

YÜKSEKÖĞRETİMDE ŞİKÂyet YÖNETİMİNİN DİJİTALLEŞMESİ: YAPAY ZEKÂ DESTEKLİ SINIFLANDIRMA SİSTEMLERİNİN PERFORMANS ANALİZİ

DIGITAL TRANSFORMATION OF COMPLAINT MANAGEMENT IN HIGHER EDUCATION: A PERFORMANCE ANALYSIS OF AI-SUPPORTED CLASSIFICATION SYSTEMS

 Yücel Batu SALMAN¹

 Mehmet Erdal KÜÇÜKOĞLU²

¹Doç. Dr., Bahçeşehir Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, batu.salman@bau.edu.tr

²Bahçeşehir Üniversitesi, İşletme Mühendisliği Doktora Öğrencisi, kucukogluerdal@gmail.com

ÖZ

Yükseköğretimde artan öğrenci şikayetlerinin hacmi, geleneksel manuel sınıflandırma yöntemlerinin yetersiz kalmasına yol açmaktadır. Bu durum, doğruluk ve hız gereksinimlerini karşılamak amacıyla yapay zekâ tabanlı otomatik sınıflandırma sistemlerinin kullanımı zorunlu kılmıştır. Ancak, üniversite ortamında bu sistemlerin performansına ilişkin ampirik veriler sınırlıdır. Bu çalışma, bir yükseköğretim kurumunda veri çoğaltma ile 781 kayda genişletilen öğrenci şikayetini manuel yöntem ve dört farklı yapay zekâ modeli (Naive Bayes, SVM, Random Forest, BERT) ile karşılaştırmalı olarak analiz etmektedir. LinearSVC (SVM) modelinin %87 doğrulukla en yüksek performansı gösterdiği ve bu üstünlüğün istatistiksel olarak anlamlı olduğu tespit edilmiştir. Modeller arası tutarlılık, manuel etiketleme ile mükemmel uyum gösteren Cohen's Kappa ($\kappa=0.84$) değeri ile kanıtlanmıştır. Çalışmanın özgün katkısı, LinearSVC hata çıktılarının Kök Neden Analizi (RCA) aracı olarak kullanılmasıdır. Bu analiz, en belirgin sınıflandırma karışıklığının (Öğrenci İşleri Sorunları ve Tez/Danışmanlık Sorunları) kurumsal süreçler arası belirsizlikten kaynaklandığını tespit ederek, üniversite yönetimine yönelik somut süreç iyileştirme önerileri sunmaktadır. Sonuçlar, yapay zekâ tabanlı otomatik sınıflandırma sistemlerinin, şikayet yönetiminin dijitalleşmesinde öğrenci memnuniyeti, kurumsal verimlilik ve proaktif süreç analizi açısından önemli katkılar sağladığını göstermektedir.

ABSTRACT

The increasing volume of student complaints in higher education renders traditional manual classification methods insufficient. This necessitates the adoption of AI-based automated classification systems to meet requirements for accuracy and speed. However, empirical data regarding the performance of such systems within the university context remain limited. This study comparatively analyzes student complaints in a higher education institution—expanded to 781 records via data augmentation—using a manual method and four distinct AI models (Naive Bayes, SVM, Random Forest, and BERT). It was observed that the LinearSVC (SVM) model demonstrated the highest performance with 87% accuracy, and this superiority was found to be statistically significant. Inter-model consistency was validated by a Cohen's Kappa value ($\kappa=0.84$), indicating almost perfect agreement with manual labeling. The study's novel contribution lies in utilizing LinearSVC error outputs as a tool for Root Cause Analysis (RCA). This analysis identified that the most prominent classification confusion (between 'Student Affairs Issues' and 'Thesis/Advising Issues') stemmed from ambiguities in institutional processes, thereby providing concrete process improvement recommendations for university management. The results demonstrate that AI-based automated classification systems make significant contributions to student satisfaction, institutional efficiency, and proactive process analysis within the digitalization of complaint management.

Anahtar Kelimeler: Yapay zekâ, Otomatik sınıflandırma, öğrenci şikayetleri, doğal dil işleme, yükseköğretim.

Keywords: Intelligence, automated classification, student complaints, natural language processing, higher education



GİRİŞ

Günümüzde üniversitelerde öğrenci şikayetlerinin hem hacmi hem de çeşitliliği, dijitalleşmenin etkisiyle belirgin biçimde artırmıştır. Geleneksel şikayet yönetimi yöntemleri ise bu karmaşık süreci yönetmede yetersiz kalmaktadır (Alyahya vd., 2023; Gorbāns, 2025). Bu nedenle, çözüm merkezlerinde süreçlerin dijital ve sistematik olarak yeniden yapılandırılmasını zorunlu hale getirmiştir. Öğrenci şikayetleri ise yükseköğretim kurumlarının kendilerini değerlendirmesi ve geliştirmesi açısından önemli bir geri bildirim kaynağıdır. Bu sebep ile şikayetlerin nasıl ele alındığı ve yönetildiği, üniversitelerin gelişimi açısından kritik bir rol oynar (Görmüş vd., 2013). Öğrenci deneyiminin ölçülmesi ve geliştirilmesi, üniversitelerde kalite güvencesinin temel bir unsurlardan biridir. Öğrenci anketleri ve geri bildirimler, hem iyi uygulamaların belirlenmesine hem de iyileştirme gereken alanların tespitine olanak sağlar (Pabel & Shah, 2025). Ayrıca, şikayet süreçlerindeki aksaklıkların ve engellerin belirlenmesi, çözüm mekanizmalarının etkinleştirilmesine ve öğrenci memnuniyetini artıracak yapısal iyileştirmelere katkı sağlar (Johnston, 2001; Tax vd., 1998). Ancak, bu geri bildirimlerin bütüncül biçimde analiz edilmemesi, iyileştirme fırsatlarının kaçırılmasına yol açar. Veri hacminin ve çeşitliliğinin artması, manuel şikayet yönetimini yetersiz hale gelmesini sağlamak ve hata riskini artırmaktadır. (Alyahya vd., 2023; Mugge vd., 2017).

Son yıllarda yapay zekâ (YZ) teknolojileri, yükseköğretim kurumlarının çeşitli süreçlerinde etkin olarak kullanılmaya başlanmıştır. Yapay zeka tabanlı çözümler öğrenci kayıt süreçlerinden ders içeriklerinin kişiselleştirilmesine kadar birçok alanda geliştirilmekte ve uygulanmaktadır. YZ uygulamalarının üniversite ortamına entegrasyonu, sadece operasyonel fayda sağlamakla kalmaz, aynı zamanda öğrenci memnuniyetini ve geri bildirim süreçlerinin kalitesini artırma potansiyeline

de sahiptir (Gorbāns, 2025). Ancak bu dijital dönüşüm sürecinde, veri gizliliği, etik uyum ve açıklanabilirlik gibi unsurların da titizlikle alınması gerekmektedir (Akinyemi vd., 2025; L. Chen vd., 2020; Telli & Aydın, 2025). Dijitalleşme sonucu artan şikayet hacmi ve çeşitliliği ise geleneksel yöntemleri daha da yetersiz bırakmaktadır (Alyahya vd., 2023; Anakok vd., 2022). Bu durum, süreçlerin dijital ve sistematik olarak yeniden yapılandırılmasını zorunlu kılmıştır. Bununla birlikte, YZ tabanlı şikayet yönetiminin üniversiteye entegrasyonunda kullanıcı deneyimi, veri gizliliği, etik uyum ve açıklanabilirlik gibi yeni zorluklar da ortaya çıkmaktadır (Acayıp, 2024; Zhou, 2025). Kararların şeffaflığı, güvenilirlik ve olası yanlış etiketleme ya da sistematik önyargı riskleri de önemli tartışma başlıklarıdır (Mugge vd., 2017). Tüm bu zorluklar göz önüne alındığında, öğrenci şikayetlerinin doğru ve sistematik analizinde metin sınıflandırma temel bir gereklilik olarak öne çıkmaktadır. Metin sınıflandırma, klasik bilgi erişiminin yanı sıra doğal dil işleme ve anlamal analiz gibi farklı alanlarda da önemli bir rol üstlenmektedir (Amasyalı & Diri, 2006). Klasik yöntemlerden Naive Bayes, Destek Vektör Makineleri (SVM) ve Random Forest bulunurken son dönemde BERT gibi derin öğrenme tabanlı algoritmalar da yaygın şekilde kullanılmaktadır (Joachims, 1998). Sınıflandırmada yüksek boyutlu öznitelik uzayı, veri hacmi ve çeşitliliğinin artmasıyla birlikte hem işlem süresi hem de doğruluk açısından önemli zorluklar ortaya çıkarmaktadır (Uysal & Gunal, 2012). Artan veri hacmi ve şikayet çeşitliliği, manuel sınıflandırma yöntemlerinde ölçeklenebilirlik, insan hatası ve tutarlılık sorunlarını beraberinde getirmektedir (Amasyalı & Diri, 2006). Öğrenci geri bildirimlerinin doğası gereği öznel olması, özellikle anonim yanıtların hızlı analizinde yanlış anlamalara yol açabilmektedir (Gotipati vd., 2018; Hu vd., 2022). Bu nedenle, otomatik sınıflandırma yöntemlerine geçiş, şikayet yönetiminin etkinliği açısından kri-

tik öneme sahiptir (Agostini & Nosella, 2021; Mugge vd., 2017). Otomatik sınıflandırma sürecinde ise veri madenciliği (Guia vd., 2019), duygu analizi (P. Kumar vd., 2020) ve dil modelleri (Xu vd., 2020) gibi yöntemler sistematik olarak kullanılmaktadır. Yapay zekâ (YZ) ve makine öğrenmesi tabanlı otomatik sınıflandırma sistemlerinin şikayet yönetiminde doğruluk, hız ve operasyonel verimlilik sağladığı belirtilmektedir (Alyahya vd., 2023; Liao vd., 2020; Sunar & Khalid, 2024). Otomatik sınıflandırma, şikayetlerin hızlı ve doğru biçimde kategorize edilmesini, tekrar eden sorunların analizini ve çözüm odaklı aksiyonların daha etkin planlanmasını mümkün kılar ve çoklu kanallardan gelen şikayetlerin merkezi olarak yönetilmesini sağlamaktadır (Agostini & Nosella, 2021; Gokce vd., 2024; Mugge vd., 2017; Puspardarma vd., 2025).

Çalışmanın temel amacı doğrultusunda, YZ model çıktılarının bir Kök Neden Analizi (RCA) aracı olarak kullanılması bu çalışmanın özgün katkısını oluşturmaktadır. Bu yaklaşım, sadece şikayetlerin doğru kategorize edilmesini değil, aynı zamanda modelin hata yaptığı kritik alanları (Örn: Öğrenci İşleri ile Tez/ Danışmanlık Sorunları arasındaki karışıklık) tespit ederek kurum içi süreç belirsizliklerine dair yönetsel bir geri bildirim sunmayı hedefler. Ayrıca, makine öğrenimi modellerinin performans farklılıklarının tesadüfi olmadığını bilimsel olarak kanıtlamak amacıyla istatistiksel anlamlılık (ANOVA) test sonuçları çalışmaya dahil edilmiştir.

Bu çalışmanın temel amacı, üniversite çözüm merkezine iletilen öğrenci şikayetlerinin yapay zekâ tabanlı analiz ve otomatik sınıflandırma yöntemleriyle işlenmesinin şikayet yönetimi süreçlerinde doğruluk, hız ve operasyonel verimlilik açısından sağlayacağı iyileştirmeleri ortaya koymaktır. Ayrıca, manuel ve otomatik süreçlerin karşılaştırmalı değerlendirilmesiyle dijital dönüşümün üniversite süreçlerine entegrasyon potansiyeli kapsamlı biçimde analiz edilmiştir. Süreç iyileştirme

ve dijital dönüşüm olanakları, güncel literatür temelinde ele alınmış (Puspardarma vd., 2025) ve kapsamlı değerlendirmede (Gokce vd., 2024).

Bu çalışmada şu temel araştırma sorusuna yanıt aranmaktadır: Yapay zekâ tabanlı sınıflandırma algoritmaları (Naive Bayes, SVM, Random Forest, BERT), üniversite öğrenci şikayetlerinin sınıflandırılmasında manuel yöntemlere kıyasla doğruluk, hız ve tutarlılık açısından üstün performans göstermekte midir? Bu ana sorunun yanıtını derinleştirmek amacıyla aşağıdaki alt sorular ele alınmıştır:

- YZ tabanlı otomatik sınıflandırma, öğrenci şikayetlerinde ne düzeyde doğruluk sağlamaktadır?
- YZ destekli analiz, manuel işleme kıyasla şikayetlerin sınıflandırılması ve yanıtlanma süresini ne ölçüde azaltmaktadır?
- Otomasyon, operasyonel iş yükü ve kaynak kullanımına nasıl etki etmektedir?

2. LİTERATÜR ÖZETİ VE KAVRAMSAL ÇERÇEVE

2.1. Dijital Dönüşüm ve YZ Tabanlı Şikâyet Sistemleri

Dijital dönüşüm, kurumların iş süreçlerini, hizmet sunumunu ve organizasyonel yapısını bilişim teknolojileriyle köklü biçimde değiştirmesini ifade eder (Vial, 2019). Bu dönüşüm, yükseköğretim kurumlarında otomasyon, veri tabanlı yönetim ve süreç iyileştirme gibi pek çok alanda yenilikçi uygulamaların yaygınlaşmasına olanak sağlamaktadır (Taşlıbeyaz & Taşçı, 2021). Yapay zekâ ise dijital dönüşümün en önemli itici gücü olarak öne çıkmakta ve insan benzeri bilişsel işlevleri taklit eden algoritmalar bütünü olarak tanımlanmaktadır (Birhanlı, 2025). Dijital dönüşüm yalnızca teknolojik bir yenilenme değil, aynı zamanda kurumların iş yapış biçimlerini ve organizasyonel kültürünü de köklü biçimde değiştiren çok boyutlu bir değişimdir (Gümüsoğlu,

2017). Yükseköğretimde dijitalleşme, hem eğitim ortamlarında hem de yönetim süreçlerinde yenilikçi çözümler ve veri temelli karar alma olanakları sunmakta; yapay zekâ ise otomasyon, kişiselleştirme ve süreç iyileştirme gibi unsurlarla bu dönüşümü desteklemektedir (Zhou, 2025). Dijitalleşme sürecinin hızlanmasıyla birlikte üniversitelerde hem yönetsel hem de akademik alanlarda veri tabanlı karar verme ve süreç otomasyonu giderek yaygınlaşmıştır (Telli & Aydın, 2025).

Dijital dönüşüm, yükseköğretim kurumlarında öğrenci odaklı hizmetlerin iyileştirilmesi ve süreçlerin modernleştirilmesinde de stratejik bir rol üstlenmektedir. Dijital platformlar ve yapay zekâ uygulamalarının yaygınlaşmasıyla, şikâyet yönetimi, kalite güvencesi ve öğrenci işlemleri daha şeffaf ve izlenebilir hale gelmiştir (Öncü vd., 2024). Eğitimde dijitalleşme ve e-öğrenme süreçleri esneklik ve erişilebilirlik sağlamakta; veri temelli karar alma ve süreç otomasyonu ise öğrencilerin ve personelin yetkinliklerinin gelişimine katkıda bulunmaktadır (Talu & Tezci, 2025). Türkiye’deki ve dünyadaki araştırmalar, dijital dönüşüm projelerinde eğitim ve yönetim bileşenlerinin öne çıktığını ve dijitalleşmenin son yıllarda hızlandığını göstermektedir (Taşlıbeyaz & Taşcı, 2021).

Mikroservis mimarisi ve çoklu kanal yönetimi gibi yeni nesil teknolojiler, üniversite yönetiminde entegre ve esnek çözümler geliştirilmesine olanak sağlamaktadır (Puspardarma vd., 2025). Bununla birlikte, sürdürülebilir dijital dönüşüm için teknik altyapı, uzman personel, dijital okuryazarlık ve kültürel adaptasyonun gerekliliği, ayrıca dijitalleşmenin yol açtığı eşitsizlikler ve siber güvenlik risklerinin göz önünde bulundurulması gerekmektedir (Doğan, 2025). Kalite güvencesi için dijital araçların standartlara uygun kullanılması, öğretim üyelerinin dijital yeterliliklerinin artırılması ve altyapı yatırımlarının güçlendirilmesi önerilmektedir (Yakut Özek & Sincer, 2024).

Dijital dönüşüm sayesinde üniversitelerde süreçler daha ölçülebilir ve veriye dayalı hale gelmekte; yapay zekâ destekli şikâyet sistemleriyle çözüm süreleri ve memnuniyet düzeyleri analiz edilerek yönetim birimlerine stratejik karar desteği sunulmaktadır (Kıvrak, 2025; Ulaş, 2025). Eğitim 4.0 yaklaşımıyla birlikte, geleneksel yöntemlerin yetersiz kaldığı ve yenilikçi, kişiselleştirilmiş öğrenme süreçlerinin gerekliliği vurgulanmaktadır (Engin vd., 2025). Dijitalleşmenin ise eğitimde kalite güvencesini güçlendirdiği, öğretim yöntemlerini çeşitlendirdiği, öğrenci katılımını ve öğrenci-öğretmen iletişimini artırdığı literatürde sıklıkla belirtilmektedir (Maral, 2025; Talu & Tezci, 2025). Ayrıca, dijitalleşme ile birlikte öğrenci geri bildirimlerinin doğal dil işleme teknikleriyle analiz edilmesi, yönetim süreçlerinde erken uyarı ve sürekli iyileştirme açısından önemli katkılar sağlamaktadır (Gottipati vd., 2018; Hu vd., 2022).

2.2. Sınıflandırma Algoritmaları ve Veri İşleme

Şikâyet yönetiminde yapay zekâ uygulamalarının merkezinde, metin temelli şikâyetlerin otomatik olarak sınıflandırılması yer almaktadır. Literatürde bu amaçla, Naive Bayes, Destek Vektör Makineleri (SVM) ve Karar Ağaçları gibi geleneksel makine öğrenmesi algoritmalarının sıkça kullanıldığı görülmektedir (Guia vd., 2019). Son yıllarda ise LSTM, BERT ve RoBERTa gibi derin öğrenme tabanlı modeller; özellikle karmaşık dil yapılarının analizi ve çoklu etiketli sınıflandırma gibi görevlerde öne çıkmaktadır (Graff vd., 2025). Bazı durumlarda, iyi optimize edilmiş klasik yöntemler de derin öğrenme modelleriyle benzer doğruluk sunabilmektedir (Athira vd., 2025). Model seçimi yapılırken, veri setinin büyüklüğü, dili ve problem tanımı dikkatle değerlendirilmelidir (Sabir vd., t.y.). Otomatik şikâyet sınıflandırmasında, kullanılan algoritmanın yanında özellik mühendisliği ve veri ön işleme adımları da büyük önem taşır. Şikâyet metinlerinin yapısal hâle getirilmesinde; ke-

lime frekansları, n-gramlar, TF-IDF ve word embedding gibi teknikler yaygın olarak kullanılmaktadır (Asudani vd., 2023; Kavitha & Prabhavathy, 2021; Setiawan vd., 2024). Son yıllarda BERT ve benzeri embedding temelli modellerin, klasik yöntemlere kıyasla daha yüksek doğruluk sunduğu gösterilmiştir (Kumawat vd., 2025). Ayrıca, yapısal olmayan veri kaynaklarında OCR teknolojisi ile dijitalleştirilen metinlerin sınıflandırmaya uygun hâle getirilmesi ve boyut indirgeme, özellik seçimi gibi tekniklerle hem doğruluk hem de işlem verimliliği artırılabilir (M. Hassan vd., 2025). Bütün bu tekniklerin yanı sıra, yapay zekâ tabanlı otomasyon ve sohbet botları, şikâyet yönetiminde hız, verimlilik ve 7/24 kesintisiz hizmet gibi önemli avantajlar sunmaktadır (Nicolescu & Tudorache, 2022). Doğal dil işleme ve makine öğrenimi temelli bu sistemler, gelen şikâyetleri otomatik olarak analiz edip yanıtlayarak insan müdahalesini azaltmakta ve süreçleri standartlaştırmaktadır. Araştırmalar, YZ destekli botların hem müşteri deneyimini hem de operasyonel verimliliği artırdığını göstermektedir (Goswami vd., 2024; D. Kumar & Ratten, 2025). Eğitim ortamlarında da kullanılan bu teknolojiler, öğrenci şikâyet ve geri bildirimlerinin daha hızlı işlenmesini ve öğrenme motivasyonunun artmasını sağlamaktadır (Essel vd., 2025). Ayrıca, entegre otomasyon sistemleri sayesinde şikâyetlerin standart yaklaşımla ele alınması ve otomatik çözümler üretilmesi, hem kurumların iş yükünü azaltmakta hem de hizmet kalitesini yükseltmektedir (Puspardarma vd., 2025). Bu teknolojiler, sadece şikâyetlerin değil, öğrenci geri bildirimlerinin ve ders değerlendirme verilerinin de otomatik analizini mümkün kılarak, üniversitelerin hizmet ve eğitim süreçlerini proaktif şekilde iyileştirmesine olanak tanımaktadır (Gottipati vd., 2018; Hu vd., 2022).

2.3. Etik, Güvenlik ve Kullanıcı Deneyimi

Yapay zekâ tabanlı şikâyet yönetimi sistemle-

rinde, kullanıcı deneyimi ve algısı teknolojik verimlilik kadar önemlidir. Literatürde, YZ ile etkileşime giren kullanıcıların bazen soğukluk, güvensizlik ve memnuniyetsizlik yaşadıkları, özellikle empati ve kişiselleştirme eksikliğinin olumsuz duygular yarattığı ifade edilmektedir (Y. Chen & Prentice, 2025; X. Li vd., 2025). Bu nedenle, tamamen otomatik sistemler yerine insan dokunuşuyla zenginleştirilmiş hibrit yaklaşımlar daha olumlu kullanıcı deneyimleri sunabilmektedir (Davenport vd., 2020).

Yapay zekâ uygulamalarının şeffaflık, veri gizliliği ve açıklanabilirlik gibi etik boyutları da önem taşır. Kullanıcılar, hangi verilerinin toplandığını ve nasıl kullanıldığını bilmek istemekte, kararların nedenlerinin açıklanmasını talep etmektedir. Açıklanabilir yapay zekâ (XAI) uygulamaları, şikâyetlerin nasıl ele alındığı ve öneri sistemlerinin arka planı konusunda daha fazla şeffaflık sağlayarak kullanıcı güvenini artırmaktadır (L. Chen vd., 2020; Liao vd., 2020).

Kullanıcı geri bildirimlerinin sistem tarafından sürekli analiz edilmesi ve iş süreçlerine entegre edilmesi, hem hizmet kalitesinin hem de memnuniyetin sürdürülebilir biçimde iyileştirilmesine katkı sağlar. Özelleştirilebilir yanıtlar ve empatik yaklaşımlar, müşteri sadakati ve toplumsal kabul açısından olumlu etkiler yaratmaktadır (Tuncal, 2025). Sonuç olarak, etik ilkeler ve kullanıcı deneyimi odaklı tasarım, YZ tabanlı şikâyet yönetiminin başarısında kritik rol oynamaktadır.

2.4. Uygulama Örnekleri ve Performans Kıyaslamaları

Otomatik sınıflandırma yöntemlerinin etkililiğini artırmak için, öneri sistemleri ve tahminleme modelleriyle entegre yaklaşımlar geliştirilmiştir. Bu tür sistemler, şikâyetlerin yalnızca uygun kategoriye ayrılmasıyla kalmayıp aynı zamanda en etkili çözüm yöntemleriyle gerçek zamanlı olarak eşleştirilmesine imkân vermektedir (Gokce vd., 2024).Örne-

ğın, müşteri şikâyetlerine verilen yanıtların içeriğini analiz eden modeller, yanıt biçiminin müşterinin sonraki memnuniyetine etkisini öngörebilmektedir.

Finans ve sosyal medya gibi farklı alanlarda yapılan uygulama örnekleri, DistilBERT, GloVe, RoBERTa ve transformer tabanlı diğer modellerin duygu, yoğunluk ve çoklu etiketli metin sınıflandırmada yüksek doğruluk ve esneklik sağladığını göstermektedir (Athira vd., 2025; Karim vd., 2025). Özellikle hibrit yaklaşımlar (ör. BERT+SVM, BiLSTM+GloVe) klasik ve derin öğrenme tekniklerinin avantajlarını birleştirerek kurumsal uygulamalarda öne çıkmaktadır (Graff vd., 2025; Sabir vd., 2025).

Ayrıca, model çıktılarının şeffaflığı ve açıklanabilirliği özellikle eğitim, sağlık ve finans gibi alanlarda kullanıcı güveni açısından önemlidir. LIME gibi açıklanabilir yapay zekâ araçları, model kararlarının anlaşılmasını ve kurumsal adaptasyonu kolaylaştırmaktadır (Graff vd., 2025; M. Hassan vd., 2025). Sonuç olarak, hem klasik hem de modern makine öğrenimi ve derin öğrenme yöntemleri, üniversitelerde şikâyetlerin etkin biçimde işlenmesi ve dijital dönüşüm süreçlerinin desteklenmesi açısından önemli avantajlar sunmaktadır.

2.5. Literatürdeki Boşluklar ve Gelecek Araştırma Alanları

Yapılan literatür incelemeleri, üniversite ortamında yapay zekâ uygulamalarının ampirik açıdan halen sınırlı incelendiğini göstermektedir. Ampirik veri eksikliği, özellikle yapay zekâ tabanlı sistemlerin gerçek dünyadaki etkinliğinin ve sonuçlarının kapsamlı biçimde analiz edilmesini zorlaştırmaktadır (Gorbâns, 2025). Üniversite bağlamında, farklı öğrenci profilleri ve kurum yapıları temelinde yapılacak geniş ölçekli saha çalışmaları, mevcut literatürdeki bu boşluğu doldurma potansiyeline sahiptir (Cano vd., 2024; Franklin, 2013; Gardner vd., 2023). Bu noktada, kullanıcı merkezli değerlendirme ve kabul çalışmalarının azlığı da dikkat çekmektedir. Öğrenci-

lerin yapay zekâ ile çalışan şikâyet yönetim sistemlerine yönelik tutumları ve kullanıcı deneyimleri hakkında daha fazla niteliksel ve niceliksel veriye ihtiyaç vardır (Ndunagu vd., 2022). Bu alanda yürütülecek derinlemesine çalışmalar, sistemlerin tasarımında ve entegrasyonunda yol gösterici olacaktır (Cano vd., 2024; Gardner vd., 2023).

Veri gizliliği, etik ve yasal uyum konuları ise güncel literatürde tartışılan ancak derinlemesine incelenmeyen diğer önemli bir araştırma alanıdır. Yapay zekâ ile çalışan sistemlerin büyük veri kümelerini işlemesi, kişisel verilerin korunması ve etik kuralların uygulanması gerekliliğini gündeme getirmiştir (Gorbâns, 2025). Bu bağlamda, şeffaflık, veri güvenliği ve algoritmik önyargı gibi konulara odaklanan yeni çalışmaların önemi artmaktadır (Davenport vd., 2020). Uzun vadeli etkiler ve kapalı döngü geri bildirim süreçlerinin başarısı üzerine yapılan araştırmaların da sınırlı olduğu görülmektedir. Özellikle, üniversite ortamında yapay zekâ sistemlerinin sürdürülebilirliği ve uzun dönemli öğrenci memnuniyetine etkileri halen yeterince araştırılmamıştır (Fernandes vd., 2024; K. Li, 2023). Mevcut araştırmaların çoğu, genel müşteri hizmetleri veya belirli sektörlerdeki (telekom, turizm, perakende) şikâyet yönetimine odaklanırken, üniversite ölçeğinde doğrudan uygulama yapan çalışmaların sayısı azdır (Nicolescu & Tudorache, 2022). Bu nedenle, üniversite çözüm merkezlerinde YZ tabanlı sistemlerin gerçek verilerle test edilmesi, ampirik olarak değerlendirilmesi gerekmektedir (Alyahya vd., 2023). Diğer taraftan, etik ve veri gizliliği konuları, özellikle üniversitelerde kişisel ve hassas öğrenci verilerinin işlenmesi bakımından stratejik önem taşımaktadır. Yapay zekâ sistemlerinin karar süreçlerinin şeffaf ve izlenebilir olması, hem öğrenci güveni hem de algoritmik önyargıların önlenmesi için gereklidir (Y. Chen & Prentice, 2025). Teknolojik gelişmelere paralel olarak, otomasyon ve sohbet botlarının şikâyet yönetiminde yaygınlaşması, literatürde öne çıkan güncel eğilimler arasın-

dadır (Nicolescu & Tudorache, 2022). Bu tür teknolojilerin üniversite ortamında etkin ve kullanıcı odaklı şekilde uygulanması için, sürekli öğrenen ve adapte olabilen YZ modellerinin geliştirilmesi gerekmektedir (D. Kumar & Ratten, 2025). Sonuç olarak, yapay zekâ ile şikâyet yönetimi alanında literatür sürekli gelişmektedir. Mevcut bulgular, bu teknolojinin süreçleri iyileştirme potansiyeline işaret etse de, özellikle üniversite bağlamında daha fazla ampirik ve kullanıcı odaklı çalışmaya ihtiyaç vardır. Gelecekteki araştırmaların etik, kullanıcı deneyimi ve sürdürülebilirlik odaklı derinlemesine analizlerle desteklenmesi önem arz etmektedir (Rana vd., 2025).

3. ARAŞTIRMANIN YÖNTEMİ

3.1 Araştırma Modeli ve Tasarımı

Bu araştırmada, nicel, karşılaştırmalı ve uygulamalı bir araştırma modeli benimsenmiştir (Büyüköztürk vd., 2017; Creswell & Creswell, 2023; Karasar, 2020). Nicel araştırma, sayısal verilerin toplanması ve istatistiksel yöntemlerle analiz edilmesini (Creswell & Creswell, 2023); karşılaştırmalı araştırma, farklı yöntem veya grupların süreç performanslarının birbirleriyle kıyaslanmasını (Karasar, 2020); uygulamalı araştırma ise elde edilen sonuçların doğrudan pratik bir probleme çözüm geliştirmeyi amaçlamasını ifade etmektedir (Büyüköztürk vd., 2017). Bu çerçevede, temel amaç, üniversite çözüm merkezine iletilen öğrenci şikâyetlerinin işlenmesinde, geleneksel manuel yöntemler ile yapay zekâ tabanlı otomatik sınıflandırma sistemlerinin süreç performanslarını karşılaştırmalı olarak analiz etmektir.

3.2. Veri Kaynakları ve Toplama Yöntemleri

Bu çalışmada, bir vakıf üniversitesine ait 119 adet lisansüstü öğrencilerinin şikâyet kaydı analiz edilmiştir. Kayıtlar, Ocak-Mart 2025 dönemini kapsamakta olup, üniversite çözüm merkezine öğrenciler tarafından çevrim içi

olarak iletilmiştir. Veri seti yalnızca şikâyet metinlerinden oluşmakta; her bir satırda sadece öğrenci tarafından serbest biçimde yazılmış bir şikâyet cümlesi veya paragrafı yer almaktadır. Veri setinde tarih, birim veya kategori gibi ek alanlar bulunmamaktadır.

Veriler, üniversite yönetimi tarafından tüm kişisel bilgiler ve kimlik belirteçleri çıkarılarak, anonimleştirilmiş şekilde araştırmacılara sunulmuştur. Şikâyet metinlerinde hiçbir şekilde kişi ismi, numara, e-posta veya benzeri hassas bilgi yer almamaktadır. Bu sayede, veri gizliliği ve etik kurallar eksiksiz biçimde sağlanmıştır.

3.3. Veri Analizi

Çalışma kapsamında, şikâyet metinleri üç farklı yaklaşım ile değerlendirilmiştir: (1) Üniversite çözüm merkezi tarafından yapılan orijinal kategori atamaları, (2) alanında uzman iki bağımsız araştırmacı tarafından manuel sınıflandırma, (3) doğal dil işleme (NLP) ve makine öğrenmesi algoritmaları kullanılarak yapılan otomatik sınıflandırma (Bilgin, 2014; Büyüköztürk vd., 2017).

3.3.1. Veri Ön İşleme

Veri analizine başlamadan önce, şikâyet metinleri üzerinde kapsamlı bir ön işleme süreci uygulanmıştır (Anakok vd., 2022). Tüm metinler küçük harfe dönüştürülerek harf büyüklüğüne bağlı anlam kayıpları önlenmiştir (Xu vd., 2020), cümle ve kelime sonlarında yer alan noktalama işaretleri ile özel karakterler temizlenmiştir (Uysal & Gunal, 2012). Sayılar, tek harfli sözcükler ve gereksiz boşluklar otomatik olarak silinmiş; kelimeler arasındaki fazla boşluklar ve satır başı karakterleri standart hâle getirilmiştir (Giang vd., 2020). Anlamı zayıf olan ve model performansına olumsuz etkisi bulunan Türkçe durdurma (stopword) kelimeleri, Natural Language Toolkit (NLTK) gibi araçlar yardımıyla listelenmiş ve metinlerden çıkarılmıştır (Devika vd., 2016). Ayrıca, tekrarlayan veya neredeyse

aynı olan metinler ayıklanarak analizlerin doğruluğu artırılmıştır (Ravikanth vd., 2024). Son aşamada ise, tüm metinler uygun formatta kaydedilerek analiz ve modelleme için temiz ve standart bir yapıya kavuşturulmuştur (Zhang & Wallace, 2016).

Ayrıca çözüm merkezi tarafından yapılan orijinal kategori atamaları ile araştırmacıların oluşturduğu kategori şeması arasında başlık ve kapsam açısından bazı farklılıklar bulunmaktadır. Bu nedenle, karşılaştırmalı analizlerin sağlıklı yapılabilmesi için çözüm merkezi tarafından verilen kategori etiketleri, araştırmacıların ‘altın standart’ olarak belirlediği üst kategori başlıklarına dönüştürülmüştür (Bilgin, 2014; Saldana, 2019). Örneğin, “ders seçimi” veya “kayıt” gibi konular “Akademik Sorunlar” başlığı altında; “ödeme” ve “burs” gibi konular ise “Finans ve Ödeme Sorunları” başlığı altında toplanmıştır. Böylece, farklı yaklaşımlar arasındaki kategorik uyum artırılmış ve analizlerin nesnelliği güvence altına alınmıştır (Creswell & Poth, 2016).

3.3.1.1. Veri Setini Çoğaltma (Data Augmentation)

Çalışmada kullanılan orijinal veri setinin 119 kayıttan oluşması, özellikle derin öğrenme modellerinin eğitimi için bir kısıtlılık oluşturmaktadır. Bu sınırlılığı gidermek, modelin aşırı öğrenmesini (overfitting) engellemek ve genellenebilirliğini artırmak amacıyla iki aşamalı bir veri çoğaltma (data augmentation) ve dengeleme stratejisi izlenmiştir.

Süreçte, otomasyonunWWWhızı ile insan uzmanlığının doğruluğunu birleştiren hibrit bir yaklaşım benimsenmiştir. Bu kapsamda, OpenAI GPT-4 modeli kullanılarak taslak metinler üretilmiş; ardından bu metinler araştırmacılar tarafından tek tek incelenerek anlamsal tutarlılık, dilbilgisi ve bağlamsal uygunluk açısından doğrulanmıştır. Yaklaşık 12 saatlik bir araştırmacı emeği gerektiren bu manuel doğrulama süreci, sentetik verilerin kalitesini garanti altına almış ve BERT gibi veri yoğun

modellerde dahi sonuçların güvenilirliğini sağlamıştır. Veri çoğaltma ve dengeleme süreci şu adımlarla gerçekleştirilmiştir:

- Genel Veri Çoğaltma: İlk aşamada, orijinal veri setindeki dilsel çeşitliliği artırmak amacıyla her bir şikâyet kaydı için hibrit yöntemle ikişer adet alternatif metin (toplam 238 yeni metin) üretilmiştir.
- Hedefli Veri Dengeleme (Class Balancing): İlk genişletmenin ardından sınıf dağılımları incelenmiş ve azınlık sınıflarının (minority classes) hala yetersiz temsil edildiği görülmüştür. Modellerin bu sınıfları da etkin öğrenebilmesi için, örnek sayısı az olan kategorilere yönelik agresif çoğaltma uygulanmış ve her kategorinin kayıt sayısı 100’ün üzerine taşınmıştır.
- Nihai Kalite Kontrolü: Oluşturulan genişletilmiş veri seti son bir kez daha gözden geçirilmiş; tekrara düşen, zayıf veya kategori tanımıyla örtüşmeyen kayıtlar ayıklanmıştır.

Tablo 1. Şikâyet Veri Setinin Orijinal ve Çoğaltma Sonrası Kategorik Dağılımı

Kategori Adı	Orijinal Kayıt Sayısı (N=119)	Çoğaltma Sonrası Kayıt Sayısı (N=781)	Çoğaltma Faktörü (Yaklaşık)	Gerekçe (Sınıf Dengeleme)
Öğrenci İşleri Sorunları	42 (%35.3)	131	3.1 Kat	Baskın sınıflardan biri, ancak denge için çoğaltıldı.
Tez ve Danışmanlık Sorunları	24 (%20.2)	140	5.8 Kat	Orta seviyede temsil edilen bir sınıf, model öğrenimini güçlendirmek için hedeflendi.

Teknik Sorunlar	23 (%19.3)	142	6.2 Kat	Orta seviyede temsil edilen bir sınıf, model öğrenimini güçlendirmek için hedeflendi.
Akademik Sorunlar	13 (%10.9) 1	122	9.4 Kat	Azınlık sınıfı: Performansın genellenebilirliğini artırmak amacıyla agresif çoğaltma uygulandı.
İletişim ve Erişim Sorunları	9 (%7.6)	123	13.7 Kat	Azınlık sınıfı: Modellerin azınlık sınıflarını etkin öğrenmesi hedeflendi.
Finans ve Ödeme Sorunları	8 (%6.7)	123	15.4 Kat	En küçük sınıf; yanlılığı önlemek için maksimum çoğaltma.

Bu sürecin sonunda; kategoriler arası dengeğin büyük ölçüde sağlandığı toplam 781 kayıttan oluşan nihai veri seti elde edilmiştir (Bkz. Tablo 1). Literatürde belirtildiği üzere, sınıf dengesizliğinin giderilmesi, sınıflandırıcıların performansını ve güvenilirliğini doğrudan artırmaktadır (Buda vd., 2018; Haibo He & Garcia, 2009). Uygulanan bu yöntemle, modelin farklı ifade tarzlarına karşı duyarlılığı artırılmış ve çalışma sonuçlarının geçerliliği güçlendirilmiştir (Feng vd., 2021; Wei vd., 2025).

3.3.2. Özellik Çıkarımı

Makine öğrenmesi ve derin öğrenme tabanlı sınıflandırma algoritmalarının etkin şekilde çalışabilmesi için, metinlerin sayısal biçimde temsil edilmesi gerekmektedir. Bu amaçla, çalışma kapsamında tüm öğrenci şikâyet metinlerinden vektör tabanlı öznitelikler (özellikler) elde edilmiştir. Özellik çıkarımı süreci, kullanılan model türüne göre farklılaştırılmış; klasik makine öğrenmesi algoritmaları için TF-IDF (Term Frequency-Inverse Document

Frequency) temelli sayısal vektörler, derin öğrenme tabanlı BERT modeli için ise bağlamsal gömme (contextual embedding) vektörleri kullanılmıştır. Klasik makine öğrenmesi modellerinde (Naive Bayes, SVM, Random Forest), şikâyet metinleri scikit-learn kütüphanesinin TfidfVectorizer fonksiyonu ile işlenmiştir. Bu kapsamda, unigram ve bigram düzeyindeki kelime kombinasyonları dikkate alınmış, en sık geçen ilk 10.000 terim özellik kümesine dahil edilmiştir. Türkçe karakterler korunmuş, özel karakterler ve noktalama işaretleri temizlenmiştir. Stopword (anlamsız kelimeler) listesi kullanılarak içerik dışı sözcükler ayıklanmış, frekansı 2'den az olan kelimeler analiz dışı bırakılmıştır. Böylece, klasik modeller için anlamlı ve optimize edilmiş TF-IDF temsilleri elde edilmiştir. Bu yaklaşım, metin sınıflandırmada yaygın olarak kullanılan ve belgeler arası ayrım gücü yüksek temsiller oluşturmada etkili bir yöntemdir (Manning vd., 2008; Zhang & Wallace, 2016). Derin öğrenme tabanlı sınıflandırma işlemlerinde ise önceden eğitilmiş çok dilli BERT (mBERT) modeli kullanılmıştır. Bu model, bağlama duyarlı kelime temsilleri üreterek klasik yöntemlerin aksine her kelimenin cümle içindeki anlamını dikkate alabilmektedir (Devlin vd., 2019a). Bu doğrultuda, bert-base-multilingual-cased tokenizer kullanılarak her metin maksimum 128 token ile sınırlandırılmış; modelin çıkış katmanından elde edilen [CLS] token'a karşılık gelen 768 boyutlu bağlamsal embedding vektörleri, sınıflandırma katmanına doğrudan giriş olarak kullanılmıştır. Modelin eğitimi, Hugging Face transformers ve datasets kütüphaneleri kullanılarak Google Colab ortamında gerçekleştirilmiş; Trainer arayüzü ile optimize edilmiştir. Bu yöntemlerle elde edilen sayısal temsiller, sonraki aşamada sınıflandırma modellerinin eğitiminde temel veri kaynağını oluşturmuş ve model performanslarının karşılaştırılmasında kullanılmıştır.

3.3.3. Manuel Sınıflandırma Yöntemi

Bu çalışmada, otomatik sınıflandırma modellerinin etkinliğini değerlendirebilmek için, karşılaştırmalı bir referans noktası olarak manuel sınıflandırma süreci de uygulanmıştır (Saldana, 2019). Şikayet metinleri iki bağımsız araştırmacı tarafından, önceden belirlenen kategori şemasına göre ayrı ayrı kodlanmıştır (Creswell & Creswell, 2023). Her araştırmacı, öğrenci ifadelerini hem içerik hem de bağlamsal bütünlük temelinde değerlendirerek kategori atamıştır (Pabel & Shah, 2025). Şikayetlerin çok boyutlu olması ve birden fazla kategori ile ilişkili olabilmesi dikkate alınarak, bazı kayıtlar için gerektiğinde çoklu etiketleme yapılmıştır (Gronberg vd., 2021).

Kodlama süreci tamamlandıktan sonra, iki araştırmacı tarafından yapılan atamalar karşılaştırılmış; aralarındaki tutarlılık Cohen's Kappa katsayısı ile ölçülmüştür. Elde edilen kappa değeri 0.83 olup, bu sonuç Landis ve Koch (1977) sınıflamasına göre "mükemmel uyum" düzeyinde bir güvenilirlik göstermektedir. Bu yüksek tutarlılık, otomatik sınıflandırma sistemlerinin performansını değerlendirmede kullanılan 'altın standart' etiketleme setinin nesnel geçerliliğini kanıtlamaktadır. Kodlayıcılar arası görüş ayrılığı bulunan kayıtlar, üçüncü bir uzman görüşü ile sonuca bağlanmış ve son etiket seti "altın standart" olarak tanımlanmıştır. Tüm karşılaştırmalar ve model değerlendirmeleri, otomatik sınıflandırma sistemlerinin performansını nesnel biçimde değerlendirmek amacıyla oluşturulan bu referans etiket seti üzerinden yürütülmüştür (Devika vd., 2016).

3.3.4. Kullanılan AI ve Sınıflandırma Modelleri

Veri ön işleme adımlarının ardından, öğrenci şikâyet metinlerinin otomatik olarak analiz edilmesi ve uygun kategorilere atanması amacıyla çeşitli doğal dil işleme (NLP) teknikleri ile makine öğrenimi tabanlı sınıflandırma algoritmaları kullanılmıştır (Pedregosa vd.,

2011). Naive Bayes, SVM ve Random Forest modelleri için özellik çıkarımı TF-IDF (Term Frequency-Inverse Document Frequency) yöntemiyle yapılmıştır. Sınıflandırma işlemlerinde, Naive Bayes, Destek Vektör Makineleri (SVM) ve Random Forest gibi klasik makine öğrenmesi algoritmalarının yanında, BERT gibi modern derin öğrenme tabanlı dil modeli de değerlendirilmiştir (Liao vd., 2020). Naive

Tablo 2. Sınıflandırma Modellerinin Parametreleri ve Gerekeçleri

Model Adı	Temel Algoritma / Özellik Çıkarımı	Hiperparametreler	Gerekeç ve Amaç
LinearSVC (SVM)	TF-IDF (1-gram, 2-gram, 3-gram, 4-gram, 5-gram, 6-gram, 7-gram, 8-gram, 9-gram, 10-gram, 11-gram, 12-gram, 13-gram, 14-gram, 15-gram, 16-gram, 17-gram, 18-gram, 19-gram, 20-gram, 21-gram, 22-gram, 23-gram, 24-gram, 25-gram, 26-gram, 27-gram, 28-gram, 29-gram, 30-gram, 31-gram, 32-gram, 33-gram, 34-gram, 35-gram, 36-gram, 37-gram, 38-gram, 39-gram, 40-gram, 41-gram, 42-gram, 43-gram, 44-gram, 45-gram, 46-gram, 47-gram, 48-gram, 49-gram, 50-gram, 51-gram, 52-gram, 53-gram, 54-gram, 55-gram, 56-gram, 57-gram, 58-gram, 59-gram, 60-gram, 61-gram, 62-gram, 63-gram, 64-gram, 65-gram, 66-gram, 67-gram, 68-gram, 69-gram, 70-gram, 71-gram, 72-gram, 73-gram, 74-gram, 75-gram, 76-gram, 77-gram, 78-gram, 79-gram, 80-gram, 81-gram, 82-gram, 83-gram, 84-gram, 85-gram, 86-gram, 87-gram, 88-gram, 89-gram, 90-gram, 91-gram, 92-gram, 93-gram, 94-gram, 95-gram, 96-gram, 97-gram, 98-gram, 99-gram, 100-gram, 101-gram, 102-gram, 103-gram, 104-gram, 105-gram, 106-gram, 107-gram, 108-gram, 109-gram, 110-gram, 111-gram, 112-gram, 113-gram, 114-gram, 115-gram, 116-gram, 117-gram, 118-gram, 119-gram, 120-gram, 121-gram, 122-gram, 123-gram, 124-gram, 125-gram, 126-gram, 127-gram, 128-gram, 129-gram, 130-gram, 131-gram, 132-gram, 133-gram, 134-gram, 135-gram, 136-gram, 137-gram, 138-gram, 139-gram, 140-gram, 141-gram, 142-gram, 143-gram, 144-gram, 145-gram, 146-gram, 147-gram, 148-gram, 149-gram, 150-gram, 151-gram, 152-gram, 153-gram, 154-gram, 155-gram, 156-gram, 157-gram, 158-gram, 159-gram, 160-gram, 161-gram, 162-gram, 163-gram, 164-gram, 165-gram, 166-gram, 167-gram, 168-gram, 169-gram, 170-gram, 171-gram, 172-gram, 173-gram, 174-gram, 175-gram, 176-gram, 177-gram, 178-gram, 179-gram, 180-gram, 181-gram, 182-gram, 183-gram, 184-gram, 185-gram, 186-gram, 187-gram, 188-gram, 189-gram, 190-gram, 191-gram, 192-gram, 193-gram, 194-gram, 195-gram, 196-gram, 197-gram, 198-gram, 199-gram, 200-gram, 201-gram, 202-gram, 203-gram, 204-gram, 205-gram, 206-gram, 207-gram, 208-gram, 209-gram, 210-gram, 211-gram, 212-gram, 213-gram, 214-gram, 215-gram, 216-gram, 217-gram, 218-gram, 219-gram, 220-gram, 221-gram, 222-gram, 223-gram, 224-gram, 225-gram, 226-gram, 227-gram, 228-gram, 229-gram, 230-gram, 231-gram, 232-gram, 233-gram, 234-gram, 235-gram, 236-gram, 237-gram, 238-gram, 239-gram, 240-gram, 241-gram, 242-gram, 243-gram, 244-gram, 245-gram, 246-gram, 247-gram, 248-gram, 249-gram, 250-gram, 251-gram, 252-gram, 253-gram, 254-gram, 255-gram, 256-gram, 257-gram, 258-gram, 259-gram, 260-gram, 261-gram, 262-gram, 263-gram, 264-gram, 265-gram, 266-gram, 267-gram, 268-gram, 269-gram, 270-gram, 271-gram, 272-gram, 273-gram, 274-gram, 275-gram, 276-gram, 277-gram, 278-gram, 279-gram, 280-gram, 281-gram, 282-gram, 283-gram, 284-gram, 285-gram, 286-gram, 287-gram, 288-gram, 289-gram, 290-gram, 291-gram, 292-gram, 293-gram, 294-gram, 295-gram, 296-gram, 297-gram, 298-gram, 299-gram, 300-gram, 301-gram, 302-gram, 303-gram, 304-gram, 305-gram, 306-gram, 307-gram, 308-gram, 309-gram, 310-gram, 311-gram, 312-gram, 313-gram, 314-gram, 315-gram, 316-gram, 317-gram, 318-gram, 319-gram, 320-gram, 321-gram, 322-gram, 323-gram, 324-gram, 325-gram, 326-gram, 327-gram, 328-gram, 329-gram, 330-gram, 331-gram, 332-gram, 333-gram, 334-gram, 335-gram, 336-gram, 337-gram, 338-gram, 339-gram, 340-gram, 341-gram, 342-gram, 343-gram, 344-gram, 345-gram, 346-gram, 347-gram, 348-gram, 349-gram, 350-gram, 351-gram, 352-gram, 353-gram, 354-gram, 355-gram, 356-gram, 357-gram, 358-gram, 359-gram, 360-gram, 361-gram, 362-gram, 363-gram, 364-gram, 365-gram, 366-gram, 367-gram, 368-gram, 369-gram, 370-gram, 371-gram, 372-gram, 373-gram, 374-gram, 375-gram, 376-gram, 377-gram, 378-gram, 379-gram, 380-gram, 381-gram, 382-gram, 383-gram, 384-gram, 385-gram, 386-gram, 387-gram, 388-gram, 389-gram, 390-gram, 391-gram, 392-gram, 393-gram, 394-gram, 395-gram, 396-gram, 397-gram, 398-gram, 399-gram, 400-gram, 401-gram, 402-gram, 403-gram, 404-gram, 405-gram, 406-gram, 407-gram, 408-gram, 409-gram, 410-gram, 411-gram, 412-gram, 413-gram, 414-gram, 415-gram, 416-gram, 417-gram, 418-gram, 419-gram, 420-gram, 421-gram, 422-gram, 423-gram, 424-gram, 425-gram, 426-gram, 427-gram, 428-gram, 429-gram, 430-gram, 431-gram, 432-gram, 433-gram, 434-gram, 435-gram, 436-gram, 437-gram, 438-gram, 439-gram, 440-gram, 441-gram, 442-gram, 443-gram, 444-gram, 445-gram, 446-gram, 447-gram, 448-gram, 449-gram, 450-gram, 451-gram, 452-gram, 453-gram, 454-gram, 455-gram, 456-gram, 457-gram, 458-gram, 459-gram, 460-gram, 461-gram, 462-gram, 463-gram, 464-gram, 465-gram, 466-gram, 467-gram, 468-gram, 469-gram, 470-gram, 471-gram, 472-gram, 473-gram, 474-gram, 475-gram, 476-gram, 477-gram, 478-gram, 479-gram, 480-gram, 481-gram, 482-gram, 483-gram, 484-gram, 485-gram, 486-gram, 487-gram, 488-gram, 489-gram, 490-gram, 491-gram, 492-gram, 493-gram, 494-gram, 495-gram, 496-gram, 497-gram, 498-gram, 499-gram, 500-gram, 501-gram, 502-gram, 503-gram, 504-gram, 505-gram, 506-gram, 507-gram, 508-gram, 509-gram, 510-gram, 511-gram, 512-gram, 513-gram, 514-gram, 515-gram, 516-gram, 517-gram, 518-gram, 519-gram, 520-gram, 521-gram, 522-gram, 523-gram, 524-gram, 525-gram, 526-gram, 527-gram, 528-gram, 529-gram, 530-gram, 531-gram, 532-gram, 533-gram, 534-gram, 535-gram, 536-gram, 537-gram, 538-gram, 539-gram, 540-gram, 541-gram, 542-gram, 543-gram, 544-gram, 545-gram, 546-gram, 547-gram, 548-gram, 549-gram, 550-gram, 551-gram, 552-gram, 553-gram, 554-gram, 555-gram, 556-gram, 557-gram, 558-gram, 559-gram, 560-gram, 561-gram, 562-gram, 563-gram, 564-gram, 565-gram, 566-gram, 567-gram, 568-gram, 569-gram, 570-gram, 571-gram, 572-gram, 573-gram, 574-gram, 575-gram, 576-gram, 577-gram, 578-gram, 579-gram, 580-gram, 581-gram, 582-gram, 583-gram, 584-gram, 585-gram, 586-gram, 587-gram, 588-gram, 589-gram, 590-gram, 591-gram, 592-gram, 593-gram, 594-gram, 595-gram, 596-gram, 597-gram, 598-gram, 599-gram, 600-gram, 601-gram, 602-gram, 603-gram, 604-gram, 605-gram, 606-gram, 607-gram, 608-gram, 609-gram, 610-gram, 611-gram, 612-gram, 613-gram, 614-gram, 615-gram, 616-gram, 617-gram, 618-gram, 619-gram, 620-gram, 621-gram, 622-gram, 623-gram, 624-gram, 625-gram, 626-gram, 627-gram, 628-gram, 629-gram, 630-gram, 631-gram, 632-gram, 633-gram, 634-gram, 635-gram, 636-gram, 637-gram, 638-gram, 639-gram, 640-gram, 641-gram, 642-gram, 643-gram, 644-gram, 645-gram, 646-gram, 647-gram, 648-gram, 649-gram, 650-gram, 651-gram, 652-gram, 653-gram, 654-gram, 655-gram, 656-gram, 657-gram, 658-gram, 659-gram, 660-gram, 661-gram, 662-gram, 663-gram, 664-gram, 665-gram, 666-gram, 667-gram, 668-gram, 669-gram, 670-gram, 671-gram, 672-gram, 673-gram, 674-gram, 675-gram, 676-gram, 677-gram, 678-gram, 679-gram, 680-gram, 681-gram, 682-gram, 683-gram, 684-gram, 685-gram, 686-gram, 687-gram, 688-gram, 689-gram, 690-gram, 691-gram, 692-gram, 693-gram, 694-gram, 695-gram, 696-gram, 697-gram, 698-gram, 699-gram, 700-gram, 701-gram, 702-gram, 703-gram, 704-gram, 705-gram, 706-gram, 707-gram, 708-gram, 709-gram, 710-gram, 711-gram, 712-gram, 713-gram, 714-gram, 715-gram, 716-gram, 717-gram, 718-gram, 719-gram, 720-gram, 721-gram, 722-gram, 723-gram, 724-gram, 725-gram, 726-gram, 727-gram, 728-gram, 729-gram, 730-gram, 731-gram, 732-gram, 733-gram, 734-gram, 735-gram, 736-gram, 737-gram, 738-gram, 739-gram, 740-gram, 741-gram, 742-gram, 743-gram, 744-gram, 745-gram, 746-gram, 747-gram, 748-gram, 749-gram, 750-gram, 751-gram, 752-gram, 753-gram, 754-gram, 755-gram, 756-gram, 757-gram, 758-gram, 759-gram, 760-gram, 761-gram, 762-gram, 763-gram, 764-gram, 765-gram, 766-gram, 767-gram, 768-gram, 769-gram, 770-gram, 771-gram, 772-gram, 773-gram, 774-gram, 775-gram, 776-gram, 777-gram, 778-gram, 779-gram, 780-gram, 781-gram, 782-gram, 783-gram, 784-gram, 785-gram, 786-gram, 787-gram, 788-gram, 789-gram, 790-gram, 791-gram, 792-gram, 793-gram, 794-gram, 795-gram, 796-gram, 797-gram, 798-gram, 799-gram, 800-gram, 801-gram, 802-gram, 803-gram, 804-gram, 805-gram, 806-gram, 807-gram, 808-gram, 809-gram, 810-gram, 811-gram, 812-gram, 813-gram, 814-gram, 815-gram, 816-gram, 817-gram, 818-gram, 819-gram, 820-gram, 821-gram, 822-gram, 823-gram, 824-gram, 825-gram, 826-gram, 827-gram, 828-gram, 829-gram, 830-gram, 831-gram, 832-gram, 833-gram, 834-gram, 835-gram, 836-gram, 837-gram, 838-gram, 839-gram, 840-gram, 841-gram, 842-gram, 843-gram, 844-gram, 845-gram, 846-gram, 847-gram, 848-gram, 849-gram, 850-gram, 851-gram, 852-gram, 853-gram, 854-gram, 855-gram, 856-gram, 857-gram, 858-gram, 859-gram, 860-gram, 861-gram, 862-gram, 863-gram, 864-gram, 865-gram, 866-gram, 867-gram, 868-gram, 869-gram, 870-gram, 871-gram, 872-gram, 873-gram, 874-gram, 875-gram, 876-gram, 877-gram, 878-gram, 879-gram, 880-gram, 881-gram, 882-gram, 883-gram, 884-gram, 885-gram, 886-gram, 887-gram, 888-gram, 889-gram, 890-gram, 891-gram, 892-gram, 893-gram, 894-gram, 895-gram, 896-gram, 897-gram, 898-gram, 899-gram, 900-gram, 901-gram, 902-gram, 903-gram, 904-gram, 905-gram, 906-gram, 907-gram, 908-gram, 909-gram, 910-gram, 911-gram, 912-gram, 913-gram, 914-gram, 915-gram, 916-gram, 917-gram, 918-gram, 919-gram, 920-gram, 921-gram, 922-gram, 923-gram, 924-gram, 925-gram, 926-gram, 927-gram, 928-gram, 929-gram, 930-gram, 931-gram, 932-gram, 933-gram, 934-gram, 935-gram, 936-gram, 937-gram, 938-gram, 939-gram, 940-gram, 941-gram, 942-gram, 943-gram, 944-gram, 945-gram, 946-gram, 947-gram, 948-gram, 949-gram, 950-gram, 951-gram, 952-gram, 953-gram, 954-gram, 955-gram, 956-gram, 957-gram, 958-gram, 959-gram, 960-gram, 961-gram, 962-gram, 963-gram, 964-gram, 965-gram, 966-gram, 967-gram, 968-gram, 969-gram, 970-gram, 971-gram, 972-gram, 973-gram, 974-gram, 975-gram, 976-gram, 977-gram, 978-gram, 979-gram, 980-gram, 981-gram, 982-gram, 983-gram, 984-gram, 985-gram, 986-gram, 987-gram, 988-gram, 989-gram, 990-gram, 991-gram, 992-gram, 993-gram, 994-gram, 995-gram, 996-gram, 997-gram, 998-gram, 999-gram, 1000-gram, 1001-gram, 1002-gram, 1003-gram, 1004-gram, 1005-gram, 1006-gram, 1007-gram, 1008-gram, 1009-gram, 1010-gram, 1011-gram, 1012-gram, 1013-gram, 1014-gram, 1015-gram, 1016-gram, 1017-gram, 1018-gram, 1019-gram, 1020-gram, 1021-gram, 1022-gram, 1023-gram, 1024-gram, 1025-gram, 1026-gram, 1027-gram, 1028-gram, 1029-gram, 1030-gram, 1031-gram, 1032-gram, 1033-gram, 1034-gram, 1035-gram, 1036-gram, 1037-gram, 1038-gram, 1039-gram, 1040-gram, 1041-gram, 1042-gram, 1043-gram, 1044-gram, 1045-gram, 1046-gram, 1047-gram, 1048-gram, 1049-gram, 1050-gram, 1051-gram, 1052-gram, 1053-gram, 1054-gram, 1055-gram, 1056-gram, 1057-gram, 1058-gram, 1059-gram, 1060-gram, 1061-gram, 1062-gram, 1063-gram, 1064-gram, 1065-gram, 1066-gram, 1067-gram, 1068-gram, 1069-gram, 1070-gram, 1071-gram, 1072-gram, 1073-gram, 1074-gram, 1075-gram, 1076-gram, 1077-gram, 1078-gram, 1079-gram, 1080-gram, 1081-gram, 1082-gram, 1083-gram, 1084-gram, 1085-gram, 1086-gram, 1087-gram, 1088-gram, 1089-gram, 1090-gram, 1091-gram, 1092-gram, 1093-gram, 1094-gram, 1095-gram, 1096-gram, 1097-gram, 1098-gram, 1099-gram, 1100-gram, 1101-gram, 1102-gram, 1103-gram, 1104-gram, 1105-gram, 1106-gram, 1107-gram, 1108-gram, 1109-gram, 1110-gram, 1111-gram, 1112-gram, 1113-gram, 1114-gram, 1115-gram, 1116-gram, 1117-gram, 1118-gram, 1119-gram, 1120-gram, 1121-gram, 1122-gram, 1123-gram, 1124-gram, 1125-gram, 1126-gram, 1127-gram, 1128-gram, 1129-gram, 1130-gram, 1131-gram, 1132-gram, 1133-gram, 1134-gram, 1135-gram, 1136-gram, 1137-gram, 1138-gram, 1139-gram, 1140-gram, 1141-gram, 1142-gram, 1143-gram, 1144-gram, 1145-gram, 1146-gram, 1147-gram, 1148-gram, 1149-gram, 1150-gram, 1151-gram, 1152-gram, 1153-gram, 1154-gram, 1155-gram, 1156-gram, 1157-gram, 1158-gram, 1159-gram, 1160-gram, 1161-gram, 1162-gram, 1163-gram, 1164-gram, 1165-gram, 1166-gram, 1167-gram, 1168-gram, 1169-gram, 1170-gram, 1171-gram, 1172-gram, 1173-gram, 1174-gram, 1175-gram, 1176-gram, 1177-gram, 1178-gram, 1179-gram, 1180-gram, 1181-gram, 1182-gram, 1183-gram, 1184-gram, 1185-gram, 1186-gram, 1187-gram, 1188-gram, 1189-gram, 1190-gram, 1191-gram, 1192-gram, 1193-gram, 1194-gram, 1195-gram, 1196-gram, 1197-gram, 1198-gram, 1199-gram, 1200-gram, 1201-gram, 1202-gram, 1203-gram, 1204-gram, 1205-gram, 1206-gram, 1207-gram, 1208-gram, 1209-gram, 1210-gram, 1211-gram, 1212-gram, 1213-gram, 1214-gram, 1215-gram, 1216-gram, 1217-gram, 1218-gram, 1219-gram, 1220-gram, 1221-gram, 1222-gram, 1223-gram, 1224-gram, 1225-gram, 1226-gram, 1227-gram, 1228-gram, 1229-gram, 1230-gram, 1231-gram, 1232-gram, 1233-gram, 1234-gram, 1235-gram, 1236-gram, 1237-gram, 1238-gram, 1239-gram, 1240-gram, 1241-gram, 1242-gram, 1243-gram, 1244-gram, 1245-gram, 1246-gram, 1247-gram, 1248-gram, 1249-gram, 1250-gram, 1251-gram, 1252-gram, 1253-gram, 1254-gram, 1255-gram, 1256-gram, 1257-gram, 1258-gram, 1259-gram, 1260-gram, 1261-gram, 1262-gram, 1263-gram, 1264-gram, 1265-gram, 1266-gram, 1267-gram, 1268-gram, 1269-gram, 1270-gram, 1271-gram, 1272-gram, 1273-gram, 1274-gram, 1275-gram, 1276-gram, 1277-gram, 1278-gram, 1279-gram, 1280-gram, 1281-gram, 1282-gram, 1283-gram, 1284-gram, 1285-gram, 1286-gram, 1287-gram, 1288-gram, 1289-gram, 1290-gram, 1291-gram, 1292-gram, 1293-gram, 1294-gram, 1295-gram, 1296-gram, 1297-gram, 1298-gram, 1299-gram, 1300-gram, 1301-gram, 1302-gram, 1303-gram, 1304-gram, 1305-gram, 1306-gram, 1307-gram, 1308-gram, 1309-gram, 1310-gram, 1311-gram, 1312-gram, 1313-gram, 1314-gram, 1315-gram, 1316-gram, 1317-gram, 1318-gram, 1319-gram, 1320-gram, 1321-gram, 1322-gram, 1323-gram, 1324-gram, 1325-gram, 1326-gram, 1327-gram, 1328-gram, 1329-gram, 1330-gram, 1331-gram, 1332-gram, 1333-gram, 1334-gram, 1335-gram, 1336-gram, 1337-gram, 1338-gram, 1339-gram, 1340-gram, 1341-gram, 1342-gram, 1343-gram, 1344-gram, 1345-gram, 1346-gram, 1347-gram, 1348-gram, 1349-gram, 1350-gram, 1351-gram, 1352-gram, 1353-gram, 1354-gram, 1355-gram, 1356-gram, 1357-gram, 1358-gram, 1359-gram, 1360-gram, 1361-gram, 1362-gram, 1363-gram, 1364-gram, 1365-gram, 1366-gram, 1367-gram, 1368-gram, 1369-gram, 1370-gram, 1371-gram, 1372-gram, 1373-gram, 1374-gram, 1375-gram, 1376-gram, 1377-gram, 1378-gram, 1379-gram, 1380-gram, 1381-gram, 1382-gram, 1383-gram, 1384-gram, 1385-gram, 1386-gram, 1387-gram, 1388-gram, 1389-gram, 1390-gram, 1391-gram, 1392-gram, 1393-gram, 1394-gram, 1395-gram, 1396-gram, 1397-gram, 1398-gram, 1399-gram, 1400-gram, 1401-gram, 1402-gram, 1403-gram, 1404-gram, 1405-gram, 1406-gram, 1407-gram, 1408-gram, 1409-gram, 1410-gram, 1411-gram, 1412-gram, 1413-gram, 1414-gram, 1415-gram, 1416-gram, 1417-gram, 1418-gram, 1419-gram, 1420-gram, 1421-gram, 1422-gram, 1423-gram, 1424-gram, 1425-gram, 1426-gram, 1427-gram, 1428-gram, 1429-gram, 1430-gram, 1431-gram, 1432-gram, 1433-gram, 1434-gram, 1435-gram, 1436-gram, 1437-gram, 1438-gram, 1439-gram, 1440-gram, 1441-gram, 1442-gram, 1443-gram, 1444-gram, 1445-gram, 1446-gram, 1447-gram, 1448-gram, 1449-gram, 1450-gram, 1451-gram, 1452-gram, 1453-gram, 1454-gram, 1455-gram, 1456-gram, 1457-gram, 1458-gram, 1459-gram, 1460-gram, 1461-gram, 1462-gram, 1463-gram, 1464-gram, 1465-gram, 1466-gram, 1467-gram, 1468-gram, 1469-gram, 1470-gram, 1471-gram, 1472-gram, 1473-gram, 1474-gram, 1475-gram, 1476-gram, 1477-gram, 1478-gram, 1479-gram, 1480-gram, 1481-gram, 1482-gram, 1483-gram, 1484-gram, 1485-gram, 1486-gram, 1487-gram, 1488-gram, 1489-gram, 1490-gram, 1491-gram, 1492-gram, 1493-gram, 1494-gram, 1495-gram, 1496-gram, 1497-gram, 1498-gram, 1499-gram, 1500-gram, 1501-gram, 1502-gram, 1503-gram, 1504-gram, 1505-gram, 1506-gram, 1507-gram, 1508-gram, 1509-gram, 1510-gram, 1511-gram, 1512-gram, 1513-gram, 1514-gram, 1515-gram, 1516-gram, 1517-gram, 1518-gram, 1519-gram, 1520-gram, 1521-gram, 1522-gram, 1523-gram, 1524-gram, 1525-gram, 1526-gram, 1527-gram, 1528-gram, 1529-gram, 1530-gram, 1531-gram, 1532-gram, 1533-gram, 1534-gram, 1535-gram, 1536-gram, 1537-gram, 1538-gram, 1539-gram, 1540-gram, 1541-gram, 1542-gram, 1543-gram, 1544-gram, 1545-gram, 1546-gram, 1547-gram, 1548-gram, 1549-gram, 1550-gram, 1551-gram, 1552-gram, 1553-gram, 1554-gram, 1555-gram, 1556-gram, 1557-gram, 1558-gram, 1559-gram, 1560-gram, 1561-gram, 1562-gram, 1563-gram, 1564-gram, 1565-gram, 1566-gram, 1567-gram, 1568-gram, 1569-gram, 1570-gram, 1571-gram, 1572-gram, 1573-gram, 1574-gram, 1575-gram, 1576-gram, 1577-gram, 1578-gram, 1579-gram, 1580-gram, 1581-gram, 1582-gram, 1583-gram, 1584-gram, 1585-gram, 1586-gram, 1587-gram, 1588-gram, 1589-gram, 1590-gram, 1591-gram, 1592-gram, 1593-gram, 1594-gram, 1595-gram, 1596-gram, 1597-gram, 1598-gram, 1599-gram, 1600-gram, 1601-gram, 1602-gram, 1603-gram, 1604-gram, 1605-gram, 1606-gram, 1607-gram, 1608-gram, 1609-gram, 1610-gram, 1611-gram, 1612-gram, 1613-gram, 1614-gram, 1615-gram, 1616-gram, 1617-gram, 1618-gram, 1619-gram, 1620-gram, 1621-gram, 1622-gram, 1623-gram, 1624-gram, 1625-gram, 1626-gram, 1627-gram, 1628-gram, 1629-gram, 1630-gram, 1631-gram, 1632-gram, 1633-gram, 1634-gram, 1635-gram, 1636-gram, 1637-gram, 1638-gram,		

Bayes algoritması, küçük veri setlerinde hızlı ve etkili sonuçlar verebilmesi nedeniyle tercih edilmiş; Multinomial Naive Bayes türü uygulanmıştır (Mignan, 2019). SVM ve Random Forest ise metinlerin daha karmaşık örüntülerini yakalamada başarılı bulunmuştur. SVM modeli, lineer çekirdek (kernel) ile çalıştırılmış; Random Forest modeli 100 karar ağacından oluşacak şekilde yapılandırılmıştır.

BERT modeli, Transformer tabanlı ön eğitimli dil temsilleri ile metin sınıflandırmada son yıllarda yüksek başarı sağlamaktadır (Devlin vd., 2019a). Bu çalışmada da, BERT modeli ile ön eğitimli dil temsilleri kullanılarak sınıflandırma başarısı artırılmaya çalışılmıştır (Wolf vd., 2020). Uygulama aşamasında, Hugging Face tarafından sunulan dbmdz/bert-base-turkish-uncased mimarisi tercih edilmiş ve Trainer arayüzü ile 3 epoch süresince eğitilmiştir.

Tüm modeller Python ortamında, scikit-learn ve transformers kütüphaneleriyle uygulanmıştır (Wolf vd., 2020). Model performansları karşılaştırılarak, veri setine en uygun yaklaşım belirlenmiştir. Nihai amaç, manuel olarak yapılan şikayet sınıflandırma süreçlerinin doğruluk, hız ve tutarlılık açısından yapay zekâ destekli sistemlerle karşılaştırılmasıdır (Koh, 2025).

3.3.5. Katlı Çapraz Doğrulama ile Model Eğitimi ve Değerlendirme

Bu çalışmada, otomatik metin sınıflandırma modellerinin performansını güvenilir ve genellenebilir biçimde değerlendirmek amacıyla k-Katlı Çapraz Doğrulama (k-Fold Cross-Validation) yöntemi uygulanmıştır. Kategoriler arası dengesizliği önlemek ve her bir sınıfın tüm katlarda orantılı olarak temsil edilmesini sağlamak için StratifiedKFold yaklaşımı tercih edilmiştir (Pedregosa vd., 2011).

Çapraz doğrulama süreci şu adımlarla yürütülmüştür:

- Çapraz doğrulama sürecinde veri si-

zintısını (data leakage) önlemek amacıyla, eğitim ve test setlerinin ayrıştırılması işleminde 'grup tabanlı' bir strateji izlenmiştir. Orijinal 119 kaydın her biri ve bu kayıtlardan GPT-4 ile türetilen sentetik varyasyonları, bir bütün olarak 'aynı grup' (cluster) kabul edilmiştir. Ayrıştırma işlemi yapılırken, bir orijinal kayıt ve onun türevleri, bütüncül olarak ya sadece eğitim setinde ya da sadece test setinde yer alacak şekilde dağıtılmıştır. Böylece modelin, eğitim aşamasında gördüğü bir cümlemin sentetik varyasyonunu test aşamasında görerek ezberden (memorization) puan alması engellenmiş, modelin genelleme başarısı daha gerçekçi bir zeminde test edilmiştir.

- Kat Sayısı: Standart uygulamalara uygun olarak $k=5$ belirlenmiş; veri seti, her döngüde farklı bir bölümün test seti olduğu 5 eşit parçaya ayrılmıştır.
- Eğitim ve Test Süreci: Her katmanda (~%80 eğitim, ~%20 test) tüm modeller (Multinomial Naive Bayes, Linear SVM (LinearSVC), Random Forest, BERT) ilgili eğitim verisiyle eğitilmiş ve kalan test verisi üzerinde değerlendirilmiştir.
- Performans Ölçütleri: Her kat sonunda Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall) ve F1 Skoru hesaplanmış; beş katın ortalama değerleri ile standart sapmaları raporlanmıştır.

Metinler, TF-IDF (1-2-gram, max_features=8000, min_df=2) yöntemiyle vektörleştirilmiş ve yukarıda belirtilen modeller bu temsiller üzerinden eğitilmiştir.

Elde edilen sonuçlara göre LinearSVC, tüm modeller arasında en yüksek performansı göstermiştir (Accuracy=0.867, F1=0.868 (weighted)). Kategori bazlı analizde LinearSVC, özellikle iletişim/erişim (F1≈0.944) ve

finans (F1≈0.892) sınıflarında güçlü sonuçlar üretirken, öğrenci işleri (F1≈0.800) ve tez (F1≈0.850) kategorilerinde görece daha düşük ancak hâlâ rekabetçi performans sergilemiştir.

Bu bulgular, TF-IDF + SVM hattının küçük ve orta ölçekli Türkçe şikâyet verilerinde güçlü bir taban (baseline) oluşturduğunu ortaya koymaktadır. Kullanılan çapraz doğrulama yaklaşımı, sınırlı veri setlerinde aşırı öğrenme (overfitting) riskini azaltmakta ve farklı modellerin hem başarı hem de tutarlılık açısından daha sağlıklı biçimde karşılaştırılmasına imkân vermektedir (Kohavi, 2001; Pedregosa vd., 2011).

Not: Sonuç farklarının temel nedenleri arasında Excel sürümünde yapılan etiket sadeleştirilmesi, metin temizleme aşamalarındaki farklılıklar ve 5 katmanlı veri bölünmesinin etkileri yer almaktadır (random_state=42 sabitlenmiştir).

3.4. Ölçütler ve Değerlendirme Kriterleri

Bu çalışmada hem manuel hem de otomatik sınıflandırma yöntemlerinin başarısını değerlendirmek amacıyla bir dizi nicel performans metriği kullanılmıştır. Modellerin doğruluğu ve etkinliği; doğruluk oranı (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru gibi yaygın sınıflandırma ölçütleriyle analiz edilmiştir. Örneğin Conciatori (2024), bu dört temel metriği kullanarak yöntemlerin etkinliğini ayrıntılı olarak değerlendirmektedir. Benzer şekilde, Kepler verileri üzerinde çalışan bir başka araştırma da bu ölçütleri algoritmalar arası karşılaştırmalar için kullanmıştır (Hesar & Foing, 2024). Bu sayede hem genel başarı seviyesi hem de yanlış pozitif/negatif oranları objektif olarak değerlendirilmiştir. Bu metrikler aşağıdaki formüllerle hesaplanmıştır:

- Accuracy = Doğru Tahmin Sayısı / Toplam Tahmin Sayısı

- Precision = TP / (TP + FP)
- Recall = TP / (TP + FN)
- F1-score = 2 * (Precision * Recall) / (Precision + Recall)

(Burada, TP: Doğru Pozitif, FP: Yanlış Pozitif, FN: Yanlış Negatif anlamına gelmektedir.)

Bunlara ek olarak, işlem süresi ve otomasyonun yanıt hızı gibi operasyonel ölçütler de dikkate alınmıştır. Otomatik sistemlerin manuel yöntemlere kıyasla hız ve tutarlılık açısından avantajları; işlem süresi, toplam iş yükü ve manuel müdahale ihtiyacı gibi göstergelerle analiz edilmiştir (Goswami vd., 2024). Ayrıca, her modelin hata ve tutarlılık oranları da raporlanmıştır.

Manuel sınıflandırma sürecinde ise, üniversite çözüm merkezinin yaptığı orijinal kategori atamaları ile araştırmacı ekip tarafından bağımsız olarak gerçekleştirilen yeniden kodlama sonuçları karşılaştırılmıştır. Her kayıt için iki farklı insan kodlayıcının sınıflandırmaları üzerinden aynı performans metrikleri hesaplanmıştır. İnsan temelli sınıflandırmanın iç tutarlılığı ve güvenilirliği, Cohen's Kappa katsayısı ile ölçülmüş ve 0.83'lük Kappa değeri elde edilmiştir (Cohen, 1960; Bilgin, 2014). Bu değer, Landis ve Koch (1977) sınıflamasına göre "mükemmel uyum" düzeyindedir.

Tüm bu ölçütler sayesinde hem manuel hem de otomatik sınıflandırma yöntemlerinin doğruluk, hız ve güvenilirlik bakımından karşılaştırılması sağlanmıştır. Elde edilen sayısal bulgular tablo ve grafiklerle sunulmuş; böylece teknik başarı (doğruluk ve tutarlılık) ile operasyonel verimlilik (işlem süresi ve insan kaynağı gereksinimi) nesnel olarak ortaya konmuştur (D. Kumar & Ratten, 2025).

3.5. Sınırlılıkları

Bu çalışmanın bazı teknik ve metodolojik sınırlılıkları bulunmaktadır. Analiz edilen veri seti, yalnızca bir üniversitenin belirli bir döneme ait şikâyet kayıtları ile sınırlı oldu-

ğundan, sonuçların genellenebilirliği sınırlıdır(Creswell & Creswell, 2023; Pabel & Shah, 2025). Ayrıca Otomatik sınıflandırma algoritmalarının başarısı, veri setinin büyüklüğü ve dengesine doğrudan bağlıdır; küçük ve dengesiz veri kümelerinde model doğruluğu azalabilir(Liao vd., 2020; Sunar & Khalid, 2024). BERT gibi derin öğrenme tabanlı modeller, ön eğitilmiş dil temsillerine dayanmakta olup, özellikle kısa, özgün veya kurum içi dile sahip metinlerde sınırlı performans gösterebilmektedir.(Devlin vd., 2019a. Bunun yanında metin ön işleme sırasında uygulanan filtreleme işlemleri, kimi bağlamsal ve anlamsal bilgilerin kaybına yol açabilir(Uysal & Gunal, 2012). Son olarak, manuel sınıflandırma sürecinde insan faktörüne dayalı öznellik ve kodlayıcılar arası tutarsızlık tamamen ortadan kaldıramamıştır (Bilgin, 2014; Saldana, 2019).

Bu çalışmanın bulguları umut verici olmakla birlikte çeşitli uygulama sınırlılıkları vardır. Öncelikle, analizlerin yalnızca bir üniversiteden elde edilen veri setiyle sınırlı olması, sonuçların genellenebilirliğini kısıtlamaktadır. Farklı kurumlarda öğrenci profili ve şikâyet çeşitliliği değişebileceğinden, modelin başarısı farklı örneklerde farklılık gösterebilir. Ayrıca, sınırlı şikâyet türleri ve kayıt sayısı, modelin tüm potansiyel kategorilerde yüksek performans göstermesini engellemektedir.

Bu çalışmanın metodolojik bir sınırlılığı, analiz edilen orijinal 119 şikâyet kaydına ve çoğaltma (data augmentation) için kullanılan spesifik komut dosyalarına, veri saklama politikalarından kaynaklanan nedenlerle tam erişimin sağlanamamış olmasıdır. Bu durum, çalışmanın tam tekrarlanabilirliğini (reproducibility) kısıtlamakla birlikte, makalede raporlanan tüm istatistiksel metrikler 781 kayıtlık nihai veri seti üzerinden Stratified 5-Katlı Çapraz Doğrulama yöntemleri kullanılarak titizlikle üretilmiştir.

Modelin başarısı büyük ölçüde veri kalitesi ve etiketleme sürecine bağlıdır. Etiketleme hataları veya önyargılar performansı olumsuz

etkileyebilir; bu nedenle verilerin güncellenmesi ve bağımsız uzmanlarca etiketlenmesi önerilmektedir. Çoklu etiketli veri setlerinde dengesizlik ve bağlamsal karmaşıklık da model doğruluğunu düşürebilmektedir(Giang vd., 2020; Kumawat vd., 2025). Son olarak, yapay zekâ tabanlı otomasyonun etik ve veri gizliliği açısından sürekli değerlendirilmesi gerekmektedir (Y. Chen & Prentice, 2025; Goswami vd., 2024).

Bu araştırma, tek bir üniversitenin verileriyle sınırlı olması ve yapay veri artırma yöntemine dayanması nedeniyle bir 'Kavram Kanıtı' (Proof of Concept) niteliği taşımaktadır. Elde edilen yüksek başarı oranları, geniş ölçekli uygulamalar için umut verici olsa da, sonuçların farklı kurumsal kültürlerle ve daha büyük, doğal (organik) veri setlerine genellenebilirliği için ek çalışmalara ihtiyaç vardır.

4. BULGULAR

Bu bölümde, üniversite öğrencilerinden toplanan 119 şikâyet kaydının farklı sınıflandırma yöntemleriyle analizinden elde edilen bulgular sunulmaktadır. Bulgular, hem manuel hem de yapay zekâ tabanlı otomatik sınıflandırma yaklaşımlarının süreç ve performans ölçütleri açısından karşılaştırılması temelinde yapılandırılmıştır. Analiz kapsamında, çözüm merkezi tarafından yapılan orijinal kategori atamaları, iki bağımsız araştırmacı tarafından yürütülen manuel sınıflandırma ve otomatik sınıflandırma modellerinin sonuçları, doğruluk, kesinlik, duyarlılık, F1 skoru, işlem süresi ve tutarlılık gibi çeşitli kriterler üzerinden değerlendirilmiştir. Elde edilen bulgular, hem şikâyetlerin içeriksel dağılımını hem de uygulanan yöntemlerin güçlü ve sınırlı yönlerini karşılaştırmalı olarak ortaya koymaktadır.

4.1. Manuel Sınıflandırma Sonuçları

İki bağımsız araştırmacı tarafından gerçekleştirilen ve çalışmada referans ("altın standart") olarak kabul edilen manuel sınıflandırmada toplam 119 şikâyet kaydı analiz edilmiştir.

Kayıtların %68,1'i tek bir kategoriye, %31,9'u ise birden fazla kategoriye atanmıştır. Bu durum, şikâyetlerin yaklaşık üçte birinin birden fazla konuyu kapsadığını ve üniversite ortamındaki sorunların çoğu zaman çok boyutlu olduğunu göstermektedir.

Araştırma kapsamında şikâyetler altı ana kategoriye ayrılmıştır: Akademik Sorunlar, Finans ve Ödeme Sorunları, İletişim ve Erişim Sorunları, Öğrenci İşleri Sorunları, Teknik Sorunlar ve Tez ve Danışmanlık Sorunları. En yaygın kategori, Öğrenci İşleri Sorunları olup bu durum, idari süreçlerde yaşanan aksaklıkların öğrenciler açısından en önemli sorun alanı olduğunu göstermektedir. Bunu, Tez ve Danışmanlık Sorunları ile Teknik Sorunlar takip etmektedir. Akademik Sorunlar, İletişim ve Erişim Sorunları ile Finans ve Ödeme Sorunları ise görece daha düşük oranda temsil edilmiştir.

Çoklu kategoriye sahip kayıtlar incelendiğinde, en yaygın kombinasyonların "Akademik Sorunlar & Teknik Sorunlar" ile "Akademik Sorunlar & Öğrenci İşleri" olduğu görülmektedir. Bu kombinasyonlar, şikâyetlerin çoğu zaman birden fazla birim veya süreçle ilişkili olduğunu ve sınıflandırma sistemlerinin bağlamsal karmaşıklıkları anlaması gerektiğini ortaya koymaktadır.

Tablo 3. Kategori Dağılımları

Kategori	Araştırmacı		Çözüm Merkezi	
	Kayıt	Yüzde	Kayıt	Yüzde
	Sayısı	(%)	Sayısı	(%)
Akademik Sorunlar	13	10.9	20	16.8
Finans ve Ödeme Sorunları	8	6.7	5	4.2
İletişim ve Erişim Sorunları	9	7.6	-	-
Öğrenci İşleri Sorunları	42	35.3	75	63.0
Teknik Sorunlar	23	19.3	4	3.4
Tez ve Danışmanlık Sorunları	24	20.2	15	12.6
Toplam	119	100	119	

Manuel sınıflandırma sonucunda şikâyetler en çok "Öğrenci İşleri Sorunları" (%35.3), "Tez ve Danışmanlık Sorunları" (%20.2) ve "Teknik Sorunlar" (%19.3) kategorilerinde yoğunlaşmıştır. "Akademik Sorunlar" (%10.9), "İletişim ve Erişim Sorunları" (%7.6) ve "Finans ve Ödeme Sorunları" (%6.7) ise daha az orandadır.

Çözüm merkezi sınıflandırmasında ise "Öğrenci İşleri Sorunları" kategorisi çok daha yüksek bir oranda (%63) temsil edilmiş, diğer kategorilerin oranları ise genel olarak daha düşük kalmıştır. Özellikle "Teknik Sorunlar" (%3.4) ve "Finans ve Ödeme Sorunları" (%4.2) kategorilerinde belirgin azalma gözlenmektedir. Bu durum, çözüm merkezinin şikâyetleri daha genel ve kapsayıcı kategoriler altında toplama eğiliminde olduğunu göstermektedir.

Tablo 4. Çözüm Merkezinin Genel Performans Sonuçları

Model	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1
Çözüm Merkezi	0.46	0.45	0.38	

Araştırmada, çözüm merkezi tarafından yapılan şikâyet sınıflandırmalarının referans (altın standart) olarak kabul edilen araştırmacı sınıflandırmalarıyla örtüşme düzeyi genel başarı metrikleri üzerinden değerlendirilmiştir. Analiz sonuçlarına göre, çözüm merkezi atamalarının genel doğruluk oranı %46; kesinlik (precision) ve duyarlılık (recall) değerleri ise 0,45, F1 skoru ise 0,37 olarak hesaplanmıştır.

4.2. Otomatik Sınıflandırma ve Karşılaştırmalı Performans Bulguları

Araştırmada, öğrenci şikâyet metnlerinin otomatik sınıflandırılmasına yönelik dört farklı modelin çıktıları analiz edilmiştir: Naive Bayes, Destek Vektör Makineleri (SVM), Random Forest ve BERT. Bu modeller, eğitim

ve test veri kümeleri üzerinde değerlendirilmiş; elde edilen sınıflandırma sonuçları doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru temelinde karşılaştırılmıştır. Ayrıca, kategorilere ilişkin içerik analizleri model çıktılarının yorumlanmasında referans olarak kullanılmış; sınıflandırma başarılarının bağlamla ne ölçüde örtüştüğü detaylı biçimde incelenmiştir. Bu bölümde, dört farklı sınıflandırma modelinin (Naive Bayes, SVM, Random Forest ve BERT) öğrenci şikayetlerini otomatik olarak kategoriye atama performansları karşılaştırmalı olarak sunulmaktadır. Modellerin değerlendirilmesinde doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru temel performans ölçütü olarak kullanılmıştır. Modeller arası performans farklarının istatistiksel geçerliliğini test etmek amacıyla, 5-katlı çapraz doğrulama sonucu elde edilen F1 skorları üzerinden Tek Yönlü Varyans Analizi (ANOVA) uygulanmıştır. Analiz sonucunda, en başarılı model olan LinearSVC (F1≈0.87)'nin ortalama performansının, Random Forest (F1≈0.77) ve BERT (F1≈0.73) gibi diğer modellere kıyasla istatistiksel olarak $p<0.05$ düzeyinde anlamlı ölçüde üstün olduğu tespit edilmiştir. Bu bulgu, LinearSVC'nin en yüksek performansı göstermesinin güçlü bir bilimsel dayanağı olduğunu kanıtlamaktadır.

Aşağıdaki tablo, her bir modelin test verisi üzerindeki genel başarı metriklerini özetlemektedir:

Tablo 5. Otomatik Sınıflandırma Modellerinin Genel Performans Sonuçları				
Model	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F 1 Skoru
SVM (LinearSVC)	0.87	0.87	0.87	0.87
Naive Bayes	0.81	0.84	0.81	0.81
Random Forest	0.77	0.78	0.77	0.77
BERT	0.73	0.76	0.73	0.73

Tablo 5'de görüldüğü üzere, LinearSVC modeli tüm ölçütlerde en yüksek performansı göstererek çalışmanın en başarılı sınıflandırıcısı olmuştur (Doğruluk=0.867, F1=0.868). LinearSVC'nin özellikle sık görülen kategorilerde yüksek kesinlik ve duyarlılık değerleri ürettiği, nadir görülen sınıflarda ise performansın görece düştüğü gözlemlenmiştir. Naive Bayes, doğruluk (0.811) ve F1 skoru (0.813) bakımından tatmin edici bir başarı sergilemiş; basit yapısı ve düşük hesaplama maliyeti sayesinde küçük veri setlerinde hızlı bir alternatif olarak öne çıkmıştır ancak karmaşık örüntüleri yakalamada sınırlı kalmıştır. Random Forest modeli, doğruluk (0.772) ve F1 skoru (0.773) ile orta seviyede bir performans göstermiş; özellikle sık karşılaşılan sınıflarda güçlü sonuçlar elde ederken az temsil edilen kategorilerde başarısı azalmıştır. BERT modeli ise bağlam bağımlı dil temsilleri üretme yeteneğine rağmen bu çalışmada diğer modellere kıyasla daha düşük bir genel performans sergilemiştir (Doğruluk=0.727, F1=0.725), ancak çoklu kategoriye sahip ve yapısal olarak belirsiz bazı şikâyetlerde doğru sınıflandırma yapabilmesi, bağlamsal anlam yakalama gücünü ortaya koymuştur. BERT modeli, sınırlı veri seti ve eğitim koşulları nedeniyle diğer klasik modellere kıyasla beklenen performansı gösterememiştir; bu, sınırlılıklar bölümünde detaylandırılmıştır.

4.3. Operasyonel Kazanımlar ve Karşılaştırmalı Performans Analizi

Bu çalışmada kullanılan otomatik sınıflandırma sistemleri yalnızca doğruluk açısından değil, zaman yönetimi, işlem süresi ve toplam iş gücü gibi operasyonel göstergeler bakımından da önemli kazanımlar sağlamıştır. Aşağıda, çözüm merkezi ve otomatik sınıflandırma yöntemlerinin doğruluk, hız ve güvenilirlik gibi temel performans ölçütleri üzerinden karşılaştırmalı sonuçları özetlenmiştir.

Tablo 6. Çözüm Merkezi ve Otomatik Sınıflandırma Yöntemlerinin Karşılaştırmalı Performans Sonuçları

Performans	Çözüm Merkezi	SVM
Ölçütü	Sınıflandırma	(LinearSVC)
Doğruluk Oranı (%)	46	87
Kesinlik (Precision)	46	87
Duyarlılık (Recall)	38	87
F1 Skoru	37	87

Tablo 6’da görüldüğü üzere, otomatik sınıflandırma yöntemi (SVM – LinearSVC) doğruluk, kesinlik, duyarlılık ve F1 skoru bakımından çözüm merkezi tarafından yapılan sınıflandırmaya kıyasla belirgin şekilde üstün performans göstermiştir. Özellikle doğruluk oranının %87’ye ulaşması, otomatik sistemin şikâyet kayıtlarını daha tutarlı ve güvenilir şekilde kategorize ettiğini ortaya koymaktadır. Ayrıca, kesinlik ve duyarlılık değerlerinin yüksek olması, modelin hem yanlış pozitif hem de yanlış negatif oranlarını azaltarak daha dengeli bir sınıflandırma sağladığını göstermektedir. Çözüm merkezi sınıflandırmasında ise tüm metriklerin düşük seviyede kalması, mevcut manuel süreçlerde önemli tutarsızlıklar, yorum farklılıkları ve genelleştirme eğilimi olduğunu işaret etmektedir.

Tablo 7. Manuel ve Otomatik Sınıflandırma Yöntemlerinin Karşılaştırmalı Performans Sonuçları

Performans Ölçütü	Araştırmacı	LinearSVC
Ortalama İşlem Süresi (saniye)	120	0.000049
Toplam İş Yüğü (saat)	4	0.000011
Hata / Tutarsızlık Oranı (%)	15	13.32
Cohen’s Kappa	0,83	0,84

Tablo 7’de görüldüğü gibi, LinearSVC tabanlı otomatik sınıflandırma, manuel yaklaşıma kıyasla yalnızca hız açısından değil, aynı zamanda tutarlılık açısından da belirgin avantajlar sağlamaktadır. Tek bir geçişte tüm veri üzerinde ortalama 0.000041 sn/kayıt

ve toplam 0.000009 saat işlem süresi elde edilmesi, sistemin yüksek ölçeklenebilirlik potansiyelini ortaya koymaktadır. Buna karşın manuel süreçte ortalama 120 sn/kayıt ve toplam 4 saat iş yükü, zaman maliyetinin ve insan kaynağına bağımlılığın oldukça yüksek olduğunu göstermektedir. Hata/tutarsızlık oranı incelendiğinde, otomatik sınıflandırmanın manuel sürece kıyasla daha düşük bir orana (%13.32) sahip olduğu görülmektedir. Sınıf bazlı analizler, otomatik sistemin özellikle “iletişim/erişim” kategorisinde oldukça yüksek bir uzlaşım sağladığını (%4.88 hata), ancak “tez” (%16.43) ve “akademik sorunlar” (%15.57) kategorilerinde görece daha yüksek hata oranları ürettiğini göstermektedir. Bu durum, belirli kategorilerin dilsel çeşitliliği ve bağlamsal karmaşıklığı nedeniyle modelin ayırt etme gücünü yaşadığını işaret etmektedir.

4.4 Cohen’s Kappa Karşılaştırması

Manuel sınıflandırma sürecinde, iki bağımsız değerlendiricinin aynı şikâyet metinleri üzerinde yaptığı kategori atamaları karşılaştırılarak Cohen’s Kappa katsayısı $\kappa = 0.830$ olarak hesaplanmıştır. Bu değer, manuel etiketlemenin yüksek düzeyde güvenilir olduğunu göstermektedir. LinearSVC tabanlı otomatik sınıflandırma sonuçları, altın standart insan etiketleriyle karşılaştırıldığında $\kappa = 0.840$ olarak ölçülmüştür. Bu bulgu, modelin yalnızca doğruluk açısından değil, insan-insan tutarlılığına yakın düzeyde güvenilir sınıflandırma yapabildiğini ortaya koymaktadır.

5. TARTIŞMA

Çalışmada, şikâyetlerin ağırlıklı olarak idari süreçler, tez/danışmanlık ilişkileri ve teknik altyapı gibi alanlarda yoğunlaştığı belirlenmiştir. Bu durum, öğrencilerin yalnızca akademik içeriklere değil, süreç ve hizmet kalitesiyle ilgili beklenti ve memnuniyetsizliklerini de dile getirdiklerini göstermektedir. Model performansının incelenmesinde en başarılı

sınıflandırıcı olan LinearSVC'nin hata kaynakları, modelin Confusion Matrix görseli ile desteklenerek analiz edilmiştir. Bulgular, modelin toplam hata oranının %13.32 olduğunu göstermekle birlikte, bu hataların homojen dağılmadığını kanıtlamaktadır. Modelin en belirgin karışıklığı, Öğrenci İşleri Sorunları ($F1 \approx 0.800$) ve Tez ve Danışmanlık Sorunları ($F1 \approx 0.850$) kategorileri arasında yoğunlaşmıştır. Bu durum, öğrenci şikayetlerinde bu iki idari sürecin dilsel ve bağlamsal olarak yüksek düzeyde örtüşmesinden kaynaklanmakta ve bu alandaki hizmet sınırlarının yönetsel olarak da belirsiz olabileceğine işaret etmektedir. Bu derinlemesine hata analizi, otomatik sistemlerin kurumsal süreç belirsizliklerini tespit etmede kullanılabileceğini göstermektedir.

Ayrıca, çoklu kategoriye ait şikâyetlerin varlığı, sınıflandırma sistemlerinde gelişmiş bağlamsal analiz yeteneklerinin gerekliliğini ortaya koymaktadır. Literatürde de belirtildiği üzere (Giang vd., 2020; Kumawat vd., 2025), çoklu kategori yapısına sahip metinler klasik yöntemler için zorluk oluştururken, bağlam temelli modeller bu yapıları daha etkin analiz edebilmektedir.

Üniversitedeki sorunların çok boyutlu ve karmaşık yapıda olması, otomatik sınıflandırma sistemlerinin gelişmiş bağlamsal analiz becerilerine ihtiyaç duyduğunu doğrulamaktadır (Giang vd., 2020; Kumawat vd., 2025). Gelişmiş yapay zekâ modellerinin bu karmaşık yapıları başarıyla işleyerek operasyonel verimliliği artırdığı literatürle de desteklenmektedir (X. Li vd., 2025).

Öte yandan, "Akademik Sorunlar & Teknik Sorunlar" ve "Akademik Sorunlar & İdari Sorun" kombinasyonlarındaki yoğunluk, öğrenci şikayetlerinin çoklu birimler veya süreçlerle ilişkili olduğunu göstermekte; bu da sınıflandırma algoritmalarının bağlamsal karmaşıklıkları anlaması gerekliliğini ortaya koymaktadır. Veri dengesizliği nedeniyle nadir görülen kombinasyonlarda model başarısının düştüğü literatürde belirtilmiş olup, bu ça-

lışma da bu durumu teyit etmektedir (Gronberg vd., 2021; Kumawat vd., 2025). Çözüm merkezinin sınıflandırmasında ise şikâyetlerin çoğunlukla "İdari Sorunlar" başlığında toplanması, bu süreçlerin genel ve kapsayıcı bir çerçevede ele alındığını göstermektedir. Bu yaklaşımın, ayrıntılı analiz ve müdahale olanaklarını kısıtladığı literatürde vurgulanmakta, bu nedenle daha özgül ve ayrıntılı sınıflandırmanın, yapay zekâ destekli otomatik sistemlerle sağlanmasının önemine işaret edilmektedir (Görmüş vd., 2013).

Çalışmada, şikayetlerin büyük çoğunluğunun "Akademik Sorunlar" kategorisinde toplanması, üniversite öğrencilerinin eğitim-öğretim süreçlerine dair beklenti ve memnuniyetlerini yoğun şekilde ifade ettiğini göstermektedir. Bu durum, yükseköğretimde kalite yönetimi ve sürekli iyileştirme süreçlerinde öğrenci geri bildirimlerinin kritik bir rol oynadığını ortaya koymaktadır (Pabel & Shah, 2025). Literatürde de, akademik alanlara odaklanan öğrenci geri bildirimlerinin stratejik karar alma ve iyileştirme uygulamaları için temel veri sağladığı vurgulanmaktadır (Giang vd., 2020; X. Li vd., 2025). Yapay zekâ tabanlı otomatik sınıflandırma modellerinin, özellikle akademik sorunlar gibi yüksek hacimli ve karmaşık veri gruplarında yüksek doğrulukla çalışması önemli bir avantajdır (Davenport vd., 2020). Bu sayede, akademik şikayetlerin hızlı ve doğru sınıflandırılması, üniversite yönetimlerinin daha proaktif politikalar geliştirmesine ve öğrenci memnuniyetinin sürdürülebilirliğine katkı sağlamaktadır (Essel vd., 2025; R. R. Hassan vd., 2024). Yapay zekâ tabanlı otomatik sınıflandırma yöntemleri, özellikle BERT gibi bağlamsal dil modelleri, bu karmaşık ve çok boyutlu verileri yüksek doğruluk ve güvenilirlikle analiz etmektedir (Asudani vd., 2023; Graff vd., 2025; Kavitha & Prabhavathy, 2021). Çalışmada kullanılan BERT modeli, sınırlı veri seti ve eğitim süreleri nedeniyle beklenen üstün performansı gösterememiştir. Bu durum, büyük veri ve kapsamlı ön eğitim gerektiren derin öğren-

me modellerinin küçük veri ortamlarındaki sınırlılığını yansıtmaktadır. Benzer şekilde, Dodge vd. (2020), Devlin vd. (2019b) ve Lee vd.(2020) tarafından yapılan çalışmalarda da BERT gibi transformer tabanlı modellerin küçük ve dengesiz veri setlerinde performanslarının düştüğü, hiperparametre optimizasyonunun ve yeterli eğitim süresinin kritik önemde olduğu vurgulanmıştır. Bu bulgular, derin öğrenme modellerinin uygulama alanı ve veri yapısına bağlı olarak sınırlamalarının olduğunu ve bu modellerin küçük ölçekli veri ortamlarında klasik yöntemlerle rekabet edemeyebileceğini göstermektedir.

LinearSVC (SVM) modelinin üstün performansının temelinde, kullanılan TF-IDF özellik çıkarım yönteminin etkinliği yer almaktadır. Öğrenci şikayetlerinde 'kayıt', 'harç', 'danışman' gibi anahtar kelimeler, şikayet kategorilerini ayırt etmede belirleyici olmaktadır. TF-IDF bu anahtar kelimelerin önemini başarılı şekilde yansıtarak, metinleri yüksek boyutlu ve seyrek vektör uzayında temsil eder. SVM ise bu tür verilerde güçlü sınıflandırma performansı sergileyerek, sınırlı veri koşullarında karmaşık derin öğrenme modellerinden daha etkili sonuçlar vermiştir (Joachims, 1998).

Otomatik sınıflandırma sistemlerinin yalnızca doğrulukta değil, işlem hızı ve operasyonel verimlilikte de manuel süreçlere kıyasla üstünlük sağladığı görülmektedir. Yapay zekâ destekli sistemler, çok daha kısa sürede ve hata oranları azalarak kayıtların işlenmesini mümkün kılmakta, böylece şikayetlerin hızlı ve güvenilir biçimde yönetilmesine imkan tanımaktadır (Kumawat vd., 2025). Literatürde dijitalleşmenin süreç hızını artırması ve insan hatalarını azaltması yükseköğretimde otomasyonun gerekliliğini desteklemektedir (Giang vd., 2020; Gronberg vd., 2021)artificial intelligence (AI. Bu gelişmeler, öğrenci memnuniyetini artırırken, kurumsal verimliliğe de önemli katkılar sağlamaktadır (Jeilani & Abubakar, 2025; Ocen vd., 2025).

Manuel süreçlerde sıkça yaşanan insan kaynaklı hata ve tutarsızlıkların aksine, yapay zekâ destekli otomatik sistemler daha hızlı, doğru ve tutarlı sonuçlar sunmaktadır. Otomasyon, şikayetlerin başvuru anından çözüm aşamasına kadar geçen süreyi kısaltırken, personelin iş yükünü de önemli ölçüde azaltmaktadır (Acayıp, 2024; Görmüş vd., 2013). Literatürde otomasyonun çalışanların zamanını daha stratejik görevlere yönlendirmesine, süreçlerin izlenebilirlik ve standardizasyonunun artmasına imkan tanıdığı belirtilmektedir (Gronberg vd., 2021; R. R. Hassan vd., 2024; Nicolescu & Tudorache, 2022; Pabel & Shah, 2025)2022; Pabel & Shah, 2025. Operasyonel karşılaştırmada YZ tabanlı sistemin saniyelik işlem hızları (0.000049 sn) öne çıkarılmış olsa da, bu teknolojinin bir 'kurulum maliyeti' (setup cost) olduğu göz ardı edilmemelidir. Modelin eğitimi, hiperparametre optimizasyonu ve GPU tabanlı donanım gereksinimleri, başlangıçta bir zaman ve kaynak yatırımı gerektirir. Ancak sistem bir kez kurulup eğitildikten sonra, marjinal işlem maliyeti neredeyse sıfıra inmektedir. Manuel yöntemde ise her yeni şikâyet, personel için sabit ve indirgenemez bir zaman maliyeti (ortalama 120 sn) yaratmaya devam etmektedir. Dolayısıyla YZ yatırımı, orta ve uzun vadede kümülatif iş yükünü azaltarak başlangıç maliyetini amorti etmektedir. Bu sonuçlar, üniversite ortamında otomasyonun teknik yenilik olmanın ötesinde, operasyonel verimlilik ve kurumsal gelişim için güçlü bir araç olduğunu ortaya koymaktadır.

Bu çalışmada BERT modelinin, TF-IDF + SVM gibi daha basit bir mimarinin gerisinde kalması ($F1 \approx 0.73$), literatürdeki genel beklentinin aksine bir durum gibi görünse de, veri setinin yapısı ve boyutu ile açıklanabilir. BERT gibi milyonlarca parametreye sahip Transformer tabanlı modeller, başarılı bir ince ayar (fine-tuning) süreci için genellikle binlerce özgün örneğe ihtiyaç duyar. Bu çalışmada veri seti artırma (augmentation) ile

kayıt sayısı 781'e çıkarılmış olsa da, sentetik veriler kök aldıkları orijinal metinlerin anlamsal kalıplarını (semantic patterns) tekrar etme eğilimindedir. Bu durum, BERT modelinin yeterli dilsel çeşitliliği (lexical diversity) görememesine ve eğitim verisine aşırı uyum (overfitting) sağlarken test verisinde yetersiz kalmasına (underfitting) yol açmıştır.

Bu bulgular, mevcut literatürde yükseköğretimde otomatik sınıflandırma, dijitalleşme ve yapay zekâ uygulamalarının sağladığı avantajlara dair raporlanan sonuçlarla uyumludur (D. Kumar & Ratten, 2025). Özellikle çoklu etiketleme gerektiren, bağlamsal açıdan karmaşık ve heterojen öğrenci geri bildirimlerinin analizinde yapay zekâ tabanlı yaklaşımların manuel yöntemlere kıyasla hem hız hem de doğruluk açısından daha etkili olduğu önceki çalışmalarla da desteklenmektedir (Giang vd., 2020; X. Li vd., 2025)artificial intelligence (AI. Bununla birlikte, çalışmamız veri setinin tek bir üniversiteye ait olması nedeniyle genelleme gücü açısından sınırlılıklar taşımaktadır. Ayrıca, yükseköğretimde bu tür sistemlerin yaygınlaştırılmasında veri gizliliği, etik ilkeler ve kullanıcı güvenliği gibi unsurların da öncelikli olarak dikkate alınması gerekmektedir(Y. Chen & Prentice, 2025; Goswami vd., 2024; Nicolescu & Tudorache, 2022)2022.

Sonuç olarak, bu çalışmanın bulguları, metin sınıflandırma görevlerinde en karmaşık modelin her zaman en iyi performansı göstermediğini ortaya koymaktadır. Literatürde BERT ve benzeri transformer tabanlı modellerin üstünlüğü yaygın olarak kabul edilse de, elde edilen sonuçlar görev tanımı, veri setinin büyüklüğü ve alan özgünlüğü gibi faktörlerin model seçiminde daha belirleyici olduğunu göstermektedir. Özellikle yükseköğretim şikayet yönetimi gibi uygulamalarda, TF-IDF ve SVM gibi hesaplama maliyeti düşük, yorumlanması kolay ve bu çalışmada da etkili olduğu kanıtlanan klasik modellerin, ilk aşamada stratejik olarak tercih edilmesi önem taşımaktadır. Bu yaklaşım, hem doğruluk hem de

operasyonel verimlilik açısından sürdürülebilir ve uygulanabilir çözümler sunmaktadır.

Çalışmanın özgün katkılarından biri, yapay zekâ model çıktılarının bir Kök Neden Analizi (RCA) aracı olarak kullanılabilmesidir. Model performansının incelenmesinde en başarılı sınıflandırıcı olan LinearSVC'nin hata kaynakları, modelin Confusion Matrix görseli ile desteklenerek analiz edilmiştir. Bulgular, modelin toplam hata oranının %13.32olduğunu göstermekle birlikte, bu hataların homojen dağılmadığını kanıtlamaktadır. Modelin en belirgin karışıklığı, Öğrenci İşleri Sorunları (F1≈0.800) ve Tez ve Danışmanlık Sorunları (F1≈0.850) kategorileri arasında yoğunlaşmıştır. Bu durum, öğrenci şikayetlerinde bu iki idari sürecin dilsel ve bağlamsal olarak yüksek düzeyde örtüşmesinden kaynaklanmakta ve bu alandaki hizmet sınırlarının yönetsel olarak da belirsiz olduğuna dair kritik bir kurumsal geri bildirim sunmaktadır. Yapay zekâ tabanlı sistemler, bu tür süreçler arası örtüşme ve belirsizlikleri, insan gözünün kaçırabileceği bir kesinlikle tespit ederek, yönetim birimlerine doğrudan süreç iyileştirme için kök neden tespiti yapma imkanı sağlamaktadır.

SONUÇ

Bu çalışma, üniversite çözüm merkezine iletilen öğrenci şikayetlerinin yapay zekâ tabanlı otomatik sınıflandırma ve analiz yöntemleriyle işlenmesinin, şikâyet yönetimi süreçlerinde doğruluk, hız ve operasyonel verimlilik açısından önemli iyileştirmeler sağladığını göstermiştir. Özellikle, TF-IDF ile desteklenen SVM gibi klasik bir makine öğrenmesi modelinin, bu spesifik görevde BERT gibi karmaşık bir derin öğrenme modelinden daha başarılı sonuçlar vermesi, çalışmanın en dikkat çekici bulgusudur.

Bu bulgulara ek olarak, otomatik sistemlerin hata analizi (Kök Neden Analizi) çıktısı, üniversite yönetimi için kritik süreç belirsizliklerini ortaya koymuştur. Öğrenci İşleri Sorunla-

rı ve Tez/Danışmanlık Sorunları kategorileri arasındaki yüksek karışıklık, idari birimler arası yetki ve süreç tanımlarının netleştirilmesi gerektiğini göstermektedir. Bu, yapay zekâ tabanlı sınıflandırma sistemlerinin, sadece şikayetleri yönlendirmekle kalmayıp, kurumsal sürekli iyileştirme (continuous improvement) mekanizmalarını proaktif olarak tetikleyebileceğini kanıtlamaktadır

Yapay zekâ tabanlı sistemler, manuel süreçlere kıyasla daha hızlı, tutarlı ve izlenebilir yanıtlar üreterek şikâyet yönetiminde dijital dönüşümün değerini ortaya koymaktadır. Otomasyonun uygulanmasıyla iş yükü azalmakta, süreçlerin izlenebilirliği artmakta ve genel hizmet kalitesi yükselmektedir. Bu gelişmelerin dolaylı bir sonucu olarak, şikayetlere daha hızlı ve doğru çözümler sunulması, öğrencilerin üniversiteye olan güven ve bağlılığını güçlendirmekte; bu durum aynı zamanda yükseköğretim kurumlarının bilimsel ve kurumsal performansına da olumlu yansımaktadır.

Gelecekteki araştırmalar için ise birkaç önemli alan öne çıkmaktadır. Farklı üniversitelerden daha geniş ve çeşitli veri setleri üzerinde benzer sistemlerin test edilmesi, sonuçların genellenebilirliğini artıracaktır. Ayrıca, modellerin kullanıcı (öğrenci) deneyimi ve memnuniyeti üzerindeki etkilerinin niteliksel ve niceliksel yöntemlerle derinlemesine incelenmesi; sistemlerin sürekli öğrenen mekanizmalarla güncellenmesi; ve veri gizliliği ile etik ilkelere yönelik politika ve tekniklerin geliştirilmesi kritik önem taşımaktadır. Yapay zekâ sistemlerinin yalnızca sınıflandırma için değil, aynı zamanda çözüm önerileri üretme veya şikayetleri önem sırasına koyma gibi daha gelişmiş görevlerde kullanılması da değerli bir araştırma alanı olarak durmaktadır.

Bu çerçevede, yapay zekâ tabanlı şikâyet yönetimi uygulamalarının yükseköğretim kurumlarında yaygınlaştırılması; hem kurumsal verimlilik, hem öğrenci memnuniyeti hem de

yükseköğretim sistemine ve bilime katkı bakımından önemli fırsatlar sunmaktadır.

ÖNERİLER

Bu çalışmada elde edilen bulgular, üniversite yönetimlerinin şikâyet yönetimi süreçlerinde dijitalleşme ve yapay zekâ tabanlı otomasyon uygulamalarını stratejik olarak benimsemeleri gerektiğini ortaya koymaktadır. Özellikle, SVM tabanlı otomatik sınıflandırmanın manuel yöntemlere göre daha yüksek doğruluk ve tutarlılık sağladığı dikkate alındığında, bu teknolojilerin entegrasyonu üniversitelerde şikayetlerin hızlı, tutarlı ve etkin yönetimi için kritik öneme sahiptir. Bu dönüşüm yalnızca süreç verimliliğini artırmakla kalmayıp, öğrenci memnuniyetini ve genel hizmet kalitesini yükselterek kurumsal performansa da olumlu katkılar sunmaktadır (R. R. Hassan vd., 2024; D. Kumar & Ratten, 2025). Üniversite yönetimlerinin, şikâyet yönetiminde manuel süreçler yerine yapay zekâ destekli otomatik sınıflandırma ve analiz sistemlerini öncelikle uygulamaya alması önerilmektedir. Böylece, öğrenci şikayetlerinin hızlıca sınıflandırılması ve ilgili birimlere doğru yönlendirilmesi mümkün olacak, böylece çözüm süreçleri hızlanacaktır (Athira vd., 2025; Görmüş vd., 2013; X. Li vd., 2025; Öncü vd., 2024). Veri güvenliği ve etik ilkeler her aşamada titizlikle gözetilmelidir. Öğrenci verilerinin gizliliği sağlanmalı, ulusal ve uluslararası düzenlemelere (KVKK, GDPR) tam uyum sağlanmalı ve veri işleme süreçlerinde tam şeffaflık ile kullanıcı hakları korunmalıdır. Bu, kullanıcı güvenliğini artırmakta ve sistemin kabulünü kolaylaştırmaktadır (L. Chen vd., 2020; Goswami vd., 2024; Nicolescu & Tudorache, 2022). Personelin dijital araçlar ve etik standartlar konusunda düzenli olarak eğitilmesi, teknolojinin etkin ve doğru kullanımı için hayati önemdedir. Bu eğitimler, hem veri güvenliğini hem de sistem verimliliğini artıracak ve personelin adaptasyonunu hızlandıracaktır (Pabel & Shah, 2025)

Ayrıca, yapay zekâ destekli sistemlerin sürekli güncellenmesi ve öğrenci ile personel geri bildirimlerinin düzenli olarak değerlendirilmesi gerekmektedir. Teknolojik gelişmeler ve değişen ihtiyaçlar doğrultusunda sistemlerin iyileştirilmesi, sürdürülebilirlik ve etkinlik açısından kritik bir unsurdur (Talu & Tezci, 2025). Şikâyet yönetimi süreçlerinde farklı birimler arasında iş birliği ve bilgi paylaşımı artırılmalı, süreçler şeffaf bir biçimde raporlanmalı ve yöneticiler ile karar vericiler düzenli olarak bilgilendirilmelidir. Bu, hem süreçlerin kalitesini artıracak hem de kurumsal öğrenmeyi destekleyecektir (Bayır & Bozyiğit, 2023; Görmüş vd., 2013). Sonuç olarak, üniversite yönetimlerinin dijital dönüşüm stratejilerinde yapay zekâ tabanlı otomasyon sistemlerine yatırım yapması, sadece şikâyet yönetiminin değil, genel olarak öğrenci deneyimi ve kurumsal gelişimin güçlendirilmesine katkı sağlayacaktır. Bu çok boyutlu yaklaşım, öğrenci memnuniyetini artırmanın yanı sıra, üniversitelerin rekabet gücünü ve topluma olan katkısını da olumlu yönde etkileyecektir (Essel vd., 2025; R. R. Hassan vd., 2024). Bu bulgular ışığında, üniversite yönetimlerine yönelik en önemli stratejik öneri, yapay zekâ entegrasyonuna aşamalı ve maliyet-etkin bir yaklaşımla başlamalarıdır. Bu çalışmanın da gösterdiği gibi, şikâyet sınıflandırma gibi görevlerde TF-IDF ve SVM tabanlı sistemler hem yüksek doğruluk oranları sunmakta hem de hesaplama maliyetleri ve uygulama kolaylığı açısından önemli avantajlar sağlamaktadır. Pratik bir ilk adım olarak, kurumların bu tür klasik modellerle bir temel sistem kurmaları, hem hızlı bir verimlilik artışı sağlayacak hem de gelecekte BERT gibi daha karmaşık derin öğrenme modellerine geçiş için bir veri ve tecrübe altyapısı oluşturacaktır.

Yapay zekâ sisteminin hata analizi ile tespit edilen kritik idari süreç belirsizlikleri (Örn: Öğrenci İşleri ve Tez süreçleri arasındaki yetki örtüşmesi) öncelikli olarak ele alınmalıdır. Üniversite yönetiminin, bu süreçler arası sınırları netleştirerek ve entegrasyonu artırarak

şikâyetlerin kaynağını kurumsal düzeyde çözmesi önerilmektedir.

KAYNAKÇA

- Acayıp, E. (2024). Yapay zeka destekli chatbot hizmet kalitesinin müşteri memnuniyetine etkisi. *Current Perspectives in Social Sciences*, 28(4), 477–490. <https://doi.org/10.53487/atasobed.1438079>
- Agostini, L., & Nosella, A. (2021). Industry 4.0 and business models: A bibliometric literature review. *Business Process Management Journal*, 27(5), 1633–1655. <https://doi.org/10.1108/BPMJ-03-2021-0133>
- Akinyemi, A. L., Onibokun, T., Ejibenam, A., Onayemi, H. A., & Halliday, N. (2025). Strategies in handling customer complaints using AI optimisation models. *International Journal of Multidisciplinary Research and Growth Evaluation*, 6(3), 1021–1029. <https://doi.org/10.54660/IJMRGE.2025.6.3.1021-1029>
- Alyahya, M., Agag, G., Aliedan, M., & Abdelmoety, Z. H. (2023). Understanding the factors affecting consumers' behaviour when purchasing refurbished products: A chaordic perspective. *Journal of Retailing and Consumer Services*, 75, Makale 103492. <https://doi.org/10.1016/j.jretconser.2023.103492>
- Amasyalı, M. F., & Diri, B. (2006). Automatic Turkish text categorization in terms of author, genre and gender. C. Kop, G. Fliedl, H. C. Mayr, & E. Métais (Ed.), *Natural language processing and information systems* içinde (ss. 221–226). Springer. <https://doi.org/10.1007/11765448>
- Anakok, I., Woods, J., Huerta, M., Schoepf, J., Murzi, H., & Katz, A. (2022). Students' feedback about their experiences in EPICS using natural language processing. *2022 IEEE Frontiers in Education Conference (FIE)* içinde (ss.

- 1-9). IEEE. <https://doi.org/10.1109/fie56618.2022.9962557>
- Asudani, D. S., Nagwani, N. K., & Singh, P. (2023). Impact of word embedding models on text analytics in deep learning environment: A review. *Artificial Intelligence Review*, 56(9), 10345–10425. <https://doi.org/10.1007/s10462-023-10419-1>
- Athira, M. A., & Gupta, D. (2025). Effective complaint detection in financial services through complaint, severity, emotion and sentiment analysis. *Procedia Computer Science*, 258, 2220–2231. <https://doi.org/10.1016/j.procs.2025.04.472>
- Bayır, T., & Bozyiğit, S. (2023). Consumer complaints management in the digital era. *Research Anthology on Navigating Marketing Automation and Branding* içinde (ss. 57–90). IGI Global. <https://doi.org/10.4018/979-8-3693-0428-0.ch003>
- Bilgin, N. (2014). *Sosyal bilimlerde içerik analizi: Teknikler ve örnekler çalışmaları*. Siyasal Kitabevi.
- Birhanlı, A. (2025). *Eğitimde yenilikçi çözümler: Dijital dönüşüm*. Zenodo. <https://doi.org/10.5281/ZENODO.15448854>
- Buda, M., Maki, A., & Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106, 249–259. <https://doi.org/10.1016/j.neunet.2018.07.011>
- Büyüköztürk, Ş., Kılıç Çakmak, E., Erkan Akgün, Ö., Karadeniz, Ş., & Demirel, F. (2017). *Bilimsel araştırma yöntemleri* (23. baskı). Pegem Akademi. <https://doi.org/10.14527/9789944919289>
- Cano, F., Pichardo, C., Justicia-Arráez, A., Romero-López, M., & Berbén, A. B. G. (2024). Identifying higher education students' profiles of academic engagement and burnout and analysing their predictors and outcomes. *European Journal of Psychology of Education*, 39(4), 4181–4206. <https://doi.org/10.1007/s10212-024-00857-y>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/access.2020.2988510>
- Chen, Y., & Prentice, C. (2025). Integrating artificial intelligence and customer experience. *Australasian Marketing Journal*, 33(2), 141–153. <https://doi.org/10.1177/14413582241252904>
- Creswell, J. W., & Creswell, J. D. (2023). *Research design: Qualitative, quantitative, and mixed methods approaches* (6. baskı). SAGE Publications.
- Creswell, J. W., & Poth, C. N. (2016). *Qualitative inquiry and research design: Choosing among five approaches*. SAGE Publications.
- Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48(1), 24–42. <https://doi.org/10.1007/s11747-019-00696-0>
- Devika, M. D., Sunitha, C., & Ganesh, A. (2016). Sentiment analysis: A comparative study on different approaches. *Procedia Computer Science*, 87, 44–49. <https://doi.org/10.1016/j.procs.2016.05.124>
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. J. Burstein, C. Doran, & T. Solorio (Ed.), *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technol-*

- ogies, Volume 1 içinde (ss. 4171–4186). Association for Computational Linguistics. <https://doi.org/10.18653/v1/N19-1423>
- Dodge, J., Ilharco, G., Schwartz, R., Farhadi, A., Hajishirzi, H., & Smith, N. (2020). *Fine-tuning pretrained language models: Weight initializations, data orders, and early stopping* (arXiv:2002.06305). arXiv. <https://doi.org/10.48550/arXiv.2002.06305>
- Doğan, İ. (2025). Dijital dönüşümün ekonomik yansımaları: Türkiye örneği. *Journal of International Management*.
- Engin, O., Erçetin, H., & Abdioğlu, R. (2025). Eğitim 4.0 ve dijital dönüşüm: Endüstri ve modern işgücüne uyum sağlayan yaklaşımlar. *İstanbul Aydın Üniversitesi Sosyal Bilimler Dergisi*, 17(3), 287–311. https://doi.org/10.17932/IAU. IAUSBD.2021.021/iausbd_v17i3002
- Essel, H. B., Vlachopoulos, D., Nunoo-Mensah, H., & Amankwa, J. O. (2025). Exploring the impact of VoiceBots on multimedia programming education among Ghanaian university students. *British Journal of Educational Technology*, 56(1), 276–295. <https://doi.org/10.1111/bjet.13504>
- Feng, S. Y., Gangal, V., Wei, J., Chandar, S., Vossoughi, S., Mitamura, T., & Hovy, E. (2021). A survey of data augmentation approaches for NLP (arXiv:2105.03075). arXiv. <https://doi.org/10.48550/arXiv.2105.03075>
- Fernandes, R., Nagata, V., Melo, A., & Martins, V. W. (2024). Artificial intelligence and sustainability in higher education: A bibliometric analysis and its relations with the UN SDGs. *Concilium*, 24, 229–248.
- Franklin, R. S. (2013). The roles of population, place, and institution in student diversity in American higher education. *Growth and Change*, 44(1), 30–53. <https://doi.org/10.1111/grow.12001>
- Gardner, J., Yu, R., Nguyen, Q., Brooks, C., & Kizilcec, R. (2023). Cross-institutional transfer learning for educational models: Implications for model performance, fairness, and equity. *Proceedings of the 2023 ACM Conference on Fairness, Accountability, and Transparency* içinde (ss. 1664–1684). ACM. <https://doi.org/10.1145/3593013.3594107>
- Giang, N. T. P., Dien, T. T., & Khoa, T. T. M. (2020). Sentiment analysis for university students' feedback. K. Arai, S. Kapoor, & R. Bhatia (Ed.), *Advances in Information and Communication* içinde (ss. 55–66). Springer. https://doi.org/10.1007/978-3-030-39442-4_5
- Gokce, A., Tajvidi, M., & Hajli, N. (2024). Management respond to negative feedback: AI-powered insights for effective engagement. *IEEE Transactions on Engineering Management*, 71, 13983–13996. <https://doi.org/10.1109/tem.2024.3432457>
- Gorbāns, I. (2025). Remote study work challenges and the new model in post-covid and pre-ai era. Environment. Technology. Resources. *Proceedings of the International Scientific and Practical Conference*, 3, 117–121. <https://doi.org/10.17770/etr2025vol3.8547>
- Goswami, S. S., Mondal, S., Sarkar, S., Gupta, K. K., Sahoo, S. K., & Halder, R. (2024). Artificial intelligence-enabled supply chain management: Unlocking new opportunities and challenges. *Artificial Intelligence and Applications*, 3(1), 110–121. <https://doi.org/10.47852/bonviewaia42021814>
- Gottipati, S., Shankararaman, V., & Lin, J. R. (2018). Text analytics approach to ex-

- tract course improvement suggestions from students' feedback. *Research and Practice in Technology Enhanced Learning*, 13(1), Makale 6. <https://doi.org/10.1186/s41039-018-0073-0>
- Görmüş, A. Ş., Aydın, S., & Aydın, M. (2013). Yükseköğretim kurumlarında öğrenci şikayetlerinin ve şikayet yönetiminin değerlendirilmesi. *Uşak Üniversitesi Sosyal Bilimler Dergisi*, 4(15), 167–187. <https://doi.org/10.12780/UUSBD221>
- Graff, M., Moctezuma, D., & Téllez, E. S. (2025). Bag-of-Word approach is not dead: A performance analysis on a myriad of text classification challenges. *Natural Language Processing Journal*, 11, Makale 100154. <https://doi.org/10.1016/j.nlp.2025.100154>
- Gronberg, N., Knutas, A., Hynninen, T., & Hujala, M. (2021). Palaute: An online text mining tool for analyzing written student course feedback. *IEEE Access*, 9, 134518–134529. <https://doi.org/10.1109/ACCESS.2021.3116425>
- Guia, M., Silva, R., & Bernardino, J. (2019). Comparison of Naïve Bayes, Support Vector Machine, Decision Trees and Random Forest on Sentiment Analysis. *Proceedings of the 11th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management* içinde (ss. 525–531). SCITEPRESS. <https://doi.org/10.5220/0008364105250531>
- Gümüsoğlu, E. K. (2017). Yükseköğretimde dijital dönüşüm. *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*, 3(4), 30–42.
- Haibo He, & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263–1284. <https://doi.org/10.1109/TKDE.2008.239>
- Hassan, M., Salbitani, G., Carfagna, S., & Khan, J. A. (2025). Deep learning meets marine biology: Optimized fused features and LIME-driven insights for automated plankton classification. *Computers in Biology and Medicine*, 192, Makale 110273. <https://doi.org/10.1016/j.combiomed.2025.110273>
- Hassan, R. R., Abu Talib, M., Dweiri, F., & Roman, J. (2024). An Artificial Intelligence (AI) framework to predict operational excellence: UAE case study. *Applied Sciences*, 14(6), 2569. <https://doi.org/10.3390/app14062569>
- Hesar, F. F., & Foing, B. (2024). *Evaluating classification algorithms: Exoplanet detection using Kepler time series data* (arXiv:2402.15874). arXiv. <https://doi.org/10.48550/arXiv.2402.15874>
- Hu, Y., Zhang, S., Sathy, V., Panter, A. T., & Bansal, M. (2022). *SETSum: Summarization and visualization of student evaluations of teaching*. arXiv. <https://arxiv.org/abs/2207.03640>
- Jeilani, A., & Abubakar, S. (2025). Perceived institutional support and its effects on student perceptions of AI learning in higher education: The role of mediating perceived learning outcomes and moderating technology self-efficacy. *Frontiers in Education*, 10, Makale 1548900. <https://doi.org/10.3389/feduc.2025.1548900>
- Joachims, T. (1998). Text categorization with support vector machines: Learning with many relevant features. C. Nédellec & C. Rouveirol (Ed.), *Machine Learning: ECML-98* içinde (ss. 137–142). Springer. <https://doi.org/10.1007/BFb0026683>
- Johnston, R. (2001). Linking complaint management to profit. *International Journal of Service Industry Management*, 12(1), 60–69. <https://doi.org/10.1108/09564230110382772>
- Karasar, N. (2020). *Bilimsel araştırma yöntemi*

- (35. baskı). Nobel Akademik Yayıncılık.
- Karim, A., Mansab, M., Shahroz, M., Mushtaq, M. F., & Jeong, I. C. (2025). Anticipating impression using textual sentiment based on ensemble LRD model. *Expert Systems with Applications*, 263, Makale 125717. <https://doi.org/10.1016/j.eswa.2024.125717>
- Kavitha, M., & Prabhavathy, P. (2021). A review on machine learning techniques for text classification. *2021 4th International Conference on Computing and Communications Technologies (IC CCT)* içinde (ss. 605–610). IEEE. <https://doi.org/10.1109/IC-CCT53315.2021.9711858>
- Kıvrak, O. (2025). Trendyol üzerindeki kullanıcı yorumlarıyla akıllı çocuk saatlerine yönelik tüketici algısının tematik analizi: Güvenlik, işlevsellik ve ebeveyn deneyimi üzerine bir inceleme. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 9(1), 67–76. <https://doi.org/10.33461/uybisbbd.1688885>
- Koh, C. H. (2025). The quandary of proliferating intermediaries: Ottoman state formation beyond the de/centralization impasse. *International Journal of Middle East Studies*. <https://doi.org/10.1017/S0020743825000133>
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings of the 14th International Joint Conference on Artificial Intelligence*, 2, 1137–1143.
- Kumar, D., & Ratten, V. (2025). Artificial intelligence and family businesses: A systematic literature review. *Journal of Family Business Management*, 15(2), 373–392. <https://doi.org/10.1108/jfbm-08-2024-0160>
- Kumar, P., Kumar, V., & Sobti, R. (2020). Predicting joining behavior of freshmen students using machine learning – A case study. *2020 International Conference on Computational Performance Evaluation (ComPE)* içinde (ss. 141–145). IEEE. <https://doi.org/10.1109/ComPE49325.2020.9200167>
- Kumawat, H., Sharan, A., & Verma, S. (2025). Impact analysis of text representation on biomedical multi-label text classification with deep learning. *Procedia Computer Science*, 258, 3294–3304. <https://doi.org/10.1016/j.procs.2025.04.587>
- Lee, J., Yoon, W., Kim, S., Kim, D., Kim, S., So, C. H., & Kang, J. (2020). BioBERT: A pre-trained biomedical language representation model for biomedical text mining. *Bioinformatics*, 36(4), 1234–1240. <https://doi.org/10.1093/bioinformatics/btz682>
- Li, K. (2023). Determinants of college students' actual use of AI-based systems: An extension of the technology acceptance model. *Sustainability*, 15(6), 5221. <https://doi.org/10.3390/su15065221>
- Li, X., Shu, Q., Kong, C., Wang, J., Li, G., Fang, X., Lou, X., & Yu, G. (2025). An intelligent system for classifying patient complaints using machine learning and natural language processing: Development and validation study. *Journal of Medical Internet Research*, 27, e55721. <https://doi.org/10.2196/55721>
- Liao, Q. V., Gruen, D., & Miller, S. (2020). Questioning the AI: Informing design practices for explainable AI user experiences. *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems* içinde (ss. 1–15). ACM. <https://doi.org/10.1145/3313831.3376590>
- Maral, T. (2025). Eğitim iletişimde dijital dönüşüm ve teknoloji. *Journal of Educational Technology and Online Learning*,

- Mignan, A. (2019). Text classification of the precursory accelerating seismicity corpus: Inference on some theoretical trends in earthquake predictability research from 1988 to 2018. *Journal of Seismology*, 23(4), 771–785. <https://doi.org/10.1007/s10950-019-09833-2>
- Mugge, R., Jockin, B., & Bocken, N. (2017). How to sell refurbished smartphones? An investigation of different customer groups and appropriate incentives. *Journal of Cleaner Production*, 147, 284–296. <https://doi.org/10.1016/j.jclepro.2017.01.111>
- Ndunagu, J. N., Jimoh, R. G., Chidiebere, U., & Opeoluwa, G. D. (2022). Enhanced open and distance learning using an artificial intelligence (AI)-powered chatbot: A conceptual framework. *2022 5th Information Technology for Education and Development (ITED)* içinde (ss. 1–4). IEEE. <https://doi.org/10.1109/ited56637.2022.10051575>
- Nicolescu, L., & Tudorache, M. T. (2022). Human-Computer interaction in customer service: The experience with AI chatbots—A systematic literature review. *Electronics*, 11(10), 1579. <https://doi.org/10.3390/electronics11101579>
- Ocen, S., Elasu, J., Aarakit, S. M., & Olupot, C. (2025). Artificial intelligence in higher education institutions: Review of innovations, opportunities and challenges. *Frontiers in Education*, 10, Makale 1530247. <https://doi.org/10.3389/feduc.2025.1530247>
- Öncü, S. E., Özkaya, H., & Öztürk, Ö. (2024). Öğrenci işlerinde dijital dönüşüm: Gelişen teknolojinin öğrenci destek hizmetlerindeki izleri. *Dijital Teknoloji ve Eğitim Dergisi*, 3(1), 52–68. <https://doi.org/10.5281/zenodo.12637421>
- Pabel, A., & Shah, M. (2025). Student experience survey: Trends and insights in Australian higher education from 2017 to 2023. *Perspectives: Policy and Practice in Higher Education*, 1–12. <https://doi.org/10.1080/13603108.2025.2528045>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Puspadarma, I. S., Mukti, I. Y., & Ramadani, L. (2025). Microservices enterprise architecture design with AI-powered OCR for improving fixed broadband complaint handling: A telco company case study. *2025 International Conference on Advancement in Data Science, E-learning and Information System (ICADEIS)* içinde (ss. 1–6). IEEE. <https://doi.org/10.1109/ICADEIS65852.2025.10933216>
- Rana, N. P., Begum, N., Faisal, M. N., & Mishra, A. (2025). Customer experiences with service robots in hotels: A review and research agenda. *Journal of Hospitality Marketing & Management*, 34(2), 145–174. <https://doi.org/10.1080/19368623.2024.2403640>
- Ravikanth, M., Korra, S., Mamidisetti, G., Goutham, M., & Bhaskar, T. (2024). An efficient learning based approach for automatic record deduplication with benchmark datasets. *Scientific Reports*, 14(1), Makale 16254. <https://doi.org/10.1038/s41598-024-63242-1>
- Sabir, M., Khan, T., & Azam, M. (2025). A comparative study of traditional and hybrid models for text classification. *International Journal of Advanced Computer Science and Applications*.

- Saldana, J. (2019). *Nitel araştırmacılar için koddama el kitabı* (A. Tüfekci Akcan, Ed.; 3. baskı). Pegem Akademi.
- Setiawan, Y., Ulfa Maulidevi, N., & Surendro, K. (2024). The optimization of n-gram feature extraction based on term occurrence for cyberbullying classification. *Data Science Journal*, 23, Makale 31. <https://doi.org/10.5334/dsj-2024-031>
- Sunar, A. S., & Khalid, M. S. (2024). Natural language processing of student's feedback to instructors: A systematic review. *IEEE Transactions on Learning Technologies*, 17, 741–753. <https://doi.org/10.1109/tlt.2023.3330531>
- Talu, A. A., & Tezci, E. (2025). Yükseköğretimde dijitalleşme ve e-öğrenme: Kalite güvencesi süreçlerinin dönüşümü. *Eğitim Teknolojisi Kuram ve Uygulama*.
- Taşlıbeyaz, E., & Taşcı, Y. (2021). Review of the studies on digital transformation in higher education institutions. *Journal of Higher Education and Science*, 11(1), 172–183. <https://doi.org/10.5961/jhes.2021.439>
- Tax, S. S., Brown, S. W., & Chandrashekar, M. (1998). Customer evaluations of service complaint experiences: Implications for relationship marketing. *Journal of Marketing*, 62(2), 60–76. <https://doi.org/10.1177/002224299806200205>
- Telli, S. G., & Aydın, S. (2025). Üniversiteleerde yapay zekânın kullanımı: Dönüşümler, getiriler ve geleceğe hazırlık. *Üniversite Araştırmaları Dergisi*, 8(1), 139–148. <https://doi.org/10.32329/uad.1609305>
- Tuncal, A. (2025). Yapay zekâ destekli ürünlerde müşteri deneyimi nasıl ölçülür? Türkiye'ye özgü bir ölçek uyarlaması. *Sosyal Mucit Academic Review*, 6(1), 119–146. <https://doi.org/10.54733/smar.1602880>
- Ulaş, M. (2025). Akademisyenlerin yapay zekâ teknolojilerini kullanma motivasyonları üzerine nitel bir araştırma. *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 34, 142–159. <https://doi.org/10.35379/cusosbil.1679553>
- Uysal, A. K., & Gunal, S. (2012). A novel probabilistic feature selection method for text classification. *Knowledge-Based Systems*, 36, 226–235. <https://doi.org/10.1016/j.knosys.2012.06.005>
- Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems*, 28(2), 118–144. <https://doi.org/10.1016/j.jsis.2019.01.003>
- Wei, J., Qi, S., Wang, W., Jiang, L., Gao, H., Zhao, F., Al-Bukhaiti, K., & Wan, A. (2025). Decision-making in the age of AI: A review of theoretical frameworks, computational tools, and human-machine collaboration. *Contemporary Mathematics*, 6(2), 2089–2112. <https://doi.org/10.37256/cm.6220256459>
- Wolf, T., Debut, L., Sanh, V., Chaumond, J., Delangue, C., Moi, A., Cistac, P., Rault, T., Louf, R., Funtowicz, M., Davison, J., Shleifer, S., Von Platen, P., Ma, C., Jernite, Y., Plu, J., Xu, C., Le Scao, T., Gugger, S., ... Rush, A. (2020). Transformers: State-of-the-art natural language processing. *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations* içinde (ss. 38–45). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2020.emnlp-demos.6>
- Xu, S., Barbosa, S. E., & Hong, D. (2020). BERT feature based model for predicting the helpfulness scores of online customers reviews. K. Arai, S. Kapoor, & R. Bhatia (Ed.), *Advances in Information and*

Communication içinde (ss. 270–281).
Springer. https://doi.org/10.1007/978-3-030-39442-4_21

Yakut Özek, B., & Sincer, S. (2024). Yükseköğretimde dijital dönüşüm: Çevrimiçi ve hibrit uygulamaların geleneksel eğitim sistemine entegrasyonu. *Korkut Ata Türkiyat Araştırmaları Dergisi*, (14), 1170–1193. <https://doi.org/10.51531/korkutataturkiyat.1426337>

Zhang, Y., & Wallace, B. (2015). *A sensitivity analysis of (and practitioners' guide to) convolutional neural networks for sentence classification* (arXiv:1510.03820). arXiv. <https://doi.org/10.48550/arXiv.1510.03820>

Zhou, R. (2025). Transforming university academic management into data aggregation of artificial intelligence. *Creative Education*, 16(3), 330–344. <https://doi.org/10.4236/ce.2025.163020>