




Bireylerin Çevresel Tutumlarını Tahminde Makine Öğrenmesi: ANOVA ve Ki-Kare Temelli Özellik Seçimi ile Algoritma Performanslarının Karşılaştırılması

Predicting Individuals' Environmental Attitudes Using Machine Learning: Comparison of Algorithm Performances with ANOVA and Chi-Square-Based Feature

Rukiye Uzun Arslan¹, İrem Şenyer Yapıcı², Fuat Alkan¹

 0000-0002-2082-8695  0000-0003-0655-340X  0000-0001-7914-2383

¹Elektrik-Elektronik Mühendisliği Bölümü

Zonguldak Bülent Ecevit Üniversitesi

rukiye.uzun@beun.edu.tr, fuatalkan_67@hotmail.com

²Bilgisayar Mühendisliği Bölümü

Zonguldak Bülent Ecevit Üniversitesi

senyerirem@gmail.com

Özet

Bu çalışma, bireylerin çevresel tutumlarının makine öğrenmesi (MÖ) yöntemleriyle tahmin edilmesine yönelik veri odaklı bir model geliştirmeyi amaçlamaktadır. Çalışmada, çevresel farkındalık düzeylerinin sınıflandırılmasına yönelik beş farklı MÖ algoritmasının (Destek Vektör Makineleri, Gradyan Artırma (GA), Çok Katmanlı Algılayıcı, Kuadratik Diskriminant Analizi ve Torbalama) performansı karşılaştırılmıştır. Model oluşturma sürecinde, veri setindeki değişkenlerin sınıflandırma başarısına etkisini belirlemek amacıyla tek yönlü varyans analizi (ANOVA) ve Ki-Kare Bağımsızlık Testi gibi istatistiksel yöntemler uygulanmıştır. Deneysel sonuçlar, ANOVA ve Ki-Kare tabanlı özellik seçimi süreçlerinin model başarımını artırmada etkili olduğunu göstermektedir. Özellikle GA algoritması, doğruluk, kesinlik ve F1 skoru bakımından diğer yöntemlere kıyasla üstün performans sergilemiştir. Elde edilen bulgular, MÖ algoritmalarının çevresel tutumların modellenmesi ve tahmin edilmesinde güçlü bir analitik çerçeve sunduğunu ortaya koymaktadır. Çalışma, çevresel farkındalık düzeylerinin veri odaklı yöntemlerle değerlendirilmesinin, sürdürülebilir çevre politikalarının geliştirilmesine ve bireylerin çevre bilincinin artırılmasına katkı sağlayacağını ortaya koymaktadır. Anahtar kelimeler: çevresel tutum, özellik seçimi, makine öğrenmesi, sürdürülebilirlik

Abstract

This study aims to develop a data-driven model to predict individuals' environmental attitudes based on machine learning (ML) algorithms. The study compares the performance of five different ML algorithms—Support Vector Machines, Gradient Boosting (GB), Multilayer Perceptron, Quadratic Discriminant Analysis, and Bagging—in classifying environmental awareness levels. During the model

development process, statistical methods such as one-way analysis of variance (ANOVA) and the Chi-Square Independence Test were applied to assess the impact of variables on classification accuracy. Experimental results indicate that ANOVA- and Chi-Square-based feature selection processes effectively enhance model performance. In particular, the GB algorithm outperforms others in terms of accuracy, precision, and F1 score. The findings demonstrate that ML algorithms provide a robust analytical framework for modelling and predicting environmental attitudes. This study highlights the significance of evaluating environmental awareness levels through data-driven approaches, contributing to the development of sustainable environmental policies and the enhancement of individuals' environmental consciousness.

Keywords: environmental attitude, feature selection, machine learning, sustainability

1. Giriş

Çevre, ekosistemlerin doğal işleyişini, biyolojik çeşitliliği ve yaşamın sürdürülebilmesi için gerekli kaynakları kapsayan bütünsel bir yapıdır. Ancak insan faaliyetleri, bu dengenin bozulmasına yol açarak çevreyi benzeri görülmemiş bir tehdit altına sokmuş ve çevre sorunlarını küresel bir krize dönüştürmüştür. Bu krizin temel nedenleri arasında bilinçsiz bireysel tutumlar, sanayileşmenin hızlanması, doğal kaynaklara erişimin kolaylaşması ve kontrolsüz kentleşme yer almaktadır [1, 2]. Bilimsel ve teknolojik gelişmeler yaşam standartlarını artırırken çevresel dengede ciddi bozulmalara yol açmış, nüfus artışıyla birlikte çevre kirliliği ve ekosistemler üzerindeki baskı giderek artmıştır. Bu bağlamda, çevresel sorunların önüne geçebilmek için küresel iş birliğinin güçlendirilmesi, sürdürülebilir kalkınma ilkelerinin benimsenmesi ve çevre dostu yaşam biçimlerinin teşvik

edilmesi gerekmektedir [3, 4]. Ancak, bu önlemler yeterince uygulanmadığında çevresel bozulma kaçınılmaz hale gelmekte, ekosistemlerin dengesi bozulmakta ve canlıların yaşam kalitesi olumsuz etkilenmektedir. Bu durum, uzun vadeli çevre sorunlarının ortaya çıkmasına neden olmaktadır. Özellikle, doğal sistemlere yapılan bilinçsiz müdahaleler, ekosistemlerin dengesini bozarak çevresel bozulmayı daha da derinleştirmekte ve ekosistemlerin kendini yenileme kapasitesinin azalmasına yol açmaktadır [5]. Ekolojik sistemlerde meydana gelen bu tahribat, sadece doğal yaşamı değil, insan sağlığını ve ekonomik faaliyetleri de olumsuz etkilemektedir. Bu nedenle, çevresel sürdürülebilirliği sağlamak ve ekosistemlerin kendini koruma ve yenileme kapasitesini artırmak amacıyla çevre bilinci yüksek, çevresel sorunlara duyarlı ve hem teorik hem de uygulamalı çalışmalara katkı sunabilecek bireylerin yetiştirilmesi büyük önem taşımaktadır.

Bu doğrultuda, çevre eğitimi, bireylerin çevresel farkındalık kazanmasını sağlamak, doğaya duyarlı davranışları teşvik etmek ve çevre sorunlarının çözümüne yönelik etkin stratejiler geliştirmelerine katkıda bulunmak amacıyla temel bir unsur olarak öne çıkmaktadır. Çevre eğitimi, bireylerin ekosistemlerin işleyişini anlamalarını sağlarken, aynı zamanda sürdürülebilir çözümler üretebilmeleri için gerekli bilgi, beceri ve değerleri kazanmalarına da olanak tanımaktadır [6]. Böylece, çevreye duyarlılığı yüksek bireylerin yetiştirilmesi desteklenmekte ve çevresel sorunların çözümüne uzun vadeli katkılar sağlanmaktadır. Günümüzde, çevresel sorunların yönetimi ve sürdürülebilir çözümler üretilmesi noktasında yalnızca bireysel farkındalık ve eğitim yeterli olmamakta, aynı zamanda veri odaklı yaklaşımlar da büyük bir önem kazanmaktadır. Bu bağlamda, makine öğrenimi (MÖ) gibi ileri teknoloji yöntemleri, büyük ölçekli çevresel verileri analiz ederek çevresel süreçlerin daha iyi anlaşılmasına ve etkin politika geliştirilmesine katkı sağlamaktadır. Özellikle, hava ve su kirliliği tahmini, ekosistem değişikliklerinin izlenmesi ve enerji verimliliğinin artırılması gibi alanlarda MÖ modelleri, karar destek sistemlerine entegre edilerek daha doğru ve hızlı çözümler sunmaktadır.

Literatürde yapılan çalışmalar incelendiğinde, çevresel tutumların sınıflandırılmasına yönelik MÖ tabanlı yaklaşımların giderek yaygınlaştığı görülmektedir. Bu çalışmalar, bireylerin çevresel farkındalığını ve tutumlarını nesnel verilerle analiz ederek, sürdürülebilir çevre politikalarının geliştirilmesine katkıda bulunmayı amaçlamaktadır. Özellikle, anket verileri ve diğer çevresel değişkenler kullanılarak gerçekleştirilen MÖ uygulamaları, bireylerin çevreye yönelik eğilimlerini modellemek ve gelecekteki çevresel davranışları öngörmek için güçlü bir araç olarak öne çıkmaktadır. Bu doğrultuda, MÖ algoritmaları çevresel konuların analiz edilmesi ve çevresel tutumların sınıflandırılması süreçlerinde yaygın olarak kullanılmaktadır. Beiser-McGrath ve Huber (2018), bireylerin iklim değişikliği ve çevresel bozulmaya yönelik tutumlarını tahmin edebilmek amacıyla psikolojik ve demografik faktörlerin önemini değerlendirmiştir. Çalışmalarında, Çin, İsviçre ve ABD'de gerçekleştirilen saha araştırmalarından elde edilen veriler kullanılarak Rastgele Orman (RO) algoritması uygulanmıştır. Sonuçlar, gelecek sonuçları dikkate alma ölçeğinin çevresel tutumların tahmininde güçlü bir gösterge olduğunu ortaya koymuştur. Ayrıca, geleneksel açıklayıcı değişkenler olan gelir ve eğitimin, çevresel tutumları tahmin etme gücünün

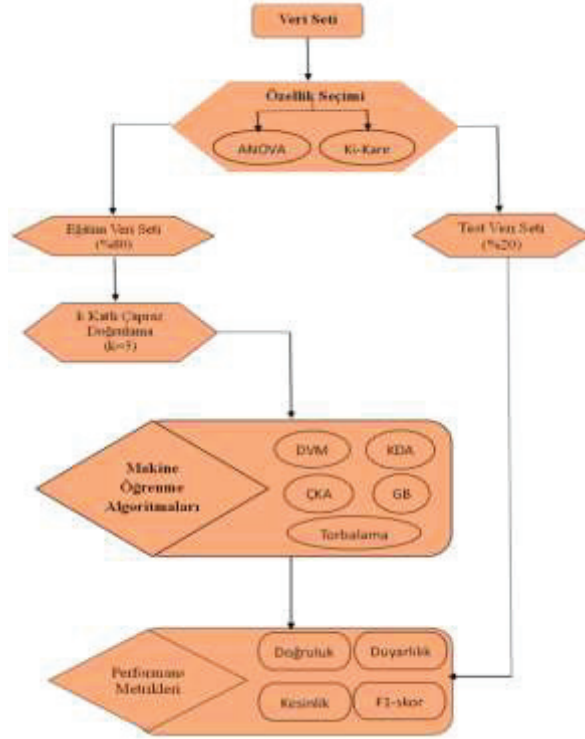
daha sınırlı olduğu tespit edilmiştir [7]. Değirmenci (2024) bireylerin çevresel tutumlarını k en yakın komşu (kNN), karar ağacı (KA) ve destek vektör makineleri (DVM) olmak üzere üç farklı MÖ algoritmasıyla analiz etmiştir. Gerçekleştirilen çalışmada algoritmalara özgü hiperparametre optimizasyonu, kapsamlı Grid Search ve 10 kat çapraz doğrulama (k = 10) ile gerçekleştirilmiştir. Elde edilen bulgular en yüksek performansın DVM algoritmasıyla (doğruluk = 0,9576, F1 skoru = 0,9615, hassasiyet = 0,9576, duyarlılık = 0,9670) elde edildiği ortaya konulmuştur [8]. Choudhury ve arkadaşları (2024), MÖ algoritmalarını kullanarak tüketicilerin yeşil satın alma niyetini tahmin etmeyi amaçlamıştır. 310 katılımcıdan toplanan verilerle RO, KA, kNN, DVM, Gradyan Artırma (GA) ve Aşırı Gradyan Artırma (Extreme Gradient Boosting, XGBoost) algoritmalarıyla yapılan analizlerde, yeşil özdeşleşme, çevresel bilinç, çevresel bilgi ve sosyal medyanın etkili faktörler olduğu belirlenmiştir. Çalışmada kullanılan algoritmalar arasında RO modeli, %83 doğruluk ve 0,84 alıcı karakteristik eğrisinin altındaki alan (AUC-ROC) değeriyle en yüksek başarıyı göstermiştir [9]. Köklü ve Sulak (2024), bireylerin çevresel tutumlarını sınıflandırmak amacıyla çeşitli yapay zeka algoritmalarını kullanarak bir analiz gerçekleştirmiştir. Çalışmada, 384 katılımcıdan elde edilen ve 37 değişkenden oluşan bir çevresel tutum veri kümesi kullanılmıştır. Sınıflandırma işlemi için Lojistik Regresyon (LR), DVM ve KA algoritmaları uygulanmıştır. Sonuçlara göre, LR modeli %94,53, DVM modeli %92,96 ve KA modeli %82,55 doğruluk oranı ile başarılı sınıflandırma performansı sergilemiştir. Elde edilen bulgular, çevresel tutumların analizinde yapay zeka tabanlı sınıflandırma yöntemlerinin etkili bir şekilde kullanılabilirliğini göstermektedir. Ayrıca, veri kümesinin genişletilmesi ve sınıfların dengeli dağıtılması gibi faktörlerin sınıflandırma başarısını artırabileceği vurgulanmaktadır [3]. Amangeldi ve arkadaşları (2024), 2014-2023 yılları arasındaki sosyal medya verilerini inceleyerek çevresel konulara dair kamuoyu duygusu ve emosyonlarını analiz etmiştir. Twitter, Reddit ve YouTube gibi üç büyük sosyal medya platformundan toplanan veriler, noktasal karşılıklı bilgi (Pointwise Mutual Information, PMI) algoritması kullanılarak değerlendirilmiştir. Çalışmanın bulguları, çevreyle ilgili paylaşımlarda negatif duyguların baskın olduğunu, iklim değişikliği, hava kalitesi, emisyonlar, plastik ve geri dönüşüm gibi konuların öne çıktığını göstermektedir. Ayrıca, korku, güven ve beklenti gibi duyguların en yaygın şekilde ifade edilen duygular olduğunu ortaya koymaktadır. Çalışma, her platformun kullanıcı etkileşimi ve duygusal yansımaları arasında farklar olduğunu; Twitter ve YouTube'un genellikle negatif, Reddit' in ise zamanla artan olumlu paylaşımlar gösterdiğini vurgulamaktadır [10]. Takshe ve arkadaşları (2023) Birleşik Arap Emirlikleri'ndeki üniversite öğrencileri arasında çevre dostu davranışları etkileyen faktörleri incelemişlerdir. Çalışma, çevresel sürdürülebilirliğin tehdit altında olduğu bir dönemde, öğrencilerin çevreye yönelik tutum ve davranışlarını etkileyen ana faktörleri keşfetmiştir. Çalışmanın bulguları, çevre bilincini artırmanın ve çevre dostu davranışları teşvik etmenin, sadece eğitimle değil, aynı zamanda ekonomik teşvikler ve doğrudan deneyimlerin de etkili olabileceğini göstermektedir. Çalışma, çevre bilincini artıran müdahalelerin, bireylerin tutumlarını şekillendirerek daha sürdürülebilir davranışlar geliştirmelerine yardımcı olabileceğini ortaya koymuştur [11]. Wang ve arkadaşları

(2022) üniversite öğrencilerinin çevreye duyarlı davranışlarını tahmin etmek amacıyla MÖ tabanlı bir KA modeli geliştirmişlerdir. Guangdong Eyaleti'nden 334 üniversite öğrencisinin katılımıyla gerçekleştirilen çalışmada, çevresel sorumluluk bilinci, yenilikçi davranışlar ve algılanan davranışsal kontrolün çevresel davranışın en güçlü belirleyicileri olduğu ortaya konulmuştur. MÖ algoritmalarının veri madenciliği süreçlerinde sunduğu yüksek tahmin doğruluğundan faydalanan bu araştırma, KA modelinin çevreye duyarlı davranışların öngörülmesinde etkili bir yöntem olduğunu göstermiştir [12]. Lou ve arkadaşları (2022) çevre koruma önceliğini ekonomik büyümenin önüne koymayı öngören bir model geliştirmek için makroekonomik, demografik ve psikolojik değişkenleri içeren bir MÖ temelli bir yaklaşım kullanmışlardır. RO algoritması ile yapılan analizlerde, sekiz değişkenin en güçlü öngörücüler olduğu belirlenmiş ve önerilen model %34,15 hata oranıyla başarılı bir performans sergilemiştir [13]. Li ve arkadaşları (2022) Çin'deki kamu firmalarının çevre koruma konusundaki tutumlarını analiz etmek için duyguyu analizi ve RO modellerini kullanmıştır. 2018-2021 yılları arasında yatırımcı-firma soru-cevap kayıtlarını toplayarak karbon ve çevreyle ilgili metinleri çıkarmış ve doğal dil işleme teknikleriyle firma düzeyindeki tutumları değerlendirmişlerdir. Çalışma, COVID-19 pandemisi ve çevre politikalarının firmaların karbon azaltımı konusundaki tutumlarını önemli ölçüde etkilediğini göstermiştir. Ayrıca, firmaların çevresel tutumlarında sektörler arası farklılıkların belirgin olduğu ve finansal performansın da tutumlar üzerinde etkili olduğu tespit edilmiştir. Model değerlendirmeleri sonucunda, RO algoritmasının firma tutumlarını tahmin etmede en iyi performansı gösterdiği ve en düşük hata oranına (karekök ortalama kare hatası = 10,98) sahip olduğu belirlenmiştir [14].

Literatürdeki bu çalışmalar, bireylerin çevresel farkındalık düzeylerinin değerlendirilmesi ve çevre dostu davranışlarının tahmin edilmesi konusunda MÖ algoritmalarının etkili olduğunu ortaya koymaktadır. Ancak, bu alandaki çalışmaların hâlâ gelişim aşamasında olduğu, farklı MÖ algoritmalarının karşılaştırmalı performans analizine yönelik araştırmaların sınırlı olduğu görülmektedir. Bu doğrultuda gerçekleştirilen bu çalışmada, bireylerin çevresel farkındalık ve tutum düzeylerini değerlendirmek amacıyla veri odaklı bir model geliştirilmiş ve çevresel tutum düzeylerinin sınıflandırılmasında beş farklı MÖ algoritmasının performansı karşılaştırılmıştır. Model oluşturma sürecinde, veri setindeki değişkenlerin sınıflandırma başarısına etkisini belirlemek amacıyla tek yönlü varyans analizi (ANOVA) ve Ki-Kare Bağımsızlık Testi uygulanmıştır. Bu aşama, modelin doğruluk oranını artırmak ve gereksiz değişkenlerin olası etkilerini en aza indirmek amacıyla gerçekleştirilmiş olup, çıkarılan anlamlı özellikler temel alınarak sınıflandırma işlemi yürütülmüştür. Bu sayede, çevresel tutumların sınıflandırılmasında daha güvenilir ve karşılaştırılabilir sonuçların elde edilmesi hedeflenmiştir.

2. Materyal ve Metot

Çalışma kapsamında bireylerin çevresel farkındalık ve tutum düzeylerini sınıflandırmak için geliştirilen modelin akış şeması Şekil 1'de sunulmaktadır.



Şekil 1: Önerilen modelin akış diyagramı.

2.1. Veri Seti

Bu çalışmada, Koklu ve Sulak tarafından açık erişime sunulan "Environmental Attitude Dataset" başlıklı veri seti kullanılmıştır. Söz konusu veri seti, Türkiye'de ikamet eden bireylere yönelik çevrimiçi uygulanan bir anket yoluyla elde edilmiştir. Veri toplama süreci, yaşları 18 ile 45 arasında değişen 177 erkek ve 207 kadın olmak üzere toplam 384 katılımcının katılımıyla gerçekleştirilmiştir. Veri seti, bireylerin çevresel sorumlu davranışlarını etkileyen faktörlerin analizine olanak tanıyacak şekilde yapılandırılmış olup, çevresel farkındalık ve tutum düzeylerini değerlendirmeye yönelik 37 farklı değişken içermektedir. Bu değişkenler, çevresel farkındalık, çevre dostu davranış kalıpları, sürdürülebilirlik bilinci ve çevresel sorumluluk düzeyi gibi çok boyutlu kavramları kapsamaktadır [3].

2.2. Veri Ön işleme

MÖ tabanlı karar destek sistemlerinin geliştirilmesinde, verinin doğru ve etkin bir biçimde işlenmesi hayati önem taşımaktadır. Bu doğrultuda, veri ön işleme süreci, modelin başarımını doğrudan etkileyen temel adımlardan biri olup eksik verilerin giderilmesi, hatalı veya gürültülü verilerin temizlenmesi, verinin normalleştirilmesi ve özellik seçimi tekniklerinin uygulanması gibi çeşitli aşamaları kapsamaktadır. Veri ön işleme, modelin doğruluk oranını artırarak daha güvenilir ve kesin tahminler yapılmasına katkı sağlamaktadır. Çalışmada bu amaç doğrultusunda, veri setindeki anlamlı özellikler ANOVA ve Ki-Kare testleri ile belirlenmiştir. Özellik seçimi sürecinde, her iki yöntem bağımsız olarak uygulanmış ve her test sonucunda ayrı veri setleri oluşturulmuştur. Modelin hedef değişken tahmin

performansını artırmak amacıyla her bir yöntemde on anlamlı özellik çıkarılmıştır. Çıkarılan bu özellikler, modelin sınıflandırma başarısını iyileştirmek amacıyla analiz sürecine entegre edilmiştir.

Özellik seçimi sürecinin tamamlanmasının ardından, çıkarılan özellikler kullanılarak oluşturulan veri setlerine StandardScaler yöntemi uygulanmıştır. Bu işlem ile tüm değişkenlerin aynı ölçek aralığında standardize edilmesi sağlanarak, model üzerindeki değişkenlerin etkilerinin dengelenmesi ve sınıflandırma performansının iyileştirilmesi hedeflenmiştir.

2.3. Makine Öğrenme Algoritmaları

Gerçekleştirilen bu çalışmada bireylerin çevresel farkındalık ve tutum düzeylerini değerlendirmek amacıyla DVM, GA, Çok Katmanlı Algılayıcı (ÇKA), Kuadratik Diskriminant Analizi (KDA) ve Torbalama (Bagging) olmak üzere beş farklı MÖ algoritmasından yararlanılmıştır. İlgili algoritmaların temel çalışma prensipleri aşağıda açıklanmaktadır:

DVM, veri noktalarını maksimum marjın sağlayacak şekilde bir hiperdüzlem ile ayırmayı amaçlayan güçlü bir MÖ algoritmasıdır. Bu yaklaşım, farklı sınıflara ait veri noktalarının birbirinden en uzak şekilde konumlanmasını sağlayarak modelin genelleme performansını artırmaktadır. Böylece DVM, yalnızca eğitim verileri üzerinde etkili olmakla kalmayıp, daha önce karşılaşmamış örnekler üzerinde de yüksek doğrulukla tahminlerde bulunabilmektedir. Bu avantaj, modelin aşırı öğrenmeden kaçınmasına ve farklı veri kümeleriyle karşılaştığında tutarlı sonuçlar üretmesine olanak tanımaktadır. Ancak, bazı veri kümelerinde sınıflar doğrusal olarak ayrılabilir değildir. Bu durumda, DVM'in esnekliği, veri noktalarını daha yüksek boyutlu bir uzaya projekte ederek ayrıştırılabilir hale getiren çekirdek (kernel) fonksiyonları sayesinde artmaktadır. Ayrıca, modelin karmaşıklığı düzenleme (regularization) parametresi ile kontrol edilerek aşırı öğrenme riski minimize edilebilmektedir. Bu özellikleri sayesinde DVM, doğrusal ve doğrusal olmayan problemlerde etkin bir şekilde kullanılmaktadır [15]-[17].

GA, birçok zayıf sınıflandırıcının bir araya gelerek güçlü bir tahmin modeli oluşturan etkili bir topluluk öğrenme algoritmasıdır. Temel olarak KA algoritmasının prensiplerine dayanan bu yaklaşım, her yeni KA'nın, önceki ağaçların hata oranlarını minimize edecek şekilde oluşturulmasına dayanır. Bu süreçte, modelin genel başarımını artırmak amacıyla yanlış sınıflandırılan örnekler üzerinde yoğunlaşmakta ve hata oranı kademeli olarak azaltılmaktadır. GA algoritması, zayıf sınıflandırıcıları ardışık olarak geliştirerek daha dayanıklı ve genellebilir bir model elde etmektedir. Bu iyileştirme süreci, modelin doğruluğunu artırmak için çeşitli ince ayar ve optimizasyon tekniklerini içermektedir. Bunun yanı sıra, GA, eksik veri yönetimi konusunda güçlü bir yetkinliğe sahiptir. Eksik verilerin neden olduğu belirsizlikleri azaltmak adına gelişmiş stratejiler kullanarak veri temizleme süreçlerine olan bağımlılığı en aza indirmektedir. [16]-[18].

ÇKA, denetimli öğrenme yaklaşımlarında yaygın olarak kullanılan, ileri beslemeli bir yapay sinir ağı modelidir. Bu model, giriş katmanından başlayarak bir veya daha fazla gizli katman aracılığıyla çıkış katmanına ulaşan çok katmanlı bir mimariye sahiptir. Her katmandaki nöronlar, önceki katmandan gelen girdileri belirli ağırlıklarla çarpılarak ve

doğrusal olmayan aktivasyon fonksiyonları aracılığıyla işleyerek bir sonraki katmana iletmektedir. Modelin öğrenme süreci, hata fonksiyonunun geri yayılım algoritması kullanılarak minimize edilmesine dayanmaktadır. Bu süreçte, türev tabanlı optimizasyon yöntemleriyle modelin ağırlık parametreleri güncellenmekte ve böylece modelin doğruluk oranı iyileştirilmektedir. Söz konusu optimizasyon süreci, modelin yüksek boyutlu ve doğrusal olmayan veri örüntülerini öğrenme yetisini artırarak daha genel ve genellebilir tahminler üretmesine olanak tanımaktadır [19]. KDA, denetimli öğrenme kapsamında kullanılan istatistiksel bir sınıflandırma algoritması olup, özellikle sınıflar arasındaki ayrımı modelleme sürecinde esneklik sağlamasıyla öne çıkmaktadır. Geleneksel Lineer Diskriminant Analizi (LDA), her sınıfın ortak bir kovaryans matrisine sahip olduğunu varsayarken, KDA her sınıf için ayrı bir kovaryans matrisi kullanmaktadır. Bu yaklaşım, özellikle sınıfların farklı varyans yapıları sergilediği ve doğrusal olmayan ayrım sınırlarının gerektiği durumlarda daha güçlü bir modelleme yeteneği sunmaktadır. KDA, sınıflandırma işlemini Bayes teoremi temelinde gerçekleştirerek, her bir veri örneğinin belirli bir sınıfa ait olma olasılığını hesaplamaktadır. Modelin öğrenme sürecinde, her sınıfa özgü ortalama vektörler ve kovaryans matrisleri hesaplanarak sınıflar arasındaki ayırt edici özellikler belirlenmektedir. Bu özellikleri sayesinde, özellikle karmaşık veri yapılarında ve sınıflar arası varyans farklılıklarının belirgin olduğu senaryolarda yüksek sınıflandırma performansı elde edilebilmektedir [20].

Torbalama, MÖ'de model kararlılığını artırmak ve genelleme hatasını en aza indirmek amacıyla geliştirilen bir topluluk öğrenme (ensemble learning) algoritmasıdır. Temel olarak, yüksek varyansa sahip modellerin aşırı öğrenme (overfitting) eğilimini azaltarak daha güvenilir tahminler üretmesini sağlamaktadır. Torbalama yönteminde, eğitim verisi içerisinden rastgele ve yinelemeli olarak seçilen alt kümeler oluşturularak birden fazla zayıf model (base learners) eğitilmektedir. Bu alt kümeler, orijinal veri kümesinden yerine koymalı (bootstrap sampling) örnekleme yöntemi ile oluşturulmakta olup, her bir alt model farklı bir veri dağılımı üzerinde öğrenme sürecini gerçekleştirmektedir. Daha sonra, elde edilen tüm modellerin tahminleri birleştirilerek nihai karar verilmektedir. Torbalama, özellikle KA gibi yüksek varyansa sahip algoritmalarla kullanıldığında önemli avantajlar sunmaktadır. Bu yöntem, eğitim verisindeki küçük değişimlere karşı modelin duyarlılığını azaltarak daha istikrarlı ve güvenilir tahminler elde edilmesini sağlamaktadır. Bununla birlikte, her bir alt modelin birbirinden bağımsız olarak eğitilmesi, paralel hesaplama teknikleri ile uygulanabilirliği artırarak büyük veri setleri üzerinde de verimli bir şekilde kullanılmasına olanak tanımaktadır [21].

Bu çalışmada kullanılan tüm MÖ algoritmaları, Python programlama dili ve Scikit-learn kütüphanesi kullanılarak gerçekleştirilmiştir. Algoritmaların eğitiminde, Scikit-learn kütüphanesinde tanımlı varsayılan hiperparametre değerleri kullanılmıştır. Gerçekleştirilen bu çalışmada hiperparametre optimizasyonuna gidilmemiş olup, algoritmalar varsayılan ayarlarla değerlendirilmiştir. Model karşılaştırmaları, algoritmaların genel eğilimlerinin değerlendirilmesi amacıyla yapılmış, her bir model varsayılan ayarlarla aynı koşullar altında test edilerek performans farkları gözlemlenmiştir. Gelecek çalışmalarda, her algoritma için hiperparametre ayarlarının optimize edilmesi planlanmaktadır.

2.4. Model Doğrulama Yöntemleri

Veri ayırma ve model değerlendirme, MÖ süreçlerinde modelin performansını doğru bir şekilde değerlendirebilmek için kritik öneme sahiptir. Bu bağlamda, k-çapraz doğrulama (k-fold cross-validation) ve hold-out sıklıkla başvurulan teknikler arasında yer almaktadır.

Daha basit ve hızlı bir veri ayırma tekniği olan hold-out tekniği; veri kümesi belirli bir oranla ikiye (eğitim/test) ayrılmaktadır. Eğitim verisi ile model eğitilirken, test verisiyle modelin başarımı değerlendirilmektedir. Bu teknik daha hızlı sonuçlar verirken, veri kümesinin sadece bir kısmı eğitim veya test için kullanıldığı için modelin genellenabilirliği konusunda daha sınırlı bilgi sağlamaktadır. Ayrıca, rastlantısal veri bölünmesi nedeniyle farklı sonuçlar elde edilme olasılığı bulunmaktadır.

k-çapraz doğrulama tekniğinde veri kümesi k eşit parçaya bölünerek her bir parça sırasıyla test kümesi olarak kullanılmakta, geri kalan k-1 parça ise eğitim verisi olarak değerlendirilmektedir. Bu işlem k kez tekrarlanarak elde edilen performans metriklerinin ortalaması alınarak modelin genel başarısı belirlenmektedir. k-çapraz doğrulama tekniği, modelin genellenabilirliği artırırken aşırı uyum (overfitting) riskini azaltmaktadır.

Gerçekleştirilen bu çalışmada, veri ön işleme sürecinde anlamlı özelliklerin belirlenmesi ve ölçeklendirme işlemlerinin tamamlanmasının ardından, modelleme aşamasına geçilmiştir. Bu kapsamda, her algoritma için belirlenen özellik kümeleri üzerinden eğitim gerçekleştirilmiş, %80 oranındaki eğitim verisiyle 5 katlı çapraz doğrulama uygulanmış ve nihai değerlendirme %20'lik test verisiyle yapılmıştır. Böylece tüm modeller aynı koşullar altında karşılaştırılmıştır.

2.5. Model Performans Değerlendirme Kriterleri

MÖ tabanlı modellerinin başarımları çeşitli performans metriklerine dayanarak değerlendirilmektedir. Modelin sınıflandırma başarısını belirleyen bu ölçütler, doğruluk düzeyinin nesnel bir şekilde ölçülmesine katkı sağlamaktadır. Bu doğrultuda, çalışmada doğruluk, kesinlik, duyarlılık ve F1 skoru gibi yaygın sınıflandırma metrikleri kullanılarak model performansı kapsamlı bir şekilde incelenmiştir. İlgili metrikler için matematiksel ifadeler aşağıda verilmiştir. Bunun yanı sıra önerilen modelin performansını daha iyi anlamak adına, yalnızca en başarılı sınıflandırma sonuçlarını veren algoritma üzerinden pozitif ve negatif örneklerin doğru ya da yanlış sınıflandırılmasına ilişkin ayrıntılar karmaşıklık matrisi ile ortaya konmuştur. Karmaşıklık matrisi, sınıflandırma performansının ayrıntılı bir şekilde incelenmesini sağlayarak her bir sınıf için modelin başarımını dört temel kategori üzerinden değerlendirmeye olanak tanımaktadır: Doğru Pozitifler (DP), model tarafından doğru şekilde pozitif olarak sınıflandırılan örneklerdir; Doğru Negatifler (DN), negatif olup model tarafından doğru şekilde negatif olarak sınıflandırılan örnekleri ifade etmektedir; Yanlış Pozitifler (YP), gerçekte negatif olan ancak model tarafından hatalı biçimde pozitif olarak sınıflandırılan örneklerdir; Yanlış Negatifler (YN) ise pozitif olup model tarafından yanlış bir şekilde negatif olarak sınıflandırılan örneklerdir. Bu kategoriler, modelin sınıflandırma başarımının kapsamlı bir

şekilde değerlendirilmesini sağlayarak farklı hata türlerinin analizi için temel oluşturmaktadır [22].

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (2)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3)$$

$$\text{F1 skor} = 2x \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

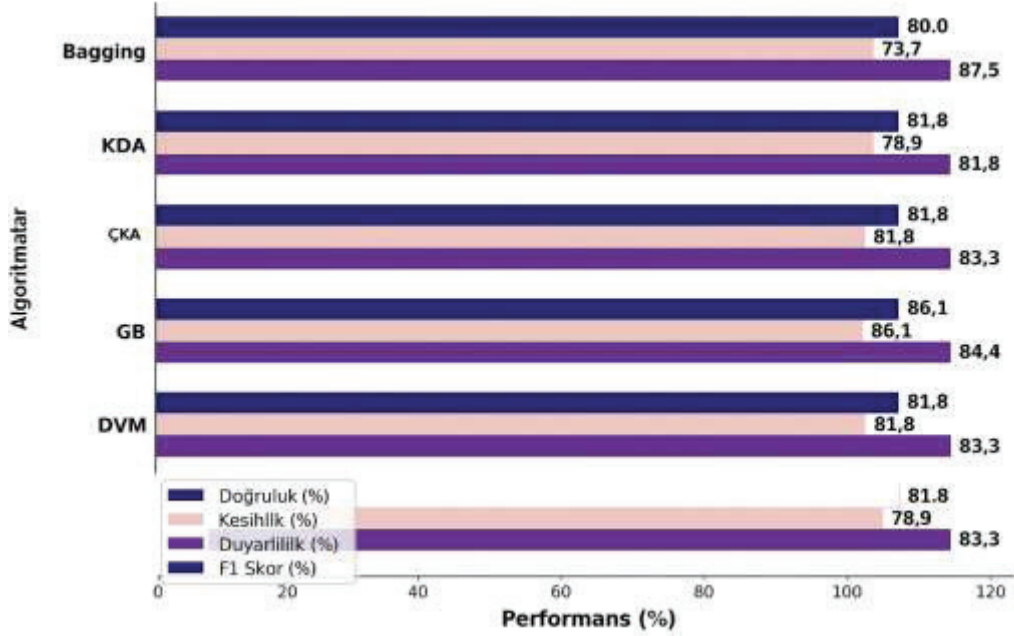
3. Deneysel Sonuçlar

Bu çalışmada, bireylerin çevresel farkındalık ve tutum düzeylerini değerlendirmek amacıyla veri odaklı bir model tasarlanmış ve bu model kullanılarak çevresel tutum düzeylerinin sınıflandırılmasında beş farklı MÖ algoritmasının performansı karşılaştırılmıştır. Model oluşturma sürecinde, öncelikle veri setindeki değişkenlerin sınıflandırma başarısına etkisini belirlemek için ANOVA ve Ki-Kare tabanlı özellik seçim yöntemleri uygulanmıştır. Bu aşama, modelin verimliliğini artırmak ve gereksiz değişkenlerin olası etkilerini en aza indirmek amacıyla gerçekleştirilmiş olup, belirlenen önemli özellikler kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

Özellik seçiminin ardından, sınıflandırma aşamasında DVM, GA, ÇKA, KDA ve Bagging algoritmalarının performansı analiz edilmiştir. Modelin değerlendirilmesi amacıyla veri kümesi, %80 eğitim ve %20 test olarak ayrılmış; ardından modelin genellenebilirliği artırmak ve aşırı öğrenme riskini azaltmak amacıyla eğitim verisi üzerinde 5 katlı çapraz doğrulama yöntemi uygulanmıştır. Bu yaklaşım, veri kümesindeki farklı örneklerin modele katkısını güçlendirerek daha güvenilir sonuçlar elde edilmesini sağlamaktadır. Model eğitiminin tamamlanmasının ardından, test verisi üzerinde doğruluk, kesinlik, duyarlılık ve F1 skoru gibi performans metrikleri kullanılarak kapsamlı bir değerlendirme gerçekleştirilmiştir. Gerçekleştirilen analizlerde, MÖ algoritmalarının sınıflandırma performansları karşılaştırılmış ve elde edilen bulgular detaylandırılmıştır. Bu kapsamda ANOVA testiyle seçilen özelliklerin algoritmaların performanslarına etkisi Şekil 2'de gösterilmiştir.


Şekil 2'deki verilere göre, en yüksek doğruluk oranı %84,4 ile GA tarafından elde edilmiştir. Diğer algoritmaların doğruluk oranları ise %81,8 seviyesinde sabit kalmıştır. Kesinlik metriği açısından, en yüksek değer %87,5 ile Bagging algoritmasında gözlenmiş, bunu sırasıyla %86,1 ile GA, %85,3 ile ÇKA ve %83,3 ile DVM ve KDA algoritmaları takip etmiştir.

Duyarlılık metriğinde, GA algoritması %81,6 ile en yüksek performansı sergilemiş, DVM ve KDA algoritmaları ise %78,9 ile benzer sonuçlar elde etmiştir. ÇKA algoritması %76,3, Bagging ise %73,7 ile bu algoritmaların gerisinde kalmıştır. F1 skoru açısından ise, GA algoritması %83,8 ile en yüksek değere ulaşırken, DVM ve KDA algoritmaları %81,1, ÇKA %80,6 ve Bagging %80,0 değerleriyle sıralanmıştır.



Şekil 2: ANOVA testi ile seçilen özelliklerin sınıflandırıcıların performanslarına etkisi.

Elde edilen bulgular, GA algoritmasının doğruluk, duyarlılık ve F1 skoru metrikleri bakımından diğer algoritmalara kıyasla daha dengeli ve üstün bir performans sergilediğini açıkça ortaya koymaktadır. Özellikle en yüksek doğruluk oranına ulaşması, bu algoritmanın sınıflandırma performansı açısından avantajlı olduğunu göstermektedir. Bu bağlamda, GA algoritmasının elde ettiği sınıflandırma başarısını daha ayrıntılı incelemek amacıyla, ilgili karışıklık matrisi Şekil 3'de sunulmuştur.



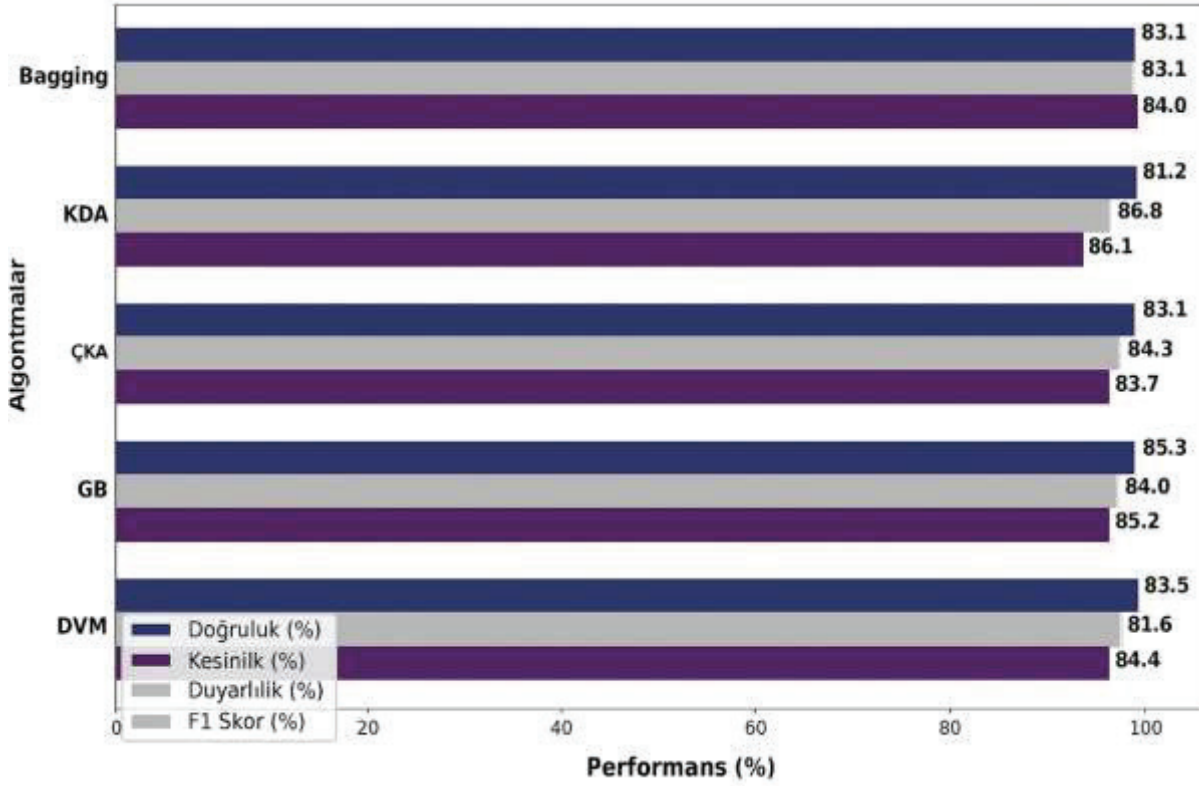
Şekil 3: Önerilen modelin akış diyagramı.

Şekil 3'de sunulan karışıklık matrisine göre, 0 sınıfına ait 39 örneğin 34'ü doğru bir şekilde 0 sınıfına atanırken, 5 örnek yanlışlıkla 1 sınıfına sınıflandırılmıştır. Benzer şekilde, 1 sınıfına ait 38 örneğin 31'i doğru olarak 1 sınıfına atanmış, 7 örnek ise hatalı bir şekilde 0 sınıfına dahil edilmiştir. Bu sonuçlar doğrultusunda, 0 sınıfına ait örneklerin doğruluk oranı %87,18, 1 sınıfına ait örneklerin doğruluk oranı ise %81,58 olarak hesaplanmıştır. Elde edilen bulgular, 0

sınıfının 1 sınıfına kıyasla daha yüksek doğruluk oranına sahip olduğunu göstermekte olup, modelin 1 sınıfına ait örnekleri sınıflandırmada görece daha fazla hata yaptığını ortaya koymaktadır.

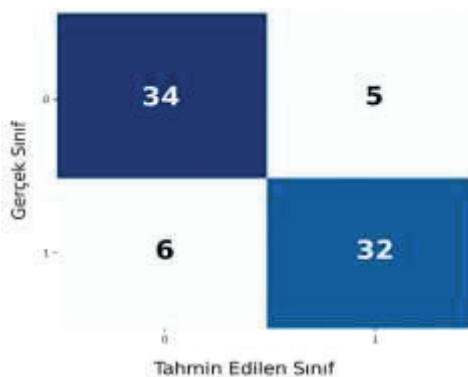
ANOVA testi ile belirlenen özellikler kullanılarak elde edilen sonuçların ardından, farklı bir özellik seçme yöntemi olan Ki-kare testi uygulanmış ve modelin performansı üzerindeki etkisi değerlendirilmiştir. Bu doğrultuda Ki-kare testi ile belirlenen özellikler kullanıldığında MÖ algoritmalarının performans metrikleri Şekil 4'de karşılaştırmalı olarak sunulmuştur.

Şekil 4'den görüldüğü üzere, en yüksek doğruluk oranı %85,7 ile GA algoritmasında elde edilmiştir. Bunu sırasıyla %84,4 ile DVM, %83,1 ile ÇKA ve Bagging algoritmaları takip etmiştir. En düşük doğruluk oranı ise %81,8 ile KDA algoritmasında kaydedilmiştir. Kesinlik metriği açısından en yüksek değer %86,5 ile GA algoritmasında elde edilmiştir. DVM algoritması %86,1, ÇKA ve Bagging algoritmaları ise %82,1 ile sıralanırken, KDA algoritması %78,6 ile en düşük kesinlik değerine ulaşmıştır. Duyarlılık metriği açısından, KDA algoritması %86,8 ile en yüksek performansı sergilemiş, bunu %84,2 ile GA, ÇKA ve Bagging algoritmaları takip etmiştir. DVM algoritması ise %81,6 duyarlılık değeri ile daha düşük bir performans sergilemiştir. F1 skoru açısından en yüksek değer %85,3 ile GA algoritmasında elde edilmiştir. Bunu sırasıyla %83,8 ile DVM, %83,1 ile ÇKA ve Bagging algoritmaları takip ederken, KDA algoritması %82,5 ile en düşük F1 skorunu göstermiştir. Genel olarak GA algoritması tüm metriklerde dengeli ve yüksek performans gösterirken, DVM kesinlik açısından, KDA ise duyarlılık açısından öne çıkmıştır. Ancak bu çalışmada doğruluk metriği öncelikli bir değerlendirme ölçütü olarak ele alındığından, Şekil 5'de en yüksek doğruluk oranına sahip GA algoritmasına ait karmaşıklık matrisi sunulmuştur.



Şekil 4: Ki-Kare testi ile seçilen özelliklerin sınıflandırıcıların performanslarına etkisi.

Şekil 5’de gösterilen karışıklık matrisi incelendiğinde, 0 sınıfına ait 39 örnekten 34’ü doğru şekilde 0 olarak sınıflandırılmış, 5 örnek ise yanlışlıkla 1 sınıfına atanmıştır. Benzer şekilde, 1 sınıfına ait 38 örneğin 32’si doğru şekilde 1 olarak sınıflandırılmış, ancak 6 örnek hatalı olarak 0 sınıfına dahil edilmiştir. Bu doğrultuda, 0 sınıfına ait örneklerin doğru sınıflandırılma oranı %87,18; 1 sınıfına ait örnekler için ise %84,21 olarak hesaplanmıştır. Bu sonuçlar, modelin her iki sınıfta da yüksek doğruluk oranlarına sahip olduğunu, ancak yanlış sınıflandırmaların dikkate alınması gerektiğini göstermektedir.



Şekil 5: Ki-kare tabanlı özellik seçimi uygulanan GA algoritmasına ait karışıklık matrisi.

4. Sonuç ve Tartışma

Bu çalışma, bireylerin çevresel farkındalık ve tutum düzeylerini sınıflandırmak amacıyla veri odaklı bir model geliştirmiş ve beş farklı MÖ algoritmasının performansını karşılaştırmıştır. Model oluşturma sürecinde, veri setindeki değişkenlerin sınıflandırma başarısına etkisini belirlemek için ANOVA ve Ki-Kare bağımsızlık testi gibi istatistiksel yöntemler uygulanmış ve anlamlı özellikler doğrultusunda sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sonuçlar, GA algoritmasının genel olarak en yüksek doğruluk oranına sahip olduğunu göstermiştir. Özellikle ANOVA tabanlı özellik seçimi ile uygulanan GA modeli, diğer algoritmalarla kıyasla daha dengeli ve başarılı bir sınıflandırma performansı sergilemiştir. Ki-Kare testi kullanılarak yapılan analizlerde de GA algoritması en yüksek doğruluk oranına ulaşmış, dolayısıyla çevresel tutumların sınıflandırılmasında bu algoritmanın güçlü bir seçenek olduğu ortaya konmuştur. Bu çalışmanın bulguları, literatürdeki benzer araştırmalarla paralellik göstermektedir. Özellikle çevresel farkındalık ve tutum düzeylerinin MÖ algoritmaları aracılığıyla başarılı bir şekilde tahmin edilebildiği görülmüştür. Bulgular, farklı algoritmaların başarı düzeylerinin, veri setinin yapısı, özellik seçimi ve sınıf dağılımı gibi faktörlere bağlı olarak değişkenlik gösterebildiğini ortaya koymaktadır. Bu durum, modelleme sürecinde algoritma seçiminin yanı sıra veri ön işleme aşamalarının da dikkatle planlanması gerektiğini göstermektedir. Ayrıca, çevresel tutumların analizinde sosyal medya gibi alternatif veri kaynaklarının kullanımı, bireylerin çevreye ilişkin duygu ve düşüncelerini daha geniş bir

bağlamda değerlendirme imkânı sunmaktadır. Mevcut çalışma, veri odaklı yaklaşımların çevresel farkındalık düzeylerinin belirlenmesinde önemli bir araç olabileceğini ortaya koymakla birlikte, bu alandaki araştırmaların henüz başlangıç aşamasında olduğunu ve daha kapsamlı çalışmalara ihtiyaç duyulduğunu da göstermektedir. Gelecekte gerçekleştirilecek çalışmalarda, dengesiz veri yapısının sınıflandırma performansı üzerindeki etkisinin azaltılmasına yönelik gelişmiş örnekleme tekniklerinin uygulanması ve elde edilen sonuçların politika geliştirme süreçlerine entegre edilmesi, bu alandaki katkıyı daha da artıracaktır.

5. Kaynaklar

- [1] R. L. Singh and P. K. Singh, "Global Environmental Problems," in *Principles and Applications of Environmental Biotechnology for a Sustainable Future*, R. Singh, Ed., Applied Environmental Science and Engineering for a Sustainable Future. Singapore: Springer, 2017, pp. 23-45
- [2] J. E. Hardoy, D. Mitlin, and D. Satterthwaite, "Environmental Problems in Third World Cities". London: Taylor & Francis, 2024.
- [3] N. Koklu and S. A. Sulak, "Classification of Environmental Attitudes with Artificial Intelligence Algorithms," *Intelligent Methods in Engineering Sciences*, vol. 3, no. 2, pp. 54-62, 2024.
- [4] S. Çelik, "The effects of climate change on human behaviors," *Environment, Climate, Plant and Vegetation Growth*, pp. 577-589, 2020.
- [5] M. Ahmadi and M. B. Tahoori, "Dynamic reconfigurable IoT security: Challenges and opportunities," *Proc. IEEE*, vol. 106, no. 1, pp. 72-86, 2018.
- [6] X. Guo, K. Huang, and J. Lach, "Energy-adaptive cryptographic solutions for energy-harvesting IoT devices," *IEEE Trans. Circuits Syst. I: Regular Papers*, vol. 63, no. 5, pp. 629-638, 2016.
- [7] L. F. Beiser-McGrath and R. A. Huber, "Assessing the relative importance of psychological and demographic factors for predicting climate and environmental attitudes," *Climatic Change*, vol. 149, pp. 335-347, 2018.
- [8] A. Değirmenci, "Comparison of K-Nearest Neighbors, Decision Tree and Support Vector Machines Methods in Predicting Environmental Attitudes," *Emerging Trends in Electrical and Electronics Engineering*, vol. 4, 2024.
- [9] N. Choudhury, R. Mukherjee, R. Yadav, Y. Liu, and W. Wang, "Can machine learning approaches predict green purchase intention? - A study from Indian consumer perspective," *Journal of Cleaner Production*, vol. 456, p. 142218, 2024.
- [10] D. Amangeldi, A. Usmanova, and P. Shamoï, "Understanding Environmental Posts: Sentiment and Emotion Analysis of Social Media Data," *IEEE Access*, vol. 12, pp. 12345-12356, 2024.
- [11] A. A. Takshé, M. Hennawi, S. E. Jebril, S. Alawi, S. AlZaidan, and A. Okasha, "Investigating determinants of pro-environmental behaviors amongst UAE university students through Q-methodology," *Discover Sustainability*, vol. 4, no. 1, p. 38, 2023.
- [12] Q. Wang, Z. Kou, X. Sun, S. Wang, X. Wang, H. Jing, and P. Lin, "Predictive analysis of the pro-environmental behavior of college students using a decision-tree model," *Int. J. Environ. Res. Public Health*, vol. 19, no. 15, p. 9407, 2022.
- [13] X. Lou, Y. Lin, and L. M. W. Li, "Predicting priority of environmental protection over economic growth using macroeconomic and individual-level predictors: Evidence from machine learning," *J. Environ. Psychol.*, vol. 82, p. 101843, 2022.
- [14] C. Li, L. Li, J. Zheng, J. Wang, Y. Yuan, Z. Lv, ... and W. Liu, "China's public firms' attitudes towards environmental protection based on sentiment analysis and random forest models," *Sustainability*, vol. 14, no. 9, p. 5046, 2022.
- [15] Z. Kadiroğlu, E. Deniz, and A. Şenyiğit, "A comparison of deep learning models for pneumonia detection from chest x-ray images," *J. Faculty Eng. Architect. Gazi Univ.*, vol. 39, no. 2, pp. 729-740, 2024.
- [16] İ. Ş. Yapıcı, R. U. Arslan, ve O. Erkamaz, "Kalp Yetmezliği Tanılı Hastaların Hayatta Kalma Tahmininde Topluluk Makine Öğrenme Yöntemlerinin Performans Analizi," *Karaelmas Fen ve Mühendislik Dergisi*, vol. 14, no. 1, pp. 59-69, 2024.
- [17] E. I. Elsedimy, S. M. AboHashish, and F. Algarni, "New cardiovascular disease prediction approach using support vector machine and quantum-behaved particle swarm optimization," *Multimedia Tools Appl.*, vol. 83, no. 8, pp. 23901-23928, 2024.
- [18] A. Villar and C. R. V. de Andrade, "Supervised machine learning algorithms for predicting student dropout and academic success: a comparative study," *Discover Artificial Intelligence*, vol. 4, no. 1, pp. 2, 2024.
- [19] B. Shankarlal, S. Dhivya, K. Rajesh, and S. Ashok, "A hybrid thyroid tumor type classification system using feature fusion, multilayer perceptron and bonobo optimization," *Journal of X-Ray Science and Technology*, Preprint, pp. 1-25, 2024.
- [20] S. M. Malakouti, M. B. Menhaj, and A. A. Suratgar, "Machine learning and transfer learning techniques for accurate brain tumor classification," *Clinical eHealth*, vol. 7, pp. 106-119, 2024.
- [21] D. V. Nguyen, J. Park, H. Lee, T. Han, and D. Wu, "Assessing industrial wastewater effluent toxicity using boosting algorithms in machine learning: A case study on ecotoxicity prediction and control strategy development," *Environmental Pollution*, vol. 341, p. 123017, 2024.
- [22] R. Janković Babić, "A comparison of methods for image classification of cultural heritage using transfer learning for feature extraction," *Neural Computing and Applications*, vol. 36, no. 20, pp. 11699-11709, 2024.

Özgeçmişler



Dr. Rukiye UZUN ARSLAN, 2004 yılında Sivas Cumhuriyet Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun olan Rukiye UZUN ARSLAN, yüksek lisans eğitimini 2010 yılında, doktorasını ise 2014 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. Şu anda Zonguldak Bülent Ecevit Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği bölümünde doçent olarak görev yapmaktadır. Çalışma alanları arasında beyin bilgisayar arayüz sistemleri, sinyal işleme, biyomedikal sinyal işleme, görüntü işleme, biyomedikal görüntü işleme, derin öğrenme, makine öğrenmesi gibi konular bulunmaktadır.



Dr. İrem ŞENYER YAPICI, 2012 yılında Zonguldak Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun olan İrem ŞENYER YAPICI, yüksek lisans eğitimini 2016 yılında, doktorasını ise 2021 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. Şu anda Zonguldak Bülent Ecevit Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde doktor öğretim üyesi olarak görev yapmaktadır. Çalışma alanları arasında beyin bilgisayar arayüz sistemleri, sinyal işleme, biyomedikal sinyal işleme, görüntü işleme, biyomedikal görüntü işleme, derin öğrenme, makine öğrenmesi gibi konular bulunmaktadır.



Fuat ALKAN, lisans eğitimini Abant İzzet Baysal Üniversitesi Düzce Teknik Eğitim Fakültesi'nde, mühendislik tamamlama eğitimini ise 2015 yılında Zonguldak Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. 2014 yılında öğretmenliğe başlayan Alkan, 2021 yılından bu yana Zonguldak Devrek Mesleki ve Teknik Anadolu Lisesi'nde Elektrik-Elektronik Öğretmeni (Uzman Öğretmen) olarak görev yapmaktadır. Akademik çalışmalarına Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği yüksek lisans programında devam etmektedir.