



Bingöl Üniversitesi
İktisadi ve İdari Bilimler Fakültesi Dergisi
Bingol University
Journal of Economics and Administrative Sciences

Cilt/Volume: 8, Sayı/Issue: 1
Yıl/Year: 2024, s. 31-46
DOI: 10.33399/biibfad.1362160
ISSN: 2651-3234/E-ISSN: 2651-3307
Bingöl/Türkiye

Makale Bilgisi / Article Info
Geliş/Received: 18/09/2023 Kabul/ Accepted: 03/01/2024



Evrişimsel Sinir Ağları Tabanlı Derin Öğrenme Yöntemiyle Müşteri Şikayetlerinin Sınıflandırılması

Classification of Customer Complaints using Convolutional Neural Network Based Deep Learning Method

Murat Fatih TUNA*
Yasin GÖRMEZ**

Öz

Günümüzde, artan nüfus ve değişen ihtiyaçlar doğrultusunda firma sayıları giderek artmakta ve firmalar büyümektedir. Bu bağlamda, aynı alanda faaliyet gösteren birçok firma ortaya çıkmakta, bu nedenle firmaların rekabet kabiliyetini artırması gerekmektedir. Bir firma için mevcut müşterinin elde tutulmasına odaklanmak, yeni müşteri kazanmaktan daha maliyetli olmaktadır. Bir müşterinin kaybedilmemesi için en önemli unsurlardan birisi müşteri ilişkileri yönetiminin bir alt dalı olan müşteri şikâyetlerinin iyi bir şekilde yönetilmesinden geçmektedir. Teknolojide meydana gelen gelişmeler doğrultusunda, birçok alanda olduğu gibi müşteri şikâyeti yönetiminde de teknolojidenden sıklıkla faydalanılmaktadır ancak bu durum henüz istenilen seviyelere ulaşmamıştır. Bu çalışmada müşteri şikâyeti yönetimi alanına katkı sağlamak için derin öğrenmeden faydalanan özgün modeller geliştirilmiştir. Bu kapsamda, evrişimsel sinir ağı katmanları kullanılarak müşteri yorumlarının hangi şikâyet türünü ilgilendirdiğini tahmin eden bir model geliştirilmiştir. Finans alanındaki bir veri seti kullanılarak analiz edilen modelin hiper-parametreleri Bayesian optimizasyon yöntemi kullanılarak optimize edilmiştir. Farklı derinliklerde geliştirilen modellerle %85,83'lere ulaşan doğruluk oranı elde edilmiştir. Literatürde benzer veri seti ile yapılan çalışmalar incelendiğinde önerilen modelin, diğer çalışmalara göre üstün olduğu gözlemlenmiştir.

Anahtar Kelimeler: Müşteri şikâyet yönetimi, derin öğrenme, evrişimsel sinir ağları, tüketici davranışları

JEL Kodları: M31; C63

Abstract

Nowadays, the number of companies is increasing, and companies are growing in line with the increasing population and changing needs. In this context, many companies operating in the same field emerge, thus companies need to enhance their competitive abilities. For a company, focusing on retaining existing customers is more cost-effective than acquiring new customers. One of the most critical elements in not losing a customer is the effective management of customer complaints, which is a sub-branch of customer relationship management. With the advancements in technology, automated systems are frequently used in customer complaint management, as in many areas, but it has not yet reached the desired levels. In this study, novel models using deep learning were developed to contribute to the field of customer complaint management. In this context, a model was created to predict which complaint type customer comments concern, using a convolutional neural network layer. The models were analyzed using a dataset in the field of finance, and the hyper-parameters of the models were optimized using the Bayesian optimization method. Accuracy of up to 85.83% were achieved with models developed at different

* Dr. Öğr. Üyesi, Sivas Cumhuriyet Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, mftuna@cumhuriyet.edu.tr, ORCID: <https://orcid.org/0000-0002-8634-8643>

** Dr. Öğr. Üyesi, Sivas Cumhuriyet Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, yasingormez@cumhuriyet.edu.tr, ORCID: <https://orcid.org/0000-0001-8276-2030>

depths. When compared to studies with similar datasets in the literature, it was observed that the proposed model outperformed other studies.

Keywords: Customer complaint management, deep learning, convolutional neural network, consumer behavior

JEL Codes: M31; C63

1. GİRİŞ

İşletme süreçlerinde müşterilerden bilgi toplamaya dayanan süreçlerden farklı olarak günümüzde, Zaltman ve Zaltman (2008, s. 6) tarafından da ifade edildiği üzere tüketiciden gelen dönütlerin detaylı bir şekilde ele alınması gerekmektedir. Bu dönütlerden biri olan şikâyetler tüm işletme türleri için önemli olduğu kadar, finansal kuruluşlar için de önemlidir. Finansal kuruluşlar günümüz dünyasında giderek müşteri sayısını artırmakta ve buna bağlı olarak bu kuruluşlardan hizmet gören tüketicilerin şikâyetleri de artış göstermektedir. Bu durum ilgili kuruluşların şikâyetleri yönetme noktasında yenilikçi yöntemlere yatkınlığını artırmaktadır. Ayrıca Meyer-Waarden ve Sabadie (2023) hizmet işletmelerinde insan faktörünün varlığını şikâyetin temel dinamiği olarak görmekte ve müşterilerin tatminin bu şikâyetin giderilmesine bağlı olduğunu vurgulamaktadır. Bu görüşe paralel olarak Ferri (2018) şikâyet yönetim programlarının müşterilerin elde tutulması açısından önemli olduğunu vurgulamakta ve şikâyetin hızlı çözülmesini müşterilerin firmaya sadakatinin artması ile ilişkilendirmektedir.

Şikâyetlerle alakalı dikkat çekici istatistikler bulunmaktadır. İngiltere’de işletmelerle müşteriler arasındaki finansal uyuşmazlıkları çözümleyen Financial Ombudsman Service kurumuna sadece 2021-22 yılları arasında firmalar tarafından çözülmemeyen ve uyuşmazlık sürecine giren 282.035 şikâyet girişmiştir ki bunların 164.560’ı işletmeler nezdinde ilk defa sunulmuştur (Financial Ombudsman Service, 2023). Yine aynı portalda verilen bilgiye göre 2022-23 yılları arasındaki yeni şikâyet sayısı 70.416 olmuştur. Aynı amaçla Amerika’da kurulan The Consumer Financial Protection Bureau Kurumu, 54.700 şikâyetin birimlerine aktarıldığı rapor etmiştir (Statista Research Department, 2023). Öte yandan Türkiye’de müşterilerin şikâyetlerini paylaştığı ve firmalar nezdinde çözüm aradığı en büyük platformlardan biri olan ŞikayetVar sitesinde (erişilen 17.08.2023 tarihinde), Türkiye genelinde 17.08.2023 tarihi itibarıyla çözülmemiş 11.012.768 şikâyet olduğu, bunların 20.094’ünün ‘finans’ ve 517.796’sının ‘banka’ terimlerini içerdiği görülmektedir (ŞikayetVar, 2023).

İnternet ortamının işletme süreçlerine dâhil oluşu, finansal şikâyetlerin firmalara daha rahat ulaştırılmasına imkân tanımıştır. Bu durum klasik müşteri ilişkileri yönetim (MİY) süreçlerinin e-MİY’e evrilmesine ve şikâyetlerin de e-MİY’in bir parçası haline gelmesiyle sonuçlanmıştır (Cho vd., 2002). Dolayısıyla internet kanallı şikâyet verileri aynı zamanda e-MİY ve alt stratejilerinin gerçekleştirilmesinde yadsınamaz bir öneme sahip olmuştur. Dolayısıyla şikâyetleri yönetmek müşterileri elde tutmanın ve onları kaybetmemenin bir yoludur (Keramati vd., 2016). Ayrıca bir müşteriyi firma bünyesinde tutmak ve onun gereksinimlerine odaklanmak, yeni bir müşteriyi firma bünyesine kazandırmaktan oldukça maliyetlidir (Kaynar vd., 2017). Dolayısıyla iyi bir e-MİY stratejisi şikâyetlerin doğru, etkin ve hızlı bir şekilde yönetilmesine ihtiyaç duyarken, aynı zamanda müşterilerin firmaları terk etmesini engelleyerek onların sadakatini artırmaktadır. Müşteri şikâyet yönetimi sürecindeki hız ve etkinliğin sağlanması ise bilişim teknolojilerinin yoğun bir şekilde benimsenmesini ve kullanımını gerektirmektedir (DiCarlo vd., 2023). Buna ek olarak şikâyetlerden oluşan veri setlerinin giderek daha karmaşık hale gelmesi (Harrison vd., 2016) ve klasik makine öğrenmesi yöntemlerinde gereken ön işleme süreçlerini ortadan kaldıracı olması (Janiesch vd., 2021), derin öğrenme yöntemlerine duyulan ihtiyacı artırmaktadır. Bu noktada

derin öğrenme metotları otomatik nitelik çıkarımı, geniş ve karmaşık veri setleriyle rahat çalışma, yüksek performans ve doğrusal olmayan ilişkileri de nitelikli yordayabilme gibi birtakım üstünlüklere sahiptir (Strasser, 2023).

1.1. Araştırmanın Amacı

Çalışmanın giriş kısmında verilen bilgiler derin öğrenme yöntemlerini kullanan şikâyet yönetim süreçlerinin önemini ve işletmeler nezdinde sağladığı avantajı gözler önüne sermektedir. Ayrıca bu yönde yapılacak çalışmaların oldukça yeni ve geliştirilmeye açık akademik bir boşluğa işaret ettiği yapılan yayınların güncelliğinden de anlaşılmaktadır. Bu maksatla çalışmada etkin bir şikâyet yönetim sürecinde evrişimsel sinir ağlarının kullanımını amaçlamaktadır.

1.2. Araştırmanın Önemi

Çalışmanın şikâyet yönetimi sürecinde hız ve güç kazanmak isteyen firmalara yönelik bir fırsat sunabileceği gibi aynı zamanda evrişimsel ağların şikâyet yönetim süreçlerinde kullanılmasını benimseyecek devam çalışmalarına rehberlik edeceği düşünülmektedir. Nitekim yerli literatürde tüketici davranışlarının ve müşteri ilişkileri yönetiminin kesişiminde yer alan müşteri şikâyetleri ve bunların evrişimsel sinir ağları ile yönetilmesini konu edinen herhangi bir çalışmaya rastlanamamıştır. Bu durum, çalışmanın, özgünlüğünü ve yerli literatürdeki gelişmelere öncülük etmesi noktasında sahip olduğu önemi derinleştirmektedir. Dolayısıyla araştırmanın pazarlama ve tüketici davranışları problemlerine derin öğrenme ve evrişimsel sinir ağları gibi bilgisayar bilimlerine dair modern yöntemleri uygulayacak araştırmalara öncülük edeceği düşünülmektedir. Dolayısıyla çalışma müşteri ilişkileri yönetimi, bilgisayar bilimleri, derin öğrenme ve tüketici davranışları gibi spesifik alanları bünyesinde barındıran ileri görüşlü ve kompleks bir çalışma olarak betimlenebilir

2. LİTERATÜR TARAMASI

Literatürde şikâyet yönetimini makine öğrenmesi (Peker, 2022; Shin vd., 2022; Shobana vd., 2022), yapay sinir ağları (Correa ve Correa, 2022; Seymen vd., 2023; Yang vd., 2019) ve derin öğrenme (Anagun vd., 2022; Jain vd., 2021; Khedkar ve Shinde, 2020a, 2020b; Singh vd., 2022) aracılığıyla şikâyet yönetimine odaklanan birtakım çalışmalar olduğu görülmektedir. Müşteri şikâyetlerinin kategorize edilmesinde derin öğrenme yöntemlerini kullanan çalışmalarda; RNN (Recurrent Neural Network-Yinelemeli Sinir Ağı), LSTM (Long-Short Term Memory-Uzun-Kısa Vadeli Bellek) ve CNN (Convolutional Neural Network-Evrişimsel Sinir Ağı) yöntemlerinin kullanıldığı literatürden anlaşılmaktadır (Alamsyah vd., 2022; Aldunate vd., 2022; Khedkar ve Shinde, 2020a; Kohler vd., 2020; Oyewola vd., 2023; Salminen vd., 2022; Sun vd., 2019; Tahsin vd., 2023).


Hayuningrum (2021), müşteri şikâyetlerinin otomatik kategorizasyonunu gerçekleştirmede RNN yöntemiyle birlikte CNN yöntemini kullanmıştır. Çalışmasının sonucunda, kelime gömme yöntemlerinden biri olan word2vec yöntemiyle ön eğitilmiş CNN katmanının en iyi sınıflandırma performansına sahip olduğunun altını çizmiştir. Evrişimsel sinir ağı yöntemiyle müşteri şikâyetlerinin kategorize edildiği bir diğer çalışmada Kohler vd. (2020), şikâyet anlatılarının sınıflandırılması için geliştirdikleri derin öğrenme yaklaşımında PCA ve t-SEN yöntemleriyle birlikte CNN yönteminden yararlanmıştır. Araştırmanın sonucunda t-SNE ve CNN yöntemlerinin metin sınıflandırmasında tercih edilebilecek başarılı yöntemlerden olduğunu ve bu noktada ön eğitilmiş kelime vektörlerinin kullanımının model başarımına etki ettiğini vurgulamışlardır. CNN yönteminden yararlanan bir diğer çalışmada Oyewola vd. (2023) tek boyutlu bir CNN katmanı kullanmışlardır. %69,63 ve %71 doğruluk

değerlerine iki farklı ablasyonda ulaştıkları çalışmalarının sonucunda önerdikleri modelin müşteri şikâyetlerinin sınıflandırılmasında geçerli ve etkin bir yöntem olduğunu ve yığın müşteri şikâyetlerinde bu yaklaşımın güçlü bir performans sergilediğini vurgulamıştır. Bunlara ek olarak Sun vd. (2019), su abonelerinin müşteri şikâyetlerinin sınıflandırılmasında CNN yöntemini kullanmışlardır. Sonuç olarak CNN'nin su abonelerinin şikâyetlerine ilişkin desenleri başarılı bir şekilde kestirme kabiliyetine sahip olan bir yöntem olduğunu ve %90'ın üzerinde başarıma sahip olabileceğini öne sürmüşlerdir.

3. YÖNTEM

Çalışmada müşteriler tarafından yapılan yorumların hangi şikâyet türünü ilgilendirdiğini tespit etmek için özgün derin öğrenme yaklaşımları geliştirilmiştir. Bu bağlamda geliştirilen derin öğrenme modelinde gömme (Embedding), tek boyutlu evrişimsel sinir ağı (1-D Convolutional Neural Network - Conv1D) ve tam bağlı (Fully Connected - FC) katmanlardan faydalanılmıştır. Çalışmamızda tasarladığımız derin öğrenme modelinde Conv1D katmanı sayısı bir ile dört arasında olan dört farklı model geliştirilmiş böylece derinliğin model başarısına etkisini ölçmek amaçlanmıştır. Tasarlanan derin öğrenme modellerinden, Conv1D katman sayısı iki olan modelin mimari yapısı şekil 1 ile gösterilmektedir. Diğer modellerde ise seri bağlı Conv1D katman sayısı farklılık göstermektedir.

Şekil 1: İki Adet Seri Bağlı Conv1D Katmanına Sahip Önerilen Mimari Yapısı Derin Öğrenme Modeli



Önerilen modelin geliştirilmesi için Python dilinde var olan, Keras kütüphanesinden faydalanılmıştır (Keras, 2023). Şekil 1'de de gösterildiği üzere, önerilen modelin ilk katmanında metin verilerinin okunduğu girdi katmanı bulunmaktadır. Modelin ikinci aşamasında, girdi katmanından alınan metin verileri vektörlere dönüştürülmüştür. Bu aşamada Keras kütüphanesinde var olan TextVectorization sınıfından faydalanılmıştır. Önerilen modelde kullanılan TextVectorization katmanında, kelime dağarcığının maksimum uzunluğu (max_tokens) 20.000, çıktı türü tam sayı (Integer) ve çıktı dizisi uzunluğu ise 500 olarak ayarlanmıştır. Bunun yanı sıra her bir girdi metnini temizlemek için standart fonksiyonu (standardize) eklenmiştir. Bu fonksiyonda tüm girdiler küçük harfe çevrilmiş, girdilerde var olan HTML objeleri (br, div vb.) temizlenmiş ve metinler noktalama işaretlerinden arındırılmıştır. Daha sonra elde edilen bu vektörler Embedding katmanı sayesinde 128 uzunluğunda sabit vektörlere dönüştürülmüştür. Daha sonra modelimize Dropout katmanı eklenerek modelin ezber yapmasının önüne geçilmek istenmiştir. Dropout katmanından sonra modelimize seri şekilde Conv1D katmanları eklenmiştir. Buradaki Conv1D katmanı sayısına bağlı olarak, DeepCusComp-1, DeepCusComp-2, DeepCusComp-3 ve DeepCusComp-4 ismini verdiğimiz dört farklı model tasarlanmıştır. Şekil 1'de DeepCusComp-2 modeli gösterilmektedir. DeepCusComp-1 modeli için çekirdek genişliği (kernel_size) 7; DeepCusComp-2 modeli için çekirdek genişlikleri sırası ile 7 ve 5, DeepCusComp-3 modeli için çekirdek genişlikleri sırası ile 7, 5 ve 3; DeepCusComp-4 modeli için ise çekirdek genişlikleri sırası ile 7, 5, 3 ve 1 olarak belirlenmiştir. Conv1D katmanlarından sonra modelimize GlobalMaxPooling katmanı eklenmiş ve bu katmanı tam bağlı katman takip

etmiştir. Tam bağlı katmandan sonra modelin ezberlemesinin önüne geçmek için tekrar bir Dropout katmanı eklenerek model, çıktı katmanı ile sonlandırılmıştır. Çıktı katmanı, nöron sayısı 5 (beş farklı sınıf olduğu için) ve aktivasyon fonksiyonu softmax olan bir tam bağlı katmandır. Sınıflama katmanı haricinde kalan diğer tüm katmanlar için aktivasyon fonksiyonu olarak relu tercih edilmiştir. Modellerimizde optimizasyon olarak Adam fonksiyonu ve kayıp fonksiyonu olarak categorical_crossentropy tercih edilmiştir.

4. DENEYLER

4.1. Veri Seti Hazırlama ve Ön İşlem

Çalışmada Kaggle platformunda açık kaynak olarak paylaşılmış “Consumer Complaints Dataset for NLP” veri seti kullanılarak müşteri şikâyetleri sınıflandırılmıştır (Tiwari, 2021). Bu veri setinde Mart 2020 ile Mart 2021 yılları arasında toplanmış, Amerika tüketici mali koruma bürosuna (The Consumer Financial Protection Bureau U. S.) ait ve finans şirketlerinden toplanmış tüketici şikâyetleri bulunmaktadır. Veri setinde kredi raporlama, borç toplama, ipotek ve krediler, kredi kartları ve perakende bankacılık olmak üzere beş farklı sınıf bulunmaktadır. Veri setindeki amaç, müşteri tarafından yazılan bir şikâyetin, beş sınıftan hangisini ilgilendirdiğinin tespit edilmesidir. Deneyin ilk aşamasında veri seti eğitim, test ve validasyon olmak üzere üç bölüme ayrılmıştır. Bu kapsamda veri setindeki örneklerden rastgele %20’si ve %10’u seçilerek sırası ile test ve validasyon veri setleri oluşturulmuştur. Kalan örnekler ise eğitim veri seti olarak kullanılmıştır. Bu veri setlerinde sınıflara göre örnek sayıları Tablo 1’de gösterilmektedir.

Tablo 1: Sınıf Türlerine Göre Her Bir Veri Seti İçin Örnek Sayıları

Veri Seti	Kredi Raporlama	Borç Toplama	İpotek ve Krediler	Kredi Kartları	Perakende Bankacılık	Toplam Örnek Sayısı
Eğitim	62.891	15.503	13.620	11.854	9.827	113.695
Test	18.846	5.319	3.363	2.540	2.416	32.484
Doğrulama	9.442	2.328	2.007	1.172	1.293	16.242
Tüm Veri Seti Toplam	91.179	23.150	18.990	15.566	13.536	162.421

Tablo 1’de de görüleceği üzere her bir eğitim, test ve validasyon veri kümelerinde örnek sayıları sınıflara göre de dengeli olarak dağılmıştır. Herhangi bir veri kümesinde sınıflar bazında diğer veri kümesine göre dengesizlik oluşmamasına dikkat edilmiştir. Bölümleme aşamasından sonra veri setleri, analiz aşamasında hız kazanılması için Python dilinde var olan tensorflow kütüphanesi yardımı ile parti boyutu (batch_size) 32 olan tensör dilimlerine dönüştürülmüştür.

4.2. Hiper-Parametre Optimizasyonu

Çalışmada veri seti hazırlama aşamasından sonra hiper-parametre optimizasyonu yapılmıştır. Hiper-parametreler makine öğrenmesi modellerinde performansı etkileyen en önemli unsurlardan biridir. Özellikle derin öğrenme gibi hiper-parametre çeşidinin fazla ve parametre uzaylarının geniş olduğu modellerde hiper-parametre optimizasyonu daha da büyük bir önem kazanmaktadır. Çalışmamızda hiper-parametre optimizasyonu için diğer yöntemlere göre hız ve performans açısından üstünlük sağladığı bilinen Bayesian Optimizasyon yöntemi kullanılmıştır (Gormez vd., 2020; Salama vd., 2019; Snoek vd., 2012). Bayesian Optimizasyon yöntemi Python dilinde var olan scikit-optimize (skopt) yöntemi kullanılarak geliştirilmiştir (Sci-Kit Optimize, 2023). Skopt yönteminde gp_minimize fonksiyonu, acq_func parametresi “EI” ve n_calls parametresi 100 olacak şekilde kullanılmıştır. Bu aşamada acq_func bir önceki hiper-parametreleri kullanan modelin Gauss

değerini en aza indirmeyi amaçlayan fonksiyonu temsil etmektedir ve bu fonksiyon için beklenen negatif iyileşme (expected improvement - EI) kullanılmıştır. Yöntemde kullanılan diğer bir parametre olan n_calls ise optimizasyon modelinin kaç kez çağırılacağını belirlemektedir. Bu yöntem vekil fonksiyonu modellemek için Gauss sürecini kullanmaktadır ve skor fonksiyonunu en aza indirmeyi amaçlamaktadır. Skopt kütüphanesi parametre olarak, bir sayı değeri dönen fonksiyon almakta ve bu fonksiyonu n_calls değeri kadar çağırılmaktadır. Her bir çağırıda, bir önceki değerleri dikkate alarak, fonksiyondan dönen değeri en aza indirmeyi hedeflemektedir. Çalışmamızda doğruluk oranı (Accuracy - acc) artırılmak istenmektedir bu nedenle skor fonksiyonu olarak doğruluk oranının negatif değeri dönülmüştür. Çünkü bir sayının negatifini minimize etmek pozitifini maksimize etmeye eş değerdir. Bu sayede skopt kütüphanesinin, doğruluk oranı değerinin negatifini minimize etmesi yani doğruluk oranını maksimize etmesi sağlanmıştır. Doğruluk oranı değeri ise, modelin validasyon veri setinde doğru tahmin ettiği örnek sayısının, validasyon veri setindeki toplam örnek sayısına bölünmesi ile elde edilmiştir.

Bayesian optimizasyon yöntemi, ızgara aramadan farklı olarak bir hiper-parametre değeri için belirlenen aralık değeri almakta ve o aralık değerinde en uygun hiper-parametre değerini seçmektedir. Tablo 2’de optimize edilen her bir hiper-parametre için, parametre değer türü, en küçük değer, en büyük değer ve modeller için elde edilen optimum değerler gösterilmektedir. Bu aşamada modelimiz eğitim veri seti kullanılarak eğitilmiş ve validasyon veri seti üzerinde en yüksek doğruluk oranını veren hiper-parametreler optimum olarak seçilmiştir.

Tablo 2: Her Bir Model İçin Optimize Edilen Hiper-Parametrelerin Arama Uzayları Bilgileri ve Optimum Değerler

Hiper-Parametre adı	Hiper-Parametre değer türü	En küçük değer	En büyük değer	DeepCusComp-1 modeli optimum değer	DeepCusComp-2 modeli optimum değer	DeepCusComp-3 modeli optimum değer	DeepCusComp-4 modeli optimum değer
Öğrenme oranı	Gerçek Değer	10 ⁻⁴	10 ⁻¹	0.0001003	0.0001012	0.0001	0.0001003
Filtre sayısı	Tam Sayı	16	150	148	118, 146	19, 140, 139	53, 134, 50, 38
Nöron sayısı	Tam Sayı	100	500	105	120	106	167
Döngü sayısı	Tam Sayı	10	300	183	20	10	227

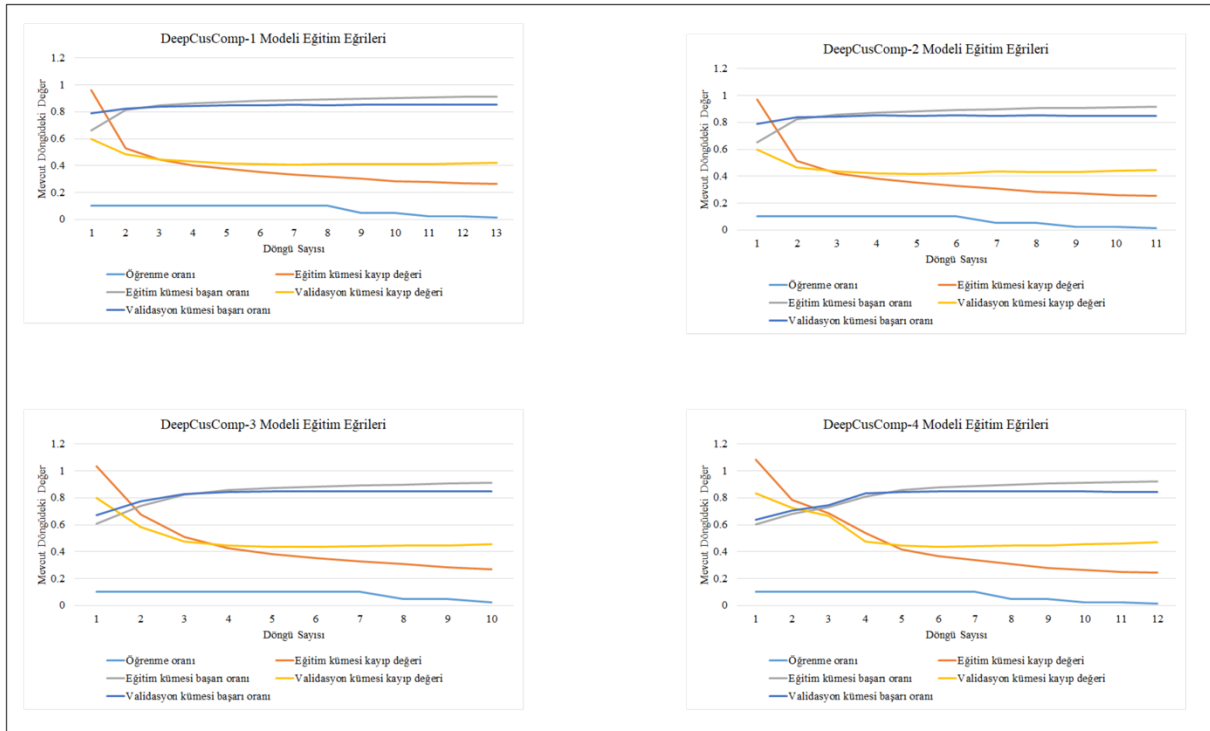
Bu tabloda öğrenme oranı, (learning_rate) eğitim esnasına hesaplanan gradyan için çarpım katsayısını; filtre sayısı, Conv1D katmanlarında kullanılan filtre adedini; nöron sayısı, tam bağlı katmandaki toplam nöronu ve döngü sayısı (epoch), tüm verilerin modelde eğitim için kaç kez kullanılacağını temsil etmektedir. Filtre sayısı optimum değeri DeepCusComp-1 haricindeki modeller için tabloda birden fazla gösterilmektedir. Bunun nedeni bu modellerde birden fazla Conv1D katmanı olmasıdır. Tabloda ilgili model için gösterilen birden fazla değer, sırası ile o modelde kullanılan Conv1D katmanına aittir.

4.3. Model Performansı Değerlendirme

Deneyimizin son aşamasında, hiper-parametre optimizasyonu sayesinde belirlenen optimum hiper-parametreler kullanılarak dört adet model eğitim veri kümesi ile eğitilmiş ve test veri set kümesi üzerindeki başarı performansları hesaplanmıştır. Optimum hiper-

parametrelerin yanı sıra performansı artırmak için modellerimize iki adet geri çağırma (callback) fonksiyonu eklenmiştir. Bu fonksiyonlardan ilkinde eğitim esnasında art arda 2 döngüde validasyon veri kümesindeki kayıp fonksiyonu değerinde iyileşme olmaması durumunda öğrenme oranı ikiye bölünmüştür. Bu fonksiyonlardan ikincisinde ise eğitim esnasında art arda 6 döngüde validasyon veri kümesindeki kayıp fonksiyonu değerinde iyileşme olmaması durumunda eğitim sonlandırılmıştır. Şekil 2’de önerilen modeller için her bir döngüde validasyon ve eğitim kümesi üzerinde elde edilen doğruluk oranı ve loss değerleri ile modelin öğrenme oranı değerinin eğri grafiği gösterilmektedir. Optimum döngü sayılarının daha fazla olmasına rağmen şekillerdeki döngü sayılarının daha az olmasının nedeni ikinci geri çağırma fonksiyonu sayesinde eğitimin erken bitirilmesidir.

Şekil 2: Derin Öğrenme Modelleri Eğitim Eğrileri



Öğrenme oranı değeri, kayıp değerleri ve başarı oranlarına göre çok daha küçük değerler almaktadır. Şekil 2’de gösterilen eğrilerde, grafik çizgileri arasında büyük bir boşluk olmaması için öğrenme oranı değeri 1000 ile çarpılarak gösterilmektedir. Bu durum eğri çizimlerinde herhangi bir değişime neden olmamakta sadece öğrenme oranları ile diğer değerler arasındaki boşluğun kapanmasını sağlamaktadır. Doğru oluşturulmuş ve ezber yapmayan bir makine öğrenmesi modelinde kayıp değerinin zamanla düşmesi, doğruluk oranının ise zamanla artması beklenmektedir. Şekillerdeki eğrilerde de görüleceği üzere önermiş olduğumuz dört modelde de hem eğitim hem de validasyon veri kümesi için kayıp değerleri düşerken, doğruluk oranı değerleri yükselmektedir. Makine öğrenmesi modellerindeki asıl amaç geçmişteki veriler ile model eğitimini yaparak, gelecekteki veriler için en az hata ile tahmin yapmaktır. Bu nedenle model eğitimi esnasında eğitim veri kümesindeki kayıp değeri ve doğruluk oranı ile validasyon veri kümesindeki kayıp değeri ve doğruluk oranı arasında büyük farklılıklar olmaması gerekmektedir. Şekillerdeki eğrilere bakıldığında dört modelimizin de bu durumu sağladığı görülmektedir. Bu durumun nedeni modelimize eklemiş olduğumuz geri çağırma fonksiyonlardır.

Doğruluk oranı, makine öğrenmesi yöntemlerinde model performansını belirlemek için en sık kullanılan metriklerden birisidir ancak dengeli olmayan veri setleri için tek başına yeterli olmamaktadır. Dengeli veri seti, bir veri setinde bulunan farklı sınıfların aynı ya da çok yakın sayıda örnek ile temsil edilme durumudur. Örneğin üç sınıfı olan bir setinde birinci sınıfa ait 1000 örnek, ikinci sınıfa ait 1000 örnek ve üçüncü sınıfa ait 1000 örnek olması durumunda bu veri dengeli veri seti olarak değerlendirilmektedir. Bizim veri setimizde ise en çok örneğe sahip Kredi Raporlama sınıfı tüm örneklerin %56,1'i tarafından temsil edilirken, en az örneğe sahip Perakende Bankacılık sınıfı tüm örneklerin %8,3'ü tarafından temsil edilmektedir. Benzer bir şekilde diğer sınıflar arasında da farklılıklar bulunmaktadır. Bu yapı ile veri setimiz dengesiz bir veri seti olarak değerlendirilmiş ve bu nedenle doğruluk oranı değerinin model performansını değerlendirmede yeterli olmayacağı ön görülmüştür. Önerilen modelleri farklı açılardan değerlendirmek için tablo 3'te gösterilen doğruluk oranının yanı sıra kesinlik (precision), f1-skoru ve rok eğrisi altında kalan alan (auc) değerleri de hesaplanmıştır. Doğruluk oranı değeri, modelin validasyon veri setinde doğru tahmin ettiği örnek sayısının, validasyon veri setindeki toplam örnek sayısına bölünmesi ile elde edilmiştir. Kesinlik metriği, doğru olarak tahmin edilen pozitif örneklerin tüm tahmin edilen pozitif örnekler içindeki oranını ölçmektedir. F1-skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalamasını temsil etmektedir. Auc ise çizilen rok eğrinin altında kalan alanın hesaplanması ile elde edilmektedir.

Tablo 3: Önerilen Modellerin Performans Metrik Skorları

Model Adı	Doğruluk Oranı	Kesinlik	F1-skoru	AUC
DeepCusComp-1	85.83%	88.42%	82.08%	96.73%
DeepCusComp-2	85.20%	87.67%	80.79%	96.59%
DeepCusComp-3	84.30%	86.57%	79.85%	96.06%
DeepCusComp-4	84.19%	86.46%	80.14%	95.92%

Çalışmamızda çoklu sınıf tahmini yapıldığı için kesinlik değeri hesaplamada makro ortalama ve auc skoru hesaplamada bire karşı kalan (one-versus-rest) yaklaşımları kullanılmıştır. Tablodaki sonuçlar incelendiğinde tüm metrik değerlerinde en başarılı modelin DeepCusComp-1 olduğu gözlemlenmektedir. Bu model tüm metrik skorları için %82'den daha iyi sonuçlar elde etmiştir. Tüm modeller ele alındığında DeepCusComp-3 modelinin f1-skoru dışındaki tüm skorların %80'den daha iyi olduğu tablodaki sonuçlardan elde edilmektedir.

4.4. Model Karşılaştırması

Önermiş olduğumuz modelin, geçerliliğinin yüksek olması için literatürdeki çalışmalardan daha iyi sonuç elde etmesi büyük önem arz etmektedir. Makine öğrenmesi tabanlı modeller kullanılarak elde edilen sonuçlar, kullanılan veri setine bağlı olarak büyük değişiklikler gösterebilmektedir. Bu nedenle model karşılaştırılması yapılırken aynı ya da yüksek benzerlik oranına sahip veri setleri ile yapılan çalışmaların kullanılması, adil bir karşılaştırma için gereklidir. Bu bağlamda çalışma ile önermiş olduğumuz model, Shobana ve diğerleri ile Kohler ve diğerleri tarafından önerilen iki model ile karşılaştırılmıştır (Kohler vd., 2020; Shobana vd., 2022). Tablo 4 her iki çalışma tarafından elde edilen ve önerdiğimiz model tarafından elde edilen başarı oranlarını göstermektedir. Bu iki modelin seçilme nedeni çalışmalarda, önerdiğimiz modeli eğitmek kullandığımız veri seti ile benzer veri setlerinin kullanılmasıdır.

Tablo 4: Önerilen Model ile Literatürdeki Modellerin Performans Karşılaştırması

Model Adı	Doğruluk Oranı	Kesinlik	F1-skoru
Shobana v.d. (2022)	%82.32	%81.89	%81.78
Kohler vd. (2020)	%85	-----	-----
Çalışmada Önerilen Model	%85.83	%88.42	%82.08

Tablo 4’deki sonuçlar incelendiğinde modelimizin her iki yöntemden de daha iyi sonuç elde ettiği görülmektedir. Bunun yanı sıra Kohler ve diğerleri tarafından çalışma detaylı olarak incelendiğinde validasyon ve test başarı oranları arasında ciddi farklılıklar olduğu görülmektedir. Şekil 2’de görüleceği üzere bizim modelimizde ise bu fark çok fazla değildir. Bu nedenle önermiş olduğumuz modelin, Kohler ve diğerleri tarafından önerilen modelden daha dirençli (robust) olduğu kanısına varılmaktadır.

5. SONUÇ VE ÖNERİLER

Günümüzde işletmeler en az nicel veriler kadar sözel verilerin analizinin de işletme kararlarında önemli olduğunun farkına varmışlardır. Bu sözel verilerden biri olan şikâyetler ise işletmelerin sürdürülebilirliği sağlama noktasında göz ardı edemeyecekleri kadar hayati öneme sahip bir veri kaynağı olma özelliği taşımaktadır. Dolayısıyla işletmeye gelen her bir şikâyetin hızlı bir şekilde işlenmesi ve işletmenin kullanacağı bilginin bu şikâyetten çıkarılması gerekmektedir. Öte yandan şikâyetin tüketiciler nezdinde önemini anlaşılması ve tüketicilerin işletmeler karşısında dijital platformlardaki yayılım etkisinden hareketle kazandığı güç, Tuna vd. (2021) tarafından ifade edildiği üzere müşterilerden gelen net birer memnuniyet geri bildirimini olan şikâyetin doğru sınıflandırılmasını ve anlaşılmasını zorunlu kılmaktadır.

Her ne kadar müşteri şikâyetlerinin manuel olarak değerlendirilmesi mümkün olsa da günümüz işletmelerine gelen şikâyetlerin değerlendirilmesi noktasında bilgisayar teknolojileri doğrultusunda geliştirilmiş modern yöntemlerin kullanımını gerekli kılmaktadır. Daha geniş bir perspektiften bakıldığında, her ne kadar bu yöntemler bilgisayar bilimleri kapsamında yoğun bir şekilde kullanılsa da sosyal bilimler alanındaki (ve dolayısıyla pazarlama ve tüketici davranışları kapsamındaki) problemlere uygulanması yeni yeni yaygınlaşmaktadır. Bu noktada hem yerli (Demirel & Şen, 2023; Kaynar vd., 2017; Sezgin & Duman, 2023; İlkuçar & Artun, 2023) hem de yabancı literatürün (Erkayman vd., 2023; Kohler vd., 2020; Shobana vd., 2022; Tahsin vd., 2023) yoğun bir şekilde bu yöndeki tekniklerden makine öğrenmesine odaklandığı görülmektedir. Öte yandan yerli literatürde, bahsedilen yenilikçi ve bilgisayar tabanlı yöntemlerden daha az çalışılan biri olan evrşimsel sinir ağları ile yapılan ve işletme alanını kapsayan çok az sayıda çalışma bulunmaktadır (bkz. Karataş vd., 2023). Her ne kadar yabancı literatürde kimi örneklerine rastlansa da (bkz. Kohler vd., 2020; Shobana vd., 2022), yerli literatürde tüketici davranışlarından şikâyetleri ve bunların evrşimsel sinir ağları ile yönetilmesini konu edinen herhangi bir çalışmaya rastlanamamıştır. Bu durum, çalışmanın, özgünlüğünü ve yerli literatürdeki gelişmelere öncülük etmesi noktasında sahip olduğu önemi derinleştirmektedir. Dolayısıyla araştırmanın pazarlama ve tüketici davranışları problemlerine derin öğrenme ve evrşimsel sinir ağları gibi bilgisayar bilimlerine dair modern yöntemleri uygulayacak araştırmalara rehberlik edeceği (ve doğal olarak çokça refere edileceği) düşünülmektedir.

Mevcut çalışmanın birtakım kısıtlılıkları bulunmaktadır. Bu kısıtlılıklardan biri araştırmada yabancı dildeki hazırlanmış ikincil veri seti kullanılmış olmasıdır. Çalışmanın sahip olduğu bu kısıt, yerli literatürün ilgisi bu yöne kaydıkça, yerli şikâyet metin

derlemlerinin oluşturulabileceği ve bu yönde çalışmaların yapılabilmesi sonucuna işaret etmektedir. Çalışmadaki bir diğer kısıt, şikâyetin belirli bir yöndeki (finansal) müşteri şikâyetlerini içermesidir. Dolayısıyla ilerideki araştırmalar, farklı sektörlerdeki işletmelerin tüketicilerinin (bkz. Tahsin vd., 2023) ya da yabancı literatürde de yer aldığı gibi farklı devlet kurumlarının tüketicileri sayılabilecek vatandaşların (bkz. Sun vd., 2019) şikâyetlerine ve bu şikâyetlerin yenilikçi yöntemlerle çözümüne ve yönetimine odaklanabilirler.

Pazarlama ve tüketici davranışlarındaki güncel trend, tüketici davranışlarını anlamada ve müşteri ilişkileri yönetimi performansını artırmada klasik istatistiksel tekniklerden ziyade makine öğrenmesi ve derin öğrenme gibi analiz yöntemlerinin kullanılması yönünde gelişim göstermektedir (bkz. Hakami vd., 2022; Qianyu, 2021; Ghosal & Prasad, 2023; Lang & Rettenmeier, 2017). Hatta müşteri şikâyetleri üzerine yapılan derin öğrenme çalışmalarının da nadir olmasıyla birlikte global literatürün odağına oturmaya başladığı da açıkça görülmektedir (Oyewola vd., 2023; Shivaprasad, 2020; Vairetti vd., 2024). Bahsedilen trendin temel sebebi işletmelerin veri destekli kararlar almasını sağlayan büyük veri uygulamalarının analizinde gelişmiş tekniklerin kullanılmasının zorunluluğudur. Bu tarz yöntemlerin kullanıldığı analizlerin bilişim ve mühendislik kökenli yöntemlerden oluşması her ne kadar interdisipliner yazım zorluklarını beraberinde getirirse de işletme yönlü çalışmalara yeni yeni uyarlanması ve trendin bu yönde ilerleyeceğinin erken tespiti açısından çalışmanın literatürdeki önemli bir boşluğu doldurduğu düşünülmektedir. Nitekim bahsedilen trend, tüketici psikolojileri ve tipolojileri üzerine yapılan klasik araştırmaların büyük ölçüde değişime uğrayacağına ve derin öğrenme gibi üst düzey analiz tekniklerinin kullanıldığı yeni paradigmalara dönüşeceğine işaret etmektedir (Ghosal & Prasad, 2023). Dolayısıyla ileride yapılacak araştırmaların işletme ve hatta tüketici bazında yapılacak detaylı analizlerle (örneğin duygu analizi) birleştirilecek karma yöntemleri benimsemesinin ve böylelikle bahsedilen geçiş sürecini yumuşatılmasıyla ve benimsenecek interdisipliner yapının belirgin bir avantaja dönüşebileceği düşünülmektedir. Ayrıca şikâyette bulunan tüketicilerin bireysel algılarını araştırarak araştırmaların sonuçlarıyla karşılaştırılmalı olarak sunulacak gelecek araştırmalarının şikâyetin niteliği hakkında derinlemesine bilgi sunabileceği düşünülmektedir. Bu anlamda mevcut çalışma gibi bilişim temelli çalışmaların birey bazında şikâyetleri değerlendiren araştırmaların bulgularının yarattığı etkiyi derinleştireceği düşünülmektedir.

Kaynakça

- Alamsyah, D. P., Arifin, T., Ramdhani, Y., Hidayat, F. A., & Susanti, L. (2022). Classification of customer complaints: TF-IDF approaches. 2022 2nd International Conference on Intelligent Technologies (CONIT), 1-5. <https://doi.org/10.1109/CONIT55038.2022.9848056>
- Aldunate, Á., Maldonado, S., Vairetti, C., & Armelini, G. (2022). Understanding customer satisfaction via deep learning and natural language processing. *Expert Systems with Applications*, 209, 118309. <https://doi.org/10.1016/j.eswa.2022.118309>
- Ali Hakami, N., & Hosni Mahmoud, H. A. (2022). Deep learning analysis for reviews in Arabic e-commerce sites to detect consumer behavior towards sustainability. *Sustainability*, 14(19), 12860.
- Anagun, Y., Bolel, N. S., Isik, S., & Ozkan, S. E. (2022). Deep learning-based customer complaint management. *Journal of Organizational Computing and Electronic Commerce*, 32(3-4), 217-231. <https://doi.org/10.1080/10919392.2023.2210049>
- Cho, Y., Im, I., Hiltz, R., & Fjermestad, J. (2002). An analysis of online customer complaints: Implications for web complaint management. *Proceedings of the 35th Annual Hawaii*

- International Conference on System Sciences, 2308-2317. <https://doi.org/10.1109/HICSS.2002.994162>
- Correa, N., & Correa, A. (2022). Neural text classification for digital transformation in the financial regulatory domain. 2022 IEEE ANDESCON, 1-6. <https://doi.org/10.1109/ANDESCON56260.2022.9989638>
- Demirel, G. K., & Şen, A. (2023). Makine öğrenmesi tekniklerinin bütçe verimliliğine uygulanması üzerine bir çalışma. *İşletme Araştırmaları Dergisi*, 15(2), 953-969.
- DiCarlo, M., Berglund, E. Z., Kaza, N., Grieshop, A., Shealy, L., & Behr, A. (2023). Customer complaint management and smart technology adoption by community water systems. *Utilities Policy*, 80, 101465. <https://doi.org/10.1016/j.jup.2022.101465>
- Erkayman, B., Erdem, E., Aydın, T., & Mahmat, Z. (2023). New artificial intelligence approaches for brand switching decisions. *Alexandria Engineering Journal*, 63, 625-643. <https://doi.org/10.1016/j.aej.2022.11.043>
- Ferri, E. (2018). The evolving practice of complaint management. *Bloomberg Law*, 1-8.
- Financial Ombudsman Service (2023). Annual complaints data and insight 2022/23. <https://www.financial-ombudsman.org.uk/data-insight/annual-complaints-data/annual-complaints-data-insight-202223> Erişim Tarihi: 17.08.2023.
- Ghosal, I., & Prasad, B. (2023). Transforming consumer behavior to new paradigms through deep learning applications. *International Journal of Advances in Business and Management Research (IJABMR)*, 1(1), 26-29.
- Gormez, Y., Aydın, Z., Karademir, R., & Gungor, V. C. (2020). A deep learning approach with Bayesian optimization and ensemble classifiers for detecting denial of service attacks. *International Journal of Communication Systems*, 33(11), e4401. <https://doi.org/10.1002/dac.4401>
- Harrison, R., Walton, M., Healy, J., Smith-Merry, J., & Hobbs, C. (2016). Patient complaints about hospital services: Applying a complaint taxonomy to analyse and respond to complaints. *International Journal for Quality in Health Care*, 28(2), 240-245. <https://doi.org/10.1093/intqhc/mzw003>
- Hayuningrum, V. (2021). Customer complaints auto-categorization: performance comparison of recurrent and convolutional neural networks, Master's Thesis in Data Science & Society, Tilburg University.
- İlkuçar, M., & Artun, C. (2023). Misafir yorumlarının makine öğrenmesi yardımıyla duygu analizi: Fethiye beş yıldızlı oteller örneği. *Journal of Business in the Digital Age*, 6(1), 33-41.
- Jain, P. K., Saravanan, V., & Pamula, R. (2021). A hybrid cnn-lstm: a deep learning approach for consumer sentiment analysis using qualitative user-generated contents. *ACM Transactions on Asian and Low-Resource Language Information Processing*, 20(5), 84:1-84:15. <https://doi.org/10.1145/3457206>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695. <https://doi.org/10.1007/s12525-021-00475-2>
- Karataş, A. F., Mercan, Ö. B., Özdil, U., & Ozan, Ş. (2023). Çağrı merkezlerinde olumsuzluk içeren çağrıların evrşimsel sinir ağları ile tespiti. *Bilişim Teknolojileri Dergisi*, 16(1), 13-19. <https://doi.org/10.17671/gazibtd.1156330>
- Kaynar, O., Tuna, M. F., Görmez, Y., & Devenci, M. A. (2017). Makine öğrenmesi yöntemleriyle müşteri kaybı analizi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(1), 1-14.
- Keramati, A., Ghaneei, H., & Mirmohammadi, S. M. (2016). Developing a prediction model for customer churn from electronic banking services using data mining. *Financial Innovation*, 2(1), 10. <https://doi.org/10.1186/s40854-016-0029-6>

- Keras. (2023). Keras: Deep learning for humans. <https://keras.io/> Erişim Tarihi: 25.07.2023.
- Khedkar, S., & Shinde, S. (2020a). Deep learning and ensemble approach for praise or complaint classification. *Procedia Computer Science*, 167, 449–458. <https://doi.org/10.1016/j.procs.2020.03.254>
- Khedkar, S., & Shinde, S. (2020b). Deep learning-based approach to classify praises or complaints from customer reviews. In S. Bhalla, P. Kwan, M. Bedekar, R. Phalnikar, & S. Sirsikar (Eds.), *Proceeding of International Conference on Computational Science and Applications* (pp. 391–402). Springer. https://doi.org/10.1007/978-981-15-0790-8_38
- Kohler, M., Sondermann, L., Forero, L., & Pacheco, M. A. (2020). Classifying and grouping narratives with convolutional neural networks, PCA and t-SNE. In A. M. Madureira, A. Abraham, N. Gandhi, & M. L. Varela (Eds.), *Hybrid Intelligent Systems* (pp. 22–30). Springer International Publishing. https://doi.org/10.1007/978-3-030-14347-3_3
- Lang, T., & Rettenmeier, M. (2017, April). Understanding consumer behavior with recurrent neural networks. In *Workshop on Machine Learning Methods for Recommender Systems*.
- Meyer-Waarden, L., & Sabadie, W. (2023). Relationship quality matters: How restaurant businesses can optimize complaint management. *Tourism Management*, 96, 104709. <https://doi.org/10.1016/j.tourman.2022.104709>
- Oyewola, D. O., Omotehinwa, T. O., & Dada, E. G. (2023). Consumer complaints of consumer financial protection bureau via two-stage residual one-dimensional convolutional neural network (TSR1DCNN). *Data and Information Management*, 100046. <https://doi.org/10.1016/j.dim.2023.100046>
- Peker, S. (2022). Predicting firms' performances in customer complaint management using machine learning techniques. In C. Kahraman, A. C. Tolga, S. Cevik Onar, S. Cebi, B. Oztaysi, & I. U. Sari (Eds.), *Intelligent and Fuzzy Systems* (pp. 280–287). Springer International Publishing. https://doi.org/10.1007/978-3-031-09176-6_33
- Qianyu, Z., Dongping, L., & Xiaozhou, Z. (2021, June). Research on financial consumer behavior based on deep Learning. In *2021 International Conference on Big Data Analysis and Computer Science (BDACS)* (pp. 179-182).
- Salama, A., Hassanien, A. E., & Fahmy, A. (2019). Sheep identification using a hybrid deep learning and bayesian optimization approach. *IEEE Access*, 7, 31681–31687. <https://doi.org/10.1109/ACCESS.2019.2902724>
- Salminen, J., Mustak, M., Corporan, J., Jung, S., & Jansen, B. J. (2022). Detecting pain points from user-generated social media posts using machine learning. *Journal of Interactive Marketing*, 57(3), 517–539. <https://doi.org/10.1177/10949968221095556>
- Sci-Kit Optimize (2023). Scikit-optimize: Sequential model-based optimization toolbox. <https://scikit-optimize.github.io/> Erişim Tarihi: 27.07.2023.
- Sezgin, M., & Duman, A. (2023). Elektronik ağızdan ağıza pazarlama kapsamında konaklama işletmelerine yönelik çevrimiçi yorumların duygu analizi yöntemiyle incelenmesi: Alanya örneği. *Türk Turizm Araştırmaları Dergisi*, 7(2), 244-265. <https://doi.org/10.26677/TR1010.2023.1240>
- Seymen, O. F., Ölmez, E., Doğan, O., Er, O., & Hiziroğlu, K. (2023). Customer churn prediction using ordinary artificial neural network and convolutional neural network algorithms: A comparative performance assessment. *Gazi University Journal of Science*, 36(2), Article 2. <https://doi.org/10.35378/gujs.992738>
- Shin, J., Son, S., & Cha, Y. (2022). Spatial distribution modeling of customer complaints using machine learning for indoor water leakage management. *Sustainable Cities and Society*, 87, 104255. <https://doi.org/10.1016/j.scs.2022.104255>

- Shivaprasad, V. (2020). Analysis of customer complaint data of consumer financial protection bureau using different text mining techniques (Doctoral dissertation, Dublin Business School).
- Shobana, G., Sanjay, S. S., Saran, V., & Vardan, G. K. (2022). Consumer grievance handler. 2022 IEEE 3rd Global Conference for Advancement in Technology (GCAT), 1-5. <https://doi.org/10.1109/GCAT55367.2022.9971905>
- Singh, A., Saha, S., Hasanuzzaman, Md., & Dey, K. (2022). Multitask learning for complaint identification and sentiment analysis. *Cognitive Computation*, 14(1), 212-227. <https://doi.org/10.1007/s12559-021-09844-7>
- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical bayesian optimization of machine learning algorithms. *Advances in Neural Information Processing Systems*, 25. <https://proceedings.neurips.cc/paper/2012/hash/05311655a15b75fab86956663e1819cd-Abstract.html>
- Statista Research Department (2023). Company responses to consumer complaints to the Consumer Financial Protection Bureau (CFPB) in the United States in 2019, by response type <https://www.statista.com/statistics/1105735/company-response-consumer-complaint-cfpb-usa/> Erişim Tarihi: 17.08.2023.
- Strasser, T. (2023). Don't trust the machine? Der fremdsprachliche unterricht englisch, 2023(184), 20-27.
- Sun, L., Yan, H., Xin, K., & Tao, T. (2019). Contamination source identification in water distribution networks using convolutional neural network. *Environmental Science and Pollution Research*, 26(36), 36786-36797. <https://doi.org/10.1007/s11356-019-06755-x>
- ŞikayetVar (2023). Tüm şikâyetler <https://www.sikayetvar.com/sikayetler> Erişim Tarihi: 17.08.2023.
- Tahsin, M. U., Shanto, M. S. H., & Rahman, R. M. (2023). Combining natural language processing and federated learning for consumer complaint analysis: A case study on laptops. *SN Computer Science*, 4(5), 537. <https://doi.org/10.1007/s42979-023-01989-6>
- Tiwari, S. (2021). Consumer complaints dataset for NLP. Consumer complaints dataset for NLP-Kaggle. <https://www.kaggle.com/datasets/shashwatwork/consume-complaints-dataset-fo-nlp>, Erişim Tarihi: 25.07.2023.
- Tuna, M. F., Akdoğan, Ş., & Kaynar, O. (2021). Otellere ilişkin yorum dışı müşteri geri bildirimlerinin analizi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 22(2), 50-81. <https://doi.org/10.37880/cumuiibf.869489>
- Vairetti, C., Aránguiz, I., Maldonado, S., Karmy, J. P., & Leal, A. (2024). Analytics-driven complaint prioritisation via deep learning and multicriteria decision-making. *European Journal of Operational Research*, 312(3), 1108-1118.
- Yang, W., Tan, L., Lu, C., Cui, A., Li, H., Chen, X., Xiong, K., Wang, M., Li, M., Pei, J., & Lin, J. (2019). Detecting customer complaint escalation with recurrent neural networks and manually-engineered features. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 2 (Industry Papers)*, 56-63. <https://doi.org/10.18653/v1/N19-2008>

Etik Beyanı: Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder. Aksi bir durumun tespiti halinde BİİBFAD Dergisinin hiçbir sorumluluğu olmayıp, tüm sorumluluk çalışmanın yazarlarına aittir.

Yazar Katkıları: Murat Fatih TUNA, çalışmada konunun belirlenmesi, literatür taraması, giriş bölümünün oluşturulması ve sonuçların yorumlanması bölümlerinde katkı sağlamıştır. Yasin GÖRMEZ, veri analizi, sonuçların elde edilmesi, yöntemlerin belirlenmesi ve sonuçların literatür ile karşılaştırılması aşamalarında katkı sağlamıştır. 1. yazarın katkı oranı yaklaşık olarak %50, 2. yazarın katkı oranı ise %50'tir

Çıkar Beyanı: Yazarlar arasında çıkar çatışması yoktur.

Teşekkür: Gösterdikleri yoğun ilgi ve emeklerinde dolayı BİİBFAD Dergisi Editör Kurulu'na ve sağladıkları katkılarında dolayı hakemlere teşekkür ederiz. Bu araştırmada yer alan tüm/kısmi nümerik hesaplamalar TÜBİTAK ULAKBİM, Yüksek Başarım ve Grid Hesaplama Merkezi'nde (TRUBA kaynaklarında) gerçekleştirilmiştir.

Classification of Customer Complaints using Convolutional Neural Network Based Deep Learning Method

Extended Abstract

Aim: The information gathered from the literature review conducted within the scope of this study underscores the significance of complaint management processes employing deep learning methods and the advantages they offer to businesses. Furthermore, the relevance of recent publications suggests that research in this field highlights a relatively novel and promising academic gap with room for further development. To address this, the study aims to employ convolutional neural networks effectively within the complaint management process. Through the utilization of a unique model designed for this purpose, the objective is to classify customer complaints with a reduced error rate. Consequently, the aim is to enhance complaint management processes, which represent a sub-discipline of customer relations management.

Method(s): In this study, four distinct original deep learning models were developed, each utilizing different numbers of convolutional neural network layers. What sets these models apart from one another is the varying number of convolutional neural network layers employed. In the realm of deep learning methods, the values of hyperparameters are of paramount importance during the training process. Therefore, the hyperparameter values for the deep learning models proposed in this study were fine-tuned using the Bayesian optimization method. The study involved training and testing these models using the 'Consumer Complaints Dataset for NLP,' which was generously shared as an open-source resource on the Kaggle platform. For all aspects of model training and hyperparameter optimization, the Keras and skopt libraries, available in Python, were employed.

Findings: Accuracy is among the most frequently used metrics for assessing model performance in machine learning methods. However, it alone is not sufficient for evaluating models on unbalanced datasets. The dataset utilized in our study was indeed unbalanced, which led us to anticipate that accuracy alone would not adequately evaluate model performance. To comprehensively assess the proposed models, we calculated additional metrics such as precision, F1-score, and the area under the receiver operating characteristic curve (AUC). Given that our study involved multi-class prediction, we employed the macro-average for precision calculations and the one-versus-rest approach for AUC score calculations. Upon reviewing the results, it becomes evident that the most successful model across all metric values is DeepCusComp-1, achieving results exceeding 82% across all metrics. When considering all models, the results table reveals that, except for the F1-score of DeepCusComp-3, all scores exceed 80%. It is of paramount importance for the model we propose to outperform previous studies in the literature in order to establish its high validity. Machine learning-based model results can vary significantly based on the dataset employed. Therefore, for a fair comparison, it is imperative to compare models using datasets that are either the same or highly similar. In this context, our model, proposed in this study, was compared with two similar models. Upon examining the comparison results, it is evident that our model outperforms both methods. Furthermore, upon closer examination of the first compared study, significant differences between validation and test success rates are observed. In contrast, our model exhibits less difference between these rates. Consequently, it is concluded that the model we propose demonstrates greater resilience than other models.

Conclusion and Discussion: In recent times, businesses have come to recognize that the analysis of verbal data is just as crucial as quantitative data in making informed business decisions. Complaints, a form of verbal data, represent a vital information source that

businesses cannot afford to overlook when striving for sustainability. Consequently, each complaint received by a business should be promptly addressed, and valuable insights for the business should be extracted from these complaints. Moreover, acknowledging the significance of complaints for consumers and the influence consumers wield over businesses due to the amplifying effect of digital platforms underscores the importance of accurately classifying and comprehending complaints, which often serve as clear indicators of customer satisfaction. While manual evaluation of customer complaints is possible, modern methods aligned with computer technologies have become indispensable for assessing complaints received by contemporary businesses. In a broader context, although these methods have found extensive use within the realm of computer science, their application to issues in the social sciences is only now gaining traction. A thorough examination of the literature deepens the uniqueness and underscores the pioneering role of this study in domestic literature. As a result, we believe that this research will serve as a guide for future studies that aim to apply modern computer science methods, such as deep learning and convolutional neural networks, to challenges in marketing and consumer behavior. Nevertheless, the current study does have some limitations. One of these limitations is the use of a secondary dataset prepared in a foreign language. This limitation suggests that, as interest in domestic literature grows in this direction, domestic collections of complaint texts can be established, and research can progress in this area. Another limitation is that the study focuses solely on complaints within a specific sector (financial). Therefore, future research could center on complaints from consumers in various industries or individuals who can be considered consumers of different government institutions, as indicated in foreign literature. Such research could explore innovative methods for addressing and managing these complaints.