



BIST Sürdürülebilirlik Endeksinde Yer Alan Firmaların ESG ve Çevresel Skorlarının Makine Öğrenmesi Yöntemleriyle Tahmini

Prediction of ESG and Environmental Scores of Firms Listed in the BIST Sustainability Index Using Machine Learning Methods

Mehmet Hanifi Ateş^{1*}
İdil Özlem Koç²

¹ Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü, Sermaye Piyasası ve Borsa Doktora Programı, İstanbul, Türkiye
mehmetates@marun.edu.tr

² Marmara Üniversitesi, Finansal Bilimler Fakültesi, Sigortacılık Bölümü, İstanbul, Türkiye
iokoc@marmara.edu.tr

*Sorumlu Yazar /Corresponding Author

Öz: Çevresel, sosyal ve kurumsal yönetim (environmental, social, and governance-ESG) skorları, şirketlerin çevresel duyarlılığı, toplumsal sorumluluğu ve kurumsal yönetim ilkelerine uyumu açısından önemli bir değerlendirme aracıdır. ESG göstergelerine ilişkin veriler çoğunlukla yapılandırılmamış metin biçiminde yayımlandığından, sistematik analizleri hem teknik hem yöntemsel açılarından güçleşmektedir. Bu kapsamda, doğal dil işleme (NLP) tekniklerinin metin madenciliği ile birlikte kullanılması, yapılandırılmamış verilerin anlamlı özniteliklere dönüştürülmesinde önemli avantajlar sunmaktadır.

Çalışmada, şirketlerin sürdürülebilirlik performanslarını değerlendirmek amacıyla ESG ve çevresel skorlarının tahmin edilmesine yönelik bir makine öğrenmesi yaklaşımı geliştirilmiştir. 2016-2023 dönemine ait BIST Sürdürülebilirlik endeksinde dahil 95 şirketin Refinitiv veritabanından elde edilen ESG ve çevresel skorları ile şirketlerin sürdürülebilirlik ve entegre faaliyet raporları modelde kullanılmıştır. Metin tabanlı veriler üzerinde uygulanmak üzere toplam 6 farklı makine öğrenmesi algoritması denenmiş; Lojistik Regresyon, Support Vector Machines, GradientBoost ve LightGBM algoritmalarının, doğruluk ve F1 skoru gibi performans ölçütleri açısından en yüksek başarıyı gösterdiği saptanmıştır. Uygulanan modeller, literatürdeki benzer çalışmalarla tutarlılık arz etmiş ve elde edilen sonuçlar, ESG skorlarının tahminlerinde yapay zekâ tabanlı yöntemlerin kullanılabilirliğini ortaya koymuştur.

Anahtar Kelimeler: ESG Skorlaması, Çevresel Skorlama, Sürdürülebilir Finans, Metin Madenciliği, Makine Öğrenmesi

Geliş Tarihi/Received: 01.08.2025
Kabul Tarihi/Accepted: 15.12.2025
Yayımlanma Tarihi/ Published Online: 20.05.2026

Abstract: Environmental, Social, and Governance (ESG) scores serve as an important assessment tool for evaluating companies' environmental awareness, social responsibility, and adherence to corporate governance principles. Since data related to ESG indicators are mostly published in unstructured text format, conducting systematic analyses becomes challenging from both technical and methodological perspectives. In this context, the use of Natural Language Processing (NLP) techniques in combination with text mining offers significant advantages in transforming unstructured data into meaningful features.

In this study, a machine learning approach was developed to predict ESG and environmental scores with the aim of evaluating companies' sustainability performance. The model utilized ESG and environmental scores obtained from the Refinitiv database, along with the sustainability and integrated activity reports of 95 companies included in the BIST Sustainability Index for the 2016–2023 period. A total of six different machine learning algorithms were tested on the text-based data, and it was determined that the Logistic Regression, Support Vector Machines, GradientBoost and LightGBM algorithms achieved the highest performance in terms of evaluation metrics such as accuracy and F1 score. The applied models were found to be consistent with similar studies in the literature, and the results demonstrated the applicability of artificial intelligence-based methods in predicting ESG scores.

Keywords: ESG Rating, Environmental Rating, Sustainable Finance, Text Mining, Machine Learning

Extended Abstract

The concept of sustainability originated in Europe in 1713, tied initially to the responsible use of forest resources. Over time, it evolved and was adopted by French and British foresters through the principle of “continuous and efficient forestry.” It gained global attention with the 1987 Brundtland Report, which defined sustainable development as “meeting the needs of the present without compromising the ability of future generations to meet their own needs.” Since then, sustainability has expanded to include environmental, social, and economic dimensions, becoming a central element of corporate strategy.

The Environmental, Social, and Governance (ESG) framework plays a key role in translating these dimensions into measurable criteria for sustainable investment. ESG scores are widely used to evaluate firms’ performance beyond traditional financial metrics. However, these scores often rely on self-reported data, which may be selective or incomplete. As a result, questions about transparency, consistency, and reliability arise.

Artificial intelligence (AI), particularly machine learning (ML) and natural language processing (NLP), has emerged as a promising solution to these limitations. By extracting structured information from unstructured sources such as sustainability and integrated reports, AI-driven approaches can support more objective and scalable ESG evaluations.

Literature review

Several studies have identified shortcomings in traditional ESG ratings, including inconsistencies and a lack of transparency among rating agencies like Refinitiv and MSCI. In response, researchers have explored ML models to estimate ESG scores using firm-level disclosures. For example, Caudron (2022) and Svanberg and colleagues (2022) used Random Forest classifiers, achieving F1-scores of 75% and 71%, respectively. Meanwhile, advanced deep learning models such as BERT, RoBERTa, and KLUE-RoBERTa have achieved higher performance (F1-scores between 84%–86%), particularly when trained on large datasets. However, studies focusing on emerging markets like Turkey remain scarce. These contexts face challenges such as limited data availability, inconsistent reporting practices, and the lack of standardized frameworks, all of which constrain the effective application of AI.

Contribution to literature

This study contributes to the existing body of knowledge in several ways:

- It represents one of the first in-depth efforts to apply ML and text mining techniques to predict ESG scores in Turkey.
- It builds dual prediction models for both overall ESG scores and the environmental (E) subcomponent.
- It demonstrates the effectiveness of NLP-based preprocessing, transforming unstructured corporate sustainability disclosures into machine-readable features.
- It benchmarks the performance of six widely-used ML algorithms and compares their results with findings from prior studies in developed markets.

Methodology and findings

The dataset comprised sustainability and integrated activity reports, as well as ESG and environmental scores, for 95 companies listed in the Borsa Istanbul Sustainability Index (BIST) from 2016 to 2023. ESG and environmental scores were obtained from the Refinitiv database, while the reports were collected in PDF format from corporate websites. The reports underwent extensive preprocessing, including text cleaning, tokenization, and NLP-based feature extraction, to convert unstructured text into structured data suitable for machine learning. Six supervised machine learning algorithms were tested: Logistic Regression, Support Vector Machines (SVM), Random Forest, Gradient Boosting, XGBoost, and LightGBM. The models were evaluated using widely accepted performance metrics, including accuracy, precision, recall, F1-score, and the area under the receiver operating characteristic curve (ROC-AUC).

Key findings:

- Logistic Regression showed the best performance for predicting ESG scores, achieving 78% accuracy and a 76% F1-score.

- GradientBoost followed closely with 75% accuracy and 72% F1-score, consistent with previous studies.
- For environmental score (E) prediction Logistic Regression and Support Vector Machines delivered exceptional ROC-AUC values between 91% and 96%. This is likely due to the relatively structured and quantifiable nature of environmental indicators such as carbon emissions, energy use, and waste data.
- Although deep learning models like BERT and RoBERTa reported slightly higher F1-scores in the literature, this study demonstrates that traditional ensemble and boosting-based models remain competitive, especially when applied to features extracted from textual data.

Policy implications and future research

This research emphasizes the potential of AI-based techniques to enhance ESG evaluation practices by reducing dependence on self-reported scores and enabling more objective, replicable assessments.

- Regulatory bodies and ESG rating agencies could incorporate ML- and NLP-based tools into their assessment frameworks.
- Harmonization of ESG disclosure standards would improve data quality and facilitate comparability across firms and markets.

Identified limitations and suggestions for future research:

- The limited sample size and class imbalance reduced model generalizability.
- Differences in the structure and content of sustainability reports introduced variability into the feature extraction process.
- Inconsistencies across ESG rating methodologies complicate benchmarking.

Future studies should aim to:

- Expand the dataset by including more firms and longer time spans.
- Incorporate additional emerging markets for comparative analysis.
- Utilize transformer-based deep learning models (e.g., BERT, ESG-BERT) to enhance prediction accuracy and model robustness.

To conclude, this study demonstrates that machine learning and text mining techniques can effectively predict ESG and environmental scores from sustainability reports, even within the constraints of an emerging market context. The findings underscore the growing role of AI in sustainable finance, offering practical tools to enhance transparency, consistency, and trust in ESG evaluations. The proposed approach offers valuable insights for academics, investors, and policymakers aiming to strengthen ESG frameworks in both local and global contexts.

1. Giriş

Sürdürülebilirlik kavramı, Avrupa'da ilk kez 1713 yılında orman kaynaklarının dengeli yönetimi çerçevesinde ortaya konmuş; daha sonra Fransız ve İngiliz ormancılar tarafından "sürekli ve verimli ormancılık" ilkeleri doğrultusunda benimsenmiştir. Buna karşın 1800'lü yıllarda İngiltere'de kömür madenlerinin sürdürülebilir kullanımı gündeme gelmiş olsa da bu konu 1970'li yıllara kadar geniş kapsamlı bir ilgi görmemiştir (Heinberg ve Lerch, 2010). Sürdürülebilirlik kavramı, küresel ölçekte ise ilk kez 1987 yılında yayımlanan Brundtland Raporu ile çevreyle uyumlu kalkınma bağlamında "gelecek nesillerin ihtiyaçlarını tehlikeye atmadan, bugünkü neslin ihtiyaçlarını karşılamak" şeklinde tanımlanarak yaygın bir kabul kazanmıştır (Brundtland, 1987). Sürdürülebilir kalkınma kavramı ise 1970'li yıllarda sürdürülebilirlik ve ekonomik kalkınma politikalarının uyumlaştırılmasıyla ortaya çıkmıştır (Friede vd., 2015). İlk ortaya çıktığı dönemlerde çevresel konulara odaklanan sürdürülebilir kalkınma, zamanla sosyal, ekonomik, etik ve teknolojik meseleleri de kapsayacak şekilde genişlemiştir. Böylece sürdürülebilir kalkınma, ekonomik, çevresel ve sosyal boyutlar üçlemesi olarak şekillenmiştir (Hoverstadt ve Bowling, 2005). II. Dünya Savaşı sonrasında Amerika ve Avrupa'da yaşanan yoğun sanayileşme süreci, çevresel tahribat ve çeşitli sosyal sorunları beraberinde getirmiş; bu durum, kamuoyunda çevre bilincinin gelişmesine ve çeşitli çevresel koruma hareketlerinin başlamasına neden olmuştur. Bu gelişmelerin etkisiyle sermaye piyasalarında da çevresel hassasiyeti yüksek yatırım anlayışları giderek önem kazanmaya başlamıştır (Gao vd., 2021).

ESG (Çevresel, sosyal ve kurumsal yönetim) kavramı, yalnızca finansal getiriye maksimize etmeyi değil, aynı zamanda toplumsal faydayı da gözeten sosyal sorumlu yatırım stratejilerinin bir yansıması olarak ortaya çıkmıştır. ESG terimi ilk kez 2004 yılında Birleşmiş Milletler'in yayımladığı "Who Cares Wins" başlıklı raporda literatüre girmiştir. Takip eden süreçte, 2006 yılında Birleşmiş Milletler Sorumlu Yatırım İlkeleri (UN-PRI) oluşturulmuş ve ESG kriterlerinin çerçevesi kurumsal düzeyde resmileştirilmiştir (UNPRI, 2005). Şirketlerin çevresel etkileri, sosyal sorumlulukları ve kurumsal yönetim yapılarının bütüncül biçimde değerlendirilmesi, ESG'nin yatırım kararlarında belirleyici bir unsur haline gelmesini sağlamıştır. Bu doğrultuda ESG kriterleri, iş dünyasında sorumlu ve sürdürülebilir değer üretiminin temel bileşenlerinden biri olarak ön plana çıkmaktadır. ESG skorları ise başlangıçta sadece finansal şirketlerin kullanımı için geliştirilmiş olmasına rağmen, şirketlerin itibarlarını artırmalarına, yasal baskıları hafifletmelerine, finansal riskleri azaltmalarına ve daha fazla sermaye çekmelerine yardımcı olarak hızla popülerlik kazanmıştır (Clément vd., 2022).

ESG skorları, yatırımcılar açısından şirketlerin sürdürülebilirlik performanslarını değerlendirmek, potansiyel riskleri analiz etmek ve uzun vadeli yatırım stratejileri geliştirmek amacıyla önemli bir ölçüt olarak kabul edilmektedir. Bu ölçütlerin temel amacı, bir şirketin çevresel etkilerini, toplumsal sorumluluk düzeyini ve kurumsal yönetim uygulamalarını nesnel ve bütüncül bir şekilde değerlendirmektir. ESG skorları sayesinde yatırımcılar, şirketleri sürdürülebilirlik kriterlerine göre karşılaştırabilir ve bu verileri yatırım analizlerine entegre etme imkânına sahip olabilmektedir. Şirketler de benzer şekilde ESG skorları aracılığıyla sürdürülebilirlik çabalarının etkinliğini değerlendirme olanağı bulmakta; sürdürülebilirlik çabaları stratejik planlamalarına, operasyonel süreç yönetimi ve yönetsel teşvik sistemlerine dahil edebilmektedir (Kotsantonis ve Serafeim, 2019). ESG skorları, şirketler açısından ise sektörlerin veya ülkelerin ESG kriterlerinin değerlendirilmesine dayalı olarak puanlandığı için, şirketlerin kurumsal ölçütler ve yatırım endeksleri tarafından izlenebilir hale gelmelerine olanak sağlamaktadır (Pagano vd., 2018). ESG'nin çevresel, sosyal ve kurumsal yönetim olmak üzere üç temel faktörü, 2004 yılında önerildiği tarihten bu yana Avrupa, Amerika ve diğer gelişmiş ülkelerde aktif bir şekilde uygulanmaktadır. ESG'nin popülerliği arttıkça çevresel, sosyal ve kurumsal yönetim faktörlerinin gelişimi hız kazanmış ve ESG dünya genelinde araştırmacıların ilgisini çekmeye devam etmektedir (Li vd., 2021).

Günümüzde birçok şirket detaylı sürdürülebilirlik raporları hazırlamakta ve yıllık raporlarında şirketlerinin ESG davranışları hakkında bilgiler sunmaktadır. Yayımlanan raporların çoğu değerlendirilen şirketler tarafından sağlandığından, şirketlerin kendileri için olumsuz notlamada bulunacaklarını varsaymak gerçekçi değildir. Ayrıca ESG ve sürdürülebilirlik raporlarının belirli standartları olmadığından, şirketler bu raporlardaki bilgiler için denetime tabi tutulmamakta ve bu nedenle kendi ESG davranışlarını daha olumlu gösterme eğiliminde olabilmektedir (Pasch ve Ehnes, 2022). Henriksson ve arkadaşları (2019) tarafından yapılan mevcut ESG metodolojilerindeki sınırlamaların ele alındığı çalışmada, giriş verilerinin genellikle gönüllü olduğu, oldukça seyrek olduğu ve farklı ESG veri sağlayıcıları arasında puanlama metodolojilerinin değişkenlik gösterdiği vurgulanmaktadır. Bu durum, şirketlerin ESG performansını değerlendirmek için önemli bir zorluk oluştururken özellikle de bu verilerin sürekli olarak sağlanması ve değerlendirilmesi için gereken çaba göz önüne alındığında, özellikle sosyal medya veya haber verileri gibi büyük metin verileriyle çalışılırken karşılaşılan zorluklar daha da belirgin hale gelmektedir. ESG skorlaması için gerekli verilerin eksikliği, ESG stratejilerinin daha geniş bir şekilde benimsenmesini engelleyen önemli bir faktör olarak öne çıkmaktadır. ESG veri sağlayıcıları tarafından kullanılan metodolojilerdeki tutarsızlık, bir portföy oluşturmak için kullanıldığında büyük farklılıklara yol açabilmesi nedeniyle yatırımcıların doğru ve güvenilir ESG değerlendirmelerine ulaşma sürecinde karşılaşılan zorlukları artırmaktadır (Yeprem, 2022).

ESG skorlamasıyla ilgili bazı metodolojik sorunlar ve eleştiriler literatürde sıkça dile getirilmektedir. ESG skorlaması yapan kuruluşlarının değerlendirme süreçlerinde kullandıkları kriterleri ve metodolojileri yeterince şeffaf şekilde açıklamaması, sistemin güvenilirliğini zedelemektedir. Bu bağlamda, aynı şirketin farklı derecelendirme kuruluşları tarafından farklı skorlarla değerlendirilmesi, yatırımcılar açısından kafa karışıklığına ve ölçülebilirlik sorunlarına yol açmaktadır (Pagano vd., 2018). Bu çalışmada, söz konusu belirsizliklerin ve metodolojik çeşitliliğin ESG skorlarının analitik güvenilirliği üzerindeki etkisi dikkate alınarak, sürdürülebilirlik raporları vasıtasıyla ESG skorlarının tahmin edilmesi amaçlanmaktadır.

Sürdürülebilir yatırımlar, finans sektörünün diğer alanları gibi son zamanlarda büyük veri çağının içine girmiştir. Şirketler sürdürülebilirliğe olan bağlılıklarını göstermek için kurumsal sosyal sorumluluk raporları ile iletişimlerini artırırken dış kaynaklardan elde edilen veriler, haber bültenleri ve sosyal medya içerikleri de son yıllarda önemli ölçüde artış göstermiştir. Elde edilen verilerdeki artışla birlikte ESG yatırım ekosisteminde büyük veri ve yapay zekanın kullanımı, özellikle makine öğrenmesi ve doğal dil işleme (NLP) alanlarındaki gelişmelerle ivme kazanmıştır. Geleneksel finans alanında olduğu gibi makine öğrenmesi ve doğal dil işleme tekniklerinin alternatif skorlama yaklaşımlarına en büyük katkısı, yapılandırılmamış verileri maliyet ve zaman açısından verimli bir şekilde işleyebilme yeteneğine dayanmaktadır. Sürdürülebilirlik açıklamalarındaki bilgilerin çoğunun yapılandırılmamış formatta sunulması, verimliliğini artırmayı hedefleyen geleneksel derecelendirme ajansları ve yatırımcılar için metin madenciliği yöntemlerini cazip bir seçenek haline gelmiştir (Caudron, 2022; Gupta vd., 2020; Kiriu ve Nozaki, 2020; Shahi vd., 2014).

2. ESG Skorlarının Belirlenmesi

ESG, yatırımcılar tarafından şirketlerin davranışlarını ve gelecekteki finansal performansını değerlendirmek amacıyla kullanılan bir strateji olarak kabul edilmektedir. ESG yaklaşımı, şirketlerin sürdürülebilir gelişimini değerlendirmek için önemli bir rol oynamaktadır. ESG'ye olan ilgi hızla artmasına rağmen ESG için genel kabul görmüş bir endeksin henüz oluşturulmamış olması nedeniyle değerlendirme kriterleri skorlama yapan kuruluşlar arasında farklılıklar göstermektedir. ESG skorlama kriterlerinin eksikliği şirketler ve yatırımcılar için kafa karışıklığı yaratması nedeniyle ESG uzmanlarının rolü giderek daha fazla önem kazanmaktadır (Zaccone ve Pedrini, 2020). Araştırmacılar ESG analizinde yapay zekâ algoritmalarını, özellikle de makine öğrenmesi ve derin öğrenme yöntemlerini önermekte; ancak veri setlerinin toplanması hala büyük bir zorluk olarak karşımıza çıkmaktadır. Karbon emisyonu gibi çevresel verilere nispeten erişilebilirirken; sosyal ve yönetimle ilgili verilerin toplanması ve standartlaştırılmasının oldukça zor olmasına karşın, sosyal medya gibi platformlarda yayımlanan sosyal ve yönetim faaliyetleri ile ilgili metin verilerini toplamak için doğal dil işleme etkin bir çözüm sunmaktadır (D'Amato vd., 2021). Yatırımcıların büyük veri ve yapay zekâ entegrasyonunun özellikle önyargılarla başa çıkmada etkili olabileceğine inanması, makine öğrenmesi ve metin madenciliği tekniklerinin birleştirilmesi sayesinde değerlendirme ajanslarının güvenilirlik, şeffaflık ve önyargı gibi mevcut sorunlara çözüm bulma potansiyeli taşımaktadır (Caudron, 2022; Wong ve Petroy, 2020). Ancak makine öğrenmesi ve metin madenciliği yöntemlerinin metodolojilere dahil edilmesi yeni bir aşamada olduğundan, araştırma ve uygulamanın henüz gelişme sürecinde olduğu değerlendirilmekte ve sürdürülebilir finans dünyasında metin madenciliğinin somut kullanımı üzerine odaklanılması oldukça ilgi çekici gözükmektedir.

ESG skorları, bir şirketin çevresel, sosyal ve yönetim uygulamalarını değerlendirirken çeşitli veri kaynakları temel alınarak hesaplanmaktadır. ESG skorlaması için esas alınan veriler, düzenleyici kurumlar, şirket raporları, halka açık finansal veriler, firmaların gönüllü olarak paylaştığı bilgiler, sivil toplum kuruluşları, borsa hareketleri, kurumsal sosyal sorumluluk raporları ve haber kaynaklarından sağlanmaktadır (Şişman ve Çankaya, 2021).

Tablo 1

Derecelendirme Kuruluşlarının ESG Kategori Skorları

ESG Bileşenleri	Thomson Reuters	MSCI	Bloomberg	
Çevresel	Kaynak Kullanımı	İklim Değişimi	Karbon Emisyonları	
	Emisyonlar	Doğal Kaynaklar	İklim Değişimi Etkileri	
Sosyal	İnovasyonlar	Karbon Emisyonları	Kirlilik	
		Kirlilik ve Atık	Atık Tasfiyesi	
		İklim Değişimi Etkileri	Yenilenebilir Enerji	
		Çevresel Fırsatlar	Kaynakların Azalması	
		İşgücü	Beşerî Sermaye	Tedarik Zinciri
		İnsan Hakları	Ürün Sorumluluğu	Ayrımcılık
	Topluluk	Paydaş Karşılığı	Siyasi Katkılar	
	Ürün Sorumluluğu	Sosyal Fırsatlar	Çeşitlilik	
			İnsan Hakları	
			Topluluk İlişkileri	

Tablo 1(Devamı)

Yönetişim	Yönetim Paydaşlar KSS Strateji	Kurum Yönetimi Kurum Davranışları	Birikimli Oylama Yetkili Tazminatı Paydaşların Hakları Devir İşlemleri Aşamalı Yönetim Kurulu Bağımsız yöneticiler
-----------	--------------------------------------	--------------------------------------	---

Tablo 1’de, üç ana derecelendirme kuruluşunun hangi alt kategorilerde değerlendirme yaptığı gösterilmekte olup, her bir alt kategori altında detaylı kriterlerin incelenmesi ile nihai skorlar oluşturulmaktadır. ESG skorlarının hesaplanmasında kullanılan metodoloji, kuruluşlar arasında farklılık gösterse de puanlamada dikkate alınan bazı temel unsurların genellikle ortak olduğu görülmektedir. ESG kriterleri, yatırımcılara bir şirketin faaliyetlerini değerlendirirken, şirketin uzun vadeli finansal performansını öngörmede rehberlik etmektedir.


Çevresel boyut (“E”), iklim değişikliği, çevre kirliliği, doğal kaynak yönetimi ve su kıtlığı gibi konuları kapsarken, sosyal boyut (“S”), çalışan hakları, toplum üzerindeki etkiler, insan hakları ve etik dışı ürün veya hizmet üretimi gibi alanları içermektedir. Yönetişim boyutu (“G”) ise şirketin iç yapısındaki politika, uygulama ve kuralları, yani kurumsal yönetimi ve şeffaflığı temsil etmektedir (Ting vd., 2019).

ESG Kombine Skoru (ESGC), ESG puanını ESG tartışmaları ile birleştirerek, şirketin sürdürülebilirlik performansını ve zaman içindeki davranışını kapsamlı bir şekilde değerlendirmek için kullanılmaktadır. ESGC skoru, ESG skoru ve ESG tartışma skoru olmak üzere iki bileşene ayrılmaktadır. ESG skoru, çevresel, sosyal ve yönetim olmak üzere üç ayrı kategoride belirlenen metriklere göre hesaplanmaktadır. ESG tartışma skoru ise 10 tartışma başlığını bir araya getirerek oluşturulmaktadır. ESG Kombine Skoru, ESG skoru ve ESG tartışma skoru arasındaki ilişkiye göre hesaplanmaktadır (Refinitiv, 2023).

Del Giudice ve Rigamonti (2020)’ye göre, çevresel performansın ölçülmesi nispeten daha kolaydır, çünkü kural koyucular ve düzenleyici otoriteler bu konularla daha net bir şekilde ilgilenmektedir. Sosyal performans gerektiği kadar detaylı incelenmemekte ve ölçülmesi daha zor olmaktadır; ayrıca sosyal konularda kural koyucular ve düzenleyicilerin tavsiye vermesi daha karmaşık hale gelmektedir. Yönetim performansı ise çevresel ve sosyal performansa kıyasla daha kolay ölçülebilmektedir.

Şekil 1

ESG Kategori Skorları ve Alt Kategorileri



Kaynak: Refinitiv, <https://www.lseg.com/>, (05.10.2024).

Yapay zekâ ve doğal dil işleme teknolojilerinin ESG skorlamasında kullanılmasının en çok vurgulanan avantajları arasında daha sağlam, daha şeffaf ve daha karşılaştırılabilir skorlar yaratma potansiyelleri bulunmaktadır (Hughes vd., 2021; Wong ve Petroy, 2020). Geleneksel derecelendirme kuruluşlarının aksine makine öğrenmesi ve yapay zekâ kullanan kuruluşlar, insan analizi faktörünü minimize ederek skorlarındaki önyargı riskini sınırlayabileceklerini iddia etmektedir. Metin madenciliği, insan hatalarını azaltarak objektifliği artırabilmekte ve bu sayede ESG skorlamasının kalitesini yükseltebilmektedir (Kiriü ve Nozaki, 2020). Tamamen otomatik çözümlere dayanmanın bir diğer avantajı ise şirket açıklamalarında gizli kalmış özelliklerin ortaya çıkarılmasını mümkün kılabilmesidir. Makine destekli analizlerin büyük miktarda veriyi bulma ve işleme kapasitesi derecelendirme kuruluşlarının haber bültenleri ve sosyal medya içerikleri gibi bağımsız ve güvenilir verilere erişimini de artırmıştır.

(Antoncic, 2020). Böylece derecelendirme kuruluşları, değerlendirilen şirketler tarafından bildirilen bilgilere olan bağımlılıklarını azaltarak, öz-bildirim önyargısını önemli ölçüde düşürebilmekte ve nihai yatırımcıların gözünde daha güvenilir hale gelebilmektedir (Dumont, 2017). ESG performansını tahmin eden çalışmalarda veri sağlayıcılarından elde edilen ESG puanlarındaki farklılıkları açıklamak amacıyla çeşitli değişken setlerine başvurulmaktadır. ESG ile ilgili sorunlar ele alınırken verilerin heterojen ve belirsiz yapısı nedeniyle birçok zorlukla karşılaşmaktadır (Hughes vd., 2021). ESG ile ilgili bilgilerin yapılandırılmamış belgelerden çıkarılması gibi problemler önceki dönemlerdeki çalışmalarda genellikle spesifik sorunlara yönelik elle yapılan müdahaleler gerektiren metin analizi yöntemleri tercih edilmişken, sonraki araştırmalar doğal dil işleme tekniklerinden yararlanarak bu zor süreçleri daha otomatik hale getirmiştir. Doğal dil işleme, geleneksel metin analiz yöntemlerine göre daha fazla yetenek sunarak insan gücüne duyulan ihtiyacı azaltmakta ve ESG skorlaması süreçlerini daha verimli hale getirmektedir (Yeprem, 2022).

3. Literatür İncelemesi

Sürdürülebilirlik açıklamaları üzerine yapılan araştırmalar, kullanılabilir veri kaynaklarının artmasıyla birlikte diğer araştırma alanlarından gelen bilim insanlarının da ilgisini çekmeye başlamıştır. Bu alandaki araştırmacılar, büyük veri kümelerini hızlı bir şekilde analiz etmek için gelişmiş hesaplama yöntemlerinden yararlanmaktadır. Metin madenciliği teknikleri birçok araştırmacının yıllık faaliyet raporları, kurumsal sosyal sorumluluk raporları veya sürdürülebilirlik raporları gibi belgelerden açıklamalı sonuçlar elde etmek için kullandığı önemli bir araçtır.

3.1. Finansal getiri ve ESG skorlaması

ESG açıklamalarının hem finansal hem de finansal olmayan paydaşların ilgisini çektiği ve bunun sonucunda firmaların finansal yapılarının güçlendiği önceki çalışmalarda ortaya koyulmaktadır (Chowdhury vd., 2023; Lee vd., 2022; Shakil vd., 2019). Her iki paydaş türü de şirketlerin ESG bilgilerini şeffaf bir şekilde açıklamalarını beklemektedir. Finansal paydaşlardan olan varlık yöneticileri ve yatırımcılar, yatırım kararlarını verirken giderek daha fazla ESG kriterlerini dikkate almaktadır. ESG verilerinin yatırım performansı ile doğrudan ilişkili olması nedeniyle, finansal paydaşlar yüksek düzeyde ESG açıklaması yapan firmalara daha fazla ilgi göstermektedir (Chowdhury vd., 2023).

Shakil ve arkadaşları (2019), gelişmekte olan ülkelerde faaliyet gösteren 93 adet bankanın 2015-2018 yılları arasında ESG skorları ile finansal ve operasyonel performansını incelemişlerdir. Operasyonel performansı ölçmek için ROA, finansal performansı ölçmek için ise ROE bağımlı değişken olarak kullanılmıştır. Verilerin dinamik yapısı nedeniyle Genelleştirilmiş Momentler (GMM) ile yapılan analizde çalışmaya dahil edilen bankaların çevresel ve sosyal skorlarının bankaların finansal performansı üzerinde pozitif ve anlamlı bir etkisi olduğu, kurumsal yönetim uygulamalarının bankaların finansal performansı üzerinde bir etkisinin olmadığı gözlemlenmiştir.

Ting ve arkadaşları (2019), gelişmekte olan ülkelerdeki 1317 adet ve gelişmiş ülkelerdeki 3569 adet firmanın ESG skorlarının finansal performanslarına etkisini incelemiştir. Tobin Q, ROE ve P/E (F/K) rasyolarının bağımlı değişken olarak incelendiği regresyon probleminde gelişmekte olan ülke firmalarının kaynak kullanımı, iş gücü, insan hakları ve kurumsal sosyal sorumluluk stratejileri açısından daha yüksek ESG girişimlerine sahip olduğu sonucuna varılmıştır.

Lee ve arkadaşları (2022), firmaların finansal rasyolarını kullanarak ESG skorlarını tahmin etmenin yanı sıra ESG skorlarından faydalanarak finansal performansını tahmin etmeye çalışmıştır. Finansal rasyoların ve ESG değişkenlerinin, yatırım sonucunu etkili bir şekilde tahmin edebileceği ve ESG ile yıllık getiri arasında yüksek bir pozitif ilişki olduğu tespit edilmiştir.

Chowdhury ve arkadaşları (2023), 73 ülkeden 6166 adet firmanın makroekonomik göstergelerini kullanarak ESG skorunu altı farklı makine öğrenmesi algoritması ile tahmin ettikleri çalışmada, Random Forest algoritmasının %78,50 ile en yüksek doğruluğu sağladığı bulunmuştur. Değişkenlerin önem faktörleri incelendiğinde bir önceki yılın ESG puanının modelde en yüksek katkıyı sağladığı tespit edilmiştir. ESG skorlarının büyük ölçüde firmanın önceki yılki performansından etkilendiği anlaşılmakta, firmaların büyüklüğünün de ESG skor tahminine önemli katkı sağladığı ifade edilmektedir.

Castellano ve arkadaşları (2024), bir şirketin belirli bir zamana ait ESG skor sınıfını tahmin etmedeki faydasını değerlendirmek amacıyla 2016-2021 döneminde EuroStoxx 600 endeksindeki şirketleri incelemiştir. Bu doğrultuda Random Forest sınıflandırma modeli kullanılarak ESG skoru yüksek

doğrulukla tahmin edilmiştir. En etkili finansal göstergelerden biri olan toplam özkaynak, şirketin sürdürülebilir girişimlere yatırım yapma kapasitesini ve uzun vadeli finansal istikrarını yansıtarak ESG puanlamasında önemli bir rol oynadığı belirtilmiştir.

3.2. Metin madenciliği ile ESG performansının değerlendirilmesi

Şirketler, faaliyetlerinin çevresel, sosyal ve kurumsal yönetim boyutlarını daha şeffaf bir şekilde ortaya koymak için sürdürülebilirlik raporları yayımlamakta; bu raporlar ise yatırımcılar, paydaşlar ve araştırmacılar tarafından şirketlerin sürdürülebilirlik performansının değerlendirilmesinde kullanılmaktadır. Şirketlerin sürdürülebilirlik açıklamalarının ESG skorlarını yansıttığı varsayımı, bu alandaki çalışmaların temelini oluşturmaktadır. ESG skorlaması, sürdürülebilirlik açıklamalarından elde edilen bilgiler aracılığıyla şirketlerin sürdürülebilirlik alanındaki performansını ölçmeyi amaçlamaktadır. Bu durum, ESG skorlaması ile sürdürülebilirlik açıklamaları arasındaki ilişkinin daha derinlemesine incelenmesine ve anlaşılmasına önemli katkılar sağlamaktadır. Günümüzde sürdürülebilirlik raporlaması uygulamalarının giderek artması, bu açıklamalara dayalı ESG skorlamasını birçok araştırmacının önemli bir konusu haline getirmiştir. Shahi ve arkadaşlarına (2014) göre sürdürülebilirlik açıklamaları şirketlerin çevresel performansı ile ilgili isteği, çevresel sorumluluğun kabulü, rekabet avantajı sağlama, sosyal onay elde etme ve yasal uyumluluğu gösterme gibi çeşitli motivasyonlar doğrultusunda yapılmaktadır. Başka bir görüşe göre ise yüksek ESG skoruna sahip şirketler aynı zamanda daha fazla ESG bilgisi açıklamalıdır. Bu bağlamda, zayıf ESG skoruna sahip şirketlerin algıyı değiştirmek ve paydaşların sürdürülebilirlik performansına ilişkin baskılarını azaltmak için daha fazla açıklama yapma eğiliminde olacağı ve kurumsal açıklamaların daha çok sosyal baskılarla şekillenmekte olduğu savunulmaktadır (Caudron, 2022; Shahi vd., 2014; Verbeeten vd., 2016).

Sürdürülebilirlik açıklamaları ile ESG skoru arasındaki ilişkiye dair sonuçlar da oldukça ayrıntılıdır. Verbeeten ve arkadaşları (2016), kurumsal sosyal sorumluluk raporlarının sürdürülebilirlik boyutlarıyla ilgili önemli bilgiler içerdiğini ancak bu bilgilerin sürdürülebilirliğin tüm boyutları için aynı düzeyde olmadığını gözlemlemiştir.

Yatırımcıların yalnızca açıklamalara dayanarak iyi ve kötü ESG skorunu ayırt etmelerine yardımcı olabilecek dilsel kalıpları belirlemeye dair çalışmalar da dikkat çekmektedir. Bacha ve Ajina (2020), cümle uzunluğu ve kelimelerin karmaşıklığı gibi yüksek okunabilirlik seviyesinin daha iyi bir ESG skoru ile ilişkili olduğunu göstermiştir. Clarkson ve arkadaşları (2020), iyi kurumsal sosyal sorumluluk performansına sahip şirketlerin raporlarına dair ek dilsel özellikler tespit etmiştir. İyi performans gösterenlerin daha fazla açıklama yaptığı, daha fazla kelime ve cümle kullandığı ve daha ileri düzeyde yazım yeteneklerine sahip olduğu, daha uzun ve daha karmaşık kelimelerle yazıldığı gözlemlenmiştir.

Székely ve Vom Brocke (2017), 1999 ile 2015 yılları arasında yayımlanan 9.514 adet sürdürülebilirlik raporunu analiz ederek sürdürülebilirlikle ilgili ortak konuları ve uygulamaları belirlemiştir. Çevresel, sosyal ve ekonomik sürdürülebilirlik kategorileri için toplamda 42 konu tespit edilmiş ve genel gözlemler raporlanmıştır. Ning ve arkadaşları (2021) ise GRI veri tabanından topladıkları verilerle konu modelleme analizi yapmış ve çevre, sosyal ve yönetim olmak üzere üç tema belirlemiştir. Bu çalışmalar metin madenciliği tekniklerinin kurumsal sosyal sorumluluk açıklamalarının anlaşılması ve değerlendirilmesi konusundaki önemini göstermektedir.

Literatürde sürdürülebilirlik raporlarının duygu analizi, içerik analizi veya metin sınıflandırması yoluyla özelleştirilmiş ESG skorlarının oluşturulması giderek daha yaygın hale gelmiştir (Gupta vd., 2020; Shahi vd., 2014).

Metin sınıflandırması ve içerik analizi yöntemlerine odaklanan çalışmaların büyük bir kısmı, şirket açıklamalarında ESG ile ilgili konulara yapılan atıfların sıklığının, sürdürülebilirlik faaliyetlerinin sayısı üzerinden ESG skorlarını yansıttığını varsaymaktadır. Ancak, bu yaklaşımın temel varsayımı, metin madenciliği yöntemlerinin önemli bir sınırlılığı olarak da değerlendirilmektedir (Kiriü ve Nozaki, 2020; Verbeeten vd., 2016). Özellikle "iklim" gibi kelimelerin farklı bir ton veya anlamda kullanılabilmesine dair bir bağlantı eksikliğinin, metin analizinde önemli bir sorun oluşturduğu belirtilmektedir (Caudron, 2022).

Kiriü ve Nozaki (2020), sürdürülebilirlik raporlarında ESG ile ilgili kelimelerin sıklığı ve özgünlüğünün, ESG faaliyetlerinin niteliğini tahmin edebileceğini savunmaktadır. Yüksek ESG skoru sergileyen bir firmanın, daha fazla ve aynı zamanda daha spesifik ESG terimlerine yer vermesi beklenmektedir.

Clarkson ve arkadaşları (2020), 2002-2016 yılları arasında ABD şirketlerinin sosyal sorumluluk raporları üzerinde bilgisayar tabanlı metin analizi ile açıklama kalıplarını incelemiştir. Analizlerde kurumsal sosyal sorumluluk raporlarında kullanılan dilsel özelliklerin, şirketlerin gerçek kurumsal sosyal sorumluluk performans tipini ortaya koymada etkili olduğu gösterilmiştir. Özellikle kelime ve cümle sayısının kurumsal sosyal sorumluluk performansını %81 doğrulukla öngörebildiği belirlenmiştir.

Miklosik ve arkadaşları (2021), Avustralya borsasına kote şirketlerin yıllık faaliyet raporlarında çevresel sürdürülebilirlik ile ilgili konuların nasıl açıklandığını içerik analizi yöntemi ile incelemiştir. Şirketlerin %95'inin yıllık faaliyet raporlarında çevresel açıklamalara yer verildiği sonucuna varılmıştır.

ESG skorlarının tahmini için makine öğrenmesi ve büyük veri analitiği yaklaşımlarına olan ilgi giderek artmaktadır. Makine öğrenmesi algoritmalarının, veri setinin yapısına bağlı olarak hem regresyon hem de sınıflandırma yöntemleriyle yaygın şekilde kullanıldığı görülmektedir. ESG skorlarının tahmininde veri madenciliği ve metin madenciliği tekniklerinin kullanılması, makine öğrenmesi algoritmalarının başarılı performans göstermesiyle araştırmacıların bu alana olan ilgisini artırmaktadır. Özellikle, gelişmiş doğal dil işleme teknikleri arasında yer alan BERT algoritmalarının, güçlü bilgisayar sistemleriyle birlikte kullanıldığında daha etkili ve başarılı sonuçlar ürettiği dikkat çekmektedir. Svanberg ve arkadaşları (2022), çalışmalarında ESG kriterlerinin değerlendirilmesi ve şirketlerin kurumsal yönetim skorlarının anlaşılması için 10 yıllık bir dönemi kapsayan 2.517 adet şirketin kapsamlı yönetim verilerine dayanarak yönetim tartışmalarını öngörmek ve çevresel, sosyal, yönetim kriterlerinin yönetim bileşenini değerlendirmek için bir ölçüm geliştirmişlerdir. Çalışmada dokuz farklı makine öğrenmesi algoritması incelenmiş ve bu algoritmalar arasında Random Forest (RF;0.75), GBoost;0.65) ve Yapay Sinir Ağı (ANN; 0.62) gibi algoritmaların diğerlerine göre belirgin derecede daha yüksek bir kesinlik değerine sahip olduğu sonucuna varılmıştır.

Yıldız ve Ağdeniz (2023), Borsa İstanbul XU100 ve XKURY endekslerinde yer alan 83 şirketin yıllık faaliyet raporlarını kullanarak metin madenciliği yöntemleriyle kurumsal yönetim özelliklerini analiz etmiştir. Çalışmada Knn, Naive Bayes ve Karar Ağacı algoritmaları kullanılarak şirketlerin kurumsal yönetim endeksine dahil olup olmadıkları sınıflandırılmıştır. Analiz sonuçlarına göre en yüksek sınıflandırma başarısı %85 doğruluk oranı ile KNN algoritmasında elde edilmiştir.

Nugent ve arkadaşları (2021), 31.605 adet haber makalesini doğal dil işleme yöntemiyle analiz ederek 20 ESG kategorisine sınıflandırılmak için ESG verilerini kullanmıştır. Alan adaptasyonu modeli olan 'BERT' kullanılarak önerilen modelin %84 doğruluk ve %75 F1-skoru ile iyi performans gösterdiği belirtilmiştir. Çalışmada iş ve finans haberlerinden büyük miktarda alan içi veri kullanılarak dil modeli ön eğitimi yapma ve model için veri kümesinin boyutunu arttırma yöntemlerini uygulamışlardır.

Caudron (2022), şirketlerin yıllık faaliyet raporlarını inceleyerek ESG skorlarını tahmin etmek için çeşitli sınıflandırma ve tahmin algoritmaları kullanmıştır.

Kelime frekans verilerinden yola çıkılarak ESG skorları oluşturulmuş ve bu puanlama metodolojisinin kalitesini değerlendirmek amacıyla ESG skorları ile karşılaştırmalar yapılmıştır. Yapılan değerlendirmeler sonucunda, Random Forest sınıflandırıcısının yüksek doğruluk ve F1 skorlarına ulaşabilen tek model olduğu tespit edilmiştir.

Ruberg (2021), GRI veri tabanından Brezilya kalkınma bankasının yıllık faaliyet raporlarından yararlanarak ESG skorlarını hesaplamışlardır. Karşılaştırma yapabilmek amacıyla klasik bir doğal dil işleme yaklaşımı olan Naive Bayes uygulanmış ve %51 doğruluk ve %50,33 F1-skora ulaşılmıştır. RoBERTa ve BERT-large modelleri %88 doğruluk ve yaklaşık %85 F1-skora ulaşarak, çalışmadaki en iyi sonuçları elde etmiştir.

Kartal ve arkadaşları (2024a), BIST Sürdürülebilirlik endeksine dahil 37 şirketin ESG açıklamalarının ESG skoru üzerindeki etkilerini analiz etmiştir. ESG açıklamalarının varlığı, ESG skorlarının önemli bir belirleyicisi olarak tespit edilmiştir. Çevresel açıklamaların, özellikle iklim değişikliği ve enerji yönetimi gibi başlıkların, ESG skorunu en fazla etkileyen faktörler olduğu; yönetim açıklamalarının görece daha düşük etki yarattığı belirtilmiştir.

Depren ve arkadaşları (2025), 2022 ve 2023 yılları için Borsa İstanbul XU100, XU50 ve XU30 endekslerine dahil firmaların sürdürülebilirlik raporları ile çevresel, sosyal ve yönetim skorlarının ESG skorlarını tahmin etmedeki başarısını incelemiştir. Borsa İstanbul'daki farklı likidite düzeylerine sahip şirket gruplarının incelendiği ve makine öğrenmesi algoritmalarıyla gerçekleştirilen analizde,

özellikle çevresel ilkelere dayalı göstergelerin ESG skorları üzerinde daha yüksek açıklayıcı etkisi olduğu tespit edilmiştir.

Lee ve Kim (2023), sürdürülebilirlik raporlarını kullanarak ESG skorlarını doğal dil işleme teknikleri ile verileri yapısal hale getirmiş ve BERT algoritmaları yardımıyla ESG metin sınıflandırması uygulamışlardır. BERT algoritmasının metin sınıflandırmasında %86,66'lık doğruluk skoruyla oldukça başarılı sonuçlar verdiği belirtilmiştir.

Chowdhury ve arkadaşları (2023), 73 farklı ülkenin firmalarının finansal rasyoları ile ESG skorlarını tahmin edebilmek için altı farklı makine öğrenmesi algoritması kullanmışlardır. Çalışmanın bulgularına göre Random Forest yaklaşımı algoritmasının %78,5 doğruluk değeriyle en başarılı tahminci olduğu ifade edilmiştir. Değişkenlerin önemi sonuçlarına göre ise geçmiş döneme ait ESG skorlarının, firma büyüklüğünün ve finansal kaldıraç oranının ESG skorlarının tahmininde önemli etkisi olduğu sonucuna varılmıştır.

Kartal ve arkadaşları (2024b), ESG açıklamalarının ESG skorları üzerindeki etkisini incelemek için BIST'te işlem gören 102 şirketin 2022 ve 2023 sürdürülebilirlik raporları dikkate alınarak yapılan analizde SL modeli, %94 R² doğruluk ile ESG skorlarını başarılı şekilde tahmin etmiştir. Analizler, çevresel bileşenin en yüksek etkiye sahip olduğunu ve kurumsal yönetişimin ESG skorları üzerindeki belirleyici rolü olduğunu vurgulamıştır.

Taskin ve arkadaşları (2025), BIST Sürdürülebilirlik endeksine dahil 50 şirketin 2017–2019 dönemine ait geçmiş ESG skorlarını kullanarak, 2020 yılı ESG performansını tahmin etmeye yönelik makine öğrenmesi modeli geliştirmiştir. Çalışmada geçmiş performansın, gelecekteki ESG skorları için anlamlı bir belirleyici olduğu ortaya konmuştur. Özellikle Random Forest algoritması yüksek R² değeriyle en başarılı model olurken, genel olarak tüm modeller yüksek tahmin gücü sergilemiştir.

Bu çalışmada, şirketlerin ESG ve çevresel skorlarını makine öğrenmesi algoritmalarıyla tahmin edebilmek için Refinitiv'in sağladığı ESG skorlama verileri kullanılmış; yıllık yayımlanan ESG skorları ve şirketlerin yıllık sürdürülebilirlik raporları doğrultusunda 2016–2023 dönemi analiz edilmiştir. Ancak, literatürdeki benzer çalışmalarla karşılaştırıldığında, mevcut firma sayılarının nispeten sınırlı olduğu anlaşılmaktadır. Çalışma sürdürülebilirlik raporlarını kullanarak doğal dil işleme teknikleriyle ESG ve çevresel skorların tahminini yapan ulusal literatürde yapılan ilk çalışma olma özelliğine sahiptir.

Ayrıca uluslararası literatürde sürdürülebilirlik raporlarını kullanarak ESG ve çevresel skor tahminini metin madenciliği ile yapan sınırlı sayıda çalışma olmasının yanı sıra BIST Sürdürülebilirlik endeksinde yer alan firmaları inceleyen öncü araştırmalardan biri olması çalışmanın özgünlüğünü öne çıkarmaktadır.

4. Yöntem ve Veri Seti

4.1. Verilerin toplanması ve metin madenciliği

Bir şirketin ESG skorunu tahmin etmek için literatürde yaygın olarak ESG derecelendirme kuruluşları tarafından sağlanan verilere başvurulmaktadır. Bu çalışmada ESG skorlarını değerlendirmek amacıyla Thomson Reuters'ın ESG veri sağlayıcısı olan Refinitiv'in sunduğu skorlamalar kullanılmaya karar verilmiştir. Clarkson ve arkadaşları (2020) Refinitiv'in kurumsal sosyal sorumluluk performansını değerlendirirken daha kapsamlı bir yaklaşım sunduğunu vurgularken Svanberg ve arkadaşları (2022) ise Refinitiv'in şeffaf, objektif ve denetime tabi bilgi sağlayıcı olma iddiasını öne çıkarmaktadır. Tüm bu nedenlerle çalışmada Refinitiv'in ESG skorlaması güvenilir ve nitelikli bir bilgi kaynağı olarak kullanılmıştır.

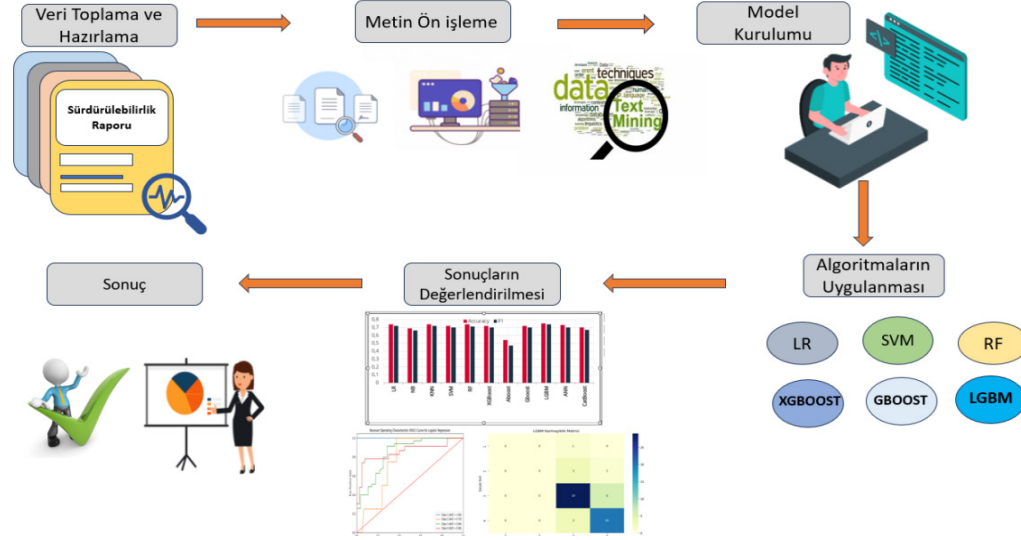
ESG skorları daha anlaşılır ve karşılaştırılabilir hale getirebilmek için puanlar belirli aralıklara göre sayısal (0'dan 100'e kadar) veya harf (D-'den A+'ya kadar ya da D'den A'ya kadar) formatında gösterilebilmektedir.

- D- notu (0.0 ≤ puan ≤ 0.08333): ESG performansı nispeten düşük olan ve somut ESG verilerini kamuoyuyla paylaşmada yetersiz şeffaflığa sahip şirketleri temsil eder.
- D, D+ ve C- notları (0.08333 < puan ≤ 0.333333): Geride kalanlar kategorisini oluşturur ve ortalamanın altında bir ESG performansına işaret eder.

- C, C+ ve B- notları ($0.333333 < \text{puan} \leq 0.583333$): ESG performansı ortalama veya ortalamanın biraz üzerinde olan şirketleri gösterir.
- B, B+ ve A- notları ($0.583333 < \text{puan} \leq 0.833333$): İyi veya çok iyi ESG performansına ve yüksek şeffaflığa işaret eder.
- A ve A+ notları ($0.833333 < \text{puan} \leq 1$): Lider konumda olan, mükemmel ESG performansı gösteren ve ESG verilerini kamuoyuyla yüksek düzeyde şeffaflıkla paylaşan şirketleri ifade eder.

Şekil 2

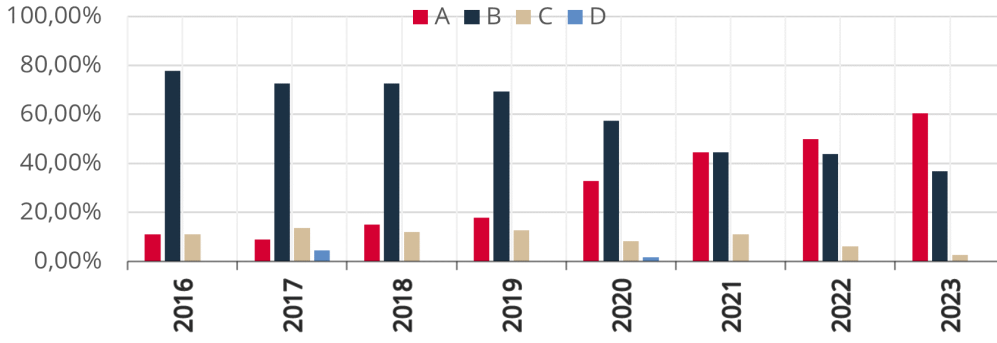
Çalışma Akış Diyagramı



Bu çalışmada şirketlerin küresel ESG performansı ile ilgilenildiğinden dolayı Refinitiv Eikon'da mevcut olan geniş ESG verileri arasından yalnızca ESG ve çevresel skorları dikkate alınmıştır. Firmaların ESG ve çevresel skorlarını metin madenciliği yöntemiyle tahmin edebilmek için sürdürülebilirlik açıklamaları modelde bağımsız değişken olarak değerlendirildiğinde şirketlerin web sitelerinden sürdürülebilirlik raporlarının elde edilebilir olması önemli bir koşul olarak belirlenmiştir. Bu bağlamda, 2016-2023 yılları arasında Refinitiv Eikon verilerine göre BIST Sürdürülebilirlik endeksine dahil olan ESG skoru yayımlanmış ve sürdürülebilirlik açıklamalarını içeren raporları temin edilebilen firmalar çalışma kapsamına alınmıştır. Çalışmanın veri setini oluşturmak amacıyla örnekleme yer alan her bir şirketin resmî web siteleri ziyaret edilerek 2016, 2017, 2018, 2019, 2020, 2021, 2022 ve 2023 mali yıllarına ait sürdürülebilirlik raporları PDF formatında temin edilmiştir. Bazı durumlarda diğer yıllara ait raporların bulunamaması veya yalnızca iki yılda bir yayımlanması gibi açıklama eksiklikleriyle karşılaşmış olması, sekiz yıllık örneklemler arasındaki boyut farkının nedenini açıklamaktadır. Bu çalışmada yalnızca şirketlerin yayınladığı sürdürülebilirlik ve entegre faaliyet raporları dikkate alınarak bu belgelerin sürdürülebilirlik açıklamalarını yansıttığı düşüncesiyle ve bağımsız değişken olarak modelde kullanılmıştır. Şekil 2'de görselleştirildiği gibi sürdürülebilirlik ve entegre raporları PDF formatında toplandıktan sonra metin ön işleme adımları uygulanmış ve bu metinler yapılandırılmış verilere dönüştürülmüştür. Son aşamada, şirketlerin sürdürülebilirlik raporlarının ait olduğu yıl ile eşleştirilen ESG skorları ve çevresel skorları, makine öğrenmesi algoritmaları kullanılarak tahmin edilmiştir.

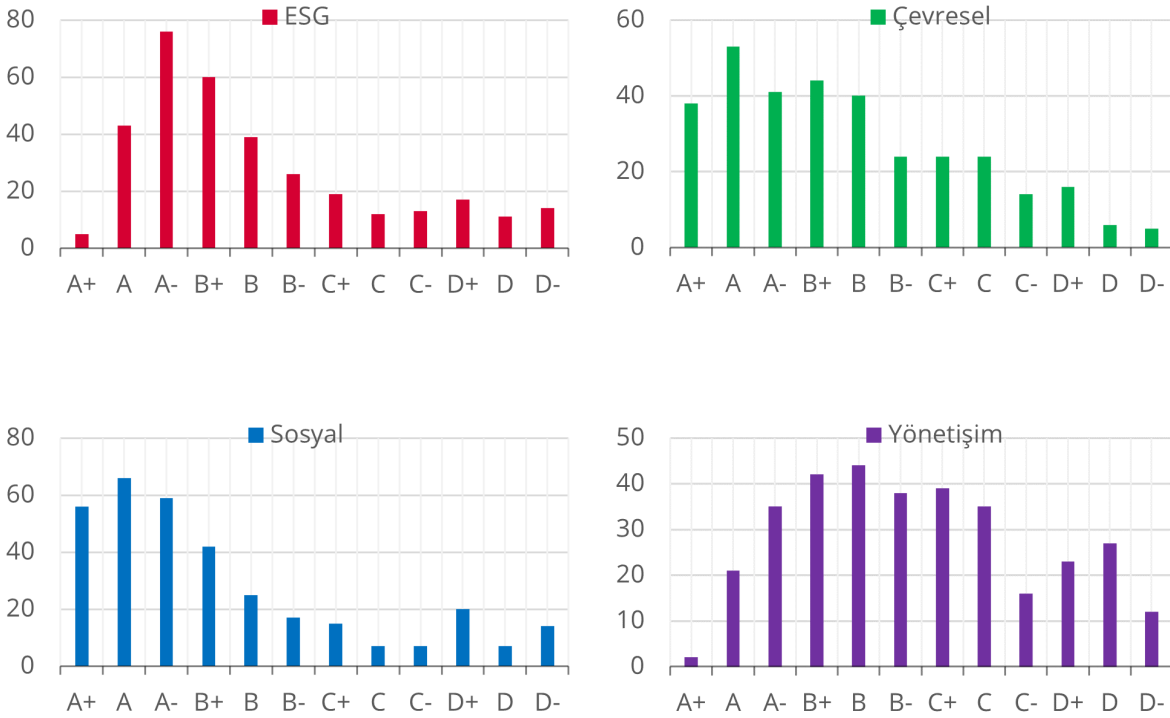
4.2. Veri seti

Çalışmaya, 2016-2023 yılları arasında faaliyet gösteren 95 farklı şirket dahil edilmiş olup, bu dönem boyunca toplam 403 sürdürülebilirlik ve entegre raporu incelenmiştir. Çalışma kapsamındaki şirket sayısı 2016 yılında 18 iken, 2023 yılına gelindiğinde bu sayı 76'ya ulaşmıştır. Literatürde yer alan benzer çalışmalarla karşılaştırıldığında, söz konusu rakamların görece düşük seviyede kaldığı görülmektedir.

Şekil 3*Şirketlerin ESG Skorlarının Dağılımı*

Kaynak: Refinitiv, <https://www.lseg.com/>, (05.10.2024).

Çalışmada kullanılan şirketlerin ESG skor dağılımı Şekil 3 'te incelendiğinde, ESG skorlarının A ve B kategorisinde yoğunlaştığı ve ESG skorlarının C ve D kategorilerinde yeterince temsil edilmediği görülmektedir. 2016–2019 döneminde B skoru en yüksek orana sahipken, A skoru oldukça düşük seviyelerde kalmıştır. 2020 yılı itibarıyla A skoruna sahip şirketlerin oranında belirgin bir artış gözlenmesi, şirketlerin sürdürülebilirlik raporlamasına ve ESG ilkelerine daha fazla uyum sağladığına işaret etmektedir. 2021–2023 yıllarında, A skoruna sahip şirketlerin oranı B skorunu geçmesi ise ESG performansının genel olarak iyileştiğini ve ESG kriterlerine verilen önemin arttığını göstermektedir.

Şekil 4*Şirketlerin ESG Kategorik Skorlarının Dağılımı (2016-2023)*


Kaynak: Refinitiv, <https://www.lseg.com/>, (05.10.2024).

Şekil 4'te BIST sürdürülebilirlik endeksinde yer alan şirketlerin 2016-2023 döneminde ESG'nin alt başlıklarındaki skor dağılımı görülmektedir. Söz konusu dönemde çevresel skor A ve B kategorileri arasında dağılırken sosyal skorların A kategorisinde yoğunlaştığı dikkat çekmektedir. Yönetişim skorunun ise diğer kategorilerden farklı olarak B ve C kategorilerinde yoğunluk göstermektedir. Çalışmada kullanılan 95 adet firmanın sankey diyagramı ile yıllara göre sektörel dağılımının verildiği Şekil 5'te 2023 yılı verilerine göre Refinitiv tarafından skoru belirlenmiş olan 16 finans, 13 sanayi,

10 tüketici hizmetleri, 10 kamu hizmetleri, 10 temel tüketim ürünleri ve 10 hammadde sektöründe faaliyet gösterdiği görülmektedir. Yıllara göre çalışmaya dahil edilen firma sayısında artış olduğu tespit edilmiş; ESG puanlarının ise ağırlıklı olarak B+, A- ve B kategorilerinde yer aldığı belirlenmiştir.

Şekil 5

Şirketlerin ESG Skorlarının Sektörel Dağılımı



Kaynak: Refinitiv, (E.T. 05.10.2024).

Sınıflandırma algoritmalarının performansını değerlendirmek ve farklı algoritmaların başarı düzeylerini karşılaştırmak için çeşitli ölçütler kullanılmaktadır. Bu ölçütler arasında karmaşıklık matrisi (confusion matrix), doğruluk (accuracy), kesinlik (precision) ve duyarlılık (recall) gibi ölçütler öne çıkmaktadır. Makine öğrenmesi sistemlerinin etkinliğini analiz etmek amacıyla kullanılan bu ölçütler, belirli matematiksel ifadelerle tanımlanmakta ve genel olarak performans ölçütleri olarak adlandırılmaktadır. Bu performans ölçütleri, bir algoritmanın sınıflandırma hatalarını ne ölçüde azalttığını, doğru sınıflandırma yapma oranını ve tahmin sonuçlarının güvenilirliğini ortaya koyarak modellerin karşılaştırılmasına ve iyileştirilmesine olanak sağlamaktadır (Zheng, 2015). Karmaşıklık matrisi, bir sınıflandırıcının farklı sınıfları ne kadar doğru şekilde ayırt edebildiğini analiz etmek için kullanılan bir araçtır. Modelin başarısını ve sınıflandırıcıdan kaynaklanan hataları tablo şeklinde sunan bu matris, iki boyutludur; bir boyut gerçek sınıfları, diğer boyut ise tahmin edilen sınıfları gösterir. Genellikle ikili sınıflandırma problemlerinde kullanılsa da çok sınıflı sınıflandırma problemlerinde de uygulanabilir (Markoulidakis vd., 2021).

Şekil 6

Karmaşıklık Matrisi Diyagramı

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Kaynak: Markoulidakis vd. (2021).

Doğruluk, sınıflandırıcının doğru tahmini ne sıklıkta yaptığının ölçülmesidir. Doğru tahminlerin sayısının toplam tahmin sayısına oranıdır. Doğruluk değeri,

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

Pozitif tahmin edici bir değer olarak da bilinen kesinlik (precision) performans ölçütü, tüm sınıflardan doğru olarak ne kadar tahmin edildiğinin bir ölçüsüdür. Çok sınıflı ve dengesiz bir sınıflandırma probleminde, Kesinlik, tüm sınıflardaki gerçek pozitiflerin toplamı ile tüm sınıflardaki gerçek pozitiflerin ve yanlış pozitiflerin toplamına bölünmesiyle hesaplanır. Kesinlik değeri doğru tahmin edilen pozitif örnek sayısının, yani Doğru Pozitif (DP) sayısının, doğru tahmin edilen pozitif örnekler (DP) ile yanlış tahmin edilen negatif örnekler (YP) toplamına bölünmesiyle elde edilir.

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

Duyarlılık ölçütü (recall), yanlış tahmin edilen gerçek pozitiflerin bir göstergesidir. Çok sınıflı ve dengesiz bir sınıflandırma probleminde, tüm sınıflardaki gerçek pozitiflerin toplamının, tüm sınıflardaki gerçek pozitiflerin ve yanlış negatiflerin toplamına bölünmesiyle aşağıdaki formül ile hesaplanır.

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

F-ölçütü (F1), kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Böylelikle, iki önemli performans metriğinin bir arada kullanıldığı bir metrik olarak da F1 değerinin hesaplanması

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

denklem (4)'te gösterildiği gibidir.

4.3. ESG ve çevresel skor tahmininin performans göstergeleri

Bu bölümde ESG skorlarının 4 kategori ile temsil edildiği farklı sınıflandırma modellerinin doğruluk, kesinlik, duyarlılık ve F1-skoru gibi performans ölçütleri açısından nasıl performans gösterdiği incelenmektedir. ESG skorlarının 4 kategori ile temsil edildiği modellere ilişkin veriler Tablo 2'de sunulmuştur. ESG skorlarını tahmin eden modellerin performansları değerlendirildiğinde Lojistik Regresyon, XGBoost ve GradientBoost algoritmalarının öne çıktığı söylenebilir. Modellerde hiperparametre seçimi olmaksızın sırasıyla %72, %74 ve %75 doğruluk skoru ile %68, %72 ve %72 F1 skoru elde edilmiştir. GridSearchCV hiperparametre seçilmesi ile Lojistik Regresyon modelinin doğruluk skoru %72'den %78'e; F1 skoru ise %68'den %76'ya yükselmiş ve Lojistik Regresyon modelinin performans skorlarındaki iyileşme öne çıkmaktadır. SVM ve LightGBM modellerinin doğruluk skorları sırasıyla %70, %72; F1 skorları ise %70 olarak hesaplanmıştır.

ESG skorlarının 4 kategoriye göre tahminlerinin yapıldığı makine öğrenmesi algoritmalarının doğruluk ve F1 ölçütlerine göre değerlendirilmesi Şekil 7'de görselleştirilmiştir. Şekil 7'de yer alan bilgilere göre Lojistik Regresyon, XGBoost ve GBoost sınıflandırma algoritmalarının ESG skorunu tahmin etmede en başarılı modeller olduğu anlaşılmaktadır.


Tablo 2

ESG Skor Tahmini Performans Göstergeleri


Default	Logistic Regression	Support Vector Machine	Random Forest
Doğruluk	0,72	0,68	0,70
Kesinlik	0,66	0,62	0,64
Duyarlılık	0,72	0,68	0,70
F1	0,68	0,65	0,67
Default	XGBoost	GradientBoost	LightGBM
Doğruluk	0,74	0,75	0,72
Kesinlik	0,76	0,69	0,70
Duyarlılık	0,74	0,75	0,72
F1	0,72	0,72	0,70
GridSearchCV	Logistic Regression	Support Vector Machine	Random Forest
Doğruluk	0,78	0,70	0,69
Kesinlik	0,80	0,70	0,63
Duyarlılık	0,78	0,70	0,69
F1	0,76	0,70	0,66

Şekil 7

Sınıflandırma Algoritmaları ile ESG Skor Tahmininin Doğruluk ve F1 Performans Metrikleri

**Şekil 8**

Sınıflandırma Algoritmaları ile ESG Skor Tahmininin Karmaşıklık Matrisleri

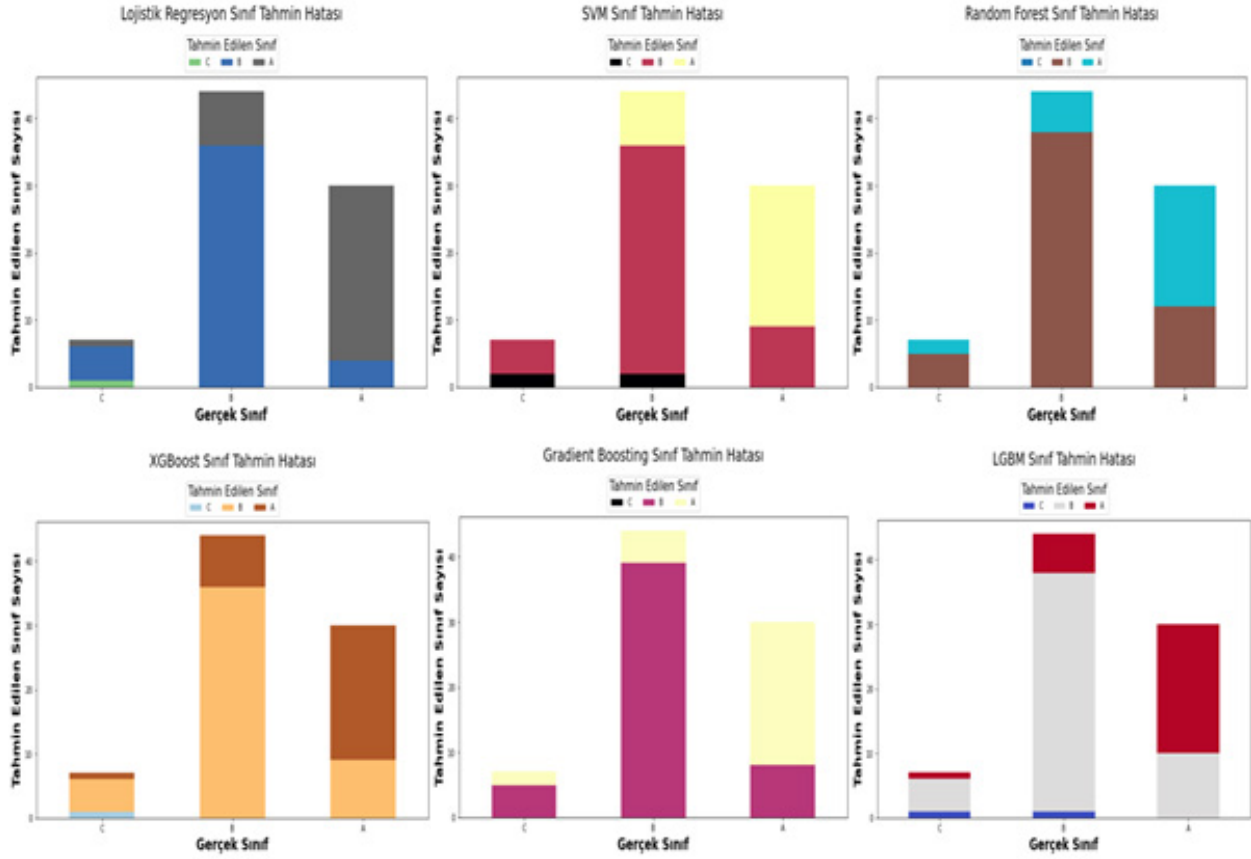


Karmaşıklık matrisleri, her bir modelin sınıflandırma performansını daha detaylı değerlendirme olanağı sağlamaktadır. ESG skorlarının 4 kategori ile tahmin edilmesine yönelik yapılan makine öğrenmesi modellerine ait karmaşıklık matrisleri Şekil 8’de sunulmuştur. Karmaşıklık matrisi verilerine göre, GradientBoost algoritması B kategorisindeki 44 gerçek değerinin 39’unu doğru tahmin ederek yüksek bir başarı sergilemiştir. Random Forest algoritması B kategorisindeki değerleri 38 kez doğru tahmin ederken; XGBoost ve LightGBM algoritmaları 37 kez, Lojistik Regresyon 36 kez, SVM algoritması ise 34 kez doğru tahminde bulunmuştur. Bu sonuçlar Random Forest, XGBoost, GradientBoost ve LightGBM algoritmalarının B kategorisinin doğru tahmin edilmesinde yüksek performans sergilediğini göstermektedir. A kategorisinde ise Lojistik Regresyon modeli 30 gerçek değerinin 26’sını doğru tahmin ederek öne çıkmaktadır. XGBoost ve GradientBoost algoritmaları A kategorisinde 22, SVM 21, LightGBM ise 20 doğru tahmin gerçekleştirmiştir. Bu sonuçlara göre A kategorisinde Lojistik Regresyon, XGBoost ve GradientBoost modellerinin daha başarılı tahminler yaptığı görülmektedir. Şekil 8’de yer alan bilgilere göre, C kategorisi Lojistik Regresyon, SVM, XGBoost ve LightGBM modelleri ile doğru tahmin edilirken; Random Forest ve GradientBoost modeli ile C kategorisinin doğru tahmin edilememesi dikkat çekmektedir. C kategorisinde yaşanan başarısızlığın veri setindeki örneklem dengesizliklerinden veya C kategorisinin ayırt edici özelliklerinin belirgin olmamasından kaynaklandığı düşünülmektedir.

Sınıflandırma tahmininde kullanılan algoritmaların sınıf tahmin hatalarının görselleştirilmiş hali Şekil 9’da sunulmaktadır. ESG skorlarının dört kategoriye ayrıldığı modelde algoritmaların B sınıfını yüksek doğruluk oranıyla tahmin ettiği gözlemlenmiştir. C sınıfının tahmininde Lojistik Regresyon, SVM, XGBoost ve LightGBM algoritmalarının başarılı olduğu, Random Forest ve GradientBoost algoritmasının doğru tahmin yapamadığı görülmektedir. A sınıfı tüm algoritmalar tarafından yüksek doğrulukla tahmin edilirken, C sınıfının ise tüm algoritmalarda yüksek oranda yanlış tahmin edilmesi dikkat çekici bir sonuç olarak değerlendirilmektedir.

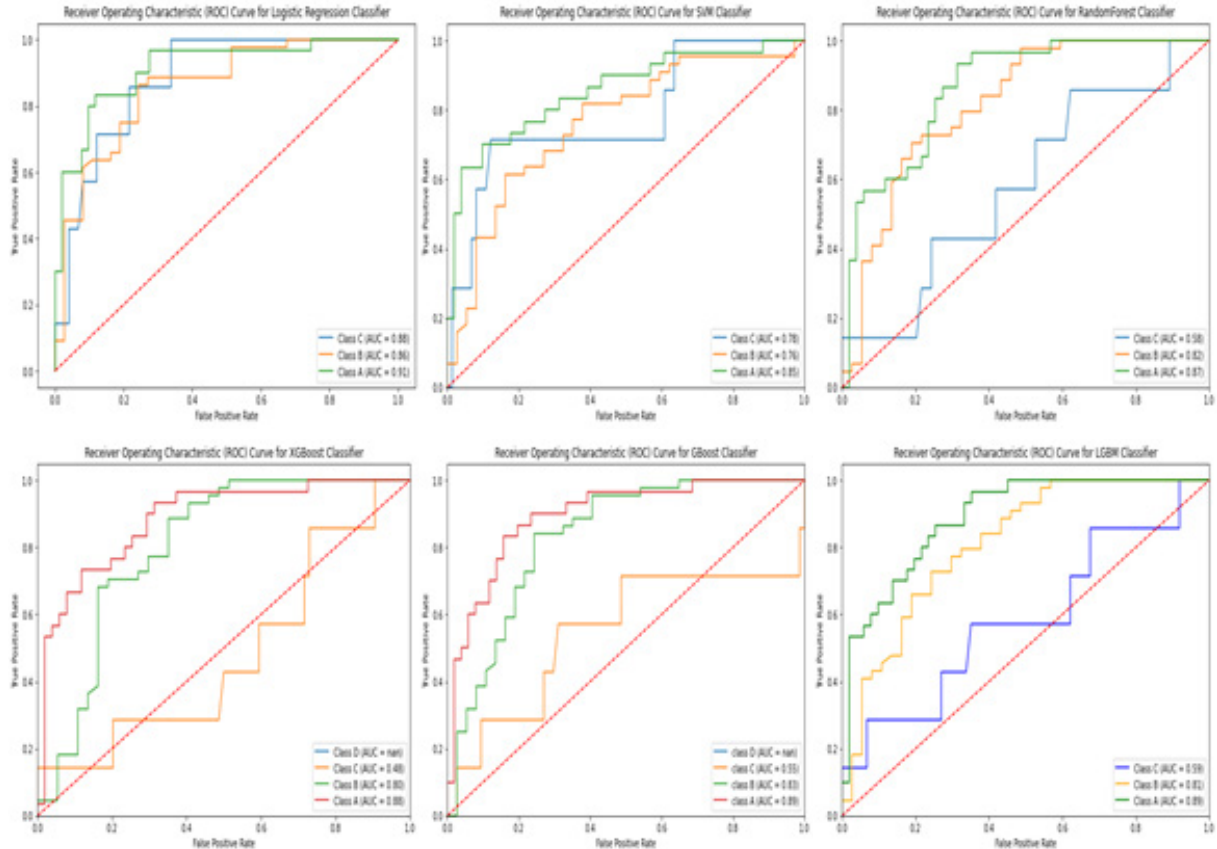
Şekil 9

Sınıflandırma Algoritmaları ile ESG Skor Tahmininin Sınıf Tahmin Hatası



Şekil 10

Sınıflandırma Algoritmaları ile ESG Skor Tahmininin ROC-AUC Eğrileri



ROC eğrileri, bir modelin sınıflandırma performansını değerlendirmede kullanılan yaygın bir yöntemdir. Grafikte yer alan ROC eğrileri, her sınıf için Doğru Pozitif Oranı (True Positive Rate - TPR) ve Yanlış Pozitif Oranı (False Positive Rate - FPR) arasındaki ilişkiyi göstermektedir. ROC eğrisi, modelin performansını daha net anlamak için çizilir ve Eğri Altındaki Alan (AUC - Area Under Curve) değeri ile modelin doğruluğunu ölçmektedir. AUC değeri, 0 ile 1 arasında değişir ve değer 1'e yakın olması, modelin o sınıf için daha yüksek bir doğrulukla tahmin yaptığını göstermektedir (Zheng, 2015).

Şekil 10 incelendiğinde Lojistik Regresyonun AUC değerlerinin sınıflar arasında yakın değerler aldığı görülürken özellikle diğer modellere kıyasla yüksek performans gösterdiği görülmektedir. SVM, diğer modellere kıyasla daha yüksek AUC değerleri ile C sınıfının tahminini yaptığı anlaşılmaktadır. GradientBoost ve LightGBM algoritmaları, A kategorisinde %89, B kategorisinde ise sırasıyla %83 ve %81 AUC değerlerine ulaşarak daha tutarlı ve güvenilir sonuçlar sağlamaktadır. Random Forest algoritmasının A kategorisi için %87, B kategorisi için %82 AUC değerleri ile tahmin başarısı orta düzeyde olup, modelin performansının genel olarak iyi olduğu değerlendirilmektedir. XGBoost modelinin AUC değerleri ise A kategorisi için %88 ve B kategorisi için %80 olup görece yüksek ve dengeli olması ESG skoru tahminlerinde başarılı sonuçlar sunmasını sağlamaktadır.

Tablo 3

Çevresel Skor Tahmini Performans Göstergeleri

Default	Logistic Regression	Support Vector Machine	Random Forest
Doğruluk	0,77	0,75	0,73
Kesinlik	0,69	0,68	0,65
Duyarlılık	0,77	0,75	0,73
F1	0,72	0,71	0,68
Default	XGBoost	GradientBoost	LightGBM
Doğruluk	0,65	0,69	0,73
Kesinlik	0,63	0,64	0,70
Duyarlılık	0,65	0,69	0,73
F1	0,63	0,66	0,71
GridSearchCV	Logistic Regression	Support Vector Machine	Random Forest
Doğruluk	0,78	0,78	0,73
Kesinlik	0,71	0,69	0,64
Duyarlılık	0,78	0,78	0,73
F1	0,74	0,73	0,68

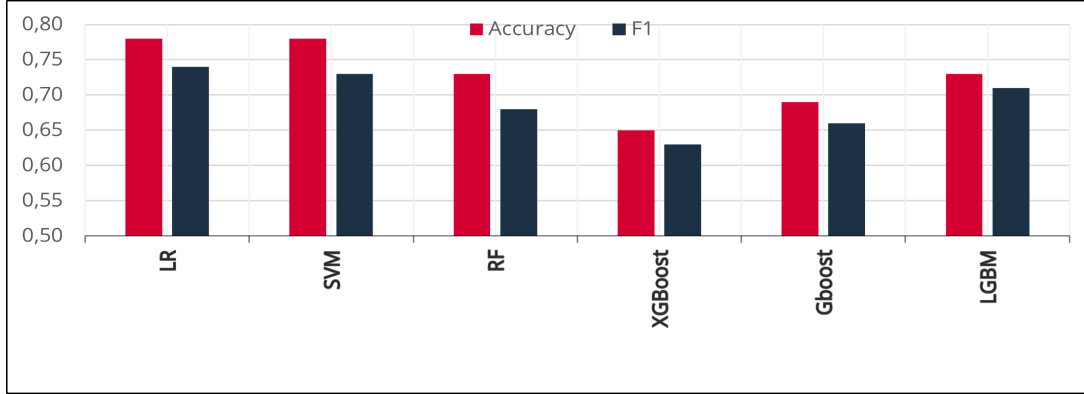
Çevresel skorların 4 kategori ile tahmin edildiği modele ilişkin veriler Tablo 3'te sunulmuştur. 4 kategori ile çevresel skorlarını tahmin eden modellerin performansları değerlendirildiğinde Lojistik Regresyon, SVM ve LightGBM algoritmalarının öne çıktığı söylenebilir. Modellerde hiperparametre seçimi olmaksızın sırasıyla %77, %75, %73 doğruluk skoru; %72, %71, %71 F1 skorları elde edilmiştir.

GridSearchCV hiperparametre seçilmesi ile Lojistik Regresyon ve SVM modellerinde performans skorlarında görece iyileşme dikkat çekerken, %78 doğruluk skoru ve sırasıyla %74, %73 F1 skoru elde edilmiştir. Random Forest algoritmasının performans metrikleri %73 doğruluk, %68 F1 skoru olarak hesaplanmıştır.

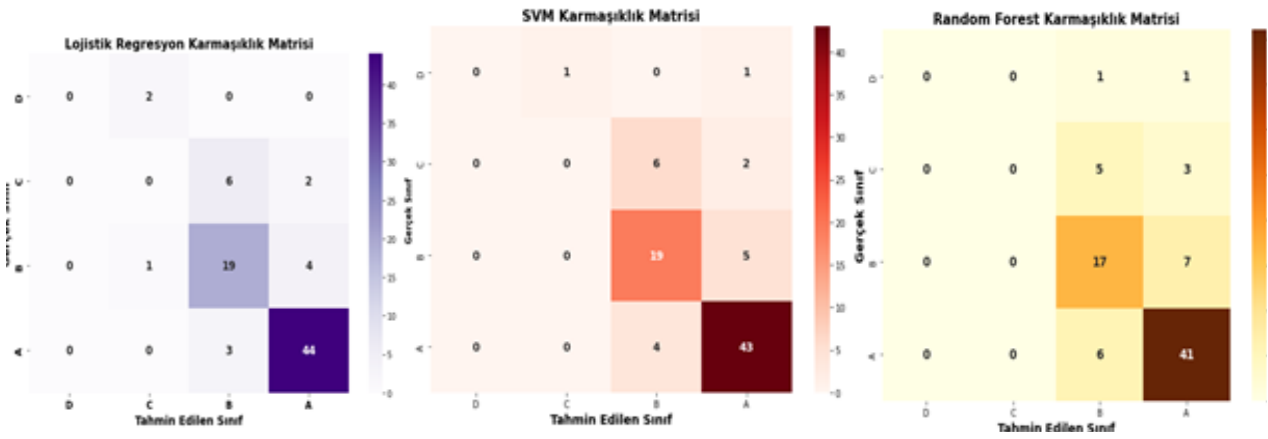
Çevresel skorların 4 kategoriye göre tahminlerinin yapıldığı makine öğrenmesi modellerinin performans metriklerinden doğruluk ve F1 ölçütlerine göre değerlendirilmesi Şekil 11'de sunulmuştur. Şekil 11'de yer alan bilgilere göre Lojistik Regresyon ve SVM sınıflandırma algoritmalarının çevresel skoru 4 kategoriye göre tahmin etmede en başarılı modeller olduğu; LightGBM algoritmasının da başarılı tahminler yaptığı görülmektedir.

Şekil 11

Sınıflandırma Algoritmaları ile Çevresel Skor Tahmininin Doğruluk ve F1 Performans Metrikleri

**Şekil 12**

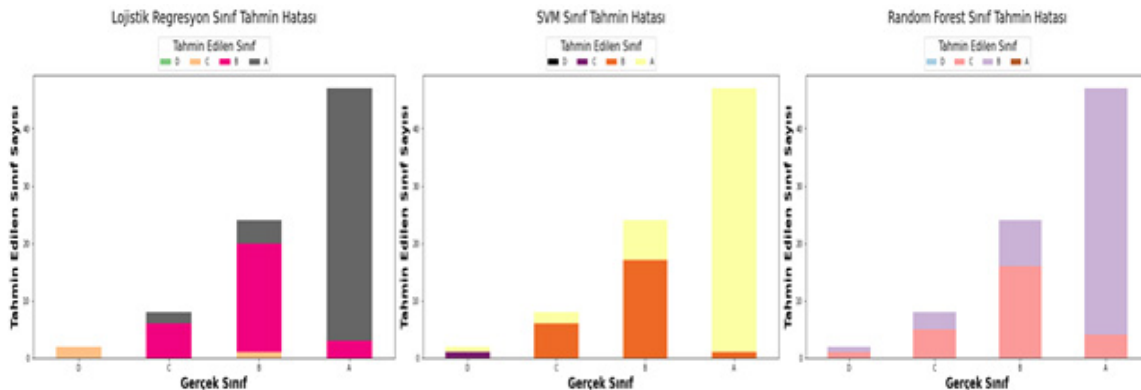
Sınıflandırma Algoritmaları ile Çevresel Tahmininin Karmaşıklık Matrisleri



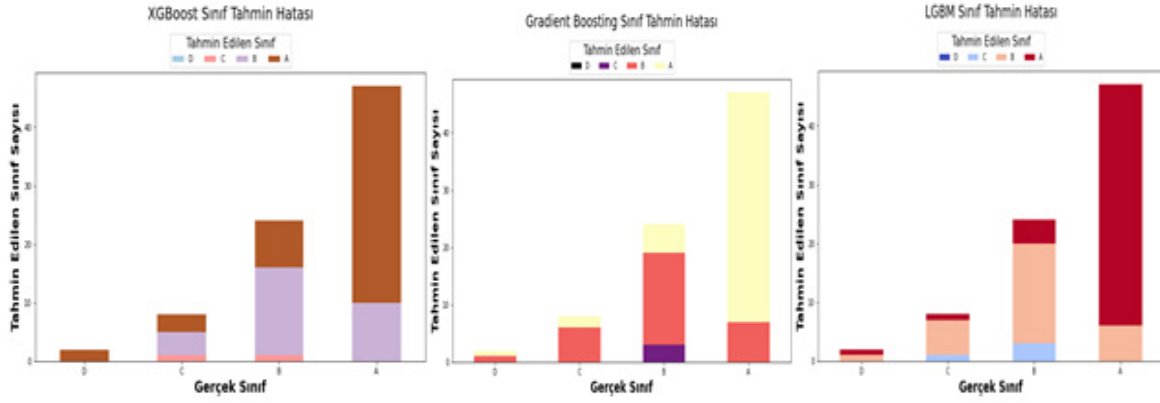
Çevresel skorların 4 kategori ile tahmin edilmesine yönelik yapılan makine öğrenmesi modellerine ait karmaşıklık matrisleri Şekil 12’de sunulmuştur. Lojistik Regresyon ve SVM modeli, B kategorisini 19 kez doğru tahmin ederek performanslarıyla öne çıkmaktadır. Karmaşıklık matrisi verilerine göre, Random Forest ve LightGBM algoritmaları, B kategorisindeki 24 gerçek değer 17’sini doğru tahmin ederek yüksek bir başarı sergilemiştir. GradientBoost algoritması ise B kategorisindeki değerleri 16 kez doğru tahmin ederken XGBoost algoritması 15 doğru tahmin yapmıştır. Karmaşıklık matrisine ait sonuçlar, B kategorisinin yüksek doğrulukla tahmin edildiğini göstermektedir. A kategorisinde ise Lojistik Regresyon ve SVM modeli 47 gerçek değer 44’ünü ve 43’ünü doğru tahmin etmiş, Random Forest ve LightGBM algoritmaları ise 47 gerçek değer 41’ini doğru tahmin ederek oldukça başarılı bir performans göstermiştir. Bu sonuçlara göre A kategorisinde Lojistik Regresyon algoritması %93 doğru tahmin oranı ile oldukça dikkat çekici sonuçlar elde etmiştir.

Şekil 13

Sınıflandırma Algoritmaları ile Çevresel Skor Tahmininin Sınıf Tahmin Hatası Kodlar ve Kategorileri



Şekil 13(Devamı)



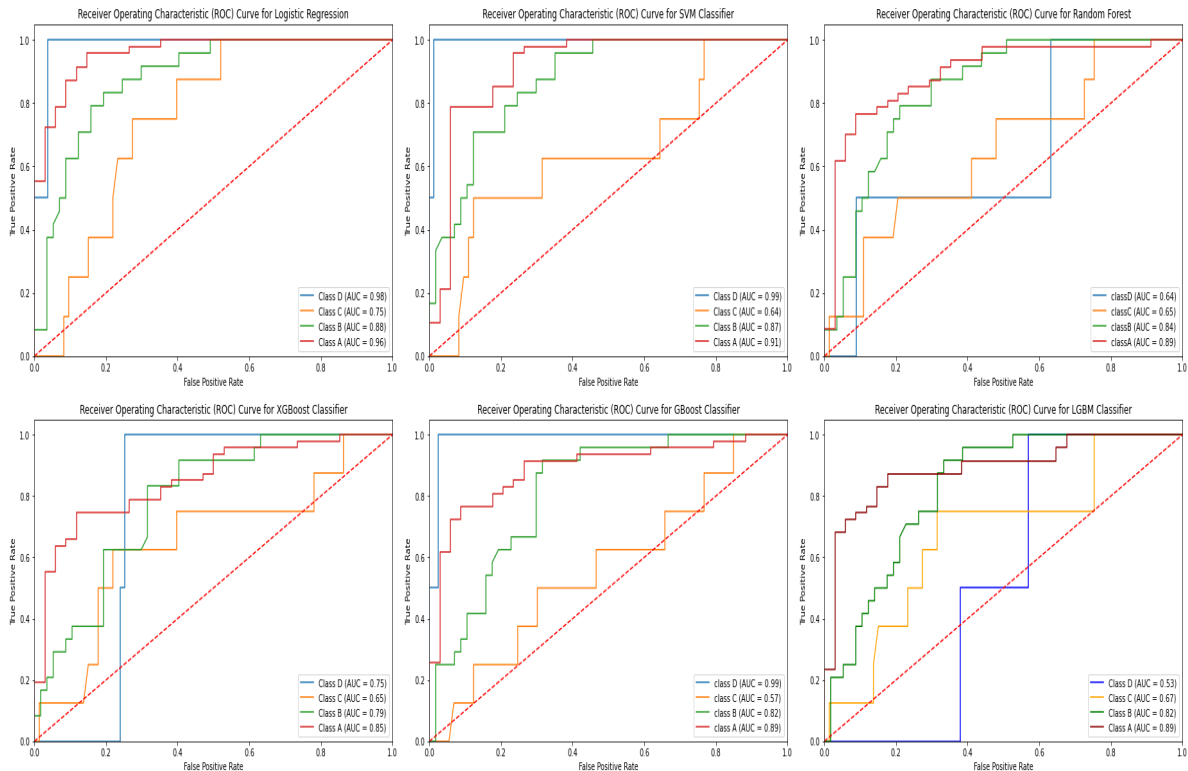
Sınıflandırma tahmininde kullanılan algoritmaların sınıf tahmin hatalarının Şekil 13'te görselleştirilmiş hali sunulmaktadır. Çevresel skorlarının dört kategoriye ayrıldığı modelde, SVM algoritması ile A sınıfının tahmininde oldukça başarılı sonuçlar elde edilmiştir. Diğer algoritmaların da A sınıfını yüksek doğruluk oranıyla tahmin ettiği gözlemlenirken; B sınıfının tahmininde görece hatalar olduğu göze çarpmaktadır. D sınıfının tahmininde tüm algoritmaların başarısız olduğu görülmektedir. C sınıfı ise yalnızca XGBoost ve LightGBM algoritmaları ile doğru tahmin edilmiştir. A sınıfı tüm algoritmalar tarafından yüksek doğrulukla tahmin edilirken, D sınıfının ise tüm algoritmalarda yanlış tahmin edilmesinin modellerin performans metriklerini olumsuz etkilediği düşünülmektedir.

Şekil 14'te çevresel skorların 4 kategori ile tahmin edilmesine yönelik yapılan makine öğrenmesi modellerine ait ROC-AUC değerleri verilmiştir. Lojistik Regresyon ve SVM modellerinin AUC değerleri benzerlik gösterirken özellikle D sınıfının başarısız tahminlerindeki değerlerin AUC değerlerini de olumsuz etkilediği anlaşılmaktadır.

XGBoost ve LGBM algoritmaları, A kategorisinde %85, %89; B kategorisinde ise %79, %82 AUC değerlerine ulaşarak daha tutarlı ve güvenilir sonuçlar sağlamaktadır. Random Forest algoritması A kategorisi için %89, B kategorisi için %84 AUC değerleri ile tahmin başarısı yüksek düzeyde olup tahmin performansının genel olarak iyi olduğu değerlendirilmektedir.

Şekil 14

Sınıflandırma Algoritmaları ile Çevresel Skor Tahmininin ROC-AUC Eğrileri



Çalışma kapsamında elde edilen sınıflandırma performansları, literatürdeki benzer çalışmalarla kıyaslandığında genel olarak uyumlu ve rekabetçi sonuçlar ortaya koymaktadır. Bu çalışmada ESG skoru tahmininde Lojistik Regresyon algoritması %78 doğruluk ve %76 F1 skoru ile en başarılı model olarak öne çıkarken; GradientBoost modeli %75 doğruluk ve %72 F1; XGBoost %74 doğruluk ve %72 F1 skoru ile yakın bir başarı göstermiştir. Çevresel skorun tahmininde ise Lojistik Regresyon algoritması %78 doğruluk ve %74 F1 skoru ile en başarılı model olarak öne çıkarken; Support Vector Machine modeli %78 doğruluk ve %73 F1; Random Forest %73 doğruluk ve %68 F1 skoru ile yakın bir başarı göstermiştir. Bu çalışmada elde edilen bulgular, literatürde yer alan benzer çalışmaların sonuçlarıyla büyük ölçüde örtüşmektedir. Nitekim, Caudron (2022) tarafından ulaşılan %75 F1 skoru, Svanberg ve arkadaşları (2022) çalışmasındaki %71 F1 skoru, Clarkson ve arkadaşları (2020) tarafından raporlanan %81 doğruluk oranı, Chowdhury ve arkadaşları (2023) çalışmasındaki %78 doğruluk skoru, Yıldız ve Ağdeniz (2023) tarafından elde edilen %85 doğruluk ve F1 skorları ile Kartal ve arkadaşları (2024a) tarafından raporlanan %84 doğruluk oranı, bu çalışmada ulaşılan sonuçlarla benzerlik göstermektedir. Bu doğrultuda, mevcut çalışmanın sınıflandırma başarısı, literatürdeki güncel ve öncü çalışmalardan elde edilen performans metrikleriyle tutarlılık sergilemektedir.

Derin öğrenme temelli modellerin kullanıldığı bazı çalışmalarda ise daha yüksek başarı oranları bildirilmiştir. Örneğin, Clarkson ve arkadaşlarının (2020) çalışmasında %96 doğruluk, Nugent ve arkadaşları (2021) tarafından BERT modeliyle %84 F1 skoru, Ruberg (2021) tarafından RoBERTa ile %85 F1 skoru ve Lee ve Kim (2023) çalışmasında KLUE-RoBERTa ile %86 F1 skoru elde edilmiştir.

Bu durum, BERT tabanlı modellerin daha yüksek tahmin performansına sahip olduğunu gösterirken, bu çalışmada kullanılan geleneksel ve boosting temelli algoritmaların da yapılandırılmamış metin verilerinden elde edilen özniteliklerle yüksek doğruluk sağlayabildiğini ortaya koymaktadır.

5. Sonuç

Günümüzde sürdürülebilirlik performansının ölçümünde yalnızca finansal göstergelere dayalı analizler yetersiz kalmakta; şirketlerin ESG skorları gibi finansal olmayan verilerinin de yatırım kararları ve kurumsal değerlemelerde belirleyici rol oynadığı görülmektedir. Bu bağlamda ESG skorlamasında, şirketlerin yıllık faaliyet raporlarında, sürdürülebilirlik ve entegre faaliyet raporlarında yer alan yapılandırılmamış metinsel veriler oldukça zengin ve anlamlı bir bilgi kaynağı sunmaktadır. Ancak bu tür yapılandırılmamış verilerin geleneksel istatistiksel yöntemlerle analiz edilmesi büyük ölçüde güçtür. Bu nedenle, çalışmada metin madenciliği ve doğal dil işleme teknikleri kullanılarak, finansal olmayan metin verileri sayısal özniteliklere dönüştürülmüş ve bu veriler üzerinden ESG skorlarının tahmini amaçlanmıştır.

Şirketlerin ESG performanslarının ölçümünde metin madenciliği ve makine öğrenmesi yöntemlerinin uygulanabilirliğinin analiz edildiği çalışmada temel amaç; ESG skorlarının, şirketlerin yayımlamış oldukları sürdürülebilirlik ve entegre faaliyet raporlarından elde edilen metin verileri kullanılarak tahmin edilmesidir. Bu çalışmada, şirketlerin ESG skorlarını değerlendirmek amacıyla, Thomson Reuters'ın ESG veri sağlayıcısı olan Refinitiv tarafından sunulan skorlamalar esas alınmıştır. ESG skorlarının yıllık olarak yayımlanması ve şirketlerin de sürdürülebilirlik ile entegre faaliyet raporlarını yine yıllık periyotlarla kamuya açıklamaları dikkate alınarak, analiz kapsamında 2016-2023 yılları arasındaki son sekiz yıllık dönem seçilmiştir.

Çalışmada kullanılan sınıflandırma algoritmaları arasında Lojistik Regresyon, Support Vector Machines (SVM), Random Forest, Gradient Boosting, XGBoost, LightGBM yer almıştır. Model performansları doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1 skoru ve AUC değerleri gibi değerlendirme kriterleri üzerinden karşılaştırılmıştır ve her algoritmanın farklı özellikleri nedeniyle farklı performans seviyelerine ulaşıldığı gözlemlenmiştir.

Genel ESG skoru tahminlerinde, Lojistik Regresyon, GradientBoost ve XGBoost algoritmaları diğer modellere kıyasla daha yüksek başarı sağlamıştır. Elde edilen bu sonuçlar, Yıldız ve Ağdeniz (2023), Caudron (2022), Svanberg ve arkadaşları (2022), Clarkson ve arkadaşları (2020), Chowdhury ve arkadaşlarının (2023) bulgularıyla benzerlik göstermektedir. Öte yandan, derin öğrenme tabanlı modellerin kullanıldığı bazı çalışmalarda daha yüksek sınıflandırma başarıları elde edildiği görülmektedir (Clarkson vd., 2020; Nugent vd., 2021; Ruberg, 2021; Lee ve Kim, 2023). Bu bağlamda, derin öğrenme temelli modellerin özellikle metin verisi üzerinde daha yüksek öngörü performansı sunduğunu ortaya koymaktadır. Ancak buna rağmen, bu çalışmada kullanılan geleneksel ve boosting

tabanlı yöntemlerin de yapılandırılmamış verilerle anlamlı ve güvenilir tahminler üretebildiği anlaşılmıştır. Lojistik Regresyon, GradientBoost, SVM, LightGBM ve Random Forest algoritmalarının başarısı; yüksek boyutlu ve yapısal olmayan metin verisi üzerinde güçlü modelleme kapasitelerine sahip olmalarından kaynaklanmaktadır. Özellikle Lojistik Regresyon modeli, veri setindeki sınıf dengesizlikleri ve bağımsız değişkenler arasındaki etkileşimleri etkili şekilde yöneterek genel ESG skorlarının tahmininde oldukça yüksek doğruluk ve F1 skoru elde etmiştir.

Çevresel skor tahminlerinde en yüksek performans Lojistik Regresyon, Support Vector Machines ve Random Forest modelleri tarafından gösterilmiştir. Bu sonuç, çevresel performans verilerinin daha çok sayısal, ölçülebilir ve raporlama standartları bakımından daha homojen yapıda olmasından kaynaklanmaktadır. Bu modellerin ROC-AUC değerleri %89-96 aralığında oldukça yüksek çıkmıştır. AUC değerinin bu denli yüksek olması, modellerin pozitif ve negatif sınıfları ayırt etme kapasitesinin güçlü olduğunu göstermektedir.

Yapılandırılmamış metin verileri üzerinden ESG skorlarının tahmin edilmesinde metin madenciliği ve makine öğrenmesi yöntemlerinin uygulanması, özellikle büyük veri setleriyle çalışıldığında etkili ve ölçeklenebilir çözümler sunmaktadır. Çalışma kapsamında uygulanan yöntemler hem sınıflandırma doğruluğu hem de model kararlılığı açısından yüksek düzeyde performans sergilemiş; bu da sürdürülebilirlik odaklı karar alma süreçlerinde yapay zekâ tabanlı çözümlerin önemini bir kez daha ortaya koymuştur.

Bu çalışma, Türkiye’de Borsa İstanbul Sürdürülebilirlik endeksinde yer alan şirketlerin sürdürülebilirlik ve entegre faaliyet raporlarını temel alarak ESG skorlarını makine öğrenmesi ve metin madenciliği yoluyla tahmin eden öncü çalışmalardan biri olmuştur. Literatürde sınırlı sayıda yer bulan benzer çalışmalara kıyasla çalışmada geliştirilen modellerin önemli katkıları şunlardır:

- ESG skoru ve çevresel alt bileşeni için ayrı ayrı modelleme yapılmıştır.
- Doğal dil işleme ve makine öğrenmesi algoritmalarının yapılandırılmamış metin verileri üzerinde uygulanabilirliği sistematik şekilde gösterilmiştir.
- Literatürde sınırlı sayıda ele alınan ESG tahminleme problemine yerli veri seti üzerinden yeni bir yaklaşım sunulmuştur.

Ancak sınırlı sayıda örneklem, veri dengesizlikleri ve sürdürülebilirlik raporlarının içerik ve format farklılıkları ile ESG skorlarının hesaplanma yöntemlerindeki belirsizlikler model doğruluğunu etkileyen başlıca kısıtlar olarak tespit edilmiştir. İlerleyen çalışmalarda veri setlerinin genişletilmesi, raporlama standartlarının artması ve özellikle BERT ve ESG-BERT gibi derin öğrenme tabanlı dil modellerinin uygulanması, daha yüksek tahmin doğruluğuna ulaşılması mümkün olacağından genellenebilirlik sağlayacaktır.

Firmaların ESG performansı, yalnızca finansal bilgilerle sınırlı olmayan, yatırımcıların karar alma süreçlerinde belirleyici bir unsur haline gelmiştir. Özellikle uzun vadeli yatırımcıları çekmeyi hedefleyen şirketler açısından, ESG açıklamalarının şeffaf ve nitelikli biçimde sunulması stratejik bir zorunluluk haline almıştır. Bu bağlamda, sürdürülebilirlik odaklı yatırımcıların beklentilerine yanıt verebilmek ve sermaye maliyetlerini azaltmak isteyen firmalar, ESG performanslarını sürekli geliştirmelidir. Çalışma bulguları, firmaların ESG’nin önemi konusunda genel bir farkındalığa sahip olduklarını ortaya koymaktadır. Ancak bu farkındalığın kurumsal stratejiye dönüşebilmesi için politika yapımcıların daha proaktif yaklaşımlar benimsemesi gerekmektedir. Öncelikle, karmaşık ve erişimi zor ESG veri sistemleri yerine, sade fakat yüksek doğruluk sunan makine öğrenmesi temelli modellerin (örneğin Lojistik Regresyon) teşvik edilmesi önerilmektedir. Bu yaklaşım, hem analiz süreçlerini kolaylaştırmakta hem de veri güvenilirliğini artırmaktadır. Yeşil badana (greenwashing) riskinin önüne geçilebilmesi için ESG raporlarının şirket içi denetim mekanizmaları veya bağımsız düzenleyici otoriteler tarafından kontrol edilmesi büyük önem taşımaktadır. Raporda yer alan içeriklerin eksiksiz ve hatasız olması, firmaların güvenilirliğini artıracığı gibi sürdürülebilirlik performanslarının da doğru değerlendirilmesine katkı sağlayacaktır. Ayrıca, sektörel ve ölçek bazlı karşılaştırmalı ESG veri tabanlarının oluşturulması, hem akademik çalışmaları hem de kurumsal analizleri destekleyecek altyapıyı sağlayacaktır. ESG açıklamalarında kaliteyi artıran ve sürdürülebilirlik hedeflerine katkı sunan firmalara yönelik vergi avantajları veya teşvik paketleri gibi finansal destek mekanizmalarının hayata geçirilmesi de sürdürülebilirlik uygulamalarının yaygınlaşmasına katkı sunacaktır.

Sonuç olarak, ESG açıklamaları sadece yasal bir yükümlülük olarak değil, aynı zamanda yatırımcı güvenini artıran stratejik bir iletişim aracı olarak görülmelidir. Bu kapsamda geliştirilen ESG skor tahminleme modelleri, politika yapıcılara, yatırımcılara ve düzenleyici kurumlara strateji geliştirme, risk analizi ve sürdürülebilir finansal ekosistemin inşası için önemli bir araç sunmaktadır. Kurumsal sürdürülebilirlik kültürünün oluşması için bu tür yaklaşımların desteklenmesi ve politika belgelerine entegre edilmesi önem arz etmektedir.

Makale Bilgi Formu

Yazarların Notları: Bu çalışma Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü, Sermaye Piyasası ve Borsa Anabilim Dalı'nda Prof. Dr. İdil Özlem Koç'un danışmanlığında Mehmet Hanifi Ateş tarafından hazırlanan "Makine Öğrenmesi Yöntemleri ile Şirketlerin Çevresel, Sosyal ve Yönetişim (ÇSY) Skorlarının Tahmin Edilmesi: Borsa İstanbul (BIST) Sürdürülebilirlik Endeksi Üzerine Bir Uygulama" başlıklı Doktora tezinden üretilmiştir.

Yazarların Katkıları: Kavramsallaştırma: MHA, İÖK; Metodoloji: MHA; Yazılım: MHA; Doğrulama: MHA, İÖK; Araştırma: MHA, İÖK; Kaynaklar: MHA, İÖK; Veri küresasyonu: MHA; Yazım - orijinal taslak: MHA, İÖK; Yazım - inceleme ve düzenleme: İÖK; Görselleştirme: MHA. Tüm yazarlar son metni okumuş ve onaylamıştır.

Çıkar Çatışması Bildirimi: Yazarlar tarafından potansiyel çıkar çatışması bildirilmemiştir.

Yapay Zeka Bildirimi: Bu makale yazılırken hiçbir yapay zekâ aracı kullanılmamıştır.

İntihal Beyanı: Bu makale iThenticate tarafından taranmıştır.

Kaynakça

- Antoncic, M. (2020). Uncovering hidden signals for sustainable investing using big data: Artificial intelligence, machine learning and natural language processing. *Journal of Risk Management in Financial Institutions*, 13(2), 106-113. <https://doi.org/10.69554/CIKJ7477>
- Bacha, S. ve Ajina, A. (2020). CSR performance and annual report readability: Evidence from France. *Corporate Governance: The International Journal of Business in Society*, 20(2), 201-215. <https://doi.org/10.1108/CG-02-2019-0060>
- Brundtland, G. H. (1987). *Report of the World Commission on Environment and Development: Our Common Future*. <https://sustainabledevelopment.un.org/content/documents/5987our-common-future.pdf>
- Castellano, R., Cini, F. ve Ferrari, A. (2024). Machine learning for ESG rating classification: An integrated replicable model with financial and systemic risk parameters. *İçinde Mathematical and Statistical Methods for Actuarial Sciences and Finance* (ss. 87-92). Springer.
- Caudron, E. (2022). *Measuring ESG performance: A text mining approach*. [Yayımlanmamış yüksek lisans tezi, Université Catholique de Louvain].
- Chowdhury, M. A. F., Abdullah, M., Azad, M. A. K., Sulong, Z. ve Islam, M. N. (2023). Environmental, social and governance (ESG) rating prediction using machine learning approaches. *Annals of Operations Research*, 1-25. <https://doi.org/10.1007/s10479-023-05633-7>
- Clarkson, P. M., Ponn, J., Richardson, G. D., Rudzicz, F., Tsang, A. ve Wang, J. (2020). A textual analysis of US corporate social responsibility reports. *Abacus*, 56(1), 3-34.
- Clément, A., Robinot, É. ve Trespeuch, L. (2022). Improving ESG scores with sustainability concepts. *Sustainability*, 14(20). <https://doi.org/10.3390/su142013154>
- D'Amato, V., D'Ecclesia, R. ve Levantesi, S. (2021). Fundamental ratios as predictors of ESG scores: A machine learning approach. *Decisions in Economics and Finance*, 44(2), 1087-1110. <https://doi.org/10.1007/s10203-021-00364-5>
- Del Giudice, A. ve Rigamonti, S. (2020). Does audit improve the quality of esg scores? Evidence from corporate misconduct. *Sustainability*, 12(14), 5670. <https://doi.org/10.3390/su12145670>

- Depren, S. K., Taşkın, D. ve Ulussever, T. (2025). Uncovering the nexus between ESG reports and ESG scores across various liquidity levels: Evidence from publicly traded Turkish companies by machine learning algorithms. *Journal of Sustainable Marketing*, 1-20. <https://doi.org/10.51300/JSE-2025-154>
- Dumont, N. H. R. (2017). Sentiment analysis & natural language: Processing techniques for capital markets & disclosure. *The Corporate Governance Advisor*, 25(6), 16-23.
- Friede, G., Busch, T. ve Bassen, A. (2015). ESG and financial performance: Aggregated evidence from more than 2000 empirical studies. *Journal of Sustainable Finance & Investment*, 5(4), 210-233. <https://doi.org/10.1080/20430795.2015.1118917>
- Gao, S., Meng, F., Gu, Z., Liu, Z. ve Farrukh, M. (2021). Mapping and clustering analysis on environmental, social and governance field a bibliometric analysis using scopus. *Sustainability*, 13(13), 7304. <https://doi.org/10.3390/su13137304>
- Gupta, A., Dengre, V., Kheruwala, H. A. ve Shah, M. (2020). Comprehensive review of text-mining applications in finance. *Financial Innovation*, 6(1), 1-25. <https://doi.org/10.1186/s40854-020-00205-1>
- Heinberg, R. ve Lerch, D. (2010). *What is sustainability*, The post carbon reader, Post Carbon Institute. https://mycourses.aalto.fi/pluginfile.php/1159956/mod_page/content/9/Heinberg_WhatIsSustainability.pdf
- Henriksson, R., Livnat, J., Pfeifer, P. ve Stumpp, M. (2019). Integrating ESG in portfolio construction. *The Journal of Portfolio Management*, 45(4), 67-81. <https://doi.org/10.3905/jpm.2019.45.4.067>
- Hoverstadt, P. ve Bowling, D. (2005). Organisational viability as a factor in sustainable development of technology. *International Journal of Technology Management & Sustainable Development*, 4(2), 131-146. <https://doi.org/10.1386/ijtm.4.2.131/1>
- Hughes, A., Urban, M. A. ve Wójcik, D. (2021). Alternative ESG ratings: How technological innovation is reshaping sustainable investment. *Sustainability*, 13(6), 3551. <https://doi.org/10.3390/su13063551>
- Kartal, M. T., Kılıç Depren, S., Pata, U. K., Taşkın, D. ve Şavlı, T. (2024a). Modeling the link between environmental, social, and governance disclosures and scores: The case of publicly traded companies in the Borsa Istanbul Sustainability Index. *Financial Innovation*, 10(1), 80. <https://doi.org/10.1186/s40854-024-00619-1>
- Kartal, M. T., Taşkın, D., Shahbaz, M., Depren, S. K. ve Pata, U. K. (2024b). Effects of environment, social, and governance (ESG) disclosures on ESG scores: Investigating the role of corporate governance for publicly traded Turkish companies. *Journal of Environmental Management*, 368, 122205. <https://doi.org/10.1016/j.jenvman.2024.122205>
- Kiriü, T. ve Nozaki, M. (2020). A text mining model to evaluate firms' ESG activities: An application for Japanese firms. *Asia-Pacific Financial Markets*, 27(4), 621-632. <https://doi.org/10.1007/s10690-020-09309-1>
- Kotsantonis, S. ve Serafeim, G. (2019). Four things no one will tell you about esg data. *Journal of Applied Corporate Finance*, 31(2), 50-58. <https://doi.org/10.1111/jacf.12346>
- Lee, J. ve Kim, M. (2023). ESG Information extraction with cross-sectoral and multi-source adaptation based on domain-tuned language models. *Expert Systems with Applications*, 221, 119726. <https://doi.org/10.1016/j.eswa.2023.119726>
- Lee, O., Joo, H., Choi, H. ve Cheon, M. (2022). Proposing an integrated approach to analyzing ESG data via machine learning and deep learning algorithms. *Sustainability*, 14(14), 8745. <https://doi.org/10.3390/su14148745>
- Li, T. -T., Wang, K., Sueyoshi, T. ve Wang, D. D. (2021). ESG: Research progress and future prospects. *Sustainability*, 13(21), 11663. <https://doi.org/10.3390/su132111663>

- Markoulidakis, I., Kopsiaftis, G., Rallis, I. ve Georgoulas, I. (2021). Multi-class confusion matrix reduction method and its application on net promoter score classification problem. Proceedings of the 14th Pervasive Technologies Related to Assistive Environments Conference, Corfu, Greece.
- Miklosik, A., Starchon, P. ve Hitka, M. (2021). Environmental sustainability disclosures in annual reports of ASX industrials list companies. *Environment, Development and Sustainability*, 1-19. <https://doi.org/10.1007/s10668-021-01338-8>
- Ning, X., Yim, D. ve Khuntia, J. (2021). Online sustainability reporting and firm performance: Lessons learned from text mining. *Sustainability*, 13(3), 1069. <https://doi.org/10.3390/su13031069>
- Nugent, T., Stelea, N. ve Leidner, J. L. (2021). Detecting environmental, social and governance (ESG) topics using domain-specific language models and data augmentation. *Flexible Query Answering Systems: 14th International Conference, FQAS, Bratislava, Slovakia* içinde (ss. 157-169). Springer. https://doi.org/10.1007/978-3-030-86967-0_12
- Pagano, M. S., Sinclair, G. ve Yang, T. (2018). Understanding ESG ratings and ESG indexes. *Research Handbook of Finance and Sustainability*, 339.
- Pasch, S. ve Ehnes, D. (2022). NLP for Responsible finance: Fine-tuning transformer-based models for ESG. 2022 IEEE International Conference on Big Data (Big Data), Osaka, Japan.
- Refinitiv. (2023). *Environmental, social and governance (ESG) scores from Refinitiv*, https://www.lseg.com/content/dam/data-analytics/en_us/documents/methodology/lseg-esg-scores-methodology.pdf
- Ruberg, N. (2021). *BERT goes sustainable: An NLP approach to ESG financing*. [Yayımlanmamış yüksek lisans tezi, University of Bologna].
- Shahi, A. M., Issac, B. ve Modapothala, J. R. (2014). Automatic analysis of corporate sustainability reports and intelligent scoring. *International Journal of Computational Intelligence and Applications*, 13(01), 1450006. <https://doi.org/10.1142/S1469026814500060>
- Shakil, M. H., Mahmood, N., Tasnia, M. ve Munim, Z. H. (2019). Do environmental, social and governance performance affect the financial performance of banks? A cross-country study of emerging market banks. *Management of Environmental Quality: An International Journal*, 30(3), 1331-1344. <https://doi.org/10.1108/MEQ-08-2018-0155>
- Svanberg, J., Ardeshiri, T., Samsten, I., Öhman, P., Neidermeyer, P. E., Rana, T., Semenova, N. ve Danielson, M. (2022). Corporate governance performance ratings with machine learning. *Intelligent Systems in Accounting, Finance and Management*, 29(1), 50-68. <https://doi.org/10.1002/isaf.1505>
- Székely, N. ve Vom Brocke, J. (2017). What can we learn from corporate sustainability reporting? Deriving propositions for research and practice from over 9,500 corporate sustainability reports published between 1999 and 2015 using topic modelling technique. *PLOS One*, 12(4), e0174807. <https://doi.org/10.1371/journal.pone.0174807>
- Şişman, M. E. ve Çankaya, S. (2021). Çevresel, sosyal ve kurumsal yönetim (ESG) verilerinin firmaların finansal performansına etkisi: Hava yolu sektörü üzerine bir çalışma. *Çukurova Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 25(1), 73-91. <https://doi.org/10.51945/cuiibfd.880468>
- Ting, I. W. K., Azizan, N. A., Bhaskaran, R. K. ve Sukumaran, S. K. (2019). Corporate social performance and firm performance: Comparative study among developed and emerging market firms. *Sustainability*, 12(1), 26. <https://doi.org/10.3390/su12010026>
- Taskin, D., Sariyer, G., Acar, E. ve Cagli, E. C. (2025). Do past ESG scores efficiently predict future ESG performance? *Research in International Business and Finance*, 74, 102706. <https://doi.org/10.1016/j.ribaf.2024.102706>
- UNPRI. (2005). *Principles for Responsible Investment (PRI), United Nations Global Compact*. <https://www.unpri.org/>

- Verbeeten, F. H. M., Gamerschlag, R. ve Möller, K. (2016). Are CSR disclosures relevant for investors? Empirical Evidence from Germany. *Management Decision*, 54(6), 1359-1382. <https://doi.org/10.1108/MD-08-2015-0345>
- Wong, C. ve Petroy, E. (2020). *Rate the raters 2020: Investor survey and interview results*. SustainAbility. <https://www.sustainability.com/globalassets/sustainability.com/thinking/pdfs/sustainability-ratetheraters2020-report.pdf>
- Yeprem, U. (2022). *A Machine Learning-Based Approach to Corporate Social Performance Assessment*. [Yayımlanmamış yüksek lisans tezi, University of Guelph].
- Yıldız, B. ve Ağdeniz, Ş. (2023). *Using text mining in financial reporting: To predict the companies' corporate governance qualifications*. Contemporary Studies of Risks in Emerging Technology, Part B içinde (ss. 147-168). Emerald Publishing Limited. <https://doi.org/10.1108/978-1-80455-566-820231007>
- Zaccone, M. C. ve Pedrini, M. (2020). ESG factor integration into private equity. *Sustainability*, 12(14), 5725. <https://doi.org/10.3390/su12145725>
- Zheng, A. (2015). *Evaluating machine learning models: A beginner's guide to key concepts and pitfalls*. O'Reilly Media.