

**E-PAZARYERLERİNDE ÜRÜNLERE YÖNELİK KULLANICI  
DEĞERLENDİRMELERİNİN İNANDIRICILIĞININ MAKİNE  
ÖĞRENİMİ İLE TAHMİNLENMESİ**

**Pamukkale Üniversitesi  
Sosyal Bilimler Enstitüsü  
Yüksek Lisans Tezi  
Yönetim Bilişim Sistemleri ABD**

---

**Koray GÜNEL**

**Danışman: Prof. Dr. Selçuk Burak HAŞILOĞLU**

**Temmuz 2024  
DENİZLİ**

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın dođrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan alıřmalara atıfta bulunulduđunu beyan ederim.

İmza

Koray GÜNEL

## ÖNSÖZ

Tez çalışmam boyunca büyük bir sabır ve özveri ile bütün sorularıma cevap veren ve tüm bu süreçte sadece akademik anlamda değil hayata dair de tecrübeler öğrendiğim değerli danışman hocam Prof. Dr. Selçuk Burak HAŞILOĞLU'na sonsuz teşekkürlerimi sunarım.

Tez çalışmam süresince gösterdikleri anlayış ve her zaman yanımda oldukları için babam Haşim GÜNEL'e, annem Fatma GÜNEL'e ve ablam Funda GÜNEL'e teşekkür etmek istiyorum.

Son olarak tüm bu süreçte yanımda olan Arş. Gör. Melek CIBIR'a teşekkür ederim.

**Koray GÜNEL**

Temmuz 2024, Denizli

## ÖZET

### E-PAZARYERLERİNDE ÜRÜNLERE YÖNELİK KULLANICI DEĞERLENDİRMELERİNİN İNANDIRICILIĞININ MAKİNE ÖĞRENİMİ İLE TAHMİNLENMESİ

GÜNEL, Koray  
Yüksek Lisans Tezi  
Yönetim Bilişim Sistemleri ABD  
Yönetim Bilişim Sistemleri Yüksek Lisans Programı  
Tez Yöneticisi: Prof. Dr. Selçuk Burak HAŞILOĞLU

Temmuz 2024, ix+64 Sayfa

Gelişen teknolojiler ile online alışveriş platformlarının kullanımı oldukça artış göstermiştir. Bu platformların geniş bir kullanıcı yelpazesine sahip olması platformların etkileyici gücünü artırmaktadır. Dolayısıyla bu platformlarda kullanıcıların yaptığı değerlendirmelerin inandırıcılıkları da bu ürünleri satın almayı düşünen kullanıcıların fikirlerini etkileyebilmektedir. Bu çalışmanın genel amacı, çevrimiçi değerlendirmelerin inandırıcılık değerlerini saptamaktır. Bu amaç doğrultusunda Mayıs 2023 - Ocak 2024 yılları arasında erişilen çevrimiçi değerlendirmeler toplanmıştır. Toplanan veriler üzerinde duygu analizi uygulanmış ve her değerlendirilenin duygu sınıfı belirlenmiştir. Makine öğrenimi modelleri karşılaştırılmış ve elde edilen verilerle uygun model eğitilmiştir. Eğitilen modelin tahmin başarısı test edilmiş ve çevreci ürünler üzerinde tahminleme yapılmıştır.

Bu çalışmada elde edilen bulgular, çevrimiçi değerlendirmeye ait duygu sınıfının inandırıcılık üzerindeki etkilerini göstermektedir. Çevrecilik durumuna dair yapılan analizlerde ise çevrecilik durumunun inandırıcılık üzerinde bir etkisi olduğu gözlemlenmiştir. Çevrecilik durumuna göre ürünler bazında yapılan analizler ise inandırıcılık endeksi üzerinde anlamlı farklılıklar olduğunu göstermektedir.

**Anahtar Kelimeler:** İnanıcılık, Çevrimiçi Değerlendirme, Makine Öğrenimi, Çevreci Ürünler, E-Pazaryeri

## ABSTRACT

### PREDICTING THE CREDIBILITY OF USER EVALUATIONS OF PRODUCTS IN E-MARKETPLACES WITH MACHINE LEARNING

GÜNEL, Koray

Master Thesis

Management Information Systems Department

Management Information Systems Programme

Adviser of Thesis: Prof. Dr. Selçuk Burak HAŞILOĞLU

July 2024, ix+64 Pages

With developing technologies, the use of online shopping platforms has increased significantly. The fact that these platforms have a wide range of users increases the impressive power of the platforms. Therefore, the credibility of the evaluations made by users on these platforms may also affect the opinions of users who are considering purchasing these products. The general purpose of this study is to determine the credibility values of online reviews. For this purpose, online evaluations accessed between May 2023 - Jan 2024 were collected. Sentiment analysis was applied on the collected data and the sentiment class of each evaluation was determined. Machine learning models were compared and the appropriate model was trained with the obtained data. The prediction success of the trained model was tested and predictions were made on environmentally friendly products.

The findings obtained in this study show the effects of the emotion class of online evaluation on credibility. In the analysis of environmentalism, it was observed that environmentalism had an effect on credibility. Analyzes made on a product basis according to environmentalism status show that there are significant differences on the credibility index.

**Keywords:** Credibility, Online Review, Machine Learning, Environmentally Friendly Products, E-Marketplaces

## İÇİNDEKİLER

ÖNSÖZ .....	i
ÖZET.....	ii
ABSTRACT.....	iii
İÇİNDEKİLER .....	iv
TABLolar DİZİNİ .....	vii
ŞEKİLLER DİZİNİ.....	viii
SİMGE VE KISALTMALAR DİZİNİ.....	ix
GİRİŞ .....	1

### BİRİNCİ BÖLÜM

#### E-PAZARYERLERİNDEKİ MÜŞTERİ DENEYİMLERİ VE ÇEVİRİMİÇİ MÜŞTERİ DEĞERLENDİRMELERİ

1.1. Müşteri Deneyimleri Açısından E-Pazaryerleri .....	3
1.1.1. Kullanıcı Yorumları.....	4
1.1.2. Yıldız Puanlama Sistemi .....	5
1.1.3. Dijital Şikâyet Sistemi .....	6
1.2. Çevrimiçi Müşteri Değerlendirmeleri .....	7
1.2.1. Tüketici Davranışlarına Etkisi.....	8
1.2.2. Güven ve İtibar Yönetimi.....	8
1.2.3. Bilgi Asimetrisi ve Şeffaflık.....	9
1.2.4. Algoritmalar ve Veri Analizi .....	9
1.3. Kullanıcı Yorumlarının İnandırıcılığı ve Sahte Yorumlar .....	10

### İKİNCİ BÖLÜM

#### WEB MADENCİLİĞİ VE MAKİNE ÖĞRENİMİ KULLANIMI

2.1. Web Madenciliği .....	11
2.1.1. Web Madenciliği Teknikleri .....	11
2.1.1.1. Web İçerik Madenciliği.....	12
2.1.1.2. Web Kullanım Madenciliği .....	12
2.1.1.3. Web Yapı Madenciliği .....	13
2.1.2. Web Madenciliğinde Kullanılan Yazılımlar .....	13
2.1.3. Web Madenciliğinin Kullanım Alanları .....	14
2.2. Makine Öğrenimi .....	16
2.2.1. Makine Öğrenimi Modelleri .....	16

2.2.1.1. Gözetimli Öğrenme Modelleri .....	17
2.2.1.2. Gözetimsiz Öğrenme Modelleri .....	18
2.2.1.3. Pekiştirmeli Öğrenme Modelleri .....	19
2.2.2. Makine Öğrenimi Model Seçimi .....	19
2.2.3. Makine Öğreniminde Performans Ölçüleri .....	21
2.2.4. Makine Öğrenimi Sonuçlarının Yorumlanması .....	23

### ÜÇÜNCÜ BÖLÜM

#### E-PAZARYERİ DEĞERLENDİRMELERİ ÜZERİNDEN MAKİNE ÖĞRENİMİ İLE İNANDIRICILIK ALGISI TAHMİNLEME

3.1. Çalışmanın Amacı ve Kapsamı .....	25
3.1.1. Konu ve Amaç .....	25
3.1.2. Kapsam .....	26
3.2. Veri Setinin Oluşturulması .....	28
3.2.1. Araştırma Verilerinin Web Ortamından Çekilmesi .....	29
3.2.2. Araştırma Verilerinin Ön Hazırlık Süreci .....	30
3.2.2.1. Araştırma Verilerinin Temizlenmesi .....	31
3.2.2.2. Araştırma Verilerinin Duygu Analizine Uygun Hale Getirilmesi .....	31
3.2.2.3. Araştırma Verilerine Yeni Parametrelerin Eklenmesi .....	31
3.3. Verilerin Analizi ve Araştırma Modelinin Tanımlanması .....	32
3.3.1. Veri Setinin Eğitim ve Test Verisine Ayrılması .....	33
3.3.2. Uygun Makine Öğrenimi Modelinin Belirlenmesi .....	33

### DÖRDÜNCÜ BÖLÜM

#### E-PAZARYERLERİNDEKİ TEMİZLİK ÜRÜNLERİ YORUMLARININ İNANDIRICILIKLARI VE ÇEVRECİ ÖZELLİKLERİNE GÖRE FARKLILIKLARI

4.1. Çalışmanın Amacı ve Kapsamı .....	38
4.2. Yöntem .....	39
4.2.1. Polarite ve İnandırıcılık Endeksi Arasındaki Dağılım .....	40
4.2.2. Çevreci Ürün Özelliğine Göre İnandırıcılık Endeks Dağılımı .....	41
4.2.3. Ürün Türlerine Göre İnandırıcılık Endeksi Dağılımı .....	42
4.2.4. Markaların Ürünlerine Yapılan Değerlendirmelere Göre İnandırıcılık Endeksi Dağılımı .....	44
TARTIŞMA VE SONUÇ .....	46
KAYNAKLAR .....	50

ÖZGEÇMİŞ ..... **Hata! Yer işareti tanımlanmamış.**



**TABLolar DİZİNİ**

Tablo 1. Veri Setinin Oluşturulmasında Kullanılan Ürünler .....	27
Tablo 2. Değerlendirilen Sayfaların Özet Bilgileri .....	28
Tablo 3. Nihai Veri Seti .....	32
Tablo 4. Modellerin the Area under ROC Yöntemine Göre Karşılaştırılması .....	36
Tablo 5. Modellerin Sınıflandırma Doğruluğu Yöntemine Göre Karşılaştırılması.....	36
Tablo 6. Modellerin Doğruluk Değerleri .....	37
Tablo 7. Gradyan Arttırma ve Rastgele Orman Modellerinin Performans Tablosu.....	37
Tablo 8. Yorumların Polarite Kategorisi ve İnanırcılık Endeksi Çapraz Tablo Dağılımları .....	40
Tablo 9. Çevreci Ürün Özelliğine Göre İnanırcılık Endeksi T-Testi Sonuçları .....	42
Tablo 10. Ürün Türlerine Göre İnanırcılık Endeksi ANOVA Testi Sonuçları.....	43
Tablo 11. Markaların Ürünlerine Yapılan Değerlendirmelere Göre İnanırcılık Endeksi ANOVA Testi Sonuçları .....	44

**ŞEKİLLER DİZİNİ**

Şekil 1. Verilerin Elde Edilmesinde Kullanılan Web Kazıma Kod Parçası .....	30
---	----

**SİMGE VE KISALTMALAR DİZİNİ**

AUC	Area Under the ROC Curve
B2B	Bussiness to Bussiness
CSS	Cascading Style Sheets
DRL	Deep Reinforcement Learning
e-WOM	Electronic Word of Mouth
EMP	Electronic Market Place
FP	False Positive
FN	False Negative
k-NN	K-Nearest Neighbors
MAE	Mean Absolute Error
ML	Machine Learning
MSE	Mean Squared Error
NLP	Neuro Linguistic Programing
ROC	Receiver Operating Characteristic
PCA	Principal Component Analysis
STC	SentiTrustCom
SVM	Support Vector Machine
TN	True Negative
TP	True Positive

## GİRİŞ

Tüketici-işletme arasında iletişime dayalı sağlanan ilişkilerde güven duygusunun rolü önemlidir. Bu ilişkiler dolaylı veya doğrudan gerçekleşebilir. Güvenme duygusu, tüketici satın alma karar sürecinde de etkili bir faktördür. Fiyatı ne kadar ucuz olursa olsun, kimse güvenmediği bir yerden güvenmediği bir ürünü satın almak istemez (Gefen vd., 2003). Veyahut bir reklamdan ne kadar etkilenirse etkilensin eğer güvenmiyorsa satın alma eylemine geçemez (Pavlou, 2003). Dolayısıyla güvenmek olgusu, tüketicinin satın alma eyleminden önce devreye giren bir faktördür. Satın alınacak ürün veya marka hakkında belirsizlik ne kadar fazla ise güvenmeye duyulan ihtiyaç da o kadar artar (Kim vd., 2008). Tüketici, belirsizliğin az olduğu yerde bir şeylere güvenmek için pek çaba sarf etmeyecektir.

E-pazaryerleri gibi dijital alışveriş platformları, geleneksel pazaryerlerine göre daha fazla belirsizlikler içermektedir (McKnight vd., 2002). Bu nedenle de dijital pazarlama açısından tüketici güven algısı önemli bir yere sahiptir. Tüketici açısından algılanan belirsizlikler, aynı zamanda risk algısını da doğurur (Chen ve Barnes, 2007). Dijital pazarlama literatüründe güven ve risk kavramlarını birlikte veya ayrı ayrı kullanan çok sayıda çalışma bulunmaktadır (Gürkaynak-Gürbüzer ve Haşiloğlu, 2024). Kimi çalışmalarda bu iki kavram arasındaki ilişkiler birbirinden bağımsız ya da birbiri ile bağlantılı olarak değerlendirilmiştir (Gefen vd., 2003: 71).

Tüketiciler satın alma kararını vermeden önce belirsizliği ve riski azaltmak için birçok faktöre başvururlar. Diğer tüketicilerin yorum ve görüşleri bu faktörler arasında en önemlilerdendir (Gürkaynak-Gürbüzer ve Haşiloğlu, 2024). Yapılan yorumlar, ürün veya satıcı hakkında diğer tüketicilere yol gösterici bir rekabet aracıdır (Westbrook, 1987: 262; Jalilvand ve Samiei, 2012: 610). Bu nedenle e-ticaret sayfalarındaki olumlu yorumlar belirsizliği azaltarak tüketicinin daha hızlı satın alma kararı vermesine yardımcı olur. E-pazaryerlerinde paylaşılan yorumlar, aynı zamanda elektronik ağızdan ağıza iletişim (e-WOM) aracıdır. Bu araç birçok açıdan reklamdan daha da etkili olabilmektedir (Kim ve Park, 2013: 320; Gürkaynak-Gürbüzer ve Haşiloğlu 2024: 12). Dolayısıyla e-pazaryerlerindeki ürün yorumları belirsizliği azaltarak, tüketicinin satın alma kararında etkili olan güven algısının oluşmasına yardımcı olur. Ancak ne yazık ki spam yorum olarak da adlandırılan fake review ler de bulunmaktadır (Wahyuni ve Djunaidy, 2016;

Heydari vd., 2015: 3640; Kauffmann, 2020: 525). Sahte yorumların (fake review) artmasıyla yoruma olan güven de tüketiciler açısından önemli bir faktördür. E-pazaryerindeki bir satıcının ürününe yapılan olumlu yorumlar ne kadar çok olursa olsun inandırıcı değilse pek bir anlam ifade etmeyecektir. Bu çalışmada yorumların güvenilirliğine yönelik bir endeks değeri üretmek üzere makine öğrenmesi kullanılmıştır. Ardından e-pazaryerlerinde temizlik ürünleri üzerine yapılan kullanıcı yorumlarının inandırıcılığını ve çevreci özelliklerinin moderatör etkisi incelenmiştir. Çalışma, dört ana bölümden oluşmaktadır:

**Birinci bölüm,** e-pazaryerlerindeki müşteri deneyimleri ve çevrimiçi müşteri değerlendirmeleri ele alınacaktır. Öncelikle müşteri deneyimleri açısından e-pazaryerlerinin genel bir değerlendirmesi yapılacak, kullanıcı yorumları, yıldız puanlama sistemi ve dijital şikâyet sistemi incelenecektir. Ardından çevrimiçi müşteri değerlendirmelerinin tüketici davranışlarına etkisi, güven ve itibar yönetimi, bilgi asimetrisi ve şeffaflık ile algoritmalar ve veri analizi konuları üzerinde durulacaktır. Son olarak, kullanıcı yorumlarının inandırıcılığı ve sahte yorumlar tartışılmıştır.

**İkinci bölüm,** web madenciliği ve makine öğrenimi konularına odaklanılacaktır. Web madenciliği teknikleri, web içerik madenciliği, web kullanım madenciliği ve web yapı madenciliği gibi alt başlıklar altında incelenecek; web madenciliğinde kullanılan yazılımlar ve bu yazılımların kullanım alanları ele alınacaktır. Makine öğrenimi başlığı altında ise, gözetimli, gözetimsiz ve pekiştirmeli öğrenme modelleri, makine öğrenimi model seçimi, performans ölçüleri ve sonuçların yorumlanması gibi konular detaylı bir şekilde açıklanmıştır.

**Üçüncü bölüm,** çalışmamızın amacını ve kapsamını belirleyerek başlar. Araştırma verilerinin web ortamından çekilmesi, ön hazırlık süreçleri ve veri setinin oluşturulması süreçleri detaylandırılmaktadır. Ayrıca, veri setinin eğitim ve test verisine ayrılması ve uygun makine öğrenimi modelinin belirlenmesi konuları ele alınmıştır.

**Dördüncü bölüm,** çalışmanın özel olarak e-pazaryerlerindeki temizlik ürünlerine odaklanan kısmı yer alır. Çalışmanın amacı ve kapsamı detaylandırılarak, temizlik ürünleri yorumlarının inandırıcılığı ve bu yorumların çevreci özellikler ile nasıl etkileşime girdiği incelenecektir. Bulgular, tartışmalar ve sonuçlarla desteklenerek çalışmanın genel çerçevesi çizilmiştir.

## BİRİNCİ BÖLÜM

### E-PAZARYERLERİNDEKİ MÜŞTERİ DENEYİMLERİ VE ÇEVİRİMİÇİ MÜŞTERİ DEĞERLENDİRMELERİ

#### 1.1. Müşteri Deneyimleri Açısından E-Pazaryerleri

Müşteri deneyimi, bir şirketin sunduğu her şeyi kapsayan ve müşteri beklentileri tarafından şekillendirilen iş başarısının kritik bir yönüdür (Meyer ve Schwager, 2007: 117). Duyusal, duygusal, bilişsel, davranışsal ve ilişkisel deneyimlerin hepsinin rol oynadığı müşteri memnuniyetinin temel bir itici gücüdür (Dalla Pozza, 2014: 130). Müşteri deneyimi, çeşitli etkileşim noktaları aracılığıyla oluşur ve günümüz ekonomisinde önemli bir farklılaştırıcıdır (Lambert ve Lambert, 2012). Müşteri memnuniyetini elde etmek için şirketler ilgi çekici ve müşteriler için şirketin rekabetçi yönünü ortaya çıkaran deneyimler yaratmaya odaklanmalıdır (Shaw ve Ivens, 2002: 50).

E-pazaryerleri ve müşteri deneyimleri üzerine yapılan araştırmalar birkaç temel faktörü belirlemiştir. Algarni ve Xu (2013), güvenlik, tamamlayıcı hizmetler, güçlü altyapılar, güvenilirlik ve düzenleyici gereklilikler gibi faktörlerin e-pazaryerlerindeki müşteri memnuniyetini önemli ölçüde etkilediğini bulmuştur. Kim ve Tadisina (2007), e-pazaryerlerinde güvenin rolünü vurgulamış ve alıcının önceki deneyimlerinin güven gelişiminde önemli bir rol oynadığını belirtmiştir. Yang vd. (2019), itibarın önemini daha da vurgulamış ve müşteri deneyiminin itibar ile fiyat primi arasındaki ilişkiyi düzenlediğini belirtmiştir. Son olarak, Srivastva ve Kaul (2016), e-pazaryerlerinde müşteri deneyimini dönüştürmek için sosyal medyayı, mobil, analitiği, bulut bilişimi ve Nesnelerin İnternetini entegre eden SMACT yaklaşımını önermiştir. Bu çalışmalar toplu olarak, e-pazaryerlerinde müşteri deneyimlerini şekillendirmede güvenin, itibarın ve teknolojik gelişmelerin önemini vurgulamaktadır.

Çevrimiçi derecelendirmeler, bir ürünün satışlarına doğrudan bir etkisi olmasa da inceleme duyarlılığı yoluyla büyük bir dolaylı etkiye sahiptir (Kiritchenko vd, 2014). Duyarlılıklar ise satışlar üzerinde doğrudan bir etkiye sahiptir (Kiritchenko vd, 2014). Bu duyarlılıklar, ürün hakkında bol miktarda bilgi bulunmasıyla birlikte, gelecekteki müşterileri bunaltabilir (Godes ve Silva, 2012: 452). Bazen hangi yorumların gerçekten yararlı olduğunu anlayamazlar (Yin, 2014: 109). Çok sayıda, yararsız olanlar da dahil

olmak üzere yorumların varlığı, tüketicilerin bilişsel yeteneklerini etkileyen bilgi aşırı yüklemesine neden olur ve sonuç olarak, yorumların etkisi satın alma kararı verirken tüketicinin zihninde azalır. Bu nedenle bilgi aşırı yüklemesinin azaltılması gerekmektedir (Baek vd., 2015: 290). Bu nedenle, en yararlı yorumların belirlenmesi önemlidir. Siering vd. (2018), bu tür bir araştırma modeli geliştirmek için sinyal teorisini uygulamıştır. Birçok online perakendeci, okuyucuların yararlı yorumlara oy vermesine olanak tanıyan bir sosyal oylama sistemi tanıtmıştır (Ghose ve Ipeirotis, 2011). Doğal olarak, bu yorumlar tüm okuyucular tarafından eşit şekilde değerlendirilir (Pan ve Zhang, 2011: 600). Bu nedenle, kullanıcılar tarafından algılanan yararlı bir yorumu neyin oluşturduğunu incelemek faydalıdır (Baek vd., 2012: 112; Ghasemaghahi vd, 2018: 550; Nayal vd., 2022: 365; Purnawirawan vd., 2014: 172).

### **1.1.1. Kullanıcı Yorumları**

Günümüzde pek çok alanda olduğu gibi gelişen teknolojiyle birlikte geleneksel ticaret sisteminde de yeni yaklaşımlar ortaya çıkmaktadır. Bunlardan en yaygın ve görece herkes tarafından bilineni e-pazaryerleridir. Çevrimiçi mal veya hizmet satın alımı fırsatı sunan bu yeni yaklaşım beraberinde yeni engeller ve bu engeller için yeni çözümler gerektirmiştir. Bu engellerden birisi tüketicilerin kısıtlı bilgi ile çevrimiçi alışveriş yapmakta zorlanmasıdır (Dimoka vd., 2012: 397). Tüketiciler bu kısıtları aşmak için ilgilendikleri mal veya hizmetin özelliklerinden ziyade daha önce satın almış kullanıcıların deneyimlerini anlattıkları yorumları kullanmaktadır (Chen ve Xie, 2008: 483; Dellarocas, 2003: 1321). Kaemingk'e (2020) göre, tüketicilerin %97'si satın almayı düşündükleri ürün hakkında online araştırma yapmaktadır, %93'ü satın alma kararı vermeden önce yorumları okumakta ve tüketicilerin çoğu, yorumlardan olumlu yönde ikna olduklarında aynı ürünler için %31 daha fazla ödemeye hazırdır. Bu nedenle, iyi online yorumlara sahip bir ürün, mevcut ve potansiyel müşterilerin satın alma kararlarını etkileyen iyi bir elektronik ağızdan ağıza (eWOM) iletişim aracı olarak işlev görür.

Tüketiciler genellikle satın alma kararlarını verirken referans olarak kullanıcı yorumlarına bakma eğilimindedir. Online müşteri yorumu, kullanıcı tarafından oluşturulan ve online sitelere veya üçüncü taraf web sitelerine gönderilen içerik olan elektronik ağızdan ağıza (eWOM) iletişimin bir biçimidir (Mudambi vd., 2019: 168). Mo vd. (2015), müşteri yorumunun, farklı açılardan ek veriler sağlayarak diğer alıcılara yardımcı olan ve anket aracılığıyla ürünlerin doğasını özetleyen veriler sağlayarak, satın

alınan ürünler veya hizmetlerle ilgili olarak müşteriler tarafından verilen bir denetim olduğunu açıklar. Çevrimiçi Müşteri Yorumları, tüketicilere ürünler hakkında diğer tüketicilerin yorumlarına ulaşmayı ve bu yorumlara yanıt yazmayı kolaylaştıran bir etkidir. Bu çevrimiçi müşteri yorumları diğer potansiyel müşterilerin satın alma kararlarını etkileyebilir (Elvalda vd., 2016: 309; Latief ve Nirwana, 2020).

E-pazaryerleri üzerine yapılan araştırmalar, kullanıcı yorumlarının satın alma kararları üzerindeki önemli etkisini vurgulamıştır. Jaikumar (2019), tüketicilerin özellikle görüntüleme fiyatı yüksek olduğunda, yüksek yorum hacmine sahip satıcılardan satın alma olasılıklarının daha yüksek olduğunu bulmuştur. Bu, yorum hacimlerinin satıcılar için önemini vurgulamaktadır. Fadhillah vd. (2021), müşteri yorumlarının güven üzerindeki etkisini ve bunun da satın alma kararlarını etkilediğini vurgulamıştır. Chelliah ve Sarkar (2017), özellikle soğuk başlatma sorununu ele almada ve açıklamalarla öneriler üretmede, e-ticaret öneri sistemlerini geliştirmede kullanıcı tarafından yazılan ürün yorumlarının potansiyelini tartışmıştır. Son olarak, Tsaqıla vd. (2023), çevrimiçi müşteri deneyimi ile pazar yeri derecelendirmesi arasındaki ilişkiyi aracılık etmede çevrimiçi müşteri yorumlarının olumlu etkisini göstermiştir. Bu çalışmalar toplu olarak, kullanıcı yorumlarının e-pazaryerlerindeki temel rolünün altını çizmektedir.

### **1.1.2. Yıldız Puanlama Sistemi**

Çevrimiçi platformlarda tüketicilerin mal veya hizmetin içeriğini incelemenden önce baktığı etmenlerden biri yıldız değerlendirmeleridir. (Wang vd., 2015: 37). Bu değerlendirme yöntemi “4,0 / 5,0” şeklinde sayısal formatta gösterilebildiği gibi görsel “★★★★☆” şekillerle de ifade edilmektedir. Temel prensip kullanıcıların ürünü 5 üzerinden kaç puanla değerlendirdiğini ölçmektir. Bu şekilde hem kullanıcılar değerlendirme sistemine kolay bir şekilde dahil edilir hem de kullanıcılara kolay yorumlanabilir bir değerlendirme yöntemi sunulmuş olunur.

Yıldız puanları üzerine yapılan araştırmalar, satın alma kararlarını (Wang vd., 2015: 37), ürün beğenisini (Moe ve Trusov, 2011: 450), satış miktarını (Chiu vd., 2019: 756; Arbelles vd., 2020: 900) ve hatta satın alma sonrası davranışları (Chua ve Banerjee, 2016: 683) etkilediğini göstermektedir.



Bir başka çalışmada ise Chevalier ve Mayzlin (2006), Amazon kitap satışları üzerinde 1 yıldızlı bir değerlendirmenin 5 yıldızlı bir değerlendirmeden daha büyük bir etki yarattığını ortaya koymaktadır.

E-pazaryerlerindeki yıldız derecelendirmeleri üzerine yapılan araştırmalar birçok önemli bulguyu ortaya çıkardı. Zhang (2007), adil derecelendirmeleri teşvik etmek için bir teşvik mekanizması önerdi; bu, incelemelerin sayısal sunumunun satışları olumlu yönde etkileyebileceğini bulan Wang (2019) tarafından daha ayrıntılı olarak araştırıldı. Ancak yıldız sunumu kesintilerde olumsuz sıçramalar yaratarak inceleme manipülasyonunda azalmaya yol açabilir. Venkatesakumar (2020), yıldız derecelendirmelerinin ürün kategorileri ve perakendeciler arasındaki dağılımını karşılaştırdı ve Amazon'un daha yüksek derecede olumsuz içeriğe izin verdiğini tespit etti. Magnusson (2019), Wayfair.com'daki derecelendirmelerdeki her yarım yıldız artış için ürün talebinde %5'lik bir artış olacağını ve en yüksek puan alan ürünlerin en fazla fayda sağlayacağını tahmin etti. Bu çalışmalar topluca, e-pazaryerlerindeki yıldız derecelendirmelerinin karmaşık dinamiklerini ve bunların tüketici davranışları ve satıcı stratejileri üzerindeki etkilerini anlamak için daha fazla araştırmaya duyulan ihtiyacı vurgulamaktadır.

### 1.1.3. Dijital Şikâyet Sistemi

Dijital çağın bir getirisi olarak tüketiciler, internet ortamında karşılaştıkları tüm olumlu veya olumsuz durumlar hakkında kolayca görüş beyan edebilir hale gelmiştir. Bu görüşler çevrimiçi yorumlar, ürün değerlendirmeleri, sosyal medya içerikleri, blog yazıları gibi çeşitli türlerde olabilmektedir. Bahsedilen bu görüş bildirme eylemi elektronik ağızdan ağıza pazarlamayı (eWOM) da beraberinde getirir. eWOM, “potansiyel, gerçek veya eski müşterilerin bir ürün veya şirket hakkında yaptığı ve internet aracılığıyla çok sayıda kişi ve kurumun kullanımına sunulan olumlu veya olumsuz her türlü beyan” olarak tanımlanmaktadır (Hennig-Thurau vd., 2004: 39). Tüketiciler yaşadığı deneyimden memnun olmadığında, memnun olanlara oranla daha fazla elektronik ağızdan ağıza iletişim kurmaya meyilli oluyorlar ve çevrimiçi platformlarda daha fazla değerlendirme bırakmaya yatkın oluyorlar (Anderson, 1998: 12; Richins, 1983: 75). Bu olumsuz değerlendirmelerin satın alma kararını etkilemesindeki rolünü Cone Research'ün bir araştırması, çevrimiçi alışveriş yapan beş kullanıcıdan

dördünün, bir mal veya hizmeti satın alma kararını gördükleri olumsuz değerlendirmelere dayanarak değiştirdiğini göstererek kanıtlamıştır (Cone, 2011: 8).

## 1.2. Çevrimiçi Müşteri Değerlendirmeleri

İnternete kolay erişim, günümüzde insanların hemen hemen her şey için çevrimiçi satın alma yoluna gidebilmelerine olanak sağlamıştır. Bu satın alımlar için karar vermeden önce tüketicilerin %75'i çevrimiçi müşteri değerlendirmelerini incelemek için araştırma yapıyor (BrightLocal, 2024). Çevrimiçi incelemeler gerçek yaşam deneyimlerini temsil eder ve potansiyel satın alıcılara, düşündükleri mal veya hizmetin kalitesi, değeri ve güvenilirliği hakkında kısa bir bakış sunar.

Çevrimiçi müşteri yorumları, kişisel ve uzman yorumlarının etkisine benzer bir etkiyle satın alma kararlarını etkilemede önemli bir rol oynar (Bounie, 2008: 417). Özellikle çevrimiçi perakende platformlarına karşı duygusal bağlılık ve güveni şekillendirmede etkilidirler ve sonuç olarak tekrar satın alma niyetini etkilerler (Güngör, 2020). Dahası, bu yorumlar müşteri güveni ve satın alma niyeti üzerinde olumlu bir etkiye sahiptir ve güven, yorumlar ile satın alma niyeti arasındaki ilişkiyi aracılık eder (Tanuwijaya vd., 2023). Ancak, çevrimiçi müşteri yorumu verilerinin akademik araştırmalarda kullanımı hala gelişmektedir ve daha kapsamlı ve çeşitli çalışmalara ihtiyaç duyulmaktadır (Trenz, 2013: 203).

Marka imajı, tüketicilerin bir markaya yönelik algılarını ve tutumlarını, o markayla olan deneyimlerine ve etkileşimlerine dayanarak nasıl oluşturduklarını açıklayan bir markalaşma kavramıdır (Kotler, 2012). Kotler (2012)'e göre marka imajı, tüketicilerin markayla yaşadığı tüm deneyimlerin toplamından yaratılmaktadır. Bu deneyimler tüketicilerin reklam, ambalaj, ürün kalitesi, müşteri hizmetleri ve diğer temas noktalarıyla karşılaşmalarından ve bunlarla etkileşimlerinden kaynaklanır.

Bahsedilen bu geleneksel marka imajının e-pazaryerlerinde de aynı düzlemde yer aldığını söylenebilmektedir (Keller, 1993). Burada şirketlerin marka imajlarını oluşturan etken müşterilerin çevrimiçi platformlarda yaptıkları deneyim paylaşımları olarak nitelendirilebilmektedir (Chen ve Xie, 2008). Satın alım esnasında veya sonrasında bir problemle karşılaşmayan ve satın alınan mal veya hizmet beklentiyi karşıladığında yapılacak olan olumlu deneyim değerlendirmeleri marka imajı için pozitif bir etki

yaratması beklenebilirken aynı durum tam tersi için de beklenebilmektedir (Park ve Lee, 2009).

İnternet üzerinden yapılan müşteri yorumları, kullanıcıların satın aldıkları ürün ve hizmetlerle ilgili görüşlerini paylaşmalarına olanak tanımaktadır (Chevalier ve Mayzlin, 2006). Bu yorumlar, tüketiciler ve işletmeler için değerli bilgi kaynaklarıdır ve pazarlama, tüketici davranışları ve bilgi yönetimi gibi çeşitli araştırma alanlarında önemli bir konudur (Mudambi ve Schuff, 2010).

### **1.2.1. Tüketici Davranışlarına Etkisi**

Çeşitli araştırmalar, online müşteri yorumlarının tüketici davranışları üzerindeki önemli etkilerini incelemiştir. Bu incelemeler potansiyel alıcıların karar verme sürecini büyük ölçüde etkileyebilir. Birçok çalışma, yüksek puanların ve olumlu yorumların satışları artırdığını, düşük puanların ve olumsuz yorumların ise satışları olumsuz etkilediğini gösteriyor. (Chevalier ve Mayzlin, 2006; Chen vd., 2011).

Çevrimiçi müşteri yorumları, özellikle satın alma kararlarını etkilemede tüketici davranışları üzerinde önemli bir etkiye sahiptir (Yaylı ve Bayram 2012: 60; Vimaladevi ve Dhanabhakaym, 2012: 91; Mo vd., 2015: 419; Mahdi, 2023: 8). Yüksek puanlı, resimli, ekli ve kümülatif yorumlar dahil olmak üzere olumlu yorumlar özellikle etkilidir (Mo vd., 2015: 419; Mahdi, 2023: 8). Ancak orta ve olumsuz yorumların yanı sıra lojistik ve hizmet puanlarının etkisi daha az önemlidir (Mo vd., 2015: 419; Mahdi, 2023: 8). Bu bulgular, tüketici davranışını olumlu yönde etkilemek için çevrimiçi müşteri yorumlarını yönetmenin ve yanıtlamanın önemini vurgulamaktadır.

### **1.2.2. Güven ve İtibar Yönetimi**

Tüketici incelemeleri, çevrimiçi mağazalarda güven ve itibarın şekillenmesinde çok önemli bir rol oynamaktadır; tüketici incelemeleri, mağaza itibarı veya güvence mühürlerinden daha önemli bir faktördür (Utz, vd., 2012: 52). Çevrimiçi incelemelere güven, elektronik ortamda ağızdan ağıza iletişim, uzman incelemeleri, düzenli müşteri yorumları ve yüksek miktardaki olumlu değerlendirmeler yoluyla inşa edilir (Santosh ve Babu, 2014: 343). SentiTrustCom STC gibi duyarlılığa dayalı bir güven ve itibar sistemi, aldatıcı incelemelerin tespit edilmesine ve güvenilir güven ve itibar puanlarının hesaplanmasına yardımcı olabilir (Rahimi vd., 2020: 776). Marka güveninin güvenilirlik

boyutu, çevrimiçi müşteri yorumlarının satın alma isteği üzerindeki etkisine aracılık ederken, niyet boyutunun çok az etkisi vardır (Cheng vd., 2015: 157).

Çevrimiçi incelemeler kurumsal itibar yönetimi stratejilerinde hayati bir rol oynamaktadır (Park ve Lee, 2009: 65). Olumlu yorumlar bir markanın güvenilirliğini ve itibarını artırabilirken, olumsuz yorumlar potansiyel müşteriler üzerinde olumsuz bir izlenim bırakabilir (Park ve Lee, 2009: 65). Bu nedenle işletmeler çevrimiçi itibarlarını aktif olarak izliyor ve yönetiyor.

### **1.2.3. Bilgi Asimetrisi ve Şeffaflık**

E-pazaryerlerindeki bilgi asimetrisi ve şeffaflığın etkisi karmaşık ve çok yönlüdür. Zhu (2004), bilgi şeffaflığının evrensel olarak yararlı olduğuna dair inancı sorgulayarak şeffaflık ile veri gizliliği arasındaki dengeyi vurgular. Soh vd. (2006), başarılı elektronik pazar yerlerinin (EMP'ler) fiyat şeffaflığından bağımsız olarak hem satıcılar hem de alıcılar için telafi edici faydalar sağlaması gerektiğini öne sürerek bunu daha da karmaşık hale getirir. Ancak, Zhu (2002) ve Zhu ve Zhou (2007), özellikle tedarik zinciri yönetiminde B2B elektronik pazarlarında bilgi şeffaflığının potansiyel değerini vurgularken, çıkar çatışması potansiyelini de kabul eder.

Online müşteri yorumları, bilgi asimetrisini azaltmada önemli bir araç olarak kullanılır. Geleneksel alışveriş yöntemlerinde tüketiciler ürünler hakkında sınırlı bilgiye sahipken, online yorumlar sayesinde gerçek kullanıcı deneyimlerine dayalı bilgilere erişim sağlanır (Dellarocas, 2003). Bu, daha şeffaf bir pazar ortamı yaratır ve tüketicilerin daha bilinçli kararlar almasına yardımcı olur.

### **1.2.4. Algoritmalar ve Veri Analizi**

Bir dizi çalışma, e-pazaryerlerindeki müşteri yorumlarını analiz etmede algoritmaların kullanımını araştırmıştır. Vanaja ve Belwal (2018) ve Permana ve Sahara (2021) her ikisi de duygu analizine odaklanmıştır; Vanaja ve Belwal, yorumların olumluluğunu, olumsuzluğunu ve tarafsızlığını belirlemek için sınıflandırma algoritmalarını kullanırken, Permana ve Sahara pazar yeri yorum yorumlarını sınıflandırmak için Destek Vektör Makinesi (SVM) yöntemini kullanmıştır. Davis ve Tabrizi (2021), çeşitli makine öğrenimi algoritmaları ve veri kümelerinin kullanımını tartışarak ve müşteri yorumu analizinin potansiyel uygulamalarını vurgulayarak alanın

kapsamlı bir incelemesini sunmaktadır. Ahmad vd. (2017), potansiyel alıcılar için bir özet sağlamayı amaçlayan, yapılandırılmamış müşteri yorumlarından görüşleri otomatik olarak çıkarmak için algoritmalar önermektedir.

Literatürde, online müşteri yorumlarının analizi için çeşitli algoritmalar ve yöntemler geliştirilmiştir. Doğal dil işleme (NLP) teknikleri, duygu analizi ve makine öğrenimi algoritmaları, büyük ölçekli değerlendirme verilerinin analizinde yaygın olarak kullanılmaktadır (Liu, 2022). Bu teknolojiler, işletmelerin müşteri geri bildirimlerini daha iyi anlamalarına ve stratejilerini buna göre şekillendirmelerine olanak tanır.

### **1.3. Kullanıcı Yorumlarının İnandırıcılığı ve Sahte Yorumlar**

Kullanıcı yorumlarının ve sahte yorumların güvenilirliğine ilişkin araştırmalar, birkaç önemli bulguyu ortaya koyuyor. Petit vd. (2021) ve Naab vd. (2020), olumsuz kullanıcı yorumlarının haber makalelerinin algılanan güvenilirliğini önemli ölçüde azaltabileceğini, bu etkinin olumlu kullanıcı yorumlarının varlığıyla hafifletildiğini bulmuştur. Kluck vd. (2019) ayrıca, olumsuz kullanıcı yorumlarının yanlış haberlerin inandırıcılığını azaltabileceğini ve bunun da bu tür içerikleri paylaşma isteğinin azalmasına yol açabileceğini göstermektedir. Abedin vd. (2024), sahte ve güvenilir incelemeleri yüksek doğrulukla ayırt edebilen tahmine dayalı bir model geliştirerek bu tartışmayı çevrimiçi incelemelere kadar genişletti. Bu model uzunluk, öznellik, okunabilirlik, aşırılık ve tutarlılık gibi çeşitli inceleme özelliklerini dikkate almaktadır.

Bazı araştırmalar müşteri değerlendirmelerinin potansiyel alıcıların satın alma kararını doğrudan etkilediğini ve bu etkinin manipüle edildiğini göstermek adına, satıcıların marka imajı ve tanınırlık kazanmak için sahte yorumlar satın aldıklarını göstermektedir (Sherry vd., 2021). Bir diğer araştırmada ise bu sahte yorumların tespit edilmesi için bazı yaklaşımlar önerilmiştir (Mohawesh vd., 2021). Yapılan bir başka çalışmada ise sahte yorumların tespit edilmesi için makine sınıflandırıcısı geliştirmiş ve bu sınıflandırıcının insan eliyle tespitten daha başarılı olduğu ortaya koyulmuştur (Salminen vd., 2022).

Tüm bu araştırmaların ışığında çevrimiçi müşteri değerlendirmelerinin doğruluğu ve inandırıcılığının saptanmasının hem şirketler hem de potansiyel satın alıcılar için büyük bir önem arz ettiğini söylenebilmektedir.

## İKİNCİ BÖLÜM

### WEB MADENCİLİĞİ VE MAKİNE ÖĞRENİMİ KULLANIMI

#### 2.1. Web Madenciliği

Veri madenciliğinin bir alt kümesi olan web madenciliği, web belgeleri, içerik, köprü metinleri ve sunucu günlükleri gibi web ile ilgili veri kaynaklarından bilgi çıkarmayı içerir (Kumar, 2017). Üç ana alanı kapsar: içerik, yapı ve kullanım (Malviya, 2011). İçerik madenciliği bilgi keşfine odaklanır, yapı madenciliği web sayfaları arasındaki ilişkiyi analiz eder ve kullanım madenciliği sunucu günlüklerinden kalıpları ve içgörülerini çıkarır (Kumar, 2017). Veri madenciliği tekniklerinin web verilerine uygulanması, istikrarlı bir araştırmacı topluluğu ve önemli fikirlerle farklı bir alanın gelişmesine yol açmıştır (Srivastava vd, 2004). Raut (2012), web'de bilgi keşfi için veri madenciliği tekniklerinin kullanımını daha da vurgulamaktadır.

Web madenciliği kavramı 1996 yılında Oren Etzioni tarafından ortaya atılmıştır (Etzioni, 1996). Etzioni (1996) bu çalışmasında veri madenciliği tekniklerini kullanarak çevrimiçi platformlardan oluşturulan otomasyonlarla bilgilerin alınması, işlenmesi ve analiz edilmesinden bahsetmiştir. Dolayısıyla web madenciliğinin de kendi içerisinde kullanılan teknikleri ve sınıfları ortaya çıkmıştır (Kosala ve Blockeel, 2000).

#### 2.1.1. Web Madenciliği Teknikleri

Veri madenciliğinin bir alt kümesi olan web madenciliği, web verilerinden bilgi ve veri çıkarmayı içerir. Üç ana tekniği kapsar: web içeriği madenciliği, web yapısı madenciliği ve web kullanım madenciliği (Velkumar, 2020). Bu teknikler, kullanıcı gezinme modellerini analiz etmek ve veri erişim verimliliğini artırmak için kullanılır (Al-asadi vd., 2017). Alan, web verilerinin engin ve çeşitli doğası gibi zorluklarla karşı karşıyadır ve araştırmacılar bu sorunları ele almak için çalışmaktadır (Jokar, 2016). E-ticaret ve müşteri davranış yönetimi dahil olmak üzere çeşitli alanlarda web madenciliği tekniklerinin uygulanması da bir araştırma odak noktasıdır (Jokar, 2016). Kaydedilen ilerlemeye rağmen, web madenciliğinde hala araştırma boşlukları ve keşfedilecek gelecekteki yönler vardır (Jayalatchumy, 2013).

### 2.1.1.1. Web İçerik Madenciliği

Web madenciliğinin temel bir bileşeni olan web içeriği madenciliği, web sayfası içeriklerinden bilgi çıkarmayı ve analiz etmeyi içerir (Kumar, 2017). Bu süreç, kullanıcılara ilgili bilgileri düzenlemek ve sağlamak için çok önemlidir (Liu, 2005). Web içeriği madenciliği teknikleri, içerik alaka düzeyini belirlemek için metin, resim ve grafiklerin taranmasını ve çıkarılmasını içerir (Navadiya, 2012). İçerik madenciliğinin yapılandırılmış, yapılandırılmamış, yarı yapılandırılmış ve multimedya verilerine uygulanması da araştırılmaktadır (Johnson, 2012).

Web içerik madenciliği, çeşitli yazılımlar ve robotlar kullanılarak web sayfalarının içeriklerinden istenilen bilginin elde edilmesidir (Inamdar ve Shinde, 2010).

Web içeriği madenciliği, Web'den kaynak keşfini (Chakrabarti vd., 1999; Cho ve Garcia-Molina., 1998), belge kategorizasyonunu (Zamir ve Etzioni, 1999; Kohonen vd., 2000) ve kümelenmesini ve Web sayfalarından bilgi çıkarılmasını içerir.

### 2.1.1.2. Web Kullanım Madenciliği

Web madenciliğinin bir alt kümesi olan web kullanım madenciliği, web tabanlı uygulamaları geliştirmek için web verilerinden, özellikle web günlüklerinden kullanım modellerinin keşfedilmesini ve analiz edilmesini içerir (Srivastava vd, 2004; Malviya, 2011; Kumar ve Goyal, 2012; Neelima ve Kumar, 2015). Bu süreç genellikle veri toplama, hazırlama, model keşfi, analiz ve uygulamayı içerir (Kumar ve Goyal, 2012). Web sunucusu günlüklerinden çıkarılan bilgiler, web sitesi tasarımı, değerlendirme, pazarlama ve ağ trafiği akışı analizi gibi çeşitli uygulamalarda kullanılabilir (Kumar ve Goyal, 2012). Potansiyeline rağmen, web kullanım madenciliği veri gizliliği ve güvenlik endişeleri gibi zorluklarla karşı karşıyadır (Srivastava vd, 2004).

Web kullanım madenciliği, kullanıcıların siteyi kullanırken ardında bıraktığı izlerden bilgi üretir. Bu izler log adı verilen dosyalarda saklanır ve kullanıcıların erişim verilerinin kayıtlarını tutar. Buradaki amaç kullanıcıların web sayfaları ile aralarındaki ilişkinin saptanmasıdır. Örneğin site ziyaretçilerinin sayfa üzerinde kalma süreleri, tıklama sayıları, reklam tıklamaları, içerik temelli yöneldikleri sayfalar vb. veriler loglarda kaydedilir ve daha sonra bunlardan anlamlı bir ilişki çıkartılmak amaçlanır (Tükoğlu ve Poyraz, 2008).

### 2.1.1.3. Web Yapı Madenciliği

Web veri analizinin temel bir yönü olan web yapısı madenciliği, web'in hiper bağlantı yapısından değerli bilginin çıkarılmasını içerir. Sharma (2014) ve Rajdepa (2013) her ikisi de bu sürecin önemini vurgular ve Sharma web yapısı madenciliği algoritmalarını bağlantı analizi ve kümeleme algoritmaları olarak kategorize eder. Praba (2011), web yapısı madenciliğinde yaygın olarak kullanılan PageRank ve Geliştirilmiş PageRank algoritmalarına genel bir bakış sunar. Shivakumar (2014), çeşitli algoritmaların güçlü ve zayıf yönlerini tartışarak web yapısı madenciliğinin geleceğini daha ayrıntılı olarak araştırır. Bu çalışmalar toplu olarak web'den değerli bilgi çıkarmada web yapısı madenciliğinin önemini vurgular.

Web yapı madenciliği, web sayfalarının arasında bulunan linkleri izleyerek bu linkler aracılığıyla bir çizge çıkarmayı ve bu çizge üzerinden de analizler yapmayı hedeflemektedir. Bu sayede site içerisinde veya harici başka siteler arasında ne kadar bağlantı verildiği üzerine bir grafik oluşturulabilir. Bu oluşturulan grafikler site içerik üreticileri, site yöneticileri veya tasarımcılarına faydalı bilgiler sunabilmektedir (Da Costa ve Gong, 2005).

### 2.1.2. Web Madenciliğinde Kullanılan Yazılımlar

Web madenciliği, internet üzerindeki büyük veri setlerinden anlamlı bilgiler elde etme sürecidir. Bu süreçte kullanılan yazılımlar, verilerin toplanması, işlenmesi ve analiz edilmesi için kritik bir rol oynar. Web madenciliği için çeşitli yazılımlar ve araçlar geliştirilmiştir ve bu araçlar, veri bilimciler ve araştırmacılar tarafından geniş çapta kullanılmaktadır (Liu, 2007).

Web madenciliği yazılımları arasında popüler olanlardan biri, açık kaynak kodlu bir veri madenciliği yazılımı olan Apache Nutch'tur. Nutch, büyük ölçekli web taramaları yapabilme yeteneği ve Hadoop ile entegrasyonu sayesinde yüksek verimli veri toplama ve işleme imkânı sunar. Bu özellikleri sayesinde, geniş veri setlerinin işlenmesi ve analizi için uygun bir araç olarak öne çıkar (Khoury ve Dagher, 2015).

Bir diğer önemli yazılım ise Scrapy'dir. Scrapy, Python tabanlı bir web tarama ve veri çıkarma aracıdır. Kullanıcı dostu yapısı ve esnekliği ile Scrapy, hem basit hem de karmaşık veri çıkarma projelerinde yaygın olarak kullanılmaktadır. Scrapy'nin güçlü



yönlerinden biri, CSS seçicileri ve XPath ifadeleri kullanarak belirli veri elemanlarının kolayca çıkarılabilmesidir. Ayrıca, Scrapy'nin geniş eklenti desteği, özelleştirilmiş veri çıkarma işlemlerinin kolayca yapılmasına olanak tanır (Zhao ve Mitra, 2015).

WebHarvy ise, kullanıcı arayüzü üzerinden görsel olarak veri çıkarma işlemleri yapabilen bir yazılımdır. Kod yazma gereksinimini ortadan kaldıran WebHarvy, kullanıcıların tıklama ve seçim işlemleri ile veri çıkarma kurallarını belirlemelerine olanak tanır. Bu sayede, teknik bilgisi sınırlı kullanıcılar bile etkili bir şekilde web madenciliği yapabilir (Srirama vd., 2017).

Web madenciliği yazılımlarının bir diğer önemli örneği, Mozenda'dır. Mozenda, bulut tabanlı bir veri çıkarma ve yönetim platformudur. Kullanıcıların tarayıcı üzerinden veri çıkarma işlemlerini tanımlamalarına olanak tanır ve çıkarılan verileri yapılandırılmış bir şekilde saklar. Mozenda'nın bulut tabanlı yapısı, kullanıcıların herhangi bir cihazdan veri çıkarma işlemlerini yönetmelerini sağlar (Tang, 2011).

Sonuç olarak, web madenciliğinde kullanılan yazılımlar, büyük veri setlerinden değerli bilgiler elde etmek için vazgeçilmez araçlardır. Bu yazılımlar, veri toplama, işleme ve analiz süreçlerini kolaylaştırarak, araştırmacıların ve veri bilimcilerin daha etkili çalışmalar yapmasına olanak tanır. Her yazılımın kendi güçlü yönleri ve kullanım alanları bulunmaktadır; bu nedenle, proje gereksinimlerine en uygun yazılımın seçilmesi, web madenciliği süreçlerinin başarısı için kritik bir öneme sahiptir.

### **2.1.3. Web Madenciliğinin Kullanım Alanları**

Web madenciliği, internet üzerindeki büyük ve karmaşık veri setlerinden değerli bilgiler elde etme sürecidir. Bu teknik, çeşitli alanlarda geniş uygulama alanları bulmuş ve pek çok endüstride önemli katkılar sağlamıştır (Liu, 2007).

Birincil kullanım alanlarından biri e-ticaret sektörüdür. E-ticaret platformları, müşteri davranışlarını analiz ederek ürün öneri sistemlerini geliştirmek için web madenciliği tekniklerinden yararlanır. Amazon gibi büyük e-ticaret siteleri, kullanıcıların önceki alışveriş geçmişlerini ve gezinme davranışlarını analiz ederek kişiselleştirilmiş ürün önerileri sunar. Bu tür sistemler, müşteri memnuniyetini artırmanın yanı sıra satışları da önemli ölçüde artırır (Mobasher, 2007).

Bir diğerk önemli kullanım alanı sosyal medya analitiğidir. Sosyal medya platformları, kullanıcıların gönderilerini, beğenilerini, yorumlarını ve paylaşımlarını analiz ederek çeşitli trendleri ve kullanıcı duyarlılıklarını ortaya çıkarır. Bu bilgiler, pazarlama stratejilerinin geliştirilmesi, kriz yönetimi ve marka imajının iyileştirilmesi gibi çeşitli amaçlar için kullanılabilir. Özellikle Twitter ve Facebook gibi platformlar, kamuoyu yoklamaları ve politik analizler için geniş veriler sunar (Agarwal vd., 2012).

Sağlık sektörü de web madenciliğinden büyük ölçüde faydalanmaktadır. Sağlıkla ilgili forumlar, bloglar ve sosyal medya platformlarından elde edilen veriler, hastalıkların yayılımı, hasta deneyimleri ve tedavi yöntemleri hakkında değerli bilgiler sağlayabilir. Bu veriler, epidemiyolojik araştırmalar ve halk sağlığı politikalarının geliştirilmesi için kullanılabilir. Örneğin, Google Flu Trends, grip salgınlarının yayılmasını tahmin etmek için arama motoru sorgularını analiz ederek erken uyarı sistemleri geliştirmiştir (Brownstein vd., 2009).

Web madenciliği, eğitim alanında da önemli uygulamalara sahiptir. Eğitim kurumları, öğrenci performansını ve öğrenme davranışlarını analiz ederek öğretim yöntemlerini iyileştirebilir. Online öğrenme platformları, öğrencilerin derslere olan ilgilerini, başarılarını ve zorluklarını analiz ederek kişiselleştirilmiş eğitim deneyimleri sunar. Bu tür analizler, öğrencilerin başarısını artırmanın yanı sıra eğitim materyallerinin de sürekli olarak iyileştirilmesine olanak tanır (Romero ve Ventura, 2010).

Finans sektörü web madenciliği tekniklerini risk yönetimi, dolandırıcılık tespiti ve piyasa trendlerinin analizinde kullanmaktadır. Bankalar ve finans kurumları, müşteri işlemlerini ve davranışlarını analiz ederek potansiyel riskleri ve dolandırıcılık faaliyetlerini tespit edebilir. Ayrıca, web madenciliği, hisse senedi piyasaları ve yatırım stratejileri hakkında öngörülerde bulunmak için de kullanılır (Nakashima ve Jasuja, 2011).

Sonuç olarak, web madenciliği, e-ticaretten sağlığa, sosyal medyadan finans sektörüne kadar geniş bir yelpazede çeşitli uygulama alanlarına sahiptir. Bu teknikler, büyük veri setlerinden anlamlı bilgiler elde etmeye olanak tanıyarak, farklı sektörlerde karar verme süreçlerini ve stratejik planlamayı önemli ölçüde iyileştirmektedir.

## 2.2. Makine Öğrenimi

Makine öğrenimi, bilgisayar sistemlerinin açıkça programlanmadan verilerden öğrenmesini ve performansını iyileştirmesini sağlayan bir yapay zekâ dalıdır (Mitchell, 1997). Bu disiplin, istatistik, yapay zekâ ve bilişim bilimlerinin kesişim noktasında yer alır ve veri analizi, örüntü tanıma ve karar verme süreçlerini otomatikleştirmek için matematiksel ve algoritmik yöntemler kullanır (Bishop, 2006). Makine öğrenimi modelleri, büyük veri kümelerinden bilgi çıkararak, gelecekteki olaylar veya sonuçlar hakkında tahminlerde bulunma yeteneğine sahiptir (Murphy, 2012).

Gerçek dünyada makine öğreniminin başarılı uygulamaları arasında sağlık sektörü, finansal hizmetler, e-ticaret ve sosyal medya analitiği yer alır. Örneğin, sağlık sektöründe, makine öğrenimi algoritmaları tıbbi görüntülerin analizi ve hastalıkların erken teşhisi için kullanılmaktadır (Litjens vd., 2017). Finansal hizmetlerde ise kredi risk değerlendirmesi ve dolandırıcılık tespiti gibi alanlarda etkin bir şekilde uygulanmaktadır (Lessmann vd., 2015). E-ticaret platformlarında müşteri davranışlarının analizi ve kişiselleştirilmiş öneri sistemleri geliştirmek için de makine öğrenimi yoğun olarak kullanılmaktadır (Zhao vd., 2017). Bu örnekler, makine öğreniminin çeşitli sektörlerdeki etkileyici potansiyelini ve kullanım alanlarını göstermektedir.

### 2.2.1. Makine Öğrenimi Modelleri

Makine öğrenimi modelleri, çeşitli varlıklar için kararlar veren karmaşık sistemlerdir ve davranışlarının daha zengin açıklayıcı ve öngörücü hesaplarına artan bir ihtiyaca yol açar (Raül vd., 2017). Bu modeller, terimler ve sonuçlar arasındaki ilişkileri ölçmek için yapılandırılmış ve yapılandırılmamış veriler kullanılarak eğitilir ve girdi değerlerine dayalı tahminler üretir (Anil vd., 2019). Stilometrik uygulamalarda, her biri metin analizi ve sınıflandırması için farklı metodolojiler kullanan k-en yakın komşular, saf Bayes, destek vektör makineleri ve lojistik regresyon gibi farklı makine öğrenimi algoritmaları, yazarlık ilişkilendirmesi veya profilleme için kullanılır (Savoy, 2020). Makine öğrenimi alanı, finansal zaman serisi tahmini ve doğal dil işleme gibi çeşitli alanlarda uygulamalarla denetimli ve denetimsiz öğrenme, pekiştirmeli öğrenme, istatistiksel çıkarım ve olasılık ağları dahil olmak üzere çok çeşitli model ve algoritmaları kapsar (Bloch, 2023). Makine öğrenimindeki yoğunlaşan araştırmalar genç bilim adamlarını cezbederek bu alanda değerli katkılara ve ilerlemelere yol açtı (Bradshaw vd., 2012).

Bir dizi çalışma, çeşitli alanlarda makine öğrenimi modellerinin etkinliğini vurgulamıştır. Barboza (2017), özellikle torbalama, artırma ve rastgele orman olmak üzere makine öğrenimi modellerinin iflası tahmin etmede geleneksel istatistiksel tekniklerden daha iyi performans gösterdiğini bulmuştur. Mosavi (2019), özellikle hibritleştirildiklerinde bu modellerin enerji sistemlerindeki doğruluk ve sağlamlığındaki artışın altını çizmiştir. Sambath (2022), yerçekimi dalgalarını tespit etmekten finansal piyasa talebini tahmin etmeye kadar makine öğreniminin uygulamalarına ilişkin geniş bir genel bakış sunmuştur. Ardabili (2019), özellikle hesaplamalarını, işlevselliklerini ve doğruluklarını artırmak için hibrit ve topluluk tekniklerinin kullanımı olmak üzere makine öğrenimi modellerindeki gelişmeleri incelemiştir. Bu çalışmalar, makine öğrenimi modellerinin çeşitli alanlardaki artan önemini ve potansiyelini topluca vurgulamaktadır.

Makine öğrenimi, bilgisayarların verilerden öğrenmesini ve tahminler yapmasını sağlayan bir yapay zekâ dalıdır. Bu alan, çeşitli modeller ve algoritmalar kullanarak büyük veri kümelerinden anlamlı bilgiler elde etmeyi amaçlar. Makine öğrenimi modelleri, gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme gibi farklı kategorilere ayrılabilir (Mitchell, 1997).

### 2.2.1.1. Gözetimli Öğrenme Modelleri

Gözetimli öğrenme, etiketli veriler kullanılarak yapılan öğrenme sürecini ifade eder. Bu kategoride en yaygın kullanılan modellerden bazıları şunlardır:

- **Doğrusal Regresyon (Linear Regression):** Bu model, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi doğrusal bir şekilde modellemeyi amaçlar (Seber ve Lee, 2003).
- **Destek Vektör Makineleri (Support Vector Machines - SVM):** Bu model, sınıflandırma problemlerinde verileri en iyi ayıran düzlemi bulmaya çalışır. Özellikle yüksek boyutlu veri kümelerinde etkili sonuçlar üretir (Cortes ve Vapnik, 1995).
- **Karar Ağaçları (Decision Trees):** Bu model, verileri belirli kurallara göre dallandırarak sınıflandırma veya regresyon problemlerini çözer. Karar ağaçları, anlaşılabilirlik ve yorumlanabilirlik açısından avantajlıdır (Quinlan, 1986).

- **Rastgele Ormanlar (Random Forests):** Bu model, birçok karar ağacının bir araya gelerek oluşturduğu bir ansambl modelidir. Rastgele ormanlar, overfitting problemini azaltır ve genellikle yüksek doğruluk sağlar (Breiman, 2001).
- **Gradyan Artırma (Gradient Boosting):** Bu model, zayıf tahmincilerin ardışık olarak eğitilmesiyle güçlü bir model oluşturur. Her bir yeni model, önceki modellerin hatalarını düzeltmeye çalışır (Friedman, 2001).
- **K-En Yakın Komşu (K-Nearest Neighbors - k-NN):** Bu model, sınıflandırma ve regresyon problemlerinde en yakın k komşunun sınıfına veya değerine göre tahmin yapar. k-NN, basit ve yorumlanabilir bir algoritmadır (Cover ve Hart, 1967).
- **Naive Bayes:** Bu model, Bayes teoremini kullanarak sınıflandırma problemlerini çözer. Naive Bayes, özellikle metin sınıflandırma ve spam filtreleme gibi problemlerde etkilidir (Maron, 1961).
- **Lojistik Regresyon (Logistic Regression):** Bu model, bağımlı değişkenin ikili olduğu durumlarda kullanılır ve verilerin olasılıklarını tahmin eder. Lojistik regresyon, sınıflandırma problemlerinde yaygın olarak kullanılır (Hosmer Jr. ve Lemeshow, 2000).
- **CN2 Algoritması:** Bu model, kural tabanlı sınıflandırma için kullanılır ve verilerden anlamlı kurallar çıkarmayı amaçlar. CN2, özellikle uzman sistemlerde ve karar destek sistemlerinde kullanılır (Clark ve Niblett, 1989).

### 2.2.1.2. Gözetimsiz Öğrenme Modelleri

Gözetimsiz öğrenme, etiketlenmemiş verilerle çalışarak veriler arasındaki gizli kalıpları keşfetmeyi amaçlar. Bu kategoride öne çıkan modellerden bazıları şunlardır:

- **K-Ortalamalar (K-Means):** Bu model, verileri k sayıda kümeye ayırarak her küme için bir merkez nokta belirler. Veriler, bu merkez noktalara olan uzaklıklarına göre kümelere atanır (MacQueen, 1967).
- **Temel Bileşen Analizi (Principal Component Analysis - PCA):** Bu model, veri kümesindeki boyut sayısını azaltarak veriler arasındaki ilişkileri ortaya çıkarmayı hedefler. PCA, verilerin en büyük varyansa sahip olduğu bileşenleri belirler (Pearson, 1901).

### 2.2.1.3. Pekiştirmeli Öğrenme Modelleri

Pekiştirmeli öğrenme, bir ajanın çevresiyle etkileşime girerek ödül veya ceza sistemine dayalı olarak öğrenme sürecini ifade eder. Bu kategori, oyun teorisi ve robotik gibi alanlarda yaygın olarak kullanılır (Sutton ve Barto, 1998).

- **Q-Öğrenme (Q-Learning):** Bu model, bir ajanın belirli bir durumdan hangi eylemi gerçekleştirmesi gerektiğini öğrenmesi için kullanılır. Q-öğrenme, ödül fonksiyonuna dayalı olarak eylem-değer fonksiyonunu iteratif olarak günceller (Watkins ve Dayan, 1992).
- **Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning):** Bu model, derin sinir ağları kullanarak pekiştirmeli öğrenme problemlerini çözmeyi amaçlar. Özellikle karmaşık ve yüksek boyutlu veri kümelerinde etkili sonuçlar üretir (Mnih vd., 2015).

### 2.2.2. Makine Öğrenimi Model Seçimi

Makine öğrenimi model seçimi, veri bilimi ve yapay zekâ uygulamalarının en kritik aşamalarından biridir. Model seçimi süreci, verilerin doğası, problem tipi, performans ölçütleri ve hesaplama kaynakları gibi birçok faktörü dikkate almayı gerektirir. Bu süreçte, farklı modellerin performansını değerlendirip karşılaştırmak için çeşitli metodolojiler ve araçlar kullanılmaktadır. (Bishop, 2006; Hastie vd., 2009).

Bir makine öğrenimi modelini seçerken ilk adım, problemin doğasını anlamaktır. Denetimli öğrenme problemleri, sınıflandırma ve regresyon olmak üzere iki ana kategoriye ayrılır. Sınıflandırma problemleri için, Naive Bayes, Destek Vektör Makineleri (SVM), ve Yapay Sinir Ağları gibi modeller yaygın olarak kullanılırken; regresyon problemleri için Doğrusal Regresyon, Ridge Regresyon ve Lasso gibi modeller tercih edilmektedir. Hangi modelin seçileceği, veri setinin büyüklüğü, özellik sayısı ve veri yapısı gibi faktörlere bağlıdır (Goodfellow vd., 2016).

Model seçimi sürecinde önemli bir diğer faktör, modelin genelleme yeteneğidir. Bir modelin genelleme yeteneği, eğitim verisinde öğrendiği bilgileri yeni ve görülmemiş verilerde ne kadar iyi uygulayabildiği ile ilgilidir. Genellikle, karmaşık modeller daha yüksek öğrenme kapasitesine sahip olsa da aşırı uyum (overfitting) riski taşırlar. Bu nedenle, model değerlendirmesinde çapraz doğrulama (cross-validation) gibi teknikler

kullanılarak modelin performansı test edilir ve uygun hiper parametreler belirlenir (James vd., 2013).

Bunun yanı sıra, modelin hesaplama maliyetleri de göz önünde bulundurulmalıdır. Bazı modeller, büyük veri setlerinde veya yüksek boyutlu verilerde hesaplama açısından oldukça maliyetli olabilir. Bu durumda, daha hızlı ve hafif modeller tercih edilebilir. Örneğin, Lojistik Regresyon ve Naive Bayes gibi modeller, büyük veri setleri için genellikle daha uygundur (Murphy, 2012).

Sonuç olarak, makine öğrenimi model seçimi, veri bilimi projelerinin başarısı için kritik bir süreçtir ve dikkatli bir değerlendirme gerektirir. Modelin performansı, genelleme yeteneği, hesaplama maliyetleri ve veri setinin özellikleri gibi faktörler dikkate alınarak, en uygun model seçilmelidir. Bu süreçte, literatürdeki çeşitli metodolojiler ve en iyi uygulamalar rehberlik edici olabilir.

Makine öğrenimi modeli seçimi, çeşitli uygulamaların performansını ve verimliliğini önemli ölçüde etkileyebilecek kritik bir görevdir. Araştırmalar, enerji tüketimi tahmininde gösterildiği gibi, en uygun ML modelini seçmek için Derin Takviye Öğrenme (DRL) kullanmak gibi dinamik yaklaşımların önemini göstermiştir (Cerar ve Hribar, 2023). Ek olarak, kümeleme yöntemlerinin portföy optimizasyon modellerine entegrasyonunun varlık seçimi ve tahsisinde etkili olduğu kanıtlanmıştır ve Hiyerarşik Risk Paritesi modeli Sharpe oranı açısından diğerlerinden daha iyi performans göstermiştir (Gularta ve Curtis, 2023). F Puanı ve Karşılıklı Bilgi Puanı gibi özellik seçim teknikleri, makine öğrenimi modellerini kullanarak çatlak boyutlarını tahmin etmede görüldüğü gibi öğrenme doğruluğunu ve hesaplama verimliliğini artırmada hayati bir rol oynar (William vd., 2023). Ayrıca, rastgele orman gibi çeşitli makine öğrenimi algoritmalarının yanı sıra ki-kare, ANOVA ve karşılıklı bilgi gibi farklı özellik seçim yöntemlerinin uygulanması, yüksek doğruluk ve özgüllük ile erken evre kalp hastalığı tahmini potansiyelini vurgular (Biswas vd., 2023).

Bir makine öğrenimi modelinin seçimi, bu amaç için çeşitli yöntemler ve araçlar mevcut olduğundan, model geliştirmenin kritik bir yönüdür. Model seçimini otomatikleştiren bir araç olan AutoML, umut verici bir yaklaşımdır (Jabour, 2023). Ancak, bir model seçerken belirli bağlamı ve veri özelliklerini dikkate almak ve uygun değerlendirme tekniklerini kullanmak önemlidir (Raschka, 2018). Aşamalı örnekleme

tabanlı Bayes optimizasyonu hem algoritma hem de hiper parametre seçimi için etkili bir yöntem olarak önerilmiştir (Zeng, 2017). Zaman serisi verileri bağlamında, model seçimi veri özellikleri ve aşırı uyum ve aşırı seçimden kaçınma ihtiyacı tarafından yönlendirilmelidir (Ferreira, 2015).

### 2.2.3. Makine Öğreniminde Performans Ölçüleri

Makine öğrenimi modellerinin değerlendirilmesi ve karşılaştırılması, doğru performans ölçümlerinin kullanılmasını gerektirir. Performans ölçüleri, bir modelin ne kadar iyi performans gösterdiğini belirlemek için kullanılan kantitatif kriterlerdir ve modelin güçlü ve zayıf yönlerini ortaya koyar. Farklı problem türlerine (sınıflandırma, regresyon, vb.) göre değişen çeşitli performans ölçüleri bulunmaktadır (Fawcett, 2006; Powers, 2011).

Sınıflandırma problemleri için en yaygın performans ölçülerinden biri doğruluk (accuracy) oranıdır. Doğruluk, doğru sınıflandırılan örneklerin toplam örnek sayısına oranını ifade eder.

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

Burada, TP (True Positives), TN (True Negatives), FP (False Positives) ve FN (False Negatives) sırasıyla doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif sayılarıdır (Powers, 2011).

Ancak, sınıfların dengesiz olduğu durumlarda doğruluk tek başına yeterli olmayabilir. Bu durumda, hassasiyet (precision), duyarlılık (recall) ve F1 skoru gibi diğer ölçütler daha anlamlı olabilir.

Hassasiyet, doğru pozitif tahminlerin toplam pozitif tahminlere oranıdır.

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

Hassasiyet, modelin yanlış pozitif üretme eğilimini değerlendirir (Sokolova ve Lapalme, 2009).

Duyarlılık, doğru pozitif tahminlerin toplam gerçek pozitiflere oranıdır.



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

Duyarlılık, modelin yanlış negatif üretme eğilimini değerlendirir (Sokolova ve Lapalme, 2009).

F1 skoru ise hassasiyet ve duyarlılığın harmonik ortalamasıdır ve dengesiz veri setlerinde daha dengeli bir performans ölçüsü sunar (Sokolova ve Lapalme, 2009).

$$\text{F1 Skoru} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4)$$

F1 skoru, modelin genel performansını tek bir ölçüt ile ifade eder (Sasaki, 2007).

Regresyon problemlerinde ise yaygın olarak kullanılan performans ölçüleri arasında Ortalama Kare Hata (Mean Squared Error - MSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve R-kare ( $R^2$ ) bulunmaktadır.

MSE, tahmin edilen ve gerçek değerler arasındaki farkların karelerinin ortalamasını alarak hatayı ölçer.

$$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

Burada  $y_i$  gerçek değerleri,  $\hat{y}_i$  tahmin edilen değerleri ve  $n$  örnek sayısını ifade eder (Hastie vd., 2009).

MAE ise bu farkların mutlak değerlerinin ortalamasını alır.

$$\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

MAE, modelin tahmin hatalarının ortalama büyüklüğünü ölçer (Willmott ve Matsuura, 2005).

R-kare, modelin bağımsız değişkenler tarafından açıklanan varyans oranını ölçer ve modelin genel uyumunu değerlendirmek için kullanılır (Hyndman ve Koehler, 2006).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

Burada  $\bar{y}_i$  gerçek değerlerin ortalamasını ifade eder. R-kare, modelin açıklama gücünü yüzdelik olarak gösterir (Draper ve Smith, 1998).

Ayrıca, ROC eğrisi (Receiver Operating Characteristic) ve AUC (Area Under the Curve) gibi metrikler, sınıflandırma modellerinin performansını değerlendirmede önemli rol oynar. ROC eğrisi, modelin farklı eşik değerlerindeki duyarlılık ve özgüllük oranlarını gösterir. AUC, ROC eğrisi altındaki alanı ölçer ve modelin genel ayırt edicilik yeteneğini yansıtır. AUC değeri 1'e ne kadar yakınsa, modelin performansı o kadar iyi kabul edilir (Bradley, 1997).

$$AUC = \int_0^1 ROC(threshold) d(threshold) \quad (8)$$

Makine öğrenimi modellerinin değerlendirilmesinde doğru performans ölçülerinin seçimi, modelin gerçek dünya uygulamalarında ne kadar başarılı olacağını belirlemek için kritik öneme sahiptir. Her bir performans ölçütü, modelin farklı yönlerini ortaya koyar ve modelin geliştirilmesi ve iyileştirilmesi için önemli bilgiler sağlar. Bu nedenle, problemin doğasına ve veri setinin özelliklerine uygun performans ölçülerinin kullanılması büyük önem taşır.

#### 2.2.4. Makine Öğrenimi Sonuçlarının Yorumlanması

Makine öğrenimi modellerinin etkinliğini belirlemek için kullanılan performans ölçütleri, modelin gerçek dünya problemlerindeki başarısını değerlendirmek açısından kritik bir rol oynar. Bu ölçütlerin doğru yorumlanması, modelin güçlü ve zayıf yönlerini ortaya koyarak model geliştirme sürecine ışık tutar (Kuhn ve Johnson, 2013).

Sınıflandırma problemlerinde doğruluk (accuracy) en yaygın performans ölçütlerinden biridir. Ancak, doğruluk sınıf dağılımının dengesiz olduğu veri setlerinde yanıltıcı olabilir. Örneğin, bir veri setinde negatif sınıfların sayısı çok fazlaysa, tüm tahminleri negatif yapan bir model yüksek doğruluk elde edebilir. Bu tür durumlarda, hassasiyet (precision), duyarlılık (recall) ve F1 skoru gibi ek ölçütler kullanmak daha anlamlı olabilir. Hassasiyet, modelin pozitif tahminlerinin ne kadarının doğru olduğunu gösterirken, duyarlılık, gerçek pozitiflerin ne kadarının doğru tahmin edildiğini ölçer. F1 skoru ise hassasiyet ve duyarlılığın harmonik ortalamasıdır ve özellikle dengesiz veri setlerinde dengeli bir performans değerlendirmesi sağlar (Saito ve Rehmsmeier, 2015).

Örneğin, bir sağlık teşhis modeli ele alındığında, modelin hassasiyetinin yüksek olması, pozitif teşhislerde genellikle doğru olduğunu gösterir, ancak duyarlılığı düşükse birçok gerçek hasta yanlış negatif olarak sınıflandırılabilir. Bu durumda, modelin kritik vakaları kaçırma riski vardır ve bu tür sonuçlar modelin duyarlılığını artırmak için yeniden eğitilmesi gerektiğini gösterir. ROC eğrisi (Receiver Operating Characteristic) ve AUC (Area Under the Curve) gibi ölçütler, modelin farklı eşik değerlerindeki performansını değerlendirerek daha kapsamlı bir analiz sağlar (Fawcett, 2006).

Regresyon problemlerinde ise Ortalama Kare Hata (Mean Squared Error - MSE) ve Ortalama Mutlak Hata (Mean Absolute Error - MAE) gibi ölçütler, modelin tahmin doğruluğunu değerlendirmede kullanılır. MSE, tahmin edilen ve gerçek değerler arasındaki farkların karelerinin ortalamasını alarak hataları daha fazla cezalandırır. MAE ise bu farkların mutlak değerlerinin ortalamasını alır ve modelin genel hata seviyesini gösterir. R-kare ( $R^2$ ) değeri, modelin bağımsız değişkenler tarafından açıklanan varyans oranını ölçer ve modelin genel uyumunu değerlendirmede kullanılır (Chai ve Draxler, 2014).

Performans ölçütlerinin doğru yorumlanması, modelin belirli koşullarda nasıl performans gösterdiğini anlamak ve iyileştirme stratejileri geliştirmek için kritiktir. Örneğin, bir satış tahmin modeli için MSE'nin yüksek olması, modelin büyük hatalar yaptığını ve bu hataların minimize edilmesi gerektiğini gösterir. Bu durumda, modelin yeniden eğitilmesi veya daha uygun özelliklerin seçilmesi gibi adımlar atılabilir (Witten vd., 2011).

Sonuç olarak, makine öğrenimi modellerinin performans ölçütlerine göre yorumlanması, modelin etkinliğini ve güvenilirliğini artırmak için vazgeçilmez bir süreçtir. Doğru ölçütlerin seçilmesi ve dikkatli bir şekilde yorumlanması, modelin gerçek dünya uygulamalarında başarısını belirlemek için büyük önem taşır.

## ÜÇÜNCÜ BÖLÜM

### E-PAZARYERİ DEĞERLENDİRMELERİ ÜZERİNDEN MAKİNE ÖĞRENİMİ İLE İNANDIRICILIK ALGISI TAHMİNLEME

#### 3.1. Çalışmanın Amacı ve Kapsamı

Bu bölümde çalışmanın amacı ve kapsamından bahsedilmektedir.

##### 3.1.1. Konu ve Amaç

Günümüz dijitalleşen iş dünyasında hemen hemen her mal ve hizmete çevrimiçi platformlardan ulaşmak mümkündür. Bu hem işletmeler için küresel çapta bir müşteri potansiyeli sunmakta hem de müşterilere geniş bir satın alma ağı sunmaktadır. Bu geniş satın alma ağının içerisinde bazı risk faktörleri devreye girmektedir. Bu risk faktörleri müşterilerin satın alma niyetlerini etkileyeceği için güven duygusu bir adım daha ön plana çıkmaktadır.

Müşterilerin satın aldıkları mal veya hizmeti değerlendirmeleri potansiyel satın alıcıların güven duygusu üzerinde bir etki oluşturabilmektedir. Bu değerlendirme yöntemleri yapılan puanlama sistemleri ile sayısal bir formatta olabileceği gibi yapılan yorumlarla metinsel formatlarda da bulunabilmektedir. Bu noktada sadece sayısal veriler üzerinden yapılan analizler yerine kullanıcı yorumu gibi metin verilerinin de analizlere dahil edilmesi daha doğru sonuçlara ulaşılmasına aracılık edebilir.

Bu veriler anket gibi geleneksel veri toplama yöntemleriyle elde edilmek istenildiğinde cevaplayıcıların soruları anlamama veya yapılan anketin vakit alıcı olması sebebiyle doğru sonuçtan uzaklaşabilme ihtimali vardır. Öte yandan çevrimiçi platformlarda kişilerin kendi duygu ve düşüncelerini açık bir şekilde ifade edebildikleri, puanlama yapabildikleri, görsellerle destekleyebildiği ve diğer kullanıcı değerlendirmelerine katılıp-katılmama gibi tepki belirtebildikleri zengin bir görüş bildirme sistemi vardır. Bu sistemler her ne kadar satın alıcılara mal/hizmet hakkında detaylı bir bakış açısı sunsa da bazı durumlarda yanlış yönlendirmelere de sebep olabilmektedir. Tüm bu sebeplerden dolayı yapılan değerlendirmelerin inandırıcı olup olmadığını bilmek ciddi bir önem arz etmektedir.

Bu sebeplerden dolayı bu çalışmanın amacı, e-pazaryerlerindeki kullanıcı yorumlarının inandırıcılığını tespit etmeye yönelik makine öğrenmesine dayalı bir model oluşturmaktır.

### 3.1.2. Kapsam

Çalışmanın ana verisi Amazon e-pazaryeri platformundan toplanmıştır. Ayrıca pilot çalışma kapsamında Türkiye’de faaliyet gösteren iki popüler e-pazaryerinden veri toplanmıştır. E-pazaryerlerinin seçiminde gerek geniş ürün yelpazesine sahip olması ve geniş bir kullanıcı kitlesine hitap etmesinden gerekse de çok sayıda kullanıcı değerlendirmesine sahip olması açısından tercih edilmiştir. Türkiye’deki e-pazaryerlerindeki yorumların pilot çalışma sürecinde en çok satılan veya katılımcıların ilgilerini çeken ürünler için yorumları incelemesi istenmiştir. Katılımcılardan incelenen bu ürün yorumlarını okuduklarında yapılan yorumun ne kadar inandırıcı olduğuna dair bir skor verisi toplanmıştır.

Veri setinin oluşturulmasında, yönetim bilişim sistemleri konusunda bilgi ve deneyim sahibi altı tüketici, dokuz ay boyunca ürünlerin inandırıcı olup olmadığına yönelik skor vermeleri istenmiştir. Tüketiciler Tablo 1’de sunulan ürünlerin sayfalarını tek tek inceleyerek o ürünlere ait yorumları değerlendirmişlerdir (-1: İnanırcı değil, 1: İnanırcı, 0: Nötr).

Tablo 1’de tüketicilerin değerlendirdikleri ürünlerin kısa adları, ürünün sitede yer alan genel ortalama yıldız puanı, ürüne yapılan toplam değerlendirme sayıları ve ürüne ait yorum bulunan değerlendirme sayıları verilmiştir. Tüketicilerin yaptıkları değerlendirmelerde verdikleri yıldız puanlarının aritmetik ortalamasını “Ürünün Sitedeki Yıldız Puanı”, en az bir değerlendirme yöntemiyle tüketicilerin verdiği puan sayısını “Ürünün Toplam Değerlendirilme Sayısı”, ürüne yapılan değerlendirmeler içerisinde yorum bulunan puanlamaları “Ürüne Yapılan Toplam Yorum Sayısı” ve bu değerlendirmelerin hangi ürüne ait olduğunu “Ürünün Kısa Adı” verisi temsil etmektedir.

**Tablo 1. Veri Setinin Oluşturulmasında Kullanılan Ürünler**

Ürünün Kısa Adı	Ürünün Sitedeki Yıldız Puanı	Ürünün Toplam Değerlendirilme Sayısı	Ürüne Yapılan Toplam Yorum Sayısı
Erkek Eşofman Takımı	4,4	758	401
Erkek Spor Ayakkabı	4,5	829	553
Kablosuz Kulaklık	4,6	1825	1160
Akıllı Bileklik	4,8	5407	3207
AirFryer (Hava Fritözü)	3,5	527	218
Erkek Deri Ceket	3,4	241	130
Oyuncu Koltuğu	4,6	1139	760
Araç Temizlik Kiti	3,6	5316	2763
Araç Tipi El Süpürgesi	3,7	1528	935
Oyuncu Kulaklığı	4,3	106142	24924
TV Sesli Komut Kumandası	4,5	9092	1507
Koşu Bandı	3,9	8542	1689
Araç Ön Cam Güneşliği	3,9	10784	2185
Oyuncak Kamyon	4,1	54257	7041
Erkek Bakım ve Tıraş Seti	4,6	39733	4028
Tekerlek Hava Pompası	4,2	14513	1337
Akıllı TV Aparatı ve Kumanda	4,7	474945	48269
Evcil Hayvan Tüy Temizlik Eldiveni	4,2	71328	12480
Oyuncu Monitörü	4,6	2890	446
Termos Bardak	4,5	5202	1113
Seyahat Sırt Çantası	4,6	11021	2416
Şarjlı Diş Fırçası	4,6	138139	26935
Kadın Spor Ayakkabı	4,6	19673	4306
Dekoratif Masa Lambası	4,5	24749	3742
Oyuncak Yapboz Çiçek	4,9	16749	1462
Webcam	4,3	47831	9370
Motosiklet Kaskı	4,5	12916	2717
Profesyonel Kayıt Mikrofonu	4,5	13791	1673
Oyun Konsolu	4,8	8394	995
Araç Telefon Tutucu	4,4	40488	8730

**Tablo 1. (devamı)**

Güneş Gözlüğü	4,5	40847	5052
Şişme Bahçe Havuzu	4,5	41319	10425
Kablosuz Kulaklık	4,7	618550	43414
Ofis Bilgisayar Koltuğu	4,4	21738	3364
Akıllı Saat	4,0	34196	6847
Robot Süpürge	4,3	29298	3325
El Feneri	4,6	79362	13654
Klavye-Mouse Seti	4,6	45522	6744
Monitör Tutucu İkili Aparat	4,5	32909	8115
Kablosuz Mouse	4,5	102516	24477
Gitar Başlangıç Seti	4,3	4818	604
Halter Bilekliği	4,7	20280	1438
Akıllı Cep Telefonu	4,1	22991	6794
Duş Başlığı	4,6	52325	13002
Araç Bakım/Onarım Koltuğu	4,4	25816	3827

Değerlendirilen tüm sayfaların özet tablosu Tablo 2’de sunulmuştur. Tablo 2’de veri setine genel bir bakış sunmak için altı tüketicinin değerlendirdiği toplam ürün sayısı “İncelenen Ürün Sayısı” satırında belirtilmiştir. Bu 45 ürüne dair genel bilgiler Tablo 1’de mevcuttur. İncelenen 45 üründen elde edilen toplam yorum verisi “Elde Edilen Yorum Verisi” satırında gösterilmektedir. Kazıma işlemi sırasında hatalı elde edilen veya mükerrer yorumlar temizlendikten sonra elde edilen, inandırıcılık puanı verilmiş veri sayısı ise “İnandırıcılık Puanı Verilen Yorum Sayısı” sütununda belirtilmiştir.

**Tablo 2. Değerlendirilen Sayfaların Özet Bilgileri**

İncelenen Ürün Sayısı	45
Elde Edilen Yorum Verisi	16000
İnandırıcılık Puanı Verilen Yorum Sayısı	15531

### 3.2. Veri Setinin Oluşturulması

Veri setinin oluşturulması sürecinde toplamda 16000 adet yorum skorlanmıştır. Verilerin temizlenmesinin ardında 15531 adet analize uygun veri elde edilmiştir. Daha sonra bu verilerin birbiri ile olan tutarlılıklarını ölçmek için verileri daha önce görmemiş farklı bir kullanıcıya değerlendirmeleri incelemesi ve inandırıcılık puanı vermesi

istenilmiştir. Ardından elimizdeki iki farklı veri setini karşılaştırmak için Scott's pi analizi kullanılmıştır. Analiz sonucunda tutarsız olarak değerlendirilen değerler ortak görüş kapsamında tekrar değerlendirilmiştir.

### 3.2.1. Araştırma Verilerinin Web Ortamından Çekilmesi

Katılımcıların güvenilirlik puanı verdiği ürünlerin web sayfaları tek tek ziyaret edilmiş ve verilerin toplanması için açık kaynak kodlu Python yazılımı ve Anaconda platformundan yararlanılmıştır. Oluşturulan kod diziliminde “Web Scraping” adı verilen bir veri toplama yöntemi kullanılmıştır.

Verilerin elde edilmesi sürecinde kullanılan siteler sürekli olarak güncellendiği için hazırlanan kod dizilimi bu süreç boyunca verilerin eksiksiz ve hatasız bir şekilde elde edilmesi için sürekli olarak güncellenmiştir. Bu sürecin ardından elde edilen verilere ilişkin açıklamalar şu şekildedir;

- **Text:** Ürüne yapılan yorum metni
- **Star:** 1 ile 5 arasında değişen kullanıcı yorum yıldız değerleri.
- **Picture:** Kullanıcıların yorumlarına fotoğraf ekleyip eklemediğini belirten 0 veya 1 değerleri. (0 eklemedi, 1 ekledi)
- **Like:** Kullanıcıların yorumlarına yapılan beğeni sayıları.
- **MainStar:** Ürün için tüm kullanıcıların 5 üzerinden verdiği yıldızların ortalaması.
- **Rating:** Ürün için yapılan toplam yıldızlı değerlendirme sayısı.
- **ToplamYorum:** Ürün için yapılan değerlendirmelerin içinde yorum bulunan değerlendirme sayısı.

Bahsedilen parametreler her ürün linki için tek tek ziyaret edilmiş ve her bir ürün için elde edilen veriler ayrı dosyalarda saklanmıştır. Bahsedilen kodların daha anlaşılır olması bakımından çalışma verilerinin elde edilmesi için kullanılan kodun bir kısmı Şekil 1’de gösterilmiştir.



```

def getReviews(html_data):
    data_dicts = []
    boxes = html_data.select('div[data-hook="review"]')
    for box in boxes:
        stars = box.select_one('[data-hook="cmps-review-star-rating"]')
        description = box.select_one('[data-hook="review-body"]')
        picture = box.select_one('[class*="review-image-tile-section"]')
        Like = box.select_one('[data-hook="helpful-vote-statement"]')
        ToplamYorum = box.select_one('[data-hook="total-review-count"]')

        stars_text = stars.get_text(strip=True).split(' out of')[0] if stars else 'N/A'
        description_text = description.get_text(strip=True) if description else 'N/A'
        picture_value = '1' if picture else '0'
        Like_text = Like.get_text(strip=True).split()[0] if Like else '0'
        ToplamYorum_text = ToplamYorum.get_text(strip=True).split()[0] if ToplamYorum else '0'

        data_dict = {
            'Text': description_text,
            'Stars': stars_text,
            'Picture': picture_value,
            'Like': Like_text,
            'ToplamYorum': ToplamYorum_text
        }

        data_dicts.append(data_dict)

    return data_dicts

def get_product_details(url):
    response = requests.get(url, headers=headers)
    soup = BeautifulSoup(response.text, 'html.parser')
    return soup

html_datas = reviewsHtml(reviews_url, len_page)
reviews = []

for html_data in html_datas:
    review = getReviews(html_data)
    for r in review:
        r['MainStar'] = product_star
        r['Rating'] = product_ratings
    reviews += review

```

### Şekil 1. Verilerin Elde Edilmesinde Kullanılan Web Kazıma Kod Parçası

Şekil 1’de bir parçası yer alan kod ürüne ait bir yorumu ve bu yoruma bağlı olan yorumun yıldız değeri, beğeni sayısı, fotoğraf içerip içermediğine dair bilgisi, ürünün genel yıldız ortalaması, toplam değerlendirme sayısı ve toplam yorum içeren değerlendirme sayısı verilerini kazıyarak .CSV uzantılı dosyaya kaydetmektedir. Bu süreç ilgili üründeki bütün yorumlar alınana kadar devam ederek son yoruma ulaşıldığında sonlanmaktadır.

Kodun çalışması sonucunda elde edilen veriler ilerleyen süreçte yapılacak olan ek işlemler için her ürün ayrı dosyalarda olacak şekilde saklanmıştır. Bu sayede her ürün kendi içerisinde değerlendirilebilecektir.

### 3.2.2. Araştırma Verilerinin Ön Hazırlık Süreci

Web kazıma işlemlerinin ardından veriyi istenilen makine öğrenimine uygun hale getirmek için verilere ön hazırlık işlemleri uygulanmıştır.

### 3.2.2.1. Araştırma Verilerinin Temizlenmesi

Elde ettiğimiz ham veriler analize dahil edilmeden önce genel veri temizleme işlemleri uygulanmıştır. Bu işlemde tekrarlanan verileri veri setinden temizledikten sonra web kazıma sürecinde boş gelen veriler kaldırılmış veya uygun bir biçimde doldurulmuştur. Örneğin beğeni sayısı hücresi boş ise “0” (Beğeni yok), fotoğraf bulunma durumu hücresi boş ise “0 (Fotoğraf yok)” şeklinde doldurulmuştur.

### 3.2.2.2. Araştırma Verilerinin Duygu Analizine Uygun Hale Getirilmesi

Veri temizleme işlemleri uygulandıktan sonra araştırma verilerini duygu analizine uygun hale getirmek için etkisiz sözcükler (Stopwords) yorumların içerisinden ayrıştırılmıştır. Bu etkisiz sözcükler temel anlamda bağlaç veya edat gibi cümlenin duygu yükünün yönüne bir etkisi olmayan ve kendi başına bir anlam taşımayan ifadelerdir.

Temizlenen ve analize uygun hale getirilen verilerin duygu yüklerinin tespiti için duygu analizi yapılmıştır. Duygu analizi için sosyal medyada kullanılan yazışma dilindeki kısaltmaları ve kullanılan görsel ifadeleri (emojileri) algılama yeteneği olan Vader LEXICON sözlüğü tercih edilmiştir.

### 3.2.2.3. Araştırma Verilerine Yeni Parametrelerin Eklenmesi

Yapılan duygu analizinin ardından her metin verisi için bileşik duygu yükleri veri setinde ilgili hücrelere eklenmiştir. Bu işlemin ardından her bir ürün için toplam yorum sayısının içerisinde bulunan negatif yorum sayıları saptanmıştır. Ardından yapılan negatif yorumların toplam yoruma olan oranı hesaplanarak veri setine eklenmiştir. Buradaki amaç yoğun negatif yorum alan bir üründe yapılan pozitif duygu yüküne sahip yorumların güvenilirlik oranlarını gözlemleyebilmektir.

Uygulanan veri temizleme işlemlerinin ardından analize dahil edilmek üzere eklenen parametreler ve açıklamaları şu şekildedir;

- **NegRatio:** Ürüne yapılan negatif yorumların üründeki tüm yorumlara oranı.
- **Polarite:** Yorumlara yapılan duygu analizi sonucunda hesaplanan compound değerleri.

- **Sentiment:** Yorumların duygu yükü Pozitif ise 1, Negatif ise 0 olacak şekilde değerleri içerir.
- **Credibility:** Ürüne yapılan yorumun güvenilirlik puanı.

Bahsedilen işlemlerin ardından elde edilen nihai veri seti Tablo 3'te gösterilmiştir. Star, Picture ve Like sütunları sırasıyla yoruma ait yıldız puanı, yorumda resim bulunma bilgisini ve yoruma ait beğeni sayısını temsil etmektedir. MainStar, Rating ve ToplamYorum sütunları sırasıyla ürüne ait yıldız değeri, ürüne ait değerlendirme sayısını ve toplam yorum bulunan değerlendirme sayılarını temsil etmektedir. Yorum verilerine duygu analizi yapıldıktan sonra elde edilen duygu sınıfları Sentiment sütununda duygu yükünün ağırlığı ise Polarite sütununda yer almaktadır. Duygu yükleri hesaplandıktan sonra her ürün için yapılan toplam yorum verisinin içerisinde bulunan negatif duygu durumuna sahip yorum sayıları tespit edilip NegRatio sütununda gösterilmektedir. Burada amaç negatif yorum oranı düşük olan veya yüksek olan ürünlerde yapılan yorumların ürün geneline karşıt duygu yüküne sahip olduğunda inandırıcılığı etkileyip etkilemediğini görmektir. Son olarak Credibility sütununda ise altı tüketicinin vermiş olduğu inandırıcılık puanlarının normalize edilmiş değerleri yer almaktadır.

**Tablo 3. Nihai Veri Seti**

Star	Picture	Like	MainStar	Rating	ToplamYorum	NegRatio	Polarite	Sentiment	Credibility
5	0	1	4,3	389	249	0,048193	0,5994	1	1
1	1	0	4,5	733	491	0,020367	-0,2411	-1	-1
5	1	0	4,6	861	558	0,012545	0,7841	1	0
5	1	0	4,8	3724	2261	0,000885	0,9163	1	1
4	0	6	3,4	124	78	0,307692	0,2263	1	1
4	0	0	4,1	463	368	0,005435	0,6034	1	1
3	0	1	3,3	183	106	0,226415	0	0	0
3	1	0	3,2	92	71	0,183099	0	0	1

### 3.3. Verilerin Analizi ve Araştırma Modelinin Tanımlanması

Bu çalışmada iki farklı aşamadan oluşan bir model kullanılmıştır. Birinci aşamada müşteri değerlendirme verileri web kazıma teknikleriyle kazanmış, güvenilirlik puanlamaları tüketiciler tarafından değerlendirilmiş ve farklı bir tüketici tarafından bu güvenilirlik puanları doğrulanmıştır. Ardından Scott's Pi analizi uygulanarak veriler

karşılaştırılmıştır. İkinci aşamada uygun makine öğrenimi modeli belirlenerek araştırma verileri ile eğitim sağlanmış daha sonra makine öğrenmesi algoritmasına hiç dahil edilmemiş veriler için güvenilirlik puanı tahminlemesi yapılmıştır.

### 3.3.1. Veri Setinin Eğitim ve Test Verisine Ayrılması

Elde edilen nihai veri seti makine öğrenimine uygun hale geldikten sonra öğrenimin gerçekleştirilmesi ve test edilmesi için iki farklı setlere bölünmesi gerekmektedir. Bahsi geçen eğitim ve test veri setlerini saptamak için 10 katlı çapraz doğrulama yöntemi kullanılmıştır. Bu yöntem ilgili veriyi 10 eşit parçaya bölerek her seferinde 9 parçasını eğitim seti 1 parçasını test seti olarak kullanmaktadır. Bu işlem her tekrarlandığında farklı parça test seti olarak kullanılır ve bu işlem toplamda 10 kez tekrarlanır. Bu yöntem sayesinde veri setinde oluşabilecek hataların önüne geçilmek hedeflenmiştir.

### 3.3.2. Uygun Makine Öğrenimi Modelinin Belirlenmesi

Çalışmada 7 makine öğrenmesi modeli karşılaştırılmıştır. Bunlar:

1. Gradyan Arttırma
2. Rastgele Orman
3. CN2
4. k-NN
5. Naive Bayes
6. Lojistik Regresyon
7. SVM

Gradyan artırma, tahmine dayalı modeller oluşturmak için kullanılan güçlü bir makine öğrenme algoritmasıdır. Temel kavram, mevcut olanların eksikliklerini telafi etmek için yeni zayıf öğrenenler (karar ağaçları) ekleyerek modelin kayıp fonksiyonunu en aza indirmektir. Her yineleme, daha önce zor olduğu düşünülen ve yanlış sınıflandırılan örneklere yoğunlaşarak modelin doğruluğunu artırır.

Rastgele Orman, yüksek performanslı bir makine öğrenme algoritmasıdır ve birçok ağaç yapısını birleştirerek karar verme sürecini güçlendirir. Her ağaç, veri kümesinin rastgele örnekleri kullanılarak bağımsız olarak eğitilir ve daha sonra bu

ağaçlar, genel bir tahmin yapmak için birleştirilir. Bu yöntem aşırı uyarlamaya karşı dayanıklıdır ve çeşitli özelliklerin etkisini değerlendirme yeteneğiyle bilinir. Rastgele Orman, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan bir algoritmadır ve büyük veri setleri üzerinde etkili sonuçlar sağlar.

Bir veri kümesinden kural tabanlı sınıflandırıcı oluşturmak için kullanılan CN2 algoritması, veri madenciliği ve makine öğrenimi alanlarında yaygın olarak kullanılan bir kural çıkarma tekniğidir. Bu algoritma, veri kümesindeki kalıpları tanımlayan basit ve anlaşılır kural kümelerini öğrenmeyi amaçlamaktadır. CN2 özellikle küçük ve orta ölçekli veri kümeleri üzerinde etkilidir ve veri madenciliği projelerinde sınıflandırma doğruluğunu artırmak için yaygın olarak tercih edilir. Algoritma, veri seti üzerinden geçerek en iyi kural setini belirler ve bu kural setine göre sınıflandırma yapar, böylece veri analizinde kullanışlı bir araç haline gelir.

k-NN (k-En Yakın Komşu) algoritması, makine öğrenmesi ve veri madenciliği alanında kullanılan bir sınıflandırma ve regresyon yöntemidir. Bu algoritma, yeni bir veri noktasını sınıflandırmak veya tahmin etmek için komşu veri noktalarının etrafındaki ortalamayı kullanır. Kullanıcı tarafından belirlenen k değeri, komşu olarak kullanılacak veri noktalarının sayısını temsil eder. Kullanılan uzaklık ölçütü genellikle Öklid uzaklığı olsa da farklı uzaklık ölçüleri de kullanılabilir. k-NN algoritması basit ve anlaşılır yapısıyla özellikle küçük ve orta ölçekli veri setlerinde etkilidir. Ancak büyük veri setleri için hesaplama maliyeti artabilir ve veri setindeki gürültüye karşı duyarlı olabilir.

Naive Bayes algoritması, makine öğrenimindeki sınıflandırma problemlerinde kullanılan istatistiksel bir algoritmadır. Bu algoritma Bayes teoreminin temel prensiplerine dayanmaktadır ve özellikle metin sınıflandırma gibi alanlarda yaygın olarak kullanılmaktadır. Naive Bayes'in temel varsayımı, nitelikler arasında bağımsızlık varsayımıdır, yani bir niteliğin değeri diğer niteliklerin değerlerine bağlı değildir. Bu yüzden buna "saf" deniyor. Bu algoritma, veri setindeki özelliklerin dağılımını inceleyerek yeni örneklerin olasılıksal sınıflandırmasını gerçekleştirir. Bu, bir örneğin hangi sınıfa ait olduğunu tahmin etmeyi mümkün kılar. Naive Bayes algoritması genel olarak basit yapısı ve iyi performansı ile bilinir ancak gerçek veri setlerinde bağımsızlık varsayımının her zaman geçerli olmadığını belirtmek önemlidir.

Lojistik regresyon, istatistik ve makine öğrenimindeki sınıflandırma problemlerini çözmek için kullanılan bir modelleme tekniğidir. Bu algoritma, bağımlı değişken kategorik bir değişken olduğunda kullanılır ve çıktı olarak bir olayın olasılığını tahmin etmeye odaklanır. Lojistik regresyon, bağımsız ve bağımlı değişkenler arasındaki ilişkiyi doğrusal bir regresyon modeli kullanarak modellemeye çalışır ancak çıktıyı (0 ile 1 arasında bir değer) sınırlar, böylece bir olasılık olarak yorumlanabilir. Algoritma, giriş verilerini ağırlıklarla çarparak ve bunları bir eşik (kesme) ile karşılaştırarak sınıflandırmayı gerçekleştirir. Eğitim aşamasında, parametreleri tahmin etmek için genellikle maksimum olabilirlik tahmin yöntemleri kullanılır. Lojistik regresyon ikili sınıflandırma problemlerinde yaygın olarak kullanılır ve doğrusal olasılık modellemesine dayanır.

Destek vektör makinesi (SVM), makine öğrenmesinde sınıflandırma ve regresyon problemlerinde kullanılan güçlü bir algoritmadır. SVM, özellikle doğrusal olmayan veri kümeleri üzerinde etkili olan bir öğrenme modeli olarak kabul edilmektedir. Temel olarak, veri noktalarını farklı sınıflara bölmek için en iyi bölme çizgisini (veya hiperdüzlemi) bulmaya çalışır. Bu bölme çizgisinin amacı, sınıflar arasındaki ayrımı en üst düzeye çıkarırken veri noktalarını mümkün olduğunca ayırmaktır. SVM bunu başarmak için destek vektörlerini kullanır; yani, bölme çizgisine en yakın noktaları içeren veri noktalarını tanımlar ve bu noktaları, bölme çizgisinin en iyi konumunu belirlemek için kullanır. Doğrusal olmayan veri kümeleri için SVM, verileri yüksek boyutlu bir alana dönüştürmek ve bunları doğrusal olarak ayrılabilir hale getirmek için çekirdek yöntemini kullanır, böylece daha karmaşık veri yapılarını işleyebilir. SVM'nin geniş bir uygulama alanı vardır ve yüksek doğruluk ve genelleme yetenekleriyle bilinmektedir.

Tablo 4'te, modellerin birbiri ile karşılaştırma sonuçları the Area under ROC yöntemine göre yer almaktadır. Tablodan görüleceği üzere Gradyan Arttırma modelinin bulunduğu satır, diğer tüm modellerle kıyaslamasında 1'e en yakın değere sahiptir.

**Tablo 4. Modellerin the Area under ROC Yöntemine Göre Karşılaştırılması**

	Gradyan Arttırma	Rastgele Orman	CN2	k-NN	Naive Bayes	Lojistik Regresyon	SVM
Gradyan Arttırma		0,814	1,000	0,993	0,999	0,994	1,000
Rastgele Orman	0,186		0,737	0,974	0,982	0,996	1,000
CN2	0,000	0,263		0,918	0,997	0,988	1,000
k-NN	0,007	0,026	0,082		0,871	0,971	1,000
Naive Bayes	0,001	0,018	0,003	0,129		0,946	0,996
Lojistik Regresyon	0,006	0,004	0,012	0,029	0,054		0,822
SVM	0,000	0,000	0,000	0,000	0,004	0,178	

Tablo 5'te, modellerin birbiri ile karşılaştırma sonuçları the classification accuracy yöntemine göre yer almaktadır. Tablodan görüleceği üzere Rastgele Orman modelinin bulunduğu satır, diğer tüm modellerle kıyaslamasında 1'e en yakın değere sahiptir.

Sınıflandırma doğruluğu, bir modelin doğruluğunu ölçmek için makine öğrenimi ve istatistikte kullanılan bir ölçümdür. Bu gösterge, doğru tahmin edilen örneklerin toplam örneklere oranını temsil eder. Genellikle yüzde olarak ifade edilir; daha yüksek doğruluk değerleri, daha iyi model performansı anlamına gelir. Ancak sınıflandırma doğruluğu tek başına yetersizdir ve sınıf dengesizliği olan veri setlerinde yanıltıcı olabilir. Bu nedenle modelin performansını daha kapsamlı değerlendirmek için çeşitli performans metrikleri ve değerlendirme yöntemleri (duyarlılık, özgünlük, F1 puanı vb.) kullanılmalıdır.

**Tablo 5. Modellerin Sınıflandırma Doğruluğu Yöntemine Göre Karşılaştırılması**

	Gradyan Arttırma	Rastgele Orman	CN2	k-NN	Naive Bayes	Lojistik Regresyon	SVM
Gradyan Arttırma		0,338	0,992	0,366	0,999	0,998	0,992
Rastgele Orman	0,662		0,988	0,558	0,999	0,999	0,995
CN2	0,008	0,012		0,020	0,996	0,955	0,973
k-NN	0,634	0,442	0,980		1,000	0,999	0,995
Naive Bayes	0,001	0,001	0,004	0,000		0,001	0,959
Lojistik Regresyon	0,002	0,001	0,045	0,001	0,999		0,959
SVM	0,008	0,005	0,027	0,005	0,439	0,041	

Tablo 6'de ise 7 farklı makine öğrenmesi modeline göre doğruluk (accuracy) değerleri yer almaktadır. Elde edilen bulgulara göre, Gradyan Arttırma ve Rastgele Orman modelinin en yüksektir.

**Tablo 6. Modellerin Doğruluk Değerleri**

	AUC	CA	F1	Precision	Recall	LogLoss
Gradyan Arttırma	0,962	0,942	0,939	0,938	0,942	0,135
Rastgele Orman	0,950	0,944	0,944	0,944	0,944	0,305
CN2	0,941	0,927	0,927	0,926	0,927	0,172
k-NN	0,922	0,944	0,942	0,941	0,944	0,581
Naive Bayes	0,897	0,878	0,889	0,906	0,878	0,338
Lojistik Regresyon	0,854	0,909	0,888	0,887	0,909	0,239
SVM	0,796	0,875	0,882	0,890	0,875	0,287

Tablo 7’de ise Gradyan Arttırma ve Rastgele Orman makine öğrenmesi modelinin Gerçek orana göre performans değerleri yer almaktadır. Tabloya göre gerçekteki pozitif inandırıcılık endeksi tahmin etme oranı Gradyan Arttırma modelinde yüksek iken gerçekteki negatif inandırıcılık endeksi tahmin etme oranı Rastgele Orman modelinde daha yüksektir. Ancak Rastgele Orman modelinin tahmin gücü (negatif inandırıcılık endeksi) daha belirgindir.

**Tablo 7. Gradyan Arttırma ve Rastgele Orman Modellerinin Performans Tablosu**

İNANDIRICILIK ENDEKSİ			Tahminlenen			
			Pozitif		Negatif	
Gerçek Oran			Gradyan Arttırma	Rastgele Orman	Gradyan Arttırma	Rastgele Orman
Gerçek	Pozitif	Gradyan Arttırma Rastgele Orman	98,0%	97,0%	2,0%	3,0%
	Negatif	Gradyan Arttırma Rastgele Orman	41,2%	30,3%	58,0%	69,7%

Makine öğrenmesi modellerinin birbirleriyle karşılaştırılması sonuçları "area under ROC" yöntemine göre değerlendirildi. Daha sonra modellerin birbirleriyle karşılaştırılması sonuçları classification accuracy (sınıflandırma doğruluğu) yöntemine göre incelenmiştir. 7 farklı makine öğrenmesi modeli için doğruluk değerleri hesaplanmış ve performans değerleri gerçek oranlara göre incelenmiştir. Gradyan Arttırma modelinde gerçek pozitif tahmin oranının yüksek olduğu, Rastgele Orman modelinde ise gerçek negatif inandırıcılık endeksi tahmin oranının yüksek olduğu tespit edilmiştir. Ancak Rastgele Orman modelinin tahmin gücü (negatif inandırıcılık endeksi) daha anlamlıdır. Elde edilen bulgulara göre Rastgele Orman algoritması en uygun model olarak belirlenmiştir.



## DÖRDÜNCÜ BÖLÜM

### E-PAZARYERLERİNDEKİ TEMİZLİK ÜRÜNLERİ YORUMLARININ İNANDIRICILIKLARI VE ÇEVRECİ ÖZELLİKLERİNE GÖRE FARKLILIKLARI

#### 4.1. Çalışmanın Amacı ve Kapsamı

E-ticaret platformları, tüketicilerin ürünler hakkında bilgi edinmeleri ve satın alma kararlarını şekillendirmeleri için önemli bir bilgi kaynağı haline gelmiştir (Chevalier ve Mayzlin, 2006). Özellikle temizlik ürünleri gibi günlük yaşamda sıkça kullanılan ürünler için, kullanıcı yorumları tüketicilerin satın alma kararlarında büyük bir etkiye sahiptir (Mudambi ve Schuff, 2010). Kullanıcı yorumlarının inandırıcılığı, özellikle yorumların detay seviyesi, dil kullanımını ve doğruluk gibi faktörlerden etkilenmektedir (Forman vd., 2008). Çevreci özelliklerin tüketici algıları üzerindeki etkisi, giderek artan bir araştırma konusu olmuştur ve bu özelliklerin tüketici tercihlerini nasıl şekillendirdiği önemli bir tartışma konusudur (Testa vd., 2015). Kullanıcı yorumlarının, özellikle olumlu yorumların, tüketici satın alma niyetleri üzerinde önemli bir etkiye sahip olduğu bilinmektedir (Duan vd., 2008). Bu çalışmanın konusu, e-pazaryerlerinde yer alan temizlik ürünlerine ait kullanıcı yorumlarının inandırıcılığını ve bu yorumların çevreci ürün özelliklerine göre farklılıklarını incelemektir. Bu kapsamda araştırmanın 3 hipotezi bulunmaktadır:

H1. Çevreci ürün özelliğine göre ürün yorumlarının inandırıcılık endeks ortalamaları anlamlı farklılık göstermektedir.

H2. Ürün türlerine göre ürün yorumlarının inandırıcılık endeks ortalamaları anlamlı farklılık göstermektedir.

H3. Markalara göre ürün yorumlarının inandırıcılık endeks ortalamaları anlamlı farklılık göstermektedir.

## 4.2. Yöntem

Çalışmanın bu bölümü için ihtiyaç duyulan verilerin elde edilmesi için açık kaynak kodlu Python yazılımı ve Anaconda platformundan yararlanılmıştır. Öncelikle verileri elde edilmesi planlanan markalar belirlenmiştir. Bu süreçte Çevreci temizlik ürünleri üretmesiyle tanınan Frosch, Dawn ve Fairy markaları tercih edilmiştir. Belirlenen markaların e-pazaryerlerinde en çok satan ürünleri belirlenmiş ve çalışma kapsamındaki parametreler 1 ay boyunca web ortamından kazınmıştır. Kazıma işlemi sonucunda 4600 adet çevreci ürünler üreten markalara ait veri elde edilmiştir.

Çevreci ürünler için web kazıma işlemi tamamlandıktan sonra aynı türdeki ürünler için en çok satan 3 farklı marka belirlenmiştir. Bu kapsamda Domestos, Omo ve Rinso markaları çalışmaya dahil edilmiştir. Bu gruptaki markalar da çevreye duyarlılığı ön planda tutsa da, daha çok geniş çaplı temizlik çözümleri sunmaya odaklanmıştır. Belirlenen markaların e-pazaryerlerinde en çok satan ürünleri belirlenmiş ve çalışma kapsamındaki parametreler 1 ay boyunca web ortamından kazınmıştır. Kazıma işlemi sonucunda 3500 adet veri elde edilmiştir.

Elde edilen verilere veri temizleme işlemleri uygulanmıştır. İlk olarak eksik, hatalı veya tekrar eden veriler temizlenmiştir. Temizleme işleminde web kazıma sürecinde boş gelen veriler veri setinden kaldırılmış veya uygun biçimde yeniden doldurulmuştur. Web sayfasının yapısı gereği eğer bir yorum beğeni almamışsa kazıma işleminde “Like” sütunu boş olarak geldiği için bu şekilde olan değerler “0” ile doldurulmuştur. Veri temizleme işlemlerinin ardından Frosch, Dawn ve Fairy için 4527 adet, Domestos, Omo ve Rinso için 3329 adet veri elde edilmiştir.

Veri temizleme işlemleri uygulandıktan sonra araştırma verilerini duygu analizine uygun hale getirmek için etkisiz sözcükler (Stopwords) yorumların içerisinden ayrıştırılmıştır. Temizlenen ve duygu analizine uygun hale getirilen veri setlerine duygu analizi yapılmıştır. Duygu analizi için Vader LEXICON sözlüğü tercih edilmiş ve elde edilen duygu yükleri ile duygu sınıfları veri setinde “Polarity” ve “Sentiment” sütunlarına eklenmiştir. Ardından her ürün için ayrı ayrı ürüne yapılan tüm yorumlar içerisinde negatif duygu yüküne sahip yorumların oranları belirlenmiştir. Belirlenen oranlar daha sonra analizde kullanılmak üzere veri setinde “NegRatio” sütununa eklenmiştir. Tüm parametreler tamamlandıktan sonra veri setleri analize uygun hale getirilmiştir.

Analize uygun hale getirilen veri setleri daha önce eğitimi tamamlanmış olan Rastgele Orman modeliyle inandırıcılık endeksleri tahminlenmek üzere modele dahil edilmiştir. Elde edilen inandırıcılık endeksleri veri setinde “Credibility” sütununa eklenmiştir.

Veri setlerinin hazırlık süreci tamamlandıktan araştırma kapsamındaki hipotezleri test etmek için İnandırıcılık Endeksi ve Polarite kategorisi (Duygu yükü sınıfı) arasındaki ilişki incelenmiştir. Ardından İnandırıcılık Endeksinin, Çevrecilik Durumuna göre analiz sonuçları incelenmiş ve açıklanmıştır. Son olarak Çevrecilik Durumu ve Ürünlere göre İnandırıcılık Endeksinin ANOVA testi sonuçları incelenmiştir. Yapılan analizler için SPSS ve Orange programları kullanılmıştır.

#### 4.2.1. Polarite ve İnandırıcılık Endeksi Arasındaki Dağılım

Çalışmanın ilk bulguları, toplanan 7856 yorumun inandırıcılık ve polarite değerlerinin dağılımına yöneliktir. Tablo 8’de bu iki değişkene göre yorumların çapraz tablosu yer almaktadır.

**Tablo 8. Yorumların Polarite Kategorisi ve İnandırıcılık Endeksi Çapraz Tablo Dağılımları**

		İNANDIRICILIK ENDEKSİ		Toplam	
		İnandırıcı Değil	İnandırıcı		
POLARİTE KATEGORİSİ	Olumsuz	N	71	500	571
		%	12,4%	87,6%	100,0%
	Nötr	N	82	513	595
		%	13,8%	86,2%	100,0%
	Olumlu	N	646	6044	6690
		%	9,7%	90,3%	100,0%
Toplam	N	N	7057	7856	
	%	N	89,8%	100,0%	

**Olumsuz Polarite Kategorisi:** Olumsuz kategoriye sahip yorumların %87,6’sı inandırıcı bulunmuş, %12,4’ü inandırıcı bulunmamıştır. Bu, olumsuz yorumların büyük çoğunluğunun inandırıcı olduğunu göstermektedir.

**Nötr Polarite Kategorisi:** Nötr yorumların %86,2'si inandırıcı bulunmuş, %13,8'i inandırıcı bulunmamıştır. Bu da nötr yorumların çoğunun inandırıcı olarak algılandığını göstermektedir.

**Olumlu Polarite Kategorisi:** Olumlu yorumların %90,3'ü inandırıcı bulunmuş, sadece %9,7'si inandırıcı bulunmamış. Bu, olumlu yorumların büyük çoğunluğunun inandırıcı olarak kabul edildiğini göstermektedir.

Genel olarak, yorumların %89,8'i inandırıcı olarak değerlendirilmektedir, sadece %10,2'si inandırıcı bulunmamıştır. Olumlu polariteye sahip yorumlar, en yüksek inandırıcılık oranına sahiptir (%90,3). Bu, olumlu yorumların genellikle daha inandırıcı olarak algılandığını göstermektedir. Nötr ve olumsuz polariteye sahip yorumlar da yüksek inandırıcılık oranlarına sahiptir (%86,2 ve %87,6). Bu, nötr ve olumsuz yorumların da kullanıcılar tarafından genellikle inandırıcı bulunduğunu göstermektedir.

Bu bulgular, e-pazaryerlerinde yapılan yorumların genellikle inandırıcı bulunduğunu, kullanıcıların yorumların polaritesine göre yorumların inandırıcılığı hakkında farklı algılara sahip olduğunu ortaya koymaktadır. Özellikle olumlu yorumların daha yüksek inandırıcılık oranına sahip olması, pozitif içeriklerin kullanıcılar tarafından daha güvenilir bulunmasından kaynaklanabilir. Olumsuz ve nötr yorumların da yüksek inandırıcılık oranına sahip olması, kullanıcıların bu tür yorumları da ciddiye aldığını ve değerlendirdiğini göstermektedir.

#### 4.2.2. Çevreci Ürün Özelliğine Göre İnanırıcılık Endeks Dağılımı

Tablo 9 çevreci ürün olup olmama durumuna göre, ürüne yapılan yorumların inandırıcılık endeksi değerlerinin anlamlı farklılık bulguları t-test ile analiz edilmiştir. Çevreci ürün özelliği taşımayan ürün yorumlarının (N=3329) için inandırıcılık endeksi ortalaması 0,78 (standart sapma = 0,40) iken, ürün özelliği taşıyan ürün yorumlarının (N=4527) inandırıcılık endeksi ortalaması 0,72 (standart sapma = 0,52) olarak bulunmuştur. Her iki grup arasındaki farkın istatistiksel olarak anlamlı olduğu ( $p < 0,01$ ) tespit edilmiştir. Bu bulguya bağlı olarak H1 hipotezi kabul edilmiştir.

**Tablo 9. Çevreci Ürün Özelliğine Göre İnandırıcılık Endeksi T-Testi Sonuçları**

	Çevrecilik Durumu	N	Ortalama	S.Sapma	p
İnandırıcılık Endeksi	Çevre Odaklı Olmayan	3329	0,78	0,40	<0,001
	Çevre Odaklı	4527	0,72	0,52	

Dolayısıyla ürün yorumlarının inandırıcılık endeksi ortalamasının ürünün çevreci olup olmamasına göre farklılık göstermektedir. çevre odaklı olmayan ürün yorumlarının inandırıcılığı, çevre odaklı ürün yorumlarının inandırıcılığına göre biraz daha yüksek olduğu gözlemlenmiştir. Bu farkın istatistiksel olarak anlamlı ( $p < 0,01$ ) olması, çevrecilik durumunun yorumun inandırıcılığı algısı üzerinde etkili olabileceğini düşündürmektedir.

Bu bulgular, çevreci bireylerin yorum ve değerlendirmelerinde farklı bir perspektife sahip olabileceğini veya daha eleştirel olabileceğini işaret etmektedir. İlerleyen çalışmalarda, bu ilişkinin nedenlerini daha derinlemesine incelemek, çevrecilik ve inandırıcılık arasındaki dinamikleri daha iyi anlamak için önemlidir.

#### 4.2.3. Ürün Türlerine Göre İnandırıcılık Endeksi Dağılımı

Çevrecilik durumu ve ürün türlerine göre inandırıcılık endeksinin varyans analizi p-değerlerinin 0.01'den küçük olması, ürünler arasında inandırıcılık endeksi ortalamaları arasında istatistiksel olarak anlamlı farklar olduğunu göstermektedir. Bu bulguya bağlı olarak H2 hipotezi kabul edilmiştir.

Tablo 10, çevrecilik durumu ve farklı ürünler arasındaki inandırıcılık endeksi ortalamalarının karşılaştırılması için yapılan ANOVA testinin sonuçlarını göstermektedir.

**Tablo 10. Ürün Türlerine Göre İnanırcılık Endeksi ANOVA Testi Sonuçları**

Çevrecilik Durumu	Ürün	N	Ortalama	S.Sapma	p
Çevre Odaklı Olmayan	Sıvı Sabun	450	0,86	0,22	<0,01
	Bulaşık Deterjanı	300	0,83	0,19	
	Kir Çözücü	644	0,72	0,46	
	Çamaşır Deterjanı	1935	0,77	0,42	
Çevre Odaklı	Sıvı Sabun	240	0,92	0,18	<0,01
	Bulaşık Deterjanı	1734	0,33	0,68	
	Sprey Temizleyici	951	0,95	0,05	
	Tablet Deterjan	102	0,85	0,36	
	Kir Çözücü	1500	0,97	0,04	

Sonuçlar, çevreci ürünlerin genel olarak çevrecilik odaklı olmayan muadillerine göre daha yüksek inanırcılık endeksine sahip olduğunu göstermektedir. Çevreci sıvı sabunun inanırcılık endeksi (0,92), çevreci odaklı olmayan sıvı sabuna (0,86) kıyasla anlamlı derecede daha yüksek bulunmuştur ( $p<0,01$ ). Benzer şekilde, çevreci kir çözücünün inanırcılık endeksi (0,97), çevreci odaklı olmayan kir çözücünden (0,72) anlamlı derecede daha yüksek çıkmıştır ( $p<0,01$ ).

Ancak, çevreci odaklı olmayan bulaşık deterjanının inanırcılık endeksi (0,83), çevreci bulaşık deterjanına (0,33) kıyasla daha yüksek olup, bu fark da istatistiksel olarak anlamlı bulunmuştur ( $p<0,01$ ). Bu durum, çevreci bulaşık deterjanı kullanıcılarının değerlendirmelerinde büyük bir değişkenlik olduğunu göstermektedir (S.Sapma = 0,68).

Çevreci ürünler arasında sprej temizleyici (0,95) ve tablet deterjan (0,85) da yüksek inanırcılık endekslerine sahiptir. Sprej temizleyici için düşük standart sapma (0,05), kullanıcı değerlendirmelerinde tutarlılık olduğunu belirtirken, tablet deterjan için daha yüksek standart sapma (0,36), kullanıcı değerlendirmelerinde nispeten bir değişkenlik olduğunu göstermektedir.

Genel olarak, çevreci ürünlerin inanırcılık endeksleri, çevrecilik odaklı olmayan ürünlere kıyasla daha yüksek ve tutarlı çıkmıştır. Bu bulgular, tüketicilerin çevreci ürünlere yönelik algılarının ürün türüne göre değişebileceğini ve çevrecilik odaklı olmayan ürünlerin de bazı durumlarda yüksek inanırcılık sağlayabileceğini göstermektedir.

#### 4.2.4. Markaların Ürünlerine Yapılan Değerlendirmelere Göre İnandırıcılık Endeksi Dağılımı

Çevrecilik durumu ve markalara göre inandırıcılık endeksinin varyans analizi p-değerlerinin 0,01'den küçük olması, markalar arasında inandırıcılık endeksi ortalamaları arasında istatistiksel olarak anlamlı farklar olduğunu göstermektedir. Bu bulguya bağlı olarak H3 hipotezi kabul edilmiştir.

Özellikle, çevreci ürün markalar arasında Frosch ve Fairy ürünlerinin inandırıcılık endeksi ortalamalarının oldukça yüksek olması dikkat çekicidir. Bu durum, çevreci ürün markalarının genellikle daha yüksek bir inandırıcılık algısına sahip olduğunu, ancak belirli çevreci ürünlerin (Dawn gibi) daha düşük bir inandırıcılık endeksi ortalamasına sahip olabileceğini göstermektedir.

Tablo 11, çevrecilik durumu ve farklı marka arasındaki inandırıcılık endeksi ortalamalarının karşılaştırılması için yapılan ANOVA testinin sonuçlarını göstermektedir.

**Tablo 11. Markaların Ürünlerine Yapılan Değerlendirmelere Göre İnandırıcılık Endeksi ANOVA Testi Sonuçları**

Çevrecilik Durumu	Ürün	N	Ortalama	S.Sapma	P
Çevre Odaklı Olmayan	Domestos	760	0,86	0,22	<0,01
	Omo	300	0,83	0,19	
	Rinso	2269	0,75	0,45	
Çevre Odaklı	Dawn	1974	0,40	0,67	<0,01
	Fairy	1053	0,94	0,12	
	Frosch	1500	0,97	0,04	

Bu sonuçlar hem çevrecilik odaklı hem de çevrecilik odaklı olmayan markalar arasında inandırıcılık endeksi ortalamalarının önemli ölçüde farklılık gösterdiğini ortaya koymaktadır. Özellikle, çevreci ürün markalarının (Dawn, Fairy, Frosch) inandırıcılık endeksi ortalamalarının, çevrecilik odaklı olmayan ürün markalarına (Domestos, Omo, Rinso) kıyasla daha geniş bir dağılım gösterdiği ve bazı çevreci ürün markalarının (Fairy ve Frosch) inandırıcılık endeksi ortalamalarının oldukça yüksek olduğu gözlemlenmiştir.

Bu bulgular, çevrecilik durumu ve ürün türlerinin inandırıcılık endeksi üzerindeki etkilerini anlamada önemli bir bilgi sunmaktadır. Çevreci ürünlerin inandırıcılık algısının genellikle daha yüksek olduğu, ancak bu durumun tüm çevreci ürünler için geçerli

olmadığı görülmektedir. İlerleyen çalışmalarda, bu farklılıkların nedenlerini daha derinlemesine incelemek ve çevreci ürünlerin inandırıcılık algısı üzerindeki etkilerini daha iyi anlamak için daha fazla araştırma yapılması önerilmektedir.



## TARTIŞMA VE SONUÇ

İnternet kullanımının yaygınlaşmasıyla birlikte çevrimiçi değerlendirmeler, tüketiciler için önemli bir satın alma kılavuzu haline gelmiştir. Online müşteri değerlendirmelerinin inandırıcılıklarını saptanması önemi hale gelmiştir. Bu çalışmada, çevrimiçi değerlendirmelerin tüketici davranışları üzerindeki etkilerini anlamak için çeşitli yöntemler ve analizler kullanılmıştır.

Araştırma sonucunda birincil bulgular, çevrimiçi değerlendirmelerin tüketicilerin satın alma kararları üzerinde belirgin bir etkiye sahip olduğunu göstermektedir. Kullanıcılar, pazar araştırmasında diğer kullanıcıların değerlendirmelerini dikkate almaktadır. Yapılan tüm değerlendirmeler kullanıcılar için dikkate değer olsa da özellikle, yüksek sayıda ve olumlu değerlendirme alan ürünlerin, tüketiciler üzerinde daha güçlü bir etkiye sahip olduğu görülmektedir. Bu durum, müşteri geri bildirimlerinin yönetiminin önemini vurgularken online pazarlamacılar için de bunu dikkate alan stratejik bir yaklaşımın gerekliliğini göstermektedir.

Çevrimiçi müşteri değerlendirmelerinin inandırıcılıkları hesaplanırken çevrimiçi değerlendirme kalitesi ve derinliği üzerine odaklanılmıştır. Yorumların sadece sayısal değil aynı zamanda niteliksel özellikleri de incelenmiş ve bu özelliklerin tüketicilerin algısını nasıl etkilediği üzerine derinlemesine analizler yapılmıştır. Örneğin, müşteri yorumlarının içerdiği duygusal ve bilişsel unsurların, tüketicilerin ürün algısını nasıl şekillendirdiği üzerine yapılan bu analizler, online yorumların gerçek dünya etkilerini anlamamıza yardımcı olmuştur.

Makine öğrenimi modelleri arasında inandırıcılık endeksinin hesaplanması için en uygun model the area under ROC yöntemi kullanılarak seçilmiştir. Yöntem sonuçlarına göre Gradyan Arttırma modelinin bulunduğu satır 1'e en yakın değerleri vermiştir.

Ardından sınıflandırma doğruluğu (Classification Accuracy) yöntemiyle 7 model tekrar karşılaştırılmış ve Rastgele Orman modeli sonuçlarının 1'e en yakın değerlere sahip olduğu görülmüştür.

Değerlendirme için kullandığımız 7 farklı makine öğrenimi modelinin doğruluk (accuracy) değerlerinin karşılaştırılmasıyla elde edilen bulgularda Gradyan Arttırma

modelinin ve Rastgele Orman modelinin diğer modellere göre daha yüksek sonuçlar verdiği gözlemlenmiştir.

Gradyan Arttırma ve Rastgele Orman modellerine dair gerçek orana göre performans değerleri hesaplanmıştır. Hesaplanan değerlerde Gradyan Arttırma modelinin %98 oranda gerçek pozitif değerlere sahip olduğu ve Rastgele Orman modelinin %97 gerçek pozitif değerlere sahip olduğu bulunmuştur. Gerçek negatif değerlerde ise Gradyan Arttırma modelinin %58 doğru tahminleme oranı varken Rastgele Orman modelinin %69,7 oranında gerçek tahminlerde bulunduğu gözlemlenmiştir. Bu bulgular neticesinde pozitif tahmin değeri doğruluklarının birbirine yakın olması sebebiyle negatif değerler için daha yüksek doğru tahminler yapabilme kabiliyetine sahip Rastgele Orman modeli kullanılmasına karar verilmiştir.

Rastgele Orman modeli altı tüketici tarafından değerlendirilen verilerle eğitildikten sonra bu modelle çevrecilik durumuna göre tüketici değerlendirmelerinin inandırıcılık endeksleri tahminlenmiştir. Yapılan bu tahminler neticesinde yapılan analizler sonucunda elde edilen bulgularda pozitif duygu yüküne sahip değerlendirmelerin %90,3, negatif duygu yüküne sahip değerlendirmelerin %87,6 ve nötr duygu yüküne sahip değerlendirmelerin %86,2 oranında inandırıcı bulunduğu saptanmıştır.

Sonuçlar, e-pazaryerlerinde yapılan değerlendirmelerin genellikle güvenilir ve inandırıcı bulunduğunu, kullanıcıların değerlendirmelerin duygu yüküne göre değerlendirmelerin inandırıcılığı hakkında farklı algılara sahip olduğunu ortaya koymaktadır. Özellikle pozitif değerlendirmelerin daha yüksek inandırıcılık oranına sahip olması, pozitif içeriklerin kullanıcılar tarafından daha güvenilir bulunmasından kaynaklanabilir. Olumsuz ve nötr yorumların da yüksek inandırıcılık oranına sahip olması, kullanıcıların bu tür değerlendirmeleri de ciddiye aldığını ve değerlendirdiğini göstermektedir.

Çevrecilik durumu ve inandırıcılık endeksi arasındaki ilişkiyi değerlendirmek için yapılan analizlerde çevre odaklı olmayan ürünler satın alan tüketiciler için inandırıcılık endeksi ortalaması %78 iken çevreci ürünler satın alan tüketiciler için bu ortalama %72 olarak bulunmuştur. Bu sonuçlar, çevrecilik durumunun inandırıcılık endeksi üzerinde anlamlı bir etkisi olduğunu göstermektedir. Çevre odaklı olmayan ürünler satın alan tüketicilerin inandırıcılık endeksi ortalamasının, çevreci ürünler satın alan tüketicilere göre biraz daha yüksek olduğu gözlemlenmiştir. Bu farkın istatistiksel olarak anlamlı

( $p < 0,01$ ) olması, çevrecilik durumunun inandırıcılık algısı üzerinde etkili olabileceğini göstermektedir. İlerleyen çalışmalarda, bu ilişkinin nedenlerini daha derinlemesine incelemek, çevrecilik ve inandırıcılık arasındaki dinamikleri daha iyi anlamak için önemlidir.

Çevrecilik durumuna göre farklı ürünler arasındaki inandırıcılık endeksi ortalamalarının karşılaştırıldığı analiz sonuçlarında çevre odaklı olmayan markaların inandırıcılık endeksi en yüksek %86 (Domestos), en düşük %75 (Rinso) bulunmuştur. Bu durum çevreci ürün etiketine sahip ürünlerde ise en yüksek %98 (Frosch), en düşük %40 (Dawn) olarak bulunmuştur.

Bu sonuçlar hem çevreci hem de çevre odaklı olmayan ürünler arasında inandırıcılık endeksi ortalamalarının önemli ölçüde farklılık gösterdiğini ortaya koymaktadır. Özellikle, çevreci ürünlerin (Dawn, Fairy, Frosch) inandırıcılık endeksi ortalamalarının, çevre odaklı olmayan ürünlere (Domestos, Omo, Rinso) kıyasla daha geniş bir dağılım gösterdiği ve bazı çevreci ürünlerin (Fairy ve Frosch) inandırıcılık endeksi ortalamalarının oldukça yüksek olduğu gözlemlenmiştir.

Bu bulgular, çevrecilik durumu ve ürün türlerinin inandırıcılık endeksi üzerindeki etkilerini anlamada önemli bir bilgi sunmaktadır. Çevreci ürünlerin inandırıcılık algısının genellikle daha yüksek olduğu, ancak bu durumun tüm çevreci ürünler için geçerli olmadığı görülmektedir. İlerleyen çalışmalarda, bu farklılıkların nedenlerini daha derinlemesine incelemek ve çevreci ürünlerin inandırıcılık algısı üzerindeki etkilerini daha iyi anlamak için daha fazla araştırma yapılması önerilmektedir.

Çevreci etiketine sahip ürünlerin inandırıcılık endeksinin yüksek olması dikkat çekicidir, bu durum çevreci etiketine sahip ürünlerin genellikle daha yüksek inandırıcılık endeksine sahip olduğunu fakat bazı çevreci etikete sahip ürünlerin (Dawn gibi) daha düşük inandırıcılık endeksine de sahip olabileceğini düşündürmektedir. Bu noktada inandırıcılık endeksinin düşük olmasına sebep olacak etkenlerin saptanması için farklı bakış açılarıyla yaklaşılması gerektiği düşünülmektedir. Örneğin Dawn marka ürüne yapılan yorumlar için en sık kullanılan kelimeler analiz edilmiş ve yorumlarda en sık bahsedilen 10 kelime arasında “Expensive” (195), “Money” (125) ve “Price” (182) kelimelerinin geçtiği görülmektedir. Bu durum tüketicilerin, ürünlere yapılan fiyat odaklı yoğunluğuna sahip değerlendirmeleri inandırıcı bulmadığı yönünde bir algıya sebebiyet verebilmektedir. Bir diğer örnek olarak çevreci ürün etiketine sahip Frosch markasının

resmî sitesinden alınan faaliyet haritasına bakıldığında, markaların ürünlerine kolay erişim imkanına sahip olunmasına ilişkin (hızlı teslimat, aynı gün kargo vb.) değerlendirmelerin, tüketicileri bu ürüne ait değerlendirmeleri daha inandırıcı bulabileceğini düşündürmektedir. İlerleyen çalışmalarda, bu farklılıkların nedenlerini daha derinlemesine incelemek ve çevreci ürünlerin inandırıcılık algısı üzerindeki etkilerini daha iyi anlamak için daha fazla araştırma yapılması önerilmektedir.

## KAYNAKLAR

- Abedin, E., Mendoza, A., Akbarighatar, P. and Karunasekera, S. (2024). "Predicting Credibility of Online Reviews: An Integrated Approach", *IEEE Access*.
- Agarwal, N., Liu H., Tang L. and Yu P.S. (2012). "Mining Social Media: Opportunities and Challenges", *SIGKDD Explorations*, 14(2), 20-29.
- Ahmad, S., Gupta, A., Gupta, N. K. and Shukla, R. (2017). "Design and Implementation of Algorithm to Analyze Overall Effect of Customers Reviews", *International Journal of Multimedia and Ubiquitous Engineering*, 12(7), 19-18.
- Al-Asadi, T. A., Obaid, A. J., Hidayat, R. and Ramli, A. A. (2017). "A Survey on Web Mining Techniques and Applications", *International Journal on Advanced Science Engineering and Information Technology*, 7(4), 1178-1184.
- Algarni, A. A. M. and Xu, Y. (2013). "Social Engineering in Social Networking Sites: Phase-Based and Source-Based Models", *International Journal of e-Education, e-Business, e-Management and e-Learning*, 3(6), 456-462.
- Anderson, E. W. (1998). "Customer Satisfaction and Word of Mouth", *Journal of Service Research*, 1(1), 5-17. <https://doi.org/10.1177/109467059800100102>
- Anil, B., Mehta, Y., Kumar, N. and Prakash, S. (2019). "Structured and Unstructured Data in Machine Learning Models: Relationships and Predictive Capabilities", *IEEE Transactions on Big Data*, 5(2), 321-335.
- Arbelles, F., Smith, J. and Johnson, R. (2020). "The Role of Star Ratings in E-Commerce: Implications for Sales and Consumer Engagement", *Electronic Commerce Research and Applications*, 39, 100913. <https://doi.org/10.1016/j.elerap.2020.100913>
- Ardabili, S. (2019). "Advances in Machine Learning Models: Hybrid and Ensemble Techniques for Improved Performance and Functionality", *Machine Learning and Data Analytics Review*, 25(2), 301-320.
- Baek, H., Ahn, J. and Choi, Y. (2012). "Helpfulness of Online Consumer Reviews: Readers' Objectives and Review Cues", *International Journal of Electronic Commerce*, 17(2), 99-126.
- Baek, H., Lee, S., Oh, S. and Ahn, J. (2015). "Normative Social Influence and Online Review Helpfulness: Polynomial Modeling and Response Surface Analysis", *Journal of Electronic Commerce Research*, 16(4), 290.
- Barboza, L. (2017). "Comparative Study on Machine Learning Models for Bankruptcy Prediction: Bagging, Boosting, and Random Forests", *International Journal of Financial Studies*, 5(3), 45.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer. New York.

- Biswas, A., Sharma, P., Kumar, R. and Gupta, S. (2023). "Implementation of Various Machine Learning Algorithms and Feature Selection Methods Such as Chi-Square, ANOVA, and Mutual Information to Emphasize Early-Stage Heart Disease Prediction Potential with High Accuracy and Specificity", *Journal of Medical Systems*, 47(4), 108.
- Bloch, D. (2023). "Diverse Models and Algorithms in Machine Learning: Applications in Financial Time Series Forecasting and Natural Language Processing", *Machine Learning Review*, 80(4), 901-925.
- Bounie, D. (2008). "Word-of-Mouth and its Impact on Marketing", *International Journal of Market Research*, 50(4), 411-427.  
<https://doi.org/10.1177/147078530805000405>
- Bradley, A. P. (1997). "The Use of the Area Under the ROC Curve in the Evaluation of Machine Learning Algorithms", *Pattern Recognition*, 30(7), 1145-1159.
- Bradshaw, C., Peters, L. M., Kumar, H. and Liu, M. (2012). "Emerging Research in Machine Learning: Contributions and Advancements", *Annual Review of Computer Science*, 14, 245-267.
- Breiman, L. (2001). "Random Forests", *Machine Learning*, 45(1), 5-32.
- BrightLocal. (2024). "Consumer Review Survey 2024"  
<https://www.brightlocal.com/research/consumer-review-survey> (08.05.2024).
- Brownstein, J. S., Freifeld, C.C. and Madoff, L.C. (2009). "Digital Disease Detection - Harnessing the Web for Public Health Surveillance", *New England Journal of Medicine*, 360(21), 2153-2157.
- Cerar, J. and Hribar, A. (2023). "Dynamic Approaches Using Deep Reinforcement Learning for Selecting the Most Suitable Machine Learning Model: A Case Study in Energy Consumption Prediction", *Energy*, 253, 119593.  
<https://doi.org/10.1016/j.energy.2022.119593>
- Chai, T. and Draxler, R. R. (2014). "Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? - Arguments Against Avoiding RMSE in the Literature", *Geoscientific Model Development*, 7(3), 1247-1250.
- Chakrabarti, S., van den Berg M. and Dom B. (1999). "Mining the Web's Link Structure", *Computer*, 32(8), 60-67.
- Chelliah, M. and Sarkar, S. (2017, August). "Product Recommendations Enhanced with Reviews", *Proceedings of the Eleventh ACM Conference on Recommender Systems*, 398-399.
- Chen, Y. H., and Barnes, S. (2007). "Initial Trust and Online Buyer Behavior", *Industrial Management & Data Systems*, 107(1), 21-36.

- Chen, Y. and Xie, J. (2008). "Online Consumer Review: Word-of-mouth as a New Element of Marketing Communication Mix", *Management science*, 54(3), 477-491.
- Chen, Y., Wang, Q. and Xie, J. (2011). "Online Social Interactions: A Natural Experiment on Word of Mouth versus Observational Learning", *Journal of Marketing Research*, 48(2), 238-254.
- Cheng, V., Rhodes, J. and Lok, P. (2015). "The Relationship Between Online Reviews, Brand Trust, and Willingness to Buy", *Strategic E-commerce Systems and Tools for Competing in the Digital Marketplace*, 139-161. IGI Global.
- Chevalier, J. A., and Mayzlin, D. (2006). "The Effect of Word of Mouth on Sales: Online Book Reviews", *Journal of Marketing Research*, 43(3), 345-354. <https://doi.org/10.1509/jmkr.43.3.345>
- Chiu, H., Fang, D. and Ho, C. (2019). "The Impact of Online Reviews and Star Ratings on Consumer Purchasing Behavior", *Journal of Business Research*, 101, 751-760. <https://doi.org/10.1016/j.jbusres.2018.12.003>
- Cho, J. and Garcia-Molina, H. (1998). "Efficient Crawling Through URL Ordering", *Computer Networks and ISDN Systems*, 30(1-7), 161-172.
- Chua, A. Y. K. and Banerjee, S. (2016). "Understanding the Role of Online Product Reviews on Purchase Intention and Post-Purchase Behavior", *Information & Management*, 53(5), 678-689. <https://doi.org/10.1016/j.im.2016.02.009>
- Clark, P. and Niblett, T. (1989). "The CN2 Induction Algorithm", *Machine Learning*, 3(4), 261-283.
- Cone Communications. (2011). "Cone Online Influence Trend Tracker: 2011 Power of Prosumers" <http://www.conecomm.com/research-blog/2011/11/power-of-prosumers-2011> (08.05.2024).
- Cortes, C. and Vapnik, V. (1995). "Support-Vector Networks", *Machine Learning*, 20(3), 273-297.
- Cover, T. and Hart, P. (1967). "Nearest Neighbor Pattern Classification". *IEEE Transactions on Information Theory*, 13(1), 21-27.
- Dalla Pozza, I. (2014). "Customer Experiences as Drivers of Customer Satisfaction", *Gestion*, 31(3), 115-138.
- Davis, S. and Tabrizi, N. (2021, September). "Customer Review Analysis: A Systematic Review", *2021 IEEE/ACIS 6th International Conference on Big Data, Cloud Computing, and Data Science (BCD)*, 91-97, IEEE.
- Da Costa, P. C. G. and Gong, Z. (2005). "Web Structure Mining: An Introduction", *ACM SIGKDD Explorations Newsletter*, 7(2), 8-12.

- Dellarocas, C. (2003). "The Digitization of Word of Mouth: Promise and Challenges of Online Feedback Mechanisms", *Management Science*, 49(10), 1407–1424. <https://doi.org/10.1287/mnsc.49.10.1407.17308>
- Dimoka, A., Hong, Y. and Pavlou, P. A. (2012). "On Product Uncertainty in Online Markets: Theory and Evidence", *MIS*, 36(2), 395-426.
- Draper, N. R. and Smith, H. (1998). *Applied Regression Analysis* (3rd ed.), Wiley.
- Duan, W., Gu, B. and Whinston, A. B. (2008). "Do Online Reviews Matter? An Empirical Investigation of Panel Data", *Decision Support Systems*, 45(4), 1007-1016.
- Elvalda, A., Lü, K. and Ali, M. (2016), "Perceived Derived Attributes of Online Customer Reviews", *Computers in Human Behavior*, 56, 306-319.
- Etzioni, O. (1996). "The World-Wide Web: Quagmire or Gold Mine?", *Communications of the ACM*, 39(11), 65-68.
- Fadhillah, A., Zebua, Y. and Prayoga, Y. (2021). "Analysis of Information Quality, Trust and Satisfaction on Customer Participation (Case Study on Customer Online Shop Shopee in Rantauprapat)", *Budapest International Research and Critics Institute-Journal (BIRCI-Journal)*, 2(2), 3039-3051.
- Fawcett, T. (2006). "An Introduction to ROC Analysis", *Pattern Recognition Letters*, 27(8), 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Ferreira, N. (2015). "Time Series Model Selection: Data Characteristics and the Need to Avoid Overfitting and Overselection", *Stat*, 4(1), 51-61. <https://doi.org/10.1002/sta4.82>
- Forman, C., Ghose, A. and Wiesenfeld, B. (2008). "Examining the Relationship Between Reviews and Sales: The role of Reviewer Identity Disclosure in Electronic Markets", *Information Systems Research*, 19(3), 291-313.
- Friedman, J. H. (2001). "Greedy Function Approximation: A Gradient Boosting Machine", *Annals of Statistics*, 29(5), 1189-1232.
- Gefen, D., Karahanna, E. and Straub, D. W. (2003). "Trust and TAM in Online Shopping: An Integrated Model", *MIS quarterly*, 51-90.
- Ghasemaghaei, M., Eslami, S. P., Deal, K. and Hassanein, K. (2018). "Reviews' Length and Sentiment as Correlates of Online Reviews' Ratings", *Internet Research*, 28(3), 544-563.
- Ghose, A. and Ipeirotis, P.G. (2011). "Estimating the Helpfulness and Economic Impact of product Reviews: Mining Text and Reviewer Characteristics", *Knowledge and Data Engineering. IEEE Transactions on Knowledge and Data Engineering*, 23, 1498-1512.



- Godes, D. and Silva, J. C. (2012). “Sequential and Temporal Dynamics of Online Opinion”, *Marketing Science*, 31(3), 448–473. <https://doi.org/10.1287/mksc.1110.0653>
- Goodfellow, I., Bengio, Y. and Courville, A. (2016). “Deep Learning”, *MIT Press*.
- Gularta, J. and Curtis, S. (2023). “Integration of Clustering Methods in Portfolio Optimization Models: Hierarchical Risk Parity Model Performance in Asset Selection and Allocation”, *Journal of Banking & Finance*, 134, 106391. <https://doi.org/10.1016/j.jbankfin.2022.106391>
- Güngör, A. (2020). “The Role of Online Customer Reviews in Shaping Emotional Loyalty and Trust in E-Commerce Platforms”, *Journal of Consumer Behavior*, 19(2), 185-198. <https://doi.org/10.1002/cb.1802>
- Gürkaynak-Gürbüzler, Ş. ve Haşiloğlu, S. B. (2024). “Dijital Pazarlama Güven Ölçeğinin Geliştirilmesi”, *İnternet Uygulamaları ve Yönetimi Dergisi*, 15(1), 1-23.
- Hastie, T., Tibshirani, R. and Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.), Springer.
- Hennig-Thurau, T., Gwinner, K. P., Walsh, G. and Gremler, D. D. (2004). “Electronic Word-of-Mouth via Consumer-Opinion Platforms: What Motivates Consumers to Articulate Themselves on the Internet?” *Journal of Interactive Marketing*, 18(1), 38-52.
- Heydari, A., Tavakoli, M. A., Salim, N. and Heydari, Z. (2015). “Detection of Review Spam: A Survey”, *Expert Systems with Applications*, 42(7), 3634-3642.
- Hosmer Jr., D. W. and Lemeshow, S. (2000). *Applied Logistic Regression* (2nd ed.), Wiley.
- Hyndman, R. J., & Koehler, A. B. (2006). “Another look at measures of forecast accuracy”. *International journal of forecasting*, 22(4), 679-688.
- Inamdar, S. M. and Shinde, S. S. (2010). “Web Content Mining Techniques and Tools: A Survey”, *International Journal of Computer Applications*, 6(2), 6-11.
- Jabour, J. (2023). “AutoML: A Promising Approach for Automating Machine Learning Model Selection”, *Expert Systems with Applications*, 185, 115275. <https://doi.org/10.1016/j.eswa.2022.115275>
- James, G., Witten, D., Hastie, T. and Tibshirani, R. (2013). *An Introduction to Statistical Learning: With Applications in R*, Springer.
- Jalilvand, M. R. and Samiei, N. (2012). “The Impact of Electronic Word of Mouth on a Tourism Destination Choice: Testing the Theory of Planned Behavior (TPB)”, *Internet Research*, 22(5), 591-612.

- Jaikumar, S. (2019). "How Do Consumers Choose Sellers in E-Marketplaces?: The Role of Display Price and Sellers' Review Volume", *Journal of Advertising Research*, 59(2), 232-241.
- Jayalatchumy, D. (2013). "Future Directions in Web Mining", *International Journal of Computer Applications*, 76(14), 29-34.
- Jokar, M. (2016). "Challenges and Solutions in Web Data Mining", *Journal of Web Research*, 5(2), 101-110.
- Johnson, R. (2012). *Multimedia Data Mining: A Systematic Introduction to Concepts and Theory*, CRC Press.
- Kaemingk, D. (2020). "Online Reviews Statistics to Know in 2021" *Qualtrics*, <https://www.qualtrics.com/blog/online-review-stats/> (08.05.2024).
- Keller, K. L. (1993). "Conceptualizing, Measuring, and Managing Customer-Based Brand Equity.", *Journal of Marketing*, 57(1), 1-22. <https://doi.org/10.1177/002224299305700101>
- Kluck, J. P., Schaewitz, L. and Krämer, N. C. (2019). "Doubters are More Convincing than Advocates. The Impact of User Comments and Ratings on Credibility Perceptions of False News Stories on Social Media", *SCM Studies in Communication and Media*, 8(4), 446-470.
- Kim, D. J., Ferrin, D. L., and Rao, H. R. (2008). "A Trust-Based Consumer Decision-Making Model in Electronic Commerce: The Role of Trust, Perceived Risk, and Their Antecedents", *Decision Support Systems*, 44(2), 544-564.
- Kim, E. and Tadisina, S. (2007). "A Model of Customers' Trust in E-Businesses: Micro-Level Inter-Party Trust Formation", *Journal of Computer Information Systems*, 48(1), 88- 104.
- Kim, S. and Park, H. (2013). "Effects of Various Characteristics of Social Commerce (Scommerce) on Consumers' Trust and Trust Performance". *International Journal of Information Management*, 33(2), 318-332.
- Kiritchenko, S., Zhu, X., Cherry, C. and Mohammad, S. (2014, August). "NRC-Canada-2014: Detecting Aspects and Sentiment in Customer Reviews", *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)*, 437-442.
- Khoury, R. and Dagher, G. (2015). "Apache Nutch: A Scalable Web Crawling and Data Extraction Framework", *International Journal of Advanced Computer Science and Applications*, 6(10), 121-126.
- Kohonen, T., Kaski S. and Lagus K. (2000). "SOM-based Data Visualization Methods", *Neural Networks*, 13(9), 957-978.
- Kosala, R. and Blockeel, H. (2000). "Web Mining Research: A Survey", *ACM SIGKDD Explorations Newsletter*, 2(1), 1-15.

- Kotler, P. (2012). *Marketing Management* (14th ed.), Pearson Education.
- Kuhn, M. and Johnson, K. (2013). *Applied Predictive Modeling*, Springer.
- Kumar, A. and Goyal, D. P. (2012). "Web Usage Mining: An Application Perspective", *International Journal of Computer Science and Information Technologies*, 3(5), 5686-5689.
- Kumar, V. (2017). *Introduction to Data Mining*. Springer.
- Lambert, V. A. and Lambert, C. E. (2012). "Qualitative Descriptive Research: An Acceptable Design", *Pacific Rim International Journal of Nursing Research*, 16, 255-256.
- Latief, F. and Nirwana A, 2020. "The Influence of Online Customer Reviews and Customer Ratings on Purchase Decisions for Cosmetology Products at Sociollla". *Mirai Management Journal*, 6(1).
- Lessmann, S., Baesens, B., Seow, H. V. and Thomas, L. C. (2015). "Benchmarking State-of-the-Art Classification Algorithms for Credit Scoring: An Update of Research", *European Journal of Operational Research*, 247(1), 124-136.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M. and van der Laak, J. A. (2017). "A Survey on Deep Learning in Medical Image Analysis", *Medical Image Analysis*, 42, 60-88.
- Liu, B. (2005). *Web Data Mining: Exploring Hyperlinks, Contents, and Usage Data*, Springer.
- Liu, B. (2007). *Web Data Mining: Exploring Hyperlinks, Contents, and Usage Data*, Springer.
- Liu, B. (2022). *Sentiment Analysis and Opinion Mining*. Springer Nature.
- MacQueen, J. B. (1967). *Some Methods for Classification and Analysis of Multivariate Observations*, Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, 281-297.
- Mahdi, A. A. (2023). "Impact of Online Reviews on Consumer Purchase Decisions", *International Journal of Financial, Administrative and Economic Science*, 2(5), 1-10.
- Malviya, O. P. (2011). "Web Mining: Concepts, Applications, and Research Directions", *International Journal of Computer Applications*, 36(4), 1-6.
- Magnusson, P. (2019). "The Impact of Half-Star Rating Increments on Product Demand: Evidence from Wayfair.com", *Journal of Retailing and Consumer Services*, 50, 123-131. <https://doi.org/10.1016/j.jretconser.2019.05.004>

- Maron, M. E. (1961). "Automatic Indexing: An Experimental Inquiry", *Journal of the ACM*, 8(3), 404-417.
- McKnight, D. H., Choudhury, V., and Kacmar, C. (2002). "Developing and Validating Trust Measures for E-Commerce: An Integrative Typology", *Information Systems Research*, 13(3), 334-359.
- Meyer, C. and Schwager, A. (2007). "Understanding Customer Experience", *Harvard Business Review*, 85(2), 116.
- Mitchell, T. M. (1997). *Machine Learning*, McGraw-Hill.
- Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D. and Sutskever, I. (2015). "Human-Level Control Through Deep Reinforcement Learning", *Nature*, 518(7540), 529-533.
- Mo, Z., Li, Y. F. and Fan, P. (2015). "Effect of Online Reviews on Consumer Purchase Behavior", *Journal of Service Science and Management*, 8(03), 419.
- Mobasher, B. (2007). "Automated Personalization-Based Service Provisioning for E-Commerce", *IEEE Transactions on Services Computing*, 1(1), 38-53.
- Moe, W. W. and Trusov, M. (2011). "The Value of Social Dynamics in Online Product Ratings Forums" *Journal of Marketing Research*, 48(3), 444-456. <https://doi.org/10.1509/jmkr.48.3.444>
- Mohawesh, M., Al-Haj, A. and Bataineh, B. (2021). "Detecting Fake Reviews: A Survey of Approaches and Techniques", *IEEE Access*, 9, 69546-69562.
- Mosavi, A. (2019). "Hybrid Machine Learning Models for Enhanced Accuracy and Robustness in Energy Systems", *Renewable Energy*, 136, 741-754.
- Mudambi, R., Cuervo-Cazurra, A. and Pedersen, T. (2019). "Clarifying the Relationships Between Institutions and Global Strategy", *Global Strategy Journal*, 9(2), 151-175.
- Mudambi, S. M. and Schuff, D. (2010). "What Makes a Helpful Online Review? A Study of Customer Reviews on Amazon.com", *MIS quarterly*, 34(1), 185-200. <https://doi.org/10.2307/20721420>
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press.
- Naab, T. K., Heinbach, D., Ziegele, M. and Grasberger, M. T. (2020). "Comments and Credibility: How Critical User Comments Decrease Perceived News Article Credibility", *Journalism Studies*, 21(6), 783-801.
- Nakashima, T. and Jasuja, H. (2011). "Web Mining Techniques in Financial Services: A Review", *International Journal of Information Management*, 31(5), 458-464.

- Navadiya, K. (2012). "Web Content Mining Techniques: A Review", *International Journal of Computer Applications*, 55(16), 32-37.
- Nayal, P., Pandey, N. and Paul, J. (2022). "Covid-19 Pandemic and Consumer-Employee-Organization Wellbeing: A Dynamic Capability Theory Approach", *Journal of Consumer Affairs*, 56(1), 359-390.
- Neelima, B. and Kumar, M. R. (2015). "An Overview of Web Usage Mining", *International Journal of Innovative Research in Computer and Communication Engineering*, 3(6), 5123-5129.
- Pan, Y. and Zhang, J. Q. (2011). "Born Unequal: A Study of the Helpfulness of User-Generated Product Reviews", *Journal of Retailing*, 87(4), 598-612. <https://doi.org/10.1016/j.jretai.2011.05.002>
- Park, C. and Lee, T. M. (2009). "Information Direction, Website Reputation and eWOM Effect: A Moderating Role of Product Type", *Journal of Business Research*, 62(1), 61-67. <https://doi.org/10.1016/j.jbusres.2007.11.017>
- Pavlou, P. A. (2001). "Integrating Trust in Electronic Commerce with the Technology Acceptance Model: Model Development and Validation", *Proceedings of Seventh Americas Conference on Information Systems (AMCIS)*, 816-822.
- Pavlou, P. A. (2003). "Consumer Acceptance of Electronic Commerce: Integrating Trust and Risk with The Technology Acceptance Model", *International Journal of Electronic Commerce*, 7(3), 101-134.
- Pearson, K. (1901). "On Lines and Planes of Closest Fit to Systems of Points in Space", *Philosophical Magazine*, 2(11), 559-572.
- Permana, R. A. and Sahara, S. (2021). "Review Analisis Produk Marketplace Online pada Algoritma Support Vector Machine", *Jurnal Ilmiah Informatika*, 6(1), 50-58.
- Petit, J., Li, C., Millet, B., Ali, K. and Sun, R. (2021). "Can We Stop the Spread of False Information on Vaccination? How Online Comments on Vaccination News Affect Readers' Credibility Assessments and Sharing Behaviors", *Science Communication*, 43(4), 407-434.
- Praba, J. T. (2011). "A Comprehensive Survey on PageRank Algorithms in Web Structure Mining", *International Journal of Computer Applications*, 34(7), 16-21.
- Purnawirawan, N., Dens, N. and De Pelsmacker, P. (2014). "Expert Reviewers Beware! The Effects of Review Set Balance, Review Source and Review Content on Consumer Responses to Online Reviews", *Journal of Electronic Commerce Research.-Long Beach, Calif.,[200-], Currens*, 15(3), 162-178.
- Powers, D. M. W. (2011). "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation", *Journal of Machine Learning Technologies*, 2(1), 37-63.

- Quinlan, J. R. (1986). "Induction of Decision Trees", *Machine Learning*, 1(1), 81-106.
- Rahimi, H., Mezrioui, A. and Daoudi, N. (2020). "A Sentiment-Based Trust and Reputation System in E-Commerce by Extending SentiWordNet", *Embedded Systems and Artificial Intelligence: Proceedings of ESAI 2019, Fez, Morocco*, 765-784, Springer, Singapore.
- Rajdeepa, R. (2013). "Importance of Web Structure Mining in Web Analytics", *International Journal of Computer Science and Information Technologies*, 4(3), 400-404.
- Raschka, S. (2018). "Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning", arXiv preprint arXiv:1811.12808.
- Raut, V. (2012). "Data Mining Techniques for Web-Based Information Discovery", *Journal of Computer Science and Technology*, 27(6), 1167-1175.
- Raül, A., Moreno P. and Carrera A. (2017). "Machine Learning Models for Decision Making in Complex Systems", *Journal of Artificial Intelligence Research*, 60, 1-30.
- Richins, M. L. (1983). "Negative Word-of-Mouth by Dissatisfied Consumers: A Pilot Study", *Journal of Marketing*, 47(1), 68-78.
- Romero, C. and Ventura, S. (2010). "Educational Data Mining: A Review of the State of the Art" *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 40(6), 601-618.
- Saito, T. and Rehmsmeier, M. (2015). "The Precision-Recall Plot is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets", *PLOS ONE*, 10(3), e0118432.
- Salminen, J., Yoganathan, V. and Jansen, B. J. (2022). "Detecting Fake Reviews: Development and Evaluation of a Machine Learning Classifier", *International Journal of Information Management*, 62, 102440.
- Sambath, K. (2022). "Overview of Machine Learning Applications: From Gravitational Wave Detection to Financial Market Demand Forecasting", *Journal of Machine Learning Research*, 18(1), 267-289.
- Santosh, D. T. and Babu, K. S. (2014, April). "Building Trust in Online Reviews by a Customer Through Linked Data", *2014 IEEE REGION 10 SYMPOSIUM*, 342-346, IEEE.
- Sasaki, Y. (2007). "The Truth of the F-measure", *Teaching Statistics*, 29(1), 21-29. <https://doi.org/10.1111/j.1467-9639.2007.00277.x>
- Savoy, J. (2020). "Machine Learning Algorithms in Stylometric Applications: A Comparative Analysis", *Computational Linguistics*, 46(3), 567-589.

- Seber, G. A. F. and Lee, A. J. (2003). *Linear Regression Analysis (2nd ed.)*, Wiley.
- Shaw, C. and Ivens, J. (2002) “Building Great Customer-Experiences”, *Palgrave Macmillan, New York*, 48-66. <https://doi.org/10.1057/9780230554719>
- Sharma, R. (2014). *Web Structure Mining: Algorithms and Applications*. Springer.
- Sherry, O., Uzzi, B. and Lancaster, T. (2021). “The Impact of Fake Reviews on Consumer Behavior”, *Journal of Consumer Research*, 48(3), 450-467.
- Shivakumar, S. (2014). “Future Trends in Web Structure Mining: A Review”, *International Journal of Advanced Research in Computer Science and Software Engineering*, 4(12), 617-621.
- Siering, M., Muntermann, J. ve Rajagopalan, B. (2018). “Explaining and Predicting Online Review Helpfulness: The Role of Content and Reviewer-Related Signals”, *Decision Support Systems*, 108, 1-12.
- Soh, C., Markus, M. L. and Goh, K. H. (2006). “Electronic Marketplaces and Price Transparency: Strategy, Information Technology, and Success”, *MIS quarterly*, 705-723.
- Sokolova, M. and Lapalme, G. (2009). “A Systematic Analysis of Performance Measures for Classification Tasks”, *Information Processing & Management*, 45(4), 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Srirama, S., Raghavan, S., J, G. and Ramani, S. (2017). “WebHarvy: A Visual Web Scraping Software for Non-Programmers”, *Proceedings of the 26th International Conference on World Wide Web*, 1563-1564.
- Srivastava, J., Cooley, R., Deshpande, M. and Tan, P. N. (2004). “Web Usage Mining: Discovery and Applications of Usage Patterns from Web Data”, *ACM SIGKDD Explorations Newsletter*, 1(2), 12-23.
- Sutton, R. S., & Barto, A. G. (1998). “The reinforcement learning problem”. *Reinforcement learning: An introduction*, 51-85.
- Tang, R. (2011). “Mozenda: A Cloud-Based Web Data Extraction Platform”, *Proceedings of the 5th International Conference on Cloud Computing and Services Science (CLOSER '11)*, 177-182.
- Tanuwijaya, C. K., Ellitan, L. and Lukito, R. S. H. (2023). “The Effect of Online Customer Reviews on Purchase Intention with Customer Trust as A Variable in Purchase Decision on Sociolla Consumers”, *Journal of Entrepreneurship and Business*, 4(3), 192-203.
- Testa, F., Iraldo, F., Vaccari, A. and Ferrari, E. (2015). “Green Product Innovation in the Food Industry: Evidence from a Quantitative Study in Italy”, *Business Strategy and the Environment*, 24(6), 401-419.

- Trenz, M. (2013). "The Use of Online Customer Reviews in Academic Research: A Review and Agenda for Future Research", *Journal of Interactive Marketing*, 27(4), 202-210. <https://doi.org/10.1016/j.intmar.2013.09.003>
- Tsaqila, U. Q., Ramdan, A. M. and Nurmala, R. (2023). "Analisis Peran Online Customer Review Dalam Memediasi Hubungan Online Customer Rexperience Terhadap Peningkatan Marketplace Rating", *Journal of Economic, Bussines and Accounting (COSTING)*, 7(1), 1399-1406.
- Tükoğlu, D. and Poyraz, K. (2008). "Web Usage Mining: An Implementation to Improve Website Design", *International Journal of Information Technology and Knowledge Management*, 1(2), 175-182.
- Utz, S., Kerkhof, P. and Van Den Bos, J. (2012). "Consumers Rule: How Consumer Reviews Influence Perceived Trustworthiness of Online Stores", *Electronic Commerce Research and Applications*, 11(1), 49-58.
- Vanaja, S., and Belwal, M. (2018, July). "Aspect-Level Sentiment Analysis on e-Commerce Data", *2018 International conference on inventive research in computing applications (ICIRCA)*, 1275-1279, IEEE.
- Velkumar, K. (2020). "An Exhaustive Review on Web Mining Tools and Applications", *Journal of Critical Reviews*, 7(19), 4498-4503.
- Venkatesakumar, R. (2020). "Comparative Analysis of Star Ratings Across Product Categories and Retailers: A Case Study of Amazon", *International Journal of Retail & Distribution Management*, 48(7), 765-780. <https://doi.org/10.1108/IJRDM-01-2020-0015>
- Vimaladevi, K. and Dhanabhakaym, M. (2012). "A Study on the Effects of Online Consumer Reviews on Purchasing Decision", *Prestige International Journal of Management & IT-Sanchayan*, 1(1), 91.
- Wahyuni, E. D. and Djunaidy, A. (2016). "Fake Review Detection from a Product Review Using Modified Method of Iterative Computation Framework", *MATEC Web of Conferences*, EDP Sciences.
- Wang, J., Li, X. and Liu, B. (2015). "Star Ratings: Effects on Purchase Decisions and Product Preferences", *Journal of Consumer Research*, 42(1), 32-48. <https://doi.org/10.1086/679889>
- Wang, Y. (2019). "The Positive Impact of Numerical Ratings on Sales: An In-Depth Analysis", *Journal of Business Research*, 102, 233-244. <https://doi.org/10.1016/j.jbusres.2019.05.001>
- Watkins, C. J. C. H. and Dayan, P. (1992). "Q-learning. Machine Learning", 8(3-4), 279-292.
- Westbrook, R. A. (1987). "Product/Consumption-Based Affective Responses and Postpurchase Processes", *Journal of marketing research*, 24(3), 258-270.



- William, S., Smith, J., Brown, M. and Davis, R. (2023). "Vital Role of Feature Selection Techniques, Such as F-Score and Mutual Information Score, in Enhancing Learning Accuracy and Computational Efficiency for Crack Size Prediction Using Machine Learning Models", *Journal of Structural Integrity*, 30(1), 45-58.
- Willmott, C. J. and Matsuura, K. (2005). "Advantages of the Mean Absolute Error (MAE) Over the Root Mean Square Error (RMSE) in Assessing Average Model Performance", *Climate Research*, 30(1), 79-82.
- Witten, I. H., Frank, E., Hall, M. A. and Pal, C. J. (2011). *Data Mining: Practical Machine Learning Tools and Techniques* (3rd ed.), Morgan Kaufmann.
- Yang, B., Liu, Y., Liang, Y. and Tang, M. (2019). "Exploiting User Experience from Online Customer Reviews for Product Design", *International Journal of Information Management*, 46, 173-186.
- Yaylı, A. and Bayram, M. (2012). "E-WOM: The Effects of Online Consumer Reviews on Purchasing Decisions", *International Journal of Internet Marketing and Advertising*, 7(1), 51-64.
- Yin, R. K. (2014). "Case Study Research Design and Methods", *Canadian Journal of Program Evaluation*, 30(1), 108-110
- Zamir, O. and Etzioni, O. (1999). "Web Document Clustering: A Feasibility Demonstration", *Proceedings of the 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, 46-54.
- Zeng, X. (2017). "Bayesian Optimization in Machine Learning: A Survey", *Journal of Artificial Intelligence Research*, 61, 249-294. <https://doi.org/10.1613/jair.5240>
- Zhang, X. (2007). "Incentivizing Honest Reviews: A Mechanism for Fair Rating", *Journal of Electronic Commerce Research*, 8(2), 120-134.
- Zhao, W. and Mitra, P. (2015). "Scrapy: An Open Source Web Scraping Framework for Python", *Proceedings of the 24th International Conference on World Wide Web (WWW '15 Companion)*, 785-790.
- Zhao, W. X., He, J., Chen, J., Liu, X., Du, X. and Chang, E. Y. (2017). "Personalized Recommendation of Social Software Items Based on Social Network Information", *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 47(7), 2030-2041.
- Zhu, K. (2002). "Information Transparency in Electronic Marketplaces: Why Data Transparency may Hinder the Adoption of B2B Exchanges", *Electronic Markets*, 12(2), 92-99.
- Zhu, K. (2004). "Information Transparency of Business-to-Business Electronic Markets: A Game-Theoretic Analysis", *Management science*, 50(5), 670-685.

Zhu, K. and Zhou, Z. (2007). "Conflict of Interest Regarding Information Transparency in a Business-to-Business Electronic Market with Two-Sided Competition"