

Akran Zorbalığı Tahmininde Farklı Makine Öğrenmesi Algoritmalarının Performanslarının Karşılaştırılması

Erol ALTINIŞIK^{*1} Aytuğ ONAN²

¹İzmir Kâtip Çelebi Üniversitesi, Yazılım Mühendisliği, Türkiye, altmsk.erol@gmail.com
²İzmir Kâtip Çelebi Üniversitesi, Bilgisayar Mühendisliği, Türkiye, aytugonan@gmail.com

(Received: 11 March 2024, Accepted: 12 March 2024)

(4th International Conference on Innovative Academic Studies ICIAS 2024, March 12-13, 2024)

ATIF/REFERENCE: Altınışik, E. & Onan, A. (2024). Akran Zorbalığı Tahmininde Farklı Makine Öğrenmesi Algoritmalarının Performanslarının Karşılaştırılması. *International Journal of Advanced Natural Sciences and Engineering Researches*, 8(2), 424-429.

Abstract – Akran zorbalığı, benzer yaş grubundaki kişilere karşı kasıtlı olarak zarar verici davranışları içeren bir olgudur. Çalışma, akran zorbalığının ciddi etkileri olabileceğini ve uzun vadeli psikolojik sorunlara yol açabileceğini vurgulayarak, bu nedenle zorbalığa karşı farkındalık yaratma, eğitim sağlama ve önleme önlemleri almanın önemini vurgulamaktadır. Veri seti olarak OECD Pisa Eğitim Anketleri Türkiye verileri kullanılmış ve 6821 gözlem ile 24 öznitelik içermektedir. Yöntemler bölümünde, veri setinin ön işleme aşamaları detaylı bir şekilde açıklanmıştır. Eksik veriler mod alma yöntemiyle doldurulmuş, likert ölçeği anket verileri sayısal çevrime kavuşturulmuş ve çeşitli öznitelikler oluşturulmuştur. Bulgular bölümünde, LR, KNN, SVM, RF, CART, GBM, XGBM, LGBM, CATBOOST ve MLP algoritmaları kullanılarak zorba hedef özniteliği tahmini yapılmıştır. Algoritmaların başarı sıralamaları doğruluk, kesinlik, duyarlılık, ROC_AUC ve F1 Skor metrikleri kullanılarak karşılaştırılmıştır. İlk aşamada ve hiper parametre optimizasyonları sonrasında elde edilen sonuçlar benzerlik göstermiştir. Sonuç bölümünde, yapılan çalışmanın genel başarı sıralamaları verilmiş ve hiper parametre optimizasyonlarıyla daha iyi sonuçlar elde edilebileceği öne sürülmüştür. Bu çalışmanın, literatüre LR, KNN, SVM, MLP, RF, CART, GBM, XGBM, LGBM, CATBOOST gibi algoritmaların doğruluk, kesinlik, duyarlılık, ROC_AUC ve F1 skor metrikleriyle beraber kullanılarak tahmin sonuçlarını karşılaştıran bir katkı sağladığı belirtilmiştir.

Keywords – Akran Zorbalığı, Makine Öğrenmesi, Sınıflandırma Algoritmaları.

I. GİRİŞ

Akran zorbalığı, bir kişinin ya da bir grup insanın benzer yaş gruplarındaki diğer kişi veya kişilere karşı, kasıtlı ve tekrarlı, sözel ya da fiziki olarak zarar verici davranışlarda bulunmasıdır. Bu tür davranışlar genellikle bir güç dengesizliği temelinde gerçekleşir ve hedef alınan kişinin savunmasız olduğu durumlarda gerçekleşir. Akran zorbalığı kişi de fiziksel, sözlü, duygusal veya sosyal tüm hayatını etkileyebilecek durumları içerir. Örnek olarak, alay etme, dışlama, dedikodu yayma, saldırgan davranışlar sergileme, tehdit etme gibi davranışlar akran zorbalığına örnek olarak gösterilebilir. Zorbalık, okul, iş yeri, sosyal yaşam alanı, çevrimiçi platformlar gibi farklı ortamlarda gerçekleşebilir.

Olweus [2] akran zorbalığı 'bir veya bir grup öğrencinin bir başka öğrenciye karşı uyguladıkları saldırgan davranışlar' olarak tanımlamıştır. İki farklı araştırmada akran zorbalığını Olweus [2], Hinduja ve Patchin [3], 'fiziksel, sözel, ilişkisel ve siber zorbalık' şeklinde ele almışlardır. Ayas ve Pişkin,[4], Crick ve Grotmeter,[5], İlişkisel zorbalığın diğerlerine göre farkında olunmasının zor tespit edilebilmesi nedeniyle ve sonuçlarının daha kalıcı ve zedeleyici sonuçlar üretmesi kaçınılmazdır.

Akran zorbalığı, kurban üzerinde ciddi etkiler bırakabilir ve uzun vadeli psikolojik sorunlara yol açabilir. Bu nedenle, akran zorbalığına karşı farkındalık yaratmak, eğitim sağlamak ve bu tür davranışları önlemek için çeşitli önlemler almak önemlidir. Okullar ve diğer topluluklar zorbalığı önlemek ve mücadele etmek amacıyla plan ve programlar geliştirmelidir. Bu çalışmanın amacı da tahmin ve algoritma performans ölçümleri bakımından literatüre katkı sağlamaktır.

II. MATERYAL VE YÖNTEM

Bu bölümde çalışmanın içeriğinde kullanılan veri seti ve yöntemler hakkında bilgi verilmiştir.

Çalışmada kullanılan veri seti [1] OECD Pisa Eğitim Anketleri Türkiye verilerinden derlenmiştir. Veri seti 6821 gözlem ve 24 öznitelik içermektedir. Veri seti ön işleme kapsamında eksik veriler mod alma yöntemiyle doldurulmuştur. Öznitelikler likert ölçeği anket verilerinden oluştuğu üzere yeniden sınıflandırma yapılması gereği doğmuştur. Bu kapsamda öznitelikler binary kod çevrimi gerçekleştirilerek makine öğrenmesi algoritmalarının çalışabileceği sayısal çevrime kavuşturulmuştur. Bu çalışmadan sonra özniteliklerin oluşturulması aşamasına geçilmiştir.

Veri setinde ön işleme adımları ile veri hazır hale getirilmeye çalışılmış devamında öznitelik seçimi aşamasına geçilmiştir. Bu aşamada likert ölçekli verilerin sadeleştirilmesi ve binary kod çevrimine tabi tutulduktan sonra anlamlı değişken oluşturma aşamasına geçilmiştir. Bu kapsamda çeşitli operatörler yardımıyla (if, for vb mantıksal operatörler) yeni öznitelikler oluşturulmaya çalışılmıştır. Bu bağlamda oluşturulan öznitelikler zorba, mağdur, mağdur ve zorba, mağdur ama zorba değil, zorba ama mağdur değil, mağdur değil, zorba değil, mağdur ve zorba değil, empati, apati, dışlanmışlık, aidiyet, aile yükseköğrenim, aile lise, aile ilk ve orta öğrenim, aile eğitimsiz olarak adlandırılmışlardır. Bu özniteliklerden olan zorba, çalışmamızın hedef özniteliği olmuş ve bu bağlamda kullanılmıştır.

Aşağıda kullanılan algoritmalar hakkında açıklamalara yer verilmiştir.

Lojistik Regresyon (LR): Bağımlı değişkenin kategorik olduğu durumlarda ve özellikle ikili sınıflandırma problemleri için bağımlı değişkenin olasılığını tahmin etmek için kullanılır [6].

K-Nearest Neighbors (KNN): Temel olarak bir sınıflandırma problemiyle karşı karşıya olduğunuzda, yeni bir örneğin sınıfını belirlemek için etrafındaki en yakın komşularına bakar. Bu komşuların sınıfları, yeni örneğin sınıfının tahmin edilmesinde kullanılır [7].

Support Vector Machine (SVM): Doğrusal olmayan veri kümelerini sınıflandırmak için etkilidir ve ayrık, sürekli veya kategorik veri türlerini işleyebilir. Temel amacı, veri noktalarını sınıflandırma veya regresyon işlemleri için bir hiper düzlemlerle bölmektir. İki sınıf arasındaki en geniş marjı (margin) bulmak için optimize edilmiştir. Marj, sınıflar arasındaki boşluktan oluşur ve sınıflandırma doğruluğu için kritiktir. SVM, veri noktalarını bu marjın maksimum olduğu şekilde bölmeye çalışır [8].

Random Forest (RF): Sınıflandırma problemleri için sınıf belirleme ve regresyon problemleri için tahmin yapma gibi birçok uygulamada kullanılır. Birden çok karar ağacının bir araya gelerek bir model oluşturduğu bir ensemble yöntemidir [9].

Classification and Regression Trees (CART): Sınıflandırma ve regresyon problemlerini çözmek için kullanılan bir yöntemdir. Veri kümesinin özelliklerine dayanarak ağaç yapısı oluşturur. Her iç düğüm, bir özellik testi yapar ve veri kümesini bu test sonuçlarına göre bölümlere ayırır. Bu bölünme işlemi, belirli bir kriteri (genellikle homojenliği artırmak için bilgi kazancı veya Gini endeksi gibi) optimize etmeye çalışır [10].

Gradient Boosting Machine (GBM): Sınıflandırma ve regresyon problemleri için kullanılan bir makine öğrenimi tekniğidir. Zayıf öğrenicileri (genellikle karar ağaçları olarak adlandırılan modelleri) bir araya getirerek güçlü bir tahminci oluşturur. Her bir zayıf öğrenici, veri setindeki hataları düzeltmek için bir öncekinden daha iyi çalışmaya odaklanır. Bu, her bir ağacın önceki ağaçların hatalarını düzeltmeye çalıştığı bir 'artımlı' (boosting) yaklaşımdır [11].

Extreme Gradient Boosting Machine (XGBM): GBM tekniğini daha da geliştiren ve optimize eden bir türdür [11].

Light Gradient Boosting Machine (LGBM): Gradient Boosting algoritması üzerine kurulu hızlı ve dağıtılmış bir makine öğrenimi kütüphanesidir. Microsoft tarafından geliştirilmiştir ve açık kaynaklı bir proje olarak sunulmuştur. Bu kütüphane, büyük ölçekli veri kümeleriyle ve yüksek boyutlu özellik uzaylarıyla çalışmak için özellikle optimize edilmiştir [12].

Category Boosting (CatBoost): Geleneksel makine öğrenimi modelleri, kategorik değişkenleri kullanmak için öncelikle sayısal değerlere dönüştürme gereksinimi duyarlar. Ancak bu dönüştürme işlemi bilgi kaybına neden olabilir ve model performansını olumsuz etkileyebilir. CatBoost, bu sorunu çözmek için kategorik değişkenlerle doğrudan çalışabilir ve model performansını artırabilir [14].

Multilayer Perceptron (MLP): yapay sinir ağları (Artificial Neural Networks - ANN) alanında kullanılan bir tür derin öğrenme modelidir. MLP'ler, en azından üç katmana sahip bir yapay sinir ağı mimarisini ifade eder: giriş katmanı, gizli katman(lar) ve çıkış katmanı [15].

III. BULGULAR


Bu bölümde proje içerisinde zorba hedef özniteliği tahmini amacıyla LR, KNN, SVM, RF, CART, GBM, XGBM, LGBM, CATBOOST makine algoritmaları ve MLP basit yapay sinir ağı algoritması kullanılmıştır. Algoritmaların zorba hedef özniteliği sınıflandırma tahmini ve algoritmalarının kendileri arasındaki performans ölçümleri karşılaştırılmıştır. İlk aşamada algoritmalara veriler eğitim ve test verileri %80 ve %20 olacak şekilde bölümlenerek verilmiştir. Bu aşamada ayrıca Kfold 10 çapraz doğrulama yöntemi ile performans değerleri ölçümlenmeye çalışılmıştır. Makine öğrenmesi algoritmalarında bu aşamada hangi metrikte hangi algoritma sayısal değeriyle daha başarılı olmuştur Tablo 1 de verilmiştir.

Tablo 1. Eğitim aşaması en başarılı algoritmalar

Metrikler	Algoritma	Değer
Doğruluk	SVM	0.8737
Kesinlik	GBM	0.6773
Duyarlılık	SVM	0.7411
Roc_Auc	GBM	0.9421
F1 Skor	SVM	0.6945

Bu aşamada verilerin diğer tüm ölçümleri karşılaştırılıp ortalama skorları alınarak bu değerler bulunmuştur. Algoritmaların metrik sonuçları genelde birbirine çok yakın seyretmekle beraber ufak farklarla üstünlük sağladıkları görülmüştür.

Şekil 1 de tüm algoritmaların doğruluk, kesinlik, duyarlılık, roc_auc, f1 skor değerlerinin bulunduğu ilk aşama sonuçlarının yer aldığı grafikler verilmiştir.



Şekil 1. 0.20-0.80 Kfold 10 Model Performansı

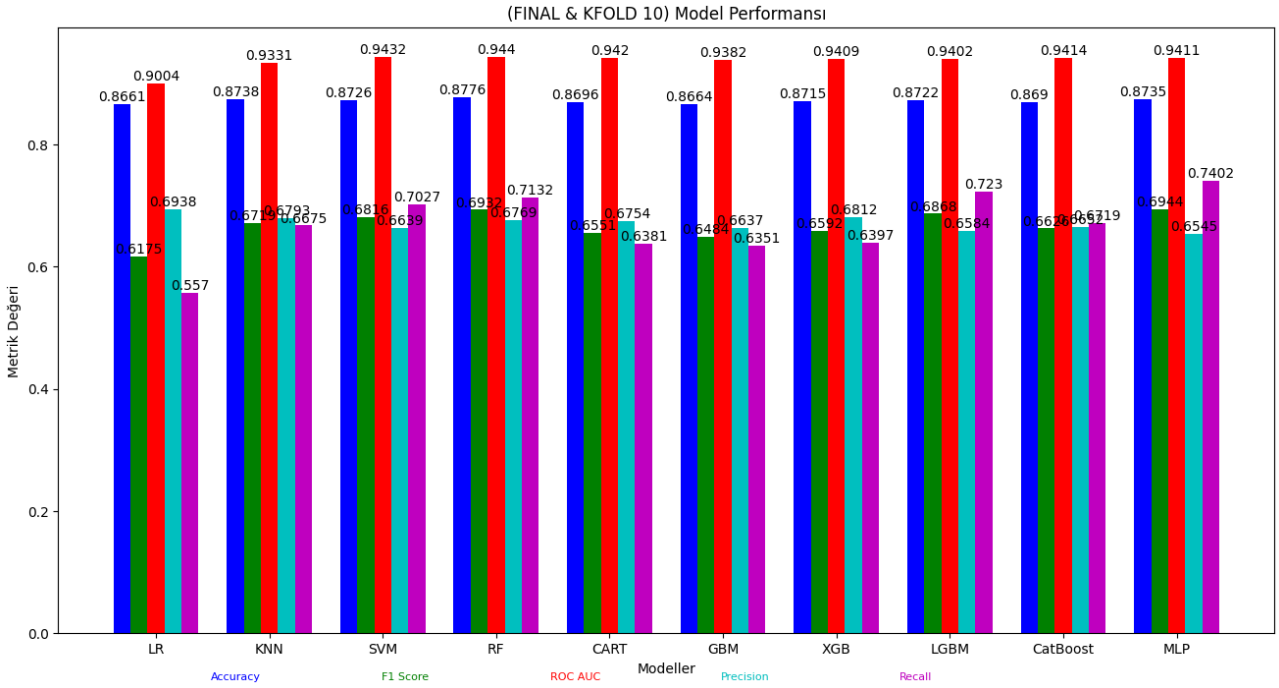
İkinci aşamada algoritmalara çeşitli hiper parametre optimizasyonları uygulanarak yeniden ölçümler yapılmıştır. Bu ölçümler esnasında Kfold 10 çapraz doğrulama uygulanarak verilerin doğrulanması sağlanmıştır. Makine öğrenmesi algoritmalarında bu aşamada hangi metrikte hangi algoritma sayısal değeriyle daha başarılı olmuştur sırası Tablo 2 de verilmiştir.

Tablo 2. Hiper parametre optimizasyonu sonrası en başarılı algoritmalar

Metrikler	Algoritma	Değer
Doğruluk	RF	0.8776
Kesinlik	LR	0.6938
Duyarlılık	MLP	0.7402
Roc_Auc	RF	0.9440
F1 Skor	MLP	0.6944

Bu aşamada verilerin yine tüm ölçümleri karşılaştırılarak ortalama skorları alınarak bu değerler bulunmuştur. Hiper parametre optimizasyonları yapılan modeller ölçümlerde birbirlerine yakın sonuçlar üretmiş ve çok az farkla birbirlerine üstünlük kurmuşlardır.

Şekil 2 de tüm algoritmaların doğruluk, kesinlik, duyarlılık, roc_auc, f1 skor değerlerinin bulunduğu final aşaması yani hiper parametre optimizasyonları yapılarak alınan sonuçlarının yer aldığı grafikler verilmiştir.



Şekil 2. FINAL Kfold 10 Model Performansı

IV. TARTIŞMA

Literatürde akran zorbalığı tanımı, nedenleri, çevresel faktörleri, önleme, gibi birçok çalışma bulunmaktadır. Bu çalışmada da değinilmiştir. Akran zorbalığı tespitinin kişinin ilerleyen yaşamını çok ağır etkileyeceği durumlar ortaya çıkarabileceği düşünüldüğünde önemli olduğu açıktır. Bu alanda yapılan anketler, çeşitli formlar, bilgilendirmeler daha sonra farkındalık oluşturmak için değerlidir. Ancak günümüz teknolojilerinin de bu kapsam da bu çalışma da ki gibi değerlendirme kapsamına alınması değerli olacaktır.

V. SONUÇLAR

Bu çalışmada literatürde sıklıkla kullanılan LR, KNN, SVM, MLP, RF, CART, GBM, XGBM, LIGHTGBM, CATBOOST, algoritmaları doğruluk, kesinlik, duyarlılık, F1 skor metrikleriyle beraber kullanılarak tahminleme sonuçları karşılaştırılmıştır. Bunun için öncelikle veri seti ön işleme aşamalarından geçirilmiş elde edilen veriler kullandığımız algoritmaları eğitmek ve test etmek amacıyla kullanılmıştır. Değerlendirme sonuçlarına bakıldığında tüm sonuçlar az farkla sonuçlanmıştır. Eğitim test aşamasında doğruluk metriği için SVM, kesinlik metriği için GBM, duyarlılık metriği için SVM, ROC_AUC metriği için GBM, F1 Skor metriği için SVM algoritmaları üstünlük sağlamıştır. Makine öğrenmesi algoritmalarında hiper parametre optimizasyonları sonrası final başarı sırası doğruluk metriği için RF, kesinlik metriği için LR, duyarlılık metriği için MLP, ROC_AUC metriği için RF, F1 Skor metriği için -MLP algoritması üstünlük sağlamıştır.

Sonuç olarak yapılan çalışma kapsamında hiper parametre optimizasyonları geliştirilerek daha iyi sonuçlar alınabileceği öngörülmüştür. Başka çalışmalarda farklı modeller ve buna ek olarak yapay sinir ağları algoritmaları da konu kapsamında literatüre katkı sağlayacaktır.

REFERANSLAR

- [1] OECD 2018 Pisa Eğitim Anketleri Türkiye verileri, <https://www.oecd.org/pisa/data/2018database/>
- [2] Olweus, D. (1993). *Bullying at school: What we know and what we can do*. Oxford, UK: Blackwell.
- [3] Hinduja, S. ve Patchin, J. W. (2014). *Bullying beyond the schoolyard: Preventing and responding to cyberbullying*. Corwin Press.
- [4] Ayas, T. ve Pişkin, M. (2011). Lise öğrencileri arasındaki zorbalık olaylarının cinsiyet, sınıf düzeyi ve okul türü bakımından incelenmesi. *İlköğretim Online*, 10(2), 550-568.
- [5] Crick, N. R. ve Grotpeter, J. K. (1995). Relational aggression, gender, and social-psychological adjustment. *Child Development*, 66, 710–722.
- [6] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
- [7] Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- [8] K. C. Sivakumar. (2015). *Support Vector Machines: A Survey*.
- [9] Breiman, Leo. "Random forests." *Machine learning* 45.1 (2001): 5-32.
- [10] Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and Regression Trees*. Wadsworth International Group.
- [11] Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794).
- [12] Ke, Guolin, et al. "LightGBM: A highly efficient gradient boosting decision tree." *Advances in Neural Information Processing Systems*. 2017.
- [13] I. Prokhorenkova, et al., "CatBoost: unbiased boosting with categorical features." In *Advances in Neural Information Processing Systems*, pp. 6638-6648. 2018
- [14] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.