak sağlamaktadır. Bu durum, modelin güvenilirliğini artırmakta ve elde edilen bulguların daha sağlam bir temele dayandırılmasına katkı sunmaktadır. Ayrıca açıklanabilir yapay zekâ

yöntemlerinin kullanılması, makine öğrenmesi modellerinin “kara kutu” yapısını ortadan kaldırarak, model kararlarının şeffaf ve yorumlanabilir hale getirilmesine olanak sağlamaktadır.

Bulgular

Tanımlayıcı İstatistikler

Araştırma kapsamında katılımcıların demografik özellikleri incelenmiş ve bu özelliklere ilişkin frekans ve yüzde dağılımları hesaplanmıştır. Elde edilen bulgular Tablo 3'te sunulmaktadır.

Tablo 3: Katılımcıların Demografik Özellikleri

Değişken	Kategori	n	%
GNO (Başarı Durumu)	Başarılı	180	50.99
	Başarısız	173	49.01
Cinsiyet	Kadın	217	61.47
	Erkek	136	38.53
Bölüm	Finans ve Bankacılık	157	44.48
	Pazarlama	93	26.35
	Uluslararası Ticaret ve Lojistik	103	29.18
Sınıf Düzeyi	1. Sınıf	151	42.78
	2. Sınıf	83	23.51
	3. Sınıf	58	16.43
	4. Sınıf	61	17.28
Anne Eğitim	İlkokul	137	38.81
	Ortaokul	82	23.23
	Lise	91	25.78
Baba Eğitim	Üniversite	43	12.18
	İlkokul	111	31.44
	Ortaokul	73	20.68
	Lise	113	32.01
İkamet Türü	Üniversite	56	15.86
	Aile Evi	75	21.25
	Öğrenci Yurdu	212	60.06
	Diğer	66	18.70

Tablo 3'te araştırmaya katılan 353 öğrencinin demografik özellikleri sunulmaktadır. Katılımcıların akademik başarı durumları incelendiğinde, başarılı (%50.99, n=180) ve başarısız (%49.01, n=173) öğrencilerin dağılımının oldukça dengeli olduğu görülmektedir. Bu bulgu, analizlerde sınıflar arası karşılaştırmaların daha sağlıklı yapılabilmesine olanak sağlamaktadır.

Veri setinde “GNO” hedef değişken olarak kullanılmıştır. Hedef değişkenin dengeli sınıf dağılımına sahip olması (başarılı: %50.99; başarısız: %49.01), modelleme sürecinde sınıf dengesizliğine bağlı yanlılık riskini azaltmakta ve performans ölçütlerinin daha güvenilir biçimde değerlendirilmesine olanak sağlamaktadır.

Cinsiyet dağılımına bakıldığında, katılımcıların çoğunluğunu kadın öğrencilerin oluşturduğu (%61.47, n=217), erkek öğrencilerin ise %38.53 (n=136) oranında temsil edildiği görülmektedir.

Bölüm bazında incelendiğinde, en yüksek katılımın Finans ve Bankacılık bölümünden (%44.48, n=157) olduğu, bunu Uluslararası Ticaret ve Lojistik (%29.18, n=103) ve Pazarlama (%26.35, n=93) bölümlerinin izlediği görülmektedir.

Sınıf düzeyine göre dağılım incelendiğinde, katılımcıların büyük çoğunluğunun 1. sınıf öğrencilerinden (%42.78, n=151) oluştuğu, üst sınıflara doğru kademeli bir azalma olduğu görülmektedir.

Ebeveyn eğitim düzeyleri değerlendirildiğinde, annelerin büyük çoğunluğunun ilkokul mezunu olduğu (%38.81), bunu lise (%25.78) ve ortaokul (%23.23) mezunlarının izlediği görülmektedir. Benzer şekilde babaların eğitim düzeyinde de en yüksek oran lise (%32.01) ve ilkokul (%31.44) mezunlarında yoğunlaşmaktadır.

İkamet türü açısından incelendiğinde, katılımcıların büyük çoğunluğunun öğrenci yurdunda kaldığı (%60.06, n=212), aile yanında kalanların %21.25 (n=75) ve diğer barınma yerlerinde ise kalanların %18.70 (n=66) oranında olduğu görülmektedir.

Demografik özelliklerin ardından, araştırmada kullanılan sürekli değişkenlere ilişkin betimsel istatistikler analiz edilmiştir. Bu kapsamda değişkenlerin ortalama ve standart sapma değerleri hesaplanarak Tablo 4'te sunulmuştur.

Tablo 4: Sürekli Değişkenlere Ait Betimsel İstatistikler

Değişken	Min	Maks	Ortalama ($\bar{x}$)	SS
Yaş	17	27	19.90	1.74
Öz-Düzenleme	1.00	5.00	3.25	0.88
Akademik Motivasyon	1.80	5.00	4.17	0.68
Aktif Öğrenme	1.00	5.00	3.73	0.73
Akademik Katılım	1.00	5.00	3.76	0.76
Akademik İyi Oluş	1.00	5.00	2.99	0.92
Dijital Öğrenme Erişimi	2.50	5.00	4.26	0.61
Çevresel Destek	2.00	5.00	3.66	0.69
Çalışma Çabası	1.00	20.00	4.28	2.64
Ekran Süresi (saat)	1	12	6.48	2.24
Uyku Süresi (saat)	4	13	7.19	1.52
Sosyal Katılım	1	5	3.01	1.15

Tablo 4 incelendiğinde katılımcıların yaş ortalaması 19.90 (SS=1.74) olduğu görülmektedir. Öğrenme süreçlerine ilişkin değişkenler incelendiğinde, akademik motivasyon düzeyinin yüksek olduğu ($\bar{x}$ =4.17, SS=0.68) görülmektedir. Benzer şekilde dijital öğrenme erişimi de yüksek bir ortalamaya sahiptir ($\bar{x}$ =4.26, SS=0.61). Aktif öğrenme ($\bar{x}$ =3.73, SS=0.73), akademik katılım ($\bar{x}$ =3.76, SS=0.76) ve çevresel destek ($\bar{x}$ =3.66, SS=0.69) değişkenlerinin orta-üst düzeyde olduğu görülmektedir. Öz-düzenleme düzeyi ($\bar{x}$ =3.25, SS=0.88) orta seviyede olup, bireyler arasında görece daha yüksek bir değişkenlik göstermektedir. Akademik iyi oluş değişkeninin ortalaması ($\bar{x}$ =2.99, SS=0.92) diğer değişkenlere kıyasla daha düşük olup, öğrencilerin psikolojik ve akademik iyi oluş düzeylerinin görece sınırlı olduğunu göstermektedir. Davranışsal değişkenler incelendiğinde, çalışma çabası ortalaması 4.28 (SS=2.64) olup geniş bir dağılıma sahiptir. Bu bulgu, öğrencilerin ders çalışma yoğunluklarının oldukça heterojen olduğunu göstermektedir. Ekran süresi ortalaması günlük 6.48 saat (SS=2.24) olarak bulunurken, uyku süresi ortalaması 7.19 saat (SS=1.52) olarak hesaplanmıştır. Bu bulgular, öğrencilerin önemli bir kısmının yüksek ekran kullanımına sahip olduğunu göstermektedir. Son olarak sosyal katılım düzeyi ($\bar{x}$ =3.01, SS=1.15) orta seviyede olduğu görülmektedir.

Model Performanslarının Karşılaştırılması

Bu çalışmada üniversite öğrencilerinin akademik başarısını tahmin etmek amacıyla geliştirilen makine öğrenmesi modellerinin performansları doğruluk, kesinlik, duyarlılık, F1 skoru ve ROC-AUC ölçütleri kullanılarak değerlendirilmiştir. Model performanslarının hiperparametre optimizasyonundan bağımsız olarak değerlendirilmesi amacıyla, algoritmalar varsayılan parametre ayarları ile test edilmiştir. Bu kapsamda LR, RF, DVM ve XGB modelleri üzerinde 5 katlı çapraz doğrulama uygulanmış ve elde edilen performans sonuçları Tablo 5'te sunulmuştur.

Tablo 5: Modellerin 5 Katlı Çapraz Doğrulama Sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru	ROC-AUC
DVM	0.69	0.71	0.68	0.69	0.75
RF	0.68	0.69	0.71	0.69	0.76
XGB	0.65	0.66	0.65	0.65	0.73
LR	0.65	0.65	0.68	0.66	0.72

Elde edilen bulgular incelendiğinde RF ve DVM modellerinin diğer modellere kıyasla daha yüksek performans sergilediği görülmektedir. Özellikle RF modeli, en dengeli performansı sunarken, DVM modelinin doğruluk ve kesinlik değerlerinin görece yüksek olduğu dikkat çekmektedir. Buna karşılık, LR ve XGB modellerinin performanslarının daha sınırlı kaldığı gözlemlenmiştir.

Modellerin genellenebilirlik düzeylerinin daha ayrıntılı biçimde incelenebilmesi amacıyla, veri seti %80 eğitim ve %20 test olacak şekilde ikiye ayrılmış ve modeller bu ayrım üzerinden değerlendirilmiştir. Eğitim veri seti modelin öğrenme sürecinde kullanılırken, test veri seti modelin daha önce görmediği veriler üzerindeki performansını ölçmek amacıyla kullanılmıştır. Elde edilen bulgular Tablo 6'da sunulmaktadır.

Tablo 6: Eğitim ve Test Veri Setleri Üzerinde Model Performanslarının Karşılaştırılması

Model	Doğruluk		F1 Skoru		Kesinlik		Duyarlılık		ROC-AUC	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
LR	0.69	0.64	0.71	0.64	0.69	0.65	0.72	0.63	0.76	0.76
RF	1.00	0.76	1.00	0.76	1.00	0.77	1.00	0.75	1.00	0.82
DVM	0.90	0.76	0.90	0.77	0.91	0.73	0.88	0.83	0.94	0.80
XGB	1.00	0.66	1.00	0.68	1.00	0.65	1.00	0.72	1.00	0.73

Tablo 6 incelendiğinde, RF ve XGB modellerinin eğitim veri seti üzerinde çok yüksek performans değerlerine (Doğruluk = 1.00, F1 = 1.00) ulaştığı, ancak test veri setinde bu performansın belirgin biçimde düştüğü görülmektedir. Bu bulgu, söz konusu modellerin eğitim verisine aşırı uyum sağladığını göstermektedir.

Buna karşılık, DVM modelinin eğitim ve test performansları arasında daha dengeli bir yapı sergilediği görülmektedir. LR modelinin ise hem eğitim hem de test performanslarının görece düşük olması, modelin veri setindeki karmaşık ve doğrusal olmayan ilişkileri yeterince temsil edemediğini göstermektedir.

Varsayılan parametrelerle elde edilen başlangıç performanslarının ardından, modellerin performansını artırmak amacıyla hiperparametre optimizasyonu uygulanmıştır. Bu kapsamda veri seti %80 eğitim ve %20 test olacak şekilde ayrılmıştır. Hiperparametre optimizasyon sürecinde 5 katlı çapraz doğrulama yöntemi kullanılmış ve nihai model seçiminde F1 skoru temel alınmıştır. Modellerin performansı, eğitim sürecinden bağımsız olarak daha önce görülmemiş test verisi üzerinde değerlendirilmiştir. Bu yaklaşım, elde edilen sonuçların genellenebilirliğini artırmayı amaçlamaktadır. Ayrıca her model için hiperparametre optimizasyonunda Grid Search ve Optuna yöntemleri karşılaştırılmıştır. Buna göre daha yüksek F1 skoru sağlayan yöntem ilgili model için tercih edilmiştir. Elde edilen sonuçlar Tablo 7'de sunulmaktadır.

Tablo 7: Hiperparametre Optimizasyonu Sonrası Model Performansları

Model	Yöntem	Doğruluk	F1 Skoru	Kesinlik	Duyarlılık	ROC-AUC
RF	Grid Search	0.78	0.79	0.78	0.80	0.81
DVM	Optuna	0.76	0.77	0.74	0.80	0.80
XGB	Grid Search	0.73	0.72	0.75	0.69	0.77
LR	Grid Search	0.66	0.68	0.65	0.72	0.76

Tablo 7 incelendiğinde, genel olarak modellerin performanslarının arttığı görülmektedir. Bu modeller arasında RF modelinin en yüksek genel performansı sergilediği dikkat çekmektedir. RF modeli, doğruluk (0.78) ve F1 skoru (0.79) açısından diğer modellere kıyasla daha başarılı sonuçlar üretmiştir. Ayrıca kesinlik (0.78) ve duyarlılık (0.80) değerlerinin birbirine oldukça yakın olması, modelin hem pozitif sınıfı doğru tahmin etme hem de gerçek pozitifleri yakalama açısından dengeli bir performans sunduğunu göstermektedir. ROC-AUC değerleri incelendiğinde, RF (0.81) ve DVM (0.80) modellerinin en yüksek ayırt edicilik performansını sergilediği görülmektedir. XGB (0.77) ve LR (0.76) modelleri ise görece daha düşük performans sunmaktadır. Bu bulgular, RF modelinin genel performansın yanı sıra sınıflar arası ayırım gücü açısından da en başarılı model olduğunu göstermektedir.

DVM modeli, doğruluk (0.76) ve F1 skoru (0.77) bakımından RF modelinin gerisinde kalmakla birlikte, duyarlılık değeri (0.80) RF ile aynıdır. Bu bulgu, DVM modelinin pozitif sınıfa ait örnekleri yakalama konusunda oldukça başarılı olduğunu göstermektedir. Ancak kesinlik değerinin (0.74) daha düşük olması, modelin yanlış pozitif üretme eğiliminin RF modeline kıyasla daha yüksek olabileceğini düşündürmektedir. Bu bulgu, DVM modelinin pozitif sınıfın tespit edilmesinin öncelikli olduğu uygulamalar açısından potansiyel bir alternatif olabileceğini düşündürmektedir.

XGB modeli orta düzeyde bir performans sergilemiştir. Kesinlik değerinin (0.75) görece yüksek olmasına rağmen duyarlılık değerinin (0.69) daha düşük olması, modelin daha seçici davrandığını ve bazı gerçek pozitif örnekleri kaçırdığını göstermektedir. Bu bulgu, yanlış negatif oranının artabileceğine işaret etmekte ve özellikle duyarlılığın önemli olduğu uygulamalarda sınırlılık oluşturabileceğini düşündürmektedir.

LR modeli ise tüm performans ölçütleri açısından en düşük sonuçları vermiştir (Doğruluk = 0.66, F1 = 0.68). Bu bulgu, veri setindeki ilişkilerin doğrusal varsayımlar ile yeterince temsil edilemediğini ve daha karmaşık, doğrusal olmayan modellerin daha başarılı sonuçlar ürettiğini göstermektedir.

Doğruluk ve F1 skoru birlikte ele alındığında RF modelinin en dengeli ve yüksek performansı sunduğu, DVM modelinin ise özellikle duyarlılık açısından güçlü bir alternatif oluşturduğu sonucuna ulaşılmaktadır. Bu doğrultuda, genel sınıflandırma performansı öncelikli olduğunda RF modeli öne çıktığı görülmektedir.

Model performanslarının karşılaştırılmasının ardından, her bir algoritma için en yüksek performansı sağlayan hiperparametre kombinasyonları incelenmiş ve ilgili sonuçlar Tablo 8’de sunulmuştur.

Tablo 8: Optimize Edilmiş Model Hiperparametreleri

Model	Yöntem	Hiperparametreler
RF	Grid Search	max_depth = 5, n_estimators = 200
DVM	Optuna	C = 0.118, kernel = rbf
XGB	Grid Search	learning_rate = 0.01, max_depth = 3, n_estimators = 300
LR	Grid Search	C = 0.01, class_weight = balanced

Tablo 8’de, F1 skoru ölçütü esas alınarak hiperparametre optimizasyonu sonucunda her bir model için en iyi performansı sağlayan hiperparametre değerleri sunulmuştur. Tablo 8 incelendiğinde, Grid Search ve Optuna yöntemlerinin farklı modeller üzerinde farklı düzeylerde etkili olduğu görülmektedir. Grid Search yöntemi özellikle RF ve XGB modellerinde tercih edilirken, DVM modelinde Optuna ile daha esnek bir parametre arama süreci gerçekleştirilmiştir. Elde edilen parametre değerleri, modellerin veri setine özgü en uygun yapılandırmalarını yansıtmaktadır. Ancak genel olarak değerlendirildiğinde, her iki yöntemin birlikte kullanılması model performansının daha kapsamlı biçimde optimize edilmesine katkı sağlamıştır.

Hiperparametre optimizasyonu sonrasında RF (0.78 doğruluk, 0.79 F1 skoru, 0.81 ROC-AUC) modelinin akademik başarıyı tahmin etmede en yüksek ve dengeli performansı sergilediği görülmektedir.

Model performanslarının genel değerlendirilmesinin ardından, modellerin doğru ve hatalı sınıflandırma örüntülerini daha ayrıntılı analiz edebilmek amacıyla test verisi üzerinden elde edilen her bir algoritmaya ait karışıklık matrisleri Tablo 9'da sunulmuştur.

Tablo 9: Karışıklık Matrisi Sonuçları


Model	Doğru Negatif (TN)	Yanlış Pozitif (FP)	Yanlış Negatif (FN)	Doğru Pozitif (TP)
LR	21	14	10	26
RF	27	8	7	29
DVM	25	10	7	29
XGB	27	8	11	25

Tablo 9'a göre RF modeli düşük FP ve FN değerleri ile en dengeli performansı sunmaktadır. DVM benzer TP değerine sahip olmakla birlikte hata oranları biraz daha yüksektir. XGB modeli yüksek FN değeri nedeniyle pozitif sınıfı kaçırma eğilimi gösterirken, LR modeli en yüksek hata oranları ile en düşük performansı sergilemektedir.

SHAP Küresel Bulguları

Bu çalışmada, en yüksek performans gösteren RF modelinin karar mekanizmasını küresel düzeyde açıklamak amacıyla SHAP yöntemi kullanılmıştır. SHAP analizi, model tahminlerine her bir değişkenin katkısını nicel olarak ortaya koyarak değişken önem sıralamasını ve etkilerin yönünü analiz etmeye olanak sağlamaktadır.

Bu kapsamda elde edilen SHAP bulguları Şekil 2'de sunulmaktadır. Şekil 2(a)'da değişkenlerin ortalama mutlak SHAP değerlerine göre önem sıralaması verilmiş, Şekil 2(b)'de ise değişkenlerin model çıktısı üzerindeki etkilerinin yönü ve dağılımı gösterilmiştir.



Şekil 2: SHAP Küresel Açıklama Sonuçları: (a) Değişken Önem Sıralaması, (b) SHAP Özet Grafiği

Şekil 2(a) incelendiğinde, modelin tahmin performansında en etkili değişkenin sınıf düzeyi olduğu görülmektedir. Bu değişkeni sırasıyla akademik katılım, çevresel destek, öz-düzenleme ve akademik motivasyon izlemektedir.

Şekil 2(b)'de sunulan SHAP özet grafiği, değişkenlerin yalnızca önem düzeylerini değil, aynı zamanda model çıktısı üzerindeki etkilerinin yönünü de ortaya koymaktadır. Grafikte kırmızı renk yüksek, mavi renk ise düşük değişken değerlerini temsil etmektedir. Sınıf düzeyi hizasındaki mavi noktaların sağda, kırmızı noktaların solda yoğunlaşması, düşük sınıf düzeylerinin model çıktısını pozitif yönde, yüksek sınıf düzeylerinin ise negatif yönde etkilediğini göstermektedir. Buna göre, model düşük sınıf düzeyindeki öğrencileri “başarılı” sınıfına daha yakın değerlendirirken, sınıf düzeyi yükseldikçe tahminin “başarısız” yönüne kayma eğilimi artmaktadır. Bu bulgu, veri setinde alt sınıflardaki öğrencilerin akademik başarı bakımından daha avantajlı bir profile sahip olabileceğini ya da sınıf düzeyi arttıkça akademik yük, ders zorluğu ve performans baskısı gibi unsurların başarı olasılığını azaltıcı yönde etkide bulunduğunu düşündürmektedir. Bununla birlikte, elde edilen bu bulgunun örneklem yapısından kaynaklanan bir yanlılık içerme olasılığı da göz önünde bulundurulmalıdır. Araştırma örnekleminin önemli bir bölümünü (%42.78) birinci sınıf öğrencilerinin oluşturması, modelin öğrenme sürecinde bu gruba ait örüntülerin daha baskın hale gelmesine neden olmuş olabilir.


Akademik katılım, öz-düzenleme ve akademik motivasyon değişkenlerinin ise yüksek değerlerinin model çıktısını pozitif yönde etkilediği, düşük değerlerinin ise başarı olasılığını azalttığı gözlemlenmektedir. Bazı değişkenlerin ise etkisinin sınırlı olduğu görülmektedir. Özellikle dijital öğrenmeye erişim, yaş ve baba eğitim düzeyi gibi değişkenlerin SHAP değerlerinin düşük olması, bu değişkenlerin model karar sürecine görece daha az katkı sağladığını göstermektedir.

SHAP analizleri modelin kararlarının büyük ölçüde öğrencilerin akademik davranışları, öğrenme süreçlerine katılım düzeyi ve çevresel destek faktörleri tarafından şekillendiğini ortaya

koymaktadır. Bu bulgu, akademik başarının yalnızca bireysel özelliklerle değil, aynı zamanda öğrenme ortamı ve davranışsal faktörlerle de yakından ilişkili olduğunu göstermektedir.

SHAP Yerel Bulguları

Modelin yerel düzeyde karar mekanizmasını analiz etmek amacıyla SHAP yöntemi kullanılarak yerel açıklamalar elde edilmiştir. Bu kapsamda veri setinden; tipik bir başarılı öğrenci, tipik bir başarısız öğrenci ve karar sınırına yakın bir öğrenci olmak üzere üç farklı gözlem seçilmiştir. Böylece modelin yalnızca tek bir gözlem üzerindeki karar süreci değil, farklı öğrenci profilleri üzerindeki açıklama örüntüleri karşılaştırmalı olarak değerlendirilmiştir.




Şekil 3: SHAP Şelale Grafiği ile Yerel Açıklama

Şekil 3(a)'da yer alan tipik başarılı öğrenci, model tarafından doğru biçimde “başarılı” sınıfında tahmin edilmiş olup “başarılı” sınıfına ait olasılık değeri 0.856 olarak hesaplanmıştır. Bu gözlemlerde akademik katılım, öz-düzenleme, akademik motivasyon, çevresel destek ve akademik iyi oluş değişkenlerinin pozitif katkı sağlayarak öğrenciyi “başarılı” sınıfına yaklaştırdığı görülmektedir. Özellikle akademik katılımın yüksek düzeyde olması, model kararında en belirgin pozitif etkiyi oluşturmuştur. Buna karşılık sınıf düzeyi ve çalışma çabası değişkenlerinin sınırlı düzeyde negatif katkı ürettiği gözlemlenmektedir.

Şekil 3(b)'de yer alan tipik başarısız öğrenci için modelin “başarılı” sınıfına ait olasılık tahmini 0.277'dir. Bu gözlemlerde sınıf düzeyi, çevresel destek, çalışma çabası ve akademik katılım değişkenleri negatif katkı sağlayarak öğrencinin “başarısız” sınıfına yönelmesinde etkili olmuştur. Özellikle sınıf düzeyinin negatif etkisi, bu gözlemlerde model kararını belirleyen temel unsur olarak öne çıkmaktadır. Bununla birlikte anne eğitim düzeyi, dijital öğrenmeye erişim değişkenlerinin sınırlı düzeyde pozitif katkı sağladığı görülmektedir.

Şekil 3(c)'de ise karar sınırına yakın öğrenci, model tarafından “başarılı” sınıfında tahmin edilmiş olup “başarılı” sınıfına ait olasılık değeri 0.533 olarak hesaplanmıştır. Bu değer karar sınırı olan 0.50'ye oldukça yakındır. Sınıf düzeyi ve akademik katılım değişkenleri pozitif yönde katkı sağlarken; uyku süresi, akademik motivasyon, çevresel destek ve ekran süresi değişkenleri negatif yönde katkı üretmiştir. Ayrıca bölümlere ait değişkenlerin de model çıktısı üzerinde sınırlı düzeyde etkili olduğu görülmektedir. Bu bulgu, öğrencinin başarı ve başarısızlık sınıfları arasında hassas bir konumda yer aldığını ve küçük değişikliklerin model tahminini değiştirebileceğini göstermektedir.

Genel olarak değerlendirildiğinde, üç farklı gözlemlerde de model kararlarının tek bir değişkene bağlı olarak değil; akademik katılım, sınıf düzeyi, öz-düzenleme, motivasyon ve çevresel destek gibi birden fazla değişkenin birlikte etkisiyle oluştuğu görülmektedir. Bu bulgu, akademik başarının çok boyutlu yapısını desteklemekte ve SHAP yerel açıklamalarının model kararlarını bireysel düzeyde yorumlamaya katkı sağladığını göstermektedir.




Şekil 4: SHAP Kuvvet Grafiği ile Yerel Açıklama

Şekil 4’te yer alan SHAP kuvvet grafiği, aynı gözlem için değişkenlerin model çıktısını hangi yönde etkilediğini bütüncül bir yapı içerisinde göstermektedir. Grafikte kırmızı renkli değişkenler tahmin üzerinde pozitif, mavi renkli değişkenler ise negatif etkiyi temsil etmektedir. Bu doğrultuda, sınıf düzeyi, akademik katılım ve bölüm kategorilerinden uluslararası ticaret ve lojistik bölümü (department_3) ve finans ve bankacılık bölümü (department_1) değişkeninin pozitif yönde katkı sağlayarak gözlemi “başarılı” sınıfına yaklaştırdığı görülmektedir. Buna karşılık uyku süresi, akademik motivasyon, çevresel destek ve ekran süresi değişkenlerinin negatif yönde katkı sağlayarak gözlemi “başarısız” sınıfına yaklaştırdığı görülmektedir.

SHAP yerel analizleri modelin kararlarının çoklu değişken etkileşimleri sonucunda oluştuğunu açık biçimde ortaya koymaktadır. Bu bulgu, akademik başarının tek bir faktörle açıklanamayacağını, bireysel ve çevresel değişkenlerin birlikte değerlendirilmesi gerektiğini göstermektedir. Ayrıca, modelin doğru sınıflandırma yapmasına rağmen başarı olasılığının sınır değere yakın olması (0.53), bu gözlemin karar sınırına yakın bir profil sergilediğini ve küçük değişikliklerin sınıf tahminini değiştirebileceğini göstermektedir.

LIME Yerel Bulguları

Modelin yerel düzeyde karar mekanizmasını farklı bir açıklanabilir yapay zekâ yöntemi ile incelemek amacıyla LIME yöntemi uygulanmıştır. LIME analizi, modelin belirli bir gözlem için verdiği kararın, ilgili değişkenlerin hangi aralıklarında nasıl şekillendiğini yerel doğrusal bir yaklaşım ile açıklamaktadır. Bu kapsamda SHAP analizinde kullanılan gözlemler ile tutarlılığı sağlamak amacıyla aynı üç gözlem üzerinde analiz gerçekleştirilmiştir. Böylece model kararlarının farklı açıklanabilir yapay zekâ yöntemleri ile karşılaştırmalı olarak değerlendirilmesi mümkün hale getirilmiştir. LIME yerel açıklama grafiği Şekil 5’te sunulmuştur.



Şekil 5: LIME Yerel Açıklama Grafiği

Şekil 5’te sunulan LIME sonuçları, her bir gözlem için değişkenlerin model tahminine olan katkılarını göstermektedir. Grafikte yeşil renkli değişkenler tahmini “başarılı” sınıfına yaklaştıran, kırmızı renkli değişkenler ise “başarısız” sınıfına yönlendiren etkileri temsil etmektedir.

Şekil 5(a)’da yer alan tipik başarılı öğrenci incelendiğinde, akademik katılım (academic_engagement > 4.38), öz-düzenleme (self_regulated_learning > 3.50) ve akademik motivasyon (academic_motivation > 4.55) değişkenlerinin pozitif katkılar sağlayarak öğrenciyi “başarılı” sınıfına yönlendirdiği görülmektedir. Ayrıca ikamet türüne ilişkin öğrencinin aile yanında

barınması ($\text{residence_type_1} \leq 0.00$), baba eğitim düzeyi ($\text{father_education} > 3.00$), uyku süresi ($7.00 < \text{sleep_duration} \leq 8.00$) ve sosyal katılım ($3.00 < \text{social_participation} \leq 4.00$) değişkenleri de modele pozitif yönde katkı sağlamaktadır. Buna karşılık, sınıf düzeyinin yüksek olması ($\text{grade_level} > 3.00$), uluslararası ticaret ve lojistik bölümü (department_3) ve ekran süresi ($\text{screen_time} \leq 5.00$) değişkenlerinin negatif katkı ürettiği görülmektedir. Bu bulgular, öğrencinin “başarılı” sınıfına yönelmesinde özellikle akademik katılım, öz-düzenleme ve motivasyon değişkenlerinin belirleyici olduğunu göstermektedir.

Şekil 5(b)'de sunulan tipik başarısız öğrenci için LIME sonuçları, sınıf düzeyinin yüksek olması ($\text{grade_level} > 3.00$) ve akademik katılımın düşük seviyede olması ($\text{academic_engagement} \leq 3.50$) gibi faktörlerin model tahminini “başarısız” yönünde etkilediğini göstermektedir. Ayrıca orta düzey öz-düzenleme ($2.83 < \text{self_regulated_learning} \leq 3.33$), düşük baba eğitim düzeyi ($\text{father_education} \leq 1.00$) ve yüksek çalışma çabası ($\text{study_effort} > 5.50$) değişkenlerinin de negatif katkı ürettiği görülmektedir. Buna karşılık, öğrencinin aile yanında barınması ($\text{residence_type_1} \leq 0.00$), uluslararası ticaret ve lojistik ($\text{department_3} \leq 0.00$), $0.00 < \text{finans ve bankacılık bölümü} (\text{department_1}) \leq 1.00$, düşük anne eğitim düzeyi ($\text{mother_education} \leq 1.00$) ve düşük aktif öğrenme düzeyi ($\text{active_learning} \leq 3.50$) değişkenlerinin model çıktısına sınırlı düzeyde pozitif katkı sağladığı gözlemlenmektedir. Genel olarak değerlendirildiğinde, özellikle yüksek sınıf düzeyi ve düşük akademik katılımın bu gözlemlerde model kararını belirleyen temel unsurlar olduğu anlaşılmaktadır.

Şekil 5(c)'de yer alan “başarılı” olarak sınıflandırılmış ve sınır değere yakın öğrenci için LIME sonuçları incelendiğinde, düşük sınıf düzeyi ($\text{grade_level} \leq 1.00$) ve yüksek akademik katılımın ($\text{academic_engagement} > 4.38$) öğrenciyi “başarılı” sınıfına yönlendiren en güçlü pozitif değişkenler olduğu görülmektedir. Bunun yanı sıra, uluslararası ticaret ve lojistik bölümü ($\text{department_3} \leq 0.00$), öğrencinin aile yanında barınması ($\text{residence_type_1} \leq 0.00$), $0.00 < \text{finans ve bankacılık bölümü} (\text{department_1}) \leq 1.00$ ve $\text{gender} \leq 0.00$ değişkenleri de sınırlı düzeyde pozitif katkı sağlamaktadır. Buna karşılık, düşük uyku süresi ($\text{sleep_duration} \leq 6.00$), düşük akademik motivasyon ($\text{academic_motivation} \leq 4.00$), düşük öz-düzenleme ($\text{self_regulated_learning} \leq 2.83$) ve ekran süresi ($\text{screen_time} \leq 5.00$) değişkenlerinin model çıktısını negatif yönde etkilediği gözlemlenmektedir. Bu bulgular, öğrencinin karar sınırına yakın bir profilde bulunduğunu ve pozitif ile negatif etkilerin birbirine oldukça yakın düzeyde gerçekleştiğini göstermektedir.

Genel olarak değerlendirildiğinde, LIME analizleri model kararlarının belirli değişken aralıkları üzerinden şekillendiğini ortaya koymakta ve SHAP bulgularını destekler nitelikte benzer değişkenlerin öne çıktığını göstermektedir. Bu bulgu, iki farklı açıklanabilir yapay zekâ yönteminin tutarlı sonuçlar ürettiğini ve modelin yerel karar mekanizmasının güvenilir biçimde yorumlanabileceğini ortaya koymaktadır.

Sonuçlar ve Tartışma

Bu çalışmada, üniversite öğrencilerinin akademik başarılarının makine öğrenmesi yöntemleri ile tahmin edilmesi ve model kararlarının açıklanabilir yapay zekâ ile yorumlanması amaçlanmıştır. Elde edilen bulgular, akademik başarının çok boyutlu bir yapı sergilediğini ve bu yapının doğrusal olmayan ilişkiler üzerinden daha etkili biçimde modellenebileceğini ortaya koymaktadır.

Makine öğrenmesi modellerinin performansları karşılaştırıldığında, hiperparametre optimizasyon sonrasında RF modelinin diğerler modellere göre yüksek performans sergilediği görülmüştür. Hiperparametre optimizasyonu sonrasında RF modeli %78 doğruluk ve 0.79 F1 skoru ile en dengeli sonuçları üretmiştir. Destek Vektör Makineleri (DVM) modeli ise %76 doğruluk ve 0.77 F1 skoru ile RF modelini takip etmiştir. Buna karşılık, XGBoost (%73 doğruluk, 0.72 F1) ve Lojistik Regresyon (%66 doğruluk, 0.68 F1) modellerinin daha düşük performans sergilediği belirlenmiştir. Literatürde, makine öğrenmesi ile akademik başarının tahmin edilmesine yönelik birçok çalışmada, ağaç tabanlı algoritmaların özellikle karmaşık ve büyük veri setlerinde güçlü ve

rekabetçi performans sergilediği raporlanmaktadır (Guevara-Reyes vd., 2025; Saqr, 2024; Sun vd., 2026; Wang & Luo, 2024). Bu bulgular, akademik başarıyı etkileyen değişkenler arasındaki ilişkilerin doğrusal olmaktan ziyade karmaşık ve etkileşimli bir yapıya sahip olduğunu göstermektedir.

Model performanslarının eğitim ve test veri setleri üzerindeki karşılaştırılması, bazı modellerde aşırı öğrenme probleminin ortaya çıktığını göstermiştir. Özellikle RF ve XGB modellerinin eğitim veri setinde %100 doğruluk ve F1 skoruna ulaşmasına rağmen test veri setinde performanslarının sırasıyla %76 ve %66 seviyelerine düşmesi, bu modellerin eğitim verisine aşırı uyum sağladığını göstermektedir. Buna karşılık, DVM modelinin eğitim (%90 doğruluk) ve test (%76 doğruluk) performansları arasında daha dengeli bir yapı sergilemesi, modelin genellenebilirlik açısından daha istikrarlı olduğunu ortaya koymaktadır. Bununla birlikte, nihai model seçimi yalnızca eğitim-test performans farkına dayalı olarak değil, çapraz doğrulama ve bağımsız test veri seti üzerindeki optimize edilmiş performans değerleri, sınıflandırma başarısının dengesi (kesinlik ve duyarlılık dengesi ve F1 skoru) dikkate alınarak gerçekleştirilmiştir. Bu kapsamda RF modelinin test veri seti üzerindeki daha yüksek doğruluk (0.78) ve F1 skoru (0.79) ile daha dengeli bir kesinlik-duyarlılık yapısı sunması, modelin uygulama bağlamında diğer modellere göre daha yüksek tahmin başarısı sağladığını göstermektedir.

Hiperparametre optimizasyonu sonrasında tüm modellerde performans artışı gözlemlenmiştir. Bu bulgu, uygun hiperparametre seçimlerinin model performansı üzerinde anlamlı bir etkiye sahip olduğunu göstermektedir (Dewi vd., 2025; Dhilsath & Samuel, 2021). Elde edilen bulgular, akademik başarı tahmini problemlerinde model performansının yalnızca algoritma seçimine bağlı olmadığını, aynı zamanda modelin veri setine özgü olarak yapılandırılmasının da kritik bir rol oynadığını ortaya koymaktadır.

Çalışmanın diğer boyutu, model sonuçlarının açıklanabilir yapay zekâ ile detaylı biçimde analiz edilmesidir. SHAP analizleri, akademik başarı tahmininde en etkili değişkenlerin sınıf düzeyi, akademik katılım, çevresel destek, öz-düzenleme ve akademik motivasyon olduğunu göstermiştir. Bu bulgular, akademik başarı üzerinde katılım, çalışma davranışları ve motivasyon gibi değişkenlerin belirleyici rolünü vurgulayan önceki çalışmalarla örtüşmektedir (Ahmed vd., 2025; Alkan, 2026; Cleary & Kitsantas, 2017; Morosanova vd., 2022; Wang & Holcombe, 2010). Bu bulgu, akademik başarının öğrencilerin öğrenme süreçlerine aktif katılımı ve içinde bulundukları çevresel koşullarla da yakından ilişkili olduğunu ortaya koymaktadır.

SHAP özet grafikleri, değişkenlerin yalnızca önem düzeylerini değil, aynı zamanda model çıktısı üzerindeki etkilerinin yönünü de ortaya koymuştur. Özellikle sınıf düzeyinin artmasının başarı olasılığı üzerinde negatif yönde bir etki oluşturmaktadır. Buna karşılık akademik katılım, öz-düzenleme ve akademik motivasyon düzeylerinin yüksek olmasının başarıyı artırıcı yönde etkide bulunduğu görülmüştür. Dijital öğrenmeye erişim, yaş ve ebeveyn eğitim düzeyi gibi bazı değişkenlerin model karar sürecine görece daha sınırlı katkı sağladığı belirlenmiştir.

Yerel düzeyde gerçekleştirilen SHAP ve LIME analizleri, model kararlarının farklı öğrenci profillerinde değişkenlerin ortak etkisiyle şekillendiğini göstermektedir. Tipik başarılı öğrenciye ilişkin bulgularda akademik katılım, öz-düzenleme, akademik motivasyon, çevresel destek ve akademik iyi oluş değişkenleri başarı tahminini güçlendiren temel faktörler olarak öne çıkmıştır. Buna karşılık tipik başarısız öğrenci gözleminde özellikle sınıf düzeyi, düşük akademik katılım ve çevresel destek gibi değişkenlerin model kararını başarısız sınıfa yönlendirdiği görülmüştür. Karar sınırına yakın gözlemde ise başarı olasılığının 0.533 olarak hesaplanması, bu öğrenci profilinde pozitif ve negatif değişken katkılarının birbirine yakın düzeyde olduğunu göstermektedir. Bu bulgu, bazı gözlemlerde model tahminlerinin kesin bir ayırmadan ziyade hassas bir dengeye dayandığını ve küçük değişken değişimlerinin sınıflandırma sonucunu etkileyebileceğini ortaya koymaktadır. SHAP ve LIME sonuçlarının benzer değişkenlere işaret etmesi, yerel açıklamaların tutarlılığını

desteklemekte ve modelin karar mekanizmasının yorumlanabilirliğini artırmaktadır. Bu kapsamda bulgular, akademik başarının yalnızca bireysel özelliklerle değil; akademik katılım, motivasyon, öz-düzenleme ve çevresel destek gibi çoklu faktörlerin birlikte etkisiyle açıklanabileceğini göstermektedir.

LIME analizi sonuçları da SHAP bulgularını destekler nitelikte olup, modelin karar sürecinde benzer değişkenlerin belirleyici olduğunu göstermiştir. Her iki yöntemin tutarlı sonuçlar üretmesi, modelin yorumlanabilirliğini ve elde edilen bulguların güvenilirliğini artırmaktadır (Sathyan vd., 2022). Bu durum, açıklanabilir yapay zekâ yöntemlerinin makine öğrenmesi modellerinin “kara kutu” yapısını ortadan kaldırarak karar süreçlerini daha şeffaf hale getirdiğini ortaya koymaktadır (Rane vd., 2024; Samek vd., 2021).

Genel olarak değerlendirildiğinde, akademik başarının tek bir değişkenle açıklanamayacağı, aksine bireysel, davranışsal ve çevresel faktörlerin etkileşimi sonucunda ortaya çıkan karmaşık bir yapı olduğu görülmektedir. Bu bulgu, eğitim süreçlerinin yalnızca akademik içerik üzerinden değil, aynı zamanda öğrencilerin öğrenme davranışları, motivasyon düzeyleri ve çevresel koşulları dikkate alınarak planlanması gerektiğini göstermektedir.

Bu çalışmanın bazı sınırlılıkları bulunmaktadır. Öncelikle veri seti, tek bir üniversitenin belirli bir fakültesinde öğrenim gören öğrencilerden elde edilmiştir. Bu durum, elde edilen bulguların genellenebilirliğini sınırlandırabilir. Veri toplama sürecinde kullanılan anket yöntemi, öz-bildirim temelli olduğundan yanlılık içerebilir. Bunun yanında çalışmada kullanılan tematik bileşik değişkenler için kapsamlı psikometrik geçerlik ve güvenirlik analizlerinin gerçekleştirilmemiş olması, ölçüm yapısına ilişkin önemli metodolojik sınırlılıklardan biri olarak değerlendirilmelidir.

Bununla birlikte, akademik başarı değişkeninin ikili sınıfa dönüştürülmesi, başarı düzeylerinin daha ayrıntılı analiz edilmesini sınırlandırmaktadır. Çalışmada kesitsel veri kullanılması, değişkenler arasındaki nedensel ilişkilerin ortaya konulmasına imkân vermemektedir. Ayrıca bazı modellerde gözlemlenen aşırı öğrenme problemi, veri setinin büyüklüğü ve yapısı ile ilişkili bir sınırlılık olarak değerlendirilebilir.

Gelecek araştırmalarda farklı üniversitelerden ve daha geniş örneklemelerden veri toplanarak model sonuçlarının genellenebilirliği artırılabilir. Ayrıca boylamsal veri kullanılarak akademik başarıyı etkileyen faktörlerin zaman içerisindeki değişimi incelenebilir.

Eğitim uygulamaları açısından, akademik katılım, öz-düzenleme ve motivasyon gibi değişkenlerin başarı üzerindeki belirleyici rolü dikkate alınarak öğrenci destek programlarının bu alanlara odaklanması önerilmektedir. Bunun yanı sıra, öğrencilerin çevresel ve sosyoekonomik koşullarının iyileştirilmesi, akademik başarıyı artırmaya yönelik önemli bir strateji olarak değerlendirilebilir.

Son olarak, açıklanabilir yapay zekâ yöntemlerinin makine öğrenmesi alanında daha yaygın kullanılması, yalnızca tahmin doğruluğunu incelemekle kalmayıp, aynı zamanda karar verme süreçlerinin daha şeffaf, yorumlanabilir ve veri temelli kararlar alınmasına katkı sağlayacaktır.

References

- Abdulrazagova, K., Kır, B., & Kocabıyık Çaşkurlu, S. (2025). From traditional methods to digitalization: The transformation of the ready-to-wear industry. *Turkish Studies*, 20(Ö1), 1-16. <https://doi.org/10.7827/TurkishStudies.80296>
- Ahmed, M. A. U., & Hamod, M. (2026). The effectiveness of using artificial intelligence models and active learning to assess hadith reading skills: Innovation and development / Hadis okuma becerisinin değerlendirilmesinde yapay zekâ modellerinin ve aktif öğrenmenin kullanım etkililiği: İnovasyon ve geliştirme. *Turkish Studies – Comparative Religious Studies*, 21(1), 1-48. <https://doi.org/10.7827/TurkishStudies.89106>
- Ahmed, W., Wani, M. A., Pławiak, P., Meshoul, S., Mahmoud, A., & Hammad, M. (2025). Machine learning-based academic performance prediction with explainability for enhanced decision-making in educational institutions. *Scientific Reports*, 15, Article 26879. <https://doi.org/10.1038/s41598-025-12353-4>
- Akyıldız, S. G., & Akyıldız, Y. (2020). Westworld dizisinde makine öğrenmesi: Cinsiyet eşitsizliğini yeniden üreten yapay zekâ yaratımları. *Turkish Studies*, 15(2), 999-1010. <https://doi.org/10.29228/TurkishStudies.41975>
- Alkan, A. (2026). Analysis of factors affecting academic success with machine learning: Data-driven inferences in education. *Turkish Journal of Engineering*, 10(1), 48-62. <https://doi.org/10.31127/tuje.1779491>
- Altındış, F. (2020). General evaluation on non-emotional investment method "algorithmic trading" and sample of algorithm study. *Turkish Studies*, 15(1), 23-34. <https://doi.org/10.29228/TurkishStudies.37827>
- Ardaturk, A. S. (2026). An analysis of the sector; digital interfaces and techniques used in the design offices / Bir sektör analizi: Tasarım ofislerinde kullanılan dijital arayüzler ve teknikler. *Turkish Studies*, 21(1), 143-197. <https://doi.org/10.7827/TurkishStudies.87841>
- Arduç Kara, E. (2026). Artificial intelligence fatigue, technostress and journalism: A conceptual literature review / Yapay zekâ yorgunluğu, teknostres ve gazetecilik: Kavramsal bir literatür taraması. *Turkish Studies*, 21(1), 199-235. <https://doi.org/10.7827/TurkishStudies.87954>
- Arğın, E. (2025). Ethics and artificial intelligence: Data privacy and algorithmic transparency in social sciences / Yapay zekâ ve etik: Sosyal bilimlerde veri gizliliği ve algoritmik şeffaflık. *Turkish Studies*, 21(2), 2111-2155. <https://doi.org/10.7827/TurkishStudies.86847>
- Arıcı, N., & Karacı, A. (2013). Türkçe öğrenimi için web tabanlı zeki öğretim sistemi (TÜRKZÖS) ve değerlendirmesi. *Turkish Studies*, 8(8), 65-87. <https://doi.org/10.7827/TurkishStudies.4878>
- Aşkun, V. (2024). ChatGPT gibi üretken yapay zekalar ile insan kaynakları yönetimi etkileşimi: Daha fazla çalışma için görüşler ve yollar. *Turkish Studies – Economics, Finance, Politics*, 19(2), 679-699. <https://doi.org/10.7827/TurkishStudies.75863>
- Baran, Z. (2022). Geleneksel yemeklerde dijital gastronomi vizyonu. *Turkish Studies*, 17(4), 685-703. <https://doi.org/10.7827/TurkishStudies.62028>
- Başar, F. (2025). The relationship between ChatGPT use, academic engagement, and life satisfaction: An empirical study in a faculty of tourism. *Turkish Studies*, 20(4), 2131-2144. <https://doi.org/10.7827/TurkishStudies.86796>
- Bayat Arslan, S., & Cuma, A. (2026). Local language and cultural gaps in AI-generated literary production: Turkish folk and German folk literature examples / Yapay zekâ edebî üretiminde

- yerel dil ve kültür boşlukları: Türk Halk ve Alman Halk Edebiyatı örnekleri. *Turkish Studies – Language and Literature*, 21(2), 2479-2558. <https://doi.org/10.7827/TurkishStudies.89780>
- Bekil, N. (2018). Transhumanism: Immortality & singularity in *Do Androids Dream of Electric Sheep?* & *The Transhumanist Wager*. *Turkish Studies – Social Sciences*, 13(18), 251-262. <https://doi.org/10.7827/TurkishStudies.13790>
- Boujmiraz, S., Darhmaoui, H., & Drissi El Maliani, A. (2026). Predicting student performance: A comprehensive review of machine learning, deep learning, and explainable AI approaches. *Computers and Education: Artificial Intelligence*, 10, Article 100548. <https://doi.org/10.1016/j.caeai.2026.100548>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32.
- Büyükboyacı, Ş., & Yozcu, Ö. (2026). The codes of mental transformation in education: A thematic analysis of graduate social studies students' perspectives on artificial intelligence / Eğitimde zihinsel dönüşümün kodları: Lisansüstü sosyal bilgiler öğrencilerinin yapay zekâya ilişkin görüşlerinin tematik analizi. *Turkish Studies*, 21(1), 623-665. <https://doi.org/10.7827/TurkishStudies.87753>
- Civelek, S. (2025). From tradition to dataset: Digital archiving of traditional artistic heritage and the ethical and epistemological consequences of its use as training data for artificial intelligence. *Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 26-43. <https://ais3journal.com>
- Cleary, T. J., & Kitsantas, A. (2017). Motivation and self-regulated learning influences on middle school mathematics achievement. *School Psychology Review*, 46(1), 88-107. <https://doi.org/10.1080/02796015.2017.12087607>
- Cohen, L., Manion, L., & Morrison, K. (2018). *Research methods in education* (8th ed.). Routledge Falmer. <https://doi.org/10.4324/9781315456539>
- Coşkun, O. (2025). "Les Indes Noires"ın Türkçe çevirileri: İnsan ve yapay zekâ çevirisinin karşılaştırılması. *Turkish Studies – Language and Literature*, 20(Ö1), 291-320. <https://doi.org/10.7827/TurkishStudies.88179>
- Credé, M., & Kuncel, N. R. (2008). Study habits, skills, and attitudes: The third pillar supporting collegiate academic performance. *Perspectives on Psychological Science*, 3(6), 425-453. <https://doi.org/10.1111/j.1745-6924.2008.00089.x>
- Çakmak, B. (2025). Duygusal tipografi: Yazı tiplerinin semantik potansiyeli ve görsel iletişimde yapay zekâ (DALL-E) yorumlaması. *Turkish Studies*, 20(Ö1), 191-214. <https://doi.org/10.7827/TurkishStudies.82281>
- Çark, Ö. (2020). İşletmelerin dijital dönüşüm sürecinde "nesnelerin interneti" teknolojisinin etkisi. *Turkish Studies – Economics, Finance, Politics*, 15(3), 1247-1266. <https://doi.org/10.47644/TurkishStudies.41888>
- Çelik, R., Çiçeklioğlu, H., & Yazıcı, A. M. (2025). Geleceği beslemek: Girişim sermayesinin yapay zeka hesaplama girişimleri ve sürdürülebilir yenilik üzerindeki etkisi. *Turkish Studies – Economics, Finance, Politics*, 20(4), 2191-2214. <https://doi.org/10.7827/TurkishStudies.82939>
- Çora, H., Mikail, E. H., & Çora, A. N. (2026). Algorithmic diplomacy: AI-assisted decision-making models and ethical boundaries in international relations / Algoritmik diplomasi: Yapay zekâ destekli karar alma modelleri ve uluslararası ilişkilerde etik sınırlar. *Turkish Studies*, 21(1), 801-850. <https://doi.org/10.7827/TurkishStudies.87722>

- Dalmış, E. (2026). AI performance in translating rich points: A comparative analysis of the ChatGPT, DeepSeek and Gemini / Çeviride zengin noktalar üzerinden yapay zekâ performansı: ChatGPT, DeepSeek ve Gemini sistemleri üzerine karşılaştırmalı bir inceleme. *Turkish Studies – Language and Literature*, 21(1), 681-727. <https://doi.org/10.7827/TurkishStudies.88767>
- Denizci, Ö. M., Kırık, A. M., & Çetinkaya, A. (2018). A learning-based approach to fuzzy logic in framework of philosophy of informatics. *Turkish Studies – Information Technologies & Applied Sciences*, 13(29), 47-59. <https://doi.org/10.7827/TurkishStudies.14730>
- Dewi, F., Wibowo, N. C. H., Handayani, M. R., & Umam, K. (2025). Evaluasi hyperparameter tuning pada support vector machine (SVM) dalam klasifikasi ulasan hotel di Tripadvisor. *JIPi (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 10(3), 2584-2593. <https://doi.org/10.29100/jipi.v10i3.7774>
- Dhilsath, F. M., & Samuel, S. J. (2021). Hyperparameter tuning of ensemble classifiers using grid search and random search for prediction of heart disease. In O. P. Jena, A. R. Tripathy, A. A. Elngar, & Z. Polkowski (Eds.), *Computational intelligence and healthcare informatics* (pp. 139-158). Wiley. <https://doi.org/10.1002/9781119818717.ch8>
- Doğru, A., & Hacımüftüoğlu, E. (2025). Tefsirde yapay zekâ uygulamalarının kullanımı: ChatGPT-4o, Google Gemini Advanced 1.5 Pro ile Microsoft Copilot'un karşılaştırması. *Turkish Studies – Comparative Religious Studies*, 20(4), 1867-1891. <https://doi.org/10.7827/TurkishStudies.87246>
- Efendioğlu, İ. H. (2023). Yapay zekâ pazarlaması: İnternette yapılan alışverişlerde yapay zekânın satın alma niyetine etkisi. *Turkish Studies – Economics, Finance, Politics*, 18(1), 133-153. <https://doi.org/10.7827/TurkishStudies.66785>
- Ekinci, E. (2025). Yerel yönetimlerde yapay zekâ algısı: Yozgat belediyesi örneği. *Turkish Studies – Economics, Finance, Politics*, 20(3), 1441-1467. <https://doi.org/10.7827/TurkishStudies.81663>
- Erdem, M. D., & Demiryakan, D. (2025). On language education, linguistic inequality, and linguistic justice. *Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 1-25. <https://ais3journal.com>
- Erdem, M. D., & Demiryakan, D. (2026). Responsibility, transparency, and disclosure in the use of generative artificial intelligence in Turkish-language academic writing. *Artificial Intelligence Studies in Society, Science, and Systems*, 2(1), 1-51. <https://ais3journal.com>
- Ertan, İ. F. (2026). Generative artificial intelligence in digital games / Dijital oyunlarda üretken yapay zekâ. *Turkish Studies*, 21(1), 1125-1161. <https://doi.org/10.7827/TurkishStudies.88191>
- Fan, X., & Chen, M. (2001). Parental involvement and students' academic achievement: A meta-analysis. *Educational Psychology Review*, 13(1), 1-22. <https://doi.org/10.1023/A:1009048817385>
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems* (2nd ed.). O'Reilly Media.
- Guanin-Fajardo, J. H., Guaña-Moya, J., & Casillas, J. (2024). Predicting academic success of college students using machine learning techniques. *Data*, 9(4), Article 60. <https://doi.org/10.3390/data9040060>
- Guevara-Reyes, R., Ortiz-Garcés, I., Andrade, R., Cox-Riquetti, F., & Villegas-Ch, W. (2025). Machine learning models for academic performance prediction: Interpretability and

- application in educational decision-making. *Frontiers in Education*, 10, Article 1632315. <https://doi.org/10.3389/feduc.2025.1632315>
- Gunning, D., & Aha, D. W. (2019). DARPA's explainable artificial intelligence program. *AI Magazine*, 40(2), 44-58. <https://doi.org/10.1609/aimag.v40i2.2850>
- Güçlüten, Ç. (2026). The securitization of cross-border migration movements: Digital solutions and their impacts on law enforcement agencies / Sınır ötesi göç hareketlerinin güvenlikleştirilmesi: Kolluk kuvvetlerinin dijital çözümleri ve etkileri. *Turkish Studies – Economics, Finance, Politics*, 21(2), 2773-2808. <https://doi.org/10.7827/TurkishStudies.88553>
- Günay, M. (2025). The role of the aesthetic value function in evolutionary art generation. *Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 44-67. <https://ais3journal.com>
- Güzel, K. (2024). Bir distopik bilim kurgu oyunu örneği olarak *Landscape with Weapon*'ın mühendislik etiği bağlamında incelenmesi. *Turkish Studies – Language and Literature*, 19(2), 617-638. <https://doi.org/10.7827/TurkishStudies.76479>
- Hashim, A. S., Awadh, W. A., & Hamoud, A. K. (2020). Student performance prediction model based on supervised machine learning algorithms. *IOP Conference Series: Materials Science and Engineering*, 928, Article 032019. <https://doi.org/10.1088/1757-899X/928/3/032019>
- Işık, M., & Darı, A. B. (2023). Yapay zeka film afişlerinin göstergebilimsel analizi: *Artificial Intelligence, Frank & Robot, Ex Machina* örneği. *Turkish Studies*, 18(1), 63-82. <https://doi.org/10.7827/TurkishStudies.64322>
- Kan Çelik, A. (2026). Once upon a code: The digital evolution of traditional narrative (artificial intelligence) / Bir varmış bir kodmuş - Geleneksel masal anlatısının dijital evrimi (yapay zekâ). *Turkish Studies – Language and Literature*, 21(2), 2607-2635. <https://doi.org/10.7827/TurkishStudies.88760>
- Kanat, E. (2020). Determination of optimum artificial neural network in the stock market. *Turkish Studies – Economics, Finance, Politics*, 15(1), 239-252. <https://doi.org/10.29228/TurkishStudies.4003>
- Karaağaç Cingöz, Z., Anlatan, Ö., Akşab, Ş., & Seggie, F. N. (2025). Akademik başarı ile psikososyal faktörler arasındaki ilişkinin incelenmesi: PISA 2018 örneği. *Uluslararası Türkçe Edebiyat Kültür Eğitim Dergisi*, 14(3), 980-1025.
- Karadağ, E. (2025). Kamusal alanda dijital destekli heykel uygulaması örneği: Blaundos heykel uygulaması. *Turkish Studies*, 20(3), 1609-1624. <https://doi.org/10.7827/TurkishStudies.86486>
- Karakuş, N., Eren Ökten, C., & Gedik, K. (2025). İki dillilik ve yapay zekâ: Diller ötesilik tespiti için kavramsal bir model önerisi. *Turkish Studies – Language and Literature*, 20(2), 1167-1188. <https://doi.org/10.7827/TurkishStudies.79747>
- Keleş, A. (2018a). Derin öğrenme ve sağlık alanındaki uygulamaları. *Turkish Studies – Information Technologies & Applied Sciences*, 13(21), 113-127. <https://doi.org/10.7827/TurkishStudies.14189>
- Keleş, A. (2018b). Dijital oyunlarda sonlu durum makineleri ve bulanık mantık. *Turkish Studies – Information Technologies & Applied Sciences*, 13(29), 73-82. <https://doi.org/10.7827/TurkishStudies.14651>
- Keleş, A., & Keleş, A. (2017). BİDEMAT - Zeki öğretim sistemi. *Turkish Studies*, 12(6), 547-564. <https://doi.org/10.7827/TurkishStudies.11547>

- Keleş, A., & Keleş, A. (2018). Nesnelerin internetinin getirdiği yenilikler ve sorunları. *Turkish Studies – Information Technologies & Applied Sciences*, 13(13), 53-66. <https://doi.org/10.7827/TurkishStudies.13872>
- Keleş, A., Keleş, A., & Akçetin, E. (2017). Pazarlama alanında yapay zekâ kullanım potansiyeli ve akıllı karar destek sistemleri. *Turkish Studies*, 12(11), 109-124. <https://doi.org/10.7827/TurkishStudies.12022>
- Kızıldağ, H. (2023). Yapay zekâ bir masal yaratıcısı/anlatıcısı olabilir mi?: ChatGPT masalları. *Turkish Studies – Language and Literature*, 18(3), 1759-1775. <https://doi.org/10.7827/TurkishStudies.71763>
- Koçakoğlu, M. A., & Koçakoğlu, Ö. (2025). Bir yapay zeka denemesi: BRICS-Türkiye ülkelerinin ortak para birimi "The Unit" in uygulanabilirliği üzerine bir analiz. *Turkish Studies – Economics, Finance, Politics*, 20(Ö1), 739-757. <https://doi.org/10.7827/TurkishStudies.83867>
- Köksal, O., & Zorlu Kale, B. N. (2025). Integration of technology in the teaching of English as a foreign language: A review study. *Turkish Studies*, 20(3), 2231-2240. <https://doi.org/10.7827/TurkishStudies.82557>
- Kyriazos, T., & Poga, M. (2024). Application of machine learning models in social sciences: Managing nonlinear relationships. *Encyclopedia*, 4(4), 1790-1805. <https://doi.org/10.3390/encyclopedia4040118>
- Mane, D., Magar, A., Khode, O., Koli, S., Bhat, K., & Korade, P. (2024). Unlocking machine learning model decisions: A comparative analysis of LIME and SHAP for enhanced interpretability. *Journal of Electrical Systems*, 20(2s), 598-613. <https://doi.org/10.52783/jes.1480>
- Mazlum, Ö., & Mazlum, F. M. (2025). Tasarımın dünü, bugünü, geleceği: Yapay Zekâ (YZ) çağında tasarımın kavramsal ve estetik dönüşümü. *Turkish Studies*, 20(3), 1721-1739. <https://doi.org/10.7827/TurkishStudies.86478>
- Metin, S. (2025). Öğrencilerin akademik not ortalamalarının makine öğrenmesi yöntemleri ile tahmini. *Adıyaman Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (50), 886-910. <https://doi.org/10.14520/adyusbd.1627396>
- Morosanova, V. I., Bondarenko, I. N., & Fomina, T. G. (2022). Conscious self-regulation, motivational factors, and personality traits as predictors of students' academic performance: A linear empirical model. *Psychology in Russia: State of the Art*, 15(4), 170-187. <https://doi.org/10.11621/pir.2022.0411>
- Nayak, P., Vaheed, S., Gupta, S., & Mohan, N. (2023). Predicting students' academic performance by mining the educational data through machine learning-based classification model. *Education and Information Technologies*, 28, 14611-14637. <https://doi.org/10.1007/s10639-023-11706-8>
- Odacıoğlu, C. (2022). Dijital dönüşümün mütercim tercümanlık bölümlerine yansımaları bağlamında "Çeviride bilgi teknolojileri ve araçları" adlı bir ders önerisi. *Turkish Studies – Language and Literature*, 17(4), 1367-1376. <https://doi.org/10.7827/TurkishStudies.62915>
- Ölçer, M. (2025). Yapay zekâ ile edebî metin çözümlemesi ve çeviri kalite değerlendirmesi: Modern Kore edebiyatı üzerine bir vaka analizi. *Turkish Studies – Language and Literature*, 20(4), 2931-2948. <https://doi.org/10.7827/TurkishStudies.87757>

- Önen, L. (2025). AI-supported image education in drawing: Adaptive learning environments - Personalized systems modeling student style development and generating feedback. *Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 68-81. <https://ais3journal.com>
- Özdemir, A. (2025a). Görsel sanatlarda yapay zekâ-dijital sanat. *Turkish Studies*, 20(4), 2585-2602. <https://doi.org/10.7827/TurkishStudies.87601>
- Özdemir, A. (2025b). Ontological and ethical boundaries in AI-based image restoration. *Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 82-95. <https://ais3journal.com>
- Özdemir, A. (2026). The intersection of digital art and artificial intelligence: New aesthetic paradigms and theoretical approaches / Dijital sanat ve yapay zekânın kesişimi yeni estetik paradigmlar ve kuramsal yaklaşımlar. *Turkish Studies*, 21(1), 1457-1486. <https://doi.org/10.7827/TurkishStudies.87600>
- Özdemir, F., Taş, A., Canbay, Y., & Utku, A. (2026). Makine öğrenmesi yöntemleri ile öğrenci akademik başarısının tahmin edilmesi. *Bingöl Üniversitesi Teknik Bilimler Dergisi*, 2026(1), 1-20. <https://doi.org/10.5281/zenodo.18670660>
- Paul, R., Sarker, S., El Aouifi, H., Hussain, S., Baruah, A. K., & Gaftandzhieva, S. (2025). Analyzing dropout of students and an explainable prediction of academic performance utilizing artificial intelligence techniques. *Frontiers in Education*, 10, Article 1698505. <https://doi.org/10.3389/educ.2025.1698505>
- Przybyś-Małaszczek, A., Antoniuk, I., Szymanowski, K., Kruk, M., & Kurek, J. (2023). Application of machine learning algorithms for tool condition monitoring in milling chipboard process. *Sensors*, 23(13), Article 5850. <https://doi.org/10.3390/s23135850>
- Rane, N. L., Rane, J., Mallick, S. K., & Kaya, Ö. (2024). Enhancing black-box models: Advances in explainable artificial intelligence for ethical decision-making. In J. Rane, S. K. Mallick, Ö. Kaya, & N. L. Rane (Eds.), *Future research opportunities for artificial intelligence in Industry 4.0 and 5.0* (pp. 136-180). Deep Science Publishing. https://doi.org/10.70593/978-81-981271-0-5_4
- Raschka, S., Liu, Y. H., & Mirjalili, V. (2022). *Machine learning with PyTorch and scikit-learn: Develop machine learning and deep learning models with Python*. Packt Publishing.
- Richardson, M., Abraham, C., & Bond, R. (2012). Psychological correlates of university students' academic performance: A systematic review and meta-analysis. *Psychological Bulletin*, 138(2), 353-387. <https://doi.org/10.1037/a0026838>
- Romya Bilgin, K., & Küçükşabanoğlu, Z. (2023). ABD'nin yeni güç stratejisinde yapay zekâ. *Turkish Studies – Economics, Finance, Politics*, 18(1), 273-289. <https://doi.org/10.7827/TurkishStudies.63490>
- Sakin, İ., & Türk, Z. (2025). Teknolojiye hazırlık düzeyi ve kullanım algılarının muhasebede yapay zekanın benimseme düzeyine etkilerinin tespiti. *Turkish Studies – Economics, Finance, Politics*, 20(2), 901-919. <https://doi.org/10.7827/TurkishStudies.79592>
- Samek, W., Montavon, G., Lapuschkin, S., Anders, C. J., & Müller, K. R. (2021). Explaining deep neural networks and beyond: A review of methods and applications. *Proceedings of the IEEE*, 109(3), 247-278. <https://doi.org/10.1109/JPROC.2021.3060483>
- Sandıkçı, Y. T., & Soy, S. (2026). Artificial intelligence and crisis communication: A qualitative analysis within the framework of the technology acceptance model (TAM) in public relations / Yapay zekâ ve kriz iletişimi: Halkla ilişkilerde teknoloji kabullenme modeli (TAM)

- bağlamında nitel bir analiz. *Turkish Studies*, 21(2), 3715-3787. <https://doi.org/10.7827/TurkishStudies.88029>
- Saqr, M., & López-Pernas, S. (2024). Why explainable AI may not be enough: Predictions and mispredictions in decision making in education. *Smart Learning Environments*, 11, Article 52. <https://doi.org/10.1186/s40561-024-00343-4>
- Sarıbaş, S. (2025). Yapay zekâ çağında mitin dijital mitosferdeki edebi yeniden yazımı: Kültürel bellek ve anlatısal dönüşümler. *Turkish Studies – Language and Literature*, 20(3), 1939-1962. <https://doi.org/10.7827/TurkishStudies.82517>
- Sathyan, A., Weinberg, A. I., & Cohen, K. (2022). Interpretable AI for bio-medical applications. *Complex Engineering Systems*, 2, Article 18. <https://doi.org/10.20517/ces.2022.41>
- Serçemeli, M. (2018). Muhasebe ve denetim mesleklerinin dijital dönüşümünde yapay zekâ. *Turkish Studies – Economics, Finance and Politics*, 13(30), 369-386. <https://doi.org/10.7827/TurkishStudies.14373>
- Sert, M. F. (2026). Exploring the determinants of global income inequality using an ensemble learning, explainable artificial intelligence, and causal inference-based methodology / Topluluk öğrenmesi, açıklanabilir yapay zekâ ve nedensel analiz tabanlı bir metodoloji ile küresel gelir eşitsizliğinin belirleyicilerinin keşfi. *Turkish Studies – Economics, Finance, Politics*, 21(2), 3523-3566. <https://doi.org/10.7827/TurkishStudies.87348>
- Sirin, S. R. (2005). Socioeconomic status and academic achievement: A meta-analytic review of research. *Review of Educational Research*, 75(3), 417-453. <https://doi.org/10.3102/00346543075003417>
- Sönmez, O., & Zengin, K. (2023). Süt sığırlarının buzağılama zamanının tahmininde makine öğrenme yöntemlerinin kullanımı çalışmaları üzerine bir değerlendirme. *Journal of New Results in Engineering and Natural Sciences*, (18), 27-39.
- Sun, H., Jiang, Y., & Tang, X. (2026). Artificial intelligence-driven academic performance early warning system for engineering universities: Application of XGBoost-SHAP algorithm. *International Journal of High Speed Electronics and Systems*, 35(4), Article 2540536. <https://doi.org/10.1142/S0129156425405364>
- Tao, Y., Meng, Y., Gao, Z., & Yang, X. (2022). Perceived teacher support, student engagement, and academic achievement: A meta-analysis. *Educational Psychology*, 42(4), 401-420. <https://doi.org/10.1080/01443410.2022.2033168>
- Tetik Küçükkelçi, D. (2025). The mediating role of AI anxiety in the relationship between psychological resilience and social appearance anxiety. *Turkish Studies*, 20(3), 1943-1959. <https://doi.org/10.7827/TurkishStudies.80498>
- Tuğcu, M. S. (2025). Sinemada posthümanizmin ve yapay zekânın temsili: M3GAN filmi örneği. *Turkish Studies*, 20(4), 2821-2839. <https://doi.org/10.7827/TurkishStudies.87416>
- Uygun, S. V. (2026). The use of artificial intelligence in public services related to public order and security: Country examples and recommendations for Türkiye / Asayiş ve güvenlik yönlü kamu hizmetlerinde yapay zeka kullanımı: Ülke örnekleri ve Türkiye için öneriler. *Turkish Studies*, 21(2), 3789-3825. <https://doi.org/10.7827/TurkishStudies.89247>
- Varol, M. (2025). İlahi imge ve teknolojik insan: Transhümanizm ile dinî geleneklerin Kur'an kursu öğreticileri perspektifinden incelenmesi. *Turkish Studies – Religion*, 20(4), 2291-2308. <https://doi.org/10.7827/TurkishStudies.87056>

- Wang, M.-T., & Holcombe, R. (2010). Adolescents' perceptions of school environment, engagement, and academic achievement in middle school. *American Educational Research Journal*, 47(3), 633-662. <https://doi.org/10.3102/0002831209361209>
- Wang, S., & Luo, B. (2024). Academic achievement prediction in higher education through interpretable modeling. *PLOS ONE*, 19(9), Article e0309838. <https://doi.org/10.1371/journal.pone.0309838>
- Yağcı, M. (2022). Educational data mining: Prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 9, Article 11. <https://doi.org/10.1186/s40561-022-00192-z>
- Yener, S., & Köse, İ. (2023). Treatment prediction using artificial intelligence-integrated chatbots in call centers in medical tourism. *Turkish Studies – Economics, Finance, Politics*, 18(2), 583-597. <https://doi.org/10.7827/TurkishStudies.67267>
- Yıldırım Altun, C. (2025). Geçmiş geleceğe aktarmak: Kültürel miras alanında dijital ikiz oluşturma. *Turkish Studies*, 20(4), 2947-2960. <https://doi.org/10.7827/TurkishStudies.82722>
- Yıldız, İ. (2025). AI-based mobile attendance system with multi-layered security architectures. In E. Gülbandır (Ed.), *AI-driven digital ecosystems: From genetics to IoT for a secure and sustainable future* (pp. 184-219). BİDGE Yayınları.
- Yıldız, M. (2025). Bireysel yenilikçilik ile yapay zekâ tutumu arasındaki ilişki: Gençlik merkezlerinde etkinliklere katılan üniversite öğrencileri üzerine bir araştırma. *Turkish Studies*, 20(Ö1), 1109-1124. <https://doi.org/10.7827/TurkishStudies.86698>
- Yılmaz, O. K. (2025). Avrupa Komisyonu'nun "Avrupa Akıllı Turizm Başkenti" uygulaması ve Türkiye kentlerinin katılımları üzerine bir araştırma. *Turkish Studies*, 20(1), 635-660. <https://doi.org/10.7827/TurkishStudies.77830>
- Zan, N., & Zan, B. U. (2025). Yapay zekâ destekli derin sahtecilik teknolojisinin pedagojik, etik ve toplumsal boyutları. *Turkish Studies*, 20(4), 2961-2983. <https://doi.org/10.7827/TurkishStudies.83049>
- Zenginaloğlu, K. (2026). Culture, ethics and functionality in translation strategies: A comparison of translations produced by artificial intelligence tools and human translators / Çeviri stratejilerinde kültür, etik ve işlevsellik: Yapay zekâ araçlarının ve insan çevirmenin çevirilerinin karşılaştırması. *Turkish Studies – Language and Literature*, 21(1), 2071-2139. <https://doi.org/10.7827/TurkishStudies.89002>

ETHICAL DECLARATIONS

Research and Publication Ethics

I declare that this manuscript is an original work prepared in accordance with the principles of scientific research and publication ethics. The manuscript has not been previously published and is not currently under consideration for publication elsewhere. I confirm that all sources used in the preparation of this study have been properly cited and referenced. I declare that the work contains no plagiarism, fabrication, falsification, or manipulation of data. The research findings are presented honestly and transparently in accordance with the principles of academic integrity.

Ethics committee approval for the survey used in this study was obtained from the Bolu Abant İzzet Baysal University Social Sciences Human Research Ethics Committee at its meeting numbered 2026/03, and the application was deemed ethically appropriate (Protocol No: 2026/212).

Author Contributions

As the sole author of this manuscript, I declare that I have carried out all stages of the study, including its conception, design, analysis, interpretation of the findings, and preparation of the manuscript. I have read and approved the final version of the manuscript and agree to its submission and publication.

Conflict of Interest

I declare that there is no conflict of interest regarding the publication of this manuscript.

Funding

I declare that this research did not receive any specific grant, financial support, or funding from any public, commercial, or non-profit funding agencies.

Artificial Intelligence (AI) Usage Disclosure

During the preparation of this manuscript, artificial intelligence tools were used only to a limited extent for language editing and stylistic improvement. Artificial intelligence tools were not used to generate the core scientific content, research design, analyses, or scholarly conclusions of the study. The scientific content, analyses, and conclusions of the study are the sole responsibility of the author, and all academic responsibility for the content of the manuscript rests with me.

Copyright and Permissions

I confirm that all necessary permissions for copyrighted materials have been obtained where required and that the manuscript does not violate any intellectual property rights.

Author Approval

I confirm that I have read and approved the final version of the manuscript and consent to its submission and publication.

ETİK BEYANLAR

Araştırma ve Yayın Etiği

Bu makalenin bilimsel araştırma ve yayın etiği ilkelerine uygun olarak hazırlanmış özgün bir çalışma olduğunu beyan ederim. Makale daha önce herhangi bir yerde yayımlanmamış olup hâlihazırda başka bir yerde yayımlanmak üzere değerlendirme sürecinde değildir. Bu çalışmanın hazırlanmasında kullanılan tüm kaynakların uygun şekilde atıflandığını ve kaynakçada gösterildiğini beyan ederim. Çalışmanın intihal, veri uydurma, veri tahrifi veya veri manipülasyonu içermediğini beyan ederim. Araştırma bulguları, akademik dürüstlük ilkelerine uygun olarak doğru ve şeffaf biçimde sunulmuştur.

Bu çalışmada kullanılan anket için gerekli etik kurul izni, Bolu Abant İzzet Baysal Üniversitesi Sosyal Bilimler İnsan Araştırmaları Etik Kurulu'nun 2026/03 sayılı toplantısında verilmiş olup başvuru etik açıdan uygun bulunmuştur (Protokol No: 2026/212).

Yazar Katkısı

Bu makalenin tek yazarı olarak, çalışmanın tasarlanması, yürütülmesi, analizlerin gerçekleştirilmesi, bulguların yorumlanması ve makalenin hazırlanması dâhil olmak üzere tüm aşamalarını kendimin yürüttüğünü beyan ederim. Makalenin son hâlini okuduğumu ve onayladığımı; makalenin sunulmasını ve yayımlanmasını kabul ettiğimi beyan ederim.

Çıkar Çatışması

Bu makalenin yayımlanmasına ilişkin herhangi bir çıkar çatışması bulunmadığını beyan ederim.

Finansal Destek

Bu araştırmanın herhangi bir kamu kurumu, ticari kuruluş veya kâr amacı gütmeyen kuruluş tarafından özel bir hibe, finansal destek veya fon almadığını beyan ederim.

Yapay Zekâ Kullanım Beyanı

Bu makalenin hazırlanması sürecinde yapay zekâ araçları yalnızca dil düzenleme ve anlatım iyileştirmesi amacıyla sınırlı ölçüde kullanılmıştır. Yapay zekâ araçları, çalışmanın temel bilimsel içeriğinin, araştırma tasarımının, analizlerinin veya akademik sonuçlarının oluşturulmasında kullanılmamıştır. Çalışmanın bilimsel içeriği, analizleri ve sonuçları tamamen yazara ait olup makalenin içeriğine ilişkin tüm akademik sorumluluk tamamen bana aittir.

Telif Hakları ve İzinler

Gerekli olduğu durumlarda telif hakkı kapsamındaki materyaller için tüm gerekli izinlerin alındığını ve makalenin herhangi bir fikrî mülkiyet hakkını ihlal etmediğini beyan ederim.

Yazar Onayı

Makalenin son hâlini okuduğumu ve onayladığımı, ayrıca makalenin sunulmasına ve yayımlanmasına onay verdiğimi beyan ederim.