

# E-Ticaret ve sosyal medya yorumlarının analizinde lemmatizasyonun etkisi: adlandırılmış varlık tanıma ve duygu analizi tabanlı bir yaklaşım

## The effect of lemmatization in the analysis of e-commerce and social media comments: an approach based on named entity recognition and sentiment analysis

Emre Şatır<sup>1\*</sup>, Sena Yüksel<sup>1</sup>, Beyza Aydoğmuş<sup>1</sup>, Dila İkra Aygün<sup>1</sup>, Nezih Beyazıt<sup>1</sup>, Halim Ağdemir<sup>1</sup>, Erdem Altuğ Malkan<sup>1</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü, Mühendislik ve Mimarlık Fakültesi, İzmir Kâtip Çelebi Üniversitesi, İzmir, Türkiye.  
emre.satir@ikcu.edu.tr, senayuksel408@gmail.com, beyzaaydogmus0@gmail.com, dilaikra2002@gmail.com, beyazitneziha@gmail.com, agdemirhalim4@gmail.com, malkanaltug@gmail.com

Geliş Tarihi/Received: 10.03.2025  
Kabul Tarihi/Accepted: 05.12.2025

Düzeltilme Tarihi/Revision: 03.11.2025

doi: 10.65206/pajes.89956  
Araştırma Makalesi/Research Article

### Öz

İnternetin yaygınlaşmasıyla birlikte müşteriler, satın alma kararlarını verirken çevrimiçi yorumları ve puanlamaları dikkate almaktadır. Ancak, artan veri hacmi ve bilgi kirliliği, kullanıcıların doğru bilgiye ulaşmasını zorlaştırmaktadır. Bu makalede, olumsuz duygu tespitinde lemmatizasyon işleminin etkilerini incelemek amacıyla yapılan üç farklı yöntem açıklanmakta ve olumsuzluk eki içeren kelimelere lemmatizasyon uygulanmamasının en başarılı sonuçları verdiği gösterilmektedir. Geliştirilen yöntem, iki farklı çalışmada kullanılarak duygu analizi doğruluğunu artırmada etkili olmuştur. İlk çalışmada, kullanıcıların ürün özelliklerine göre doğru tercihler yapmasını sağlayan bir öneri sistemi geliştirilmiştir. Burada, Trendyol e-ticaret platformundan elde edilen 85000 kullanıcı yorumuna dayalı bir veri seti kullanılmıştır. Sistem, tüketici yorumlarını adlandırılmış varlık tanıma ve duygu analizi teknikleriyle işleyerek, ürün özelliklerine yönelik puanlama yapmaktadır. Ayrıca, yorumların doğruluğunu artırmak için standart yıldız puanlama sisteminden farklı olarak "Hesaplanan Yıldız Puanı" yöntemi geliştirilmiş ve daha güvenilir bir değerlendirme sağlanmıştır. Yapılan deneyler sonucunda, adlandırılmış varlık tanıma modelinde 0.894, duygu analizi modelinde ise 0.838 F1 skoru elde edilmiştir. İkinci çalışma, müşteri yorumlarının analiz edilerek şirketlere geri bildirim sağlanmasını amaçlamaktadır. Toplamda 96960 yorum Twitter platformundan elde edilmiştir. Yorumlardaki şirket isimleri adlandırılmış varlık tanıma tekniği ile belirlenmiş, ardından her bir varlık için duygu analizi yapılmıştır. Bu sayede, geleneksel yöntemlerden farklı olarak cümle bazında değil, varlık bazında duygu belirleme gerçekleştirilmiştir. Bu çalışmada hem adlandırılmış varlık tanıma hem de duygu analizi modelinde 0.801 F1 skoru elde edilmiştir. Elde edilen sonuçlar, geliştirilen yöntemlerin müşteri deneyimini iyileştirmede etkili olduğunu göstermektedir.

Anahtar kelimeler: Lemmatizasyon, Adlandırılmış varlık tanıma, Duygu analizi, Öneri sistemi, Müşteri geri bildirim, Doğal dil işleme (DDİ)

### Abstract

With the widespread use of the Internet, customers consider online reviews and ratings when making purchasing decisions. However, increasing data volume and information pollution make it difficult for users to access accurate information. This paper describes three different methods tested to examine the effects of lemmatization on negative sentiment detection and show that not applying lemmatization to words containing negativity suffixes yields the most successful results. The developed method was used in two different studies to improve the accuracy of sentiment analysis. In the first study, a recommendation system was developed to help users make the right choices based on product features. Here, a dataset based on 85000 user reviews from the Trendyol e-commerce platform was used. The system processes consumer reviews with named entity recognition and sentiment analysis techniques to score product attributes. In addition, to increase the accuracy of the reviews, a "Calculated Star Score" method was developed different from the standard star scoring system and a more reliable evaluation was provided. As a result of the experiments, an F1 score of 0.894 was obtained in the named entity recognition model and 0.838 in the sentiment analysis model. The second study aims to provide feedback to companies by analyzing customer reviews. A total of 96960 reviews were obtained from the Twitter platform. The company names in the reviews were identified using named entity recognition, followed by sentiment analysis for each entity. In this way, unlike traditional methods, sentiment analysis is performed on an entity basis rather than on a sentence basis. In this study, an F1 score of 0.801 was obtained in both named entity recognition and sentiment analysis models. The results show that the developed methods are effective in improving customer experience.

Keywords: Lemmatization, Named entity recognition, Sentiment analysis, Recommendation system, Customer feedback, Natural language processing (NLP)

## 1 Giriş

## 2 Giriş

İnternet kullanımının geçmişten günümüze artmasıyla bireyler, ihtiyaçlarını internet üzerinden karşılar olmuş ve kullanıcılar geri dönüşlerini de internet üzerinden yapmaya başlamıştır. Bu durum internet üzerindeki oluşan verilerin önemini de artırmıştır. Bu veriler birçok alanda hem müşterilerin hem de

satıcıların ihtiyaçlarını karşılayacak şekilde kullanılabilir. Ancak, bu artan veri miktarının doğru şekilde analiz edilmemesi, kullanıcı deneyimini olumsuz etkilemekle birlikte veri odaklı karar alma süreçlerini güçleştirmektedir. Covid-19 pandemisinin ortaya çıkmasıyla uygulanan sokağa çıkma yasakları, insanların alışveriş alışkanlıklarını değiştirerek e-ticaret platformlarını daha fazla tercih edilir hale getirmiş [1] ve insanların iletişim, bilgi alma ve sosyalleşme ihtiyaçlarını büyük ölçüde dijital platformlar

\*Yazışılan yazar/Corresponding author

üzerinden karşılamasına neden olmuştur [2]. Öte yandan, internet kullanımındaki artış bilgi kirliliğini de beraberinde getirmiştir. Yanlış bilgilerin yayılması, toplumun panik ve kaygı düzeylerini arttırabilirken, doğru bilgiye ulaşmanın önemi daha da belirgin hale gelmiştir. Bu makalede, müşteri geri bildirimlerini analiz etmek ve bu geri bildirimleri hem müşterilerin hem de satıcıların yararına kullanılabilir bilgiye dönüştürmek amacıyla gerçekleştirilen iki farklı çalışma anlatılmaktadır. Her iki çalışmada da doğal dil işleme (DDİ) tekniklerini temel alarak, yorumlardan anlamlı bilgiler çıkarma ve kullanıcı deneyimini iyileştirme hedefini taşımaktadır.

Birinci çalışma, özellik bazlı öneri sistemi üzerine çalışan e-ticaret sitelerindeki yorumları inceleyerek kullanıcı deneyimini iyileştirmeye çabalayan bir yöntemle dayanmaktadır. E-ticaret platformlarının artışıyla satıcı ve ürün çeşitliliği de artmaya başlamıştır. Müşteriler kendilerine uygun ürünü bulmaya çalışırken, bir kategori için çok sayıda e-ticaret sitesini ve her e-ticaret sitesindeki satıcı ve ürünü incelemek zorunda kalmaktadır. Kaya'nın yayınladığı çalışmaya göre olumsuz yorumla karşılaşınca ürünü almaktan vazgeçen müşterilerin oranı %74,5'tir [3]. Yapılan bu çalışma, yorumların kullanıcılar tarafından büyük ölçüde dikkate alındığını göstermektedir. Yorumlara ek olarak, Kim ve arkadaşlarının çalışmasında, güven faktörünün artması durumunda, bunun tüketicinin satın alma kararı için olumlu etkisi olduğu belirtilmiştir [4]. Satıcı ve ürün çeşitliliğinin çok olması ve ürünlere yazılan binlerce yorumun müşteri tarafından incelenmesinin imkansızlığı müşterinin kendine uygun ve güvenilir ürün bulmasını zorlaştıran etkenlerdendir. Buna ek olarak e-ticaret sitelerindeki puanlama ve yıldız sisteminin yorumlarla tutarsız olması da kullanıcıların güvenini azaltan faktörlerdendir.

Değinen sorunları çözmek için bu çalışmada DDİ teknikleri kullanılarak özellik bazlı öneri sistemi geliştirilmiştir. Öneri sistemi üç aşamadan oluşmaktadır:

- İlk aşamada, müşteriden almak istediği ürünle ilgili detaylı açıklama istenir ve ürün özellikleri açıklanmadan tespit edilir.
- İkinci aşamada, ürünleri satın alarak deneyimlemiş müşterilerin yorumlarını içeren daha önceden oluşturulmuş veri setinden, ilk aşamada belirlenen özellikleri içeren ürünler tespit edilir.
- Son olarak, tespit edilen ürünler ilk aşamada belirlenen her bir özellik için puanlandırılır ve genel öneri sıralaması yapılır. Ek olarak, her bir ürün için, geliştirilen yıldız atama algoritması kullanılarak tutarsızlık en aza indirilir.

İkinci çalışmada ise, satıcı firma odaklı geri bildirim sistemi üzerine çalışan sosyal medya üzerindeki müşteri geri bildirimleri incelenerek, satıcıya geri bildirim sağlayan bir yaklaşım kullanılmaktadır. Sosyal medya kullanımının artmasıyla birlikte kullanıcılar sosyal medyayı sadece sosyalleşmek için değil aynı zamanda günlük hayatındaki problemlere çözüm ararken de kullanmaya başlamıştır. Bu problemler genellikle alınan hizmetten memnun kalınıp kalınmadığı hakkındaki bilgilerden oluşmaktadır. Bu yolla kişiler yetkili kurumlara ulaşmayı umarak sorunlarına çözüm aramaktadırlar. Ancak bu tip yorumlar günümüzde o kadar artmıştır ki satıcı firmanın bu yorumların hepsini okumaya zaman bulması imkânsız olmaktadır ve bunun sonucunda satıcılar müşterilerinin ne istediğini bilmemekte ve müşteriler de istek ve şikayetlerini firmaya ulaştırmakta zorluk çekmektedirler.

Değinen sorunları çözmek için, ilk çalışmaya benzer şekilde yine DDİ teknikleri kullanılarak satıcı firma odaklı bir geri

bildirim sistemi geliştirilmiştir. İlgili geri bildirim sistemi üç aşamadan oluşmaktadır:

- İlk aşamada, sosyal medyadan alınan yorumun "Uygulama Programlama Arayüzüne" (Application Programming Interface - API) yazılması istenir.
- İkinci aşamada, yapılan yorumda bahsedilen firmalar varlık (entity) olarak belirlenir.
- Son olarak, ikinci aşamada tespit edilen firmaların her birine özel bir duygu ataması gerçekleştirilir.

Özellikler, adlandırılmış varlık tanıma (named entity recognition) kullanılarak tespit edilirken, her özelliğin cümlede belirttiği olumlu, olumsuz, nötr anlam duygu analizi (sentiment analysis) ile belirlenmektedir.

Adlandırılmış varlık tanıma [5], DDİ'de bilgi çıkarımı (information extraction) işleminin alt görevidir ve bir metin içindeki adlandırılmış varlıkları (insanlar, kuruluşlar, konular, tarihler, miktarlar vb.) tanımlamayı ve sınıflandırmayı içerir. Adlandırılmış varlık tanıma işleminin amacı, belirli öğeleri önceden tanımlanmış kategorilere göre tespit etmek ve bunları kategorize etmektir.

Duygu analizi [6] ise bireyin metin içinde belirttiği duyguyu olumlu, olumsuz ve nötr olarak tanımlamak için kullanılan DDİ yöntemidir. Duygu analizi, bireylerin fikirlerini öğrenmek için kullanıldığından, pek çok alanda yaygın olarak tercih edilen bir yöntemdir. Bu alanlardan biri olan müşteri geri bildirimleri, satıcıların ürünlerini geliştirmesine yardım edebileceği gibi, ürünleri satın alan kişilerin kendilerine uygun ve güvenilir ürünleri belirlemesine de yardımcı olur.

Duygu analizi genellikle belge düzeyinde, cümle düzeyinde ve son olarak varlık ve özellik düzeyinde yapılır [7]. Belge düzeyinde duygu analizi, belgenin tamamında hangi duygunun belirtildiğini bulmak için bir yöntemken, cümle düzeyinde duygu analizi ise metnin her cümlesi için ayrı ayrı analiz yapılarak buradaki duyguların tespiti için kullanılır. Varlık ve özellik düzeyinde duygu analizi ise sadece metinlerin taşıdığı duyguyu değil daha detaylı olarak varlıkların özelliklerinin belirttiği duyguları saptar [8]. Bu çalışmada, müşteri yorumları odaklı çalışıldığından, tespit edilen her özellik için varlık düzeyinde duygu analizi yapılmaktadır. Özellik belirleme işlemi ise cümledeki varlıkların önceden tanımlanmış kategorilere otomatik olarak atanması ile adlandırılmış varlık tanıma tekniği kullanılarak yapılmaktadır.

Literatürde genellikle cümle düzeyinde duygu analizi yöntemleri uygulanmış olup, her bir cümlede yalnızca tek bir duygunun baskın olduğu varsayılmıştır. Ancak müşteri yorumlarında çoğu zaman birden fazla varlık tek bir cümlede farklı duygularla birlikte ifade edilmektedir. Bu nedenle bu çalışmada varlık bazlı duygu analizi tercih edilmiştir.

Benzer şekilde, Kılıçer ve Samlı (2023) çalışmasında e-ticaret ürün yorumları üzerinde cümle düzeyinde duygu analizi uygulanmış ve %69,6 F1 değeri elde edilmiştir [9]. Benzer veri tipi üzerinde geliştirilen bu çalışmada ise, varlık bazlı duygu analizi yaklaşımı benimsenmiş ve her bir varlığa özgü duygu durumu ayrı ayrı sınıflandırılmıştır. Bu yaklaşım sayesinde, özellikle çok-varlıklı cümlelerde F1 skorlarında yaklaşık %4-7 oranında bir artış gözlenmiştir. Dolayısıyla, varlık düzeyinde yapılan analiz, yalnızca metin veya cümle düzeyinde yapılan klasik analizlere kıyasla daha ayrıntılı ve yüksek doğruluklu bir duygu tespiti sağlamaktadır.

Çalışmanın literatüre katkıları aşağıdaki gibi özetlenebilir:

- Olumsuzluk eki içeren kelimelere lemmatizasyon uygulanmamasının duygu analizi doğruluğunu artırdığı deneysel olarak gösterilmiştir. Türkçe gibi eklemeli bir dil için lemmatizasyonun duygu analizi üzerindeki etkisi kapsamlı bir şekilde test edilmiştir.
- Geleneksel cümle bazlı duygu analizinden farklı olarak, varlık bazlı duygu analizi uygulanmıştır. Her bir varlığın (ürün, marka, şirket vb.) duygu durumu ayrı ayrı değerlendirilmiş ve daha hassas sonuçlar elde edilmiştir.
- Özellik tabanlı bir öneri sistemi geliştirilerek, müşteri yorumlarından ürün özelliklerine dayalı puanlama yapılmıştır. Geleneksel yıldız puanlama sistemlerinin eksiklikleri giderilerek, "Hesaplanan Yıldız Puanı" adlı yeni bir puanlama yöntemi önerilmiştir.
- Sosyal medya platformlarından müşteri yorumları analiz edilerek, şirketlere doğrudan geri bildirim sağlayan bir sistem geliştirilmiştir. Twitter'dan şirketlere yönelik müşteri yorumları içeren yeni bir veri seti oluşturulmuş ve bu veri seti, varlık bazlı duygu analizi için etiketlenmiştir.

Yapılan çalışmaların anlatıldığı bu yazının ilk bölümünden sonraki kısım olan Ön Bilgiler'de, çalışmada kullanılan teknolojilere değinilirken, İlgili Çalışmalar başlığında, ilk olarak literatürde var olan mevcut yayınlara değinilmiş ve bölümün ilerleyen kısımlarında bu çalışmanın yarattığı farklılardan ve literatüre katkılarından bahsedilmiştir. Dördüncü bölüm olan Materyal ve Metod'ta, veri setinden, bu veri seti oluştururken kullanılan yöntemlerden ve çalışmanın temel tekniklerinden bahsedilmiştir. Beşinci bölüm olan Bulgular ve Tartışma'da ise, kullanılan DDİ yöntemleri ile elde edilen sonuçlar tablolar yardımıyla özetlenmiş ve detaylıca açıklanmıştır. Son bölüm ise, Sonuçlar kısmıdır ve bu bölümde çalışmanın sonucunda elde edilen bulgulardan kısaca bahsedilmektedir. Bu bölümde ayrıca, gelecek perspektifinden söz edilmiştir.

### 3 Ön bilgiler

DDİ, bilgisayarların insan dilini anlaması ve işlemesi amacıyla geliştirilen yapay zekâ yöntemlerini kapsayan geniş bir araştırma alanıdır. Bu bölümde, adlandırılmış varlık tanıma ve duygu analizi yöntemlerinin matematiksel temelleri ve bu yöntemlerin özellikle Türkçe gibi eklemeli dillerde uygulanması üzerine odaklanılmaktadır. Ayrıca, lemmatizasyon (lemmatization) süreçlerinin duygu analizi üzerindeki etkisinden bahsedilmektedir.

Adlandırılmış varlık tanıma, metinlerdeki belirli türdeki varlıkları (örneğin, kişi adları, konular, tarihler, miktarlar) otomatik olarak belirleme ve kategorize etme işlemidir [5]. Adlandırılmış varlık tanıma, bilgi çıkarımı, metin madenciliği (text mining) ve duygu analizi gibi birçok DDİ uygulamasında kritik rol oynar ve problemleri genellikle ardışık veri modelleme çerçevesinde ele alır. Belirli bir metindeki kelimelerin dizisi  $X = \{x_1, x_2, \dots, x_n\}$  ve bu kelimelere karşılık gelen etiketler  $Y = \{y_1, y_2, \dots, y_n\}$  olduğu düşünüldüğünde amaç, gözlemlenen kelime dizisi  $X$  için en olası etiket dizisi  $Y$ 'yi bulmaktır. Belirtilen etiket dizisi Denklem (1) ile bulunur:

$$\hat{Y} = \underset{Y}{\operatorname{argmax}} P(Y|X) \quad (1)$$

Adlandırılmış varlık tanıma modelinin belirli bir kelimenin hangi varlık türüne ait olduğunu belirlerken en olası sınıfı seçmesi için bu formül kullanılmaktadır. Bu olasılık genellikle Denklem (2)'deki gibi faktörize edilir:

$$P(Y|X) = \prod_{i=1}^n P(y_i | y_{i-1}, X) \quad (2)$$

Bu formül, her  $y_i$  çıktısının bir önceki çıktı  $y_{i-1}$  ve giriş verisi  $X$  dikkate alınarak hesaplanan koşullu olasılıklarının tüm zaman adımları boyunca çarpımı ile toplam olasılığı ifade eder. Modern yöntemlerde, bu problemin çözümünde derin öğrenme (deep learning) tabanlı yaklaşımlar kullanılmaktadır. Transformer [10] tabanlı modeller, özellikle BERT (Bidirectional Encoder Representations from Transformers) [11], bağlamsal bilgiyi yakalamak için yaygın olarak kullanılır. Bu çalışmada da Türkçe diline özel olarak önceden eğitilmiş BERTurk modelinin iki varyantı dbmdz/bert-base-turkish-128k-uncased ve dbmdz/bert-base-turkish-cased üzerinde fine-tuning gerçekleştirilmiştir. Bu modeller, Yıldırım (2024) tarafından da benzer biçimde Türkçe NLU görevlerinde başarılı sonuçlar elde edilmesini sağlayan BERTurk mimarisine dayanmaktadır [12]. BERT tabanlı adlandırılmış varlık tanıma modelinin çıkışı, dikkat mekanizması (attention) ile Denklem (3)'teki gibi hesaplanır:

$$\operatorname{Attention}(Q, K, V) = \operatorname{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3)$$

Burada  $Q$  sorgu,  $K$  anahtar,  $V$  değer matrisidir.  $d_k$  ise matris boyutlarını ölçeklendiren bir sabittir. Bu formül, giriş verisindeki farklı öğelere (kelimelere, tokenlara) daha fazla veya daha az önem verilmesini sağlamak için kullanılır. Yani, modelin belirli kelimelere odaklanmasını ve bağlamı daha iyi anlamasını sağlar. BERT tabanlı modeller, çift yönlü dikkat mekanizması sayesinde, kelimelerin hem önceki hem de sonraki bağlamını öğrenerek yüksek doğruluk seviyelerine ulaşır.

Adlandırılmış varlık tanıma modellerinin başarılarını değerlendirmek için performans metriklerinden kesinlik (precision), duyarlılık (recall), F1 skoru (F1-Score) ve MCC (Matthews Correlation Coefficient) kullanılmış olup, bunların matematiksel ifadeleri Denklem (4), Denklem (5), Denklem (6) ve Denklem (7)'de verilmiştir [5].

$$\operatorname{Kesinlik} = \frac{TP}{TP + FP} \quad (4)$$

$$\operatorname{Duyarlılık} = \frac{TP}{TP + FN} \quad (5)$$

$$\operatorname{F1 skoru} = 2 \times \frac{\operatorname{Kesinlik} \times \operatorname{Duyarlılık}}{\operatorname{Kesinlik} + \operatorname{Duyarlılık}} \quad (6)$$

$$\operatorname{MCC} = \frac{(TP \times TN) - (FP \times FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (7)$$

Kesinlik, doğru tahmin edilen pozitif gözlemlerin toplam tahmin edilen pozitif gözlemlere oranıdır. Duyarlılık, yine doğru tahmin edilen pozitif gözlemlerin gerçek sınıftaki tüm gözlemlere oranıdır. F1 skoru ise, kesinlik ve hassasiyetin harmonik ortalamasıdır [13]. MCC ölçütü; TP, TN, FP ve FN değerlerini dengeli şekilde değerlendirerek modelin dengesiz veri kümelerinde de iyi olup olmadığını anlaşılmasına yardımcı olur.

Duygu analizi, metinlerdeki duygusal eğilimlerin (örneğin olumlu, olumsuz, nötr) belirlenmesi amacıyla kullanılan bir DDİ tekniğidir. Günümüzde bu analiz, sadece genel metin düzeyinde değil, özellik ve varlık düzeyinde de yapılmaktadır [7]. Kelimeleri sayısal bir temsile dönüştürerek duygu analizinde kullanılabilir yapı oluşturmak için öncelikle bir metin  $X$ ,  $X = \{x_1, x_2, \dots, x_n\}$  gibi kelimelerin sıralı bir dizisi olarak temsil

edilir. Ardından bu metin, bir gömme (embedding) fonksiyonu (f) kullanılarak yüksek boyutlu bir vektör uzayına Denklem (8) ile dönüştürülür:

$$w_i = f(x_i) \in \mathbb{R}^d \quad (8)$$

Bu formülde  $w_i$ ,  $x_i$  kelimesinin d-boyutlu vektör temsili olarak tanımlanır.

Duygu analizi bağlamında, bir metnin hangi duygu kategorisine ait olduğunu belirlemek için kullanılan bir sinir ağı modelinin çıktı fonksiyonu genellikle Denklem (9)'daki gibi ifade edilir:

$$P(y|X) = \text{softmax}(W_2 \cdot \text{ReLU}(W_1 \cdot h + b_1) + b_2) \quad (9)$$

Bu formülde h gömme vektörlerin birleştirilmiş temsili,  $W_1$  ve  $W_2$  ağırlık matrisleri,  $b_1$  ve  $b_2$  "bias" terimleri ve  $\text{ReLU}(z) = \max(0, z)$  aktivasyon fonksiyonu anlamına gelmektedir.

Özellik tabanlı duygu analizi, sadece metnin genel duygusunu değil, belirli varlıkların veya özelliklerin duygusal eğilimlerini belirler. Örneğin, "Bu kulaklığın ses kalitesi harika, ancak fiyatı çok yüksek." cümlesinde "ses kalitesi" olumlu, "fiyat" olumsuz anlam taşıdığını anlamak için adlandırılmış varlık tanıma ve duygu analizi modellerinin entegrasyonu gereklidir. Duygu analizinde de adlandırılmış varlık tanımaya benzer şekilde kesinlik, duyarlılık ve F1 skoru ölçütleri kullanılır. Ancak bu ölçütler, her sınıf (olumlu, olumsuz, nötr) için ayrı ayrı hesaplanır ve bir ağırlıklı ortalama alınarak genel performans değerlendirilir.

Lemmatizasyon, kelimenin kök formunu elde etmek için kullanılan ön işleme (preprocessing) tekniğidir. Türkçe gibi eklemeli dillerde, lemmatizasyon işlemi genellikle karmaşıktır ve dil bilimsel eklerin doğru şekilde işlenmesini gerektirir [14]. Özellikle olumsuzluk eklerinin doğru işlenmesi, duygu analizinde kritik rol oynar. Lemmatizasyon olasılığı Denklem (10)'daki şekilde formüle edilebilir:

$$\text{Lemma}(w) = \underset{l \in L}{\text{argmax}} P(l|w) \quad (10)$$

Bu formülde w girdi kelime, l lemma (kök) adayları kümesi ve  $P(l|w)$  kelimenin kökünün l olma olasılığıdır.

Türkçe gibi eklemeli dillerde, olumsuzluk eklerinin yanlış işlenmesi, duygu analizinin doğruluğunu ciddi şekilde etkileyebilir. Örneğin Türkçede "yeterli" kelimesi olumlu anlam taşıırken "yetersiz" kelimesi olumsuz anlam taşımaktadır. İkisinin de kökü "yeter" olduğundan kök alma (stemming) işlemi uygulanınca duygu analizinde yanlış anlam çıkmasına yol açmaktadır. Bu nedenle, çalışmada olumsuzluk ekleri içermeyen kelimelere lemmatizasyon işlemi uygulanmış ve bu da daha iyi sonuçlar alınmasını sağlamıştır.

#### 4 İlgili çalışmalar

Literatürde bu alandaki çalışmalar genelde ürün incelemelerinin kullanıcı üzerindeki etkisini incelemek üzerine kuruludur. Xia ve arkadaşları tarafından yapılan çalışmada, duygu sınıflandırmasını iyileştirmek için birleşik model (ensemble) teknikleri kullanılmıştır [15]. İlgili çalışmada, sözcük türü (POS) ve sözcük ilişkisi tabanlı (WR) olmak üzere iki tür özellik seti ve "Naive Bayes", "Maximum Entropy" ve "Destek Vektör Makineleri (Support Vector Machines - SVM)" olmak üzere üç sınıflandırma algoritması kullanılmıştır. Sabit kombinasyon, ağırlıklı kombinasyon ve meta-sınıflandırıcı kombinasyonu olmak üzere üç birleşik model yöntemi değerlendirilmiş ve bu yöntemler daha yüksek doğruluk sağlanması amacıyla beş farklı veri kümesinde test edilmiştir. Çalışmanın savı, duygu sınıflandırmasında farklı özellik

kümelere ve sınıflandırma algoritmalarını birleştirerek genel performansı artırmak için birleşik model tekniklerinin etkili bir yöntem olduğu yönündedir.

Rie Johnson ve Tong Zhang tarafından yapılan çalışmada ise metin kategorileme için kelime sırasını esas alarak tahminleme amacıyla Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN) incelenmiştir [16]. Bu çalışmanın diğer çalışmalardan ayrılan asıl özelliği ise düşük boyutlu metin verisi yerine doğrudan yüksek boyutlu metin verilerinin kullanılmasıdır. Bu çalışma, kelime sıralamasıyla konu sınıflandırma performansını arttıran ilk çalışmalardan biri olarak bilinmektedir. Sonuç olarak, Seq2-bow-CNN modeli, IMDB'de %7.67 ve ELEC'te %7.14 hata oranı ile oldukça iyi sonuçlar elde etmiştir.

Twitter verileriyle duygu analizi üzerine yapılan bir diğer çalışmada [17], hem sözlük tabanlı hem de n-gram modeli kullanılarak olumlu, olumsuz ve nötr sınıflandırmaları yapılmıştır. Çalışmada, sözlük yöntemi n-gram yöntemine göre daha başarılı bulunmuş ve DDİ yöntemleriyle Türkçe Twitter verilerinin analiz edilmesine yönelik önemli katkılar sağlanmıştır.

Cem Rıfky Aydın tarafından yapılan çalışmada ise 'Twitter' ve 'beyazperde.com' üzerindeki veriler kullanılarak denetimsiz (unsupervised) ve yarı denetimli (semi-supervised) makine öğrenimi (machine learning) yöntemleriyle duygu analizi gerçekleştirilmiştir [18]. Çalışmada, duygu sözcükleri oluşturma, derin yapay sinir ağları, anlamsal/duygusal kelime vektörleri ve yön bazlı duygu analizi gibi teknikler uygulanmıştır. Çalışmanın en önemli özelliklerinden biri, sondan eklemeli yapısı ve olumsuzluk içeren ifadeleri nedeniyle işlenmesi zor olan Türkçe dilinin kullanılmış olmasıdır. Çalışmanın sonucu itibarıyla, film yorumları için %90, 'Twitter' veri seti için ise %80 doğruluk oranları saptanmıştır.

İrem Nur Yoldaş tarafından yapılan çalışmada, Türkçe duygu analizi için sözlük tabanlı bir sistem geliştirilmiştir [19]. Sözlük tabanlı yaklaşım ile duygu analizi için SentiTurkNet sözlüğü kullanılmıştır. Tweepy modülü ile Twitter üzerinden belli anahtar kelimeler kullanılarak veri seti toplanmıştır. Sözlük, kelimeler ve onların pozitif, negatif ve nötr kutup puanlarını içerecek şekilde sadeleştirilip düzenlenmiştir. Test aşamasında veriler sırası ile çekilip gelen cümle etkisiz kelimelerden (stop words) ve noktalama işaretlerinden arındırılmıştır. Kök bulma işleminde ağaçlar kullanılmış ve en iyi analiz kök kabul edilmiştir.

Zekeriya Anıl Güven tarafından yapılan çalışmada, BERT modelleri ve makine öğrenimi yöntemlerinin karşılaştırması yapılmıştır [20]. Veri seti 5 sınıfa ayrılarak etiketlenmiştir. Ön işleme teknikleri olarak normalizasyon işlemi yapılmış, NLTK etkisiz kelimeler kütüphanesinin Türkçe için oluşturduğu dosya kullanılmış ve kök alma işlemi uygulanmıştır. Makine öğrenimi yöntemleri olarak Rastgele Orman (Random Forest), Navie Bayes ve Lojistik Regresyon kullanılmıştır ve Lojistik Regresyon %98.4 ile en başarılı yöntem olmuştur. BERT modellerinde ise Bert-T ve DBert-T modelleri Lojistik Regresyon yönteminin başarısının üzerine çıkmıştır. Tüm yöntemler ve modeller arasında dil modellerinden Bert-T modeli %98.75 ile en yüksek başarıyı elde etmiştir.

Serpil Aslan tarafından yapılan çalışmada ise veri seti olarak veri paylaşım platformu olan Kaggle'dan alınan, ürün inceleme yorumlarını içeren 'Womens Clothing E-Commerce Reviews' veri seti kullanılmıştır [21]. Sınıflandırma için "TF-IDF" ve

“Word2Vec” teknolojileri, duygu analizi için ise sözlük tabanlı bir duygu analizi aracı olan “VADER” kullanılmıştır. Çalışmanın iddiası geleneksel yöntemlerin aksine özellikle düzeyli duygu analizi ile ilgili platformlarda alışveriş yapanlara daha doğru bir satın alma sunulacağı yönündedir.

Literatürde yer alan önceki çalışmalarda yaygın olarak kullanılan lemmatizasyon teknikleri, genellikle olumsuzluk eklerini dikkate almadan uygulanmış ve bu durum duygu analizinde hata oranlarını artırmıştır. Örneğin, Serpil Aslan’ın çalışmasında [21] TF-IDF ve Word2Vec kullanılarak özellik tabanlı duygu analizi yapılmış ancak olumsuzluk ekleri özel olarak ele alınmamıştır. Benzer şekilde, Zekeriya Anıl Güven’in çalışmasında [20] BERT modelleri ve makine öğrenimi yöntemleri karşılaştırılmış olsa da lemmatizasyonun duygu analizi üzerindeki etkisi ayrıntılı olarak incelenmemiştir. Bu çalışmada ise, üç farklı lemmatizasyon yöntemi test edilmiş ve “olumsuzluk eki içeren kelimelere lemmatizasyon uygulanmaması” tekniğinin duygu analizi doğruluğunu artırdığı gösterilmiştir. Bu, özellikle Türkçe gibi eklemeli dillerde duygu analizi model performansını artırmada kritik bir adımdır.

Bu metinde açıklanmaya çalışılan, e-ticaret sitelerindeki yorumlara yönelik olan ilk çalışmada, Türkiye’de en çok kullanılan alışveriş sitelerinden olan Trendyol’daki kullanıcı yorumları çekilerek oluşturulan bir veri seti kullanılmıştır. Burada yöntem olarak, bahsi geçen diğer çalışmalardan farklı olarak, çekilen verilerin belirlenen bir gerçeklik kriterinden geçirilip gerçek olmadığı düşünülen verilerin veri setinden çıkarılması ve daha detaylı özellik tanımlama şablonu ile etiketlenmesi kullanılmıştır. Böylece kullanıcılara, ürünün özellikleri hakkında daha detaylı ve gerçekçi bir geri dönüş sağlanabilmiştir. Müşteri geri bildirimlerine yönelik olan ikinci çalışmada ise, veri seti Twitter platformundan kazınan kullanıcı yorumlarıyla oluşturulmuştur. Toplanan kullanıcı yorumları işlenirken metinler belirteçleştirme (tokenization) yöntemiyle kelimelere ayrılıp dil analizlerinde gerekli olmayan etkisiz kelimelerden temizlenmiştir. Çift aşamalı ön işleme yöntemi kullanılarak, ilk aşamada gürültü temizleme işlemi gerçekleştirilmiş, ardından geliştirilen lemmatizasyon algoritması uygulanmıştır. İki çalışmada da lemmatizasyon işlemi yapıldığında olumsuz ekler de silinebildiği için duygu analizinin çıktılarının yanlış sonuç verebileceği tespit edilmiş ve bu nedenle en doğru sonucu elde etmek için üç farklı lemmatizasyon yöntemi test edilmiştir. Aynı parametreler kullanılarak üç yol için de modeller eğitilmiş ve farklı lemmatizasyon yöntemlerinin etkisi incelenmiştir. Ayrıca e-ticaret çalışması için oluşturulan arayüzde “Hesaplanan Yıldız Puanı” adlı gerçeği daha doğru yansıtan yıldız puanlama sistemi oluşturulmuştur. Oluşturulan bu puanlama sistemi diğer puanlama sistemlerinden farklı olarak seçilen ürün özelliklerinin yorumda pozitif geçtiği sayı baz alınarak ve gerçek dışı yorumlar puanlamaya dahil edilmeyerek oluşturulmuştur. Bunun sonucunda ortaya çıkan puanlamanın gerçeği çok daha iyi yansıttığı söylenebilir. Bu aşamalar sayesinde DDİ alanına büyük ve çeşitli bir veri seti kazandırılmış, geliştirilen lemmatizasyon algoritmaları ile Türkçe dili adına literatüre yeni yöntemler eklenmiştir.

## 5 Materyal ve metod

### 5.1 Veri seti

Çalışmanın ilk safhasında, e-ticaret sitelerindeki yorumlara yönelik olan çalışmada en çok tercih edilen e-ticaret

şirketlerinden olan Trendyol seçilirken müşteri geri bildirimlerine yönelik olan çalışma için Twitter seçilmiş olup bu platformlara uygun veri kazıma yazılımları geliştirilmiştir. Veri kazıma kodu yazarken Beautiful Soup [22], Selenium [23] ve Pandas [24] kütüphanelerinden faydalanılmıştır. E-ticaret sitelerindeki yorumlara yönelik olan çalışmada, veri çekerken güvenlik protokolüne takılmamak ve veri kaybını önlemek için yorum yıldızına göre yorumları çekme özelliği olan bir kod geliştirilmiştir. Veri çekmek için dikkat edilmesi gereken kısımlardan biri de veri seçimidir. Yapılan incelemeler sonrasında, Trendyol’da müşteri geri bildirimlerinde en fazla çeşitliliğe sahip olan ürün kategorisinin “kulaklık” olduğu tespit edilmiştir. Bu nedenle kullanılacak olan kategori kulaklık olarak belirlenmiştir. Trendyol’dan veri kazıma işleminin sonunda toplamda 85000 adet veri elde edilmiştir. Müşteri geri bildirimlerine yönelik olan çalışma için Twitter’den veri çekilirken kolaylık sağlama açısından verilerin çekileceği tarih aralıkları ve hedeflenen anahtar kelimeler (varlıklar) belirlendi. Tablo 1’de belirli kategoriler için kullanılan anahtar kelimeler görülmektedir.

Tablo 1. Müşteri geri bildirimlerine yönelik çalışmada kullanılan detaylandırılmış varlıklar ve kategorileri.

Table 1. Detailed entities and categories used in the study on customer feedback.

Kategori	Anahtar Kelimeler (Varlıklar)
Hava Yolları	Türk Hava Yolları, Pegasus Hava Yolları, SunExpress, AnadoluJet
Canlı Yayın Platformları	Kick-Turkey, Twitch, Nimo TV, Youtube Gaming, Facebook Gaming
Telekomünikasyon Şirketleri	Turkcell, Vodafone, Türk Telekom, Türksat, SuperOnline, TurkNet, Bimcell, Pttcell

Veri seti adımının sonunda Twitter platformundan 96960 adet veri çekilmiştir.

### 5.2 Ön işleme

Doğal dilin karmaşıklığı göz önüne alındığında, ön işleme, ham veriyi analiz için daha yönetilebilir biçime dönüştürmeyi amaçlayan çok önemli bir safhadır. Literatürde yaygın olarak kullanılan ön işleme yöntemleri, temel olarak veri temizleme, veri dönüştürme ve veri azaltma kategorilerine ayrılmaktadır. [25]. Bu çalışmamızda, metin bazlı hataları gidermek amacıyla özel algoritmalar geliştirilmiş ve veri temizleme işlemleri iki aşamalı ön işleme sürecine tabi tutulmuştur. İlk aşamada, özel karakterlerin boşlukla değiştirilmesi, verilerin küçük harfe çevrilmesi, fazla boşlukların ve emojilerin kaldırılması gibi işlemler yapılarak veriler “csv” formatına getirildi. E-ticaret sitelerindeki yorumlara yönelik olan çalışmada ürün, satıcı özellikleri ve yorumlar gibi birçok sütuna ayrılırken müşteri geri bildirimlerine yönelik olan çalışmada sadece Twitter’den çekilen yorumlar dikkate alınmaktadır. İkinci aşamada ise, bilgisayarın metinleri daha kolay işleyebilmesi için metin daha küçük parçaları olan belirteçlere ayrıldı. Çalışmada, özelliklerin doğru belirteçlere atanması ve duygu analizinde duygunun yanlış tespit edilmemesi için kendi geliştirdiğimiz lemmatizasyon yöntemine başvuruldu. Olumsuz duygu tespitinde sorun yaşamamak için, en iyi sonucun alındığı yöntem, olumsuzluk eki içeren kelimelere lemmatizasyon işleminin uygulanmamasının olduğu tespit edildi. Bu bağlamda, kullanılan farklı lemmatizasyon yöntemlerinin avantaj ve dezavantajları da değerlendirildi. Kullanılan lemmatizasyon yöntemleri arasında, “tüm kelimelerin lemmatizasyon işleminden geçirilip olumsuzluk eki içeren kelimelerin köklerine gerekli eklerin tekrardan yerleştirilmesi yöntemi”,

kelimeleri yalın haline getirdikten sonra dil bilgisi kurallarını göz önüne alarak olumsuzluk eklerini sonradan ekleyen bir dönüşüm sağlamıştır. Bu yöntem ile, olumsuzluk eki içeren kelimeler dikkatle işlenmiş ve kelime kökünün yapısı (örneğin, son ünlü harfi gibi) dikkate alınarak uygun olumsuzluk eki ile tamamlanmıştır. "Olumsuzluk eki içeren kelimelere lemmatizasyon işleminin uygulanmaması yöntemi", olumsuzluk eki alan kelimelerin kök forma indirgenmesi veya olumsuzluk eklerinin işlenmesi gibi işlemler gerçekleştirilmemiş ve bu tür yapılar sonraki aşamalara devredilmiştir. "Sadece gürültü temizleme işlemi uygulayıp lemmatizasyon işleminin yapılmaması yönteminde" ise kök-ek ayrımı ya da olumsuzluk eklerinin işlenmesi gibi süreçler gerçekleşmemiş ve kelimeler olduğu gibi listeye eklenmiştir. Böylelikle, bu yöntem yalnızca kelimelerin doğrudan aktarımını sağlamış ve herhangi bir dil bilgisel dönüşüm ya da özel kural uygulanmamıştır.

Bu işlemler sırasında ayrıca tekrarlanan sorunlarla karşılaşmış ve bunların düzeltilmesi için de farklı algoritmalar tasarlanmıştır. Örneğin "yetersiz, kalitesiz, ilgisiz ..." gibi olumsuzluk belirten kelimelerin sonuna gelen -sız,-siz eklerinde karşılaşılan hataları düzeltebilmek için kelimenin sonunda bu ekler varsa kelimeyi işlemden geçirmemek; "değil, yok, hiç, asla, 'hayır'" gibi olumsuzluk ifadelerinin aynı kalması; kendi oluşturduğumuz etkisiz kelimeler listesini kullanarak duygu belirten etkisiz kelimeleri bu listeye eklememek ve son olarak etiketleme sürecinde önemli rolü olan bazı kelimelerin liste halinde değiştirilmemesini sağlamak, gibi yöntemlerden faydalanıldı. Bu çalışmada, Türkçe DDİ üzerinde çalışıldığı için Türkçe dili için geliştirilmiş en işlevli kütüphanelerden olan Zemberek [26] kullanıldı. Çalışmada müşteri yorumları verileri kullanımı nedeniyle yazım yanlışları Zemberek kütüphanesinde bulunan yazım denetleyici (spell checker) ile düzeltildi. Tespit edilemeyen kelimeler için de liste oluşturularak bunların entegrasyonu sağlandı. Bu sayede yazım kontrolü çift aşamalı olarak gerçekleştirilmiş oldu.

### 5.3 Etiketleme ve model eğitimi

E-ticaret sitelerindeki yorumlara yönelik olan çalışmada detaylı bir özellik sistemi oluşturuldu. Oluşturulan bu özellik sisteminin bileşenleri Tablo 2'de gösterilmektedir.

Tablo 2. E-ticaret sitelerindeki yorumlara yönelik olan çalışmada kullanılan detaylandırılmış özellik sistemi.

Table 2. Detailed feature system used in the study on comments on e-commerce sites.

Ana Kategorileri	Alt Kategorileri
Duygu Analizi	Olumlu, olumsuz, nötr
Hizmet Özellikleri	İade sürecinde müşteri hizmetleri, orijinallik, teslimat ve paketlenme, hijyen, satıcı, fiyat
Kullanım Özellikleri	Ses kalitesi, pil ömrü, performans, konfor, bağlantı kalitesi, tasarım, gürültü önleyici, mikrofon kalitesi

İki çalışma için de etiketleme işlemi Label Studio aracı [27] kullanılarak gerçekleştirildi. E-ticaret çalışmasında detaylandırılmış olması ve etiketlemelerin genel görüşe hitap edebilmesi için en doğru olduğunu düşünülen 8323 veri seçilerek bunlar model eğitiminde kullanıldı. Kullanılan 8323 verinin %90'ı eğitim için %10'u ise doğrulama için ayrıldı. İkinci çalışmada da aynı şekilde verilerin %90'ı eğitim, %10'u doğrulama için ayrıldı. Müşteri geri bildirimlerine yönelik olan çalışmada Tablo 1'de gösterilen kategorilere göre varlık

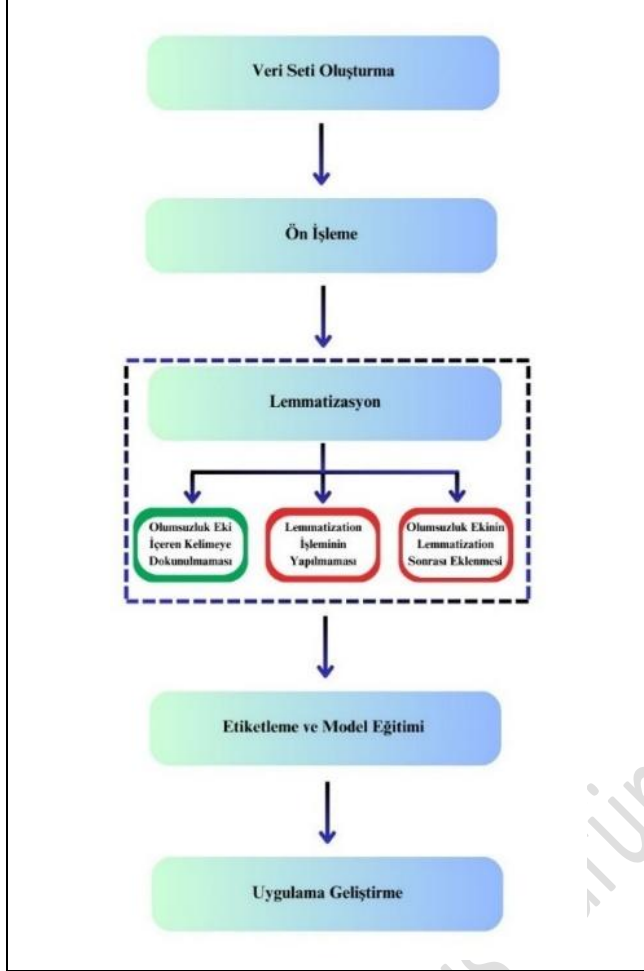
etiketlemeleri yapılırken etiketlenen varlıkların cümledeki duyguları için de olumlu, olumsuz ve nötr şeklinde etiketlemeler yapılmıştır. Son yıllarda DDİ alanında çok tercih edilen ve başarıyla kullanılan BERT [11] modelinde karar kılındı. BERT modelini tercih etmemizin temel nedeni, çift yönlü olarak eğitilmiş bir model olması ve bu sayede bağlamı daha iyi anlayabilmesiydi. Transformer tabanlı alternatif bir model olan GPT-3, metin oluşturma konusunda başarılı olmasına karşın, çok sayıda parametreye sahip olması nedeniyle hesaplama açısından maliyetlidir [28]. BERT, soru ve bağlamı birleştirir; ön eğitim sırasında elde edilen dil temsillerinden faydalanarak bilgiyi anlamak ve kesin yanıtlar üretmek için çalışır [29]. Bir diğer alternatif model olan RoBERTa, daha büyük ölçekli ön eğitim, geniş veri kümeleri ve optimize edilmiş eğitim süreçleri sayesinde bazı kıyaslamalarda daha iyi performans gösterse de, bu iyileştirmelerle artan hesaplama maliyeti ve kaynak gereksinimleri nedeniyle uygulamamız açısından dezavantaj sağlar [30]. Ayrıca, BERT tarafından sunulan önceden eğitilmiş gösterimler, az sayıda etiketli veriyle verimli ince ayar yapılmasına olanak tanıyarak çalışmamızın hız, verimlilik ve sonuçların sunulmasında veri etiketleme açısından maliyet tasarrufu sağlamasına olanak tanır. Çalışmalarda, adlandırılmış varlık tanıma modeli eğitimi için "dbmdz/bert-base-turkish-128k-uncased" modeli, duygu analizi modeli eğitimi için "dbmdz/bert-base-turkish-cased" modeli kullanıldı. Eğitim sırasında model performansını artırmak için hiper parametre ayarlamaları yapıldı.

### 5.4 Kullanıcı uygulaması geliştirme aşaması

E-ticaret sitelerindeki yorumlara yönelik olan çalışmada, veri kazıma aşamasında elde edilen 85000 veri içerisinde birçok kulaklık markası ve modeli bulunmaktaydı. İlk aşama için 2 marka ve 4 model belirlenerek 8323 etiketlenmiş veri dışında kalan müşteri yorumlarının tümü elektronik tablo dosyasında toplandı. Etiketlenen veriler model eğitimi için kullanılırken elektronik tablo dosyasında tutulan veriler her modelin puanlandırılması için kullanıldı. Tüm verilerdeki yorumlarda adlandırılmış varlık tanıma modeli kullanılarak özellik kategorileri belirlendi ve duygu analizi modeli kullanılarak da olumlu, olumsuz, nötr şeklinde olan duyguları atandı. İkinci aşama için FastAPI [31] arayüzü kullanılarak bu veriler çalışmaya uygun olarak işlemler yapıldı. Uygulamanın çalışma aşamasında, kullanıcıdan istediği ürünü açıklaması istenip bu açıklamadan adlandırılmış varlık tanıma modeli kullanılarak özellikler belirlenmektedir. Arka planda tutulan elektronik tablo verilerinden tespit edilen özelliklere sahip olan modeller için pozitif duyguların, tespit edilen tüm duygulara oranı alınıp beğeni sayısı dikkate alınarak bunlara puanlamada daha yüksek bir ağırlık verilmektedir. Sistemde, her bir özellik için puanlandırma yapılabileceği gibi, istenilen tüm özelliklere uygun puanlandırma sistemi ile modeller sıralanabilmekte ve yıldız sistemi ile kullanıcılara daha doğru bir sonuç yansıtılabilmektedir. Sıralama sırasında ayrıca, kullanıcıya sunulan kulaklık modellerinin özellikleri de kendisine iletilmektedir. Müşteri geri bildirimlerine yönelik olan çalışmada da etiketleme ve model eğitim süreçlerinin tamamlanmasının ardından, modelin entegrasyonu ve ürünün ortaya çıkarılması için FastAPI kullanılmıştır. Kullanıcıdan gelen veriler, FastAPI üzerinden alınıp ön işleme adımlarından geçirildikten sonra ilgili modele yönlendirilir. Modelin ürettiği sonuçlar uygulama programlama arayüzü aracılığıyla kullanıcıya geri döndürülür. Böylece, hızlı, ölçeklenebilir ve

kullanıcı dostu bir duygu analizi ve varlık tanıma hizmeti sunulmuştur.

Çalışmalarda kullanılan yöntemin aşamaları Şekil 1’de verilmiştir.



Şekil 1. Çalışmalarda kullanılan yöntemin aşamaları.

Figure 1. Stages of the method used in the studies.

## 6 Bulgular ve Tartışma

Yazının önceki bölümlerinde, olumsuz duygu tespitinde sorun yaşamamak için lemmatizasyon safhasında farklı yöntemlerin denendiğinden bahsedilmişti. Yöntemlerin doğruluk tespiti için, daha küçük bir veri seti ile aynı parametreler kullanılarak “olumsuzluk eki içeren kelimelere lemmatizasyon işleminin uygulanmaması”, “sadece gürültü temizleme işlemi uygulayıp lemmatizasyon işleminin yapılmaması” ve “tüm kelimelerin lemmatizasyon işleminden geçirilip olumsuzluk eki içeren kelimelerin köklerine gerekli eklerin tekrardan yerleştirilmesi” şeklinde üç yol için de modeller eğitildi ve “olumsuzluk eki içeren kelimelere lemmatizasyon işleminin uygulanmaması” tekniğinin duygu analizi modeli için daha iyi çıktığı tespit edildi. Adlandırılmış varlık tanıma modelinde beklendiği kadar iyi bir sonuç alınmasa da yapılan işlem duygu analizi için önemli olduğundan çalışmada bu yöntemin kullanılmasına karar verildi.

E-ticaret sitelerindeki yorumlara yönelik olan çalışmada adlandırılmış varlık tanıma ve duygu analizi modelleri için parametreler “train epochs = 10”, “train batch size = 16”, “eval

batch size = 16” ve “learning rate = 2e-5” olarak alınmış olup üç yöntem için de her iki model eğitilmiş ve alınan sonuçlar Tablo 3’de listelenmiştir.

Tablo 3. E-ticaret sitelerindeki yorumlara yönelik olan çalışmada iki model için alınan eğitim sonuçları.

Table 3. Training results for two models in the study on comments on e-commerce sites.

	Sadece Temizleme İşlemi	Olumsuzluk Ekli Kelimeye Dokunulmadığı	Olumsuzluk Ekinin Sonradan Eklendiği
NER Modeli Yöntemler / İstatistikler			
Eval Loss	0.578	0.614	0.626
Precision	0.547	0.488	0.519
Recall	0.297	0.313	0.351
F1 Score	0.385	0.382	0.419
Duygu Modeli Yöntemler / İstatistikler			
Eval Loss	0.801	0.601	0.652
Precision	0.747	0.776	0.711
Recall	0.633	0.727	0.667
F1 Score	0.677	0.750	0.688

Müşteri geri bildirimlerine yönelik olan çalışmada adlandırılmış varlık tanıma modeli için parametreler “train epochs = 5”, “train batch size = 16”, “eval batch size = 16” ve “learning rate = 2e-5” olarak, duygu analizi modeli için parametreler “train epochs = 20”, “train batch size = 16”, “eval batch size = 16” ve “learning rate = 2e-5” olarak alınmış olup üç yöntem için de her iki model eğitilmiş ve alınan sonuçlar Tablo 4’de listelenmiştir.

Tablo 4. Müşteri geri bildirimlerine yönelik olan çalışmada iki model için alınan eğitim sonuçları.

Table 4. Training results for two models in the study on customer feedback.

	Sadece Temizleme İşlemi	Olumsuzluk Ekli Kelimeye Dokunulmadığı	Olumsuzluk Ekinin Sonradan Eklendiği
NER Modeli Yöntemler / İstatistikler			
Eval Loss	0.217	0.193	0.159
Precision	0.771	0.866	0.840
Recall	0.739	0.806	0.793
F1 Score	0.755	0.835	0.816
Duygu Modeli Yöntemler / İstatistikler			
Mcc	0.350	0.388	0.344
Precision	0.806	0.916	0.890
Recall	0.672	0.744	0.745
F1 Score	0.715	0.800	0.797


Tablo 3’deki e-ticaret sitelerindeki yorumlara yönelik olan çalışmadaki sonuçlar değerlendirildiğinde, “olumsuzluk eki içeren kelimelere lemmatizasyon uygulanmaması” yönteminin varlık tanıma modeli için iyi bir sonuç vermediği, ancak duygu analizi modeli için en iyi sonucu sağladığı görülmektedir. Olumsuzluk ekleri duyguların belirlenmesinde önem taşımakta olduğundan duygu analizi için önemlidir. Ayrıca bu eklerin eklenmesiyle kökte değişim görülebilmektedir ve olumsuz kelimelerin lemmatizasyon işleminden geçirilmemesi modelin bu değişimi daha iyi anlamasına olanak sağlamaktadır. Buna karşılık, varlıklar için lemmatizasyon işlemi uygulandığında, model varlıkları daha iyi tanıyabilmekte, bu da sonuçların varlık tanıma modellerinde iyi olmamasını sağlamaktadır. Fakat duygu analizinin çalışma için önemi dikkate alındığında,

tablonun ikinci kısmındaki sonuçlar daha çok önem taşımaktadır.

Üç yöntem karşılaştırıldığında “olumsuzluk eki içeren kelimelere lemmatizasyon işleminin uygulanmaması” yönteminin 0.750 F1 skor değeri ile en iyi sonucu verdiği gözlenmiştir. Lemmatizasyon işleminin olumsuzluk eki içermeyen kelimelere uygulanması modelin karmaşık yapıları daha iyi anlaması için önemlidir. Ancak, olumsuzluk eki içeren kelimelere lemmatizasyon uygulanmaması yöntemi duygu analizi modeline katkı sağlamıştır. Bunun nedeni, olumsuzluk eklerinin duygusal ton üzerinde önemli bir rol oynaması ve bu eklerin korunmasıyla modelin olumsuz duyguları daha doğru şekilde algılayabilmesidir. Buna karşın, olumlu kelimelere de lemmatizasyon yapılması, “sadece gürültü temizleme işlemi yapıp lemmatizasyon işleminin yapılmaması” yönteminin en kötü sonucu vermesine yol açmıştır.


“Tüm kelimelerin lemmatizasyon işleminden geçirilip olumsuzluk eki içeren kelimelerin köklerine gerekli eklerin tekrardan yerleştirilmesi” yöntemi, en iyi sonuç olmasa da olumlu kelimelere lemmatizasyon uygulanması ve olumsuzluk eklerinin korunmaya çalışılması nedeniyle ikinci en iyi yöntem olmuştur. Ancak Zemberek kütüphanesi ile olumsuzluk eklerinin tespitindeki zorluk, bu yöntemin birinci olmasını engellemiştir.

Tablo 3’de alınan sonuçlar bar grafiği şeklinde Şekil 2, Şekil 3’te gösterilmektedir.



Şekil 2. E-ticaret Sitelerindeki Yorumlara Yönelik Çalışmanın Adlandırılmış Varlık Tanıma Modeline Ait Sonuçlar.

Figure 2. Results of the Named Entity Recognition Model of the Study on Comments on E-commerce Sites.



Şekil 3. E-ticaret Sitelerindeki Yorumlara Yönelik Çalışmanın Duygu Modeline Ait Sonuçlar.

Figure 3. Results of the Sentiment Model of the Study on Comments on E-commerce Sites.


Tablo 4’teki müşteri geri bildirimlerine yönelik olan çalışmadaki sonuçlar değerlendirildiğinde, “olumsuzluk eki içeren kelimelere lemmatizasyon uygulanmaması” yönteminin varlık tanıma ve duygu analizi modeli için en iyi sonucu sağladığı görülmektedir.

Üç yöntem karşılaştırıldığında “olumsuzluk eki içeren kelimelere lemmatizasyon işleminin uygulanmaması” yönteminin 0.835 F1 skor değeri ile varlık tanıma modelinde, 0.800 F1 skor değeri ile duygu analizi modelinde en iyi sonucu verdiği gözlenmiştir. Özellikle, olumsuzluk eklerinin korunmasının, duygusal tonun doğru bir şekilde yakalanmasında kritik bir rol oynadığı ve bu nedenle duygu analizi modeline katkı sağladığı görülmektedir. Bununla birlikte, varlık tanıma modelinde de bu yöntemin etkili sonuçlar verdiği anlaşılmaktadır.

Olumsuzluk eki içermeyen kelimelere lemmatizasyon uygulanması, modelin genel olarak daha karmaşık yapıları adapte olmasını sağlarken, olumsuzluk eki içeren kelimelerin bu işlemde muaf tutulması, E-ticaret sitelerindeki yorumlara yönelik olan çalışmada da olduğu gibi, duygu analizi açısından modelin daha hassas bir şekilde çalışmasını mümkün kılmıştır.


Hem adlandırılmış varlık tanıma hem de duygu analizi modellerinde en iyi ikinci sonucu “Olumsuzluk ekinin sonradan eklendiği” yöntem vermiştir. Yöntemin bu başarısı, olumsuzluk eklerinin etkisini hesaba katma çabasına dayanmaktadır. Hem adlandırılmış varlık tanıma hem de duygu analizi modellerinde en düşük performans “Sadece temizleme işlemi” yöntemi göstermiştir. Özellikle olumsuzluk eklerinin dikkate alınmaması, duygusal tonun doğru şekilde yakalanmasını engellemiştir. Serbest ve senaryo verileri kıyaslandığında, her iki veri setinde de “olumsuzluk eki içeren kelimelere lemmatizasyon uygulanmaması” yönteminin en başarılı sonuçları verdiği görülmektedir. Ancak, serbest verilerdeki F1 skor değerlerinin senaryo verilerine göre daha yüksek olduğu gözlemlenmektedir. Bu durum, serbest veri setinin daha geniş ve düzenli bir kelime içeriği sunması dolayısıyla modelin bu verilerden daha iyi öğrenebilmesiyle açıklanabilir.

Tablo 4’de alınan sonuçlar bar grafiği şeklinde Şekil 4, Şekil 5’te gösterilmektedir.



Şekil 4. Müşteri Geri Bildirimlerine Yönelik Olan Çalışmanın Adlandırılmış Varlık Tanıma Modeline Ait Sonuçlar.

Figure 4. Results of the Study on Named Entity Recognition Model Based on Customer Feedback.



Şekil 5. Müşteri Geri Bildirimlerine Yönelik Olan Çalışmanın Duygu Modeline Ait Sonuçlar.

Figure 5. Results of the Emotion Model of the Study on Customer Feedback.

Üç yöntem karşılaştırıldığında, en verimli olan yöntem seçilmiş ve bu yöntemle birçok varlık ve duygu modeli eğitilmiştir. Birden fazla eğitim yapılmasının nedeni hiper parametrelerin farklı kombinasyonlarının denenip en iyi sonucun bulunmaya çalışılmasıdır. "Batch size" ve "learning rate" seçimleri, model performansı üzerinde önemli etkiye sahiptir. Goodfellow ve arkadaşları [32] ile Bengio ve arkadaşları'nın [33] yaptığı çalışmalar, bu parametrelerin model doğruluğu ve genelleme yeteneği gibi kritik rollerde önemli etkiye sahip olduğunu göstermiştir. Küçük bir batch size, modelin daha sık güncellenmesine ve karmaşık yapıları öğrenmesine yardımcı olurken, learning rate çok düşük veya çok yüksek değere ayarlandığında model performansında dalgalanmalara yol açtığı daha önceki çalışmalarda gözlemlenmiştir [34]. Bu nedenle, her iki çalışmada da modellerin eğitiminde hiper parametre olarak "train batch size" için 16, 32 ve "learning rate" için  $2e-5$ ,  $3e-5$  değerlerinin kombinasyonları denenmiştir. Bu hiperparametreler, daha önceki çalışmalarda da yapıldığı gibi farklı değerlerle test edilerek öğrenme sürecinin daha kararlı hale getirilmesi hedeflenmiştir [35],[36]. Batch size değeri ve learning rate'in optimal olması için her bir modelin skoru karşılaştırılarak en iyi sonuç belirlenmiştir. En iyi sonuç alınan model parametreleri e-ticaret sitelerindeki yorumlara yönelik çalışmada "train batch size = 16", "learning rate =  $3e-5$ " olurken müşteri geri bildirimlerine yönelik olan çalışmada "train batch size = 32", "learning rate =  $2e-5$ " olarak belirlenmiştir. Eğitim sonuçları Tablo 5'te gösterilmektedir.

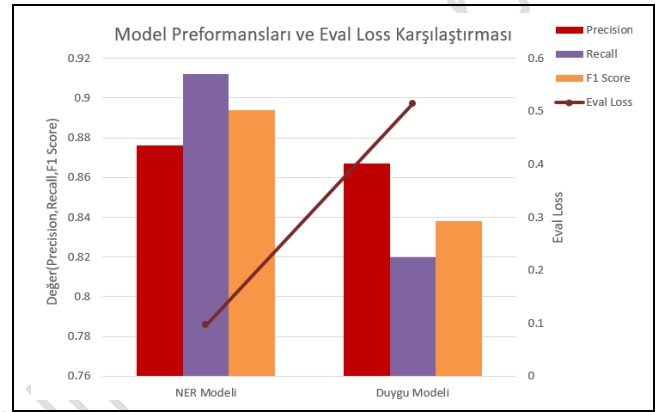
Tablo 5. En iyi sonuç veren model parametreleri ile alınan skorlar.

Table 5. Scores obtained with the model parameters that gave the best results.

E-Ticaret Sitelerindeki Yorumlara Yönelik Olan Çalışma		
	NER Modeli	Duygu Modeli
Eval Loss	0.097	0.514
Precision	0.876	0.867
Recall	0.912	0.820
F1 Score	0.894	0.838
Müşteri Geri Bildirimlerine Yönelik Olan Çalışma		
	NER Modeli	Duygu Modeli
Eval Loss	0.191	0.801
Precision	0.814	0.788
Recall	0.788	0.801
F1 Score	0.801	0.801

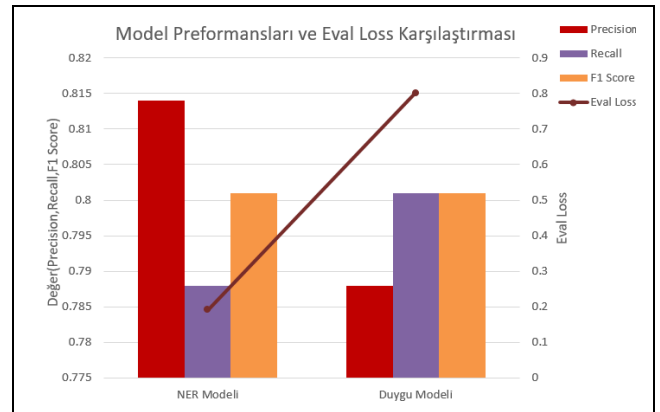
E-ticaret sitelerindeki yorumlara yönelik olan çalışmada eğitilen tüm modeller karşılaştırıldığında seçilen varlık tanıma modeli 0,876 ve seçilen duygu analizi modeli 0,867 değeri ile en yüksek doğruluğa ulaşmıştır. F1 skoru dengeli bir performans göstermekte olup seçilen varlık tanıma modelinde 0,894, duygu analizi modelinde 0,838 olmuştur.

Müşteri geri bildirimlerine yönelik olan çalışmada ise eğitilen tüm modeller karşılaştırılmasıyla seçilen varlık tanıma modeli 0,814 ve seçilen duygu analizi modeli ise 0.788 ile en yüksek doğruluk değerine ulaşmıştır. F1 skoru ise tamamen dengeli bir performans sergileyerek iki model içinde 0.801 değerindedir. Tablo 5'te verilen verilerin görselleştirilmiş hali Şekil 6 ve Şekil 7'de incelenebilir.



Şekil 6. E-ticaret sitelerindeki yorumlara yönelik çalışmanın model performansı.

Figure 6. Model performance of the study on comments on e-commerce sites.



Şekil 7. Müşteri geri bildirimlerine yönelik olan çalışmanın model performansı.

Figure 7. Model performance of the study on customer feedback.

Sonuçlar, her iki çalışmada da adlandırılmış varlık tanıma modelinin kesinlik, duyarlılık ve F1 skoru bakımından duygu analizi modeline göre daha yüksek bir performans sergilediğini göstermektedir. Ayrıca, her iki modelin "eval loss (doğrulama kaybı)" değerleri karşılaştırıldığında, adlandırılmış varlık tanıma modelinin kaybının duygu analizi modelinden daha düşük olduğu gözlemlenmiştir.

Elde edilen "eval loss" değerlerine bakıldığında, özellikle duygu analizi modellerinde kayıp azaldıkça precision, recall ve F1 değerlerinin arttığı görülmektedir. Örneğin, Tablo 3'te kaybın 0.801'den 0.601'e düşmesiyle F1 skoru 0.677'den 0.750'ye

yükselmiştir. Benzer bir şekilde, Tablo 4'te "eval loss" değeri 0.217'den 0.193'e düştüğünde F1 skoru 0.755'ten 0.835'e çıkmıştır. Ancak, e-ticaret sitelerindeki yorumlara yönelik olan çalışmanın adlandırılmış varlık tanıma (NER) modelinde bu ilişki daha zayıf bir şekilde gözlemlenmiştir. Tablo 3'te NER modelinde kayıp 0.614'ten 0.626'ya artarken, F1 skoru 0.382'den 0.419'a yükselmiştir. Bu durum, "eval loss" ile başarı metrikleri arasında her zaman doğrusal bir ilişki olmadığını ve modelin parametreleri ile öğrenme sürecinin bu ilişkiyi etkileyebileceğini göstermektedir.

## 7 Sonuçlar

Bu çalışmada, müşteri geri bildirimlerinin analizinde DDİ tekniklerinin etkinliği incelenmiş ve adlandırılmış varlık tanıma ile duygu analizi yöntemleri kullanılarak geliştirilen iki farklı sistem sunulmuştur. İlk çalışmada, e-ticaret platformlarında kullanıcıların en uygun ürünü bulmasını kolaylaştıran özellik bazlı bir öneri sistemi geliştirilmiştir. Kullanıcı yorumlarından çıkarılan ürün özellikleri temel alınarak, ilgili e-ticaret sitesindeki ürünler puanlanmış ve yeni bir yıldızlama yöntemi ("Hesaplanan Yıldız Puanı") ile sıralanmıştır. Öneri sisteminin kullanıcılara sunulması için FastAPI tabanlı açık kaynak uygulama geliştirilmiş olup, sistem şu an yalnızca kulaklık kategorisinde, iki markanın dört modeli üzerinde test edilmiştir. Çalışmanın kapsamı, farklı kategoriler ve markalar eklenerek genişletilebilir. Ayrıca, veri seti yalnızca Trendyol platformundan alınmıştır. Gelecek çalışmalarda, farklı e-ticaret platformlarından veri toplanarak çapraz platform kıyaslamaları yapılması planlanmaktadır.

İkinci çalışmada, müşteri geri bildirimlerini analiz eden bir sistem geliştirilmiştir. Twitter platformundan hava yolları, canlı yayın platformları ve telekomünikasyon şirketlerine yönelik müşteri yorumları toplanarak incelenmiştir. Yapılan ön işleme sürecinde lemmatizasyon teknikleri karşılaştırılmış ve "olumsuzluk eki içeren kelimelere lemmatizasyon uygulanmaması" yönteminin, BERT tabanlı adlandırılmış varlık tanıma ve duygu analizi modellerinde en iyi sonuçları verdiği belirlenmiştir.

Bu çalışmada kullanılan yöntemler, literatürdeki mevcut çalışmalardan farklılaşmaktadır. Duygu analizi ve adlandırılmış varlık tanıma üzerine yapılan önceki çalışmalar genellikle genel metin veya cümle bazlı analizlere odaklanırken, bu çalışmada varlık bazlı duygu analizi uygulanmıştır. Bu yöntem, her bir varlığın duygu durumunu ayrı ayrı değerlendirmeye olanak tanıyarak daha hassas ve anlamlı sonuçlar elde edilmesini sağlamıştır.

Çalışmanın doğruluğu ve sağlamlığı iki farklı uygulama alanında test edilmiştir. İlk olarak, geliştirilen yaklaşımın öneri sisteminde duygu analizinin doğruluğunu artırmada etkili olduğu görülmüştür. İkinci olarak, yöntem müşteri geri bildirimleri analizinde hem duygu analizi hem de adlandırılmış varlık tanıma modellerinin doğruluğunu artırmıştır.

Elde edilen bulgular, hem e-ticaret platformlarında kullanıcı deneyimini iyileştiren özellik bazlı öneri sistemlerinin geliştirilmesine hem de sosyal medya yorumlarından anlamlı içgörüler çıkararak şirketlere geri bildirim sağlayan sistemlerin oluşturulmasına katkı sağlamaktadır. Ayrıca, standart yıldız puanlama sistemine alternatif olarak geliştirilen "Hesaplanan Yıldız Puanı" yöntemi, tüketici değerlendirmelerinin güvenilirliğini artırmada önemli bir adım olarak öne çıkmaktadır. Gelecekte, modelin farklı sektörlerde uygulanarak genişletilmesi ve daha büyük veri kümeleri üzerinde test

edilmesi, müşteri geri bildirimlerinden daha doğru ve etkili bilgi çıkarım süreçleri geliştirilmesine olanak sağlayacaktır.

## 8 Conclusions

In this study, the effectiveness of NLP techniques in analyzing customer feedback was examined, and two different systems were developed using named entity recognition and sentiment analysis methods. The first study introduced a feature-based recommendation system to help users find the most suitable products on e-commerce platforms. Based on the extracted product features from customer reviews, products on the relevant e-commerce site were scored and ranked using a new star rating system ("Calculated Star Score"). To make the recommendation system accessible to users, an open-source application based on FastAPI was developed. Currently, the system has been tested only on two brands and four models within the headphones category. The scope of the study can be expanded by incorporating different categories and brands. Additionally, the dataset was obtained solely from the Trendyol platform. Future research aims to collect data from multiple e-commerce platforms to enable cross-platform comparisons.

The second study focused on developing a system for analyzing customer feedback. Customer reviews related to airlines, live streaming platforms, and telecommunication companies were collected from Twitter and examined. During the preprocessing phase, various lemmatization techniques were compared, and it was determined that "not applying lemmatization to words with negation suffixes" yielded the best results in BERT-based named entity recognition and sentiment analysis models.

The methods used in this study differ from existing research in the literature. While most previous studies on sentiment analysis and named entity recognition focused on general text or sentence-level analysis, this study applied entity-based sentiment analysis. This approach allowed for the independent evaluation of sentiment for each entity, leading to more precise and meaningful results.

The robustness of the proposed method was validated across two different application domains. First, the approach was found to be effective in improving sentiment analysis accuracy within the recommendation system. Second, it enhanced both sentiment analysis and named entity recognition accuracy in customer feedback analysis.

The findings demonstrate that the proposed method contributes to the development of feature-based recommendation systems that improve user experience on e-commerce platforms and the creation of systems that extract meaningful insights from social media reviews to provide feedback to companies. Additionally, the "Calculated Star Score" method, developed as an alternative to traditional star rating systems, stands out as a significant improvement in enhancing the reliability of consumer evaluations. In the future, expanding the model to different industries and testing it on larger datasets will enable the development of more accurate and effective information extraction processes from customer feedback.

## 9 Yazar katkı beyanı

Gerçekleştirilen çalışmada Yazar 1, danışman olarak yer almış, yazım denetimi ve içerik açısından makalenin kontrol edilmesi başlıklarında; Yazar 2, algoritma ve metot tasarımları ile kullanılacak yazılımların oluşturulması başlıklarında; Yazar 3, elde edilen sonuçların değerlendirilmesi ve makalenin giriş

kısımının yazılması başlıklarında; Yazar 4, literatür taraması ve çalışmaya farklılık kazandıracak araştırmaların yapılması başlıklarında; Yazar 5, çalışma sonuçlarını karşılaştırarak değerlendirme ve bulgular ile tartışma kısmının yazılması başlıklarında; Yazar 6, çalışmada kullanılacak teknik bilgilerin araştırılması ve ön bilgiler bölümünün yazılması başlıklarında; Yazar 7, sonuçların değerlendirilmesi, geçmiş çalışmalarla kıyaslanması ve sonuç bölümünün yazılması başlıklarında katkı sunmuştur. Tüm yazarlar çalışmanın yazılımsal olarak geliştirilmesine katkı sağlamıştır.

## 10 Etik kurul onay ve çıkar çatışması beyanı

"Hazırlanan makalede etik kurul izni alınmasına gerek yoktur". "Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır".

## 11 Kaynaklar

- [1] Kulak H. "COVID-19 pandemisinin e-ticaret üzerindeki etkisinin incelenmesi". *İmgelem*, 7(12), 333-362, 2023.
- [2] Statista. "Increase in social media usage due to COVID-19 worldwide as of April 2020". <https://www.statista.com/topics/7863/social-media-use-during-coronavirus-covid-19-worldwide/> (15.02.2024).
- [3] Kaya M. "Satın alma davranışında yorumların rolü: Trendyol müşterileri üzerinden bir değerlendirme". *Maltepe Üniversitesi İletişim Fakültesi Dergisi*, 7(1), 49-67, 2020.
- [4] Kim D, Ferrin D, Rao R. "A trust-based consumer decision-making model in electronic commerce: The role of trust, perceived risk, and their antecedents". *Decision Support Systems*, 44(2), 544-564, 2008.
- [5] Jurafsky D, Martin JH. *Speech and language processing*. 2<sup>nd</sup> ed. New Jersey, USA, Prentice Hall, 2009.
- [6] Pang B, Lee L. "Opinion mining and sentiment analysis". *Foundations and Trends in Information Retrieval*, 2(1-2), 1-135, 2008.
- [7] Liu B. "Sentiment analysis and opinion mining". *Synthesis Lectures on Human Language Technologies*, 5(1), 1-167, 2012.
- [8] Liang B, Su H, Gui L, Cambria E, Xu R. "Aspect-based sentiment analysis via affective knowledge enhanced graph convolutional networks". *Knowledge-Based Systems*, 235, 107643, 2022.
- [9] Kılıçer S, Şamlı R. "E-ticaret sitelerindeki Türkçe ürün yorumları üzerine makine öğrenmesi algoritmaları ile duygu analizi". *Veri Bilim Dergisi*, 6(2), 15-23, 2023.
- [10] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, Kaiser Ł, Polosukhin I. "Attention is all you need". *Advances in Neural Information Processing Systems*, 30, 2017.
- [11] Devlin J, Chang MW, Lee K, Toutanova K. "BERT: Pre-training of deep bidirectional transformers for language understanding". *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, Volume 1 (Long and Short Papers), Minneapolis, Minnesota, USA, 2-7 June 2019.
- [12] Yıldırım, S. (2024). Fine-tuning transformer-based encoder for turkish language understanding tasks. arXiv preprint arXiv:2401.17396.
- [13] Gencer M. *Yapısal Olmayan Metinler İçin Adlandırılmış Varlık Tanıma Algoritmaları ve Uygulamaları*. Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, İzmir, Türkiye, 2022.
- [14] Uludoğan G, Özçelik R, Parlar S, Ercan G, Yıldız OT. "Türkçe doğal dil işleme için arayüzler". *Signal Processing and Communications Applications Conference*, Sivas, Turkey, 24-26 April 2019.
- [15] Xia R, Zong C, Li S. "Ensemble of feature sets and classification algorithms for sentiment classification". *Information Sciences*, 181(6), 1138-1152, 2011.
- [16] Johnson R, Zhang T. "Effective use of word order for text categorization with convolutional neural networks". *Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, Denver, Colorado, USA, 31 May-5 June 2015.
- [17] Akgül ES, Ertano C, Diri B. "Twitter verileri ile duygu analizi". *Pamukkale University Journal of Engineering Sciences*, 22(2), 106-110, 2016.
- [18] Aydın CR. Developing a comprehensive frameworks for sentiment analysis in Turkish. PhD Thesis, Boğaziçi University, İstanbul, Turkey, 2020.
- [19] Yoldaş İN. "Türkçe metinlerde duygu analizi: Sözlük tabanlı yaklaşım ve insanların tepkilerinin karşılaştırılması". *ESTUDAM Bilişim Dergisi*, 2(1), 1-6, 2021.
- [20] Güven ZA. "Comparison of BERT Models and Machine Learning Methods for Sentiment Analysis on Turkish Tweets". 2021 6th International Conference on Computer Science and Engineering (UBMK), Ankara, Turkey, 15-17 September 2021.
- [21] Aslan S. "Doğal dil işleme teknikleri kullanarak e-ticaret kullanıcı incelemelerinde özellik tabanlı duygu analizi". *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(2), 875-882, 2023.
- [22] Richardson L. "Beautiful Soup Documentation". <https://www.crummy.com/software/BeautifulSoup/> (20.02.2024).
- [23] SeleniumHQ. "Selenium Documentation". <https://www.selenium.dev/> (20.02.2024).
- [24] The pandas development team. "pandas-dev/pandas: Pandas". <https://doi.org/10.5281/zenodo.3509134> (11.03.2024).
- [25] Çetin V, Yıldız O. "A comprehensive review on data preprocessing techniques in data analysis". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 28(2), 299-312, 2022.
- [26] Akın AA, Akın MD. "Zemberek-NLP: Natural Language Processing for Turkic Languages". <https://github.com/ahmetaa/zemberek-nlp> (12.01.2024).
- [27] Label Studio. "Label Studio: Multi-type data labeling tool". <https://labelstud.io> (14.03.2024).
- [28] Sawiński M, Węcel K, Księżniak E, Stróżyńska M, Lewoniewski W, Stolarski P, Abramowicz W. "OpenFact at CheckThat! 2023: Head-to-Head GPT vs. BERT - A Comparative Study of Transformers Language Models for the Detection of Check-worthy Claims". *CLEF 2023: Conference and Labs of the Evaluation Forum*, Thessaloniki, Greece, 18-21 September 2023.
- [29] Özkurt C. "Comparative Analysis of State-of-the-Art Q&A Models: BERT, RoBERTa, DistilBERT, and ALBERT on SQuAD v2 Dataset". *Chaos and Fractals*, 1(1), 19-30, 2024.
- [30] Chatzimina E, Kampolis I, Varlamis I. "A Comparative Sentiment Analysis of Greek Clinical Conversations Using BERT, RoBERTa, GPT-2, and XLNet". *Bioengineering*, 11(1), 521, 2024.
- [31] Ramírez S. "FastAPI Documentation". <https://fastapi.tiangolo.com/> (24.02.2024).
- [32] Goodfellow I, Bengio Y, Courville A. *Deep Learning*. MIT Press, 2016.
- [33] Bengio Y, Boulanger-Lewandowski N, Pascanu R. "Advances in optimizing recurrent networks". *29th International Conference on Machine Learning (ICML)*, Edinburgh, Scotland, 27 June - 3 July 2012.
- [34] Smith LN. "Cyclical learning rates for training neural networks". *2017 IEEE Winter Conference on Applications of*

*Computer Vision (WACV)*, Santa Rosa, California, USA, 24-31 January 2017.

[35] Keskar NS, Mudigere D, Nocedal J, Smelyanskiy M, Tang PTP. "On large-batch training for deep learning: Generalization gap and sharp minima". *International Conference on Learning Representations (ICLR)*, Toulon, France, 24-26 April 2017.

[36] Hoffer E, Hubara I, Soudry D. "Train longer, generalize better: Closing the generalization gap in large batch training of neural networks". *Advances in Neural Information Processing Systems (NeurIPS)*, Long Beach, California, USA, 4-9 December 2017.

Düzenlenmemiş Sürüm - Uncorrected Version