



Restoran Müşteri Yorumlarının Duygu Analizi: Sıfır-Atış Metin Sınıflandırma Yaklaşımı

Kutan Koruyan^{1*}

¹ Yönetim Bilişim Sistemleri, İktisadi ve İdari Bilimler Fakültesi, Dokuz Eylül Üniversitesi, İzmir, Türkiye

kutan.koruyan@deu.edu.tr

Öz

Bu makale, restoranlara yapılan çevrimiçi müşteri yorumlarından yararlanarak müşteri memnuniyetini değerlendirmek ve artırmak amacıyla makine öğrenmesi ve doğal dil işleme temelli bir yöntem önermektedir. Araştırma, çoğunluğu İzmir Körfezi çevresinde yer alan ilçelerdeki 89 balık restoranına odaklanmakta olup, veri seti 2013-2023 yılları arasında yapılan, 43 farklı dili içeren yaklaşık 15.000 müşteri yorumundan oluşmaktadır. Bu kapsamda, çalışmada hedef tabanlı duygu analizi kullanılarak, yemek kalitesi, servis kalitesi, fiziksel çevre ve adil fiyat restoran kalite boyutları temel alınarak sıfır-atış metin sınıflandırma yöntemiyle müşteri yorumlarının analiz edilmesi amaçlanmaktadır. Model değerlendirme metrikleri ümit verici sonuçlar vermekte olup, her sınıf için %75-%88 arası doğruluk ve %72-%88 arası F1 puanı elde edilmiştir. Önerilen yöntem, restoran yöneticilerinin müşteri yorumlarını otomatik olarak farklı kalite boyutlarında değerlendirmesine, restoranın güçlü ve zayıf yönlerini belirlemesine, zaman içinde müşteri memnuniyetindeki değişimleri izlemesine, rakip restoranlarla performans karşılaştırması yapmasına ve Türkçe ile yabancı dildeki müşteri yorumlarını birlikte veya ayrı ayrı analiz etmesine olanak tanımaktadır. Çalışmada önerilen bu yaklaşım, restoran yöneticilerine müşteri beklentilerini daha derinlemesine anlama ve restoran kalitesini iyileştirme konusunda veri analizi odaklı bir yol haritası sunmaktadır.

Anahtar kelimeler: Sıfır-Atış Metin Sınıflandırma, Hedef Tabanlı Duygu Analizi, Müşteri Yorumları, Müşteri Memnuniyeti, Çok Dilli Veri Seti

Sentiment Analysis of Restaurant Customer Reviews: A Zero-Shot Text Classification Approach

Abstract

This paper proposes a machine learning and natural language processing-based method to evaluate and increase customer satisfaction by using online customer reviews of restaurants. The research focuses on 89 fish restaurants, mostly located in the districts around Gulf of İzmir, and the dataset consists of approximately 15,000 customer reviews written between 2013 and 2023, covering 43 different languages. In this context, the study aims to analyse customer reviews using target-based sentiment analysis using zero-shot text classification method based on restaurant quality dimensions of food quality, service quality, physical environment, and fair price. Model evaluation metrics give promising results, with accuracy between 75% and 88% and F1 score between 72% and 88% for each class. The proposed method allows restaurant managers to automatically evaluate customer reviews on different quality dimensions, identify restaurant strengths and weaknesses, monitor changes in customer satisfaction over time, compare performance with competitor restaurants, and analyse Turkish and foreign language customer reviews together or separately. This approach proposed in the study provides restaurant managers with a data analysis-focused roadmap to understand customer expectations more deeply and improve restaurant quality.

Keywords: Zero-Shot Text Classification, Target-Based Sentiment Analysis, Customer Reviews, Customer Satisfaction, Multilingual Data Set

1. Giriş (Introduction)

Küreselleşme ve şehirleşmenin etkisiyle bireylerin yaşam tarzları, gelir düzeyleri, tüketim ve yeme-içme

alışkanlıkları hızla değişmektedir. Yeme-içme alışkanlıklarındaki değişimin bir sonucu olarak ise restoran işletmeciliği giderek daha fazla önem

* Sorumlu yazar.
E-posta adresi: kutan.koruyan@deu.edu.tr

Alındı : 3 Eylül 2024
Revizyon : 27 Ekim 2024
Kabul : 4 Şubat 2025

kazanmakta; bireylerin evleri dışında yemek yeme eğilimi, etkin hizmet sunan restoranların sayısının artmasına neden olmaktadır (Yüksekbilgili, 2014). Günümüzde, restoranlar insanların sadece beslenme ihtiyacını karşılamakla kalmayıp, aynı zamanda sosyal etkileşim merkezleri haline dönüşmüştür. Bunun sonucu olarak da dışarıda yemek yeme alışkanlığı günlük bir aktivite haline gelmiş, bu da birçok yeni restoranın açılması sonucunda rekabetin artmasına sebep olmuştur (Bengül ve Dinç, 2023). Ayrıca, yerel halkın dışında, turistlerin yeni yiyecek ve içecek deneyimleri kazanmasına imkân tanıyan gastronomi turizmi, geçmişten günümüze yaygınlaşarak, önemli bir pazar haline gelmiştir (Akkurt Kurnaz, 2024; Küçükkömürler vd., 2018). Gastronomi turizmi bölge turizminin tanıtımına yardımcı olarak, bölgenin ekonomik gelişimine katkı sağlamaktadır (Hall vd., 2003).

Rekabetin yüksek olduğu restoran sektöründe, müşterilerin beklentilerini karşılamak ve hizmet sonrası memnun kalmalarını sağlamak tüm işletmelerin kritik hedefidir (Kukanja vd., 2017). Başarılı bir restoran yönetimi, hedef pazarlarının ana özelliklerini, yeni müşterileri nasıl çekeceğini, mevcut müşterileri elde tutmak için hangi rekabet faktörlerinin önemli olduğunu bilmek zorundadır (Yi vd., 2018).

Son zamanlarda, sosyal ağlar gibi birçok çevrimiçi kanal, her sektörde olduğu gibi restoranlar için de daha fazla performans izleme fırsatı sunmaktadır (Lepkowska-White ve Parsons, 2019). Çünkü, restoran yöneticileri neyi doğru veya neyi yanlış yaptıklarını, başka bir deyişle, müşteri memnuniyetini (veya memnuniyetsizliğini) müşteri yorumları vasıtasıyla çevrimiçi mecralardan takip edebilmektedir. Bunun yanı sıra işletmeler, bu yorumları zamanında değerlendirip analiz ettiğinde iş fırsatlarını geliştirmek ve iyileştirmek için kullanabilmektedirler (Revathi vd., 2023). Tüketiciler ise bir restorana gitmeden önce çevrimiçi kanallardan restorana daha önce ziyaret edenlerin tavsiye ve yorumlarını dikkate almakta; böylece, kendi algıları şekillenmektedir (Jurafsky vd., 2014; Kumar vd., 2020).

Tüm bunlar göz önünde bulundurulduğunda, çevrimiçi müşteri yorumları restoran yöneticileri için önemli bir veri kaynağıdır. Diğer taraftan, bazen müşteri yorumları teker teker okunup analiz edilemeyecek kadar büyük boyutta veya devamlı akan yapıda olabilmektedir. Dolayısıyla, müşterilerin işletme hakkında yazdıkları yorumlardaki memnuniyeti belirlemek, başka bir deyişle, metinlerdeki pozitif veya negatif duygu durumunu otomatik olarak nitelendirmek için literatürde duygu analizi olarak adlandırılan yöntem kullanılmaktadır. Duygu analizi, bir metin parçasındaki duyguyu belirlemek amacıyla, belirli kelimelerin varlığı veya belirli konuların ele alınma düzeyi gibi özelliklere dayalı olarak, doğal dil işleme ve makine öğrenmesi teknikleri kullanılarak belgelerin sınıflandırılması olarak tanımlanmaktadır (Henrickson vd., 2019).

Geleneksel duygu analizi metindeki genel duyguyu ortaya çıkarmaktadır. Fakat, bazen müşteri yorumları

birçok boyuta odaklanabilmektedir. Örneğin müşteri, tek bir yorumda bir şeyi çok sevdiğini gibi aynı anda başka bir şeyden memnun kalmadığını belirtebilir. Böyle durumlarda, geleneksel duygu analizinin kullanımı restoranın hangi özelliğinin iyi veya kötü olduğunu ortaya çıkarmayıp, sadece genel bir sonuç verecektir. Literatürde hedef tabanlı duygu analizi olarak adlandırılan yaklaşımla ise metnin belirli parçaları veya özellikleri üzerine odaklanılmakta ve bu farklı özellikler üzerine duygu analizi gerçekleştirilmektedir. Böylece, bu yöntem sayesinde işletmelerde iyileştirilmesi gereken spesifik boyutlar belirlenebilir, bu boyutlara yönelik gerekli düzenlemeler yapılabilecektir.

Bu çalışmada, Google Maps haritalama servisi bünyesindeki Google Yerel Rehberler’de yer alan çoğunluğu İzmir Körfezi çevresindeki ilçelerde konumlanmış 89 adet balık restoranına yapılan müşteri yorumları veri seti olarak kullanılarak, sıfır-atış metin sınıflandırma yöntemi ile hedef tabanlı duygu analizi gerçekleştirilmiştir. Çalışmada metinler, Gagić vd.’nin (2013) önerdiği restoran müşterilerinin memnuniyetini etkileyen en önemli boyutlar olan yemek kalitesi, servis kalitesi, fiziksel çevre ve adil fiyat, olumlu ve olumsuz olmak üzere sekiz kategoride sınıflandırılmıştır.

Bu çalışmanın amacı; restoranların müşteri memnuniyetini etkileyen kalite boyutlarının analiz edilerek, restoranların güçlü ve zayıf yönlerinin belirlenmesi ve bu doğrultuda iyileştirilmesi gereken alanların tespit edilmesine yönelik bir yöntem ortaya koymaktır. Buna yönelik olarak da müşteri yorumları kullanılarak restoranların zaman içindeki kalite boyutlarındaki değişimler incelenmiştir. Ayrıca, çok dilli yapıya sahip olan müşteri yorumları üzerinden Türkçe ve yabancı dilde yazan kullanıcıların görüşleri de karşılaştırılmıştır. Çalışmada önerilen yöntem sayesinde, restoran yöneticilerinin stratejik karar alma süreçlerinde veri odaklı bir yaklaşımla zaman içindeki müşteri memnuniyetindeki değişimleri izleyebilmeleri, müşteri beklentilerini daha iyi anlayabilmeleri ve hizmet kalitesinin iyileştirilmesine yönelik somut adımlar atmalarının desteklenmesi hedeflenmiştir. Bu çerçevede, işletmelerin restoran sektöründe artan rekabet koşullarında sürdürülebilir müşteri memnuniyetini sağlama kapasitelerinin artırılması amaçlanmaktadır.

Restoran işletmelerine yönelik olarak literatürde çoğunlukla metnin genel duygusunu belirleyen çalışmalar bulunurken, bu çalışmada farklı boyutların aynı anda değerlendirmesini sağlayan bir yöntem önerilmektedir. Bunun yanında, genellikle metnin sınıflandırılması ve duygu analizi şeklinde iki aşamada uygulanan geleneksel hedef tabanlı duygu analizi bu çalışmada tek adımda gerçekleştirilebilmektedir. Ayrıca, önerilen yöntem ile farklı dillerde yazılan yorumlardaki konular ve bunlara ait duygular dilden bağımsız olarak analiz edilmektedir.

2. Literatür Taraması (Literature Review)

Literatürde çeşitli sektörlere yönelik makine öğrenmesi ve doğal dil işleme yöntemleri kullanılarak müşteri yorumlarının duygu analizi ile değerlendirildiği birçok çalışma mevcuttur. Bu bölümde, duygu analizi, sıfır-atış öğrenme ve sıfır-atış metin sınıflandırma tanıtılacak ve literatürde müşteri yorumları kullanılarak restoran işletmelerine yönelik gerçekleştirilen duygu analizi çalışmaları incelenecektir.

2.1. Duygu Analizi (Sentiment Analysis)

Duygu analizi çeşitli makine öğrenmesi ve doğal dil işleme teknikleri kullanılarak metinsel verideki duygu durumunun ortaya çıkarılmasıdır. Duygu durumu, metinlerin pozitif ve negatif (ve bazen nötr) olarak sınıflandırılmasıyla belirlenmektedir.

Duygu analizinde veri kaynağı olarak kelime veya kelime öbekleri (cümleler); yani, blog yazıları, SMS ve sohbet mesajları gibi birçok metin kullanılmaktadır (Mohammad, 2017). Son yıllarda, insanların çeşitli konularda fikirlerini belirttiği, ürün ve hizmetler hakkında yorumlar yaptıkları sosyal ağlar (X, Facebook, vb.), çevrimiçi alışveriş siteleri (Amazon, Hepsiburada, vb.), çevrimiçi seyahat bilgi ve rezervasyon platformları (TripAdvisor, Etstur) ve yerel işletme rehberleri (Yelp, Google Maps: Google Yerel İşletmeler) gibi platformlar giderek daha popüler hale gelmiştir. Bunun sonucu olarak da bu platformlarda yapılan yorumlar, duygu analizi için önemli bir veri kaynağı olarak öne çıkmaktadır (Ahmed vd., 2020; Soleymani vd., 2017). Duygu analizi; ürün veya hizmetler için müşteri eğilimlerini incelemek, devletlerin düşmanca veya olumsuz tavırlarını belirlemek ve siyasi parti seçmenlerinin düşüncelerini anlamak gibi farklı alanlarda kullanılmaktadır (Pang ve Lee, 2008).

Duygu analizi çok kullanılan bir yöntem olsa da zorlukları da bulunmaktadır. Chifu ve Fournier (2023) eş sesli kelimeler, dildeki muğlaklık, alaycılık ve kültürel farklılıklar, veri kalitesi ve miktarı, eğitim verisinin yanlılığı gibi faktörlerin duygu analizi başarısını etkilediğini belirtmiştir. Bunun yanında, dillerin kendine özgü farklı gramer yapıları ve alfabeleri de buna eklenebilir. Nankani vd. (2020) metinlerdeki yazım yanlışları, kelimelerin farklı alanlarda farklı duygular içerebilmesi veya sahte içerikler gibi olgulara ek olarak, çok dilli (multilingual) metinlerde dillerin gramer ve morfolojik yönden farklılıklarını doğal dil işleme uygulamalarında karşılaşılan zorluklar olarak sıralamıştır.

Geleneksel duygu analizi, duygunun ne hakkında olduğunu nitelendirmeden genel duyguyu sınıflandırmaya odaklanır. Fakat, metin aynı anda farklı konular veya varlıklarla ilgiliyse ve muhtemelen farklı konulara yönelik farklı duygular ifade ediyorsa, burada geleneksel duygu analizi yeterli olmayacaktır (Hoang vd., 2019). Bu tür problemlerde metin içindeki birden çok konu hakkındaki duyguları belirlemek için hedef tabanlı duygu analizi kullanılmaktadır. Hedef tabanlı

duygu analizi, bir cümledeki belirli bir özelliğe yönelik duygu kutupluluğunu belirlemeyi amaçlamakta ve hedef özellik, bir varlığın bir özelliğini tanımlayan kelime veya ifadeye atıfta bulunmaktadır (Jiang vd., 2019).

Örneğin, “*Hizmet çok iyiydi. Mehmet Bey’e teşekkür ederim.*” cümlesi pozitif bir anlamdadır ve cümlede tek bir konuya (yani hizmete) ait duygu durumu vardır. Başka bir örnekte ise “*Yemekler harika! Özellikle kalamar. Fakat restoran çok gürültülüydü ve ışıklandırma rahatsız ediciydi.*” cümlesinde müşteri restoranda yediği yemeği çok beğenmesine rağmen, ambiyanstan rahatsız olmuştur. Bu tür cümlelerde aynı anda farklı konular hakkında farklı duygular yer almaktadır. Geleneksel duygu analizi yerine, böyle durumlarda hedef tabanlı duygu analizi kullanılarak her bir konu için duygu durumu belirlenebilmektedir.

2.2. Restoran Yorumlarının Duygu Analizi (Sentiment Analysis of Restaurant Reviews)

Restoranları ziyaret eden kişilerin çevrimiçi yaptıkları müşteri yorumlarını duygu analizi ile inceleyen bazı çalışmalarda, geleneksel denetimli makine öğrenmesi algoritmaları ve kelime gömme (Word Embedding) yaklaşımları kullanılarak müşterilerin restoranlar hakkındaki yorumları hiçbir kategoriye ayrılmadan analiz edilmiştir. Krishna vd. (2019) İngilizce restoran yorumlarının duygu analizini gerçekleştirmek için Naïve Bayes, Destek Vektör Makinesi, Karar Ağacı ve Rastgele Orman sınıflandırma algoritmalarını kullanmışlardır. Çalışmanın sonuçlarına göre, Destek Vektör Makinesi diğer algoritmalara kıyasla %94,56 gibi bir doğruluk puanına ulaşmıştır. Hossain vd. (2020) Bangladeş'teki restoranlara ait müşteri yorumlarını Evrişimli Sinir Ağı ve Uzun-Kısa Vadeli Bellek algoritmalarını birlikte kullanarak olumlu ve olumsuz olarak sınıflandırmışlardır. Hossain vd. (2021) farklı kaynaklardan edindikleri Bengalce restoran yorumlarını Çift Yönlü Uzun-Kısa Vadeli Bellek, Lojistik Regresyon, Karar Ağacı, Rastgele Orman, Naïve Bayes, Destek Vektör Makinesi modellerini kullanarak duygu analizini gerçekleştirmişlerdir. Çift Yönlü Uzun-Kısa Vadeli Bellek modeli %95,35 ile en yüksek doğruluk puanına ulaşmıştır. Patil vd. (2022) olumlu ve olumsuz restoran yorumlarını sınıflandırmak için K-En Yakın Komşu Sınıflandırıcı, Lojistik Regresyon, Destek Vektör Sınıflandırıcı ve Naïve Bayes algoritmaları kullanmış ve en iyi doğruluk puanını %78 ile Destek Vektör Sınıflandırıcısı ile elde etmişlerdir. Abdullah vd. (2023) Arapça çevrimiçi restoran yorumlarının duygu analizini gerçekleştirmek için Naïve Bayes, Karar Ağacı, Destek Vektör Sınıflandırıcısı, K-En Yakın Komşu, Rastgele Orman ve Lojistik Regresyon algoritmalarını kullanmışlardır. Destek Vektör Sınıflandırıcısı %97,6 ile en yüksek doğruluk puanına ulaşarak yorumları pozitif, negatif ve nötr olarak sınıflandırmada en iyi performansı göstermiştir. Gedif vd. (2023) Etiyopya'nın bir dili olan Amharca yazılan restoran yorumlarını

Destek Vektör Makinesi, K-En Yakın Komşu ve Naïve Bayes sınıflandırıcı kullanarak duygu analizini gerçekleştirmiştir. Değerlendirme sonucunda Destek Vektör Makinesi modelinin en yüksek doğruluğu verdiği görülmüştür. Lavanya vd. (2023) çalışmalarında restoran incelemeleri için Yelp veri setini kullanarak kelime çantası (Bag of Words, BoW), Terim Frekans-Ters Doküman Frekansı (Term Frequency-Inverse Document Frequency, TF-IDF), GloVe, Word2Vec ve Doc2Vec gibi farklı kelime gömme yaklaşımlarını test etmişler, Lojistik Regresyon ve Destek Vektör Makinesi gibi denetimli makine öğrenmesi algoritmalarını kullanarak, sonuçları doğruluk, kesinlik, duyarlılık ve F1 puanı gibi performans metriklerine göre değerlendirmişlerdir. Karşılaştırmalı bulgular, Destek Vektör Makinesi ve TF-IDF'nin birlikte kullanımının %98 doğruluk puanı ile sonuçlar ürettiğini göstermiştir. Bozkurt ve Yalçın (2024) Amazon yemek yorumları üzerinde topluluk öğrenmesi algoritmalarını kullanarak duygu analizi yapmayı amaçlamıştır. Çalışmada, Rastgele Orman, CatBoost ve XGBoost algoritmaları kullanılarak olumlu, olumsuz ve nötr duygu sınıflandırması yapılmıştır. Çalışmada, farklı vektörleştirme tekniklerinin başarısı da karşılaştırılmış, çeşitli değerlendirme metrikleri kullanılarak en yüksek %90,22 test doğruluk değeri, Rastgele Orman ve CountVectorizer tekniği ile elde edilmiştir. Ayrıca, web kazıma ile yeni bir veri seti oluşturulmuş ve modeller bu veri seti üzerinde de test edilmiştir.

Bazı çalışmalarda ise duygu analizi yanında bir de lezzet, hizmet, ambiyans ve fiyatlandırma gibi kategoriler ele alınıp, müşterileri yorumları her kategoride hedef tabanlı duygu analizi yapılarak incelenmiştir. Suciati ve Budi (2019) çalışmalarında Endonezya'daki restoranların Endonezyaca ve İngilizce müşteri yorumlarını yemek, fiyat, hizmet ve ambiyans boyutlarını kullanarak olumlu, olumsuz ve nötr olarak sınıflandırmışlardır. Rastgele Orman, Multinomial Naïve Bayes, Lojistik Regresyon, Karar Ağacı ve Ekstra Ağaç sınıflandırıcı algoritmaları kullanılan çalışmada Lojistik Regresyon en yüksek skoru yemek (%81,76) ve ambiyans (%77,29) boyutlarıyla, en yüksek skor fiyat (%78,71) ve hizmet (%85,07) boyutları için Karar Ağacı algoritması ile elde edilmiştir. Zahoor vd. (2020) Karachi Pakistan'daki restoran yorumlarını Facebook'dan temin ederek, Naïve Bayes sınıflandırıcı, Lojistik Regresyon, Destek Vektör Makinesi ve Rastgele Orman algoritmalarından yararlanarak, yorumları pozitif ve negatif olarak sınıflandırmışlardır. En yüksek doğruluk oranı %95 Rastgele Orman modeli ile elde edilmiştir. Daha sonra, aynı veriyi lezzet, ambiyans, servis ve fiyatlandırma olacak şekilde yine aynı dört algoritmayı kullanarak kategorilere ayırmışlardır. Bunun sonucunda, lezzet kategorisi %97 doğruluk oranı ile en yüksek performansı göstermiştir. Diğer kategoriler için ise doğruluk, fiyat %84, ambiyans %86,49 ve hizmet %89 oranlarında bulunmuştur. Ara vd. (2020) bir restoranın web portalı üzerinden edinmiş oldukları yemek kalitesi, hizmet, ortam, fiyat, online

yemek siparişi gibi konular hakkındaki müşteri yorumları vasıtasıyla, SentiStrength sınıflandırıcısı kullanılarak görüşlerde ifade edilen kelimelerin duygu gücünü bulmuşlardır. Daha sonra, yorumlar standart sapma tekniği kullanılarak pozitif, negatif ve nötr olarak sınıflandırılmış ve %85,71'lik bir doğruluk elde etmişlerdir. Zhang vd. (2022) Yelp'deki restoran incelemelerini veri kaynağı olarak kullanarak ve fiyat, zaman, yemek, hizmet ve konum konularını temel olarak Gizli Dirichlet Ayrımı yöntemi ile konu modelleme gerçekleştirmişlerdir. Daha sonra, TextBlob ile her konu için duygu analizi yapmışlardır.

Bazı çalışmalarda ise dönüştürücü (transformer) mimarisini kullanan BERT'den (Bidirectional Encoder Representations from Transformers, Dönüştürücülerden Çift Yönlü Kodlayıcı Temsilleri) yararlanılmıştır. Tuna vd. (2023) yaptıkları çalışmada, Word2vec, Glove, fastText ve BERT gibi çeşitli modeller kullanmışlardır. SemEval'15 ABSA yarışmasında sunulan restoran müşterilerine ait yorumlardan oluşan veri seti kullanılarak hedef terim, hedef kategori ve duygu sınıfları belirlenmiştir. fastText yöntemi hedef terim ve kategori tespitinde en yüksek başarıyı göstermiş, BERT yöntemi ile duygu sınıflandırmasında en iyi sonuç elde edilmiştir. Bu sonuçlar, fastText ve BERT yöntemlerinin Türkçe metinlerde başarılı olduğunu göstermiştir. Branco vd. (2024) Portekizce restoran yorumlarının duygu analizi için BERT ve RoBERTa (Robustly Optimized BERT Approach, Güçlü Bir Şekilde Optimize Edilmiş BERT Yaklaşımı) modellerini kullanarak, yorumların duygu sınıflandırmasını gerçekleştirmiş ve önceden eğitilmiş derin öğrenme modellerinin uygunluğunu değerlendirmişlerdir. Modelin performansının tespiti için doğruluk ve Alıcı Çalışma Karakteristiği (Receiver Operating Characteristic, ROC) eğrisi altındaki alan metrikleri kullanılmış ve çalışmada %80'in üzerinde bir sonuç elde edilmiştir. Bazı çalışmalarda BERT yöntemine ek olarak bir de OpenAI GPT'den (Generative Pre-trained Transformer, Üretici Önceden Eğitilmiş Dönüştürücü) yararlanılmıştır. Carrasco ve Dias (2023) Portekiz'in Algarve bölgesinde yer alan restoranlara yapılan yorumları TripAdvisor'dan edinmiş, müşteri memnuniyetinin beş temel özelliği olan gıda kalitesi, hizmet, ortam, fiyat ve restoranın konumu ile ilgili konuları BERT, USE (Universal Sentence Encoding, Evrensel Cümle Kodlama) ve OpenAI GPT ile kategorize etmişlerdir. Daha sonra, önceden belirlenen ve duygular için referans olan cümleler temel alınarak kosinüs benzerliği kullanılmış, pozitif ve negatif duygulara yönelik bir sınıflandırma gerçekleştirilmiştir. Değerlendirme için üç model karşılaştırıldığında doğruluk %93, kesinlik %86, duyarlılık %83 ve F1 puanı %85 ile OpenAI GPT en yüksek puana ulaşmıştır. Benzer şekilde, Carrasco ve Dias (2024) yine Algarve bölgesindeki restoran yorumlarını kullanarak bu sefer müşteri memnuniyetinin beş temel özelliği ayrıntılandırıp, BART (Bidirectional and Auto-Regressive

Transformers, Çift Yönlü ve Oto-Regresif Dönüştürücüler), DeBERTa (Decoding-enhanced BERT with disentangled attention, Ayrıştırılmış dikkat ile kod çözümü geliştirilmiş BERT), ChatGPT 3.5 ve ChatGPT 4.0'ı kullanmışlardır. Çalışmada ChatGPT 4.0 modelinde en yüksek F1 skoru elde edilmiştir.

2.3. Sıfır-Atış Öğrenme (Zero-Shot Learning)

Bilindiği üzere, veri sınıflandırma görevlerinde kullanılan denetimli makine öğrenmesinde, veri içindeki sınıflar önceden belirlenmekte (veya bilindiği varsayılmakta) ve her bir örnek için eğitim verisinin hangi sınıfa ait olduğuna dair etiketleme yapılarak, sonrasında eğitim ve test işlemi gerçekleştirilmektedir. Bunun sonucu olarak da bazen bilinmeyen sınıfların gözden kaçma olasılığı bulunmaktadır. Yani, sınıflandırıcı -eğer iyi bir eğitim için her sınıfta yeterli sayıda etiketli veri bulunursa- sadece eğitim verilerinin kapsadığı sınıflara ait örnekleri sınıflandırabilmektedir (Wang vd., 2019). Bununla birlikte, projelerde öğrenme aşamasından sonra yeni sınıflar da ortaya çıkabilmektedir (Romera-Paredes ve Torr, 2015). Dahası, etiketlemenin zaman alıcı ve maliyetli bir süreç olduğu da göz ardı edilmemelidir (Liu vd., 2004). Bu noktada, Chang vd. (2008) geleneksel makine öğrenmesi çalışmalarının aksine, etiketli örnekler ihtiyacı duyulmadan verinin sınıflandırma işlemini gerçekleştiren ve başta “Verisiz Sınıflandırma” (Dataless Classification) olarak adlandırılan bir model önermişlerdir. Daha sonra sıfır-atış öğrenme olarak adlandırılan bu model, geleneksel denetimli makine öğrenmesi modelleri ile karşılaştırıldığında, görülen ve görülmeyen sınıflar arasındaki boşluğu doldurmaktadır. Bir başka deyişle sıfır-atış öğrenme, anlamsal bilgi yardımıyla görülen diğer sınıflardan elde edilen bilgiyi aktararak, görülmeyen sınıflardaki nesnelere sınıflandırabilen bir model eğitmeyi amaçlamaktadır (Pourpanah vd., 2022). Bu yüzden, eğitim ve çıkarım olmak üzere iki aşamalı bir sürece sahip olan sıfır-atış öğrenmede, niteliklerle ilgili bilgiler eğitim aşamasında yakalanırken, bu bilgiler çıkarım aşamasında örnekleri yeni bir sınıf kümesi arasında kategorize etmek için kullanılmaktadır (Çelik ve Dalyan, 2023).

Sıfır-atış öğrenme geçmişten günümüze daha çok bilgisayarlı görü ve doğal dil işleme projelerinde uygulama alanı bulmuştur (Rezaei ve Shahidi, 2020). Sıfır-atış öğrenme, nesne veya hayvanların algılanması (Bansal vd., 2018; Lampert vd. 2014), tıbbi görüntüleme ve görüntü sınıflandırma (Mahapatra vd., 2021; Vétıl vd., 2022), arazi örtüsü haritalanması (Li vd., 2021; Pradhan vd., 2020), video sınıflandırma ve eylem tanımlama (Brattoli vd., 2020; Estevam vd., 2021), fotoğraf iyileştirme (Kar vd., 2021; Zheng ve Gupta, 2022), araç rotası belirleme (Yu vd., 2020), metinden görüntü oluşturma (Sanghi vd., 2022) ve insan duygularının tanımlanması (Zhan vd., 2019) gibi bilgisayarlı görü çalışmalarında başarı ile kullanılmıştır.

Sıfır-atış öğrenme doğal dil işleme görevlerinde birçok çalışmada kullanılmıştır. Örneğin, bir sohbet robotunun kullanıcının ne istediğini anlayabilmesini sağlayan niyet sınıflandırması (intent classification) (Liu vd., 2019), metnin anlamının daha iyi anlaşılması için metinden nesnelere ve kavramları çıkarma işlemi olan öznelik çıkarımı (feature extraction) (McInerney vd., 2023), metin içindeki varlıkları (kişiler, yerler, kuruluşlar vb.) tanımlama ve onları bir bilgi kaynağındaki ilgili varlıklara bağlama işlemi olan varlık bağlama (entity linking) (Logeswaran vd., 2019), bir dilden başka bir dile çeviri için kullanılan makine çevirisi (Johnson vd., 2017; Thompson ve Post, 2020; Zhang vd., 2020), bir metnin yazarının verilen hedeften yana mı yoksa ona karşı mı olduğunun algılanması sağlayan duruş tespiti (stance detection) (Choi ve Ko, 2023; Jiang vd., 2023), otomatik özetleme (Goodwin vd., 2020) ve devam eden bölümde anlatılacak metin sınıflandırma ve duygu analizi olmak üzere birçok alanda kullanılmaktadır.

2.4. Sıfır-Atış Metin Sınıflandırma Kullanılarak Duygu Analizi (Sentiment Analysis Using Zero-Shot Text Classification)

Doğal dil işlemenin bir alt dalı olan metin sınıflandırma, metin belgelerini içeriklerine göre otomatik olarak kategorilere ayırma işlemini ifade etmektedir. (Quazi ve Musa, 2022). Uzun yıllardır doğal dil işleme alanında bir araştırma konusu olan metin sınıflandırma, duygu analizi, konu modelleme ve bilgi çıkarımı gibi çeşitli görevlerde kullanılmaktadır (Jiao, 2023).

Sıfır-atış metin sınıflandırmada, geleneksel olarak belgelerin belirli bir sınıftaki diğer belgelerle karşılaştırılarak sınıflandırılması yerine, sınıflar arasındaki bilinen ilişkilerden yararlanılmaktadır. Böylece, bir taksonominin tüm sınıfları için eğitim verisi gerekmemekte ve eğitim sırasında görülmeyen sınıfların tahmin edilmesi mümkün kılınmaktadır (Hoppe vd., 2021). Vaswani vd.'nin (2017) dönüştürücü mimarisini tanıtmaları ile birçok farklı doğal dil anlama görevinde kullanım alanı bulan sıfır-atış metin sınıflandırma, önceden eğitilmiş dil modellerinden (Pre-trained language models) yararlanmaktadır. Önceden eğitilmiş dil modellerinde transfer öğrenme kullanılmakta, önceden eğitilmiş bir model alınıp, modelin ilgili ancak farklı bir görev üzerinde çalışması için ince ayar yapılmaktadır (Azunre, 2021). Bu modeller genel olarak Wikipedia, X, haber siteleri gibi büyük ölçekli metinlerden eğitilmektedir. Ayrıca, kelime dağarcığı daha spesifik olan bilim, tıp veya hukuk gibi alanlara özgü modeller de geliştirilmektedir (Pérez vd., 2021). Önceden eğitilmiş dil modellerinin bir özelliği de çok dilli bir yapıya sahip olmasıdır. Diller arası dil anlama (Cross-lingual language understanding) olarak adlandırılan bu özellik, bir makine öğrenimi modelinin her dil için ayrı bir eğitim gerektirmeden, birden fazla dilde doğal dil metnini anlama ve işleme

yeteneğini ifade etmektedir (Conneau vd., 2019). Böylece bu vasıf, özellikle uluslararası düzeyde, birçok farklı dildeki sosyal ağ kullanıcı gönderileri veya müşteri yorumları gibi metne dayalı verilerin sınıflandırılmasında büyük kolaylık sağlamaktadır.

Sıfır-atış metin sınıflandırmaya yönelik olarak yapılan çalışmalarda, örneğin, Lin ve Wen (2022) semantik benzerlik (Sentence-BERT) ve sıfır-atış sınıflandırma olmak üzere iki modeli kullanarak müşteri geri bildirimlerini sınıflandırmak için bir prototip tanıtmıştır. Çalışma sonucunda sıfır-atış metin sınıflandırmada en yüksek doğruluk elde edilmiştir. Cherapanukorn ve Sugunnasil (2022) görüş madenciliği tekniği kullanarak ve sıfır-atış metin sınıflandırma yöntemi ile turistik cazibe merkezleri için turist memnuniyeti bileşenlerini belirlemiştir. Buna yönelik olarak da 2010 ile 2021 yılları arasında TripAdvisor'da yayınlanan Tayland'daki 40 turistik merkeze ait toplam 40.000 çevrimiçi turist yorumu analiz edilmiştir. Rey-Moreno vd. (2023) 2018 ile 2021 yılları arasında Airbnb ve otel konaklamalarına ait toplamda 24.436 cümleyi kullanarak, misafir memnuniyeti ve güveniyle ilgili hizmet özelliklerini tanımlamak için BERTopic, sıfır-atış sınıflandırma ve temel bileşen analizi yöntemlerinin kombinasyonunu kullanmışlardır. Das vd. (2023) on altı popüler Google Play Store uygulamasına ait yorumları veri kaynağı olarak kullanarak uygulama incelemelerinin otomatik olarak analiz edilmesi ve uygulama geliştiricilerinin kullanıcı geri bildirimlerini daha verimli şekilde yönetmelerine yardımcı olmak için bir çerçeve sunmuştur. Çalışmada; duygu analizi için BERT, sınıflandırılan metnin temalarını belirlemek için sıfır-atış sınıflandırma, metin özetlerinin oluşturulması için ise GPT-3 kullanılmıştır.

Sıfır-atış metin sınıflandırma kullanılarak yapılan duygu analizi çalışmalarında ise örneğin Masarifoglu vd. (2021) bankacılık alanındaki Türkçe müşteri yorumlarının duygu analizini gerçekleştirmiş, bunun için önceden eğitilmiş çok dilli BERT, BERTurk, sıfır-atış metin sınıflandırmada kullanılan XLM-Roberta-Large-XNLI modeli ve geleneksel makine öğrenmesi yöntemlerini (Destek Vektör Makineleri, Naïve Bayes ve Lojistik Regresyon) karşılaştırmışlardır. Çalışmada farklı senaryolar test edilmiş ve etiketli eğitim verisinin olmadığı durumda XLM-Roberta-Large-XNLI modeli %83 ağırlıklı F1 skoru ile en yüksek başarıyı elde etmiştir. Kumar ve Albuquerque (2021) Hintçe üzerine duygu analizi yapmak için XLM-RoBERTa çapraz dilli modeli ve sıfır-atış çapraz-dilli transfer öğrenme (Zero-shot Cross-lingual Transfer Learning) yöntemini kullanmışlardır. İngilizce veri setiyle eğitilen model, Hintçe cümle seviyesinde duygu analizinde test edilmiş ve çalışmada hibrit derin öğrenme yönteminden (Evrışimli Sinir Ağır, CNN ve Destek Vektör Makinesi) daha yüksek bir doğruluk oranı elde edilmiştir. Modelin performansını değerlendirmek için ortalama duyarlılık, F1 puanı ve makro F-puanı doğrulama metrikleri kullanılmıştır. XLM-R modeliyle ortalama %60,93

doğruluk elde edilmiştir. Sahar vd. (2022) BERT ve sıfır-atış öğrenme yardımıyla Amazon'dan edindikleri kozmetik ürün incelemelerini kullanarak duygu analizini gerçekleştirmişlerdir. Manias vd'nin. (2023) çalışmasında ise Twitter verileri ile dört farklı BERT tabanlı çok dilli sınıflandırıcı (mBERT, XLM-R, DistilBERT, ve BERT-m) ve sıfır-atış metin sınıflandırma yöntemini doğruluk ve uygulanabilirlik açısından karşılaştırmışlardır. Sonuçlar, çok dilli BERT tabanlı modellerin yüksek performans sağladığını ve sıfır-atış öğrenme yaklaşımının daha hızlı, verimli ve ölçeklenebilir çözümler sunduğunu göstermiştir.

2.5. Literatürden Elde Edilen Temel Bulgular (Key Findings from Literature)

Literatürde restoran müşterilerinin yorumlarının duygu analizi ile değerlendirilmesi çalışmalarında çoğunlukla metinlerdeki genel duygu ortaya çıkarılmış ve geleneksel makine öğrenmesi ve derin öğrenme algoritmaları kullanılmıştır. Fakat, metinde farklı konulara ait farklı duygular araştırılmak istenirse bu yaklaşımlar yetersiz kalmaktadır. Buna yönelik olarak da lezzet, hizmet, ambiyans ve fiyatlandırma gibi spesifik boyutlar ele alınarak hedef tabanlı duygu analizi gerçekleştirilmiştir. Ayrıca son dönemlerde hedef tabanlı duygu analizi için BERT ve OpenAI GPT gibi dönüştürücü tabanlı modeller de kullanılmaya başlanmıştır.

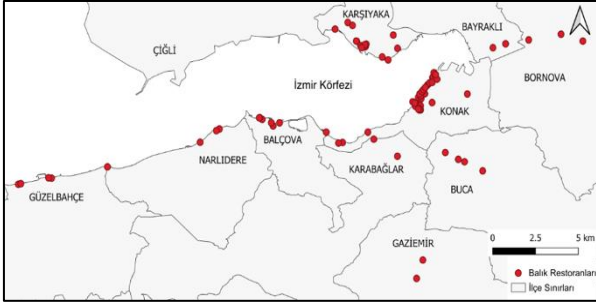
Sıfır-Atış öğrenme ile etiketli verilere ihtiyaç duyulmadan verilerin sınıflandırılması gerçekleştirilmektedir. Ayrıca, yaklaşımın özellikle metin sınıflandırma ve duygu analizi görevlerinde önceden eğitilmiş dil modelleri ile kullanılması farklı dillerden oluşan veri setlerinin sınıflandırılması zorluğunu ortadan kaldırmıştır. Önceden yapılan çalışmalar, bu yöntemin kullanımında yüksek doğruluk oranlarına ulaşıldığını ve diğer modellere kıyasla hızlı ve etkili olduğunu göstermektedir.

3. Metodoloji (Methodology)

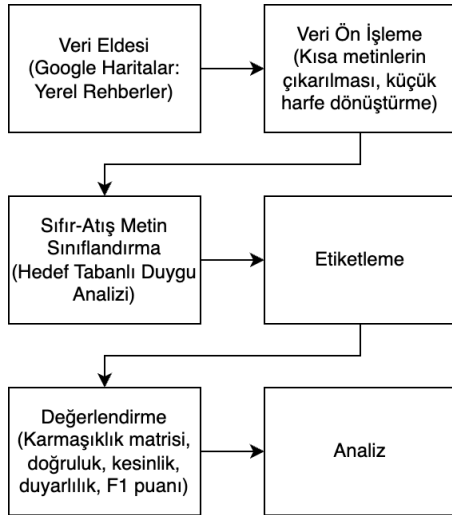
İzmir, yeme-içme sektörü bakımından zengin, aynı zamanda potansiyeli olan ve geliştirilmesi gereken bir şehirdir (Akgündüz vd., 2024; Altıntaş ve Hazarhun, 2020). İzmir yüzyıllardır farklı kültürlerle ev sahipliği yapmış, bu da İzmir mutfağına yansımıştır. Özellikle İzmir'e özgü çeşitli bitkiler, otlar, sebzeler, zeytinyağlılar, balık ve deniz ürünleri İzmir'e özgü yemekler olarak sıralanmaktadır (Erdoğan ve Özdemir, 2018). Bilhassa, İzmir'in Ege Denizi'ne kıyısı ve uzun sahil şeridinde sahip olması, deniz ürünleri mutfağının da gelişimine yol açmıştır. Böylelikle İzmir, kıyı şeridi balık restoranları ve balık pazarları açısından zenginlik göstermektedir (Yentür ve Demir, 2022).

Çalışmada, çoğunluğu İzmir Körfezi çevresindeki ilçelerde yer alan balık restoranlarına yönelik olarak sıfır-atış metin sınıflandırma yaklaşımı kullanılarak hedef tabanlı duygu analizi gerçekleştirilmiştir (Şekil 1). Veri kaynağı olarak Google Haritalar: Google Yerel

Rehberler’de yer alan balık restoranlarına yapılan müşteri yorumları kullanılmıştır. Veri eldesi, Selenium Python kütüphanesinden yararlanılarak web kazıma metodu ile Şubat-Mart 2023 aralığında gerçekleştirilmiştir ve 89 adet balık restoranı çalışma kapsamında yer almıştır. Çalışmanın akış şeması Şekil 2’de verilmektedir.



Şekil 1. Çalışmada incelenen balık restoranları konumları (Locations of fish restaurants analysed in the study)



Şekil 2. Akış şeması (Flow chart)

Çalışmada işlenen veri setinde tüm restoranlar için toplam yorum sayısı 15.305’tir. En eski yorum 2013, en yeni yorum ise 2023 yılına aittir. Çok dilli bir yapıya sahip olan ve 43 farklı dili barındıran veri setinde yorumların büyük bir çoğunluğu Türkçe (89%) olup, diğer diller ise İngilizce (%7), Almanca (%1), Rusça (%0,9), Fransızca (%0,5), Arapça (%0,4), Korece (%0,2) ve diğer dillerdedir (%1). Veri setinde kullanıcıların yaptıkları restoran yorumları, zaman (yıl), restoran adı, kullanıcı adı ve puan verileri yer almakta, bu çalışma kapsamında sadece yorum ve zaman verisi kullanılmıştır.

3.1. Veri Ön İşleme (Data Preprocessing)

Veri ön işleme aşamasında, sadece puan verilir ve boş olan girdiler ve üç kelimenin altında olan “Harika!”,

“Muhteşem restoran” veya “Berbat!” gibi anlamsal olarak çok genel olan yorumlar göz ardı edilmiş ve veriden çıkarılmıştır. Ayrıca, tüm yorumlar küçük harfe dönüştürülmüştür. Buna ek olarak, Liu vd. (2021), Leburu-Dingalo vd. (2022) ve Manias vd.’nin (2023) çalışmalarında değindikleri üzere, mikro-metinler kullanılarak yapılan çok dilli duygu analizinde noktalama işaretleri, emojiler ve yüz ifadelerini temsil eden karakterler (emoticon) metindeki duyguyu ve anlamı pekiştirdiği için metinden çıkartılmamıştır.

3.2. Veri Analizi (Data Analysis)

Çalışmada, Gallego’nun (2023) huggingface.co’da sunduğu, "XLM-RoBERTa-large" modelinin birkaç doğal dil çıkarımı (Natural Language Inference, NLI) veri kümesi üzerinde ince ayarlanmış “vicgalle/xlm-roberta-large-xnli-anli” modeli kullanılmıştır. Model çok dilli olup, "XLM-RoBERTa-large" temel modeli 100 farklı dilde önceden eğitilmiştir (Conneau vd., 2020).

Kodlama ve veri işleme, Google Colaboratory’de Python programlama dili kullanılarak ve GPU (Graphics Processing Unit, Grafik İşlemci Birimi) hizmetinden yararlanılarak yapılmıştır. BERT, GPT, RoBERTa gibi birçok farklı dil modelini ve mimarisini içeren transformers kütüphanesindeki pipeline fonksiyonu yardımıyla, "vicgalle/xlm-roberta-large-xnli-anli" modeli ile sıfır-atış sınıflandırma işlemi için bir hattın (pipeline) oluşturulması sağlanmıştır. Hat, basit bir uygulama programlama arayüzü (Application Programming Interface, API) sunarak, ham metni girdi olarak almakta, onu kelimelere veya alt kelimelere ayırmakta ve ardından belirli görevler için modele beslemektir (Hugging Face, 2024).

Kategoriler, Gagić vd.’nin (2013) restoran kalitesinin ölçülmesi için önerdiği yemek kalitesi, servis kalitesi, fiziksel çevre ve adil fiyat boyutları temel alınarak oluşturulmuştur. Buna yönelik olarak da kategoriler hem olumlu hem de olumsuz yorumları kapsayacak şekilde kaliteli yemek (KY), kalitesiz yemek (KsizY), kaliteli servis (KS), kalitesiz servis (KsizS), güzel ambiyans (GA), kötü ambiyans (KA), düşük fiyat (DF) ve yüksek fiyat (YF) olmak üzere sekiz sınıf olarak belirlenmiştir. Müşteriler yorumlarda restoranın birkaç özelliğinden aynı metin içinde bahsedebildikleri için model çok-etiketli sınıflandırma (multi-label classification) şeklinde ayarlanmış, böylece her sınıf için puanlar ayrı ayrı hesaplanmıştır. Tablo 1’de çeşitli restoranlara yönelik örnek yorum ve tahminlenmiş kategorilerin puanları verilmektedir. Yüksek puanlar yorumun hangi sınıfa ait olabileceğini göstermektedir.

Tablo 1. Örnek restoran yorum ve tahmin puanları (Examples of restaurant reviews and prediction scores)

Müşteri Yorumları	KY	KsizY	KS	KsizS	GA	KA	YF	DF
Lezzetleri mükemmel, özellikle mezeler harika ve leziz, ayrıca işletme ve çalışanları gayet güler yüzlü ve sıcakkanlılar. Hizmet olarak kaliteli ve keyifli bir mekân.	0,9751	0,0002	0,9996	0,0002	0,5721	0,0002	0,0150	0,0002
Потрясающая кухня, обслуживание на высоте, один из самых лучших ресторанов города Рекомендую! (Harika mutfak, mükemmel hizmet, şehrin en iyi restoranlarından biri. Tavsiye ederim!)	0,9989	0,0002	0,9994	0,0002	0,0010	0,0003	0,0228	0,0008
الأكل عادي و أسعارو غالية (Yemek sıradan ve fiyatları pahalı.)	0,0003	0,0005	0,0007	0,0008	0,0002	0,0080	0,0020	0,9115
Pricy but excellent service and delicious food. (Pahalı ama mükemmel servis ve lezzetli yemekler.)	0,9992	0,0002	0,9997	0,0002	0,0014	0,0003	0,6844	0,0007
Böyle yüksek faturalı bir yer için balıklar rezaletti. Ayrıca servis de kötüydü. Hiç tavsiye etmiyorum.	0,0002	0,9993	0,0004	0,9371	0,0003	0,3136	0,0004	0,9988

Kaliteli Yemek (KY), Kalitesiz Yemek (KsizY), Kaliteli Servis (KS), Kalitesiz Servis (KsizS), Güzel Ambiyans (GA), Kötü Ambiyans (KA), Düşük Fiyat (DF), Yüksek Fiyat (YF)

3.3. Model Performans Değerlendirmesi (Model Performance Evaluation)

Çalışmada kullanılan modelin tahmin performansını ölçmek için tüm veriden yaklaşık %11'lik bir kısım gelişigüzel örnek olarak alınmış, 0 ve 1 ikili yapı (binary) şeklinde etiketlenmiştir. Tahminlenmiş veri setinden de aynı satırların seçilimi yapılarak, veri 0,5 eşik değerine göre yine ikili yapıya dönüştürülmüştür. Örnek alınan veri seti içindeki Türkçe haricindeki müşteri yorumlarının oranı yaklaşık %10'dur.

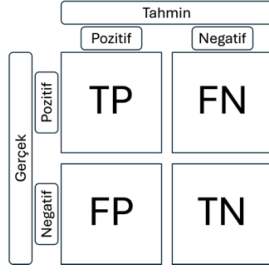
Veri setinin çok-etiketli yapısından dolayı her bir sınıf içerisinde yer alan pozitif ve negatif örneklerin eşit sayıda olması neredeyse mümkün değildir ve sınıflar dengesiz bir yapıya sahiptir (Tablo 2). Bu tür durumlarda doğruluk, kesinlik, duyarlılık gibi metriklerin hesaplanmasında verilerin bu haliyle doğrudan kullanılması performans değerlendirmesinde yanıltıcı olabilmektedir (Iram vd., 2016). Bu yüzden, her sınıfı dengeli hale getirmek amacıyla azınlık sınıfı sayısını çoğunluk sınıfı sayısına eşitlemek için aşırı örnekleme (over-sampling) veya çoğunluk sınıfı sayısını azınlık sınıfı sayısına eşitlemek için alt örnekleme (under-sampling) gibi yöntemler kullanılmaktadır. Aşırı örnekleme metodu için yeni metin üretimi veya azınlık sınıfındaki verileri çoğunluk sınıfı sayısına eşitlemek için azınlık sınıfındaki bazı satırların aynılarını ekleyerek veriyi çoğaltmak gibi teknikler bulunmaktadır. Bu yöntem, azınlık sınıfındaki verilerin çoğaltılmasıyla

sınıf dengesizliklerini azaltmasına rağmen, yukarıda bahsedilen tekniklerin, sırasıyla, yeni veri üretiminin başka bir araştırma konusu olduğundan veya aynı verilerin tekrar kullanılması ile yeni bilgi sağlamadığından tercih edilmemiştir. Bu yüzden, çalışmada alt örnekleme metodu kullanılarak pozitif ve negatiflerde en küçük azınlık sınıfı temel alınarak, tüm sınıflarda pozitif ve negatif sayıları eşitlenmiştir. Bir başka deyişle, en küçük eleman sayısına sahip KA sınıfının pozitif sayısı 101 olduğu için diğer tüm sınıf sayıları bu değere indirgenmiştir (Bknz. Tablo 2, KA sınıfı, Pozitif: 101). Bu işlemden sonra, karmaşıklık matrisi ve doğruluk, kesinlik, duyarlılık, F1 puanı metrikleri hesaplanmıştır.

Karmaşıklık matrisi, makine öğrenimi modellerinin performansını değerlendirmek için kullanılan bir tablo yapısıdır. Bu tablo, bir sınıflandırma modelinin tahmin sonuçlarını dört temel kategoride özetler: doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) (Khakhar ve Dubey, 2022). TP, doğru sınıflandırılan pozitif örneklerin sayısını, TN ise doğru sınıflandırılan negatif örneklerin sayısını gösterir. Benzer şekilde, FP, pozitif ve yanlış olarak sınıflandırılan örneklerin sayısını, FN ise negatif ve yanlış olarak sınıflandırılan örneklerin sayısı ifade etmektedir (Kulkarni vd., 2020). Şekil 3'te karmaşıklık matrisi örneği ve her sınıf için karmaşıklık matrisleri Şekil 4'te verilmektedir.

Tablo 2. Örnek alınan verilerde sınıfların pozitif ve negatif dağılımları (Positive and negative distributions of classes in the sampled data)

		KY	KsizY	KS	KsizS	GA	KA	YF	DF
Pozitifler (1'ler)	Frekans	1005	171	652	229	510	101	243	305
	Frekans (%)	58,13	9,89	37,71	13,24	29,50	5,84	14,05	17,64
Negatifler (0'lar)	Frekans	724	1558	1077	1500	1219	1628	1486	1424
	Frekans (%)	41,87	90,11	62,29	86,76	70,50	94,16	85,95	82,36



Şekil 3. Karmaşıklık Matrisi (Confusion matrix)

KY		KsizY		KS		KsizS	
88	13	81	20	92	9	76	25
7	84	4	97	36	65	10	91
GA		KA		DF		YF	
83	18	63	38	73	28	74	27
21	80	13	88	26	75	5	96

Şekil 4. Her sınıfa göre karmaşıklık matrisleri (Confusion matrices for each class)

Çalışmada kullanılan değerlendirme metriklerinden ilki doğruluktur. Bu metrik, bir modelin ne kadar doğru tahmin yaptığını gösteren bir performans ölçütüdür. Doğru sınıflandırılanların tüm sınıflandırılanlara oranıdır ve

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

şeklinde hesaplanır. Kesinlik, modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu ölçmektedir. Yani, TP'lerin toplam pozitif tahminlere oranıdır ve

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

formülü ile hesaplanır. Duyarlılık, modelin gerçek pozitif örnekleri ne kadar iyi tespit ettiğini ölçer. TP'nin toplam gerçek pozitiflere oranıdır ve

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

ile hesaplanır. F1 puanı ise bir modelin kesinlik ve duyarlılığı birlikte değerlendiren bir metriktir. F1 puanı, kesinlik ve duyarlılığın harmonik ortalamasıdır. Kesinlik ve duyarlılığın dengeli olduğu durumlarda en yüksek değere ulaşır. F1 puanı, aşağıdaki formül ile hesaplanır:

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

Çalışmada alt örnekleme metodu kullanıldığından, yani azınlık sınıfına göre her sınıftaki pozitif ve negatiflerden rastgele örnek alındığından değerlendirme metriklerinin hesaplaması on kere tekrarlanmış ve her bir metriğin aritmetik ortalaması alınmıştır. Sonuçlar Tablo 3'te verilmektedir.

Tablo 3. Her sınıf için değerlendirme metrikleri ortalamaları (Evaluation metrics averages for each grade)

Kalite Boyutları	Doğruluk	Kesinlik	Duyarlılık	F1 Puanı
KY	0,8807	0,8867	0,8743	0,8800
KsizY	0,8673	0,9514	0,7743	0,8533
KS	0,7609	0,6986	0,9188	0,7936
KsizS	0,8332	0,9030	0,7475	0,8175
GA	0,8262	0,8297	0,8228	0,8256
KA	0,7604	0,8613	0,6238	0,7229
DF	0,7490	0,7643	0,7218	0,7415
YF	0,8312	0,9519	0,6980	0,8051

Tablo 3'ten görüldüğü üzere, modelin performansı her sınıfa göre değişiklik göstermekte, değerlendirme sonucu mükemmel olmasa da iyi bir performans elde edildiği söylenebilmektedir. Buna göre doğruluk, tüm sınıflar için genelde %75 ile %88 arasında değişmekte, çoğu sınıfta %80'in üstünde değer almaktadır. Kesinlik, özellikle KsizY ve YF sınıflarında oldukça yüksektir ve bu da modelin bu sınıflar için tahmin ettiği pozitif örneklerin çoğunlukla doğru olduğunu göstermektedir. KS sınıfında %70 ile en düşük kesinlik değeri gözlenmiştir. Bu da modelin pozitif tahminlerinin bir kısmının hatalı olduğunu işaret eder. Duyarlılıkta KS %91 ile en yüksek seviyededir. Bu, modelin bu sınıftaki gerçek pozitifleri iyi bir şekilde yakaladığını göstermektedir. Ancak, KA ve YF sınıflarında duyarlılık değerleri sırasıyla %62 ve %70 olarak hesaplanmıştır. Bu da modelin bu sınıflarda daha fazla hatalı negatif tahmin yaptığını işaret eder. F1 puanı incelendiğinde en yüksek F1 puanı KY sınıfında (%88) elde edilmiş, en düşük F1 puanı ise KA sınıfında (%72) gözlemlenmiştir.

4. Bulgular (Findings)

Çalışmada, 89 balık restorana yapılan müşteri yorumları kullanılmıştır. En fazla yorum alan restoranın yorum sayısı 609, en düşük ise 8'dir. Restoran başına ortalama yorum sayısı ise 171,97'dir.

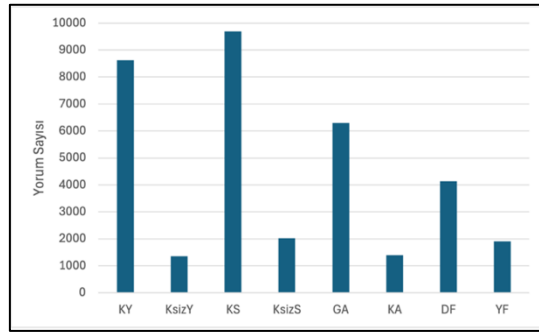
Müşteri memnuniyetini etkileyen farklı boyutların karşılaştırılarak, restoranların güçlü ve zayıf yönlerinin belirlenmesi ve bu alanlara yönelik iyileştirmeler yapılması restoranlar için kritik önem taşımaktadır. Bunun yanında, yorumların farklı kategorilerdeki pozitif ve negatif duygu dağılımlarının zaman içindeki değişimlerinin incelenmesi, restoranların müşteri memnuniyeti eğilimlerini anlamalarına ve bu doğrultuda gelecek için stratejik kararlar almalarına olanak tanımaktadır. Ayrıca, müşteri yorumları içinde farklı

dillerde yapılan yorumlar da bulunmaktadır. İzmir'in turistik bir yer olması ve balık restoranları ile ilgili ünü göz önünde bulundurulduğunda, yabancı müşterilerin algılarının da araştırılması önem taşımaktadır.

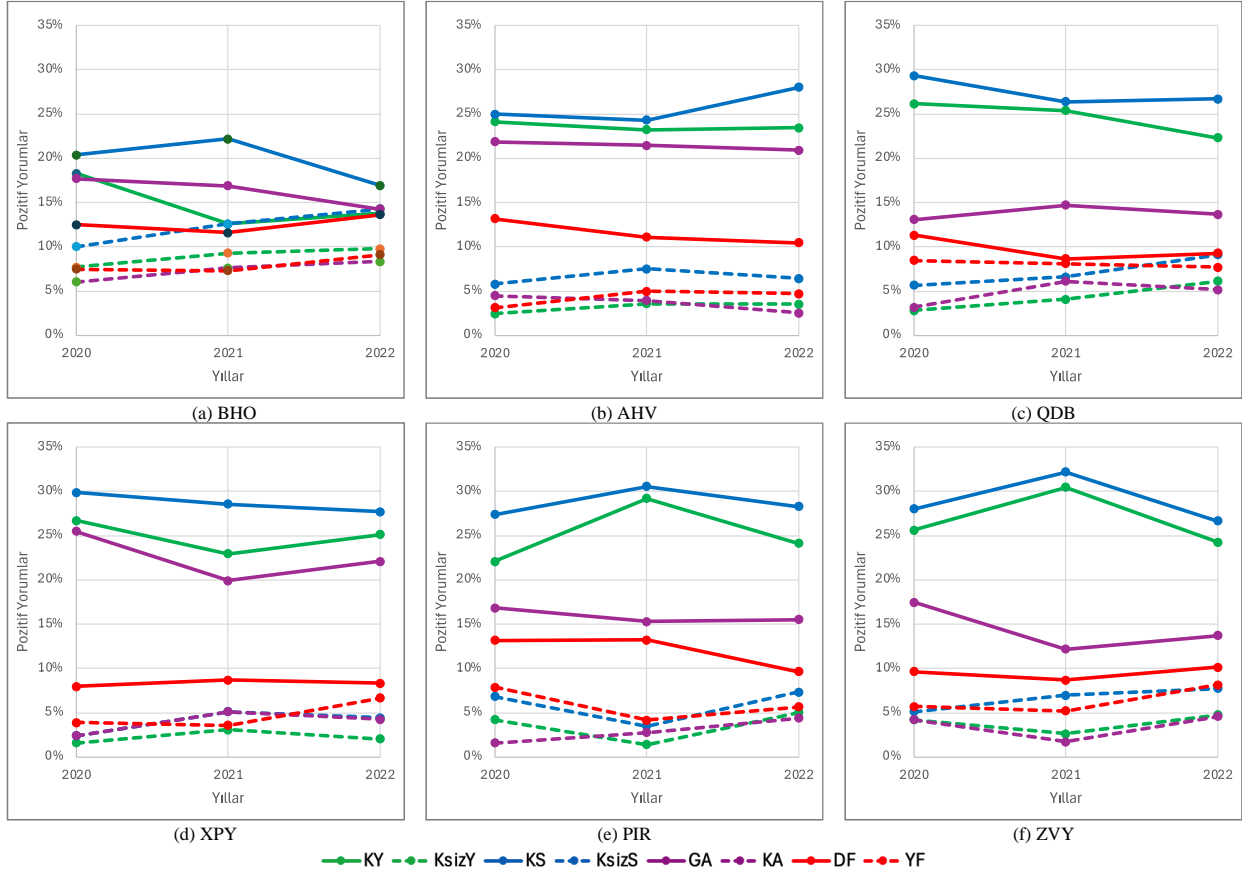
Buna yönelik olarak, başta 2013-2023 yılları arasında İzmir genelindeki balık restoranları için müşterilerin memnuniyetini etkileyen en önemli boyutlar araştırılmıştır. Şekil 5'ten de görüleceği üzere 89 restoran için en çok KS üzerine yorum yapılmıştır. En az yorum ise KsizY üzerinedir. Ayrıca, müşteriler çoğunlukla servis boyutu (KS + KsizS) üzerine yorum yapmışlar ve en az yorumlanan ise fiyat boyutudur (DF + YF). Ayrıca, olumlu yorumlar olumsuz yorumlara göre çok daha fazla sayıdadır.

Tüm yorumların %20'lik kısmını kapsayan en çok yorum yapılan ilk altı restoran seçilmiş ve yıllara göre

müşteri yorumlarındaki değişim incelenmiştir (Şekil 6). Veriler en son Mart 2023'te alındığından ve 2023 yılında çok az veri olduğundan bu yıla ait veriler incelemeye dahil edilmemiştir. Her yıl için farklı yorum sayıları bulunduğu için, bu değerler o yılda kategorilerde kaç yorum bulunuyorsa toplam yorum sayısına göre yüzde olarak hesaplanmıştır. Bu analiz sayesinde zamansal olarak restoran işletmelerinin kalite boyutlarında olumlu veya olumsuz değişimler gözlenebilmekte, böylece restoranların hangi kalite boyutunda iyileştirme yapmaları gerektiği belirlenebilmektedir. Ayrıca, rakip restoranlar karşılaştırılarak, birbirlerine yönelik eksi veya artı yönlere gösterilebilmektedir.




Şekil 5. İzmir balık restoranları kalite boyutu sınıfları dağılımları (Distribution of quality dimension classes of İzmir fish restaurants)



Şekil 6. En çok yorum alan ilk altı restoran için sınıfların yıllara göre değişimi (Yearly change in classes for the top six most reviewed restaurants)

Örneğin, BHO kodlu restoran incelendiğinde her yıl GA üzerine yapılan pozitif yorum sayısı azalmış, aynı şekilde, KA boyutuna yönelik pozitif yorum sayısı artmıştır. Bu durum, restoranın ambiyansa yönelik iyileştirme yapması gerektiğini göstermektedir. Aynı zamanda, GA ve KA sınıfları arasındaki artış ve azalıştaki denge de göz önüne serilmektedir. Bu durum, örnek verilen diğer restoranların çoğunda da farklı boyutlarda gözlenmektedir. XPY ve ZVY restoranları incelendiğinde, ikisinde de DF'a yönelik pozitif olarak pek bir değişim olmadığı görülürken, YF'da özellikle 2021 yılından sonra az da olsa küçük bir artış gözlenmektedir. Bu da bu iki restoranın nispeten fiyatlandırma stratejilerini doğru uyguladıklarını açıklamaktadır. AHV restoranında 2021-2022 yılları arasında KS'de gözle görülür bir iyileşme olduğu görülmektedir. Bu da restoran açısından müşteri memnuniyetini artırıcı bir özelliktir. Rakip restoranlar karşılaştırıldığında örneğin, XPY 2021'den sonra rakiplerine göre özellikle GA sınıfında müşterilerden gelen pozitif yorumlar neticesinde daha başarılı görülürken, diğer restoranlar bu sınıfta pek de bir başarı gösterememiştir. Buna yönelik olarak da restoranların iyileştirme yapmaları gerekmektedir.

Çalışmada ayrıca Türkçe haricindeki dillerde yapılan yorumlar da incelenmiştir. 15305 yorum için yabancı dilde yapılan yorum sayısı yaklaşık %11'lik paya sahiptir. Müşteri yorumlarındaki Türkçe harici dillerin tespiti için Google Sheets'de yer alan DETECTLANGUAGE() fonksiyonu kullanılmıştır. Şekil 7'de İzmir'deki tüm restoranlar için Türkçe ve yabancı dilde yapılan yorumlar kalite boyutlarına göre karşılaştırılmıştır. 31.287 Türkçe pozitif ve 4137 yabancı dil pozitif olan veriler yüzdeliğe dönüştürülmüştür.

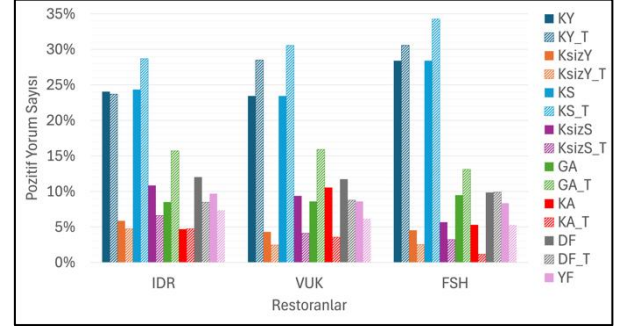


Şekil 7. İzmir'deki balık restoranlarına yapılan yorumların sınıflar ve dillere göre karşılaştırılması (Comparison of comments on fish restaurants in İzmir by classes and languages)

Şekil 7'den görüldüğü üzere, KY ve KS sınıflarında yabancı dilde yazan müşteriler bu sınıflarda Türkçe yazanlara göre daha fazla oranda pozitif yönde görüşlerini belirtmişlerdir. Türkçe yorumda bulunanlarda ise GA sınıfı öne çıkmaktadır.

En çok yabancı dilde yorumun yapıldığı ilk üç restoran incelendiğinde, KS ve GA sınıfları hakkında Türkçe yorumlar, yabancı dildeki yorumlardan oranca daha fazladır (Şekil 8). VUK ve FSH restoranlarında KY

sınıfı Türkçe yorum yapanlarda daha yüksek orandadır. Yabancı dilde yorum yapan müşteriler GA'ya pek önem vermezken, Türkçe yorum yapan müşterilerde bu oran daha yüksektir. Fiyatlandırma incelendiğinde ise IDR ve VUK restoranlarında yabancı dilde yazan müşteriler Türkçe yazan müşterilere göre DF sınıfı üzerine pozitif yorumlarda bulunmasının yanında, her üç restoranda da fiyatların yüksekliğinden bahsedilmektedir.



Şekil 8. En çok yabancı dilde yorum yapılan üç restorana ait müşteri yorumlarının Türkçe yorumlarla karşılaştırılması (Comparison of customer reviews of the three restaurants with the most foreign language reviews with Turkish reviews)

5. Sonuçlar ve Tartışmalar (Conclusions and Discussions)

Bu makalede, İzmir'deki balık restoranlarına ait müşteri yorumları üzerinde sıfır-atış metin sınıflandırma yöntemi kullanılarak hedef tabanlı duygu analizi gerçekleştirilmiştir. Çalışmada kullanılan yöntem ile restoranların yemek kalitesi, servis kalitesi, fiziksel çevre ve adil fiyat kalite boyutlarında güçlü ve zayıf yönleri belirlenebilmektedir.

Çalışmada kullanılan yöntem, çeşitli açılardan önemli avantajlar sunmaktadır. İlk olarak, sıfır-atış metin sınıflandırma yönteminde kullanılan önceden eğitilmiş dil modelleri, özellikle büyük veri setlerinin hızlı ve etkin bir biçimde sınıflandırılmasını ve kullanıcıların uzun süren eğitim ve test gibi geleneksel makine öğrenmesi aşamalarını atlamasını sağlamaktadır. Bu durum, ayrıca, sürekli artan müşteri yorumlarını gerçek zamanlı olarak analiz etme ihtiyacı olan işletmeler için büyük faydalar sağlayacaktır. İkinci olarak, geleneksel doğal dil işleme projelerinde genellikle tek bir dil üzerinde çalışılırken, diller arasındaki farklılıklar çok dilli veri setleri ile çalışmaya engel olmakta, çalışmada önerilen yöntem ise farklı dillerdeki metinlerden oluşan veri setlerinin dilden bağımsız şekilde analiz edilmesini mümkün kılmaktadır. Üçüncü olarak, sıfır-atış metin sınıflandırma geleneksel hedef tabanlı duygu analizine kıyasla önemli bir avantaj sağlamaktadır. Çünkü, geleneksel yöntem, iki safhada gerçekleştirilmektedir. Yani, başta konular belirlenmekte (örneğin konu modelleme) ve daha sonra belirlenen konular üzerine duygu analizi gerçekleştirilmektedir. Çalışmada önerilen yöntem, bu adımları birleştirerek tek seferde

verilen konu üzerinden duyguyu belirlemede, böylece, adımlar basitleşerek analiz süresi kısalmaktadır.

Modelin performansının değerlendirilmesi aşamasında, veri setindeki farklı kalite boyutları için pozitif ve negatif örnek sayısındaki dengesizlik, performans değerlendirmesinde zorluk yaratmıştır. Bu durumu azaltmak için alt örnekleme yöntemi kullanılmış, bazı bilgilerin kaybolması dezavantajını en aza indirmek için azınlıklık sınıfı sayısına göre örnekleme tekrarlanmış ve çıkan sonuçların aritmetik ortalaması alınmıştır.

Değerlendirme metrikleri incelendiğinde, modelin farklı sınıflarda değişken bir performans sergilediği gözlemlenmektedir. Doğruluk incelendiğinde, tüm sınıflarda %75 ve üzerinde çıkmıştır. Bu durum, modelin çoğu durumda doğru tahminler yaptığını ve güvenilir olduğunun göstergesidir. KY, KsizY, KsizS, GA ve YF sınıflarında %80 ve üzerindeki F1 puanları modelin bu sınıflarda güvenilir bir şekilde çalıştığını göstermektedir. Bununla birlikte, KS, KA ve DF sınıflarında F1 puanları (sırasıyla, 0,79, 0,72 ve 0,74) modelin bu sınıflardaki performansında dengesizlikler olabileceğini işaret etmektedir. Özellikle KS sınıfında yüksek duyarlılığa (0,92) rağmen nispeten düşük kesinlik (0,70), bu sınıfta hatalı pozitif oranının varlığını göstermektedir. Benzer şekilde, KA sınıfında yüksek kesinlik (0,86) ancak düşük duyarlılık (0,62), modelin doğru pozitifleri belirlemede zorluk yaşadığını ortaya koymaktadır. Fakat diğer sınıflardaki performans, modelin etkili tahminler yapma kapasitesini açıkça gözler önüne sermektedir.

Hataların sebeplerinin birçok nedene bağlı olduğu düşünülmektedir. Örneğin model, “*Çok nezih ve balığı lezzetli bir restoran. Fiyatlar biraz yüksek.*” veya “*Yeri çok merkezi. Yiyecekler ve mezeler çok lezzetli.*” yorumlarında KS’den bahsedilmemesine rağmen eşik değerinin üstünde bir puanı KS sınıfına vermiştir. Bu tür hatalar kesinlik puanının KS sınıfında düşük çıkmasına yol açmıştır. Aynı şekilde, KA sınıfında, örneğin, “*El değiştirmiş ve gayet bozmuş...*” veya “*Mezgit şiş enfes.*” yorumlarında model KA’ya yüksek puan vermiştir. Yukarıda bahsedilen bu tür hataların sebebinin restoran hakkında yapılan bazı yorumların genel bir değerlendirme olduğundan kaynaklandığı ve böylece modelin yanlış yorumladığı kanısına varılmıştır. Bununla birlikte, her ne kadar veri ön işleme aşamasında üç kelimenin altındaki yorumlar veri setinden çıkarılmış olsa da yukarıda örneği verilen nispeten kısa cümlelerden ötürü, modelin hatalar yapmış olduğu olasıdır. Örneğin, “*Yemek kalitesi iyiydi, fiyatlarda bu kalite için çok pahalı değil. Fakat restorandaki yaklaşım maalesef iyi değildi. Mekân genel anlamda boş olduğu halde talep ettiğimiz masayı bize vermediler, eşimle beni ısrarla kuytu köşe bir yere oturtular. 600 TL’lik bir hesaptan sonra meyve ikram edilmesi usuldendir, yapamayacaklarını söylediler, zorunda değiller tabi. Ama çay ikram ettiler.*” yorumu gayet başarılı bir şekilde sınıflandırılmıştır.

Bu çalışmada kullanılan yöntem, yöneticilerin karar alma süreçlerinde restoranların güçlü ve zayıf yönlerini hızlı ve etkin bir biçimde belirlemelerine yardımcı olacak ve hizmet kalitesini artırmak için gerekli iyileştirme alanlarını tespit etmelerini sağlayacaktır. Bu sayede yöneticiler, stratejik kararlar alabilecek ve operasyonel iyileştirme süreçlerini başlatabileceklerdir. Örneğin, yemek kalitesinin iyi olduğu, ancak servis kalitesinin veya fiyatlandırmanın olumsuz geri bildirim aldığı tespit edildiğinde, bu bilgi, yöneticilerin ilgili alanlara yönelik iyileştirme ve yatırımlar yapma kararı almasına olanak sağlayacaktır.

Çalışmada önerilen yöntem, yöneticilerin, farklı müşteri gruplarının restoran hizmetleri konusundaki ihtiyaç ve beklentilerini, bunların ne ölçüde karşılandığını daha iyi değerlendirmelerini sağlayacaktır. Örneğin, yabancı müşterilerin belirli bir boyuta verdikleri önem, Türk müşteriler için farklı olabilmektedir. Bu bilgiler, müşteri segmentasyonuna göre özelleştirilmiş hizmet sunum stratejilerinin geliştirilmesine yardımcı olacaktır.

Gelecekteki çalışmalar için model performansının daha etkin bir şekilde değerlendirilmesinin önemli olduğu düşünülmektedir. Örneğin, KY boyutunda 1005 olan pozitif yorum sayısı, alt örnekleme yöntemiyle KA boyutundaki pozitif yorum sayısına, yani 101’e düşürülmüştür. Rastgele on kez örnek alınarak alt örnekleme uygulanıp sonuçların aritmetik ortalaması alınsa da azınlık sınıflarının temsil edilebilirliğini artırmak ve modelin düşük sayıya sahip sınıflarda daha tutarlı performans göstermesini sağlamak için bu sınıfların veri sayısının artırılması gerekmektedir. Bu amaçla, sentetik veri üretim yöntemleri kullanılabilirliği olasıdır. Ayrıca, çalışmada kullanılan önceden eğitilmiş dil modeli yerine farklı modellerin denenmesiyle hataların azaltılması ve model performansının iyileştirilmesi de mümkündür. Buna ek olarak, veri setine özgü bir ince ayar yapılmasıyla modelin hedef boyutlar üzerindeki duyarlılığını ve genel performansını artırabileceği öngörülmektedir.

İleriki çalışmalarda, kullanılan yöntemin GPT gibi yeni nesil dönüştürücü tabanlı modeller ile karşılaştırılması hedeflenmektedir. Bu sayede, karmaşık dil yapılarının işlenmesi konusunda yeni açılımlar sağlanacaktır. Ayrıca, metinlerdeki duygu yoğunluğunun ölçülmesi (örneğin, müşterinin bir şeyi çok, az veya orta seviye sevmesi), müşteri taleplerinin ve beklentilerinin daha derinlemesine anlaşılmasını sağlayacaktır. Bu sayede, müşterilerin belirli bir hizmet veya ürüne dair farklı unsurlara yönelik duygu yoğunlukları arasındaki farklar net bir şekilde ortaya konabilecektir.

Kaynaklar (References)

- Abdullah, M., Waheed, S., Hossain, S., 2023. Sentiment analysis of restaurant reviews using machine learning. Fourth International Conference on Trends in Computational and Cognitive Engineering: TCCE 2022, 17–18 December 2022, Tangail, Bangladesh, pp. 419–428.

- Ahmed, M., Chen, Q., Li, Z., 2020. Constructing domain-dependent sentiment dictionary for sentiment analysis. *Neural Computing & Applications*, 32(18), 14719–14732.
- Akgündüz, Y., Koba, Y., Alkan, C., 2017. Yerel halkın bakışıyla İzmir'in gastronomi turizmi değerleri ve gelişme potansiyeli. *Aydın gastronomy*, 8(1), 169–186.
- Akyurt Kurnaz, H., 2024. Gastronomi rehberliği. *Anatolia: Turizm araştırmaları dergisi*, 35(1), 129–132.
- Altıntaş, V., Hazarhun, E., 2020. İzmir'in gastronomi turizmi potansiyeline turist rehberlerinin bakış açıları. *International journal of applied economic and finance studies*, 5(2), 13-36.
- Ara, J., Hasan, Md. T., Al Omar, A., Bhuiyan, H., 2020. Understanding customer sentiment: Lexical analysis of restaurant reviews. 2020 IEEE Region 10 Symposium (TENSYP), 5-7 June 2020, Dhaka, Bangladesh, pp. 295-299.
- Azunre, P., 2021. Transfer learning for natural language processing. Manning, New York.
- Bansal, A., Sikka, K., Sharma, G., Chellappa, R., Divakaran, A., 2018. Zero-shot object detection. ECCV 2018, 15th European Conference, 8-14 September 2018, Munich, Germany, pp. 397–414.
- Bengül, S., Dinç, T. E., 2023. Marka deneyimi ile müşteri sadakati arasındaki ilişkinin kanonik korelasyon analizi ile incelenmesi, yiyecek içecek işletmeleri üzerinde bir uygulama. *Pazarlama ve pazarlama araştırmaları dergisi*, 16(2), 421-450.
- Bozkurt, A. H., Yalçın, N., 2024. Topluluk öğrenmesi algoritmaları kullanarak Amazon yemek yorumları üzerine duygu analizi. *Bilecik Şeyh Edebali Üniversitesi fen bilimleri dergisi*, 11(1), 128–139.
- Branco, A., Parada, D., Silva, M., Mendonça, F., Mostafa, S. S., Morgado-Dias, F., 2024. Sentiment analysis in Portuguese restaurant reviews: Application of transformer models in edge computing. *Electronics*, 13(3), 589.
- Brattoli, B., Tighe, J., Zhdanov, F., Perona, P., Chalupka, K., 2020. Rethinking zero-shot video classification: End-to-end training for realistic applications. Conference on Computer Vision and Pattern Recognition (CVPR), 13-19 June 2020, Seattle, WA, USA, pp. 4612-4622.
- Carrasco, P., Dias, S., 2023. Exploring natural language processing and sentence embeddings for sentiment analysis of online restaurant reviews. *Atas da 23ª Conferência da Associação Portuguesa de Sistemas de Informação*, 19-21 October 2023, Peja, Portugal.
- Carrasco, P., Dias, S., 2024. Enhancing restaurant management through aspect-based sentiment analysis and NLP techniques. *Procedia computer science*, 237, 129–137.
- Chang, M-W., Ratinov, L., Roth, D., Srikumar, V., 2008. Importance of semantic representation: dataless classification. 23rd National Conference on Artificial Intelligence – Volume 2, 13–17 July 2008, Chicago Illinois, pp. 830–835.
- Cherapanukorn, V., Sugunasil, P., 2022. Tourist attraction satisfaction factors from online reviews. A case study of tourist attractions in Thailand. *Journal of environmental management and tourism*, 13(2), 379.
- Chifu, A.-G., Fournier, S., 2023. Sentiment difficulty in aspect-based sentiment analysis. *Mathematics*, 11(22), 4647.
- Choi, K., Ko, Y., 2023. Meta-learning with topic-agnostic representations for zero-shot stance detection. *Pattern recognition letters*, 171, 15–20.
- Conneau, A., Khandelwal, K., Goyal, N., Chaudhary, V., Wenzek, G., Guzmán, F., Grave, E., Ott, M., Zettlemoyer, L., Stoyanov, V., 2020. Unsupervised cross-lingual representation learning at scale. 58th Annual Meeting of the Association for Computational Linguistics, July 2020, Online, pp. 8440-8451.
- Çelik, E., Dalyan, T., 2023. Unified benchmark for zero-shot Turkish text classification. *Information processing & management*, 60(3), 103298.
- Das, S., Deb, N., Chaki, N., Cortesi, A., 2023. Driving the technology value stream by analyzing app reviews. *IEEE transactions on software engineering*, 49(7), 3753–3770.
- Erdoğan, S., Özdemir, G., 2018. İzmir destinasyonunda gastronomi turizmi üzerine bir araştırma. *Journal of tourism and gastronomy studies*, 10(3), 249–272.
- Estevam, V., Pedrini, H., Menotti, D., 2021. Zero-shot action recognition in videos: A survey. *Neurocomputing*, 439, 159–175.
- Gagić, S., Tešanović, D., Jovičić, A., 2013. The vital components of restaurant quality that affect guest satisfaction. *Turizam*, 17(4), 166–176.
- Gallego, V., 2023. (5 Haziran 2024) XLM-RoBERTa-large-XNLI-ANLI. <https://huggingface.co/vicgalle/xlm-roberta-large-xnli-anli>
- Gedif, B., Alemu, A., Assefa, Y., Nibret, S., 2023. Design amharic text sentiment analysis model using machine learning techniques. In case of restaurant reviews. 2023 International Conference on Information and Communication Technology for Development for Africa (ICT4DA), 26-28 October 2023, Bahir Dar, Ethiopia, pp. 150–154.
- Goodwin, T. R., Savery, M. E., Demner-Fushman, D., 2020. Towards zero-shot conditional summarization with adaptive multi-task fine-tuning. Findings of the Association for Computational Linguistics: EMNLP 2020, 16-20 November 2020, Online, pp. 3215–3226.
- Hall, C.M., Sharples, L., Mitchell, R., Macionis, N., Cambourne, B. (Eds.), 2003. Food tourism around the world. Butterworth-Heinemann, Oxford.
- Henrickson, K., Rodrigues, F., Pereira, F. C., 2019. Data preparation. C. Antoniou, L. Dimitriou, F. Pereira (Eds.), *Mobility patterns, big data and transport analytics* pp. 73–106, Elsevier, Amsterdam.
- Hoang, M., Bihorac, O. A., Rouces, J., 2019. Aspect-based sentiment analysis using BERT. 22nd Nordic Conference on Computational Linguistics, 30 September – 2 October 2019, Turku, Finland, pp. 187–196.
- Hoppe, F., Dessi, D., Sack, H., 2021. Understanding class representations: An intrinsic evaluation of zero-shot text classification. Workshop on Deep Learning for Knowledge Graphs (DL4KG@ISWC2021), 25 October, Online.
- Hossain, E., Sharif, O., Hoque, M. M., Sarker, I. H., 2021. SentiLSTM: A deep learning approach for sentiment analysis of restaurant reviews. 20th International

- Conference on Hybrid Intelligent Systems (HIS 2020), 14-16 December, Online, pp. 193–203.
- Hossain, N., Bhuiyan, M. R., Tumpa, Z. N., Hossain, S. A., 2020. Sentiment analysis of restaurant reviews using combined CNN-LSTM. 2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT), 1-3 July 2020, Kharagpur, India.
- Hugging Face, 2024. Pipelines. (10 Temmuz 2024) https://huggingface.co/docs/transformers/main_classes/pipelines
- Iram, S., Vialatte, F.-B., Qamar, M. I., 2016. Early diagnosis of neurodegenerative diseases from gait discrimination to neural synchronization. D. Al-Jumeily, A. Hussain, C. Mallucci, C. Oliver (Eds.), *Applied computing in medicine and health* (pp. 1–26). Elsevier, Waltham.
- Jiang, Q., Chen, L., Xu, R., Ao, X., Yang, M., 2019. A challenge dataset and effective models for aspect-based sentiment analysis. 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), 3-7 November 2019, Hong Kong, China, pp. 6280–6285.
- Jiang, Y., Gao, J., Shen, H., Cheng, X., 2023. Zero-shot stance detection via multi-perspective contrastive learning with unlabeled data. *Information processing & management*, 60(4), 103361.
- Jiao, Q., 2023. A brief survey of text classification methods. 2023 IEEE 3rd International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA), 26-28 May 2023, Chongqing, China, pp. 1384-1389.
- Johnson, M., Schuster, M., Le, Q. V., Krikun, M., Wu, Y., Chen, Z., Thorat, N., Viégas, F., Wattenberg, M., Corrado, G., Hughes, M., Dean, J., 2017. Google's multilingual neural machine translation system: Enabling zero-shot translation. *Transactions of the Association for Computational Linguistics*, 5, 339–351.
- Jurafsky, D., Chahuneau, V., Routledge, B. R., Smith, N. A., 2014. Narrative framing of consumer sentiment in online restaurant reviews. *First Monday*, 19(4).
- Kar, A., Dhara, S. K., Sen, D., Biswas, P. K., 2021. Zero-shot single image restoration through controlled perturbation of Koschmieder's model. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 20-25 June 2021, Nashville, TN, USA, pp. 16200-16210.
- Khakhar, P., Dubey, R. K., 2022. The integrity of machine learning algorithms against software defect prediction. R. Pandey, S. K. Khatri, N. K. Singh, P. Verma (Eds.), *Artificial Intelligence and Machine Learning for EDGE Computing*, (pp. 65–74). Elsevier, London.
- Krishna, A., Akhilesh, V., Aich, A., Hegde, C., 2019. Sentiment analysis of restaurant reviews using machine learning techniques. *International Conference, ICERECT 2018*, 23-24 August 2018, Mandya, India, pp. 687–696.
- Kukanja, M., Gomezelj Omerzel, D., Kodrič, B., 2017. Ensuring restaurant quality and guests' loyalty: An integrative model based on marketing (7P) approach. *Total quality management & business excellence*, 28(13–14), 1509–1525.
- Kulkarni, A., Chong, D., Batarseh, F. A., 2020. Foundations of data imbalance and solutions for a data democracy. F. A. Batarseh, R. Yang (Eds.), *Data Democracy* (pp. 83–106). Elsevier, London.
- Kumar, A., Albuquerque, V. H. C., 2021. Sentiment analysis using XLM-R transformer and zero-shot transfer learning on resource-poor Indian language. *ACM transactions on Asian and low-resource language information processing*, 20(5), 1–13.
- Kumar, J., Konar, R., Balasubramanian, K., 2020. The impact of social media on consumers' purchasing behaviour in Malaysian restaurants. *Journal of tourism, sustainability and well-being*, 8(3), 197-216.
- Küçükkömürler, S., Şırvan, N. B., Sezgin, A. C., 2019. Dünyada ve Türkiye'de gastronomi turizmi. *Uluslararası turizm ekonomi ve işletme bilimleri dergisi*, 2(2), 78-85.
- Lampert, C. H., Nickisch, H., Harmeling, S., 2014. Attribute-based classification for zero-shot visual object categorization. *IEEE transactions on pattern analysis and machine intelligence*, 36(3), 453-465.
- Lavanya, B. N., Shenoy, P. D., Venugopal, K. R., 2023. Sentiment analysis of social media reviews using machine learning and word embedding techniques. 2023 IEEE 4th Annual Flagship India Council International Subsections Conference (INDISCON), 5-7 August 2023, Mysore, India.
- Leburu-Dingalo, T., Ntwaagae, K. J., Motlogelwa, N. P., Thuma, E., Mudongo, M., 2022. Application of XLM-RoBERTa for multi-class classification of conversational hate speech. *FIRE 2022 Working Notes*, 9-13 December 2022, Kolkata, India, pp 590-595.
- Lepkowska-White, E., Parsons, A., 2019. Strategies for monitoring social media for small restaurants. *Journal of Foodservice Business research*, 22(4), 351–374.
- Li, Y., Zhu, Z., Yu, J.-G., Zhang, Y., 2021. Learning deep cross-modal embedding networks for zero-shot remote sensing image scene classification. *IEEE transactions on geoscience and remote sensing*, 59(12), 10590–10603.
- Liu, B., Li, X., Lee, W S., Yu, P. S., 2004. Text classification by labeling words. 19th national conference on artificial intelligence (AAAI'04), 25-29 July 2004, San Jose, California, USA, pp. 425–430.
- Liu, C., Fang, F., Lin, X., Cai, T., Tan, X., Liu, J., Lu, X., 2021. Improving sentiment analysis accuracy with emoji embedding. *Journal of safety science and resilience*, 2(4), 246–252.
- Liu, H., Zhang, X., Fan, L., Fu, X., Li, Q., Wu, X.-M., Lam, A. Y. S., 2019. Reconstructing capsule networks for zero-shot intent classification. 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), 3-7 November 2019, Hong Kong, China, pp. 4799–4809.
- Logeswaran, L., Chang, M.-W., Lee, K., Toutanova, K., Devlin, J., Lee, H., 2019. Zero-shot entity linking by reading entity descriptions. 57th Annual Meeting of the Association for Computational Linguistics, 28 July – 2 August 2019, Florence, Italy, pp. 3449–3460.
- Mahapatra, D., Bozorgtabar, B., Ge, Z., 2021. Medical image classification using generalized zero shot learning. 2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW), 11-17 October 2021, Montreal, BC, Canada, pp. 3337-3346.

- Manias, G., Mavrogiorgou, A., Kiourtis, A., Symvoulidis, C., Kyriazis, D., 2023. Multilingual text categorization and sentiment analysis: A comparative analysis of the utilization of multilingual approaches for classifying twitter data. *Neural computing & applications*, 35, 21415–21431.
- Masarifoglu, M., Tigrak, U., Hakyemez, S., Gul, G., Bozan, E., Buyuklu, A. H., Özgür, A., 2021. Bankacılık alanında müşteri yorumlarının BERT tabanlı yaklaşımlar ile duygu analizi. 2021 29th Signal Processing and Communications Applications Conference (SIU), 9-11 June, Istanbul, Turkey.
- McInerney, D. J., Young, G., van de Meent, J.-W., Wallace, B. C., 2023. (15 Temmuz 2024). CHiLL: Zero-shot custom interpretable feature extraction from clinical notes with large language models. <https://arxiv.org/abs/2302.12343>
- Mohammad, S. M., 2017. Challenges in sentiment analysis. E. Cambria, D. Das, S. Bandyopadhyay, A. Feraco (Eds.), *A practical guide to sentiment analysis* (pp. 61–83), Springer, Cham.
- Nankani, H., Dutta, H., Shrivastava, H., Rama Krishna, P. V. N. S., Mahata, D., Shah, R. R., 2020. Multilingual sentiment analysis. B. Agarwal, R. Nayak, N. Mittal, S. Patnaik (Eds.), *Deep learning-based approaches for sentiment analysis* (pp. 193–236). Springer, Singapore.
- Pang, B., Lee, L., 2008. Opinion mining and sentiment analysis. *Foundations and trends® in information retrieval*, 2(1–2), 1–135.
- Patil, D. R., Shukla, D., Kumar, A., Rajanak, Y., Pratap Singh, Y., 2022. Machine learning for sentiment analysis and classification of restaurant reviews. 2022 3rd International Conference on Computing, Analytics and Networks (ICAN), 18-19 November 2022, Rajpura, Punjab, India.
- Pérez, J. M., Furman, D. A., Alemany, L. A., Luque, F. M., 2022. RoBERTuito: A pre-trained language model for social media text in Spanish. Thirteenth Language Resources and Evaluation Conference, 20-25 June 2022, Marseille, France, pp. 7235–7243.
- Pourpanah, F., Abdar, M., Luo, Y., Zhou, X., Wang, R., Lim, C. P., Lim, C. P., X-Z., Wang, Wu, Q. M. J., 2023). A review of generalized zero-shot learning methods. *IEEE transactions on pattern analysis and machine intelligence*, 45(4), 4051–4070.
- Pradhan, B., Al-Najjar, H. A. H., Sameen, M. I., Tsang, I., Alamri, A. M., 2020. Unseen land cover classification from high-resolution orthophotos using integration of zero-shot learning and convolutional neural networks. *Remote Sensing*, 12(10), 1676.
- Quazi, S., Musa, S. M., 2022. Text classification and categorization through deep learning. 2022 14th International Conference on Computational Intelligence and Communication Networks (CICN), 4-6 December 2022, Al-Khobar, Saudi Arabia, pp. 513-519.
- Revathi, K. L., Satish, A. R., Rao, P. S., 2023. Feature level fine grained sentiment analysis for classifying online restaurant reviews. 2023 Second International Conference on Electrical, Electronics, Information and Communication Technologies (ICEEICT), 5-7 April 2023, Trichirappalli, India.
- Rey-Moreno, M., Sánchez-Franco, M. J., Rey-Tienda, M. D. la S., 2023. Examining transaction-specific satisfaction and trust in Airbnb and hotels. An application of BERTopic and zero-shot text classification. *Tourism & management studies*, 19(2), 21-37.
- Rezaei, M., Shahidi, M., 2020. Zero-shot learning and its applications from autonomous vehicles to COVID-19 diagnosis: A review. *Intelligence-based medicine*, 3(100005), 100005.
- Romera-Paredes, B., Torr, P. H. S., 2017. An embarrassingly simple approach to zero-shot learning. R. S. Feris, R. S., C. Lampert, D. Parikh (Eds.), *Visual attributes* (pp. 11–30). Springer, Cham.
- Sahar, A., Ayoub, M., Hussain, S., Yu, Y., Khan, A., 2022. Transfer learning-based framework for sentiment classification of cosmetics products reviews. *Pakistan journal of engineering and technology*, 5(3), 38–43.
- Sanghi, A., Chu, H., Lambourne, J. G., Wang, Y., Cheng, C.-Y., Fumero, M., Malekshan, K. R., 2022. CLIP-forge: Towards zero-shot text-to-shape generation. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 18-24 June 2022, New Orleans, LA, USA, pp. 18582-18592.
- Soleymani, M., Garcia, D., Jou, B., Schuller, B., Chang, S.-F., Pantic, M., 2017. A survey of multimodal sentiment analysis. *Image and vision computing*, 65, 3–14.
- Suciati, A., Budi, I., 2019. Aspect-based opinion mining for code-mixed restaurant reviews in Indonesia. 2019 International Conference on Asian Language Processing (IALP), 15-17 November 2019, Shanghai, China, pp. 59–64.
- Thompson, B., Post, M., 2020. Automatic machine translation evaluation in many languages via zero-shot paraphrasing. 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), 16-20 November 2020, Online, pp. 90–121.
- Tuna, M. F., Polatgil, M., Kaynar, O., 2023. Restoran müşterilerinin geri bildirimleri üzerinde hedef kategorinin tespiti ve hedef tabanlı duygu analizi. *Süleyman Demirel Üniversitesi vizyoner dergisi*, 14(40), 1205–1221.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., Polosukhin, I., 2017. Attention is all you need. 31st International Conference on Neural Information Processing Systems (NIPS 2017), 4-9 December 2017, Long Beach, CA, USA.
- Vétül, R., Abi-Nader, C., Bône, A., Vullierme, M.-P., Rohé, M.-M., Gori, P., Bloch, I., 2022. Learning shape distributions from large databases of healthy organs: Applications to zero-shot and few-shot abnormal pancreas detection. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2022: 25th International Conference*, 18-22 September 2022, Singapore, Singapore, pp. 464–473.
- Wang, W., Zheng, V. W., Yu, H., Miao, C., 2019. A survey of zero-shot learning. *ACM transactions on intelligent systems and technology*, 10(2), 1–37.
- Yentür, F., Demir, C., 2022). The current perceptions of travel agencies in Izmir about gastronomy tourism and their actual gastronomic tourism offers. *Journal of gastronomy hospitality and travel*, 5(1), 238-249.
- Yi, S., Zhao, J., Joung, H.-W. (david), 2018. Influence of price and brand image on restaurant customers' restaurant selection attribute. *Journal of foodservice business research*, 21(2), 200–217.

- Yu, L., Feng, Q., Qian, Y., Liu, W., Hauptmann, A. G., 2020, June 14-19). Zero-VIRUS: Zero-shot vehicle route understanding system for intelligent transportation. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 14-19 June, 2020, Seattle, WA, USA, pp. 2534-2543.
- Yüksekbilgili, Z., 2015. Restoran seçim ölçütleri üzerine bir araştırma. *Journal of Yaşar University*, 9(36), 6453-6360.
- Zahoor, K., Bawany, N. Z., Hamid, S., 2020. Sentiment analysis and classification of restaurant reviews using machine learning. 2020 21st International Arab Conference on Information Technology (ACIT), 28-30 November 2020, Giza. Egypt.
- Zhan, C., She, D., Zhao, S., Cheng, M.-M., Yang, J., 2019. Zero-shot emotion recognition via affective structural embedding. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 27 October-2 November 2019, Seoul, Korea (South), pp. 1151-1160.
- Zhang, B., Williams, P., Titov, I., Sennrich, R., 2020. Improving massively multilingual neural machine translation and zero-shot translation. 58th Annual Meeting of the Association for Computational Linguistics, 5-10 July 2020, Online, pp. 1628–1639.
- Zhang, S., Ly, L., Mach, N., Amaya, C., 2022. Topic modeling and sentiment analysis of Yelp restaurant reviews. *International journal of information systems in the service sector*, 14(1), 1–16.
- Zheng, S., Gupta, G., 2022. Semantic-guided zero-shot learning for low-light image/video enhancement. 2022 IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW), 4-8 January 2022, Waikoloa, HI, USA, pp. 581-590.