

İSTANBUL BİLGİ ÜNİVERSİTESİ
LİSANSÜSTÜ PROGRAMLAR ENSTİTÜSÜ
PAZARLAMA İLETİŞİMİ YÜKSEK LİSANS PROGRAMI

**SAĞLIK SEKTÖRÜNDE MÜŞTERİ MEMNUNİYETİ VE DUYGU ANALİZİ: BİR
TWITTER ÖRNEĞİ**

İlhami Arda DİKER

118652048

Prof. Dr. Beril DURMUŞ

İSTANBUL

2021

İSTANBUL BİLGİ ÜNİVERSİTESİ

LİSANSÜSTÜ PROGRAMLAR ENSTİTÜSÜ

PAZARLAMA İLETİŞİMİ YÜKSEK LİSANS PROGRAMI

SAĞLIK SEKTÖRÜNDE MÜŞTERİ MEMNUNİYETİ VE DUYGU ANALİZİ: BİR
TWİTTER ÖRNEĞİ

İlhami Arda DİKER

118652048

Prof. Dr. Beril DURMUŞ

İSTANBUL

2021

İlhami Arda DİKER

118652048

Tez Danışmanı: Prof. Dr. Beril Durmuş
Marmara Üniversitesi

Jüri Üyesi: Dr. Öğr. Üyesi Barış Ursavaş
İstanbul Bilgi Üniversitesi

Jüri Üyesi: Dr. Hüseyin Ekizler
Marmara Üniversitesi

Tezin Onaylandığı Tarih:

Toplam Sayfa Sayısı:

Anahtar Kelimeler (Türkçe)

- 1) Duygu Analizi
- 2) Müşteri Memnuniyeti
- 3) Sağlık Sektörü
- 4) Twitter
- 5) Sosyal Medya

Anahtar Kelimeler (İngilizce)

- 1) Sentiment Analysis
- 2) Customer Satisfaction
- 3) Healthcare Industry
- 4) Twitter
- 5) Social Media

İÇİNDEKİLER

İÇİNDEKİLER	iii
ŞEKİL LİSTESİ.....	vi
TABLO LİSTESİ.....	vii
ÖZET	viii
ABSTRACT.....	ix
ÖNSÖZ.....	x
GİRİŞ	1
1. BÖLÜM	3
LİTERATÜR TARAMASI.....	3
1.1 SAĞLIK SEKTÖRÜNDE PAZARLAMA YÖNTEMLERİ	3
1.2 SAĞLIK SEKTÖRÜNDE MÜŞTERİ MEMNUNİYETİ VE ÖNEMİ.....	8
1.3 DİJİTAL PAZARLAMANIN SAĞLIK SEKTÖRÜNDE KULLANIMI.....	11
1.4 LİTERATÜRDE DUYGU ANALİZİ HAKKINDA YAPILAN ÇALIŞMALAR..	13
2. BÖLÜM	17
DUYGU ANALİZİNDE KULLANILAN TEKNİKLER.....	17
2.1. DOĞAL DİL İŞLEME VE DUYGU ANALİZİ	18
2.1.1 Doğal Dil İşleme Nedir	18
2.1.2 Duygu Analizi ve Uygulama Alanları	19
2.2. DUYGU ANALİZİNİN AMACI.....	19
2.3 SÖZLÜK TEMELLİ DUYGU ANALİZİ YÖNTEMLERİ.....	20
2.4 MAKİNE ÖĞRENMESİ YÖNTEMLERİNE GENEL BAKIŞ	21
2.4.1 Denetimli/Danışmanlı Öğrenme (Supervised Learning).....	21
2.4.2 Denetimsiz/Danışmansız Öğrenme (Unsupervised Learning).....	21
2.5 DENETİMLİ/DANIŞMANLI ÖĞRENME ALOĞİRTMALARI	22
2.5.1 Karar Ağacı Sınıflandırıcılar	22
2.6.2 Lineer Sınıflandırıcılar.....	27
2.6.3 Kural Tabanlı Sınıflandırıcılar	31
2.6.4 Olasılık Tabanlı Sınıflandırıcılar	32
2.7 DUYGU ANALİZİNDE VERİ ÖN İŞLEME	34
2.5.1 Ham veri indirilmesi ve etiketleme	35
2.5.3 Dizgeciklere ayırma (Tokenization).....	35
2.5.4 N-gram yöntemi	36
2.5.6 Filtreleme.....	36

2.5.6 Gövdeleme (Stemming - Lemmatization).....	36
2.6 METİNE İŞLEMEDE BOYUT İNDİRGEME	37
2.6.1 Terim Ağırlıklandırma.....	37
2.6.2 Terim frekansı ve dizgeciklere ayırma örneği	38
2.8 MAKİNE ÖĞRENME YÖNTEMLERİNİN DEĞERLENDİRİLMESİ	41
2.8.1 Hata Matrisi (Confusion Matrix).....	41
2.8.2 Sınıflandırma Doğruluğu (Classification Accuracy)	42
2.8.3 Duyarlılık (Sensitivity).....	42
2.8.4 Belirleyicilik (Specificity)	42
2.8.5 Kesinlik Precision	42
2.8.6 F – Ölçüsü.....	43
2.8.7 Microsoft Makine Öğrenmesi Kütüphanesi Model Değerlendirme Kriterleri	43
BÖLÜM 3 METODOLOJİ.....	45
3.1. ARAŞTIRMANIN AMACI.....	45
3.2. ARAŞTIRMANIN YÖNTEMİ	46
3.3 ANA KÜTLE VE ÖRNEKLEM SEÇİMİ	47
3.4 VERİ HAZIRLANMASI ve MODELLEME	50
3.5 MAKİNE ÖĞRENMESİ MODELLERİ SINIFLANDIRMA SONUÇLARI	50
BÖLÜM 4 BULGULAR.....	51
4.1 VERİ ÖN İŞLEME VE MODELLEME.....	51
4.2 MODELİN OLUŞTURULMASI VE PERFORMANSININ ÖLÇÜLMESİ.....	53
SONUÇ.....	58
KAYNAKÇA.....	60
EKLER.....	67

KISALTMALAR

ACC: Doğruluk (Accuracy)

BOW: Kelime çantası / heybesi (bag-of-words)

DA: Duygu analizi

DÖ: Derin Öğrenme

DVM: Destek Vektör Makineleri (Support Vector Machines)

KNN: K En yakın Komşu (K Nearest Neighbor)

DDİ: Doğal Dil İşleme

FP: Doğruya yanlış denmesi (False Positive)

FN: Yanlışta doğru denmesi (False Negative)

ME: Maksimum Entropi (Maximum Entropy)

MÖ: Makine Öğrenmesi

MS: Microsoft

NB: Naïve Bayes

TF: Terim Frekansı

IDF: Ters Doküman Frekansı (Inverse Document Frequency)

TF -IDF: Terim Frekansı - Ters Doküman Frekansı

TP: Doğruya doğru denmesi (True Positive)

TN: Yanlışta yanlış denmesi (True Negative Rate)

WOM: Ağızdan Ağıza İletişim (Word of Mouth)

eWOM: Elektronik Ağızdan Ağıza İletişim (Electronic Word of Mouth)

ŞEKİL LİSTESİ

Şekil 1.1: Pazarlama süreçleri.....	4
Şekil 1.2: Pazarlama karması.....	4
Şekil 1.3: Memnuniyet Seviyeleri.....	7
Şekil 1.4: Hasta memnuniyet faktörleri	10
Şekil 1.5: Hastanelerde kullanılan çevrimiçi/dijital pazarlama araçları	12
Şekil 2.1: Duygu analizinde kullanılan yapay zeka yaklaşımları	18
Şekil 2.2: Karar ağacı sınıflandırıcılarına genel bakış	23
Şekil 2.3: Karar ağacı sınıflandırıcıları örnek problem – ağaç oluşturma ilk adım	25
Şekil 2.4: Karar ağacı sınıflandırıcıları örnek problem – ağaç oluşturma nümerik adım gösterimi	27
Şekil 2.5: Destek vektör makinelerinin veri kategorizasyon örneği	28
Şekil 2.6: Sinir ağları genel gösterim – aktivasyon fonksiyonları	30
Şekil 2.7: Sinir ağları genel gösterim.....	31
Şekil 2.8: Yapay zeka süreçleri için ham veri indirilmesi ve etiketleme süreci	35
Şekil 2.9: Microsoft makine öğrenmesi çok sınıf sınıflandırması değerlendirme ölçümleri...43	
Şekil 3.1: MedicalPark hakkındaki Twitter kategorileri.....	46
Şekil 3.2: MedicalPark hakkındaki atılan Tweet'lerin müşteri memnuniyeti modeli kategorilerine göre eşleşmeleri	47
Şekil 3.3: Manuel olarak etiketlenen Tweet örnekleri	48
Şekil 3.4: Manuel olarak etiketlenen Tweet'lerin kategori dağılımları	48

TABLO LİSTESİ

Tablo 1.1: Türkiye’de önde gelen sağlık gruplarının sosyal medya takipçi sayıları	12
Tablo 2.1: Türkiye’de önde gelen sağlık gruplarının sosyal medya takipçi sayıları	24
Tablo 2.2: Karar ağacı sınıflandırıcıları ortalama yaşa göre Gini endeksi oluşturulması	26
Tablo 2.3: Karar ağacı sınıflandırıcıları ortalama yaşa göre Gini endeksi hesaplanması.....	26
Tablo 2.4: Kural tabanlı sınıflandırma örneği tablosu	32
Tablo 2.5: TF, IDF ve TF-IDF üzerine bir örnek	40
Tablo 2.6: Hata Matrisi	41
Tablo 4.1: Veri ön işleme ve ilk modelin maksimum entropi yöntemiyle gerçekleşen doğruluk oranı.....	51
Tablo 4.2: İlk modelin hata matrisi.....	52
Tablo 4.3: İyileştirilen modelin maksimum entropi yöntemiyle doğruluk oranı.....	54
Tablo 4.4: İyileştirilen modelin DVM yöntemiyle doğruluk oranı.....	54
Tablo 4. 5: İyileştirilen modelin maksimum entropi yöntemiyle müşteri memnuniyeti kategorileri F değeri.....	55
Tablo 4. 6: İyileştirilen modelin maksimum entropi yöntemiyle duygu kategorisi F değeri ..	55
Tablo 4. 7: İyileştirilen modelin maksimum entropi yöntemiyle nitelik kategorisi F değeri ..	55
Tablo 4. 8: İyileştirilen modelin DVM yöntemiyle müşteri memnuniyeti kategorileri F değeri	55
Tablo 4. 9: İyileştirilen modelin DVM yöntemiyle duygu kategorisi F değeri	56
Tablo 4. 10: İyileştirilen modelin DVM yöntemiyle nitelik kategorisi F değeri	56
Tablo 4. 11: İyileştirilen modelin maksimum entropi yöntemine göre oluşan memnuniyet faktörleri kategorisi hata matrisi	57
Tablo 4. 12: İyileştirilen modelin maksimum entropi yöntemine göre oluşan duygu kategorisi hata matrisi.....	57

ÖZET

Müşteri memnuniyeti, rekabetin en üst düzeye eriştiği bugünlerde firmalar için çok önemli bir yere sahiptir. Mutsuz bir müşterinin olumsuz deneyimini sosyal medyanın gücü sayesinde birçok kişiye ulaştırması olasıdır. Bununla beraber yeni müşteri elde etme maliyetinin mevcut bir müşteriyi elde tutma maliyetinden çok daha yüksek olması firmaların ve markaların müşteri memnuniyetine çok daha fazla önem vermesine ve kaynak ayırmasına yol açmıştır.

Bugüne kadar müşteri memnuniyeti ölçümü için anketler yapılmış ve yıldan yıla gelişmeler takip edilmiştir. Günümüzün dinamik dünyasında sosyal medya aracılığıyla, bilhassa da Twitter üzerinden müşteriler, markalar hakkındaki şikayet ve memnuniyetlerini anlık olarak belirtmektedirler. Müşteri memnuniyetini arttırmanın yollarından biri şikayetlerin ve olumlu beyanların yönetiminden geçmektedir. Bu tez çalışmasında sağlık sektöründe çalışan bir hastaneler grubu hakkındaki Twitter mesajlarının duygu analizleri yapılmıştır. Ardından bu analizler, müşteri memnuniyeti modeline uygun faktörlerle, makine öğrenmesi yöntemlerinden maksimum entropi ve destek vektör makineleriyle eşleştirilmiştir.

Çalışmanın amacı sosyal medyada, şirketlerin ve markaların kendileri hakkındaki müşteri beyanlarındaki duyguların, müşteri memnuniyeti modeline göre otomatik analiz edilebilmesi için uygun sistemin oluşturulması ve bu sistemin tüm metinsel mikro blog veri kaynaklarında kullanımının mümkün kılınmasıdır. Bu amaç doğrultusunda, çalışmanın ilk bölümünde duygu analizi ve müşteri memnuniyeti modelinin tanımları yapılmış ve literatürdeki çalışmalar özetlenmiş, ikinci bölümde duygu analizinde kullanılan teknikler ele alınmıştır. Son kısımda ise, bir hastaneler grubu hakkındaki Twitter mesajları önerilen modele göre incelenmiş ve uygulamanın sonuç tablolarına yer verilmiştir.

Anahtar kelimeler: Twitter, Sosyal Medya, Duygu Analizi, Müşteri Memnuniyeti, Sağlık Sektörü

ABSTRACT

In this highly competitive era, customer satisfaction has the utmost importance for companies. It is a widely accepted fact that an unhappy customer may convey their negative experience to many potential customers with the help of social media. On the other hand, the cost of acquiring new customers is much higher than the cost of holding an existing one. Therefore, companies and brands to give much more importance to customer satisfaction and allocate resources to keep the existing ones.

To date, surveys have been conducted to measure customer satisfaction and developments in customer sentiment have been followed annually. In today's dynamic world, customers can instantly express their complaints and satisfaction about brands through social media, especially on Twitter. One of the ways to increase customer satisfaction is managing complaints and positive statements of customers actively. In this thesis, a hospital group company was chosen, and its customers' twitter messages were collected analyzed in accordance with the sentiment analysis. Afterwards, relevant Tweets were classified according to customer satisfaction model factors with the help of popular machine learning algorithms, maximum entropy, and support vector machine.

The aim of the study is to create a system that can automatically analyze sentiments in the customer statements about companies and brands in social media then classify them according to the customer satisfaction model and finally to enable the use of this system in all textual micro blog data sources.

In the first part of the study, sentiment analysis and customer satisfaction model were defined and the studies in the literature were summarized. Sentiment analysis methodologies were discussed in the second part. In the last part, the Twitter messages about a hospital group were analyzed according to the proposed model and the results tables of the application were given.

Keywords: Twitter, Social Media, Sentiment Analysis, Customer Satisfaction, Healthcare industry

ÖNSÖZ

Bu çalışma, İstanbul Bilgi Üniversitesi Sosyal Bilimler Enstitüsü İletişim Fakültesi, Pazarlama İletişimi Yüksek Lisans Programı'nda yüksek lisans tezi olarak hazırlanmıştır. Çalışmada Türkiye'de sağlık sektöründe faaliyet gösteren bir firmanın müşterilerinin Twitter platformundaki mesajlarının duygu analizi yapılmış ve müşteri memnuniyet modeli faktörlerine göre yapay zekalı sistem tarafından otomatik sınıflandırılması sağlanmıştır.

Çalışma boyunca her daim destekleyen ve yol gösteren Prof. Dr. Beril Durmuş'a ne kadar teşekkür etsem azdır. Ayrıca bu çalışmanın başlanmasını imkan veren Marka Okulu'ndaki tüm hocalarımıza ve program direktörümüz Doç. Dr. Gresi Sanje'ye teşekkürlerimi sunarım.

Tez yazım sürecinde desteklerini esirgemeyen ve motive eden ailem ve Can Kaynak'a müteşekkirim.

Çalışmanın, şirketlerin sosyal medyada, müşteri memnuniyeti analizlerini hızlı bir şekilde yapmalarına yardımcı olacaklarını umarım.

İlhami Arda DİKER

İstanbul, 2021

GİRİŞ

Günümüzde müşteriler, bir marka veya şirkete yönelik memnuniyet ve memnuniyetsizliklerini dijital platformlarda etkin bir şekilde ifade etmektedir. Bu platformlar mikro blog olarak da adlandırılmakta olup en önemlileri Twitter, Facebook ve Instagram'dır. Bu platformların hem kullanıcı sayısı hem de bu kullanıcıların yarattığı veri miktarı oldukça yüksektir. Örneğin Twitter, tüketicilerin şirketlere ve markalar sesini duyurmak için etkin olarak kullandıkları önde gelen sosyal medya platformlarından biri olmanın yanında 2021 Statista verilerine göre Twitter'ın aylık 322,4 milyon aktif toplam kullanıcısı ve 11,8 Milyon Türk kullanıcısı bulunmaktadır (Tankovska, 2021). Twitter'da günlük 500 milyon Tweet atıldığı belirtilmektedir (Krikorian, 2013). Benzer şekilde Facebook da yoğun kullanılan başka bir platformdur. Facebook'a günde 350 milyon resim yüklenmekte ve platformun 2,7 milyar aktif kullanıcısı bulunmaktadır (Aslam, 2021).

Müşterilerin, ilgili mikro bloglar üzerinden kurdukları iletişim elektronik ağızdan ağıza iletişim (eWOM) olarak adlandırılmaktadır. Mikro bloglarda belirtilen müşteri görüşleri veya memnuniyetsizlikleri diğer müşterilerin görüşlerini etkileyebilmektedir. Markaların ve şirketlerin müşterileriyle karlı ve uzun süreli bir ilişki kurmaları, marka sadakatini sağlamaları ve yeni müşteri kazanmaları için müşteri memnuniyeti, önem verdikleri konuların başında gelmektedir.

Yoğun veri akışının olduğu mikro bloglarda, müşterilerin beyan ve yorumlarının tümünün insanlar tarafından el yordamıyla tasnifi mümkün olmadığından, şirketler ve markalar algoritma ve programlardan yararlanmaktadır. Bu konuda en sık yapılan analiz türlerinden biri duygu analizidir. Duygu analizinin yapılması için makine öğrenmesi ve sözlük bazlı yöntemlerden yararlanılmıştır. Bu tekniklerin yardımıyla markalara yönelik, müşterilerin olumlu, olumsuz veya nötr duygu durumu başarıyla tespit edilmiştir. Bu da göstermektedir ki bu teknik ve analizler yardımıyla eWOM'un markalar tarafından anlık olarak takip edilmesi mümkündür. Bu sayede tüketicinin markaya yönelik ve rakiplere yönelik tutumları kayıt altına alınabilir ve çıkabilecek krizlere hemen müdahale edilebilir. eWOM'un markaya tutumla beraber müşteri tercihlerine de etki etmektedir. Appel, Grewal, Hadi ve Stephan (2019) sosyal medyada markanın aldığı beğenilerin, müşteri tercihlerine hiç veya çok az etkisi olurken, olumsuz ağızdan ağıza yayılmanın (WOM) marka tercihinin olumsuz etkilediğini

belirtmişlerdir. İstanbulluoğlu (2017) sonuç bölümünde şikayetlere sadece hızlı cevap vermenin şikâyet yönetiminde tek boyut olmadığı, şikâyetin ciddiyetinin de araştırılması gereğini belirtirken, Chang, Tsai, Wong ve Wang (2015) şikâyetin ciddiyeti arttıkça, tüketicilerin ilgili marka/firmayı suçlayıcılığının arttığını ve olumsuz WOM'a katkıda bulunduğunu tespit etmişlerdir. Dolayısıyla her şikâyet aynı önemde olmayıp müşteri memnuniyetsizliğine olan katkısı farklı olabilmektedir.

Literatürde bugüne kadar yapılan duygu analizi çalışmaları kabul görmüş müşteri memnuniyeti modelleriyle eşlenmemiş olduğundan çıkan sonuçlar bir marka veya şirkete yönelik olumlu veya olumsuz anlamda, genel bir tutumu tespit etmiştir. Fakat bu duygu durumunun kök nedeni ve müşteri memnuniyet modelinde hangi faktörle bağlantılı olduğu önceki çalışmalarda eksik kalmıştır.

Elektronik ağızdan ağıza iletişimin müşteri memnuniyetine etkisi sebebiyle, şirketler sosyal dinleme adında, mikro blog ve benzeri mecralarda kendileri hakkında konuşulanları manuel olarak takip etmektedir. Bu da yoğun emek isteyen bir süreç olup otomasyona muhtaçtır. Araştırma kapsamında, sağlık sektöründe bir firma hakkında, popüler bir mikro blog platformu olan Twitter üzerinden atılan Tweet'lerin duygu analizi yapılmıştır. Ayrıca, sağlık sektörü için geliştirilmiş olan Abirami ve Askarunisa'nın (2017) oluşturduğu müşteri memnuniyeti modeli kullanılarak, atılan Tweetler ile model faktörleriyle eşleştirilmiş ve bu modele göre sınıflandırma da yapan otomatik bir sistem oluşturulmuştur.

Yapay zeka destekli müşteri memnuniyet modelindeki faktörler sayesinde memnuniyetsizliğin hangi kök sebepten kaynaklandığı hemen görülebilmektedir. Böylece, ücretlendirmeye problem yaşayan müşteriyle doktor ilişkisinde problem yaşayan bir müşteri arasında önceliklendirme yapılabilmesi mümkün kılınmıştır. Bu da hızlı ve etkin dönüş sağlanması için marka ve şirketlere yardımcı olacaktır.

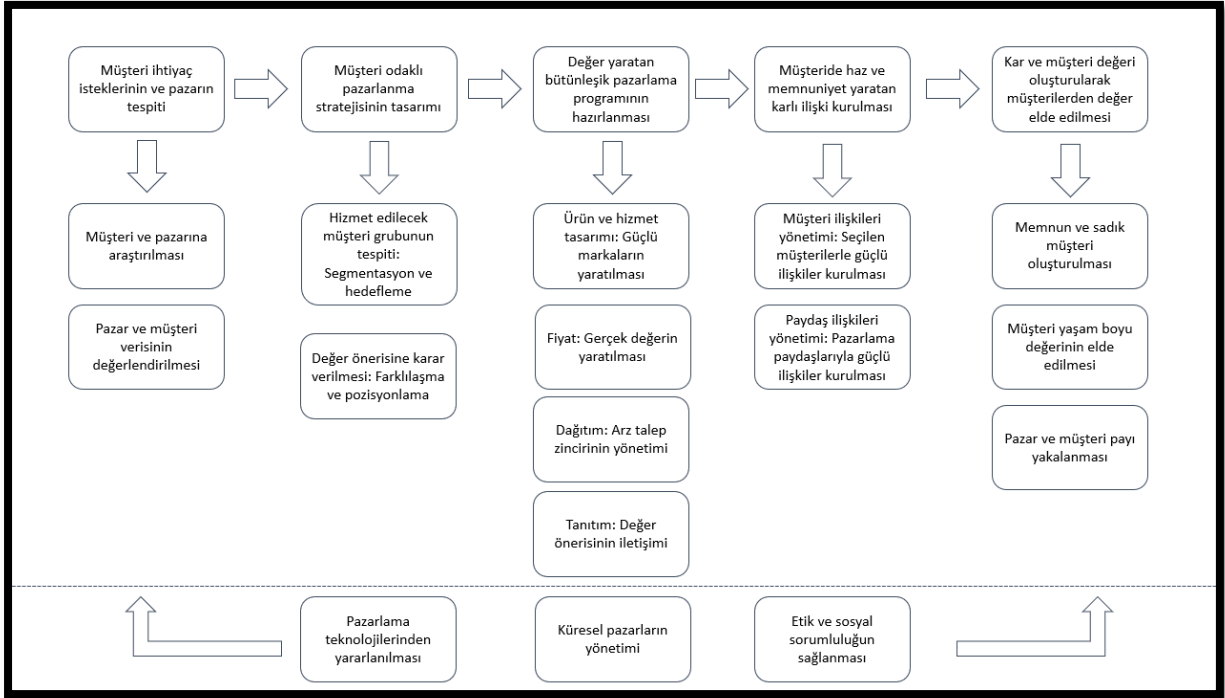
1. BÖLÜM

LİTERATÜR TARAMASI

1.1 SAĞLIK SEKTÖRÜNDE PAZARLAMA YÖNTEMLERİ

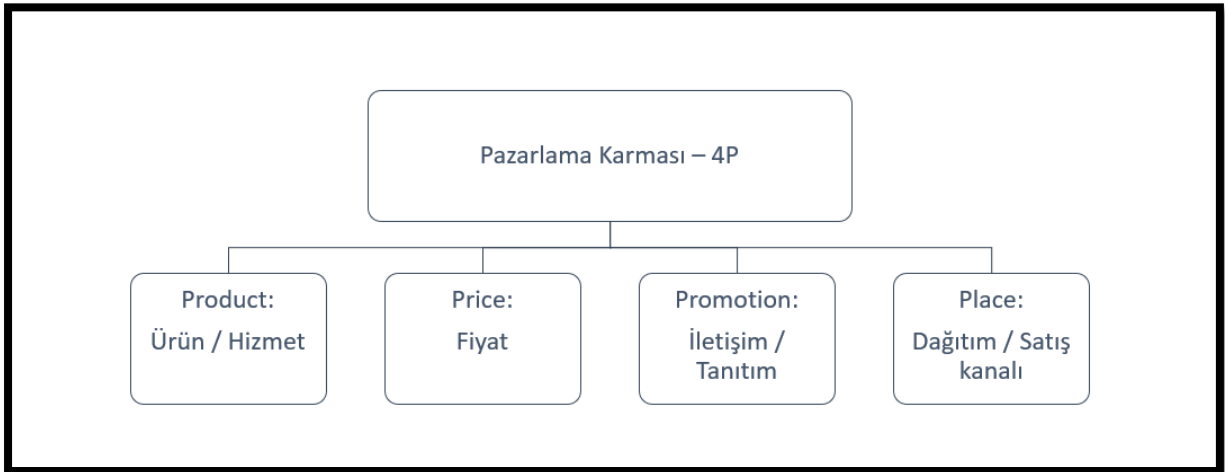
Pazarlama çoğu zaman reklamcılık ve satış ile karıştırılan günümüz şirketlerinin en önemli departman ve fonksiyonlarından biridir. Kotler ve Armstrong (2008), pazarlamayı şirketlerin müşteriler için değer yarattığı ve karşılığında müşterilerden değer elde etmek için güçlü ilişkiler kurduğu süreç olarak tanımlamışlardır. Bu süreç sayesinde şirketler, müşterileriyle karlı ilişkiler kurabilirler. Pazarlama yöntemlerinin iyi uygulanması sayesinde müşteri ihtiyaçları ve istekleri tespit edilebilir, pazar hedeflemesi yapılabilir ve şirketlerin müşterilerine en iyi nasıl hizmet edebileceği ve değer üretebileceği belirlenebilir. Bu sayede de şirketler yeni müşteriler kazanabilir, mevcut müşterilerini elde tutabilir ve yeni müşteriler kazanabilir. Şekil 1.1 pazarlama süreçlerini ve adımlarını özetlemektedir. Pazarlama süreçleri kapsamında ilk adım müşteri ihtiyaç ve istekleriyle, pazarın tespitidir. Bu adımda pazar büyüklüğü ve dinamikleri için araştırma yapılır ya da ikincil verilerden pazar büyüklüğü büyüme hızı gibi farklı metriklere göre tespitler yapılır. Müşteri ihtiyaç ve isteklerinin tespiti içinse anket ve odak grupları çalışmaları yapılır. İkinci adımda müşteri odaklı pazarlama stratejisinin oluşturulması için ürün veya hizmetin sunulacağı pazarın müşteri segmentasyonu yapılır. Hedeflenen müşteri segmentine göre değer önerisine karar verilir. Bu sayede pazarda pozisyon alınır ve rakiplerden farklılaşma sağlanır. Üçüncü adım, bu süreçlerden en kritik olan adımlarından biri olan değer yaratan bütünleşik pazarlama programının hazırlanmasıdır. Bu adım pazarlama dünyasında, pazarlama karması veya 4P olarak da bilinir. Şekil 1.2’de görüleceği üzere 4P, İngilizce product, price, promotion ve place kelimelerinden oluşmaktadır. Türkçe olarak karşılığı ise sırasıyla ürün, fiyat, tanıtım / iletişim ve dağıtım / satış kanalıdır. Pazarlama süreçleri kapsamında dördüncü adımsa müşteriyle karlı ilişkiler kurulması ve müşteri memnuniyetinin sağlanmasıdır. Son adım ise atılan ilk dört adımın sonucu olarak kar elde edilmesi, sadık müşteri kitlesinin oluşturulması, müşteri yaşam boyu değerinin ve pazar payının elde edilmesidir.

Şekil 1.1: Pazarlama süreçleri



Kaynak: Kotler, P., & Armstrong, G. (2008). *Principles of marketing*. Upper Saddle River, NJ: Pearson/Prentice Hall.

Şekil 1.2: Pazarlama karması



Kaynak: Araştırmacı tarafından hazırlandı

Sağlık sektöründe de pazarlama süreçlerinden ve karmasından yararlanılmıştır. Gray (2008), pazarlama literatüründeki 4P ve bunun sağlık sektöründeki karşılığını şu şekilde özetlemiştir:

Product (Ürün): Ürünü ve verilen hizmeti ifade etmektedir. Sağlık sektöründe konsültasyon, operasyon veya hastanede kalışı ifade edebileceği gibi teşhis veya tedavi de olabilir. Bunların dışında checkup gibi hizmetlerde hastane için ürün grubuna girer.

Price (Fiyat): Ürün veya hizmet için müşteri / hastanın ödediği ücrettir. Türkiye özelinde, devlet tarafından kısmen veya tamamen bazı ücretlerin karşılanması mümkün olduğundan hastane sektöründeki etkisi diğer sektörlerle göre daha karışıktır.

Place (Yer): Hizmet veya ürünün alındığı yer ya da kanalı ifade eder. Sağlık sektörünün değişen dinamikleri sonrası evde de bazı hizmetler bir kısım ülkede alınabilmektedir. Diyaliz hastalarının evde tedavi olması buna bir örnektir.

Promotion (İletişim): Sağlık dışında ve regülasyona tabi olmayan sektörlerde reklam dahil her türlü iletişim faaliyeti bu grup altında incelenmektedir. Sağlık sektöründe ise yönetmelik ve kurallar bu konuda sınırlamalar getirmektedir. Dolayısıyla, sağlık sektöründe iletişim ülke özelinde incelenmelidir. Türkiye’de iletişim genel anlamıyla bilgilendirme kapsamında ilerlemektedir. Bunlara bazı örnekler ise: Hastane doktorlarının belli konular için televizyon programlarında bilgi vermesi, sosyal medya ve halkla ilişkiler aracılığıyla hizmet ve faaliyetler hakkında bilgi verilmesidir.

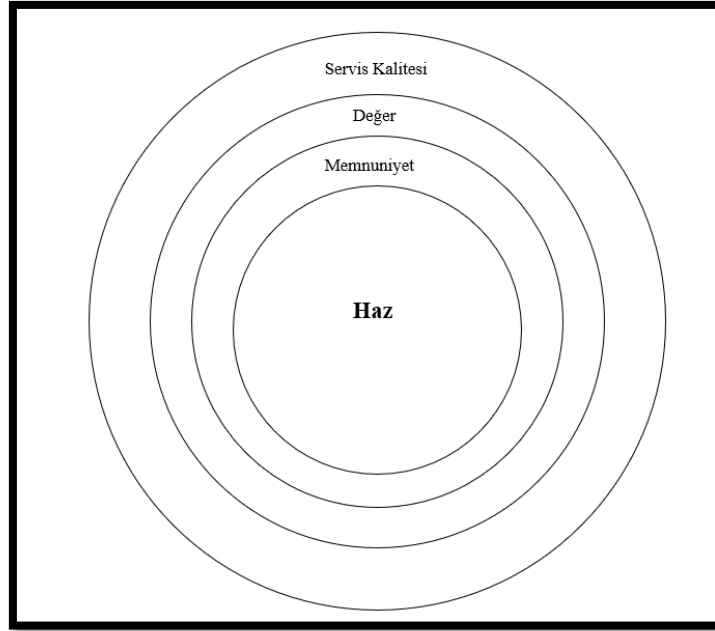
Sağlık sektöründe iletişim ve pazarlama faaliyetleri sıkı kurallara tabi olması sebebiyle iletişimin tamamen özgür olduğu sektörlerle göre de farklı değerlendirilmelidir. Giritlioğlu (2017), Türk Tabipleri Sitesinde, sektörde reklam yapmanın kesinlikle yasak olduğu ve verilebilecek ilanlarla bilgilendirmeler için sınırlandırmalar olduğunu belirtmiştir. Giritlioğlu (2017) reklamı “bir ürün veya hizmetin alım, satım veya kiralanmasını geliştirmek, bir amaç veya düşünceyi yaymak veya reklamcının istediği başka etkileri oluşturmak amacıyla, ücret veya benzer bir karşılık ile iletim zamanında reklamcıya tahsis edilen kamuya yönelik duyuruları ifade etmektedir” olarak tanımlamaktadır. Ayrıca, 6023 sayılı Kanun’un 39. maddesi gereğince, Tabip Odaları inceleme yapma, soruşturma açma, disiplin kovuşturması yürütme, disiplin cezası verme yetkilerine de sahiptir. Birçok ülkede de durum benzer olup Amerika ve Yeni Zelanda gibi çok kısıtlı bazı ülkelerde iletişim serbesitesi bulunmaktadır (Balogun ve Ogunnaike, 2017).

Pazarlama karması bakış açısında önemli bir nokta ise müşteri vurgusudur. Geleneksel olarak sağlık kuruluşlarına gelen kişiler ise hasta olarak nitelendirilmektedir. Sağlık sektöründe özellikle 1970'lerden sonra değişen bakış açısı ve hizmet arzındaki fazlalık, rekabeti arttırmış ve sağlık sektöründe pazarlamayla ilgili ilk akademik makale 1980 yılında basılmıştır (Balogun ve Ogunnaike, 2017). Hastalar günümüzde aynı zamanda müşteri olarak da addedilmeye başlanmıştır.

Sağlık sektöründeki düzenlemeler ve benzer hizmetlerin farklı kuruluşlar tarafından verilebilmesi veya kopyalanabilmesi, 4P pazarlama karışımı modelini özellikle de ürün ve fiyat anlamında kullanımını engellemektedir (Fischer, 2014). Bu sebeple farklı bakış açıları oluşturulmuştur. Gray (2008) aslında 5P olduğunu ve son P'nin prensipleri yani değerleri temsil ettiğini, bunun itibarı korumanın ana yolu olduğunu, itibarın ise marka sadakatini ve tekrar satın almada kilit rol aldığını belirtmiştir. Lim ve Ting (2012) hastalarla ilgili göze çarpan sorunları sağlık hizmeti kalitesi, tatminsizlik, bilişsel uyumsuzluk, kaygı, belirsizlik ve kontrol eksikliği olarak sıralamış ve hastanın asıl dikkat ettiği noktalar olarak sunmuştur. Tüm bunlarla beraber hastaların plansız ve farklı frekanslarla yapmış oldukları ziyaretler, sağlık konularında almak zorunda kaldıkları riskli kararlar ve buldukları duygusal anlamdaki kırılgan durum, önerilen tedavinin kalitesini ölçmekteki bilgi eksiklikleri onları bambaşka kendine has bir müşteri tipine sokmaktadır (Fischer, 2014).

Sağlık sektörü dinamiklerinin çok daha farklı olması, pazarlama karmasının sağlık sektöründeki etkisinin diğer sektörlerde yaptığı etkiyi yapmadığı anlamına da gelmektedir. Dolayısıyla, sağlık sektörünün pazarlamasında rekabetten ayrışma noktası olarak hizmet kalitesi ve müşteri memnuniyetine özel bir önem verilmiştir. Corbin, Kelley ve Schwartz (2001), servis kalitesi arttıkça, müşteri memnuniyetinin artmaya meyilli olduğunu belirtmişler ve Şekil 1.3'te bu memnuniyeti seviyelendirmişlerdir. İlk seviyede, kaliteli hizmetin verilmesi, ikinci seviyede müşterinin ödediğinin karşılığını alarak değer yaratılması, üçüncü seviyede hizmetten tümüyle memnun olunması ve alınan hizmetin yararının maliyetini geçmesi olarak belirtilmiştir. Son seviyede ise bir hizmetten alınan haz olarak nitelendirilmiş ve müşteri sadakatinin ağızdan ağıza iletişim oluşturmaya, tekrar satın almaya imkan veren nokta olarak tarif edilmiştir.

Şekil 1.3: Memnuniyet Seviyeleri



Kaynak: Corbin, C. L., Kelley, S. W., & Schwartz, R. W. (2001). Concepts in service marketing for healthcare professionals. *The American Journal of Surgery*, 181(1), 1-7. doi:10.1016/s0002-9610(00)00535-3

Butt, Iqbal ve Zohaib (2019), sağlık sektöründeki pazarlama faaliyetleriyle ilgili literatür incelemesi yapmış, oluşturdukları filtre ve sisteme göre 1987-1991 yıllarında konuyla ilgili 146 makale basılırken 2007-2011 yılları arasında 566 makale basılmış ve 2012-2016 yılları arasında 419 makale basılmıştır. Makale başına alıntı sayısı da aynı dönemlerde sırasıyla 0,29, 1,42 ve son olarak da 1,63'e ulaşmıştır. Bu bağlamda sağlık sektörü pazarlama alanı gittikçe popülerleşen bir araştırma alanı haline gelmektedir. İlgili çalışmada alıntı sayıları dikkate alınarak değerlendirme yapıldığında en etkin ikinci makale Aagja ve Garg (2010)'un yaptığı devlet hastanelerinin algılanan servis kalitesi üzerine araştırmasıdır. Nitekim, bu bir rastlantı olmayıp, hastanelerin pazarlama faaliyetlerindeki kısıtlamaları sebebiyle servis kalitesine ve müşteri memnuniyetine verdikleri önemi ortaya koymaktadır.

Konumlandırmanın daha etkin yapılması için farklı çalışma ve bakış açıları geliştirilmiş olup bunlardan biri arketip kullanımınıdır. Fischer (2014), hastaneler için dört farklı arketip önermiştir. Bunlar, kurumsal değer icracısı (corporate value performer), hizmet sağlayıcı (service provider), kalite lideri (quality leader) ve halk kahramanı güvenilir danışman (public hero and trusted advisor) arketipleridir. Kurumsal değer icracısı pozisyonlanmasında

hastanenin misyonu, vizyonu ve deęerleri mesajlarda baskın olarak yer alır. Bu pozisyon Gray (2008)'in prensipler ve deęerler önermesi ile paralellik göstermektedir. Hizmet saęlayıcı arketipinde ise ilgili hastanenin iletişimde verilen hizmetlere vurgu yapılır. Kalite lideri arketipi, servis arketipiyle paralellik gösterse de sadece servisler deęil üstün kalite vurgusu mesajlarda iletilir. Bu mesajın iletişimde hastanenin aldığı ödüller ve sertifikalar vurgulanır. Halk kahramanı güvenilir danışman arketipinde farklılaşma halk saęlığını ilgilendiren konularda ve halk için verilen hizmetlerin iletişimiyle mümkün olmaktadır. Bu konumlandırmalar sayesinde izin verilen kısıtlı iletişim çerçevesinde etkin bir konumlandırma mümkün olabilmektedir.

1.2 SAęLIK SEKTÖRÜNDE MÜŞTERİ MEMNUNİYETİ VE ÖNEMİ

Pazarlama süreçlerinden dördüncü adım müşteride haz ve memnuniyet yaratan karlı ilişki kurulmasıdır. Müşteri memnuniyetini Gonzalez (2019) bir şirket tarafından saęlanan ürün ve hizmetlerin müşteri beklentilerini nasıl karşıladığının veya aştığının bir ölçüsü olarak tanımlamaktadır. Müşteri memnuniyeti, anketler yardımıyla tespit edilir ve firmanın ürünleri/hizmetleri hakkında müşteri beyanları dikkate alınır. Bu beyanlardan memnuniyet hedeflerini aşan müşteri sayısı veya toplam müşteri yüzdesi ile müşteri memnuniyeti ölçülür. Söderlung (1998), WOM'u bir müşterinin belirli bir memnuniyet düzeyi yaratan bir olay hakkında arkadaşlarını, akrabalarını ve meslektaşlarını bilgilendirmesi olarak tanımlanmaktadır. Söderlung (1998) ayrıca müşteri memnuniyeti ile WOM arasındaki ilişkinin biçimi memnuniyet düzeyine baęlı olduğunu belirtmiş, düşük memnuniyet düzeyinde olumsuz bir ilişki oluşurken, yüksek düzeyde olumlu bir ilişki oluşmasına sebep olduğunu göstermiştir. Yine aynı çalışmada, müşteri memnuniyeti ve müşteri sadakati arasında da ilişki olduğu da belirlenmiştir. Dolayısıyla, müşteri memnuniyeti hem WOM'u hem de müşteri sadakatini etkilemektedir. Günümüzde ise internetin yaygınlaşması ile bireyler ürünler ve hizmetler hakkındaki düşüncelerini internetteki farklı mecralarda belirtebilmektedir. Buna elektronik ağızdan ağıza pazarlama anlamında eWOM (electronic word of mouth) denmektedir (Park ve Lee, 2009). Saęlık sektöründe iletişimin kısıtlı olması, sektörün iletişim için önceki hastaların WOM ve eWOM ile yeni hastaları çekmesine bel bağlamasına sebep vermektedir. (Balogun ve Ogunnaike, 2017).

Mevcut yasaklar sebebiyle müşteri memnuniyeti çalışmalarında en çok dikkat edilen konulardan biri müşteri memnuniyeti olmaktadır. Bu konuyla ilgili yapılan çalışmalardan,

sağlık sektörü müşterisinin memnuniyetine etki eden faktörler araştırıla gelmiştir. Özel hastanelerin müşteri tecrübesine etki eden faktörleri Otani, Waterman ve Dunagan (2012) şu şekilde tespit ve test etmiştir: Hasta kabul süreçleri, hemşirelik hizmetleri, doktor hizmeti, hastane personeli hizmeti ve hastane odası. Günümüzde sağlık kurumlarına gelen hastaların memnuniyeti, müşteri memnuniyeti olarak değerlendirilmekte, hatta kimi çalışmalarda hastalar ziyaretçi olarak addedilmektedir (Otani ve arkadaşları, 2012). Farklı parametrelere göre hastaların memnuniyetini araştıran çalışmalar yapılmıştır. Otani ve arkadaşları (2012) farklı sağlık durumlarında gelen hastaların, memnuniyetinin belirttikleri memnuniyet girdilerinde farklılık gösterdiklerini fakat hastaların memnuniyetini arttırmanın en önemli yollarından birinin hemşirelik ve personel hizmetlerindeki kalite artışından geçtiğini belirtmişlerdir. Mazurenko, Zemke, Lefforge, Shoemaker ve Menachemi (2015) ameliyat geçiren hastaların memnuniyetleri üzerine odaklanmıştır. Konu ele alınırken hem hastalar hem de doktor, hemşire, hastanın aile üyeleri ve hastanenin yöneticilerinin olduğu paydaşlarla odak grup çalışması yapılmıştır. Çalışma sonucunda hasta memnuniyetine etki eden unsurları şu şekilde sıralamışlardır: Disiplinler arası ilişkiler, teknik altyapı ve çalışanlar. Çalışmanın ilginç bulgularından biri bu faktörlerin hastanelerde çok sıklıkla kullanılan HCAHPS anketinde bulunmamasıdır. Kim, Kaplowitz ve Johnston (2004) yaptıkları çalışmada hekimlerin iletişimlerinde empatik olmalarının hastalarının tedaviye uyumunu ve hasta memnuniyetini arttırdığını tespit etmişlerdir.

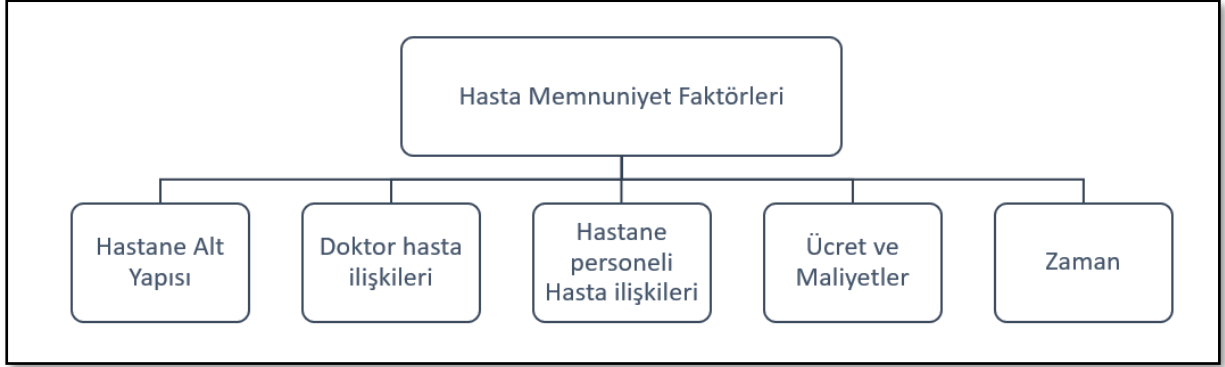
Abirami ve Askarunisa (2017) ise D'Aiviico (1995)'in çalışmasındaki hastane tercihine etki eden faktörleri Şekil-1.4'teki gibi özetlemiş ve daha kapsayıcı bir bakış geliştirmiştir.

İlgili faktörlerin temsil ettiği kavramları incelemek gerekirse aşağıdaki gibi özetlenebilir.

Hastane alt yapısı: Bu faktör altında, hastanenin temizliği, kullanılan ekipmanların ve hastanenin genel teknolojik durum, hastane büyüklüğü ve hastane içindeki hizmetler değerlendirilir.

Doktor hasta ilişkileri: Bu kapsamda, doktorun kaliteli bakımı, doktorların ünü ve tecrübesi değerlendirilmektedir.

Şekil 1.4: Hasta memnuniyet faktörleri



Kaynak: Abirami, A., & Askarunisa, A. (2017). Sentiment analysis model to emphasize the impact of online reviews in healthcare industry. *Online Information Review*, 41(4), 471–486. doi: 10.1108/oir-08-2015-0289

Hastane personeli ve hasta ilişkileri: Genel anlamda hastane personelinin hastaya yönelik tavır ve davranışlarıyla, tecrübeleri bu faktöre etki eden alt bileşenlerdir.

Ücret ve maliyetler: Hastanın, aldığı ücretler için ödediği miktar ve bunu uygun bulup bulmaması bu faktör altında değerlendirilmektedir.

Zaman: İlgili faktör altında, hastanenin modern ekipmanlara sahip olup olmaması ve hizmetlere erişim irdelenmektedir.

Literatürü incelediğimizde sağlık sektöründe hasta memnuniyeti farklı faktörlerle ele alınmış ve devamlı üzerine araştırma yapılan bir konu olmuştur. Kondasani ve Panda (2015), hastanenin fiziksel alt yapısının, çalışanların dostane olmasının, etkin iletişimin var olması, hızlı yanıt verebilmesinin ve mevcut sadakat düzeyinin algılanan kaliteye ve bu faktör üzerinden müşteri memnuniyetiyle müşteri sadakatine etki ettiğini bulmuştur. Öte yandan Gonzalez (2019), müşteri memnuniyetini arttırmak için incelediği müşteri beklentileri şu şekildedir: Hastayla olan iletişim, hasta güveni, hastane altı yapısına erişim ve kolay kullanımı, fiziksel altyapı ve finansal konular. Naidu (2009) ise sağlık sektöründe hizmetlerin değerlendirilmesinin, itimat ve inanç değerlerinin çok etkin olduğu için, oldukça zor olduğunu belirtmiş ve beş farklı faktörün hasta memnuniyetine etki ettiğini not etmiştir. Bunlar, sağlık hizmetinden alınan sonuç, hizmetlere erişim, bakım, iletişim ve hastane koşulları gibi alt yapı faktörleridir.

Sağlık sektöründe hasta / müşteri memnuniyeti gelişen bir konu olduğundan, araştırmacıların ve şirketlerin odaklanacakları faktörlerin değişmesi söz konusu olabilir. Bu tez kapsamında oluşturulacak yapay zeka modelinin de dinamik olması ve değişimlere ayak uydurması gereklidir.


1.3 DİJİTAL PAZARLAMANIN SAĞLIK SEKTÖRÜNDE KULLANIMI

Dijital pazarlama her geçen gün önemini arttırmakta ve bu konuda aksiyon alan sağlık sektörü firmaları da artmaktadır. Smith (2017), üst düzey sağlık kuruluşlarının %95'inin sosyal medya kullandığını belirtmektedir; en sık kullanılan üç platform ise %95'le Facebook, %79'la Twitter ve %75'le Youtube'dur. Sağlık kuruluşları, sosyal medyayı ağırlıklı olarak sağlıklı alışkanlıkların yayılmasını sağlamak, sağlıkla ilgili önemli bilgileri paylaşmak için kullanmakta olup, sosyal medyadan hasta sorularını alabilmek ve yeni ihtiyaçları tespit etmek için de yararlanmaktadırlar (Smith, 2017). Sosyal medya uygun maliyetlerle geniş kitlelere ulaşma imkanı verirken, iletişimde dikkat edilmesi gereken yeni noktalar da ortaya çıkarmıştır. Bunlardan en önemlilerinde biri iletişimin iki yönlü olması ve sadece kurum tarafından kontrol edilmesinin mümkün olmamasıdır.

Şekil 1.5'te görüldüğü üzere hastane sektörünün dijital pazarlamasında web siteleri en önemli araç olurken hemen arkasından sosyal medya pazarlama aktiviteleri gelmektedir. Programatik, tekrar hedefleme gibi birçok yeni dijital pazarlama aracı da kullanılmaktadır.

Nitekim, Grbic, Grbic D., Stimac ve Sostar (2019), akıllı cihaz kullanıcılarının %85'inin bir ürün veya hizmet seçmeden önce ürün veya hizmetler hakkındaki değerlendirmeleri okuyup karşılaştırdığını belirtmekte. Google, hastaların %77'sinin karar vermeden önce İnternet'te arama yaptığını belirtiyor. Bu nedenle giderek daha fazla sayıda sağlık kuruluşu çevrimiçi varlığın ve yeni müşteri çekmek için bu kanalların önemini farkına varmaktadır. Sosyal medyaya güvenen ve önemli kararlar söz konusu olduğunda kolay iletişim biçimlerini tercih eden 15-35 yaş grubuna ulaşmanın önemli bir yolu da dijital pazarlama araçlarından geçmektedir. Dünya genelinde tüm demografik grupları ortalama olarak 144 dakikalarını sosyal medya üzerinde geçirmektedirler ("Average time spent daily on social media", 2021). Sosyal medya, potansiyel müşterilerin çok yoğun zaman geçirdiği bir mecra olduğu için önemi her geçen gün artmaktadır.

Şekil 1.5: Hastanelerde kullanılan çevrimiçi/dijital pazarlama araçları



Kaynak: The State of Digital Marketing in Healthcare Moving Toward 2017. (n.d.). 23 Nisan 2021 tarihinde from <https://www.greystone.net/docs/default-source/surveys/the-state-of-digital-marketing-in-healthcare-in-2017.pdf?sfvrsn=0> adresinden erişildi

Ayrıca, Eckler, Worsowicz ve Rayburn (2010), sağlık sektörü çalışanlarının sosyal medyayı müşteri hizmetleri, topluluklara erişim, hasta eğitimi, kriz yönetiminde etkin bir şekilde kullanılabileceğini belirtmiştir. Tablo 1.1’de görüleceği üzere, Türkiye’de hastane sayısı bakımından önde gelen beş hastanesi ve sosyal medya takipçi sayıları da sektörün dijital pazarlama ve sosyal medyaya verdiği önemi göstermektedir.

Tablo 1.1: Türkiye’de önde gelen sağlık gruplarının sosyal medya takipçi sayıları

Sağlık Grubu	Hastane Sayısı	Takipçi Sayısı			
		Facebook	Twitter	Instagram	Youtube
Medical Park	25	218.289	14.400	86.800	15.300
Acıbadem	22	910.161	28.700	81.900	99.600
Medicana	14	221.778	8.998	33.700	14.300
Memorial	13	1.034.194	48.000	79.000	121.000

1.4 LİTERATÜRDE DUYGU ANALİZİ HAKKINDA YAPILAN ÇALIŞMALAR

Duygu analizi, metin madenciliği alanında bir araştırma konusu olup, bir metindeki duyguların ve özneliğin sayısallaştırılarak ele alınmasıdır. Bu teknik sayesinde herhangi bir metindeki duygu içeren ifadeler sayısallaştırılır ve tek bir baskın duygu sonucu veya kutbuna ulaşılır. Duygu analizi çerçevesinde en sık yapılan analiz, duygu kutbunun belirlenmesidir. Bu analiz sonucunda kutup, olumlu, olumsuz veya nötr olarak sınıflandırılır. Duygu analizi, metindeki mutluluk, aşk, şaşkınlık, kızgınlık, üzüntü veya korku gibi temel duyguların tespitinde de kullanılabilir. Duygu analizinin pazarlama açısından önemi, müşterilerin marka veya hizmetlere yönelik tutumlarının ve pazar eğilimlerinin sosyal ağ tartışmalarında ve çevrimiçi gönderilerde takip edilmesine imkan vermesinde yatmaktadır.

Duygu analizi farklı disiplinler tarafından üzerine birçok çalışma yapılmış ve bu konudaki çalışmalar artarak devam etmektedir. Dobrucalı ve İlter (2021), duygu analizi, doğal dil işleme ve benzeri anahtar kelimelerle Web of Knowledge üzerinden yaptığı literatür araştırmasında 42 makale incelemiştir. Bu makalelerin %52,36'sı iş, yönetim ve pazarlama dergilerinde yer alırken %47,64'ü ise bilgisayar mühendisliği alanındaki dergilerde çıkmıştır. Qazi, Raj, Hardaker ve Standig (2017) ise benzer bir literatür araştırmasını farklı veri tabanları üzerinde yapmışlardır. Araştırmalarına başlamadan ve eleme yapmadan hemen evvel 280 makale toplamışlardır. Dağılım ise şu şekildedir: ACM'de 70, IEEE Xplore'da 38, Science Direct'de 121, Wiley'de 15, Springer Link'de 16, ISI Web of Knowledge'da 20 makale süzülmüştür. Dolayısıyla duygu analizi çok disiplinli bir konudur. Bununla beraber her disiplinin konuya yaklaşımı farklı olmuştur. Teknik alt yapıli dergilerde duygu analizine oldukça teknolojik açıdan bakılmış ve geliştirilen algoritmalarla, çalışmaların isabet oranın arttırılmasına odaklanılmıştır. Bilgisayar mühendisliğiyle ilgili yayınlarda ise hem konuyu teknik olarak ilettilirken hem de sözlük çalışmaları gibi alt yapıyı geliştirecek diğler araştırmalarda da bulunulmuştur. İletişim, pazarlama ve iş modelini geliştirme için duygu analizi uygulamalarında ise daha çok konaklama ve e-ticaret sektörüne odaklanılmıştır.

Denetimli öğrenme yöntemiyle yapılan kapsamlı çalışmalardan biri Go, Bhayani ve Huang (2009) tarafından yapılmıştır. İngilizce dilinde yazılmış 1.600.000 Tweet küme seti kullanılmış ve naive bayes yöntemiyle %82,7, maksimum entropi yöntemiyle %83 ve destek vektör makineleriyle %82,2 oranında sonuçları doğru bulmuştur.

Pang, Lee ve Vaithyanathan (2002) duygu analizini metinleri sınıflandırmak için farklı yöntemlerle kullanmış ve naive bayes, maksimum entropi ile destek vektör makinelerini sinema değerlendirme verileri üzerine karşılaştırmışlardır. Vektör makineleri yönteminin %82,9 başarı oranı ile diğer yöntemleri geçtiğini tespit etmişlerdir.

Pang ve Lee (2004) bir başka çalışmasında nesnel ifadeleri dışarda bırakarak sadece öznel ifadelerle odaklanmış böylece ayırt ediciliği arttırmaya çalışmışlardır. Yine sinema verileri üzerinde makine öğrenmesi yöntemleri çalıştırmış ve naive bayes modeliyle %86,40, destek vektör makineleriyle %86,15 doğruluk oranına ulaşmışlardır.

Sadece sözlük tabanlı ve denetimsiz makine öğrenmesi uygulamalarda ise başarı oranı düşük olabilmektedir. Nitekim, Fernandez-Gavilanes (2016) film veri seti üzerinde yaptığı böyle bir çalışmada doğruluk oranının %69,9'da kaldığı görülmüştür.

Agarwal ve Mittala (2014) film ve kitap yorumları üzerinde destek vektör makinesi, naive bayes, maksimum entropi, boolean multinomial naive bayes (BMNB) yaklaşımlarını araştırmış ve BMNB'nin %89,5 isabet oranıyla, %87,95 isabet oranı olan destek vektör makinelerinden daha iyi sonuç verdiğini tespit etmişlerdir.

Onan ve Korukoğlu (2016) etiketli veri setinin yeterli olması durumunda etkin çözümler üretebildiğini belirtmişlerdir. Bu yöntemin en büyük eksisi etiket eklemenin maliyetli olmasıdır.

Kaya, Fidan ve Toroslu (2012), Türkiye'deki haberler hakkında yaptıkları makine öğrenmesi temelli duygu analizi araştırmalarında naive bayes, maksimum entropi, n-gram dil modeli ve destek vektör makinelerini test etmiştir. Farklı parametrelere göre algoritmaların sırasıyla elde ettikleri en iyi sonuçlar %72,05, %76,78, %76,78 ve %76,31'dir. N-gram dil modeli ve maksimum entropi en iyi sonuçları elde etmiştir.

Najadat, Al-Abdi ve Sayaheen (2018), Ürdün'deki önemli telekom şirketlerinin müşterilerinin Facebook üzerinde yaptığı yorumları öncelikle manuel olarak soru, diğer ve kanaat olarak işaretlemişlerdir. Ardından kanaatleri nötr olmaksızın olumlu ve olumsuz olarak destek vektör makineleri, naive bayes, karar ağacı ve KNN algoritmalarıyla tahmin etmişlerdir. Sırasıyla başarı oranları %95,75, %78,5, %91,98, %94,37'dir.

Denetimsiz öğrenmede ise eğitim verilerinde etiket bulunmaz (Sağlam, 2019). Bu yaklaşımın amacı, sınıflandırmadan ziyade belli özelliklere göre kümeleme yapılmasıdır. Turney (2002) denetimsiz öğrenme yöntemini değerlendirme sitesi verileri üzerinde uygulamıştır. Çalışması

üç ana adımdan oluşmaktadır. Turney, öncelikle POS (part of speech) yöntemiyle kelime öbeklerini tümcedeki görevlerine göre tespit etmiş ardından sıfat ve zarf kombinasyonlarını ayırmıştır. İkinci adımda ilgili zarf ve sıfat tümcelerinin polaritesini anlamsal olarak belirlemiş ve son adımda da değerlendirmenin ilgili konuda tavsiye ediyor (olumlu) ya da tavsiye etmiyor (olumsuz) olup olmadığını tespit etmiştir. Böyle bir yaklaşımla, otomobiller hakkındaki değerlendirmeleri %84, bankalar hakkındakileri %80, seyahat hakkındakileri %70,53 ve filmler hakkındakileri %65,83 isabet oranıyla tahmin etmiştir.

Khotimah ve Sarno (2019), çalışması bu çalışmadaki yaklaşıma benzer bir yaklaşımı farklı bir metodolojiyle otel değerlendirmeleri üzerine uygulamışlardır. Örtülü olasılık anlam analizi yöntemiyle (probabilistic latent semantic analysis) ile daha önce farklı çalışmalarda otel değerlendirme başlıklarını almışlardır. Bu başlıklar lokasyon, yemek, hizmet, konfor ve temizliktir. Daha sonra, değerlendirmelerdeki bu başlıklarla ilgili anahtar kelimeler belirlenmiş bu sayede değerlendirmelerin hangi başlıkla alakalı olduğu tespit edilmiştir. Bunun akabinde ilgili algoritma ile duygu kutbunu belirlemişlerdir. Çalışmanın elde ettiği en iyi isabet oranı %93,2'dir Yaklaşımdaki en temel eksiklik, girdi ana başlıklarının akademik bir müşteri memnuniyeti modeline oturtulmamasıdır.

Literatürde yeni gelişen konulardan biri ise müşteri memnuniyetine etki eden konu başlıklarının otomatik keşfinin yapılmasıdır. Otomatik keşif için Calheiros, Moro ve Rita (2017) LDA (latent dirichlet allocation) modelini kullanırken, Luo, Huang ve Wang (2020) ise derin öğrenme yöntemini kullanmışlardır. Tüm bu yaklaşımlar gizli kalabilecek konuların ve başlıkların ortaya çıkarılmasında açısından yararlı olsa da Khotimah ve Sarno'nun (2019) çalışmasında olduğu gibi hali hazırda literatürdeki iyi bilinen müşteri memnuniyet modelleri temel alınmamıştır.

Yarı denetimli öğrenme yöntemini bir örnek ise He ve Zhou'nun (2011) çalışmasıdır. Bu çalışmada, mevcut bir duygu sözlüğü ve etiketsiz verileri kullanarak öncelikle öğrenim sağlanmış, ardından etiketlenmemiş verilerin de tahminlenmesi için bu veri kullanılmıştır. Kullandıkları yöntemle %74,70 isabet oranına ulaşırken, denetimli öğrenme yöntemi olan naive bayes %82,53 isabet oranı yakalamıştır. Davidov, Tsur ve Rappoport (2010) alaylı ifadelerin tespiti için yarı denetimli bir yaklaşım kullanmışlardır. Tohum olarak oldukça kısıtlı adette etiketli veriden yararlanmışlardır. Bu etiketli veri, 1 ve 5 arasında değişen notlama sistemidir. 1 hiçbir alaycı ifade yoku temsil ederken 5 net bir alaycı ifadenin olduğunu ifade etmektedir. Elleriindeki öğretici veriyle 5,9 Milyon Tweet ve Amazon üzerinde yapılmış 66.000

ürün deęerlendirilmesi üzerine yarı öęreticili SASI adını verdikleri sistemlerini uygulamışlardır. Amazon veri seti için %90,6, Twitter veri seti için %94,7 isabet oranlarına ulaşmışlardır.

2. BÖLÜM

DUYGU ANALİZİNDE KULLANILAN TEKNİKLER

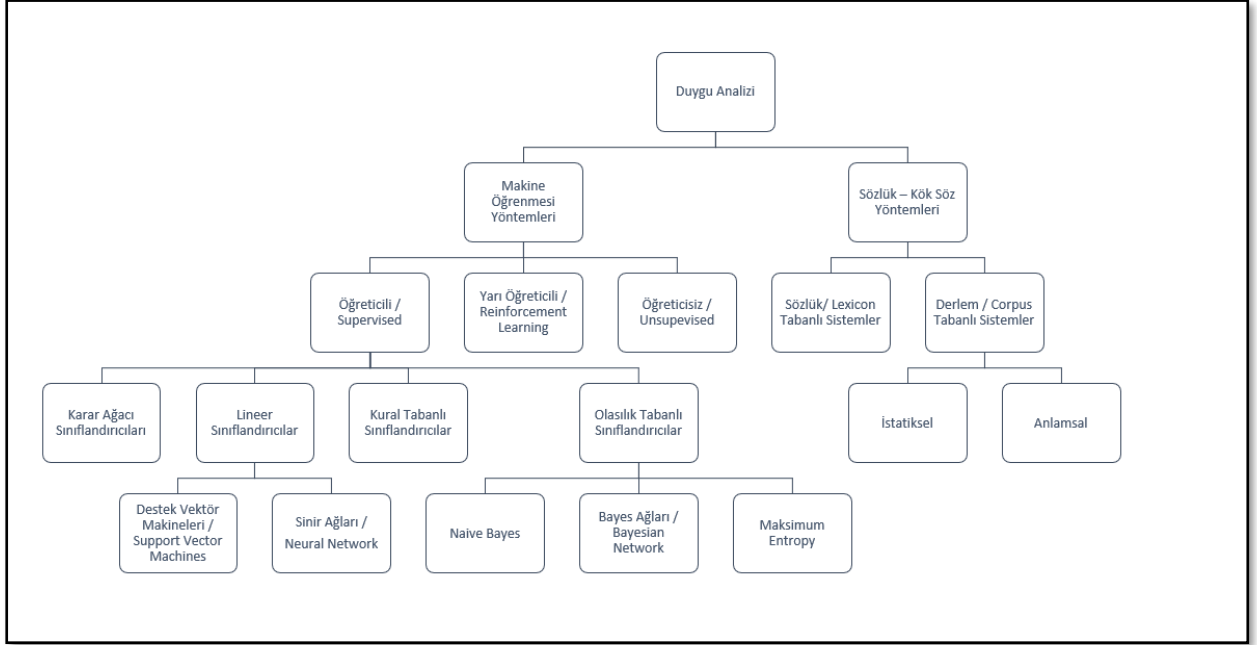
İnternet'in ve elektronik araçların yaygınlaşmasıyla beraber üretilen veri miktarı gittikçe artmaktadır. Üretilen veri miktarının günlük 59 Zettabyte olduğu tahmin edilmekte (Holst, 2021) ve günde 500 Milyon Tweet atıldığı belirtilmektedir (Whitney, 2020). Mikro blog platformlarında, kullanıcıların belli konu ve markalara yönelik duygu durumlarının analizi, önemli bir araştırma konusu olup, verinin tasniflenmesi için yapay zekâ araçlarından sıklıkla yararlanılmaktadır. Yapay zekâ literatüründe mikro bloglardaki veriler yapısal olmayan veriler olarak tanımlanmaktadır. Bu veriler, bir veri tabanı altında düzenli veya kategorize edilmiş halde değildir.

Günlük üretilen bu devasa verinin ve şirketlerdeki verilerin %80'inin yapılandırılmamış veriler olduğu tahmin edilmektedir (Balducci ve Marinova, 2018) ("Unstructured data", 2020). Metin madenciliği ve yapay zeka uygulamalarını bu kadar popüler yapan nedenlerden biri de bu büyük yapılandırılmamış veriden analiz ve anlam çıkartılarak bilgi ve içgörü oluşturma ihtiyacıdır.

Metin madenciliği sayesinde yapılandırılmamış verilerin sınıflandırılması, duygu analizi, metin özetlemesi, ilişkili dokümanların bulunması mümkün olmaktadır (Değer, 2017). Bu bağlamda duygu analizi metin madenciliğinin bir alt kolu olup bugüne kadar makine öğrenmesi ve sözlük temelli yaklaşımlar kullanılmıştır.

Yapısal olmayan verilerin değerlendirilmesi için yapay zekâ uygulamalarından makine öğrenmesi yoğun olarak kullanılmaktadır. Yapay zekâ ile veriyi kategorize etmek için üç yöntemden yararlanılmaktadır. Bunlar denetimli / danışmanlı (supervised learning), yarı-denetimli (semi-supervised / reinforced learning) ve denetimsiz / danışmansız (unsupervised learning) yöntemlerdir. Sözlük tabanlı yaklaşımlar ise derlem ve sözlük tabanlı olarak iki farklı yöntem mevcuttur (Medhat, Hassan ve Korashy, 2014). Şekil 2.1, yöntem ve yaklaşımların genel özetini göstermektedir.

Şekil 2.1: Duygu analizinde kullanılan yapay zeka yaklaşımları



Bugüne kadar yapılan duygu analizi araştırmalarında hem sözlük tabanlı hem de makine öğrenmesi yöntemleri kullanılmıştır. Fakat Türkçe dili için açık kaynaklı sözlük ve derlem kaynaklarının İngilizce kaynaklara göre nispeten kısıtlı olması sözlük tabanlı yöntemin başarı oranını ve uygulanabilirliğini sınırlamaktadır. Dehkharghani, Saygın, Yanıkoğlu ve Oflazer (2015) sözlük yaklaşımlarının daha genel maksatlı olduğunu ve farklı alanlarda, kültürlerde ilgili duyguyu tam olarak yakalayamadıklarını, bununla beraber genele hitap etmeleriyle daha ölçeklendirilebilir olduklarını belirtmişlerdir. Makine öğrenmesi uygulamaları ise alana özgü çalışmalarda daha çok tercih edilmektedir (Sağlam, 2019).

2.1. DOĞAL DİL İŞLEME VE DUYGU ANALİZİ

2.1.1 Doğal Dil İşleme Nedir

Doğal dil insanların konuştuğu dil olarak tanımlanırken, bu dilin bilgisayarlar tarafından işlenmesi ve yorumlanmasına doğal dil işleme denmektedir. Doğal dil işleme sayesinde, analiz edilen cümle ve metinlerde hangi konudan bahsedildiği ve duygu analizi yapılması beklenir.

2.1.2 Duygu Analizi ve Uygulama Alanları

Duygu analizi metin veya metin parçalarından olumlu, olumsuz ve nötr gibi farklı hislerin tespitinde veya mutlu, mutsuz, üzgün, kızgın gibi duyguların ortaya çıkarılmasında kullanılan yöntemdir. Amaç kullanıcıların belli bir ürün veya nesneye karşı kanaatini tespit etmektir (Ajitha, 2020). Duygu analizi, belge, cümle veya özellik için yapılabilir. Özellik ürün ismi olarak belirlenirse o ürüne karşı duygu durumu tespit edilebilir (Değer, 2017). Belge seviyesinde yapılan analizlerde, tüm belge taranır içinde farklı duygular da olsa, analiz çıktısı baskın olan tek bir duygu olarak belirtilir (Sağlam, 2019). Cümle seviyesinde ise aynı analiz cümle cümle yapılır ve her bir cümlenin duygu kutbu, belge seviyesindeki analize benzer şekilde olumlu, olumsuz ya da nötr olarak belirlenir.

Duygu analizinin pratik birçok uygulamasına karşın zorlukları da bulunmaktadır. Değer (2019), bu zorlukları sekiz başlık altında şu şekilde özetlemiştir: Olumsuzluk durumları, şiddetlendirme, koşul cümleleri, onaylayıcı sorular, kinayeli ifadeler, bağlaçlar, deyim ifadeleri ve arka plan bilgisi. Tüm bu kullanımlarda kelimelere yüklenen polarite yüklerinde kayma olmaktadır. Örneğin yüze gülmek deyimini yalandan dost görünmek anlamına gelirken gülmek kelimesi ise pozitif polariteye sahip olduğunda yanlış bir puanlamaya sebep olabilmektedir.

2.2. DUYGU ANALİZİNİN AMACI

Duygu analizinin etkin bir şekilde icra edilmesi şirketlere rekabet avantajı sağlayabileceği gibi müşteri memnuniyetinin artırılmasına ve olası krizlerin yönetilmesine yardımcı olabilir.

Duygu analizi sayesinde:

- Pazarlama yöneticileri, ürünleri ve hizmetleri hakkında ne düşünüldüğünü sosyal medya gibi çok fazla yazılı metin üreten mecralardan öğrenebilir veya firmalar kendileri hakkındaki genel kullanıcı kanaatini tespit edebilirler.
- Çoğu zaman el yordamıyla yapılan ve oldukça zor olan sosyal dinleme ve kategorizasyonu sürecini akademik bir modele uygun otomatikleştirilebilir.
- Süreç otomatikleştiği için çok daha hızlı ve anlık raporlamalar yapılabilir. Müşterilerin fikirleri duraksamalar olmaksızın dinlenebilir.
- Kriz anında firma konu hakkında daha hızlı haberdar olur ve konuyu yönetmeye ivedilikle başlayabilir.

- Müşterinin marka ve firma hakkındaki kanaatleri bu tezde bahsedilen yöntemle müşteri memnuniyet faktörleri veya belirlenecek başka sınıflara göre kategorileştirilebilir. Önerilen sistem farklı faktörlere sahip akademik çalışmalarda da kullanılabilir.
- Marka ve firmalar aynı zamanda rakipleri hakkındaki kanaat ve duyguları takip edebilir. Buna göre stratejiler oluşturabilir.

2.3 SÖZLÜK TEMELLİ DUYGU ANALİZİ YÖNTEMLERİ

Duygu analizinde sözlük tabanlı (lexicon) iki farklı yaklaşım bulunmaktadır bunlar sözlük tabanlı duygu sözlüğü (dictionary based) ve duygu derlemi (corpus based) tabanlıdır.

2.3.1 Duygu Derlemi (Corpus) Tabanlı Sistemler

Duygu derleminde duygu içeren kelimelerden veritabanı oluşturulur (Değer, 2017). Bu tip sözlükteki terimler duygu polaritesi olumlu, olumsuz ve nötr olarak işaretlenir ve duygu skoru da sayısal olarak tutulur (Sağlam, 2019). Derlem temelli yaklaşım, çekirdek kanaat sözcükleri listesiyle başlar ve daha sonra, ilgili bağlama özgü kanaat sözcüklerini bulmak için büyük bir külliyatta (corpus) diğer görüş sözcüklerini bulur (Medhat vd., 2014). Sözlüğe dayalı yaklaşım ise, kanaatlere ait tohum kelimelerini bulmaya dayanır ve daha sonra sözlükte bunların eşanlamlı ve zıt anlamlı karşılıklarını araştırır. Sözlük temelli yapılan analizlerde ilgili terimler duygu sözlüğünden bakılır ardından yön ve skor değerleri toplanarak puanlanır. Oluşan nihai sonuç sıfırdan büyükse olumlu, küçükse olumsuz ve tam olarak sıfır çıkarsa da nötr olarak çıkarım yapılır (Sağlam, 2019).

Duygu derlemiyle duygu sözlüğü oluşturulması için öncelikle eldeki olumlu/olumsuz olarak duygu kutbu etiketlenmiş verilerden çalışma başlanır. Ardından sözlük kapsamı adım adım geliştirilmelidir. Fakat hali hazırda olan etiketlenmiş bu derlemler belirli alanlara özgüdür (Sağlam, 2019). Kapsamı genişletmek için Sağlam (2019), literatürde sık kullanılan yöntemlerden birinin bağlaç kullanımı olduğu belirtmiştir. Bu yaklaşımda iki kelimeye denklik sağlayan “ve” bağlacı gibi bağlaçlar tespit edilir. Eldeki duygu derleminde olumlu ya da olumsuz olarak belirlenen sıfatlarla beraber “ve” bağlacının bağladığı diğer sıfat da aynı kutup ile işaretlenir. Bu sayede duygu derlemi büyütülür.

2.3.2 Sözlük (Lexicon) Tabanlı Sistemler

Sözlük tabanlı yaklaşımda kelimelerin birlikte belirmesi ve bunların istatistiklerini ve frekanslarını hesaplayarak anlam çıkarılmaya çalışılır. Sözlük tabanlı yaklaşımlarda en sık kullanılan veri tabanı Wordnet'tir. Türkçe Wordnet olarak BalkaNet ve KeNet bulunmaktadır. KeNet adetsel olarak daha kapsayıcı olup 77,330 anlamdaş kelime dizisi (synset) bulunmaktadır. Bu kelimeler cümledeki isim, fiil, sıfat, zarf, zamir gibi görevlerine göre de işaretlenmiş haldedirler (Bakay, Ergelen, Sarıms, Yıldırım, Arıcan, Kocabalıoğlu ve Yıldız, 2021). Diğer kullanılan sözlük tipi ise SentiWordNet'tir. Bu sözlükte kelimelerin duygu puanlarının bulunduğu veriler bulunmaktadır. Türkçe için yapılan tek SentiWordNet çalışması Dehkarghani ve arkadaşları (2017) tarafından yapılmış ve 13.527 adet anlamdaşın değerlendirmesi mevcuttur ("Polarity Resources", 2021). Kapsayıcılık açısından ilgili çalışma dar kalmakta ve dolayısıyla Türkçe için genel bir SentiWord halen bulunmadığı söylenebilir. Bu nedenle, çoğu zaman, araştırmacılar kendi duygu sözlüklerini oluşturmakta veya İngilizce SentiWordNet'i çevirmek suretiyle çalışmalar yapmaktadırlar (Aydın ve Güngör 2020).

2.4 MAKİNE ÖĞRENMESİ YÖNTEMLERİNE GENEL BAKIŞ

Makine öğrenmesi yöntemleri üç ana başlıkta incelenebilir bunlar: Denetimli / danışmanlı, yarı denetimli / yarı danışmanlı ve denetimsiz / danışmansız yöntemlerdir. Bu üç yaklaşımı birbirinden ayıran en önemli girdi ise eldeki verinin ne kadarının etiketli olup olmadığıdır.

2.4.1 Denetimli/Danışmanlı Öğrenme (Supervised Learning)

Öğreticili makine öğrenmesinde eşleme / haritalamanın yapılması için girdi ve çıktılar /etiketler çift olarak hazır olmalıdır (Lee ve Shin, 2020). Dolayısıyla, etiketleme belli bir girdi için araştırılmak istenen çıktıya göre işaretlenmelidir. Tweet'lerin duygu kutuplarının olumlu, olumsuz şekilde işaretlenmesi bir çeşit etiketlemedir. Etiketli veri, yapay zekanın eğitiminde kullanılan bir girdidir.

2.4.2 Denetimsiz/Danışmansız Öğrenme (Unsupervised Learning)

Etiketli veri girdisi yeterli miktarda olabileceği gibi hiç de olmayabilir. Eğer eğitim seti tümüyle etiketliyse öğreticili yöntemler kullanılabilirken, hiçbir etiketleme olmaksızın yapay

zeka uygulaması yapılmak isteniyorsa öğreticisiz algoritmalar kullanılmalıdır. Yarı öğreticili sistemlerde ise kısıtlı etiketli veri mevcuttur, verinin büyük kısmı ise etiketsizdir (Onan ve Korukoğlu, 2016). Lee ve Shin (2020), yarı öğreticili yönetimi birden fazla makine öğrenimi beraber kullanılması olarak tanımlamaktadır. Örneğin, öğreticisiz makine öğrenmesi yöntemiyle elde edilen çekirdek veri setinin, ardından öğreticili makine öğrenmesiyle sınıflandırmasının yapılması gibi. Bu tip bir uygulama özellikle eldeki verinin etiketlenen çok uzun süreceği veya maliyetli olacağı durumlarda uygulanabilmektedir. Nitekim, denetimli öğrenme ile hazırlanan sınıflandırma modellerinin en büyük eksisi başka bir alanda kullanılmak istendiğinde tekrar etiketleme sürecine ihtiyaç duymasıdır. Yarı öğreticili ve öğreticisiz modeller bu anlamda daha genel geçer ve ölçeklendirilebilir.

2.5 DENETİMLİ/DANIŞMANLI ÖĞRENME ALGORİTMALARI

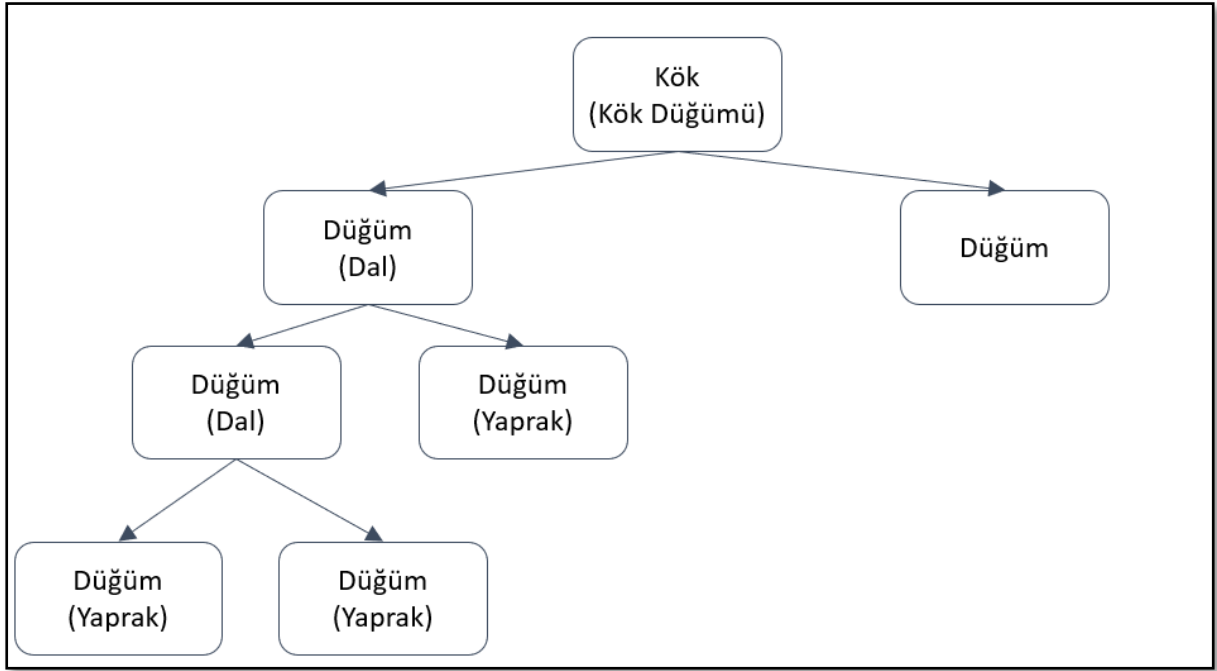
2.5.1 Karar Ağacı Sınıflandırıcılar

Karar ağacı, veri madenciliği makine öğreniminde kullanılan tahmine dayalı modelleme yaklaşımlarından biridir. Bu yöntem çerçevesinde kök, düğüm ve dallardan oluşan ağaç yapısı oluşturulmaktadır. Karar ağacında başlangıç noktası kök veya kök düğümü olarak adlandırılmaktadır. Kök düğümün altında sıralanan düğümler ise ya dal ya da yaprak olarak isimlendirilmektedir. Şekil 2.2’de görüldüğü üzere, eğer bir düğüm okla işaret edildiği gibi kendisi de başka düğümlere işaret ediyorsa bu bir dal tipinde düğümdür. Fakat, bir düğüm okla işaret edildiği gibi kendisi de başka düğümlere işaret etmiyorsa bu bir yaprak tipi düğümdür.

Karar ağaçları kendi içinde ikiye ayrılmaktadır. Tahminlenmek istenen sonuç bir sınıfsa (sonlu değişken) sınıflandırma karar ağacı oluşturulur. Fakat tahmin edilen sonuç gerçek bir sayı (sürekli değişken) ise regresyon ağacı analizi kullanılır.

Karar ağaçlarının kurulması ve değişkenlerin seçimi için iki farklı metrik ağırlıkla kullanılmaktadır. Bunlar gini safsızlık (gini impurity) ve bilgi edinimi (information gain) metrikleridir.

Şekil 2.2: Karar ağacı sınıflandırıcılarına genel bakış



Gini safsızlık endeksi aşağıdaki formüle göre hesaplanmaktadır:

$$I_{G(p)} = 1 - \sum_{i=1}^J p_i^2$$

J sınıf adedini göstermekte olup $i \in \{1,2, \dots, J\}$ ve p_i sette sınıf i ile etiketlenmiş öğelerin oranıdır.

Bilgi edinimi (information gain) formülünü ise Değer (2017) şu şekilde belirtmiştir:

“Bir veri setinin C_1, C_2, \dots, C_n şeklinde birkaç sınıftan oluştuğunu ve T'nin sınıf değerlerini gösterdiğini düşünürsek, bir sınıfa ait olasılık $P_i = (C_i \setminus |T|)$ olur ve sınıflara ait entropi değeri aşağıdaki gibi hesaplanır.

$$Entropi(T) = - \sum_{i=1}^n \log_2(P_i)$$

Bilgi Kazancı, sınıf niteliğinin entropisinin tüm özellik vektörlerinin entropisi çıkartılarak her özellik için hesaplanmasıdır. KA algoritmasında en iyi ayrılma noktasını bulmak için bu yöntemler ile hesaplama yapılır. Veri setinde B öz niteliğine göre T sınıf değerleri T_1, T_2, \dots, T_n

şeklinde alt kümelere ayrıldığı durumda, B öznitelik değerleri kullanılarak T sınıf değerlerinin bölünmesi durumunda elde edilecek kazanç şu şekilde olur:

$$Kazanç (B, T) = Entropi (T) - \sum_{i=1}^n \frac{|T_i|}{|T|} Entropi(T_i)$$

$$Bölünme bilgisi(B) = - \sum_{i=1}^k \frac{|T_i|}{|T|} \log_2\left(\frac{|T_i|}{|T|}\right)$$

Ardından bölünme bilgisi ile B özniteliğinin değeri belirlenir ve son olarak da kazanç oranı hesaplanır.

$$Kazanç Oranı = \frac{Kazanç (B, T)}{Bölünme Bilgisi (B)}$$

»

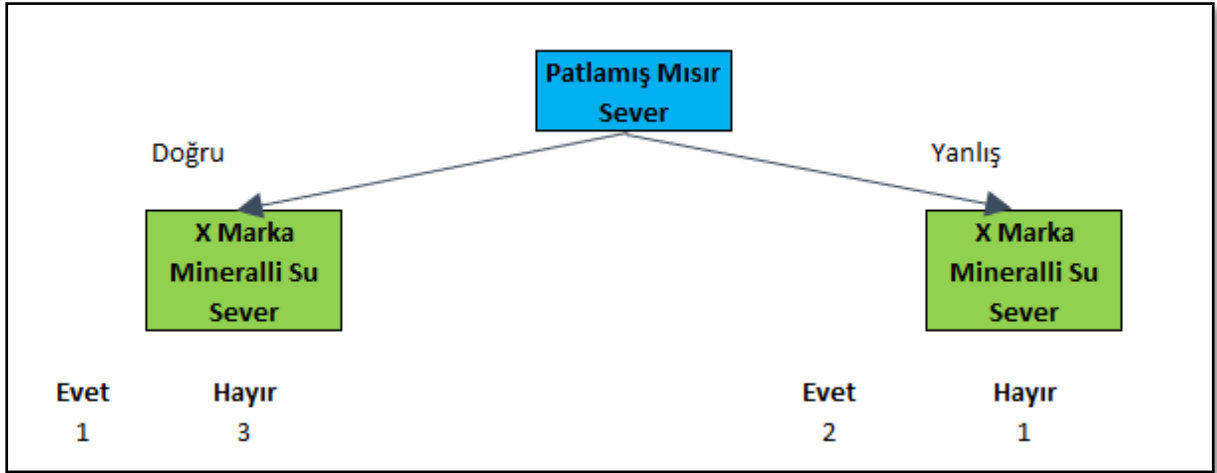
Gini safsızlık endeksi daha sık kullanılan bir yöntem olduğu için bir örnek üzerinde incelenmeye değer bulunmuştur.

Tablo 2.1: Türkiye’de önde gelen sağlık gruplarının sosyal medya takipçi sayıları

Patlamış Mısır Sever	Gazoz sever	Yaş	X Marka Mineralli Suyu Sever
Evet	Evet	7	Hayır
Evet	Hayır	12	Hayır
Hayır	Evet	18	Evet
Hayır	Evet	35	Evet
Evet	Evet	38	Evet
Evet	Hayır	50	Hayır
Hayır	Hayır	83	Hayır

Tablo 2.1’de gösterilen örnekteki amaç, bir kişinin yaşına, gazoz ve patlamış mısır sevip sevmeyeceğine göre X marka mineralli suyu sevip sevmeyeceğine karar ağacıyla tahmin edilmesidir. Böyle bir karar ağacının yapılandırılması için Gini safsızlık endeksi her bir girdi için hesaplanmalıdır.

Şekil 2.3: Karar ağacı sınıflandırıcıları örnek problem – ağaç oluşturma ilk adım



Bu bir örnekte formül şu şekilde oluşur:

$$\text{Gini safsızlık endeksi} = 1 - (\text{Evet Olasılığı})^2 - (\text{Hayır Olasılığı})^2$$

Öncelik sol yapraktaki Gini endeksi hesaplanırsa:

$$\text{Gini safsızlık endeksi} = 1 - \left(\frac{1}{1+3}\right)^2 - \left(\frac{3}{1+3}\right)^2$$

İşlem yapıldığında sonuç 0,375 olarak bulunur.

Sağ yapraktaki Gini endeksi hesaplanırsa:

$$\text{Gini safsızlık endeksi} = 1 - \left(\frac{2}{1+2}\right)^2 - \left(\frac{1}{1+2}\right)^2$$

İşlem yapıldığında sonuç 0,444 olarak bulunur.

Her iki yaprak için Gini endeksleri bulunmakla beraber bir yaprakta 4 diğer yaprakta 3 verinin olması sebebiyle ağırlıklandırma yapılmalıdır.

Patlamış mısır sever girdisinin ağırlıklandırılmış Gini safsızlık endeksi

$$= \frac{4}{7} \times 0,375 + \frac{3}{7} \times 0,444$$

İşlem yapıldığında sonuç 0,405 olarak bulunur.

Bu hesaplamalar, tüm sınıflar için yapılmalı ve nihai sınıflandırma ağacı oluşturulmalıdır.

Bu örnek çerçevesinde gazoz sever sınıflandırması Gini safsızlık endeksi hesaplandığında 0,214 değeri bulunur. Yaş için benzer hesaplamalar yapılmak istendiğinde yaş nümerik olduğunda hesaplama farklı yapılır. Öncelikle yaş küçükten büyüğü sıralanmalı ve her yaş sırasının aritmetik ortalama değeri hesaplanmalıdır. Çıkan safsızlık endekslerinden minimum olan 0,343 alınır.

Tablo 2.2: Karar ağacı sınıflandırıcıları ortalama yaşa göre Gini endeksi oluşturulması

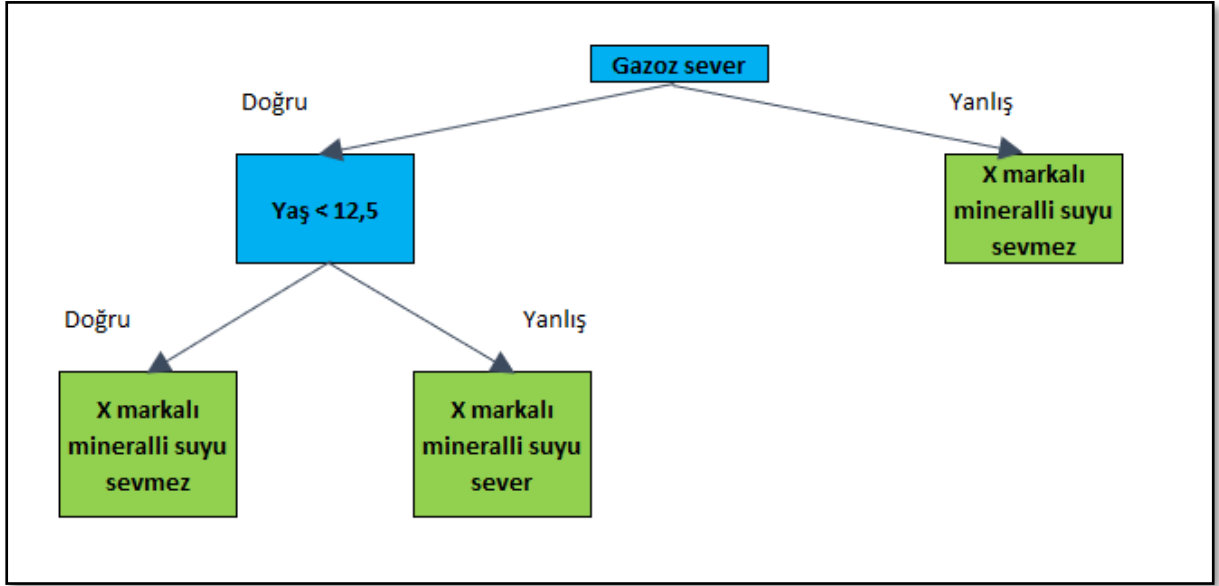
Ortalama Yaş	Yaş	X Marka Mineralli Su Sever	
15	9,5	7	Hayır
		12	Hayır
36,5	26,5	18	Evet
		35	Evet
66,5	44	38	Evet
		50	Hayır
		83	Hayır

Tablo 2.3: Karar ağacı sınıflandırıcıları ortalama yaşa göre Gini endeksi hesaplanması

Ortalama Yaş	Gini Safsızlık Endeksi
9,5	0,429
15	0,343
26,5	0,476
36,5	0,476
44	0,343
66,5	0,429

Böylece tüm Gini endeksleri hesaplanmış olunur ve 0,205 değeriyle en düşük olan Gazoz sever girdisi oluşturulacak ağacın giriş noktası olarak seçilmiş olur. Ardından gini safsızlık endeksi minimize edilecek şekilde Şekil 2.4'teki karar ağacı oluşturulmuş olur. Ağacın kullanımı ise oldukça kolaydır. Eğer patlamış mısır ve gazoz seven, 15 yaşında birisinin X markalı mineralli suyu sevip sevmediğini tahmin etmek istersek bu ağacı kullanabiliriz. Karar ağacında kişi gazozu sevdiği için sol düğüme yönelir, yaşı da 12,5'tan büyük olduğu için yaş düğümünde sağa doğru yönelir ve bu kişinin X markalı mineralli suyu seveceği tahmini yapılır.

Şekil 2.4: Karar ağacı sınıflandırıcıları örnek problem – ağaç oluşturma nümerik adım gösterimi



Karar ağacı kullanmanın faydaları ve kısıtları bulunmaktadır. Faydaları şu şekildedir:

- Ağaçlar grafiksel olarak gösterilebildiği için anlaşılması ve yorumlanması kolaydır.
- Hem sayısal hem sınıfsal değerler ile çalışabilir
- Verilerin normalizasyonu gerekmediği için veri hazırlanma süreci nispeten kısadır.
- Büyük veri setleriyle hızlı çalışır.

Kısıtları:

- Eğitim setindeki ufak değişiklikler karar ağacı yapısında büyük değişikliklere sebep olabilir ve bu da tahmin edilen sonuçlara etki eder.
- Kategorilerde yeterli veri bulunmazsa sonuçlar etkilenir ve yanlış sonuçlar oluşabilir
- Kullanılan algoritma yerel optimal noktalarının tespit etmektedir. Fakat büyük bir sistem içinde birçok optimal noktanın seçilmesi sistem genelindeki optimal noktanın bulunduğu anlamına gelmeyebilir.

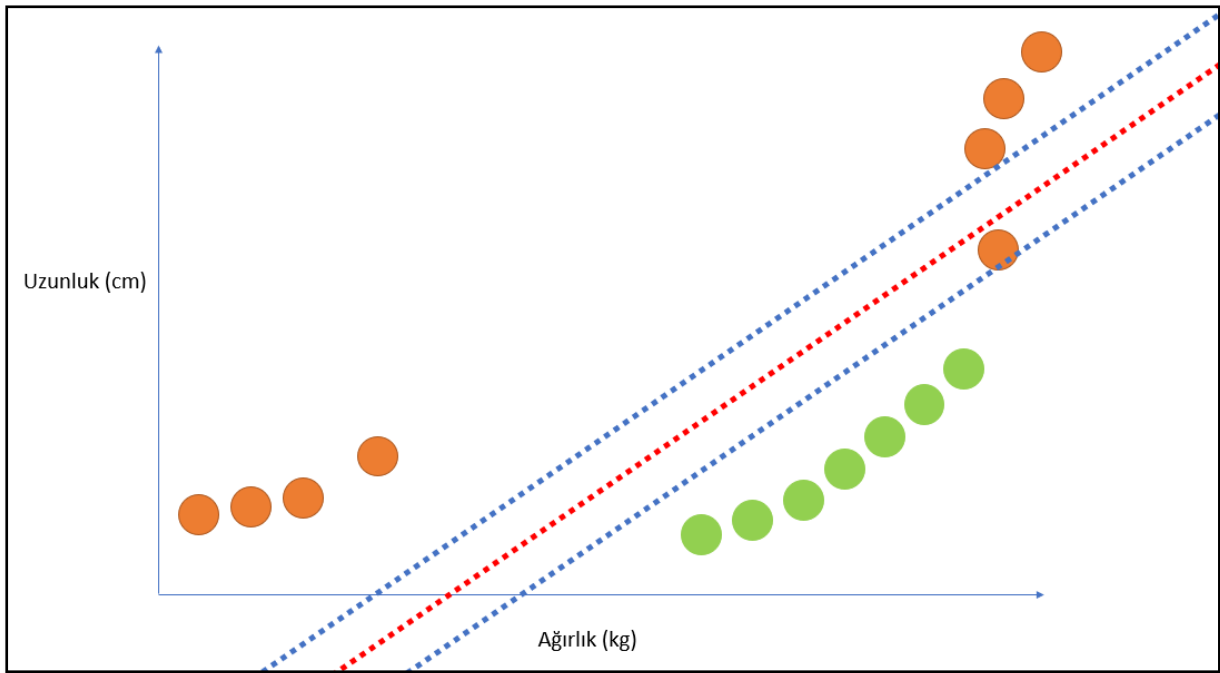
2.6.2 Lineer Sınıflandırıcılar

Bu bölümde sıklıkla kullanılan iki lineer tip sınıflandırıcı ele alınacaktır. Bunlar destek vektör makineleri ve sinir ağlarıdır.

2.6.2.1 Destek vektör makineleri (DVM)

DVM, sınıflandırma için kullanılan popüler bir algoritma olup birçok çalışmada uygulanmış ve iyi performans göstermiştir. DVM, tek veya çok boyutlu uzayda verileri birbirinden bir alt uzay boyutuyla ayırarak çalışır. Eğer 3 boyutlu bir veri seti varsa düzlemle, eğer 2 boyutlu bir veri varsa doğruyla veri setlerini birbirinden ayırır. DVM modelleri tüm sınıflandırmaları olabilecek en optimum hiper düzlem ve en yüksek marj ile ayırmayı hedefler.

Şekil 2.5: Destek vektör makinelerinin veri kategorizasyon örneği



Örneğin, elimizde bir grup hayvanın boy ve ağırlık verisi olsun. Bu hayvanları obez olup olmamalarına göre sınıflandırıp ayırmak istediğimizde şekil 2.5'teki gibi ilgili koordinatlara noktalar koyulmalıdır. Turuncu noktalar obez olmayan hayvanları yeşil olanlar ise obez hayvanları temsil etmektedir. Bu verileri en iyi şekilde ayıran çizgi ise kırmızı çizgidir. Bu çizgi destek vektör sınıflandırıcısı olarak geçmektedir. Mavi çizgiler ise marj çizgileri (soft margins) olup veri noktalarının diğer noktalarla olan ilişkisi hakkında fikir vermektedir. Marjın içinde sadece bir turuncu nokta bulunmaktadır. Bu nokta obez olmadığı halde obez olarak sınıflandırılmış bir veriyi temsil etmektedir. Eğer veri seti uzunluk, ağırlık ve yaş gibi 3 boyutlu olsaydı DVM bir düzlem olarak belirtilirdi.

Değer (2017), DVM formüllerini şu şekilde belirtmiştir:

“ $X_i, i= 1,2,...,N$ eğitim setinin özellik vektörüdür. Bunların w_1, w_2 (ya da $-1, +1$) sınıf etiketleri ile, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden doğrusal olarak ayrılabilirdi varsayılır. İlgili hiper düzlem denklemi aşağıdaki gibidir.

$$g(x) = w^T x + w_0 = 0$$

Destek vektörlerinin, sınır çizgisine olan uzaklıkları ise genişlik olarak tanımlanmaktadır. Genişlik w ile gösterilirken, hiper düzlemin uzaydaki gerçek konumunu (w_0) ifade eder. Herhangi bir w_1 veya w_2 sınıfı tercih etmek istiyoruz, noktalar arası uzaklık şöyle hesaplanır:

$$d = \frac{|w_0|}{\sqrt{w_1^2 + w_2^2}}$$

DVM için en optimal noktanın tespiti içinde aşağıdaki amaç fonksiyonu minimize edilirken ilgili kısıtlar dikkate alınır

Amaç fonksiyonu

$$\text{Min}_{w,b} \frac{1}{2} w^T w$$

Kısıtlar

$$Y_i (w^T x_i + b) \geq 1 \quad \forall_i$$

2.6.2.2 Sinir Ağları

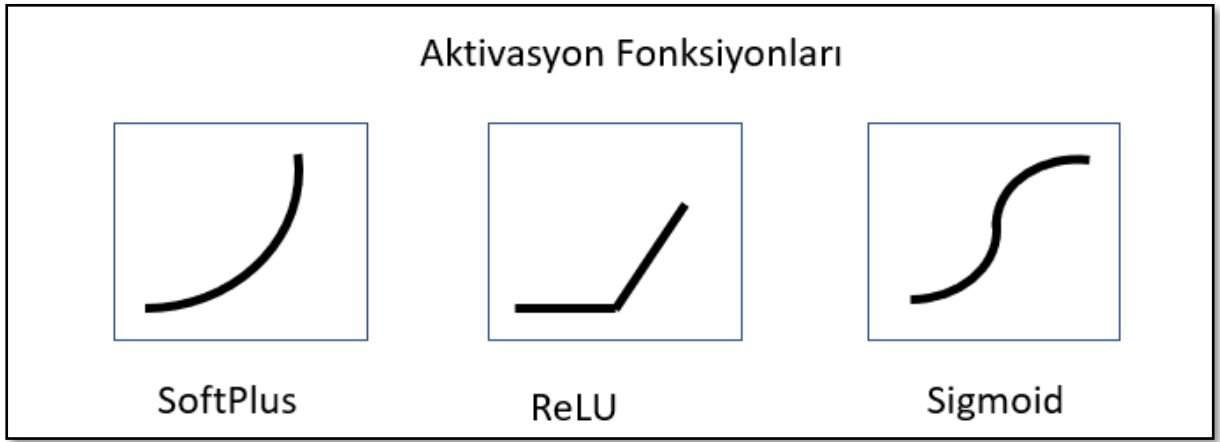
Sinir ağları öğreticili bir yapay zeka uygulaması olup, insanların sinir ağlarının iletişiminden ilham alınarak modellenmiştir. Tıpkı bir insanın sinir ağlarında olduğu gibi nöron denem temel birimlerden oluşmaktadır. Nöronlara yapılan girdiler vektör (X_i) olarak gösterilmektedir. Bu i 'nci metindeki kelime frekanslarıdır. Her bir nöron ile ilişkilendirilmiş A vektörüyle gösterilen ağırlıklandırılmalar bulunmaktadır. Sinir ağlarının fonksiyonu şu şekilde özetlenmiştir:

$$p_i = A \cdot \bar{X}_i$$

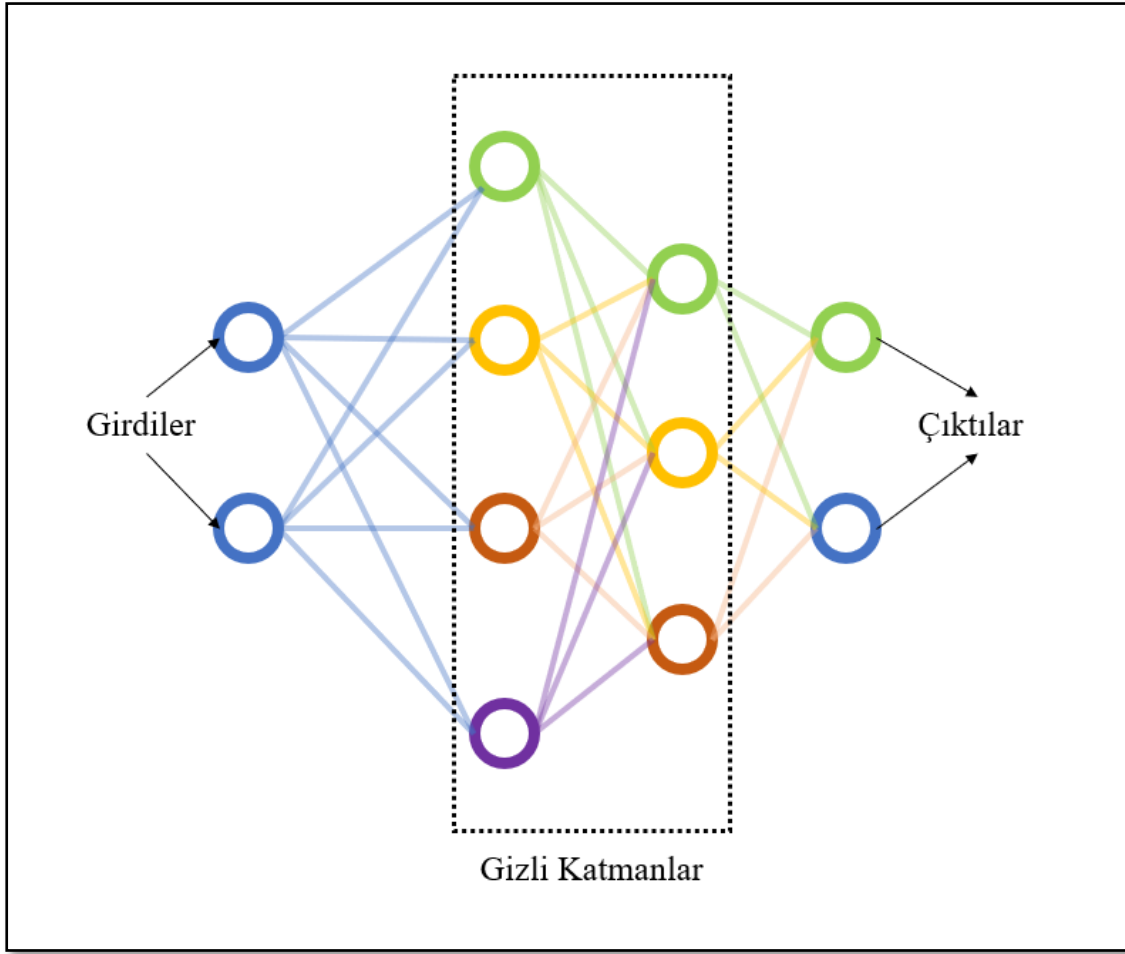
p_i tahmin fonksiyonunda sınıflandırma ismine denk gelmektedir (Medhat, 2014). Sinir ağları kullanımında en büyük dezavantaj işleyişinin karar ağacı kadar net anlaşılabilmesidir. Bununla beraber gürültü içeren veri setlerinde ve doğrusal olmayan modellerle de kullanılması avantajlı yöndür.

Tipik bir sinir ağı, bir veya birden fazla girdiyle çıktı nöronuna sahip olabilir. Girdi ve çıktılar arasındaki nöronlar gizli katman olarak adlandırılmaktadır. Gizli katman sayısı sadece bir katman olabildiği gibi birden çok da olabilir. Gizli katman içindeki nöronlar birbirlerine oklarla bağlıdır. Her bir nöron ise belli bir fonksiyonu temsil etmektedir. En sık kullanılan üç fonksiyon tipi şekil 2.6'daki gibidir. Bu fonksiyonların şekillenmesi içinse parametreler gereklidir. İlgili parametreler geri yayılım (backproagation) denen bir yöntem ile bulunur ve nöronları birbirine bağlayan okların üzerinde yer alır. Tüm bu fonksiyonlar parametrelerle şekillendikten sonra birleşerek girdi ve çıktıları en iyi temsil edecek şekle ulaşır.

Şekil 2.6: Sinir ağları genel gösterim – aktivasyon fonksiyonları



Şekil 2.7: Sinir ağları genel gösterim



2.6.3 Kural Tabanlı Sınıflandırıcılar

Kural tabanlı sınıflandırıcılarda, veri alanı bir dizi kural ile modellenir. Kurallar için şartlar oluşturulur. Tablo 2.4'teki gibi bir veri tabanımız olduğunu varsayalım. Bu tablodan örnek şu şekilde kurallar çıkarılabilir:

- (Kan Tipi = Sıcak kanlı) ve (Doğum tipi = Yumurtlar) → Kuş
- (Kan Tipi = Soğuk kanlı) ve (Doğum tipi = Yumurtlar) ve (Suda yaşar= Hayır) → Yılan

Kural tabanlı sınıflandırıcılarda kapsam oranı ve kural doğruluğu önemli metriklerdendir. Kural kapsamı, bir kuralın, toplam kayıtlardan yüzdesel olarak ne kadarını kapsadığını gösterirken, kural doğruluğu, bir kuralın, tahmin etmesi gereken sınıfı yüzdesel olarak ne doğrulukta tahmin ettiğini göstermektedir.

Örneğin, Tablo 2.4'teki veri tabanı için (Suda yaşar = Evet) → Balık diye bir kural olduğunu varsayalım. Bu kuralın kapsamı $2/6$ 'dır, bu da %33 etmektedir. Yani 6 kayıttan ikisinde bu

kural bulunmakta. Bulunduğu iki kayıttan birinde sonuç memeli iken diğerinde ise balık sınıfı çıkmaktadır. Dolayısıyla doğruluk oranı 50%'dir.

Kural tabanlı sınıflandırıcılarda sıklıkla karşılaşılabilen bazı problemler ise aynı sınıf sonucuna ulaşabilen birden fazla kural olması durumudur. Bu durumda kurallara önem sırası atfedilerek çözüme ulaşılabilir. Bunun için iki farklı yaklaşım bulunmaktadır. Bunlar büyüklüğü göre sıralama ve kural sıralamadır.

Büyüklüğe göre sıralamayı bir örnekle anlatmak gerekirse:

Aşağıdaki iki kuralında herhangi bir sınıfı doğru karşıladığını varsayalım.

- Özellik1 ve Özellik2 → Kural1
- Özellik1 ve Özellik2 ve Özellik3 ve Özellik4 → Kural2

Kural2 daha fazla özellekle tahminleme yaptığı için bu yaklaşım çerçevesinde Kural1'in önüne geçecek ve kullanılacaktır. Bu yöntem büyüklüğe göre sıralama denmektedir.

Kural sıralama ise iki farklı şekilde icra edilebilmektedir. Bunlar sınıf bazlı veya kural bazlı yaklaşımlardır. Sınıf bazlı yaklaşımda en sık geçen sınıfın tahminlemede kullanılan kural seti tercih edilmektedir. Kural bazlı yaklaşımdaysa, kurallar belli metriklere göre öncelik sıralaması alınır. Kuralların sıralamasında kullanılan bazı metrikler kuralın doğruluk oranı, kapsamı veya içerdiği özellik sayısı olabilir.

Tablo 2.4: Kural tabanlı sınıflandırma örneği tablosu

Canlı İsmi	Kan Tipi	Doğum yapabilir (Yumurtlamaz)	Uçabilir	Suda Yaşar	Sınıfı
İnsan	Sıcak kanlı	Evet	Hayır	Hayır	Memeli
Yılan	Soğuk kanlı	Hayır	Hayır	Hayır	Sürüngen
Somon	Soğuk kanlı	Hayır	Hayır	Evet	Balık
Balina	Sıcak kanlı	Evet	Hayır	Evet	Memeli
Kurbağa	Soğuk kanlı	Hayır	Hayır	Bazen	Amfibi
Güvercin	Sıcak kanlı	Hayır	Evet	Hayır	Kuş

2.6.4 Olasılık Tabanlı Sınıflandırıcılar

Olasılık tabanlı sınıflandırıcılar, sınıflandırma için karışım modellerini kullanır. Karışım modeli, her sınıfı oluşturan bileşenler olduğunu varsayar. Her karışım bileşeni, o bileşen için belirli bir terimi örnekleme olasılığını sağlayan üretici bir modeldir. Bu tür sınıflandırıcılara

aynı zamanda üretken sınıflandırıcılar da denir. En ünlü olasılık sınıflandırıcılarından üçü sonraki bölümlerde tartışılmaktadır.

2.6.4.1 Naive Bayes

Naive Bayes, en temel ve en yaygın kullanılan sınıflandırıcıdır. Naive Bayes sınıflandırma modeli, belgedeki kelimelerin dağılımına bağlı olarak bir sınıfın sonraki olasılığını hesaplar.

Model, belgedeki kelimenin konumunu dikkate almadan, BOW'un öznitelikleriyle çalışır. Belirli bir öznitelik setinin belirli bir etikete ait olma olasılığını tahmin etmek için Bayes teoremini kullanır (Medhat, 2014).

Bayes Teoremi:

$$P(\text{etiket}|\text{öznitelik}) = \frac{P(\text{etiket}) \times P(\text{öznitelik}|\text{etiket})}{P(\text{öznitelik})}$$

$P(\text{etiket})$ bir etiketin herhangi bir öznitelik tarafından belirlenme olasılığı olarak tanımlanmaktadır. $P(\text{etiket}|\text{öznitelik})$ ise belli bir öznitelik seçildiğinde ilgili etiketin belirlenme olasılığıdır. Naive Bayes çerçevesinde tüm özniteliklerin bağımsız olduğu varsayımına göre denklem tekrar yazılırsa, şu şekilde olacaktır:

$$P(\text{etiket}|\text{öznitelik}) = \frac{P(\text{etiket}) \times P(\text{Ö1}|\text{etiket}) \times P(\text{Ö2}|\text{etiket}) \dots \times P(\text{Ön}|\text{etiket})}{P(\text{öznitelik})}$$

Denklemden öznitelik "Ö" olarak kısaltılmıştır.

2.6.4.2 Bayes Ağları

NB sınıflandırıcısının ana varsayımı, özniteliklerin bağımsızlığıdır. Diğer bir varsayımsa, diğer tüm özelliklerin tamamen bağımlı olduğunu varsaymaktır. Bu varsayımlar uygulamada zorluklara sebep verdiğinden, düğümleri rastgele değişkenleri ve kenarları koşullu bağımlılıkları temsil eden, yönlendirilmiş döngüsel olmayan bir grafik olan Bayes Ağ modeline ihtiyaç duyulmasına sebep olmuştur. Bununla beraber, Bayes Ağlarının hesaplama karmaşıklığı yüksek olduğundan sık kullanılmamaktadır.

2.6.4.3 Maksimum Entropi

Maksimum entropi modeli özünde lojistik regresyon tekniğinin genelleştirilmesidir. İkisi arasındaki temel fark lojistik regresyon sadece ikili (binary) sınıflandırma için çalışırken

maksimum entropi birçok sınıfın işlenmesini icra edebilmektedir. Berger, Pietra ve Pietra V. (1996) maksimum entropi tekniğini bilinen tüm verinin modellenmesi ve bilinmeyen veriler hakkında hiçbir varsayım yapılmaması şeklinde yorumlar. Modelin genel formülü ise şu şekildedir:

$$P_w(y|x) = \frac{\exp(w^T f(x, y))}{\sum_{y'} \exp(w^T f(x, y'))}$$

Formülde x bağlamı, y bağlamdaki etiketi/sınıfı ve w ise vektörün ağırlığını temsil etmektedir. Vektör fonksiyon $f(x, y)$ ise x bağlamındaki y etiketli bir özelliği belirtmektedir (Yu ve arkadaşları, 2011).

$$P(c|x) = \frac{e^{y^c}}{\sum_{c'=1}^m e^{y^{c'}}$$

$$y^c = w_c^T x + b_c$$

Çalışmada kullanılan algoritma ise yukarıdaki gibi belirtilmiştir (“SdcaMaximumEntropyMulticlassTrainer class”, t.y.). İlgili formül, doğrusal model eğitimi gerçekleştirerek çok sınıfa sahip problemlerin çözümünde kullanılabilir.

m adedinde sınıf olduğunu ve n adedinde özellik olduğunu varsayılırsa, w_c vektör katsayısı c 'inci sınıfa atanmaktadır, c 'nin değeri 1 ve m arasındadır. $P(c|x)$ ise özellik vektörünün x olduğunda c sınıfının gözlenme ihtimalini göstermektedir

2.7 DUYGU ANALİZİNDE VERİ ÖN İŞLEME

Mikro blog platformlarında, müşteri beyanlarının hem duygu analizi yapılması hem de kategorize edilmesi hedeflenmektedir. Dolayısıyla sözlük bazlı yaklaşımlardan ziyade makine öğrenmesi yöntemleri bu hedef için daha uygundur. Başarı oranını arttırmak içinse öğreticili makine öğrenmesi yöntemlerinden maksimum entropi ve destek vektör makineleri yöntemi analiz için en uygun modeller olarak belirlenmiştir.

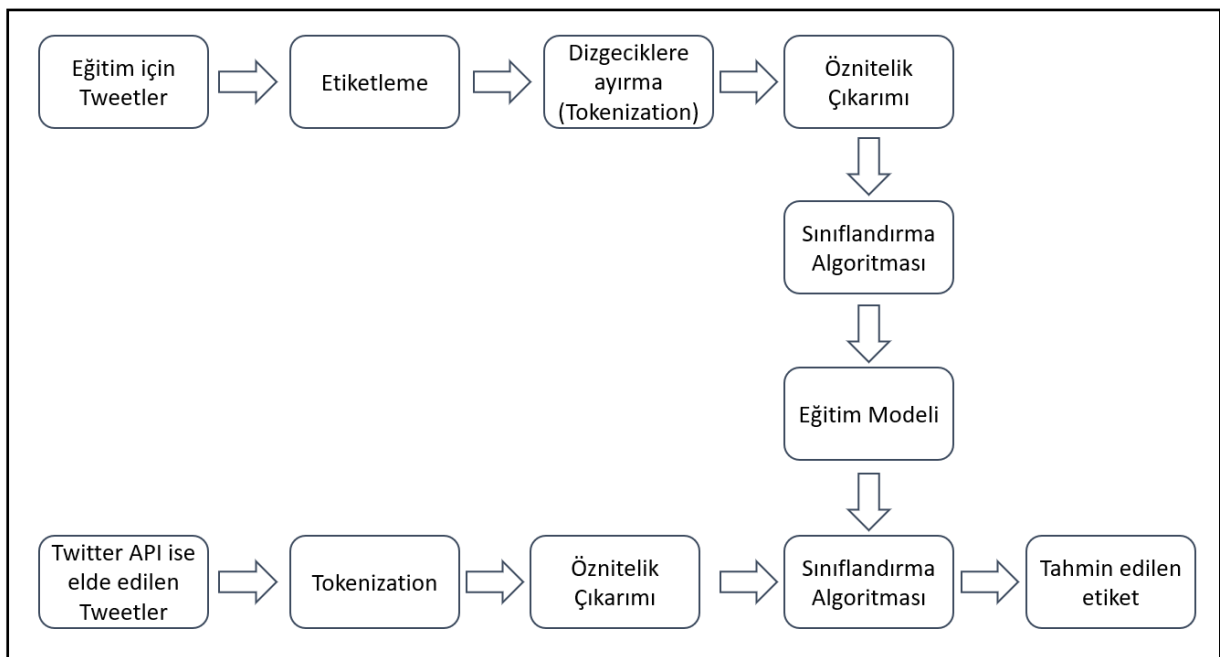
Bu modeller sayesinde müşteri beyanın sadece ton ve sınıflanan müşteri memnuniyeti konusu değil başka kategorilerin de sınıflaması yapılabilmektedir. Bu duruma örnek olması amacıyla,

müşteri ifadesinin niteliği de yani bu ifadenin şikayet, teşekkür, genel, istek/soru kategorisi de çalışma kapsamına eklenmiş bulunmaktadır.

2.5.1 Ham veri indirilmesi ve etiketleme

Duygu analizi çerçevesinde yapılacak analizler öncesi ham veri toplanması veya indirilmesi gereklidir. Verinin oldukça büyük olmasından dolayı çalışma yapılacak mikro blog uygulamasının API uygulamaları bu iş için kullanılmaktadır. Bu yöntem mümkün olmadığında veri kazıma (scraping) araçları da kullanılabilir. Toplanan verilerde mükerrer olan veriler veya ilgisiz olanlar temizlenir. Denetimli öğrenme uygulamaları yapmak içinse toplanan veriler etiketlenir. Çıktı olarak hangi sınıfların bulunması isteniyorsa, ham veri buna göre etiketlenir. Şekil 2.8'deki sürece uygun olarak, bu araştırma çerçevesinde indirilen müşteri beyanları üç farklı kategoriye göre etiketlenmiştir. Bu kategoriler: Duygu tonu, memnuniyet ve nitelik kategorileridir. Oluşturulan veriler daha sonra veri ön işleme çerçevesinde temizlenmiş ardından dizgeciklere ayrılarak yapay zeka algoritmalarının kullanabileceği formata dönüştürülmüştür.

Şekil 2.8: Yapay zeka süreçleri için ham veri indirilmesi ve etiketleme süreci



2.5.3 Dizgeciklere ayırma (Tokenization)

Müşteri ifadelerinin algoritma içinde işlenebilmesi için öncelikle tokenization denen süreçle kelimelere ve harflere ayrılır. Ardından noktalama işaretleri bağlaç gibi tümceler temizlenir,

tüm büyük harfler küçük harfe çevrilir. Ardından öznitelik çıkarımı için n-gram yöntemi kullanılmaktadır.

2.5.4 N-gram yöntemi

N-gram, hedef metinden bilgi elde etmek için kullanılan, DDİ, karakter veya sözcük temelli sınıflandırma yapan istatistiksel yöntemdir. Çoğu dilde kelime öbekleri, sözcüklerin tek tek içerdikleri anlamdan daha farklı bir anlama sahip olabilmektedir. Bu manada, sadece metin parçalarının anlamı değil kelimelerin sırası da önem arz edebilmektedir. Kelime ve karakter seviyesinde yapılan n-gram uygulamasında ilgili kelime/karakter, kendinden önceki (n-1) kelime/karakterle ilişkilendirilir ve olasılık hesabına katılır.

Yılmaz ve Yumuşak (2021), n-gram yönteminin, dizgeciklerin kaç kelimedenden oluşacağını belirlemek için kullanıldığını belirtmektedir. Değer (2017) ise n-gram yöntemini her kelimenin ayrı ayrı anlamından farklı veya daha büyük anlam taşıyabilen kelime öbeği veya kelime kombinasyonu olarak tanımlar. Kelimeler veya harflerle n-gram işlemi yapılabilir. Yani kelime bazında 1-gram kullanılması demek cümledeki tüm kelimelerin tek tek ayrıştırılması anlamına gelmektedir. Aynı ayrıştırma yöntemi karakter bazında da yapılabilir.

N-gram yöntemini büyük verilerle de iyi çalışmasından ötürü makine öğrenmesi yöntemlerinde sıklıkla tercih edilmektedir.

2.5.6 Filtreleme

Filtreleme çerçevesinde işlenmek istenen dokümandaki anlama katkısı olmayan bağlaç, edat veya benzeri sözcük tipleri filtrelenerek uygulama performansı artırılması hedeflenir. Bu gibi sözcükler, sınıflama performansına ve genel anlama katkısı düşük olduğu için özniteliklerden oluşan vektörleri kalabalıklaştırıp performansı düşürme ihtimali bulunmaktadır. Bu sözcükler her dilde ve araştırma özelinde farklılık gösterebilir (Değer, 2017).

2.5.6 Gövdeleme (Stemming - Lemmatization)

Dizgeciklere ayırma işleminden sonra yapılan bir işlem olup genel olarak sözlük yardımıyla yapılan duygu analizi süreçlerinde kullanılmaktadır. Hem stemming hem de lemmatization yöntemlerinin amacı sözcük köklerine ulaşmaktır. Stemming kapsamında sözcüklerinde köküne kadar inilmesi için ön ve son ekler atılır. Bu ekler içinde fiillerdeki zaman, iyelik ekleri, sıfat ekleri bulunmaktadır. Bu yöntemde zaman zaman ulaşılan kök, sözcük anlamını temsil etmeyebilir. Ya da yeterli derecede köke inilemezse anlam karmaşası doğabilmektedir.

Lemmatization ise dilbilim kökenli bir yaklaşımdır. Doğru lemma çıkarımı ise morfolojik bir analiz gerektirmektedir. Bu tip ayrıntılı bir analiz içinse ilgili içinde çalışılmış bir sözlüğün oluşturulması esastır.

Kelime köklerine inmek için gösterilen gayretteki ana maksat uygulama performansını yüksek tutmaktır. Her bir kelimenin n-gram yönteminde olduğu öznitelik olarak vektörde bir yer tuttuğu için modelleme performansı kelime sayısından etkilenmektedir. Kelimeler ne kadar ortak paydada temsil edilebilirse performansın da o ölçüde artması beklenir.

2.6 METİNE İŞLEMEDE BOYUT İNDİRGEME

Modeldeki verilerin büyümesi ve boyutların artmasıyla beraber işlenmesi de o ölçüde zorlaşmaktadır. Bununla beraber artan boyut sayısı modelin doğruluk oranını da azaltabilmektedir. Artan boyut sayısı model içinde gürültü oluşturabilmektedir. Tüm bu sebeplerden ötürü makine öğrenmesinde metinlerde boyut indirgeme yöntemleri kullanılmaktadır.

2.6.1 Terim Ağırlıklandırma

Bir metinde kelimelerin benzersiz olarak toplanarak oluşturulan derleme, kelime heybesi (bag of words-BOW) gösterimi denmektedir. BOW iki boyutlu bir vektör olup bir boyutundan metindeki kelimeler diğer boyutunda ise bu kelimelerin frekansları bulunmaktadır. Elimizde n adet metin olduğu ve k tane benzersiz kelime/terim bulunduğu varsayılırsa ($n \times k$) boyutunda bir matris oluşur. BOW gösteriminde terimlerin sayısallaştırılması ve ağırlıklandırılması gereklidir. Bu amaçla terim frekansı veya terim frekansı - ters belge frekansı gibi yaklaşımlar kullanılmaktadır. Bunlarında dışında ikili sınıflandırma (binary classification) gibi yöntemler de bulunmaktadır. Bu yöntemde terim varsa 1 yoksa 0 gibi sadece var / yok yaklaşımı kullanılmaktadır. Bu yaklaşımda bilgi eksikliği oluşabileceğinden tercih edilmemektedir.

Terim frekansı: Bu yaklaşımda sık kullanılan kelimeler yüksek skorlar almaktadır. Hesaplanması şu şekildedir (Karaman, 2020): “

$$TF(t, d) = \frac{f_d(t)}{\max_{w \in d} f_d(w)} ”$$

$f_d(t)$: t teriminin d metnindeki frekansını gösterirken $\max_{w \in d} f_d(w)$ ise metinde en sık geç terimin sayısını göstermektedir.

Ters metin frekansı (Inverse Document Frequency -IDF) metindeki bir kelimenin sıralamasını metinle ilgili olarak hesaplamaktadır. İlgili rakamın düşük çıkması etkisinin daha yüksek olduğunu göstermektedir. Karaman (2020) ilgili formülü şu şekilde belirtmiştir:”

$$IDF(t, D) = \log \left(\frac{|D|}{|\{d \in D: t \in d\}|} \right)$$

D ise belge derlemidir.”

Terim frekansı – Ters Metin Frekansı (TF-IDF) her iki bakış açısının kombinasyonu olup şu şekilde hesaplanmaktadır:

$$TF - IDF(t, d, D) = TF(t, d) \times IDF(t, D)$$

2.6.2 Terim frekansı ve dizgeciklere ayırma örneği

Terim frekansı ve dizgecikler ayırma aşağıdaki örneklerde gösterilmiştir.

Örnek Cümle: “Yapay zeka uygulamaları çok yararlı.”

Kelime bazında 1-gram:

[Yapay, zeka, uygulamaları, çok, yararlı]

Kelime bazında 2-gram:

[Yapay zeka, zeka uygulamaları, uygulamaları çok, çok yararlı]

Kelime bazında 3-gram:

[Yapay zeka uygulamaları, zeka uygulamaları çok, uygulamaları çok yararlı]

Karakter bazında 1-gram:

[y,a,p,a,y,z,e,k,a,u,y,g,u,l,a,m,a,l,a,r,ı,ç,o,k,y,a,r,a,r,l,ı]

Karakter bazında 2-gram:

[ya,ap,pa,ay,yz,ze,ek,ka,au,uy,yg,gu,ul,la,am,ma,al,la,ar,rı,ıç,ço,ok,ky,ya,ar,ra,ar,rl,lı]

Karakter bazında 3-gram:

[yap,apa,pay,ayz,yze,zek,eka,kau,auy,uyg,ygu,gul,ula,lam,ama,mal,ala,lar,arı,rıç,ıço,çok,oky,
kya,yar,ara,rar,ar,rlı]

Öznitelik çıkarımı ve frekans vektörünün oluşturulması için oluşturulan her bir token / dizgecik vektörleştirilir. Aşağıda 1-gram yöntemine göre başka bir örnek gösterilmiştir.

Örnek Tweet: “Mükemmel ötesi bir insan iyi ki böyle güzel yürekli doktorlarımız var.” İlgili etiket personel olarak işaretli.

Tokenization: [Mükemmel, ötesi, bir, insan, iyi, böyle, güzel, yürekli, doktorlarımız, var]

Örnek Tweet 2: “Hastane ve tüm ekipman mükemmel. Randevu süreçleri de iyi” İlgili etiket hastane koşulları olarak işaretli.

Tokenization: [Hastane, tüm, ekipman, mükemmel, randevu, süreçleri, iyi]

Örnek Tweet 3: “Mükemmel doktorlarımız ve hemşirelerimiz var.”

Tokenization: [Mükemmel, doktorlarımız, hemşirelerimiz] İlgili etiket personel olarak işaretli.

Daha sonra her bir token'ın hangi başlıkta daha çok geçtiğine göre sayısallaştırma yapılır. Başlıklar, müşteri memnuniyetinin alt kategorileri olup öznitelik olarak adlandırılmaktadır. Tüm Tweetler bu şekilde token'larına ayrılmakta ve hangi öznitelik altında işaretlenmelerine göre olasılık dağılımı oluşmaktadır. Yepyeni bir Tweet'in hangi alt kategoriye girdiği değerlendirilmek istendiğinde ilgili Tweet tokenlarına ayrılır ve yukarıda oluşturulan tabloya göre değerlendirilir ve baskın olasılığa göre kategori belirlenir.

Tablo 2.5: TF, IDF ve TF-IDF üzerine bir örnek

Tweet 1 : “Mükemmel ötesi bir insan iyi ki böyle güzel yürekli doktorlarımız var.”
Tweet 2 : “Hastane ve tüm ekipman mükemmel. Randevu süreçleri de iyi.”
Tweet 3 : “Mükemmel doktorlarımız ve hemşirelerimiz var.”
<i>Metin Terim Matrisi</i>
[‘bir’, ‘böyle’, ‘de’, ‘doktorlarımız’, ‘ekipman’, ‘güzel’, ‘hastane’, ‘hemşirelerimiz’, ‘insan’, ‘iyi’, ‘ki’, ‘mükemmel’, ‘ötesi’, ‘randevu’, ‘süreçleri’, ‘tüm’, ‘var’, ‘ve’, ‘yürekli’]
$\begin{bmatrix} 1 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 & 1 & 0 \end{bmatrix}$
<i>Terim Frekansları (TF)</i>
[‘bir’, ‘böyle’, ‘de’, ‘doktorlarımız’, ‘ekipman’, ‘güzel’, ‘hastane’, ‘hemşirelerimiz’, ‘insan’, ‘iyi’, ‘ki’, ‘mükemmel’, ‘ötesi’, ‘randevu’, ‘süreçleri’, ‘tüm’, ‘var’, ‘ve’, ‘yürekli’]
$\begin{bmatrix} 1 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 & 1 & 0 \end{bmatrix}$
<i>Terim Metin Frekansları (IDF)</i>
[‘bir’, ‘böyle’, ‘de’, ‘doktorlarımız’, ‘ekipman’, ‘güzel’, ‘hastane’, ‘hemşirelerimiz’, ‘insan’, ‘iyi’, ‘ki’, ‘mükemmel’, ‘ötesi’, ‘randevu’, ‘süreçleri’, ‘tüm’, ‘var’, ‘ve’, ‘yürekli’]
$\begin{bmatrix} 0.477 & 0.477 & 0.477 & 0.176 & 0.477 & 0.477 & 0.477 & 0.477 & 0.477 & 0.477 & 0.176 & 0.477 & 0.000 & 0.477 & 0.477 \\ 0.477 & 0.477 & 0.176 & 0.176 & 0.477 \end{bmatrix}$
<i>Terim Frekansı- Term Metin Frekansları (TF-IDF)</i>
[‘bir’, ‘böyle’, ‘de’, ‘doktorlarımız’, ‘ekipman’, ‘güzel’, ‘hastane’, ‘hemşirelerimiz’, ‘insan’, ‘iyi’, ‘ki’, ‘mükemmel’, ‘ötesi’, ‘randevu’, ‘süreçleri’, ‘tüm’, ‘var’, ‘ve’, ‘yürekli’]
$\begin{bmatrix} 0.477 & 0.477 & 0.000 & 0.176 & 0.000 & 0.477 & 0.000 & 0.000 & 0.477 & 0.176 & 0.477 & 0.000 & 0.477 \\ 0.000 & 0.000 & 0.000 & 0.176 & 0.000 & 0.477 \end{bmatrix}$
$\begin{bmatrix} 0.000 & 0.000 & 0.477 & 0.000 & 0.477 & 0.000 & 0.477 & 0.000 & 0.000 & 0.176 & 0.000 & 0.000 & 0.000 & 0.477 & 0.477 & 0.477 \\ 0.000 & 0.176 & 0.000 \end{bmatrix}$
$\begin{bmatrix} 0.000 & 0.000 & 0.000 & 0.176 & 0.000 & 0.000 & 0.000 & 0.477 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.176 & 0.176 & 0.000 \end{bmatrix}$

TF- IDF sayesinde sadece frekans değil her bir terimin ağırlıklandırması da yapılmaktadır. Tüm bu adımlardan sonra elde edilen metinlerin makine öğrenmesi algoritmalarında kullanılabilmesi için vektörel formatları da oluşmuş olur.

2.8 MAKİNE ÖĞRENME YÖNTEMLERİNİN DEĞERLENDİRİLMESİ

Uygulanan makine öğrenimi tekniklerinin başarısı birçok farklı ölçüm kriteriyle ölçülmeli ve model doğrulanmalıdır. Bu çalışma çerçevesinde ML makine öğrenmesinin sunduğu mikro ve makro doğruluk, log loss fonksiyonları değerlendirildiği gibi hata matrisinden de yararlanılmıştır. Hata matrisinde dikkat edilen kriterler sınıflandırma doğruluğu, duyarlılık, belirleyicilik, kesinlik ve F ölçüsüdür.

2.8.1 Hata Matrisi (Confusion Matrix)

Hata matrisi $n \times n$ boyutlarından oluşan kare bir matris olup n her bir tahmin edilen kategoriye temsil etmektedir. Örneğin DA için bu kategoriler: Pozitif, negatif ve nötrdür. Her bir kategori için gerçek ve tahmin edilen frekanslar hata matrisine işlenir. İlgili $n \times n$ matrisinde bu durumda 3 sütun ve 3 sıra olacaktır. Sıralar gerçek değerleri gösterirken, sütunlar tahmin edilen değerleri gösterir. Matrisin köşegeninde bulunan değerler doğru tahminleri gösterirken bu sıranın dışındaki tüm frekans değerleri yanlış tahminleri göstermektedir. Temel hata matrisi tablo 2.6'da gösterilmiş olup her bir değerlendirme kriterinin açıklaması da aşağıda belirtilmiştir. Bu hesapların her bir kategori için yapılmalıdır.

Tablo 2.6: Hata Matrisi

		Tahmin edilen değerler	
		Pozitif	Negatif
Gerçek Değerler	Pozitif	True Positive (TP) Doğruların doğru tahmin edilmesi	False Negative (FN) Doğruların yanlış tahmin edilmesi
	Negatif	False Positive (FP) Yanlışların doğru tahmin edilmesi	True Negative (TN) Yanlışların yanlış olarak tahmin edilmesi

Kaynak: Karaman, N. İ. (2020). *Measuring The Effect Of Social Media Strategies On The Consumer Perception Of Political Parties In Turkey* (Yayımlanmamış doktora tezi). İstanbul Bilgi University.

2.8.2 Sınıflandırma Doğruluğu (Classification Accuracy)

Sınıflandırma doğruluğu, doğru tahminlerin sayısını tüm örneklem büyüklüğüne oranını ölçer.

$$\text{Sınıflandırma doğruluğu} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Sınıflandırma Hata oranı} = 1 - \text{Sınıflandırma doğruluğu}$$

Doğru tahminleme oranı sıfır ile bir arasında çıkabilecek bir değerdir. Dolayısıyla birden (1) doğru sınıflandırma doğruluk oranını çıkararak sınıflandırma hata oranına ulaşılabılır.

2.8.3 Duyarlılık (Sensitivity)

Duyarlılık, pozitif sınıflı etiketli verilerin tahmin edilmesindeki etkinliktir. Bu etkinlik doğru sınıflandırılan pozitif etiketli verilerin tüm pozitif olarak etiketlenmiş verilere oranı şeklinde ölçülür.

$$\text{Duyarlılık} = \frac{TP}{TP + FN}$$

2.8.4 Belirleyicilik (Specificity)

Belirleyicilik, negatif sınıflı etiketli verilerin tahmin edilmesindeki etkinliktir. Bu etkinlik negatif sınıflandırılan negatif etiketli verilerin tüm negatif olarak etiketlenmiş verilere oranı şeklinde ölçülür.

$$\text{Belirleyicilik} = \frac{TN}{TN + FP}$$

2.8.5 Kesinlik Precision

Kesinlik doğru olarak sınıflandırılmış pozitif etiketli verilerin, doğru ve yanlış fark etmeksizin tüm pozitif etiketli verilerin oranıdır.

$$\text{Kesinlik} = \frac{TP}{TP + FP}$$

2.8.6 F – Ölçüsü

F-ölçüsü kesinlik ve duyarlılık oranlarının harmonik ortalamasıdır.

$$F - \text{Ölçüsü} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

2.8.7 Microsoft Makine Öğrenmesi Kütüphanesi Model Değerlendirme Kriterleri

MS makine öğrenmesi kütüphanesinin sınıflandırma algoritmalarında kullandığı ana performans kriterleri Şekil 2.9’da belirtildiği gibidir. Veri setinde, sınıf içindeki kategorilerde homojenlik olmadığında Mikro-Doğruluk, modelin değerlendirmesinde kullanılacak ana kriterlerden biridir. Bununla beraber günlük kayıp olarak çevrilmiş olan log loss ise diğer önemli bir metrik olup değerlendirmede dikkate alınmalıdır. Capellman (2020) bu metriği sınıflandırıcının doğruluğu olarak tarif etmiştir. Log loss modelin yaptığı tahminle gerçekleşen sınıflandırma arasındaki farkı hesaplar. Bu değer sıfıra yakın çıkması arzulanır; tam sıfır çıkması ise test verisi üzerinde mükemmel tahmini gösterir.

Şekil 2.9: Microsoft makine öğrenmesi çok sınıf sınıflandırması değerlendirme ölçümleri

Ölçümler	Açıklama	Aramak
Mikro doğruluk	Mikro ortalama doğruluk , ortalama ölçümü hesaplamak için tüm sınıfların katkılarını toplar. Doğru tahmin edilen örneklerin kesiri. Mikro ortalama, bir sınıf üyeliğini hesaba almaz. Temel olarak her örnek sınıf çifti, doğruluk ölçüsüne eşit olarak katkıda bulunur.	1,00 ' ye yaklaşarak daha iyidir. Çok sınıflı bir sınıflandırma görevinde, bir sınıf dengesizliği olabileceğinden şüphelenirseniz, mikro doğruluk, makro doğruluğu üzerinde tercih edilir (ör. diğer sınıflardan daha fazla bir sınıfa daha fazla örnek olabilir).
Makro doğruluğu	Makro-ortalama doğruluk , sınıf düzeyindeki ortalama doğruluk sayıdır. Her sınıfın doğruluğu hesaplanır ve makro doğruluğu bu accuracies ortalaması olur. Temel olarak her sınıf, doğruluk ölçüsüne eşit olarak katkıda bulunur. Mininlik sınıflarına daha büyük sınıflar olarak eşit ağırlık verilir. Makro-ortalama ölçümü her sınıfa aynı ağırlığı verir, bu sınıftan kaç örnek veri kümesi içeriyor olsun.	1,00 ' ye yaklaşarak daha iyidir. Ölçüyü her sınıf için bağımsız olarak hesaplar ve ortalama alır (Bu nedenle tüm sınıfları eşit olarak değerlendiriliyor)
Günlük kayıp	Logaritmik kayıp, tahmin girişinin 0,00 ile 1,00 arasında bir olasılık değeri olduğu bir sınıflandırma modelinin performansını ölçer. Gerçek etiketten ayrılan tahmini olasılık arttıkça günlük kaybı artar.	0,00 ' ye yaklaşarak daha iyidir. Kusursuz bir modelde 0,00 günlük kaybı olur. Machine Learning modellerimizin amacı bu değeri en aza indirmektir.
Günlük kaybını azaltma	Logaritmik kayıp azaltma , sınıflandırıcının rastgele bir tahmin üzerinden faydalanması olarak yorumlanabilir.	-INF ve 1,00 aralıklarında, 1,00 ' in mükemmel tahminlerden ve 0,00 ise ortalama tahmine göre belirlenir. Örneğin, değer 0,20 eşitse, "doğru bir tahmine ait olasılık %20 tahmininden daha iyidir" olarak yorumlanabilecek.

Kaynak: ML.net metrics. (n.d.). 9 Nisan 2021 tarihinde <https://docs.microsoft.com/en-us/dotnet/machine-learning/resources/metrics> adresinden erişildi

Günlük kaybın azaltılması (log loss reduction) ise sınıflandırma algoritmasının rastgele bir sınıflandırma arasındaki farkına bakar. Bu değerin bir sayısına yakın olması arzulanır.

BÖLÜM 3 METODOLOJİ

3.1. ARAŞTIRMANIN AMACI

Bu araştırmanın yapılmasında önceki araştırmalardaki şu eksikliklerin de tamamlanması amaçlanmıştır:

- Literatürde yapılmış olan duygu analizi çalışmaları müşteri memnuniyet modelleri ile eşlenmemiş olduğundan sadece genel kanaati tespit etmektedir. Bu çalışmayla mikro bloglardaki müşteri şikayetlerinin literatürde kabul görmüş müşteri memnuniyet modeline göre uygulanması mümkün olacaktır.
- Bugüne kadar sözlük ve derlem tabanlı duygu analizi farklı çalışmalarda kullanılmış fakat Türkçe derlem ve analizi, uygun sözlük eksikliği bulunmaktadır. Dolayısıyla bu çalışmada tercih edilmemişlerdir. Ayrıca, bu tip çalışmalardaki veriler daha genel veri setlerinden oluşturulmuştur. Oysa sektör temelli incelemeler ile öğrenim verisinin oluşturulması, makine öğrenmesi başarı oranını arttırarak daha etkin bir duygusal analiz otomasyonu oluşturulabilecektir. Çalışmaya girdi olarak işaretlenen müşteri beyanları sağlık sektörü duygu analizi çalışmaları için de girdi oluşturacaktır.

Araştırma tüm mikro bloglarda kullanabilmekle beraber, örnek uygulama Twitter üzerinden yapılmıştır. Eylül 2017 öncesinde yapılan literatür çalışmalarında Twitter, bir Tweet içinde 140 adet karakter kullanımına izin vermekteydi. İlgili tarihten sonra bu limit 280 karaktere çıkmış bulunmaktadır. Bu artış sayesinde kullanılan kısaltmalarda azalma, kullanıcı ifadelerinin ise güçlenmesi olasıdır. Bu yeni değişiklik çerçevesinde Twitter duygu durumu analizlerinin güncellenmesi gerekmektedir. İlgili çalışma yeni karakter sayısına göre yapılmakta olduğundan literatüre bu parametre çerçevesinde yenilik katacaktır.


Tüm bunların yanında bu araştırma sayesinde yoğun veri akışının olduğu sosyal medya mecralarında marka ve şirketlere karşı tutum anlık olarak tespit edilebilecektir. Müşteri şikayetlerinin ciddiyetine göre müşteri memnuniyetsizlikleri önceliklendirilecektir. Bu, şikayetlerin, krize dönmeden şirketler tarafından müdahale şansı oluşturacağı gibi, yüksek ciddiyet içeren şikayetlerde, sektöre özel en doğru müdahale şeklinin araştırılması için bir temel teşkil edecektir. Böylece şirketlere rekabette bir avantaj elde etme fırsatı sunan bir alt yapı oluşturulacaktır.

3.2. ARAŞTIRMANIN YÖNTEMİ

Bu araştırma, Microsoft makine öğrenmesi kütüphaneleri, MS Excel ve Twitter API'si kullanılarak hazırlanmıştır. Twitter API veri toplanması, MS Excel veri temizliği yapılması için .Net platformu ise kodlama ve makine öğrenmesinin icra edilmesi için kullanılmıştır. Kullanılan tüm kütüphane kodları açık kaynak olarak kullanılabilir. İlgili kaynaklar github'dan ("dotnet", t.y.) indirilebileceği gibi .Net platformu kullanan C# kullanıcıları da aynı şekilde ML.Net kütüphanelerini ekleyerek kullanabilirler.

Araştırma çerçevesinde, örnek uygulamanın, dinamik yapısı ve müşteri şikayetlerinin yoğun bir şekilde ifade edildiği Twitter üzerinde yapılmasına karar verilmiştir. Veri toplanması için Twitter API'si kullanılarak çalışmaya konu olan Tweet'ler indirilmiş ve öğrenme seti oluşturulmuştur. Öğrenme setinin müşteri memnuniyet faktörlerine göre işaretlenmesi için Abirami ve Askarunisa (2017)'nin müşteri memnuniyet modeli temel alınmıştır. İlgili modelin yaklaşımının, Twitter'ın dinamik ve çok farklı konunun söz konusu olduğu kapsamda bazı ilişkileri gözden kaçırmaması mümkündür. Ayrıca, Twitter şikayetlerin diğer mikro blog platformlarına göre daha hızlı çözüm beklendiği bir platformdur (İstanbuluoğlu, 2017). Dolayısıyla, modelde belirtilmeyen birçok konu hakkında sorular veya şikayetler iletilmektedir. Türkiye'deki özel hastaneler kapsamında, müşteri memnuniyet / memnuniyetsizlikleri faktörlerinin tespiti için test edilecek başlangıç modeli Şekil 3.1'deki gibi oluşturulmuştur.

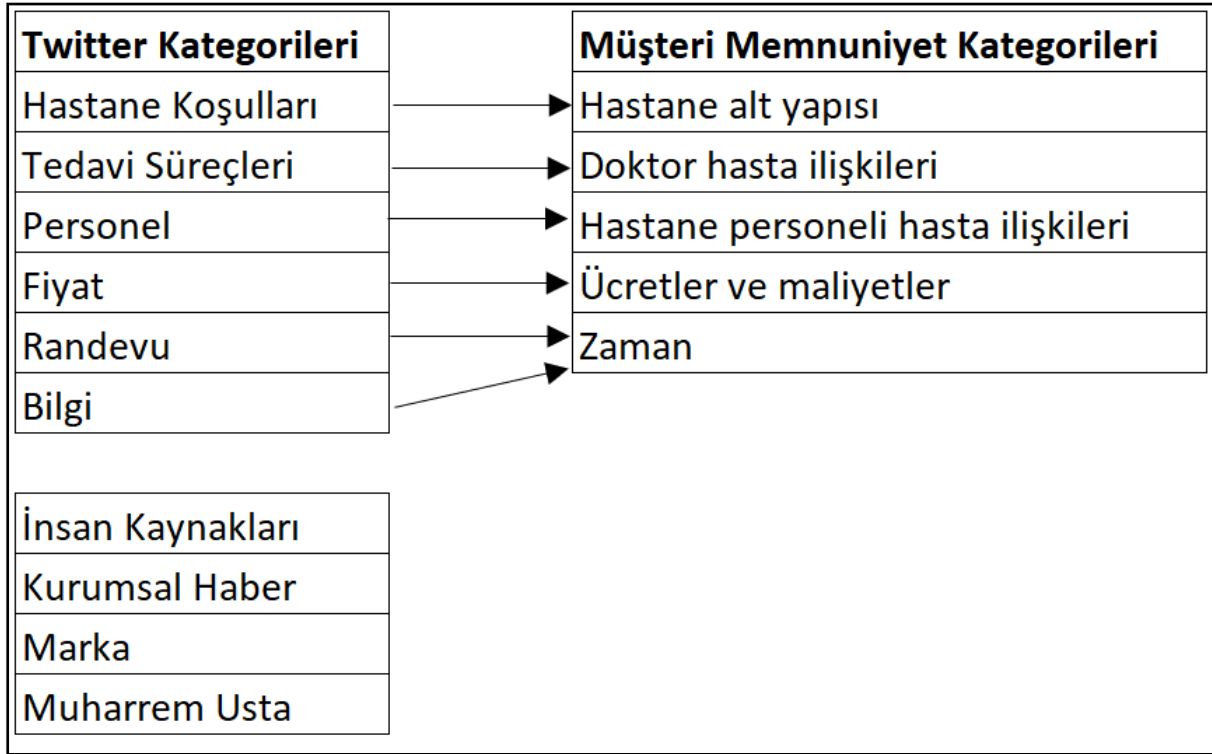
Şekil 3.1: MedicalPark hakkındaki Twitter kategorileri



Bu sebeplerden ötürü Abirami ve Askarunisa (2017)'nin çalışmasındaki modellerdeki faktörlerle beraber, Twitter'ın tartışma ortamındaki sertlik ve politik duruşun, acil ve farklı bilgi ihtiyaçlarının ayrıca kurum hakkında iletişimin oluşturduğu kurumsal haberlerin de modele etkisinin incelenmesi için ek kategoriler olarak eklenmiş ve Şekil 3.1'te gösterilmiştir.

Şekil 3.2 planlanan kategorilerle memnuniyet kategorilerinin nasıl eşleştiğini de göstermektedir.

Şekil 3.2: MedicalPark hakkındaki atılan Tweet’lerin müşteri memnuniyeti modeli kategorilerine göre eşleşmeleri



Öğrenme seti hem duygu analizi hem de memnuniyet modeline göre hazırlanmış ve değerlendirilmesi için popüler denetimli makine öğrenmesi yöntemlerinden destek vektör makineleri ve maksimum entropi yöntemleri seçilmiştir.

3.3 ANA KÜTLE VE ÖRNEKLEM SEÇİMİ

Öncelikle, Twitter API’sini kullanmak için Twitter’a başvurulmuş ardından ilgili API kullanılarak toplu Tweet indirmek mümkün olmuştur. API, Application Programming Interfaces kelimelerinin kısaltması olup Twitter’dan toplu veri çekmenin bir yoludur. 02 Şubat 2019 ile 05 Şubat 2021 tarihleri arasında MedicalPark hakkında ve tarafından atılan tüm Tweetler bu yöntemle indirilmiştir

Twitter API'si ile indirilen verilerde öncelikle veri temizliği yapılmıştır. Veriden yabancı dilde atılan Tweetler, tekrar eden Tweet'ler atılmış ve 14.279 adetlik bir veri seti elde edilmiştir. İlgili veri seti manuel olarak ton, kategori ve niteliğine göre şekil 3.3'teki gibi işaretlenmişlerdir. Her bir kategorinin seçilebilecek özellikleriyse şekil 3.4'te belirtilmiş ve tüm manuel etiketleme bu şekilde yapılmıştır. Çekilen verilerde, şekil 3.4'te göze çarpacağı üzerine duygu ifadelerinde negatif ve nötr, kategori kısmında marka, nitelik kısmında ise genel ve şikayet sınıflarında aşırı ağırlık bulunmaktadır. Bu ağırlık kayması yapay zeka modelinin performansının düşmesine sebep olmaktadır. Dolayısıyla ağırlığı fazla olan verilerin modellenmesinde başarı oranı baz alınmalıdır

Şekil 3.3: Manuel olarak etiketlenen Tweet örnekleri

Tweet	Ton	Kategori	Nitelik	No
BU DA BENİM TESTİM ÖKSÜR NEFES	Negatif	Fiyat	Genel	1
- BAŞ AĞRINIZIN NEDENİ SUSUZLUK C	Nötr	Marka	Genel	2
Check-up, size mi? Bir daha asla...Soğ	Negatif	Fiyat	Şikayet	3
- COVID-19 SONRASI KİLO SORUNU U	Nötr	Kurumsal H	Genel	4
- Galatasaray'ın hastane alanında spc	Nötr	Marka	Genel	5
- Gaziantep Gazeteciler Cemiyeti'nin	Nötr	Kurumsal H	Genel	6
- GÜNEŞ GİRMEYEN EVE VEREM GİRE	Nötr	Kurumsal H	Genel	7
- HEMOROİTTEN 15 DAKİKADA KURTİ	Nötr	Kurumsal H	Genel	8
- İyi günler , Medikal Park Hastanesin	Nötr	Marka	Genel	9
Kepçe Kulak Çocuğunuzun Kaderi Olr	Nötr	Kurumsal H	Genel	10
- Kırık Kalp Sendromu Kadınları Etkili	Nötr	Kurumsal H	Genel	11
Menajitden Korunmanın En Kolay Y	Nötr	Kurumsal H	Genel	12

Şekil 3.4: Manuel olarak etiketlenen Tweet'lerin kategori dağılımları

Ton	Tweet Adedi	% Dağılım	Kategori Konusu	Tweet Adedi	% Dağılım	Nitelik	Tweet Adedi	% Dağılım
Negatif	7.125	49,9%	Marka	6.779	47,5%	Genel	7.764	54,4%
Nötr	6.716	47,0%	Kurumsal Haber	3.166	22,2%	Şikayet	5.883	41,2%
Pozitif	438	3,1%	Tedavi Süreçleri	1.787	12,5%	Teşekkür/Beğeni	358	2,5%
Toplam	14.279	100,0%	Fiyat	1.002	7,0%	İstek/Öneri/Soru	274	1,9%
			Personel	593	4,2%	Toplam	14.279	100,0%
			Hastane Koşulları	572	4,0%			
			Randevu	124	0,9%			
			Bilgi	96	0,7%			
			İnsan Kaynakları	88	0,6%			
			Muharrem Usta	72	0,5%			
			Toplam	14.279	100,0%			

Çalışma çerçevesinde kullanılan etiketler ve tanımları aşağıdaki gibidir.

Marka: Medikal Park isminin geçtiği veya markaya yönelik ifadelerin olduğu Tweetler.

Kurumsal Haber: Medikal Park kurumsal iletişim tarafından atılan Tweetler

Tedavi Süreçleri: Tedavi süreçleri, hastanenin genel işleyişini içerir

Fiyat: Tedavi için alınan fiyatlarla ilgili Tweetleri içerir.

Personel: Doktorlar da dahil olmak üzere tüm hastane personeli hakkındaki hasta Tweetleridir.

Hastane koşulları: Hastanenin temizliği, otoparkı ve hasta odalarının durumu gibi fiziksel alt yapı hakkında yapılan yorum ve Tweetleri içerir.

Randevu: Hastaya dokunan tüm iletişim noktalarındaki randevu süreçleriyle ilgili Tweetlerdir.

Bilgi: Genel bilgi talebi istenen Tweetlerdir.

İnsan kaynakları: Medikal Park insan kaynaklarına ulaşmak için atılan Tweetlerdir. Açık pozisyon ve iş talepleri konularını içerir.

Muharrem Usta: Medikal Park yönetim kurulu başkanı olduğu için kendisine ulaşmak isteyen hastaların ismini geçirerek attığı Tweetleri içerir.

Çalışmanın amaçları doğrultusunda, Tweet'in ton ve kategori konusunun makine öğrenmesiyle değerlendirilmesi amaca ulaştırmakla beraber, kullanılan metotlar, birçok sınıflandırmaya mümkün kıldığından ve raporlamalara katacağı olası değerden ötürü nitelik sınıfı da çalışmaya eklenmiştir. Çalışmanın yenilikçi yönlerinden biri de istenen kadar sınıfın modele eklenmesine olanak vermesidir.

İlgili sınıflandırma işlemleri yapıldıktan sonra elimizde oluşan Tweet kümesi öncelikle rassallaştırılmış ardından eğitim ve test kümesi olarak ikiye bölünmüştür. Jurafsky, Chahuneau, Routledge ve Smith adaşlarının (2014) uyguladığı yöntem üzerine eğitim için toplam verinin 80%'i eğitim, geri kalanı test için kullanılmıştır. Yani, 11.423 adetten oluşan bir küme, eğitim kümesi olarak kullanılmış kalan 2.856'lık Tweet'ten oluşan diğer küme ise denetim kümesi olarak değerlendirilmiştir.

3.4 VERİ HAZIRLANMASI ve MODELLEME

MS makine öğrenmesi kütüphanesi kullanımında en büyük pratiklik verinin hazırlanmasında ve modellemesinde sunduğu kolaylıktır. Kullanılan maksimum entropi ve DVM metotları kolaylıkla çağırılarak veri işleme yapılabilmektedir. Bu durum farklı modellerin de hızlıca denenmesine imkan vermektedir.

3.5 MAKİNE ÖĞRENMESİ MODELLERİ SINIFLANDIRMA SONUÇLARI

Modelden çıkan sonuçlar denetim kümesiyle karşılaştırılacağı gibi, modelin kendi sunduğu metrikler de bulunmaktadır. Bu metrikler Şekil 2.9'da özetlenmiştir. Veri setinde, sınıf içindeki kategorilerde homojenlik olmadığından Mikro-Doğruluk modelin değerlendirmesinde kullanılacaktır. Destek vektör makineleri ve maksimum entropi yöntemleri çoklu sınıflarda uygulanacağı ve sınıflar arası dengesizlik olduğundan dolayı (marka, nötr, negatif sınıflarının baskınlığı gibi) algoritma başarı kriteri olarak mikro doğruluk alınacaktır. Sınıf için başarı başarısızlık tespitinde F ölçütü dikkate alınmalıdır.

BÖLÜM 4 BULGULAR

4.1 VERİ ÖN İŞLEME VE MODELLEME

Öncelikle veriler maksimum entropi modeline göre eğitilmiş ve model tarafından ilk tahmini veriler şekil 4.1 ve tablo 4.1'deki gibi oluşmuştur.

Şekil 4.1: Veri ön işleme ve ilk modelin maksimum entropi yöntemiyle oluşan MS kriterleri sonucu

```
*****
*      Metrics: Ton
-----
*      MicroAccuracy:   %85,1
*      MacroAccuracy:   %68
*      LogLoss:         %38,2
*      LogLossReduction: %52,4
*
*****
*      Metrics: Kategori
-----
*      MicroAccuracy:   %70,2
*      MacroAccuracy:   %43,7
*      LogLoss:         %84,8
*      LogLossReduction: %43,4
*
*****
*      Metrics: Nitelik
-----
*      MicroAccuracy:   %83,6
*      MacroAccuracy:   %53,9
*      LogLoss:         %43,9
*      LogLossReduction: %48
*****
```

Tablo 4.1: Veri ön işleme ve ilk modelin maksimum entropi yöntemiyle gerçekleşen doğruluk oranı

	Sonuç Ton	Sonuç Kategori	Sonuç Nitelik
Toplam Doğru Sayısı	2.434	2.037	2.398
Toplam Twitter Adedi	2.856	2.856	2.856
Yüzdese Doğruluk	85%	71%	84%

Ardından modelden çıkan sonuçlar test kümesiyle şekil 4.3'teki gibi denetlenmiştir. Şekil 4.3'te görüleceği üzere, yapay zeka modelinin sonuçları manuel kodlama ile tuttuğunda 1

tutmadığında 0 olarak işaretlenmiştir. Buna göre başarı oranları tablo 4.1'teki gibidir. Ton 85%, nitelik 84% ile başarılı sonuçlar yakalarken kategorinin başarı oranı 71%'de kalmıştır.

Şekil 4.2: Manuel kodlama ile kontrol

Data seti Kontrol Verileri				Yapay Zeka modeli değerlendirilmesi			Sonuçlar tutuyor mu				
Metin	Ton	Kategori	Nitelik	NO	Ton Değerlendirmesi	Kategori Değerlendirmesi	Nitelik Değerlendirmesi	Sonuç Ton	Sonuç Kategori	Sonuç Nitelik	Sonuç (Fin.)
çukurova'nın en pal	Negatif	Fiyat	Şikayet	36163	Negatif	Fiyat	Şikayet	1	1	1	1
Medical Park Bahçe	Nötr	Kurumsal Haber	Genel	36164	Nötr	Marka	Genel	1	0	1	0
@selcukkosovalı	Nötr	Marka	Genel	36165	Negatif	Marka	Genel	0	1	1	0
Dün izmir medicalp	Negatif	Marka	Şikayet	36166	Negatif	Marka	Şikayet	1	1	1	1
Arkadaşlar gaziantep	Nötr	Marka	Genel	36167	Nötr	Marka	Genel	1	1	1	1
Sen bizim en güçlü	Nötr	Marka	Genel	36168	Nötr	Marka	Genel	1	1	1	1
Izmit Belediyespor	Nötr	Kurumsal Haber	Genel	36169	Nötr	Marka	Genel	1	0	1	0
Emekli sandığı gece	Nötr	Bilgi	Istek/Öneri/Soru	36170	Nötr	Marka	Istek/Öneri/Soru	1	0	1	0
Değerli hastamız se	Nötr	Marka	Genel	36171	Nötr	Marka	Genel	1	1	1	1
Daha çok estetik an	Nötr	Marka	Genel	36172	Nötr	Marka	Genel	1	1	1	1
Epilepsi halk arası	Nötr	Marka	Genel	36173	Nötr	Marka	Genel	1	1	1	1

Kategori kısmındaki başarı oranını aşağıya çeken faktörler tablo 4.1'deki hata matrisi (confusion matrix) ile irdelenmiştir. Buna göre test kümesinde, marka kategorisinde 1.345 adet girdi bulunmaktadır ve yapay zeka modeli 1.069 adedini doğru olarak tespit ederken, 276 adet Tweet (276 = 1345 - 1069) marka olduğu halde farklı kategori olarak sınıflandırılmış, 424 adet Tweet ise (424 = 1493 - 1069) marka olmadıkları halde marka olarak sınıflandırılmıştır. Hataların yoğunlaştığı kategori ise kurumsal haberlerin marka olarak değerlendirilmesidir. Bunun sebeplerinden biri marka isminin kurumsal haberlerde çok yoğun geçmesidir. Nitekim müşteri memnuniyeti modelinde de olmayan bu kategoriyi marka altında birleştirilmesi uygun görünmüştür. Aynı zamanda Muharrem Usta hakkında atılan Tweetler de aynı sebeple ve veri adedinin çok az olması sebebiyle eğitim ve denetim kümesinden atılarak, model tekrar eğitilmiş ve değerlendiremeye alınmıştır.

Tablo 4.2: İlk modelin hata matrisi

Kategori	Bilgi	Fiyat	Hastane Koşulları	İnsan Kaynakları	Kurumsal Haber	Marka	Muharrem Usta	Personel	Randevu	Tedavi Süreçleri	Toplam
Bilgi				1	3	15		1		3	23
Fiyat		123			3	64		2		20	212
Hastane Koşulları		2	29		2	62		1	3	11	110
İnsan Kaynakları				3	1	8					12
Kurumsal Haber					544	91		1		5	641
Marka		24	27		134	1069	3	16	4	68	1345
Muharrem Usta		1			1	13	2			2	19
Personel		2	5		8	62		36	3	3	119
Randevu	1		4		1	10			6	3	25
Tedavi Süreçleri		8	8		5	99		2	3	225	350
Toplam	1	160	73	4	702	1493	5	59	19	340	2856

4.2 MODELİN OLUŞTURULMASI VE PERFORMANSININ ÖLÇÜLMESİ

Yapılan iyileştirmelerin ardından modelin kendi içsel tahminlerine göre kategori başarı oranları şekil 4.3'teki gibi yükselmiştir. Daha sonra tablo 4.3'te görüleceği gibi test verisiyle kontrol edilmiş ve benzer sonuçlar görülmüştür. Böylece maksimum entropi sınıflandırma algoritması kullanılarak Ton'da %85,5 Kategori'de %78,6 ve Nitelik sınıflandırmasında %83,8 başarı oranı elde edilmiştir.

Daha sonra aynı işlemler tekrar edilmiş ve destek vektör makinesi sınıflandırma algoritması kullanılmıştır. Şekil 4.4'te görüleceği üzere modelin öncül tahminlemesi maksimum entropi yöntemi sonuçlarına çok benzemekte isabet oranında sadece %3-5 daha düşük çıkmaktadır. Ardından test verisiyle sonuçlar denetlendiğinde tablo 4'teki sonuç çıkmaktadır. Bu sonuçlarda Ton'da %82,9, Kategori'de %77,7 ve Nitelik sınıflandırmasında %81,6 başarı oranı elde edilmiştir.

Şekil 4.3: İyileştirilen modelin maksimum entropi yöntemiyle MS kriterleri sonucu

```
*****
*   Metrics: Ton
-----
*   MicroAccuracy: %85
*   MacroAccuracy: %67,6
*   LogLoss: %38,2
*   LogLossReduction: %52,7
*
*****
*   Metrics: Kategori
-----
*   MicroAccuracy: %78,8
*   MacroAccuracy: %38,6
*   LogLoss: %65,3
*   LogLossReduction: %39,6
*
*****
*   Metrics: Nitelik
-----
*   MicroAccuracy: %83,1
*   MacroAccuracy: %54,1
*   LogLoss: %43,7
*   LogLossReduction: %50,1
*
*****
```

Tablo 4.3: İyileştirilen modelin maksimum entropi yöntemiyle doğruluk oranı

	Sonuç Ton	Sonuç Kategori	Sonuç Nitelik	Sonuç (Fin.)
Toplam Doğru Sayısı	2.430	2.233	2.383	1.830
Toplam Twitter Adedi	2.842	2.842	2.842	2.842
Yüzdesele Doğruluk	85,5%	78,6%	83,8%	64,4%

Şekil 4.4: İyileştirilen modelin DVM yöntemiyle MS kriterleri sonucu

```
*****
*      Metrics: Ton
-----
*      MicroAccuracy:   %82,6
*      MacroAccuracy:   %61,4
*      LogLoss:         %44,6
*      LogLossReduction: %44,8
*
*****
*      Metrics: Kategori
-----
*      MicroAccuracy:   %75,8
*      MacroAccuracy:   %23,8
*      LogLoss:         %75,6
*      LogLossReduction: %30,1
*
*****
*      Metrics: Nitelik
-----
*      MicroAccuracy:   %81,3
*      MacroAccuracy:   %46,5
*      LogLoss:         %50,7
*      LogLossReduction: %42,2
*
*****
```

Tablo 4.4: İyileştirilen modelin DVM yöntemiyle doğruluk oranı

	Sonuç Ton	Sonuç Kategori	Sonuç Nitelik	Sonuç (Fin.)
Toplam Doğru Sayısı	2.356	2.209	2.319	1.751
Toplam Twitter Adedi	2.842	2.842	2.842	2.842
Yüzdesele Doğruluk	82,9%	77,7%	81,6%	61,6%

F- Ölçüt değerleri ise tablo 4.5, 4.6 ve 4.7’de maksimum entropi için, tablo 4.8, 4.9 ve 4.10’da ise DVM için görülebilir.

Tablo 4. 5: İyileştirilen modelin maksimum entropi yöntemiyle müşteri memnuniyeti kategorileri F değeri

Kategori	Kesinlik	Duyarlılık	Belirleyicilik	F- Ölçüsü
Bilgi	0,50	0,04	1,00	0,08
Fiyat	0,75	0,61	0,98	0,67
Hastane Koşulları	0,40	0,22	0,99	0,28
İnsan Kaynakları	1,00	0,17	1,00	0,29
Marka	0,84	0,92	0,59	0,88
Personel	0,53	0,27	0,99	0,36
Randevu	0,33	0,24	1,00	0,28
Tedavi Süreçleri	0,60	0,60	0,94	0,60

Tablo 4. 6: İyileştirilen modelin maksimum entropi yöntemiyle duyu kategorisi F değeri

Kategori	Kesinlik	Duyarlılık	Belirleyicilik	F- Ölçüsü
Negatif	0,84	0,90	0,83	0,87
Nötr	0,87	0,84	0,89	0,85
Pozitif	0,79	0,28	1,00	0,42

Tablo 4. 7: İyileştirilen modelin maksimum entropi yöntemiyle nitelik kategorisi F değeri

Kategori	Kesinlik	Duyarlılık	Belirleyicilik	F- Ölçüsü
Genel	0,86	0,88	0,83	0,87
İstek/Öneri/Soru	0,68	0,22	1,00	0,34
Şikayet	0,81	0,85	0,86	0,83
Teşekkür/Beğeni	0,85	0,27	1,00	0,41

Tablo 4. 8: İyileştirilen modelin DVM yöntemiyle müşteri memnuniyeti kategorileri F değeri

Kategori	Kesinlik	Duyarlılık	Belirleyicilik	F- Ölçüsü
Bilgi		-	1,00	
Fiyat	0,75	0,47	0,99	0,58
Hastane Koşulları	0,75	0,03	1,00	0,05
İnsan Kaynakları		-	1,00	
Marka	0,79	0,96	0,41	0,87
Personel	0,89	0,07	1,00	0,13
Randevu	0,50	0,04	1,00	0,07
Tedavi Süreçleri	0,66	0,52	0,96	0,58

Tablo 4. 9: İyileştirilen modelin DVM yöntemiyle duygu kategorisi F değeri

Kategori	Kesinlik	Duyarlılık	Belirleyicilik	F- Ölçüsü
Negatif	0,83	0,87	0,82	0,85
Nötr	0,83	0,83	0,85	0,83
Pozitif	0,80	0,05	1,00	0,09

Tablo 4. 10: İyileştirilen modelin DVM yöntemiyle nitelik kategorisi F değeri

Kategori	Kesinlik	Duyarlılık	Belirleyicilik	F- Ölçüsü
Genel	0,86	0,32	0,53	0,46
İstek/Öneri/Soru	-	-	-	
Şikayet	0,84	0,26	0,59	0,40
Teşekkür/Beğeni	0,03	0,00	0,02	0,00

Veriler dikkatlice incelendiğinde maksimum entropi yönteminin hem nihai sonuçlarda hem de alt grupların sınıflandırma performansında DVM yöntemine göre daha başarılı olduğu görülmektedir. Nitekim, DVM yönteminin alt sınıflarının F ölçüt sonuçlarında tanımsız gruplar oluşmuştur. ME yöntemiyle yapılan çalışmada ise bilgi, insan kaynakları, hastane koşulları, personel gibi sınıflarla, duygu analizindeki pozitif sınıfının ve nitelik analizde istek ve teşekkür kısmının F ölçüt değerlerinin düşük çıktığı görülmektedir. Bunun sebebi daha önce de belirtildiği üzere veri dağılımındaki dengesizliktir. Eğer tüm gruplarda yeterli miktar veri olsaydı modelin genel başarı oranını tablo 4.11'deki marka alt grubunun başarı oranı olan 93%'e tablo 4.8'deki F-ölçüt değerinin ise 0.88'e yakınsaması beklenebilir. Tablo 4.12'de ayrıntısı belirtilen duygu analizi kısmında negatif duygu ve nötr duygu dağılımları baskın olup ME ile sırasıyla %90,3 ve %83,9 doğruluk oranı ile tahmin edilmiştir. Pozitif duyguları belirten duygu oranlarına benzer verisi miktarı olsaydı benzer isabet oranına ulaşılabilirdi.

Tablo 4. 11: İyileştirilen modelin maksimum entropi yöntemine göre oluşan memnuniyet faktörleri kategorisi hata matrisi

Kategori	Bilgi	Fiyat	Hastane Koşulları	İnsan Kaynakları	Marka	Personel	Randevu	Tedavi Süreçleri	Toplam
Bilgi	1		1		20			1	23
Fiyat		130	1		61	1		19	212
Hastane Koşulları		3	24		64	5	2	12	110
İnsan Kaynakları				2	9			1	12
Marka		27	22		1827	16	4	95	1991
Personel		2	2		71	32	3	9	119
Randevu	1		4		13		6	1	25
Tedavi Süreçleri		12	6		112	6	3	211	350
Toplam	2	174	60	2	2177	60	18	349	2842

Tablo 4. 12: İyileştirilen modelin maksimum entropi yöntemine göre oluşan duygu kategorisi hata matrisi

Kategori	Negatif	Nötr	Pozitif	Toplam
Negatif	1282	135	3	1420
Nötr	213	1125	3	1341
Pozitif	26	32	23	81
Toplam	1521	1292	29	2842

Homojen kümelerin kullanımıyla gerek başarı oranları gerekse F-ölçüt değerlerinde artış olması beklenmektedir. Mevcut başarı oranları da tatminkar olup Twitter gibi markalarında daha çok şikayet aldığı bir mecradan şikayetlerin hem duygu analizleri hem de arzulanan müşteri modeliyle birleştirilerek şirketlerin anlık olarak veri toplamasına ve sınıflandırmasına imkan kılan bir sistem geliştirilmiştir. Sistemin en önemli avantajı sadece bu esneklik olmayıp eklenecek verilerle eğitim seti de kuvvetlendirilebilmektedir. Böylece kullanıldıkça gelişen ve öğrenen bir sistem de tasarlanmış bulunmaktadır.

SONUÇ

Mikro blogların bilhassa da sosyal medya metinlerinin duygu analizi birçok araştırmamanın konusu olmuş ve çok farklı yöntemlerle yüksek tahmin oranlı algoritmaların geliştirilmesi için çaba harcanmıştır. Birçok teknik bakış açılı uygulamalar geliştirilmiş, özellikle de mühendislik disiplinlerinin, duygu analizi uygulamalarından, azami verimin alınması için yoğun çaba sarf ettiği görülmüştür. Pazarlama ve yönetim bakış açısıyla da birçok çalışma yapılmış olsa da teknik bakış açısıyla yapılan araştırmaların konu üzerinde yoğun bir ağırlığı bulunmaktadır. Araştırma konusu hakkında literatürde son dönemde yarı öğreticili ve öğreticisiz sistemlerle üzerine yoğun çalışma yapılmakta olduğu görülmüş ve metinlerde geçen konuların da otomatik olarak keşfedilmesi üzerine gayret sarf edildiği tespit edilmiştir. Her ne kadar şirketlerdeki verilerin %80'inin yapılandırılmamış veriler olduğu tahmin edilse de unutulmamalıdır ki kalan %20'lik veri için şirketlerin veri tabanları, excel dosyaları ve çok çeşitli kaynakları bulunmaktadır. Bu %20'lik veri iyi kıymetlendirilirse denetimli makine öğrenme algoritmaları için çok yararlı bir kaynak olabilir. Yapılabilecek yapay zeka uygulamalarında bir operatörün değerlendirmesi ve sonuçları düzeltmesiyle, öğrenim verisi devamlı gelişip isabet oranı çok daha yüksek bir noktaya ulaştırılabilir. Bu anlamda ilgili tez çalışması mevcut verilerin değerlendirilmesi açısından pratik bir uygulama bakış açısıyla konuyu ele almıştır. Diğer önemli bir konu ise çalışma boyunca açık kaynak kodlu Microsoft ML kütüphanelerinin kullanılmış olmasıdır. Böylece, dileyen şirketler yazılım maliyetlerini asgari düzeyde tutarak ilgili tez çalışmasındaki benzer uygulamaları yapabilirler.

Literatürde akademik müşteri memnuniyeti çerçevesine uygun yapılan ve duygu analiziyle birleştirilen bir çalışma tespit edilememiş olması da bu çalışmanın yenilikçi yönüdür. Ayrıca oluşturulan yapı çok sınıflı birden çok kategori tipini destekliyor olması sayesinde, dilenirse farklı modeller de uygulanabilir. Bu anlamda çalışma statik değil dinamik bir altyapıya sahiptir.

Tüm olumlu özelliklerle beraber, çalışmada iyileştirmeye açık konular ve gelecekte araştırmaya ihtiyaç olabilecek konular bulunmaktadır. Öncelikle, Microsoft ML kütüphanelerinin desteklediği diller arasında Türkçe bulunmaması önemli bir ayrıntıdır. Her ne kadar kullanılan yöntem sebebiyle dil önemli bir faktör olmasa da terim, tarih gibi bazı kullanımların model tarafından tanımlanmasında eksiklik oluşabilmektedir. Modelin doğruluk oranının artması için bu anlamda optimizasyon fırsatı bulunmaktadır. Diğer önemli bir konu ise veri setindeki sınıflar arasındaki dengesiz dağılımlar ve belli etiketler altında aşırı yoğunlaşmış verilerdir. Diğer etiketlerle veri çiftlerinin sayılarının artması ve veri kümelerinin

homojenleşmesi sayesinde algoritmaların isabet oranlarında iyileşmeler olması beklenebilir. Türkçe duygu sözlüğü çalışmaları olgunlaştıkça hibrit uygulamalar da yapılabilir. Örneğin duygu analizinin sözlük yardımıyla yapılırken kategori ve nitelik değerlendirmesinin öğreticili algoritmalar ile yapılması gibi.

Internet'te üretilen veri miktarının günlük 59 Zettabyte'a ulaştığı (Holst, 2021) ve günde 500 Milyon Tweet atıldığı (Whitney, 2020) günümüzde, markaların manuel olarak bu kadar veriye işlemleri ve müşterilerin markaya olan tutumlarını ve duygu durumlarını tam olarak tespit etmeleri mümkün değildir. Duygu analizinin, yapay zeka yöntemleriyle yapılarak müşterinin markaya olan tutumunun anlık olarak takibi hayatidir. Bu tezdeki çalışmanın şirketlerin sosyal medya üzerinden anlık müşteri memnuniyetini belirlemede ve daha iyi hizmet seviyesinin oluşturulmasında yardımcı olacağı umulmaktadır. Böylece olası krizler çıkmadan önlenecek ve müşteride memnuniyeti her daim sağlanması mümkün olacaktır.

KAYNAKÇA

- Aagja, J. P., & Garg, R. (2010). Measuring perceived service quality for public hospitals (PubHosQual) in the Indian context. *International Journal of Pharmaceutical and Healthcare Marketing*, 4(1), 60-83. doi:10.1108/17506121011036033
- Abirami, A., & Askarunisa, A. (2017). Sentiment analysis model to emphasize the impact of online reviews in healthcare industry. *Online Information Review*, 41(4), 471–486. doi: 10.1108/oir-08-2015-0289
- Ajitha, P. et al. 'Design of Text Sentiment Analysis Tool Using Feature Extraction Based on Fusing Machine Learning Algorithms'. 1 Jan. 2020 : 1 – 9. Doi:10.3233/JIFS-189478
- Appel, G., Grewal, L., Hadi, R., & Stephen, A. T. (2019). The future of social media in marketing. *Journal of the Academy of Marketing Science*, 48(1), 79–95. doi: 10.1007/s11747-019-00695-1
- Aslam, S. (2021, Ocak 6). The latest FACEBOOK Statistics (2018). 16 Mayıs 2021 tarihinde <https://www.socialreport.com/insights/article/360000094166-The-Latest-Facebook-Statistics-2018> adresinden erişildi.
- Average time spent daily on social media. (n.d.). 16 Mayıs 2021 tarihinde <https://www.broadbandsearch.net/blog/average-daily-time-on-social-media> adresinden erişildi.
- Aydın, C. R., & Güngör, T. (2020). Sentiment analysis in TURKISH: Supervised, SEMI-SUPERVISED, and unsupervised techniques. *Natural Language Engineering*, 1-29. doi:10.1017/s1351324920000200
- Bakay, Ö., Ergelen, Ö., Sarmış, E., Yıldırım, S., Arıcan, B. N., Kocabalcıoğlu, A., ... & Yıldız, O. T. (2021, January). Turkish WordNet KeNet. In *Proceedings of the 11th Global Wordnet Conference* (pp. 166-174).
- Balducci, B., & Marinova, D. (2018). Unstructured data in marketing. *Journal of the Academy of Marketing Science*, 46(4), 557–590. doi: 10.1007/s11747-018-0581-x
- Balogun, B. A., & Ogunnaike, O. O. (2017). Healthcare organisations in a Global Marketplace: A systematic review of the literature on healthcare marketing. *SSRN Electronic Journal*. doi:10.2139/ssrn.3047747

- Basant Agarwal, Namita Mittala, "Semantic Feature Clustering for Sentiment Analysis of English Reviews", IETE Journal of Research, C.60, No.6, 2014, pp. 414- 422.
- Berger, A., Della Pietra, S. A., & Della Pietra, V. J. (1996). A maximum entropy approach to natural language processing. *Computational linguistics*, 22(1), 39-71.
- Bo Pang, Lillian Lee, "A Sentimental Education: Sentimental Analysis Using Subjectivity Summarization Based On Minimum Cuts", (Çevrimiçi) <http://www.cs.cornell.edu/home/llee/papers/cutsent.pdf> , 15 Ekim 2016, pp.1-8.
- Butt, I., Iqbal, T., & Zohaib, S. (2019). Healthcare marketing: A review of the literature based on citation analysis. *Health Marketing Quarterly*, 36(4), 271-290. doi:10.1080/07359683.2019.1680120
- Calheiros, A. C., Moro, S., & Rita, P. (2017). Sentiment classification of consumer-generated online reviews using topic modeling. *Journal of Hospitality Marketing & Management*, 26(7), 675-693. doi:10.1080/19368623.2017.1310075
- Capellman, J. (2020). Hands-on machine learning with ml.net: Getting started with microsoft's ml.net to implement ... popular machine learning algorithms in c#. In *HANDS-ON MACHINE LEARNING WITH ML.NET: Getting started with microsoft's ml.net to implement ... popular machine learning algorithms in c#* (sf. 90). PACKT Publishing Limited.
- Chang, H. H., Tsai, Y.-C., Wong, K. H., Wang, J. W., & Cho, F. J. (2015). The effects of response strategies and severity of failure on consumer attribution with regard to negative word-of-mouth. *Decision Support Systems*, 71, 48–61. doi: 10.1016/j.dss.2015.01.007
- Corbin, C. L., Kelley, S. W., & Schwartz, R. W. (2001). Concepts in service marketing for healthcare professionals. *The American Journal of Surgery*, 181(1), 1-7. doi:10.1016/s0002-9610(00)00535-3
- D'Aiivico, R. J. (1995). An examination of consumer criteria for choosing hospital services.
- Davidov, D., Tsur, O., & Rappoport, A. (2010, July). Semi-supervised recognition of sarcasm in Twitter and Amazon. In *Proceedings of the fourteenth conference on computational natural language learning* (pp. 107-116).
- Değer, N. (2017). *Sosyal medya mesajlarında veri madenciliği ile duygu analizi* (Yayımlanmamış doktora tezi). T. C. İstanbul Üniversitesi.

- Dehkharghani, R., Saygin, Y., Yanikoglu, B., & Oflazer, K. (2015). SentiTurkNet: A Turkish polarity lexicon for sentiment analysis. *Language Resources and Evaluation*, 50(3), 667-685. doi:10.1007/s10579-015-9307-6
- Dobrucalı, B., & İltter, B. Machine Learning Applications in Social Media Analytics: A State-of-Art Analysis. *Journal of Yaşar University*, 16(61), 95-127.
- Dotnet. (n.d.). Dotnet/machinelearning. 9 Nisan 2021 Tarihinde <https://github.com/dotnet/machinelearning> adresinden erişildi.
- Eckler, P., Worsowicz, G., & Rayburn, J. W. (2010). Social media and health Care: An overview. *PM&R*, 2(11), 1046-1050. doi:10.1016/j.pmrj.2010.09.005
- Farris, P. W., Bendle, N. T., Pfeifer, P. E., & Reibstein, D. J. (2016). *Marketing metrics: The definitive guide to measuring marketing performance*. Upper Saddle River, NJ: FT Press.
- Fischer, S. (2014). Hospital positioning and Integrated Hospital Marketing Communications: State-of-the-art Review, conceptual framework, and research agenda. *Journal of Nonprofit & Public Sector Marketing*, 26(1), 1-34. doi:10.1080/10495142.2014.870431
- Giritlioğlu, H. (2017, November 17). Sağlık alanında Reklam yasağı ve nedenleri - ilan ve bilgilendirmenin sınırı - Tabip Odalarının Görevleri. 9 Nisan 2021 Tarihinde https://ttb.org.tr/makale_goster.php?Guid=95b4cbc4-cb75-11e7-9277-41cb35a9b17b adresinden erişildi.
- Go, A., Bhayani, R., & Huang, L. (2009). Twitter sentiment classification using distant supervision. *CS224N project report, Stanford*, 1(12), 2009.
- Gonzalez, M. E. (2019). Improving customer satisfaction of a healthcare facility: Reading the customers' needs. *Benchmarking: An International Journal*, 26(3), 854-870. doi:10.1108/bij-01-2017-0007
- Gray, S. J. (2008). Healthcare marketing has five 'P's. *Journal of Management & Marketing in Healthcare*, 1(3), 306-313. doi:10.1179/mmh.2008.1.3.306
- Grbic, M., Stimac Grbic, D., Stimac, L., & Sostar, Z. (2019). Digital marketing in healthcare. *European Journal of Public Health*, 29(Supplement_4). doi:10.1093/eurpub/ckz186.077

- He, Y., & Zhou, D. (2011). Self-training from labeled features for sentiment analysis. *Information Processing & Management*, 47(4), 606-616. doi:10.1016/j.ipm.2010.11.003
- Holst, A. (2021, February 05). Amount of information globally 2010-2024. 9 Nisan 2021 tarihinde, <https://www.statista.com/statistics/871513/worldwide-data-created/>
- İstanbuluoğlu, D. (2017). Complaint handling on social media: The impact of multiple response times on consumer satisfaction. *Computers in Human Behavior*, 74, 72–82. doi: 10.1016/j.chb.2017.04.016
- İstatistik veri Portalı. (n.d.). 9 Nisan 2021 Tarihinde <https://data.tuik.gov.tr/Kategori/GetKategori?p=saglik-ve-sosyal-koruma-101&dil=1> adresinden erişildi.
- Jurafsky, D., Chahuneau, V., Routledge, B. R., & Smith, N. A. (2014). Narrative framing of consumer sentiment in online restaurant reviews. *First Monday*. doi:10.5210/fm.v19i4.4944
- Kaya, M., Fidan, G., & Toroslu, I. H. (2012). Sentiment analysis of turkish political news. 2012 *IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology*. doi:10.1109/wi-iat.2012.115
- Karaman, N. İ. (2020). *Measuring The Effect Of Social Media Strategies On The Consumer Perception Of Political Parties In Turkey* (Yayımlanmamış doktora tezi). İstanbul Bilgi University.
- Kim, S. S., Kaplowitz, S., & Johnston, M. V. (2004). The effects of physician empathy on patient satisfaction and compliance. *Evaluation & the Health Professions*, 27(3), 237-251. doi:10.1177/0163278704267037
- Khotimah, D., & Sarno, R. (2019). Sentiment analysis of Hotel aspect using Probabilistic latent semantic Analysis, word embedding and LSTM. *International Journal of Intelligent Engineering and Systems*, 12(4), 275-290. doi:10.22266/ijies2019.0831.26
- Kotler, P., & Armstrong, G. (2008). *Principles of marketing*. Upper Saddle River, NJ: Pearson/Prentice Hall.
- Kondasani, R. K., & Panda, R. K. (2015). Customer perceived service Quality, satisfaction and loyalty in Indian private healthcare. *International Journal of Health Care Quality Assurance*, 28(5), 452-467. doi:10.1108/ijhcqa-01-2015-0008

- Krikorian, R. (2013, August 16). New tweets per SECOND record, And how! 16 Mayıs 2021 tarihinde, https://blog.twitter.com/engineering/en_us/a/2013/new-tweets-per-second-record-and-how.html adresinden erişildi.
- Lee, I., & Shin, Y. J. (2020). Machine learning for enterprises: Applications, algorithm selection, and challenges. *Business Horizons*, 63(2), 157-170. doi:10.1016/j.bushor.2019.10.005
- Lim, W. M., & Ting, D. H. (2012). Healthcare marketing: Contemporary salient issues and future research directions. *International Journal of Healthcare Management*, 5(1), 3-11. doi:10.1179/204797012x13293146890048
- Luo, J., Huang, S. S., & Wang, R. (2020). A fine-grained sentiment analysis of online guest reviews of economy hotels in China. *Journal of Hospitality Marketing & Management*, 30(1), 71-95. doi:10.1080/19368623.2020.1772163
- Marketing Türkiye. (2020, Ekim 22). Social media AWARDS Turkey 2020 Ödülleri sahiplerini buldu. 09 Nisan 2021 tarihinde, <https://www.marketingturkiye.com.tr/haberler/social-media-awards-turkey-2020-odulleri-sahiplerini-buldu/> adresinden erişildi.
- Mazurenko, O., Zemke, D., Lefforge, N., Shoemaker, S., & Menachemi, N. (2015). What Determines the Surgical Patient Experience? Exploring the Patient, Clinical Staff, and Administration Perspectives. *Journal of Healthcare Management*, 60(5), 332–346. doi: 10.1097/00115514-201509000-00007
- Medhat, W., Hassan, A., & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*, 5(4), 1093-1113. doi:10.1016/j.asej.2014.04.011
- Milagros Fernandez-Gavilanes, et.al., “Unsupervised Method for Sentiment Analysis in Online Texts”, *Expert System With Applications*, V. 58, 2016, pp. 57-75.
- ML.net metrics. (n.d.). 9 Nisan 2021 tarihinde <https://docs.microsoft.com/en-us/dotnet/machine-learning/resources/metrics> adresinden erişildi.
- Naidu, A. (2009). Factors affecting patient satisfaction and healthcare quality. *International Journal of Health Care Quality Assurance*, 22(4), 366-381. doi:10.1108/09526860910964834
- Najadat, H., Al-Abdi, A., & Sayaaheen, Y. (2018). Model-based sentiment analysis of customer satisfaction for the Jordanian telecommunication companies. *2018 9th International Conference on Information and Communication Systems (ICICS)* (pp. 233-237). IEEE. doi:10.1109/iacs.2018.8355429

- Onan, A., & Korukoğlu, S. (2016). A review of literature on the use of machine learning methods for opinion mining. *Pamukkale University Journal of Engineering Sciences*, 22(2), 111-122. doi:10.5505/pajes.2015.90018
- Otani, K., Waterman, B., & Dunagan, W. C. (2012). Patient Satisfaction: How Patient Health Conditions Influence Their Satisfaction. *Journal of Healthcare Management*, 57(4), 276-293. doi: 10.1097/00115514-201207000-00009
- Pang, B., & Lee, L. (2004). A Sentimental Education: Sentiment Analysis Using Subjectivity Summarization Based on Minimum Cuts. *Proceedings of the 42nd Annual Meeting on Association for Computational Linguistics - ACL '04*. doi:10.3115/1218955.1218990
- Pang, B., Lee, L., & Vaithyanathan, S. (2002). Thumbs up? *Proceedings of the ACL-02 Conference on Empirical Methods in Natural Language Processing - EMNLP '02*. doi:10.3115/1118693.1118704
- Park, C., & Lee, T. M. (2009). Information direction, website reputation and ewom effect: A moderating role of product type. *Journal of Business Research*, 62(1), 61-67. doi: 10.1016/j.jbusres.2007.11.017
- Polarity resources. (n.d.). 09 Nisan 2021 tarihinde <http://myweb.sabanciuniv.edu/rdehkharghani/sentiturknet-3/> adresinden erişildi.
- Qazi, A., Raj, R. G., Hardaker, G., & Standing, C. (2017). A systematic literature review on opinion types and sentiment analysis techniques. *Internet Research*, 27(3), 608-630. doi:10.1108/intr-04-2016-0086
- Sağlam, F. (2019). *Otomatik duygu sözlüğü geliştirilmesi ve haberlerin duygu analizi* (Yayımlanmamış doktora tezi). Hacettepe Üniversitesi.
- SdcaMaximumEntropyMulticlassTrainer class. (n.d.). 9 Nisan 2021 tarihinde <https://docs.microsoft.com/en-us/dotnet/api/microsoft.ml.trainers.sdcamaximumentropymulticlasstrainer?view=ml-dotnet> adresinden erişildi.
- Smith, K. T. (2017). Hospital marketing and communications via social media. *Services Marketing Quarterly*, 38(3), 187-201. doi:10.1080/15332969.2017.1363518

- Söderlund, M. (1998). Customer satisfaction and its consequences on customer behaviour revisited. *International Journal of Service Industry Management*, 9(2), 169-188. doi:10.1108/09564239810210532
- Tankovska, H. (2021, Şubat 09). Twitter: Most users by country. 23 Nisan 2021 tarihinde <https://www.statista.com/statistics/242606/number-of-active-twitter-users-in-selected-countries/> adresinden erişildi.
- Tankovska, H. (2021, Şubat 10). Twitter: Number of users worldwide 2019-2020. 23 Nisan 2021 tarihinde <https://www.statista.com/statistics/303681/twitter-users-worldwide/> adresinden erişildi.
- The State of Digital Marketing in Healthcare Moving Toward 2017. (n.d.). 23 Nisan 2021 tarihinde from <https://www.greystone.net/docs/default-source/surveys/the-state-of-digital-marketing-in-healthcare-in-2017.pdf?sfvrsn=0> adresinden erişildi.
- Turney, P. D. (2002). Thumbs up or thumbs down? Semantic orientation applied to unsupervised classification of reviews. *arXiv preprint cs/0212032*.
- Unstructured data. (25 Aralık 2020). 09 Nisan 2021 tarihinde https://en.wikipedia.org/wiki/Unstructured_data adresinden erişildi.
- Whitney, M. (2020, Nisan 14). 40 Twitter Statistics marketers need to know in 2020. 23 Nisan 2021 tarihinde <https://www.wordstream.com/blog/ws/2020/04/14/twitter-statistics> adresinden erişildi.
- Yılmaz, H., & Yumuşak, S. (2021). Açık Kaynak Doğal Dil İşleme Kütüphaneleri,. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. doi:10.47769/izufbed.879217
- Yu, H., Huang, F., & Lin, C. (2010). Dual coordinate descent methods for logistic regression and maximum entropy models. *Machine Learning*, 85(1-2), 41-75. doi:10.1007/s10994-010-5221-8

EKLER

EK 1: Örnek Tweetler

Mesaj	Ton	Kategori	Nitelik
Merhaba, 20.05.2020 tarihinde 15.30 civarında istanbul beylerbeyi tüneline kaza geçirdim. O sırada yoldan geçmekte olan araçtan 1 kadın 3 erkek, lacivert kıyafetli beyaz önlüklü sağlık çalışanları inerek ilk müdahalede bulundular. Bu kişiler medical park pendik hastanesinde çalıştıklarını söylediler. Olayın şoku ile isimlerini almadım. Ama kendilerine teşekkür etmek istiyorum acaba kendilerini nasıl bulabilirim? Verdiğim bilgiler çok az ama bu konuda destek olabilir misiniz?	Nötr	Bilgi	İstek/Öneri/Soru
Merhaba, paylaşımlarınız çok güzel ve bilgilendirici. Bu resimde ki "insülin" kelimesi sanırım dikkatinizden kaçtı. insülin yerine "inülin" olmalıydı. Kucuk bir harf hatası olduğu suphesiz asıkar. Ancak bilmeyenler için yanıltıcı bilgi olabileceğinden gozunuzden kacan bu detayı sizinle paylaşmak istedim. İyİ çalışmalar dilerim.	Negatif	Bilgi	Genel
1 haftayı geçti biyopsi sonucu bekliyoruz! Websitenizden görüntüleyemiyorum, çağrı merkezini mail attığını iddia ediyor mail gelmiyor, laboratuvar görüntüleyiyor! Vahiy mi iniyi hastalarınıza bu sonuclar? Nasil iletiyorsunuz siz tam olarak?!! @MedicalParkHG	Negatif	Bilgi	Şikayet
@imamcage @turkseven @DrGunerSonmez "yeşil sebzeler, tahlil ürünleri, balık, badem, fındık, fıstık, ceviz, soya fasulyesi, kuşkonmaz, soğan, domates, havuç, kereviz, pırasa, gravyer peyniri, hurma, kara turp, ayçiçeği, kakao, muz, dil balığı ve sert sular magnezyumdan zengindir." https://t.co/r16ioX9f1O	Nötr	Bilgi	Genel
Batıkentteki hastaneye telefonla ulaşılabilir lütfen yardımcı olur musunuz	Nötr	Bilgi	İstek/Öneri/Soru
@MedicalParkHG "hastanelerimizin lobilerinde yer alan bağış alanları" Bu hastahanein sahibi kim ve bir ticaret söz konusu mu ? Düşündürücü, Resmi ve devlet kanalı ile olmalı bu işlemler.	Nötr	Bilgi	İstek/Öneri/Soru
Merhaba Hastanenede 3 tesla mı var mı bunu öğrenmek istiyorum iyi günler https://t.co/H6HTmqCzZW	Nötr	Bilgi	İstek/Öneri/Soru
Merhaba Urla İyte Gülbahçe Kampüsü içinde 550 yataklı özel bir yükseköğretim öğrenci yurdumuz var. Organ bağışının bilinçlendirilmesi için yurdumuz da konferans verebilir misiniz veya stant kurabilir misiniz ?	Nötr	Bilgi	İstek/Öneri/Soru
Hergün ayrı bir şaşkınlık!. 10 yıllık Sağlık sigortamı Tamamlayıcıya döndürmek istedim. Sigorta acenteleri yüksek ücret talebinde bu da çok mümkün değil. (Devletin ön gördüğü emekliler de dahil denilen) Ama gelin görün ki yaşa takıldım. İnsanlar kaç yaşında emekli oluyor benim mi bilgim eksik!.. Yaş 62 ve red veriliyor Sizin özel kapsamınıza aldığınız tamamlayıcı sigortanız varmı.! Bu Devlete katkı hem yol veriliyor hem ön kesiliyor. Yardım ve desteklerinizi bekliyorum. Saygılarımla verna engin Özdağlar Yalnızoğlu GSM: 05322420100	Nötr	Bilgi	İstek/Öneri/Soru
Merhaba ben goztepe hastanenede covid antikor testi olmak istiyorum, ücretleriniz ne kadar ve randevu sistemi ile mi çalışıyorsunuz?	Nötr	Bilgi	İstek/Öneri/Soru
Tüp bebek tedavisi için yazılan reçete hastaya verildikten sonraki süreç nasıl işlemeli. Hasta istediği Eczaneden almalı. Dkt eczane nasıl fark nasıl ister. Burdaki eczane bu kadar alıyor diyebilir. Bu durum hasta yönlendirmeye girmezmi. Etik midir. Dkt sadece tedavi ile ilgilenmesi gerekmezmi	Nötr	Bilgi	İstek/Öneri/Soru
...SMA hareket hücreleri adı verilen motor nöronlardan kaynaklanan, kas kaybı ile karakterize ilerleyen bir hastalıktır.(Medicalpark) #kramiyeSmalıÇocuklaraVerilsin	Nötr	Bilgi	Genel
@MedicalParkHG Benim önceliğim sağlıktan önce ailenize katılmak. sonra sağlık geliyor şahsen benim için...	Nötr	Bilgi	Genel
Şizofreni, hastaların gerçek ile gerçek dışı olan olguları birbirinden ayırt edememesine yol açan; sağlıklı düşünce akışı, duygu kontrolü ve normal davranışa engel olan ciddi bir beyin hastalığıdır. Kaynakça: https://t.co/XeRzDDwjFe https://t.co/4BeDN1K1u6	Nötr	Bilgi	Genel
selam, bu sene içerisinde mide rahatsızlığımdan dolayı Tarsus Medical Park hastahanesinde muayene oldum. Bu süreçte ilgili epikriz raporuna ihtiyacım var. Tarsus şubesiyle görüştüğümde hastahaneye gelmemiz gerekiyor diye bir cevap aldım ancak benim hastahaneye gelmem mümkün değil şu an için. Yardımcı olabilir misiniz?	Nötr	Bilgi	İstek/Öneri/Soru
Kayıtlı cep telefon numaramı değiştirmek için Gaziosmanpaşa İstinye hastaneni aradığımda hasta kayıt birimi bile görüşmem gerektiğini söylediler. Her aradığımda aktarıyorlar ancak kimse açmıyor. Santraldekiler de daha sonra arayın diyor. Enabız a düşmeyen sonuçlarını sitenizden görüntülemek istiyorum, telefon numaram değiştiği için sms düşmüyor. Yardımcı olabilir misiniz?	Nötr	Bilgi	İstek/Öneri/Soru
Hastanenede 12.10.2018 tarihinde bir tedavi gördüm. Bunun faturası ve raporlarını iletmesini istiyorum	Nötr	Bilgi	İstek/Öneri/Soru
Merhabalar.Medical park olarak üniversite öğrencilerine burs veriyor musunuz?	Nötr	Bilgi	İstek/Öneri/Soru
@MedicalParkHG daha önce muayene olduğum bir hekime bir şey danışmam gerekiyor. Hekime mail atacağım ancak kartını bulamadım. Kurumunuzun mail uzantısı nedir? Çağrı merkezinden öğreneмедim.	Nötr	Bilgi	İstek/Öneri/Soru
Merhaba, geçtiğimiz ay İstinye üni GOP MPark hastanesinde, kızama özel aşılarını yaptırılmışım. Sigortadan ödeme almak istiyorum fakat elimde sadece fiş var. Hastaneye gidip reçeteyi ve faturayı almam mümkün mü?	Nötr	Bilgi	İstek/Öneri/Soru
İyi günler Bursa medikal parkta babam ameliyat oldu ve ben bütün masrafların faturasını aldım ancak baro bizden faturanın detaylandırılmış halini istiyor telefonla iletişime geçiyorum kimse geri dönüş yapmıyor	Nötr	Bilgi	İstek/Öneri/Soru
Sumak çayı içerken faydalarından bilmeli idi. https://t.co/PsBWSSMtcqe	Nötr	Bilgi	Genel
Bugün Galatasaraylı bir oyuncu sağlık kontrollerine gelmiş kimmiş acaba öğrendiyeniz söyler misiniz aramızda kalacak	Nötr	Bilgi	İstek/Öneri/Soru
PENDİK medical park hastahanesine ulaşmıyorum.hasta hakları birimi ile görüşme gerekiyor.dönüş istiyorum.05356298099	Nötr	Bilgi	İstek/Öneri/Soru
perşembe den beri evde oturuyorum lütfen yardımcı olun evde 2 tane 1,5 yaşında çocuk var eşim var kızım var kayın validem var testin pozitif olduğu sisteme düşmediği için ilaçta alamıyorum @drfahrettinkoca @korkmazkaraca31 @MedicalParkHG	Nötr	Bilgi	Genel
Dün medical park antalya hastanesinden almış olduğun hizmetin detaylı dökümünü istedim. Çalışan arkadaş beklemeğin mail atayım dedi. Arkadaşa ulaşmaya çalışıyorum bağlamıyorlar yada açmıyorlar. Aldığım hizmetin detayını neden saklıyorsunuz? @MedicalParkHG @saglikbakanligi	Negatif	Bilgi	Şikayet
@MedicalParkHG Bu redavisi denemek isteyenler ne yapmalı gbm grade 4 hastasım 3 ameliyat oldum	Nötr	Bilgi	İstek/Öneri/Soru
@saglikbakanligi @saglikcozum @MedicalParkHG @drfahrettinkoca Merhabalar, Eşimin Tamamlayıcı sağlık sigortası olmuş olup, bugün medical park Gaziantep te Kolonoskopi oldu eşim. Bize günü birlik yatış işlemi yapıldıBu konu hakkında bilgi almak istiyorum lütfen ilgilendirir misiniz?	Nötr	Bilgi	İstek/Öneri/Soru
Merhaba, ben Göztepe şubenede covid-19 testi yaptırdım. Ücretimin bir kısmının iadesini isteyecektim. Telefonla yetkiliye ulaşamadım. Yardımcı olur musunuz acaba? Tesekjurler	Nötr	Bilgi	İstek/Öneri/Soru

Mesaj	Ton	Kategori	Nitelik
Samsunda yoğun bakımda yer lütfen @sagliklicozum @MedicalParkHG	Nötr	Bilgi	İstek/Öneri/Soru
Merhabalar internet sitenizde şikayet bölümünden şikayet oluşturmuyoruz hata veriyor.Yardımcı olur musunuz	Nötr	Bilgi	İstek/Öneri/Soru
Merhabalar bana bu şekilde bir mesaj geldi, bu kişi ben değilim. Benim numaram mı kayıtlı sisteminizde,iyi günler	Nötr	Bilgi	İstek/Öneri/Soru
@MedicalParkHG Hangi Medical park	Nötr	Bilgi	İstek/Öneri/Soru
Psikolojik danışma saat ücretlerinde ki fiyat nedir? @MedicalParkHG @MedicanaSaglik @MemorialSaglik	Nötr	Bilgi	İstek/Öneri/Soru
Sitenizde e sonuç çalışmıyor şifre göndermiyor ilgilendirilmesinin sonuçları göremiyorum	Nötr	Bilgi	İstek/Öneri/Soru
@MedicalParkHG bitcoin takasına burun estetiği yapacak doktorunuz varmı @MP Destek trabzon hastanesi tercihimdir	Nötr	Bilgi	İstek/Öneri/Soru
@MedicalParkHG Mucize doktor dizisi sizin hastanenizde çekiliyor diye duydum,bu akşam da bu konu işleniyor...müracaat her hastanede mümkün mü acaba ?	Nötr	Bilgi	İstek/Öneri/Soru
Şikayetim ile ilgili sonucu öğrenebilir miyim.	Nötr	Bilgi	İstek/Öneri/Soru
@sputnik_TR @fatihaltayli bende gönderebilirim @drfahrettinkoca ya ekstremit benden de göztepe medical park hastanesi 500 tl almıştır.....tavan fiyat 250 tl yalanını vurayım yüzüne...	Negatif	Fiyat	Genel
Ameliyat için Medikal Park 35 bin dedi.düşünmüsünüz dediler. hayır dedim.5 dakika sora aradılar 25 dediler.gıcık kaptım.serbest piyasa da 5 dakikada bu kadar olmaz.burası 1 gece için 1000 dedi...Acbadem 4000	Negatif	Fiyat	Genel
@MedicalParkHG Peki corona şüphesi ile gelenlerden 1600 lira tedavi için gecelik 1200 lira istediğinize dair söylentilere açıklama yapmalısınız. Susmanız gerçek olduğunu düşündürecektir.	Negatif	Fiyat	Genel
Arkadaşlar dün medical park acile götürdüğüm hastamı 1.000 TL vermeden içeri sokmadı. Bahçelievler Medicalpark lütfen sizde bunu rt yapın ki sizlerde yaşamayın. @MedicalParkHG @MP_Destek @saglikbakanligi #pazar @drfahrettinkoca #pazartesi #AllahRaziOlsunReis ! @RTERdogan	Negatif	Fiyat	Şikayet
► @MedicalParkHG Hasta Memnuniyetisizliği! via @SikayetvarCom https://t.co/JZSEvN3te	Negatif	Fiyat	Şikayet
@chabyhan Ben dun yaptirdim. Delta hospital kucukyali 240 TL. Medical park'ta ayni sekilde 250 TL.	Nötr	Fiyat	Genel
06.11.2020 tarihinde eşime Medical Park Gop hastanesinde PCR testi yapıldı ve testi pozitif çıktı.450 TL ödeme alındı. Tarafınızdan 250 TL olduğu ve üst kısmın iade olacağı açıklandı fakat hastaneden iade edilemeyeceği bilgisi iletildi. @sagliklicozum @drfahrettinkoca	Negatif	Fiyat	Genel
@027_sar Ağam Dragos daki Medikal Park 150 TL	Nötr	Fiyat	Genel
@drfahrettinkoca Samsun özel hastaneler Medicalpark medicana 1,500 tl gecesi bu durumu fırsata çevirdiler bu nasıl anlayış bakanım lütfen el atm bu duruma 500 tl iken bu kadar olurmu yazık	Negatif	Fiyat	Genel
@bluePpink @MuratMmturk Hocam annem medical park gaziosmanpaşa da 7 gün covid tedavisi gördü ve bunun karşılığı olarak 9 bin tl aldılar benden...	Negatif	Fiyat	Şikayet
Corana testi; Balat Yahudi hastanesi 100 TL Çapa Medilife hastanesi 150 TL Bezmi alem vakif hastanesi 250 TL Medical park hastanesi 300 TL devlet hastaneleri ücretsiz yapıyor fark neden acaba ?	Negatif	Fiyat	Genel
@MedicalParkHG En azından bilgiye para almıyorsunuz.	Negatif	Fiyat	Genel
Medical park bir hastane değil kan emici paragöz bir kurumdur. Dun cagri merkezinden ozel saglik sigortamin alerji muayenesini karsiladigi hakkında onay aldım. Gittim muayene oldum. 1300 tl para istediler. Bir de haklı çıkmaya çalışıyorlar @MedicalParkHG @MP_Destek @drdilekarman	Negatif	Fiyat	Şikayet
septom varsa ücret 0, İstanbul Acbadem 300, Medical park 700 TL, Semptom varsa 250 TL . Bu komediden sonra öncelikle böyle bir zihniyeti denetlemeyenleri tebrik etmek isterim. @drfahrettinkoca @MedicanaSaglik	Negatif	Fiyat	Şikayet
İyi Günler bu sabah kızkardeşim Uşak merkezdeki hastaneye geldi corona testi için 135 lira talep edilmiş cebinde 60 lira olan ücretsiz izinde bir vatandaş olarak maalesef geri çevrilmiş devlet hastanesine geçti orada da test yok kan tahlili bekliyor ama ne olacağı belli değil çok mağdur olduk yardımcı olunacağına geri çevrilmesini tasvip etmiyoruz umarım bundan sonraki süreçte uygulama farklılaşır en azından ücret anlamında https://t.co/NHiARE9mp8	Negatif	Fiyat	Şikayet
@MuratMmturk @bluePpink @MedicalParkHG Evet kaydımız mevcut medical park gaziosmanpaşa yetkilileri yalanlarını cevap verirse çıkaracak ortaya bekleyin. ..	Negatif	Fiyat	Şikayet
@AliCaatay daha yeni 300 tl bayıldım medikal park izmir	Nötr	Fiyat	Genel
Kızımın kolumda su toplanması oldu medicalpark bahçelievler hastanesine gittik ve doktora gözükme ücreti kan testi ve hariç 285 lira alındı artı 15 lira katkı payı yazaktır bu paralara 330 lira olan ücretin 30 lirasını devlet veriyor @MedicalParkHG https://t.co/eFGilXDZnm	Negatif	Fiyat	Şikayet
@kacsaatolduturk 65 yıllık omrunun 36 yılını tsk ya ve bu ülkenin savunmasına adanmış en yüksek memur statusundan emekli olmuş bir adamdan @MedicalParkHG Antalya acile geldi diye 300 TL alalı 10 dk oldu Aciller ücretsiz değil miydi ?	Negatif	Fiyat	Şikayet
@sputnik_TR 215 TL muayeneye ücreti verdim ağa medikal park bundan habersiz mi?	Negatif	Fiyat	Şikayet
Bahçelievler medical parka bugün covid 19 testi için gittim 1600 TL ücret aldılar.. #firsatçılık @MedicalParkHG @FOXhaber @fatihportakal	Negatif	Fiyat	Şikayet
Antalya hastanesinde nakil olduk Sut gereği tedavi ve kontrollerde ilave ücret alınmaması gerekirken hastane yönetimi sürekli ücret talep etmektedir.	Negatif	Fiyat	Şikayet
@kacsaatolduson Medicalpark bahçelievler de dahil ... dün akşam 450 tl dediler..	Nötr	Fiyat	Genel
Acbadem , liv, medipol, medical park vs getirir 1500 - 2000 tl ye yaparlar bu biontech aşısını	Nötr	Fiyat	Genel
@Dortmund1907 Bu kafa ile gelişmez. Ben gözlükçüyüm 2 gün önce Medical park hastanesine İsviçre'li bir hasta götürdüm 120 Euro istediler. Dedim ki ben muayene olsam ne kadar 165 TL dedi. Sonra turist otelden niye çıkmıyor. Ben olsam bende çıkmam.	Negatif	Fiyat	Genel
@koronapatt @Hbb32 Medikal park 400 TL. Pazar günü yaptirdim	Nötr	Fiyat	Genel
@kacsaatolduson Medikalpark Gaziosmanpaşa 450 TL alıyor	Nötr	Fiyat	Genel
Özel hastaneler deli gibi covid 19 testi yapıyor. Özel bir hastane yakınında oturuyorum. Küçük bir hastane ve günlük ortalama 100 test yapıyor. Kurumsal her şehirde hastanesi olan medikal park kaç test yapıyor sizce? Ve bir test 300 tl @mpark	Nötr	Fiyat	Genel
@drfahrettinkoca Bakanım medikal park hastanesinde covid testi 450 tl.	Nötr	Fiyat	Genel
Durdurmuyor dün bütün gün hastamızı olan @MedicalParkHG Pendik de sıfır temizlik önlemleri ile dizi çekimi yaptılar !!! https://t.co/b6wjPhUb2t	Negatif	Hastane Koşulları	Şikayet

Mesaj	Ton	Kategori	Nitelik
@MedicalParkHG uşak hastahaneniz devamlı lokanta gibi kokuyor!	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG İstanbul Göztepe Hastanesi 1. Kat Radyoloji servisiniz de bekleme alanı Tuvalet kokusundan oturulamaz halde. Kapıya değnekçi koyup sıkı sıkıya yaptığınızı takibi, hava filtrelerine tuvalet hijyenine de gösterin	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG Çanakkale Medikalpark acaba para mı yok temizlemeye? Yoksa bağışıklık kazansın insanlar diye mi çamur bırakıyorsunuz yerleri?WC kokusunu alan yönetici de mi yok ??Biraz temizlik !! İtibarınıza leke vurmayın...@saglikbakanligi	Negatif	Hastane Koşulları	Şikayet
☹☹ Bir kontrol etmeniz dileğiyle!! https://t.co/ps7VXFNEB			
@MuratpasaBld Fener Mah. 1940 Sok.'ta oturuyoruz. Medical Park hastanesi müşterilerinin otopark olarak kullandığı boş arazide bir sürü çöp ve tıbbi atıklar vardır. Ayrıca, Falez boyu da hiç temiz değil. Lütfen, gereğini yapın. Sevgi ve saygılarımla.	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG Uşak hastanenizde mademki tadilat yapacaksınız. Hasta almayın. 700 TL sadece yatak ücreti ni sizin mıcır ve balyoz seslerinizi dinlemek için odemiyorum.	Negatif	Hastane Koşulları	Şikayet
@MP_Destek @MedicalParkHG Yani daha önce de ilettiğim oldu ama pek bir şey değişmedi. Hatta yine gittim hastanenize, değişen bir şey yok. Lavaboda el sabunu yok. Yani ben numaramı verince çözülecek, hemen vereyim ama iletişim bilgilerimle alakasını çözemedim...	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG yok yok hala yok resepsiyonda 25 dkdir bekliyoruz tekerlekli sandalyeniz yokkkk	Negatif	Hastane Koşulları	Şikayet
Kurum olarak sosyal mesafe kuralınız sizin için bundan mi ibaret @MedicalParkHG @Medicalparktarsus @saglikbakanligi	Negatif	Hastane Koşulları	Şikayet
@drfahrettinkoca https://t.co/YoERSRbNRZ			
Selamlar burası D100 bulvarındaki Pendik Vm Medicalpark Hastanesi acil bölümü. Hastanenin srka kısmına denk geliyor yol ve D100 e bağlanıyor yaklaşık 18 aydır faaliyette ve ne bir trafik ışığı var nede bir üst geçit hergün hastalar kucaklarında bebekleriyle koşa koşa geçiyorlar. https://t.co/ovFYSXhwIM	Negatif	Hastane Koşulları	Şikayet
Medical park bahçelievler Hastanesinde neredeyse tüm dezanfektan kutularının boş olması, hastanede bulunduğu süreçte bir kez bile ateş ölçümü yapılmıyış şaka mı? normalleşme süreci farklı anlaşılması olabilir mi? @MedicalParkHG #coronavirus #COVID19 #SağlıkBakanlığıSiziDinliyor	Negatif	Hastane Koşulları	Şikayet
medikal park'ta korona testi yaptırıldı. kabin yapmışlar insanlar içeri giriyodu doktor dışarda test yapıldı. onlarca kişi giriyodu kabine dezenfekte falan yok. koronam yoksa bile orda kapmışlardır. doktorun içerde bizim dışarda olmamız gerekmiyo mu?	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG @saglikbakanligi			
@MedicalParkHG Hastane odalarınıza bakım yapmayı düşünüyormusunuz	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG bahçelievlerdeyim katlaradae dezenfekte unitelerinin içi boş bu nasıl hassasiyet?!..	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG Trabzon Karadeniz Hastaneniz 6. Katta 1 aylık bebeğimizle bizi maruz bıraktığınız bali kokusuna sonsuz teşekkürler harika hastaneler grubu. Bütün kat leş oldu bali kokusundan gece vakti. Bunjn hesabını nasıl vereceksiniz	Negatif	Hastane Koşulları	Şikayet
@ahmetsaymadi Babam mide kanseri. İki aydır hastaneye gidip geliyoruz. Onu evden yeni doğmuş bir bebek gibi korunaklı çıkarıp her seferinde dezenfekte ettiğim arabaya koyup hastaneye götürüyordum. Peki hastaneden durum ne ? #medicalpark Eldivensiz maskesiz çalışanlar, doktorlar.	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG Gzt.hst. nde hasta işlemleri bankosunda ki yoğunluk sebebiyle,kimik bırakmak ve çıkışta provizyon işlemlerini yapabilmek için 30'ar dk.dan en az 1 saat bekleniyor. Hasta kabul ve banko işlemlerinizi acil iyileştirmeniz gerekiyor. Devlet hst.nin paralı hali! https://t.co/UhYX4k8ws	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG Batman medical hastanesinde namaz vakti namaz koşmak istedim. Mescit yok dediler. Üzücü bir durum malesef. Bayanlar için varmış erkekler için yok dediler. Kocaman özel bir hastanede erkekler için mescit olmaması garip bir durum.	Negatif	Hastane Koşulları	Şikayet
@drfahrettinkoca			
@MedicalParkHG @livhospital temizlik sıfır ... https://t.co/7uLJESXBn	Negatif	Hastane Koşulları	Şikayet
@drfahrettinkoca Sayın Bakanım; Burası özel bir hastane daracık koridorlarda nasıl net yapalım !!! @MedicalParkHG 'a bir sorun bence bu durumda kaç net hasta çıkar!! Konum Çanakkale MedicalPark....Kaç yere sosyal medyadan yazdım ama cevap veren yok!! https://t.co/fBWedicEvG	Negatif	Hastane Koşulları	Şikayet
@saglikbakanligi @MedicalParkHG @Kucukkayalsmail @ismailsaymaz her yerde #coronavirus ten bahsediyorduz hastanenin tüm katlarında dezenfektanlar tükenmiş durumda yetkililere bildirildiği halde çözüm bulunmamakta stokta olmadığı söyleniyor hastaneler böyle ise vay halimize ... https://t.co/7PCm4qazc5	Negatif	Hastane Koşulları	Şikayet
Medical Park - Acil servis rezilliği ... https://t.co/8cLscw7WQB https://t.co/L05oi463L9	Negatif	Hastane Koşulları	Şikayet
Medical Park Ankara Hastanesi'de @MedicalParkHG sonda boşaltacak kap bile yok. Nasıl bir özel hastanesiniz acaba. Paralı devlet hastanesi olmuştunuz. Geçmiş olsun.	Negatif	Hastane Koşulları	Şikayet
@MP_Destek En büyük üzüntüm ciddiyet sıfır. 11. Kattan -3e inmek 15dk sürdü. Allah korusun deprem olsa düşünemiyorum, uzak durun burdan.	Negatif	Hastane Koşulları	Şikayet
Trabzon yıldızlı medicalpark hastanesi, ısıtma sistemini nezaman açmayı planlıyorsunuz? Kemoterapi servisindeki hastalar üşüyorrrrr...#medicalpark	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG Medicalpark Karadenizhastanesi Trabzon dayım. Yine aynı problem. Acil gibi yerin müşahede odasında hasta çok görevli yok.	Negatif	Hastane Koşulları	Şikayet
@MedicalParkHG Pendik hastanesi otoparkınızda yanlış park eden araç yüzünden mahsur kaldım.Pendik Hastanenizin otoparkında kaos var 3 kez anons ettirdim görevli bile gelmedi. Hizmet anlayışınızla ilgili endişelerim var. Halen bekliyorum!	Negatif	Hastane Koşulları	Şikayet
Mersin Tarsus a personel alımı olacakmış bununla ilgili süreç hakkında bilgi alabilir miyiz	Nötr	İnsan Kaynakları	İstek/Öneri/Soru
@MedicalParkHG			
Çalışanlarının bu zor zamanında maaşını ödememek nedir yahu? Nasıl bir mobbingtir bu. ?	Negatif	İnsan Kaynakları	Şikayet
Bundan sonra #Medicalpark'a gitmiyorum.			
@drfahrettinkoca Sağlıkçıları ücretsiz izine çıkarıyorlar, zorla rapor aldırıyorlar alanlarda eksik çalıştırıyorlar. servisleri kaldırıp işe nasıl gelirsiniz gelin diyorlar kimse sesimizi duymuyor medicalpark izmit hastanesine ne olursunuz bir el atın hepimiz mağduru	Negatif	İnsan Kaynakları	Şikayet
#vaka98674			
1 ay Gazinatep Medikal park hastanesinde hemşire olarak çalışmış olmama rağmen hakkımı yediniz maaşımı yatırmıyorsunuz lafa gelince de Türkiye'nin en iyi özel hastanesi,yersen @MedicalParkHG @medicalparkgza	Negatif	İnsan Kaynakları	Şikayet
1 ay Gazinatep Medikal park hastanesinde hemşire olarak çalışmış olmama rağmen hakkımı yediniz maaşımı yatırmıyorsunuz lafa gelince de Türkiye'nin en iyi özel hastanesi,yersen	Negatif	İnsan Kaynakları	Şikayet
@MedicalParkHG @medicalparkgza			
Merhabalar,Biyomedikal Mühendisliği okumaktayım. Samsunda oturuyorum ve hastanenizde staj görmek istiyorum. Lütfen yardımcı olabilir misiniz? İletişime kimle geçebilirim.	Nötr	İnsan Kaynakları	İstek/Öneri/Soru
RT @oktaydogan1983: Merhaba Dostlar Engelli Kardeşimiz Ezgi'nin iş arayışında bugün bir gelişme oldu. Medical Park sesimize ses oldu ve...	Pozitif	İnsan Kaynakları	Teşekkür/Beğeni
@precdexx 1 ay Gazinatep Medikal park hastanesinde hemşire olarak çalışmış olmama rağmen hakkımı yediniz maaşımı yatırmıyorsunuz lafa gelince de Türkiye'nin en iyi özel hastanesi,yersen @MedicalParkHG @medicalparkgza	Negatif	İnsan Kaynakları	Şikayet
Cv için mail adresi alabilir miyim?	Nötr	İnsan Kaynakları	İstek/Öneri/Soru
@oktaydogan1983 @MP_Destek Allah rast getirsin,yardımcı olanların işi rastgelsin	Pozitif	İnsan Kaynakları	Teşekkür/Beğeni
@hattiyilmaz Buna dikkat ettiğimizi için teşekkürler. Eşim Medical Park'ta YSP ve hemşirelerle birlikte covid19 lularla en hafır neşir olan grupta. Ek ödemeyi bırakın, çalışma saatleri artırıldı ve işi bırakanlar nedeniyle iş yükü neredeyse iki katına çıktı. :/	Negatif	İnsan Kaynakları	Genel
@yekta_sarac @istinyeunivedu öğrencisiz çoğu devlet üniversitesinin aynı bölümleri uzaktan eğitim alırken klinik uygulama adı altında LİV ve Medicalpark hastaneleri için ücretsiz iş gücü olarak çalıştırılıyor Bizler başboş hastanelerde kendi kendimize öğrenmeye çalışıyoruz @UstaMuharrem	Negatif	İnsan Kaynakları	Şikayet
İşsizim bana hastanede bir görev verin	Nötr	İnsan Kaynakları	İstek/Öneri/Soru

Mesaj	Ton	Kategori	Nitelik
Sevgili Elazığ için yardım vakti ailesi, gözleri görmeyen dört çocuklu bir annemiz için medicalpark hastanesindeydik. Anne önce sevgili hocamız Dr. Turgut YILMAZ hocamıza, sonrasında Dr. Fetih KILIÇ hocamıza yönlendirildi. https://t.co/P2j2aqizBb	Nötr	Marka	Genel
RT @MedicalParkHG: Ramazan çorbalarınızı şehriye, beyaz un, erişte yerine buğday, bulgur, mercimek veya nohut ile zenginleştirin. Bol sebze...	Nötr	Marka	Genel
@sinemums Sinirden ne yapacağımı bilmiyorum ama medicalpark da böyle	Negatif	Marka	Genel
İlçemizde başan ile faaliyetlerini sürdüren Medical Park Hastanesinde tedavi görmekte olan komşularımızı ziyaret ettik. Her birine acil şifalar diliyorum https://t.co/UEkZmxluGp	Pozitif	Marka	Genel
@lazedadas25 Allah razı olsun.. Medical Park :))	Pozitif	Marka	Genel
Oyuncumuz Mario Lemina'nın sponsor hastanemiz Medical Park Bahçelievler Hastanesi'nde yapılan tetkikleri sonrası sağ üst arka adale grubu ve fasyasında orta düzeyde zorlanma (ikinci derece strain) ve kanama tespit edilmiştir. Oyuncumuzun tedavisine başlanmıştır. https://t.co/PsglsH1F78	Nötr	Marka	Genel
Bu videoyu MedicalPark göztepe hastanesinde Acil bölümündeki doktora izletmelisiniz. Korona korkusundan gelen her hastaya elini dahi sürmeden devlet hastanesin gönderiyir. Zor bir salgın sürecindin geçerken @MedicalParkHG hastanelerinin bu süreci ne derece güzel yönettiğini gördük https://t.co/VMxD9mbxG7	Negatif	Personel	Şikayet
@UstaMuharrem Hocam ellerinizden operim benim kardesim goztepe medical park ta kanser tedavisi goruyordu.doktorların ihmali yuzunden kardesim vefat etti.	Negatif	Personel	Şikayet
@atakumbeltr @bskcemildeveci Siz. Tanıyorsunuzuz Dr da baska Dr yokmuymdu diye yorum yazıyorsunuz medikalpark acile hemen hemen hergün hastamı getiriyorum ben Dr gibi Çalışkan hastalara değer veren canını dişine takan hemde acil gibi stresli bir ortamda herkese sevgiyle yaklaşan nadir Dr bir tanesi	Pozitif	Personel	Genel
Ebe bana koridorıda "Ablanın açıklığı 4 cm. Doğuracaksa doğursun doğurmayacaksa taburcu olsun" dedi. Biz de insanlık ölmüş diye düşünüp Elazığ Medical Park'a gittik. Sevgili @ElazigMP umarım çalışanlarına hakettikleri ücreti ödüyorsunuz. Gerçekten muazzamlar. +	Pozitif	Personel	Teşekkür/Beğeni
@MedicalParkHG Hocam insanlığın bilgi ve tecrübenle çok övgüye değerisin. Başarılarının devamını dilerim.	Pozitif	Personel	Teşekkür/Beğeni
@sema_caner Sanırım bunların sonu gelmeyecek bugün de biz yabancı uyruklu doktor krizi yaşadık. Davanızda sonuna kadar haklısınız keşke böyle insaale doktor olmasa. Neliidi belirsiz biri daha öğrenci gelmiş burada doktorum diyor. @MedicalParkHG	Negatif	Personel	Şikayet
Gaziantep de yoğun bakımda yatan hastamız Hatice yükseloglunu defalarca tuvalet e götürmek te Zorluk çikaran hemşirenizi hemşirelerinizi nereye şikayet edebilirim	Negatif	Personel	Şikayet
@MedicalParkHG #medicalpark hastanesi #Covid_19 #Covid2019TR #COVID19 #coronavirus #CoronavirusPandemic #CoronaWarnApp #Corona tedavi yöntemlerive ilgililerine çok teşekkür. Ağrılan durumumu düzelten bütün covid kati çalışanlarına entube olan canım doktrma minnettarım acılışıfa	Pozitif	Personel	Teşekkür/Beğeni
Merhaba, 21 inde KBB doktoru Muhammet Bey ile görüşüp operasyon kararı aldık.Halkbankası emekli sandığı üyesiyim sigortamın karşılaması için kurumumdan provizyon alınması adına Kardelen Hanıma belgeleri teslim ettim. Öğlene kadar tüm işlemlerim bitmiş olmasına rağmen 25inde hala dönüş yapılmadığı için farklı 4-5 kişiden aktarılarak kendisine ulaştığımda tomografi raporumun yeni çıktığını başvuruymu hemen yapacağını iletti. Az önce beni tekrar aradığımda kuruma nasıl başvuru ve bilgileri iletmesi gerektiğini bilmediğini farkettim çünkü bana sordu. Ben daha önce de 2 kez bu operasyonu farklı hastanelerde oldum özel kurumda çalışanlar tarafından aranılıp başvuru işlemlerine dair bilgi vermedim sorgulanmadım da. Üstelik dün yapacağını belirttiği başvuruymu bugün gün bitmiş hala kurumuma iletmediğini belirtmektedir. SİZDEN RİCAM ACİL OLARAK BİLGİLİ VE YETKİLİ TARAFINDAN MÜDAHALE EDİLEREK İŞLEMLERİMİN DOĞRU VE HIZLI BİR ŞEKİLDE TAMAMLAYACAK PERSONEL İÇİN YARDIMLARINIZI RİCA EDERİM. İyi çalışmalar	Negatif	Personel	Şikayet
@TrErdemSezer @Yektani @MedicalParkHG Haznedardaki mesicalpark çalışanları aşırı ukala bu arada bana bi keresinde tc numaranızı verirmisiniz hani kimliğinizde yazıyo ya demişti	Negatif	Personel	Şikayet
@MedicalParkHG Samsun hastaneiniz kamu hastanelerinden daha ilgisiz, umursamaz çalışanlara sahip bilin istedim!	Negatif	Personel	Şikayet
Medicalpark doktorlarınız Harika. Personeliniz çok kötü.	Negatif	Personel	Şikayet
Evet Dr geldi,toparladınız ,yann taburcusunuz dedi. Bu süreçte özverili şekilde çalışan Medikal park sağlık çalışanları ve enfeksiyon uzmanı dr'um Fatih Bostancı'ya çok teşekkür ederim. Bi badireyi atlatk. ☺	Pozitif	Personel	Teşekkür/Beğeni
Dr. Gülay demirdağ yanındaki asistanınıza isminin bengüsü olduğunu öğrendik lütfen konuşma uslubünü müşterilerle nasıl konuşulması gerektiği hakkında eğitim verebilir misiniz	Negatif	Personel	Şikayet
@Angel_Turkish @MedicalParkHG @MemorialSaglik Birbirine kattım valla. En tahammül edemediğim gülmeyen surat. Bu işi yapıyorsan hakkıyla yapacaksın.	Negatif	Personel	Şikayet
@saglikbakanligi @sagliklicozum @drfahrettinkoca istanbul medical park gop hastanesi , dr yavuz selim yıkıcı ve hasta hakları temsilcisi ecem hn hakkında ciddi bir şikayetim var bana ulaşın. Kayınvalidem hastanede düştü doktor hastaneden kovdu şimdi yan hastanedeyiz bu bir rezalet	Negatif	Personel	Şikayet
@karakulecommand Hayrı gözlüğüller var , medical park daydı en son abi bir araştı istersen iyi bir doktor	Pozitif	Personel	Teşekkür/Beğeni
@drfahrettinkoca sayın bakanım, bir doktor, hasta olduğum halde (sesim kısık, zor nefes alıyorum); 'siz başka doktor arkadaşın hastasısınız, size bakamam, benden randevu almışsınız ama kontrole giriyor, ben ilgilene mem diye bilir mi? @MedicalParkHG Gop dr akin zengin.	Negatif	Personel	Şikayet
Merhaba dün istinye üniversitesi medicalpark gaziosmanpaşa hastanesi acil bölümüne geldik 5 aylık oğlum var adı yiğit ali güngör yüksek ateşi vardı kan tahlilleri yapıldı ve bekleme sürecine geçtik saat 16:00 gibi hastaneye giriş yaptık. Kan testi sonuçlarının çıkması 17:00 yi geçti ve acil doktorunun kapısında 18:15 e kadar bekleidik kendisi 17:00 ye kadar normal mesaisini yapıp acil nöbetine geçiyormuş o nedenle 17:00-18:00 arası dinleniyormuş hemşire hanımdan rica edip doktor beyi aratıp 5 dakika gelip test sonuçlarına ve bebeğimize bakmasını istedik. Kendisi gelmedi ve bizi odasının önünde bekletti. Biz bebeğimizin tüm kontrolleri için sürekli bu hastaneye geliyoruz ve doktorumuz hidayet katipoğludur. Doktorumuzdan memnunuz fakat acil bölümü bizi çok şartırtı demekki bebeğimize ciddi bir şey olsa 17:00-18:00 arası hastaneye gelsek bir başımıza kalacağız orada ben bu kadar ilgisiz bir acil doktoru görmedim. Hidayet bey olmasa emin olun bir daha bu hastaneye kesinlikle gelmem.	Negatif	Personel	Şikayet
@MuratMmturk Marmara üniv. Prof. Larından Necmettin Pamir'in talebesi Prof dr. Deniz Konya şiddetle tavsiyemdir. Bugün Türkiye'deki 2. 3 beyin cerrahinden birisidir. Medical park göztepe	Pozitif	Personel	Teşekkür/Beğeni
yardımcı olan firmalara da teşekkür etmek gerekiyor burada. @MedicalParkHG @MP_Destek medical park göztepe müşteri hizmetleri bölümünde çalışan kıymet hanım'a (umarım doğru hatırlıyorumdur) ve çalışanlara teşekkür ederim. hızlıca yardımcı oldular. ❤️🙏	Pozitif	Personel	Teşekkür/Beğeni
@FUATUGUR Acil şifalar diliyorum... Izmirde medikal park bize yakın acil olsun normal olsun sağlık için oraya gidiyoruz... Acil bölümünde her defasında güler yüzlü işinin ehli bir personel ile karşılaştık... Acilci doktorlar hep doğ yada yrd doğ oldu... Allah razı olsun hepsinden...	Pozitif	Personel	Teşekkür/Beğeni
@fondiplermisin Çok üzgünüm ama bir mucize arıyorsun umarım bulursun izmir medical park hastanesinde prof uğur hoca var en azından hastayı yormuyor gerçekçi bir doktor	Pozitif	Personel	Genel

Mesaj	Ton	Kategori	Nitelik
Bir muhattap bulabilmek için çırpınan ve aldığı cevaplarla tatmin olmayarak "Şikayetle bulunacağım" diyen vatandaşa "bana birşey olmaz ben her zaman buradayım!" diyerek vatandaşı püskürtmeye çalışan saygısız personelinizle hizmet vermeye devam! @MedicalParkHG #medicalpark https://t.co/xDFYh01p	Negatif	Personel	Şikayet
@MedicalParkHG Hiçbir sebep göstermeden randevuyu 24 saat kala nasıl iptal edilebiliyor . Keyfe göre mi? hasta alınıyor . Sorunca açıklama bile yapılmıyor. Bunu birde Göztepe medicalpark yapıyor. Hastane mi? Bakkal dükkanı mı? Belli değil.	Negatif	Randevu	Şikayet
Bahçelievler hastanenizde, randevu olduğu halde bankoda yarım saat hatta 40 dk. varan sürelerde hastalarınızı bekletmek, bekleli yada hamile hastalara öncelik vermemek, hastaya hasta olarak değil de müşteri olarak bakmak sizde adet galiba @MedicalParkHG	Negatif	Randevu	Şikayet
2 gündür hastanenizden randevu almak için uğraşıyorum nesiniz siz ülkenin en ulaşılabilir hastanesi falan mı? @MedicalParkHG	Negatif	Randevu	Şikayet
yahu arkadaş bu nedir satarken bir telefonla satıyorlar ama iş olması iyadeye gelince bir o kadar süründürüyorlar medikal park hastahanesi	Negatif	Randevu	Şikayet
@MedicalParkHG saatlerdir ulaşamıyoruz geri dönen de yok nasıl randevu alacağız devlet hastanesi daha çabuk cevap veriyor nasıl özel hastahane bu ???	Negatif	Randevu	Şikayet
@MedicalParkHG Merhabalar, 14/10/2020 Saat: 13:45 Doc. Dr. Banu Kale ile randevum bulunmaktadır. Bu randevuyu 09:00'a alma imkanım olabilir mi ? şehir dışına çıkacağım öncesinde Banu Hanım ile görüşmem lazım. Asistanına ulaşamadığımdan buradan ya Yardımcı olursanız çok sevinirim.	Nötr	Randevu	İstek/Öneri/Soru
On line randevu alacağım sigortamı kullanarak 1 saat telefondan telefona aktardınız bu kadar mükemmel zor.	Negatif	Randevu	Şikayet
@MedicalParkHG Hastanesi size yanlış randevu verir, düzeltceğini söyler bu konuda aksiyon da almaz hemen. Doktorunuza ulaşmanız konusunda da yardımcı olmaz. Sizin de nasılsa kolayca tedavinizi bilen doktoru bırakamayacağınızı bildikleri için günlerce oyalarlar.	Negatif	Randevu	Şikayet
@drfahrettinkoca sayın bakanım eşim 6,5 aylık hamile,takibimizi @MP_Destek medicalpark hast yapılmakta, geçen hafta hekimimizin Mayıs ayına kadar olmadığını söylediler ve başka bir hekime randevu oluşturdular,bugün ise yeni hekiminde 1 ay idari izne ayrıldığını söyleyip başka +	Negatif	Randevu	Şikayet
Çağrı merkezinden randevu alıyorsunuz, hastaneye geldiğinde doktor işe "yeni başladığı için" özel sağlık sigortası olan hastaları "henüz kaşesi olmadığı için" ancak ücretli görebileceğini öğreniyorsun. İşini gücünü ayarlayan hiç önemli değil!	Negatif	Randevu	Şikayet
@MedicalParkHG mu sistem??	Negatif	Randevu	Şikayet
@MedicalParkHG Medicalpark fatihten randevu aldık cumartesiye randevu onaylandı.sonrasında ise iptal ettiler doktor rapor almış annemin tansiyon 20 ve böyle bir hastane gormedim lutfen duyarlı olun bashekimim hemen doktor rapor aldı deyip kilif uydurdu tabii ellerinde @drfahrettinkoca @RTErdoğan	Negatif	Randevu	Şikayet
Yaklaşık 3 hafta önce 14.01.2021 tarihine yani bugüne randevu aldım. 2 gün önce randevu onayı için gelecek misiniz diye aradılar. Sorun yok geliyor dedik. Dün tekrar beni aradılar telefonla başka görüşmede olduğum için açamadım. Sonrasında mesaj geldi randevunuzda değişiklik gerekmektedir aranız diye. 444 ile başlayan numarayı aradım oradakiler bilgi sahibi değil. Hastane size dönecek diyorlar ancak dönen yok. 3 kez aradım sonuç değişmedi. Doktor öğleden sonra hastane dışındaymış. Randevular iptal ya da değiştirilmiştir diyorlar. Hastaneden dönüş yapılacaktı. Niye 3 hafta bekledik neden 2 gün önce randevu teyidi aldınız. Bu nasıl bir mantıksızlıktır.	Negatif	Randevu	Şikayet
@UstaMuharrem @barisbezel @MP_Destek @MedicalParkHG @AllianzDestek 1 haftadır Medical Park Bahçelievler Radyoloji bölümüne ulaşamıyorum. Biraz önce 15 dakika telefonda bekledim. Randevu almak için çile çekiyorum. Allianz Sigorta tetkik için ödemeleri bile yaptı. Büyük rezalet!!!	Negatif	Randevu	Şikayet
@MedicalParkHG iki gündür Ankara'daki hastanede randevu verip iki gündür keyfinize göre randevu iptalini sadece sizde görüyorum. Hasta ilişkileriniz çok güzel. Bu keyfiyeti sağladığı için size de teşekkür ederim @saglikbakanligi @drfahrettinkoca	Negatif	Randevu	Şikayet
@MedicalParkHG basit bir ultrason için 3 hafta sonrasına gün veren, devlet hastanesinden farkı olmayan kurum. Parayı pesin alıp mağdur ediyorlar.	Negatif	Randevu	Şikayet
@SikayetvarCom @MedicalParkHG göztepe hastanesindeki check up biriminden sattıkları paket doğrultusunda randevu almak için 4 gündür, günde en az 30 kere arıyorum. Açan yok, ana merkezden biz size geri dönüş sağlayacağı deniyor. Asla gerçekleşmiyor. Rezillik!	Negatif	Randevu	Şikayet
@saglikbakanligi @drfahrettinkoca 04/04 tarihinde Medical park florya hastanesi ambulans ile gelen korona şüphelisi ananemi kabul etmedi.En yakın devlet hastanesine yönlendirildi. 83 yaşındaki kadın 24 saat acilde bekletildi ve test sonucumuz daha çıkmadı ve ölmek üzere!!!!!!!	Negatif	Tedavi Süreçleri	Şikayet
Fatura istedi, ameliyatı İPTAL ettiler #700BinOEğretmenTakiplesiyor #AcikveNet #ANTvFB #AbdullahCATLI #Arta #CenazelskencesineSon #ALLAHUEEKBER #medicalpark #seskocaeli	Negatif	Tedavi Süreçleri	Şikayet
@MP_Destek Medical park hastanesine görüşme ağırsı şikayeti ile gittim. anjyo ettiler. hiçbir şey çıkmadı. 10 gün sonra aa pardon sizde kansızlık varmış. 15 ekimde bir daha gelin ,bir daha tahlil yapalım. Tahlillerimi istiyorum vermiyorlar. insanları bu şekilde kandırarak mı ...	Negatif	Tedavi Süreçleri	Şikayet
@karakurt_e @barisatay @drfahrettinkoca Yoo test ücretsiz onda sıkıntı yok ama doktorlar ısrarla test yapmak istemiyor Yedikule görüş hastanesi bahçelievler medicalpark ve samatya	Negatif	Tedavi Süreçleri	Şikayet
@YelizKoray @drfahrettinkoca @MedicalParkHG Bu olay sadece sağlık bakanlığını değil aynı zamanda fatura kesmeyi red ettiği için hazine bakanlığına bağlı defterdarlık ve maliye gibi kurumlarında işlerini yapmadıklarını gösterir.	Negatif	Tedavi Süreçleri	Şikayet
@MP_Destek @forzabesiktas Hastane ismi verilmiş,ameliyat tipi belli. iptal edilen ameliyata, çıkışlara baksanız bulursunuz rahatlıkla.Hasta şikayetlerini dikkate almadığınızı ben bire bir yaşayarak öğrenmiş birisiyim..Son bir senedir check up için aradığınızda hastanenize bir daha adım atmam diyorum.	Negatif	Tedavi Süreçleri	Şikayet
Sağlıklı olmasına rağmen check-up a giren babam verdiğiniz ilaç sonucu bir sonraki gün acillik oldu ve acil de para almadığınız için hiçbir müdahale yapmadınız sizi mahkeme paklar doktorlarınız ve gerekli kurumlara şikayetlerimi yapıyorum sınıftakaldın	Negatif	Tedavi Süreçleri	Şikayet
@MP_Destek @MedicalParkHG	Negatif	Tedavi Süreçleri	Şikayet
@MedicalParkHG @saglikbakanligi Dün Pendik hastanenizden öğlen verdiğiniz tahlil sonucum 24 saatte çıkacak denildiği halde hala çıkmadı. Arıyorum tek bir muhatap bulamıyorum. Not bırakıyorum dönen yok! Müşteri hzmtlerine şikayet açıyor ama dönen yok! Kandırıldım ve muhatabım yok!	Negatif	Tedavi Süreçleri	Şikayet
Babaannem Medical Park'ta kanser tedavisi gördü. Butun tedavi masraflarını bizden tahsil etti. Cunku eliniz kolunuz bağlı, veriyorsunuz. Dava ettik. Sgk para cezası kesti, istinafa basverdular. Istinaf paranin iadesine karar verdi. 2016'da acilan dava 2020'de lehimize sonuclandı. https://t.co/JQZuwH1Wu	Negatif	Tedavi Süreçleri	Şikayet
Samsun @MedicalParkHG de Coronavirüs şüphesi taşıyan bir hasta tespit edilip "sen coronavirüs taşıyıcısı olabilirsiniz" diyerek Samsun Eğitim ve Araştırma Hastanesine yollanıyor. Hem de kendi imkanlarıyla yani dolmuşla. Coronavirüs ile mücadele nasıl?	Negatif	Tedavi Süreçleri	Şikayet
@yeesimsalkim @drfahrettinkoca Fatura vermekten kaçınmaları, yaptıkları hareketin yasal olmadığını ve kayıt altına geçmek istemediklerinin ispatı olarak görünüyor.	Negatif	Tedavi Süreçleri	Şikayet
Bir acıklamaları vardır herhalde? @MedicalParkHG	Negatif	Tedavi Süreçleri	Şikayet
Devlet Hastanesi'nde yapılan covid testi 1 günde çıkarken 350 TL verip 5 gündür sonuç beklemem çok koyuyor açıkçası Bakikent hastanenizde test yapıldı halen bekliyoruz yardımcı olabilir misiniz ?	Negatif	Tedavi Süreçleri	Şikayet

I. ETHICS BOARD APPROVAL

Ethics Board Approval is available in the printed version of this dissertation.