

Müşteri Duyarlılığını Keşfetmek İçin Yapay Zeka Destekli Analiz ile Çevrimiçi Ürün İncelemelerinden Anlamlı Bilgiler Elde Etme

Özge CÖMERT^{1*}, Nurcan YÜCEL²

¹ Ulaştırma Hizmetleri Bölümü, Teknik Bilimler Meslek Yüksekokulu, Samsun Üniversitesi, Samsun, Türkiye

² İşletme Bölümü, İktisadi ve İdari Bilimler Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

*¹ ozge.comert@samsun.edu.tr, ² nyucel@firat.edu.tr

(Geliş/Received: 29/05/2023;

Kabul/Accepted: 18/07/2023)

Öz: E-Ticaret, internet aracılığıyla ürün ve hizmetlerin alım-satım işlemlerinin gerçekleştirildiği bir dijital ticari model olarak bilinmektedir. İnternetin yaygınlaşması ve internete erişimin kolaylaşması ile e-ticaret, daha geniş bir müşteri kitlesine ulaşma, maliyetleri azaltma ve işlem hızını artırma gibi avantajları nedeniyle günümüz iş dünyasında vazgeçilmez bir rol oynamaktadır. E-Ticaret sitelerindeki müşteri ürün incelemeleri, işletmeler açısından önemli bir pazarlama aracı olarak görülmektedir. Doğru yönetildiğinde, olumlu ürün incelemeleri satışları artırırken; olumsuz incelemeler ise potansiyel müşterilerin kaybına yol açabilmektedir. Bununla birlikte, müşteri ürün incelemeleri ürün kalitesi ve müşteri hizmeti hakkında fikir vermekle birlikte, güvenilirliği ve müşteri sadakatini arttırmaktadır. Bu nedenle, e-ticaret sitelerinin müşteri ürün incelemelerini dikkate almaları, doğru bir şekilde yönetmeleri ve müşteri memnuniyetini arttırmak için geri bildirimlere dikkat etmeleri gerekmektedir. Bu çalışmada, çevrimiçi müşteri ürün incelemelerinden anlamlı bilgiler elde etmek için yapay zekâ destekli bir analiz gerçekleştirilip, müşteri duyarlılığı keşfedilmektedir. Bu kapsamda, e-ticaret sitelerinde herkese açık olarak yayımlanmış olan ve toplamda 2000 adet müşteri incelemesi içeren bir veri seti araştırma kapsamında oluşturuldu. Oluşturulan veri seti üzerinde müşteri duyarlılığını analiz etmek üzere, derin öğrenme modellerinden biri olan Uzun Kısa Süreli Bellek (LSTM) modeli ve metin kodlamaya dayalı yeni bir model önerisi yapıldı. Denetimli öğrenme yaklaşımı ile geliştirilen model üzerinde yapılan analizler neticesinde %91,50 doğruluk elde edildi. Bir başka ifadeyle, müşteri duyarlılığını oldukça yüksek bir doğruluk oranı ile tahmin edebilen, yüzlerce hatta binlerce müşteri incelemesinin yer aldığı ürün sayfalarında, bu incelemelerden anlamlı sonuçlar üretebilen bir yapay zekâ modeli geliştirildi. Çalışmada, işletmelerin müşteri memnuniyetini arttırmak, çeşitli ürün pazarlama stratejileri geliştirmek, çevrimiçi pazarlama süreçlerini yönetmek ve farklı iş modelleri uygulamak üzere yapay zekâ destekli algoritmalarından faydalanılabileceğine işaret etmektedir.

Anahtar kelimeler: E-ticaret, duyarlılık analizi, makine öğrenmesi, sınıflandırma

Mining Meaningful Insights from Online Product Reviews with AI-Powered Analytics to Discover Customer Sentiment

Abstract: E-Commerce is a digital commercial model in which the purchase and sale of products and services are realized through the internet. With the widespread use of the Internet and easier access to the Internet, e-commerce has an essential role in today's business world due to its advantages such as reaching a wider customer base, reducing costs and increasing transaction speed. Customer product reviews on e-commerce sites are an important marketing tool for companies. When managed correctly, positive product reviews can increase sales, while negative reviews can lead to the loss of potential customers. In addition, customer product reviews provide insight into product quality and customer service, and increase trustworthiness and customer loyalty. Therefore, e-commerce sites need to consider customer product reviews, manage them properly, and pay attention to feedback to increase customer satisfaction. This study explores customer sentiment by performing an artificial intelligence-supported analysis to extract meaningful information from online customer product reviews. In this context, a dataset containing a total of 2000 customer reviews published publicly on e-commerce sites was created within the scope of the research. In order to analyze customer sentiment on the created dataset, a new model based on the Long Short Term Memory (LSTM) model, one of the deep learning models, and text encoding was proposed. As a result of the analysis on the model developed with the supervised learning approach, 91.50% of accuracy was obtained. In other words, an artificial intelligence model that can predict customer sentiment with a very high accuracy rate and produce meaningful results from these reviews on product pages with hundreds or even thousands of customer reviews has been developed. This study indicates that businesses can benefit from artificial intelligence-supported algorithms to increase customer satisfaction, develop various product marketing strategies, manage online marketing processes and implement different business models.

Key words: E-commerce, sentiment analysis, machine learning, classification.

* Sorumlu yazar: ozge.comert@samsun.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0001-7419-1848, ² 0000-0002-6845-1284

1. Giriş

E-ticaret, ticari faaliyetlerin internet üzerinden yürütülmesi ve bu şekilde ürünlerin ve hizmetlerin dijital olarak pazarlanması, satışını ve teslimatını kapsayan ticari bir iş modelidir [1]. Bu iş modeli, alışveriş sürecinin dijital olarak gerçekleşmesine imkân vermekte ve tüketicilere kolay, hızlı ve güvenli bir alışveriş deneyimi sunmaktadır. E-ticaret iş modelleri, çeşitli türdeki ürünlerin ve hizmetlerin pazara sunulmasını sağlamakta ve tüketicilerin ihtiyaçlarını giderebileceği ürünlere ve hizmetlere daha kolay bir şekilde erişmelerine olanak vermektedir [2]. İnternet kullanımının yaygınlaşması, internete erişimin kolaylaşması, mobil cihazların ve mobil uygulamaların sayısının artması, avantajlı fiyatlar, 7/24 kesintisiz hizmetlerin sağlanması, ürün seçeneklerinin ve alternatiflerinin sunulması, kolay iade opsiyonu vb. birçok etki ile birlikte e-ticaretin giderek artan bir şekilde tercih edildiği görülmektedir [3].

İşletmeler, rekabet güçlerini geliştirmek ve müşterilerinin gereksinimlerini karşılamak için geri bildirim toplama ve analiz etme işlemine giderek daha fazla önem vermektedir. Müşterilerin geri bildirimleri, işletmelerin ürünlerini ve hizmetlerini geliştirmelerine, müşteri memnuniyetini artırmalarına ve müşteri sadakatini sağlamalarına yardımcı olmaktadır [4]. Bu amaçla işletmeler destek hatları, anketler, şikâyet formları ve sosyal medya etkileşimleri kullansalar da; bu çerçevedeki en önemli veri kaynaklarından biri de ürünlere yapılan çevrimiçi müşteri yorumları bir başka ifadeyle çevrimiçi müşteri ürün incelemeleridir. Müşteri ürün incelemeleri, ürünlerin kalitesi, performansı, fiyatı ve müşteri hizmetleri gibi konularda işletmelere değerli bilgiler sağlamaktadır. Ayrıca, ürünlerin diğer müşteriler tarafından satın alma davranışlarını da etkileyebilmektedir. Müşteriler, ürünleri satın almadan önce ürünün kalitesi, performansı ve kullanıcı deneyimi hakkında bilgi sahibi olmak isteyebilmektedir. Müşteri yorumları, ürün hakkında farklı bakış açıları sunarak, diğer müşterilerin satın alma kararını etkileyebilmektedir. Olumlu yorumlar, ürünün satın alınmamasına neden olabilmektedir. Ağızdan ağıza elektronik iletişim (word of mouth) kavramı ile açıklanan bu durum, benzer ürünlere veya hizmetlerle ilgilenen potansiyel müşterilerin elektronik bir platform üzerinden iletişim kurması, ürünlere ya da hizmetlere ilişkin görüşlerini ve deneyimlerini paylaşmasına dayanmaktadır [5]. Dolayısıyla işletmeler, müşteri yorumlarını takip ederek, ürünlerini geliştirebilmekte ve müşteri memnuniyetini arttırabilmektedirler.

En çok kullanılan e-ticaret iş modellerine bakıldığında; İşletmeden Tüketiciciye (Business-to-Consumer B2C) e-ticaret modeli, bir işletmenin doğrudan tüketicilere ürün veya hizmet satışı yapmasıdır. Bu modelde, işletme tüketicilerle doğrudan etkileşime girer ve ürün veya hizmetlerini tüketicilere sunar. Bu tür e-ticaret, tüketicilerin internet üzerinden ürünleri veya hizmetleri kolayca satın almalarını sağlar. Amazon, eBay, Airbnb, Alibaba, Hepsiburada, Netflix, N11 ve Trendyol B2C iş modeline örnektir. Hepsiburada, N11 ve Trendyol gibi kuruluşlar B2C (işletmeden doğrudan tüketiciciye) iş modeline örnek olsa da, aynı zamanda bir B2B (işletmeden işletmeye) iş modeline de sahiptir.

Yapay zekâ teknolojileri, büyük veri kümelerindeki yorumları otomatik olarak analiz ederek, işletmelere ürünlerinin kalitesi, performansı ve müşteri memnuniyeti hakkında önemli bilgiler sağlamaktadır. Böylece işletmeler, müşteri geri bildirimlerinden daha hızlı ve etkili bir şekilde yararlanabilirler [3]. Bu çerçevede literatürde çok sayıda çalışmanın yapıldığı görülmektedir. İşletme veri tabanında yer alan müşteri yorumları örneklem seçilerek, mevcut yorumları şikâyet, talep ve teşekkür şeklinde sınıflara ayıran ve karar ağacına dayanan bir model önerisi yapılmıştır. Araştırma bulguları metin üzerinden sınıflandırma yapmak üzere karar ağaçlarının kullanılabilirliğine işaret etmektedir [6]. Bir diğer çalışmada, Kahramanmaraş'ta bulunan işletmelere yönelik yapılan müşteri yorumları dikkate alınmıştır. Bu çerçevede sosyal ağlar kategorisinde değerlendirilebilecek Tripadvisor uygulaması kullanılmıştır. Yorumlar dikkate alınarak müşteri şikâyetlerinin ağırlıklı olarak hangi kategoriler altında yer aldığı ortaya çıkarılmıştır [7]. Türkiye'nin önde gelen üç tüketici elektroniği perakende firması için yapılan şikâyetler bir diğer çalışmada dikkate alınmıştır. Bu çerçevede şikâyetlerin otomatik kategorilere ayrılması sağlanmış ve analiz gerçekleştirilmiştir. İade/değişim ve geri ödeme, teslimat/kargo, müşteri ilişkileri ve hizmetleri ve son olarak garanti ve servis olmak üzere dört kategori dikkate alınmıştır. Lojistik regresyon (LR), doğrusal destek vektör makineleri (DVM) ve olasılıksal dereceli azalma yöntemleri çalışma kapsamında kullanılmıştır. Sonuç olarak %80 doğruluk oranı ile en iyi sonuç LR algoritması ile elde edilmiştir [8]. Müşteri incelemeleri sürecinde şikâyet tespiti ve sınıflandırması için yinelemeli bir sinir ağı olan uzun kısa süreli bellek bir diğer çalışmada dikkate alınmıştır. Çalışma sonucunda F_1 puanı 0,85 olarak elde edilmiştir. Bir diğer çalışmada, ürün, film ve restoran yorumlarını içeren farklı veri setleri kullanılarak veri madenciliği teknikleriyle duygu analizi gerçekleştirilmiştir. DVM, k-en yakın komşu (k-EK), Naive Bayes, karar ağacı (KA) ve rastgele orman (RO) algoritmaları ilgili çalışmada kullanılmıştır. En iyi genelleştirme performansı DVM algoritmasıyla elde edilmiştir [9]. LR aracılığı ile faydalı tüketici yorumlarının tahmini bir diğer çalışmada dikkate alınmıştır. Türkçe metinler için önceden eğitilmiş ve BERT kütüphanesine dayanan bir model çalışmada

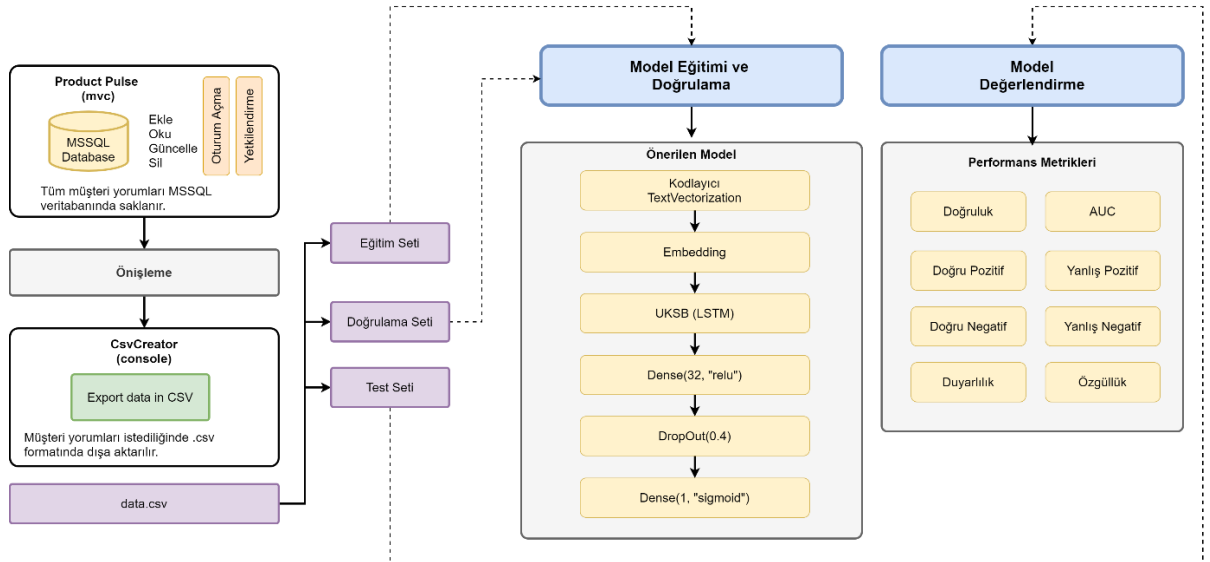
kullanılmıştır. Araştırma sonucunda %94,03 sınıflandırma doğruluğu raporlanmıştır [10]. BERTopic konu modelleme tekniği üzerinde yapılan bir araştırmada müşteri şikâyetlerinin kategorize edilmesi sağlanmıştır. Araştırma sonucunda en fazla şikâyet alanları; kargolama, televizyon, cep telefonu, dizüstü bilgisayar, kulaklık gibi ürünlere yoğunlaşmıştır [11]. Tüketici yorumları üzerinde boyut indirme yaklaşımlarına odaklanan araştırmada, tekil değer ayrışımı (TDA) ve genelleştirilmiş lineer model (GLM) dayalı bir model önerisi gerçekleştirilmiştir. Araştırma sonucunda, boyut indirgeme yaklaşımının modellerin genelleştirme performansı ortalama %6 katkı sağladığı rapor edilmiştir [12]. Sözlük tabanlı SentiTFIDF yöntemi, Türkçe otel yorumlarını içeren bir veri seti üzerinde kullanılmıştır ve araştırma sonucunda RO algoritmasıyla %89'luk bir AUC değeri rapor edilmiştir [13]. Sözlük tabanlı önerilen bir diğer araştırmada, %77,50 sınıflandırma doğruluğu rapor edilmiştir ve önerilen modelin Türkçe metinler için iyi bir genelleştirme performansı sağladığı vurgulanmıştır [14]. Bir diğer araştırmada, sosyal medya uygulamalarında kullanıcı yorumlarının sınıflandırılmasını sağlamak üzere Bayes algoritmasına dayanan bir mobil uygulama çalışması gerçekleştirilmiştir ve çalışma sonucunda %88 sınıflandırma başarımına ulaşılmıştır [15].

Bu çalışmada; müşteri duyarlılığını keşfetmek üzere yapay zeka destekli bir model sunulmaktadır. İlgili model ile aynı zamanda çevrimiçi müşteri ürün incelemelerinin analizi gerçekleştirilmektedir. Çalışma kapsamında Türkiye'de yaygın olarak kullanılan üç farklı e-ticaret sitesinden, farklı ürünler için yapılan müşteri incelemeleri toplanmıştır. Yarısı pozitif ve diğer yarısı negatif olmak üzere toplamda 2000 adet müşteri ürün incelemesinden oluşan bir veri seti araştırma kapsamında oluşturulmuştur. Oluşturulan veri seti açık erişimli olarak araştırmacıların kullanımına sunulmuştur. Bu çalışmada; öncelikle metin girdi uzunluğundan bağımsız olarak çalışabilen ve girdi metinlerini sabit bir vektör uzayında temsil eden, bir başka ifadeyle metin uzunluğundan bağımsız olarak çalışabilen bir model önerisi yapılmıştır. İlgili model, derin öğrenme algoritmalarından biri olan Uzun Kısa Süreli Bellek (LSTM) modeli üzerine inşa edilmiştir. Deneysel çalışmalar sonucunda yüksek bir genelleştirme başarımına erişilmiştir.

Bu çalışmanın geriye kalan bölümleri şu şekilde organize edilmiştir: Bölüm 2'de materyal ve metotlar özetlenmiştir. Bölüm 3'de bulgular ve tartışma gerçekleştirilmiştir. Bölüm 4'de ise sonuç cümlelerine yer verilmiştir.

2. Materyal ve Metotlar

Şekil 1'de önerilen modelin blok diyagramına yer verilmiştir. ProductPulse veri toplama aracı ile depolanan tüm müşteri yorumları yapay zeka destekli analiz öncesinde ön işleme adımından geçirilerek .csv formatına, yani virgül ile ayrılmış değerlere dönüştürülmüştür.



Şekil 1. Önerilen modelin blok diyagramı

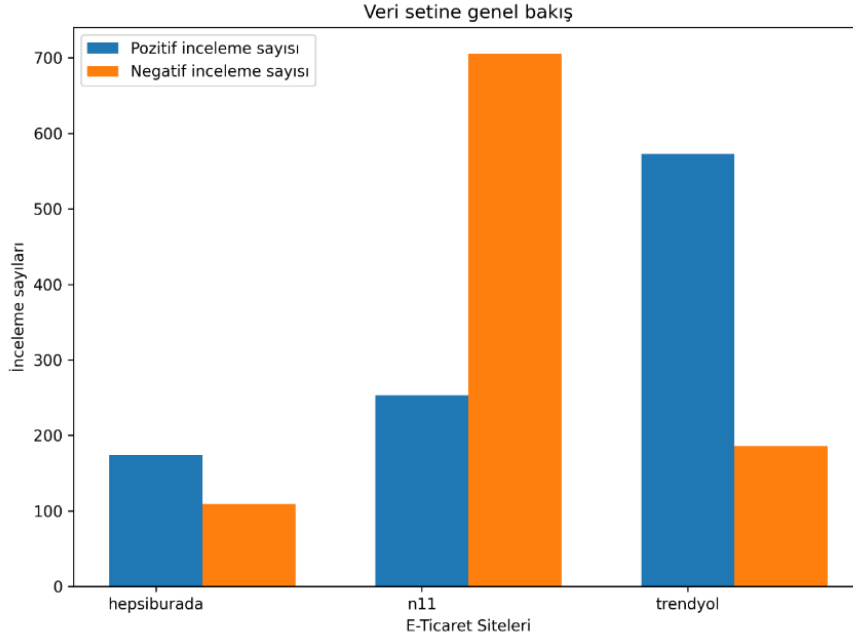
Tüm veri seti; eğitim, doğrulama ve test olmak üzere üç parçaya ayrılmıştır. Eğitim ve doğrulama setleri model eğitim aşamasında kullanılırken; test veri seti modelleri değerlendirmek üzere dikkate alınmıştır. Model geliştirme ortamı için Python dili kullanılmıştır. Google tarafından geliştirilen ve açık kaynak kodlu olan

TensorFlow (sürüm: 2.12.0) kütüphanesi model geliştirme ve değerlendirme çalışmaları kapsamında kullanılmıştır.

2.1. Veri seti

Müşteri yorumlarının (ürün incelemelerinin) toplanması model eğitimi için önemli bir adımdır. Bu adımı gerçekleştirmek için Türkiye’de tanınmış ve yaygın bir şekilde kullanılan hepsiburada.com, n11.com ve trendyol.com e-ticaret sitelerindeki gerçek müşteri yorumları dikkate alınmıştır. Tüm ürün kategorilerine yapılan müşteri yorumları rastgele seçilerek veri seti oluşturulmuştur.

Müşterilerin yorumlarını toplamak ve işlemek için "ProductPulse" adlı bir veri toplama aracı geliştirilmiştir. Bu araç ASP.NET Core MVC proje şablonu üzerine inşa edilmiştir ve verilerin kalıcı olarak depolanmasını sağlamak için MSSQL veritabanını kullanacak şekilde tasarlanmıştır. Model-View-Controller (MVC), bir mimari desendir ve web tabanlı uygulamalar geliştirirken yaygın bir şekilde kullanılmaktadır [16]. MVC deseni ile inşa edilen ProductPulse çevrimiçi olarak kullanılacak şekilde tasarlandığından, ilgili uygulama kullanılarak her an yeni müşteri yorumlarının girilmesi, var olan müşteri yorumlarının güncellenmesi ve silinmesi gibi temel işlevler internet üzerinden kolayca yapılabilmektedir. Bununla birlikte, veri güvenliğini sağlamak amacıyla geliştirilen veri toplama aracı, oturum açma ve yetkilendirme mekanizmalarıyla da donatılmıştır.



Şekil 2. Verileri dağılımı

Şekil 2’de toplanan verilerin dağılımına yer verilmiştir. Görüldüğü üzere; 1000 pozitif ve 1000 negatif olmak üzere toplamda 2000 çevrimiçi müşteri ürün incelemesi toplanmış ve dengeli bir veri seti elde edilmiştir. Bu kayıtlardan 283 tanesi hepsiburada.com’dan, 958 tanesi n11.com’dan ve 759 tanesi ise trendyol.com e-ticaret sitesinden alınmıştır. Platformlardan hepsiburada.com’dan alınan verilerin 174 tanesi pozitif iken, 109 tanesi negatif olduğu görülmüştür. Benzer şekilde, n11.com’dan alınan verilerin 253 tanesi pozitif iken, 705 tanesi negatiftir. Son olarak, trendyol.com sitesinden alınan verilerin 573 tanesi pozitif iken, 186 tanesi negatiftir.

2.2. Önişleme

Makine öğrenmesi ya da derin öğrenme gibi algoritmalar kullanılmadan önce, verinin işlenebilir hale dönüştürülmesini sağlamak üzere gerçekleştirilen işlemler önişleme olarak ifade edilir. Bu adımda, veri setindeki hatalar, eksik veriler ve aykırı değerler gibi sorunlar giderilir [17]. Önişleme adımı doğru bir şekilde yapılmadığında, sonuçlar yanıltıcı olabilir ve yanlış kararlar alınabilir. Bu nedenle, önişleme adımı, veri bilimindeki en önemli adımlardan biridir ve dikkatle yapılması gerekmektedir [18].

ProductPulse veri toplama aracı ile elde depolanan tüm müşteri yorumları yapay zeka destekli analiz öncesinde ön işleme adımından geçirilerek .csv formatına, yani virgül ile ayrılmış değerlere dönüştürülmüştür. Bu çalışmada doğrudan müşteri yorumları dikkate alındığından ön işleme adımı oldukça basit tutulmuştur. Bu adımda öncelikle cümlelerin başındaki ve sonundaki boşluklar metinden izole edilmiştir. Sonrasında tırnak ifadesi içeren karakterler metinden atılmıştır ve tüm metinler küçük harfe çevrilmiştir.

Ön işleme adımı sonrasında bir etiket (Label) ve bir de metin olmak (Text) üzere 2000×2 boyutunda bir matris elde edilmiştir.

2.3. Önerilen model ve katmanların işlevi

Ardışıl (Sequential) katmanlardan oluşan bir model önerisi yapılmıştır. Bu çerçevede temelde metin kodlayıcı (TextVectorization), gömme (Embedding), yoğun (Dense) ve bırakma (Dropout) katmanları kullanılmıştır.

Metin vektörlendirme (text vectorization), doğal dil işleme (NLP) alanında, metin verilerini matematiksel vektörlere dönüştürme işlemidir. Bu dönüşüm, makine öğrenimi algoritmalarının metin verilerini işlemesi ve analiz etmesi için gereklidir. Bu sayede, metinlerdeki kelime ve cümle yapıları, sayısal verilerle ifade edilebilir ve daha kolay bir şekilde işlenebilir hale getirilir [19]. Model önerisinde yer alan TextVectorization katmanı, bu nedenle kullanılmıştır. Bu katman, öncelikle metin verilerindeki kelimeleri token olarak ifade edilen bir yapıya ayırır. Daha sonra, bu token yapıları sayısal vektörlere dönüştürür. Bu katmanın bir diğer işlevi metin verilerindeki farklı uzunlukları normalleştirerek, tüm metin verilerinin aynı boyutta temsil edilmesini sağlamasıdır. Böylece girdi uzunluğundan bağımsız olarak modelin çalışması sağlanabilmektedir. Bu, metin verilerinin daha verimli bir şekilde işlenmesine olanak tanınması açısından önemli bir niteliktir. Metin kodlayıcı katmanı, önceden belirlenmiş bir kelime dağarcığı kullanır ve burada veri setindeki kelimelerin kullanım sıklığıyla sıkı bir ilişki bulunmaktadır.

Embedding katmanı, özellikle doğal dil işleme işlemlerinde kullanılan bir katmandır. Bu katman, metin verilerindeki farklı kelimeleri vektörlere dönüştürerek verilerinin sayısal olarak temsil edilmesini sağlar. Bu vektörler, kelimelerin anlamsal olarak benzer olduğu durumlarda benzer vektörlere sahip olur. Bu sayede, Embedding katmanı, metin verilerindeki anlamsal ilişkileri yansıtabilir [20]. Örneğin, "araba" ve "otomobil" kelimeleri anlamsal olarak benzer olduğu için, Embedding katmanı, bu kelimeleri benzer vektörlere dönüştürür. Bu vektörler, kelimelerin anlamsal olarak benzer olduğunu yansıtır.

Uzun-Kısa Süreli Bellek (Long Short-Term Memory, LSTM) katmanı, özellikle doğal dil işleme ve zaman serisi verileri ile çalışan modellerde kullanılan bir tür Recurrent Neural Network (RNN) katmanıdır. LSTM, gelen verilerdeki uzun vadeli bağımlılıkları modellemek için kullanılır ve bu katman, özellikle zaman serisi verilerindeki trendleri ve doğal dil işleme işlemlerindeki cümle yapısını modellemek için kullanışlıdır [21]. Bu katman gelen verilerin önceki adımlarından (tarihlerinden) bilgi alarak, o anki adımın çıktısını hesaplar. Bu amaçla, hafıza hücreleri ve kapıları kullanır. Bir başka ifadeyle, hafıza hücreleri, LSTM'nin önceki adımlarından gelen bilgileri depolarken kapılar ise, hafıza hücrelerine ne kadar bilgi eklenmesi gerektiğini kontrol eder. LSTM katmanındaki kapılar; unutma (forget), girdi (input) ve çıkış (output) kapılarıdır. Unutma kapısı, hafıza hücrelerindeki bilginin ne kadarının unutulacağını belirler. Girdi kapısı, yeni bilginin hafıza hücrelerine ne kadar ekleneceğini belirler. Çıkış kapısı ise, hafıza hücrelerindeki bilginin ne kadarının çıktı olarak kullanılacağını belirler [22].

Bellek bloğunda bulunan unutma kapısı, aşağıdaki gibi tanımlanan bir aktivasyon fonksiyonu kullanılarak basit bir tek katmanlı sinir ağı yardımıyla kontrol edilir:

$$f_t = \sigma(W[x_t, h_{t-1}, C_{t-1}] + b_f) \quad (1)$$

Burada, giriş dizisi, önceki bloğun çıkışı, önceki LSTM bloğunun hafızası ve sapma vektörü sırasıyla x_t , h_{t-1} , C_{t-1} , ve b_f ile gösterilmiştir. W , herbir giriş vektörü için tanımlanan ağırlık vektörü ve σ logistic sigmoid aktivasyon fonksiyonudur [23]. Bu aktivasyon fonksiyonu, önceki hafıza bloğunun eleman-bilgi çarpımı kullanılarak mevcut LSTM üzerindeki etkisini belirlemek için önceki hafıza bloğuna uygulanır. Önceki bellek, çıkış aktivasyon vektörünün değerinin sifıra yakın olup olmadığı göz önünde bulundurularak unutulur.

Giriş kapısında, yeni hafıza önceki hafıza bloğunun etkisi ve tanh aktivasyon fonksiyonunun her ikisi de dikkate alınarak temel bir sinir ağı tarafından aşağıdaki gibi tanımlanarak oluşturulur:

$$i_t = \sigma(W[x_t, h_{t-1}, C_{t-1}] + b_i) \quad (2)$$

$$C_t = f_t C_{t-1} + i_t \tanh(W[x_t, h_{t-1}, C_{t-1}] + b_c) \quad (3)$$

Burada i_t giriş kapısının çıktısını ifade eder. W ağırlık vektörünü gösterirken; b_i sapma vektörünü gösterir. h_{t-1} ve C_{t-1} sırasıyla önceki bloğun çıktısı ve önceki LSTM hafızasına karşılık gelir. Aktivasyon parametresi ise σ ile gösterilir.

Çıkış kapısı ise aşağıda verilen denklemler dikkate alınarak mevcut LSTM bloğunun çıkışının oluşturulduğu bir bölümdür:

$$o_t = \sigma(W[x_t, h_{t-1}, C_t] + b_0) \quad (4)$$

$$h_t = \tanh(C_t) \cdot o_t \quad (5)$$

Aktivasyon fonksiyonu diğer kapılarda olduğu gibi σ ile gösterilir ve çıkışın 0 ve 1 arasında olmasını sağlar. \tanh aktivasyon fonksiyonu ise çıkış değerlerini -1 ve 1 arasına indirger. Bu fonksiyonlar modelin doğrusal olmayan yapısını destekler.

2.4. Performans değerlendirme

Denetimli öğrenme yöntemiyle geliştirilmiş sınıflandırma modellerinin performansını ölçmek için temelde karmaşıklık (hata) matrisi kullanılır. Bu matris doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP) ve yanlış negatif (YN) olmak üzere temelde dört göstergeye bağlı olarak oluşturulur. Hata matrisi kullanılarak çeşitli performans göstergeleri modellerin genelleştirme performansını değerlendirmek üzere kullanılır [24].

$$\frac{DP+DN}{DP+YP+YN+DN} \quad (6)$$

Denklemin 6'da doğruluk (accuracy) metriğine yer verilmiştir. Bu metrik, modelin doğru tahminlerinin toplam veri noktalarına oranını verir. Diğer bir ifadeyle, doğru sınıflandırılan örneklerin toplam örnek sayısına oranını ifade eder. Doğruluk, modelin genel performansını ölçer.

$$\frac{DP}{DP+YP} \quad (7)$$

Denklemin 7'de hassasiyet (precision) metriğinin matematiksel modeline yer verilmiştir. Bu metrik, modelin bir sınıfı doğru tahmin etme oranını ifade eder. Hassasiyet, yanlış pozitiflerin önemli olduğu durumlarda kullanışlıdır.

$$\frac{DP}{DP+FN} \quad (8)$$

Denklemin 8'de hatırlatma (Recall) metriğine yer verilmiştir. Bu metrik, gerçekte pozitif olan örneklerin ne kadarının doğru şekilde pozitif olarak sınıflandırıldığını gösterir. Recall, özellikle yanlış negatiflerin önemli olduğu durumlarda kullanışlıdır. Recall değeri, hassasiyet (precision) ile birlikte kullanıldığında, modelin sınıflandırma performansını daha iyi anlamamıza yardımcı olur. Hassasiyet, doğru sınıflandırılmış pozitif örneklerin, yanlış sınıflandırılmış pozitif örneklerle birlikte toplam pozitif tahmin sayısına oranını ifade eder. Hassasiyet, yanlış pozitiflerin önemli olduğu durumlarda kullanışlıdır.

Model değerlendirme yaparken kullanılan bir diğer verimli metrik Area Under the Curve (AUC) olarak ifade edilir. AUC sınıflandırma problemlerinde kullanılan bir performans ölçütüdür. ROC (Receiver Operating Characteristic) eğrisi altındaki alanı ifade eder ve DP oranının YP oranına karşı performansını ölçer. AUC değeri, 0 ile 1 arasında değişir ve 1 yaklaşması beklenir. Yüksek AUC değerleri, modelin doğru sınıflandırma oranının yüksek olduğunu gösterirken, düşük AUC değerleri ise modelin sınıflandırma performansının düşük olduğunu ifade eder [25].

3. Bulgular ve Tartışma

Bu çalışmada, Türkiye'de hizmet veren e-ticaret sitelerinde herkese açık olan müşteriler tarafından yapılan ürün yorumları toplanarak; 1000 adet pozitif ve 1000 adet negatif olmak üzere toplam 2000 adet örnekten oluşan

bir veri seti oluşturulmuştur. Hazırlanan veri seti ve önerilen model bir GitHub deposunda açık erişimli olarak araştırma çıktısı olarak paylaşılmıştır.


Veri seti model geliştirme aşamasından önce eğitim, doğrulama ve test olmak üzere üç parçaya ayrılmıştır. Bu çerçevede veri setinin, %80'i eğitim (yaklaşık 1600 adet) ve %10'u doğrulama (yaklaşık 200) ve geriye kalan %10'u (yaklaşık 200) ise test adımı için kullanılacak şekilde ayarlanmıştır.

Önerilen modeldeki en kritik katman, TextVectorization katmanıdır. Bu katman metin ile beslenen modelin, en fazla kaç kelime ile besleneceğini belirler. Bu parametre yardımıyla modeli beslemek üzere kullanılan metinlerin boyutu sınırlanır ve aşırı öğrenme önlenir. Girdi boyutu olarak kullanılacak maksimum kelime dağarcığı, token sayısı ile ifade edilir. Deneysel çalışmada ilk adımda token sayısının tespitini sağlamak üzere 500 ve 10000 arasında değişken token sayısına bağlı olarak, bir analiz gerçekleştirilmiştir. Bu amaçla model eğitimi için kullanılan parametrelere ve parametrelerin değerlerine Tablo 1'de yer verilmiştir.

Tablo 1. Model parametreleri

Katman (Tipi)	Çıkış ve Şekil	Parametre Sayısı
Text Vectorization	(None,None)	0
Embedding	(None,None,32)	201856
LSTM	(None,32)	8320
Dense	(None,32)	1056
Dropout	(None,32)	0
Dense	(None,1)	33
Toplam Parametre Sayısı	211,265	
Eğitilebilir Parametre Sayısı	211,265	
Döngü Sayısı (Epochs)	128	


Şekil 3'de eğitim sırasında elde edilen doğruluk ve kayıp eğrilerine yer verilmiştir. Görüldüğü üzere token sayısı arttıkça model sınıflandırma başarımının da kademeli olarak arttığı gözlenmiştir. Eğitim için çağ/döngü (epochs) sayısı 128 olarak belirlenmiştir. Eğitimin belirli ölçütlere bağlı olarak erken bir şekilde tamamlanmasını sağlamak üzere herhangi bir geri çağırma fonksiyonu bu aşamada kullanılmamıştır. Bu noktadaki temel amaç; model eğitiminin tamamen gerçekleştirildiğinden emin olmaktır.



Şekil 3. Eğitim kümesine göre modellerin doğruluk ve kayıp eğrileri

Model eğitimi gerçekleştirilirken kayıp fonksiyonunu minimize etmek amacıyla optimizasyon algoritmalarından faydalanılır. İdeal token sayısını belirlemek üzere yapılan deneysel çalışma kapsamında Adam optimizasyon algoritması kullanılmıştır ve bu algoritmanın girdi parametreleri varsayılan değerleriyle kullanılmıştır [26]. Öğrenme oranının başlangıç değeri 0,001 olarak atanmıştır.

Deneysel çalışma kapsamında elde edilen sonuçların bir bölümüne Tablo 2'de yer verilmiştir. İlaveten Şekil 4'de ilgili verilere ilişkin bir grafik sunulmuştur. Deneysel çalışmalar maksimum token sayısı için en uygun değer 8500 olduğunu göstermektedir. Bu noktada kayıp değeri 0.4615, sınıflandırma doğruluğu 0,9100 AUC 0,9454, hassasiyet 0,9090 ve hatırlama metriği 0.9259 olarak elde edilmiştir.



Şekil 4. Token sayısına bağlı olarak model performansı

Tablo 2. Maksimum token sayısına ilişkin performans sonuçları

Metrikler	Maksimum Token Sayısı								
	500	1000	2000	3000	5000	6000	7000	8500	9500
Kayıp	0.6804	0.9215	0.8237	0.5270	0.7920	0.7682	0.5292	0.4615	0.4950
Doğruluk	0.8550	0.8700	0.8800	0.8900	0.8900	0.8650	0.9000	0.9100	0.8950
AUC	0.9069	0.9053	0.9102	0.9393	0.9208	0.9159	0.9368	0.9454	0.9244
Hassasiyet	0.8623	0.8727	0.9038	0.9300	0.9056	0.9450	0.9489	0.9090	0.9223
Hatırlama	0.8703	0.8888	0.8703	0.8611	0.8888	0.7962	0.8611	0.9259	0.8796

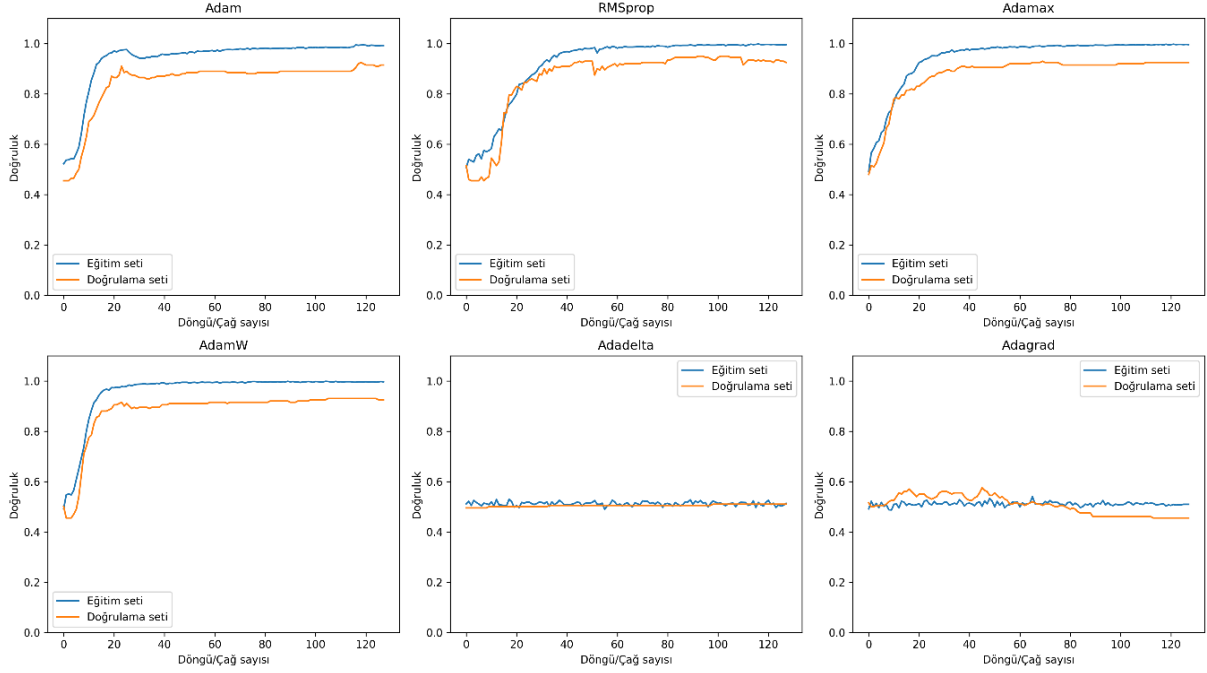
Deneysel çalışmanın ikinci adımında, optimizasyon algoritmalarının keşfi için bir çalışma gerçekleştirilmiştir. Bu çerçevede öğrenme oranı (learning rate) 0.001 değeri için Adam, RMSprop, Adamax, AdamW, Adadelat ve Adagrad algoritmaları dikkate alınmıştır. Elde edilen sonuçlar Tablo 3’de rapor edilmiştir.

Tablo 3. Optimizasyon sonuçları

Optimizasyon Algoritması	Kayıp	Doğruluk	AUC	Hassasiyet	Hatırlatma
Adam	0.3393	0.8950	0.9556	0.8541	0.9213
RMSprop	0.4399	0.8850	0.9453	0.8235	0.9438
Adamax	0.6609	0.9150	0.9591	0.8750	0.9438
AdamW	0.2640	0.9000	0.9581	0.8484	0.9438
Adadelat	0.6927	0.4650	0.6276	0.4510	0.9325
Adagrad	0.6935	0.4450	0.5669	0.4450	1.0000

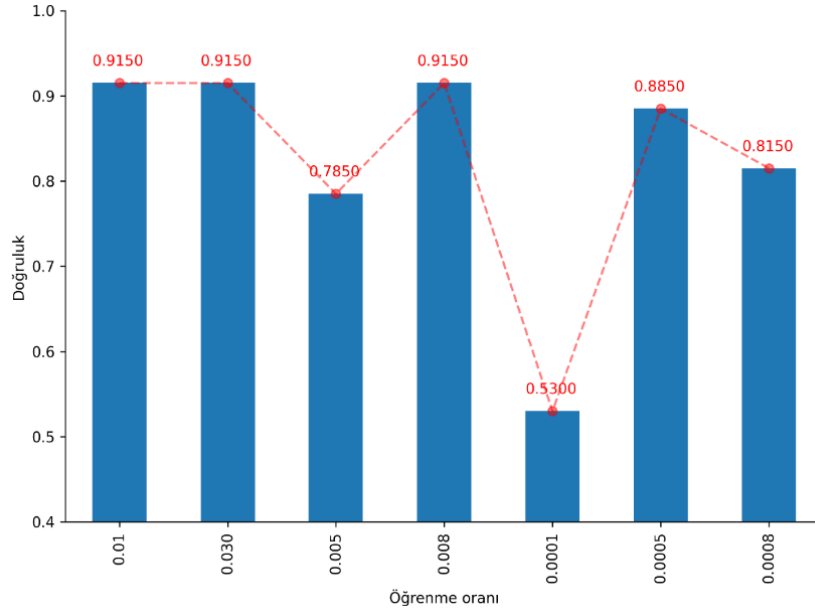
Görüldüğü üzere en iyi sınıflandırma performansını sağlayan optimizasyon algoritması Adamax olarak belirlenmiştir ve algoritmanın sınıflandırma doğruluğu 0,9150, AUC 0,9591, hasasiyeti 0,8750 ve hatırlatma metriği ise 0,9438 olarak elde edilmiştir.

Şekil 5’de ise optimizasyon algoritmalarının eğitim ve doğrulama seti üzerindeki başarımına yer verilmiştir. Görüldüğü üzere Adam, RMSprop, Adamax ve AdamW algoritmaları problemi hızlıca öğrenebilmiştir ancak Adadelat ve Adagrad algoritmalarının mevcut parametreler ile problemi öğrenemediği ve iyi bir genelleştirme performansı sağlayamadığı gözlemlenmiştir.



Şekil 5. Optimizasyon algoritmalarının eğitim ve doğrulama seti üzerindeki başarıları

Deneysel çalışma sonucunda en verimli optimizasyon algoritması Adamax olarak elde edilmiştir. İlgili algoritma farklı öğrenme oranları kullanılarak yeniden eğitilmiştir. Bu eğitim aşamasında eğitim sürecini özelleştirmek, aşırı uyumu engellemek, model eğitim süresini kısaltmak ve eğitim sürecini izlemek üzere geri çağırma (callback) metotları dikkate alınmıştır. Geri çağırma metotları modelin ezberleme sorununun önüne geçtiği gibi; öğrenme oranının dinamik olarak değişmesini sağlayarak eğitimin daha kısa sürede tamamlanmasına da olanak sağlamaktadır.




Şekil 6. Farklı öğrenme oranlarına göre modelin eriştiği doğruluk oranları


Geri çağırma işlevleri kapsamında tanımlanan ilk işlev, *ReduceLRonPlateau* geri çağırma işlevidir. Bu işlev, model eğitimi sırasında öğrenme hızını dinamik olarak değiştirmek için kullanılır. Bir başka ifadeyle, model

eğitimi sırasında izlenen bir ölçüt (metrik) değerinin belirli bir sayıdaki döngü/çağ boyunca gelişmediği durumlarda öğrenme hızını azaltır. Böylece, modelin daha iyi sonuçlar elde etmek için daha fazla iterasyon yapmasına olanak tanınır. Bu çerçevede iki parametre önem kazanır; bunlar *factor* ve *patience* parametreleridir. Deneysel çalışmada ilgili parametrelere sırasıyla 0,5 ve 5 değerleri verilmiştir. Öğrenme hızının azaltılma oranı *factor* parametresi ile kontrol edilirken, ölçütün yani performans metriğinin iyileşmediği/gelişmediği döngü ya da çağ sayısı ise *patience* parametresi ile kontrol edilir.

Geri çağırma işlevleri kapsamında tanımlanan ikinci işlev, *EarlyStopping* geri çağırma işlevidir. Bu işlev, belirtilen bir performans metriğini izler. Hangi performans metriği, izleneceği monitör parametresi ile belirtilir. İzlenen metrik üzerinde minimum değişim miktarı *min_delta* parametresi ile bildirilir. Bu durumda belirtilen performans metriğinde, belirtilenden daha az miktarda bir değişim olması durumunda modelde bir gelişme olmadığını kabul ederek eğitimi durdurabilir. Şekil 6'da farklı öğrenme oranlarına göre modellerin sağladığı doğruluk değerlerine yer verilmiştir. Bu kapsamda öğrenme oranı 0,01, 0,003 ve 0,008 iken; model test veri seti üzerinde 0,9150 doğruluk oranına eriştiği gözlemlenmiştir. Şekil 7'de farklı öğrenme oranlarına karşılık elde edilen eğitim eğrilerine yer verilmiştir.



Şekil 7. Öğrenme oranlarına bağlı olarak eğitim grafikleri



Şekil 8. Hata matrisleri

0,01, 0,003 ve 0,008 öğrenme oranında aynı doğruluk oranını yakalayan modellerin eğitim eğrileri incelendiğinde; ideal öğrenme oranının 0,008 olarak ayarlanmasının eğitimi en kısa sürede yani 20 döngüde/çağda sonuçlanmasını sağladığı görülmektedir. Öğrenme oranı, bir makine öğrenmesi algoritmasının problemi ne ölçüde hızlı öğrendiğini ve probleme ne kadar hızlı uyum sağladığını belirler. Doğru öğrenme oranının seçilmesi, hem algoritmanın hızını hem de doğruluğunu etkiler. Çok yüksek bir öğrenme oranı, algoritmanın doğru sonuçlara ulaşma olasılığını azaltabilirken; çok düşük bir öğrenme oranı ise algoritmanın eğitim sürecini yavaşlatabilir ve aşırı uyumu, yani ağır problemi ezberlemesini teşvik edebilir. Bu nedenle, doğru öğrenme oranını seçmek, makine öğrenmesi modelinin başarısı için önemlidir. Şekil 8’de farklı öğrenme oranlarına bağlı olarak elde edilen hata matrislerine yer verilmiştir. Hata matrislerinden türetilen performans metriklerine bağlı olarak elde edilen performans göstergeleri ise Tablo 4’de raporlanmıştır. Bu doğrultuda gerek pozitif müşteri ürün incelemelerini ve gerekse negatif müşteri ürün incelemelerini ayırt etme konusunda modelin yanlış davranmaması, yani her iki sınıfı da doğru bir şekilde ayırt etmesi gerekir. Bu noktada verilerin dengeli dağılımı da dikkate alındığında, hem duyarlılık ve özgüllük metriklerinin birlikte yorumlanması ya da F1 skor metriğine göre karar vermek mantıklı olur. Sonuçlar irdelendiğinde; en iyi F1-skor değerinin öğrenme oranı 0,008 olarak ayarlandığı durumda elde edildiği görülmektedir.

Tablo 4. Modelin farklı öğrenme oranlarına göre performans sonuçları

Öğrenme Oranı	Doğruluk	Hata	Duyarlılık	Özgüllük	Hatırlatma Geri Çağrı	F1-Skor	AUC
0.01	0.9150	0.0850	0.9677	0.8692	0.8635	0.9137	0.9728
0.003	0.9150	0.0850	0.9677	0.8692	0.8665	0.9137	0.9606
0.005	0.7850	0.2150	0.7364	0.8732	0.9134	0.8155	0.9146
0.008	0.9150	0.0850	0.9142	0.9063	0.9230	0.9187	0.9510
0.0001	0.5300	0.4700	0.5352	0.5172	0.7307	0.6179	0.4939
0.0005	0.8850	0.1150	0.8521	0.9294	0.9423	0.8950	0.9413
0.0008	0.8150	0.1850	0.7557	0.9275	0.9519	0.8426	0.9162

4. Sonuç

E-Ticaret, ürünlerin ve hizmetlerin internet üzerinden alınıp satılabildiği dijital bir iş modelidir. İnternetin yaygınlaşması, internete erişimin kolaylaşması, mobil cihazların kullanımının artması, dijital ödeme teknolojilerinin gelişmesi gibi pek çok faktöre bağlı olarak e-ticaret sürekli olarak gelişmeye devam etmektedir. Müşteri ürün incelemeleri, e-ticaretin önemli bir parçasıdır çünkü müşterilerin alacakları ürün hakkında bilgi edinmelerini ve diğer müşterilerin deneyimlerinden faydalanmalarını sağlamaktadır. Bu incelemeler, müşterilerin satın alma kararlarını etkilemekte ve satıcıların ürün kalitesini artırarak müşteri memnuniyetini sağlamalarına yardımcı olmaktadır. Bu çalışmada, çevrimiçi müşteri ürün incelemelerinin otomatik olarak gerçekleştirilmesini sağlayan hesaplamalı bir model önerisi yapılmıştır. Önerilen model derin öğrenme algoritmalarından biri olan LSTM modeli ve metin kodlayıcı algoritmalarına dayanarak geliştirilmiştir. Geliştirilen modelin genelleştirme performansını arttırmak üzere çok sayıda deneysel çalışma yapılmıştır. Sonuç olarak, oldukça umut vadeden ve genelleştirme performansı tatmin edici bir model geliştirilmiş ve geliştirilen model ile %91,50 sınıflandırma doğruluğu elde edilmiştir. Çalışma kapsamında üretilen veri seti ve geliştirilen model açık erişimli bir kod deposunda araştırmacılar ile paylaşılmıştır.

Araştırma, işletmelerin müşteri memnuniyetini arttırmak, çeşitli ürün pazarlama stratejileri geliştirmek, çevrimiçi pazarlama süreçlerini yönetmek ve farklı iş modelleri uygulamak üzere yapay zekâ destekli algoritmalarından faydalanılabileceği doğrulamaktadır. Gelecek çalışmamızda, yapay zekâ algoritmaları kullanılarak müşteri ürün incelemelerini gerçek zamanlı olarak sınıflayabilen ve müşteri ürün incelemeleri için otomatik olarak skor üretebilen bir model çalışmasının yapılması planlanmaktadır.

Veri Erişimi

Bu çalışma kapsamında kullanılan veri setine ve üretilen modele GitHub üzerinden erişim sağlanabilir.

<https://github.com/ozgekervan/Turkish-Online-Customer-Reviews-Dataset>

Kaynaklar

- [1] Demirdöğmez, M.; Gültekin, N.; Taş, Y. Türkiye’de E-Ticaret Sektörünün Yıllara Göre Gelişimi. Uluslararası Toplum Araştırmaları Derg. 2018, 8, 2217–2237.
- [2] Soydal, H. Küçük ve Orta Büyüklükteki İşletmelerde E-Ticaret. J. Selcuk Univ. Social Sci. 2006, 539–552.
- [3] Güven, H.; Ayvaz, G.; Türkan, E. Use of Artificial Intelligence Applications in E-Commerce. Int. J. Manag. Adm. 2023, 7, 69–94.

- [4] Marangoz, M.; Yeşiladağ, B.; Saltık, I.A. E-Ticaret İşletmelerinin Web Ve Sosyal Ağ Sitelerinin İçerik Analizi Yöntemiyle İncelenmesi. *İnternet Uygulamaları ve Yönetimi Derg.* 2012, 3, 53–78.
- [5] Aydın, İ.; Çelik, Z. Drone İle Teslimata Yönelik Algılanan Güvenin Kullanım Niyeti Üzerindeki Etkisinde Algılanan Risk Ve Ağızdan Ağıza İletişimin Aracılık Rollerinin Araştırılması. *J. Econ. Bus. Polit. Stud.* 2023, 10, 49–67.
- [6] Aytekin, Ç.; Sütçü, C.S.; Özfıdan, U. Karar Ağacı Algoritmasıyla Metin Sınıflandırma: Müşteri Yorumları Örneği. *Uluslararası Sos. Araştırmalar Derg.* 2018, 11, 782–792.
- [7] HülyaTaştan, O. Kahramanmaraş'ta Bulunan Yiyecek İçecek İşletmelerine Yönelik Tripadvisor.Com'da Paylaşılan Şikâyetlerin Sınıflandırılması. *Journal* 2017, 26, 270–284.
- [8] Kutankoruyan, A. Classification of Customer Complaints with Machine Learning. *Journal* 2022, 13, 168–183.
- [9] Çelik, E.; Dal, D.; Aydın, T. Duygu Analizi İçin Veri Madenciliği Sınıflandırma Algoritmalarının Karşılaştırılması. *Avrupa Bilim ve Teknol. Derg.* 2021, 27, 880–889.
- [10] Akbıyık, A.; Arı, O. Forecasting Useful Customer Reviews via Logistic Regression. *J. Res. Bus.* 2022, 7, 15–32.
- [11] Koruyan, K. Classification of Customer Complaints Using BERTopic Topic Modelling Technique. *Journal* 2022, 4, 66–79.
- [12] Yücel, A. Tüketici Yorumları Üzerine Bir Metin Madenciliği ve Veri Boyutu İndirgeme Yaklaşımı. *Zeki Sist. Teor. ve Uygulamaları Derg.* 2021, 1, 8–16.
- [13] Oğul, B.B.; Ercan, G. Sentiment Classification on Turkish Hotel Reviews. In *Proceedings of the 2016 24th Signal Processing and Communication Application Conference (SIU)*; 2016; pp. 497–500.
- [14] Demir, Ö.; Chawai Baban, A.I.; Doğan, B. Türkçe Metinlerde Sözlük Tabanlı Yaklaşım ile Duygu Analizi. *Int. Period. Recent Technol. Appl. Eng.* 2019, 58–66.
- [15] Dandıl, E.; Karakurt, B. Sosyal Medya Uygulamalarında Kullanıcı Yorumlarının Metin Madenciliği İle Sınıflandırılması. In *Proceedings of the International Congress on Human-Computer Interaction, Optimization and Robotic Application*; 2019; pp. 203–207.
- [16] Akçay, M.; Taşdelen, Z.; Kasım, Ö. ASP.NET Ve MVC Temelli Responsive Web Uygulaması. *J. Estud. Inf.* 2021, 2, 34–41.
- [17] Çetin, V.; Yıldız, O. A Comprehensive Review on Data Preprocessing Techniques in Data Analysis. *Pamukkale Univ. J. Eng. Sci.* 2022, 28, 299–312, doi:10.5505/pajes.2021.62687.
- [18] Hark, C.; Uçkan, T.; Karıcı, A. A New Multi-Document Summarisation Approach Using Saplings Growing-up Optimisation Algorithms: Simultaneously Optimised Coverage and Diversity. *J. Inf. Sci.* 2022, 01655515221101841, doi:10.1177/01655515221101841.
- [19] Yang, X.; Yang, K.; Cui, T.; Chen, M.; He, L. A Study of Text Vectorization Method Combining Topic Model and Transfer Learning. *Processes* 2022, 10.
- [20] Ramasubramanian, K.; Singh, A. Deep Learning Using Keras and TensorFlow BT - Machine Learning Using R: With Time Series and Industry-Based Use Cases in R. In; Ramasubramanian, K., Singh, A., Eds.; Apress: Berkeley, 2019; pp. 667–688 ISBN 978-1-4842-4215-5.
- [21] Öncül, A.B. LSTM-GRU Based Deep Learning Model with Word2Vec for Transcription Factors in Primates. *Balk. J. Electr. Comput. Eng.* 2023, 11, 42–49.
- [22] Daldal, N.; Sengur, A.; Polat, K.; Cömert, Z. A Novel Demodulation System for Base Band Digital Modulation Signals Based on the Deep Long Short-Term Memory Model. *Appl. Acoust.* 2020, 166, 107346, doi:https://doi.org/10.1016/j.apacoust.2020.107346.
- [23] Budak, Ü.; Cömert, Z.; Rashid, Z.N.; Şengür, A.; Çıbuk, M. Computer-Aided Diagnosis System Combining FCN and Bi-LSTM Model for Efficient Breast Cancer Detection from Histopathological Images. *Appl. Soft Comput.* 2019, 85, 105765, doi:10.1016/j.asoc.2019.105765.
- [24] Cömert, Z.; Kocamaz, A.F.; Subha, V. Prognostic Model Based on Image-Based Time-Frequency Features and Genetic Algorithm for Fetal Hypoxia Assessment. *Comput. Biol. Med.* 2018, 99, 85–97, doi:10.1016/J.COMPBIOMED.2018.06.003.
- [25] Toğaçar, M.; Ergen, B.; Cömert, Z. Classification of Flower Species by Using Features Extracted from the Intersection of Feature Selection Methods in Convolutional Neural Network Models. *Measurement* 2020, 158, 107703, doi:https://doi.org/10.1016/j.measurement.2020.107703.
- [26] Zou, F.; Shen, L.; Jie, Z.; Zhang, W.; Liu, W. A Sufficient Condition for Convergences of Adam and RMSProp. 2018, 11127–11135.