T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TÜRKÇE SÖZLÜK TABANLI DUYGU ANALİZİ ARACI

Semih DURMAZ

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Prof. Dr. Banu DİRİ

Temmuz, 2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TÜRKÇE SÖZLÜK TABANLI DUYGU ANALİZİ ARACI

Semih Durmaz tarafından hazırlanan tez çalışması 22.07.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Banu DİRİ
Yildiz Technical University
Danışman

Danışmanım Prof. Dr. Banu DİRİ sorumluluğunda tarafımca hazırlanan Türkçe Sözlük Tabanlı Duygu ANALİZİ Aracı başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Semih Durmaz

İmza

Bu süreçte desteğini hiç esirgemeyen değerli hocam Prof. Dr. Banu Diri'ye ve bana her zaman güç ve moral veren sevgili eşime teşekkür ederim...

İÇİNDEKİLER

KISALTMA LİSTESİ vi

ŞEKİL LİSTESİ vii

TABLO LİSTESİ viii

ÖZET ix

ABSTRACT xi

1 GİRİŞ 1

1.1 Literatür Araştırması . . . 1

1.2 Makine Öğrenmesi Yöntemi . . . 2

1.2.1 Gözetimli Öğrenme . . . 2

1.2.2 Gözetimsiz Öğrenme . . . 4

1.3 Sözlük Tabanlı Yöntem . . . 6

2 MEVCUT ÇALIŞMALAR 8

2.1 TextBlob . . . 8

2.2 AFINN . . . 9

2.3 VADER . . . 10

2.3.1 VADER Sözlüğünün Oluşturulması . . . 10

2.3.2 VADER Sözlüğü . . . 11

2.3.3 VADER Cümle Puanlama . . . 11

2.3.4 VADER Sonuçları . . . 12

3 DUYGU SÖZLÜĞÜNÜN OLUŞTURULMASI 13

3.1 Çalışmanın Hedefi ve Avantajları . . . 13

3.2 Sözlüğün Oluşturulması . . . 14

3.2.1 Sık Kullanılan Kelimelerin Belirlenmesi . . . 15

3.3 Güçlendirici Kelimelerin Belirlenmesi . . . 17

3.4 Olumsuzluk Kelimelerinin Belirlenmesi . . . 18

3.5 Sözlüğün Etiketlenmesi . . . 19

4 DENEYSEL SONUÇLAR **21**
4.1 Veri Ön İşleme Adımları 21
4.2 Ürün Yorumları Üzerinde Yapılan Başarı Testleri 22
4.3 Yanlış Sonuçların Değerlendirilmesi 23
4.4 Yanlış Sonuçlara Yönelik Alınan Aksiyonlar ve Çözümler 24
4.4.1 Veri Etiketleme ve Genişletme 24
4.4.2 Gelişmiş Cümle Analizi 24
4.4.3 İyileştirilmiş Ön İşleme 25
4.4.4 Yorum-Puan Tutarlılığı 26
4.4.5 Alınan Aksiyonların Model Başarısına Etkisi 26
4.5 Sözlüğün Geliştirilmesi ve Güncellenmesi 26

5 SONUÇ **28**

KAYNAKÇA **29**

KISALTMA LİSTESİ

VADER	Valence Aware Dictionary and sEntiment Reasoner
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
AFINN	Affective Norms for English Words

ŞEKİL LİSTESİ

Şekil 2.1 TextBlob Cümle Puanlama 8
Şekil 2.2 TextBlob Cümle Puanlama Örneği 9
Şekil 2.3 AFINN Cümle Puanlama Örneği 10
Şekil 2.4 VADER Sözlüğü [15] 11
Şekil 2.5 VADER Cümle Puanlama 11
Şekil 2.6 VADER Sonuçları [16] 12
Şekil 3.1 En çok satılan kitaplar 16
Şekil 3.2 Kelime Sayımı Sonuçları 16
Şekil 3.3 Filtrelenmiş Kelime Sayımı Sonuçları 16
Şekil 3.4 Wikipedia Kelime Sayımı Sonuçları 17
Şekil 3.5 Etkiyi Arttıran Kelimeler 17
Şekil 3.6 Güçlendirici Kelimenin Duygu Puanına Etkisi 18
Şekil 3.7 Etkiyi Azaltan Kelimeler 18
Şekil 3.8 Olumsuzluk Kelimeleri 19
Şekil 3.9 Etiketlenmiş Sözlük 20
Şekil 4.1 Veri Ön İşleme Adımlarının Uygulanması 22
Şekil 4.2 Puanlama Örnekleri 22

TABLO LİSTESİ

Tablo 4.1 Hata Matrisi 23
Tablo 4.2 Veri Sınıflarına Göre Başarı Oranları Tablosu 23

ÖZET

Türkçe Sözlük Tabanlı Duygu ANALİZİ Aracı

Semih Durmaz

Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lİsans Tezi

Danışman: Prof. Dr. Banu DİRİ

Son yıllarda hızlanan ve COVID-19 ile zirveye ulaşan dijitalleşme, tüm alışkanlıklarımızı kökten değiştirdi. Teknolojinin sürekli değişip gelişmesiyle birlikte alışkanlıklarımız da dönüşüme uğruyor. Artık mağaza mağaza dolaşıp ürün aramak yerine internet üzerinden alışveriş yapıyoruz; restorana gidip yemek seçmek yerine uygulamalar üzerinden sipariş veriyoruz ve yemeklerimiz kapımıza kadar geliyor. Eskiden yüz yüze yaptığımız geri bildirimleri şimdi birkaç cümleyle online yorumlar aracılığıyla ifade ediyoruz. Bu yorumlar, gelecekteki müşteriler için önemli bilgiler sağlıyor ve onların satın alma kararlarını etkileyebiliyor. Aynı zamanda, işletme sahiplerine de geliştirilmesi gereken yönler hakkında değerli geri bildirimler sunuyor. Dijitalleşmenin bu hızlı yükselişi, günlük yaşamımızın her alanını etkileyerek alışkanlıklarımızı yeniden şekillendiriyor.

Yorumların değerlendirilmesi, işletmeler açısından son derece önemlidir. Müşteri geri bildirimleri, işletmelerin ürün ve hizmetlerini iyileştirmeleri için kritik bilgiler sunar. Olumlu yorumlar, müşteri memnuniyetinin göstergesi olarak işletmenin güçlü yönlerini vurgularken, olumsuz yorumlar işletmenin geliştirmesi gereken alanlarını işaret eder. Bu bağlamda, projede geliştirilecek olan duygu analizi aracı büyük bir öneme sahiptir. Bu araç sayesinde, müşterilerin hangi yorumlarının olumlu, hangilerinin olumsuz olduğu tespit edilebilir. Böylece işletmeler, binlerce yorumu hızlıca analiz ederek, mevcut memnuniyetsizliklere hızlıca müdahale edebilir ve gerekli iyileştirmeleri yaparak müşteri sadakatini artırabilir. Duygu analizi aracı, işletmelerin müşteri geri bildirimlerine dayalı olarak aksiyon alma konusunda reaksiyon süresini önemli ölçüde kısaltır.

Çalışma kapsamında, Türkçe ürün yorumlarında karşılaşılan, alınan hizmeti değerlendirirken en sık kullanılan sıfat ve zarflar belirlenecektir. Ardından bu kelime listesinde, her bir kelime için en az 3 farklı kişi tarafından, kelimenin duygu durumunu belirten -4 ile +4 arası bir duygu skoru belirlenecektir. Oluşturulan puanlı sözlük ile gerçek yorumlar üzerinde testler gerçekleştirilecek ve başarı performansı tespit edilecektir.

Anahtar Kelimeler: doğal dil işleme, sözlük tabanlı, duygu analizi, yorum sınıflandırma

ABSTRACT

Turkish Lexicon-Based Sentiment Analysis Tool

Semih Durmaz

Department of Computer Engineering
Master of Science Thesis

Supervisor: Prof. Dr. Banu DIRI

In recent years, the acceleration of digitalization, reaching its peak with COVID-19, has radically changed all our habits. As technology continuously changes and evolves, our habits are also transforming. Instead of searching for clothes by going from store to store, we now shop online; instead of going to a restaurant to choose food, we order through applications and have our meals delivered to our door. Feedback that we used to give face-to-face is now expressed in a few sentences through online reviews. These reviews provide important information for future customers and can influence their purchasing decisions. At the same time, they offer valuable feedback to business owners on areas that need improvement. The rapid rise of digitalization is affecting every aspect of our daily lives, reshaping our habits.

Evaluating reviews is extremely important for businesses. Customer feedback provides critical information for businesses to improve their products and services. Positive reviews highlight the strengths of the business as an indicator of customer satisfaction, while negative reviews indicate areas that need improvement. In this context, the sentiment analysis tool to be developed in the study is of great importance. With this tool, it will be possible to determine which customer reviews are positive and which are negative. Thus, businesses can quickly analyze thousands of reviews, promptly address existing dissatisfaction, and make necessary improvements to increase customer loyalty. The sentiment analysis tool significantly shortens the reaction time for businesses to take action based on customer feedback.

Within the scope of the study, the most frequently used adjectives and adverbs encountered in Turkish customer reviews, especially when evaluating the received service, will be determined. Subsequently, for each word in this list, a score between -4 and +4 will be assigned by at least 3 different people, indicating the sentiment score of the word. Using this dictionary, tests will be conducted on real reviews and the success rate will be determined.

Keywords: natural language processing, dictionary-based, sentiment analysis, text classification

1
GİRİŞ

1.1 Literatür Araştırması

Bu çalışmada kullanılacak olan sözlük tabanı yöntemine geçiş yapmadan önce genel olarak duygu analizine bakacak olursak, duygu analizi kısaca bir metnin olumlu, olumsuz ve nötr olup olmadığının belirlenmesidir.

Genellikle aşağıdaki adımlar sırasıyla izlenir:

- Metin parçası kelimelere ayrılır,
- Durak kelimeleri denilen cümleye anlam katmayan kelimeler cümleden çıkartılır,
- Cümleye pozitif ya da negatif anlam katabilecek kelimeler belirlenir,
- Stemming işlemiyle bu kelimelerin köküne inilir,
- Kelimenin olumlu veya olumsuz olduğu bilgisi belirlenen yöntem ile tespit edilir.

Son adım cümledeki her kelime için yapıldıktan sonra cümlenin genel pozitiflik-negatiflik durumu belirlenir ve cümleye olumlu ya da olumsuz sınıf etiketi atanır.

Bu işlemler genellikle bir ürün ile alakalı memnuniyet ölçümlerinde kullanılır. Günümüzde aşina olduğumuz pek çok online alışveriş platformunun müşterilerinin yorumlarını analiz etmek için kullanılır.

Duygu analizinde başlıca 2 yöntem kullanılır, bunlardan birincisi makine öğrenmesi diğeri ise sözlük tabanlı yöntemdir .

1.2 Makine Öğrenmesi Yöntemi

Makine öğrenmesi yönteminde gözetimli ve gözetimsiz olacak şekilde 2 yaklaşım vardır. Bu yaklaşımlarlar sırasıyla incelenecektir.

1.2.1 Gözetimli Öğrenme

Gözetimli öğrenme yaklaşımında cümleler ve bu cümlelere ait duygu puanları kullanılmaktadır [1]. Çoğu sitede gördüğümüz üzere, ürün yorumları genellikle 1-5 arasında bir puan ile değerlendirilir. Bu puan-cümle çiftleri eğitim verisi olarak kullanılır. Daha sonra Naive Bayes, Lineer Regresyon, Destek Vektör Makineleri veya başka bir gözetimli öğrenme modeli kullanılarak eğitim gerçekleştirilir.

Model, yüksek puanlı cümlelerde bulunan ve düşük puanlı cümlelerde nadiren görülen kelimelerin olumlu kelimeler olduğunu öğrenir. Aynı şekilde, düşük puanlı cümlelerde sıkça rastlanan ve yüksek puanlı cümlelerde bulunmayan kelimeler olumsuz kelimeler olarak tanımlanır.

Eğitim aşamasının tamamlanmasının ardından, modelin başarısı test aşamasında kontrol edilir ve yüzdelik başarı oranı belirlenir. Gözetimli öğrenme, modelin belirli etiketlenmiş veri kullanarak eğitilmesini ve ardından yeni, etiketlenmemiş veriler üzerinde doğru tahminler yapabilmesini sağlar.

Bu süreçte, eğitim verisinin kalitesi ve çeşitliliği, modelin başarısında önemli bir rol oynar. Gözetimli öğrenme, geniş bir uygulama yelpazesine sahip olup, metin sınıflandırma, duygu analizi, görüntü tanıma ve daha birçok alanda kullanılabilir. Örneğin, metin sınıflandırmada, model çeşitli kategorilere ayrılmış metinleri öğrenir ve ardından yeni metinleri doğru kategorilere atamayı öğrenir.

Gözetimli öğrenme modellerinin etkinliği, kullanılan algoritmaya, verinin miktarına ve kalitesine bağlı olarak değişebilir. Bu nedenle, modelin eğitimi sırasında uygun veri ön işleme tekniklerinin kullanılması ve algoritmanın doğru bir şekilde ayarlanması önemlidir. Bu yaklaşımlar, modelin genelleme yeteneğini artırarak gerçek dünya verileri üzerinde daha iyi performans göstermesini sağlar.

1.2.1.1 Veri Etiketleme Süreci

Gözetimli öğrenmenin temelini etiketli veri oluşturur. Etiketleme süreci, modelin başarısı için kritik bir rol oynar. Bu süreç, aşağıdaki adımlardan oluşur:

- **Veri Toplama:** İlk adım, etiketlenecek yeterli ve ilgili verinin toplanmasıdır. Bu

veri, kullanıcı yorumları ve sosyal medya gönderileri gibi çeşitli kaynaklardan gelebilir.

- **Etiketleme Kriterlerinin Belirlenmesi:** Etiketleme sürecinde kullanılacak kategorilerin ve kriterlerin belirlenmesi gerekir. Örneğin, duygu analizi için veriler pozitif, negatif ve nötr olarak sınıflandırılabilir.

- **Etiketleme Araçları:** Etiketleme işlemi manuel olarak yapılabilir ancak büyük veri setleri için etiketleme araçları ve yazılımları kullanmak daha verimli olabilir. Bu araçlar, etiketleme sürecini hızlandırır ve hata oranını düşürür. Örneğin, Labelbox [2] ve Prodigy [3] gibi etiketleme araçları, kullanıcı dostu arayüzleri ve otomasyon özellikleri ile etiketleme sürecini önemli ölçüde kolaylaştırır.

- **Etiketleyicilerin Eğitimi:** Etiketleme işlemini gerçekleştirecek kişilerin, belirlenen kriterlere göre doğru şekilde etiketleme yapabilmesi için eğitilmesi gerekir. Kelimelerin duygu skorlarının etiketlenmesinde tutarlılık ve bağlamı doğru anlama gibi unsurlar son derece önemlidir. Bu unsurlar, etiketlemenin doğruluğunu sağlamakla birlikte modelin başarısını da doğrudan etkiler.

- **Kontrol Aşaması:** Etiketleme sürecinin doğruluğunu sağlamak için kalite kontrol adımları uygulanmalıdır. Farklı kişiler tarafından etiketlenmiş, rastgele seçilen veri örneklerinin karşılaştırılması, etiketleme tutarlılığını artırır.

1.2.1.2 Model Eğitimi ve Değerlendirme

Gözetimli öğrenme algoritmaları, etiketli verilerden öğrenerek gelecekteki verileri tahmin eder veya sınıflandırır. Lojistik Regresyon, Karar Ağaçları, Rastgele Ormanlar, Destek Vektör Makineleri ve Naive Bayes yaygın olarak kullanılan algoritmalardır. Bu algoritmalar, farklı türdeki veriler ve problemler için çeşitli avantajlar ve dezavantajlar sunar. Problemin yapısına ve verinin özelliklerine bağlı olarak doğru algoritmayı seçmek gerekmektedir.

Doğru algoritmanın seçilmesinin ardından model eğitimi ve değerlendirme süreci gelmektedir. Bu süreç aşağıdaki adımları içerir:

- **Model Eğitimi:** İlk olarak veri seti, eğitim ve test seti olarak ikiye bölünür. Eğitim seti, modelin öğrenmesi için kullanılırken, test seti modelin performansını değerlendirmek için ayrılır. Genellikle, veri setinin %80'i eğitim için, %20'si ise test için kullanılır. Eğitim verileri kullanılarak model eğitilir. Bu aşamada, model parametreleri ve hiperparametreler optimize edilir. Model, eğitim verilerindeki özellikler ve etiketler arasındaki ilişkileri öğrenir.

- **Çapraz Doğrulama:** Modelin görmediği veriler üzerindeki performansını mümkün olduğunca objektif ve doğru bir şekilde değerlendirmek için çapraz doğrulama kullanılır. En yaygın yöntemlerden biri k-katlı çapraz doğrulamadır. Veri seti k adet alt kümeye bölünür ve model, her seferinde bir alt kümeyi test seti olarak kullanarak k-1 alt kümeyle eğitilir. Bu işlem k kez tekrarlanır ve sonuçlar ortalaması alınarak modelin performansı değerlendirilir.

- **Model Değerlendirme Metrikleri:** Model performansını ölçmek için çeşitli değerlendirme metrikleri kullanılır. Bunlar arasında doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru bulunur. Her bir metrik, modelin farklı yönlerini değerlendirmede kullanılır:

  - Doğruluk: Doğru tahmin edilen örneklerin toplam örnek sayısına oranıdır.
  - Kesinlik: Pozitif tahminlerin ne kadarının doğru olduğunu gösterir.
  - Geri Çağırma: Gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğini gösterir.
  - F1 Skoru: Kesinlik ve geri çağırma değerlerinin harmonik ortalamasıdır, dengesiz veri setlerinde kullanışlıdır.

- **Model Optimizasyonu:** Model performansını artırmak için hiperparametre optimizasyonu yapılır. Grid Search ve Random Search gibi yöntemler, en uygun hiperparametreleri belirlemek için kullanılır. Bu süreç, modelin genelleştirme yeteneğini ve doğruluğunu artırabilir.

1.2.2 Gözetimsiz Öğrenme

Gözetimsiz öğrenme ise, etiketlenmemiş veriler üzerinde gerçekleştirilir. Gözetimsiz öğrenme, verilerin etiketlenmesinin zor, masraflı veya zaman alıcı olduğu durumlarda kullanılır. Bu yöntemde puan bilgisi bulunmamakta, sadece cümleler bulunmaktadır. Örneğin sosyal medya platformu X'de atılan tivitleri örnek olarak ele alabiliriz. Bir hashtag içerisinde yazılmış on binlerce tivit mevcuttur ve bunlarla ilgili herhangi bir puan bilgisi yoktur. Bu yaklaşımda temel anlamda bir kümeleme yapılmaktadır [4]. Burada hakim olan ana fikir, olumsuz kelimelerin olumsuz kelimelerle birlikte kullanılıp, olumlu kelimelerin de olumlu kelimelerle birlikte kullanılmasıdır.

Örneğin gündemdeki bir konser ile alakalı "Konser çok sıkıcıydı, bunaldık" şeklinde atılan bir tivit analiz edildiğinde, "sıkıcı" ve "bunalmak" kelimeleri küme analizi sonucunda aynı kümede yer alır. Aynı şekilde olumlu kelimeler de bir arada kullanıldıkça aynı kümede yer alır. Böylece olumlu-olumsuz kelime kümeleri oluşur.

Gözetimsiz öğrenme yöntemlerinin en önemlileri arasında, verileri benzerliklerine göre gruplara ayıran kümeleme (K-means, DBSCAN, Hiyerarşik Kümeleme), yüksek boyutlu verileri daha düşük boyutlu temsilcilere dönüştüren boyut azaltma (PCA, t-SNE, UMAP) ve verideki olağandışı noktaları belirleyen bağlamsal anomali tespiti (Isolation Forest, LOF) yöntemleri bulunmaktadır. Bu literatür çalışması kapsamında yalnızca kümeleme yöntemlerinden detaylıca bahsedilecektir.

1.2.2.1 Kümeleme Yöntemleri

Kümeleme yöntemi, benzer veri noktalarını bir araya getirerek gruplar (kümeler) oluşturmayı hedefler [5]. Kümeleme yöntemleri, veri setinde doğal olarak oluşan alt grupları belirlemede kullanılır. Yaygın kümeleme algoritmaları şunlardır:

- **K-Means Kümeleme:** K-means kümeleme yöntemi, veri setini belirli sayıda kümeye ayırmayı amaçlayan bir tekniktir [6]. Her küme, veri noktalarının benzerliklerine göre gruplanmasını sağlar. İşleyişi şu şekildedir:
  - İlk adımda, veri setinde yer alan noktalar arasından k adet merkez rastgele seçilir. Bu k, kaç küme oluşturulacağını belirtir. Algoritmanın başarısı, k değerinin doğru seçilmesine bağlıdır. Yanlış bir k değeri, hatalı kümelere yol açabilir.
  - Her veri noktası, kendisine en yakın merkezi bulur ve o merkeze ait kümeye atanır.
  - Her kümenin yeni merkezi, o kümenin içerisindeki tüm veri noktalarının ortalaması alınarak yeniden hesaplanır. Bu, kümelerin daha iyi temsil edilmesini sağlar.
  - Atama ve merkez güncelleme adımları, merkezler sabitlenene veya merkezlerin değişimi çok küçük bir değere ulaşana kadar tekrarlanır.

  K-means, büyük veri setleriyle hızlı çalışabilen bir algoritmadır. Temel prensipleri ve adımları oldukça basittir, bu yüzden uygulanması kolaydır.

- **Hiyerarşik Kümeleme:** Hiyerarşik kümeleme, veri noktalarını (örneğin, belgeler, cümleler veya kelimeler) bir ağaç yapısında organize ederek benzerliklerine göre gruplayan bir yöntemdir [7]. Hiyerarşik kümeleme, doğal dil işleme alanında doküman kümeleme, metin sınıflandırma, anlam haritaları oluşturma, kelime gömme analizi, metin özetleme ve bilgi keşfi gibi çeşitli uygulamalarda veri noktalarını benzerliklerine göre organize ederek daha iyi veri analizi, bilgi keşfi ve anlam çıkarımı sağlar [8].

- **DBSCAN:** DBSCAN, yoğunluk tabanlı bir kümeleme algoritmasıdır ve veri noktalarını yoğunluklarına göre gruplar [9]. DBSCAN, küme merkezlerinden belirli bir yarıçap içerisindeki yeterli sayıda veri noktası olan bölgeleri küme olarak tanımlar ve bu bölgelerdeki veri noktalarını birbirine bağlayarak kümeler oluşturur. Ayrıca, yoğun bölgelerin dışında kalan ve herhangi bir kümeye dahil edilemeyen noktaları gürültü (outlier) olarak kabul eder. Bu algoritma, kümelerin şekil ve boyutlarından bağımsız olarak, gürültüye karşı dayanıklıdır ve küme sayısını önceden belirtme gereksinimi yoktur.

  DBSCAN, doğal dil işleme alanında; büyük metin koleksiyonlarında benzer belgelerin gruplandırılması, kelime veya cümle gömme vektörleriyle anlam ilişkilerinin keşfedilmesi ve sosyal medya analizlerinde yoğun tartışma gruplarının belirlenmesi gibi çeşitli kullanım alanlarına sahiptir [10]. Gürültüye karşı dayanıklılığı sayesinde, düzensiz ve karmaşık metin verilerinde etkili bir şekilde uygulanabilir.

1.3 Sözlük Tabanlı Yöntem

Sözlük tabanlı yöntemler, metin analizi için belirli kelime ve ifadelerin önceden tanımlandığı listelere dayanır. Bir grup insan, sözlükte yer alan kelimeleri puanlandırarak her bir kelimeye olumlu ya da olumsuz olduğunu belirten bir puan ataması yapar. Bu şekilde her kelimenin bir puana sahip olduğu bir sözlük oluşturulur. Örneğin, "mutlu" kelimesi +3 puan alırken, "üzgün" kelimesi -3 puan alabilir. Bu puanlar, kelimelerin genel duygusal tonunu yansıtır ve metin analizinde kullanılır.

Bu yöntemde eğitim aşaması yoktur, oluşturulan sözlük kullanıma hazır bir şekildedir. Eğitim süreci yerine, kelimelerin önceden belirlenmiş puanları kullanılır. Test aşamasında, gelen cümledeki her kelimenin puanı sözlükten bulunup, cümleye ait genel puan belirlenir. Eğer cümlenin puanı, beklenen duygu ile uyumluysa test aşaması başarılı sayılır. Örneğin, "Bugün hava çok güzel ve mutluyum." cümlesi, "güzel" ve "mutlu" kelimelerinden pozitif puanlar alarak genel olarak pozitif bir duyguya sahip olarak değerlendirilir.

Sözlüklerin oluşturulmasında dikkat edilmesi gereken bazı önemli unsurlar şunlardır:

- **Kelime Listeleri:** Sözlükler genellikle pozitif ve negatif kelimeleri içeren listelerden oluşur. Pozitif ve negatif her kelimenin duygusal değeri belirtilir. Bu kelimelerin dışında kalan kelimeler nötr kelime olarak kabul edilir. Nötr kelimeler cümlenin genel duygu durumuna katkı sağlamaz.

- **Kelime Puanları :** Kelimeler, duygusal yoğunluklarına göre puanlandırılır. Bu puanlar, cümledeki duygu durumunu belirlemede kullanılır.
- **Sözlük Kaynakları:** Sözlükler, bu alanda uzman kişiler tarafından manuel olarak oluşturulabilir veya otomatik yöntemlerle web verilerinden elde edilebilir.
- **Özelleştirilmiş Sözlükler:** Belirli bir alan veya sektör için özel olarak hazırlanmış sözlükler kullanılabilir. Örneğin, otel müşterisi yorumlarını analiz etmek için, otel ile ilgili terim ve ifadeleri içeren bir sözlük kullanılabilir. Bu tür özelleştirilmiş sözlükler, analizin doğruluğunu ve etkinliğini artırarak, belirli bir bağlamda daha anlamlı sonuçlar elde edilmesine olanak tanır.

2
MEVCUT ÇALIŞMALAR

Duygu analizi yapılmasına olanak sağlayan mevcut araçlara baktığımızda, 2011 yılında geliştirilen AFINN [11], 2013 yılında tanıtılan TextBlob [12] kütüphanesinin duygu analizi özelliği ve 2014 yılında tanıtılan VADER [13] bulunmaktadır.

Türkçe için doğrudan etiketlenmiş bir sözlük yoluyla yapılan duygu analizi araçları bulunmamaktadır. Mevcut olan duygu analizi araçları üzerinde kelimelerin birebir çeviri yoluyla uyarlanarak Türkçe'ye adapte edilmesi şeklinde yapılmış çalışmalar vardır ancak bu uyarlamalar, bizzat elle etiketlenen bir Türkçe sözlük aracı kadar başarılı değildir. Dilin kendine özgü yapısı ve duygusal ifadelerinin doğru şekilde tanımlanması, doğrudan Türkçe için hazırlanmış bir duygu sözlüğünün önemini vurgulamaktadır. Bu durum, bu çalışma kapsamında yapılacak Türkçe analiz aracının önemini ve gerekliliğini ortaya koymaktadır.

2.1 TextBlob

TextBlob metin verileri üzerinde pek çok farklı işlemler yapmamıza olanak sağlayan bir Python kütüphanesidir [14]. Duygu analizinin yanısıra kelime türü etiketleme (POS tagging), cümledeki isimleri çıkarma, cümleyi token'larına ayırma (tokenization), kök çözümleme (lemmatization) ve yazım yanlışlarını düzeltme (spell checking) gibi birçok işlemin yapılmasına da olanak sağlar.

```
from textblob import TextBlob

text = "I had such a wonderful day today"
blob = TextBlob(text)
sentiment = blob.sentiment
```

Şekil 2.1 TextBlob Cümle Puanlama

Duygu analizini basitçe yerine getirebilmemizi sağlayan TextBlob kütüphanesi,

metinlerin duygu durumu (polarite) ve öznelik (subjectivity) değerlerini hesaplamak için kullanılabilir.

Polarite: -1 ile 1 arasında bir değerdir. -1 tamamen negatif, 1 tamamen pozitif, 0 ise nötr anlamına gelir.

Öznelik: 0 ile 1 arasında bir değerdir. 0 tamamen nesnel, 1 ise tamamen öznel anlamına gelir.

Şekil 2.1'de görüldüğü üzere basit bir kullanıma sahiptir. Şekil 2.2'de alınan sonuca göre "I had such a wonderful today" cümlesi polarite kapsamında 0,5 alarak cümlenin gayet olumlu olduğunu bildirirken, Öznellik kapsamında ise 0,75 cümlenin öznel bir cümle olduğunu bildirmektedir.

```
print(sentiment("I had such a wonderful day today ")
```

```
Polarity:  0.5   Subjectivity:  0.75
```

Şekil 2.2 TextBlob Cümle Puanlama Örneği

TextBlob her ne kadar sözlük tabanlı olsa da, VADER'in aksine, bu sözlükte yer alan kelime listesine doğrudan erişim pek mümkün değildir. Dolayısıyla, literatür araştırması kapsamında daha fazla detaya girilemeyecektir.

2.2 AFINN

2011 yılında Finn Årup Nielsen tarafından geliştirilen AFINN, duygu analizi için kullanılan ve "Affective Norms for English Words" olarak bilinen bir kelime listesidir [11]. AFINN, İngilizce kelimelere pozitif ve negatif duygu puanların atandığı bir sözlükten oluşmaktadır. Bu sözlük, yaklaşık 2.500 kelime veya kelime öbeği içerir ve her biri -5 (en negatif) ile +5 (en pozitif) arasında bir duygu puanı ile etiketlenmiştir. Örneğin, "happy" kelimesi +3 puan alırken, "sad" kelimesi -2 puan alır. AFINN, özellikle sosyal medya, anketler, müşteri yorumları ve blog yazıları gibi metinlerde duygu analizleri yapmak için kullanılır ve basit, hızlı bir analiz imkanı sunar.

AFINN'in çalışma prensibi, metindeki her kelimenin duygu puanlarının toplamını alarak metnin genel duygu skorunu belirlemektir. Pozitif puanlar, metnin olumlu bir duygu taşıdığını, negatif puanlar ise olumsuz bir duygu taşıdığını gösterir. Şekil 2.3'te görüldüğü üzere "I had such a wonderful today" cümlesi 4 puan almıştır.

AFINN'in sonucu teorik olarak metindeki kelime sayısına bağlı olarak çok geniş bir aralıkta olabilir. Her bir kelimenin -5 ile +5 arasında puan alabileceğini göz önünde bulundurursak, 10 kelimelik bir cümlede toplam duygu skoru -50 ile +50 arasında olabilir. Şekil 2.3'teki örnekteki cümlenin 4 puana sahip olmasını sağlayan "wonderful" kelimesi eğer 3 defa tekrarlansaydı cümle duygu puanı 12 olacaktı.

```
from afinn import Afinn
afinn = Afinn()
afinn.score('I had such a wonderful  day today')
```

```
4.0
```

Şekil 2.3 AFINN Cümle Puanlama Örneği

AFINN, en başta sadece İngilizce için geliştirilmiş olup, Türkçe desteği bulunmamaktadır. Çeşitli çeviri yöntemleriyle Türkçe'ye uyarlanmış versiyonları mevcut olsa da, bu çeviriler genellikle iyi sonuçlar vermemektedir.

2.3 VADER

VADER (Valence Aware Dictionary for sEntiment Reasoning) bir sözlük tabanlı duygu analizi aracıdır [15]. Anlamsal yönelimlerine göre olumlu ya da olumsuz olarak etiketlenen kelimelerin listesini kullanır. Sadece olumlu – olumsuz durumunu değil, aynı zamanda kelimenin ne kadar olumlu veya olumsuz olduğunu da söyler. Eğitim verisine ihtiyaç duymaz, kullanıma hazır haldedir.

2.3.1 VADER Sözlüğünün Oluşturulması

VADER sözlüğünün oluşturulması için öncelikle sosyal medyada, Wikipedia'da ve internet sitelerinde en sık kullanılan yaklaşık 9000 kelime belirlenmiştir. Ardından bu kelimelerin her biri 10 farklı kişi tarafından değerlendirmeye tabi tutularak -4 ile +4 arasında bir puan ataması yapılması sağlanmıştır. Bu sayede 9000 kelimenin her biri 10 farklı kişi tarafından verilen bir puanlama dizisine sahip olmuştur.

Bu puanlamaların değerlendirilmesi aşamasında ise iki koşul kontrol edilmiştir. Öncelikle verilen puanların ortalamasının 0'dan farklı olması gerekmektedir. Eğer puanların ortalaması 0 ise, bu kelimenin nötr olduğunu gösterir ve bu kelimeyi sözlüğe eklemeye gerek yoktur. Şartlardan diğeri ise, verilen puanların standart sapmasının

2,5 değerinden küçük olmasıdır. Örneğin bir kelimeye değerlendiricilerin bazıları çok olumlu anlamında +4, diğerleri ise çok olumsuz anlamında -4 vermişse, bu kelimeyle ilgili bir anlaşmazlık mevcuttur, standart sapması yüksektir, bu sebeple sözlükte bu kelimeye yer verilmez.

2.3.2 VADER Sözlüğü

Yapılan değerlendirmelerin ardından, bazı kelimelerin çıkartılması ve emojilerin eklenmesiyle birlikte nihai sözlükte 7520 adet kelime yer almıştır. Şekil 2.4'te görüldüğü üzere her kelimeye ait 10 elemanlık bir puan dizisi, bu puanların standart sapması ve o kelimenin duygu durumunu veren ortalama bir değer bulunmaktadır.

Bu ortalama değer [-1,1] aralığındadır. 1 çok olumlu, -1 çok olumsuz, 0 ise nötr bir duyguyu ifade eder.

```
3331   good    1.9     0.9434  [2, 1, 1, 3, 2, 4, 2, 2, 1, 1]
3332   goodness        2.0     1.54919 [2, 2, 2, 3, 1, 2, -2, 4, 3, 3]
3333   gorgeous        3.0     0.63246 [3, 3, 2, 3, 3, 3, 4, 4, 3, 2]
3334   gorgeously      2.3     0.78102 [2, 2, 2, 3, 1, 2, 4, 3, 2, 2]
3335   gorgeousness    2.9     0.9434  [3, 4, 3, 1, 4, 4, 2, 2, 3, 3]
3336   gorgeousnesses  2.1     0.7     [3, 2, 1, 3, 2, 2, 1, 2, 3, 2]
3337   gossip  -0.7    0.45826 [-1, -1, -1, 0, 0, -1, -1, 0, -1, -1]
3338   gossiped        -1.1    0.53852 [-1, -1, -1, -1, -1, -1, 0, -1, -2, -2]
3339   gossiper        -1.1    0.7     [-1, -1, -1, 0, -2, -1, -1, -2, 0, -2]
3340   gossipers       -1.1    0.53852 [-1, 0, -1, -1, -1, -1, -1, -1, -2, -2]
3341   gossiping       -1.6    0.4899  [-1, -2, -1, -2, -1, -2, -2, -1, -2, -2]
```

Şekil 2.4 VADER Sözlüğü [15]

2.3.3 VADER Cümle Puanlama

VADER cümleye ait 4 puan verir. Şekil 2.5'te görüldüğü üzere, neg (negativity) cümlenin olumsuzluk oranın, neu (neutral) cümlenin nötr olma oranını, pos (positivity) cümlenin olumluluk puanını ve son olarak compound puanı da bu üç değerin normalleştirilmiş halini verir.

```
print(sentiment_scores("Today is a good day"))
```

```
{'neg': 0.0, 'neu': 0.508, 'pos': 0.492, 'compound': 0.4404}
```

Şekil 2.5 VADER Cümle Puanlama

Pos, neu ve neg puanları, her kategoriye düşen duygu oranlarıdır, bu nedenle toplamları 1 olmalıdır. Bir cümle için duygu analizi yapmak istiyorsak, her bir

duygunun ayrı ayrı tespit edilmesi oldukça önemlidir. Sadece olumlu cümleler içeren bir yorum ile, hem olumlu hem olumsuz cümleler içeren bir yorum müşteri memnuniyeti açısından oldukça farklı sonuçlar verir.

2.3.4 VADER Sonuçları

VADER sözlüğü oluşturulduktan sonra başarısı test edilmek istenmiş ve o dönem popüler olan diğer duygu analizi araçlarıyla kıyaslanmıştır. Sosyal medyadan alınan 4200 tivit üzerinden yapılan testlerde, Şekil 2.6'da görüldüğü üzere VADER diğer rakiplerine açık ara fark atarak, en başarılı duygu analizi aracı olmuştur.

	Correlation to ground truth (mean of 20 human raters)	3-class (positive, negative, neutral) Classification Accuracy Metrics		
		Overall Precision	Overall Recall	Overall F1 score
Social Media Text (4,200 Tweets)				
VADER	0.881	**0.99**	**0.94**	**0.96**
Hu-Liu04	0.756	0.94	0.66	0.77
SCN	0.568	0.81	0.75	0.75
GI	0.580	0.84	0.58	0.69
SWN	0.488	0.75	0.62	0.67
LIWC	0.622	0.94	0.48	0.63
ANEW	0.492	0.83	0.48	0.60
WSD	0.438	0.70	0.49	0.56

Şekil 2.6 VADER Sonuçları [16]

3
DUYGU SÖZLÜĞÜNÜN OLUŞTURULMASI

Bu çalışma kapsamında, Türkçe'de en sık kullanılan kelimeler listesi çıkartılmıştır. Bu kelimelerin belirlenmesinde edebi kitaplar, Wikipedia, Online alışveriş siteleri gibi platformlardan yararlanılmıştır.

Kelimelerin belirlenmesinin ardından veri ön işlem adımları gerçekleştirilerek kelime tekrarlarının önüne geçilmiştir.

Telegram botu yardımıyla sözlükte yer alan kelimelerin her biri en az 3 farklı kişi tarafından [-4,+4] aralığında bir puan ile etiketlenmiştir. Değerlendirme aşamasında standart sapma düşük tutulmuştur, bu sayede anlamı herkes tarafından aynı kabul edilen kelimeler sözlükte yer almıştır.

Türkçe'de yer alan "çok, az, biraz, hiç" gibi kendinden sonra gelen kelimenin etkisini arttıran ya da azaltan kelimeler belirlenmiş ve bu kelimelerin ardından gelen kelimeleri belirli bir oranda arttırma ya da azaltma uygulanmıştır. Böylece gerçek anlamın yakalanması sağlanmıştır.

Bir puana sahip müşteri yorumları yardımıyla modelin başarısı test edilmiştir. Başarının düşük gelmesi durumunda parametre değişiklikleriyle başarının arttırılması sağlanılacaktır.

3.1 Çalışmanın Hedefi ve Avantajları

Sözlük-tabanlı duygu analizi aracı proje fikrinin doğmasından ve ilk adımlarının atılmasından sonra, Chat-GPT gibi büyük dil modelleri (LLM'ler) hızla popülerlik kazandı [17]. Bu durum, sözlük-tabanlı yöntemlerin önemini bir ölçüde gölgede bıraktı ancak, yine de belirli avantajlar sunduğu düşünüldüğü için çalışmalara devam edilmiştir.

Sözlük-tabanlı yöntemlerin avantajlarına dair bazı önemli noktalar şu şekilde sıralanabilir:

- **Basitlik ve Hız:** Sözlük-tabanlı yöntemler daha basit algoritmalara dayalıdır ve hızlı bir şekilde uygulanabilirler [18]. Sözlük-tabanlı yöntemlerde, her bir kelimeye duygu değeri atayarak bir kelime listesinin oluşturulması nispeten hızlı bir şekilde geliştirilir. Güncellemeler veya iyileştirmeler, sadece sözlük listesine yeni kelimeler eklemek veya mevcut değerleri değiştirmek suretiyle hızlıca yapılabilir. Öte yandan, LLM'lerin geliştirilmesi, büyük miktarda metin verisinin toplanması, temizlenmesi ve işlenmesini gerektirir. Modelin eğitilmesi için yoğun hesaplama kaynakları ve zaman gerekir. Eğitim süreci, modellerin karmaşıklığına ve büyüklüğüne bağlı olarak günler veya haftalar alabilir.
- **Özelleştirilebilirlik:** Sözlük-tabanlı yöntemler, belirli bir domain veya sektör için kolayca özelleştirilebilir. Örneğin "dar" kelimesi nötr olduğundan dolayı sözlükte yer almıyor iken, otel sektöründe odanın darlığından ya da koridorların darlığından bahsedilirken negatif bir etkisi olduğu için otel sektörüne özel olarak olumsuz olarak etiketlenebilir.
- **Eğitim Aşaması ve Veri Miktarı:** Çok büyük veri kümeleri üzerinde eğitilmeyi gerektiren LLM'lerin aksine, sözlük-tabanlı yöntemler, eğitime ihtiyaç duymadan, çok kısıtlı veri kaynaklarıyla birlikte dahi gerçekleştirilebilir. Büyük veri kümesi bulunmayan ve dil modelleri mevcut olmayan bazı nadir diller için sözlük-tabanlı yöntemler hızlı bir şekilde uygulanabilir.

3.2 Sözlüğün Oluşturulması

Çalışmanın ilk adımı olan sözlüğün oluşturulması aşaması aşağıda belirtilen alt başlıklar altında değerlendirilecektir. Bunlar sırasıyla;

- Türkiye'de en çok okunan kitapların arasından kelime sayımı ile en sık kullanılan kelimelerin belirlenmesi,
- Wikipedia metinlerinde en sık kullanılan kelimelerin belirlenmesi,
- Bu iki listeye destekleyici olarak, daha önce yapılan çalışmalarda bulunan en sık kullanılan 1000 kelimenin çekilmesi,
- Önceki adımlarda belirlenen 3 farklı kelime listesinin birleştirilerek ortak kelime listesinin oluşturulması
- Zemberek ve Stanza [19] yardımıyla kelimelerin pos-tag bilgilerine erişilmesi ve sıfat görevi gören kelimeler haricindeki kelimelerin listeden çıkartılması

- Oluşturulan sıfat kelimeler listesinin, her biri en az üç kişi tarafından puanlanacak şekilde etiketlenmesi

şeklindedir.

3.2.1 Sık Kullanılan Kelimelerin Belirlenmesi

Çalışma kapsamında, Türkiye merkezli online kitap satış platformu olan `kitapyurdu.com`'da son 10 yıl içinde en çok satılan kitapların içeriği üzerinde kelime sayımı yapılması planlanmıştır.

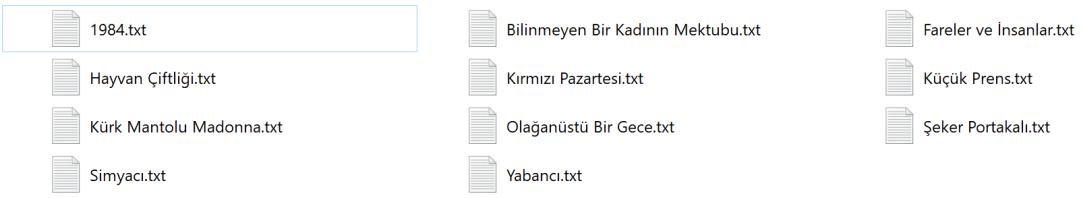
Bu yöntemin uygulanmasında,

- **Veri Kaynağının Güvenilirliği:** Kitaplar genellikle yayınevleri tarafından dikkatlice denetlenen bir süreçten geçerler. Yazarlar, editörler ve yayınevi ekibi tarafından metin üzerinde detaylı incelemeler yapılır bu nedenle dil bilgisi hataları, yazım yanlışları düzeltilir. Bu sayede kitapların içeriği, genellikle daha güvenilir olur [20].
- **Kelime ve Sözcük Çeşitliliği:** Kitaplar genellikle zengin bir kelime dağarcığına sahiptir. Yazarlar, ifade edilmek istenen duygu ve düşünceyi betimlemek için geniş bir sözcük yelpazesi kullanırlar. Bu geniş sözlük yelpazesi, çalışma kapsamında önemli katkı sağlayacaktır.
- **Okuyucu Kitlesi Üzerindeki Etkisi:** En çok satan kitaplar genellikle geniş bir okuyucu kitlesi tarafından tercih edilir, bu da okuyucuların, bu kelimeleri günlük konuşmalarında, sosyal medya paylaşımlarında ya da yorumlarında da kullanabileceği anlamına gelir. Özellikle popüler eserler belirli kelimelerin yaygınlaşmasına yol açabilir.

gibi hususlar etkili olmuştur.

Bu doğrultuda belirlenen kitapların içerikleri txt formatında elde edilerek kelime sayımı işlemine hazır hale getirildi.

Toplamda 250 bin kelimeden oluşan bu 10 kitabın içerikleri üzerinde kelime sayımı işlemi yapıldı ve Şekil 3.2'teki sonuçlar elde edilmiştir. Beklenildiği üzere bir, ve, bu, de, için, ama gibi bağlaç kelimeler en fazla kullanılan kelimeler olarak tespit edilmiştir. Listeyi bu kelimelerden kurtarmak için dilbilgisel etiketleme (POS-tagging) araçlarından birinin kullanılması gerekmektedir.



Şekil 3.1 En çok satılan kitaplar

```
Counter({'bir': 9772, 've': 4585, 'bu': 2989, 'de': 1826, 'için': 1738, 'ama': 1665, 'da': 1627, 'o': 1571, 'daha': 1419, 'gi
bi': 1312, 'ne': 1199, 'her': 1195, 'kadar': 1193, 'sonra': 1174, 'çok': 1115, 'şey': 1010, 'dedi': 874, 'zaman': 852,
'bana': 846, 'diye': 823, 'olan': 718, 'bile': 696, 'olduğunu': 682, 'onu': 679, 'ben': 675, 'beni': 666, 'bütün': 645,
'ki': 634, 'hiç': 620, 'en': 614, 'hiçbir': 607, 'küçük': 580, 'vardı': 566, 'onun': 547, 'fakat': 540, 'büyük': 507, 'iki':
505, 'ona': 502, 'başka': 487, 'içinde': 478, 'çünkü': 463, 'benim': 453, 'şimdi': 444, 'winston': 442, 'değil': 439, 'bunu':
428, 'artık': 425, 'var': 419, 'gün': 419, 'olarak': 414, 'olduğu': 406, 'ya': 405, 'doğru': 398, 'iyi': 375, 'aynı': 370, 'b
öyle': 370, 'kendi': 363, 'biraz': 359, 'birkaç': 353, 'önce': 352, 'mi': 333, 'sen': 327, 'belki': 324, 'nasıl': 323, 'san
a': 323, 'pek': 307, 'bunun': 301, 'yoktu': 296, 'karşı': 288, 'uzun': 282, 'delikanlı': 282, 'kez': 279, 'yok': 276, 'son':
274, 'şeyi': 271, 'ile': 268, 'adam': 268, 'on': 266, 'yalnızca': 265, 'hemen': 264, 'insan': 257, 'evet': 257, 'senin': 255,
'üç': 254, 'ilk': 253, 'yeniden': 248, 'neden': 242, 'hep': 236, 'kadın': 230, 'seni': 229, 'tam': 220, 'başladı': 219, 'ger
```

Şekil 3.2 Kelime Sayımı Sonuçları

Çalışma kapsamında Zemberek kütüphanesinin TurkishMorphology bileşeni kullanılarak dilbilgisel etiketleme yapılmıştır [21]. Şekil 3.3'te elde edilen sonuçlarda sıfat ve zarf kelimeler filtrelenmiştir. Bu kelimeler, bir hizmeti ya da ürünü değerlendirirken kullanılabilecek kelimeler olarak belirlenmiştir. Bu kelime listesi, daha sonra diğer kelime listeleriyle karma yapılarak ortak liste oluşturulacak ve etiketleme aşamasında kullanılacaktır.

```
2024-06-24 20:51:16,441 - zemberek.morphology.turkish_morphology - INFO
Msg: TurkishMorphology instance initialized in 6.39113712310791


ama - Adjective, daha - Adverb, ne - Adjective, her - Adjective, sonra - Adverb, çok - Adverb, bütün - Adjective, hiç - Adver
b, en - Adverb, küçük - Adjective, büyük - Adjective, içinde - Adverb, şimdi - Adverb, artık - Adverb, var - Adjective, doğru
- Adjective, iyi - Adverb, aynı - Adjective, böyle - Adjective, biraz - Adverb, önce - Adverb, belki - Adverb, nasıl - Adject
ive, pek - Adjective, yoktu - Adjective, uzun - Adverb, delikanlı - Adjective, yok - Adjective, yalnızca - Adverb, hemen - Ad
verb, insan - Adjective, evet - Adverb, ilk - Adjective, yeniden - Adverb, neden - Adverb, hep - Adverb, kadın - Adjective, t
am - Adverb, geri - Adverb, yeni - Adverb, ancak - Adverb, yine - Adverb, üzerinde - Adverb, güzel - Adjective, sanki - Adver
b, hayır - Adjective, öyle - Adverb, üzerine - Adverb, tekrar - Adverb, sonunda - Adverb, fazla - Adverb, sadece - Adverb, ha
tta - Adverb, tüm - Adjective, hâlâ - Adverb, eski - Adjective, gece - Adverb, ağır - Adverb, beyaz - Adjective, az - Adverb,
demek - Adverb, beri - Adjective, gerçekten - Adverb, gelen - Adjective, genç - Adjective, asla - Adverb, gerçek - Adjective,
```

Şekil 3.3 Filtrelenmiş Kelime Sayımı Sonuçları

Sözlüğün oluşturulması aşamasının ikinci adımında Wikipedia metinlerinde en sık kullanılan kelimeler belirlenmiştir. Veri kaynağı olarak Wikipedia metinlerinin kullanılmasında;

- **Geniş Kapsam ve Zengin İçerik:** Wikipedia, geniş bir konu yelpazesine sahiptir ve bu nedenle çeşitli alanlarda sık kullanılan sıfatlara erişim sağlar. Bu da sözlüğün kapsamının genişlemesine yardımcı olur.
- **Kolay Erişim:** Wikipedia gibi online ve genel erişime açık kaynaklar, herkesin erişine açıktır ve ulaşımı kolaydır.
- **Güncellik:** Wikipedia, düzenli olarak güncellenir ve yeni bilgiler eklenir. Bu sayede sözlükteki sıfatlar güncel kalabilir.

gibi sebepler etkili olmuştur. Toplamda 4 milyon kelime içeren Wikipedia verisinde kelime sayımı işlemi yapılmış ve Şekil 3.4'teki sonuçlar elde edilmiştir. Yine beklendiği üzere bağlaç kelimeler en fazla kullanılan kelimeler olarak tespit edilmiştir. Aynı işlemler bu sonuçlar üzerinde de yapılarak sadece sıfat olan kelimeler çıkartılarak nihai liste oluşturulmuştur.

Oluşturulan bu nihai liste belirlendikten sonra her biri en az üç farklı kişi tarafından etiketlenmek üzere etiketleme aşamasına geçilmiştir.

```
Counter({'ve': 129320, 'i': 62138, 'bir': 59318, 'bu': 32099, 'olarak': 25116, 'ile': 23247, 'de': 21908, 'da': 20284, 'ö': 1
6797, 'için': 15910, 'olan': 15836, 'en': 13638, 'amerikalı': 13288, 'türk': 13161, 'daha': 10437, 'tarafından': 10323, 'sonr
a': 10021, 'büyük': 9773, 'ilk': 9371, 'yılında': 9296, 'gibi': 8976, 'ise': 8494, 'çok': 8404, 'kadar': 6724, 'oyuncu': 672
2, 'arasında': 6636, 'göre': 6505, 'yer': 6090, 'futbolcu': 5965, 'veya': 5882, 'ngiliz': 5742, 'eski': 5674, 'iki': 5495, 'y
azar': 5495, 'olduğu': 5306, 'fransız': 5266, 'diğer': 5155, 'ancak': 5126, 'her': 5005, 'osmanlı': 4924, 'yeni': 4883, 'alma
n': 4776, 'önemli': 4678, 'oldu': 4458, 'ayrıca': 4400, 'aynı': 4261, 'dünya': 4227, 'ya': 4145, 'siyasetçi': 4094, 'devlet':
3990, 'genel': 3854, 'birlikte': 3852, 'yıl': 3824, 'te': 3785, 'son': 3775, 'kabul': 3649, 'birçok': 3502, 'alan': 3440, 'th
e': 3426, 'etti': 3425, 'bazı': 3352, 'üzerine': 3309, 'karşı': 3297, 'şarkıcı': 3286, 'yüksek': 3271, 'içinde': 3234, 'vardı
r': 3207, 'birleşik': 3154, 'yapılan': 3151, 'bulunan': 3100, 'talyan': 3083, 'film': 3070, 'gelen': 2997, 'tüm': 2965, 'üzer
e': 2905, 'kişi': 2903, 'o': 2875, 'başladı': 2873, 'adı': 2822, 'yazarı': 2821, 'sahip': 2811, 'millî': 2806, 'oyuncusu': 28
```

Şekil 3.4 Wikipedia Kelime Sayımı Sonuçları

3.3 Güçlendirici Kelimelerin Belirlenmesi

Güçlendirici (booster) kelimeler, metindeki diğer kelimelerin duygu değerlerini güçlendiren (yükselten veya azaltan) kelimelerdir. Duygu analizi aşamasında önemli rol oynarlar.

Güçlendirici kelimeler; duygu yoğunluğunu belirlemede, metindeki duyguları daha iyi yakalamada ve bağlamın daha iyi anlaşılmasında etkin bir rol alır.

Yapılan çalışmalar neticesinde Türkçe'de sık kullanılan güçlendiriciler belirlenmiştir. Şekil 3.5'te sunulan bu etki arttırıcı kelimeler, sıfatların önüne geldiğinde duygu puanını önemli ölçüde yükselterek cümle genelinde daha güçlü bir etki yaratmaktadır.

```
positive_boosters = [
    'gayet', 'epey', 'pek', 'çok', 'oldukça', 'gerçekten', 'fazla', 'ziyadesiyle',
    'aşırı', 'fazlasıyla', 'haddinden fazla', 'inanılmaz derecede', 'süper', 'muazzam',
    'şahane', 'müthiş', 'inanılmaz', 'son derece', 'fevkalade', 'korkunç', 'felaket',
    'dehşet', 'harika', 'mükemmel', 'olağanüstü']
```

Şekil 3.5 Etkiyi Arttıran Kelimeler

Bu kelimeler, metinlerdeki duygusal tonun vurgulanmasını sağlayarak, ifade edilen duygunun daha yoğun ve belirgin olmasına katkıda bulunur. Örneğin, "güzel" kelimesi tek başına olumlu bir anlam taşırken, önüne "çok" veya "inanılmaz" gibi güçlendirici kelimeler eklendiğinde bu olumlu etki katlanarak artar ve cümle, okuyucuda veya dinleyicide daha güçlü bir izlenim bırakır.

Gerçekleştirilen testlerin bir kısmı Şekil 3.6'da detaylı olarak gösterilmiştir. Bu testler, güçlendirici kelimelerin duygu analizi puanlarında nasıl önemli artışlara yol açtığını net bir şekilde ortaya koymaktadır.

```
print(duygu_analizi("Kebabın yanında gelen salata gayet güzeldi."))
```

```
Duygu Analizi Puanı:  8.26
```

```
print(duygu_analizi("Kebabın yanında gelen salata aşırı güzeldi."))
```

```
Duygu Analizi Puanı:  8.37
```

```
print(duygu_analizi("Kebabın yanında gelen salata inanılmaz güzeldi."))
```

```
Duygu Analizi Puanı:  8.52
```

Şekil 3.6 Güçlendirici Kelimenin Duygu Puanına Etkisi

Güçlendirici kelimelerin olduğu gibi, etkiyi azaltıcı kelimelerin de dilde önemli bir yeri vardır. Güçlendirici kelimeler nasıl sıfatların etkisini artırıyorsa, etkiyi azaltıcı kelimeler de sıfatların etkisini yumuşatır ve daha etkisiz hale getirir. Bu tür kelimeler, metinlerde kullanılan ifadeyi yumuşatır ve duygu puanı anlamında etkisini azaltır.

Yapılan incelemeler neticesinde belirlenen, Türkçe'de sık kullanılan az sayıda azaltıcı kelimeler Şekil 3.7'de yer almaktadır. Bu kelimeler, sıfatların etkisini azaltarak cümlelerin genel duygusal tonunu dengeler ve ifadelerin daha ölçülü olmasını sağlar.

```
negative_boosters = [
    'az', 'biraz', 'nispeten', 'bir miktar', 'orta derecede']
```

Şekil 3.7 Etkiyi Azaltan Kelimeler

Her ne kadar iki farklı liste gibi görünse de, etki arttırıcı ve azaltıcı kelimeler aynı grupta yer almıştır. Bu kelimelere atanan 0 ile 2 arasındaki puanlar, kelimelerin etkilerini belirlemek için kullanılacaktır. Etki azaltıcı kelimeler 0 ile 1 arasında puan alırken, etki arttırıcı kelimeler 1 ile 2 arasında puan alacaktır. Bu puanlama sistemi, her bir kelimenin cümlede yarattığı duygusal tonu ve etkisini daha net bir şekilde ortaya koymaktadır. Her bir kelimeye ait ayrıntılı puanlar, Deneysel Sonuçlar bölümünde gösterilecektir.

3.4 Olumsuzluk Kelimelerinin Belirlenmesi

Olumsuzluk kelimeleri, bir cümlenin anlamını olumsuz yönde etkileyen kelimelerdir. Bu kelimeler, bir ifadenin anlamını tersine çevirerek veya olumsuz yönde değiştirerek

kullanılır.

Özellikle duygu analizi yaparken, bu kelimelerin varlığı veya yokluğu, cümlenin genel duygusunu doğru bir şekilde tespit etmek için dikkate alınmalıdır.

Yapılan incelemeler neticesinde Türkçe'de sık kullanılan az sayıda olumsuzluk kelimeleri Şekil 3.8'te yer almaktadır. Bu kelimeler, önüne geldiği sıfatı ya da içinde bulunduğu cümleyi tamamen değiştirerek olumsuzluk veya zıtlık yaratır.

```
negative_words = [
    'değil', 'hiç', 'yok', 'asla', 'hayır',
    'olmadı','olmamalı', 'etmez', 'etmedi']
```

Şekil 3.8 Olumsuzluk Kelimeleri

3.5 Sözlüğün Etiketlenmesi

Oluşturulan sözlük, her bir kelime en az üç kişi tarafından puanlanacak şekilde etiketlenmiştir. Kelimeleri etiketleme işleminin güvenilirliğini ve doğruluğunu sağlamak için bazı önlemler alınmıştır.

Etiketleme sürecinde gizlilik ve bağımsızlığı sağlamak adına her bir kişinin, diğer kişilerin verdiği puanları görmemesi sağlandı. Bu da her etiketleyicinin kendi algı ve değerlendirme kriterlerine göre puan vermesini mümkün kıldı.

Güvenilirliğin sağlanmasına adına varyans kontrolü yapıldı. Farklı etiketleyiciler arasında büyük puan farkları olması, değerlendirme aşamasında bir tutarsızlık olduğuna işaret edebilir. Yüksek varyans durumunda kelimeler tekrar gözden geçirilerek, değerlendirme sürecinin doğruluğunu ve güvenilirliğini arttırıldı.

Yapılan etiketlemelerin ardından her bir kelimeye ait puanların ortalaması alındı ve Şekil 3.9'daki sözlük elde edildi. Sözlüğün oluşturulmasının ardından gerçek müşteri yorumları üzerinde test aşamasına geçildi.

Word	Avg
iyi	3.6
sıcak	2.7
soğuk	-2.3
güzel	3.8
güçsüz	-2.1
havalı	2.5
garip	-1.8
güvenli	2.9
tehlikeli	-3.7

Şekil 3.9 Etiketlenmiş Sözlük

4
DENEYSEL SONUÇLAR

Bu bölümde, oluşturulan sözlük ile yapılan başarı testleri detaylı bir şekilde anlatılacaktır.

4.1 Veri Ön İşleme Adımları

Yapılan testlerin doğruluğunu arttırmak, gereksiz gürültüyü azaltmak ve çalışma performansını optimize etmek amacıyla testlerden önce aşağıdaki veri ön işleme adımları uygunlanmıştır:

- **Metin Temizleme:** Gereksiz karakterler, sayılar ve özel işaretler kaldırılmıştır.
- **Metni Cümlelere Ayırma:** Daha başarılı bir analiz birden fazla cümle içeren metinler cümlelere ayrılmıştır. Bir metin içerisinde yer alan farklı cümleler, farklı duygusal içeriklere sahip olabilir. Örneğin, bir müşteri yorumu hem olumlu hem de olumsuz ifadeler içerebilir. Bu durumda, tüm metni tek bir duygusal sınıfa atamak yanlış sonuçlar doğuracağından, cümle bazlı analiz gerçekleştirilmiştr.
- **Kelimelere Ayırma (Tokenization) :** Sözlük tabanlı yöntemlerin en önemli adımlarından biri olan kelimelere ayırma işlemi yapılmıştır. Bu sayede her kelime sözlükte aranır ve bulunan kelimelerin puanları üzerinden duygu analizi yapılır.
- **Kelimeleri Köklerinin Bulunması :** Kelimelere gelen çekim ekleri sözlükte o kelimeyi bulmayı zorlaştıracağı için kelimeler temel formlarına indirgenerek kök haline getirilmiştir.
- **Yazım Yanlışlarının Düzeltilmesi :** Kelimelerdeki yazım hataları, örneğin "ö" yerine "o", "ü" yerine "u" gibi basit harf hatalarını düzeltmek suretiyle giderilmiştir.

Belirtilen veri ön işleme adımların bir metin üzerindeki uygulaması ve elde edilen sonuç Şekil 4.1'te gösterilmiştir.

```
metin = "Otel herseyiyle mukemmeldi. Konum her yere yakin,temizlik cok cok iyi budapestede ev ortami arayanlar icin ideal"

clean_text(metin)

['otel', 'herşeyiyle', 'mükemmel']
['konum', 'her', 'yere', 'yakın', 'temizlik', 'çok', 'çok', 'iyi', 'budapeştede', 'ev', 'ortamı', 'arayanlar', 'için', 'ideal']
```

Şekil 4.1 Veri Ön İşleme Adımlarının Uygulanması

4.2 Ürün Yorumları Üzerinde Yapılan Başarı Testleri

Sözlüğü test etmek için kullanılmak üzere booking.com, trendyol.com ve getir.com gibi online platformlardan veri kazıma (web scraping) yöntemleriyle müşteri yorumları çekilmiştir.

Çekilen her bir yorum veri ön işleme adımlarından geçtikten sonra sözlük tarafından puanlanmıştır. Puanlamaya ait örnekler Şekil 4.2'de yer almaktadır.

```
print(duygu_analizi("çok guzeldi bayildimmmmmm"))

Duygu Analizi Puanı:  9.35
```

```
print(duygu_analizi("isteklerimizin dışında şeylerde vardı içinde ve çiğ köftesi bozuk tadı vardı ziyan oldu"))

Duygu Analizi Puanı:  2.74
```

```
print(duygu_analizi("Siparişim çabuk geldi ve çok lezzetliydi, teşekkürler"))

Duygu Analizi Puanı:  7.87
```

Şekil 4.2 Puanlama Örnekleri

Her bir online platform için en az 1000 adet yorum içeren veri üzerinde testler yapılmıştır. Test aşamasında, modelin müşterinin verdiği puanı doğrudan tespit etmesi yerine yorumunun olumlu mu, olumsuz mu yoksa nötr mü olduğunu tahmin etmesi amaçlanmıştır. Bu sebeple model her ne kadar 1 ile 5 arasında sayısal bir değer veriyor olsa da, bu değerler 3 sınıfa ayrılmıştır. Bu sınıflar;

- **Olumsuz:** Duygu puanı 1,00 - 2,49 aralığında olan yorumlar
- **Nötr:** Duygu puanı 2,49 - 3,49 aralığında olan yorumlar
- **Olumlu :** Duygu puanı 3,50 - 5,00 aralığında olan yorumlar

şeklindedir. Test aşamasında modelin olumsuz olarak tahmin ettiği yoruma müşterinin verdiği puan 1 ya da 2 ise tahmin başarılı sayılmıştır. Aynı şekilde modelin olumlu

Tablo 4.1 Hata Matrisi

Hata Matrisi		Sözlük Tahmini		
		Negatif	**Nötr**	**Pozitif**
Gerçek Değerler	**Negatif**	1369	163	47
	Nötr	129	491	250
	Pozitif	94	308	2674

Tablo 4.2 Veri Sınıflarına Göre Başarı Oranları Tablosu

	Doğruluk	**Kesinlik**	**Duyarlılık**	**F-1 Skoru**
Negatif	0.922	0.86	0.87	0.86
Nötr	0.837	0.51	0.53	0.52
Pozitif	0.864	0.88	0.87	0.88

olarak tahmin ettiği yoruma müşteri 4 ya da 5 puan vermiş ise tahmin başarılı olarak kabul edilmiştir.

Bu değerlendirme kriterleri doğrultusunda beş binden fazla müşteri yorumu üzerinde gerçekleştirilen testler sonucu elde edilen hata matrisi Tablo 4.1'de yer almaktadır.

Bu tabloya her bir veri sınıfı için elde edilen Doğruluk, Kesinlik, Duyarlılık ve F-1 Skoru ise Tablo 4.2'de yer almaktadır.

4.3 Yanlış Sonuçların Değerlendirilmesi

Test sonuçlarının elde edilmesinin ardından yanlış sonuçların sebepleri değerlendirilmiş ve alt başlıklara ayrılmıştır. Bu alt başlıklar;

- **Yetersiz Veri:** Nötr sınıfına ait başarı oranının diğer sınıflara göre düşük olması, aslında olumlu ya da olumsuz olan çok sayıda kelimenin sözlükte yer almadığını, bu nedenle cümle içerisinde tespit edilemediğini ve cümleye bir sınıf bilgisi atanamadığını gösterir. Bu kelimelerin tespiti yapılarak etiketlenmesi planlanmıştır.
- **Karmaşık Cümleler:** Karmaşık yapıya sahip cümlelerin Türkçe dil yapısına uygun olmaması, bu cümlelerin sınıflandırma tahminini zorlaştırmaktadır. Bu gibi cümleler için daha ayrıntılı cümle analizi planlanmaktadır.
- **Eksik Ön İşleme:** Veri ön işleme adımlarında bazı kelimelerin kök formuna doğru bir şekilde getirilmediği, yazım yanlışlarının yeterince iyi düzeltilemediği için model tarafından tespit edilemediği görülmüştür. Önlem olarak veri ön işleme adımlarına ek kontroller planlanmıştır.

- **Müşteri Hatası :** Bazı yorumlarda müşterilerin yazdığı yorum ile verdiği puanın tutarsız olduğu gözlemlenmiştir. Özellikle müşterilerin yorumu üstte gözüksün diye 5 yıldız verip olumsuz yorumunu yazması gözlemlenmiştir. Bu gibi durumlar için önlemler alınacaktır.

şeklindedir. Planlanan önlemlerin alınmasının ardından başarı oranlarında önemli bir artış beklenmektedir.

4.4 Yanlış Sonuçlara Yönelik Alınan Aksiyonlar ve Çözümler

Yanlış sonuçların sebeplerinin belirlenmesinin ardından, bu sorunları çözmek için çeşitli aksiyonlar alınmıştır, bu çözümler alt başlıklarda incelenecektir.

4.4.1 Veri Etiketleme ve Genişletme

Nötr sınıfına ait düşük başarı oranını iyileştirmek için, sözlükte bulunmayan olumlu ve olumsuz kelimeler tespit edilerek etiketlenmiş ve sözlüğe eklenmiştir. Bu sayede, model daha fazla kelimeyi doğru sınıflandırabilir hale gelmiştir.

Oluşturulan sözlük sabit ya da tamamlanmış değildir, aksine sürekli olarak güncellenmekte ve genişletilmektedir. Dil, dinamik bir yapıya sahip olduğu için, yeni kelimeler ve ifadeler sürekli olarak ortaya çıkmakta ve mevcut kelimeler farklı anlamlar kazanabilmektedir. Bu nedenle, modelin doğruluğunu ve etkinliğini artırmak amacıyla sözlük düzenli aralıklarla gözden geçirilmekte ve güncellenmektedir.

Güncellemeler, yeni kelimelerin eklenmesi, mevcut kelimelerin anlamlarının genişletilmesi veya yeniden sınıflandırılması gibi çeşitli işlemleri içermektedir. Bu dinamik yapısı sayesinde, modelin performansı zaman içinde daha da iyileştirilmekte ve dildeki değişimlere hızlı bir şekilde uyum sağlaması mümkün olmaktadır. Ayrıca, kullanıcı geri bildirimleri ve yeni veriler de sözlüğün güncellenmesinde önemli bir rol oynamaktadır. Bu şekilde, model, kullanıcıların ihtiyaçlarına daha iyi cevap verebilmekte ve daha doğru sonuçlar üretebilmektedir.

4.4.2 Gelişmiş Cümle Analizi

Karmaşık cümle yapılarının doğru analiz edilmesi için daha ayrıntılı cümle analiz algoritmaları geliştirilmiş ve uygulanmıştır. Bu yöntemlerle, karmaşık cümlelerin yapısına uygun olarak sınıflandırılması sağlanmıştır.

- **"Ne ... ne de ..." cümle yapısı:** Türkçede "Ne ... ne de ..." cümle yapısı, genellikle iki unsurun aynı anda değerlendirilmesinde kullanılır. Bir unsurdan olumlu, diğer unsurdan olumsuz olarak bahsedilmek istediğinde cümlenin genel yapısı nötr bir hal alır. Örneğin "Ne iyi ne de kötüydü" cümlesinde yer alan "iyi" ve "kötü" kelimelerinin skorları birbirini nötrleyeceği için cümlenin genel duygu durumu nötr olur. Bu durum için ek bir kontrol koymaya gerek yoktur ancak iki unsurun da olumsuz olarak ifade edilmek istendiği durum için detaylı analiz gerekmektedir. Örnek olarak, "Ne ürün kalitesi iyi ne de müşteri hizmetleri yeterli" cümlesi hem ürün kalitesinin hem de müşteri hizmetlerinin yetersiz olduğunu belirtir ancak kelime kelime puanlandığında "iyi" ve "yeterli" kelimeleri pozitif olduğu için cümle duygu puanını hatalı bir şekilde tahmin edecektir.

  Bu sorunun çözümü adına daha gelişmiş cümle analizi gerçekleştirilmiştir. Yazılan regEx ifadesi ile cümle içerisinde "Ne [kelime] ne de [kelime]" yapısı aranmıştır ve her iki kelime de olumlu kelime ise cümlenin genel puanı olumsuz olarak atanmıştır.

- **Negatif Olumlama Cümleleri:** Negatif olumlama cümle yapıları, olumsuz bir kelime veya yapı kullanarak olumlu bir anlam ifade eder. Bu tür ifadeler, doğrudan olumlu bir ifade yerine, dolaylı olarak olumlu bir anlam taşır. Örneğin, "Hiç fena değil" ifadesi aslında "iyi" anlamına gelir.

  Negatif olumlama ifadelerini tespit ve analiz etmek için regEx ile belirli anahtar kelimeler ve kalıplar oluşturulmuştur. Eğer cümlede bu tür ifadeler bulunursa, cümlenin olumlu anlam taşıdığına karar verilip, bu şekilde işaretlenmiştir.

- **Çelişkili İfadeler İçeren Cümle Yapısı:** Çelişkili ifadeler, bir cümlenin iki veya daha fazla zıt duygu ifade eden öğenin birlikte bulunmasıdır. Bu tür ifadeler, olumlu ve olumsuz değerlendirmeleri aynı anda içerir ve genellikle bir şeyin hem iyi hem de kötü yanlarını belirtir. Çelişkili ifadelerin doğru bir şekilde analiz edilmesi için detaylı cümle parçalama işlemleri gerçekleştirilmiştir. Bu sayede her bir özellik için iki ayrı duygu puanı elde edilmiştir.

4.4.3 İyileştirilmiş Ön İşleme

Veri ön işleme adımlarında eksik olan kelime köklerine ulaşma ve yazım yanlışlarını düzeltme işlemleri için ek kontroller ve geliştirmeler yapılmıştır. Bu iyileştirmelerle, modelin hatalı tespitleri en aza indirgenmiştir.

4.4.4 Yorum-Puan Tutarlılığı

Müşteri yorumları ile verilen puanların tutarsızlığını engellemek için yorumların ve puanların daha iyi analiz edilmesini sağlayacak kurallar geliştirilmiştir. Bu kurallar, tutarsızlıkları belirleyerek aksiyonlar alınmasını sağlamıştır.

- **"Yorumum Üstte Gözüksün Diye" Cümle Yapısı:** Müşteri, dikkat çekmek ve yorumunu üst sıralara taşımak amacıyla 5 yıldız vermekte ancak yorumda olumsuz deneyimlerinden bahsetmektedir. Bunun sonucunda da model başarısı düşmektedir. Bu durumun önüne geçmek için yazılan regEx ifadesi ile "yorumum gözüksün diye", "yorumum üste çıksın diye" ve benzeri ifadeler yakalanmıştır. Bu ifadeye ait cümlelerin puan bilgisi test aşamasında değerlendirmeye katılmamıştır.

- **Küçük Şikayet İçeren Olumlu Yorumlar:**

  Müşteri, genel olarak memnun kaldığı halde, bazı küçük şikayetlerini belirtirken yüksek puan verebilir. Bu durumda, şikayet edilen husus genellikle hizmetin genel kalitesine kıyasla önemsiz bir detaydır ve bu nedenle ana özellikler kadar önem taşımaz. Örneğin "Restoranın yemekleri gerçekten lezzetliydi ve sunum harikaydı ancak masada peçeteler eksikti" cümlesinde peçetelerin eksik olması genel memnuniyetini ciddi anlamda etkilemeyen küçük bir detay olarak değerlendirilebilir. Belirli sektörlerde bu tür küçük detaylar ayrıca belirlenebilir ve değerlendirme sürecinde ana özelliklerden ayrı olarak, cümlenin duygu skoruna daha az etki edecek şekilde ele alınabilir. Bu yaklaşım, genel müşteri memnuniyetini daha doğru bir şekilde yansıtır.

4.4.5 Alınan Aksiyonların Model Başarısına Etkisi

Karşılaşılan problemlere yönelik alınan aksiyonların ardından farklı test verileri üzerinde gerçekleştirilen performans testlerinde, önceki sonuçlara kıyasla ortalama %4-%5 oranında bir başarı artışı gözlemlenmiştir.

4.5 Sözlüğün Geliştirilmesi ve Güncellenmesi

Sözlüklerin geliştirilmesi ve güncellenmesi, dinamik ve sürekli bir süreçtir. Çalışma kapsamında sözlüğün oluşturulması aşamasında karşılaşılan problemler ve bu problemlere yönelik alınan aksiyonların yanısıra kullanıcıların da sözlük hakkında geri bildirim sağlayabileceği mekanizmalar oluşturulmalıdır. Bu, sözlüğün sürekli olarak iyileştirilmesine yardımcı olur.

Kullanıcılar, deneyimlerini paylaşmak, hataları bildirmek ve yeni kelime önerilerinde bulunmak için geri bildirim formlarını kullanabilirler. Bu formlar, kullanıcıların karşılaştıkları eksiklikleri veya hataları iletmelerini kolaylaştırır. Analiz edilen geri bildirimler doğrultusunda sözlük güncellenir. Bu güncellemeler, yeni kelimelerin eklenmesi, mevcut kelimelerin anlamlarının güncellenmesi veya hataların düzeltilmesi şeklinde olabilir. Bu şekilde, kullanıcıların aktif katılımı ve geri bildirimleri, sözlüğün kapsamını genişletmek ve doğruluğunu artırmak için etkili bir yöntem olarak kullanılabilir.

5
SONUÇ

Proje kapsamında, Türkçe ürün yorumlarında en sık kullanılan sıfat ve zarflar farklı kaynaklardan tespit edilerek değerlendiriciler tarafından etiketlenmiştir. Popüler LLM modellerine rağmen denenen bu sözlük tabanlı yöntem, hızlı ve başarılı sonuçlar vermiştir. Her bir kelime en az 3 farklı kişi tarafından etiketlenerek -4 ile +4 arası bir duygu skoru belirlenmiştir. Oluşturulan bu puanlı sözlük, gerçek yorumlar üzerinde test edilmiş ve başarı performansı tespit edilmiştir. Testler sonucunda elde edilen hatalı sonuçlar analiz edilip belirli kategoriler altında sınıflandırılmıştır. Bu yanlış sonuçlara yönelik çeşitli önlemler geliştirilmiş ve uygulanmıştır. Alınan bu tedbirler neticesinde, başarı oranında belirgin bir artış sağlanmıştır.

Sonuç olarak, projede geliştirilen duygu analizi aracı, müşteri yorumlarını hızlı ve doğru bir şekilde analiz ederek işletmelerin müşteri memnuniyetini artırmalarına yardımcı olabilecek etkili bir araçtır. Geliştirilen yöntem, hız ve doğruluk açısından tatmin edici sonuçlar vermiş, bu da proje kapsamında oluşturulan duygu sözlüğünün ve analiz aracının değerini ortaya koymuştur. Dijitalleşmenin getirdiği bu dönüşümle birlikte, işletmeler müşteri geri bildirimlerini daha etkin bir şekilde değerlendirebilecek ve rekabet avantajı elde edebilecektir.

KAYNAKÇA

[1] D. Shah, A. Singh, S. S. Prasad, "Sentimental analysis using supervised learning algorithms," in *2022 3rd International Conference on Computation, Automation and Knowledge Management (ICCAKM)*, IEEE, 2022, pp. 1–6.

[2] Labelbox, *Labelbox: The leading training data platform for ai*, `https://labelbox.com/research/`, Erişim Tarihi: 14-07-2024.

[3] Prodigy, *Prodigy: Radically efficient machine teaching*, `https://prodi.gy/`, Erişim Tarihi: 14-07-2024.

[4] D. Srivastava, V. K. Soni, "A systematic review on sentiment analysis approaches," in *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, IEEE, 2022, pp. 01–06.

[5] G. W. Milligan, M. C. Cooper, "Methodology review: Clustering methods," *Applied psychological measurement*, vol. 11, no. 4, pp. 329–354, 1987.

[6] K. P. Sinaga, M.-S. Yang, "Unsupervised k-means clustering algorithm," *IEEE access*, vol. 8, pp. 80 716–80 727, 2020.

[7] F. Murtagh, P. Contreras, "Algorithms for hierarchical clustering: An overview," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 2, no. 1, pp. 86–97, 2012.

[8] A. Ushioda, "Hierarchical clustering of words and application to nlp tasks," in *Fourth Workshop on Very Large Corpora*, 1996.

[9] K. Khan, S. U. Rehman, K. Aziz, S. Fong, S. Sarasvady, "Dbscan: Past, present and future," in *The fifth international conference on the applications of digital information and web technologies (ICADIWT 2014)*, IEEE, 2014, pp. 232–238.

[10] S. Mishra, V. C. Manam, *et al.*, "A comparative study of unsupervised learning techniques and natural language processing in network traffic classification," in *2023 IEEE International Conference on Advanced Networks and Telecommunications Systems (ANTS)*, IEEE, 2023, pp. 138–143.

[11] F. Å. Nielsen, "A new anew: Evaluation of a word list for sentiment analysis in microblogs," in *Proceedings of the ESWC2011 Workshop on 'Making Sense of Microposts': Big things come in small packages*, 2011, pp. 93–98.

[12] S. Loria, *Textblob: Simplified text processing*, `https://textblob.readthedocs.io/en/dev/`, 2013.

[13] C. Hutto, E. Gilbert, "Vader: A parsimonious rule-based model for sentiment analysis of social media text," in *Proceedings of the International AAAI Conference on Web and Social Media*, 2014, pp. 216–225.

[14] *Textblob*, https://textblob.readthedocs.io/en/dev/, Erişim Tarihi: 10-06-2022.

[15] *Vader*. [Online]. Available: https : / / github . com / cjhutto / vaderSentiment (visited on 06/10/2022).

[16] C. Hutto, E. Gilbert, “"vader: A parsimonious rule-based model for sentiment analysis of social media text.",” *Proceedings of the international AAAI conference on web and social media*, vol. Vol. 8. No. 1, 2014.

[17] J. Deng, Y. Lin, “The benefits and challenges of chatgpt: An overview,” *Frontiers in Computing and Intelligent Systems*, vol. 2, no. 2, pp. 81–83, 2022.

[18] M. Wankhade, A. C. S. Rao, C. Kulkarni, “A survey on sentiment analysis methods, applications, and challenges,” *Artificial Intelligence Review*, vol. 55, no. 7, pp. 5731–5780, 2022.

[19] P. Qi, Y. Zhang, Y. Zhang, J. Bolton, C. D. Manning, “Stanza: A Python natural language processing toolkit for many human languages,” in *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, 2020. [Online]. Available: https://nlp.stanford.edu/pubs/qi2020stanza.pdf.

[20] W. Q. Meeker, L. A. Escobar, F. G. Pascual, *Statistical methods for reliability data*. John Wiley & Sons, 2022.

[21] *Zemberek*. [Online]. Available: https://github.com/ahmetaa/zemberek-nlp?tab=readme-ov-file (visited on 06/16/2024).