T.C.
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
SAYISAL YÖNTEMLER BİLİM DALI

Veri Madenciliği ile Markaların Dijital Pazarlama Kanallarının Performansının Değerlendirilmesi Üzerine Bir Uygulama

Doktora Tezi

SERKAN ETİ

İSTANBUL, 2021

T.C.
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
SAYISAL YÖNTEMLER BİLİM DALI

Veri Madenciliği ile Markaların Dijital Pazarlama Kanallarının Performansının Değerlendirilmesi Üzerine Bir Uygulama

Doktora Tezi

SERKAN ETİ

Danışman: DOÇ. DR. MEHMET NURİ İNEL

İSTANBUL, 2021

T.C.
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

TEZ ONAY BELGESİ

İşletme Anabilim Dalı Sayısal Yöntemler Bilim Dalı Yüksek Lisans/Doktora öğrencisi Serkan ETİ 'nın Veri Madenciliği ile Markaların Dijital Pazarlama Kanallarının Performansının Değerlendirilmesi Üzerine Bir Uygulama adlı tez çalışması, Enstitümüz Yönetim Kurulunun ..... tarih ve .....sayılı kararıyla oluşturulan jüri tarafından oy birliği / oy çokluğu ile Yüksek Lisans/Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi ...../...../.....

Öğretim üyesi Adı Soyadı			**İmzası**
1	Tez Danışmanı		
2	Jüri Üyesi		
3	Jüri Üyesi		
4	Jüri Üyesi		
5	Jüri Üyesi		

ÖZET

VERİ MADENCİLİĞİ İLE MARKALARIN DİJİTAL PAZARLAMA KANALLARININ PERFORMANSININ DEĞERLENDİRİLMESİ ÜZERİNE BİR UYGULAMA,

Pazarlama, müşterilerin, markaların ürün veya hizmetleri ile ilgilenmesini sağlama sürecidir. Geleneksel pazarlama yöntemlerinde, pazar araştırmaların yapılması, hedef kitlelerin tespiti ve analiz edilmesiyle ilgilerinin belirlenmesi hem maliyetli hem uzun bir süreç iken internetin yaygınlığının artması ile bu süreç kısaltılabilmiştir. Verinin çeşitliliği, büyüklüğü ve yoğunluğundan dolayı kanallardan sağlanan verilerin analizinde veri madenciliği vazgeçilmez bir hale gelmiştir. Bundan dolayı çalışmanın amacı, markaların dijital pazarlama kanallarının veri madenciliği teknikleri yardımıyla değerlendirmektir. Böylelikle ele alınan markaların, dijital kanallardaki etkinliğini ve performansını ölçülebilir hale getirebilecektir. Oluşturulacak sistemsel uygulama yardımıyla belirli periyodlarda sektör dinamiklerindeki değişimleri kanal bazında ve anlık olarak analitik olarak takip edebileceklerdir. Bunun sonucunda markalar pazarlama stratejilerini ve odaklanma noktalarını hızlı bir şekilde güncelleyebileceklerdir. KNIME programına entegre olarak API ve Python kütüphaneleri yardımıyla, Facebook, Instagram, Youtube, Twitter ve Google Haberler'den veriler çekilmiştir. Gönderilerdeki istatistiklerin yanı sıra, metinler metin analizi yöntemlerinden duygu analizi ile resimler için de resim analizi ile incelenmiştir. Analizin sonucunda hem kanal bazından hem toplam dijital pazarlama bazında ele alınan hastaneler sıralanmıştır. Bazı hastanelerin sadece bir dijital pazarlamaya önem verdiği bazı hastane işletmelerinin ise dijital pazarlamayı dikkate almadıkları görülmüştür. Ayrıca yapılan metin ve resimdeki nesne tespiti sonucunda ise, "Meyve", "Vitamin" gibi kelimelerin beğenileri artırırken "Riskli" kelimesinin katsayısı negatif olarak hesaplanmıştır. Beslenme uzmanlarının meyveler ve vitaminler hakkında bilgilendirici röportajların yer aldığı paylaşımlarda bulunulması tavsiye edilmektedir. Ayrıca, yapılan analizler sonucunda üroloji alanının çıkması sebebiyle, üroloji uzmanları bilgilendirme videoları çekilebilir veya bu hastalık için geliştirilen en son teknolojik tedavi yöntemleri vurgulanabilir. Bu birimde yapılan son çalışmalar ve gelişmeler hakkında bilgiler ve reklamlar üretilebilir.

Anahtar Kelimeler: Veri Madenciliği, Dijital Pazarlama, Sosyal Medya, Metin Madenciliği, Resim Analizi

ABSTRACT

AN APPLICATION ON THE EVALUATION OF THE PERFORMANCE OF DIGITAL MARKETING CHANNELS OF BRANDS WITH DATA MINING

Marketing is the process of getting the customer interested in the products or services of the brands. In traditional marketing methods, while conducting market research, identifying the target audience and determining their interest by analyzing it is both a costly and long process, it does not take a long time with the increase in the prevalence of the internet. Due to the diversity, size and density of the data, data mining has become indispensable in the analysis of the data obtained from the channels. Therefore, the aim of the study is to evaluate the digital marketing channels of brands with the help of data mining techniques. Thus, it will be able to measure the effectiveness and performance of the brands under consideration in digital channels. With the help of the systematic application to be created, they will be able to follow the changes in the dynamics of the sector in certain periods analytically on a channel basis and instantaneously. As a result, brands will be able to quickly update their marketing strategies and focus. Data were extracted from Facebook, Instagram, Youtube, Twitter and Google News with the help of API and Python libraries integrated into the KNIME program. In addition to the statistics in the posts, the texts were analyzed with sentiment analysis, one of the text analysis methods, and picture-in-picture analysis. As a result of the analysis, the hospitals that were considered both on the basis of channels and on the basis of total digital marketing were listed. It has been observed that some hospitals attach importance to only one digital marketing, while some hospital businesses do not consider digital marketing. In addition, as a result of the object detection in the text and picture, words such as "Fruit" and "Vitamin" increased the likes, while the coefficient of the word "Risky" was calculated as negative. It is recommended to share informational interviews with nutritionists about fruits and vitamins. In addition, due to the emergence of the field of urology as a result of the analyzes, informative videos of urology specialists can be taken or the latest technological treatment methods developed for this disease can be emphasized. Information and advertisements can be produced about the latest studies and developments in this unit.

Keywords: Data Mining, Digital Marketing, Social Media, Text Mining, Image Mining

ÖNSÖZ

Çalışmamın süresi boyunca desteğini benden esirgemeyen tez danışmanım, değerli hocam Sayın Doç. Dr. Mehmet Nuri İNEL'e ve her zaman yanımda olan sevgili aileme sonsuz teşekkürlerimi sunarım.

Serkan ETİ

İstanbul, 2021

İÇİNDEKİLER

ÖZET i
ABSTRACT ii
ÖNSÖZ iii
KISALTMALAR vii
TABLO LİSTESİ viii
ŞEKİL LİSTESİ ix
GRAFİK LİSTESİ x
GİRİŞ 1
2. DİJİTAL PAZARLAMA VE SOSYAL MEDYA 3
2.1.Dijital Pazarlama 3
2.2.Dijital Pazarlama Kanalları 5
2.2.1.PPC(Pay Per Click) Reklamları 6
2.2.2.Sosyal Medya 6
2.2.2.1.Sosyal Ağlar 8
2.2.2.2.Mikro Bloglar 8
2.2.2.3.Haber Kaynakları 9
2.2.2.4.Sosyal Oyunlar 9
2.2.3.Mobil- E-Posta Pazarlama 10
2.3.Sosyal Medya Analizi 10
2.3.1.Sosyal Medya Analizinde Metin Madenciliği 11
2.3.1.1.Duygu Analizi 11
2.3.1.2.Konu Modelleme 17
2.3.1.3.Öngörü Modelleri 18
2.3.1.4.Diğer Kullanım Alanları 20

2.3.2.Sosyal Medya Analizinde Resim Analizi 24
2.3.2.1.Sınıflandırma 25
2.3.2.2.Nesne Tespiti 27
2.3.2.3.Diğer Kullanım Alanları 28
2.3.3.Sosyal Medya Analizinde Sayısal Ölçümler 29
3.UYGULAMA 33
3.1.Uygulamanın Konusu, Amacı ve Önemi 33
3.1.1.Uygulamanın Konusu 33
3.1.2.Uygulamanın Amacı 33
3.1.3.Uygulamanın Önemi 34
3.1.4.Uygulamada Kullanılan Değişkenlerin Tanımlanması 34
3.1.5.Facebook Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler 35
3.1.6.Twitter Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler 37
3.1.7.Youtube Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler 39
3.1.8.Instagram Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler 42
3.1.9.Google Haberler Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler 43
3.2.Dijital Pazarlama Kanallarının Modellenmesi 45
3.3.Kanalların Modellerinin Kurulması 49
3.3.1.Dijital Pazarlama Skorlama Modeli 52
3.3.2.Modelin Yorumlanması 52
3.3.2.1.Birinci Dönem 53
3.3.2.2.İkinci Dönem 56
3.3.2.3.Üçüncü Dönem 58
3.4.Dijital Pazarlama Kanallarının Performansının Geliştirilmesi 59
3.4.1.Metin Bazlı Performans Analizi 60
3.4.2.Resim Bazlı Performans Analizi 60
3.4.3.Kanal Bazlı Performans Geliştirmesi 61

3.5.Genel Değerlendirme ve Tartışmalar 63
4. SONUÇ 66
KAYNAKÇA 69

KISALTMALAR

KNIME: Konstanz Information Miner

YSA: Yapay Sinir Ağları

PCA: Principal Component Analysis

API: Uygulama Programlama Arayüzü

TÜİK: Türkiye İstatistik Kurumu

PPC: Pay Per Click

GDSS: Game Data and Support Service

NLP: Doğal Dil İşleme

LDA: Gizil Konu Modellemesi

ETM: Duygusal Metin Madenciliği

ICC: Sınıf İçi Korelasyon Katsayısı

DM: Direkt Mesaj

SNS: Sosyal Ağ Siteleri

TF: Terim Sıklığı

IDF: Ters Belge Sıklığı

Pip: Python Package Index

KA: Karar Ağacı

MLP: Çok Katmanlı Yapay Sinir Ağı

TABLO LİSTESİ

Tablo 1. Dijital Pazarlama Kanallarının Performasında Kullanılan Değişkenler 49
Tablo 2. Birinci Dönem Performans Sıralaması 53
Tablo 3.İkinci Dönem Performans Sıralaması 56
Tablo 4.Üçüncü Dönem Performans Sıralaması 58

ŞEKİL LİSTESİ

Şekil 1. Dijital Pazarlama Kanalları 6
Şekil 2.Facebook Değerlendirme Modelinin KNIME İş Akışı 37
Şekil 3.Twitter Değerlendirme Modelinin KNIME İş Akış 39
Şekil 4.Youtube Değerlendirme Modelinin KNIME İş Akış 41
Şekil 5.Instagram Değerlendirme Modelinin KNIME İş Akış 43
Şekil 6.Google Haberler Değerlendirme Modelinin KNIME İş Akış 44
Şekil 7. Temel Sinir Hücresi 47
Şekil 8.İleri Beslemeli Çok Katmanlı Yapay Sinir Ağ Modeli 48
Şekil 9. Genel Değerlendirmede Kullanılan Modeller 52
Şekil 10.Metin Bazlı Strateji Geliştirme Modeli 60
Şekil 11.Resim Bazlı Strateji Geliştirme Modeli 61

GRAFİK LİSTESİ

Grafik 1.Yıllara Göre İnternet Erişim Oranları 3
Grafik 2.Birinci Dönemde Hastanelere ait Radar Grafikleri 55
Grafik 3.İkinci Dönemde Hastanelere ait Radar Grafikleri 57
Grafik 4.Üçüncü Dönemde Hastanelere ait Radar Grafikleri 59

GİRİŞ

Pazarlama, müşterilerin, markaların ürün veya hizmetleri ile ilgilenmesini sağlama süreci olarak ele alınabilmektedir. Bu süreç, pazar araştırması, analiz ve hedef müşterilerin ilgilerini anlama yoluyla gerçekleştirilmektedir. Geleneksel pazarlama yöntemlerinde, pazar araştırmalarının yapılması, hedef kitlenin tespiti ve analiz edilerek ilgilerinin belirlenmesi hem maliyetli hem uzun vadeli bir süreçtir. Verilen bir gazete veya televizyon reklamının geri dönüşünün analiz edilmesi günler, haftalar hatta aylar gerektirebilmektedir. Günümüzde zamanın önemi ve rekabetin hızıyla bu süreçler ciddi önem arz etmeye başlamıştır (Bulunmaz, 2016).

Teknoloji ve veri madenciliğindeki gelişmeler günümüzde hız kazanmıştır. Pazarlama da bu alanlardaki gelişmelerden etkilenen alanlardan birisidir. İnternetin dünya üzerinde yaygınlığının artması ile markalar müşteri sınırını kaldırmaya dünya üzerinde satış ve pazarlama imkânı elde edebilmektedir. İnternette yapılacak pazarlama da bundan dolayı önem kazanmaya başlamıştır. İnternette oluşan verinin çokluğu ve hızından dolayı analiz işlemleri için veri madenciliği teknikleri daha sık kullanılır hale gelmiştir. Ayrıca, dijital pazarlama kanallarındaki müşterilerin geri bildirimleri geleneksel pazarlamada olduğu gibi uzun bir süreçte olmamaktadır. Beğeni, paylaşım veya yorum gibi anlık geri bildirim verilebildiği gibi elektronik ticaret üzerinden satışlarda anlık olarak yapılabilmektedir. Böylelikle bir reklamın etkisi çok hızlı olarak karşılık bulabilmektedir. Bundan dolayı, dijital pazarlama kanalları günümüzde markalar için vazgeçilmez bir argüman olmaktadır. Sosyal ağlar, haber siteleri, mikrobloglar, forumlar gibi kanalların her biri, markalar için birer dijital pazarlama kanalı haline gelmiştir.

Sosyal ağlar, birçok marka için giderek daha fazla önem kazanan bir dijital pazarlama kanalı haline gelmeye başladığı görülmektedir. Bunun en büyük nedeni, sosyal medyanın sağladığı geniş erişim imkanıdır. Bir diğer nedeni ise, kullanıcıların Facebook gibi sosyal medya kanallarında markaya bağlanmayı kendi tercihleri ile seçmeleri olabilmektedir. Bu durum markaların pazarlaması için çok yararlı olabilir. Çünkü bu kişiler marka için potansiyel müşterilerdir. Başka bir ifade ile markanın çok kolay bir şekilde etkileşim kurabileceği bir dizi ilgili kullanıcıdır. Bunun ikinci avantajı, bu kullanıcılarla etkileşime girerek ücretsiz reklamcılık elde etme avantajı sağlar. Çünkü bu kullanıcılar mesajlarınızı arkadaşlarıyla ve ağlarıyla paylaşılabildiğinde dolayı bu içerik ücretsiz olarak etkileşim kazanır. Üçüncü avantajı, bağlantılı kullanıcılarınızın içeriğinizi paylaştığı kullanıcıların da bir marka olarak ilgilenme ihtimali de yüksektir. Çünkü bu kullanıcılar sosyal olarak birbirleriyle bağlantılı olduklarında, markayı takip edenlerle benzer algıya sahip olması yüksek bir ihtimaldir. Bundan dolayı markayı takip edenin çevresinin de markayı takip etmesi yüksek olabilmektedir (Marangoz vd, 2012; Halis, 2012; Demirel, 2013).

Anlaşılabileceği gibi, dijital pazarlama kanallarında etkileşimin daha hızlı ve verimli olduğu bir alan olup teknolojinin yaygınlaşması ile markalar için vazgeçilmez olmaya başladığı söylenebilmektedir. Ayrıca dijital pazarlama kanallarındaki paylaşımlar ağızdan ağıza pazarlamada olduğu gibi profillerin takipçileri veya arkadaşları olarak ifade edilen bağlantıları arasında da yayılabilmektedir.

Paylaşımlardaki milyonlarca gönderi veri madenciliği teknikleri yardımıyla analiz edilebilmektedir. Gönderilere ait istatistiklerin yanı sıra paylaşımlardaki resim ve metin gibi yapısal olmayan veri yapıları da günümüzde derin öğrenme yöntemleri ile analiz edilebilmektedir. Doğal dil işleme algoritmalarındaki gelişmeler sayesinde metinlerde sınıflandırma yapılabilmekte, içerikleri analiz edilebilir hale gelmektedir. Benzer şekilde resim analizi alanındaki algoritmalar geliştirilmektedir. Geliştirilen bu algoritmalar ile daha güvenilir olarak resimlerdeki objeler veya nesneler tespit edilebilmekte, sınıflandırılabilmekte ve analize hazır hale getirilebilmektedir. Günümüzde artık her türlü yapının analizine imkân sağlayacak şekilde algoritmalar geliştirilmekte ve geliştirilmeye devam etmektedir. Veri madenciliğindeki bu gelişmeler sayesinde ne tür içeriğe sahip paylaşımlar, beğeniler ve yorumlar açısından anlamlı bir etkileşim ürettiğine bakılabilmekte, marka kişiliği içeriğinin bir mesaja dahil edilmesinin katılımda büyük miktarda artış veya gelişme sağladığı görebilmektedir. Örneğin, markaların sundukları fiyatlar, fırsatlar veya kuponlar hakkındaki bilgiler gibi performans içeriğinin dahil edilmesine bakıldığında, bunun ne derece etkileşim ürettiğini anında görebilmek mümkün olmaktadır. Daha fazla etkileşim kazandıkça, haber beslemeleri veya algoritmalar markalara daha ön plana çıkma imkânı sunabilmektedir. Ardından daha fazla tüketiciye veya müşteriye ulaşma şansı elde edilebilmektedir. Bu anlamda, paylaşımlar daha fazla erişim sağlar, daha fazla görüntülenme daha fazla müşteri kazandırabilmektedir.

Günümüzde pazarlama artık çok veriye dayalı bir alan haline geldiği görülebilir. Teknolojideki bu evrimin bir parçası olarak, artık tüketicilerin ve insanların gerçekte ne yaptıklarına dair gerçek veriler markalar tarafından toplanabilirse, müşterilerinin belirttiği niyet, verilerinden yola çıkarak üstünlük sağlaması mümkündür. Pazarlamayla ilgili pek çok harcama ya yanıt vermeyen ya da zaten satın almış olan insanları hedef alma eğilimindedir. Bu hedef kitlelere daha az maliyet ve daha homojen gruplara ulaşmak konusunda dijital pazarlama geleneksel pazarlamaya göre veri madenciliği teknikleri yardımıyla daha üstün olabilir.

Dijital pazarlama ile maliyetlerin düşürülmesi, daha çok müşteriye ulaşılması, geri bildirimlerin daha hızlı olmasından dolayı markalar için vazgeçilmez bir alan olmuştur. İnternette elde edilecek verilerin hız, hacim, çeşitliliği çok fazladır. Bu veriler büyük veri yapıları oluşturmaktadır. Dijital pazarlama kanallarındaki bu büyük verilerden daha hızlı ve daha doğru sonuçlar elde edilmesi, veri madenciliği tekniklerinin uygulanması ile ancak mümkündür.

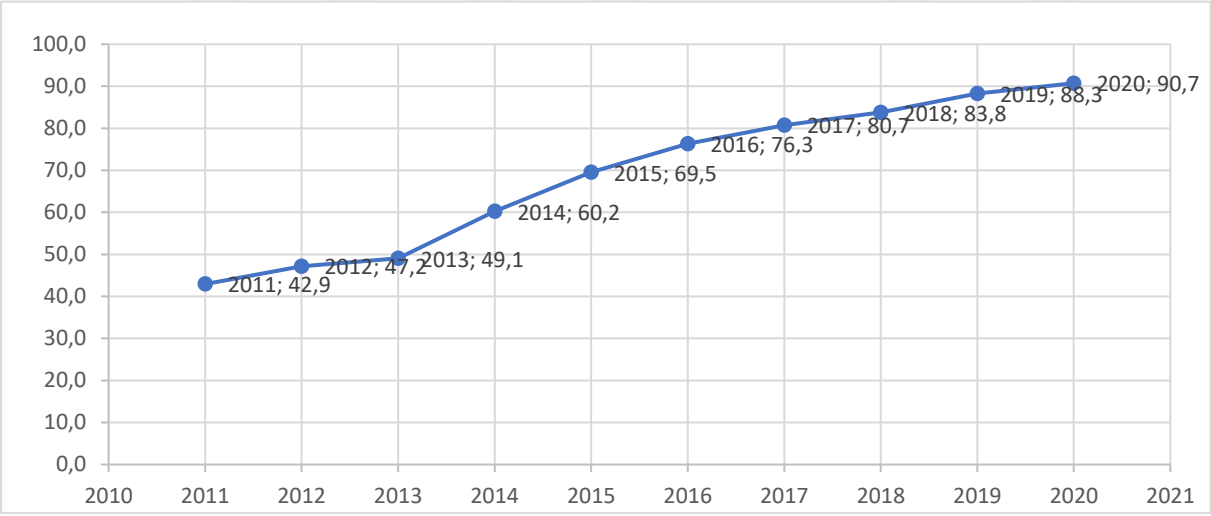
Tezin giriş bölümünde, internet, pazarlama ve pazarlama türleri ile ilgili kavramlar üzerinde durumuştur. Tezin ikinci bölümünde ise, dijital pazarlama, sosyal medya tanımları ile birlikte dijital pazarlama kanallarına detaylıca yer verilecektir. Tezin üçüncü bölümünde ise, ele alınan sağlık sektöründeki hastanelerin dijital pazarlama kanallarına ait performanslarının değerlendirilmesine ait detaylı bir analizden bahsedilecektir. Tezin son bölümü ise çalışmanın sonuç bölümünü oluşturmaktadır.

2. DİJİTAL PAZARLAMA VE SOSYAL MEDYA

Bu bölümde, ilk olarak dijital pazarlama ve sosyal medya kavramlarının tanımları verilecektir. Daha sonrasında dijital pazarlama kanalları hakkında bilgiler sunulacaktır. Devamında söz konusu bu kanallardan elde edilebilen veriler ile yapılabilecek sosyal medya analizleri tanıtılacaktır. Bölümün sonunda da bu kanallardan elde edilen verilerin işlenmesinde kullanılan analizler hakkında bilgi verilecektir. Bu analizlerden en sıklıkla kullanılanları olan metin madenciliği ve resim analizinde yapılan analizler literatür tabanlı olarak tanıtılacaktır.

2.1.Dijital Pazarlama

Dünyada ve Türkiye'de internete erişim artmaktadır. Günümüzde bilgisayar, cep telefonu, tablet gibi internete erişim sağlayan teknolojik cihazların artması ile bireysel olarak internete erişim oranı ülkemizde de artmaktadır. TÜİK 2020 raporuna göre, evlerde internete erişim oranı ülkemizde %90,7 oranına yükselmiştir (TÜİK, 2020). Ülkemizde internete erişimin artması da bireylerin hem sosyal hem ticari hayatlarını dijital ortama aktarmasına imkân sağlayabilmektedir.



Grafik 1.Yıllara Göre İnternet Erişim Oranları

Kaynak: TÜİK, 2020

Reel sektörde rekabet hızla artmakta, işletmeler pazar paylarını korumak ve genişletmek için stratejiler üretmektedir. Bazı markalarda bu stratejilerin en başlarında pazarlama stratejileri ve marka imajı yer alabilmektedir. Modern dünyada pazarlama da kendini dijital dünyaya taşınmış, yeni pazarlama alanları kazandığı söylenebilmektedir. İnternetin ve teknolojideki erişebilirliğin artması ile dijital pazarlama, işletmeler için vazgeçilmez bir saha olmuştur. Aynı zamanda teknoloji ile büyüyen veri kavramı da beraberinde veri madenciliği ve makine öğrenmesini gerekli kılabilmektedir. Bu iki kavramın ortak noktası

olan teknoloji ile söz konusu kavramların entegrasyonu vazgeçilmez hale gelmektedir. Dijital pazarlama ve bununla ilgili terimler, örneğin Internet / çevrimiçi pazarlama, pazarlama çabalarında teknolojilerin kullanımını tanımlamak için yaygın olarak kullanılmaktadır (Järvinen vd, 2012). Dijital; sayı ile ilgili, sayı bazlı veya sayısal anlamında kullanılmaktadır. Bundan dolayı, bir pazarlama yöntemi olarak ele alınabilecek olan dijital pazarlama kavramı ise, pazarlama sisteminin ölçülebilir hali olarak görülebilmektedir. Teknolojinin getirisi ile geleneksel pazarlama kanallarında, zaman alan reklam ve kampanyaların geri dönüşü, efektifliğinin ölçümü süreçleri, dijital pazarlamada anlık olarak ölçülüp değerlendirilebilmektedir.

Farrah (2010) internet pazarlamasını "Dijital pazarlamayı anlamak" başlığı altında ele alırken, Melewar ve Smith (2003) internet kullanımının engellerini "Çevrimiçi pazarlamayla ilgili tartışmalı sorunlar" başlığı altında dijital pazarlama hakkında güncel tartışmaları sunmaktadır. Wymbs 'in (2011), dijital pazarlama yalnızca internet üzerinden iletişimden çok daha fazlası olarak yorumlamaktadır. Dijital pazarlama, internet, mobil ve kablosuz iletişimin yanı sıra dijital televizyon da dahil olmak üzere çok çeşitli dijital kanalları içerir (Li vd, 2011). Dijital, internet ve çevrimiçi pazarlama, sosyal unsurlar etkileşimli dijital medya ortamına giderek daha fazla entegre edildiğinden, dijital ve sosyal medya kavramları ayrılmaz birer kavram haline geldiğini söylemek mümkündür.

Pazarlamanın anlamı, insan ihtiyaçlarına hizmet etmek ve karşılamak olduğu bu alandaki uzman akademisyenleri tarafından uzun zamandır bilinmektedir. Böylelikle, tüketiciler için, tüketimin itici gücü sonucu olan memnuniyet önemli hale gelebilmektedir. Dijital dünyada kullanıcılar televizyondaki gibi reklamlara karşı davranış sergilemeleri farklı olabilmektedir. Bu ortamda reklamları reddeder veya görmezden gelebilmektedirler. Bu durum sosyal medya pazarlaması yükselmesinde en büyük engelini oluşturabilmektedir. Sosyal medyada pazarlamayı artırmanın yolu kullanıcı ihtiyaç ve memnuniyeti arasındaki uyumu sağlamaktır (Zhu & Chen, 2015). Bu yüzden sosyal medya pazarlamasının ihtiyaçlarından biri de kullanıcıların ihtiyaç ve memnuniyet duyduğu noktaları belirleyebilmektir. Sonrasında, pazarlama içeriğini, sürecini ve hedefini kullanıcıların sosyal medya kullanım ihtiyaçlarına göre ayarlayabilmektir.

Sosyal medyanın yükselişi ile kurumsal iletişimin şekli değişmek zorunda kalabilmektedir. İşletmelerdeki tek yönlü iletişimin artık daha demokratik olduğunu ifade eden uzmanların sayısı her geçen gün artmaktadır. Ticaretteki pazarlamacıların gücü, bloglara, Tweetlere, Facebook gibi paylaşım ve tüketim yapan birey ve toplulukların eline geçmiştir. Dijital pazarlama kanallarında markalarla ilgili iletişim, söz konusu firmaların izni olsun ya da olmasın gerçekleşir. Dave Carrooll' un gitarının 2008 yılında bir uçak firması tarafından kırılmasından sonra deneyimlerini Youtube 'da anlatmıştır. Bu anlatım ile bu olayın viral olması iletişimin tek yönlü olmadığının en güzel örneklerindendir. Şirket buna yanıt vermemesi ve buna hazırlıksız olmasından dolayı hisse fiyatlarında zarar etmesine sebep olmuştur. Bu gibi zor durumlarda kalmak istemeyen markalar, dijital pazarlama kanalları için olan yedi yapı taşını analiz ederek, toplulukları için uygun yapı taşları dengesine dayalı uyumlu bir stratejisi geliştirmelidirler. Bu söz konusu olan yedi temel yapı: Kimlik, konuşmalar, paylaşım, mevcudiyet, ilişkiler, itibar ve gruplar. Ancak bu yedi yapı üzerine kurulan bir strateji ile markalar dijital pazarlama kanalları üzerindeki işlevliğini ve etkinliklerini izleyebilirler (Kietzmann vd, 2011).

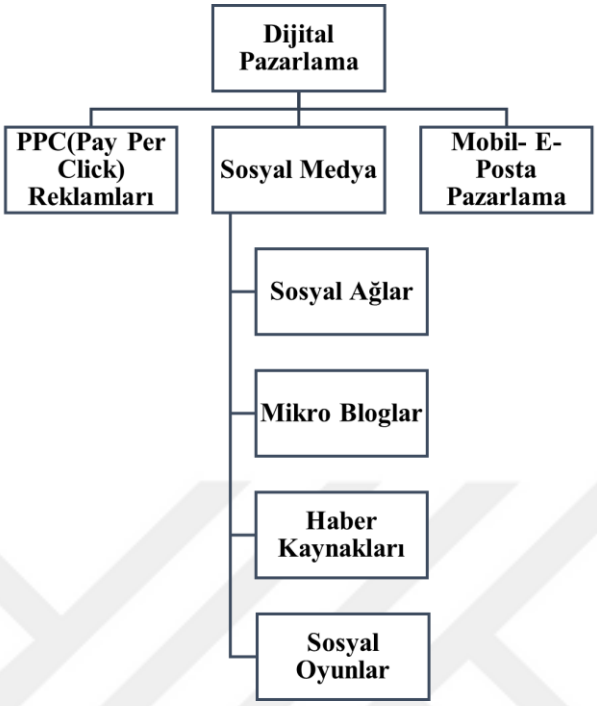
Geçmişte, pazarlamacılar firma veya ürünleriyle ilgili bilgileri yaymak için e-posta patlamaları, doğrudan pazarlama, tele pazarlama, bilgilendirici web siteleri, televizyon, radyo ve diğer mekanizmaları

kullanıyordu. World Wide Web (WWW) hayatlara girmesi ile birlikte kısa sürede işletmeler çok sayıda insana ulaşmak için sayfa görüntülemeleri ve reklam yoluyla pazarlama mesajlarını kullanmayı tercih edebilmektedirler. Alıcılar ve satıcılar arasındaki etkileşimi kolaylaştıran bir araç olmaktan çok gezinti davranışını şekillendiren bir reklam aracı olarak hizmet etmeye başlamıştır (Berthon vd, 1996). Markalar özellikle içerik ve anlamı birlikte vurgulayan promosyon stratejileri kullanarak dijital ilişkiler geliştirmeye çalışabilmektedir. Bu amaçla, ağızdan ağıza iletişim, dijital pazarlamada en büyük yardımcı bir argüman haline gelebilmektedir. İnternet ile çevrimiçi iletişim araçlarının müşterilerin markalara eskiye nazaran daha fazla yanıt vermesine olanak sağlayabilmektedir (Mangold & Faulds, 2009). Bu durum markaları dijital bir varlık oluşturmaya zorlayabilmektedir. İletişim teknolojisindeki bu gibi küresel gelişmeler ve internet erişimi için daha düşük maliyetler oluşturması, dijital pazarlama stratejilerinde büyük değişikliklere sebep olabilmektedir. Özellikle bu değişiklik pazarlamanın promosyon karması boyutunda görülebilmektedir. Pazarlama iletişimi dijital alanla giderek daha fazla bütünleştikçe, pazarlamacılar müşterilerle dijital bağlantılar oluşturmak için sosyal medyayı kullanımlarını arttırabilmektedir. Müşterilerle bağlantıyı geliştirmenin iki ana yolu vardır. Birincisi dijital veya etkileşimli bir firma olarak çalışmak veya çeşitli sosyal medya etkileşimi türlerini benimseyerek dijital pazarlamadan yararlanabilmektedir. (Tiago & Verişime, 2014). Markalar tarafından oluşturulan dijital varlığın birçok faydası olabilmektedir. Yapılan bir anket çalışmasına göre, bilgi toplaması ve geri bildirimi geliştirmesi, kullanıcı dostu araç sağlaması, bilgiyi artırması, iç ve dış ilişkileri teşvik etmesi, karar verme sürecini desteklemesi, üretkenliği artırması ve daha gerçekçi sonuç ölçümü yapması bunlardan bazıları olduğu söylenmektedir (Tiago & Verissimo, 2014).

Dijital reklamcılık ise, tüketici davranışıyla ilgili olarak, tüketicilerin dijital reklamların çeşitli yönlerine nasıl tepki verdiklerini inceleyebilmektedir. Dijital reklam hedeflemesinin kişiselleştirilebilir olmasından dolayı psikolojik tepkinin yönetilebilmesi gerekebilmektedir. Bir tüketici bir web sitesine döndüğünde önceki web tarama geçmişine dayalı kişiselleştirilmiş reklamlar, bazı çevrelerce olumsuz tepkiler alırken, tüketicilerin reklamların kişiselleştirme için kullanılan özel bilgilerin kontrolünde olduğu durumda olumlu tepkiler verebilmektedir (Stephen, 2016). Günlük fırsatlar gibi grup satın alınan reklamların popülerliği satın almada itici bir rol oynadığını gösteren birçok çalışma da mevcuttur. Bu çalışmaların sonucu olarak, dijital görüntülü ve arama ağı reklamlarının, çevrimiçi davranışı artırmada çevrimdışı reklamlardan daha etkili olduğunu sonucuna varıldığı ifade edilmektedir (Luo vd, 2014; Jerath vd, 2014; Puccinelli vd, 2015; Dinner vd, 2014; Goldstein vd, 2014).

2.2.Dijital Pazarlama Kanalları

Bu bölümde geçmişten günümüze kadar dijital pazarlamada kullanılan kanallar tanıtılacaktır. Kanallar hakkında tanımlar ve literatür tabanlı bilgiler verilecektir. Dijital pazarlama kanalları dijital reklamlar, sosyal ağlar ve mobil-elektronik posta kanalları şeklinde sınıflandırmak mümkün olacaktır (Durmaz & Efendioğlu, 2016; Heinze vd., 2016).



Şekil 1. Dijital Pazarlama Kanalları

2.2.1.PPC(Pay Per Click) Reklamları

Dijital pazarlamanın ilk adımları olan tıkla kazan reklamlarıdır. Tıklama Başına Ödeme (Pay Per Click), reklam veren işletmelerin çeşitli dijital mecralarda gösterdikleri reklamlara tıklamaları sonucu ücretlendirildiği bir çevrimiçi reklam yöntemidir. PPC reklamcılığı adından da anlaşılacağı gibi tıklama başına ücretlendirme temeline dayanır. Reklam verenler, tıklamalar için site sahiplerine ödeme yaparlar. Bunların öncüsü ise Google Adward 'tır. Sosyal medyada veya başka platformlarda verilen reklamları da bu başlık altında toplayabilirsiniz. Web sitelerinin muhtelif yerlerine verilen görsel ve hareketli reklamlar, bir nevi sokaklardaki pano reklamlarının görevini görmektedir. Web sitesini ziyaret eden kullanıcılar buradaki reklamları görür ve linke tıklayarak reklamdaki ürüne ulaşır. Bu pazarlamada reklamlara tıklanması ile web sitesi para kazanırken, reklamı veren ise ürününü pazarlamaktadır (Zafarani vd, 2014; Zhang & Guan, 2008).

2.2.2.Sosyal Medya

Sosyal medya, web 2.0'ın ideolojik ve teknolojik temellerini baz alan ve kullanıcı tarafından oluşturulan içeriğin değiştirilmesine izin veren internet tabanlı uygulamalar grubudur. Sosyal medyanın birçok kategorisi mevcuttur. Sosyal ağlar (Facebook), mikro bloglar (Twitter), resim paylaşımı (Picasa, Instagram), haberler (Google Haberler, Feedburner), video paylaşımı (Youtube, MetaCafe), canlı yayın(Ustream, Periscope), sosyal oyunlar (World of Warcraft), arama motorları (Google, Yandex, Bing), ve mesajlaşma (Skype, Google Talk, Yahoo!messenger) bunların bazılarıdır. Sosyal Medya yükselişiyle, web

sayfaları, bireyler ve şirketler bazında milyonlar paylaşım, gönderi ile günlük aktiviteleri içeren canlı ve etkileşimli bir ortam oluşturabilmektedir (Zafarani vd, 2014).

Sosyal medya geçirdiği değişimler sonucunda günümüzde, artan hacmi ile son dakika haberlerine, çeşitli politikalara, mevzuatlara, kişiler ve sosyal hareketler hakkında kamuoyunun görüşlerini ölçmek için kullanılan bir araç haline gelebilmektedir. Günümüzde ise işletmelere de mevcut ve potansiyel her türlü müşteri ile iletişim kurma imkânı sunabilmektedir. Ayrıca işletmelerin müşterilerine hizmet sunmalarına, ürünlerinin fonksiyonlarını tanıtmalarına kadar geniş fırsatlar sağlayabilmektedir (Baykara & Gürtürk, 2017). Günümüzde sosyal medya, kolektif davranışı etkiler ve bilginin yayılmasında çok önemli bir role sahip olabilmektedir. Bu nedenle, sosyal medyadaki gönderilerin etkisini tahmin etmek için otomatik bir yöntem, pazarlama, psikoloji, eğitim alanları, güvenlik vb. gibi çeşitli alanlarda yararlı olabilmektedir (Sam vd, 2018; Chaffey & Ellis-Chadwick, 2019).

Bahsi geçen amaçlardan biri ya da birden fazlası için sosyal medya üzerinden pazarlama stratejisi geliştirmek isteyen markaların, sosyal medya kullanımının arkasındaki ihtiyaç ve motivasyonu tanımalı ve anlamlandırmaları gerekebilmektedir. Markalar televizyon reklam zamanı ve / veya basılı sayfaları satın almak yerine, sosyal medya, minimum maliyetle, özgürce ve istedikleri sıklıkta duyuru yapmalarını sağlayabilirler. Sosyal medya bağlamında özelleştirme, kullanıcılar tarafından gönderilen mesajların hedef kitlesini ifade edebilirler. Böylelikle markalar hedef kitlerine göre özelleştirilmiş reklamlar üretebilmektedirler (Kingsnorth, 2019).

Sosyal medya pazarlamasının etkili olabilmesi için bu çabaların sosyal medya kullanıcılarının farklı motivasyonları ve ihtiyaçları ile uyumlu olması gerektiği ifade edilmektedir. Sheldon ve arkadaşlarının (2001) yaptıkları çalışmada insan doğasını tatmin eden 10 ihtiyacı belirlemişlerdir: özerklik, yeterlilik, ilişki, fiziksel gelişme, güvenlik, benlik saygısı, kendini gerçekleştirme, zevk uyarımı, para - lüks ve popülerlik etkisi. Sosyal medyada yapılan paylaşımların temelinde de bu temel on ihtiyaç görülebilmektedir. Başka bir ifade ile kullanıcılar tarafından yapılan paylaşımlarda insan doğasındaki tatmin duygusu yer alabilmektedir.

Sosyal medya pazarlama çabalarının başarılı olabilmesi için ilişki yönü dikkate alınması gerekebilmektedir. Örneğin, Facebook şirketlerle değil bireylerle iletişim kurma aracı olara görülebilmektedir. Sosyal medya, işletmeler ve müşteri ağları arasındaki sosyal etkileşimi kolaylaştıran entegre dijital pazarlama kanalı, platformları ve araçları olarak görülebilmektedir. Buna göre, dijital pazarlama, şirketlerin müşterilerle etkileşimlerini geliştirmelerine olanak tanıyan her türlü dijital ve sosyal medya araçlarının kullanımını ifade etmek için kullanılabilmektedir (Järvinen vd, 2012; Chugh & Ruhi, 2018).

Günümüzde insanlar alışveriş ve ticaret konularında e-ticaretin artması ile birlikte sosyal medya paylaşımlarından etkilenebilmektedir. Yapılan çalışmalar sosyal medyada paylaşılan deneyimlerin potansiyel müşterilerin davranışlarını etkilediğini göstermiştir. Paylaşımlar, yeni ürün benimseme, tekrarlanan satın alma ve çapraz satışlar üzerinde etkili olduğu yapılan çalışmalar ile gösterilmiştir. Araştırmaların sonuçları, bu konuda davranışlarda etkili kullanıcıların belirlemenin önemli olduğunu ifade edilmişiir. Bu etkili kullanıcıların belirlenmesi için geliştirilen bir model çalışmasının sonuçları, çok yönlü arkadaş çevrelerinin küresel merkezlerinin ve yerel merkezi düğümlerinin, takipçilerin benimseme davranışları üzerinde benzer etkilere sahip olduğunu ortaya çıktığı söylenebilmektedir. Ayrıca, bu tarz çok yönlü arkadaş çevrelerinin,

takipçilerinin de benimseme davranışları üzerinde benzer etkilere sahip olduğunu ortaya koyduğu ifade edilmiştir (Chen vd, 2019; Habibi vd., 2015; Constantinides, 2014).

Buraya kadar sosyal medyanın literatürdeki tanımları ve dijital pazarlama ile ilişkisi üzerinde durulmuştur. Bölümün başında ele alındığı gibi sosyal medya birçok farklı kategoriden oluşmaktadır. Sondaki bölümlerde söz konusu bu kategoriler üzerinde durulacaktır.

2.2.2.1.Sosyal Ağlar

Sosyal ağlar, arkadaşlarımız, ailemiz, meslektaşlarımız, müşterilerimiz veya onlarla bağlantıda kalmak için kullanılan internet tabanlı sosyal medya siteleridir. Facebook, LinkedIn ve Instagram gibi sosyal ağ sitelerini kullanan insanların sosyal bir amacı, iş amacı veya her iki amacı da olabilir. Günümüzde sosyal ağlar, müşterilerle etkileşim kurmak isteyen pazarlamacılar için önemli bir bağlantı haline gelmeye başladığı söylenebilmektedir.

Bir sosyal ağ, birbirine bağlı kişilerden oluşan bir topluluk olarak ele alınabilmektedir. Başka bir ifade ile sosyal ağlar, noktalardan (insanlar ve potansiyel müşteriler) ve bu noktalar arasındaki bağlantılardan oluşturduğu söylenebilmektedir. Her bir kullanıcının kişisel bir kişi listesi var. Bu listeler arası paylaşımlar ile bağlantılar kurabilmektedir. Sonuç olarak, kişisel bağlantılardan oluşan bir ağ oluşturabilmekte veya resmi adı altında bir sosyal ağ oluşturabilmektedir (Doyle, 2007). Sosyal ağ kavramı için başka bir bakış açısında ise bir bilgisayar ağı insanları veya kuruluşları birbirine bağladığında, buna bir sosyal ağ denilebilmektedir. Tıpkı bir bilgisayar ağının bir dizi kabloyla birbirine bağlanan bir dizi makine olması gibi, sosyal ağ da arkadaşlık, birlikte çalışma veya bilgi değiş tokuşu gibi farklı sosyal ilişkiler ile birbirine bağlanan bir dizi insandan (veya kuruluşlardan veya diğer sosyal varlıklardan) oluşuturduğu ifade edilebilmektedir (Garton vd, 1997).

Sosyal ağlar, insanlar veya kuruluşlar arası iletişimin dijital versiyonu olarak da ele almak mümkün olabilmektedir. Buradaki sosyal terimi, sosyal bağların varlığına atıfta bulunmak için kullanılmaktadır. Sosyal ağ terimi, bireyleri çevreleyen sosyal ilişkiler ağını ifade etmek için söylenebilmektedir. Sosyal ağların yapısı, ağdaki odak kişi ile diğer kişiler arasındaki belirli ikili özellikleri barındırabilmektedir. Ayrıca sosyal ağ yapısı, bir bütün olarak ağın özellikleri bakımından bu ikili özellikler açısından tanımlanabilmektedir. İkili özellikler, sosyal etkinin ve yapının bir ilişkide ne ölçüde karşılıklı olarak verildiğini ve alındığını, bir ilişkinin duygusal yakınlık ile karakterize edilme derecesini, bir ilişkinin ne ölçüde bağlı olduğunu ifade ettiği söylenebilmektedir (Israel, 1982; House vd, 1988). Sosyal ağlar, sosyal etki, sosyal kontrol, sosyal zayıflama, sosyal karşılaştırma, arkadaşlık ve sosyal destek gibi çeşitli sosyal fonksiyonları içerdiği ifade edilmiştir (Heaney & Israel, 2008).

2.2.2.2.Mikro Bloglar

Mikro blog web siteleri, çeşitli türden bir bilgi kaynağı haline getirebilmek için geliştirilebilmektedir. Bu mecra, insanların çeşitli konulardaki görüşleri hakkında gerçek zamanlı mesajlar gönderdikleri, güncel konuları tartıştıkları, şikâyet ettikleri ve günlük hayatta kullandıkları ürünler için olumlu duygular ifade ettikleri sosyal medya kategorisi olarak ele alınabilmektedir. Söz konusu bu insan davranışları

mikro blogların doğasını oluşturmaktadır. Son zamanlarda, ürün ve hizmet üreten şirketler, ürünleri ve hizmetleri hakkında genel bir fikir edinmek için bu mikro blogları araştırmaya başladığı görülebilmektedir. Genellikle bu tür şirketler kullanıcı tepkilerini inceleyebilmekte ve kullanıcılara mikro bloglarda yanıt verebilmektedir (Agarwal vd, 2011). Kullanıcıların "her şey" hakkında gerçek zamanlı tepkiler ve görüşler yayınladıkları Twitter gibi mikrobloglar günümüzde önem kazanmaktadır. Ağızdan ağıza pazarlamanın dijital karşılığı olarak görülebilen bu mikrobloglar, toplumsal hareketlerin araştırılmasında çokça başvurulabilmektedir.

Mikro bloglardaki mesajların yazarları yaşamları hakkında yazabilirler, çeşitli konularda fikirlerini paylaşabilirler ve güncel konuları tartışabilirler. Ücretsiz mesaj formatı ve mikro blog platformlarının kolay erişilebilirliği nedeniyle, internet kullanıcıları geleneksel iletişim araçlarından mikro blog servislerine geçmesi kolay olabilmektedir. Giderek daha fazla kullanıcı, kullandıkları ürün ve hizmetler hakkında paylaşımda bulunabilmektedir. Bu tür paylaşımlarda bulundukça veya politik ve dini görüşlerini ifade ettikçe, fikirleri ve duyguları araştırmacılar için değerli kaynaklar haline gelmeye başladığı söylenebilir. Böylelikle bu tür veriler pazarlama veya sosyal çalışmalar için verimli bir şekilde kullanılmaya hazır hale gelebilmektedir. Böylelikle mikro blog platformlarının ve hizmetlerinin kullanıcıları her geçen gün büyüdükçe, bu kaynaklardan gelen veriler ile fikir madenciliği ve duygu analizi gibi işlemlerinde daha çok kullanmak için başvurulduğu ifade edilmiştir (Pak & Paroubek, 2010).

2.2.2.3.Haber Kaynakları

Sosyal medya kullanıcıların birçoğu günümüzde interneti haber alma kaynağı olarak kullanılabilmektedir. Geleneksel basın ve yazılı haber kaynakları yerine daha hızlı erişebilir ve etkileşimli olmasından dolayı günlük haberlerin takibi için kullanıcılar hem sosyal ağları hem de dijital haber kaynaklarını tercih edebilmektedirler. Bundan dolayı geleneksel haber sunucuları aynı zamanda haber içeriklerini dijital platformlarda da paylaşmakta ve bu platformları aktif olarak kullanabilmektedir. Böylelikle aynı haberi farklı kaynaklardan elde edebilmektedirler. Bunları karşılaştırabilme imkânı sağlanyabilmektedir. Ayrıca haber platformları yardımıyla haberleri kişiselleştirebilmekte ve ilgi alanına göre haberleri görüntüleyebilme imkânı sağlayabilmektedir. Kullanıcıların dijital haber kaynaklarını tercih etmesindeki bir diğer neden ise buradaki haberlerin yöneticilerin doğrudan kontrol edememelerinden kaynaklı özgürlüğün verdiği hissiyat olabilmektedir. Günümüzde müşteri ilişkileri yönetiminin getirilerinden dolayı müşteri istek ve talepleri doğrultusunda söz konusu bu alandaki değişimde kaçınılmazdır. Sosyal medyanın, geleneksel entegre pazarlama yönteminden farkı olmasına karşın, sosyal medyanın promosyon karşımı melez bir yapı olduğu da yadsınamaz bir gerçek haline aldığı araştırmacılar tarafından ifade edilmektedir. Bundan dolayı yöneticiler için tüketicilerine ağ platformları sağlamayı ve müşterileri çekmek için blogları, sosyal medya araçlarını ve promosyon araçlarını kullanmaları gerektiği ifade edilmiştir (Mangold & Faulds, 2009).

2.2.2.4.Sosyal Oyunlar

Oyun sağlayıcıları, web, Facebook ve mobil (Android ve İOS uygulamaları) gibi farklı platformlar için mevcut olan oyunları kullanıcılara sağlayan unsurdur. Farklı platformlar da mevcut olmasına rağmen, çalışma modeli her zaman bu platformlarda aynıdır. Temelde kimlik doğrulama sistemini sağlamak, oyunları

yüklemek ve sağlamak, arka planda veri toplamak ve daha sonra veri tabanına ve destek sistemi (Game Data and Support Service - GDSS) 'ne göndermekle sorumludur. Sağlayıcılar tarafından toplanan veriler, sadece oynanan oyunu değil, aynı zamanda bağlamsal bilgiler barındırabilmektedir. Başka bir ifade olarak, sağlayıcılar oyuncular hakkında birçok veriyi takip edebilmektedir: Oyuncunun konumu (ülke, şehir, GPS koordinatları), kullanılan cihaz bilgisi (marka, model ve işletim sistemi), oyun süresi, oyunun bölümleri ve bunların meydana geldiği zaman damgası ile ilgili önemli olayların bir listesi, oyun skoru. Oyunlar, sunucular tarafından sağlanan ve oyun tarafından veri göndermek / almak için kullanılabilen bir API 'nin kullanılmasıyla birlikte çalışabilmektedir. Bazı oyunlarda oyun oynamak için kullanıcının kimliğinin doğrulanması ve bunun içinde Facebook veya Google kimlik doğrulamasını desteklemesi gerekebilir. Çoğunlukla sağlayıcılar Facebook, mobil ve kullanıcının web tarayıcısında kullanılabilir. Oyuncu bir oyunu bitirdiğinde, sağlayıcılar topladığı tüm verileri sunucuya gönderir, böylece daha fazla işlenebilir ve ilgili bilgiler ondan çıkarılabilir (Oliveira vd, 2014; Bergenti vd., 2013). Bu veriler çapraz satışlar için günümüzde çokça başvurulan verilerdir. Bu verilerin işlenmesi ile pazarlamacılar kullanıcılar hakkında bilgi edinebilirler. Bu bilgiler yardımıyla pazarlama stratejileri de üretebilmektedirler (Tillmann vd., 2012).

2.2.3.Mobil- E-Posta Pazarlama

Reklam, uzun zamandır markalar tarafından tüketicilerle çeşitli medyalar aracılığıyla iletişim kurmak için kullanılan etkili bir tanıtım aracı olarak görülmüş ve benimsenmiştir. Dijital bir dünyada reklamcılık, anlık geri bildirim olasılığı ve müşterilerin son derece kişiselleştirilmiş içerik sunma tercihlerini yakalama yeteneği teknolojik olarak uygulanabilir ve arzu edilir hale geldiğinden, reklam verenler için çok sayıda yeni fırsatlar oluşturabilmektedir. E-posta, sosyal medya ve mobil uygulamalar da dahil olmak üzere günümüzde mevcut olan diğer bazı dijital reklamcılık kanalları kadar çekici olmasa da hızlı, kullanışlı ve ucuz bir iletişim aracı olması nedeniyle son zamanlarda pazarlamacılar için popüler ve rağbet görmeye devam etmektedir. Çoğu teknolojik yeniliğin sürekli olarak daha küçük, daha hızlı, daha güçlü çözümlerle değiştirildiği çağımızda, e-posta şaşırtıcı bir şekilde teknolojik devrimin tüm ilerlemelerinden etkilenmeden kalabilmektedir. E-posta, dünya çapındaki e-posta kullanıcılarının sayısının sadece 2020 yılına kadar dört milyarı geçmesi sebebiyle değil, aynı zamanda büyümeye devam etmesi beklendiğinden, dünya çapında popülaritesini artırması ön görülmektedir (Mahmoud vd, 2019). Doğrudan e-posta pazarlaması, kökenini kırk yıl önce gönderilen ilk pazarlama e-posta gönderilmesine kadar dayanır. Bu türden bir pazarlama e-postanın, belirli hesap sahiplerini hedefleyerek veya toplu mesajlaşma yoluyla e-posta hesapları olan internet kullanıcılarına reklam mesajları gönderilmesi fikrine dayanır. Bu fikrin bir reklam aracı unsuru olarak kavramlaşmasına da elektronik posta pazarlaması denilebilmektedir (Gopal vd, 2001; Chaffey & Smith, 2017).

2.3.Sosyal Medya Analizi

Bu bölüm altında önceki bölümde bahsedilen sosyal medya mecrasından elde edilen verilerin nasıl analiz edildiği üzerinde durulacaktır. Öncelikle sosyal medya analizinin neyi ifade ettiğinden bahsedilecektir. Daha sonrasında sosyal medya analizden en çok başvurulan veri madenciliği teknikleri ve kullanım alanları tanıtılacaktır. Bu yöntemlere ait bilgiler literatürdeki çalışmalardan örnekler verilerek zenginleştirilecektir.

Sosyal medya günlük aktiviteleri paylaşma imkânı sağlayan çok kategorili canlı ve etkileşimli bir ortam olduğu önceki bölümde ifade edilebilmektedir. Sosyal medya madenciliği ise, bu söz konusu adı geçen sosyal medya sitelerinde aktiviteler ile oluşan verilerden işlem yapabilen kalıpları inşa etme, analiz etme ve çıkarma sürecine verilen genel bir adlandırması olarak ele alınabilir (Zafarani vd, 2014). Sosyal medya madenciliği, büyük sosyal medya verilerini araştırmak için uygun temel kavramları ve temel algoritmaları tanımlar. Bu algoritmalar için bilgisayar bilimi, veri madenciliği, makine öğrenimi, sosyal ağ analizi, ağ bilimi, sosyoloji, etnografi, istatistik, optimizasyon ve matematik gibi farklı disiplin teorilerinden ve metodolojilerinden yararlanılabilir. Başka bir ifade ile, sosyal medya madenciliği büyük ölçekli sosyal medya verilerinden anlamlı kalıpları oluşturmak için ölçmek, modellemek ve çıkarımda bulunmak için kullanılan araçları kapsaması olarak değerlendirilebilir. Diğer bir deyişle, sosyal medya analizi, mikro bloglardan ve sosyal medya gibi internet kaynaklı sitelerden veri toplama ve bu verilerden yola çıkarak bir iş veya konu hakkında karar vermek için analiz etme sürecini kapsadığı ifade edilmiştir (Baykara & Gürtürk, 2017; Zafarani vd, 2014). Literatür incelendiğinde son yıllarda sosyal medya analizlerinde veri madenciliği tekniklerini kullanan çok az makalenin yer aldığı görülebilmektedir. Injadat ve arkadaşlarının (2016) yaptıkları literatür bazlı bir çalışmada 2003 ile 2015 yılları arasında sosyal medya verilerinde veri madenciliği tekniklerini kullanan sadece atmış altı makale tespit edebilmişlerdir. Tespit edilen bu makaleler, altı farklı endüstriyel ve hizmet alanında yazılırken, dokuz farklı araştırma hedefine hitap ettiğini tespit etmişlerdir. Sosyal medya verilerinin analizinde farklı on dokuz veri madenciliği tekniğinin kullanıldığını görüldüğünü ifade etmişlerdir. Bundan dolayı, sosyal medyadaki veri madenciliği uygulamaları henüz başlangıç aşamasında olduğu söylenebilmektedir. Hem akademik hem de piyasa tarafından bu alanda daha fazla çalışma yapılması gerekmektedir (Injadat vd, 2016).

Bir sonraki bölümde, sosyal medya analizi için kullanılan veri madenciliği yöntemlerinden metin madenciliği, resim madenciliği üzerinde durulacaktır. Bu yöntemlerin kullanım şekilleri ve literatürdeki kullanımlarından bahsedilecektir.

2.3.1.Sosyal Medya Analizinde Metin Madenciliği

Sosyal medyada en çok kullanılan veri madenciliği, paylaşımlardaki metinler üzerinden yapılan çalışmalar olduğu söylenebilir. Gönderilerin büyük bir çoğunluğunun metinlerden oluşmasından dolayı, bu alanda metin madenciliği diğer yöntemlere göre daha çok geliştiğini söylemek mümkündür. Metin madenciliği, sosyal medyada farklı amaçlarda bilgi elde etmek amacıyla kullanılabilmektedir. Literatür incelendiğinde duygu analizi, etkileşim sayılarının tespiti, müşteri profillerinin tespiti gibi farklı amaçlarla kullanıldığı görülebilmektedir (Liu, 2010).

2.3.1.1.Duygu Analizi

Duygu analizinin ilk çalışmaları 2000 yılında Vasileios ve Janyce (Vasileios & Janyce, 2000), 2001 yılında Tong ve arkadaşlarının (Tong vd., 2001), 2002 yılında Turney'in (Turney, 2002), 2002 yılında Pang ve arkadaşlarının (Pang vd, 2002) yaptıkları çalışmalar olarak kabul edilmektedir. Duygu analizi ifade olarak ilk defa 2003 yılında Tetsuya ve Jeonghee tarafından (Tetsuya & Jeonghee, 2003) ortaya çıkarken benzer

amaçla kullanılan fikir madenciliği (opinion mining) ifadesi ise ilk defa 2003 yılında Kushal ve arkadaşları tarafından literatüre kazandırıldığı ifade edilmektedir. (Kushal vd., 2003; Özyurt & Akcayol, 2018).

Duygu analizi, sosyal medya verileri, belgeler, film yorumları gibi metinler ile çalışmaya en elverişli yöntemlerde birisi olarak görülebilmektedir. Söz konusu analizlerde metinlerde yer alan ifadelerin arka planındaki duygu kategorisinin tespitini hedeflenmektedir. Genellikle olumlu, nötr ve olumsuz üçlü kutupsal yaklaşımı kullanılmakla beraber farklı sınıflandırmalarda literatürde mevcuttur. Sosyal medyadaki Türkçe metinler üzerinden veri madenciliği algoritmalarının karşılaştırmasına yönelik çalışmalar mevcuttur. Türkçe 14777 adet Twitter mesajları üzerinden yapılan çalışma da destek vektör sistemleri, Naive Bayes, çok terimli Naive Bayes ve k-en yakın komşu algoritmaları karşılaştırılmıştır. Müşteri yorumları üzerinden olumlu-olumsuz olacak şekilde ikili kutup sınıflandırılması konusunda çok terimli Naive Bayes algoritması diğer yöntemlerden daha başarılı bir sonuç üretmiştir. Ayrıca, kelime çantası (bag of words) ve n-gram modelleri de ikinci bir analiz olarak değerlendirilmiş n-gram modelinin doğru sınıflandırma yüzdesinin daha yüksek olduğu görülmüştür. Bu iki analizin birlikte uygulanması sonucunda ise doğru sınıflandırma yüzdesi en yüksek olan kombinasyon n-gram ile çok terimli Naive Bayes olduğu rapor edilmiştir (Çoban vd, 2015; Çoban vd. 2018).

Başka bir çalışma da ise Twitter verileri ile duygu analizi için Naive Bayes, Rastsal Orman Yürüyüşü ve Destek Vektör Makinesi yöntemlerinin entegrasyonu ile yüksek oranda başarılı sınıflandırma yapılabildiği görülmüştür. Bu çalışmada ise 8321 tweet üzerinden yapılan çalışmada da n-gram yönteminin kelime çantası (bag of words) yöntemine göre bir derece daha başarılı olduğu gösterilmştir. Çoban çalışmasında yer alan ikili sınıflandırma yerine bu çalışmada ise sınıflandırmada temel üçlü (pozitif, negatif ve nötr) sınıflandırılma şeklinde kullanmayı tercih etmişlerdir. Etiketleme için Zemberek Sözlüğünden yararlanılmıştır (Meral & Diri, 2014). Benzer bir çalışmada Vermeer ve arkadaşları (2019) tarafından, sekiz farklı işletmenin 11000 tweet ve 60000 facebook yorumunu dikkate alınarak yapılmıştır. Bu çalışmada makine öğrenimi ile işletmeler için sosyal medyadaki ilgili dijital ağızdan ağıza pazarlamayı ele alınmıştır. Söz konusu çalışma için içerik ve duygu analizi yöntemlerinden yararlanmıştır. Veri madenciliği tekniklerinden Bernolli Naive Bayes, çok terimli Naive Bayes, lojistik regresyon, stokastik gradyan descent, destek vektör makinesi ve passive aggresive yöntemlerini ele alınarak karşılaştırılmıştır. Sonuç olarak söz konusu modeller arasında en yüksek doğruluk oranına lojistik regresyon yöntemiyle rastlandığını ifade etmişlerdir. Sözlük ve kelime tabanlı duygu analizinde kesinlik açısından çok terimli Naive Bayes yöntemi en başarılı yöntem olduğu sonucuna varmışlardır (Vermeer vd, 2019).

Türkçe Tweetler üzerinden yapılan başka bir çalışmada ise temel üçlü sınıflandırma ile duygu analizi yapılmıştır. Bu çalışmada dört aylık dönemde atılan paylaşımlar dikkate alınmıştır. Oluşturulan üç farklı veri seti üzerinden duygu analizi uygulanmıştır. 3-gram yönteminin %70 oranında başarılı olduğu görülmüştür (Akgül vd, 2016). Twitter üzerine yapılan benzer bir çalışmada da n-gram ve Naive Bayes yöntemi kullanılmıştır. Modeldeki etiketlenme için TreeTagger kütüphanesi kullanılarak geleneksel üçlü sınıflandırma kullanmayı tercih etmişlerdir. Yapılan bu çalışmanın sonuçlarının başarılı olduğu sonucuna varmışlardır. Böylelikle Twitter bazında otomatik bir külliyat (Corpus) oluşturulmasını hedeflemişlerdir (Pak & Paroubek, 2010).

Duygu analizi, bilgi ve yönetim, veri madenciliği, metin madenciliği, web madenciliği, doğal dil işleme (Natural Language Processing - NLP) ve hesaplama dilbilimi ile büyük ölçüde örtüşebilmektedir veya buna dayanabilmektedir. Derin öğrenme ile ironilerin algılanması üzerine son zamanlar yürütülen birçok çalışma mevcuttur. Bulanık mantık duygu analizinde pozitif ve negatifleri yakalarken, nötr ifadelerde başarısız olduğu ifade edilmiştir. Duygu analizinde bazı çalışmalarda yapay sinir ağları gibi veri madenciliği tekniklerinin kullanımı son zamanlarda popüler hale getirebilmiştir. Güncel literatürdeki çalışmalarda neutrosophic kümelerden faydalanarak iki pozitif, üç belirsiz, iki negatif üyelik tanımlanarak duygu analizi yapıldığı görülebilmektedir (Singh vd., 2020). Buradaki nötrofi, bir görüş ya da duyarlılık olan "A" ile "A olmayan" ve "A" ya da "anti-A" değil, karşıt duyarlılığı olan "anti-A" ile ilişkisini inceleyen bir yöntemdir. Bu bağlamda Kandasamy ve arkadaşlarının yürüttüğü bu tarz çalışma da Python da yer alan TextBlob kütüphanesi kullanılmıştır. TextBlob ile elde edilen -1 ile 1 aralığındaki değerler üzerinden söz konusu kutupsallaşma sağlanmıştır. Önce ikili, sonra beşli ve en son olarak da yedili olarak duygu analizi kutuplarına ayrılmıştır. Analiz kısmında on konu belirlenmiş ve bu başlıklar altında İngilizce bin tweet ile uygulama yapılmıştır (Kandasamy vd, 2020; Singh vd., 2020).

Metin madenciliği müşteri ilişkileri bazında da kullanılabilmektedir. Müşteri deneyimi, duyusal boyutunun en önemli olduğu iddia edilen çok boyutlu bir yapı olarak ele alınabilmektedir. Bu bağlamda farklı farklı sektörlerde kullanılabilmektedir (Akyüz, 2013). Mehraliyev ve arkadaşları müşteri ilişkileri üzerine yaptıkları bir çalışma da metin madenciliğinden yararlanmışlardır. Söz konusu çalışma müşteri deneyiminin duygusal boyutuna odaklanılmıştır. Duyusal deneyim, uyarılacak duyuları yani görme, işitme, dokunma, tat ve koku etkileyen müşteri deneyiminin bir bileşeni olarak tanımlamışlardır. Bu tanım ilk olarak turizm ve otelcilik sektörü literatüründe ele alındığı ifade edilmektedir. Çalışmanın sonucu olarak, müşterilerin deneyimlerinin çoğunluğu olumlu olmasına rağmen, olumsuz duyusal deneyimlerin müşteri puanlaması üzerinde daha yüksek etkiye sahip olduğunu görülebilmektedir. Ayrıca, beş duyu, genel deneyimin oluşturulmasında farklı ağırlıklara sahip olduğu görülebilmektedir. İki arkadaşın aynı sinemaya gittiği varsayıldığında, aynı patlamış mısır, aynı film, aynı koltuklar ama her biri tamamen farklı bir deneyim ile dışarı çıkabilir. Bunun nedeni, her tüketicinin benzersiz olması olarak söylenebilir. Her kişi duruma farklı bir arka plan, değerler, tutumlar ve inançlara sahip olabilir. Başka bir ifade ile, herkes kişiselleştirilmiş "gül renkli gözlüklerle (rose-colored glasses)" deneyimler olduğu ifade edilebilmektedir. Bundan yola çıkarak yapılan bir çalışmanın uygulama kısmında restoran müşterilerinin çevrimiçi deneyimlerinin duygusal terimleri analiz edilmiştir. Bu bağlamda beş pozitif ve beş negatif olmak üzere on adet sınıflandırma üzerinden analizler gerçekleştirilmiştir. Çalışmada dört yüz yirmi kelime belirlenmiş ve bunların hangilerinin görme, tat, dokunma, ses ve koku duyularına ait olduğu tanımlanabilmiştir. Daha sonra ifadeler bu duyulara göre etiketlenmiştir. Her cümle için beşli skalada duyulara ait pozitif ve negatif skorlar elde edilmiştir. Böylelikle elde edilen on skor bağımsız değişken ve yıldız puanı bağımlı değişken olarak regresyon analizi uygulandığı ifade edilmiştir. Regresyon analizi sonucuna göre, beş duyuda negatif ve pozitif yorumlar etkili iken negatif yorumlar pozitif yorumlarda daha etkili olduğu görülebilmektedir. Ayrıca pozitif yorumlarda tatma duyusu iken, negatif yorumlarda görme ve tatma en etkili duyular olarak görüldüğü ifade etmişlerdir (Mehraliyev vd, 2020; Alan vd., 2018).

Duygu analizinin bir başka türü ise hedef tabanlı duygu analizidir. Söz konusu bu yöntem, metinlerin içerisinde yer alan birden fazla farklı duyguların dikkate alınması temeline dayanır. Hedef varlıklar ile ilgili

oldukları duygu durumunun birlikte tespiti sağlanabilmektedir. Bu analiz aşamasında, hedef terim, hedef kategori ve duygu sınıfı olmak üzere üç temel alanla temsil edilen duygu tanımlama grupları ele alınarak iterasyonel olarak duygu analizi gerçekleştirilmektedir. Türkçe literatürde bu konuda yapılan ampirik çalışmalarda hedef kategori belirlemede %66,7, hedef terim belirlemede %53,2 F1-skoru elde edilirken bu iki alanda birlikte belirlenmesinde %46,71 oranında başarı sağlanabildiği ifade edilmektedir. Fakat doğrusal sınıflandırma yöntemleri ile bu başarı oranı %76,1 'e kadar yükseltilebildiği gösterilebilmiştir (Çetin & Eryiğit, 2017). İngilizce sözlükte ise bu oran %84 ile %91,48 arasında olduğu ifade edilmektedir. Ürünler üzerinde yapılan bir çalışmada cep telefonu kategorisinde en yüksek orana ulaşabilmişlerdir. Ayrıca şirketin ürünlerine ait popüler kelimeler, başlık etiketleri beş farklı yöntemle tespit edilmiştir. Yöntemler arasında tutarlılık temelli hedef tabanlı duygu analizi ile sıralamalı tutarlılık temelli hedef tabanlı duygu analizinin ele alınan diğer yöntemlere göre daha yüksek başarı oranına sahip olduğu sonucuna varmışlardır (Lakkaraju vd, 2011).

Sosyal medya paylaşımlarının gücü de yadsınamaz boyutta olabilmektedir. Bazı paylaşımlar toplumlarda hareketlenmeye neden olabilmektedir. Sosyal medyanın gücü toplumsal etkilerinin yanı sıra, ekonomik alanda da etkisi olduğu görülebilmektedir. Alanında söz sahibi kişilerin veya yüksek takipçi sayısı olan profillerinden yapılan paylaşımlarında ekonomiye de yer yer yön verdiği gösterilebilmektedir. Yapılan Twitter paylaşımlarının ikili (pozitif, negatif) sınıflandırması ile borsa açılış kapanış fiyatları arasındaki farka göre kâr-zarar durumu ile ilişkili olduğu gösterilmiştir. Kırk üç günlük Borsa İstanbul verileri ile beş yüz Twitter paylaşımları arasında yapılan dört farklı makine öğrenmesinde %70 doğruluk oranı ile Naive Bayes yöntemi ön plana çıktığı ifade edilmiştir (Yıldırım & Yüksel, 2017). Başka bir çalışmada ise on bir şirketin hisse senedinin fiyatı ile dört milyon Twitter paylaşımları üzerine yapılmıştır. Yapılan bu çalışmanın sonucunda da iki haftalık gecikmeli Granger Nedensellik yöntemi ile tespit edildiği ifade edilmiştir (Rao & Srivastava, 2014). Benzer bir çalışma büyük ölçekli uluslararası on üç şirket üzerinden yapılan çalışmanın sonucunda da hisse senetleri ile paylaşımların pozitiflikleri arasında 0,88 gibi yüksek korelasyon olduğu tespit edildiği gösterilmiştir (Rao & Srivastava, 2012).

Duygu analizi yardımıyla sınıflandırmanın kullanıldığı bir diğer alan ise açık uçlu ifadelerin değerlendirilmesi şeklinde olabilmektedir (Kasapoğlu vd., 2020). Yapılan eğitim, tedavi gibi süreç iyileştirmeye yönelik değerlendirmeler genelde istatistikteki ölçekler içeren anketler yardımıyla yapılabilmektedir. Buna alternatif bir yaklaşım olarak hazırlanan açık uçlu sorulara gelen yanıtların değerlendirmesi ile yapılması mümkün olabilmektedir. Kurs eğitimin değerlendirilmesi ile yapılan bir çalışmada bir öğretmenin performansının öğrencilerin geri bildirimleri ile yapılan metin analizi ile mümkün olduğu gösterilmiştir. KNIME üzerinden yapılan çalışmada öğrencilerin değerlendirmeleri pozitif, negatif ve nötr sınıf olmak üzere duygu analizi ile sınıflandırılmıştır. Sınıflandırma ile ölçek skoru arasında yüksek korelasyon elde edildiğinden alternatif bir değerlendirme olabileceği sonucuna varılmıştır. Ayrıca, analiz sonucunda "Fun" ve "Fine" kelimeleri orijinalinde nötr iken yaptıkları modifikasyon ile pozitif olarak kutuplaştırılmıştır. Bu tarz ifadeleri genel etiketlemelerden ziyade alan bazında değerlendirilmesinin daha uygun olduğu sonucuna varılmışlardır (Rajput vd, 2016).

Duygu analizi forum sitelerinde yazılan eleştirilerin değerlendirilmesi alanında da kullanılabilmektedir. Örneğin, film sitelerinde gelen yorumların sınıflandırılması ve sınıflandırmanın film kategorisine göre değişikliği de incelenebilmektedir. Romantik filmlerde sevgi, şirin, güzel gibi kelimeler

geçerken, melankolik filmlerde kalp kırıcı, mutsuzluk gibi kelimelerin kullanılması doğal olarak beklenebilir. Söz konusu bu sitelerde aynı zamanda filmlerin puanlaması da yer aldığından denetimli öğrenme ile film yorumları ile değerlendirme arasında ilişkiye bakılabilmektedir. Maas ve arkadaşlarının (2011) yaptıkları bu tarz bir çalışmada, kendilerinin geliştirdiği duygu modeli ve gizil duygu analizi kıyaslanabilmiştir. Geliştirdikleri model, literatürdeki modellerden daha başarılı bir sonuç vermiştir. Kıyaslamak için iki bin film yorumu içeren açık bir veri setinden yararlanmışlardır. Önerilen modelin bileşenini, örtük konular yerine kelime temsillerini yakalamayı amaçlayan bir şekilde parametre olarak kurgulamışlardır. Yöntemleri gizli konuları doğrudan modelleyen LDA 'dan daha iyi performans gösterdiği sonucuna varmışlardır (Maas vd., 2011).

Duygu analizi ile sınıflandırma genellikle pozitif, negatif veya olumlu olumsuz gibi sınıflandırılabilmektedir. Bunun haricinde duygu analizi yardımıyla şirketler gelen metinlerin şikâyet, talep, teşekkür metni olup olmadığı gibi sınıflandırmalarda yapabilmektedir. Sosyal medya ‘da yer alan bir mesajın hangi sınıflandırmaya tabi tutulacağı da işletmeler için önemli olabilmekteidr. Bundan dolayı, kullanıcıların paylaşımlarının içeriklerine göre kategorize edilmesi de çalışılan ayrıca bir alandır. Twitter ‘daki kullanıcıların paylaşımlarının duygu analizi ile gönderinin haber mi, siyaset mi yoksa kültür içerikli mi olduğu üzerine yapılan bir çalışmada Bayes algoritmasından yararlanılmıştır. Duygu analizi ile metinlerin sınıflandırmasının başarılı olduğu gösterilmiştir (Baykara & Gürtürk, 2017).

Taboada ve arkadaşlarının (2011) duygu analizi üzerine yaptıkları bir çalışmada metinden duyguları çıkarmak için sözlüğe dayalı bir yaklaşım sunmaktadırlar. Geliştirdikleri SO-CAL (The Semantic Orientation CALculator), metnin ana konusuna yönelik görüşünü yakalayan bir metne pozitif veya negatif bir etiket atama süreci olan kutupsal sınıflandırma yöntemini kullanmaktadır. Uygulamada Amazon ‘un Mechanical Turk servisi ile güvenirlilik ve geçerlilik göstermişlerdir (Taboada vd, 2011).

Sosyal medya bazı kullanıcılar için haber alma kaynağı olarak da kullanılabilmektedir. Televizyon, radyo ve yazılı haber kaynaklarının yerini günümüzde sosyal medya kanalları almaya başladığı söylenebilir. İnsanlar günlük haberleri anlık ve daha hızlı ulaşabildikleri için bu kaynaklara yönelebilmektedir (Van der Meer & Verhoeven, 2013; Shearer & Mitchell, 2021). Geleneksel haber kanalları da bundan dolayı dijital platformalar da ayrıca olarak haberleri sunmak zorunda kalabilmektedir. Bunun getirisi olarak da dijital platformlardaki haberlere ve okuyucuların yorumlarına ulaşmak araştırmacılar için çok kolaylaşabilmektedir. Beş popüler haber kaynağı olarak CNN, For News, NPR, The Economist, New York Times ele alınmış ve üçlü duygu analizi uygulanmıştır. Çalışmanın sonucu olarak olumlu ve olumsuz haberlerin kullanıcılar tarafından daha çok dikkatini çektiği görülmüştür. Ayrıca zamansal boyutta yapılan analizin sonucunda bu durumun zamana göre popülerlik ile değiştiği tespit edilmiştir. Ek olarak gönderilerin duygu analizi ile yorumların duygu analizi arasında %90 gibi yüksek bir korelasyon olduğu, dolayısıyla metinlerin içerikleri ile kullanıcıların tepkileri arasında sıkı bir ilişki olduğu söylendiği ifade edilmiştir (Kumar vd, 2018).

Duygu analizi üzerinden rakip firmaların değerlendirilmesi açısından da kullanmak mümkün olabilmektedir. Dijital kanallarda markalara ait etiketlemeler yapılan paylaşımlar incelenerek müşterilerin ilgili markalara karşı tutum ve davranışlarını incelenmesine imkân sağlayabilmektedir. Akundi ve arkadaşlarının (2018) çalışmasında buna benzer bir araştırma yapmışlardır. Söz konusu çalışmada Apple, Samsung, Huawei markalarına ait cep telefonları için atılan Twitter paylaşımları ele alınmıştır. Yaklaşık elli

bin tweet incelenmiş ve markalara ait en çok ve ilgili kelimeler tespit edilmiştir. Daha sonrasında bu kelimelerin duygu analizi ile ikili kutup sınıflandırması yapılmıştır. Başka bir ifade ile, pozitiflik ve negatiflik skorları belirlenmiştir. Bu kelimelerin skorları üzerinden markalara ait pozitiflik ve negatiflik toplam skorları elde edilmiştir. En yüksek pozitiflik skoru IOS işletim sistemi aldığı tespit edilmiştir. Buna karşın, tweetlerin analizine göre, Samsung ve Huawei ile ilgili duyguların iPhone ile karşılaştırıldığında daha olumlu olduğu tespit edilmiştir. Duygu analizin bir sonucu olarak paylaşımların konuları da tespit edilebilmektedir. Bu çalışmada da Samsung ‘a ait tweetlerin çoğu, Samsung 'un yeni Galaxy 8 sürümüne göre Apple 'a kıyasla daha fazla kar elde etmesiyle ilgiliyken, yeni bir akıllı telefonla ortaya çıkan Huawei, KFC ile iş birliğine yer veren tweet 'lerde yer aldı. Ayrıca, iPhone için çoğu tweet, iPhone 8'in fiyatı ve tasarımı ile ilgili olumsuz duygulara sahip olduğu ancak IOS sistemine yönelik duyarlılığın Android sistemine göre daha iyi olduğu görülmüştür (Akundi vd, 2018).

Birden fazla dijital pazarlama kanalının birlikte değerlendirilmesinin işletmeler için önemi yadsınamaz olduğu ifade edilebilir. Bundan dolayı günümüzde şirketler ve işletmeler, Facebook, Twitter ve Instagram gibi çevrimiçi sosyal medyanın yaygın eyleminden yararlanma eğilimine yönelebilmektedir (Murdough, 2009, Moro vd, 2016). Nitekim, birkaç dijital pazarlama kanalını eşzamanlı olarak benimseyerek birçok tanıtım ve pazarlama kampanyası yürütülebilmektedir. Böylelikle bu kampanyalar, çok sayıda farklı kullanıcı kategorisine çok hızlı bir şekilde ulaştırılabilmektedir. Çünkü çoğu insan gün boyunca zamanlarının çoğunu çevrimiçi sosyal medyada geçirebilmektedir. Bu kampanyaların performansının değerlendirilmesi için duygu analizi ile takip edilip değerlendirilmesi de bir o kadar önemli olduğu söylenebilir. Birden fazla dijital pazarlama kanalında tanıtım ve pazarlama kampanyalarının yönetilmesinde şirketlere ve işletmelere etkin bir şekilde destek olabilen bir Karar Destek Sistemi geliştirilmesi hem akademik çevrede hem de reel sektörde üzerinde durulan bir uygulama alanıdır. Literatürde bu amaçla geliştirilen bir karar destek sisteminde duygu analizindeki üçlü kutuplaştırma tercih edebilmektedir. Önerilen karar destek sisteminin özü, bir yorumda ifade edilen pozitif, negatif veya nötr kutupları açısından kullanıcıların duygularını tahmin edebilen bir Duygu Analiz Motorudur. Önerilen bu motor %90 doğruluk oranına kadar ulaşarak farklı dijital pazarlama kanallarından gelen yorumları makine öğrenmesi ile sınıflandırabilmektedir. Kurulan bu sistem, yorum akışını, olumlu, olumsuz veya tarafsız görüşler açısından Duyarlılık Analiz Motoru tarafından detaylandırabilmekte ve sınıflandırabilmektedir. Karar destek sistemi ayrıca sosyal medya dinlemesinin sonucunu özetleyen raporlar ve istatistikler oluşturabilmektedir. Özellikle, beğenilerin, takipçilerin ve olumlu ve olumsuz yorumların eğilimlerini belirli bir işletmenin pazarlama yöneticisine raporlamayabilmektedir (Ducange vd, 2019).

Duygu analizi için birçok yazılım paketi kullanılabilmektedir. Python, R gibi birçok yazılım dilinde hazırlanmış dil bazında programlar bulmak mümkündür. KNIME programı içerisinde de kendi analiz kütüphanesi bulunmaktadır. KNIME programı üzerinden yer alan nodüller yardımıyla duygu analizi yapma olanağı sağlamaktadır. Sosyal medya verileri, forumlarda yer alan yorumlar gibi internet tabanlı metinlerin duygu analizinde literatürde kütüphanelerin başarıları da yazılıma göre de değişmektedir (Minanovic vd., 2014; Nausheen & Begum, 2018; Sarlan vd., 2014; Basaraslan & Kayalalp, 2020; Danneman & Heimann, 2014; Pavaloaia vd, 2019).

2.3.1.2.Konu Modelleme

Metin madenciliğinin bir diğer kullanımı da başlık çıkarma veya konu modellemesidir. Bu amaçla kullanılan en sıklıkla tercih edilen yöntemlerin başında konu belirleme modeli (Latent Dirichlet Allocation - LDA) modelleri yer almaktadır. Bu yaklaşımda metinlerin altındaki yer alan gizil başlıkların istatistiksel bir model yardımıyla elde edilmesi hedeflenmektedir (Şeker, 2016). Metin madenciliği duygu analizi ve sayı öngörüleri dışında toplumsal yapıların incelenmesinde de kullanılabilmektedir. İşletmeler ve kurumlar, toplumsal hareketlerin arka planını ve hareket motivasyonunu öğrenip değerlendirmek isteyebilirler. Son zamanlarda Twitter üzerinden gündem olan "bende" hareketi buna bir örnek olarak verilebilir. #MeToo hareketi, Twitter üzerinden 31305 adet tweet ile son yılların en etkileyici sosyal hareketleri arasına girmiştir (Kandasamy vd., 2020). Bir araştırmada bu hareketin altındaki gizil konuların belirlenmesi için konu modelleme (Latent Dirichlet) Tahsis modeli kullanılırken, duygu analizi için denetimli vektör makinesi kullanılmıştır. Araştırmanın bulgusu olarak, iletişim kampanyasında, iş yerinde, cinsiyet eşitliği ve sosyal ağların önemi ortaya çıkarılmıştır. Lakoff ve Lakoff'a göre, ortak bir gerçeklikten bahsetmek için kullanılan kelimeler paylaşılan bir kimliği şekillendirebilir. Bu nedenle, bu tür anahtar kelimeleri analiz etmek, toplumsal yapının altında yatan ilişkileri daha iyi anlamamızı sağlayabilir (Lakoff & Lakoff, 2004). Yaşanan olaylar ile sosyal medyada, eğer bir kullanıcının hikayesi viral olursa, belirli bir takipçi grubundan çok daha geniş kitleye ulaşırsa, bir sosyal ağ hareketi başlatabildiği gösterilebilmiştir. Bundan dolayı, toplumsal hareketlerin başlangıcı ve yapısı incelemek başlı başına araştırma konusu olmuştur. Bende (Metoo) hareketinin incelenmesi için yapılan analizde Pyhton kullanılmış, elde edilen tweetlerden konu çıkarmak için konu belirleme modeli (LDA - Latent dirichlet allocation) analizinden yararlanılmıştır. Analiz sonucunda, yedi başlık elde edildiği ifad edilmiştir. Elde edilen başlıklar bazında Twitter paylaşımlarına duygu analizi yapılmıştır. Başlıkların üçü negatif, üçü nötr ve biri pozitif ilgili olarak belirlenebilmiştir. Hareketin yapısı, toplumdaki yansıması değerlendirilebildiği söylenmiştir (Reyes-Menendez vd, 2020; Tirea & Negru, 2013).

Metin madenciliğinde kullanılan konu modellemesi iş zekâsı ile birleştirilmesi de önemli olabilmektedir. İş analitiği ile makine öğrenmesinin birleştirilmesi işletmelerde zaman maliyetini düşürebilmektedir (Khazaei vd.,2016). Sosyal medyanın günlük hayatımızda her geçen gün payının büyümesi ile bu kanallardaki paylaşımların işletmelerdeki iş analitiğinde değerlendirilmesi de önem kazanmıştır. Paylaşımların içerisindeki gizil konuların belirlenip, ona göre değerlendirilmesi ve sonuçlarına göre stratejilerin üretilmesi her geçen gün önemli hale gelebilmektedir. Bu amaçla iş zekâsı ile sosyal medya analizini buluşturduğu bir çalışma son zamanlarda artış göstermektedir. Bir çalışmalarda genellikle veri madenciliği tekniklerinden, Naive Bayes, karar ağaçları ve destek vektör makinelerinden yararlanılmaktadır. Facebook ve Twitter verileri kullanılarak yapılan bir çalışmada konuların kestirilmesinde en yüksek doğruluk oranına destek vektör makinesi yöntemi ile sağlandığı sonucuna varılmıştır. Bu çalışmanın amacı olan kategorilerin ve konuların oluşturulması için içerik analizinden yararlanılmıştır (Kurnia, 2018).

Sosyal medya paylaşımlarından konu modellemesi ile temel başlıkların elde edilmesi hedeflenebilmektedir. Örneğin bir işletme hakkında yapılan yorumlardan işletme ile ilgili şikâyet, talep, teşekkür gibi başlıkları ve konuları modellenebilmektedir. Benzer bir amaç ile İtalya 'daki turistlerin ihtiyaç ve şikayetlerinin belirlenmesi için Facebook verilerinden yararlanılmıştır. Facebook 'un taktik ve stratejik olarak kullanılma şeklinin İtalya bölgesel Destinasyon Yönetim Organizasyon (Destination Management

Organisations – DMO) 'ları arasında önemli ölçüde farklılık gösterdiği gösterilmiştir. Görsel içerik yani fotoğrafların olduğu paylaşımlar ve orta derecede uzun gönderiler, Facebook etkileşimi üzerinde istatistiksel olarak önemli bir olumlu etkiye sahip oldukları, gönderilerin yüksek gönderi sıklığı ve günlük erken zamanlama yani sabahları etkileşim üzerinde olumsuz bir etkiye sahip oldukları gözlemlenmiştir. Beğeni sayısı, takipçi, yorum sayıları, toplam paylaşım sayısı gibi değişkenlerin dikkate alındığı çalışmada web madenciliğinin yanı sıra regresyon ve korelasyon gibi istatistik temelli analizlerden yararlanılmıştır (Mariani vd, 2016). Turizm üzerine yapılan bir başka çalışma da ise, Mariani ve arkadaşlarının sonuçlarını ile benzer olarak turizm müşterilerinin beklentisini anlamak amacıyla yapılmıştır. Müşteri beklentisindeki değişimi etkileyen ana faktörler olarak dijital hizmetler, dijital pazarlama, veri madenciliği ve çevrimiçi seyahat toplulukları olarak ele alınan bu çalışmada ise, dijital iletişim kanalları üzerindeki kişiselleştirilmiş bir yaklaşımın gelecekteki hizmet sunumunda önemli bir gereksinimi olduğu görülmüştür. Anket tabanlı yapılan bu çalışmada, değişen ihtiyaçları karşılamak için, tüm yapısal yolculuk boyunca, özellikle yapısal olarak zayıf bölgelerde, müşteriler ve şirketler arasında ikili iletişimin önemi vurgulanmıştır (Reichstein & Harting, 2018).

2.3.1.3.Öngörü Modelleri

Metin madenciliğinin duygu analizi ve konu modelleme dışında, beğeni ve paylaşım sayıları veya başka bağımlı bir değişkenin değerinin de öngörülmesi amacıyla kullanılabilmektedir. Takipçi sayısı, sosyal medya etkinliğinin en yaygın kullanılan performans endekslerinden birisi olarak gösterilebilir. Profiller beğeni ve paylaşım sayılarını artıran unsurları bilmek ve bu yönde paylaşım yapmak isteyebilirler. Takipçi kazanmak, bir kampanyanın başarısının önemli bir endeksi olabilmektedir. Ancak sosyal medya pazarlamasının en etkili araçlarına işaret eden takipçilerle etkileşimi arttırabilmektedir. İzleyicileri sadece pasif olarak 'Beğenmek' değil, aynı zamanda markayla ilgili aktif olarak 'Sevmek' mesajını yayınlayarak, deneyimlerini marka ile paylaşmalıdırlar. Böylelikle sosyal pazarlamacıların nihai amacı olan mümkün olan en geniş elektronik ağızdan ağıza pazarlama ağını genişletilmesi gerçekleşmesi sağlanabilir. Günümüz toplumunun bağlantılı olması, teknolojinin artması kitlesel fikir paylaşımının artışına sebep olabilmektedir. En başta Twitter olmak üzere çeşitli fenomenlerle ilgili düşüncelerini ve görüşlerini paylaşmak için dünyanın dört bir yanındaki internet kullanıcılarından büyük ilgi ve alaka görebilmektedir. Uyumlu cihaz sayısının artması ile sosyal medya, kullanıcıların fikirlerini, haberlerini, aktivitelerini, ilgi alanlarını ve çevrelerinde meydana gelen olaylarla ilgili diğer bilgileri gönüllü olarak paylaşmaları için birincil kanal haline gelebilmektedir. Kullanıcılar, orijinal gönderisine gelen beğenileri ve paylaşımları, memnuniyetlerinin bir göstergesi veya temsili olarak yorumlayabilmektedir. Bir gönderide beğeni ve paylaşım sayısı tahmini sağlamak, kullanıcıların konularını doğaçlama yapmalarına ve daha fazla kullanıcıyla etkileşim kurmalarına yardımcı olabilir. Bu bağlamda, literatürde beğeni ve paylaşım sayılarını öngörme üzerine yapılan bazı çalışmalarda mevcuttur. Yapılan bir çalışma Twitter 2015 - 2018 yılları arasındaki #datascience #machinelearning etiketli paylaşımlara odaklanmıştır. Verilerin elde edilmesi için, Python ’daki tweepy kütüphanesinden yararlanılmıştır. Söz konusu tweetlerdeki beğeni/retweet oranları 4 sınıfa bölerek, kelimelerin bu oranının tahmini üzerine modeller kurulmuştur. Makine öğrenmesi algoritmaları, Doc2Vec ve TF-IDF yöntemleri ile karşılaştırılmak üzere tasarlanmış. TF-IDF ile yapılmış metin madenciliği analizi ile metinlerin sınıflarını tahmin gücünün daha yüksek olduğu görülmüştür. Ayrıca modellerden en yüksek doğruluk oranı Naive Bayes ile kurulan model olduğu belirlemişlerdir (Daga vd, 2020).

Borsa tahmini, araştırılması gereken ilgi çekici bir araştırma problemi olarak görülmektedir. Finans haberine ait içerikler, pazar üzerinde etkisi olan en önemli faktörlerden birisi olabilmektedir. Borsa davranışının analizindeki haber etkisi dikkate alındığında, daha kesin tahminlere ve sonuç olarak daha kârlı işlemlere yol açabilmektedir. Şimdiye kadar, borsa tahmininde haberlerin etkisini dikkate alan çeşitli prototipler geliştirilmiştir. Sosyal medyada ve çevrimiçi haberlerde çevrimiçi düşüncenin yorumlarının kalitesi, finansal piyasaların öngörülebilirliğini belirleyebilir ve büyük kazançlara veya kayıplara neden olabilir. Bu nedenle, birkaç araştırmacı son zamanlarda dikkatlerini bu sorunun farklı yönlerine çevirdi. Ancak, sorunu güncel bilgiler ile ele almak için çok yönlü bir teorik ve teknik çerçeve yoktur. Konuyla ilgili bu tür netlik eksikliğinin, hem davranışsal-ekonomik konuları hem de yapay zekayı içeren disiplinler arası doğasından kaynaklanabilmektedir. Çevrimiçi metin madenciliğine dayalı piyasa tahmini incelendiğinde literatürdeki sistemlerin karşılaştırmalı analizine göre her birinin arkasındaki teorik ve teknik temellerde davranışsal ekonominin izlerini görmek mümkündür (Nassirtoussi vd, 2014).

Borsada işlem gören hisse senetlerinin fiyatlarının tahmini üzerine metin madenciliğinden yararlanmakta mümkündür. Bir çalışma da hisse senetlerine ait fiyatların öngörüsü için basın bültenlerinin yayımlanmasından hemen sonra hisse senedi fiyat eğilimlerini tahmin etmek için uygulanan bir sistem olan NewsCATS (Haber Sınıflandırma ve Ticaret Sistemi) geliştirilmiştir. Geliştirilen bu NewsCATS uygulaması temel olarak üç bileşenden oluşur. Birinci bileşen, metin önişleme tekniklerinin uygulanması yoluyla basın bültenlerinden ilgili bilgileri alır. İkinci bileşen, basın açıklamalarını önceden tanımlanmış kategorilere ayırır. Son olarak, uygun ticaret stratejileri daha önceki kategorizasyon yoluyla üçüncü bileşen tarafından türetilir. Bulgular, basın bültenlerinin kategorize edilmesinin hisse senedi fiyat eğilimlerini tahmin etmek için kullanılabilecek ek bilgiler sağlayabildiğini, ancak kategorizasyon sonuçlarının tam olarak kullanılması için yeterli bir ticaret stratejisinin gerekli olduğunu göstermektedir (Mittermayer, 2004; Mittermayer & Knolmayer, 2006). Literatürde yer alan başka çalışmalar da borsa tahmininde haberlerin etkisini dikkate alan çeşitli prototipler geliştirilmiştir. Bu tür tahmin sistemlerinin ana bileşenleri olarak metin madenciliği tekniklerini ele alan çalışmalar mevcuttur. Nikfarjam ve arkadaşlarının yaptıkları çalışmada gelişmiş farklı prototipler incelenmiş ve ana bileşenlerin uygulanma şekli birbiriyle karşılaştırılmıştır. İncelenen girişimlere dayanarak, uygulamaların eksiklikleri ve gelecekteki potansiyel araştırma faaliyetleri önerilmiştir (Nikfarjam vd., 2010).

Bir diğer borsadaki işlemler üzerine yapılan bir çalışma alanı da zaman serileri üzerinden yapılan çalışmalardır. Haber makalelerine dayalı hisse senedi fiyatlarının hareketlerini tahmin etmek gibi metinsel belgeler ve zaman serilerini aynı anda incelemek, günümüzde veri madenciliği toplumunda ortaya çıkan bir konudur. Literatürdeki araştırmalar, haber makaleleri ile hisse senedi fiyatları arasındaki ilişkinin var olduğunu göstermektedir. Bazı çalışmalar metinler üzerinden tek zaman serili analizleri dikkate almışlardır. Birden çok zaman serisini aynı anda incelemek ise sadece daha bilgi sağlayıcıdır. Fakat aynı zamanda sistemsel olarak daha zordur. Bundan dolayı birden fazla zaman serisi içeren bir yönde araştırmaların sayısı azdır. Hem bu sürecin zorlayıcı yönünü hafifletmek ve hisse senetleri hakkında daha fazla bilgiye sahip olmak için literatürde son zamanlarda modeller geliştirilmeye çalışılmıştır. Yapılan bir çalışmada böyle bir fırsatı araştırmaya ve Verimli Pazar Hipotezine dayalı çoklu zaman serilerinde metin madenciliği için sistematik bir çerçeve önerilmeye çalışılmıştır (Fung vd, 2003).

Sam ve arkadaşlarının (2018) çalışması Facebook üzerine makine öğrenmesidir. Bu çalışmada Facebook gönderilerine gelen beğeni, yorum ve paylaşım sayılarını öngörmek için makine öğrenmesinden yararlanmışlardır. Kernel tabanlı Destek Vektör Regresyonu, Yapay sinir ağ ve doğrusal regresyon tabanlı Echo State Ağları ve Fuzzy Kuralları ile paralel sistem dağılımı geliştirilmiştir. Çalışmanın veri seti olarak, yayınlamadan önce bilinen 7 özellik ve etki sonrası için kullanılan 3 çıktı değişkeni içermektedir. 25 nöron ve 0,5 spectral Radius ile kurulan modeller MSE değerleri üzerinden karşılaştırılmıştır. Beğeni sayısında en düşük hata kareleri ortalamasını geliştirilen Uyarlanabilir Ağ Bulanık Enjeksiyon Sistemi (Adaptive Network Fuzzy Inject System – ANFIS) vermiştir. Diğer iki çıktı da içinde Echo State Ağ modeline yakın sonuçlar çıkarmıştır (Sam vd., 2018).

Twitter kullanıcılarında en önemli unsurlardan biri takipçi sayısı olarak görülebilmktedir. Takipçi sayısını artırmak, düşüncelerin paylaşıldığı Twitter 'da gönderilerinizin daha çok kullanıcıya ulaşmasına olanak sağlayabilmektedir. Bundan dolayı, Twitter kullanıcıları takipçi sayısını artırmaya çalışabilirler. Yapılan çalışmalar incelendiğinde bunun için birçok faktör olduğu görülebilmektedir. Bunların başında çok paylaşım yapmak yer alırken, bu paylaşımların verimli ve önemli olması da bir diğer faktör olarak görülebilmektedir. Yapılan bir çalışmada ise profil isminin takipçi açısından önemli olup olmadığı incelenmiştir. İsim içeren, kelime içeren ve özel içerik adı ile açılan profiller karşılaştırılmıştır. Bu 3 kategori arasında ad alanında İngilizce kelimeler bulunan kullanıcılar, istatistiksel olarak önemli ölçüde daha yüksek takipçi sayılarına sahip oldukları görülmüştür. Öte yandan, isim alanında belirli bir adı olan kullanıcıların daha az takipçi artışına sahip oldukları görülmüştür (Mueller & Stumme, 2017).

İşletmelerin hem kendi sosyal medyaları hem de web sitelerinin görüntülenmesi potansiyel müşterilere ulaşılmanın bir gösterge olarak değerlendirebilmektedirler. Bundan dolayı hem teknik olarak trafiğin saptanması hem de PPC reklamları gibi pazarlama argümanları için görüntülenme sayılarının tahmini önemli olabilmektedir. Bu amaçla bir web sitesinin görüntülenme sayısını öngören modelde lineer model üzerinden beş değişken ile açıklamaya çalışmıştır. Çalışmanın analiz kısmında Robust yöntemden yararlanmıştır. Firmanın büyüklüğünün yanı sıra, bilginin özgünlüğünün, bilgi komisyonculuğunun ve bilginin toplum yanlılığının web sitelerindeki görüntüleme üzerinde etkisi olduğu görülmüştür (Pant & Pant, 2018).

2.3.1.4.Diğer Kullanım Alanları

Önceki bölümlerde metin madenciliğinin duygu analizi, konu modelleme ve öngörü modellemeleri için kullanıldığı çalışmalar üzerinde durulmuştur. Bu bölümde ise bu 3 amaç dışında metin madenciliğinin kullanıldığı çalışmalara değinilmiştir.

Twitter kullanıcıları sürekli olarak özgürce paylaşımları davranış, tutum ve tercihleri hakkında bilgi barındırması açısından araştırma ve pazarlama uzmanları için büyük fırsatlar sunabilmektedir. Bununla birlikte, bir metin madenciliği prosedüründen birisi de örtük veya açık bir şekilde, dil üretimini ve iletişim alışverişini oluşturan sosyal etkileşimi açıklayabilmektedir. Bunun için bir sosyolojik veya psikolojik teorik yaklaşıma atıfta bulunabilir. Metin madenciliği prosedürü hakkındaki literatürün çoğu, metnin açık içeriğine odaklanan kelime etiketleme, cümlenin sözcük yapısı, istatistiksel prosedür ve benzeri metodolojiye özellikle dikkat çeker. ETM (Emotional Text Mining) ise metnin örtük içeriğine odaklanan bir başka yöntemdir. Başka

bir ifade ile bu yöntem, sembolik matrisi ile bir varlığın temsili ve hissiyatının tespitine izin veren denetimsiz bir metin madenciliği sürecidir. Söz konusu yöntem kümeleme ve faktör analizi kullanarak sembolik matrisi elde etmeye amaçlar. Bu matris, sözcükler arasındaki ilişkisel bağları tespit etmek ve metinde bir arada bulunmalarını göstermektedir. Calinski-Harabasz Davies-Bouldin ve sınıf içi korelasyon katsayısı (ICC) endeksleri kullanılarak ilişkileri tespit etmek için k-ortalamalı kümeleme yöntemi kullanılır.

Greco ve Polli (2020) yaptıkları bir çalışmada Twitter 'daki tanınmış bir spor giyim markasına ait takipçilerinin ürün tercihleri ile ilgili kullanıcı profillerin çıkarılması hedeflenmiştir. Çalışmanın uygulamasında R yazılımındaki kütüphanelerden twitterR ile 29 Kasım ile 3 Aralık 2018 tarihleri arasındaki bir spor markasına ait İngilizce mesajlar toplanmıştır. Toplanan veriler EMT yöntemi ile analiz edilmiştir.107500 gönderinin %63,7 'si tekrar paylaşım (retweet) olduğu görülmüştür. Analiz ile dört profil elde edilebilmiştir. Birincisi modaya uygun olarak giyinen, ikincisi düzenli ve pazarlık yapan müşteriler, üçüncüsü eğlence ve rekabetçi sporu tercih edenler ve son grup yeni modelleri tercih edenler ama modası geçmiş başarının tekrar olmasını fark eden bir gruptur. Kullanıcı profilleri dışında beş küme elde edilmiş ve bu kümeler farklı boyutlarda ve farklı marka temsillerini yansıttığı görülmüştür. İlk kümede marka, müşterilerinin zamanla beğeneceği, ünlü spor şampiyonlarının kullandığı kaliteli spor kıyafetleri üretebilen bir firma olarak algılarken ikinci kümede marka, pazarlık avcıları tarafından toplanabilen veya takas edilebilen değerli bir nesne olarak değerlendirmektedir. Üçüncü kümede marka, spor severler, yani formda olmayı seven insanlar tarafından boş zaman etkinlikleri için yararlı spor giyim olarak temsil edilmektedir. Dördüncü kümede marka, moda spor giyim üreticisi olarak temsil edilmektedir. İkon, iyi, moda ve sevimli gibi kelimeler olduğu için müşteriler teknolojiden çok tasarımla ilgilendikleri söylenebilmektedir. Son olarak, beşinci kümede marka, birinci kümede olduğu gibi güvenilir bir spor giyim şirketi olarak algılanmaktadır, ancak müşterilerin en son modele daha fazla ilgi gösterdiği görülmektedir. Tüm temsiller çoğunlukla olumlu göründüğünden, temsilleri iki duygu altında gruplandırılmış: spor severler ve moda severler (Greco & Polli, 2020). Bu tarz çalışmalar ile markalar potansiyel müşterileri belirlenebilmektedirler. Ayrıca profil çalışmaları, markalar için pazarlama stratejileri geliştirilmesine imkân sağlamaktadır.

Metin madenciliğinde analiz kadar verilerin analize hazırlama süreci de bir o kadar önemli olabilmektedir. Yazım hataları, harflerin yerine kullanılan karakterlerin tespiti, kelime köklerin bulunması gibi işlemler ile metinlerin analize hazır hale getirilmesi aşamasına metin analizinde ön hazırlık aşaması olarak ifade edilmektedir. Sosyal medya metinleri, resmi olarak yazılmış yazılardan oldukça farklı olabilmektedir. Sosyal medya paylaşımlarında kullanıcılar, genellikle kişisel bir dil ile yazarlar ve günlük hayattaki konuşma dilini kullanabilirler. Sosyal medya metinlerinde ön hazırlık işleminde dildeki zorlukla birlikte kendi içerisinde bazı önişlemeler de gerektirebilmektedir. Örneğin, Twitter bahsedenler (@ kullanıcı adı), hashtag'ler (# konu), çeşitli ifadeler (örneğin, ': @', '<3', '@>) içerir. ',' :) ') ve özel anahtar kelimeler (RT - retweet, DM - doğrudan mesaj vb.) bunların tespiti ve düzenlenmesi gerekebilmektedir. Ayrıca kurumsal olmayan kullanıcılar dilbilgisi açısından doğru kelime veya cümleleri kullanmak zorunda olmayabilirler. Resmi dilden farklılıklar olarak ilk zamanlarda ortaya çıkan ayrım, dilbilimsel olarak Crystal (2008) tarafından logogramlar, piktogramlar, baş harfleri, atlanmış harfler, standart olmayan yazımlar ve kısaltmaların kullanımı olarak sınıflandırılmıştır. Bu aşamada yapılan işlemler de çalışmalar ile geliştirilmeye devam etmektedir.

Türkçe literatürde bu konuda sözlük desteği ile birçok çalışma mevcuttur. Gülşen Eryiğit ve Dilara Torunoğlu-Selamet (2017) sosyal medya paylaşımlarındaki metinlerin düzeltilmesi ile ilgili çalışmada, sosyal medya paylaşımlarının Türkçe diline uygun hale getirilmesi üzerine bir normalizasyon önermişlerdir. Metin normalizasyonu konuşma dilindeki kanonik olmayan dilin işlenmesi için gerekli olan bir aşamadır. Türkçe'nin zengin bir dil olmasından dolayı tek aşamalı salt bir istatistik model ile normalleştirilmesi problem oluşturmaktadır. Bu çalışmada söz konusu zorluğun üstesinden gelmek için sosyal medya metinleri üzerinden iterasyonel bir sistem önerilmektedir. Önerilen modeller %70,40 ile %67,37 oranlarında başarılar göstermiştir. Hatta büyük küçük harfe duyarlı olmayan modelde %77,07 oranında başarı elde edilmiştir. Denetimli normalleştirme yaklaşımları, dil morfolojisinin karmaşıklığından kaynaklanan çok fazla veri gerektirmesi nedeniyle zengin dil aileleri için çok büyük bir örnekleme gerektirmektedir. Türkçe morfolojik olarak çok zengin bir dildir. Ayrıca sondan eklemeli yapısı olduğundan çok yüksek sayıda olası sonek kombinasyonunu içerisinde barındırmaktadır. Bundan dolayı Türkçe dil için normalizasyon aşaması çok zahmetlidir. Genel olarak her dil için normalizasyonda iki aşama yer almaktadır. Bunlarından ilki hatalı kelimenin belirlenmesi iken ikincisi ise doğru olabilecek adayların belirlenmesidir. Ele alınan makalelerde, genel olarak 7 aşamalı bir makine öğrenmesi kullanılmıştır. Bu 7 katmanlı sistemin birinci aşamasında harf durumu dönüşümü yapılmaktadır. İkinci aşamasında ise değiştirme kuralları ve sözlük araması yapılmaktadır. Daha sonraki aşamasında ise uygun isim algılanması sağlanır. Dördüncü aşamada metinlerdeki aksan düzeltilirken beşinci aşamada ise sesli harf hataları düzeltilir. Düzeltilen aksanlar normalleştirildikten sonra son aşamada yazım düzeltmesi yapılır. (Eryiğit & Torunoğlu, 2017; Dehkharghani, 2015; Dehkharghani vd, 2016).

Sosyal ağlarda en önemli göstergeler beğeni ve takipçi sayısı olarak değerlendirilebilir. Profiller bu çıktıları artırmak için yollar arayabilmektedirler. Bir çalışmada derin görüşme yöntemi ile kızların sosyal medyada kendilerini beğendirme ve öz çekim kullanma amaçları araştırılmıştır. Toplamda yirmi dört kız ile yapılan derin mülakat üzerinden sonuçlar elde edilmiştir. Tematik analizin sonuçları, genç kızların kendine güvenleri ile algılanan güzellik standartları arasında bir boşluk olduğunu göstermiştir. Düşük benlik saygısı ve güvensizlik duyguları, düzenlenmiş kişisel sunum ve akran tanıma arayışındaki çabalarının öz çekim paylaşmalarının temelini oluşturduğu tespit edilmiştir. Ayrıca takipçiler ve akranlar, genç kızların algılarını şekillendirme ve güzelliğin gösterilmesi, hayali izleyicileri, yargıçları, dolaylı öğrenme kaynakları ve karşılaştırma gibi psikolojik olarak birden fazla rol oynadığı sonucuna varılmıştır. Sosyal medya, güzellik standartlarını oluşturmak için kişilerin paylaşımlarını sunarken aynı zamanda akranlar ile karşılıklı iletişim kurulduğu yeni etkileşimli platformlar sunar. Buna benzer durum tüzel kişiler için de geçerlidir. İşletmelerde kendilerini gösterme, sektörün standartlarını uyma, benzeme ve rakipleri ile kendilerini karşılaştırma içerisindedirler. Bundan dolayı, tüzel kişiliklerin profillerindeki beğeni alma önemli bir göstergedir (Chua & Chang, 2016; Meier & Gray, 2014). Instagram ve Facebook gibi sosyal ağ siteleri (Social Network Site - SNS) gençler ve kurumlar arasında görünüş ve imaj hakkında akran ve rakip karşılaştırmasını kolaylaştırmıştır (Mascheroni, Vincent ve Jimenez, 2015). Yapılan çalışmaların ortak sonucu olarak paylaşılan resimlerin içeriklerinin beğeni ve yorum almada etkili olduğunu göstermektedir. Örneğin, yapılan bir çalışmada resimde insanın olması durumunda daha fazla yorum ve beğeni aldığını gösterilmiştir. 23 milyon Instagram resmi ve 3 milyon profil üzerinden yapılan bu çalışmada, yüz içeren fotoğrafların beğenilme olasılığının %38 ve yorum alma olasılığının %32 daha yüksek olduğunu gösterilmiştir. Bununla birlikte, yüzlerin sayısının, yaşlarının ve cinsiyetinin bir etkisi olmadığını görülmüştür (Bakhshi vd, 2014).

Literatürde Twitter ve Instagram ‘da olduğu gibi sosyal medya kanallarında etiketler üzerinden analizler yapıldığı görülebilmektedir. Bu paylaşım sitelerinde kullanıcılar etiketleme yaparak paylaşımlarda bulunabilirler. Söz konusu bu etiketlemeler üzerinden yapılan birçok çalışma mevcuttur. Bu çalışmalarda da paylaşımlarda kullanılan etiketler kullanılarak yine duygu analizinden yararlanılmıştır. Bu etiketlerde konum bilgisinin paylaşımından yola çıkılarak coğrafi böyle hakkında bilgi edinmek mümkün olmaktadır. İklim özellikleri (örneğin ortalama sıcaklık, rüzgâr hızı, yağış, güneş radyasyonu, su buharı basıncı), arazi örtüsü kategorileri, tür oluşumu ve manzara gibi çevresel özellikleri tahmin etmek için paylaşımlarda bulunan etiketlerin ele alınması ile sosyal medya paylaşımlarının alandaki yararlılığını inceleyen çalışmalar vardır. 2000 veri üzerinden yapılan bir çalışma ile kurulan modelde etiketler yardımıyla bölgeler hakkında bilgi çıkarımı sağlanması amaçlanmıştır. Kurulan modellerde yapay sinir ağları ve destek vektör sistemleri ile entegre ile kıyaslanmış %80 öğrenmeli modelde belli bir oranda daha iyi sonuç verdiği gösterilmiştir (Jeawak vd, 2020).

Jarvinen ve arkadaşları (2012), işletmeden işletmeye (Business to Business - B2B) olarak endüstri sektöründe dijital ve sosyal medya pazarının kullanımı üzerine bir araştırma gerçekleştirmişlerdir. Söz konusu çalışmada sosyal medya pazarın kullanımının araştırılması için anket yönteminden yararlanılmıştır. 145 firma üzerinden yapılan çalışmanın sonucuna göre firmaların dijital ortamı etkin olarak kullanmadığı tespit edilmiştir (Jarvinen vd., 2012).

Medvedev ve arkadaşları (2017), yaptıkları çalışmada bulut sistemi için web tabanlı veri madenciliği tekniği önerilmişlerdir. Söz konusu çözüm önerisi, sürükle bırak özelliği basit, etkili ve kolaylık sağlamıştır. Bu çözüm, veri sınıflandırma, kümeleme ve boyutluluk azaltma sorunlarını çözmek için kullanışlı olduğu belirtilmiştir. Sınıflandırma algoritması için rassal orman algoritması ve çok katmanlı algılamadan yararlanılmıştır. Boyut indirgeme için temel birleşenler analizi ile görselleştirme yöntemi olan SMACOF yönteminden yararlanılmıştır (Medvedev vd. 2017).

Sosyal medyan madenciliğinin, hastalıkların çıkışı gibi sosyal ve biyolojik araştırmalar için yararlı bir araç olduğu literatürdeki çalışmalar ile gösterilebilmiştir. Monkman ve arkadaşlarının (2018), yaptıkları çalışmada veri ve metin madenciliği yöntemlerini kullanarak vahşi yaşamı yeniden canlandırma etkinliği hakkında bilgi edinme erişimini ortaya koymayı amaçlamışlardır. Çalışmada aktivite ve avlanma dağılımında gezi sayıları ve spatiotemporal eğilimler tahmin edilmiştir. Sonuç olarak Galler bölgesi için kovuşturma yaz aylarında kıştan daha yüksek ve dişli kullanımı ve yolculuk süreleri 2002–13 döneminde tutarlı olduğu tespit edilmiştir. Metin madenciliğinin bir yaban hayatı rekreasyon faaliyetini tanımlamak için kullanılabileceğini, ancak tarafsız nüfus seviyesi tahminlerini elde etmek için yetersiz kaldığı sonucuna varılmıştır (Monkman vd, 2018).

İstatistikte olduğu gibi iki farklı ana kütlenin benzerliğine veri madenciliği ile bakılabilmektedir. Örneğin iki farklı metnin aynı kişiye ait olup olmadığı veya benzer kişilikte insanlar tarafından mı yazıldığı kullandıkları kelimelere bakılarak tespit edilebilmektedir. Singh ve arkadaşlarının (2016), metin benzerliği üzerinden kümeleme analizi konusunda bir çalışma yapmıştır. Çalışmanın analizinde yöntem olarak k-ortalamalı kümeleme ve spektral kümeleme yöntemleri dahil edilmiştir. Söz konusu çalışma Twitter verileri üzerinde benzer metinlerin kümelenmesi üzerinde durulmuştur. Çalışmanın sonucu olarak ilgili iki yöntem benzer sonuçlar verdiği görülmüştür. K-ortalamalı kümeleme daha çok sayısal verilerde iyi sonuç verirken,

spektral kümeleme sosyal medya verilerinde metin benzerliğini bulmak için daha uygun ve hızlı olduğu görülmüştür. Fakat söz konusu yöntemin yüksek maliyete sahip olduğu vurgulanmıştır (Singh vd, 2016).

Dünya üzerinde büyük bir hacme sahip olan sektör de oyun sektörüdür. Çevrimiçi oyunlar aynı zamanda oyuncunun avatar hesabına alacağı eşyalar gibi özellikler de barındırır. Bunlar birçoğu ücretli olmakta ve pazarlanmaktadır. Olivera ve arkadaşları (2014), çevrimiçi oyun platformu göz önüne alarak interneti pazarlama aracı olarak kullanımı incelenmek istenmiştir. GameFoundry üzerinden yapılan bu çalışmanın sonucu olarak internet oyunlarındaki paylaşımlar ve ürünler bir pazarlama aracı olarak kullanıldığında önemli bir kaynak olduğu ortaya konulabilmektedir (Olivera vd., 2014).

2.3.2.Sosyal Medya Analizinde Resim Analizi

Sosyal medya siteleri, başta resimler olmak üzere multimedya içerikli gönderiler, takipçiler tarafından beğenilebilmekte ve takip edilebilmektedir. Eski bir söze göre, bir resim bin kelimeye bedel olabilmektedir. Yapılan bir araştırmaya göre insanların %75 'i kendilerini görsel öğrenenler olarak tanımladıklarını ve anlam oluşturduklarını dile getirmişlerdir. Ayrıca insanlar gördüklerine göre düşüncelerini düzenlediklerini ifade etmişlerdir (Vong, 2012). Resim analizinde temel olarak tek bir öge olarak sınıflandırmak veya resim içerindeki öğelerin sınıflandırılması yatmaktadır. Resim analizinde bu işlemler için genellikle otomatik görüntü algoritmalarından yararlanılmaktadır. Bu amaçla hizmet veren serverlar sunulmakta ve bu serverların yardımıyla analizler yapılabilmektedir. Bu amaçla kurulan Google, Imagga.Net, ImageNet gibi API ’lerden hem ücretsiz hem de ücretli paketler üzerinden yararlanılabilmektedir. Akademik çalışmaların birçoğu da bu API ’lerden yararlanarak çalışmalar üretilebilmektedir (Kanishcheva & Sharonova, 2018; Jia vd, 2019; Kadrev vd, 2016).

Resim madenciliğinin amacı, diğer veri madenciliği tekniklerinde olduğu gibi değerli bilgiler elde edebilmektir. Bu madencilikte ele alınan temel öge görüntülerdir. Denetimli görüntü sınıflandırmasını kullanan algoritmalarda, görselin içeriğinden görüntüye otomatik olarak bir etiket atamak hedeflenemektedir. Tüm süreç, standart veri madenciliği süreciyle aynıdır. Bir dizi sınıflandırılmış görüntüden bir sınıflandırıcı modeli üretilmesi esasına dayanır. Ardından, sınıf üyeliğini tahmin etmek için sınıflandırıcı modeline yeni bir görüntü gönderilerek çıktı alınması sağlanabilir. Böylelikle resim analizi aşamaları uygulanabilir.

Youtube, Instagram gibi sosyal medyalar, insanları ürettikleri içerik çıktılarına göre birleştirir ve aynı zamanda takipçilerine eğlence ve estetik içerik sağlayabilmektedir. Aynı zamanda kullanıcıların kendi özgünlüklerini göstermek için anlamlı bir pazar (çıkış, saha) sağlayabilir. Hem kullanıcı tarafından sağlanan hem de makine tarafından oluşturulan etiketlere bakarak, bir ülkenin sağlık istatistiklerini çıkarmak için kullanılabilecek bilgiler toplanabilmektedir. İnsanlar hayatlarını ve sosyal etkileşimlerini son zamanlarda daha fazla çevrimiçi olarak paylaşıldığından, veri kaynağı olarak sosyal medyayı ele almak, yaşam tarzlarını incelemek için uygun olduğuna dair görüşler yer alabilmektedir. 2015’te yapılan bir rapora göre insanlar sosyal medyada günlük 500 milyon tweet atılırken 1,8 milyardan fazla resim paylaşılıyor (Seltzer vd, 2015). Bazı durumlarda metin yerine resim tercih eden hesaplar vardır. Bunlar metin yerine daha çok görsel öge paylaşmayı tercih edebilirler. Örneğin bir toplantı veya buluşma sırasında veya sonrasında bir tweet paylaşmak yerine ortamın görüntüsünün paylaşılması sıkça rastlanan bir durum olabilmektedir.

Resimlerde açıklama olmasa bile derin öğrenmedeki ilerlemeler ile resimlerdeki objeleri otomatik olarak algılamak ve metinsel açıklama oluşturmak mümkün olmaktadır. Otomatik görüntü araçlarının avantajlarından biri de sundukları dil potansiyelidir. Bir diğer avantajı da kullanıcının atmayacağı etiketlerin ortaya çıkarabilmesidir. Bazı olumsuzluklar etiketlenmediği için metin tabanlı yöntemlerle çıkarmak mümkün değildir. Örneğin, alkol, sigara, tütün gibi durumlar etiketlenmeyip resimde paylaşılması gibi. Bu yönüyle, madde bağımlılığı gibi maddenin kötü kullanımı araştırılması ve izlenmesi için sistemler kurulabilmektedir (Garimela vd, 2016). Halk sağlığı üzerine yapılan çalışmalar, toplum hakkında genel istatistikler elde etmek için sosyal medyanın kullanılmasının önemini göstermişlerdir. Sosyal medya verilerinin büyük ölçekli, gerçek zamanlı, yansız veriler olmasından dolayı tercih edilen toplama yöntemi olarak kabul edilir. Genel toplumsal mutluluğu incelemek ve ölçmek için sosyal medyada yayınlanan görüntülerden gülümseme tanıma özelliğini kullanılan çalışmaların yanı sıra, Instagram 'da depresyonla ilgili görüntüleri incelenmesi ile toplumun depresyon yönleri belirlenebilmektedir (Abdullah vd, 2015; Andalibi vd, 2015). Instagram kullananların %35 'inden fazlası 18-29 yaşları arasındadır. Kullanıcılar tarafından günlük olarak yüklenen fotoğrafların ortalaması 80 milyondan fazladır. Ayrıca kullanıcılar fotoğraf ve videoları hafta sonları ve günün sonunda yayınlama eğiliminde olabilmektedir.

2.3.2.1.Sınıflandırma

Resim analizi özellikle ilk zamanlar resimlerin sınıflandırılması üzerine durulmuştur. Bundan dolayı yapılan çalışmalarda genellikle resimler kategorilere ayrılmaya çalışılmıştır. Pazarlamada müşterilerin cinsiyeti gibi bazı demografik bilgilerin bilinmesi önemli olabilmektedir. Merler ve arkadaşlarının yaptıkları çalışmada resimler yardımıyla özellikle cinsiyet bilgisi gibi kullanıcı bilgisi çıkarmak amaçlamışlardır. Çalışmada sadece resimler kullanılarak %75,6 doğruluk oranı elde edilmiştir. Metin analizi ile desteklendiğinde ise bu doğruluk oranı %88 ‘e çıkmıştır. Sadece metin tabanlı analiz ile cinsiyet tahmini yapmak, kültürel ve dilsel farklılıklardan dolayı tam anlamıyla başarılı olamamaktadır. Bundan dolayı metin ve resim analizlerinin birbirini tamamlayıcı rolleri olduğu aşikardır. Bazı çalışmalarda ise takip ettiği ünlü, aldığı ürün ve sosyal çevresi üzerinden cinsiyet tahmininde bulunmuştur. Ama resim tabanlı çalışmanın başarısı daha yüksek olduğu görülmüştür. Yapılan çalışmanın iddiası yapılan paylaşımların kullanıcıların özellikleri ve ilgileri hakkında bilgi verdiği ve bunlarında cinsiyetle alakalı olduğudur. Bir kullanıcının yüzünün profil resminde gösterilmediği durumlarda bile, bu resim için konu seçiminin kullanıcının cinsiyeti ile ilişkili olduğunu göstermiştir. Çalışmada görsel olarak, profil resimleri, paylaştığı resimler ve profil renk modelleri bağımsız değişkenler olarak kullanılmıştır. Sınıflandırma olarak destek vektör modelleri tercih edilmiştir. Resimlerin otomatik işlenmesinde ImageNet API ‘si kullanılmıştır. Analiz sonucunda erkekler kedi, kadınlar köpeği tercih ettikleri, erkeklerin araba, kadınlar doğa, kent ve arkadaşlarıyla olan resimleri profil resmi olarak kullandıkları belirlenebilmiştir. Ayrıca arka plan rengi analiz edilmiş, erkek ve kadın kullanıcılar tarafından en çok kullanılan yirmi rengin dağılımda, kadınlarda kırmızı, pembe ve kahverengi tonların daha fazla kullanıldığı, erkekler ise mavi, yeşil ve griye yönelik bir paleti tercih ettiği görülmüştür. Erkeklerin paylaşımı, stadyum, bisiklet, spor salonları, hayvanat bahçesi, havalimanı, Amerikan futbolu ile ilgili iken kadınların paylaşımı, Bebek, evlilik, köpek, sandviç, kutlama, kedi, mağaza, yatak odası olmuduğu görülmüştür (Merler vd, 2015).

Instagram, kullanıcıların fotoğraf çekerek ve filtreleri kullanarak değiştirerek güncellemelerini kolayca paylaşabilecekleri nispeten yeni bir iletişim şeklini alabilir. Instagram ‘da fotoğraflar ve videolar çevrimiçi temel sosyal para birimleri haline geldiği rapor edilebilmektedir. Bu fikirle Hu ve arkadaşlarının yaptıkları çalışmada, kümeleme ve bilgisayar görüntü işleme kullanılmıştır. 2014 yılında Hu, Manikonda ve Kambhampati tarafından yapılan bu çalışma Instagram üzerinde yapılan ilk çalışma olarak bilinmektedir. Instagram 'da fotoğraf içeriği ve kullanıcı etkinlikleri ve türlerinin derinlemesine analizi yapılmıştır. Çalışmada kümeleme yöntemi ile 5 farklı kullanıcı tipi 8 farklı resim kategorisi tanımlanmıştır. Başka bir ifade ile Instagram ‘da paylaşılan resimler 8 resim kategorisi altında toplanabilmektedir. Bunlar arkadaşlar, yemek, araç, yazılı resim, evcil hayvan, aktivite, öz çekim ve moda şeklindedir. Buna ek olarak, Instagram hesapları da 5 farklı kullanıcı profili altında toplanabileceği tespit edilmiştir. Ayrıca, bir kullanıcının kitlesi yani takipçi sayısı Instagram 'daki paylaşılan fotoğraflarından bağımsız olduğu görülmüştür. Araştırmanın soruları ise kullanıcılar ne tür resim paylaşırlar, kullanıcılar arasındaki farklılıklar nelerdir, kullanıcının fotoğraflar ile diğer kullanıcıların özellikleri arasında farklılık var mıdır şeklinde olup bu sorulara cevap aranmıştır. Oluşturulan 5 kullanıcı grubunun takipçi farklarına t testi ile bakılmış, buradan yola çıkarak takipçi sayısının bağımsız olduğu yorumu yapılabilmiştir (Hu vd, 2014).

Sınıflandırma algoritmaları yapay sinir ağlarının gelişmesi ile bu yöntemden yararlanılan çalışmalar son günlerde artmakta ve güvenirliliği yükseltmektedir. Son çalışmalarda CNN (Evrişimli Sinir Ağı) sınıflandırıcısının kapsamını tamamen yeniden eğitmeye gerek kalmadan genişletmek için gereken zamanın olası en aza indirilmesi sağlanmaktadır. Bu amaçla k-ortalamalı kümeleme analizi ve transfer öğrenmesi ile yeni bir resim sınıflandırılması geliştirilmiştir. İstenen başarı tam olarak sağlanamasa da çalışma ile kısmi öğretme konusunda stratejiler geliştirilebilmektedir (Kandev vd, 2016).

Resim analizi ayrıca sağlık, sosyal bilimleri gibi çok geniş bir yelpazede kullanılabilmektedir. Örneğin, sağlık alanında kan hücrelerinin incelenerek, sorunların tespitinde de kullanılmaktadır. KNIME üzerinde yapılan bir sınıflandırma ile kan hücreleri incelenmiştir. Kan hücrelerinin mikroskop altındaki görüntüleri resim madenciliği ile analiz edilerek sınıflandırılmasında yüksek başarı oranı elde edilmiştir. Hücreler, fenotiplerine göre pozitif ve negatif olarak sınıflandırmak için hem çekirdeklerin hem de sitoplazmalarının bölümlere ayrılması resim analizi ile başarılı olarak gerçekleştirilmiştir. Ayrılmanın geçerliliği için t-testi ve ANOVA ’dan yararlanılmıştır. Sınıflandırma yaparken resimlere ait temel istatistikler kullanılmıştır. Resme ait özelliklerin tespitin de KNIME ‘da yer alan Image Features nodülünden yararlanılmıştır (Dietz & Berthold, 2016).

Metin madenciliğinde olduğu gibi burada da veri madenciliğinin aynı sınıflandırma algoritmaları kullanılabilir. Metin madenciliğinde kıyaslamalar n-gram ve kelime çantası (bag of words) modelleri üzerinde durulduğu önceki bölümlerdeki çalışmalarda gösterilmiştir. Bunun yanı sıra metin madenciliğindeki sınıflandırmada, Naive Bayes, çok terimli Naive Bayes, Desktek Vektör Makinası gibi algoritmalarında kıyaslanması literatürde çokça ele alınmıştır. Benzer kıyaslama durumu resim analizinde de yapılabilmektedir. Meng ve arkadaşlarının (2010) yaptıkları çalışmada resim madenciliği için kullanılan makine öğrenmesi yöntemlerinin kıyaslanmasına odaklanmışlardır. Söz konusu çalışmada histoloji görüntü sınıflandırması üzerinde durulmuştur. Bu görüntüler kanser teşhisi gibi patolojik tanılarda sıklıkla kullanılmaktadır. Geliştirdikleri Temsili Alt Uzay Projeksiyon Modellemesi (CRSPM) denetimli sınıflandırma modeli olup, literatürde sıklıkla kullanılan sınıflandırıcılar ile kıyaslanmıştır. Geliştirilen bu

model, karşılaştırılan birçok sınıflandırıcıdan daha iyi performans göstermiştir. Model, %90 civarında yüksek doğruluk oranına sahip olduğu rapor edilmiştir (Meng vd, 2010).

2.3.2.2.Nesne Tespiti

Sınıflandırma algoritmaları resim madenciliğinde, duygu analizindeki gibi önceden belirlenen kategorilere göre ataması hedeflenebilir. Fakat bazı durumda resim analizinde kullanılan otomatik görüntü işleme algoritmaları, resimlerdeki nesnelerin varlığını bir güven ölçüsü ile verebilmektedir. Bu değer, ilgili nesnenin o resimde olabilirliğini göstermektedir. Otomatik görüntü işleme algoritmalarından elde edilen nesnelerin sayısı çok olduğu durumlarda, anlaşılabilir olması ve analizlerin daha işlenebilir olması için eşik değeri belirlenebilmektedir. Ele alınan eşik değerin üzerinde güvenirlilik veren nesneler dikkate alınarak analiz edilebilmektedir. Bunun için gerekli olan uygun eşik değerinin belirlenmesi için literatürde birçok çalışma yapılmıştır. Buradan elde edilen nesnelerin etiketlenmeleri üzerinden sınıflandırma imkânı sağlamaktadır. Garimella ve arkadaşlarının 2016 yılında halk sağlığı üzerine yaptıkları sosyal medya resim analizi çalışmasında, en yüksek korelasyonu veren aynı zamanda aşırı uyum sorunu çıkarmayan eşik değeri olarak %20 olarak tespit etmişlerdir. Söz konusu çalışmada,%20 ve üzeri güvenilirlik veren 10 etiket dikkate alınmıştır. Bunlar, `` yemek '', `` lezzetli '', `` kokteyl '', `` insanlar '', `` altın '', `` sağlıklı '', `` yetişkin '', `` beyaz '', `` kişi '', `` mutfak ''(`food', `delicious',`cocktail',`people',`gold', `healthy', `adult', `caucasian', `person', `kitchen') etiketleridir. Yöntem olarak dayanıklı (roboust) regresyon tercih edilmiştir. Resimlere ait 9 temel özellik bağımlı değişken olarak alınmıştır. Çalışmanın sonucunda, makine tarafından oluşturulan etiketlerin diğer kullanıcı etiketlerinden daha iyi öngörücüler olduğu ve bu etiketlerin insan ek açıklamalarının bir parçası olabileceği sonucuna varılabilir (Garimella vd, 2016).

Nesne tespiti ayrıca yazılı metinlerin resim ile algılanması üzerine de kullanılabilmektedir. Yazılı bir metne ait resim, algoritmalar yardımıyla metne çevrilmesi sağlanabilmektedir. Günümüz teknolojisi ile görüntü tabanlı olarak sorulara aynı anda cevaplamayı sağlayan sistemler geliştirilmiş ve geliştirilmeye devam etmektedir. UbiAsk uygulama tasarımı buna bir örnektir. Söz konusu uygulama başta Japonya'da olmak üzere 55 katılımcı ile 6 hafta boyunca denenmiş ve kullanıcılara büyük kolaylıklar sağlamıştır. Uygulamada soruların yarısı 30 dakikadan daha az sürede yanıtlanabilmiştir. Akşamları ve geceleri sistemin daha hızlı yanıt verdiği görülmüştür. Veri madenciliği üzerine kurulan uygulamanın kullanımı çok basit ve kullanıcı dostudur. Önce sıradan bir cep telefonu kamerası ile metnin resmi çekilir. Daha sonra resminden yazılan ifade tercüme edilir. Bu uygulama başta yabancı ülkelere giden turistler için yararlı olacağı düşünülmektedir. Bu amaçla geliştirilen UbiAsk, makine algoritmaları uygulamak yerine, görüntü tanıma ve metin çevirisi gibi zor hesaplama problemlerini çözmek için sosyal medyayı kullanır. Bulutta yer alan sıradan insanların sosyal ağlar aracılığıyla yaptıkları paylaşımların gücünü kullanır. Uygulamanın performans göstergesi olarak yanıt hızı ve miktarı dikkate alınabilir (Liu vd, 2012).

Literatürdeki bazı çalışmalar, resimlerin altındaki etiketleri kullanırken bazı çalışmalar makine öğrenmesinin ürettiği etiketleri kullanmaktadır. Her ne kadar resimlerin altındaki metin etiketleri gürültülü olsa da büyük bir heterojen kullanıcı grubu tarafından açıklandığı için, görüntü tanıma için hala yararlı bilgiler sağlayabilecekleri kabul edilmektedir. Örneğin, bir resimde güneş ve gökyüzü, ikinci resimde güneş ve hayvanlar ve üçüncüsünde hayvanlar ve hayvanat bahçesi olsun. Bu etiketler yardımıyla birinci resim ikinci

resme güneş ile bağlanırken, ikinci resim üçüncü resimdeki hayvanlar etiketiyle ilişkilendirilerek bağlanır. Fakat, birinci resim üçüncü resim bağlantılı değildir. Resim ve etiketleri toplandıktan sonra görsel belge ağ ile modellenip ilişkisel konu (topic) modeli inşa edilmesi mümkündür (Meng vd., 2010). 2014 yılında yapılan bir çalışmada, Flickr sitesindeki resimlerden yararlanılmıştır. Etiketler yardımıyla ilişkilendirme için, 1 ve -1 (bağlantılı - bağlantısız) etiketlemesi yapılmıştır. Çalışma, metin ve görsel analizi bir araya kullanılmıştır. Metin madenciliği başlığında değinilen konu modeli bu çalışmada hem metin hem de resim öğelerinden oluşturulması sağlanmıştır. Bu bağlamda kurulan konu modellemesinde 81 konsept elde edilirken 23 potansiyel etiket kullanılmıştır. Denenen model üzerinde en yüksek güvenirlilik %84,1 olarak elde edilmiştir (Niu vd, 2014).

2.3.2.3.Diğer Kullanım Alanları

Resim analizi önceki bölümlerde bahsedildiği gibi genel olarak sınıflandırma ve görsellerdeki nesnelerin tespiti amacıyla kullanılabilmiştir. Fakat hem akademik çalışmalarda hem de piyasadaki uygulamalarda bu iki amaç dışında da kullanıldığı görülebilmektedir. Bu bölümde bu çalışmalar üzerinde durulacaktır.

Silva ve arkadaşları (2013) dünyanın farklı şehirlerinden Instagram fotoğraflarına sosyal ve kültürel farklılıklarını incelemişlerdir. Bu amaçla dünyanın farklı ülkelerinde paylaşılan resimler analiz edilmiştir. Analiz için görselleştirme ve kültürel analitik yapılan dikkate alınarak resim madenciliği uygulamışlardır.

Kullanıcılar günlük aktivitelerinden biri olan yemek alışkanlıklarını da sosyal medyada paylaşabilmektedirler. Bundan yola çıkarak toplumların yemek alışkanlıklarını tespit etmek mümkün olabilmektedir. Yemek resimleri paylaşımları yardımıyla, insanları yiyeceklerine göre sınıflandırabilmektedir. Amato ve arkadaşlarının 2017'de yaptıkları çalışmada WorldFoodMap adı altında bir sistem geliştirmişlerdir. Bu sistem adı altında sosyal medyadaki resimleri analiz ederek insanların yiyecek kategorilerini sınıflandırabilmektedir. Twitter üzerinden toplanan resimler üzerinden, dünyada paylaşılan yiyeceklerin popülaritesi ve trendi analiz edilebilmektedir. Bunun için, GoogLeNet algoritması ile CNNs yapay sinir ağları yöntemlerini kullanarak derin öğrenme ile sistem yemek kategorileri öğretilmiştir. Trend için basit doğrusal regresyon yardımıyla ürünün sıklığı üzerinden yapılarak hem dünya geneli hem de ülke bazlı belirlenmesine olanak sağlamıştır. Kısa vadede mutfak alışkanlığının değişimi için popülarite analizi yapılmıştır. Bunun içinde, standart değerler (z-skoru)'ndan yararlanılmıştır. Yapılan bu sistem sayesinde hem bölgesel hem ülke bazında, yiyeceklerin trendi ve popülaritesi incelenebilmektedir. Ayrıca, yiyecek bazlı olarak hangi ülkelerde trend ve popülaritesi var analiz edilebilmektedir (Amato vd, 2017).

Toplumları ölçmenin yanı sıra doğa olaylarının ve etkilerinin tespitinde de resim analizinden yararlanmak mümkün olabilmektedir. Bir bölgede yaşanan doğal afetin etkilerini, o bölgede yaşayanların yaptıkları paylaşımlardan görmekte mümkündür. Örneğin, literatürde Almanya 'da olan sel felaketi üzerine yapılan görsel içerikli paylaşımlara dair resimlerin analizi üzerine bir çalışma mevcuttur. Hem metin madenciliği hem resim analizi ile mağdurlar ve afet yöneticileri arasında bilgi kirliliğini aza indirgeyerek sağlıklı ve etkili iletişim sağlanması planlanmıştır. Çalışmanın uygulaması için gerekli veriler ajans kütüphanesinden ve Alman Facebook sitelerinden toplanmıştır. Yapılan çalışma ile geliştirilen yeni ve etkili bir acil durum olayı tanıma sistemi haber akışlarından ve popüler sosyal ağ web sitelerinden gelen sel olayı

görüntülerini tanımlamak için metin ve görüntü analizinden yararlanmaktadır. Çalışmanın etkinliğinin gösterilmesinde beş bin anonim Facebook resmi, altı bin adette FEMA resmi kullanılmıştır. Görseller sel taşkını, insan ve arka plan resimlerinden oluşmaktadır. Resimlerdeki arka plan sel ve insan ile bağlantılı olmadığı görülmüştür. 2013 yılında Almanya'daki sel felaketinde sosyal medyada grup ve sayfalar oluşturuldu. Buralarda paylaşılan görüntüler sensor olarak dikkate alınmıştır. Böylelikle bilgi alışverişi ve gönüllülerin yardımı koordine edilebilme imkânı sağlanmıştır. Genel olarak, bir ontoloji, kavramların bir kelime dağarcığının ve aralarındaki ilişkilerin biçimsel özellikleri olarak tanımlanabilir. Metin madenciliği ve resim analizi arasında bağ ontoloji üzerinden kurgulanmıştır. Çalışmanın sonucunda, sel tanıma için bir entegresyon geliştirilmiştir (Jing vd, 2016).

Sinema alanında afişlerin varlığı ile resim analizi çalışmalarını görmek mümkün olabilmektedir. Bir çalışmada, beş filme ait parça üzerinden etiketleme yapılmıştır. Batman, Barselona Spor kulübü, Meghan Trainor, Açık oyunları, Remi Gaillard. Batmobile için %20 üzerinde güvenirlilik veren kelimeler araba, adam, araç gibi kelimeler bulunurken diğer ögeler içinde bu güvenirlik üzerinden etiketler elde edilmiştir (Kanishcheva & Sharonova, 2018). Bir çalışmada doğrusal olmayan korelasyon yöntemi sayesinde, resimlerdeki aynı manalı fazla etiketlemeleri tespit ederek, çekirdek etiketlenmenin elde edilmesi için bir yöntem önerisinde bulunulmaktadır. Bu çalışmada da kanonik korelasyon katsayısından yararlanarak, etiket kümelerinden çekirdek kümeler elde edilmesi amaçlanmıştır. Önerilen model 0,5091 oranında başarı gösterirken önceki modellere göre kıyaslandığında yüksek başarı ortaya koydupu gösterilmiştir (Jia vd, 2019).

Kuncoro ve Iswanto 2015 yılında yaptıkları çalışmanın amacı ise, en çok takip edilen en iyi yirmi Instagram kullanıcısının Instagram 'larındaki resim altyazılarına göre anahtar kelimelerini tespit etmektir. Kelimelerin sıralanması için Terim Sıklığı ve Ters Belge Sıklığı (TF-IDF) yöntemleri ile incelenmiştir. Bu amaçla kullanıcıya ait son 50 resim dikkate alınmıştır. Bu çalışmada TF-IDF ile yapılan ranklama sonucunda, sıralama ne kadar yüksek olursa, anahtar kelimeler kullanıcıların yayınladığı altyazılarla o kadar alakalı olduğu belirtilmiştir. TF-IDF, bir belgedeki kelimelerin (veya "terimlerin") önemini birden çok belgede ne sıklıkta göründüklerine göre puanlamanın bir yoludur. TF-IDF, 1988 yılında Salton ve Buckley tarafından önerilen nispeten eski bir yöntemdir (Kuncoro ve Iswanto, 2015). Sosyal medya resimleri ile kültürel bir bağ üzerine gerçekleştirilen çalışmalarda mevcuttur (Hochman, 2104).

2.3.3.Sosyal Medya Analizinde Sayısal Ölçümler

Sosyal medya analizinde genellikle metin veya resim bazlı olarak paylaşımlar üzerinden çalışmalar yapılmaktadır. Literatürde bu iki analizin dışında ayrıca sosyal medyadan elde edilen sayısal ve sayısal olmayan veriler üzerinde de analiz yapılmaktadır. Bu analizlerin başında da her işte olduğu gibi performans ölçümü yer alabilmektedir. Bireysel veya işletmeler bazında yapılan işlerin değerlendirilmesi ve başarı kriterleri günlük hayatta vazgeçilmez bir konusu olabilir. İşletmeler başta mali göstergeler olmak üzere faaliyetlerinin bir göstergeye dayanarak yatırımlar ve kararlar alabilmektedirler. Pazarlama ve reklamlar veren işletmeler de söz konusu departmanları ve faaliyetlerini değerlendirebilmektedirler. Bunların bir ürünü olan dijital pazarlamanın da bir performansının ölçülmesi ve değerlendirilme gereksinimi olmazsa olmaz bir unsur haline gelmektedir. Akademik çalışmalar incelendiğinde, sosyal medya profillerinin de performanslarının

ölçülmesi ve değerlendirilmesi üzerine yapılan çalışmalar görmek mümkündür. Bu çalışmalar genellikle profilin aktifliği temel alan bir puanlama sistemi geliştirilmesi esasına dayanmaktadır.

Sosyal medya birçok işletme tarafından artık günümüzde benimsenmiştir. Giderek daha fazla şirket, çeşitli hizmetler sağlamak ve müşterilerle etkileşim kurmak için Facebook ve Twitter gibi sosyal medya araçlarını kullanabilmektedir. Sonuç olarak, kullanıcı tarafından oluşturulan büyük miktarda içerik, sosyal medya sitelerinde ücretsiz olarak temin edilerek kullanılabilmektedir. Rekabet avantajını artırmak ve işletmelerin rekabet ortamını etkili bir şekilde değerlendirmek için, şirketlerin yalnızca kendi sosyal medya sitelerinde müşteri tarafından oluşturulan içeriği değil, aynı zamanda rakiplerinin sosyal medya sitelerindeki metinsel bilgileri de izlemesi ve analiz etmesi gerekebilir. Üç büyük pizza şirketi olan Pizza Hut, Domino's Pizza ve Papa John's Pizza markalarına ait Facebook ve Twitter paylaşımları incelendiğinde, sosyal medya rekabet analizinin değerini ve mevcut sosyal medya verilerinin büyük miktarından iş değeri elde etmenin ne derece etkili olduğu ortaya çıkmaktadır. Domino’s Pizza, sosyal medyadaki gönderi ve kullanıcı yorumlarının sayısı aracılığıyla diğer iki pizza zincirinden daha yüksek düzeyde bir bağlılık ve tüketici katılımı görülmüş, pazar paylarının (%7,60) Pizza Hut 'ın (%11,65) pazar payından daha küçük olduğu düşünüldüğünde, sosyal medya çabaları daha bir anlam kazanmıştır. Özellikle, Domino’s Pizza 'nın inceleme dönem boyunca kullanıcı yorumlarına daha hızlı yanıt verdiğini fark edilmiş, bu da onların sosyal medya etkinliklerini izleme ve işleme konusundaki güçlü yönlerini göstermektedir. Ayrıca, ilginç bir sonuç olarak Facebook'taki kullanıcı katılım düzeyinin Twitter 'daki etkileşim düzeyinden çok daha yüksek olduğu çalışmada ortaya çıkmıştır. Sosyal medyanın müşteri hizmetleri üzerindeki etkisini görmekte mümkündür. Bir dereceye kadar, Facebook ve Twitter gibi sosyal medya uygulamaları, "bilgi dağıtımını hızlandıran dev bir ağızdan ağıza pazarlama" gibi çalışır. Bu nedenle işletmelerin, müşteri şikayetlerini ve endişelerini zamanında ele almak ve böylelikle potansiyel halkla ilişkiler veya marka krizlerini proaktif olarak önlemek ve çözmek için, kendilerini içeren müşteri görüşmelerini takip etmek için sosyal medyayı aktif bir şekilde takip etmeleri günümüzde daha gerekli hale gelmektedir (He vd, 2013).

Twitter'da kazanılan takipçi veya bahsedenlerin miktarı gibi sayılar sosyal ağın performansının ölçümünde sıklıkla başvurulan göstergeler olabilmektedir. Bunların yanı sıra belirli algoritmalar kullanarak yorumlar dikkate alınarak Twitter kullanımının başarısını ölçmek hedeflenebilmektedir. Anger ve Kittl (2011) tarafından bir kullanıcının Twitter başarının ölçümü üzerine bir model önerilmektedir. Bu çalışmada takipçi / takip edilen oranı bir başarı göstergesi olarak alınmaktadır. Başka bir performans göstergesi olarak da paylaşım sayısı alınmıştır. Diğer bir göstergesi de etkileşim oranıdır. Bu oran, içeriği yeniden tweetleyen veya A kullanıcısından bahseden bireysel kullanıcıların sayısının, A kullanıcısının toplam takipçi sayısına bölünmesiyle elde edilmektedir. Böylelikle takipçi sayısını, bireysel etkileşimleri, retweetleri, bahsedenleri ve toplam tweet miktarını hesaba katarak bir profilin başarısının değerlendirebileceği bir model geliştirilmişlerdir.

Anger ve Kittl’ in çalışması sadece Twitter ile sınırlıdır. Genel olarak birden fazla sosyal ağın değerlendirilebilmeksi mümkün olabilmektedir. Twitter dışındaki sosyal medya kanalları olan Facebook, Instagram, Google+ gibi kanalların hem kanal bazında hem de bir bütüncül yaklaşımla değerlendirmesine ihtiyaç halini alabilmektedir. Rao ve arkadaşları (2015) dokuz farklı kanal üzerinden bütüncül bir puanlama modeli geliştirmişlerdir. Ele alınan farklı kanallar üzerinden Klout Puanlama (Klout Score) sistemi inşa etmişlerdir. Geliştirdikleri model Klout.com üzerinden hizmet verirken 2018 yılında faaliyetine son vermiştir.

Bu puanlama sisteminde beğeniler, yorumlar, etiketlemeler, arkadaş sayıları gibi sosyal medyadan elde edilen değişkenler dikkate alınmıştır. Her kanalda elde edilen değişkenler hiyerarşik olarak hesaplanarak en son Klout puanını oluşturmaktadır. Bu sunulan Klout Puanı, elbette, bir kullanıcının etkisinin yalnızca kısmi bir temsili olarak değerlendirilebilmektedir.

Dijital pazarlama kanalları üzerinde literatürün haricinde sektörden de çalışmalar mevcuttur. Bu kanallar hakkında rapor sunmayı amaçlayan pazarlama şirketleri ve danışmanlık merkezleri hem ülkemiz de hem dünya da kurulmuştur. Söz konusu firmalar daha çok sosyal ağlar üzerine odaklanmıştır. Danışmanlık şirketleri sosyal ağlardaki profillerinizi yönetmek, markanızın bilinirliliğini artırmak için stratejiler üretmek üzerine kurulmuştur. Bunun dışında rakip analizlerinin ve sosyal ağlardan verilerin çekilmesine odaklanan şirketler de mevcuttur. Boomsocial gibi siteler sektör bazında takipçiler gibi istatistikler üzerinden rapor vermektedir. Üniversiteler arasında Türkiye' de İnstagram 'da takipçi sayısı sıralamasında Anadolu üniversitesinin birinci sırada yer alması ve Boğaziçi ve İstanbul Teknik Üniversitelerinin bunu takip ediyor olması gibi istatistikleri sunabilmektedir. Sosyal ağlar üzerinden temel istatistiklere ulaşma imkânı sunmaktadır (Sezgin & Altay, 2021; Vural vd., 2021). Bu amaçla hizmet veren bir üründe Google şirketine ait Google Analytics'tir. Söz konusu bu uygulama sayesinde web sitelerine ait trafik bilgileri elde edilebilmektedir. Bu uygulamadan yararlanan şirketler, web sitelerine gelen ziyaretçilerin en çok hangi sosyal medya sitesinden yönlendirildiğini tespit edebilmektedir. Bunun sonucu olarak, müşterilerinin hangi kanala ağırlıkla kullandıkları bilgisi elde edilmektedir (Barutçu & Tomaş, 2013). Bu iki uygulama dışında, sendpulse.com, brand24.com, boomsonar.com ve jetyorum.com gibi sitelerde mevcuttur. Twitter başta olmak üzere genellikle sosyal medya kanallarına ait temel istatistikler ve paylaşımların üzerinden değerlendirmelerin mevcut olduğu bu uygulamalar aynı zamanda akademide de kullanılmaktadır (Devrani & Kesici, 2020; Bachmann, 2020; Gretzel, 2019; Tugrul & Gocer, 2017). Hem işletmelerin yöneticileri hem de akademisyenler bu siteler yardımıyla sosyal medya istatistiklerini ve verilerini elde edebilmektedir. Bunların yanı sıra aynı zamanda ülkeler ve firmalara ait sosyal ağların kullanımına ait temel istatistiklerin raporlarına ulaşılabilmektedir (Küçükali & Serçemeli, 2019).

Gerek Klout Puanlama olsun gerek Twitter üzerinden yapılan puanlama modeli olsun literatürde ve uygulama yapılan sistemlerde genellikle sayısal verilerden elde edilen değişkenleri dikkate almaktadır. Metin ve resim gibi yapısal olmayan değişkenler dikkate alınmamıştır. Literatür incelendiğinde resim analizi ve metin analizlerinin sosyal medya için ne kadar vazgeçilmez argümanlar olduğu aşikardır. Bundan dolayı bir profilin değerlendirilmesinde bu iki yöntemin dikkate alınmaması büyük bir eksiklik oluşturmaktadır. Bu bağlamda çalışma modelinin ilk bölümünde bu iki değişkende dikkate alınarak Klout Puanlama 'da olduğu gibi hiyerarşik bir modelin inşa edilmesi üzerine durulmuştur. Makine öğrenmesi algoritmaları ile işletmelerin hem rakiplerine göre dijital kanalarının hem kanal bazında hem de bütüncül olarak konumlarını görebilmesi hedeflenmiştir. Ayrıca metin ve resim analizin sonucunda elde edilebilen etiketlemeler puanlama dışında da kullanılabildiği literatürde görülmüştür. İşletmeler ve gerçek kişiler herhangi bir konuda elde edilen gösterge puanın artırılması için gerekli stratejilerin gereksinim duyarlar. Başarılarının devamlılığının sağlanması ve artırılması için araştırma yaparlar. Bu düşünceden yola çıkarak, çalışmanın ikinci ayağı olarak metin ve resim analizi tabanlı olarak stratejiler üretilmesi amaçlanmıştır. Bunun için de puanlamanın elde edilmesinde olduğu gibi veri madenciliği tekniklerinde yararlanılmıştır. Makine öğrenmesi ile paylaşımlarda yer alan metin ve

resimlerin tercihlerinin başarı göstergelerine olan etkisine bakılması hedeflenmiştir. Bu analizin sonucunda elde edilen bulgular ile markalar için stratejiler üretilebilmektedir.

3.UYGULAMA

Tezin bu bölümünde, öncelikle uygulamanın konusu, amacı ve öneminden bahsedilecektir. Daha sonra dijital pazarlama skorlarının belirlenmesinde kullanılacak olan kanal bazında değişkenlerin tanımlanması ve elde edilmesi üzerine durulacaktır. Değişkenlerin tanımı verildikten sonra ise ilk olarak modelin modellenmesi ele alınacaktır. Tanımlanan model üzerinden sağlık kuruluşları üzerine bir uygulaması ve sonuçları ele alınacaktır. Elde edilen skorlar üzerinden tartışılacak ve daha sonrasında da söz konusu kanalların performanslarının geliştirilmesi üzerine stratejilerin oluşturulması sağlanacaktır. Metin ve resim analizleri ile markaların dijital pazarlama kanallarının performanslarının arttırılması için gerekli olan argümanlar elde edilmeye çalışılacaktır.

3.1.Uygulamanın Konusu, Amacı ve Önemi

Önceki başlık çerçevesinde bu başlık altında, tezin uygulamasının konusu, amacı ve önemi üzerinde durulacaktır.

3.1.1.Uygulamanın Konusu

Uygulamanın konusu, yapısal ve yapısal olmayan verilerin analizinde kullanılan veri madenciliği tekniklerini dijital pazarlama kanalları üzerinde uygulamaktır. Dijital pazarlama kanallarından elde edilen verilerin çeşitliliği, değişkenliği ve büyüklüğü göz önüne alınarak, dijital pazarlama kanalalrının performansları veri madenciliği tekniği ile değerlendirilebilmektedir.

3.1.2.Uygulamanın Amacı

Uygulamanın amacı, markaların dijital pazarlama kanallarının performansları ve etkinlikleri veri madenciliği teknikleri yardımıyla değerlendirmektir. Böylelikle ele alınan markaların, dijital kanallardaki etkinliğini ve performansını ölçebilmektir. Ayrıca, rakiplerine göre durumlarının belirlenmesi ve performanslarının iyileştirilmesi için stratejilerinin üretilmesi amaçlanmaktadır. Oluşturulacak olan sistemsel uygulama yardımıyla belirli periyodlarda sektör dinamiklerindeki değişimleri kanal bazında ve anlık olarak analitik olarak takip edebileceklerdir. Bunun sonucunda da markalar pazarlama stratejilerini ve odaklanma noktalarını hızlı bir şekilde güncelleyebileceklerdir. Dinamik olarak sektörün aktiflerinin arasında yer alma imkânı sağlanacaktır. Çalışmanın temek iki amacı yer almaktadır. İlk amacı, markalara ait dijital pazarlama kanallarını bütüncül olarak ele alarak değerlendirmektedir. Başka bir ifade ile, ele alınacak dijital kanalların hepsi birlikte değerlendirerek markaların değerlendirilmesi, puanlanması ve sıralanması amaçlanmıştır. Çalışmanın ikinci amacı ise, markaların faaliyet gösterdiği sektör bazında performans ve etkinliklerini artıracak stratrejileri belirlemektir. Bir diğer ifade ile, potansiyel müşterilerinin metin ve resim bazında neleri beklediklerini veya takip ettiklerini belirlemek ve bunun üzerinden yeni paylaşımlara yön verecek önerilerin sunulmasnı sağlamaktır.

3.1.3.Uygulamanın Önemi

Uygulamanın önemi, markaların dijital pazarlama kanallarının değerlendirilmesinde yöneticilerin karar vermelerinde yardımcı olmaktır. Hem metin tabanlı hem resim tabanlı hem de sayısal verileri dikkate alıyor olmasından dolayı her bir dijital pazarlama kanalını geniş bir konsepte değerlendirmek mümkün olmaktadır. Dijital pazarlama kanalları bazında farklı veri türlerini bir potada değerlendiriyor olacak olması uygulamanın başlıca bir önemidir. Bunun yanı sıra, çeşitli verileri içeren potanın birden fazla dijital pazarlama kanalında uygulayarak analitik olarak biraraya getirip hem kanal bazlı hem de bütüncül bir yaklaşım sunması da karar vericilerin pazarlama kanallarını geniş perspektifte bakmasını sağlayacaktır. Böylelikle, markaların dijital pazarlama kanallarını her yönden en etkin bir şekilde kullanılması sağlanacaktır. Bu sayede, işletmelerin hem imajlarını hem de ürün ve hizmetlerini en doğru biçimde müşterilerine sunma imkânı elde edeceklerdir.

Uygulamanın bir diğer önemi ise, günümüzde sayısı artan verileri değerlendiriyor olmasıdır. Dijital kanallar başta olmak üzere, günlük olarak hızla ve çok sayıda değişken barındıran bu verilerin oluşturduğu veri tabanlarının analiz edilmesinde geleneksel istatistik yöntemleri yetersiz kalmaktadır. Bundan dolayı düzenli ve düzensiz bu verilerin analizinde son zamanlarda rağbet gören veri madenciliği teknikleri kullanılması çalışmanın diğer bir önemini oluşturmaktadır.

Literatür incelendiğinde, genellikle metin madenciliği yardımıyla ayrı ayrı kanalların incelendiği çalışmalar ön plana çıkmaktadır. Bu tür çalışmalarda, metin madenciliği yardımıyla, paylaşımların duygu analizinin yapılması dikkat çekmektedir. Bu şekilde yapılan çalışmalarda, tek bir sosyal medya kanalındaki paylaşımlarda kullanılan sözcük ve sözcük gruplarının temelde olumlu veya olumsuz anlam içermesine göre cümlenin içerdiği duyguyu anlamlandırmak hedeflenmektedir. Bu çalışmada, beş farklı dijital pazarlama kanalı birlikte alınmıştır. Bunlar, markalara ait Facebook, Twitter, Instagram, Youtube ve Google Haberler ‘dir. Ayrıca, bu kanallardan elde edilen metinlerin analizi yapılmasının yanı sıra, paylaşımlarda yer alan resimlerde değerlendirmeye alınmıştır. Bununla birlikte, bu kanallarda yer alan diğer istatistiksel verilerde, markaların dijital pazarlama kanallarının performans ölçümünde dikkate alınmıştır.

Uygulamanın önemi, amacı ve konusu çerçevesinde, İstanbul’da hizmet veren ve sağlık bakanlığına bağlı olan hastanelerden çalışmada kullanılacak dijital pazarlama kanallarında faaliyet gösteren sağlık kuruluşları ele alınmıştır. Sağlık bakanlığının resmî sitesinde[1] yer alan hastanelerden tesadüfi olarak seçilen on hastane üzerinden uygulama yapılmıştır. Haziran 2019-Aralık 2019, Ocak 2020-Haziran 2020 ve Ocak 2020-Aralık 2020 olmak üzere ele alınan on hastanesinin üç farklı dönemde performansları değerlendirilmiştir.

3.1.4.Uygulamada Kullanılan Değişkenlerin Tanımlanması

Uygulamanın bu başlığında, veri madenciliği tekniklerinin uygulandığı markalara ait dijital pazarlama kanallarından elde edilen değişkenlerin tanımları, nasıl elde edildikleri ve hangi şekilde

[1] https://ozelruhsatlandirma.saglik.gov.tr/TR,53567/ozel-hastane-listesi-faal.html

kullanıldıkları üzerinde durulacaktır. Söz konusu değişkenlerin, kanallara göre farklılık göstermesinden dolayı, bölümler kanal bazında verilecektir.

Uygulamada kullanılacak değişkenlerin elde edilmesi ve analizleri için Konstanz Information Miner (KNIME) programından yararlanılmıştır. Söz konusu program, akış diyagramı sistemiyle çalışan açık kaynak kodlu veri analizi, raporlama ve entegrasyon programıdır. İçerisindeki modüler yardımıyla, R, Python, Matlab, Java gibi yazılım dillerini çalıştırma imkânı sağlayabilmektedir. Veri analizi ve raporlamayı bir arada yapabilme imkânı sağlamasının yanı sıra, diğer kodlama dillerini de destekliyor olması programın kullanışlılığını artırmaktadır. Bundan dolayı, uygulama için KNIME programı tercih edilmiştir.

3.1.5.Facebook Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler

Markaların Facebook kanalındaki verilerin elde edilmesinde Python ve KNIME ‘ın kendi içerisindeki HTMLparser ve xpath nodülleri kullanılmıştır. Markaların facebook platformu üzerinde paylaştıkları gönderilerin çekilmesi için KNIME’daki akış diyagramına entegre edilen Python nodülünden yararlanılmıştır. Bu nodülden verilerin çekilmesi için, Python kütüphanelerinden facebook_scraper kütüphanesinden yararlanılmıştır. Söz konusu kütüphane öncelikle Python Package Index (pip) ile kurulmuştur.

KNIME üzerinde açılan Python Source nodülüne Ek1’de yer alan python kodlaması girilerek verilerin çekilmesi sağlanabilmektedir. Get_posts fonksiyonuna hastanenin facebook.com/ adresinin sonundaki profil ismi ile kaç sayfalık gönderinin çekileceği bilgisi girilmelidir. Bu iki girdi ile facebook üzerindeki anonim bilgiler çekilebilmektedir.

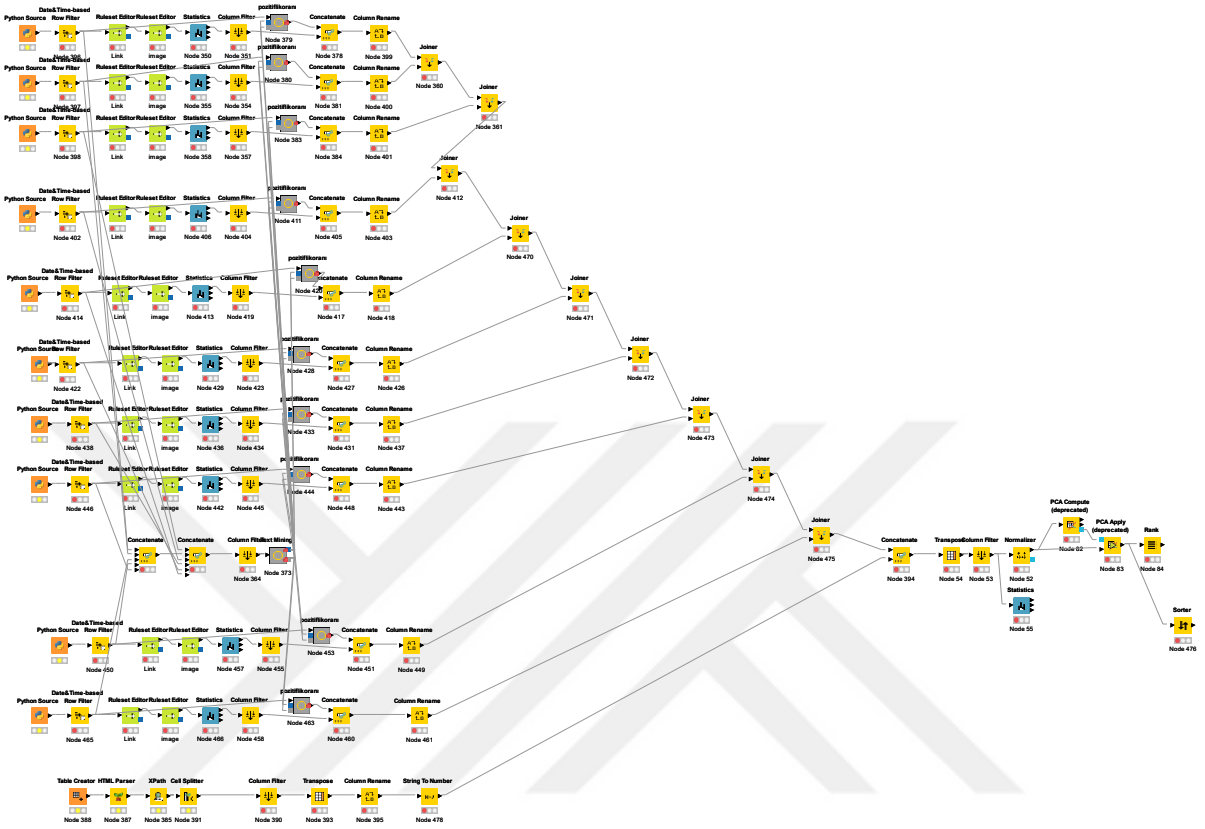
Kurulan bu kütüphane yardımıyla, markalara ait resmi Facebook sitelerinden gönderi metinleri, gönderi id’si, paylaşım zamanı elde edilmektedir. Ayrıca, paylaşım resim içeriyorsa, resme ait linki verebilmektedir. Benzer şekilde, paylaşımda bir internet sitesi linki mevcutsa, ayrıca bunu da verebilmektedir. Bunlara ek olarak, söz konusu kütüphane yardımıyla, yapılan paylaşıma gelen beğeni sayısı, paylaşım sayısı ve yorum sayısı elde edilebilmektedir.

KNIME programına ait HTMLparser ve Xpath nodülleri yardımıyla, sayfaya ait beğenen sayısı ve takipçi sayısı elde edilebilmektedir. Bu iki nodül, sayfaya ait HTML kodlarından yararlanarak, sayfada yer alan bilgilerin çekilmesini sağlamaktadır.

KNIME ‘daki nodüller ve Python kütüphanesi yardımıyla elde edilen verilerden markaya ait veri tabanı oluşturulmuştur. Daha sonrasında bu veri tabanı ile başta metin madenciliği olmak üzere veri madenciliği teknikleri yardımıyla analiz edilerek, markaya ait istatistikler elde edilmiştir. Elde edilen değişkenler, ortalama beğeni sayısı, ortalama yorum sayısı, ortalama paylaşım sayısının yanı sıra, resim ve link paylaşım oranları gibi istatistikler elde edilmiştir. Bunun yanı sıra, takipçi ve beğenen sayısı da dikkate alınmıştır. Ayrıca, gönderilerdeki yapısal olmayan metinlerin üzerinden paylaşımın pozitiflik ortalaması elde edilmiştir. Elde edilen bu sekiz değişken üzerinden markaya ait Facebook puanı hesaplanmaya çalışılmıştır.

İlk olarak, markanın resmi Facebook sayfasından elde edilen postlar KNIME üzerindeki tarih filtresi ile filtrelenmiştir. Planlanan tarih aralığındaki gönderiler analize dahil edilmiştir. Elde edilen gönderilere ait değerler kullanılarak, markanın Facebook kanalına ait istatistikler elde edilmiştir. Temel olarak, söz konusu

tarih aralığındaki gönderilere ait beğeni sayılarının toplamının toplam gönderi sayısına oranı alınarak ortalama beğeni sayısı elde edilmiştir. Benzer şekilde, toplam paylaşım sayısının toplam gönderi sayısına oranı alınarak ortalama paylaşım sayısı elde edilmiştir. Ayrıca, yapılan paylaşımlara gelen toplam yorum sayısının toplam gönderi sayısına bölünerek ortalama yorum sayısı elde edilmiştir. Bunlara ek olarak, gönderinin resim içerip içermemesine göre gösterge değişken elde edilerek, yapılan paylaşımın resim içerme oranı hesaplanmıştır. Benzer şekilde, gönderinin bağlantı içerip içermemesine göre gösterge değişken yardımıyla, yapılan paylaşımın bağlantı içerme oranı belirlenmiştir. Bir diğer değişken olarak da web madenciliği yardımıyla takipçi ve beğenen sayıları ham olarak analize dahil edilmiştir. Son olarak da metin madenciliği yardımıyla paylaşımların duygu analizi yapılmıştır. Öncelikle metinlerdeki gürültülü ifadeler temizlenmiş ve metin madenciliğinin ön işleme aşamaları gerçekleştirilmiştir. Hazır hale gelen metinler üzerinden analizler gerçekleştirilmiştir. Duygu analizinde, Dehkharghani ’in 2015 ve 2016 yıllarındaki çalışmaları ve Eryiğit ‘in 2013 ve 2014 yılındaki çalışmaları dikkate alınmıştır. Bu çalışmalarda elde edilen pür pozitif ve negatif Türkçe kelimeler tanımlanmıştır. Bu tanımlamalar ile gönderilerdeki ifadeler önce etiketlenmiştir. Daha sonrasında yapay sinir ağları vasıtasıyla bir paylaşımın ait pozitif, nötr ve negatif anlam kümelerine ait olasılıklar hesaplanmıştır. Yapay sinir ağları için KNIME içerisinde MLP Learner nodülü ile yapay sinir ağı modeli inşa edilir. Daha sonra inşa edilen modelin üzerinden yeni çıktılar elde etmek için ise MultiLayerPerceptron Predictor nodülü kullanılır. Bu olasılıklardan pozitiflik olasılığı değişken olarak analize dahil edilmiştir. Böylelikle elde edilen sekiz adet değişken, markaya ait Facebook kanalının değerlendirilmesinde kullanılmıştır. Şekil 2 ‘de KNIME programı üzerinde Facebook sistematiği gösterilmiştir. Bu sistematik yapı ve nodüller ile her bir marka için bahse geçen sekiz değişkenin elde edilmesi sağlanabilmektedir.



Şekil 2. Facebook Değerlendirme Modelinin KNIME İş Akışı

3.1.6.Twitter Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler

Twitter'dan verilerin çekilmesi için Application Programming Interface (API) den kullanılmıştır. Markaların Twitter kanalındaki verilerin elde edilmesinde KNIME 'ın kendi içerisindeki Twitter API Connector, Twitter Timeline ve Twitter Search nodülleri kullanılmıştır. Markaların twitter platformu üzerinde paylaştıkları gönderilerin çekilmesi için KNIME'daki akış diyagramına bu nodüller entegre edilmiştir. Twitter kanalından verilerin çekilmesi için, öncelikle twitter üzerinden geliştirici (developer) izinlerinin alınması gerekmektedir. Twitter' da geliştirici yetkisi alındığında, hizmetlerden yararlanılması için üretilen API key ve API secret key bilgileri üretilecektir. Üretilen bu anahtar vasıtasıyla KNIME içerisindeki Twitter API Connector nodülü aktif hale gelmektedir. Bu nodül KNIME programını Twitter 'a bağlanmasını sağlanabilmektedir.

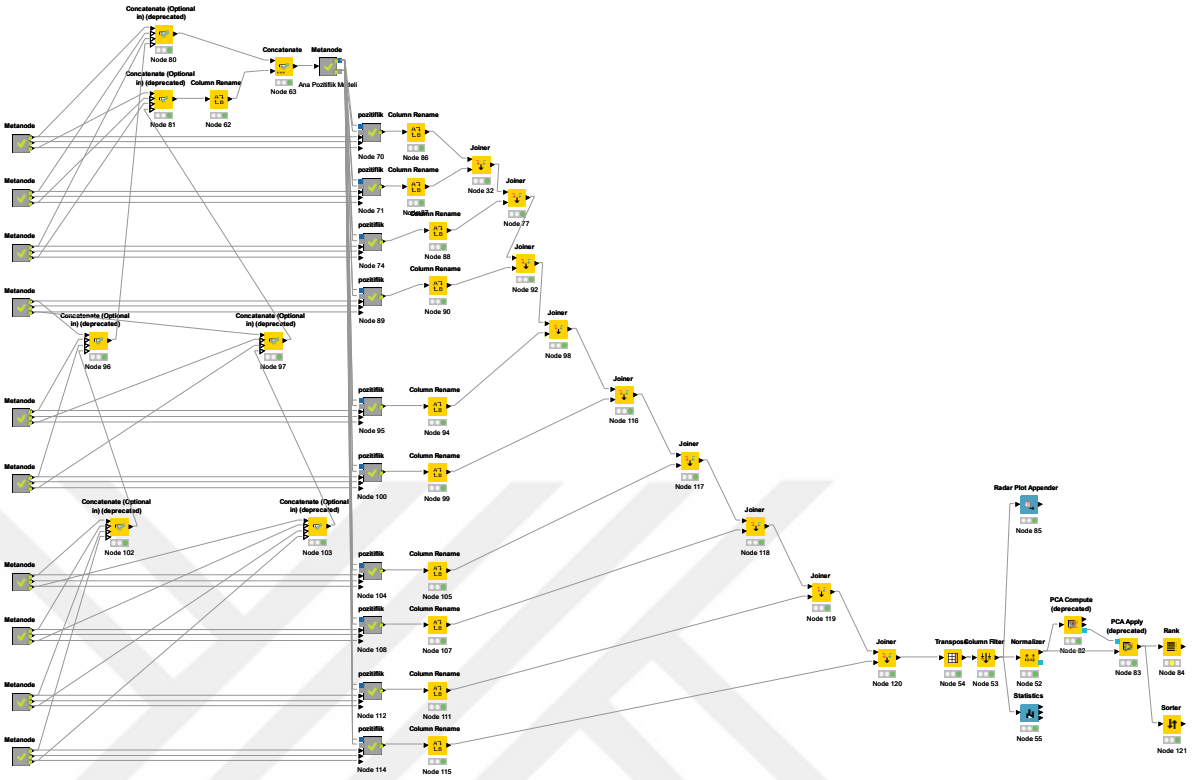
KNIME üzerinde Connector nodülü yardımıyla bağlantı sağlandıktan sonra, markaya ait resmi twitter hesabındaki verilerin çekilmesi için Twitter Timeline nodülü kullanılmıştır. Bu nodül ile istenen miktarda paylaşım ve istenen hesaba ait bilgiler KNIME programına indirilebilmektedir. Bu nodülün çıktısı olarak, paylaşım metni, zamanı, idsi, retweet sayısı, favori olması, retweet olup olmaması, favori olup olmaması, varsa lokasyon bilgisi gibi paylaşıma ait veriler elde edilmektedir. Ayrıca, bu verilerin yanında

kullanıcıya ait istatistiklerde elde edilebilmektedir. Hesabın adı, id numarası, profil resmi, hesaba ait tanımlama bilgisi, hesabın açılış zamanı, takip edilen sayısı ve takipçi sayısı bilgileri elde edilebilmektedir.

KNIME üzerinde kullanılan diğer bir nodül ise Twitter Search ‘dür. Bu nodül yardımıyla, Twitter sitesinde verilen kelime veya kelime gruplarını içeren gönderilerin çekilmesi sağlanmaktadır. Markaya ait aramaların sonucunda, bu nodülün çıktısı olarak, markayı içeren gönderi, gönderi idsi, paylaşım zamanı, retweet sayısı, favorilenmesi, retweet olup olmaması, favori olup olmaması, kimin tarafından paylaşıldığı ve konum bilgisi açık ise ülke bilgisi elde edilebilmektedir.

KNIME ‘daki nodüller yardımıyla elde edilen verilerden markaya ait veri tabanı oluşturulmuştur. Daha sonrasında bu veri tabanı ile başta metin madenciliği olmak üzere veri madenciliği teknikleri yardımıyla analiz edilerek, markaya ait istatistikler elde edilmiştir. Elde edilen değişkenler, ortalama retweet sayısı, ortalama beğenilme sayısı yanı sıra, profile ait istatistikler elde edilmiştir. Bunlar, arkadaş sayısı, favori sayısı, takipçi sayısı gibi profilin demografik bilgileridir. Ayrıca, gönderilerdeki yapısal olmayan metinlerin üzerinden paylaşımın pozitiflik ortalaması elde edilmiştir. Elde edilen bu değişkenler üzerinden markaya ait twitter puanı hesaplanmaya çalışılmıştır.

İlk olarak, markanın resmi twitter sayfasından elde edilen paylaşımlar KNIME üzerindeki tarih filtresi ile filtrelenmiştir. Planlanan tarih aralığındaki gönderiler analize dahil edilmiştir. Elde edilen gönderilere ait değerler kullanılarak, markanın twitter kanalına ait istatistikler elde edilmiştir. Temel olarak, söz konusu tarih aralığındaki gönderilere ait beğeni sayılarının toplamının toplam gönderi sayısına oranı alınarak ortalama beğeni sayısı elde edilmiştir. Benzer şekilde, toplam retweet sayısının toplam gönderi sayısına oranı alınarak ortalama retweet sayısı elde edilmiştir. Bir diğer değişken olarak da web madenciliği yardımıyla takipçi ve takip edilen sayısı ham olarak analize dahil edilmiştir. Markanın paylaştığı gönderiler haricinde, diğer twitter kullanıcılarının da paylaşımları Twitter Search nodülü yardımıyla elde edilmiştir. Bu nodülün çıktısından da ikinci bir ortalama retweet sayısı ile ortalama beğeni sayısı elde edilmiştir. Bu iki istatistikte, analize ayrıca olarak dahil edilmiştir. Son olarak da metin madenciliği yardımıyla paylaşımların duygu analizi yapılmıştır. Öncelikle metinlerdeki gürültülü ifadeler temizlenmiş ve metin madenciliğinin ön işleme aşamaları gerçekleştirilmiştir. Hazır hale gelen metinler üzerinden analizler gerçekleştirilmiştir. Duygu analizinde, Dehkharghani ’in 2015 ve 2016 yıllarındaki çalışmaları ve Eryiğit ‘in 2013 ve 2014 yılındaki çalışmaları dikkate alınmıştır. Bu çalışmalarda elde edilen pür pozitif ve negatif Türkçe kelimeler tanımlanmıştır. Bu tanımlamalar ile gönderilerdeki ifadeler önce etiketlenmiştir. Daha sonrasında yapay sinir ağları vasıtasıyla bir paylaşımına ait pozitif, nötr ve negatif anlam kümelerine ait olasılıklar hesaplanmıştır. Bu olasılıklardan pozitiflik olasılığı değişken olarak analize dahil edilmiştir. Ayrıca, Twitter Search üzerinden elde edilen metinlere duygu analizi uygulanmıştır. Bundan elde edilen ikinci bir pozitiflik olasılığı değişkeni de analizde kullanılmıştır. Bu ikinci duygu analizi, markaların değil diğer twitter kullanıcılarının marka hakkındaki paylaşımlarını içeren metinlerden elde edilmiştir. Şekil 3 ‘de KNIME programı üzerinde Twitter sistematiği ve sistemde kullanılan nodüller gösterilmiştir gösterilmiştir. Bu sistematik yapı ile her bir marka için bahse geçen değişkenlerin elde edilmesi sağlanabilmektedir.



Şekil 3. Twitter Değerlendirme Modelinin KNIME İş Akış

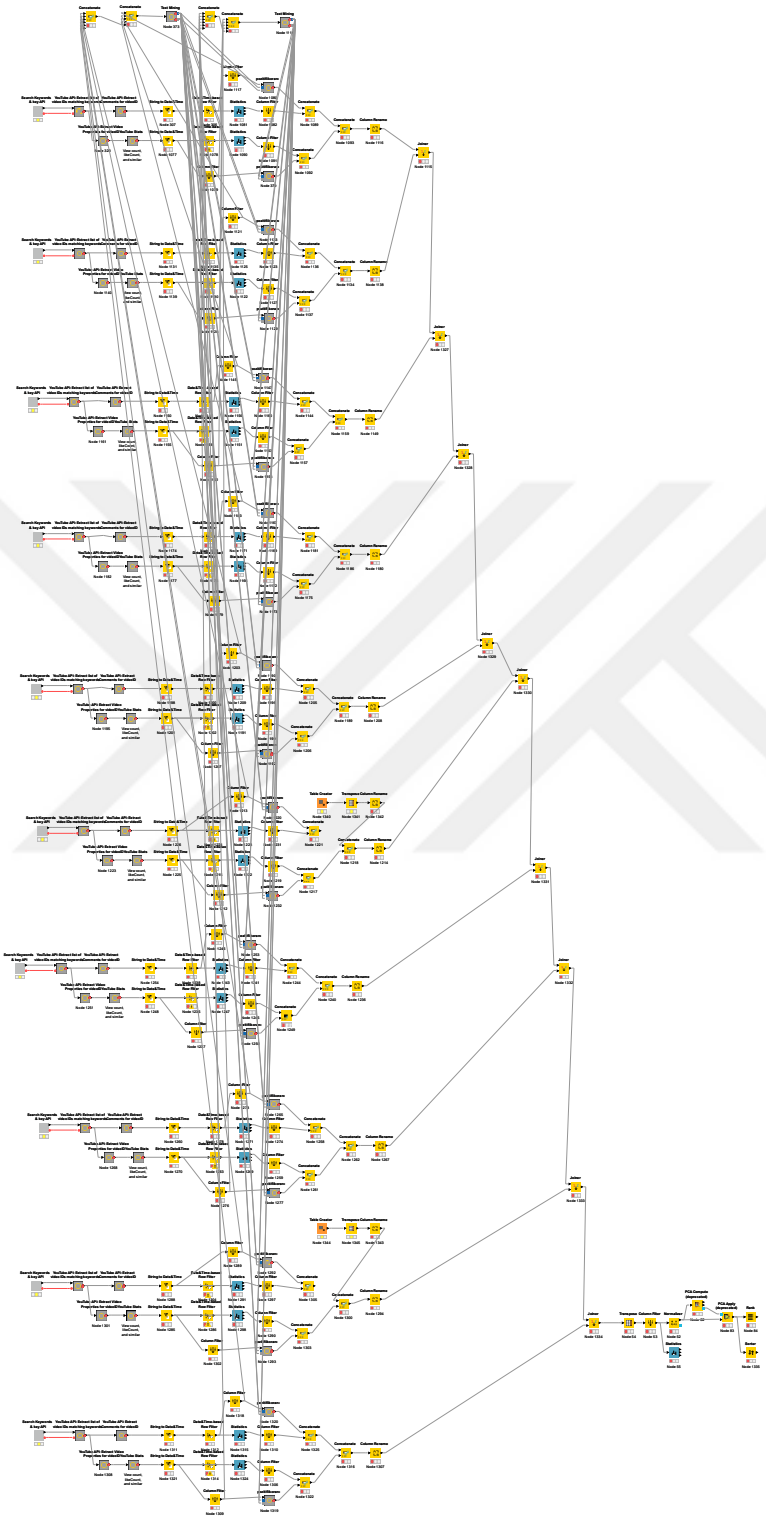
3.1.7.Youtube Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler

Çalışmanın Youtube kanalının değerlendirilmesinde kullanılan verilerin elde edilmesi sürecinde KNIME içerisine kurulan Google ‘ın API uygulamalarından yararlanılmıştır. API uygulamasının aktifleştirilmesi için Google geliştirici panelinin aktifleştirilmesi gerekmektedir.

Google geliştiriciden elde edilen anahtarlar ve aranan kelimelerin KNIME platformuna girilmesi için ayrı ayrı String Input nodülleri oluşturulmuştur. Oluşturulan bu nodüller yardımıyla girilen iki girdi, String Manupulation nodülü yardımıyla sorgulanabilir bağlantı haline getirilmiştir. KNIME ‘daki bir diğer nodül olan Get Request yardımıyla markaların Youtube kanallarındaki videolarına ait bağlantılar elde edilebilmektedir. Daha sonrasında ise bu bağlantılar yardımıyla, videoların ID numaraları, yayınlanma zamanları, videonun başlıkları, videoların açıklamaları, izlenme sayıları, beğenilme ve beğenilmeme sayıları, yorum sayıları, favori olma sayıları ve videonun sisteme girildi ise dil bilgisi gelmektedir. Ayrıca, videoya ait bu bilgilerin haricinde, paylaşıma gelen yorum metinleri, yorum yazarlarının isimler, bu yorumlara gelen beğeni ve paylaşım sayıları, yazarın profil linki ile yorum zamanı elde edilebilmektedir.

Elde edilen bu veriler ilk olarak zaman filtresi yardımıyla filtrelenmiştir. Daha sonrasında bu veri tabanı ile başta metin madenciliği olmak üzere veri madenciliği teknikleri yardımıyla analiz edilerek, markanın Youtube kanalına ait istatistikleri elde edilmiştir. Elde edilen değişkenler, izlenme sürelerinin toplamının toplam video sayısına oranı ile ortalama izlenme süresi, toplam beğeni, beğenilmeme ve

paylaşımların toplam video sayısına oranı ile sırasıyla ortalama beğeni, ortalama beğenilmeme ve ortalama paylaşım sayıları hesaplanmıştır. Benzer şekilde, toplam yorum ve toplam favori sayısının toplam videoya oranı ile sırasıyla ortalama yorum sayısı ve ortalama favori olma değişkenleri elde edilmiştir. Ayrıca, video tanımı da metin madenciliği yardımıyla analiz edilmiş ve diğer dijital pazarlama kanallarında olduğu gibi videonun içerik pozitiflik ortalaması elde edilmiştir. Bunların haricinde, videolara gelen yorumlarda analize dahil edilmiştir. Twitter 'dakine benzer şekilde Youtube izleyicilerinin yorumları da değerlendirilmeye alınması böylelikle sağlanmıştır. Yorumlardan elde edilen değişkenler ise, izleyicilerin paylaştıkları metinlerin pozitiflik oranları başta olmak üzere, aldıkları beğeni ve paylaşım sayılarının ortalaması hesaplanarak elde edilmiştir. Bunun sonucunda hem markanın paylaşımları hem de paylaşımlara gelen tepkiler dikkate alınması sağlanmıştır. Şekil 4 'te KNIME programı üzerinde Youtube sistematiği gösterilmiştir. Bu sistematik yapı ve nodüller yardımı ile her bir marka için bahse geçen değişkenlerin elde edilmesi sağlanabilmektedir.



Şekil 4. Youtube Değerlendirme Modelinin KNIME İş Akış

3.1.8.Instagram Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler

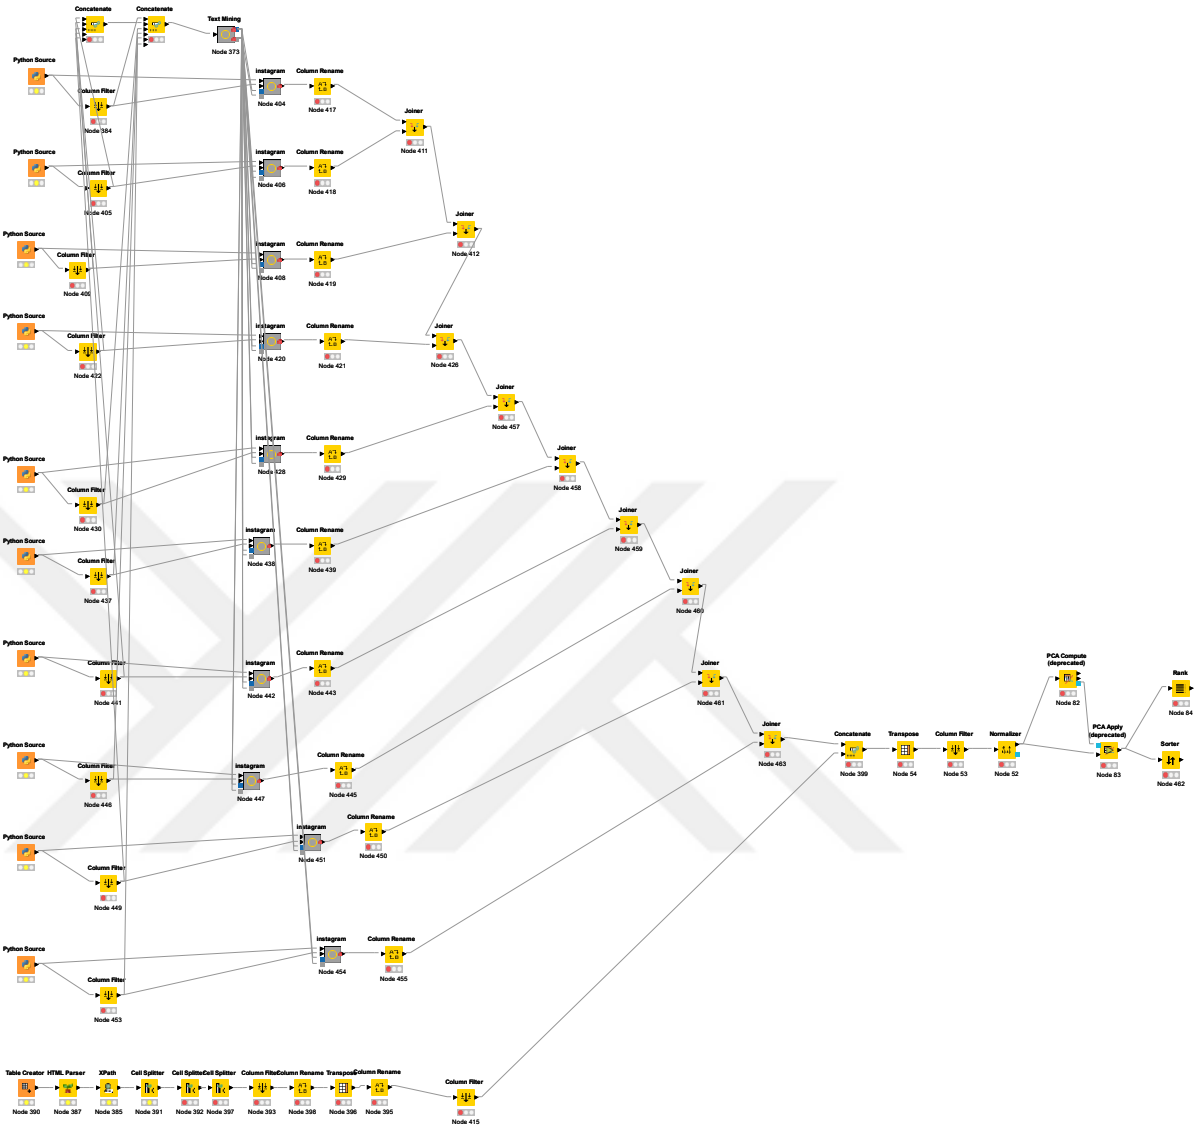
Markaların Instagram kanalındaki verilerin elde edilmesinde Python ve KNIME ‘ın kendi içerisindeki HTMLparser ve xpath nodülleri kullanılmıştır. Markaların Instagram platformu üzerinde paylaştıkları gönderilerin çekilmesi için KNIME ’daki akış diyagramına entegre edilen Python nodülünden yararlanılmıştır. Bu nodülden verilerin çekilmesi için, Python kütüphanelerinden instaloader kütüphanesinden yararlanılmıştır. Söz konusu kütüphane öncelikle Python Package Index (pip) ile kurulmuştur. KNIME içerisindeki Python Source nodülüne, Ek2 ‘de yer alan python kodlaması girilerek veriler çekilebilmektedir. Kodlamada paylaşımlar döngü yardımıyla çekilebilmektedir. Bundan dolayı ilk tarihten eski tarihli paylaşıma göre tek tek çekilerek “TamListe” veri tabanına eklenmesi usulüyle toplanabilmektedir.

Kurulan bu kütüphane yardımıyla, markalara ait resmi Instagram sitelerinden paylaşılan resimlerin açıklamaları, yorum sayısı, beğenilme sayısı, resme ait bağlantı adresi ve paylaşım zamanı elde edilmektedir. Bu sayede markaya ait Instagram dijital pazarlama kanalarındaki zaman akış sürecine uygun olarak, resimlere ait bilgiler elde edilebilmektedir. Ayrıca, resimlere ait bağlantı adresleri kullanılarak, KNIME ‘daki Image Reader nodülü sayesinde resimler strateji üretimi için indirilebilmektedir.

KNIME programına ait HTMLparser ve Xpath nodülleri yardımıyla ise Facebook sayfasında olduğu gibi profile ait takip edilen sayısı ve takipçi sayısı elde edilebilmektedir. Bu iki nodül, sayfaya ait HTML kodlarından yararlanarak, sayfada yer alan bilgilerin çekilmesini sağlamaktadır.

KNIME ‘daki nodüller ve Python kütüphanesi yardımıyla elde edilen verilerden markaya ait veri tabanı oluşturulmuştur. Daha sonrasında bu veri tabanı ile başta metin madenciliği olmak üzere veri madenciliği teknikleri yardımıyla analiz edilerek, markaya ait istatistikler elde edilmiştir. Elde edilen değişkenler, paylaşıma ait açıklama metni, paylaşıma gelen yorum sayısı ve beğeni sayılarıdır. Ayrıca gönderinin bağlantı adresi ile paylaşımın zamanı da elde edilen bilgilerdir. Bu değişkenlerle elde edilen veri tabanı, markanın Instagram performansının değerlendirilmesi için kullanılabilecektir.

İlk olarak, zaman sütunu dikkate alınarak, filtrelenmiştir. Daha sonrasında toplam yorum sayısının resim sayısına oranlaması ile resim başına düşen ortalama yorum sayısı elde edilmiştir. Benzer şekilde resimlere gelen beğeni sayılarının toplamının yine resim sayısına bölünmesi ile resim başına düşen ortalama beğeni sayısı elde edilmiştir. Ayrıca, HTMLparser ve Xpath üzerinden elde edilen takipçi ve takip eden sayıları ham veriler olarak analize dahil edilmiştir. Bir diğer değişken ise metin madenciliği ile elde edilmiştir. Pozitif, negatif ve nötr anlam durumuna göre değerlendirilen paylaşımlar üzerinden Facebook gibi diğer dijital pazarlama kanallarında olduğu gibi yapay sinir ağları yardımıyla sınıflandırılmıştır. Markaların paylaştıkları görseller altına yaptıkları açıklamalar üzerinden pozitiflik ortalaması hesaplanmıştır. Ayrıca, gönderilerdeki resimlerin özellikleri de bir değişken olarak ele alınmıştır. KNIME içerisindeki Image Features nodülü yardımıyla resimlere ait birincil istatistik olarak resim ortalaması elde edilmiştir. Bu ortalama ile birlikte bütün değişkenler dikkate alınarak markaya ait Instagram değerlendirilmesi sağlanmıştır. Instagram kanalının değerlendirilmesi için kurulan sistematik yapı ve nodüller Şekil 5’te gösterilmiştir. Bu sistematik yapı ile Instagram değerlendirilmesinde kullanılacak değişkenler elde edilmesi sağlanabilmiştir.



Şekil 5. Instagram Değerlendirme Modelinin KNIME İş Akış

3.1.9.Google Haberler Kanalının Değerlendirilmesi İçin Kullanılan Değişkenler

Markaların Google Haberlerde yayınlanan metinlerden verilerin elde edilmesinde KNIME ‘ın kendi içerisindeki GET Request nodülleri kullanılmıştır. Söz konusu nodül yardımıyla, verilen kelime veya kelime gruplarının Google haberlerde aranabilmektedir. Arama sonucunda, markaya ait Google haberlere çıkmış haber metinleri çekilebilmektedir.

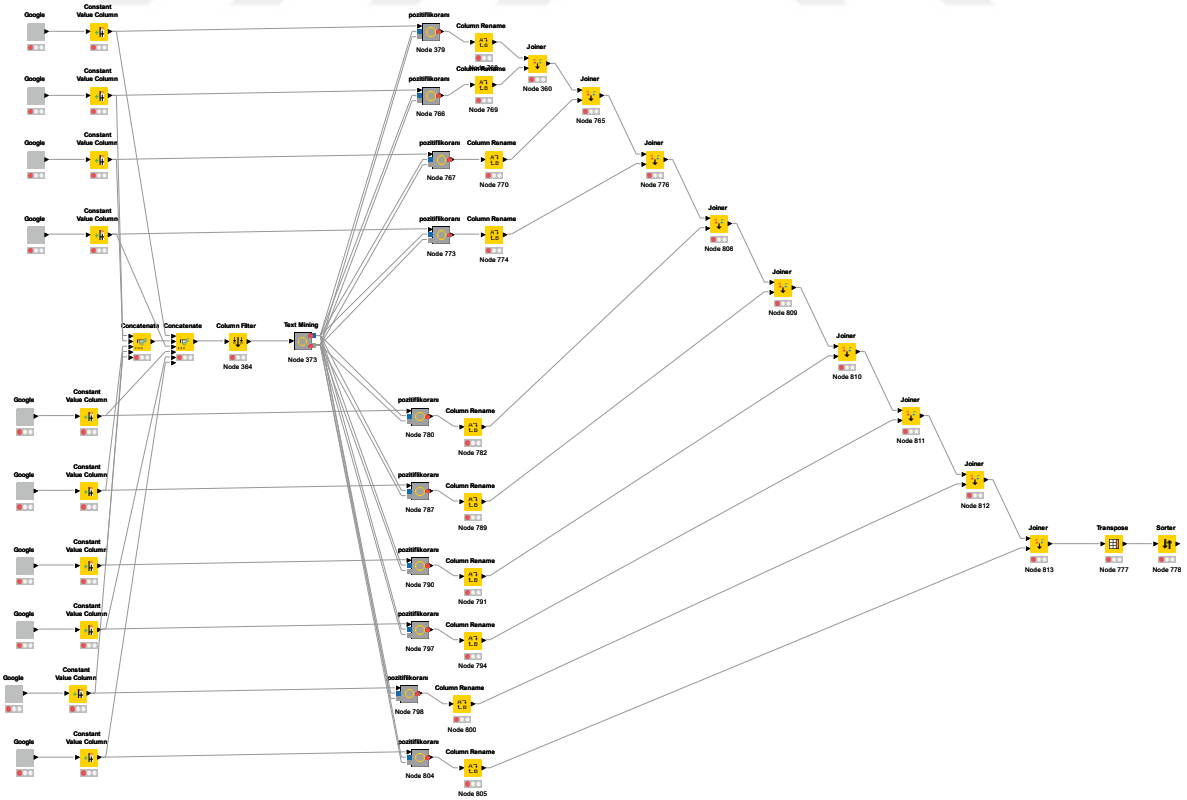
Google haberlerden verilerin çekilmesi için öncelikle Google hesabınızın geliştirici (Developer) panelinin aktifleştirilmesi gerekmektedir.[2] Aktifleştirilen hesaba ait Google API hizmetleri aktif hale gelmektedir. Aktif gelen hizmetlere ait Google KNIME üzerinde kullanabileceğiniz anahtar kod

[2] https://console.developers.google.com/

üretilebilecektir. Bu kod yardımıyla Google haberler ve Youtube başta olmak üzere Google ait diğer hizmetlere erişim sağlanmış olacaktır.

KNIME üzerinden alınan hizmet anahtar kodu yardımıyla öncelikle gerekli sorgunun oluşturulması gerekmektedir. İki adet String Input yardımıyla aranacak marka bilgileri ve anahtar kod sisteme entegre edilir. Bu iki girdi Merge Variables yardımıyla birleştirilir. Daha sonrasında, String Manipulation yardımıyla da sorgu bağlantısı oluşturulur. Oluşturulan bu bağlantı üzerinden GET Request nodülüyle haberler KNIME programı içerine alınır. Bu sorgulama sonucunda haber başlığı ve içeriği elde edilebilmektedir.

Metin madenciliği yardımıyla çekilen haber metinleri analiz edilebilmektedir. Diğer dijital pazarlama kanallarında olduğu gibi ön temizliği yapılan metinlerde etiketleme ve yapay sinir ağları yardımıyla duygu analizi yapılmıştır. Duygu analizi sonucunda, her bir haberlerin pozitiflik olma olasılıkları etiketleme ve yapay sinir ağları yardımıyla diğer dijital pazarlama kanallarına benzer şekilde kendi içerisinde hesaplanmıştır. Daha sonrasında, bu olasılıkların ortalaması alınarak, markanın Google Haberlerdeki pozitif ortalaması değişkeni elde edilmiştir. Google Haberler kanalının değerlendirilmesi için kurulan sistematik yapı ve nodüller Şekil 6 'da gösterilmiştir. Bu sistematik yapı ile haberler için değerlendirilmesinde kullanılacak değişkenler elde edilmesi sağlanabilmiştir.



Şekil 6. Google Haberler Değerlendirme Modelinin KNIME İş Akış

3.2.Dijital Pazarlama Kanallarının Modellenmesi

Bu başlık altında, önceki bölümde tanıtılan kanallara ait değişkenler kullanılarak dijital pazarlama kanallarına ait modellerin inşası tanıtılacaktır. Öncelikle, veri madenciliği ve modellerin kurulmasında yararlanılan teknikler üzerinde durulacaktır. Daha sonrasında, bu teknikler yardımıyla kanal bazında modeller tanıtılacaktır.

Veri madenciliği, büyük veri kümelerinden daha önce bilinmeyen geçerli bilgileri çıkarma teknikleridir. Başka bir ifade ile, toplanan verilerden gizli örüntüyü veya potansiyel bilginin çıkarılmasıdır. Bilgisayarın ve internetin gelişmesiyle birlikte veri setlerindeki hızlı artış veri madenciliğinin gelişmesinde büyük rol oynamıştır. İstatistiksel analizlerin büyük hacimli verilerde ve yapısal olmayan verilerde yetersiz kalması da veri madenciliğine olan ilgiyi artırmıştır. Söz konusu büyük verinin özelliği 5V olarak adlandırılan kavramlar ile tanımlanmaktadır: Hacim (Volume), Hız (Velocity), Çeşitlilik (Variety), Doğrulama (Verification), ve Değer (Value). Günümüzde ise, büyük veri kavramına gerçeklik, oynaklık, geçerlik, hassaslık ve değişkenlik boyutları da eklenerek daha geniş bir tanımlama yapılmaktadır (Demchenko vd, 2014). Büyük veri setlerinin analizi için istatistiksel analizlerin yanında yapay zekâ yöntemleri, makine öğrenmesi algoritmaları geliştirilmiştir. Makine öğrenmesi, denetimli ve denetimsiz öğrenme teknikleri olarak iki başlık altında yer almakta olup, temel olarak birliktelik, kümeleme, sınıflandırma, öngörü modelleri üzerine algoritmalar geliştirilmektedir. İstatistikte olduğu gibi bağımlı bir veya birden fazla değişkenin yer alması ile yapılan teknikler denetimli öğrenme olarak adlandırılır. Yapay sinir ağları, karar ağaçları bu öğrenme tekniğinin en çok tercih edilenleridir. Denetimsiz öğrenme ise, bütün değişkenlerin girdi olarak alındığı modeller olup boyut indirgeme modelleri içinde çokça başvurulanlarından birisidir (Silahtaroğlu, 2008; Kelleher vd., 2020).

Yapay zekâ kavramı, 1950' li yıllara kadar dayanan bir kavram olup, makinaların insanlar gibi öğrenen ve karar veren yapılar yapabilmesidir. Yapay zekâ kavramı zayıf ve kuvvetli olmak üzere iki türde olup, zayıf zekâ sadece programlanan işlemi yapma yeteneğine sahipken kuvvetli zekalar daha gelişmiş algoritmalı işlemleri hesaplama ile bularak programlanan yapıyı iyileştirebilen, hatalardan öğrenebilen sistemlerdir. Makine öğrenimi ise 1980'lerde ortaya çıkan ve veri madenciliğin kullanılması ile daha sık kullanılmaya başlanan bir kavramdır. Sisteme giren veriler ve parametreler ile benzetimler yaparak, veride ki gizli bilgiyi ve yapıyı açığa çıkarabilen, kendi kendini eğitebilen sistemlerdir. Derin öğrenme, daha yeni bir kavram olup 2000 li yıllarda kullanılmaya başlayan bir kavramdır. Büyük veri ile tek bir katmanda değil, birden fazla katman ile makine öğreniminde bulunan ve hesapları tek bir seferde yapabilen sistemledir. Ayrıca, makine öğreniminde tanımlanması gereken parametreleri kendi içerisinde belirleyen ve değerlendirmelerde bulunabilen bir sistemdir. Yapay Zekâ; makineler tarafından sergilenen insan zekâsı olarak yorumlanabilir. Makine Öğrenimi; yapay zekaya ulaşmak için bir yaklaşım olarak ele alınabilir. Derin Öğrenme; makine öğrenimini uygulamak için bir teknikler bütündür. Makine öğrenmesi ile derin öğrenme arasındaki en önemli fark katman sayısının birden fazla olmasıdır (Russell vd, 2014; Bini, 2018; Krizhevsky vd., 2012).

Yukarıda bahsedilen kapsam çerçevesinde birçok algoritma geliştirilmiş ve geliştirilemeye devam etmektedir. Bu algoritmalar genel olarak denetimli ve denetimsiz olmak üzere iki başlık altında toplanabilir. Denetimli Öğrenme algoritmaları, sınıflandırma algoritmaları (Karar ağaçları (KA), lojistik regresyon,

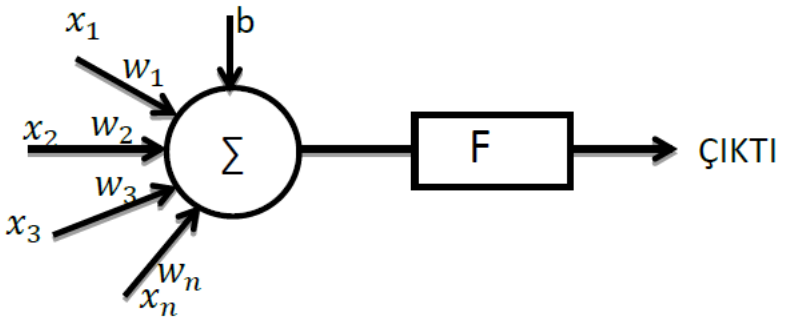
Ayrıştırma analizi, Rassal Orman Yürüyüşü, Yapay Sinir Ağları (YSA), genetik algoritmalar, destek vektör makinaları, Naive Bayes) ve tahmin modelleri (Regresyon, Regresyon tabanlı KA, YSA) en çok kullanılanlardır (Russell vd, 2014).

İlk olarak, değişkenlerin çekilmesi ve internetten ilgili verilerin elde edilmesi için web madenciliğinden yararlanılmıştır. Web madenciliği, veri tabanları başta olmak üzere, internet üzerinden verilerin elde edilmesinde kullanılan bir tekniktir (Eirinaki ve Vazirgiannis, 2003).

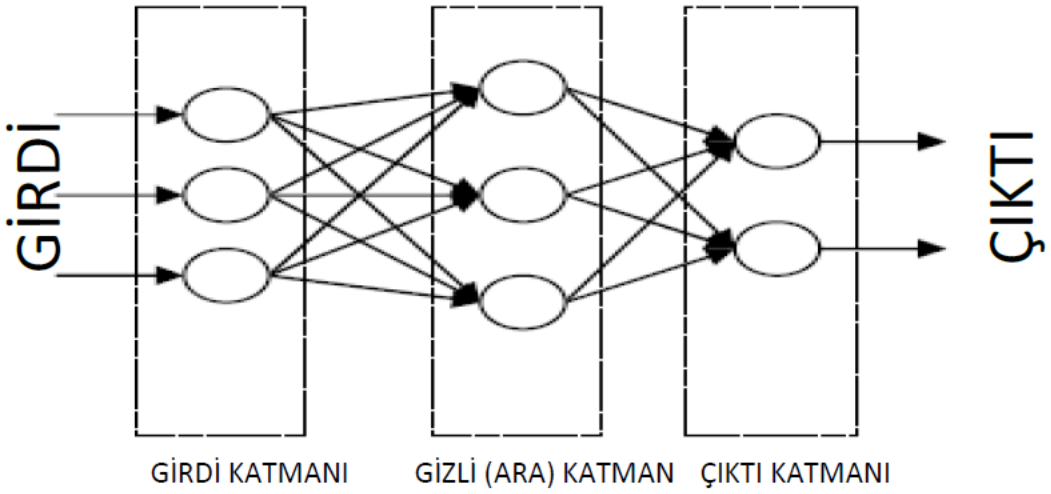
Metin Madenciliği, yapısallaştırılmamış metin verilerinden anlamlı bilgiler çıkarmaya çalışan günümüzde her geçen gün geliştirilen bir veri madenciliği tekniğidir. Metin madenciliği, metin tabanlı verilere veri madenciliğinin uygulandığı bir alt koludur. Metin madenciliğinden en önemli süreçlerden biri metinlerin önişlemden geçirilme sürecidir. Bu süreçte, verilerdeki anlamsız kelimelerin ve sembollerin temizlenmesi, yazım yanlışlarının giderilmesi, büyük küçük harflerin standartlaştırılması, noktalama işaretlerinin temizlenmesi gibi işlemlerin yer aldığı süreçtir. Bu sürecin ardından, kelime veya kelime gruplarının oluşturulması için kök dizinlerinin (stemming) elde edilmesi gerekmektedir (Eryiğit ve Toruna, 2017). Böylelikle, kökleri aynı olan ama cümle içerinde ek aldığı için farklı olan kelimeler belirlenmiş olur. Metin madenciliği çerçevesinde, metinler üzerinde kelime sıklıkları, kelime etiketleme gibi yöntemler uygulanabilmektedir. Kelime sıklıklarına bakılarak, en çok geçen kelime veya kelime grupları elde edilebilmektedir. Kelime veya kelime gruplarının etiketlenmesi yapılarak metinlerin sınıflandırılması sağlanabilmektedir. Duygu analizi ise bir tür etiketlemedir. Duygu analizinde temelinde metin işleme (text processing) işlemidir. Bu süreçte verilen metinlerin duygusal olarak ifade etmek istediği sınıfı veya kümeyi belirlenmesi hedeflenir. Duygu analizinin literatürdeki çalışmaları kutupsal duygu analizi (sentimental polarity) olarak geçmekte olup verilen metni olumlu (positive), olumsuz (negative) ve nötr gibi kategorilere ayırarak sınıflandırmayı amaçlamaktadır. Bu sınıflandırılmanın yapılabilmesi için, öncelikle belirli bir kelime kümesinin yani öğrenme kümesinin söz konusu kategorilere göre etiketlenmesi gerekmektedir. Daha sonrasında yapay zekâ veya makine öğrenmesi yardımıyla sistem, metinlerin kategorilerini öğrenir. Öğrendiği bilgiler yardımıyla yeni metinleri sınıflandırır (Şener, 2016; Eryiğit ve Toruna, 2017).

Yapay sinir ağ modelleri 1943 yılında McCulloch ve Pitts tarafından gerçekleştirilmiş olsa da yapay sinir ağlarının disiplinin resmi başlangıcı olarak 1987 yılındaki Elektrik-Elektronik Mühendisliği Enstitüsü tarafından San Diego'da gerçekleştirilen uluslararası konferans kabul edilir (Yadav vd, 2015). Yapay sinir ağları, kendisine sunulan bir girdi seti ile çıktı setini eşleştirerek modelleyebilen ve canlıların sinir sisteminden esinlenerek geliştirilen bilgisayar tabanlı denetimli veri madenciliği tekniğidir. Yapay sinir ağları tahmin sınıflandırma ve kümeleme işlemlerinin kapsamında sayılabilecek her türlü problemin çözümünde kullanılan doğrusal olmayan modellerdir. İstatistiki modeller gibi analiz öncesi varsayım gerektirmez (Akcan & Kartal, 2011). Yapay sinir ağlarının temelinde yapay sinir hücreleri (nöronlar) birbirlerine bağlantının kendisi tarafından belirlenen ve güncellenen ağırlıklarla bağlanır. Yapay sinir hücrelerinde temel olarak dış ortamdan veya diğer nöronlardan gelen veriler, giriş verisi, ağırlıklar, toplama ve aktivasyon fonksiyonu ve çıktılar bütününden oluşur. Sisteme girdi olarak alınan veri, ağırlıkları (W) ile nörona bağlanır. Toplam fonksiyonu, girişler (X) ve bunların ağırlıklarının çarpımlarının toplamı olarak tanımlanan net girişin hesaplanması ifade eder. Bu sürecin sonucunda net çıkışlarını yani nöron çıktısı hesaplanır. Bu fonksiyon genel olarak doğrusal olmayan bir fonksiyon tercih edilebilmektedir. Bu fonksiyonda kullanılan ve genellikle b ile temsil edilen bias ya da eşik değer olarak adlandırılan sabit yer alır. Söz konusu bu durum özet olarak şekil 7'de bir nöron

yapısının şekli temsil edilmiştir (Haykin ve Network, 2004; Altman vd., 1994). Yapay sinir ağlarından en çok kullanılan modeli, dışarıdan girilen verilerin oluşturduğu girdi katmanından, sonuçların oluşturduğu çıktı katmanından ve bu iki katman arasında yer alan en az bir adet gizli katmanın yer aldığı çok katmanlı ağ modelidir. Yapay sinir ağları, bu sinir hücrelerinin birleşmesi ile oluşur. Genellikle girdi, gizli veya ara ve çıktı katmanları olmak üzere 3 katmandan ve paralel olarak birbirlerine bağlanarak oluşturulur. Ağın yapısına göre ileri ya da geri beslemeli olmak üzere iki tür yapay sinir ağ modeli mevcuttur. Dış ortamdan gelen girdi bilgisinin girdi katmanından çıktı katmanına doğru akması ve bu süreçte girdi katmanından gizli katmana, gizli katmandan çıktı katmanına bağlanarak öngörü üretir. Şekil 8'de ileri beslemeli bir yapay sinir ağına ait temsili görüntüsüne yer verilmiştir. Geri beslemeli yapay sinir ağlarında çıktılar girdilere bağlanarak ileri beslemeli bir ağdan elde edilir. İleri beslemeli yapay sinir ağlarında, girdiler ve girdilerin ağırlıklarının hesaplanarak sonucu bir sonraki katmana aktarılır. Bu hesaplama işlemi, çıkış katmanındaki sinir hücrelerinde de yapıldıktan sonra sonlanır. Geri beslemeli yapay sinir ağlarında ise bazı katmanlarda önceki katmana bağlanılır. Bu tür modellerde denetimsiz öğrenme söz konusudur. Geri beslemeli yapay sinir hücrelerinin bir çıkışı diğer her bir sinir hücresinin girdisine bağlanır. Yapay sinir ağlarının dezavantajı ise, sistemin içeriğinin bilinmemesi, farklı sistemlere uygulanmasının zorluğu ve değişkenlerin ağırlıklarının veya önemlerinin hesaplanamamasıdır (Wallace, 2008; Haykin ve Network, 2004). Şekil 7'de bir nöronun yapısı ve Şekil 8'de ileri beslemeli yapay sinir ağ modelinin gösterilmiştir.



Şekil 7. Temel Sinir Hücresi



Şekil 8.İleri Beslemeli Çok Katmanlı Yapay Sinir Ağ Modeli

Boyut indirgeme modelleri, veri madenciliğinde çokça tercih edilebilen analizlerden biridir (Huang vd, 2019; Çalışan ve Talu, 2020). Temel amacı çok fazla değişken kümesini daha az değişken ile değiştirmektir. Bunun temel iki amacı vardır. Birincisi, daha az değişken ile analizlerin kolaylaştırılması ve sürecin hızlandırılmasıdır. İkinci ise, birbiriyle bağlantılı olan bir değişken kümesinden korelasyon içermeyen bir değişken kümesi elde etmektir. Temel bileşenler analizi, boyut indirgeme modellerinden en sıklıkla kullanılan yöntemlerden biridir. Söz konusu bu yöntemde, p adet değişken, p 'den daha az olan k adet değişkene indirgenmeye çalışılır. Yöntem korelasyon matrisindeki toplam varyansı dikkate alır. Değişken sayısı, varyansın maksimize edecek şekilde değişkenlerin izdüşümü alınarak azaltılması amaçlanır. Değişkenlerin oluşturduğu noktalar kümesine göre tüm noktalara ortalama uzaklığın en az olduğu doğru belirlenir. Bu doğruya da dik olan doğru en uygun doğru olarak belirlenir. Belirlenen bu doğru üzerinden istenen eşik varyansın altına inene kadar bu en uygun doğrular belirlenmeye devam edilir. Temel bileşenler analizinden bileşen elde ederek bileşenler dik olmasından dolayı, elde edilen bileşenlerin diğer analizlerde kullanımı ve sonuçların yorumlanması kolaylaşır. Temel bileşenler analizinde çözüm matematiksel olarak tek olabilmesidir. Ayrıca, bu çözüm şayet bütün bileşenler dikkate alınırsa gözlenen korelasyon matrisini koruma imkânı sağlar. Böylelikle, orijinal verinin elde edilen sonuçlardan yeniden yapılabilmesine imkân tanıyabilir. Temel bileşenler analizi ile elde edilen değişkenlerin ilişkisiz doğrusal kombinasyonları oluşturulur. İlk bileşen daima en büyük varyansa sahiptir. Diğer bileşenler sürekli olarak azalan bir varyans yapısına sahiptir. Temel Bileşenler Analizi, yüz tespiti, dosya sıkıştırma ve gizil değişken oluşturma gibi alanlarda yaygın olarak kullanılmaktadır. Temel bileşenler analizinin üstünlüklerinden birisi veri kaybının olmamasıdır (Alpar, 2011, Wold vd., 1987).

Resim analizi ise, metin madenciliği gibi metin yerine resimler üzerinden analiz yapılmasını sağlayabilmektedir. Keras algoritması başta olmak üzere derin öğrenme yöntemleri ile resimlerin sınıflandırılması veya nesne tespiti analizleri yapılabileceğinden çalışmada kullanılması tercih edilmiştir. Söz konusu algoritmaların yardımıyla, bir resme ait kategori saplanabilmektedir. En bilindik olarak, kedi köpek

analizi gibi, verilen resmin kediye mi köpeğe mi ait olduğu tespit edilebilmektedir. Benzer şekilde, verilen bir rakama ait resmin hangi rakam olduğunun tespitinde de yine bu algoritmalar kullanılabilmektedir. Bu sınıflandırma örnekleri haricinde, herhangi bir resmin içerisinde yer alan nesneler de tespit edilebilmektedir. Derin öğrenme ile resimde yer alan nesneler ve nesnelere ait güvenirlilik değerleri elde edilebilmektedir. Başka bir ifade ile, makine öğrenmesi ve derin öğrenme yardımıyla sisteme verilen resimden analiz sonucunda olabilecek nesnelere ait sonuç güvenirlilikleri yüzdelik olarak elde edilebilmektedir. Güvenirlilik ne kadar yüksek olursa o nesnenin resimde yer aldığının doğruluğu o kadar yüksek olduğu söylenebilir.

Bu bölümde anlatılan yöntemler yardımıyla markalara ait dijital pazarlama kanallarından elde edilen değişkenler analiz edilmiştir. Yapılan analizlerin sonucunda rakiplerine göre markaların hem kanal bazında hem de genel olarak performans skorları elde edilmeye çalışılmıştır. Ayrıca, analizlerin çıktıları yardımıyla performansların geliştirilmesi için yeni stratejiler üretilmesi hedeflenmiştir.

3.3.Kanalların Modellerinin Kurulması

Bir önceki bölümde anlatılan yöntemler yardımıyla, ilk olarak kanal bazında modeller kurulabilmektedir. Kanal bazında elde edilen performans skorlar daha sonra genel skorların elde edilmesinde kullanılabilmektedir. Dijital pazarlama kanallarını değerlendirmek için dikkate alınan değişkenler toplu olarak Tablo 1 ‘de yer verimiştir.

Tablo 1. Dijital Pazarlama Kanallarının Performasında Kullanılan Değişkenler

Dijital Pazarlama Kanalı	Değişkenler
Facebook	Ortalama Beğeni Sayısı, Ortalama Paylaşım Sayısı, Ortalama Yorum Sayısı, Resim İçerme Oranı, Bağlantı İçerme Oranı, Takipçi Sayısı, Beğeni Sayısı, Pozitiflik Olasılığı
Twitter	Ortalama Beğeni Sayısı, Ortalama Retweet Sayısı, Takipçi Sayısı, Takip Edilen Sayısı, Takipçilerin Ortalama Retweet Sayısı, Takipçilerin Ortalama Beğeni Sayısı, Pozitiflik Olasılığı, Etiketlenmelerin Pozitiflik Olasılığı
Youtube	Ortalama İzlenme Süresi, Ortalama Beğeni, Ortalama Beğenilmeme, Ortalama Paylaşım Sayıları, Ortalama Yorum Sayısı, Ortalama Favori Olma, Pozitiflik Olasılığı
Instagram	Ortalama Yorum Sayısı, Ortalama Beğeni Sayısı, Takipçi Sayısı, Takip Sayısı, Pozitiflik Olasılığı, Ortalama Resim Özelliği
Google Haberler	Pozitiflik Olasılığı

Facebook dijital pazarlama kanalının değerlendirme modelinde, öncelikle Python yazılımı sayesinde elde edilen sürekli değişkenlerde her bir marka için ortalama alınarak marka bazında ortalama beğeni, ortalama yorum sayısı, ortalama paylaşım sayıları elde edilebilmektedir. Çalışmanın uygulama kısmında tesadüfi olarak belilrnene on hastane ele alınmıştır. Bundan dolayı, söz konusu değişkenler üzerinden on satırlık bir veri seti elde edilebilmiştir. Ayrıca, Facebook takipçi sayısı ve beğenen sayısı da birer değişken

olarak ele alınabilmiştir. Sürekli değişkenler dışında, gönderilerdeki metinler de analiz edilerek bir değişken olarak veri setine eklenebilmiştir. Metinler ise metin madenciliği yardımıyla analiz edilebilmiştir. İlk olarak, metinlerin analiz edilebilir hale getirilmesi sağlanabilmiştir. Bunun için metinlerdeki noktalama işaretleri kaldırılmıştır. Sayılar filtrelenmiştir. Bir kelime üç harften az ise değerlendirme dışında tutulmuştur. Daha sonrasında Stop Word nodülü yardımıyla "ve", "ise" gibi kelimeler kaldırılmıştır. En son olarak bütün harflerin standart olması için Case Converter nodülü ile küçük harfe çevrilmiştir. Metnin bu hali ile de Zemberek sözlüğü kullanılarak kelimeler köklerine ayrılmıştır. Duygu analizi yardımıyla, ön süreçten geçen metinler öncelikle kelime tabanlı olarak etiketlenmiştir. Etiketlenemeyen kelime veya kelime grupları ise yapay sinir ağları yardımıyla etiketlenmeye çalışılmıştır. Bunun için, ilk olarak etiketlenme yardımıyla cümleler genel olarak üç kategoriye ayrılmıştır. Bunlar; pozitif, nötr ve negatiftir. Daha sonrasında, metinler KNIME programı içerisindeki kelime çantası (bag of words) yardımıyla kelimelerine ayrılmıştır. Daha sonrasında bu kelimeler belge vektörü (Documents Vector) nodülü yardımıyla binary değişkenlere çevrilmiştir. Burada amaç, gönderi içerisinde kelimeler var yok şeklinde 0 1 değişkenleri elde etmektir. Kelime etiketiyle elde edilen kategorilerde bağımlı değişken olarak ele alınmıştır. Bu değişkenler yardımıyla yapay sinir ağları inşa edilmiştir. On markanın tüm metinleri birleştirilerek elde edilen yapay sinir ağ modeli, daha sonra marka bazlı olarak gönderileri sınıflandırmak için kullanmıştır. Bir markanın herhangi bir gönderisi modele girdi olarak verildiğinde, çıktı olarak söz konusu 3 kategoriye aitlik olasılıkları elde edilmektedir. Bir gönderinin pozitif kategorisine ait olasılığı, pozitiflik oranı olarak ele alınmıştır. Daha sonra her gönderiden elde edilen bu değerin ortalaması alınarak ortalama pozitiflik oranı olarak veri setine eklenmiştir. Elde edilen bu veri seti en son olarak boyut indirgeme ile tek bir değişkene çevrilmiştir. Temel bileşenler analizi, Facebook değişkenleri üzerinden on markaya uygulanmıştır. Sonuç olarak, markalara ait Facebook skorları elde edilebilmiştir.

Twitter dijital pazarlama kanalının modelinin kurulmasında API 'den elde edilen değişkenler kullanılmıştır. Sürekli değişkenlerin marka bazında ortalamaları alınmıştır. Burada hem markanın kendi paylaşımları hem de markayı etiketleyerek yapılan paylaşımlar ayrı ayrı dikkate alınmıştır. Bundan dolayı, ortalamalar hem markanın ortalaması hem de kullanıcıların ortalaması olarak iki farklı değişken olarak hesaplanmıştır. Bu ortalamalar birer değişken olarak veri setine eklenmiştir. Metin tabanlı paylaşımlar ise, Facebook kanalında olduğu gibi duygu analizi yardımıyla önce kelime tabanlı sonra da yapay sinir ağ modelli olarak hesaplanmıştır. Önce 10 markaya ait gönderiler bir model oluşturulmuş daha sonrasında ise marka bazlı elde edilmiştir. Ayrıca, hashtag (etiketlenme) ile yapılan paylaşımlar içinde benzer bir model kurulmuştur. Bundan dolayı iki ayrı pozitiflik oranı hesaplanmıştır. Birincisi marka paylaşımlarının algılanmasını gösterirken diğeri ise kullanıcıların marka hakkındaki paylaşımlarının pozitiflik oranını göstermektedir. Bu değişkenler yardımıyla 10 satırlık bir veri seti elde edilmiştir. Elde edilen bu veri seti daha sonrasında temel bileşenler analizi yardımıyla tek bir skora indirgenmiştir. Bu skor markaların Twitter dijital pazarlama kanalı skoru olarak değerlendirilebilmiştir.

Instagram dijital pazarlama modelinde ise değişkenler bir önceki bölümde bahsedildiği şekilde marka bazlı olarak elde edilmiştir. Elde edilen sürekli değişkenlerin ortalamaları alınarak marka bazlı ortalama beğeni, ortalama yorum sayısı elde edilirken yine markanın profiline ait takipçi ve takip edilen sayıları da veri setinin elde edilmesinde kullanılmıştır. Facebook'taki pozitiflik oranı, burada resimlerin altındaki açıklamalar için kullanılmıştır. Gönderilerdeki metinler, ön işleme sürecinden geçirildikten sonra önce etiketlenme

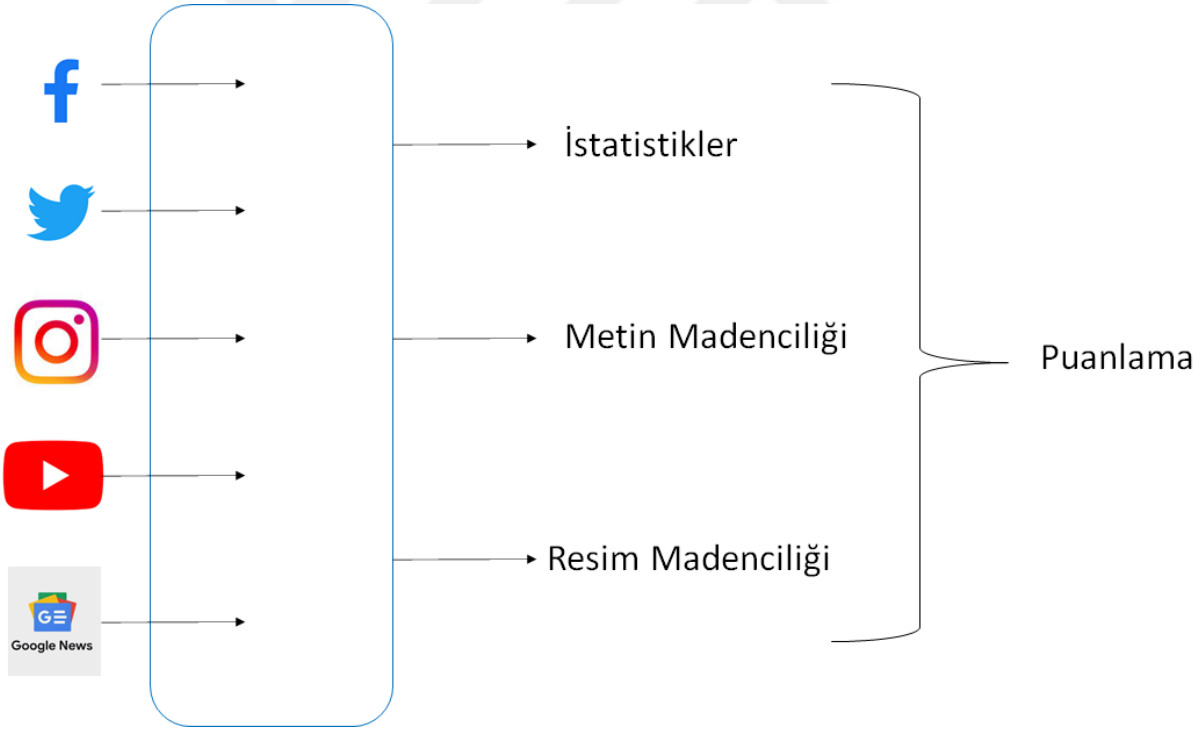
yardımıyla daha sonra da yapay sinir ağları yardımıyla metin değerlendirme modeli inşa edilebilmiştir. Bu model marka bazında gönderileri değerlendirmek için kullanılmıştır. Modelin çıktısı olarak her bir gönderinin pozitiflik oranı elde edilmiştir. Bunların da ortalaması alınarak markanın ortalama pozitiflik oranı elde edilmiştir. Ayrıca gönderilerdeki resimlere ait özelliklerde veri setine eklenmiştir. KNIME içerisindeki Image Reader yardımıyla, resimlerin URL bağlantıları kullanılarak program içerisine indirilmiştir. Bu program içerisine alınan resimler Image Features nodülü yardımıyla birincil istatistiği olan ortalama değerleri resim bazında elde edilmiştir. Buradaki resim ortalamasının anlamı, MxN boyutlu bir resmin piksellerin yoğunlukları üzerinden çizilen histogram grafiğinden hesaplanır. Başka bir deyişle, bir resmin ortalaması o resim için kalitesini gösterir. Bu ortalamaların da ortalaması alınarak marka bazında resim özellik ortalaması olarak veri setine eklenmiştir. Markaların Instagram dijital pazarlama kanalını değerlendirmede sürekli değişkenler dışında metin ve resimlerden elde edilen değişkenlerde dikkate alınmıştır. Bu değişkenler yardımıyla elde edilen veri setini tek bir değişkene indirgemek için temel bileşenler analizinden yararlanılmıştır. En son olarak temel bileşenler analizi nodülü (PCA) kullanılarak markaların skorları elde edilebilmiştir.

Markaların Youtube kanalının değerlendirmesinde Google API ‘leri yardımıyla profilde yayınlanan videolara ait veriler elde edilebilmektedir. Twitter ‘a benzer şekilde hem markanın kendi paylaşımları hem de bu paylaşımlara gelen yorumlar ayrı ayrı değerlendirilmiştir. Videonun izlenme sayısı, beğenilme sayısı, beğenilmeme sayısı, paylaşım sayısı gibi değişkenlerin ortalamaları alınarak marka bazında istatistikler elde edilmiştir. Bunun dışında videonun açıklama kısmında yer alan metinler de duygu analizi ile 3 kategori üzerinden analiz edilmiştir. Diğer dijital pazarlama kanallarındaki metin madenciliği burada da uygulanmıştır. Kanal bazında bütün metinler birleştirilerek, önce ön işleme sürecinden geçirildikten sonra ilk olarak kelime tabanlı bir etiketleme yapılmıştır. Daha sonra da etiketlendirme sonucu bağımlı değişken alınarak tekrar yapay sinir ağları modeli inşa edilmiştir. Bu ağ modeli marka bazlı olarak metinlerin pozitiflik oranlarının hesaplanmasında kullanılmıştır. Ayrıca, videolara gelen yorumlar içinde ayrıca yeni bir yapay sinir ağ modeli inşa edilmiştir. Bu model üzerinden de yorumların değerlendirilmesi yapılarak veri setine eklenmiştir. Yorumlardan elde edilen metinlerin yanı sıra, bunlara gelen beğeni ve paylaşım sayılarının ortalaması alınarak ayrı birer değişken olarak veri setine eklenmiştir. Elde edilen bu 10 markaya ait veri setinden yardımla temel bileşenler analizi uygulanmıştır. Uygulanan PCA nodülü sayesinde markalara ait Youtube skoru elde edilebilmiştir.

Google haberlerde çıkan metinlerin de değerlendirilmesinde sadece metin madenciliği kullanılmıştır. Diğer sosyal medya kanallarında olduğu gibi, bütün haber metinleri birleştirilerek ön işleme tabi tutulmuştur. Böylelikle, anlamsız kelimeler, noktalama işaretleri gibi hatalar giderilmiştir. Daha sonrasında, ilk olarak kelime tabanlı daha sonra da yapay sinir ağ modelleri sırasıyla inşa edilmiştir. Kurulan model üzerinden, Google haberlerde yayınlanan haberler marka bazlı olarak değerlendirilmiştir. Her bir haber metninden elde edilen pozitiflik oranlarının ortalaması alınarak marka bazlı istatistikler elde edilmiştir. Bunun üzerinden markaların Google haberlerdeki durumunu değerlendirme skoru elde edilebilmiştir.

3.3.1.Dijital Pazarlama Skorlama Modeli

Bir önceki bölümde anlatılan modeller üzerinden bütün dijital pazarlama kanallarının birlikte değerlendirilmesi bu bölümde ele alınacaktır. Beş dijital pazarlama kanalından elde edilen her bir skor, markanın o kanaldaki performansını göstermektedir. Bu skorların üzerinden genel bir dijital pazarlama skoru elde edilmesindeki süreçte ise bazı adımlar yapılmıştır. İlk olarak, her bir kanalın kendi içerisinde mak-min normalizasyonu uygulanarak standartlaştırılmıştır. Böylelikle her bir markanın kanal performanslarını gösteren 0 ile 100 arasında bir puan elde edilebilmiştir. Beş kanala da bu normalizasyon uygulandığında, birim yüklüğü sorunu ortadan kaldırılarak standart bir değer elde edilmiştir. Bunun için KNIME içerisindeki Normalizer nodülü kullanılmıştır. Normalleştirilen bu değerler üzerinden ortalamaları alınarak, markaya ait gelen değerlendirme skoru elde edilmiştir. Daha sonrasında ise, bu beş kanaldaki durumunu kıyaslamak için her bir markanın radar grafiği çizilmiştir. Bu grafiklerin elde edilmesi için yine KNIME içerisindeki Radar Plot nodülü kullanılmıştır. Dijital pazarlama skorunu elde etmek için kuurlan modelde, istatistik, metin madenciliği ve resim madenciliğinden yararlanılmıştır. Şekil 9'da kullanılan yöntemlere ait temel gösterime yer verilmiştir.



Şekil 9. Genel Değerlendirmede Kullanılan Modeller

3.3.2.Modelin Yorumlanması

Bu bölümde, önceki bölümlerde tanıtılan değişkenler yardımıyla bir önceki bölümde tanıtılan modellerin uygulanması ele alınacaktır. Uygulamada sağlık bakanlığına bağlı İstanbul'da hizmet veren ve ele alınan tüm dijital pazarlama kanallarına resmi olarak sahip olan hastanelerden tesadüfi olarak seçilen on adet

hastane ele alınmıştır. Ele alınan bu hastaneler üç farklı dönemde incelenerek değerlendirilmiştir. Bu üç dönem, Haziran 2019-Ocak 2020, Ocak 2020-Haziran 2020 ve Ocak 2020-Aralık 2020 dönemleridir. Üç farklı dönem seçilmesinin başlıca sebebi, bütün dünyayı etkisine alan Covid-19 Salgının sektörlere olan etkisinin çalışmalara etkisinin de gözlemlemektir. Bundan dolayı, hem Covid-19 öncesi hem de salgın süresince hastanelerin paylaşımları ve yorumları incelenmiştir. Kurulan model bu üç farklı dönemde çalıştırılmıştır. Modelden elde edilen sonuçlar her dönem kendi içinde değerlendirilmiştir.

3.3.2.1.Birinci Dönem

İlk model, 2019 yılının ikinci yarısı için kurulmuştur. Yani Haziran ile Ocak arasındaki profilde yer alan veriler üzerinden değerlendirilme yapılmıştır. On hastanenin üzerinden yapılan değerlendirme sonuçları Tablo 2'de verilmiştir.

Tablo 2. Birinci Dönem Performans Sıralaması

SAĞLIK KURULUŞLARI	Instagram		Facebook		Google Haber		Twitter		Youtube		Genel Rank
	PUAN	RANK	PUAN	RANK	PUAN	RANK	PUAN	RANK	PUAN	RANK	
H1	81,04	4	25,94	7	0,00	5	40,57	4	22,65	2	7
H2	1,25	9	39,88	6	100,00	1	76,35	2	100,00	1	1
H3	45,31	7	66,72	3	37,50	4	0,98	9	22,65	2	6
H4	100,00	1	16,44	8	0,00	5	100,00	1	1,00	9	3
H5	89,26	2	55,71	5	0,00	5	0,00	10	22,65	2	8
H6	85,44	3	3,26	9	0,00	5	5,97	7	22,15	5	9
H7	59,36	6	88,05	2	0,00	5	28,06	5	0,00	10	5
H8	0,00	10	0,00	10	75,00	2	3,69	8	22,15	5	10
H9	67,89	5	59,14	4	75,00	2	19,51	6	1,17	8	2
H10	17,24	8	100,00	1	0,00	5	67,33	3	12,09	7	4

Tablo 2'e bakıldığında, incelenen dönem içerisinde H2 hastanesi, Instagram 'da sonlarda olmasına karşın diğer 3 kanalda genel olarak üst sıralarda olduğu için genel puanlamada birinci sırada yer alıyor. H4 hastanesi ise Twitter ve Instagram'da birinci iken diğer dijital pazarlama kanallarında son sıralarda olduğundan dolayı genel sıralamada orta sıralarda yer almaktadır. H9 hastanesi ikinci sıradadır ve üçüncü olan H4 ile farklı dijital pazarlama kanalında üst sıralardalar. Listenin sonuncusu durumunda olan H8 hastanesi, Google Haberlerde üst sıralarda yer almasına karşın diğer çoğu dijital pazarlama kanalında sonlarda olduğunda dolayı genel sıralamada da sonunca durumda yer almaktadır. Sıralamaya göre birinci olarak belirlenen H2 hastanesi bu dönemde Google haberler ve Youtube dijital pazarlama kanallarında diğer markaların performansına göre çok iyi durumda görünmesinden dolayı genelde de birinci olmuştur. Buna karşın H7 hastanesi ise bu iki kanalda en düşük başarıya sahip olmasından dolayı on hastane arasındaki sıralamada sonuncu olmuştur.

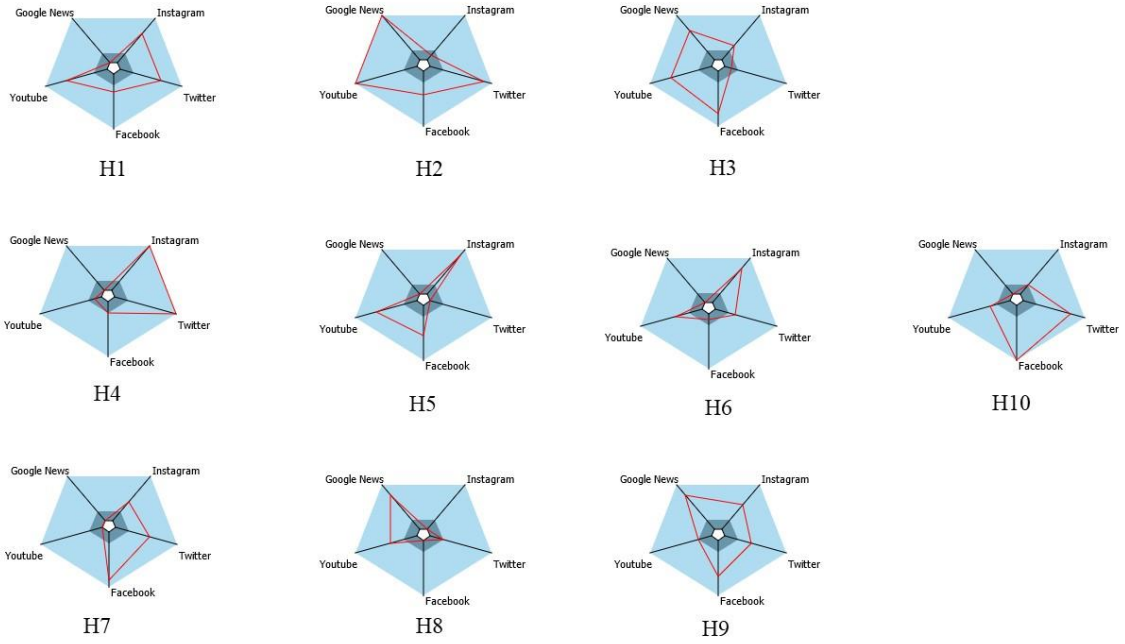
Kanallar üzerinden ayrı ayrı incelemekte mümkün olabilmektedir. Dijital pazarlama kanallarından Instagrama bakıldığında, H4 hastanesi birinci sırada yer almaktadır. Instagrama ait performans göstergeleri incelendiğinde, H4 hastanesine ait resim kalitesinin ve beğeni sayısının diğerlerinden daha fazla olmasından dolayı söz konusu kanalda H4 hastanesinin perfomansı yüksek çıkmıştır. Buna karşın, H8 hastanesi ise bu

kanalda son sırada yer aldığını görmek mümkündür. Bu durum incelendiğinde ise, H8 hastanesinin takipçi sayısının az olması görülebilmektedir. Diğer bir dijital pazarlama kanalı olan Facebook ‘ta ise, H10 hastanesi birinci sırada yer almaktadır. Bu durum incelendiğinde ise, ortalama yorum sayısının ve beğenen sayısının diğer markaların Facebook kanallarındaki göstergelerden daha yüksek olduğu görülmüştür. H8 hastanesi ise Instagram ‘da olduğu gibi Facebook kanalında da son sırada yer almaktadır. Instagram daki benzer durum H8 için Facebook’da da geçerli olmaktadır.

Google haberlerde ise tek gösterge olarak metinlerdeki pozitiflik oranı alındığından sıralamada H2 hastanesi birinci olmasındaki bu durum etkili olmuştur. Twitter ait veriler incelendiğinde ise, H4 hastanesinin birinci sırada olduğu görülmüştür. Twitter a ait performans gösterge değişkenleri açısından markalar incelendiğinde H4 hastanesinin hem kendi paylaşımları hem de etiketlendiği paylaşımlardaki olumlu ifadelerin etkisi görülebilmektedir. Twitter da son sırada yer alan H5 hastanesinde ise, takipçi sayısının az olduğu görülmektedir. Son dijital pazarlama kanalı olarak Youtube incelenmiştir. Youtube kanalına göre H2 hastanesi birinci sırada yer alırken, H7 hastanesi son sırada yer almıştır. Youtube ait performans göstergeleri açısından incelendiğinde ise, H2 hastanesine ait beğeni, izlenme sayısını diğer markalardan daha yüksek olduğu görülmektedir. Bunun aksine H7 hastanesinde ise takipçi ve izlenme sayılarının diğer markalardan daha düşük olduğu söylenebilmektedir.

Markaların dijital pazarlama kanallarının birbirlerine göre durumlarına bakmak için radar grafiklerinden yararlanılmıştır. Bu amaçla KNIME içerisindeki Radar Plot nodülü ile elde edilen sonuçlar değerlendirilmiştir. Dijital pazarlama kanallarının markaların kendi içlerinde durumuna ait graikler Grafik 2 de gösterilmiştir. Grafik 2 incelendiğinde, markalara ait beş dijital pazarlama kanalından hangilerinde daha başarılı hangi kanallarda daha az başarılı olduğunu görebilmek mümkün olabilmektedir. Buradan yola çıkarak, dijital kanal bazında stratejiler üretebilir. H2 hastanesinin Instagram kanalının diğer dört dijital pazarlama kanalına göre daha zayıf olduğu radar grafiği ile görülebilmektedir. Burdan yola çıkarak uygulamanın ikinci aşamasında bu kanala yönelik stratejilere önem verebilir. Böylelikle bu kanaldaki performansını da diğer kanallarda olduğu gibi artırması mümkün olabilecektir.

Veri madenciliği teknikleri ile dijital pazarlama kanallarının performans değerlendirilmesinin ilk aşamasında hem genel bir değerlendirme hemde kanal bazında değerlendirme mümkün olabilmektedir. Tablo 2 incelendiğinde markalara ait dijital pazarlama kanalları bazında skorlarını görebilmek mümkün olabilmektedir. Ayrıca aynı tabloda genel olarak da performans bilgilerini ulaşılabilmektedir. Bunun haricinde, radar grafikleri sayesinde de her bir markanın kendi dijital pazarlama kanallarının performansını kıyaslamak mümkün olabilmektedir.



Grafik 2.Birinci Dönemde Hastanelere ait Radar Grafikleri

Grafik 2 de görüldüğü gibi radarlar incelendiğinde, H1 hastanesinin Google Haberler platformunda kötü olduğu görülmektedir. H2 hastanesi ise Google Haberler ve Youtube kanalarında iyi performans gösterdiği görülmektedir. H3 hastanesi ise, Google Haberler, Youtube ve Facebook dijital kanallarında orta durumda iken Instagram 'da bu kanallara nazaran daha geri seviyededir. H4 hastanesinde ise, Instagram ve Twitter kanallarına yoğunlaşmışken diğer dijital pazarlama kanallarında neredeyse hiç aktiflik gösterememiştir. H5 hastanesi Instagram 'a yoğunlaştığı görülmektedir. H6 ve H7 Google Haberlerde çok pasif kalırken H8 hastanesi Google Haberlerde daha aktif görülmektedir. H9 hastanesi genel olarak dijital pazarlama kanallarında orta seviye ve dengeli seviyede iken H10 hastanesi ise Facebook kanalında aktifliğini göstermektedir.

3.3.2.2.İkinci Dönem

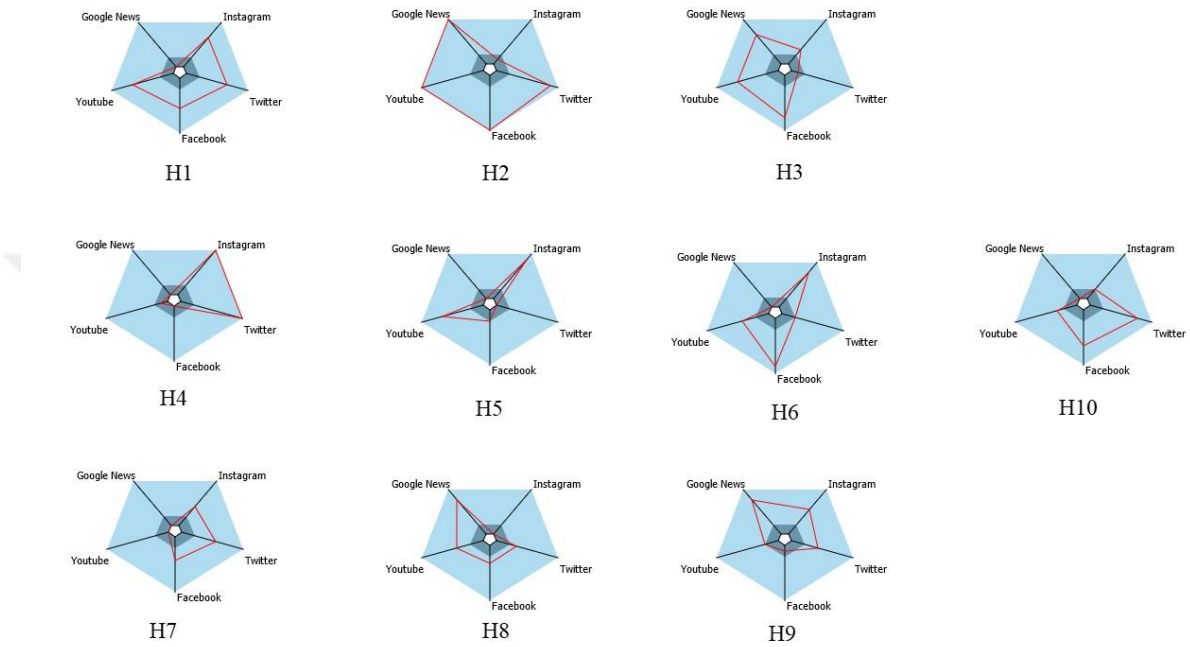
İkinci olarak model, 2020 yılının tamamı için kurulmuştur. On hastanenin üzerinden yapılan değerlendirme sonuçları Tablo 3'te verilmiştir.

Tablo 3.İkinci Dönem Performans Sıralaması

SAĞLIK KURULUŞLARI	Instagram		Facebook		Google Haber		Twitter		Youtube		Genel Rank
	PUAN	RANK	PUAN	RANK	PUAN	RANK	PUAN	RANK	PUAN	RANK	
H1	81,04	4	59,19	5	0,00	5	42,40	4	22,65	2	2
H2	1,25	9	100,00	1	100,00	1	79,16	2	100,00	1	1
H3	45,31	7	76,10	3	37,50	4	0,37	9	22,65	2	5
H4	100,00	1	0,00	10	0,00	5	100,00	1	1,00	9	3
H5	89,26	2	17,17	8	0,00	5	0,00	10	22,65	2	10
H6	85,44	3	78,68	2	0,00	5	2,93	8	22,15	5	4
H7	59,36	6	46,34	6	0,00	5	24,72	5	0,00	10	9
H8	0,00	10	40,92	7	75,00	2	12,24	7	22,15	5	7
H9	67,89	5	15,67	9	75,00	2	16,05	6	1,17	8	6
H10	17,24	8	69,90	4	0,00	5	47,66	3	12,09	7	8

Tablo 3'e bakıldığında, incelenen dönem içerisinde H2 hastanesi, Instagram 'da sonlarda olmasına karşın diğer 4 kanalda genel olarak birinci veya ikinci olduğundan genel puanlamada birinci sırada yer alıyor. Bu dönem içersinde Youtube kanalında genel olarak performans düşüklüğü görülmüştür. H4 hastanesi ise Twitter ve Instagram 'da birinci iken diğer dijital pazarlama kanallarda son sıralarda olduğundan dolayı genel sıralamada üçüncü sırada yer almaktadır. H1 hastanesi ikinci sıradadır ve üçüncü olan H4 ile karşılaştırıldığında ise Google Haberler ve Instagram 'da H4 hastanesi daha iyi performans göstermesine karşın Facebook ve Youtube kanallarında H1 hastanesinin performansı daha ağır bastığından H1 hastanesi, H4 Hastanesinin önünde yer almıştır. Listenin sonuncusu durumunda olan H5 hastanesi, Instagram kanalında başarı göstermesi karşında diğer çoğu dijital pazarlama kanalında sonlarda olduğundan dolayı genel sıralamada da sonunca durumda yer almaktadır.

Markaların dijital pazarlama kanallarının birbirlerine göre durumlarına bakmak için radar grafiklerinden yararlanılmıştır. Bu amaçla KNIME içerisindeki Radar Plot nodülü ile elde edilen sonuçlar değerlendirilmiştir.



Grafik 3.İkinci Dönemde Hastanelere ait Radar Grafikleri

Grafik 3' de görüldüğü gibi, H1 hastanesinin Google Haberler platformunda kötü olduğu görülmektedir. H2 hastanesi ise Google Haberler , Facebook, Twitter ve Youtube kanalarında iyi performans gösterdiği görülmektedir. H2 hastanesi sadece Instagramda aktifliği düşük bir hastanedir. H3 hastanesi ise, Google Haberler, Youtube ve Facebook dijital kanallarında orta durumda iken Twitterda bu kanallara nazaran daha geri seviyededir. H4 hastanesinde ise, bir önceki dönemde olduğu gibi Instagram ve Twitter kanallarına yoğunlaşmışken diğer dijital pazarlama kanallarında neredeyse hiç aktiflik gösterememiştir. H5 hastanesi Instagram 'a yoğunlaştığı görülmektedir. H6 ve H7 bir önceki dönem analizinde görüldüğü gibi bu dönem için de Google Haberlerde çok pasif kalırken H8 hastanesi Google Haberlerde daha aktif görülmektedir. H9 hastanesi Google Haberler ve Instagram 'da orta seviyelerde iken H10 hastanesi ise geçen döneme göre iyi olduğu Facebook kanalında aktifliğini düşürmüştür.

3.3.2.3.Üçüncü Dönem

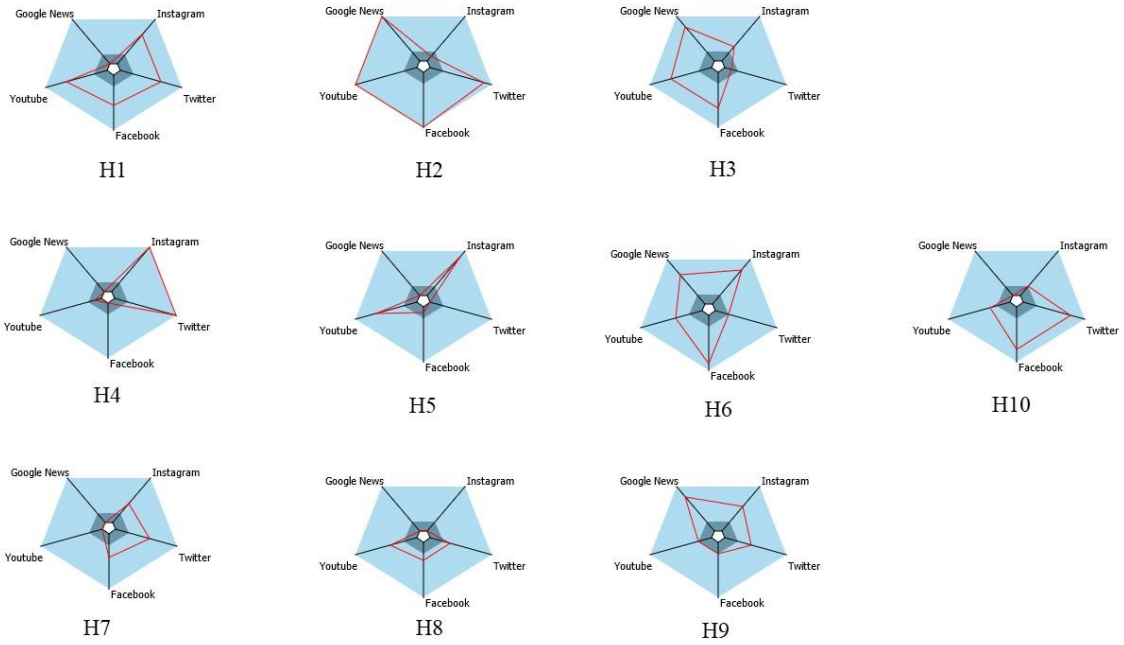
Üçüncü olarak model, 2020 yılının tamamı için kurulmuştur. On hastanenin üzerinden yapılan değerlendirme sonuçları Tablo 4'te verilmiştir.

Tablo 4.Üçüncü Dönem Performans Sıralaması

SAĞLIK KURULUŞLARI	Facebook		Twitter		Instagram		Youtube		Google Haber		Genel Rank
	PUAN	RANK	PUAN	RANK	PUAN	RANK	PUAN	RANK	PUAN	RANK	
H1	63,50	5	42,31	4	81,04	4	22,65	2	0,00	5	3
H2	100,00	1	79,16	2	12,53	9	100,00	1	100,00	1	1
H3	69,33	4	0,54	9	45,31	7	22,65	2	50,00	2	5
H4	0,00	10	100,00	1	100,00	1	1,00	9	0,00	5	4
H5	34,30	8	0,00	10	89,26	2	22,65	2	0,00	5	9
H6	82,74	2	32,45	5	85,44	3	22,15	5	30,00	4	2
H7	48,66	6	24,95	6	59,36	6	0,00	10	0,00	5	8
H8	45,10	7	12,33	8	0,00	10	22,15	5	0,00	5	10
H9	10,97	9	15,95	7	67,89	5	11,74	8	50,00	2	7
H10	82,22	3	47,61	3	17,24	8	12,09	7	0,00	5	6

Tablo 4'e bakıldığında, incelenen dönem içerisinde H2 hastanesi, Instagram 'da sonlarda olmasına karşın diğer 4 kanalda genel olarak birinci olduğu için genel puanlamada birinci sırada yer alıyor. H4 hastanesi ise Twitter ve Instagram 'da birinci iken diğer dijital pazarlama kanallarda son sıralarda olduğundan dolayı genel sıralamada orta sıralarda yer almaktadır. H6 hastanesi ikinci sıradadır ve üçüncü olan H1 ile genel olarak ilk 4 dijital pazarlama kanalında puanları çok yakın olsa da Google haberlerdeki puan farkından dolayı genel sıralamada H1 hastanesinin önüne geçerek genel sıralama da ikinci sırada konumlanmıştır. Listenin sonuncusu durumunda olan H8 hastanesi, çoğu dijital pazarlama kanalında sonlarda olduğunda dolayı genel sıralamada da sonunca durumda yer almaktadır.

Markaların dijital pazarlama kanallarının birbirlerine göre durumlarına bakmak için radar grafiklerinden yararlanılmıştır. Bu amaçla KNIME içerisindeki Radar Plot nodülü ile elde edilen sonuçlar değerlendirilmiştir.



Grafik 4.Üçüncü Dönemde Hastanelere ait Radar Grafikleri

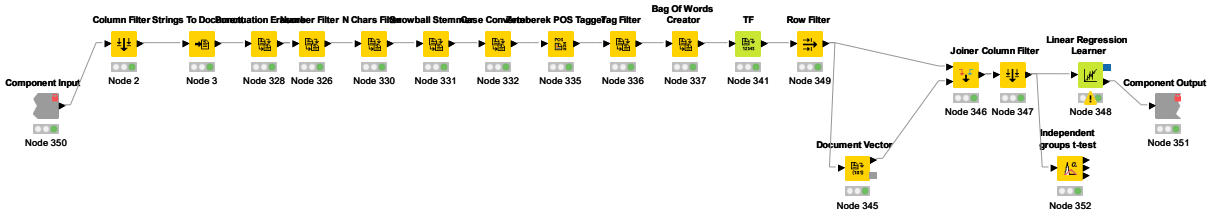
Grafik 4 incelendiğinde, H1 hastanesinin önceki dönemler için yapılan analizlerde olduğu gibi Google Haberler platformunda pasifliğini sürdürmektedir. H2 hastanesi ise Google Haberler, Twitter, Facebook ve Youtube kanalarında iyi performans gösterdiği göstermeye devam etmektedir. H3 hastanesi ise genel olarak çoğu dijital pazarlama kanalında orta seviyelerdedir. H4 hastanesinde ise, önceki dönemlerde olduğu gibi Instagram ve Twitter kanallarına yoğunlaşmaya devam erken diğer dijital pazarlama kanallarında neredeyse aktifliğini artırmamıştır. H5 hastanesi Instagram 'a yoğunlaştığı görülmektedir. H6, H7 ve H8 Google Haberlerde çok pasif kalırken diğer birçok dijital pazarlama kanalında pasif kalmıştır. Bu kanalarda kurumlar hem paylaşım olarak hem içerik olarak zayıf kalmışlardır. Veri seti incelendiğinde, hareketlilik az olması genel skorlama da gerilerde yer almasına önemli rol oynamıştır. H9 hastanesi Google Haberler ve Instagram dijital pazarlama kanallarında orta seviyede iken H10 hastanesi ise Facebook ve Twitter kanallarında aktifliğini göstermektedir.

3.4.Dijital Pazarlama Kanallarının Performansının Geliştirilmesi

Bu bölümde, bir önceki bölümde performansları ölçülerek sıralanan hastaneler için stratejiler üretilmesi amaçlanmıştır. Performanslarını artırmaları adına hastanelerin dijital pazarlama kanallarındaki izleyecekleri yolların belirlenmesi önemlidir. Bu bağlamda literatüre bakıldığında paylaşımlara gelen beğeni, yorum sayısı ve paylaşım sayıları bağımlı değişkenler olarak ele alındığı görülmektedir. Söz konusu amaç için, bu bölümde, her bir kanal için ayrı ayrı olarak yapılan paylaşımlar incelenmiştir. Paylaşımda yer alan metin ve resimler analiz edilerek, kullanılan hangi ögelerin beğeni sayısı, izlenme sayısı ve paylaşım sayısını artırdığı tespit edilmeye çalışılmıştır.

3.4.1.Metin Bazlı Performans Analizi

Metin bazlı performans analizinde, dijital pazarlama kanallarındaki paylaşımlarda yer alan metinler bağımsız değişkenler olarak ele alınmıştır. Böylelikle kullanılan kelime ve kelime gruplarının gönderiye gelen etkileşime etkisi incelenebilmiştir. Duygu analizinde ve pozitiflik oranında kullanılan ön işleme prosedürleri uygulanmıştır. Bu çerçevede, ilk olarak String yapılan Belge (Documents) yapısına çevrilmiştir. Daha sonra, noktalama işaretleri ve sayılar metinden filtrelenmiştir. Bir anlam ifade etmeyen ve bağlaç olan kelimeler Stop Filter nodülü ile temizlenmiştir. Yine KNIME üzerindeki bu nodüllerin ardından, Zemberek kütüphanesi yardımıyla kelimeler köklerine ayrılmıştır. Köklerine ayrılan kelimelerin yer aldığı metinlerden en son olarak kelime çantası (Bag of Words) oluşturulmuştur. Bunun için KNIME' da yer alan Bag of Words nodülünden yararlanılmıştır. Buraya kadarki süreç duygu analizinde yapılan ile aynıdır. Bundan sonra ise etiketleme yerine kelime vektörü oluşturulmuştur. KNIME platformunda yer alan Document Vector nodülü yardımıyla kelime çantasında yer alan kelimeler kullanılarak metinler binary olarak vektörleştirilmiştir. Başka bir deyiş ile, kelime çantasında yer alan kelimeler ilgili metinde olup olmaması üzerinden 0 1 şeklinde kodlanması sağlanmıştır. Böylelikle metinlerin sayısallaştırılması sağlanmıştır. Elde edilen bu değişkenler bağımsız değişkenler olarak ele alınmış ve ilgili bağımlı değişkene etkisi bakılmak için doğrusal regresyondan yararlanılmıştır. Bunun içinde yine KNIME' da yer alan Linear Regression Learner ve Independent groups t-test nodüllerinden yararlanılmıştır. Bu işlemler kanal bazında yapılmıştır. Şekil 10'da KNIME üzerinde kurulan model gösterilmiştir. Sistematik yapuda kullanılan nodülleri görmek mümkündür. Söz konusu sistemde öncelikle metinsel ifadeler filitrelenmesi için sütun filitre nodülü kullanılmış, daha sonra da metin tabanlı veriler belge haline çevrilmiştir. Analiz için gerekli önişlemler metinlere uygulanmıştır. Temizlenen veri analiz için hazır hale getirilmesi sağlanabilmiştir.

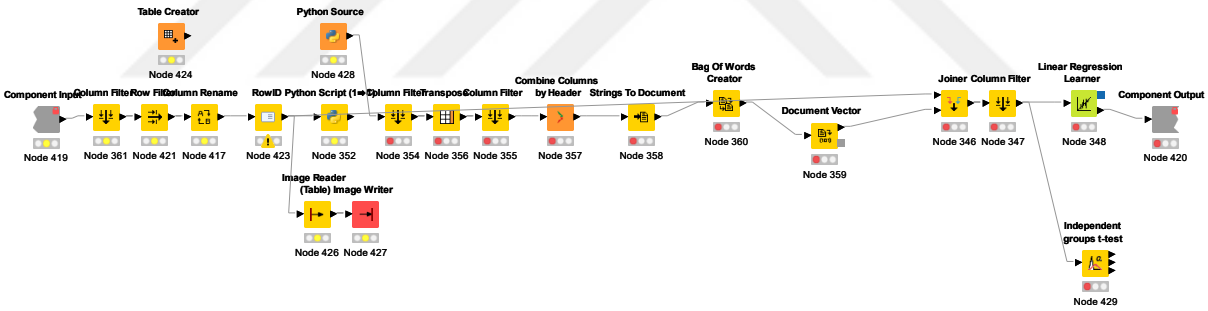


Şekil 10.Metin Bazlı Strateji Geliştirme Modeli

3.4.2.Resim Bazlı Performans Analizi

Resim bazlı performans analizinde ise dijital pazarlama kanallarındaki paylaşımlarda yer alan resimler analiz edilmiştir. Resim içeren gönderiler ve bu gönderilere gelen beğeni sayısı, paylaşım sayısı dikkate alınmıştır. Buradaki amaç, resimlerde kullanılan öğelerin hangilerinin paylaşımı olumlu hangilerinin olumsuz etkisi olduğunu ortaya koymaktır. Bu doğrultuda resimlerin içerisinde yer aldığı öğelerin tespiti için resim analizinden yararlanılmıştır. Derin öğrenme algoritmaları sayesinde bir resimdeki olası öğe ve bu öğeye ait resimde olma güvenirliliği elde edilebilmektedir. Python kullanılarak imagga.com sitesinde yer alan öğe tespit algoritması kullanılmıştır. Söz konusu sitede açılan bir hesap ile oluşturulan API bilgileri Python a

entegre edilir. Paylaşımda yer alan resimler öncelikle Image Reader üzerinden KNIME platformuna indirilir. Ayrıca veri tabanına resimlerin satırlarına beğeni sayısı gibi modelde kullanılacak bağımlı değişkenler de eklenir. Image Reader üzerinden okunan resimler, Python nodülüne girdi olarak verilir. Bu nodülün çıktısı olarak, resimdeki öğeler ve bu öğelere ait güven (confidence) değerleri sunulur. Sunulan bu çıktıdan yardımla en yüksek güvene sahip olan beş öğe resmi temsil eden öğe olarak belirlenir. Çünkü güven derecesi ne kadar yüksek ise o ögenin resimde olma olasılığı o kadar yüksektir. Resmi temsil eden bu beş öğe, daha sonrasında metin bazlı performans analizinde olduğu gibi bütün resimlerde yer alan etiketlerin oluşturduğu bir kelime çantası oluşturulur. Bunun için Bags of Words nodülünden yararlanılır. Daha sonrasında kelime çantasındaki her bir kelime ilgili resim tarafından içerip içermediğini göstermek amacıyla vektörleştirilir. KNIME içerisinde yer alan Document Vector nodülü yardımıyla öğeler binary değişken haline getirilir. Oluşturulan bu yeni değişkenler modelin bağımsız değişkenlerini oluştururken, ilgili resmi içeren paylaşımın aldığı beğeni sayısı, yorum sayısı gibi değişkenler bağımlı değişken olarak ele alınır. Linear Regression Learner nodülü yardımıyla kurulan doğrusal regresyon modeli ile öğelerin bağımlı değişkenlere olan etkisine bakılmıştır. Her bir dijital pazarlama kanalı için %95 güvenirlilik üzerinden istatistiksel olarak anlamlı öğeler üzerinden kanal bazında resim gönderi stratejileri üretilmiştir. Şekil 11'de resim analizi için kullanılan KNIME nodülleri gösterilebilmiştir.



Şekil 11.Resim Bazlı Strateji Geliştirme Modeli

Imagga.com API'si için KNIME üzerindeki Python Source nodülüne EK 3'te yer alan python kodlaması yapılır. Kodlamadaki image_path kısmına resme ait bağlantı linki yazılması yeterlidir. Böylelikle sisteme gönderilen resme ait öğe ve öğeye ait güvenirlilik değeri elde edilebilmektedir.

3.4.3.Kanal Bazlı Performans Geliştirmesi

Bu bölümde, önceki bölümde kurulan modeller üzerinden markalara dijital pazarlama kanalları bazından performanslarını artırmak için stratejiler üretilmesi amaçlanmıştır. İlk olarak 10 hastanenin verileri kanal bazında birleştirilmiştir. Bunun için KNIME içerisinde Joining ve Concatenate nodüllerinden yararlanılmıştır. Daha sonra kanaldan elde edilen verilerin yapısına göre metin ve/veya resim bazlı stratejiler geliştirilmiştir. Google Haberler 'de bağımlı değişken olacak beğeni sayısı, paylaşım sayısı gibi değişkenler olmadığı için bu kanal hakkında strateji geliştirilememiştir. Başka bir ifade ile, Google Haberler 'de sadece

metin çekilebildiğinden tek değişken elde edilebilmiştir. Dolayısıyla bu analizden muaf tutulmuştur. Diğer dijital pazarlama kanalları ise değerlendirmeye alınmıştır. Youtube kanalında resim bazlı paylaşımlar olmadığından bu kanallarda da sadece metin bazlı performans analizi yapılmıştır. Diğer Facebook ve Instagram 'da ise paylaşımın metin veya resim içermesine göre iki analizde uygulanmıştır.

Facebook paylaşımlarında hem resim içerikli hem de sadece metin içerikli gönderilerin paylaşılması mümkündür. Bundan dolayı iki analizde uygulanmıştır. Metin bazlı analiz sonucunda, Facebook paylaşımlarına gelen beğeni sayısı bağımlı değişken olarak ele alınarak doğrusal regresyon modeli kurulmuştur. Kurulan model sonucunda %95 güvenirlilik ise "Anevrizma" kelimesi geçen paylaşımlarda beğeni sayısını artırdığı görülürken, "Hastalık" kelimesi içeren paylaşımların beğeni sayısının az olduğu saptanmıştır. Buna göre, hastanelerin yapacakları paylaşımlarda "Hastalık" olumsuz bir ifade olması hasebiyle kullanmamaları takipçileri açısında ilgilerini artıracaktır. Ayrıca, resim içeren paylaşımlar incelenmiştir. Bunun için ilk olarak resim içeren gönderiler Row Filter nodülü ile filtrelenmiştir. Resim içeren paylaşımlar üzerinden yapılan resim bazlı performans analizine göre, "Hemşire" öğesi içeren gönderilerin paylaşım sayısı artırdığı görülmüştür. İnsanların gönderilerde samimi ve güler yüzlü insanlar görmesi sağlık açısından ilgilerini artırdığı söylenebilir. Hem metin hem de resim bazlı analizlerde Facebook kanalı için paylaşımı etkileyen bir ifade bulunamamıştır.

Instagram paylaşımlarında öncelik resim olmak üzere metinlerde yer almaktadır. Bundan dolayı resim analizinin yanında resimlerin altında yer alan etiketler ve açıklamalar üzerinden de metin bazlı analiz gerçekleştirilmiştir. Metin bazlı analizin sonucunda kurulan regresyon analizinde "Çocuk" ve "Ameliyat" kelimelerinin katsayıları negatif bulunurken, "Baş" kelimesine ait katsayı pozitif olarak hesaplanmıştır. Buna göre, toplum olarak çocuk sağlığının öneminden dolayı çocuk hastalıkları ve çocuklar ile ilgili sağlık sorunları takipçileri olumsuz etkilemektedir. Benzer şekilde ameliyat kavramı da kişilerdeki önyargıdan dolayı ağır ve şiddetli hastalığı temsil ettiğinden dolayı olumsuz algılanmaktadır. Bundan dolayı, sağlık kuruluşları açısından yapılacak paylaşımlarda, çocuk ve ameliyatlarla ilgili gönderiler için daha yumuşak kelimelerin tercih edilmesi önerilmektedir. Bu kelimelerin kullanılmasının elzem olduğu durumlarda ise sandviç kuruluna uygun şekilde metinlerin düzenlenmesi gönderinin etkinliğini artıracağı düşünülmektedir. Resim bazlı Instagram paylaşımlarında ise, Facebook kanalında da olduğu gibi "Hemşire" öğesi bu kanalda da beğeni sayısını artırdığı görülmüştür. Ayrıca, "Vitamin" öğesi içeren paylaşımların da beğeni üzerinde pozitif etkisi olduğu belirlenmiştir. Vitaminin yararlı olması ve hem sağlıklı hem de hastalar için etkin olarak günlük yaşamda genellikte tercih edilmesi takipçilerde merak uyandırmaktadır. Hangi vitaminin neye iyi geldiğini anlatan paylaşımlara olan ilgi, kullanıcıların bu gibi gönderilere takip etmesini artırmaktadır artırmaktadır.

Twitter dijital pazarlama kanalında ise, sadece metin bazlı analiz yapılması mümkün olmuştur. Resimlere ait bağlantılar API üzerinden çekilemediğinde resim bazlı stratejiler bu kanal için uygulanamamıştır. Metin bazlı analizinden elde edilen sonuçlara göre, "Meyve" kelimesi beğenileri artırırken "Riskli" kelimesinin katsayısı negatif olarak hesaplanmıştır. Ayrıca, bağımlı değişken olarak retweet sayıları dikkate alınarak regresyon modeli de kurulmuştur. Bunun sonucunda ise, "Hastalık" ve "Prostat" kelimeleri retweet sayısını düşürmektedir. Bu iki kelimenin de olumsuzluk içermesi ve konuşulmaktan çekinilen kelimeler olmasından dolayı beklenen bir sonuç olmuştur. Ağızdan ağıza pazarlamanın dijital ayağı olarak görülebilen retweet sayısı için hastanelerin daha olumlu ifadeler kullanması veya bu konularda daha farklı bir planlama yapması önem arz etmektedir. Pandemi süreci açısından bakıldığında bağışıklığın ön plana çıkmış

olması meyveye olan ilgiyi artırmıştır. Bundan dolayı, en ucuz ve en kolay bağışıklık sağlayıcı olması meyve içerikli paylaşımlara ilgiyi artırmıştır.

Son olarak, Youtube dijital pazarlama kanalı incelenmiştir. Twitterda olduğu gibi sadece metin bazlı inceleme yapılabilmiştir. Youtube da videolara gelen beğeni sayısının yanında izlenme sayısı da bağımlı değişken olarak değerlendirmeye alınmıştır. Beğeni sayısının bağımlı değişken olarak alındığı modelin sonucunda, "İdrar" kelimesinin geçtiği başlık ve açıklama metinli videolara beğenin arttığı görülmüştür. İkinci model olan, videonun izlenme sayısı bağımlı değişken olarak ele alınmıştır. Kurulan modelin sonucunda ise, "Göz" kelimesini başlıkta veya içerikte yer verilen videolarda izlenme sayısının düştüğü tespit edilmiştir. Bu iki model üzerinden, insanların ürolojik sorunlarını dile getirmekten çekinmeleri ve bunu araştırarak çözmeye çalışmalarından dolayı, bu konudaki videoları izleyerek öğrenmeye çalıştığı yorumu yapılabilir.

Elde edilen kelime ve resim bazlı ipuçları strateji geliştirmede ana unsurlar olabilmektedir. Analizler sonucunda hangi öğenin nasıl takipçilerde olması veya potansiyel müşterilerde ne gibi etkiler yaptığı ortaya konulabilmektedir. Bu bulgular, yeni yapılacak paylaşımlara yön vermesi açısından önemli olabilmektedir. Bir sonraki paylaşımda nelere yer verileceği veya verilmemesi gerektiği yönünde bulgular oluşturulmaktadır. Çalışmanın uygulama kısmında elde edilen sonuçlara göre, kanal bazında stratejiler üretmek mümkün olmaktadır. Instagram paylaşımlarında vitamin içeren ve bunları konu alan paylaşımların rağbet gördüğü bulgusu elde edilmiştir. Buna göre, vitaminlerin kullanımı, hangi rahatsızlıklara iyi geldiği yönünde yapılacak paylaşımlarla hem kullanıcılar bilgilendirilir hem de onların ilgileri çekilebilecektir. Böylelikle hem sosyal sorumluluk açısından bilgilendirme yapılmış olacak hem de potansiyel müşterilere kapının açılması sağlanacaktır. Benzer şekilde, Facebook kanalında ise hastalık gibi olumsuz çağrışım yapan kelimelerden uzak durarak daha çok şifa, tedavi konularına değinmek stratejik olarak daha doğru sonuçlar doğuracaktır. Facebook kanalı gibi diğer sosyal medya kanallarında da aynı hassasiyeti görmek mümkündür. Hastalık kelimesi Twitter kanalı içinde aynı olumsuzluğa sahip olduğundan bu iki kanalda ortak bir strateji kullanılarak ortak paylaşım yapılabilir. Şifa veya tedavi gibi olumlu çağrışımların yer aldığı paylaşımlar ön plana çıkarılabilir. Youtube da ise daha çok görsel durum söz konusu olduğundan, bu kanalın kendi dinamikleri üzerinden stratejiler geliştirmek daha uygun olacaktır. Youtubeda rağbet gören noktalar için kısa bilgilendirme videoları paylaşmak faydalı olacaktır. Yapılan analizler sonucunda idrar kelimesinin "çıkması sebebiyle, üroloji uzmanlarının bilgilendirme videoları çekilebilir veya bu hastalık için geliştirilen en son teknolojik tedavi yöntemleri vurgulanabilir. Örnekten yola çıkarak, hastalığın kendisi veya hastalık ile ilişkisi olan gelişmelerin yer alacağı paylaşımların yapılması sosyal medya kanalının etkinliğini artırabileceği düşünülmektedir.

3.5.Genel Değerlendirme ve Tartışmalar

İşletmeler müşterilerine hitap etmek için reklamlar gibi birçok iletişim kanalını kullanabilirler. Böylelikle hem pazar paylarını korumaya hem de ürün ve hizmetlerini duyurmaya çalışabilirler. Günümüzde teknolojinin gelişmesi ile bu iletişim kanalları daha çok dijital medyaya kayabilmektedir. Zhu ve Chen (2015) yılında sosyal medya ve insan ihtiyaçları tatmini üzerine yaptıkları çalışma da dijital medya kanallarını dört kategoriye ayırmışlardır: İlişki (Relationship), kendi kendine medya (Self Media), iş birliği (Collaboration) ve yaratıcı satış noktası (creative outlets). Sosyal medyalar hizmet şekil ve argümanlarına göre bu kategorilere

hizmet etmektedir. Örneğin Youtube sosyal ağı kişilerin birbirlerine ilgilerini ve yaratıcılıklarını göstermesine imkân veren yaratıcı satış noktası olarak tanımlanmıştır. Tüzel ve gerçek kişilikler bu sosyal medyaları kullanırken kanalların dinamiklerine göre iletişim yönleri değişmektedirler. Bundan dolayı, bir işletmenin söz konusu dört iletişim kategorisinde de aktif olarak performans gösterebilmesi için bu kanallardaki potansiyel müşterilerinin ihtiyaçlarını iyi bilmesi gerekmektedir. Bu çalışmada dört kategoriye en uygun ve yoğun olarak kullanılan beş dijital pazarlama kanalı hem ayrı hem birlikte değerlendirilmiştir. Rao ve arkadaşlarının geliştirdiği Klout Skor (Rao vd, 2015) çalışmasına Instagram, Youtube gibi güncel dijital pazarlama kanallarının eklenerek bütün dijital iletişim kanalları dikkate alınması sağlanmıştır. Ayrıca, gerçek kişilere uygulanan çalışma markalar üzerinden de uygulanabilirliği gösterilerek işletme literatürüne kazandırılmıştır. En son olarak, söz konusu performans skorunun artırılması için stratejiler üretilmesi çalışmanın başlıca özgünlüklerinden birisidir.

Ele alınan on hastane kuruluşunun üç dönem boyunca karşılaştırılabilmiştir. Bu karşılaştırma sonucuna göre, H2 hastanesi bütün dönemlerde birincilik göstermiştir. Başka bir ifade ile H2 hastanesi dijital pazarlama kanallarını yönetmede diğer hastanelere göre daha başarılı olduğu görülmektedir. İstikrarlı olarak performansını sürdürmektedir. H2 hastanesinin aksine H8 hastanesi ise ele alınan dönemlerin ikisinde sonuncu olurken bir dönemde yedinci sıradadır. Genel olarak sonuncu olan bu hastane süreci en düşük performans ile yöneten hastanelerden birisidir. Diğer sekiz hastanede ise dönemlerde sıralama farklılıkları gösterse de genel bakışta çok büyük farklılıklar göze çarpmamaktadır.

Hastanelere ait ele alınan dijital pazarlama kanallarının üç dönemleri karşılaştırmasının yanı sıra, söz konusu dönemlerdeki paylaşımlarındaki metin ve resim öğeleri analiz edilmiştir. Böylelikle, sektördeki dinamiklerin anlaşılması amaçlanmıştır. Araştırmanın sonucunda sektördeki kurumları takip eden müşterilerin neler tepki verdikleri tespit edilmiştir. Beğeni, yorum gibi performans kriterleri üzerinden kurulan modeller üzerinden stratejiler üretilmiştir. Örneğin, sağlık sektörü için Facebook ve Twitter dijital pazarlama kanallarında vitamin ögesinin ön plana çıktığı ve pozitif etkisi olduğu tespit edilmiştir. Buna göre, yeni yapılacak paylaşımlarda vitamine önem verilmesi önerilmektedir. Beslenme ve diyetetik bölümlerine ait doktor ve uzmanların bu konuda verecekleri demeçlere veya görüntülü görüşlerine yer verilmesi sağlık kuruluşlarının dijital pazarlama da amaçlarına ulaşmada etkili rol oynayacağı öngörülmektedir. Benzer şekilde bakıldığında hastalık gibi olumsuz anlam içeren kelimeler yerine şifa veya tedavi gibi olumlu his uyandıran cümleler ile revize edilmesi tavsiye edilmektedir. Göz gibi kelimelere bakarak bazı organlarda önem artışına ve ilginin artması ile hangi servislerin ön plana çıkarılması gerektiği tespit edilebilmektedir. Buna göre, göz hastalıklarında ve üroloji gibi alanlarda son gelişmeler ve yöntemlerden bahsedilebilir. Ayrıca bu alanlardaki eldeki teknolojiler pazarlama unsuru olarak kullanılabilecekleri stratejiler üretilebilir. Analiz ile organlara ait hastalıklarda hangilerinin ön plana çıkarılması gerektiği veya önem verilmesi gerektiği tespit edilebilir.

Sonuç olarak, işletmelerin dijital pazarlama kanallarındaki performansını ölçmekte kullanılması için önerilen bu çalışma beş sosyal medya kanalını birlikte alması sebebi ile özgünlük sağlanmıştır. Ayrıca, çalışmanın ilk bölümünde sektördeki markaların durumunu ortaya koymaya çalışırken, ikinci bölümde ise performanslarını artırmak için stratejiler önerilmesi hedeflenmiştir. Böylelikle, markalar yeni paylaşımlar üretirken hem metin hem görsel olarak kullanacakları argümanların, müşteriler için ilgili dönemde olumlu veya olumsuz karşılanacağını öngörmesi sağlanabilecektir. Çalışmada ele alınan dönemlerde bağışıklığın

vurgulanmasından dolayı, meyve ve vitamin gibi bağışıklık destekleyen içeriklerin kullanılması paylaşımlara olan ilgiyi artırdığı gözlemlenmiştir. Elde edilen bu sonuçlar dönem için tutarlı olduğu söylenebilmektedir.

4. SONUÇ VE ÖNERİLER

İnternetin yaygınlaştığı çağımızda markalardaki satış ve pazarlamanın odak noktaları dijitalleşmeye başladığı söylenebilmektedir. Geleneksel pazarlama araştırmaları ve reklam gibi pazarlama argümanlarının değerlendirilmesi uzun sürerken dijital pazarlama ile bu durum anlık olarak değerlendirilebilme imkânı sağlayabilmektedir. Ayrıca geleneksel pazarlamanın belirli kitle iletişim kanallarında bile ulaşabileceği potansiyel müşteri sınırlı olabilmektedir.

İnternetin ve teknolojinin gelişmesi ile birlikte daha geniş kitlelere ulaşmak hem de pazarlama stratejilerinin geri bildirimi almanın maliyet ve süreci azalması sağlayabilmektedir. Sosyal medyanın gelişimi ile markaların kendi dijital pazarlama kanallarındaki performanslarını değerlendirmesi önem kazanmaya başladığı ifade edilebilir. Ayrıca web 2.0 ile anlık ve karşılıklı iletişiminde getirisi ile yeni pazarlama stratejileri üretilmesi vazgeçilmez olmaya başlamıştır.

Bu çalışmada, ilk olarak markalara ait dijital pazarlama kanallarındaki performansın hem kanal bazında hem de bütüncül olarak değerlendirilmesi amaçlanmıştır. Bu bağlamda Zhu & Chen (2015) çalışmasındaki sosyal medya matrisi ile birlikte geleneksel haber kaynaklarını dikkate almak için dijital platformdaki Google Haberleri dikkate almışlardır. Zhu & Chen in önerdiği profil bazlı veya içerik bazlı olmak üzere özelleştirilmiş ve yaygın mesaj kanallarını temsilen ülkemizde en yaygın kullanılan sosyal medya kanalları dikkate alınmıştır. Sosyal medya matrisindeki ilişki kavramına karşılık Facebook, yaratıcı satış noktası için Youtube, Instagram, kendi kendine medya kavramına karşılık Twitter dijital pazarlama kanalları uygulamaya dahil edilmiştir.

Çalışmanın uygulama kısmında İstanbul'da hizmet veren sağlık bakanlığına bağlı özel hastaneler ele alınmıştır. Bu hastanelerin dijital pazarlama kanallarından ayrı ayrı veriler çekilmiştir. Web madenciliği olarak da ele alınan bu aşamada KNIME içerisindeki nodüllerin yanı sıra dijital pazarlama kanallarının kendilerinin sundukları API ve Python dilinde yazılan kütüphanelerden yararlanılmıştır. Literatürde sıklıkla kullanılan temel istatistiklerden elde edilmiştir. Beğeni sayısı, paylaşım sayısı, takipçi sayısı gibi profillerde yer alan temel değerlerin yanında markaların dijital pazarlama kanallarında paylaştıkları resim ve metinlerden oluşan dinamik bir veri seti elde edilmiştir. Elde edilen veri setindeki metinler üzerinden duygu analizi uygulanmıştır. Literatürdeki en çok kullanılan 3'lü kutupsal analiz dikkate alınmıştır. Sosyal medyadaki gönderilerin takipçiler üzerindeki etkisini gösteren çalışmalardan yola çıkarak, metin madenciliğindeki tekniklerden başarısı en yüksek olan yapay sinir ağları ve terim-frekans yöntemleri ile oluşturulan model yardımıyla metinlerin pozitiflik oranları elde edilmiştir. Bu oran dijital pazarlama performansını belirlemede bir değişken olarak kullanılmıştır. Gönderilerdeki resimlerin analizinde ise ilk olarak resimlere ait temel istatistikler kullanılmış, daha sonrasında ise derin öğrenme ile resimlerdeki nesneler elde edilerek metin madenciliğine benzer bir model inşa edilmiştir.

İnşa edilen model üç ayrı dönemde uygulanarak veriler elde edilmiş ve örneklemde uygulanmıştır. Her üç ayrı dönem için de hastaneler genel performansları üzerinden sıralanmıştır. Ele alınan üç dönemde de sıralamalarda büyük farklılık olmamakla birlikte, markaların kanallara verdikleri ağırlıklarda ciddi bir değişim görülememiştir. Fakat markaların rakiplerine göre üstün oldukları kanallar ve performanslar

belirlenebilmektedir. Hastanelerden bazıları Facebook ve Instagram ‘da daha aktif olmayı seçerken bazıları Twitter hesaplarında daha başarılı oldukları görülmüştür.

Her bir dijital pazarlama kanalarında ayrı ayrı kurulan model üzerinden önce kanal bazlı daha sonra kanalların performansları üzerinden gelen bir dijital pazarlama performans değerlendirme modeli kurulmuştur. Anger ve Kittl ‘ın çalışmalarında Twitter performans değerlendirmesi, Rao ve arkadaşlarının oluşturdukları Klout Skoru modeli dikkate alınmıştır. Benzer şekilde He ve arkadaşlarının 2013 çalışmasındaki gibi pizza şirketlerinin karşılaştırmasında dijital pazarlama kanallarını kullanmışlardır. Bu üç çalışmada eksik olarak görülen metin madenciliği ve resim analizi ile daha ayrıntılı bir dijital pazarlama performans modeli inşa edilebilmiştir. Klout skoru modelinde birden fazla sosyal medyayı dikkate alırken metinlerdeki paylaşımların içerikleri dikkate alınmamıştır. Çalışmamızda ise Klout skorundaki gibi birden fazla kanal dikkate alınırken eksik görülen metin ve resim madencilikleri modele dahil edilmiştir. Böylelikle markaların elde edilen dinamik model yardımıyla, dönem içerisinde rakiplerine göre dijital pazarlama kanallarındaki durumlarının tespit edilmesi ve karşılaştırılması mümkün olabilmektedir. Elde edilen sonuçlar yardımıyla, markaların hem genel olarak hem de dijital pazarlama kanalları açısından ayrı ayrı olarak değerlendirmek ve karşılaştırma imkânı sağlanabilmektedir. Ayrıca, kanal bazlı performans ile markaların hangi dijital pazarlama kanallarında başarılı hangilerinde zayıf kaldığı tespit edilebilmektedir. En son olarak da periyodik olarak markaların dijital pazarlama skorları elde edilebilmekte, kurulan dinamik yapı sayesinde, markalar dönemsel olarak durumlardaki iyileşme değişim gözlemlenebilme imkânı sahip olabilmektedir.

Uygulamanın ikinci bölümde ise, yeni paylaşımlar ve pazarlama için yeni stratejilerin veri madenciliği ile üretilmesi amaçlanmıştır. Duygu analizindeki yapılan çalışmalarda kullanılan dil ile takipçiler arasında doğrudan bir ilişki olduğunu göstermektedir. Bu bağlamda markaların da yeni ürün ve hizmetlerini dijital pazarlama kanallarında nasıl ifade edecekleri önem kazanmıştır. Benzer şekilde gönderilerde kullanılan ve ilgi çekmesi için tercih edilen görsellerde, metinlerdeki gibi potansiyel müşterilere ulaşmada etkili olduğunu gösteren çalışmalar da mevcuttur. Bundan yola çıkarak hangi ifadelerin ve görsellerin sektörde ilgi gördüğü ve yeni takipçiler elde etmede etkili olduğu araştırılması yapılmıştır. Metin madenciliği ve resim madenciliğinden elde edilen ifade ve nesneler ile beğeni sayısı, takipçi sayısı arasındaki etki için regresyon analizinden yararlanılmıştır. Elde edilen veri madenciliği ve istatistiksel modeller yardımıyla, sektörün durumuna göre kanal bazında paylaşım stratejileri belirlenebilmekte ve sektör dinamikleri hakkında bilgi edinilebilmektedir. Mariani ve arkadaşlarının 2016’da turizm sektörü üzerindeki yaptıkları metin madenciliği üzerinden turistlerin istek ve taleplerini belirlemeyi hedeflemişlerdir. Bu çalışmada benzer bir model ile sağlık kuruluşları üzerinde hem metin hem resim üzerinden yapılmıştır. Elde edilen sonuçlara göre stratejiler üretilebilmektedir. Ele alınan dönemler içinde, vitamin, meyve gibi gıda temelli kelimelerin ön plana çıkması ve olumlu etkisinden dolayı, pandemi süreci açısından bakıldığında bağışıklığın ön plana çıkmış olması meyveye olan ilgiyi artırmıştır. Bundan dolayı, en ucuz ve en kolay bağışıklık sağlayıcı olmasından dolayı meyve içerikli paylaşımlara ilgi artmıştır. Beslenme uzmanlarının yer aldığı ve meyve vitamin gibi takviyelerin bağışıklık üzerinde etkilerine yer verdikleri kısa videolar paylaşılması önerilmektedir. Ayrıca, yapılan analizler sonucunda üretilen strateji için elde edilen kelimeler üzerinden bazı hastane servislerinin veya hastalıkların dönemsel olarak önemi ortaya çıkarılması mümkün olabilmektedir. Analiz sonuçlarına göre servis ile ilgili kelimelerin çıkması sebebiyle, söz konusu servis uzmanları tarafından oluşturulacak bilgilendirme videoları çekilebilir veya ilgili hastalık için geliştirilen en son teknolojik tedavi yöntemleri

vurgulanabilir. Yeni gelişmelerin ve hizmetlerin tanıtımı üzerine reklamlar ve tanıtımlar yapılabilir. Yeni tanıtımların yanı sıra kullanılan argümanda önemli bir stratejiyi oluşturmaktadır. Ele alınan dönemler açısından bakıldığında, hastalık kelimesi Twitter kanalı içinde aynı olumsuzluğa sahip olduğundan şifa veya tedavi gibi olumlu çağrışımların yer aldığı paylaşımlar ön plana çıkarılabilir. Twitter üzerinde yapılan paylaşımlarda elde edilen bir başka bulgu ise göz ve gözle ilgili paylaşımlardır. Bundan yola çıkarak göz hastalıkları, gözlük kullanımı gibi alanlarda paylaşımların yapıldığı stratejiler üretilebilmektedir.

Genel olarak bakıldığında, metin ve resim analizi sonuçlarından yola çıkarak sağlık kuruluşlarının beslenme ve diyetetik, göz hastalıkları ve üroloji gibi alanlarda son zamanlarda yapacakları paylaşımlar ile markalarına değer katacakları, müşterilerinin bu alanlarda yoğunlaştığı görülmektedir. Bunun başlıca nedeni pandemi sürecinde insanların daha çok evde kalarak beslenme alışkanlıklarındaki değişim, bağışıklık sisteminin ön plana çıkması ve iş hayatının dijitale taşınması ile birlikte göz ve göz ile ilgili durumların artması olabilir.

Sektör uygulanan çalışmalara ek olarak uygulama ile markalara ait ele alınabilecek dijital pazarlama kanallarının performans ölçümü ile rakiplerin durumları görülmesi sağlanabilmektedir. Böylelikle hem rakiplerin durumlarına göre değerlendirme imkânı sağlanabilecektir. Rakip analizi ile birlikte dijital pazarlama kanallarındaki performansın artırılması için yeni stratejiler üretilerek, pazardaki payını ve markanın görünürlülüğünün artması mümkün olabilecektir. Markalar dijital pazarlama kanallarını değerlendirmekle birlikte yeni stratejiler üretebilecektir. Bununla birlikte, rakiplerine göre avantaj sağlayabilecektlerdir. Bu yönüyle çalışmanın markalara iş dünyasındaki dinamiklerine katkı sağlayabileceği düşünülmektedir.

Bundan sonra yapılacak çalışmalarda, KNIME üzerinde yapılan bu sistemin web tabanlı olarak yapılması dijital pazarlama sektöründe bütüncül bakış açısı kazandırabileceğinden önerilmektedir. Uygulama da böylelikle pratiklik elde edilebileceği düşünülmektedir.

Ayrıca, yapılacak yeni çalışmalarda sağlık sektörü dışında diğer sektörlerde de uygulanması önerilmektedir. Finans sektörü, eğitim sektörü, inşaat sektörü gibi farklı sektörler ele alınabilir.

Önerile ilave olarak, çalışmada yer alan göstegelerden farklı değişkenlerinde tercih edilmesi ve seçilen sektöre göre farklı kanallarında tercih edilmesi uygun olabilecektir. Bir başka öneri ise, veri madenciliği dışında diğer yöntemlerle entegre yapıların oluşturulması üzerinedir. Farklı disiplinler ve yöntemlerle uygulamanın geliştirilmesi önerilmektedir.

KAYNAKÇA

Abdullah, S., Murnane, E. L., Costa, J. M., & Choudhury, T. (2015, February). Collective smile: Measuring societal happiness from geolocated images. In *Proceedings of the 18th ACM Conference on Computer Supported Cooperative Work & Social Computing* (pp. 361-374).

Agarwal, A., Xie, B., Vovsha, I., Rambow, O., & Passonneau, R. J. (2011, June). Sentiment analysis of twitter data. In *Proceedings of the workshop on language in social media (LSM 2011)* (pp. 30-38).

Akcan, A., & Kartal, C. (2011). İMKB Sigorta Endeksini Olusturan Sirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları İle Tahmini. Muhasebe ve Finansman Dergisi, (51), 27-40.

Akgül, E. S., Ertano, C., & Diri, B. (2016). Twitter verileri ile duygu analizi. *Pamukkale University Journal of Engineering Sciences, 22*(2).

Akundi, A., Tseng, B., Wu, J., Smith, E., Subbalakshmi, M., & Aguirre, F. (2018). Text mining to understand the influence of social media applications on smartphone supply chain. *Procedia Computer Science, 140*, 87-94.

Akyüz, A. (2013). Sosyal medyada müşteri etkileşimi ve firmalar açısından önemi. *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, *2*(2), 5-22.

Alan, A. K., Kabadayı, E. T., & Erişke, T. (2018). İletişimin Yeni Yüzü: Dijital Pazarlama Ve Sosyal Medya Pazarlamasi. *Elektronik Sosyal Bilimler Dergisi, 17*(66), 493-504.

Alpar, R. (2011). Çok değişkenli istatistiksel yöntemler. Ankara: Detay Yayıncılık, 286-301.

Altman, E. I., Marco, G., & Varetto, F. (1994). Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience). Journal of banking & finance, 18(3), 505-529.

Amato, G., Bolettieri, P., Monteiro de Lira, V., Muntean, C. I., Perego, R., & Renso, C. (2017, August). Social media image recognition for food trend analysis. In *Proceedings of the 40th*

international ACM SIGIR conference on research and development in information retrieval (pp. 1333-1336).

Anger, I., & Kittl, C. (2011, September). Measuring influence on Twitter. In *Proceedings of the 11th international conference on knowledge management and knowledge technologies* (pp. 1-4).

Bachmann, P. (2020). Public Marketing: Case of Self-governing Regions´ Brands in Online Environment.

Bakhshi, S., Shamma, D. A., & Gilbert, E. (2014, April). Faces engage us: Photos with faces attract more likes and comments on instagram. In *Proceedings of the SIGCHI conference on human factors in computing systems* (pp. 965-974).

Barutçu, S., & Tomaş, M. (2013). Sürdürülebilir sosyal medya pazarlaması ve sosyal medya pazarlaması etkinliğinin ölçümü. *İnternet Uygulamaları ve Yönetimi Dergisi*, *4*(1), 5-24.

Basarslan, M. S., & Kayaalp, F. (2020). Sentiment Analysis with Machine Learning Methods on Social Media. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, *9*(3), 5-15.

Baykara, M., & Gürtürk, U. (2017). Sosyal Medya Paylaşımlarının Duygu Analizi Yöntemiyle Sınıflandırılması, 2. *International Conferance on Computer Science and Engineering*, 911-916.

Bergenti, F., Caire, G., & Gotta, D. (2013, November). An Overview of the AMUSE Social Gaming Platform. In *WOA@ AI* IA* (pp. 85-90).

Berthon, P., Pitt, L. F., & Watson, R. T. (1996). The World Wide Web as an advertising medium: Toward an understanding of conversion efficiency. *Journal of advertising research*, *36*(1), 43-55.

Bini, S. A. (2018). Artificial intelligence, machine learning, deep learning, and cognitive computing: what do these terms mean and how will they impact health care?. The Journal of arthroplasty, 33(8), 2358-2361.

Bulunmaz, B. (2016). Gelişen teknolojiyle birlikte değişen pazarlama yöntemleri ve dijital pazarlama. Trt Akademi, 1(2), 348-365.

Chaffey, D., & Ellis-Chadwick, F. (2019). *Digital marketing*. Pearson UK.

Chaffey, D., & Smith, P. R. (2017). *Digital marketing excellence: planning, optimizing and integrating online marketing*. Taylor & Francis.

Chen, Z. Y., Fan, Z. P., & Sun, M. (2019). Individual-level social influence identification in social media: A learning-simulation coordinated method. *European Journal of Operational Research*, *273*(3), 1005-1015.

Chua, T. H. H., & Chang, L. (2016). Follow me and like my beautiful selfies: Singapore teenage girls' engagement in self-presentation and peer comparison on social media. *Computers in Human Behavior*, *55*, 190-197.

Chugh, R., & Ruhi, U. (2018). Social media in higher education: A literature review of Facebook. *Education and Information Technologies*, *23*(2), 605-616.

Coban, O., Ozyildirim, B. M., & Ozel, S. A. (2018). An empirical study of the extreme learning machine for Twitter sentiment analysis. *International Journal of Intelligent Systems and Applications in Engineering*, *6*(3), 178-184.

Constantinides, E. (2014). Foundations of social media marketing. *Procedia-Social and behavioral sciences*, *148*, 40-57.

Cosley, D., Forte, A., Ciolfi, L., & McDonald, D. (2015). *Proceedings of the 18th ACM Conference on Computer Supported Cooperative Work & Social Computing*. ACM Press.

Crystal, D. (2008). *Txtng: The gr8 db8*. OUP Oxford.

ÇALIŞAN, M., & TALU, M. F. (2020) Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi. Türk Doğa ve Fen Dergisi, 9(1), 107-113.

Çetin, F. S., & Eryiğit, G. (2018). Türkçe Hedef Tabanlı Duygu Analizi İçin Alt Görevlerin İncelenmesi–Hedef Terim, Hedef Kategori Ve Duygu Sınıfı Belirleme. *Bilişim Teknolojileri*

Dergisi, *11*(1), 43-56.

Çoban, Ö., Özyer, B., & Özyer, G. T. (2015, May). Sentiment analysis for Turkish Twitter feeds. In *2015 23nd Signal Processing and Communications Applications Conference (SIU)* (pp. 2388-2391). IEEE.

Daga, I., Gupta, A., Vardhan, R., & Mukherjee, P. (2020). Prediction of Likes and Retweets Using Text Information Retrieval. *Procedia Computer Science*, *168*, 123-128.

Danneman, N., & Heimann, R. (2014). *Social media mining with R*. Packt Publishing Ltd.

Dehkharghani, R. (2015). *Sentiment analysis in Turkish: resources and techniques* (Doctoral dissertation).

Dehkharghani, R., Saygin, Y., Yanikoglu, B., & Oflazer, K. (2016). SentiTurkNet: a Turkish polarity lexicon for sentiment analysis. *Language Resources and Evaluation*, *50*(3), 667-685.

Demchenko, Y., De Laat, C., & Membrey, P. (2014, May). Defining architecture components of the Big Data Ecosystem. In 2014 International conference on collaboration technologies and systems (CTS) (pp. 104-112). IEEE.

Demirel, A. (2013). E-ticarette sosyal medya etkilerinin incelenmesi ve bir uygulama.

Devrani, A. E. P., & Kesici, İ. Yeni Medya Araştırmalarında Yöntemler Ve Araçlar Ne Kadar Yeni? Türkiye'deki Lisansüstü Tezlere Dair Bir Meta Analiz Çalışması. *Selçuk İletişim*, *13*(1), 273-293.

Dietz, C., & Berthold, M. R. (2016). KNIME for open-source bioimage analysis: a tutorial. *Focus on Bio-Image Informatics,* 179-197.

Dinner, I. M., Heerde Van, H. J., & Neslin, S. A. (2014). Driving online and offline sales: The cross-channel effects of traditional, online display, and paid search advertising. *Journal of marketing research*, *51*(5), 527-545.

Doyle, S. (2007). The role of social networks in marketing. *Journal of Database Marketing*

& Customer Strategy Management, *15*(1), 60-64.

Ducange, P., Fazzolari, M., Petrocchi, M., & Vecchio, M. (2019). An effective Decision Support System for social media listening based on cross-source sentiment analysis models. *Engineering Applications of Artificial Intelligence*, *78*, 71-85

Durmaz, Y., & Efendioglu, I. H. (2016). Travel from traditional marketing to digital marketing. *Global journal of management and business research*.

Eirinaki, M., & Vazirgiannis, M. (2003). Web mining for web personalization. ACM Transactions on Internet Technology (TOIT), 3(1), 1-27.

ERYIGIT, G., & TORUNO, D. (2017). Social media text normalization for Turkish. *Natural Language Engineering*, *23*(6), 835.

Farrah, M. (2010). Understanding digital marketing. *The British Joumal of Administrative Management* (71), 12-14.

Fung, G. P. C., Yu, J. X., & Lam, W. (2003, March). Stock prediction: Integrating text mining approach using real-time news. In *2003 IEEE International Conference on Computational Intelligence for Financial Engineering, 2003. Proceedings.* (pp. 395-402). IEEE.

Garimella, V. R. K., Alfayad, A., & Weber, I. (2016, May). Social media image analysis for public health. In *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems* (pp. 5543-5547).

Garton, L., Haythornthwaite, C., & Wellman, B. (1997). Studying online social networks. *Journal of computer-mediated communication*, *3*(1), JCMC313.

Goldstein, D. G., Suri, S., McAfee, R. P., Ekstrand-Abueg, M., & Diaz, F. (2014). The economic and cognitive costs of annoying display advertisements. *Journal of Marketing Research*, *51*(6), 742-752.

Gopal, R. D., Walter, Z., & Tripathi, A. K. (2001). Admediation: New horizons in effective email advertising. *Communications of the ACM*, *44*(12), 91-96.

Greco, F., & Polli, A. (2020). Emotional Text Mining: Customer profiling in brand management. *International Journal of Information Management*, *51*, 101934.

Gretzel, U. (2019). The role of social media in creating and addressing overtourism. *Overtourism: Issues, realities and solutions*, 62-75.

Habibi, F., Hamilton, C. A., Valos, M. J., & Callaghan, M. (2015). E-marketing orientation and social media implementation in B2B marketing. *European Business Review*.

Halis, B. (2012). Tüketimin değişen yüzü: Elektronik ticaret uygulamaları ve sosyal paylaşım ağlarının rolü/The changing face of consumption: E-commerce applications and the role of social networks. Journal of History Culture and Art Research, 1(4), 149-160.

Hatzivassiloglou, V., & Wiebe, J. (2000). Effects of adjective orientation and gradability on sentence subjectivity. In *COLING 2000 Volume 1: The 18th International Conference on Computational Linguistics*.

Haykin, S., & Network, N. (2004). A comprehensive foundation. Neural networks, 2(2004), 41.

He, W., Zha, S., & Li, L. (2013). Social media competitive analysis and text mining: A case study in the pizza industry. *International journal of information management*, *33*(3), 464-472.

Heaney, C. A., & Israel, B. A. (2008). Social networks and social support. *Health behavior and health education: Theory, research, and practice*, *4*, 189-210.

Heinze, A., Fletcher, G., Rashid, T., & Cruz, A. (2016). Digital and social media marketing. *Abingdon: Routledge*.

Hochman, N. (2014). The social media image. *Big Data & Society*, *1*(2),

House, J. S., Umberson, D., & Landis, K. R. (1988). Structures and processes of social support. *Annual review of sociology*, *14*(1), 293-318.

Hu, Y., Manikonda, L., & Kambhampati, S. (2014, May). What we instagram: A first analysis of instagram photo content and user types. In *Proceedings of the International AAAI*

Conference on Web and Social Media (Vol. 8, No. 1).

Huang, X., Wu, L., & Ye, Y. (2019). A review on dimensionality reduction techniques. International Journal of Pattern Recognition and Artificial Intelligence, 33(10), 1950017.

Injadat, M., Salo, F., & Nassif, A. B. (2016). Data mining techniques in social media: A survey. *Neurocomputing*, *214*, 654-670.

Israel, B. A. (1982). Social networks and health status: Linking theory, research, and practice. *Patient counselling and health education*, *4*(2), 65-79.

Järvinen, J., Tollinen, A., Karjaluoto, H., & Jayawardhena, C. (2012). Digital and social media marketing usage in B2B industrial section. *Marketing Management Journal*, *22*(2).

Jeawak, S. S., Jones, C. B., & Schockaert, S. (2020). Predicting the environment from social media: A collective classification approach. *Computers, Environment and Urban Systems*, *82*, 101487.

Jerath, K., Ma, L., & Park, Y. H. (2014). Consumer click behavior at a search engine: The role of keyword popularity. *Journal of Marketing Research*, *51*(4), 480-486.

Jia, Y., Bai, L., Liu, S., Wang, P., Guo, J., & Xie, Y. (2019). Semantically-enhanced kernel canonical correlation analysis: a multi-label cross-modal retrieval. *Multimedia Tools and Applications*, *78*(10), 13169-13188.

Jing, M., Scotney, B. W., Coleman, S. A., McGinnity, M. T., Kelly, S., Zhang, X., ... & Heyer, G. (2016, March). Flood event image recognition via social media image and text analysis. In *IARIA conference COGNITIVE*.

Kadrev, G., Kostadinov, G., & Ruskov, P. (2016, September). Expansion of a CNN-based image classifier's scope using transfer learning and k-NN. Technical report. In *2016 IEEE 8th International Conference on Intelligent Systems (IS)* (pp. 764-770). IEEE.

Kandasamy, I., Vasantha, W. B., Mathur, N., Bisht, M., & Smarandache, F. (2020). Sentiment analysis of the# MeToo movement using neutrosophy: Application of single-valued neutrosophic sets. In *Optimization Theory Based on Neutrosophic and Plithogenic Sets* (pp. 117-

135). Academic Press.

Kandasamy, I., Vasantha, W. B., Obbineni, J. M., & Smarandache, F. (2020). Sentiment analysis of tweets using refined neutrosophic sets. *Computers in Industry*, *115*, 103180.

Kanishcheva, O., & Sharonova, N. (2018). Image and Video Tag Aggregation. In *AIST (Supplement)* (pp. 161-172).

Kasapoğlu, C., Aksoy, R., & Başkol, M. Marka Kavram Haritalarında Metin Madenciliği Yöntemlerinin Kullanımına Yönelik Kavramsal Bir Çalışma. *Bartın Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, *11*(21), 182-206.

Kelleher, J. D., Mac Namee, B., & D'arcy, A. (2020). Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies. MIT press.

Khazaei, H., Zareian, S., Veleda, R., & Litoiu, M. (2016). Sipresk: A big data analytic platform for smart transportation. In *Smart City 360°* (pp. 419-430). Springer, Cham.

Kietzmann, J. H., Hermkens, K., McCarthy, I. P., & Silvestre, B. S. (2011). Social media? Get serious! Understanding the functional building blocks of social media. *Business horizons*, *54*(3), 241-251.

Kingsnorth, S. (2019). *Digital marketing strategy: an integrated approach to online marketing*. Kogan Page Publishers.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 25, 1097-1105.

Kumar, N., Nagalla, R., Marwah, T., & Singh, M. (2018). Sentiment dynamics in social media news channels. *Online Social Networks and Media*, *8*, 42-54.

Kuncoro, B. A., & Iswanto, B. H. (2015, November). TF-IDF method in ranking keywords of Instagram users' image captions. In *2015 International Conference on Information Technology Systems and Innovation (ICITSI)* (pp. 1-5). IEEE.

Kurnia, P. F. (2018). Business intelligence model to analyze social media

information. *Procedia Computer Science*, *135*, 5-14.

Kushal, D., Steve, L., Pennock, D.M., "Mining the Peanut Gallery: Opinion Extraction and Semantic Classification of Product Reviews", *In Proceedings of WWW'03, 12th International Conference on World Wide Web,* Budapest Congress Centre, Macaristan, ss. 519-528, 2003.

Küçükali, A., & Serçemeli, C. (2019). Akademisyenlerin Sosyal Medya Kullanımı: Atatürk Üniversitesi Örneği. *Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi*, *6*(10), 202-219.

Lakkaraju, H., Bhattacharyya, C., Bhattacharya, I., & Merugu, S. (2011, April). Exploiting coherence for the simultaneous discovery of latent facets and associated sentiments. In *Proceedings of the 2011 SIAM international conference on data mining* (pp. 498-509). Society for Industrial and Applied Mathematics.

Lakoff, R., Lakoff, R.T., 2004. Language and Woman's Place: Text and Commentaries, 3. Oxford University Press.

Li, S., Li, J. Z., He, H., Ward, P., & Davies, B. J. (2011). WebDigital: A Web-based hybrid intelligent knowledge automation system for developing digital marketing strategies. *Expert Systems with Applications*, *38*(8), 10606-10613.

Liu, B. (2010). Sentiment analysis and subjectivity. *Handbook of natural language processing*, *2*(2010), 627-666.

Liu, Y., Lehdonvirta, V., Alexandrova, T., & Nakajima, T. (2012). Drawing on mobile crowds via social media. *Multimedia systems*, *18*(1), 53-67.

Luo, X., Andrews, M., Song, Y., & Aspara, J. (2014). Group-buying deal popularity. *Journal of Marketing*, *78*(2), 20-33.

Maas, A., Daly, R. E., Pham, P. T., Huang, D., Ng, A. Y., & Potts, C. (2011, June). Learning word vectors for sentiment analysis. In *Proceedings of the 49th annual meeting of the association for computational linguistics: Human language technologies* (pp. 142-150).

Mahmoud, A. B., Grigoriou, N., Fuxman, L., Hack-Polay, D., Mahmoud, F. B., Yafi, E., & Tehseen, S. (2019). Email is evil! Behavioural responses towards permission-based direct email

marketing and gender differences. *Journal of Research in Interactive Marketing*.

Mangold, W. G., & Faulds, D. J. (2009). Social media: The new hybrid element of the promotion mix. *Business horizons*, *52*(4), 357-365.

Marangoz, M., Yeşildağ, B., & Saltık, İ. A. (2012). E-ticaret işletmelerinin web ve sosyal ağ sitelerinin içerik analizi yöntemiyle incelenmesi. Journal of Internet Applications and Management, 3(2), 53-78.

Mariani, M. M., Di Felice, M., & Mura, M. (2016). Facebook as a destination marketing tool: Evidence from Italian regional Destination Management Organizations. *Tourism management*, *54*, 321-343.

Mascheroni, G., Vincent, J., & Jimenez, E. (2015). "Girls are addicted to likes so they post semi-naked selfies": Peer mediation, normativity and the construction of identity online. *Cyberpsychology: Journal of Psychosocial Research on Cyberspace*, *9*(1), 5.

Medvedev, V., Kurasova, O., Bernatavičienė, J., Treigys, P., Marcinkevičius, V., & Dzemyda, G. (2017). A new web-based solution for modelling data mining processes. *Simulation Modelling Practice and Theory*, *76*, 34-46.

Mehraliyev, F., Kirilenko, A. P., & Choi, Y. (2020). From measurement scale to sentiment scale: Examining the effect of sensory experiences on online review rating behavior. *Tourism Management*, *79*, 104096.

Meier, E. P., & Gray, J. (2014). Facebook photo activity associated with body image disturbance in adolescent girls. *Cyberpsychology, Behavior, and Social Networking*, *17*(4), 199-206.

Melewar, T. C., & Smith, N. (2003). The Internet revolution: some global marketing implications. *Marketing intelligence & planning*.

Meng, T., Lin, L., Shyu, M. L., & Chen, S. C. (2010, December). Histology image classification using supervised classification and multimodal fusion. In *2010 IEEE international symposium on multimedia* (pp. 145-152). IEEE.

Meral, M., & Diri, B. (2014, April). Sentiment analysis on Twitter. In *2014 22nd Signal*

Processing and Communications Applications Conference (SIU) (pp. 690-693). IEEE.

Merler, M., Cao, L., & Smith, J. R. (2015, June). You are what you tweet… pic! gender prediction based on semantic analysis of social media images. In *2015 IEEE International Conference on Multimedia and Expo (ICME)* (pp. 1-6). IEEE.

Minanovic, A., Gabelica, H., & Krstić, Ž. (2014, May). Big data and sentiment analysis using KNIME: Online reviews vs. social media. In *2014 37th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)* (pp. 1464-1468). IEEE.

Mittermayer, M. A. (2004, January). Forecasting intraday stock price trends with text mining techniques. In *37th Annual Hawaii International Conference on System Sciences, 2004. Proceedings of the* (pp. 10-pp). IEEE.

Mittermayer, M. A., & Knolmayer, G. F. (2006, December). Newscats: A news categorization and trading system. In *Sixth International Conference on Data Mining (ICDM'06)* (pp. 1002-1007). Ieee.

Monkman, G. G., Kaiser, M. J., & Hyder, K. (2018). Text and data mining of social media to map wildlife recreation activity. *Biological conservation*, *228*, 89-99.

Moro, S., Rita, P., & Vala, B. (2016). Predicting social media performance metrics and evaluation of the impact on brand building: A data mining approach. *Journal of Business Research*, *69*(9), 3341-3351.

Mueller, J., & Stumme, G. (2017, June). Predicting rising follower counts on Twitter using profile information. In *Proceedings of the 2017 ACM on Web Science Conference* (pp. 121-130).

Murdough, C. (2009). Social media measurement: It's not impossible. *Journal of interactive advertising*, *10*(1), 94-99.

Nassirtoussi, A. K., Aghabozorgi, S., Wah, T. Y., & Ngo, D. C. L. (2014). Text mining for market prediction: A systematic review. *Expert Systems with Applications*, *41*(16), 7653-7670.

Nausheen, F., & Begum, S. H. (2018, January). Sentiment analysis to predict election results

using Python. In *2018 2nd international conference on inventive systems and control (ICISC)* (pp. 1259-1262). IEEE.

Nikfarjam, A., Emadzadeh, E., & Muthaiyah, S. (2010, February). Text mining approaches for stock market prediction. In *2010 The 2nd international conference on computer and automation engineering (ICCAE)* (Vol. 4, pp. 256-260). IEEE.

Niu, Z., Hua, G., Gao, X., & Tian, Q. (2014). Semi-supervised relational topic model for weakly annotated image recognition in social media. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4233-4240).

Oliveira, F., Santos, A., Aguiar, B., & Sousa, J. (2014). GameFoundry: social gaming platform for digital marketing, user profiling and collective behavior. *Procedia-Social and Behavioral Sciences*, *148*, 58-66.

Özyurt, B., & Akçayol, M. A. (2018). Fikir Madenciliği Ve Duygu Analizi, Yaklaşımlar, Yöntemler Üzerine Bir Araştırma. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, *6*(4), 668-693.

Pak, A., & Paroubek, P. (2010, May). Twitter as a corpus for sentiment analysis and opinion mining. In *LREc* (Vol. 10, No. 2010, pp. 1320-1326).

Pang, B., Lee, L., Vaithyanathan, S., "Thumbs up?: Sentiment Classification Using Machine Learning Techniques", *In Proceedings of EMNLP-2002, Conference on Empirical Methods in Natural Language Processing,* University of Pennsylvania, PA, ABD, ss. 79-86, 2002.

Pant, G., & Pant, S. (2018). Visibility of corporate websites: The role of information prosociality. *Decision Support Systems*, *106*, 119-129.

Păvăloaia, V. D., Teodor, E. M., Fotache, D., & Danileţ, M. (2019). Opinion mining on social media data: sentiment analysis of user preferences. *Sustainability*, *11*(16), 4459.

Puccinelli, N. M., Wilcox, K., & Grewal, D. (2015). Consumers' response to commercials: when the energy level in the commercial conflicts with the media context. *Journal of Marketing*, *79*(2), 1-18.

Rajput, Q., Haider, S., & Ghani, S. (2016). Lexicon-based sentiment analysis of teachers' evaluation. *Applied Computational Intelligence and Soft Computing*, *2016*.

Rao, A., Spasojevic, N., Li, Z., & DSouza, T. (2015, October). Klout score: Measuring influence across multiple social networks. In *2015 IEEE International Conference on Big Data (Big Data)* (pp. 2282-2289). IEEE.

Rao, T., & Srivastava, S. (2012). Analyzing stock market movements using twitter sentiment analysis.

Rao, T., & Srivastava, S. (2014). Twitter sentiment analysis: How to hedge your bets in the stock markets. In *State of the art applications of social network analysis* (pp. 227-247). Springer, Cham.

Reichstein, C., & Härting, R. C. (2018). Potentials of changing customer needs in a digital world–a conceptual model and recommendations for action in tourism. *Procedia Computer Science*, *126*, 1484-1494.

Reyes-Menendez, A., Saura, J. R., & Filipe, F. (2020). Marketing challenges in the# MeToo era: Gaining business insights using an exploratory sentiment analysis. *Heliyon*, *6*(3), e03626.

Russell, S., & Bohannon, J. (2015). Artificial intelligence. Fears of an AI pioneer. Science (New York, NY), 349(6245), 252-252.

Salton, G., & Buckley, C. (1988). Term-weighting approaches in automatic text retrieval. *Information processing & management*, *24*(5), 513-523.

Sam, E., Yarushev, S., Basterrech, S., & Averkin, A. (2018). Prediction of Facebook Post Metrics using Machine Learning. *arXiv preprint arXiv:1805.05579*.

Sarlan, A., Nadam, C., & Basri, S. (2014, November). Twitter sentiment analysis. In *Proceedings of the 6th International conference on Information Technology and Multimedia* (pp. 212-216). IEEE.

Seker, S. E. (2016). Duygu Analizi (Sentimental Analysis). *YBS Ansiklopedi*, *3*(3), 21-36.

Seltzer, E. K., Jean, N. S., Kramer-Golinkoff, E., Asch, D. A., & Merchant, R. M. (2015). The content of social media's shared images about Ebola: a retrospective study. *Public health*, *129*(9), 1273-1277.

SEZGİN, M., & ALTAY, I. Üniversite Tercihinde Sosyal Medyanın Aracı Rolü. *Uluslararası Sosyal Bilimler ve Eğitim Dergisi*, *3*(4), 87-104.

Shearer, E., & Mitchell, A. (2021). News use across social media platforms in 2020.

Sheldon, K. M., Elliot, A. J., Kim, Y., & Kasser, T. (2001). What is satisfying about satisfying events? Testing 10 candidate psychological needs. *Journal of personality and social psychology*, *80*(2), 325.

Silahtaroğlu, G. (2008). Veri madenciliği. Papatya Yayınları, İstanbul.

Silva, T. H., De Melo, P. O. V., Almeida, J. M., Salles, J., & Loureiro, A. A. (2013, May). A picture of Instagram is worth more than a thousand words: Workload characterization and application. In *2013 IEEE International Conference on Distributed Computing in Sensor Systems* (pp. 123-132). IEEE.

Singh, K., Shakya, H. K., & Biswas, B. (2016). Clustering of people in social network based on textual similarity. *Perspectives in Science*, *8*, 570-573.

Singh, N., Chakraborty, A., Biswas, S. B., & Majumdar, M. (2020). Impact of Social Media in Banking Sector under Triangular Neutrosophic Arena Using MCGDM Technique. *Neutrosophic Sets and Systems*, *35*, 153-176.

Stephen, A. T. (2016). The role of digital and social media marketing in consumer behavior. *Current opinión in Psychology*, *10*, 17-21.

Taboada, M., Brooke, J., Tofiloski, M., Voll, K., & Stede, M. (2011). Lexicon-based methods for sentiment analysis. *Computational linguistics*, *37*(2), 267-307.

Tetsuya, N., Jeonghee, Y., "Sentiment Analysis: Capturing Favorability Using Natural Language Processing", *In Proceedings of KCAP-03, 2nd International Conference on KnowledgeCapture,* Sanibel Island, FL, ABD, ss. 70-77, 2003.

Tiago, M. T. P. M. B., & Veríssimo, J. M. C. (2014). Digital marketing and social media: Why bother?. *Business horizons*, *57*(6), 703-708.

Tillmann, N., De Halleux, J., Xie, T., & Bishop, J. (2012, April). Pex4Fun: Teaching and learning computer science via social gaming. In *2012 IEEE 25th Conference on Software Engineering Education and Training* (pp. 90-91). IEEE.

Tirea, M., & Negru, V. (2013, September). Classifying and quantifying certain phenomena effect. In *2013 IEEE 11th International Symposium on Intelligent Systems and Informatics (SISY)* (pp. 363-368). IEEE.

Tong, R.M., "An Operational System for Detecting and Tracking Opinions in On-Line Discussion", *In Proceedings of SIGIR 2001 Workshop on Operational Text Classification,* New Orleans, Louisiana, ABD, 2001.

Tugrul, T. O., & Gocer, A. (2017). Communicating Sustainability on Social Media: A study on leading turkish and global Brands in Turkey. *International Journal of Marketing, Communication and New Media*, *5*(8).

Turney P.D., "Thumbs up or Thumbs down?: Semantic Orientation Applied to Unsupervised Classification of Reviews", *In Proceedings of ACL'02, 40th Annual Meeting of the Association for Computational Linguistics*, Pennsylvania, ABD, ss. 417-424, 2002.

TÜİK (2020, Ağustos). Hanehalkı Bilişim Teknolojileri (BT) Kullanım Araştırması [Basın bülteni]. Erişim adresi https://data.tuik.gov.tr/Bulten/Index?p=Hanehalki-Bilisim-Teknolojileri-(BT)-Kullanim-Arastirmasi-2020-33679

Van der Meer, T. G., & Verhoeven, P. (2013). Public framing organizational crisis situations: Social media versus news media. *Public Relations Review*, *39*(3), 229-231

Vermeer, S. A., Araujo, T., Bernritter, S. F., & van Noort, G. (2019). Seeing the wood for the trees: How machine learning can help firms in identifying relevant electronic word-of-mouth in social media. *International Journal of Research in Marketing*, *36*(3), 492-508.

Vong, K. (2012, August 13). Image is everything: Why people are hooked on image-based

social media. Retrieved August 18, 2014, from http://www.trendreports.com/article/imagebased social-media

VURAL, Z. B. A., SAYAT, A., & ÇAVUŞ, D. Sosyal Medyada Kurumsal Kimlik: Türk Finans Sektöründeki Sosyal Ağlar Üzerine Bir Analiz. *TroyAcademy*, *6*(1), 25-58.

Wallace, M. P. (2008). Neural networks and their application to finance. Business intelligence journal, 1(1), 67-77.

Wold, S., Esbensen, K., & Geladi, P. (1987). Principal component analysis. Chemometrics and intelligent laboratory systems, 2(1-3), 37-52

Wymbs, C. (2011). Digital marketing: The time for a new "academic major" has arrived. *Journal of Marketing Education*, *33*(1), 93-106.

Yadav, N., Yadav, A., & Kumar, M. (2015). An introduction to neural network methods for differential equations (pp. 13-15). Berlin: Springer.

Yıldırım, M., & Yüksel, C. A. Sosyal Medya İle Hisse Senedi Fiyatının Günlük Hareket Yönü Arasındaki İlişkinin İncelenmesi: Duygu Analizi Uygulaması. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 33-44.

Zafarani, R., Abbasi, M. A., & Liu, H. (2014). *Social media mining: an introduction*. Cambridge University Press.

Zhang, L., & Guan, Y. (2008, June). Detecting click fraud in pay-per-click streams of online advertising networks. In *2008 The 28th International Conference on Distributed Computing Systems* (pp. 77-84). IEEE.

Zhu, Y. Q., & Chen, H. G. (2015). Social media and human need satisfaction: Implications for social media marketing. Business horizons, 58(3), 335-345.

EKLER

Ek 1: Facebook Verisi İçin Python Kodları

```
from pandas import DataFrame
from facebook_scraper import get_posts
veriseti=get_posts("H1 Hastanesinin Facebook Adresi", pages=xxx)
output_table=DataFrame(veriseti)
```

Ek 2: Instagram İçin Python Kodları

```
from pandas import DataFrame
output_table = DataFrame()
import instaloader
from instaloader import Post, Profile, Story
import pandas as pd
from pandas import DataFrame
L = instaloader.Instaloader()
Paylasimlar = []
likesayilari = []
commentsayilari = []
ownerlar = []
url2 = []
data = {"yazi":[],
      "likesayisi":[],
      "commentsayisi":[],
      "owner":[],
      "url":[],
      "date":[]}
TamListe = pd.DataFrame(data)
shortcuts = []
for i in shortcuts:
  post = Post.from_shortcode(L.context, i)
  yazi = post.caption
  likesayisi = post.likes
  commentsayisi = post.comments
  date = post.date
  owner = post.owner_username
  url = post.url
```

```
 url2.append(url)
  Paylasimlar.append(yazi)
  if etiketler != []:
    etiketler_.append(etiketler)
  else:
    etiketler_.append("null")
  if bahsedilenler != []:
    bahsedilenler_.append(bahsedilenler)
  else:
    bahsedilenler_.append("null")
  if resimdeetiketlenenler != []:
          resimdeetiketlenenler_.append(resimdeetiketlenenler)
  else:
        resimdeetiketlenenler_.append("null")
        commentsayilari.append(commentsayisi)
        likesayilari.append(likesayisi)
        ownerlar.append(owner)

output_table=DataFrame(Paylasimlar)

output_table['commentsayilari'] = commentsayilari
output_table['likesayilari'] = likesayilari
output_table['ownerlar'] = ownerlar
output_table['url'] = url2
output_table['date'] = date
```

Ek 3: Imagga İçin Python Kodları

```
from pandas import DataFrame
import pandas as pd
import requests
import json
api_key = 'acc_47755e617bd4c97'
api_secret = 'dc17a4ff67e877e4afa16d9fde7d193e'
from pandas.io.json import json_normalize
import json
data = {"tag":[]}
allList = pd.DataFrame(data)
image_path = 'C:/Users/Serkan/Desktop/new/image_000.jpg'
print(image_path)
response = requests.post(
   'https://api.imagga.com/v2/tags?language=tr',
   auth=(api_key, api_secret),
   files={'image': open(image_path, 'rb')})
data=response.json()['result']['tags']
df = json_normalize(data)
allList=pd.concat([allList, df],axis =1).head(6)
image_path = ''
response = requests.post(
   'https://api.imagga.com/v2/tags?language=tr',
   auth=(api_key, api_secret),
   files={'image': open(image_path, 'rb')})
data=response.json()['result']['tags']
df = json_normalize(data)
allList=pd.concat([allList, df],axis =1).head(6)
a=allList
```

output_table=a

Ek 4: Kanal Bazlı Veri Tabanı Örneği

Markalar	Facebook								Twitter								Youtube							Instagram						Google Haberler
	Ortalama Beğeni Sayısı	Ortalama Paylaşım Sayısı	Ortalama Yorum Sayısı	Resim İçerme Oranı	Bağlantı İçerme Oranı	Takipçi Sayısı	Beğeni Sayısı	Pozitiflik Olasılığı	Ortalama Beğeni Sayısı	Ortalama Retweet Sayısı	Takipçi Sayısı	Takip Edilen Sayısı	Takipçilerin Ortalama Retweet Sayısı	Takipçilerin Ortalama Beğeni Sayısı	Pozitiflik Olasılığı	Etiketlenmeler in Pozitiflik Olasılığı	Ortalama İzlenme Süresi	Ortalama Beğeni	Ortalama Beğenilme me	Ortalama Paylaşım Sayıları	Ortalama Yorum Sayısı	Ortalama Favori Olma	Pozitiflik Olasılığı	Ortalama Yorum Sayısı	Ortalama Beğeni Sayısı	Takipçi Sayısı	Takip Sayısı	Pozitiflik Olasılığı	Ortalama Resim Özelliği	Pozitiflik Olasılığı
Marka 1																														
Marka 2																														
Marka 3																														
Marka 4																														
Marka 5																														
Marka 6																														
Marka 7																														
Marka 8																														
Marka 9																														
Marka 10																														