T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI
İŞLETME DOKTORA PROGRAMI

DOKTORA TEZİ

YAPAY ZEKÂ DESTEKLİ ÜRÜN PAZARINDA BİRLİKTE YARATIM ARACI OLARAK ELEKTRONİK AĞIZDAN AĞIZA PAZARLAMA VE TEKNOLOJİ ETKİLEŞİMİ

GÜL YAZICI BENZEŞ
17713037

TEZ DANIŞMANI
DOÇ. DR. TUĞÇE OZANSOY ÇADIRCI

2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI
İŞLETME DOKTORA PROGRAMI

DOKTORA TEZİ

YAPAY ZEKÂ DESTEKLİ ÜRÜN PAZARINDA BİRLİKTE YARATIM ARACI OLARAK ELEKTRONİK AĞIZDAN AĞIZA PAZARLAMA VE TEKNOLOJİ ETKİLEŞİMİ

GÜL YAZICI BENZEŞ
17713037
ORCID NO: 0009-0009-9368-9145

TEZ DANIŞMANI
DOÇ. DR. TUĞÇE OZANSOY ÇADIRCI

MAYIS 2024

Gül YAZICI BENZEŞ tarafından hazırlanan "YAPAY ZEKÂ DESTEKLİ ÜRÜN PAZARINDA BİRLİKTE YARATIM ARACI OLARAK ELEKTRONİK AĞIZDAN AĞIZA PAZARLAMA VE TEKNOLOJİ ETKİLEŞİMİ" başlıklı çalışma, **27/05/2024** tarihinde yapılan savunma sınavı sonucunda **oybirliği** ile başarılı bulunmuş ve jürimiz tarafından İşletme Ana Bilim Dalı, İşletme Programında **DOKTORA** tezi olarak kabul edilmiştir.

Danışman	**İmza**
Doç. Dr. Tuğçe Ozansoy Çadırcı	…….

Jüri Üyeleri	**İmza**
Prof. Dr. İbrahim Kırçova	…….
Prof. Dr. Zehra Bozbay	…….
Doç. Dr. Ayşegül Sağkaya Güngör	……...
Dr. Öğretim Üyesi Mehmet Çağlar	…….

ÖZET

YAPAY ZEKÂ DESTEKLİ ÜRÜN PAZARINDA BİRLİKTE YARATIM ARACI OLARAK ELEKTRONİK AĞIZDAN AĞIZA PAZARLAMA VE TEKNOLOJİ ETKİLEŞİMİ

Bu tez, müşteri yorumlarından anlamlı içgörüler çıkarma, Elektronik Ağızdan Ağıza Pazarlama (EAAP) ve Teknoloji Etkileşimi arasındaki dinamik ilişkiyi yapay zekâ destekli sanal asistanlar üzerinden derinlemesine incelemektedir. Araştırmanın temelinde, birlikte yaratım (co-creation) süreçlerinin anlaşılması yatar. Birlikte yaratım, müşterilerin ve diğer paydaşların, ürün veya hizmet geliştirme süreçlerine aktif olarak katılımını ifade eder. Bu süreç, müşteri geri bildirimlerinin, yeni ürün ve hizmetlerin şekillendirilmesinde kullanılmasını sağlar, böylece müşteri ihtiyaçlarına daha uygun ve yenilikçi çözümler ortaya çıkar.

Birinci çalışma, müşteri yorumlarından anlamlı içgörüler çıkarmak için dört farklı konu modelleme yönteminin karşılaştırılmasına odaklanmaktadır. Bu da müşteri geri bildirimlerinin daha doğru ve verimli bir şekilde analiz edilmesini sağlayarak, birlikte yaratım süreçlerinde müşteri ihtiyaçlarını ve beklentilerini daha iyi anlamak için kritik bir temel oluşturur. Yapılan analiz doğrultusunda, seçilen en iyi algoritma ikinci çalışmada kullanılarak detaylı bir konu analizi yapılmasına olanak tanır. İkinci çalışma, konu modelleme, duygu ve fırsat analizleri aracılığıyla, EAAP'nin yeni ürün geliştirme süreçlerindeki anlamlılığını iki farklı sanal asistan modeli üzerinden inceler ve müşteri geri bildirimlerinin ürün geliştirme ve pazarlama stratejileri üzerindeki etkisini değerlendirir. Bu bölüm, birlikte yaratımın müşteri memnuniyeti ve ürün inovasyonu üzerinde nasıl pozitif bir etki yaratabileceğini vurgular. Üçüncü ve son çalışma, teknoloji etkileşimi üzerine bir model önerisi sunar ve sanal asistanlar aracılığıyla gerçekleştirilen müşteri etkileşiminin, birlikte yaratım süreçlerini nasıl destekleyebileceğini ve müşteri memnuniyetini artırabileceğini gösterir.

Sonuç olarak, bu tez, müşteri yorumlarından elde edilen anlamlı içgörülerin, EAAP ve teknoloji etkileşimi aracılığıyla nasıl değerli stratejik önerilere dönüştürülebileceğini göstermektedir. Bu süreçlerin entegrasyonu, şirketlerin müşteri ihtiyaçlarını daha iyi anlamasına, müşteri memnuniyetini artırmasına ve pazar yerinde sürdürülebilir bir rekabet avantajı elde etmesine yardımcı olur.

Anahtar Kelimeler: yapay zekâ, müşteri yorumları, elektronik ağızdan ağıza pazarlama, teknoloji etkileşimi, metin madenciliği, konu modelleme, duygu analizi

ABSTRACT

E-WOM AS A CO-CREATION TOOL IN THE ARTIFICIAL INTELLIGENCE SUPPORTED PRODUCT MARKET, AND TECHNOLOGY ENGAGEMENT

This thesis explores the dynamic relationship between extracting meaningful insights from customer reviews, Electronic Word of Mouth Marketing (EWOM) and Technology Engagement through AI-powered virtual assistants. At the heart of the research is an understanding of co-creation processes. Co-creation refers to the active involvement of customers and other stakeholders in the product or service development process. This process enables customer feedback to be used to shape new products and services, resulting in innovative solutions that are more relevant to customer needs.

The first study focuses on comparing four different topic modeling methods for extracting meaningful insights from customer reviews. This provides a critical foundation for a more accurate and efficient analysis of customer feedback and a better understanding of customer needs and expectations. Based on the analysis, the best algorithm selected is used in the second study, allowing for a detailed topic analysis. The second study emphasizes the relevance of EWOM in new product development processes and the impact of customer feedback on product development and marketing strategies through an examination of two different virtual assistant models. This chapter highlights how co-creation can have a positive impact on customer satisfaction and product innovation. The third and final chapter proposes a model of technology engagement and shows how customer interaction through virtual assistants can support co-creation processes and increase customer satisfaction.

In conclusion, this thesis shows how meaningful insights from customer reviews can be transformed into valuable strategic recommendations through EWOM and technology engagement. The integration of these processes helps companies to better understand customer needs, increase customer satisfaction and achieve a sustainable competitive advantage in the marketplace.

Key Words: Artificial intelligence, customer reviews, electronic word-of-mouth marketing, technology engagement, text mining, topic modeling, sentiment analysis

ÖN SÖZ

Bu çalışmanın hazırlanmasında emeği geçen ve bana destek olan herkese en içten teşekkürlerimi sunarım.

Öncelikle, değerli danışmanım Doç. Dr. Tuğçe Ozansoy Çadırcı'ya, sürecin her aşamasında gösterdiği anlayış, destek ve sabrı için minnettarım. Bugün ortaya böyle bir tez çıkarabildiysem kendisinin bana olan güveni ve inancı sayesindedir. Tuğçe Hocam'ın bu konudaki derin bilgisi ve geniş vizyonu, araştırmamın yönünü belirlemede ve çalışmanın niteliğini artırmada büyük rol oynamıştır. Kendisi, yalnızca bir danışman değil, aynı zamanda her daim ilham kaynağım olmuştur. Ayrıca tez yazma sürecimde, beni fikirleriyle destekleyen sayın hocalarım Prof. Dr. İbrahim Kırçova ve Prof. Dr. Zehra Bozbay'a teşekkürlerimi sunuyorum.

Doktoraya başlamama vesile olan Hızır Konuk'a, bana bu yolda cesaret verdiği ve her daim motive ettiği için teşekkür ederim. Veri çekme ve kodlama adımlarında yardımlarını hiçbir zaman esirgemeyen Veli Bozatlı'ya çok teşekkür ederim. Yeterlik sürecinden itibaren yanımda olan ve her konuda destek olan arkadaşım Tuğba Özbek'e ve uzun zaman boyunca hayatımın en büyük alanını kaplayan bu sürecin her aşamasına yakınen tanık olan ve başaracağımdan hiçbir zaman şüphe etmeyen tüm dostlarıma en içten teşekkürlerimi sunarım. Ve en önemlisi aileme, sevgili eşim ve oğluma, bana gösterdikleri sevgi, sabır ve anlayış için sonsuz teşekkür ederim. Onların desteği olmasaydı, bu çalışmayı tamamlamak mümkün olmazdı.

Bu tez çalışmasının, bilgiye katkıda bulunmasını ve alandaki diğer çalışmalara ilham vermesini diliyorum.

Gül YAZICI BENZEŞ

Mayıs, 2024; İstanbul

İÇİNDEKİLER

ÖZ iv
ABSTRACT v
ÖN SÖZ vi
İÇİNDEKİLER vii
TABLOLAR LİSTESİ x
ŞEKİLLER LİSTESİ xii
KISALTMALAR xv
1. GİRİŞ 1
2. MÜŞTERİ YORUMLARINDAN ANLAMLI İÇGÖRÜLER ÇIKARMAK: 4 FARKLI KONU MODELLEME YÖNTEMİNİN KARŞILAŞTIRILMASI VE PAZARLAMA ARAŞTIRMALARINDA KULLANIMI 4
2.1. Giriş 4
2.2. Literatür Taraması 7
2.3. Veri ve Metodoloji 11
2.3.1. Konu Modelleme 13
2.3.1.1. Model 1: Latent Dirichlet Allocation 14
2.3.1.2. Model 2: Sentence-BERT (Cümle Dönüştürücüler) 17
2.3.1.3. Model 3: BERTopic 18
2.3.1.4. Model 4: Top2Vec 20
2.4. Sonuçlar ve Bulgular 21
2.4.1. LDA 21
2.4.1.1. İngilizce Durak Kelimelerinin Çıkarılması 23
2.4.1.2. Hafif Ön İşleme 24
2.4.1.3. Ağır Ön İşleme 25
2.4.2. BERT Sentence Transformers (Cümle Dönüştürücüler) 29
2.4.2.1. İngilizce Durak Kelimelerinin Çıkarılması 29
2.4.2.2. Hafif Ön İşleme 30
2.4.3. BERTopic 31
2.4.3.1. Ön İşleme Yok 32
2.4.3.2. İngilizce Durak Kelimelerinin Çıkarılması 33
2.4.3.3. Hafif Ön İşleme 34

2.4.4. Top2Vec 40
2.5. Tartışma 46
2.5.1. Yöntemsel Uygulanabilirlik 46
2.5.1.1. Ön İşleme 47
2.5.1.2. Eğitme Süresi 47
2.5.1.3. Önceden Eğitilmiş Model Erişilebilirliği 48
2.5.1.4. Görselleştirme 48
2.5.2. Uygulama Kapasitesi 49
2.6. Sonuç 58
2.7. Sınırlılıklar ve Gelecek Araştırmalar 60
3. YENİ ÜRÜN GELİŞTİRME SÜREÇLERİNDE ELEKTRONİK AĞIZDAN AĞIZA PAZARLAMANIN ANLAMLILIĞI: İKİ SANAL ASİSTAN MODELİ ÜZERİNDEN İNCELEME 62
3.1. Giriş 62
3.2. Literatür Taraması 64
3.2.1. Ürün Geliştirme Süreçlerinde EAAP 64
3.2.2. Büyük Veride Metin Madenciliği ve Duygu Analizi 67
3.3. Veri ve Metodoloji 68
3.3.1. BERTopic Konu Modelleme Tekniği 70
3.3.2. Duygu Analizi Tekniği 72
3.4. Bulgular 73
3.4.1. Konu Modelleme Sonuçları 73
3.4.1.1. Konular Arası Mesafe Haritası 75
3.4.1.2. Konu Olasılık Dağılımı 76
3.4.1.3. Hiyerarşik Kümeleme 78
3.4.1.4. Konu Kelime Puanları 79
3.4.1.5. Benzerlik Matrisi 81
3.4.1.6. Konu Başına Kelime Puan Düşüşü 83
3.4.2. Duygu ve Duyarlılık Analizi Sonuçları 85
3.4.2.1. Duygu Analizi Sonuçları 85
3.4.2.2. Puanlama Sonuçları 86
3.4.2.3. Pozitif Yorumların Sözcük Bulutu 87
3.4.2.4. Negatif Yorumların Sözcük Bulutu 88
3.4.2.5. Nötr Yorumların Sözcük Bulutu 89
3.4.2.6. Genel Kelime Bulutu 90
3.4.2.7. Duyarlılık Analizi (Yorum Sayısı) 91

3.4.2.8. Duyarlılık Analizi (Polarite-Öznellik) 92
3.4.2.9. Konu Bazlı İnceleme Değeri 93
3.4.3. Fırsat Analizi 95
3.5. Tartışma 102
3.5.1. Müşteri İçgörüleri ve Tercihleri 102
3.5.2. Stratejik Pazar Fırsatları 106
3.6. Sonuç 109
3.6.1. Sınırlılıklar ve Gelecek Araştırmalar 110
4. TEKNOLOJİ ETKİLEŞİMİ: SANAL ASİSTANLAR ÜZERİNDEN MEVCUT MÜŞTERİ VERİSİYLE MODEL ÖNERİSİ 112
4.1. Giriş 112
4.2. Literatür Taraması 114
4.2.1. Sanal Asistanlar 114
4.2.2. Teknoloji Etkileşimi 117
4.2.2.1. Algılanan Kullanım Kolaylığı 118
4.2.2.2. Algılanan Değer 119
4.2.2.3. Algılanan Kalite 120
4.2.3. Müşteri Memnuniyeti 122
4.3. Veri ve Metodoloji 124
4.3.1.1. Kümeleme Analizi 126
4.3.1.2. Regresyon Analizi 127
4.4. Bulgular 130
4.4.1.1. Kümeleme Sonuçları 130
4.4.2. Regresyon Sonuçları 134
4.5. Sonuç 137
4.6. Sınırlılıklar ve Gelecek Araştırmalar 138
5. GENEL DEĞERLENDİRME VE SONUÇ 140
KAYNAKÇA 143

TABLOLAR LİSTESİ

Tablo 1: Konu Modelleme Üzerine Yapılan Çalışmaların Bazıları 8
Tablo 2: İngilizce Durak Kelimeleri Çıkarıldığında LDA Algoritmasının Konu Modelleme Çıktıları 24
Tablo 3: Hafif Ön İşleme Yapıldığında LDA Algoritmasının Konu Modelleme Çıktıları 25
Tablo 4: Ağır Ön İşleme Yapıldığında LDA Algoritmasının Konu Modelleme Çıktıları 27
Tablo 5: İngilizce Durak Kelimeleri Çıkarıldığında SBERT Algoritmasının Konu Modelleme Çıktıları 30
Tablo 6: Hafif Önişleme Yapıldığında SBERT Algoritmasının Konu Modelleme Çıktılar 30
Tablo 7: Hiçbir Önişleme Yapılmadığında BERTopic Algoritmasının Konu Modelleme Çıktıları 33
Tablo 8: İngilizce Durak Kelimeleri Çıkarıldığında BERTopic Algoritmasının Konu Modelleme Çıktıları 34
Tablo 9: Hafif Ön İşleme Yapıldığında BERTopic Algoritmasının Konu Modelleme Çıktıları 35
Tablo 10: Top2Vec Konu Modelleme Çıktıları 41
Tablo 11: Konu Modelleme Algoritmalarının Karşılaştırılması 49
Tablo 12: SBERT ve Top2Vec Karşılaştırılması 50
Tablo 13: LDA ve BERTopic Karşılaştırması 52
Tablo 14: 4 Konu Modelleme Algoritmasının Konuları 54
Tablo 15: Amazon Echo Show 5 Konu Modelleme Sonuçlar 73
Tablo 16: Amazon Echo Show 8 Konu Modelleme Sonuçları 74
Tablo 17: Amazon Echo Show 5 Fırsat Analizi Sonuçları 96
Tablo 18: Amazon Echo Show 8 Fırsat Analizi Sonuçları 100
Tablo 19: Amazon Echo Show 5 ve Amazon Echo Show 8 Ürünlerinde Duyguların Karşılaştırılması 102
Tablo 20: Amazon Echo Show 5 ve Amazon Echo Show 8 Ürünleri İçin Fırsat Analizi 106
Tablo 21: Tanımlayıcı İstatistikler 125
Tablo 22: Kümelerin Birim Değerleri 132
Tablo 23: Küme Ortalamaları 132

Tablo 24: Önem Özelliği ve Modelin Tahmin Gücü Değerleri 136

ŞEKİLLER LİSTESİ

Şekil 1: Veri Kümesinin Öngörünümü 12
Şekil 2: Jaccard Benzerliği Algoritması- 13 Konu Sayısı 23
Şekil 3: Jaccard Benzerliği Algoritması - 14 Konu Sayısı 26
Şekil 4: Konular Arası Mesafe Haritası 28
Şekil 5: LDA Kelime Bulutu 29
Şekil 6: SBERT Kümelerinin Görselleştirilmesi 31
Şekil 7: BERTopic Konular Arası Mesafe Haritası 36
Şekil 8: Bertopic Konu Olasılıksal Dağılımı 37
Şekil 9: BERTopic Hiyerarşik Kümeleme 37
Şekil 10: BERTopic Konu Kelime Skorları 38
Şekil 11: BERTopic Benzerlik Matrisi 39
Şekil 12: BERTopic Konu Başına Kelime Puan Düşüşü 40
Şekil 13: Top2Vec Konu 0 Kelime Bulutu 42
Şekil 14: Top2Vec Konu 1 Kelime Bulutu 43
Şekil 15: Top2Vec Konu 2 Kelime Bulutu 43
Şekil 16: Top2Vec Konu 3 Kelime Bulutu 43
Şekil 17: Top2Vec Konu 4 Kelime Bulutu 44
Şekil 18: Top2Vec Konu 5 Kelime Bulutu 44
Şekil 19: Top2Vec Konu 6 Kelime Bulutu 44
Şekil 20: Top2Vec Konu 7 Kelime Bulutu 45
Şekil 22: Top2Vec Konu 9 Kelime Bulutu 45
Şekil 23: Top2Vec Konu 10 Kelime Bulutu 46
Şekil 24: Konulara Dair Venn Diyagramı 53
Şekil 25: Amazon Echo Show 5 Görseli 69
Şekil 26: Amazon Echo Show 8 Görseli 69
Şekil 27: Amazon Echo Show 5 Konular Arası Mesafe Haritası 75
Şekil 28: Amazon Echo Show 8 Konular Arası Mesafe Haritası 76
Şekil 29: Amazon Echo Show 5 Konu Olasılık Dağılımı 77
Şekil 30: Amazon Echo Show 8 Konu Olasılık Dağılımı 77
Şekil 31: Amazon Echo Show 5 Hiyerarşik Kümeleme 78

Şekil 32: Amazon Echo Show 8 Hiyerarşik Kümeleme 78
Şekil 33: Amazon Echo Show 5 Konu Kelime Puanları 80
Şekil 34: Amazon Echo Show 8 Konu Kelime Puanları 81
Şekil 35: Amazon Echo Show 5 Benzerlik Matrisi 82
Şekil 36: Amazon Echo Show 8 Benzerlik Matrisi 83
Şekil 37: Amazon Echo Show 5 Konu Başına Kelime Puan Düşüşü 84
Şekil 38: Amazon Echo Show 8 Konu Başına Kelime Puan Düşüşü 84
Şekil 39: Amazon Echo Show 5 Duygu Analizi Sonuçları 85
Şekil 40: Amazon Echo Show 8 Duygu Analizi Sonuçları 85
Şekil 41: Amazon Echo Show 5 Puanlama Sonuçları 86
Şekil 42: Amazon Echo Show 8 Puanlama Sonuçları 87
Şekil 43: Amazon Echo Show 5 Pozitif Kelime Bulutu 87
Şekil 44: Amazon Echo Show 8 Pozitif Kelime Bulutu 88
Şekil 45: Amazon Echo Show 5 Negatif Kelime Bulutu 88
Şekil 46: Amazon Echo Show 8 Negatif Kelime Bulutu 89
Şekil 47: Amazon Echo Show 5 Nötr Kelime Bulutu 89
Şekil 48: Amazon Echo Show 8 Nötr Kelime Bulutu 90
Şekil 49: Amazon Echo Show 5 Kelime Bulutu 90
Şekil 50: Amazon Echo Show 8 Kelime Bulutu 91
Şekil 51: Amazon Echo Show 5 Duyarlılık Analizi (Yorum Sayısı) 91
Şekil 52: Amazon Echo Show 8 Duyarlılık Analizi (Yorum Sayısı) 92
Şekil 53: Amazon Echo Show 5 Duyarlılık Analizi (Polarite-Öznellik) 93
Şekil 54: Amazon Echo Show 8 Duyarlılık Analizi (Polarite-Öznellik) 93
Şekil 55: Amazon Echo Show 5 Ürününde Konulara Dair Duygu Dağılımı 94
Şekil 56: Amazon Echo Show 8 Ürününde Konulara Dair Duygu Dağılımı 95
Şekil 57: Amazon Echo Show 5 Ürünü İçin Fırsat Ortamı 98
Şekil 58: Amazon Echo Show 8 Ürünü İçim Fırsat Ortamı 101
Şekil 59: Amazon Echo Show 5 ve Amazon Echo Show 8 Modellerinde Ortak Konuların Duygu Analizi Bağlamında Karşılaştırılması 104
Şekil 60: Teknoloji Etkileşimi Modeli 123
Şekil 61: Kalite Değişkeninin Histogramı 127
Şekil 62: Değer Değişkeninin Histogramı 128
Şekil 63: Kullanım Kolaylığı Değişkeninin Histogramı 128
Şekil 64: Derecelendirme Değişkeninin Histogramı 129
Şekil 65: Calinski-Harabasz Metodu Tarafından Önerilen Optimal Küme Sayısı Grafiği 131

Şekil 66: Dirsek Metodu Tarafından Önerilen Optimal Küme Sayısı Grafiği 131

KISALTMALAR

LDA : Latent Dirichlet Allocation

BERT : Biderectional Encoder Representations from Transformers

SBERT : Sentence-BERT

EAAP : Elektronik Ağızdan Ağıza Pazarlama

GAA : Gizli Anlam Analizi

oGAA : Olasılıksal Gizli Anlam Analizi

1. GİRİŞ

Teknoloji kabulü, kullanıcıların yeni teknolojilere nasıl yaklaştıklarını ve bu teknolojileri nasıl benimsediklerini anlamak için kritik bir süreçtir. Bu süreç, teknolojinin kullanımının yaygınlaşmasını ve teknolojik yeniliklerin toplumda etkin bir şekilde entegre edilmesini sağlamaktadır (Kääriä, 2017). Kullanıcıların teknolojiyi nasıl algıladıkları, teknolojinin sunduğu faydalara olan inançları ve teknolojiyi kullanma niyetleri bu sürecin temelini oluşturur (O'Brien & Toms, 2008). Etkileşim ise, iki veya daha fazla unsur arasındaki dinamik ilişkiyi ifade eder ve bu, insan ve teknoloji arasındaki ilişkiler için de geçerlidir. Etkileşim (bağlılık) kavramı, ilk kez çalışan sadakatini arttırmak için psikolojik bir mekanizma olarak önerilmiştir (Saks, 2006). Teknoloji alanında Etkileşim, bireyin herhangi bir teknolojiyle etkileşime girdiğinde meydana gelen son derece keyifli bir deneyimle odaklanmış bir dahil olma ve derin katılım durumu olarak kavramsallaştırılmıştır (Agarwal & Karahanna, 2004; Calvo-Porral & Pesqueira-Sanchez, 2022).

Yapay zekâ (YZ) teknolojilerinin gelişimi, teknoloji etkileşimini yeni bir boyuta taşımaktadır (Dwivedi vd., 2021). YZ destekli ürünler, kullanıcı ihtiyaçlarını daha derinlemesine anlayarak ve kişiselleştirilmiş, etkileşimli ve zengin deneyimler sunarak, teknoloji ile kullanıcı arasındaki ilişkiyi dönüştürmektedir (Kaartemo & Helkkula, 2018; Niksirat vd., 2018). Bu gelişme, YZ ve teknoloji etkileşimi arasındaki ilişkide kritik bir öneme sahiptir; YZ, teknolojiyle olan etkileşimin daha sezgisel ve memnuniyet verici olmasını sağlamaktadır (Shah vd., 2024).

Birlikte yaratım (Co-Creation), kullanıcıların ve üreticilerin, ürün ve hizmetlerin geliştirilmesi için bir araya gelerek aktif bir şekilde iş birliği yaptığı bir süreçtir (Prahalad & Ramaswamy, 2004). Birlikte yaratım sayesinde müşteriler, şirketlere fikir, geri bildirim ve tercihleriyle katkıda bulunarak ürün, hizmet ve deneyimlerin geliştirilmesini doğrudan etkilemektedirler (Fu & Zhou, 2020). Elektronik Ağızdan Ağıza Pazarlama (EAAP), tüketicilerin çevrimiçi platformlarda yaptıkları yorumlar, tavsiyeler ve geri bildirimler yoluyla bu süreci destekleyen güçlü bir araçtır (Hennig-Thurau & Walsh, 2003). EAAP, firmalara müşteri deneyimlerini ve beklentilerini

doğrudan dinleme fırsatı sunarak, yeni ürün geliştirme süreçlerinde önemli bir yol gösterici olmaktadır (Houda Elafdel, 2019). Sonuç olarak, tüketici yorumları ve tartışmaları, şirketlere müşteri ihtiyaçları ve tercihlerine ilişkin gerçek zamanlı geri bildirim ve içgörü sağlamakta, bu da birlikte yaratma sürecinde çok değerli olmaktadır. Bu sayede, firmalar müşterilerin gerçek ihtiyaçlarına ve sorunlarına odaklanabilmekte, ürünlerini müşteri geri bildirimlerine göre şekillendirebilmekte ve pazarın dinamiklerine daha hızlı uyum sağlayabilmektedir (Sawhney vd., 2005). Teknoloji etkileşimi ve EAAP, birlikte yaratım sürecinde firmalara rehberlik ederek, daha yenilikçi, kullanıcı dostu ve başarılı ürünlerin pazara sunulmasında katkı sağlamaktadır (Ellway & Dean, 2020; Akman vd., 2019).

Bu tezin temel amacı, müşteri memnuniyeti ve teknolojik ürünler arasındaki etkileşimi geniş çapta ele alan mevcut literatüre rağmen, özellikle yapay zekâ destekli sanal asistanların bu dinamikteki rolünü derinlemesine analiz etmek ve birlikte yaratım süreçlerinin, teknoloji ve kullanıcılar arasındaki dinamik etkileşim yoluyla nasıl desteklendiğini araştırmaktadır. Literatürde, sanal asistanların müşteri memnuniyetine etkileri üzerine yeterince ampirik kanıt olmaması nedeniyle bir boşluk bulunmaktadır; bu boşluğa işaret eden Brill vd. (2019), bu konudaki araştırma eksikliğini vurgulamaktadır. Bu açığı kapatarak, yapay zekâ destekli ürünlerin, kapsamlı bir şekilde incelenmesine olanak tanımak amacıyla, bu tez kapsamında yapılan üç çalışma, ev tipi bir sanal asistan ürünü olan "Amazon Alexa" üzerinden gerçekleştirilmiştir. Bu analizler, sanal asistan teknolojisinin kullanıcı deneyimi ve memnuniyet üzerindeki etkisine dair değerli içgörüler sunmayı amaçlamaktadır. Küresel akıllı sanal asistan pazarının 2019 ile 2025 yılları arasında yıllık %35,4 oranında büyüyerek, 2025 yılında toplamda 19,6 milyar ABD doları değerine ulaşacağı öngörülmektedir (Sena, 2023). Özellikle konut alanında akıllı hoparlörlerin kullanımındaki artışın, bu pazarın gelecekteki büyümesine önemli derecede yön vereceği beklenmektedir. Bu da kişisel asistanların kullanım motivasyonlarını, teknoloji ve müşteri etkileşimini daha iyi anlamak gerektiği konusunda önemli bir ihtiyaç ortaya çıkarmaktadır.

O nedenle, bu tez kapsamında yapılan ilk çalışmada, Amazon Alexa'nın, Echo Show 8 modelinin müşteri yorumları dört farklı konu modelleme yöntemi ile incelenmiştir. İkinci çalışmada, Amazon Alexa'nın, Echo Show 5 ve Echo Show 8 modellerine ait müşteri yorumları analiz edilerek, şirketlerin yeni ürün geliştirme süreçlerinde,

EAAP'yı nasıl kullanılabileceği araştırılmıştır. Üçüncü çalışmada, önerilen Teknoloji Etkileşimi modeli üzerinden, kullanıcıların ürünle etkileşimleri ve müşteri memnuniyeti arasındaki ilişki ele alınmıştır. Ayrıca ürün kullanım süresinin artmasının, müşteri memnuniyetine etkisi ve yapılan müşteri segmentasyonu sonucu, hangi müşteri kitlesini daha çok etkilediği analiz edilmiştir.

Bu tezin önemi, ilk olarak metodolojik derinliği ve uyguladığı yenilikçi analitik tekniklerle öne çıkmaktadır. Konu modelleme, duygu analizi, fırsat analizi, regresyon ve kümeleme analizi gibi çeşitli yöntemler, Python programlama dili kullanılarak uygulanmıştır. İlk bölümde, dört farklı konu modelleme yönteminin karşılaştırılması, en uygun metodun seçilmesine yönelik temel bir yaklaşım olarak öne çıkmakta, semantik anlamlılık ve pazarlama araştırmalarındaki pratiklik açısından literatüre metodolojik bir katkı sağlamaktadır. İkinci bölümde, EAAP'nin etkinliğini ve önemini vurgulamak için yapılan analizler, pazara sunulan aynı ürünün iki farklı modeli üzerinden gerçekleştirilmesi ile öne çıkmaktadır. Bu yaklaşım, akademik literatüre önemli bir katkı sunmanın yanı sıra, şirketler için de değerli içgörüler ortaya koymakta, ürün geliştirme stratejilerine yeni perspektifler kazandırmaktadır. Üçüncü bölümde sunulan Teknoloji Etkileşimi modeli, bu çalışmanın literatüre, özgün bir model önerisiyle katkıda bulunduğunu göstermektedir.

2. MÜŞTERİ YORUMLARINDAN ANLAMLI İÇGÖRÜLER ÇIKARMAK: 4 FARKLI KONU MODELLEME YÖNTEMİNİN KARŞILAŞTIRILMASI VE PAZARLAMA ARAŞTIRMALARINDA KULLANIMI

2.1. Giriş

Dijital dünyanın sürekli gelişimiyle birlikte, İnternet, tüketicilere satın alma deneyimleri hakkında görüşlerini paylaşabilecekleri platformlar sağlamaktadır. Müşteriler, e-ticaret sitelerinden sosyal ağlara, kişisel bloglarından ürün değerlendirme sitelerine kadar çok çeşitli mecralarda ürünler hakkında yorumlarını yayınlamaktadır. Bu müşteri yorumları, geleneksel analiz metodolojilerinin kapsamını aşan geniş ve derin metinsel veri kümeleri olarak tanımlanmaktadır. Önceleri, tüketiciler alışveriş sitelerinde yalnızca pazarlamacılar tarafından hazırlanan içeriklere dayanarak kararlar alıyordu (King vd., 2014), ancak zamanla, çevrimiçi ortamlarda daha fazla deneyim kazanan tüketicilerin etkisiyle, çevrimiçi perakendeciler müşteri yorumlarının satın alma kararları üzerindeki önemini kabul etmeye başlamıştır (Mosteller & Mathwick, 2016). Sonuç olarak, günümüzde online perakendeciler sundukları ürün geliştirme süreçlerini tüketicilerin yazdığı çevrimiçi yorumlarla desteklemeye çalışmaktadır. İş perspektifinden bakıldığında, müşteri yorumları ürün ve hizmet iyileştirme fırsatları hakkında önemli bilgiler sağlayabilir ve müşteri katılımından kaynaklanan yatırım getirisi (ROI) ölçümünü iyileştirmek için kullanılabilir (Wedel & Kannan, 2016). Ayrıca, müşterilerin bakış açısından, müşteri yorumları karar verme süreçlerinde sağladıkları bilgilerle daha akıllıca kararlar alınmasını pekiştirebilir (Kunz vd., 2017).

Perakendeciler ve karar alıcılar müşteri yorumlarının önemini ve büyük miktarda çevrimiçi verinin kullanılabilirliğini ve erişilebilirliğini vurguladıkça pazarlama akademisi öncelikle çevrimiçi yorumlardan içgörü elde etmekle ilgilenmiştir (Kundu & Chakraborti, 2020). Müşteri yorumlarına olan ilginin arkasındaki temel neden, pazar yeri bilgisi sağlama potansiyellerinde yatmaktadır. Geleneksel anket yöntemleriyle karşılaştırıldığında, veri mevcudiyeti, veri toplama hızı ve basitliği ile tarafsız ve

önyargısız bilgi sağlama açısından üstündürler (Lu & Stepchenkova, 2015). Bu nedenle, pazarlama akademisi çevrimiçi değerlendirmeleri, ürün seçimi üzerindeki etkileri (Shen vd., 2015; Schuckert vd., 2015; Moore, 2015; Duan vd., 2008; Alzate vd., 2021; Xiao & Li, 2019; C. Park & Lee, 2009), müşteri bağlılığı ile ilişkileri (R. Thakur, 2018; Lo Presti & Maggiore, 2021; Karakaya & Barnes, 2010; Zhang vd., 2021; M. Yang vd., 2019; Messner, 2022) ve algılanan yardımseverlik (Singh vd., 2017; Lee & Choeh, 2020; Ventre & Kolbe, 2020; Hu & Yang, 2020; Huifeng vd., 2020; Casaló vd., 2015) gibi alanlarda analiz etmiştir. Çevrimiçi incelemeler üzerine yapılan önceki çalışmalar da anket tasarımı (Wei vd., 2013; J. Guo vd., 2020), deneyler (V. T. P. Cheng & Loi, 2014; Roozen & Raedts, 2020) ve nitel araştırmalar (Kawaf & Istanbulluoglu, 2019; Z. Yang & Fang, 2004; Pantelidis, 2010; Y. H. Cheng & Ho, 2015) gibi farklı metodolojik yaklaşımları takip etmiştir.

Müşteri yorumları çoğunlukla geleneksel analitik becerileri zorlayan büyük metinsel veri havuzları olarak anılmaktadır. İnsan düşünce ve davranışlarının bu dijital arşivleri, bilgisayarların hesaplama gücünün üstel büyümesiyle birleştiğinde (Lazer & Radford, 2017) pazarlama biliminde büyük veri analitiği ve metin madenciliği algoritmalarını kullanan yeni bir çalışma alanı da yaratmıştır (Lucini vd., 2020; Ordenes vd., 2014; Chung vd., 2022; Jia, 2018; Agrawal & Mittal, 2022). Bu çalışmalarda, metinsel verilerden anlamlı sonuçlar elde etmek için çoğunlukla web kazıma kodları, veri madenciliği ve metin madenciliği algoritmalarının bir kombinasyonunu kullanmaktadır (Baka, 2016). İçerik analizinin önceki yıllardaki popülerliğine rağmen (Lu & Stepchenkova, 2015), bu yeni araştırma yaklaşımı müşteri yorumlarını daha etkili bir şekilde toplamak, işlemek, analiz etmek, görselleştirmek ve yorumlamak için makine öğrenimi, Doğal Dil İşleme (NLP) ve metin madenciliği algoritmalarını kullanmaktadır (Elragal & Klischewski, 2017). Çevrimiçi yorumlar sosyal medyada, şirketlerde ve üçüncü taraf web sitelerinde yığıldıkça, değerli bilgilerin elde edilmesi daha zor hale gelmektedir. Yapılandırılmamış metin verilerine gömülü gizli konu kalıpları çıkarma yetenekleri nedeniyle (Luo vd., 2020; Egger, 2022), son zamanlarda önemli ölçüde popülerlik kazananan (Albalawi vd., 2020) konu modelleme algoritmaları karşımıza çıkmaktadır.

Farklı konu modelleme yöntemleri arasında, kapsamlı belge koleksiyonları içindeki gizli konu yapılarını tanımlayan denetimsiz bir makine öğrenimi algoritması olan Latent Dirichlet Allocation (LDA) (Blei vd., 2003), en çok kullanılan tekniktir (Luo

vd., 2020; Gallagher vd., 2017). LDA, her belgeyi bir kelime sayısı vektörü olarak ele alan bir "kelime torbası" yaklaşımı kullanır (Hong & Davison, 2010). Son yıllardaki popülerliğine rağmen, güvenilirliği ve geçerliliği konusunda eleştiriler de bulunmaktadır (Egger & Yu, 2022). Bu eleştirilerin çoğu, veri ön işlemedeki zorlukları ifade etmektedir (Zhou vd., 2017). Sonuç olarak, bu sorunu çözmek için daha az çabayla daha yüksek performans sağlayan Top2Vec (Angelov & Clendenning, 2020), Sentence-BERT (SBERT) (Reimers & Gurevych, 2019) ve BERTopic (Grootendorst, 2021) gibi yeni teknikler geliştirilmiştir. Bu teknikler, gömme tabanlı bir yaklaşım kullanırlar ve daha az ön işleme uygulaması sağladıkları için pratik olarak LDA'dan daha basittirler (Zhou vd., 2017).

Bu çalışmada, Amazon Alexa ürününün Echo Show 8 modelini analiz edilmektedir. Amazon Echo Show ev ortamları için tasarlanmıştır ve medyada sıklıkla "geleceğin bilgisayarı" olarak anılmaktadır (Gao vd., 2018). Son teknoloji bir ürün seçilerek, pazarlama alanında büyük verinin kullanıldığı, bir yapay zekâ ürününün analiz edildiği ve makine öğrenmesi metodolojilerinin uygulandığı bütüncül bir teknolojik çalışma sunulması amaçlanmıştır.

Bu araştırma literatüre çeşitli şekillerde katkıda bulunmayı amaçlamaktadır. İlk olarak, makine öğrenimi yöntemleri ve pazarlama bilimindeki kullanımları hakkındaki yetersiz bilgi ile ilgili olarak, dört farklı konu modelleme algoritmasını değerlendirmeyi ve karşılaştırmayı amaçlamaktadır: LDA, SBERT, BERTopic ve Top2Vec. En iyi bilinen ve kullanılan LDA modelinin yanı sıra yeni geliştirilen gömülü yaklaşımları kullanarak ve bu farklı modelleri tanıtarak, pazarlama araştırmacılarına yeni ve güncel bilgilerin sağlanması amaçlanmaktadır. İkinci olarak, bu çalışma müşteri yorumlarının analizinde konu modelleme algoritmalarını keşfetmeye yönelik ilk girişimlerden biridir. Müşteri yorumları yapılandırılmamış metinlerdir ve yazım hataları veya kısaltmalar içerebilir, bu da uygulamada belirli zorluklara neden olur. Sosyal medya verilerinin aksine, son derece teknik bilgiler içeren oldukça uzun ve ayrıntılı metinler bulmak mümkündür. Bu nedenle, konu modelleme algoritmalarının müşteri yorumları bağlamında karşılaştırılması literatüre değerli bir katkı sağlayacaktır. DiMaggio'ya (2015) göre, bu tekniklerin çoğu, birçok sosyal bilim araştırmacısının programlama bilgisine aşina olmamaları nedeniyle oldukça zor bulduğu metodolojik beceriler gerektirmektedir. Bu nedenle, algoritmaların teknik açıdan karşılaştırılması, araştırmacıların analiz sırasında

karşılaşabileceği sorunlara ışık tutacaktır. Daha önceki araştırmalar, bu yöntemlerin kullanımını karşılaştırmış olsa da bu çalışmaların çoğu hesaplamalı dilbilim kapsamındadır. Sonuç olarak, bu yöntemlerin sosyal bilimlerdeki kullanımına ilişkin bilgileri ilerletmekte başarısız olmuşlardır. Bu çalışma, konu modelleme algoritmalarını sosyal bilimcilerin bilgi tabanı ve ihtiyaçlarına uygun bir düzeyde karşılaştırarak çevrimiçi müşteri yorumlarının analizinde bu yöntemlerin güçlü ve zayıf yönlerini ortaya koyacaktır. Son olarak, algoritmaların çıktılarını ürüne ve şirkete fayda sağlayacak şekilde yorumlayabilmek önemlidir. Müşterilerin geri bildirimlerinde ifade ettikleri bilgiler, şirketlere ürün geliştirme, ürün kullanım durumları ve yeni özellik geliştirmeleri konusunda değerli bilgiler sunacaktır. Bu nedenle, algoritmaların semantik çıktılarını pazarlama açısından anlamlandırabilmek, içgörü sağlamak adına kritik bir öneme sahiptir.

Bu çalışma şu şekilde yapılandırılmıştır: Literatür Taraması bölümünde, müşteri incelemelerini hem konu modelleme hem de diğer teknikleri kullanarak analiz eden önceki çalışmalardan bazılarını sunulmaktadır. Veri ve Metodoloji bölümü, veri toplama sürecini ve bu çalışmada incelenen dört konu modelleme türünün detaylı bilgilerini sunmaktadır. Bulgular bölümünde, tüm çıktılar sunulmakta olup bir sonraki bölümde Metodolojik Uygulanabilirlik ve Pratik Sonuçlar tartışılmaktadır. Sonuçlar bölümünde çalışmanın sonuçları verilmekte ve son olarak, pazarlama araştırmacıları için Sınırlamalar ve Gelecek Çalışmalar sunulmaktadır.

2.2. Literatür Taraması

Müşteri yorumlarının analizi, ürün kullanımı, müşteri deneyimi veya perakende süreci hakkında ayrıntılı bilgiler içerme olasılığı daha yüksek olduğundan, firma tarafından tasarlanan anketlerden veya çevrimiçi derecelendirmelerden daha fazla katma değerli bilgiler sunabilir. Akademisyenlerin ve uygulayıcıların, tüketici tercihlerini ve talebini doğru bir şekilde değerlendirmek için çevrimiçi müşteri yorumlarını önemli bir bilgi kaynağı olarak kullanabileceğini gösteren önemli sayıda araştırma bulunmaktadır (J. Guo vd., 2020). Bu nedenle, birçok çalışma müşteri memnuniyetini anlamak için derecelendirme analizinden ziyade içerik analizine odaklanmıştır. Levy vd. (2013) 1.946 otel değerlendirmesindeki şikayetlerin içerik analizini gerçekleştirmiştir. M. Yang vd. (2019) Facebook İşletme sayfalarından 12.000 gönderiyi analiz etmiş, müşteri katılımı üzerindeki etkiyi analiz etmek için içerik analizi ve ekonometrik

modellemeyi birleştirmiştir. Li vd. (2013) müşteri memnuniyetinin belirleyicilerini tespit etmek için içerik analizi kullanarak Pekin'deki 774 yıldızlı otelin 42.886 yorumunu incelemiştir.

Son yıllarda, doğal dil işleme ve makine öğrenimi araştırmaları geliştikçe, bir belge koleksiyonundaki kelimelerin gizli konularını bulmak için kullanılan konu modeli algoritmaları pazarlama çalışmalarında da kullanılmaya başlanmıştır (Barde & Bainwad, 2017). Tablo 1, müşteri yorumlarını analiz etmek için konu modelleme algoritmalarını kullanan bir grup çalışmayı özetlemektedir.

Tablo 1: Konu Modelleme Üzerine Yapılan Çalışmaların Bazıları

Yazar	Amaç	Konu	Platform	Konu Modeli
Büschken ve Allenby, 2016	Metin analizi için yeni bir model önermek	Restoran ve Otel Yorumları	we8there.com'dan 696 yorum, Expedia'dan 4,467 yorum	LDA
Sánchez-Franco ve Moreno, 2021	Kısa süreli konaklamalarda misafir önceliklerini ve müşteri deneyimini anlamak	Misafir Yorumları	Airbnb'den 73,557 yorum	BERTopic
Heng vd., 2018	Tüketicilerin çevrimiçi gıda satın alma davranışlarını etkileyen faktörleri araştırmak	Gıda Ürünleri Yorumları	1,048,576 Reviews on Amazon	LDA
Guo vd., 2017	Otel müşterilerinin hizmet algılarının kritik boyutlarını belirlemek	Otel Yorumları	TripAdvisor'dan 266,544 Otel Yorumu	LDA
Kılıç ve Ozansoy Çadırcı, 2022	Havalimanı yönetiminde hizmet iyileştirme fırsatlarını tespit etmek	Havalimanı yorumları	Skytrax'dan 1,224 yorum	LDA
Luo vd., 2020	Tema parklarda ziyaretçi davranış ve deneyimlerini belirlemek	Tema park yorumları	TripAdvisor'dan 43,869 yorum	LDA
Taecharungroj ve Mathayomchan, 2019	Turizm araştırmalarında müşteri yorumlarını analiz edecek bir metodoloji geliştirmek	Puket Yorumları	TripAdvisor'dan 65,079 yorum	LDA
Wu ve Cheng, 2020	Tüketici duygularını ve bunların inceleme konuları ile ilişkisini anlamak	Tüketici Yorumları	PTT Bülten Tahtası Sisteminde 14, 303 gönderi	LDA
Xiang vd., 2017	Konaklama ve turizmle ilgili farklı platformlardaki değerlendirme kalitesini karşılaştırmak ve incelemek	Otel Yorumları	TripAdvisor'da 991, Expedia'da 752 ve Yelp'te 53 Yorum	LDA

Büschken & Allenby (2016), araştırmalarında yeni bir cümle tabanlı konu modeli tanıtmıştır. Müşteri memnuniyeti derecelendirmelerini konu olasılıklarıyla ilişkilendirerek yeni bir müşteri memnuniyeti sürücü analizi önermişlerdir. Geliştirdikleri model, kelime tabanlı konu modellerine göre daha kapsamlı bir konu yapısı oluşturmuştur. Airbnb'deki 73.557 yorumla çalışan bir başka çalışmada, Sánchez-Franco & Rey-Moreno (2021) kentsel ve kıyı destinasyonlarındaki tüketici tercihleri tanımlanmıştır. Elde edilen sonuçlar, tüketicilerin gelecekteki kararları ve ev sahipleriyle olan ilişkileri ile konaklama özellikleri arasında güçlü ilişkiler olduğunu göstermiştir. Turizm ve seyahat bağlamında müşteri yorumlarını araştıran bir başka çalışma, analiz birimi olarak TripAdvisor yorumlarını kullanmış ve müşteri hizmetlerinin 19 kritik boyutunu belirlemiştir (Y. Guo vd., 2017). Luo vd. (2020) çalışmalarında, tema parklarını ziyaret ederken ziyaretçi deneyimini vurgulayan 41 farklı konu belirlemiştir. Müşteri değerlendirmeleri havayolu sektöründe de incelenmiştir (Kiliç & Çadirci, 2022). Yazarlar, LDA ile duygu analizini birleştirerek 10 hizmet boyutunda (konu başlığında) iyileştirme fırsatları belirlemiştir. Taecharungroj & Mathayomchan (2019), LDA konu modellemesi uyguladıkları çalışmalarında, Phuket'teki 65.079 yorumu analiz etmiş ve farklı cazibe boyutlarını belirlemiştir. Konu modelleme ve duygu analizini birleştiren bir başka çalışma, birden fazla yorum platformunu karşılaştırmış ve TripAdvisor'ı otel ziyaretçileri için birincil bilgi kaynağı olarak tanımlamıştır (Xiang vd., 2017).

N. Zhang vd. (2021), çalışmalarında LDA ve duygu analizi metodolojilerini kullanarak Airbnb platformundaki 43.752 yorumu analiz etmiştir. Ardından, işlevsel değer, hedonik değer, sosyal ilişki değeri ve epistemik değerin yeniden satın alma niyeti üzerindeki etkisini değerlendiren bir araştırma modeli sunmuşlardır. Bai vd. (2023), Shangai Disney Resort ziyaretçileri tarafından gönderilen 112.000 yorumu, yapısal konu modellemesi (STM) ile analiz etmiş ve konuların zaman içindeki değişimi üzerine çalışmışlardır. Bir başka çalışmada, bir makine öğrenimi yöntemi (Naïve Bayesian yöntemi) kullanılmış ve otellerin özelliklerini belirlemek ve nihayetinde tekrar ziyaretten bahseden otel müşterilerinin segmentasyonunu yapmak için yaklaşık 100.000 müşteri yorumu analiz edilmiştir (Marandi vd., 2023). Doğal dil işleme, makine öğrenimi ve yapay sinir ağlarında derin öğrenme tekniklerini kullanan Bigne vd. (2023) Venedik'teki turistik yerler hakkında TripAdvisor'da yayınlanan 20.954

çevrimiçi yorumun olumlu ve olumsuz duygularını ve yıldız derecelendirmeleri üzerindeki etkisini belirlemeye odaklanmıştır.

Konu modelleme çalışmalarının çoğu turizm ve seyahat sektörüne odaklanmış olsa da birkaç çalışma farklı sektörlerdeki müşteri yorumlarını konu modelleme ile analiz etmiştir. Wu & Chang (2020), araştırmalarında Tayvan'daki küresel ve yerel çevrimiçi perakendecilerin yorumlarını analiz etmiştir. Konu modellemeleri, yedi konu çıkarmıştır. Duygu analizinden yararlanarak hem uluslararası hem de yerel perakendeciler için farklı tüketici duygularını tanımlamışlardır. Heng vd. (2018), Amazon'daki market ürünü incelemelerini kullanarak dört konu çıkarmıştır. Çalışmaları, nesnel bilgilerin (fiziksel ürün özellikleri, tatlar vb.) tüketicilerin görüşlerinden daha olumlu olduğunu göstermiştir. Ahmad & Laroche (2023), çalışmalarında, iki popüler metin madenciliği tekniği olan Gizli Anlam Analizi (GAA) ve Olasılıksal Gizli Anlam Analizi (oGAA) karşılaştırmış ve yöntemlerin iki farklı pazarlama bağlamında uygulanabilirliğini değerlendirmişlerdir.

Son zamanlarda iki aşamalı metodolojiye dayanan yeni araştırmalar yapılmıştır. Nilashi vd. (2023), Amazon.com'daki bebek ürünleriyle ilgili müşteri memnuniyetini analiz etmek için metin madenciliği ve anket tabanlı yaklaşım kullanmıştır. Metin madenciliği yaklaşımı olarak, ilk aşamada LDA kullanmışlar, daha sonra konu modellemesinden toplanan faktörlere dayanarak araştırma modeli oluşturmuşlardır. Anket üzerinden toplanan verileri incelemek için Kısmi En Küçük Kareler Yapısal Eşitlik Modellemesi (PLS-SEM) kullanmışlardır. Bulgular, konfor, malzeme kalitesi, kullanılabilirlik, iade kolaylığı, tasarım, fiyat, paketleme ve boyutlandırma gibi bir dizi faktörün, alıcıların bebek eşyası satın alma konusunda nasıl hissettiklerini etkilediğini göstermiştir. Bir başka çalışmada, tüketici tercihlerini tahmin etmede geleneksel istatistiksel yöntemlere kıyasla makine öğrenimi algoritmaları kullanılmıştır. Bu karşılaştırmayı yapmak için, yöntemler bira kategorisindeki stok tutma birimi (SKU) düzeyindeki panel verilerine uygulanmıştır. Sonuçlar, makine öğrenmesi algoritmalarının ürün seçimini tahmin etmede daha iyi performansa sahip olduğunu göstermiştir (Martínez-Garmendia, 2023). Başka bir makine öğrenmesi çalışmasında Tian vd. (2021), restoran alanına odaklanarak müşterilerin çevrimiçi incelemelerinde ifade ettikleri duyguları incelemek için Yelp veri kümesini kullanmıştır. Elde ettikleri sonuçlar, hizmet kalitesinin müşterilerden olumlu geri bildirim alma üzerindeki etkisini vurgulamıştır.

Son zamanlarda, hizmet robotları üzerine yapılan çalışmalarda da konu modelleme algoritmalarının uygulanması önemli bir ilgi görmektedir. Örneğin, Hendry vd. (2021), bir e-ticaret şirketinin müşterileri ile bir sohbet robotu arasındaki konuşmaları BERTopic, Top2Vec ve LDA kullanarak analiz etmiştir. Benzer şekilde, Filieri vd. (2022), müşterilerin hizmet robotlarına yönelik duygularını öğrenmek için CTRIP ve TripAdvisor'daki müşteri yorumlarını BERTopic yöntemiyle analiz etmiştir.

Konu modellemesinde analiz birimi olarak müşteri yorumlarını kullanan çalışmaların sayısı arttıkça, bu metodolojiler arasındaki farkların anlaşılması ve her birinin müşteri yorumlarını analiz etmedeki fırsatlarının anlaşılması ihtiyacı ortaya çıkmıştır. Konu modellemesini kullanan bir araştırmacı için, her bir algoritmanın veri yapısından kolayca etkilenebilen kapasitesini ve olası güçlü yönlerini anlamak çok önemli hale gelmektedir. Bu çalışma, konu modelleme ve ilgili teknikleri hesaplama temelinde açıklamamakta; bunun yerine, müşteri yorumları analizinde kullanılmakta olan farklı algoritmaların metodolojik sürecini ve anlamsal sonuçlarını incelemeyi amaçlamaktadır.

2.3. Veri ve Metodoloji

Çalışmanın verileri, Haziran 2020 ve Temmuz 2021 tarihleri arasında Best Buy platformunda yer alan Amazon Echo Show 8 ürününe ilişkin müşteri yorumlarından elde edilmiştir. Best Buy platformu, ABD'deki en büyük elektronik perakendecilerinden biridir. Ayrıca platform, müşteri ve uzmanlar tarafından yazılan incelemeler, yıldızlar, puanlar ve ürün kalitesi, kullanım kolaylığı ve değerinin nicel analizle birlikte, ürüne dair artılar ve eksiler listesi de dahil olmak üzere çok boyutlu yorum bilgileri sağlamaktadır. Veri toplama aşaması Temmuz 2021'de gerçekleştirilmiştir. Tüm veri toplama ve analiz işlemleri Python programlama dilinde (Guido & Drake, 2009) yapılmıştır. Müşteri yorumları internette halka açıktır ve erişilebilir. Best Buy'dan veri çekmek için Pandas (McKinney, 2011) ve BeautifulSoup (Richardson, 2019) Python kütüphaneleri kullanılmıştır. Web sitesi kazıma yöntemiyle ihtiyaç duyulan veriler alınmış ve excel dosyası olarak kaydedilmiştir.

“Amazon Echo Show 8” ürününe dair 5,386 yorum çekilmiş ve bir excel dosyasına kaydedilmiştir. Belgeler arasında tutarlılığı korumak için yalnızca İngilizce yazılmış yorumlar kullanılmıştır. Bu nedenle, İspanyolca yazılmış 2 adet yorum veri kümesinden çıkartılmıştır. 5384 yorumdan 40'ının mükerrer olduğu tespit edilmiş, bu

nedenle bunların yarısı “Tekrarları Çıkar” işlevi kullanılarak excel dosyasından elenmiştir. Bu temizleme aşamalarının ardından, nihai derlem 5364 müşteri incelemesi içermektedir. Veri kümesi Şekil 1’deki gibi görünmektedir.

Şekil 1: Veri Kümesinin Öngörünümü

	A	B	C	D	E	F	G	H	I	J	K
1	Author	Quality	Value	EaseofU	Rating	Title	Comment	Date	LengthOfOwnership	Helpful	Unhelpf
2	natsonic1	4	4	4	5	Very useful	I love Star trek and this item that makes my dr	1 year ago	1 month	36	8
3	Swanky	5	5	5	5	Whatislife	I have Alexa devices all over my home. This mi	2 months a	8 months	3	0
4	HeddaCabb	5	5	4	5	Echo is the	Me and my Echo are having a nice experience t	7 months a	3 weeks	10	0
5	Liznparadis	5	5	5	5	Love it.	I can ask Alexa for recipes and read them as I cc	1 year ago	1 month	33	1
6	Umbie	5	5	5	5	Just the rig	In the space of the clock it replaced, the echo s	1 year ago	1 month	12	0
7	Lv2beasahr	5	5	5	5	It's Love!	I admit I had my eyes on this baby for a while.	9 months a	3 weeks	6	1
8	Fireplace	5	5	5	5	Love my pu	Extremely happy with this model. I originally	3 weeks ago	1 month	0	0
9	Dandy	5	5	5	5	New Amazc	Love, love, love. It's small enough to fit on my	1 year ago	3 weeks	17	0
10	StepB	5	5	5	5	Very Nice	We got this to replace an old alarm clock and i	2 months a	1 month	0	0
11	CustomerSi	5	5	5	5	Good prod	The device has worked well. I was very dissatis	6 months a	3 weeks	1	4
12	Zepher	5	5	5	5	Excellent li	Bought a pair of these for voice control of ligh	1 week ago	10 months	0	0
13	143Danie	5	5	5	5	Excellent	Excellent.....	9 months a	2 weeks	0	0
14	Hoodtralfe	5	5	4	5	echo show	I love this new Alexa echo device . You can hav	5 months a	1 month	1	0
15	DirtyD	5	5	5	5	Why did it	This thing is awesome! Not sure why it's take. I	5 months a	1 week	0	0
16	ZMBPHD	2	3	4	3	It may be al	I received this product, free, for buying the Rir	5 months a	1 month	0	0
17	EmerilOver	4	4	4	4	Cool device	Only had it a couple of weeks so we're still tryi	4 months a	1 month	0	0
18	Anonymou	4	3	5	5	Echo sho	We love ower echo show it does more than we	1 month ag	3 weeks	0	0
19	SteffieG	5	5	5	5	Best Purcha	Great we bought these for our Kids to stay in t	5 months a	2 weeks	0	0
20	Mattjp	5	5	5	5	If you use A	Easy set up. Nice size screen .Works great with	9 months a	1 week	2	0
21	Myphone	5	5	5	5	My echo sh	I love it always wanted one but never had ever	5 months a	1 month	0	0
22	Mre1	5	5	5	5	Great item	Controls everything. Add your pictures and yo	3 months a	4 months	0	0
23	Gamechang	5	5	5	5	Great value	I've purchased 4 of these so far as I have smart	6 months a	1 month	0	0
24	Tony	5	5	5	5	Worth it	Great! Using as my smart hub runs the whole h	2 months a	2 months	0	0
25	Lynvaler	5	5	5	5	Great mini	I have the original Echoe Show which we are e	1 year ago	3 months	0	0
26	Jelan	5	5	5	5	Echo is da h	Love it. Really that's all that needs to be said b	1 year ago	3 months	1	0
27	Echo	4	4	4	4	Like my nev	I really do like this item I was glad that I broug	5 months a	3 weeks	0	1
28	Sambou	5	5	5	5	Great Devic	Initially I have some problems pairing it to all	5 months a	3 weeks	0	0
29	Badwasher	5	5	5	5	Great Alexa	Great Alexa, I definitely recommend to any on	4 months a	5 months	0	0
30	AlexaEcho5	4	5	4	5	No regrets	I bought this for a Christmas present...and the	4 months a	1 month	0	0
31	Lulu	5	5	5	5	Echo show	Bought this not too long ago but immediately	1 year ago	less than 1 week	0	0
32	AllSpark23	5	5	5	5	100% awes	Absolutely love this thing. Take an echo dot ac	6 months a	11 months	0	0
33	Cheril	5	5	5	5	Gift from m	I love the Echo Show 5, so much I bought a sec	1 year ago	less than 1 week	1	0
34	SuzieQ	5	5	5	5	Baby Show	We have the Show 1 and 2 and loved them so r	5 months a	3 weeks	0	0
35	Iramis	5	5	5	5	I love it	It's great she's smart and she even tells jokes sh	7 months a	11 months	0	0
36	Jesse	5	5	5	5	Great value	Excelent for smart homes I can sync my camer	5 months a	1 month	0	0
37	aquirosguic	5	5	5	5	muy practi	me encanta poder ver mis camaras, ver mis vic	9 months a	2 weeks	0	0
38	40momo4	5	5	4	5	Happy!	A good way to connect with family during this	5 months a	2 months	0	0
39	Tgabehart	5	4	5	5	Whole hom	Great device. Connects my whole home with e	7 months a	3 weeks	0	0
40	Carousel	4	5	4	4	echo 5	It arrived on time and in good condition. It wa	6 months a	3 weeks	0	0

Veri Kümesinde yer alan bilgiler şu şekildedir:

- Yorumu yazan kişinin adı (Author)
- Kalite/değer/kullanım kolaylığı puanları
    - Kalite (Quality)
    - Değer (Value)
    - Kullanım kolaylığı (Ease of Use)
- Derecelendirme (Rating)
- Yorumun başlığı (Title)
- Yorumun içeriği (Comment)
- Yorumun yapıldığı tarih (Date)

- Yorum yapıldığında, ürüne ne kadar süre ile sahip olunduğu bilgisi (Length of Ownership)
- Yorumun diğer kullanıcılar tarafından yardımcı bulunup bulunmadığı bilgileri (Helpful/Unhelpful)

Bu çalışma, 4 farklı konu modelleme algoritmasının birbirlerine göre avantaj ve dezavantajlarını karşılaştırmayı amaçlamaktadır. Daha önce belirtildiği gibi, bunlar LDA, Bert Sentence, BERTopic ve Top2Vec'tir. Tüm konu modelleme algoritmaları, Python'un 3.8.8 sürümü (*Python 3.8.8*, 2021) kullanılarak Google Colab üzerinden çalıştırılmıştır. Her algoritmanın niteliklerine ve analiz prosedürlerine bağlı olarak, ön işleme dahil edilen ve hariç tutulan durumlar test edilmiştir.

2.3.1. Konu Modelleme

Çevrimiçi bilgi biriktikçe, bu bilgi içindeki temel konuları veya temaları anlamak öncelikli bir sorun haline gelmiştir. Konu modelleme, bu soruna bir çözüm olarak geliştirilen bir grup denetimli veya denetimsiz makine öğrenimi algoritmasını içerir. Konu modelleme, genel olarak, araştırmacıların büyük ölçekli veri kümelerinin, özellikle de metinsel verilerin bağlamını düzenlemelerine ve tanımlamalarına yardımcı olur (Vayansky & Kumar, 2020). Ayrıca, bu algoritmalar bu belgelerin konular şeklinde bir özetini oluşturur (Churchill & Singh, 2022).

2000'li yılların başında piyasaya sürülmelerinden bu yana, birçok araştırmacı çoğunlukla LDA gibi olasılıksal modellerini benimsemiş ve kullanmıştır. LDA, en eski ve en sık uygulanan konu modelleme algoritmalarından biridir (Blair vd., 2020). Her kelimeyi tek bir vektör olarak temsil eden (Hong & Davison, 2010) ve her belgenin farklı konuların bir kombinasyonu olduğunu varsayan bir kelime torbası yaklaşımı kullanır. Kelime torbası yaklaşımı güçlü olmasına rağmen, kelimeler arasındaki olası anlamsal ilişkilerin göz ardı edilmesi en belirgin olanı olmak üzere belirli sorunlar yaratmaktadır (Grootendorst, 2022; Ren vd., 2016).

LDA gibi olasılıksal konu modelleme algoritmalarının popülerliğine rağmen, son birkaç yılda farklı araştırmacılar tarafından nöral konu modelleri çatısı altında yeni yaklaşımlar üretilmiştir. Her algoritmanın uygulama sürecinde kendine göre avantajları bulunmaktadır. Daha önceki algoritmaların belirsizlik ve zaman alan süreçleri, uygulamalar sırasında hem zamanı hem de karmaşıklığı azaltmak için yeni

yöntemlerin sunulmasında başka bir artış yaratmıştır (Vayansky & Kumar, 2020). Bu iki yaklaşım karşılaştırıldığında, olasılıksal konu modelleri yorumlanabilirlik açısından daha üstünken, nöral konu modelleri tahmin gücü açısından daha güçlüdür (Abdelrazek vd., 2022)

Son yıllarda, nöral konu modelleri, mevcut konu modelleme yöntemlerini geliştirmek için nöral ağların kullanılmasında giderek daha etkili olmaktadır (Grootendorst, 2022; Larochelle & Lauly, 2012; H. Zhao vd., 2021). Yapay sinir ağlarını olasılıksal üretken süreçlerle birleştiren yapay sinir konu modelleri, daha kolay hesaplama sağlar ve LDA gibi klasik tekniklerin optimizasyon sorununun üstesinden gelmektedir (Doan & Hoang, 2021) Ayrıca, gömme modellerine odaklanan konu modelleme yöntemlerindeki son gelişmeler, gömme tabanlı konu modelleme yöntemlerinin potansiyelini göstermektedir (Bianchi vd., 2021; Dieng vd., 2020; Grootendorst, 2022; Thompson & Mimno, 2020). Sentence-BERT (Reimers & Gurevych, 2019), BERTopic (Grootendorst, 2021) veya Top2Vec (Angelov & Clendenning, 2020) gibi esnek bir konu modeline izin veren kelime ve belge gömülerini kümeleyerek konu çıkarımı yapan, çeşitli yöntemler kullanılmaktadır (Grootendorst, 2022; Sia vd., 2020).

2.3.1.1. Model 1: Latent Dirichlet Allocation

LDA, metin belgesi koleksiyonları içindeki gizli tematik yapıları tanımlamak ve açıklamak için kullanılmaktadır (Blei vd., 2003). C kodlama diline dayanan LDA, EM (Expectation-Maximization) çıkarımını kullanır (Vayansky & Kumar, 2020). Bu yöntem, veriyi üç seviyede yapısallaştırır: Kelime, konu ve doküman (Blair vd., 2020). LDA, belgeleri kelime üzerindeki olasılık dağılımları olarak görülen gizli konuların rastgele karışımlarından oluşturulmuş olarak kabul eder (Vayansky & Kumar, 2020).

Blei vd. (2003) tarafından açıklandığı gibi, LDA'nın matematiksel gösterimi modelin parametrelerinin ve üretim sürecinin tanımlanmasını içerir. M, derlemde bulunan toplam belge sayısına karşılık gelir. N, bir belgenin içerdiği toplam kelime sayısını temsil eder. $w_{d,n}$ değişkeni d belgesindeki n'inci kelimeyi göstermek için kullanılır. Benzer şekilde, $z_{d,n}$ d, belgesindeki n'inci kelime için konu atamasını temsil eder ve kelimenin hangi konuya ait olduğunu gösterir. θ_d değişkeni d belgesi için konu dağılımını temsil eder ve bu belgede bulunan konuların karışımını yansıtır. Son olarak, ϕ_k değişkeni k konusu için kelime dağılımını ifade eder ve bu konu içindeki kelimelerin olasılık dağılımı hakkında bilgi sağlar. Bu değişkenler konu modelleme

sürecinde hayati rol oynar ve belge derleminden anlamlı konuların ortaya çıkarılmasına yardımcı olur.

P (W, Z, θ, φ; α, β) olarak gösterilen aşağıdaki denklem, belirli bir belgenin hayali bir LDA (Latent Dirichlet Allocation) makinesi tarafından üretilme olasılığını temsil eder. Bu varsayımsal makinenin ayarları, belgede bulunan gizli konuların ortaya çıkarılmasında önemli bir rol oynamaktadır (R. K. Gupta vd., 2022).

$$P(W, Z;\ \theta, \varphi; \alpha, \beta) = \prod_{d=1}^{M} P\ (\theta_{d;\ \alpha)} \prod_{k=1}^{K} P\ (\varphi_{k\ ;\ \beta)} \prod_{n=1}^{N} P\left(Z_{d,n} \middle| \theta_j\right) P\left(W_{d.n} \middle| \varphi_{j,t}\right)$$

α ve β parametreleri, sırasıyla belgelerdeki konuların dağılımını ve konulardaki kelimelerin dağılımını etkilemek için LDA'nın eğitim aşamasında kullanılan hiper parametrelerdir. *k,* çıkarılacak konuların sayısını temsil eden üçüncü model hiper parametresidir (araştırmacı tarafından belirlenmelidir).

Semantik Tutarlılık ve Semantik Çapraşıklık, oluşturulan konuların yorumlanabilirliğini ve tahmin performansını değerlendirmek için eğitimden sonra kullanılan değerlendirme metrikleridir. Sonuç olarak, α ve β modelleme sürecinde kullanılırken, tutarlılık skoru ve çapraşıklık skoru model çıktısının kalitesini değerlendirmek için kullanılır. Semantik Tutarlılık, konu başlığında yüksek puan alan kelimelerin anlamsal benzerliğini ölçer (R. K. Gupta vd., 2022).

Mimno vd. (2011) $D(v)$' yi v kelime türünün belge sıklığı (yani, v türünde en az bir belirteç içeren belge sayısı) ve $D(v, v')$'yi v ve v' kelime türlerinin ortak belge sıklığı (yani hem v hem de v' türlerinin en az bir oluşumunu içeren belge sayısı) olarak tanımlayarak konuların kalitesini değerlendirmek için yeni bir metrik tasarlamıştır. $V(t)$, t konusu içindeki en olası M kelimenin bir derlemesidir. Bu durumda Semantik Tutarlılık aşağıdaki gibi ifade edilmektedir.

$$C(t; V^{(t)}) = \sum_{m=2}^{M} \sum_{l=1}^{m-1} log \frac{D\left(v_m^{(t)}, v_l^{(t)}\right)+1}{D\left(v_l^{(t)}\right)}$$

Semantik Çapraşıklık belirli bir konu modeli için istatistiksel uyum iyiliğini değerlendirmek için bir ölçü olarak hizmet eder (Blei vd., 2003) M belgeden oluşan bir test kümesi için semantik çapraşıklık aşağıda ifade edildiği gibidir:

$$perplexity(D_{test}) = exp\left\{-\frac{\sum_{d=1}^{M} \log p(\boldsymbol{w}_d)}{\sum_{d=1}^{M} N_d}\right\}$$

LDA, Python'un Gensim paketi içinde mükemmel uygulamalar sunmaktadır (Rehurek, 2018) Bununla birlikte, asıl zorluk, etkili bir şekilde ayrılmış yüksek kaliteli, iyi tanımlanmış ve anlamlı konuların çıkarılmasında yatmaktadır. Güçlü bir konu yapısı elde etmek büyük ölçüde metin ön işleme kalitesine ve optimum konu sayısını belirleme becerisine bağlıdır. Derlemi konu modeline beslemeden önce gerçekleştirilen ön işleme adımlarının sonucu önemli ölçüde etkileyebileceğini kabul etmek önemlidir.

Mevcut çalışma için veriler, L. Li vd. (2022) tarafından önerilen belirli bir dizi adım izlenerek ön işleme tabi tutulmuştur. İlk adım olarak, tüm derlem küçük harfe dönüştürülmelidir. Ardından, sayılar, kısaltmalar ve tanımlanamayan karakterler belgelerden çıkarılmalıdır, çünkü metin boyunca yüksek kelime sıklığı konu modelleme sonucuna zarar verebilir. Bu nedenle, analizden önce ön işleme sırasında bir durak kelimesi kaldırma işlemi gerekli hale gelir. Çok az topikal içeriğe sahip kelimelerin (örneğin, the, if, vb.) çıkarılması yaygın bir yaklaşımdır (Abdelrazek vd., 2022)

İnceleme metinlerinde bigram ve trigramlar tespit edilebildiğinden, LDA modeli için tokenizasyon ve lemmatizasyon işlemleri gerçekleştirilmiştir. Lemmatizasyon, NLP'de her kelimeyi ilgili temel kök moduna dönüştüren bir metin normalleştirme prosedürüdür (Plisson vd., 2004). Son olarak, derlem, terimlerin önemini ölçmek için TF-IDF (terim sıklığı-ters belge sıklığı) ile ağırlıklandırılır (Aizawa, 2003; Bafna vd., 2016; Qaiser & Ali, 2018). TF-IDF iki metriğin çarpılmasıyla hesaplanır: terim sıklığı (belirli bir terimin bir belgede görünme sayısı) ve bir kelimenin birden fazla belgedeki ters belge sıklığı (R. K. Gupta vd., 2022).

Hesaplama aşağıdaki denklemde verildiği gibidir:

$$w_{i,e} = \left(1 + \log\left(tf_{t,e}\right)\right) x \left(log\, {}^{N}/_{n_i}\right)$$

$tf_{t,e}$ t teriminin e belgesindeki sıklığını, N derlem içindeki belge sayısını, n_i t teriminin göründüğü belge sayısını ifade etmektedir.

2.3.1.2. Model 2: Sentence-BERT (Cümle Dönüştürücüler)

BERT (Bidirectional Encoder Representations from Transformers), etiketlenmemiş metinden, önceden eğitilmiş derin öğrenme modelidir. BERT kavramsal olarak basit ve deneysel olarak güçlü bir yöntemdir (Devlin vd., 2019). BERT, Google Yapay Zekâ araştırıcıları tarafından geliştirilmiş ve yayınlaşmıştır. BERT, metindeki kelimeler arasındaki bağlamsal ilişkiyi öğrenen dikkat mekanizmasını kullanır. BERT modeli genellikle uzun metinsel belgenin tümcelerinin bağlamsal olarak kodlanmasını içerir (H. Gupta & Patel, 2021). LDA makaleler üzerinde iyi performans gösterse de (R. K. Gupta vd., 2022) eksik noktası belgenin her cümlesindeki konuların anlamsal yapısıdır ve bu da müşteri yorumları gibi karmaşık metinler için konuların bulunmasını zorlaştırır. BERT gibi önceden eğitilmiş modeller, kelimelerin ve cümlelerin daha doğru temsillerini içerdikleri varsayıldığından özellikle yararlıdır (Sia vd., 2020).

SBERT olarak da bilinen Sentence-BERT, Siyam ve üçlü ağları kullanarak doğal dil işleme (NLP) alanında anlamsal olarak anlamlı cümle gömüleri üreten BERT ağına yenilikçi bir yaklaşımdır. Reimers & Gurevych (2019) tarafından geliştirilen Sentence-BERT, cümleleri sabit boyutlu vektörlere kodlayan önceden eğitilmiş BERT modelinin gücünden yararlanmaktadır. BERT cümle kodlayıcı işlevini E_BERT (.) olarak gösterirsek; burada · giriş cümlesini temsil eder. Siamese Sentence-BERT için model, aynı ağırlıkları paylaşan iki özdeş BERT kodlayıcıdan oluşur. İki giriş cümlesi verildiğinde Siyam ağı, paylaşılan BERT kodlayıcıyı kullanarak her bir cümleyi kodlar:

$$Encoded\ Sentence\ 1 = E_{BERT}(Sentence\ 1)$$

$$Encoded\ Sentence\ 2 = E_{BERT}(Sentence\ 2)$$

Üçlü Cümle-BERT durumunda, model üç özdeş BERT kodlayıcıdan oluşur. Bir cümle üçlüsü verildiğinde, her cümle paylaşılan BERT kodlayıcı kullanılarak kodlanır.

SBERT, cümle yerleştirmeleri arasındaki anlamsal benzerliği karşılaştırmak için kosinüs benzerliğini temel bir ölçüt olarak kullanır (Reimers & Gurevych, 2019).

Kosinüs benzerliği, çok boyutlu bir uzayda iki vektör arasındaki açının kosinüsünü hesaplayan bir ölçüttür. SBERT bağlamında, her cümle yüksek boyutlu bir anlamsal uzayda yoğun bir vektör temsiline (gömme) dönüştürülür (H. Gupta & Patel, 2021). Cümleler sabit boyutlu vektörlere kodlandıktan sonra, cümle gömülmeleri arasındaki benzerliği ölçmek için bir benzerlik metriği uygulanır. Kullanılan yaygın bir benzerlik metriği, iki vektör arasındaki açının kosinüsünü hesaplayan $\cos_sim(.,.)$olarak gösterilen kosinüs benzerliğidir:

$$Similarity = \cos_\text{sim}(\text{Encoded Sentence 1}, \text{Encoded Sentence 2})$$

Benzer konulara sahip belgelerin bu kümelerdeki konuları bulabilmek için bir araya toplandığından emin olmak gerekir. Bunu yapmadan önce, birçok kümeleme algoritması yüksek boyutluluğu zayıf bir şekilde ele aldığından, ilk olarak gömmelerin boyutluluğunu düşürmek gerekmektedir. Boyutluluk azaltma algoritmalarından UMAP (McInnes vd., 2018), yüksek boyutlu yerel yapının önemli bir bölümünü düşük boyutlulukta tuttuğu için tartışmasız en iyi performans gösterenidir.

UMAP, yerel yapıları korurken belge katıştırmalarının boyutluluğunu etkili bir şekilde azaltarak McInnes & Healy (2017) tarafından önerilen Hiyerarşik Yoğunluk Tabanlı Kümeleme (HDBSCAN) ile uyumlu hale getirir. HDBSCAN, UMAP'ın düşük boyutlu uzaylarda bile yerel yapıları koruma yeteneğinden yararlanan yoğunluk tabanlı bir kümeleme algoritmasıdır. UMAP ve HDBSCAN kombinasyonu, belgelerin anlamsal benzerliklerine göre etkili bir şekilde kümelenmesine ve altta yatan konuların ortaya çıkarılmasına yardımcı olur.

Bununla birlikte, veri kümesine bağlı olarak yüzlerce konu oluşturulabileceğini ve bunun da bunaltıcı olabileceğini belirtmek gerekir. Bunu ele almak için araştırmacılar HDBSCAN'ın parametrelerini, özellikle de "min_cluster_size" parametresini ayarlayarak daha az sayıda iş parçacığı oluşturabilir ve daha yönetilebilir sayıda konu elde edebilirler. Bu parametreye ince ayar yaparak, çıktı, analiz için daha kısa ve yorumlanabilir bir konu kümesi üretecek şekilde kontrol edilebilir.

2.3.1.3. Model 3: BERTopic

BERTopic, belirli bir belge kümesinden konu kümeleri oluşturmak için BERT katıştırmaları ve c-TF-IDF (sınıf tabanlı-Terim Frekansı-Ters Belge Frekansı) kullanan bir konu modelleme tekniğidir (Grootendorst, 2022). Geleneksel TF-IDF

(Terim Frekansı-Ters Belge Frekansı), bir belgedeki kelimelerin bağlamı dikkate alınarak c-TF-IDF'ye genişletilmiştir. Bir kelimenin önemini yalnızca belgedeki sıklığına göre değil, aynı zamanda diğer belgelerdeki sıklığından nasıl farklı olduğuna göre de hesaplar. BERTopic'in arkasındaki temel fikir, ortak konuları paylaşan anlamsal olarak benzer belgeleri tanımlamaktır. Bunu başarmak için BERTopic, belgeleri temsillerinin kolayca karşılaştırılabileceği bir vektör uzayına yerleştirir (Grootendorst, 2022). Algoritma, çeşitli cümle gömülü görevlerde en son teknolojiden daha iyi performans gösteren SBERT çerçevesini kullanır (Grootendorst, 2022; Reimers & Gurevych, 2019; N. Thakur vd., 2021).

BERTopic'in ilk aşamasında, önceden eğitilmiş dönüştürücü tabanlı dil modelleri kullanılır (Jeon vd., 2023). Derlemdeki her bir belge, önceden eğitilmiş BERT dil modeli kullanılarak yoğun vektör temsillerine dönüştürülür. D, derlemdeki N belge kümesini temsil etsin. BERT gömme işlevi, bir d_i belgesini girdi olarak alan ve yoğun vektör temsilini döndüren $E_{BERT}(.)$ olarak gösterilebilir.

$$Embedding_i = E_{BERT}(d_i)$$

BERT yerleştirmeleri yüksek boyutlu olduğundan, doğrudan kümelenmeleri hesaplama açısından zorlayıcı olabilir. Belge yerleştirmelerinin boyutluluğunu azaltmak için, farklı boyut uzaylarına sahip dil modelleri arasında kullanılabilirliği nedeniyle UMAP kullanılır (McInnes vd., 2018). Boyut azaltma işleminden sonra, azaltılmış gömüler HDBSCAN ile kümelenir (McInnes vd., 2017). Son adım, c-TF-IDF ile konu temsili oluşturmayı içerir. Geleneksel TF-IDF denklemi bir kelimenin farklı belgelerdeki önemini tanımlarken, c-TF-IDF bir kelimenin belirli bir sınıf (konu) içindeki önemini değerlendirir. Başka bir deyişle, c-TF-IDF, bir kelimenin belirli bir sınıfa uygunluğunu ölçmek için tasarlanmıştır ve konu modelleme bağlamında daha odaklı değerlendirmeler yapılmasını sağlar (Grootendorst, 2020).

Aşağıdaki denklemde görüldüğü gibi her kelime için c-TF-IDF puanı hesaplanır (Angelov, 2020). Bu denklemde W_{ic}, i kelimesinin c sınıfındaki ağırlığını temsil eder. i kelimesinin c sınıfındaki sıklığı tf_{ic} olarak gösterilir. A, bir sözcüğün tüm sınıflarda ortalama görülme sayısını, f ise i sözcüğünün tüm sınıflardaki sıklığını temsil eder. c-TF-IDF skoru, kelimenin hem belirli bir sınıfla yerel ilgisini hem de tüm sınıflar genelindeki küresel önemini birleştiren bir ölçüdür (Alhaj vd., 2022).

$$W_{ic} = t\, f_{ic} \times \log\left(1 + \frac{A}{tf_i}\right)$$

2.3.1.4. Model 4: Top2Vec

Top2Vec, konu modelleme için nispeten yeni bir tekniktir (Angelov, 2020). Top2Vec, birlikte gömülü kelime ve belge vektörleri oluşturmak için doc2vec'te Dağıtılmış Kelime Torbası (DBOW) kullanır (Ma vd., 2021) ve metinde sağlanan konuları otomatik olarak tanımlayarak aynı anda gömülü konular, belge ve kelime vektörleri oluşturur (Angelov, 2020; Le & Mikolov, 2014). Algoritma otomatik olarak konu sayısını bulur ve herhangi bir ön işleme gerek yoktur (Ma vd., 2021). Belgenin konusu, belgenin vektörlerine en yakın kelimeler tarafından en iyi şekilde tanımlanır, bu da konu sayısının birlikte gruplandırılmış belgeler tarafından temsil edildiği anlamına gelir (Hendry vd., 2021).

Top2Vec, yüksek boyutlu anlamsal gömme uzayında hesaplama zorlukları oluşturabilecek belge vektörlerinin seyrekliğini ele alırken, boyut azaltma için UMAP'tan yararlanır ve böylece belge vektörlerini yoğunlaştırır (McInnes vd., 2017). Bu azaltma, HDBSCAN kullanarak yoğun kümelerin tanımlanmasını kolaylaştırır, yoğun belge kümelerini ve sonraki konu vektörlerini etkili bir şekilde belirler (Angelov, 2020; Ma vd., 2021).

Her konu, o konudaki belgelerin ortak gömülü vektörlerinin ortalaması olan merkez noktası ile temsil edilir. DBOW modeli d_i belge gömülerini üretir ve bir d_i belgesi için ortak gömülü vektör gösterimi v_i olarak gösterilir. t_k konusunun merkezi C_{t_k} olarak gösterilebilir; burada D_{t_k}, t_k konusuna ait belgelerin kümesidir.

$$C_{t_k} = \frac{1}{|D_{t_k}|} \sum_{i \in D_{t_k}} v_i$$

Top2Vec, ortak katıştırmalardan yararlanarak ve UMAP ve HDBSCAN'den yararlanarak, derlem içindeki anlamlı konuları verimli bir şekilde ortaya çıkarır ve daha az hesaplama yükü ile konu modellemesine gelişmiş ve dinamik bir yaklaşım sunar (Angelov, 2020).

2.4. Sonuçlar ve Bulgular

Bu bölümde, dört farklı algoritmadan elde edilen sonuçlar sunulmaktadır. Doğru sonuçlar elde etmek için veri ön işlemenin önemi vurgulanmıştır. Daha sonra, her bir algoritmaya uygulanan ön işleme adımlarını ve diğer prosedürleri açıklayarak sürecin kapsamlı bir şekilde anlaşılması sağlanmıştır. Son adım olarak, her bir algoritma tarafından çıkarılan anahtar terimlere anlamlı konu isimleri atanmıştır. Bunu yaparak, her bir teknik tarafından belirlenen konulara ilişkin net ve yorumlanabilir bilgiler sunmayı ve sonuçların genel olarak anlaşılmasının geliştirilmesi amaçlanmıştır.

2.4.1. LDA

Bu çalışmada, farklı durak kelime listelerinin LDA algoritmasının performansı üzerindeki etkisi araştırılmıştır. Hem NLTK (Bird vd., 2001) hem de Spacy (Honnibal & Montani, 2017) kütüphaneleri durak kelime listeleri için seçenek olarak değerlendirilmiştir. Sonuçta, NLTK'dan daha geniş kelime kapsamı nedeniyle Spacy kütüphanesi seçilmiştir. Deneyler sonucunda, durak kelimelerin ağır bir şekilde çıkarılmasının en iyi sonuçları verdiğini keşfedilmiştir. Bu yaklaşımın LDA modelinin kalitesini artırmada ve konu modelleme sonuçlarını iyileştirmede en etkili olduğu kanıtlanmıştır. Durak kelimeler için Spacy kütüphanesini kullanarak ve sert bir çıkarma stratejisi uygulayarak, LDA algoritmasını optimize etmeyi ve daha doğru ve anlamlı konu temsiller elde edilmesi amaçlanmıştır.

En uygun konu sayısını belirlemek için üç temel faktörü dikkate alınmıştır: (1) Konu Örtüşmesi, (2) Semantik Tutarlılık Puanı, (3) Semantik Çapraşıklık. Semantik tutarlılık puanı, konunun kendi içindeki kelimeler arasındaki ilişki derecesine dayalı olarak bir konuyu anlama yeteneğidir (Blair vd., 2020). Model seçimini doğrulamak için en yüksek tutarlılık puanına sahip model takip edilmiştir. Ardından, modellerin verilere uyumunu değerlendirmek için LDA için standart bir değerlendirme stratejisi olan Çapraşıklık metriği uygulanmıştır (Hoffman vd., 2013). Çapraşıklık, öğrenilen LDA modellerinin çeşitli konular sunulduğunda altta yatan verileri ne kadar iyi yakaladığını değerlendirir. Daha doğru bir model daha düşük bir çapraşıklık değeri üretilmektedir (Luo vd., 2020).

Optimal sayıdaki konuyu bulmak için literatürde pek çok teknik kullanılmaktadır. Bu çalışmada hem ortalama konu örtüşmesini hem de tutarlılık puanını dikkate alan

Jaccard Benzerlik yöntemini kullanılmıştır. Jaccard Benzerlik yöntemi, iki küme arasındaki benzerlikleri ölçmek için kullanılan bir istatistiktir (Bag vd., 2019). Örneğin, iki kelimelik A ve B listeleri verildiğinde, Jaccard benzerlik yöntemi bu listeler arasındaki örtüşen kelimelerin oranını hesaplar ve bunu her iki listedeki toplam benzersiz kelime sayısına böler. Bu yaklaşım bize, içerdikleri kelimelere dayanarak konuların ne kadar yakından ilişkili olduğuna dair değerli bir ölçü sağlar (Tahmasebi, 2018).

$$J = |A \cap B| / |A \cup B| = |A \cap B| |A| + |B| - |A \cup B|$$

Jaccard Benzerlik yönteminden yararlanılarak seçilen konu sayısının, yalnızca anlamlı içgörüler sağlamakla kalmayıp aynı zamanda belirlenen konular arasında aşırı fazlalığı da önlediğinden emin olmak için tutarlılık puanı ile konu örtüşmesi arasında bir denge bulunması amaçlanmıştır. Semantik tutarlılık puanını hesaplamak için, Python'daki Gensim kütüphanesi kullanılarak, konu sayısı 1 ila 15 arasında değişen LDA modeli kurulmuştur. Her model için, her konunun en iyi 15 anahtar kelimesi, modelin tutarlılık puanını hesaplamak için girdi olarak seçilmiştir.

Müşteri yorumları, (L. Li vd., 2022) tarafından izlenen adımlar kullanılarak bir derlem haline getirilmiştir. Ön işleme ise, metnin üzerinde yapılan temizleme işlemini ifade etmektedir. Bunun için öncelikli olarak verideki kullanılacak tüm metin küçük harfe dönüştürülmüştür. Gereksiz noktalama işaretleri temizlenmiş ve tüm metin "token" adı verilen kelime parçacıkları şeklinde tekrar yaratılmıştır. Bu işlemleri ayrı ayrı yapmak yerine Gensim kütüphanesinde yer alan "simple_preprocess" metodu kullanılmıştır. Veri temizlemenin ikinci adımı olan durak kelimelerinin çıkarılması işlemi, kodun defalarca çalışması ve her birinden elde edilen çıktıların yorumlanmasına bağlı olarak ince ayar yapılmasını gerektirir. Durak sözcükler, yaygın İngilizce sözcükleri ve analiz sırasında sorun yaratabilecek sözcükleri (örneğin, Amazon, Echo, vb.) içermektedir. En iyi sonucu alabilmek için bu aşamada üç farklı yaklaşım denenmiştir.

1. Sadece "İngilizce Durak Kelimeleri"nin çıkarılması,
2. "İngilizce Durak Kelimeleri"nin çıkarılması ve yanlış yazılan kelimelerin çıkarılması,

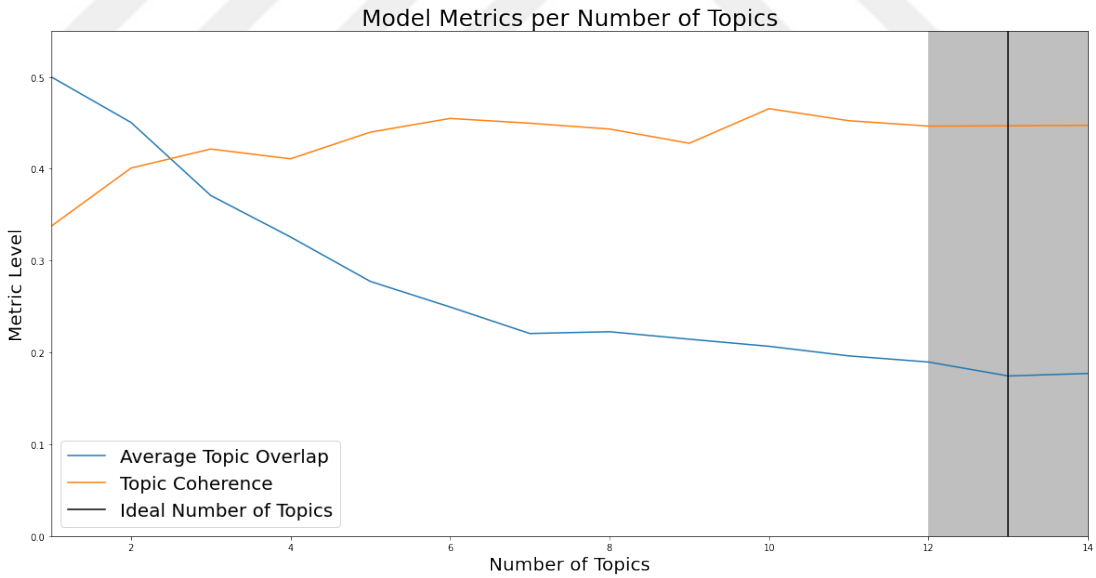
3. “İngilizce Durak Kelimeleri”nin çıkarılması, yanlış yazılan kelimelerin çıkarılması ve konu modellemeye katkı sağlayamayacak tüm kelimelerin çıkarılması.

Ardından “bigram” ve “trigram” adı verilen ikili ve üçlü kelime öbekleri tespit edilmiştir. Son olarak, LDA modeli için lemmatizasyon işlemleri gerçekleştirilmiştir.

2.4.1.1. İngilizce Durak Kelimelerinin Çıkarılması

Durak kelimeler için hem NLTK (Bird vd., 2001) hem de Spacy (*Spacy*, 2015) kütüphaneleri kullanılabilir, ancak Spacy NLTK'dan daha fazla durak kelimeye sahip olduğu için bu araştırmada Spacy kullanılmıştır. Ön işlemede, yalnızca İngilizce durak kelimelerinin çıkarılmasıyla gerçekleştiğinde Jaccard benzerliği algoritması 13 tane konunun optimal sayı olduğu bulunmuştur. Bu durumda kod çalıştırıldığında, Perplexity: -6.77123935454965 ve Coherence Score: 0.3663479631188331 olarak çıkmıştır.

Şekil 2: Jaccard Benzerliği Algoritması- 13 Konu Sayısı



Tablo 2: İngilizce Durak Kelimeleri Çıkarıldığında LDA Algoritmasının Konu Modelleme Çıktıları

Kelimeler	Konu İsimleri
gerçekten, zevk, aile, dokunmak, yol, gün, tutmak, hizmet, üye, satın alma	?
ses, iyi, harika, kalite, güzel, hoparlör, ekran, fiyat, ürün, boyut	Ses Özellikleri
çalışma, iyi, kurulum, cihaz, video, olur, telefon, harika, arama, değer	?
aşk, satın almak, görmek, kullanmak, video, mümkün, hediye, aile, aramak, almak	Hediyeleşme
kolay, kullanmak, ayarlamak, mükemmel, aşk, iyi, yapmak, açık, duymak, hayat	Algılanan Kullanım Kolaylığı
kamera, yüzük, kullanım, satış, görüntülemek, görmek, almak, aşk, bağlanmak, mutlu	?
müzik, oyun, tarif, video, aşk, dinle, kullan, bak, izle, harika	?
ekran, yankı, gösteri, büyük, boyut, aşk, ses, büyük, harika, çok	Ekran Özellikleri
göstermek, yankı, satın almak, almak, ebeveyn, satın almak, cihaz, almak, yaşlı, iletişim kurmak	?
resim, mükemmel, alexa, uygulama, kullanım, şey, uzak, çok, kontrol, sor	?
ev, cihaz, akıllı, güzel, ek, hava, kolaylığı, kullanımı, ses, kullanıcı_dostu	?
oda, çok, gibi, söyle, kızı, alarm, canlı, satın, kanca, oğlu	?
harika, ürün, tavsiye, ederim, iş, aşk, satın, değer, ürün, yatak, odası	?

Tablo 2'de görüldüğü gibi, LDA algoritmasında sadece önceden belirlenmiş İngilizce durak kelime paketinin çıkarılması ile anlamlı konular elde edilmesi güçtür. Müşteri yorumları, pek çok hatalı yazım, bazen sadece bir kelimeden oluşan ifadeler içerdiğinden, ön işlemin daha dikkatli yapılması gerektiği anlaşılmıştır.

2.4.1.2. Hafif Ön İşleme

Ön işlemede, İngilizce durak kelimelerinin çıkarılmasının yanısıra, yanlış, eksik yazılan kelimelerinde çıkarılması tüm kelime külliyatının frekansını etkileyeceğinden, daha anlamlı sonuçlar vermektedir. Jaccard benzerliği algoritması ile 14 tane konunun optimal sayı olduğu bulunmuştur. Perplexity: -6.842660800549943 ve Coherence Score: 0.35495948294185703 olarak çıkmıştır.

Tablo 3: Hafif Ön İşleme Yapıldığında LDA Algoritmasının Konu Modelleme Çıktıları

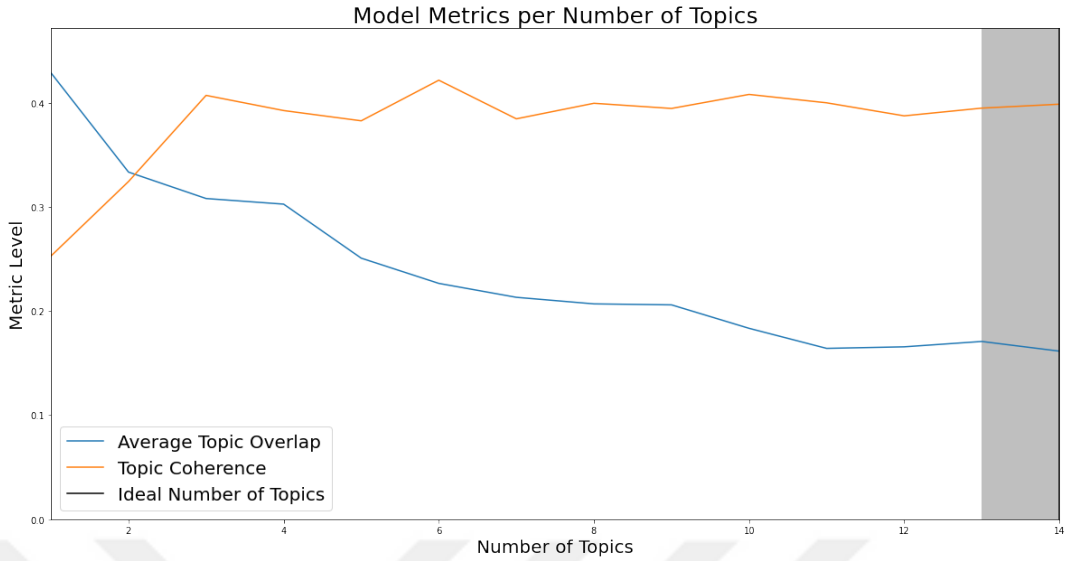
Kelimeler	Konu İsimleri
aşk, harika, aile, satın, şaşırtıcı, hediye, tavsiye, özellik, ürün, tutmak	Hediyeleşme
müzik, yemek tarifi, oyna, kullan, sev, dinle, video, mutfak, izle, hava durumu	Mutfakta Kullanım
gerçekten, zevk, bazen, değer, hizmet, yararlı, dolu, yararlı, arayüz, oldukça	Kullanışlılık
arama, video, yapmak, saat, iyi, cihaz, hala, telefon, gibi, bağlantı	?
almak, satın almak, aşk, zaman, uzak, yükseltme, kullanmak, satış, eş, satın alma	?
harika, kapı zili, ek, eski, yerine, para, gerekir, kişi, fantastik, henüz	?
harika, ses, iyi, kalite, iş, iyi, resim, ürün, ekran, hoparlör	Ürün Kalitesi
ev, büyük, cihaz, ekran, kontrol, ses, özellikle, değişim, bilgi, sürüm	?
ihtiyaç, uygulama, oda, git, değer, düşün, ev, istiyorum, satın, yeni	?
kolay, kullanmak, ayarlamak, kurulum, ürün, yapmak, iyi, koymak, yüklemek, tavsiye	Kullanım Kolaylığı
ekran, boyut, büyük, mükemmel, küçük, aşk, çok, ses, basit, al	Ekran
kamera, yüzük, iş, görünüm, harika, bağlanmak, cihaz, kullanım, aşk, görmek	Kamera Özelliği
güzel, sor, güzel, yatak odası, müzik, soru, eğlence, cevap, şey, hoparlör	Sesli Komut Özelliği

Konuların daha anlamlı çıkması daha fazla temizlik yapılması gerektiğini doğrulamıştır ancak her bir konunun yeterince anlamlı olmaması nedeniyle, konuların ayrıştırılmasına anlamlı katkısı olmayan tüm gereksiz kelimelerin çıkarılmasına karar verilmiştir.

2.4.1.3. Ağır Ön İşleme

Ön işleme, LDA algoritmasının ilk ve en önemli adımıdır. Önceki iki denemede görüldüğü gibi, İngilizce durak kelimelerinin çıkarılmasının yanısıra, yanlış, eksik yazılan kelimelerinde çıkarılması konu modelleme için yeterince anlamlı sonuçlar sağlamamıştır. Bunun için konu ile ilgili olabilecek ve aynı zamanda konuların belirlenmesine katkı sağlayabilecek tüm kelimelerin çıkarıldığı ağır bir temizlik işlemi yapılmıştır. Jaccard benzerliği algoritması ile 14 tane konunun optimal sayı olduğu bulunmuştur. Perplexity: -7.302066769368721 ve Coherence Score: 0.42638884944872046 olarak çıkmıştır.

Şekil 3: Jaccard Benzerliği Algoritması - 14 Konu Sayısı



Tüm konuların düzgün şekilde ayrıştığı görülmüştür, Tablo 4'te görüldüğü üzere kolaylıkla isimlendirme yapılmıştır.

Terimler için konu adları, konuları yorumlamak için araştırmacılar tarafından atanır. Bir terimin bir konuya atanma olasılığı (∅_kw) isimlendirmede yaygın bir uygulamadır (Sievert & Shirley, 2015). Ancak, genellikle aynı kelimeler farklı konu başlıkları altında görünür, bu nedenle bu sorunu çözmek için LDA modelindeki terimler aşağıdaki denklem kullanılarak terimin alaka düzeyine göre sıralanmıştır.

$$r(w,k \mid \lambda) = \log(\emptyset_{kw}) + (1-\lambda) log \frac{\emptyset_{kw}}{p_w}$$

λ değeri, Sievert & Shirley, (2015) ve Ozansoy Çadırcı et al., (2022) ile uyumlu olarak 0.6 olarak atanmıştır. Nihai konu adları ve ilgili terimler Tablo 4'te özetlenmiştir.

Tablo 4: Ağır Ön İşleme Yapıldığında LDA Algoritmasının Konu Modelleme Çıktıları

Kelimeler	Konu İsimleri
kurulum, ekran, ekle, eş, mutfak, kullanıcı_dostu, wifi, yüksek, tarif, takip	Mutfakta Kullanım
kamera, zil, video, görünüm, seçenek, ebeveyn, güvenlik, hizmet, kapı zili, fonksiyon	Kapı Zili Entegrasyonu
ses, kalite, resim, fiyat, bilgi, kanca, oğul, tasarım, asistan, arayüz	Sesli Asistan
fotoğraf, yatak odası, sistem, okuma, zaman, kontrol, ev, değiştirme, favori, ekran	Fotoğraf Kaydırma
değer, farklı, öğrenmek, para, lirik, internet, zor, kurulum, zor, etkinleştirmek	Kurulum
boyut, hoparlör, küçük, konuşma, arkadaş, eğlence, ekran, stand, ses, yüz	Video Arama
ev, akıllı, açık, bağlamak, ek, değer, yüklemek, yararlı, beceri, günlük	Akıllı Ev Entegrasyonu
kolay, ekran, set, büyük, daha, iyi, hayat, değişim, bağlantı, geliştirmek, beklenti	Geliştirilmiş Ekran Kalitesi
video, aile, izle, dokun, çocuk, satış, üye, film, yüksek sesle, sohbet	Video İzleme
oda, uygulama, ses, ışık, basit, kolaylık, komut, çevir, youtube, duy	Sesli Komut
müzik, çalmak, yemek tarifi, dinlemek, sormak, hava durumu, soru, yardımcı, şarkı, pişirmek	Arama Motoru
özellik, bırak, telefon, saat, anne, uygulama, yaşlı, bağlantı, zaman, hesap	Yaşlıların Kullanımı
büyük, eski, ses, alarm, canlı, iletişim, seç, şikayet, kal, model	Ses Özellikleri
tavsiye, hediye, yükseltme, anne, zaman, başlangıç, anlaşma, kızı, sipariş, duyarlı	Hediyeleşme

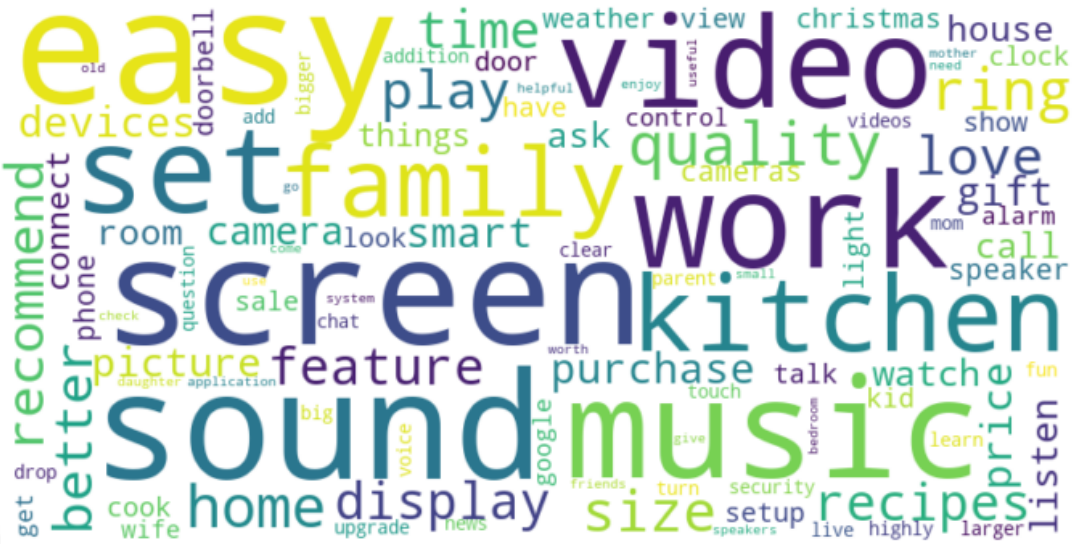
Konular arası mesafe haritası Şekil 4'te gösterilmiştir.

Şekil 4: Konular Arası Mesafe Haritası



Şekil 5, derlemin kelime bulutunun bir örneğidir. Kelime bulutu, derlemde en çok geçen kelimeleri uygun bir boyutta göstermektedir (S. Kumar vd., 2021). Temel olarak, bu kelime bulutu müşteri incelemelerinde ortaya çıkan kelime sıklığını temsil eder ve sık kullanılanlar daha iyi bir görselleştirme ve hızlı anlama sağlayan daha büyük yazı tipi boyutunda görünür.

Şekil 5: LDA Kelime Bulutu



2.4.2. BERT Sentence Transformers (Cümle Dönüştürücüler)

SBERT yaklaşımında cümle dönüştürücüler kitaplığından (Reimers & Gurevych, 2019), cümle yerleştirmelerini gerçekleştirmek için "distilbert-base-nli-mean-tokens" kullanılmıştır. Titiz bir değerlendirme ve çok sayıda deneme sonrası, ön işleme yapılmadığında konular anlamlı çıkmamıştır. Konu modelleme çalıştırıldığında elde edilen Konu-1, tüm aykırı değerleri ifade eder ve genellikle göz ardı edilmelidir. En çok kullanılan kelimelerin amazon, echo, alexa, product vb. çıkması nedeniyle ön işleme yapılmasına karar verilmiştir.

2.4.2.1. İngilizce Durak Kelimelerinin Çıkarılması

SBERT modeli işletilirken, NLTK kütüphanesi (Bird vd., 2001) kullanılarak öncelikle İngilizce durak kelimeleri çıkarılmış ve 10 konu elde edilmiştir.

Tablo 5: İngilizce Durak Kelimeleri Çıkarıldığında SBERT Algoritmasının Konu Modelleme Çıktıları

Kelimeler	Konu İsimleri
ses, ekran, kalite, harika, yüksek, yankı, iyi, müthiş, boyut, şaşırtıcı	Faydalar
mutfak, yemek tarifleri, yemek pişirme, müzik, kullan, aşk, harika, echo, dinle, izle	Mutfakta Kullanım
ev, akıllı, ev, harika, ek, cihaz, kolay, cihazlar, kullanım, kontrol	Akıllı Ev Entegrasyonu
fiyat, ürün, satın almak, iyi, harika, en iyi, tavsiye, aşk, mükemmel, satın alma	Fiyatlama
noel, hediye, satın, aldım, kızım, hediyeler, verdi, aşk, oğlum, aile	Hediyeleşme
satın aldı, seviyor, anne, anne, hediye, kızı, eşi, aldı, satın alındı, aile	Aile İçi Satınalma
kolay, kullanım, iyi, set, ürün, kurulum, çalışır, harika, ses, net	Fonksiyonellik
aile, arkadaşlar, kolay, aşk, harika, dokunmatik, seviyor, çocuklar, tavsiye, kullan	Kullanım Önerisi
daha iyi, ekran, daha büyük, yankı, daha büyük, ses, yükseltme, iyi, boyut, kalite	Ekran Kalitesi
alexa, kolay, aşk, harika, çalışır, kullanım, ürün, cihazlar, ev, kurulum	Kullanışlılık

Tablo 5'te görüldüğü gibi konular isimlendirilmiştir. Ancak konuların yeterince ayrık ve anlamlı olmaması nedeniyle, hafif ön işleme yapılmasına karar verilmiştir.

2.4.2.2. Hafif Ön İşleme

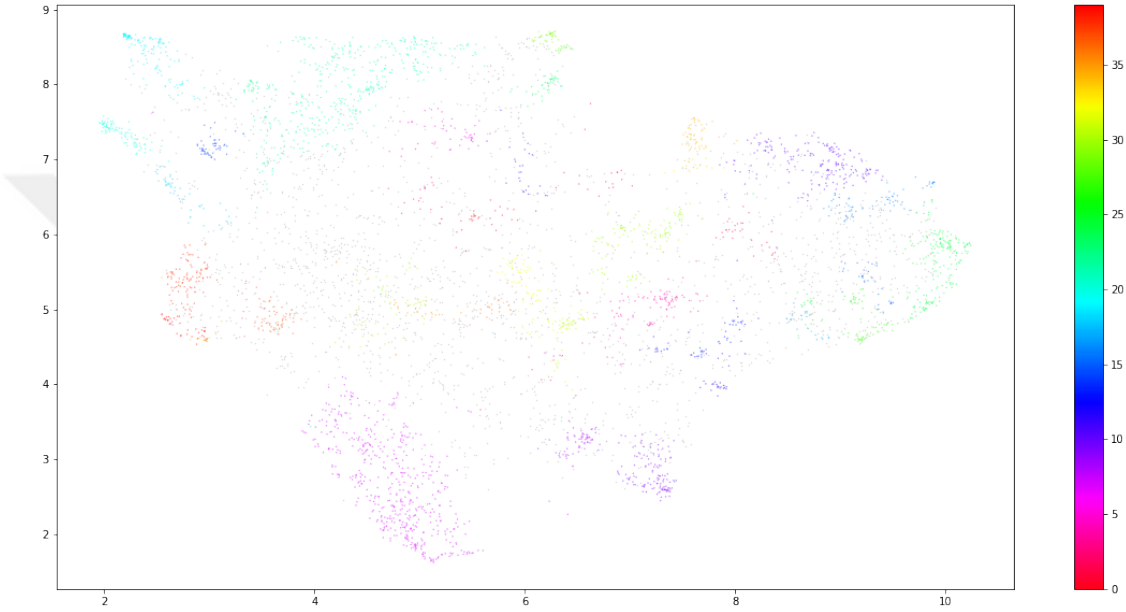
Hafif Ön İşleme yapıldığında da 10 konu elde edilmiştir Tablo 6'da görüldüğü gibi isimlendirilmiştir:

Tablo 6: Hafif Önişleme Yapıldığında SBERT Algoritmasının Konu Modelleme Çıktılar

Kelimeler	Konu İsimleri
yüksek, ses, boyut, bas, ekran, aşk, harika, kalite, müzik, hoparlör	Fonksiyonellik
hava, beğen, müzik, kamera, video, haber, aşk, güzel, kullan, ayarla	Arama Motoru
ev, akıllı, ev, harika, ek, kullanım, kolay, cihazlar, cihaz, kontrolü	Akıllı Ev Entegrasyonu
mutfak, yemek tarifleri, yemek pişirme, müzik, kullan, aşk, harika, izle, dinle, sayaç	Mutfakta Kullanım
noel, hediye, aldım, kızım, hediyeler, aşk, aile, satın aldım, verdim	Hediyeleşme
kolay, kullanım, ürün, harika, çalışır, set, kurulum, iyi, ekran, aşk	Kullanım Kolaylığı
ses, kalite, net, kolay, görüntü, harika, hoparlör, ekran, harika	Ses Kalitesi
satın alındı, seviyor, anne, hediye, anne, kızı, eşi, var, satın alındı, video	Aile İçi Kullanım
fiyat, ürün, harika, değer, iyi, mükemmel, kolay, kalite, en iyi, satın almak	Fiyatlama
iş, telefon, uygulama, kullanım, cihaz, iyi, olsun, bazen, video	Uygulama Entegrasyonu

Konuların çok daha anlamlı çıkması nedeniyle müşteri verisini incelerken, hafif ön işlemenin BERT için daha faydalı olduğuna karar verilmiş ve bu çıktılar ile ilerlenmiştir. Şekil 6'da gösterildiği gibi SBERT modelinde, ortaya çıkan konuları görselleştirmek için iki boyutlu alana indirgenebilir ve aykırı değerleri gri noktalar olarak gösterilebilir.

Şekil 6: SBERT Kümelerinin Görselleştirilmesi



2.4.3. BERTopic

BERTopic algoritması büyük ölçüde gömme yaklaşımına dayandığından, Egger & Yu, (2022) orijinal metni kullanmayı ve durak kelimesi kaldırma gibi ön işleme prosedürlerini atlamayı önermişlerdir. Ancak bu önerinin aksine, SBERT'te kullanılan yaklaşımda olduğu gibi BERTopic'in uygulamasında da hafif ön işleme yöntemi izlendiğinde, bu çalışmada en iyi sonuçlar elde edilmiştir. Spacy kütüphanesi (Honnibal & Montani, 2017) kullanılarak yaygın İngilizce kelimeler, yanlış yazılan kelimeler ve çalışmaya özgü bir grup kelime derlemden çıkarılmıştır.

Yerleştirme modeli olarak, en iyi kaliteyi sağlayan ve 1 milyardan fazla eğitim çiftinden oluşan geniş ve çeşitli bir veri kümesinde eğitilen "all-mpnet-base-v2" modeli kullanılmıştır (Reimers, 2022). Çünkü BERT, her çıkış öğesini her giriş öğesine bağlamak için cümle yapısını her iki yönden de kullanan ve bu bağlantıya

bağlı olarak ağırlıkları dinamik olarak ayarlayan bir dil modelidir. Durak kelimeler ve cümlelerin diğer gramer özellikleri, modelin daha iyi çalışmasında rol oynayabileceğinden, hafif bir temizleme daha iyi sonuç verebilir (Bricken, 2021). Bu yüzden 3 farklı ön işleme yöntemi test edilmiştir.

1. Hiçbir durak kelimenin çıkarılmaması
2. Yalnızca İngilizce durak kelimelerinin çıkarılması
3. Hafif Ön İşleme (İngilizce durak kelimelerinin yanısıra, yanlış yazılan kelimelerin de çıkarılması)

2.4.3.1. Ön İşleme Yok

UMAP'ın stokastik doğası nedeniyle, BERTopic'ten alınan sonuçlar farklılık gösterebilir ve kalite düşebilir. Kendi yerleştirmelerinizi kullanmak, size en uygun konuları bulana kadar BERTopic'i birkaç kez denemenizi gerektirebilir (Grootendorst, 2021). Bu yüzden algoritma defalarca çalıştırılmış ve her seferinde farklı sayıda konu bulunmuştur: Birinci çalıştırmada, 15; ikinci çalıştırmada, 9; üçüncü çalıştırmada, 34; dördüncü çalıştırmada, 22; beşinci çalıştırmada, 12 konu elde edilmiştir. Tüm bu denemelerde, ilk konunun her zaman konu modellemeye uygun olmayan çok genel kelimeler içerdiğini fark edilmiştir. Beşinci çalışmada 12 konu elde edildiğinde çıkan Konu -1'in kelimeleri aşağıda verilmiştir.

0: [('the', 0.050509553031539915),

('to', 0.042606699769182174),

('and', 0.04198014462777786),

('it', 0.037860890168198366),

('is', 0.03378336077193893),

('my', 0.03251221567935456),

('echo', 0.03238683165632984),

('for', 0.03094442529992961),

('this', 0.028830495234039053),

('show', 0.02751679839676835)],

12 konu elde edildiğindeki bu çalışmanın tüm çıktıları aşağıda incelenmiştir. Konu -1, aykırı konu anlamına gelir ve genellikle ihmal edilmektedir. O nedenle, son tahlilde konu sayısı 11'dir ve aşağıdaki gibi kümelenmiştir.

Tablo 7: Hiçbir Önişleme Yapılmadığında BERTopic Algoritmasının Konu Modelleme Çıktıları

Kelimeler	Konu İsimleri
ve, bu, benim, echo, için, bu, gösteri	Echo Show
zil, ile, benim, kapı, kameraları, çalışır, ve, kapı, zili	Kapı Zili Entegrasyonu
mutfak, yemek, tarifleri, müzik, içinde, onun, için, ve, aşk	Mutfakta Kullanım
saat, alarm, o, benim, için, ve, bir, için	Alarm Saat Entegrasyonu
oda, ev, içinde, için, satın, bir, o, büyük, sahip	Ev İçi Kullanım
google, daha iyi, bu, merkez, bu, ve, o, -e, -a, ama, -den, -dan	Rakipler
o, için, netflix, ama, uygulama, içinde, üstünde, -e, -a, o, bu	Uygulama Entegrasyonu
resim, ürünü, fotoğrafları, dijital, slayt, olarak, kullanmak, için	Fotoğraf Kaydırma
o, ona, o, için, bazen, anlamak, don, yani, müzik, çalmak	Müzik Çalma Özelliği
boyut, yeterli, büyük, çok, mutfak, mükemmel, ve, için, değil	Boyut
her, şeyi, yapar, daha, çok, beklenir, ne, umulur, kullanır, ama, yapar	Beklenti

Tablo 7'de görüldüğü üzere, hiçbir ön işlem yapılmadığı durumda, konuyu belirlemek için yalnızca bir kaç kelime elde edilmekte, geri kalanlar daha çok edat olarak belirmektedir. En önemli konunun (Konu 0), hiçbir konuyla ilişkilendirilemeyecek kadar genel kelimelere sahip olmasından ötürü, ikinci adımda İngilizce durak kelimeleri çıkarılarak, tekrar analiz yapılmasına karar verilmiştir.

2.4.3.2. İngilizce Durak Kelimelerinin Çıkarılması

İngilizce kelimelerin çıkarılmasında Spacy kütüphanesi (Honnibal & Montani, 2017) kullanılmıştır. Algoritma yine defalarca çalıştırılmış ve UMAP'in stokastik yapısından ötürü her seferinde farklı konu sayıları elde edilmiştir. Birinci çalıştırmada, 22; ikinci çalıştırmada, 28; üçüncü çalıştırmada, 7; dördüncü çalıştırmada, 12; beşinci çalıştırmada, 18 konu elde edilmiştir. Son çalışmanın tüm çıktıları incelendiğinde, ihmal edilebilecek olan -1 numaraları konunun kelimeleri şu şekilde çıkmıştır: {great, easy, use, love, good, product, like, sound, works, set}. O nedenle son tahlilde, 17 konu üzerinden incelemeler yapılmıştır.

Tablo 8: İngilizce Durak Kelimeleri Çıkarıldığında BERTopic Algoritmasının Konu Modelleme Çıktıları

Kelimeler	Konu İsimleri
echo, alexa, aşk, ekran, harika, amazon, gibi, ses, kullanım, video	Faydacı Yararlar
mutfak, yemek tarifleri, müzik, aşk, harika, kullan, yemek pişirme, dinle, oyna, hava	Mutfakta Kullanım
ses, kalite, ekran, harika, iyi, boyut, resim, hoparlör, güzel, aşk	Faydalar
aile, satın, video, dokunmak, mümkün, konuşmak, harika, kalmak, anne, sohbet	Aile İçi Kullanım
ürün, fiyat, satın almak, harika, en iyi, iyi, hizmet, satın alma, mükemmel, tavsiye	Fiyatlama
kolay, ayarla, kurulum, kullan, harika, dost, basit, aşk, aile, kullanıcı	Kullanım Kolaylığı
zil, kapı, kameralar, çalışır, kapı zili, kamera, yanıp sönme, zil, güvenlik, kullanım	Kapı Zili Entegraysonu
hediye, Noel, aldım, seviyor, aşk, aldım, sevdim, kesinlikle, kızım, doğum günü	Hediyeleşme
saat, alarm, uyanmak, müzik, gece, gibi, aşk, mükemmel, kullanmak, en iyi	Alarm Saat Entegrasyonu
google, daha, iyi, hub, ev, sürümü, yuva, ekran, bilmek, akıllı, gibi	Rakipler
cihaz, hayat, aşk, kolay, kullanım, eğlenceli, elektronik, harika, tavsiye, akıllı	Kullanım Kolaylığı
akıllı, ev, cihazlar, ev, cihaz, hub, ekleme, harika, uyumlu, bağlı	Akıllı Ev Entegrasyonu
netflix, uygulama, akış, sınırlı, youtube, müzik, izle, hulu, özellikler, seçenekler	Uygulama Entegrasyonu
çalışır, beklenen, yapar, harika, iyi, şikayetler, sorunlar, para, kardeş, değer	?
resimler, dijital, ürün, fotoğraflar, kamera, çerçeve, çerçeveler, kullanım, slayt, istiyorum	Fotoğraf Kaydırma
anlamak, oynamak, dinlemek, müzik, don, lol, sormak, zor, şeyler, liste	Sesli Komut
kontrol, ışıklar, ev, ev, ısı, iç içe, dönüş, otomatik, yürütmek, yatak odası	Işık Kontrol

Ancak burada konuları ayrıştırmada sıkıntı çekilmiş ve tüm konular anlamlı şekilde isimlendirilememiştir. O nedenle konuya özel kelimeler de dahil olmak üzere, hafif bir ön işleme yapılmasına gerek duyulduğuna kanaat getirilmiştir.

2.4.3.3. Hafif Ön İşleme

Algoritma yine defalarca çalıştırılmış ve UMAP'in stokastik yapısından ötürü her seferinde farklı konu sayıları elde edilmişti. Birinci çalıştırmada, 25; ikinci çalıştırmada, 28; üçüncü çalıştırmada, 26; dördüncü çalıştırmada, 23; beşinci çalıştırmada, 15 konu elde edilmiştir. Son çalışmanın tüm çıktıları incelendiğinde, ihmal edilebilecek olan -1 numaraları konunun kelimeleri şu şekilde çıkmıştır: {easy,

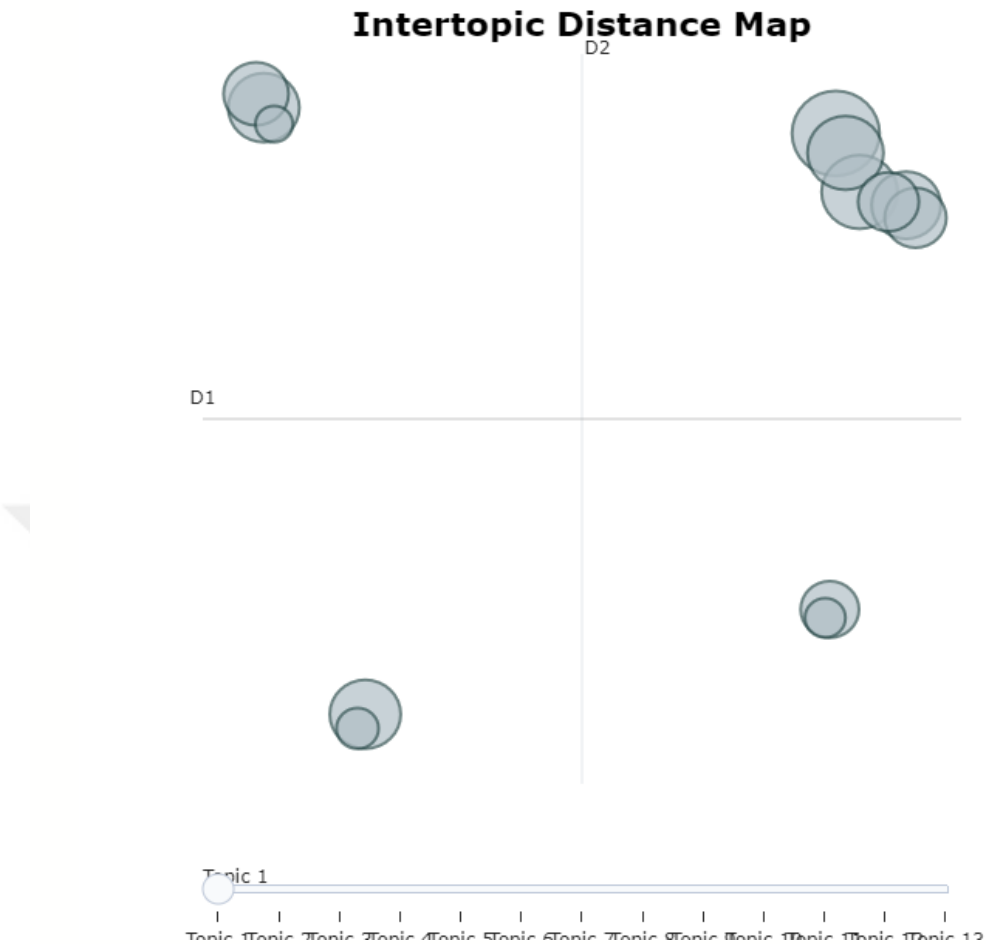
music, good, like, bought, video, sound, set, screen, family}. O nedenle son tahlilde, 14 konu üzerinden incelemeler yapılmıştır.

Tablo 9: Hafif Ön İşleme Yapıldığında BERTopic Algoritmasının Konu Modelleme Çıktıları

Kelimeler	Konu İsimleri
ekran, gibi, ses, video, müzik, ev, cihazlar, kolay, daha iyi, iyi	Fonksiyonellik
satın, iyi, fiyat, tavsiye, kolay, satın, mükemmel, nakliye, ürünler	Fiyatlama
ekran, boyut, görüntü, iyi, ses, büyük, güzel, kalite, mükemmel, büyük	Ekran Özellikleri
ses, hoparlör, iyi, kalite, görüntü, mükemmel, net, fiyat, sesler	Hoparlör Özellikleri
hediye, Noel, aldım, seviyor, sevdi, kızı, aldım, anne, doğum günü, kesinlikle	Hediyeleşme
mutfak, yemek tarifleri, müzik, yemek pişirme, tarif, bak, dinle, pişir, izle, ihtiyaç	Mutfakta Kullanım
kolay, ayarla, kurulum, yükle, dost, basit, kalite, ayar, çalışır, kolaylık	Kurulum
aile, covid'e dokun, pandemi, konuş, iletişim, satın, kal, büyükanne, yol	Pandemide Aile İletişimi
akıllı, ev, cihazlar, özellikler, ev, tavsiye, çalışır, kontrol, kolay, yaşam	Akıllı Ev Entegrasyonu
10, inç, daha, iyi, ekran, boyutu, sürümü, ses, gibi, daha, büyük, yükseltilmiş	Geliştirilmiş Ekran
zil, kapı, çalışır, kapı zili, zil, kameralar, kamera, sistem, bağlı, bağlanmak	Kapı Zili Entegrasyonu
müzik, dinle, hava, oyun, dinleme, günlük, oyun, çocuklar, haberler, kullanır	Sesli Komut
kameralar, kamera, yanıp sönme, güvenlik, izle, bebek, görünüm, çengel, eğlence, sahip olmak	Güvenlik Kamerası Entegrasyonu
görüntülü, sohbet, kızı, satın, işleri, anne, aramalar, anne, arama, arkadaşlar	Video Chat

BERTopic modeli eğitildikten sonra, çıkarılan konuları iyi bir şekilde anlamak için konular yinelemeli olarak gözden geçirilebilir. Ancak, bu oldukça zaman alır ve küresel bir temsilden yoksundur. Bunun yerine, LDAvis'e çok benzer bir şekilde oluşturulmuş görselleştirme araçlarından faydalanılabilir. Şekil 7'de, konular arası uzaklık haritası gösteren grafik verilmiştir.

Şekil 7: BERTopic Konular Arası Mesafe Haritası

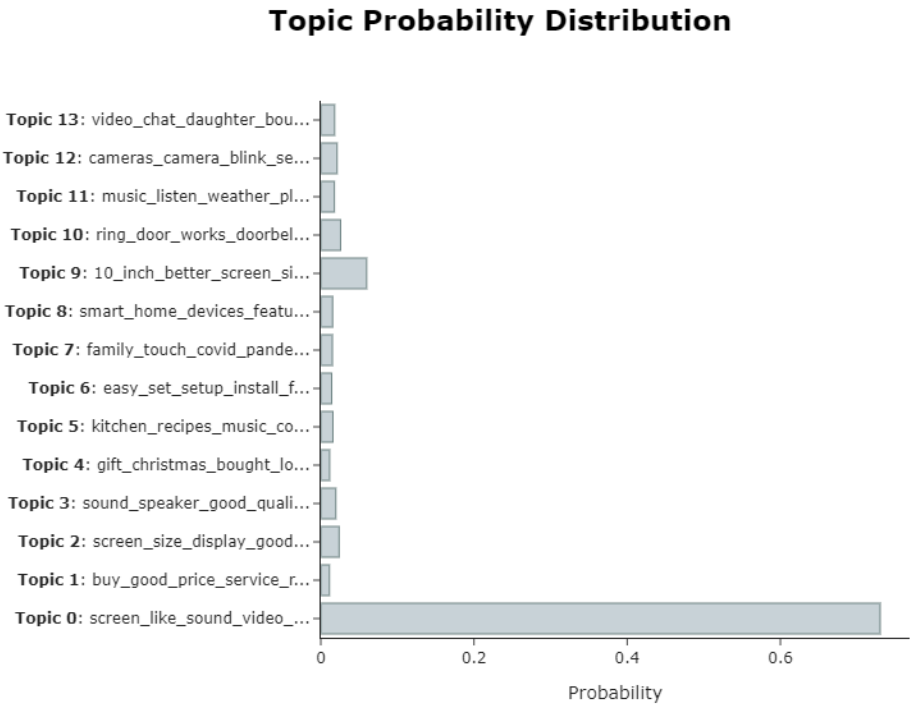


Algoritmanın çıkardığı konuların 2 boyutlu bir temsilini oluşturmak için "visualize_topics() parametresi çağırabilmektedir. Ortaya çıkan grafik, HTML'ye dönüştürülebilen etkileşimli bir grafiktir.

Konuyu seçmek için grafiğin altında yer alan kaydırıcıyı kullanılabilir, hangi konunun üzerine gelinirse, grafikte ilgili konu kırmızı renkte yanar. Bir konunun üzerine gelindiğinde, konunun boyutu ve karşılık gelen kelimeler de dahil olmak üzere konu hakkında genel bilgiler verilir.

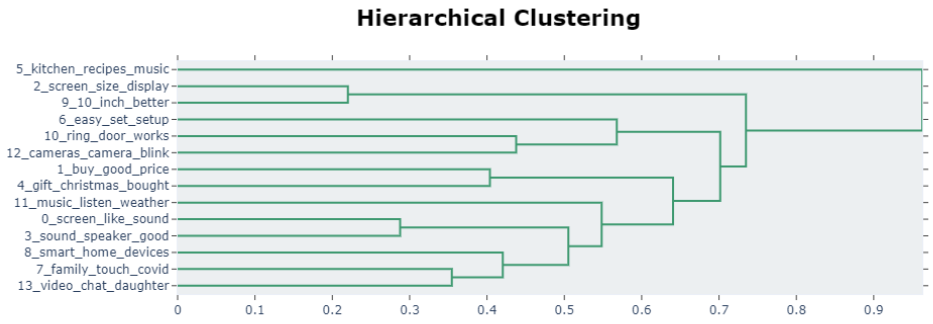
Konu Olasılıksal Dağılımı: transform() veya fit_transform() işlevinden döndürülen değişken olasılıklar, BERTopic'in belirli konuların bir belgede bulunabileceğinden ne kadar emin olduğunu anlamak için kullanılabilir. Şekil 8'de minimum 0.01 olasılıkla konularım dağılımını gösteren grafik verilmiştir.

Şekil 8: Bertopic Konu Olasılıksal Dağılımı

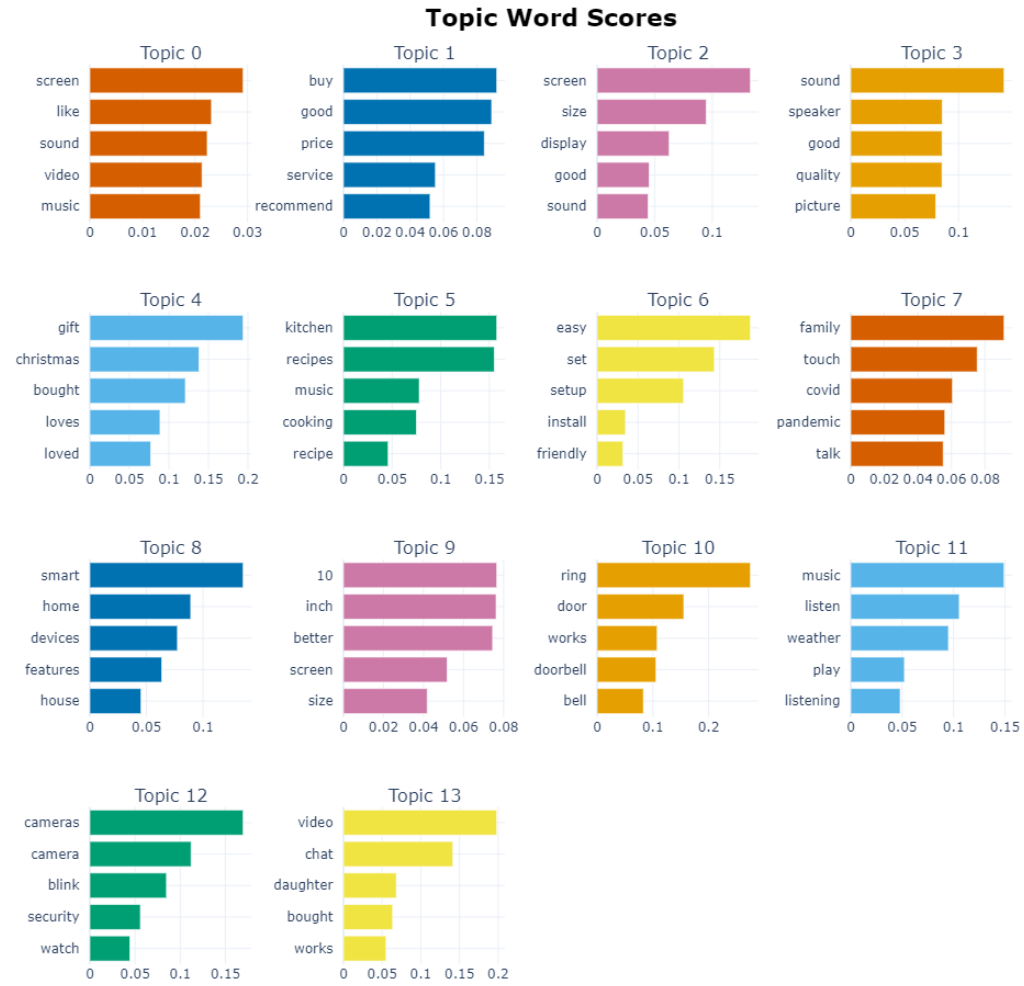


Oluşturulan konular hiyerarşik olarak azaltılabilir. Konuların potansiyel hiyerarşik yapısını anlamak için kümeler oluşturmak ve bunların birbirleriyle nasıl ilişkili olduğunu görselleştirmek için "scipy.cluster.hierarchy" kullanılmıştır. Bu, oluşturulan konu sayısını azaltırken uygun bir nr_topics seçilmesine yardımcı olabilir. Ancak 14 konu yeterince düşük olduğunda tekrar bir konu azaltma komutu çalıştırılmamıştır. Hiyerarşik kümelemenin nasıl göründüğüne dair grafik Şekil 9'da mevcuttur.

Şekil 9: BERTopic Hiyerarşik Kümeleme



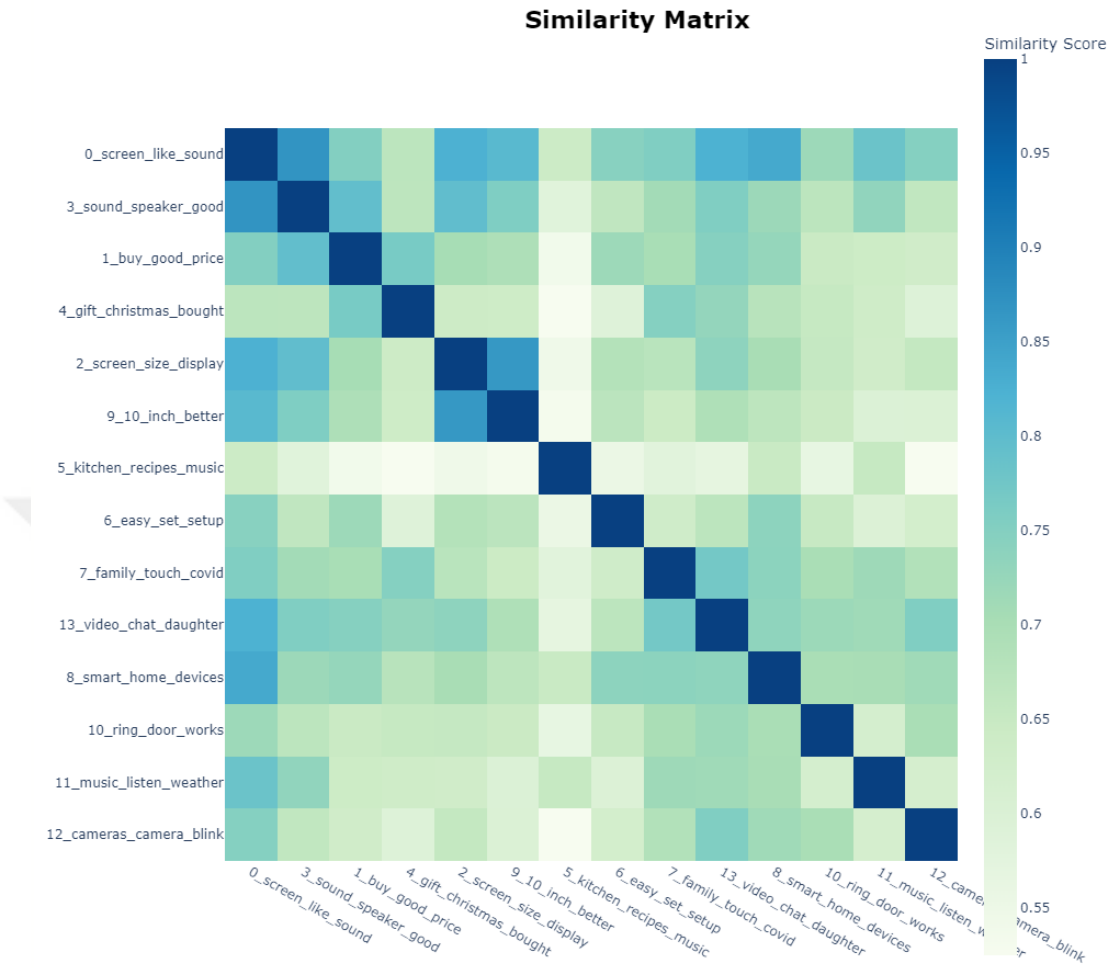
Şekil 10: BERTopic Konu Kelime Skorları



Şekil 10'da gösterildiği gibi, her konu gösterimi için c-TF-IDF skorlarından çubuk grafikler oluşturarak birkaç konu için seçilen terimler görselleştirilebilir. Konular arasındaki ve içindeki ilgili c-TF-IDF skorlarından içgörüler elde edilebilir. Ayrıca, konu temsillerini birbirleriyle kolayca karşılaştırılabilir.

Hem c-TF-IDF hem de yerleştirmeler yoluyla konu yerleştirmeleri oluşturduktan sonra, bu konu yerleştirmeleri aracılığıyla kosinüs benzerliklerini basitçe uygulayarak bir benzerlik matrisi oluşturulabilir. Şekil 11'de gösterildiği gibi sonuç, belirli konuların birbirine ne kadar benzer olduğunu gösteren bir matris olacaktır.

Şekil 11: BERTopic Benzerlik Matrisi

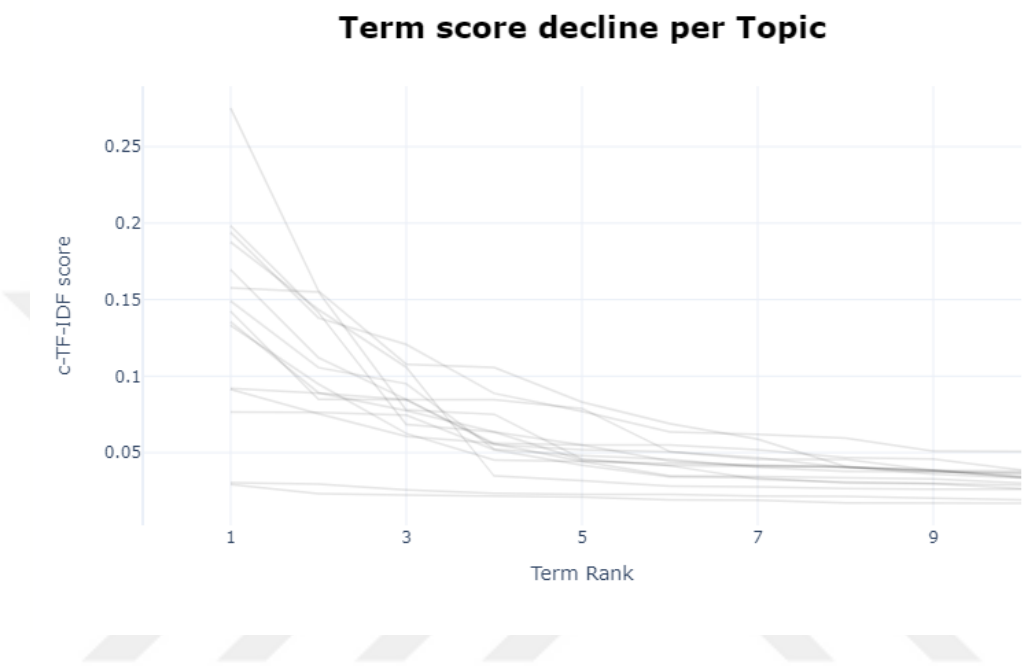


Konular, en iyi açıklayıcı kelime ile başlayan bir dizi kelime ile temsil edilir. Her kelime bir c-TF-IDF puanı ile temsil edilir. Puan ne kadar yüksek olursa, konuyu o kadar temsil eden bir kelime olur. Konu sözcükleri c-TF-IDF puanlarına göre sıralandığından, eklenen her sözcükle puanlar yavaş yavaş düşer. Bir noktada konu sunumuna kelimeler eklemek toplam c-TF-IDF puanını sadece marjinal olarak arttırır ve temsili için faydalı olmaz.

Bu etkiyi görselleştirmek için, her kelimenin terim sıralamasına göre her konu için c-TF-IDF puanları çizebilmektedir. Diğer bir deyişle, c-TF-IDF puanı en yüksek olan kelimelerin 1. sıraya sahip olacağı kelimelerin konumu (terim sıralaması), x eksenine yerleştirilecektir. y ekseni ise c-TF-IDF puanlarıyla doldurulacaktır. Sonuç, konu gösterimine kelimeler eklerken c-TF-IDF puanının düşüşünü gösteren bir

görselleştirmedir (Şekil 12). Dirsek yöntemini kullanarak bir konudaki en iyi kelime sayısının seçilmesine olanak tanır.

Şekil 12: BERTopic Konu Başına Kelime Puan Düşüşü



2.4.4. Top2Vec

Top2Vec algoritması, konu sayısının otomatik olarak belirlenebilmesiyle öne çıkmakta, durak kelimesi kaldırma, tokenizasyon ve lemmatizasyona ihtiyacı ortadan kaldırmaktadır (Angelov, 2020) ve algoritma son derece anlamlı sonuçlar vermiştir. Bu noktada, Top2Vec'in en hızlı ve en kolay çalışan algoritma olduğunu belirtmek önemlidir.

Bu çalışmada, gömme modeli için 'universal-sentence-encoder' kullanılmıştır (Top2Vec Release 1.0.27, 2022). Analiz sonucunda Tablo 10'da gösterildiği gibi en iyi sonuç olarak 11 konu başlığı çıkarılmıştır. Top2Vec yaklaşımı, hiçbir ön işleme gerek kalmadan konuları otomatik olarak belirlemek için sorunsuz ve verimli bir yol sunarak konu modelleme için değerli ve kullanıcı dostu bir araç olarak karşımıza çıkmaktadır.

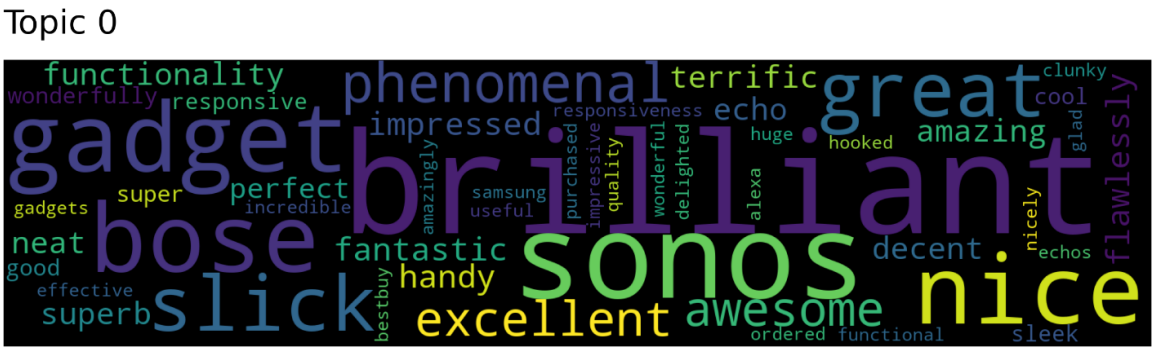
Tablo 10: Top2Vec Konu Modelleme Çıktıları

Kelimeler	Konu İsimleri
parlak, sonos, alet, bose, güzel, harika, şık, olağanüstü, mükemmel, etkileyici, etkilendim, fantastik, kusursuz, kullanışlı, işlevsellik, üstün, echo, makul, düzenli, şaşırtıcı, müthiş, mükemmel, harikulade, havalı, süper, iyi, duyarlı, şık, duyarlılık, güzelce, büyük, işlevsel, etkili, memnun, samsung, şaşırtıcı bir şekilde, alexa, inanılmaz, etkileyici, aletler, faydalı, memnunum, harika, yankılar, sipariş edildi, bağımlısı olmuş, hantal, satın alındı, bestbuy, kalite	İşlevsellik
hediye, satın aldı, torunlar, büyükanne ve büyükbabalar, torun, anneanne, ev halkı, aldı, aile, anne, teyze, akrabalar, noel, torunlar, anne, noel, hediyeler, zaman kazandıran, armağanlar, verdi, kızlar, zevk aldı, memnun oldu, ebeveynler, yardım etti, bilgili, komşu, eş, alımlar, kullanışlı, kız, aldı, sipariş etti, bebekler, kurdu, güzel, alım, ipad, yeğen, kardeşler, yardım etti, baba, taşınabilir, ebeveyn, yükseltti, tavsiye etti, sonos, bağımlısı oldu, kullandı, getirdi	Hediyeleşme
alexa, sonos, alet, yankı, aletler, yankılar, duyarlılık, duyarlı, cihaz, mikrofon, siri, mikrofonlar, roku, facetime, ipad, iot, bestbuy, roomba, samsung, cihazlar, işlevsellik, gözetim, bose, bildirimler, akıllı telefon, kindle, yankılar, hoparlör, aletler, izleme, mik, dokunmatik ekran, ekran, televizyon, kamera, dijital, özellik, monitör, zoom, diafon, hoparlörler, sesli kitap, iphone, uyarılar, elektronik, alexia, zil, tv, tablet, dinler	Cihaz Cevap Verebilirliği
alexa, sonos, alexia, siri, iot, echo, cihaz, roku, alexalar, echolar, amazon, duyarlılık, roomba, aletler, samsung, alexisler, dinler, ipad, senkronize eder, duyarlı, bildirimler, aygıt, alarmlar, kindle, spotify, faydalı, bose, işlevsellik, mikrofonlar, iphone, mikrofon, merkez, mik, interkom, elektronik, kullanışlı, hulu, pandora, komidin, bestbuy, alarm, yönlendirici, netflix, ürün, facetime, bilgili, başucu, podcastler, kaydırıcı, bildirim	Cihaz Entegrasyonu
pişirme, tarifler, mutfak, fırında pişirme, mutfaklar, tarif, ocak, pişirmek, sonos, tabak, aletler, tabaklar, tezgah, cihaz, kullanışlı, malzemeler, menü, hane, ev aletleri, yemekler, veranda, alexa, iot, beslenmeler, faydalı, dinleme, işlevsellik, senkronize etmek, yiyecek, roku, aygıt, tablet, beslemek, yapım, kurulmuş, yardımcı, dokunmatik ekran, aygıtlar, ipad, spotify, bağlanmış, akşam yemeği, sesli kitaplar, hatırlatıcılar, eğlendirme, podcastler, tabletler, rendeleme, kullanımlar	Mutfak Kullanımı
kapı zili, alexa, kapı zilleri, sonos, interkom, kameralar, zil, kamera, alarm, alarmlar, zil, kameralar, gadget'lar, iot, komidin, gözetim, samsung, roomba, cep telefonu, gadget, bose, mikrofon, bildirimler, cihaz, mikrofonlar, dijital, elektronik, izleme, kapı, kablosuz, lamba, sundurma, halkalar, bluetooth, siri, takılı değil, facetime, yankılar, zoom, projektör, başucu, uyarılar, aksesuar, akıllı telefon, yüklü, kamera, iphone, işlevsellik, elektronik, aletler	Kapı Zili Entegrasyonu

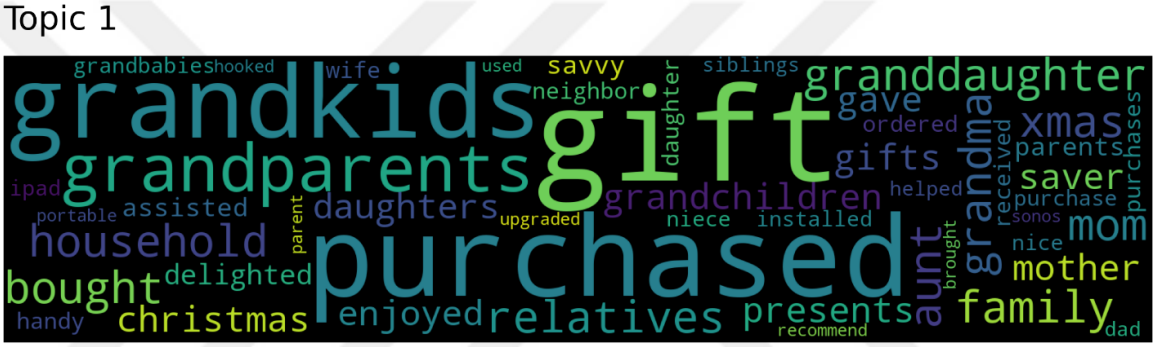
echo, sonos, alexa, satın, echos, gadget, sipariş, echoes, bestbuy, yüklü, satın, gadget'lar, komut, yanıt, görüntüleme, harcanan, karar, veranda, birim, tezgah, alımları, bose, kullanılan, duyarlı, satın, aldı, yükseltilmiş, hoparlörler, çengel, etkili, roomba, yapılan, memnun, paha biçilmez, ürün, monitör, ölçüm, dijital, kurulum, kavram, nihayet, sipariş, kullanım, getirdi, değerli, pahalı, satın almak, pikap, samsung, hoparlör	Fiyatlama
alarm, podcast, alarmlar, sonos, radyo, pandora, müzik, dinleme, spotify, senkronize, xm, gadget'lar, saatler, siriusxm, uyarılar, dinler, hatırlatıcılar, ayar, dinledi, kurulum, bildirimler, hava durumu, sesli, işlevsel, gadget, bose, kullanışlı, kullanışlı, uyandırır, ortam, saat, alexa, stereo, oynatma, zamanlayıcı, istasyon, dinle, zamanlayıcılar, cep telefonu, yüklü, başucu, interkom, çok yönlülük, tv, sirius, kapı zilleri, hoparlörler, televizyon, zamanında, yayın	Akış Kalitesi
bestbuy, sipariş, amazon, bose, sonos, satın, satın alma, pazarlık, garanti, satın alma, satın al, satın alır, tasarruf, satın alır, samsung, en iyi, fiyatlı, sipariş, gadget, satın alma, kindle, en büyük, ürün, fırsatlar, tavsiye, seçti, memnun, duyarlılık, yükseltilmiş, müşteriler, promosyon, ürünler, ipad, masa, satış, paket, yüklü, kablosuz, dükkan, inceleme, paketlenmiş, siparişler, mağaza, elektronik, alışveriş, tavsiye, sipariş, sevk, prime	Perakendecilik
netflix, spotify, sonos, hulu, roku, alexa, ipad, kindle, syncs, youtube, facetime, gadget, pandora, siriusxm, oynatma, işlevsellik, televizyon, gadget'lar, amazon, tablet, tv, akış, iot, siri, cihaz, roomba, bestbuy, uygulama, xm, akış, dinleme, video, izlenen, abonelik, duyarlılık, akışlar, duyarlı, akıllı telefon, senkronizasyon, özellik, ekolar, podcastler, yayın, elektronik, dinler, sesli, tavsiye, cihazlar, bildirimler	Uygulama Entegrasyonu
echo, echos, echoes, aile, alexa, kızları, sonos, paha biçilemez, gösteri, benim, görüntüleme, anne, dinler, memnun, hayran, kızı, sirius, ziyaretler, yeğen, torun, veranda, baba, teyze, hayranlar, dinleme, büyükanne ve büyükbaba, gösteri, torunlar, takdir, duyarlılık, çengel, arlo, ebeveynler, kardeşler, satın, yakınma, anne, hava, ünitesi, sevilen, ekran, gadget, ev, aileler, yayın, gülmek, tv, aşk, kız kardeşler, kız kardeş	Ev İçi Kullanım

Top2Vec algoritmasının çıktısı, aşağıda gösterildiği gibi her konuya özgü bir kelime torbası (BoW) görüntüsü oluşturabilir. Örneğin, Konu 0, terimlerine göre "İşlevsellik" olarak adlandırılmıştır. BoW görüntüsünden, ürünün işlevselliğini ifade eden kelimeler ilk bakışta anlaşılabilir. Şekil 13 ve Şekil 23 arasındaki şekiller, Top2Vec algoritmasının çıkarmış olduğu her bir konuya dair kelime torbası görsellerini belirtmektedir.

Şekil 13: Top2Vec Konu 0 Kelime Bulutu



Şekil 14: Top2Vec Konu 1 Kelime Bulutu

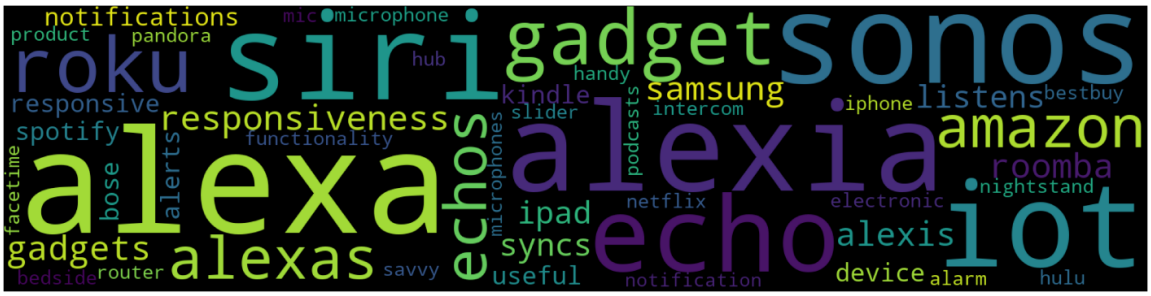


Şekil 15: Top2Vec Konu 2 Kelime Bulutu



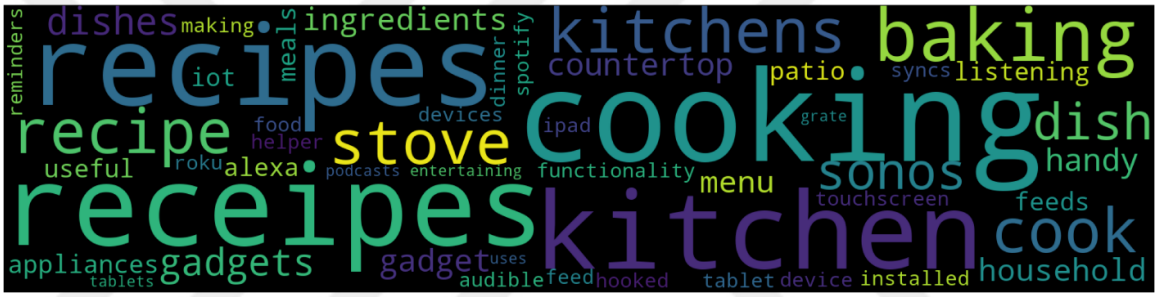
Şekil 16: Top2Vec Konu 3 Kelime Bulutu

Topic 3



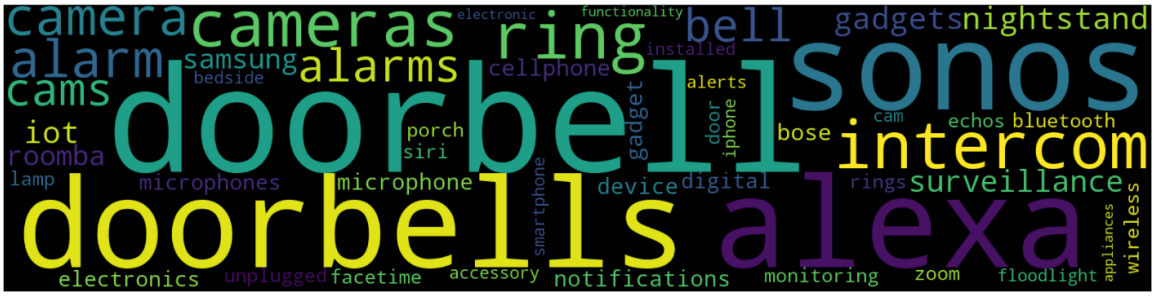
Şekil 17: Top2Vec Konu 4 Kelime Bulutu

Topic 4



Şekil 18: Top2Vec Konu 5 Kelime Bulutu

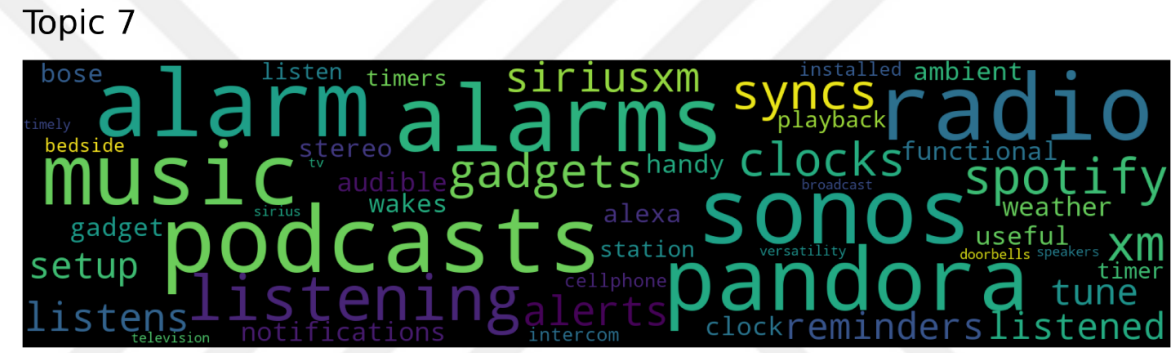
Topic 5



Şekil 19: Top2Vec Konu 6 Kelime Bulutu



Şekil 20: Top2Vec Konu 7 Kelime Bulutu



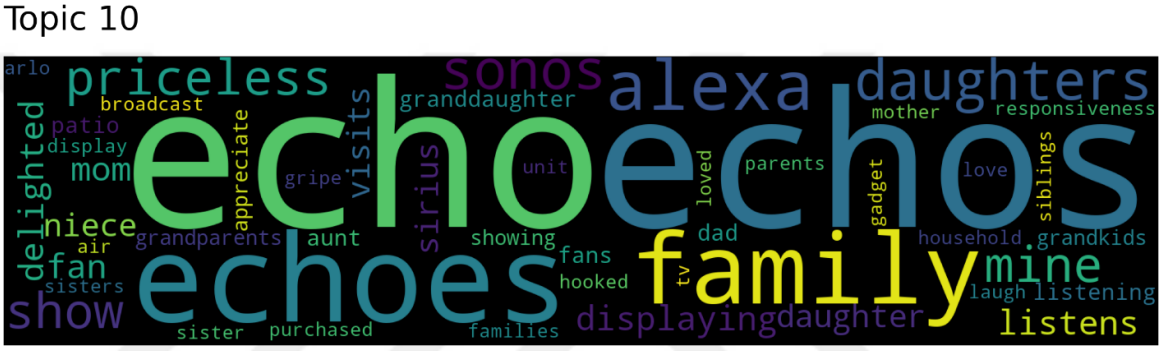
Şekil 21: Top2Vec Konu 8 Kelime Bulutu



Şekil 21: Top2Vec Konu 9 Kelime Bulutu



Şekil 22: Top2Vec Konu 10 Kelime Bulutu



2.5. Tartışma

Konu modellemesine olan ilginin artması ve sosyal bilimlerdeki kaynak eksikliği (Reisenbichler & Reutterer, 2019) farklı yöntemlerin değerlendirilmesini gerektirmektedir. Önceki bölümde tartışılan algoritmalar, metodolojik güçleri ve müşteri yorumlarını analiz etmek için sundukları fırsatlar açısından daha ayrıntılı olarak değerlendirilecektir. Metodolojik konular arasında önceden eğitilmiş model kullanılabilirliği, ön işleme, görselleştirme çeşitliliği ve eğitim süresi yer almaktadır. Ayrıca, metodolojik hususların yanı sıra, her bir algoritmanın yorumlanabilirliği, çıktılarının anlamlılığına ve pazarlama analitiği için sağladıkları içgörülere dayalı olarak değerlendirilecektir.

2.5.1. Yöntemsel Uygulanabilirlik

Bu çalışmada potansiyel metodolojik kaygılar ve LDA, SBERT, BERTopic ve Top2Vec olmak üzere dört farklı konu modelleme algoritmasının etkinliği tartışılmaktadır. Sosyal bilimciler veri bilimi konusunda uzman olmadıklarından,

müşteri inceleme verilerini değerlendirirken uygun bir algoritma seçmekte tereddüt edebilirler. LDA, SBERT, BERTopic ve Top2Vec'i hesaplama temelinde karşılaştırırken, performanslarını ve verimliliklerini etkileyebilecek çeşitli faktörler devreye girer. Metodolojik bir bakış açısıyla aşağıdaki dört maddenin seçimi, araştırmacıların analiz sürecinde yaygın olarak karşılaştıkları başlıca zorluklardan kaynaklanmaktadır. Ön işleme, veri kalitesini ve sonuçların uygunluğunu etkilediği için büyük önem taşımaktadır (Zhou vd., 2017). Etkili ön işleme teknikleri, verileri analize hazırlamak ve anlamlı içgörüler sağlamak için hayati önem taşımaktadır. Eğitme süresi, analiz sürecinin pratikliğini ve fizibilitesini doğrudan etkiler (Sia vd., 2020). Makul eğitim sürelerine sahip verimli algoritmalar, büyük veri kümelerini ve zamana duyarlı projeleri yönetmek için son derece tercih edilir. Önceden eğitilmiş model erişilebilirliği, analizin verimliliği ve doğruluğunda çok önemli bir rol oynar. İyi eğitilmiş modellere erişim, verilerden elde edilen sonuçları ve çıkarımları önemli ölçüde etkileyebilir. Son olarak, görselleştirme çeşitliliği, karmaşık bilgilerin erişilebilir ve anlaşılabilir bir şekilde aktarılmasında önemli bir değere sahiptir (Sievert & Shirley, 2015). Çeşitli görselleştirme araçları, sonuçların etkin bir şekilde keşfedilmesini ve iletilmesini kolaylaştırır. Tüm bu tekniklerin hesaplama yönlerine göre bir karşılaştırması sunulmuştur:

2.5.1.1. Ön İşleme

Ön işleme ile ilgili olarak, LDA'nın en zorlu algoritma olduğu söylenebilir. Algoritmanın düzgün çıktı vermesi için durak kelimelerin çıkarılması hayati önem taşımaktadır. Önerilenin aksine, SBERT de durak kelimelerin hafifçe çıkarılması gibi bir ön işleme ihtiyaç duymuştur. Birçok başarısız çabadan sonra, BERTopic'in de ön işleme ihtiyacı olduğu belirlenmiştir, çünkü konu 0 sürekli olarak anlamsız ve genel terminoloji içermektedir. İngilizce durak kelimeler dikkatlice çıkarıldıktan sonra, bazı terimlerin henüz konuya göre kategorize edilemediği keşfedilmiştir. Bu nedenle, son derece konuya özgü birkaç kelimenin küçük ölçüde elenmesi en iyi sonuçları vermiştir. Bununla birlikte, Top2Vec algoritmasının herhangi bir ön işlem yapmaksızın en iyi sonucu elde ettiği görülmüştür.

2.5.1.2. Eğitme Süresi

Algoritmayı eğitme süresi de bir araştırmacı için hangi yöntemin kullanılacağına karar verirken bir sorun olabilir. LDA, derin öğrenme tabanlı yaklaşımlara kıyasla nispeten

hafif bir modeldir. LDA'yı eğitmek, özellikle küçük ve orta ölçekli derlemler için genellikle daha hızlıdır. Model, LDA algoritması kullanılarak yaklaşık 30 saniyede oluşturulabilir ki bu da araştırmacı için olumlu anlamda kısa bir süredir. Ancak LDA konu modellemesinin en önemli kısmı olan konu sayısına karar verme süreci, otomatik olarak belirlenmediği için zorlayıcı olabilmektedir. Sonuç olarak, bir benzerlik yöntemi, bu çalışmada Jaccard Benzerlik yöntemi kullanılmıştır, faydalı ve oldukça değerli olmaktadır. Ancak, böyle bir yöntemin kullanılmasının zaman alıcı olabileceğini unutmamak gerekir. Bu büyüklükteki bir veri kümesi için gereken süre yaklaşık 30 dakikadır ve bu süre değerlendirilen yaklaşımlar arasında en uzun olanıdır.

SBERT modeli bu veri kümesi için sadece 6 dakikada eğitilmiştir, ancak algoritma stokastik olduğundan, konu sayısının anlamlı bir şekilde belirlenebilmesi için en az 3 kez eğitilmesi gerekmektedir. Öte yandan, BERTopic modelinin yaklaşık 3 dakika boyunca eğitilmesi gerekmiştir ve BERTopic modelde istenirse konu sayısı manuel olarak da tanımlanabilir. Top2Vec herhangi bir ön işleme prosedürü gerektirmediğinden en basit algoritmadır. Model için maksimum eğitim süresi en fazla bir dakika olmuştur. Buna karşılık, diğer gömme yaklaşımlarında olduğu gibi, doğru konu sayısını belirlemek için algoritmanın birden fazla kez çalıştırılması gerekmiştir.

2.5.1.3. Önceden Eğitilmiş Model Erişilebilirliği

Önceden eğitilmiş LDA modelleri yaygın olarak pek kullanılmamaktadır ve algoritmayı eğitmek çok hızlıdır (Sia vd., 2020). SBERT (Reimers, 2022) ve BERTopic (Grootendorst, 2021) için önceden eğitilmiş birçok model bulunabilir ve bu da belirli görevler için eğitimde zaman kazandırabilir. Top2Vec (Angelov & Clendenning, 2020) için önceden eğitilmiş modeller SBERT veya BERTopic kadar yaygın olarak mevcut değildir.

2.5.1.4. Görselleştirme

Görselleştirme, bir konu modelleme algoritması seçerken göz önünde bulundurulması gereken bir diğer faktör olabilir. Görsel çıktılar, konu yapısının daha iyi ve hızlı bir şekilde anlaşılmasını sağlar (Kherwa & Bansal, 2019). LDA için en popüler görselleştirme aracı Gensim'in pyLDAVis aracıdır (Sievert & Shirley, 2015). Konular arası mesafe haritasını ve en göze çarpan konu terimlerini çıkarır. Ancak SBERT görselleştirme konusunda oldukça zayıf görünmektedir, sadece matploblib (*matplotlib*, 2003) kullanarak kümeleri görselleştirmektedir. BERTopic görselleştirme

konusunda mükemmeldir. BERTopic görselleştirme kütüphanesi (Grootendorst, 2022) hiyerarşik kümeleme, konular arası mesafe haritası, konu olasılık dağılımı, benzerlik matrisi, konu başına terim puanı düşüşü ve konu kelime puanları sağlar. Son olarak, Top2Vec, her konu için ayrı kelime bulutları sağlar ve bu da konuyla ilgili belirli kelimelerin göreceli sıklığını görsel olarak anlamaya yardımcı olur (Angelov, 2020).

Sonuç olarak, bu bölüm sosyal bilimcilerin metinsel verilerden bilgi çıkarmak için kullanabilecekleri konu modelleme algoritmalarını metodolojik pratiklik açısından inceleyerek sunmayı amaçlamaktadır. Yukarıda ayrıntıları verilen kıyaslama sürecinden elde edilen deneyime dayanarak, Tablo 11, pazarlama araştırmacıları için hızlı bir anlayış sağlamak amacıyla ön işleme, ön eğitimli model erişilebilirliği, algoritma eğitme süresi ve görselleştirme kriterlerini karşılaştırmaktadır.

Tablo 11: Konu Modelleme Algoritmalarının Karşılaştırılması

	Ön İşleme	Önceden Eğitilmiş Model Erişilebilirliği	Algoritma Eğitme Süresi	Görselleştirme
LDA	*Yoğun ön işleme*	*Az*	*<1 dk (benzerlik metodu yok)*	★★
SBERT	*Hafif ön işleme*	*Geniş*	*<10 dk*	★
BERTopic	*Hafif ön işleme*	*Geniş*	*<5 dk*	★★★
Top2Vec	*Ön işleme yok*	*Orta*	*<3 dk*	★★

Bu karşılaştırma verilerle desteklense de yalnızca araştırmaya konu olan müşteri yorumları verilerine dayandığı unutulmamalıdır.

2.5.2. Uygulama Kapasitesi

Konu modellemesi, metin analizi için güçlü bir nicel araç olarak hizmet eder. Ancak oluşturulan konuların yorumlanması önemli ölçüde metodolojik ve teorik seçimlere bağlıdır (Jacobs & Tschötschel, 2019). Bu nedenle, sonuçlardan anlamlı içgörüler elde etmek için araştırmacıların alan uzmanlığına (Egger & Yu, 2021) ve istisnai muhakeme becerilerine sahip olması şarttır. Bu bağlamda, veri odaklı araştırma

konusunda sağlam bir geçmişe sahip olan sosyal bilimciler, nicel analitiği etkili bir şekilde değerli ve içgörülü bilgiye dönüştürebilir (Canali, 2016).

Mevcut iş ortamında, müşteri geri bildirimlerini anlamak ve ürünlerin güçlü ve zayıf yönlerini belirlemek her kuruluş için çok önemlidir. Teknolojinin yükselişiyle birlikte, müşteriler satın aldıkları ürünlerle ilgili görüşlerini genellikle web siteleri ve pazar yerleri gibi çeşitli platformlar aracılığıyla ifade etmektedir. Ancak, bu kadar büyük miktarda veriyi işlemek ve yorumlamak göz korkutucu bir görev olabilir. Konu modellemesinden elde edilen sonuçları etkili bir şekilde anlamlandırmak için araştırmacıların ürün ve hedef pazar hakkında derin bir anlayışa sahip olması gerekir. Örneğin, teknoloji ürünleri söz konusu olduğunda, sektöre özgü jargona ve teknik entegrasyonlara aşina olmak zorunlu hale gelir. Bu bilgi olmadan, veri işlemenin doğruluğu tehlikeye girebilir. Daha sorunsuz bir yorumlama süreci sağlamak için, veri kümesi üzerinde önceden genel bir etki alanı analizi yapılması şiddetle tavsiye edilir.

Bir yapay zekâ ürünü olarak Alexa, çeşitli sistemlerle çok sayıda entegrasyona sahiptir. Bununla birlikte, "Drop In" özelliğine aşina olmayan bir araştırmacı, metin işleme sırasında "drop" kelimesini yanlışlıkla durdurma kelimesi olarak kaldırabilir. Oysa "Drop In", kullanıcıları Alexa özellikli cihazlara anında bağlayan ve bir interkom gibi işlev gören hayati bir özellik olarak büyük önem taşımaktadır (*How Does Drop In Work?*, 2023); bu nedenle, analize başlamadan önce araştırmacının alan/ürün bilgisine sahip olması şiddetle tavsiye edilir. İlginç bir şekilde, "Drop In", LDA sonucundan türetilen "Yaşlı Kullanımı" konusu içinde bulunan anahtar bir terimdir. Diğer algoritmaların bu terimi çıkaramaması dikkat çekicidir; bu da LDA'nın daha genel anahtar terimleri çıkardığını göstermektedir.

Bu araştırmada, SBERT 10, Top2Vec 11 ve BERTopic ve LDA ise 14 konu çıkarmıştır ve ortak konular Tablo12'de görülebilir. Kavramayı kolaylaştırmak için algoritmaları türlerine göre değil, çıktılar anlamsal ve niceliksel benzerliklerine göre karşılaştırılmaktadır.

Tablo 12: SBERT ve Top2Vec Karşılaştırılması

SBERT		**Top2Vec**	
Konular	**Kelimeler**	**Konular**	**Kelimeler**

Mutfak Kullanımı	mutfak, yemek tarifleri, yemek pişirme, dinle, sayaç	**Mutfak Kullanımı**	yemek pişirme, yemek tarifleri, mutfak, pişirme, mutfaklar, dinleme
Hediyeleşme	noel, hediye, kızım, aile, satın alındı	**Hediyeleşme**	hediye, satın alınan, torunlar, büyükanne ve büyükbaba, Noel
İşlevsellik	ses, boyut, bas, ekran, hoparlör	**İşlevsellik**	parlak, işlevsellik, fonksiyonel, etkili, kalite
Aile Kullanımı	satın aldı, seviyor, anne, kız, eş	**Aile Kullanımı**	anne, torun, baba, torunlar, aileler
Fiyatlandırma	fiyat, harika, değer, kalite, en iyi	**Fiyatlandırma**	satın almak, memnun, paha biçilemez, değerli, pahalı
Uygulama Entegrasyonu	iş, telefon, uygulama, kullanım, cihaz	**Uygulama Entegrasyonu**	netflix, spotify, youtube, facetime, siri
Ses Kalitesi	ses, kalite, net, harika, hoparlör	**Akış Kalitesi**	podcast, müzik, dinleme, melodi, yayın
Kullanım Kolaylığı	kolay, kullanım, ürün, harika, set,	**Kapı Zili Entegrasyonu**	kapı zili, interkom, kameralar, zil, alarm
Akıllı Ev Entegrasyonu	ev, akıllı, ek, cihaz, kontrol	**Cihaz Entegrasyonu**	siri, iot, ipad, senkronizasyon, elektronik
Arama Motoru	hava durumu, müzik, haber, kullan, ayarla	**Cihaz Cevap Verebilirlik**	gadget, yankı, duyarlılık, cihaz, mikrofon
		Perakendecilik	bestbuy, satın alma, pazarlık, garanti, promosyon

Tablo 12, SBERT ve Top2Vec tarafından çıkarılan konuları göstermektedir. Konular açısından SBERT ve Top2Vec karşılaştırıldığında, "İşlevsellik", "Hediyeleşme", "Mutfak Kullanımı", "Fiyatlandırma", "Aile Kullanımı" ve "Uygulama Entegrasyonu" her iki algoritma tarafından çıkarılan ortak konular olarak görülmektedir. Bununla birlikte, Top2Vec'in çok daha spesifik kelimeler çıkardığını vurgulamak önemlidir, bu da araştırmacının ön alan bilgisine sahip olması durumunda anahtar kelimeleri adlandırmasını çok daha kolay hale getirir.

Ayrıca, Top2Vec "Kapı Zili Entegrasyonu", "Perakendecilik", "Akış Kalitesi" ve "Cihaz Entegrasyonu" gibi temel konuları çıkarmayı başarırken, SBERT "Kullanımı Kolay", "Arama Motoru", "Ses Kalitesi" ve "Akıllı Ev Entegrasyonu" gibi belirgin konuları çıkarmıştır.

Tablo 13, LDA ve BERTopic algoritmaları tarafından çıkarılan konuların bir karşılaştırmasını sunmaktadır. Her iki algoritma da "Hediyeleşme", "Akıllı Ev Entegrasyonu", "Mutfak Kullanımı", "Kapı Zili Entegrasyonu", "Görüntülü Arama", "Kurulum", "Daha İyi Ekran" ve "Sesli Komutlar" gibi ortak temalar belirlemiştir. Ayrıca LDA, ürün bağlamında kolayca tanınabilen "Arama Motoru" ve "Sesli Asistan"

ile ilgili temel konuları çıkarmıştır. Öte yandan, BERTopic, SBERT ve Top2Vec algoritmaları, şirketler için en önemli hususlardan biri haline gelen "Fiyatlandırma" konusunu vurgulamıştır. Ayrıca, veriler pandemi sırasında elde edildiğinden, BERTopic benzersiz bir terim olan "covid" {family, touch, covid, pandemic, communicate} kelimesi tespit etmiş ve bu da "Pandemi Sırasında Aile İletişimi" adlı konunun belirlenmesini sağlamıştır. LDA algoritması da benzer anahtar kelimeler içermesine rağmen, "covid" kelimesinin olmaması, konunun "Yaşlı Kullanımı" olarak etiketlenmesine neden olmuştur. Algoritmaların çıktıları arasındaki bu nüanslar, stratejilerin uygulanması için şirketlere değerli bir rehberlik sunmaktadır.

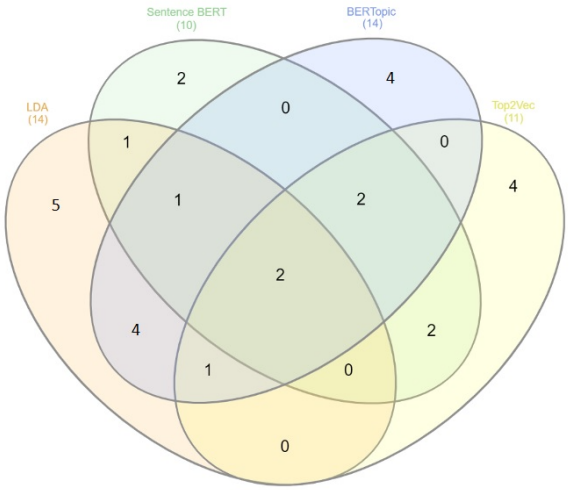
Tablo 13: LDA ve BERTopic Karşılaştırması

LDA		BERTopic	
Konular	**Kelimeler**	**Konular**	**Kelimeler**
Sesli Asistan	ses, bilgi, tasarım, asistan, arayüz	**Fonksiyonellik**	ekran, ses, video, müzik, ev
Hediyeleşme	tavsiye, hediye, anne, anlaşma, sipariş	**Hediyeleşme**	hediye, Noel, satın, kızım, doğum günü
Akıllı Ev Entegrasyonu	ev, akıllı, bağlantı, ekleme, beceri	**Akıllı Ev Entegrasyonu**	akıllı, ev, cihazları, özellikleri, kontrol
Mutfakta Kullanım	ekran, eş, mutfak, reciper, takip et	**Mutfakta Kullanım**	mutfak, yemek tarifleri, yemek pişirme, dinle, aşçı
		Fiyatlama	satın almak, iyi, fiyat, tavsiye, satın alma
Kapı Zili Entegrasyonu	kamera, zil, güvenlik, servis, kapı zili	**Kapı Zili Entegrasyonu**	halka, kapı, kapı zili, kamera, bağlan
Ses Özellikleri	ses, alarm, canlı, iletişim, seç	**Hoparlör Özellikleri**	ses, hoparlör, iyi, kaliteli, net
Yaşlı Kullanımı	düşürmek, telefon, saat, anne, yaşlı	**Pandemide Aile İletişimi**	aile, dokunmak, covid, pandemi, iletişim
Video İzleme	video, aile, izle, çocuk, üye	**Güvenlik Kamerası Entegrasyonu**	kamera, yanıp sönme, güvenlik, izle, görüntü
Arama Motoru	oyun, tarif, sor, hava, soru		
Görüntülü Arama	konuşma, ekran, stand, ses seviyesi, yüz	**Görüntülü Arama**	görüntülü, sohbet, anne, arama, arkadaşlar

Fotoğraf Kaydırma	fotoğraf, yatak odası, kontrol, değiştir, favori, ekran	**Ekran Özellikleri**	ekran, boyut, görüntü, iyi, büyük
Kurulum	değer, internet, sabit, kurulum, etkinleştir	**Kurulum**	kolay, ayarlamak, kurulum, yüklemek, ayarlamak
Geliştirilmiş Ekran	kolay, ekran, daha iyi, geliştirmek, beklenti	**Geliştirilmiş Ekran**	daha, iyi, ekran, boyut, daha, büyük, yükseltilmiş
Sesli Komut	ses, ışık, basit, komut, çevir	**Sesli Komut**	müzik, dinle, hava durumu, oynat, haberler

Her iki tablo da algoritmaların benzer konularına dayanmaktadır ve Şekil 24'te gösterilen Venn diyagramı (Heberle vd., 2015) üzerinden genel bir özet, ortak konular hakkında hızlı bir fikir verebilir.

Şekil 23: Konulara Dair Venn Diyagramı



Tablo 14'te görüldüğü gibi "Mutfakta Kullanım" ve "Hediyeleşme" tüm algoritmalar için iki önemli ortak konudur. Bu, pazarlamacılara ürünün hediye olarak satın alındığına ve en fazla mutfakta kullanıldığına dair önemli bir fikir verecektir. Devamında gelen "Fonksiyonellik, "Akıllı Ev Entegrasyonu", "Kapı Zili Entegrasyonu", "Fiyatlama" müşterilerin hakkında konuştuğu en yaygın konulardır. Ayrık konular karşılaştırıldığında, "Pandemide Aile İletişimi" konusu pandemi ile ilgili önemli bir gerçeği ortaya koyarken, "Güvenlik Kamerası Entegrasyonu" da önemli bir spesifik noktayı vurgulamaktadır. Top2Vec algoritmasının "Cihaz Cevap

Verebilirliği", "Akış Kalitesi" ve "Perakendecilik" gibi oldukça özel başlıklar çıkardığını da belirtmek gerekir.

Tablo 14: 4 Konu Modelleme Algoritmasının Konuları

Konu Modelleme Algoritmaları	Konu İsimleri
[LDA] ve [Sentence-BERT] ve [BERTopic] ve [Top2Vec]	Mutfakta Kullanım, Hediyeleşme
[Sentence-BERT] ve [BERTopic] ve [Top2Vec]	Fonksiyonellik, Fiyatlama
[LDA] ve [Sentence-BERT] ve [BERTopic]	Akıllı Ev Entegrasyonu
[LDA] ve [BERTopic] ve [Top2Vec]	Kapı Zili Entegrasyonu
[Sentence-BERT] ve [Top2Vec]	Aile Kullanımı, Uygulama Entegrasyonu
[LDA] ve [BERTopic]	Kurulum, Sesli Komut, Geliştirilmiş Ekran
[LDA] ve [Sentence-BERT]	Arama Motoru
[LDA]	Sesli Asistan, Fotoğraf Kaydırma, Video Arama, Video İzleme, Yaşlı Kullanımı, Ses Özellikleri
[Sentence-BERT]	Kullanım Kolaylığı, Ses Kalitesi
[BERTopic]	Ekran Özellikleri, Hoparlör Özellikleri, Pandemi Aile İletişimi, Güvenlik Kamerası Entegrasyonu, Video Arama
[Top2Vec]	Cihaz Cevap Verebilirlik, Cihaz Entegrasyonu, Akış Kalitesi, Perakendecilik

Bu argümanlara daha sağlam bir temel oluşturmak için, aşağıda her bir algoritmanın kapsamlı bir değerlendirmesi sunulacaktır:

LDA, konu modellemesi için olasılıksal bir üretici modeldir. Her belgenin çeşitli konuların bir karışımı olduğunu ve her konunun kelimeler üzerinde kolayca yorumlanabilen bir olasılık dağılımı olduğunu varsayar (Luo vd., 2020). LDA'nın avantajlarından biri, ön alan bilgisine ihtiyaç duymadan daha genel modeller üretebilmesidir (Rizvi vd., 2019). Kelime dağılımlarından bağımsız konuların çıkarılması söz konusu olduğunda LDA'nın sınırlamaları vardır (Campbell vd., 2015). Çakışan kümeler, LDA'nın yakından ilişkili ancak farklı kavramlar arasında ayrım

yapamadığı durumlarda ortaya çıkar (Passos vd., 2011). LDA'nın çalışma mekanizması, tüm külliyat genelinde konuların genel tutarlılığını en üst düzeye çıkarma hedefiyle (Mimno vd., 2011), belgelerdeki kelimelerin olasılıklara dayalı olarak konulara yinelemeli olarak atanmasını içerir (Piris & Gay, 2021). Bu nedenle, hiperparametrelerin dikkatli bir şekilde belirlenmesi (Gallagher vd., 2017) ve optimum konu sayısına karar verilmesi zorlu bir görev olabilir (Egger & Yu, 2022).

SBERT ve BERTopic ile ilgili olarak, her iki algoritma da sırasıyla Seo vd. (2022) ve Sánchez-Franco & Rey-Moreno, (2021) tarafından yapılan çalışmalardaki gibi, hafif ön işleme gerektirmiştir. SBERT, cümlelerin anlamsal olarak anlamlı temsillerini öğrenmek için bir Siyam veya üçlü ağ mimarisi kullanır ve bu da benzerlik karşılaştırması ve kümeleme gibi görevler için yararlı olabilir (Reimers & Gurevych, 2019). Cümle gömme modelleri büyük miktarda veri üzerinde önceden eğitilmiştir ve araştırmacılar tarafından kolayca erişilebilir (Alfeo vd., 2021). SBERT hesaplama açısından verimlidir (Reimers & Gurevych, 2019) ancak algoritma eğitim süresi bu karşılaştırmada BERTopic ve Top2Vec'den daha uzun sürmüştür. BERTopic ile en yüksek ortak konu sayısına sahiptir, ancak karşılaştırmalardaki toplam konu sayısı açısından Top2Vec'e daha yakındır. Cümleler arasındaki anlamsal ilişkileri ölçerek metin verilerini analiz ederken değerli içgörülere yol açabilmesine rağmen, çıktılarının bazıları çoğunlukla standart olarak kabul edilebilir (örneğin: “family use, “easy to use”, “search engine”).

BERTopic, önceden eğitilmiş yerleştirmelerde çalışır (Sánchez-Franco & Rey-Moreno, 2021) ve konu temsilleri oluşturmak için BERTopic, kümeleme yerleştirme tekniğinin üzerine TF-IDF'nin sınıf tabanlı bir biçimini dahil eder (Grootendorst, 2022). Bu yaklaşım, algoritmanın ana gücü olan konuların yorumlanabilirliğini artırır. Ayrıca, BERTopic modelini eğittikten sonra, araştırmacılar çıkarılan konuların sayısını azaltma esnekliğine sahiptir (Sánchez-Franco & Rey-Moreno, 2021). Bu özellik, araştırma hedefleriyle uyumlu, daha özlü ve yorumlanabilir bir konu kümesi elde etmelerini sağlar (Egger & Yu, 2022).

BERTopic gibi, Top2Vec de kelime semantiğini yakalamak için önceden eğitilmiş kelime yerleştirme kullanarak ortak gömülü belge ve kelime vektörleri oluşturur. Aradaki fark, Top2Vec'te yalnızca 3 adet önceden eğitilmiş gömme bulunurken BERTopic'te çeşitliliğin mevcut olmasıdır (Hendry vd., 2021). Top2Vec ham verilerle çalışabilir ve verilerin önceden işlenmesine gerek yoktur (Angelov, 2020) bu da

araştırmacıya analiz sırasında yüksek oranda zaman kazandırır. Bununla birlikte, Top2Vec her belgeyi tek bir konuya atar ve bu da belge içindeki gerçek konu dağılımının tam temsilini yansıtmaz (Egger & Yu, 2022). Bu nedenle, birçok aykırı değer üretebilir ve çıkarılan kelimenin çok spesifik olmasına yol açabilir, bu da konuları yorumlamak için önceden bir alan bilgisi gerektirir.

Araştırmacılar, ürün uzmanlığı ve pazar anlayışını dikkatli bir şekilde bir araya getirerek verilerden anlamlı içgörüler elde edebilir ve müşteri duyguları ve tercihleri hakkında değerli bilgiler edinmek için güçlü bir araç olarak konu modellemesinden yararlanabilir. Yapılandırılmamış verilerin metin analizi yoluyla incelenmesi, satış ve yatırım getirisi (ROI) ile ilişkilendirilebilecek müşteri farkındalığını ve duyarlılığını ortaya çıkarabilir (Van Auken, 2015). Bu şekilde şirketler, müşteri satın alma yolculuğundaki her aşamaya göre müşteri duyarlılığını takip edebilir (McGuirk, 2021). Bu, konu modelleme algoritmalarının anlamlı konuları ne ölçüde çıkarabildiğiyle doğrudan ilişkilidir. Analitiğin tüm yönlerini göz önünde bulunduran Iacobucci vd. (2019), Pazarlama Analitiğini "pazarlama kaynaklarını ve müşteriyle ilgili iş kararlarını ele almak için kullanılan veri ve modelleme araçlarının incelenmesi" olarak tanımlamıştır. Bu bağlamda, büyük veri analitiği, yapılandırılmamış metinlerden içgörü elde etmek için gerçekten de güçlü bir araç olabilir ve bu özellikle ürün inovasyonu bağlamında değerli olabilir (Erevelles vd., 2016).

Pazarlamacılar ve ürün yöneticileri bu bilgileri ürün geliştirme kararlarında kullanabilirler (Thieme vd., 2016). Ürün lansmanı aşamasında, LDA algoritması genel konuları belirlemek için yeterli olabilir. Pazarlamacılar ana pazarlama faaliyetlerini en genel konular üzerine odaklayabilirler. Krishen & Petrescu'ya (2017) göre, pazarlama analitiği, içgörü sağlama ve şirketler tarafından başlatılan etkili kampanyaları kolaylaştırma amacıyla kapsamlı ve disiplinler arası bir çalışma alanıdır; bu bağlamda, özel günlerde şirketler hediye vermenin önemine dikkat çekerek ürün için kampanyalar planlayabilir. Ancak zaman ilerledikçe ve detaylar önem kazandıkça, müşteriler tarafından belirtilen daha spesifik konuları bulmak için BERTopic veya Top2Vec kullanılabilir. BERTopic ve Top2Vec, diğer algoritmalar tarafından çıkarılmayan en spesifik konuları çıkarabilmiştir, bu da pazarlamacıların bireysel müşteriler için kişiselleştirilmiş pazarlama mesajlarına ve ürünlerine odaklandığını göstermektedir. Top2Vec çok hızlı bir algoritma olduğundan ve ön işlem gerektirmediğinden, hızlı karar verilmesi gereken durumlarda kurtarıcı olabilir. Ürün

yaşam döngüsünün olgunluk aşamasında şirketler artık genel özelliklere değil, sadık müşterilerini memnun etmeye odaklanan belirli özelliklere odaklanabilir. Örneğin, Top2Vec algoritması tarafından türetilen "Cihaz Cevap Verebilirliği" özelliği analiz edilebilir ve bir duygu analizi yapılabilir. Birçok teknoloji ürünü artık bulut üzerinde çalıştığından, şirketler ürünlerine uzaktan yazılım yükleyebilir. Cihazda gerçekten bir yanıt verme sorunu tespit edilirse, şirketin bunu hemen çözebilmesi müşteri memnuniyetini artıracaktır. Başka bir deyişle, şirketin proaktif yaklaşımı benzersiz bir birlikte yaratma faaliyeti yaratır (Fisk vd., 2018); geri bildirimlerine değer verildiğini ve bunlara göre hareket edildiğini göstermek güven oluşturur ve daha uzun süreli ilişkileri teşvik eder. Top2Vec'in "Perakendecilik" başlığını çıkardığı gibi, perakendecilik bağlamında tüketici davranışını anlamak, işletmelerin satış stratejilerini optimize etmelerine ve müşteri memnuniyetini artırmalarına yardımcı olabilir. Dolayısıyla, ürün geliştirme sürecinin farklı aşamalarına ve şirketin uygulamak istediği stratejiye bağlı olarak, kullanılacak algoritma değişebilir. Aynı öneriler BERTopic tarafından çıkarılan "Entegrasyon" özellikleri için de geçerlidir. "Akıllı Ev Entegrasyonu", "Güvenlik Kamerası Entegrasyonu" ve "Kapı Zili Entegrasyonu" müşteriler arasında en sık tartışılan konular olarak öne çıkmaktadır. Şirket, entegrasyon özellikleri için duygu analizi yaparak ürün tekliflerini geliştirebilir, güçlü ortaklıklar kurabilir ve nihayetinde müşteri memnuniyetini ve sadakatini artırabilir. Ayrıca, bir markanın sosyal medya iletişim başarısını artırmak için bağlama özgü stratejiler sağlamak da mümkün olabilir (Xu vd., 2021). Örneğin, müşterilerin belirli konular hakkında olumsuz düşünceleri varsa, sosyal medyadaki anketler aracılığıyla doğrudan müşteri geri bildirimi alınabilir. Bu nedenle, büyük veriyi bilgiye dönüştürmek için pazarlama analitiğinin başarılı bir şekilde uygulanması, şirketlerin rekabet avantajı elde etmesini sağlayacaktır (Dam vd., 2019). Yapılandırılmamış veriler, maksimum müşteri deneyimi, pazarlama kararları ve maksimum yatırım getirisi (ROI) sağlayan tahmine dayalı modelleme teknikleri (Wedel & Kannan, 2016) için girdi olarak kullanılabilir (Iacobucci vd., 2019). Metin madenciliği tekniklerinden elde edilen konular, regresyon modelleri için potansiyel bağımsız değişkenlerin belirlenmesini sağlayabilir. Bu konular, duyarlılık puanları veya frekans sayıları gibi nicel ölçümlere dönüştürülebilir ve bağımlı değişkendeki varyasyonları açıklamak için tahmin edici olarak kullanılabilir. Hangi konuların (ürün nitelikleri) en fazla memnuniyete yol açtığını belirlemek ve uygun stratejiler geliştirmek satış başarısını artırabilir. Sonuç olarak, şirketlerin yapılandırılmış ve yapılandırılmamış tekniklerin

bir kombinasyonunu kullanarak pazarlama analitiğine sistematik olarak yatırım yapması gerekmektedir (Wedel & Kannan, 2016).

Tüm bu bilgiler ışığında BERTopic, genel ve özel konuları aynı anda çıkarma başarısı ve metodolojik uygulamadaki esnekliği nedeniyle tavsiye edilebilir. Öte yandan, BERTopic'in güçlü yönü, gömülü modellerin kapsamlı koleksiyonunda yatmaktadır. Ayrıca, BERTopic tarafından üretilen çıktılar, karar vericiler ve paydaşlar için yönetici özeti raporlarına dahil edilebilecek çok çeşitli görselleştirme olanakları sunmaktadır.

Araştırmacılar arasında, ürünleri veya pazarlama mesajlarını müşteriler için özelleştirmek amacıyla makine öğreniminden (Petrescu & Krishen, 2023) yararlanmaya yönelik artan ilgiye yanıt olarak, çalışmamızda farklı konu modelleme algoritmaları uygulanmış ve bunların pazarlama alanındaki metodolojik ve pratik etkileri tartışılmıştır. Daha açık olmak gerekirse, genellikle makine öğrenmesine aşina olduğunu varsayan önceki çalışmaların aksine, bu araştırma özellikle bu gelişmiş tekniklere aşina olmayan pazarlama araştırmacılarını hedeflemektedir. Çalışmamız, farklı konu modelleme algoritmalarını ve bunların pratik pazarlama senaryolarındaki performanslarını kapsamlı bir şekilde değerlendirmektedir. Her bir algoritmanın güçlü yönlerini ve sınırlamalarını değerlendirmekte ve pazarlama analitiğini nasıl etkileyebileceklerine ışık tutmaktadır. Sonuçların titiz bir şekilde karşılaştırılması ve analiz edilmesi yoluyla, pazarlamacılara net ve uygulanabilir öneriler sunmayı amaçlamıştır.

2.6. Sonuç

Konu modellemenin artan popülaritesine rağmen, bu yöntemler de temsil edilebilirlik ve güvenilirlik açısından önemli zorluklar içermektedir (Vayansky & Kumar, 2020). Bu nedenle, bu tekniklerin karşılaştırılması, birbirlerine göre göreceli üstünlüklerinin tanımlanmasında çok önemli hale gelmektedir. Bu araştırma, dört konu modelleme algoritmasının bulgularını karşılaştırarak, müşteri yorumları gibi yapılandırılmamış metinlerden ilgili bilgileri çıkarmanın zorluğunu ele almaktadır.

Çeşitli nedenlerden dolayı, müşterilerin bir şirketin ürünleri veya hizmetleri hakkında ne söylediklerini anlamak çok önemlidir (Jones & Sasser, 2009). Konu modellemesi, farklı konularla ilişkili duyarlılığın belirlenmesine yardımcı olabilir ve şirketin müşterilerin olumlu, olumsuz veya nötr görüşler ifade edip etmediğini ölçmesine

olanak tanır. Müşteri duyarlılığının bu şekilde anlaşılması, pazarlama stratejilerinin rafine edilmesi ve ürün ya da hizmetlerin iyileştirilmesi için çok önemlidir (Kauffmann vd., 2019). Şirketler, kullanıcı tarafından oluşturulan içeriği analiz ederek müşterilerinin tercihlerini ve önceliklerini ortaya çıkarabilir (Abbasi vd., 2019). Konu popülaritesindeki değişikliklerin izlenmesi, duygular, anahtar kelimeler sürekli iyileştirmeye göre ayarlanabilir. Olumsuz duygular müşterilerin memnun olmadığı noktalara hitap ettiğinden, yeni özellik geliştirme veya ürün inovasyonu stratejileri uygulanabilir. Konulara yönelik olumlu duygular müşteri memnuniyetini ele aldığından, şirketler müşterilerin memnun olduğu bu konularla uyumlu içerikler oluşturabilir. Metin madenciliği tekniklerinden elde edilen konuların kullanılması, müşteri anlayışını, bağlılığını ve ilişki yönetimini geliştirerek müşteri yaşam boyu değerinin (CLV) artırılmasına katkıda bulunabilir. Bu konu başlıkları insan kişiliğinin karakteristik özellikleriyle uyumlu olduğundan (Lopez vd., 2020), bu bilgiler hedefli kampanyalar oluşturmak, pazarlama mesajlarını ayarlamak ve kişiselleştirilmiş deneyimler sunmak için kullanılabilir.

Şirketler, konu modellemesinden çıkarılan konuları yalnızca müşteriler için değil, kendi sistemlerini geliştirmek için de kullanabilir. Örneğin, destek veya bakım departmanlarıyla ilgili bir konunun ortaya çıkması, şirketin bu alandaki stratejisini belirleyebilir, çalışanlar için eğitim materyalleri geliştirebilir ve müşteri destek stratejilerini rafine edebilirler. Ayrıca, konu modellemesi, şirketlerin müşterileri arasında ortaya çıkan eğilimleri ve ilgi çeken konuları belirlemelerine yardımcı olabilir. Bu öngörü, işletmelerin rekabette bir adım önde olmalarını ve stratejilerini değişen tüketici taleplerini karşılayacak şekilde uyarlamalarını sağlar (Fang vd., 2008). Şirketler, kullanıcı yorumlarına ve geri bildirimlerine önem vererek müşterilerinin görüşlerine değer verdiklerini gösterirler. Müşterilerin endişeleri ve önerileri ile ilgilenmek sadakati teşvik eder ve marka-müşteri ilişkisini güçlendirir (So vd., 2014).

LDA'dan elde edilen sonuçlar geleneksel olarak kabul edilebilirken, BERTopic ve Top2Vec genellikle belirlenen konular arasında net ayrımlar üretir. SBERT bazı durumlarda etkili olabilir, ancak bazı anahtar kelimeler önemsiz ve yorumlanması zor görünmektedir. Metodolojik açıdan BERTopic daha az çalışma gerektirmiş ve pratikte bu çalışmada kullanılan müşteri yorumları için en faydalı sonuçları vermiştir. Ancak, diğer algoritmaların çıktılarındaki belirgin farklılıklar göz önünde bulundurulduğunda,

pazarlama araştırmacılarına tüm yöntemleri denemeleri tavsiye edilir. Ayrıca şirketler, ürün geliştirme sürecinin aşamalarına bağlı olarak farklı algoritmalar uygulayabilir.

Sonuç olarak, en uygun tekniğin seçimi, veri türü, özel kullanım durumu, hesaplama kaynakları ve kolayca yorumlanabilir konular veya nüanslı ve doğru anlamsal temsiller gibi istenen sonuç dahil olmak üzere birçok kritik faktöre bağlıdır. Pazarlama araştırmacıları olarak, analizin kendine özgü taleplerine göre farklı algoritmaların kullanılmasını savunuyoruz. Çalışmamızda BERTopic, anlamsal ilişkilerin karmaşıklığı ile hesaplama verimliliği arasında bir denge sağlayarak en uygun seviyede durmaktadır.

2.7. Sınırlılıklar ve Gelecek Araştırmalar

Tüm çalışmalarda olduğu gibi bu araştırmanın da bazı sınırlamaları bulunmaktadır. Konu modelleme yöntemleri farklı özelliklere sahiptir (Abdelrazek vd., 2022). Yeni çalışmalarda, pazarlama akademisyenleri farklı konu modelleme yöntemleri (Vasudeva Raju vd., 2022) veya yeni ön eğitimli modeller (ör. PhraseBert) (H. Cheng vd., 2023) kullanmaya teşvik edilebilir; bu çalışma dört konu modelleme algoritmasını değerlendirmiştir.

Son yıllarda piyasada akıllı asistanlara olan ilgi giderek artmaktadır. Bu ürün kategorisinin yaygın popülaritesine ve çok sayıda marka tarafından akıllı asistanların piyasaya sürülmesine rağmen, bu çalışma yalnızca bir markanın incelemelerine odaklanmaktadır. Farklı markaların ürünlerini analiz ederek, kullanıcıların farklı markalar için hangi konuları tartıştığını bulmak mümkündür. Şirketler, duygu analizi de yaparak bu çıktıyı rekabet analizinde kullanabilir ve önemli içgörüler elde edebilir.

Alexa yapay zekaya dayalı teknik bir ürün olduğu için yorumların içeriği ve yorumları yazan müşterilerin profili, teknik anlayış ve becerilerine göre diğerlerinden farklılık gösterebilir. Bu veri kümesinde, müşteri yorumlarının çoğu uzun ve ayrıntılıdır. Bu durum, algoritmaların anlamlı konular çıkarmasını sağlayabilir. Gelecekte yapılacak araştırmalarda, akademik araştırmacılar farklı metodolojileri karşılaştırmak ve incelemelerin içeriğinin veya müşteri profillerinin analiz edilen ürün türünü etkileyip etkilemediğini görmek için farklı ürün türlerine odaklanabilir. Bu hipotez, müşteriler tarafından yazılan incelemelerin kalitesinin içerik ve dilbilgisi açısından büyük önem taşıdığı gerçeğine dayanmaktadır (Christodoulides vd., 2012).

Ayrıca, konu modelleri birden fazla dil içeren bağlamlar için oluşturulmamıştır. Örneğin, müşteri yorumlarında sıklıkla birkaç dil kullanılır (bu veri kümesinde öncelikle "İspanyolca" diline rastlanmıştır). Bu dilsel ipuçlarını belirleme ve kullanma becerisi geliştirmek, gelecekteki bir diğer araştırma yönü olabilir (Churchill & Singh, 2022).

3. YENİ ÜRÜN GELİŞTİRME SÜREÇLERİNDE ELEKTRONİK AĞIZDAN AĞIZA PAZARLAMANIN ANLAMLILIĞI: İKİ SANAL ASİSTAN MODELİ ÜZERİNDEN İNCELEME

3.1. Giriş

Şirketlerin, müşterilerine yeni veya geliştirilmiş ürünler sunabilmeleri için müşterilerin sesine özellikle dikkat etmeleri gerekmektedir (Gensler vd., 2015). Bu nedenle şirketler, ürün veya hizmet çözümlerini satın alarak veya kiralayarak ihtiyaçlarını karşılamak isteyen müşterilerle doğrudan veya dolaylı olarak etkileşim halinde bulunmak durumundadırlar (Griffin & Hauser, 1993). Birlikte-yaratım (Co-creation) adı verilen bu kavram, şirketlerin müşterilerinin fikirlerini, yeni ürünler yaratırken dikkate almasıdır (Ramaswamy & Ozcan, 2018). Starbucks firmasının "Siz inşa edin, onlar da gelsinler" (built it and they will come) yerine, "Onlarla inşa ederseniz, zaten orada olurlar" (building it with them and they are already there) fikrini benimseyip müşteri sadakatini arttırması ve yeni ürünlerin pazarda tutunmama riskini azaltması gayet açıklayıcı bir "Birlikte Yaratım" tanımı olarak karşımıza çıkmaktadır (Ramaswamy, 2009).

Birlikte yaratım ve ağızdan ağıza pazarlama, birbirini destekleyen süreçlerdir ve şirketlerin müşteri odaklı inovasyon ve rekabetçi avantaj yakalamalarında kilit role sahiptir (R. Thakur, 2018). Müşteri geribildirimi, üzerinde yoğunlaşılması gereken değerli bir içgörü kaynağıdır ve EAAP, müşterilerin markalar hakkındaki deneyimlerini geniş kitlelere ulaştırmalarına olanak tanımaktadır (Hennig-Thurau & Walsh, 2003). Dijital platformlar, EAAP'yi fikir ve geri bildirim kaynağı olarak kullanarak ürün inovasyon süreçlerinde müşteri katılımını kolaylaştırır (Sawhney vd., 2005). Ancak, bu sürecin başarısı, müşterilerle açık ve etkileşimli bir iletişim kurulmasına, karmaşık veri yönetimine ve EAAP'nin olumsuz etkilerinin etkin bir şekilde yönetilmesine bağlıdır (Kohli & Johnson, 2011; V. Wangenheim & Bayón, 2007; Vargo & Lusch, 2014).

Günümüzde işletmelerin ve çevrimiçi hizmet sağlayıcılarının kullanımına sunulan büyük miktarda müşteri verisi üretilmektedir (Constantinides & Lorenzo-Romero, 2015). "Büyük Veri" adı verilen bu devasa bilgi kümesi yeni ürün geliştirme süreçlerinde kullanılmakta (Constantinides vd., 2015), pazarlama alanında hem müşteriler hem de şirketler için değer yaratmaktadır (Kunz vd., 2017). Büyük verinin etkin kullanımı ve metin madenciliği teknikleri, müşteri yorumları ve tepkileri hakkında hızlı ve doğru içgörüler ortaya koymakta (Pantano vd., 2019), böylelikle firmaların, tüketicilerin EAAP'sine daha hızlı tepki verebilmesine olanak sağlamaktadır (Mustak vd., 2021). Bir metin madenciliği tekniği olan konu modelleme, metin dokümanı içerisinde geçen konuları keşfetmek için kullanılan yaygın bir yöntemdir (Blei vd., 2003; Grootendorst, 2021). Kar & Dwivedi (2020) tarafından önerilen gelecek araştırma sorularından bir tanesi, kullanıcılar tarafından oluşturulan içeriklerin veri işleme teknikleri kullanılarak, ürüne dair kullanım motivasyonlarını (olumlu ve olumsuz etkilerini) nasıl analiz edilebileceğidir. Bu çağrıya cevap vererek, bu çalışmada, Amazon Echo Show 5 ve Amazon Echo Show 8 müşteri yorumları üzerinden müşteri memnuniyetini ve ürün özellikleriyle ilgili geri bildirimleri analiz edilerek, şirketlerin bu bilgileri ürün geliştirme sürecine nasıl dahil ettikleri sorgulanmaktadır. İşletmelerin, yeni ürün geliştirme süreçlerinde, müşteriler tarafından beğenilen ürün özelliklerini geliştirmeye odaklanıp odaklanmadıkları veya müşteri memnuniyetsizliği yaratan özelliklere yönelik iyileştirme çabalarını artırıp artırmadıklarını büyük veri üzerinden analiz ederek keşfetmek, bu çalışmanın temel araştırma konusudur.

Bu çalışma literatüre farklı katkılar sağlamayı amaçlamaktadır. İlk olarak, konu modelleme, duygu analizi ve fırsat analizi metotlarını tek bir çalışmada sentezleyerek metodolojik bir katkı sunmayı amaçlamaktadır. İkinci olarak aynı ürünün pazara sürülen iki farklı versiyonunun büyük veri üzerinden incelenmesiyle, farklı ürün modellerinin müşteri gözündeki algıları, memnuniyet düzeyleri ve tercihleri üzerindeki etkisi ampirik olarak değerlendirilmiştir. Bu şekilde, ürün geliştirme süreçlerinde EAAP'nin anlamlılığını ortaya koyarak, müşteri geri bildirimlerinin nasıl değerlendirildiğine dair kapsamlı bir anlayış sağlamaktadır. Son olarak, yapılan fırsat analizi çalışması, sanal asistan ürünü üzerine şirketin müşteri odaklılık düzeyini anlamak için önemli bir yaklaşım sunmaktadır.

Bu çalışma şu şekilde yapılandırılmıştır: Literatür Taraması bölümü ikiye ayrılmıştır; ilk bölümde ürün geliştirme süreçlerinde elektronik ağızdan ağıza pazarlama üzerine, ikinci bölümde büyük veride metin madenciliği ve duygu analizi üzerine yapılmış çalışmalara yer verilmiştir. Veri ve Metodoloji bölümünde, detayları ifade edilen veri toplama sürecinin ardından, BERTopic Konu Modelleme yöntemi ile Duygu Analizi yöntemi anlatılmaktadır. Bulgular bölümünde, Konu Modelleme ve Duygu Analizi çıktılarına yer verilmiş ve son olarak bu çıktıları kullanarak Fırsat Analizi sonuçları verilmiştir. Sonuç bölümünde çalışmanın sonuçları tartışılmakta ve son olarak, pazarlama araştırmacıları için Sınırlılıklar ve Gelecek Çalışmalar sunulmaktadır.

3.2. Literatür Taraması

3.2.1. Ürün Geliştirme Süreçlerinde EAAP

Ağızdan Ağıza Pazarlama, Westbrook (1987) tarafından, bir ürün ya da hizmetin satın alınmasından sonra, o ürün veya hizmetin sahipliği, kullanımı veya karakteristikleri ve/veya onların satıcıları hakkında diğer tüketicilere yönelik olarak yapılan, konuşma dilinde gerçekleşen resmi olmayan iletişimler olarak tanımlanmıştır. Ağızdan ağıza pazarlama (AAP) adı verilen bu iletişim yöntemi, müşteri davranışı üzerindeki güçlü ve güvenilir etki olarak kabul edilmektedir (P. Gupta & Harris, 2010). Müşterilere görüşlerini, deneyimlerini, eleştirilerini ve önerilerini internet üzerinde ifade etme olanağı sağlayan Web 2.0 teknolojisinin hayatımıza girmesiyle birlikte ise, müşteriler için, yüzyüze iletişim kadar elektronik ortamlarda iletişim de yaygınlaşmıştır (Nawaz vd., 2021). Elektronik ağızdan-ağıza pazarlama (EAAP) olarak tanımlanan fenomen ise, "potansiyel, mevcut veya eski müşteriler tarafından bir ürün veya şirket hakkında yapılan ve internet aracılığıyla çok sayıda kişi ve kurumun erişimine sunulan olumlu veya olumsuz her türlü açıklama" olarak ifade edilmektedir (Hennig-Thurau & Walsh, 2003). Markalar için, odak gruplar ve anketler yerine, artık sosyal medyada ve pazaryerlerinde müşterilerin yaptığı yorumları incelemek, kullanıcı fikirlerinin toplanmasında yeni ve yaratıcı bir yoldur. İnternet ve sosyal medya platformlarının ortaya çıkışı, ürün tavsiyeleri ve incelemeleri için elektronik ağızdan ağıza pazarlama kullanımında önemli bir artışa yol açmıştır. Bu durum yeni ürün geliştirme süreci üzerinde önemli bir etki yaratmış, işletmeler pazarla ilgili içgörü kazanmak, ses getirmek ve satışları artırmak için elektronik ağızdan ağıza pazarlamanın gücünden yararlanmak istemiştir.

Cheung & Thadani, (2012) EAAP literatürünü pazar düzeyinde ve tüketici düzeyinde kategoriler halinde sınıflandırmıştır. Bu durumda elektronik ağızdan ağıza fenomeni hem şirketlerin hem de müşterilerin perspektifinden araştırılabilmektedir. Kullanıcıların, ürünler veya hizmetler hakkında yaptığı birinci ağızdan yorumlar en gerçekçi pazarlama kanalını oluşturmaktadır. Bu sayede, bu yorumlar yalnızca diğer potansiyel müşterilere fikir vermekle kalmamakta aynı zamanda şirketlerin piyasaya sürdüğü ürünlerin gerçekten bir değeri olup olmadığını da göstermektedir. Şirketlerin yeni ürün geliştirme (New Product Development-NPD) süreçlerinde aktif olarak müşterileri entegre etmesindeki anahtar nokta, nitelikli müşterilerin fikirlerini ve bilgilerini açık bir şekilde şirketle paylaşmaya istekli olduklarında ve müşterilerin mevcut ürünleri ve yeni fikirleri değerlendirdikleri durumlarda birlikte-yaratımın işe yaramasıdır (Füller, 2006). Bu nedenle şirketler, müşterinin ihtiyaçlarını karşılamak üzere çözümün nasıl uygulanabileceğini anlamak için geliştirme sürecinde müşterilerle mutlaka iletişim kurmalıdır (Ogawa, 1998). Bu doğrultuda, şirketler tarafından yürütülen araştırma- geliştirme (AR-GE) ve pazarlama yaklaşımları, doğal olarak müşteri ihtiyaç analizine büyük önem vermektedir (Jeong vd., 2017). Müşteri ihtiyaç ve beklentilerini analiz ederek, yeni veya cazip ürün fırsatlarının erkenden belirlenmesi, yeni ürün geliştirme veya ürün iyileştirme sürecinde ilk ve kritik gereklilik olarak kabul edilir (van Kleef vd., 2005). Bunun nedeni, bu tür fırsatların erken tespit etmenin rakip şirketler tarafından kolayca kopyalanamayacak benzersiz ve özelleştirilmiş bir ilişki yaratmasını ve dolayısıyla şirketin değer zincirinde rekabetçi kalmasını sağlamaktır (H. Park & Yoon, 2015).

Araştırmalar, EAAP iletişiminin yeni ürün geliştirme süreci üzerinde önemli bir etkiye sahip olduğunu göstermiştir (Andreassen & Streukens, 2009). Çünkü işletmeler, müşterilerin tercihleri ve fikirleri hakkında müşterilerin verdiği geri bildirim ve karşılıklı etkileşim üzerine fikir alışverişinde bulundukları sürece bir değer yaratabilirler (Gruen vd., 2006). Bu, müşterilerin ihtiyaçlarını doğru yansıtacak şekilde ürünlerin veya hizmetlerin geliştirilmesi ve gerçekleştirilmesine katkıda bulunur (Mascarenhas vd., 2006). Ayrıca, işletmeler için EAAP, yeni ürünlere yönelik müşteri ihtiyaçları, tercihleri ve beklentileri hakkında içgörü toplamaları için önemli bir bilgi kaynağı olarak görülmektedir (Andreassen & Streukens, 2009). Pazarlamacıların, EAAP iletişimini analiz ederek ve ürün ve hizmetlerin etkinliğini görerek aksiyon almaları, yeni ürün geliştirme süreçlerini olumlu etkilemektedir (Serra Cantallops &

Salvi, 2014). Elektronik ağızdan ağıza pazarlama fenomeni iletişim bağlamı, bilginin yayılma hızı, iletişimde anonimlik ve gizlilik gibi çeşitli açılardan geleneksel ağızdan ağıza pazarlamadan farklılaşmakta ve bulunduğu dijital ortam gereği, ölçülebilir çıktılar sağlamaktadır (Bhaiswar vd., 2021). Böylelikle şirketler artık müşterilerin ne istediğine dair daha net öngörüler geliştirebilmektedir.

Y. Zhao vd.'ne (2020) göre, EAAP ürün özellikleri, fiyat noktaları ve ürün kalitesi hakkında değerli geri bildirimler sağlayabilir ve bu da işletmelerin ürün geliştirme sürecinde bilinçli kararlar almasına yardımcı olabilir. Ürüne verilen puan, yıldız sayısı, yapılan yorum, yorumun beğenilme sayısı gibi pek çok ölçülebilir kriter, şirketlere ilgili ürün/hizmet bağlamında atacakları her adımda yol gösterici veriler sağlamaktadır. Yeni ürün geliştirme sürecinde EAAP kullanımının işletmeler için önemli sonuçları vardır. İlk olarak, ürünler hakkındaki çevrimiçi konuşmaları izlemenin ve yönetmenin önemi vurgulanabilir. Bu, müşteri geri bildirimlerine yanıt vermeyi, şikayetleri ele almayı ve sosyal medya platformlarında müşterilerle etkileşim kurmayı içerir. İkinci olarak, işletmelerin müşteri ihtiyaçları ve tercihleri hakkında bilgi edinmek için EAAP iletişiminin pazar araştırma faaliyetlerine dahil edilmesi gerekmektedir.

Günümüzün modern iş dünyasında, olumlu EAAP, müşterileri çekmek ve sürdürmek için daha önemli hale gelmektedir (Noraini vd., 2016). İnternet ve sosyal medya platformlarının yaygın kullanımıyla birlikte, müşteriler artık ürün ve hizmetler hakkında çevrimiçi yorumları ve deneyimleri paylaşmaktadır, bu da diğer tüketiciler üzerinde önemli bir etkiye sahiptir (McFadden & Train, 1996). Yapılan pek çok araştırma, çevrimiçi sitelerde yapılan ağızdan ağıza pazarlamanın, müşterilerin satın alma davranışını etkilediğini ortaya koymuştur (Chatterjee, 2001, 2006; Cheung & Thadani, 2012; Chevalier & Mayzlin, 2006; P. Gupta & Harris, 2010; Hennig-Thurau & Walsh, 2003; D. H. Park vd., 2007). Bu bağlamda, işletmelerin müşteri memnuniyetini artırmak ve sadık bir müşteri kitlesi oluşturmak için EAAP'yı etkili bir şekilde yönetmeleri gerekmektedir.

Müşteri geri bildirimlerine hızlı ve doğru bir şekilde yanıt vermek, olumlu deneyimleri teşvik etmek ve olumsuz deneyimleri ele almak, işletmelerin itibarlarını güçlendirmek ve rekabet avantajı sağlamak için kritik öneme sahiptir (Knudsen, 2007). Sonuç olarak, birlikte yaratım aracı olan EAAP'nin önemi giderek artmakta ve işletmelerin başarısı için vazgeçilmez bir unsura dönüşmektedir.

3.2.2. Büyük Veride Metin Madenciliği ve Duygu Analizi

Tüketiciler, internet üzerinde yer alan bloglar, sosyal ağ siteleri, web siteleri, hayran grupları, forum siteleri gibi pek çok platform üzerinde, aldıkları hizmet ve ürünlere dair yorumlarını paylaşabilmektedir (Wattegama & Qing, 2014). Alıcılar ve satıcılar arasında aracı olarak hizmet veren elektronik pazar yeri siteleri (Bakos, 1991) ise, kullanıcılara ve şirketlere tek bir platform üzerinden binlerce ürüne ve ürünlere dair olumlu/olumsuz yorumlara erişme imkânı sunmaktadır. Tüm bu platformlar sayesinde oluşan bu dijital arşivler, insan düşünce ve davranışlarını yansıtmaktadır ve hesaplama gücünün üstel büyümesiyle birleştiğinde, pazarlama biliminde büyük veri analitiği ve metin madenciliği algoritmalarını kullanan yeni bir çalışma grubunun ortaya çıkmasına neden olmuştur (Lucini vd., 2020; Ordenes vd., 2014; Chung vd., 2022; Jia, 2018; Agrawal & Mittal, 2022). Bu yeni araştırma yaklaşımı, müşteri yorumlarını daha etkili bir şekilde toplamak, işlemek, analiz etmek, görselleştirmek ve yorumlamak için Doğal Dil İşleme (NLP), makine öğrenimi yöntemleri ve metin madenciliği algoritmalarını kullanmaktadır (Elragal & Klischewski, 2017).

Çevrimiçi yorumlar sosyal medyada, şirketlerde ve üçüncü taraf web sitelerinde yığıldıkça, değerli bilgilerin elde edilmesi daha zor hale gelmektedir. Konu modelleme algoritmaları, kapsamlı yapılandırılmamış metin verilerine gömülü gizli topikal kalıpları çıkarma yetenekleri nedeniyle (Albalawi vd., 2020) son zamanlarda önemli ölçüde popülerlik kazanmıştır (Egger & Yu, 2022; Luo vd., 2020). Duygu analizi, bir konuşmacının veya yazarın bir konuya ilişkin tutumunu veya bir belgenin genel metinsel kutupluluğunu belirlemeyi amaçlamaktadır (W. Wang vd., 2017). Fırsat Analizi ise, şirketler için müşterilerinin ne ölçüde aşırı ve yetersiz hizmet aldığının görselleştirilmesine yardımcı olan çok değerli bir araçtır (A. W. Ulwick, 2002).

Wang vd. (2018) çalışmalarında, bir müşterinin, ürün yorumlarına göre bir satın alma işleminden memnun olup olmadığını duygu analizi yoluyla çıkarmaya çalışmışlardır. Rathore & Ilavarasan (2020) ise yeni ürün geliştirme konusundaki çalışmalarında, duygu analizini yeni ürün lansmanı öncesi ve sonrası açısından değerlendirmek için kullanmıştır. Ozansoy Çadırcı vd. (2022) havayolu sektöründe servis geliştirme fırsatlarını belirlemek üzere metin madenciliği ve duygu analizinden faydalanmışlardır. Konu modelleme ve duygu analizi çalışmalarının çoğu turizm ve seyahat sektörüne odaklanmış olsa da birkaç çalışma farklı sektörlerdeki müşteri

yorumlarını konu modelleme ile analiz etmiştir. Wu & Chang (2020) araştırmalarında, Tayvan'daki küresel ve yerel çevrimiçi perakendecilerin yorumlarını analiz ederek konu modelleme ile yedi konu elde etmişler ve duygu analizinden yararlanarak hem uluslararası hem de yerel perakendeciler için farklı tüketici duygularını tanımlamışlardır. Christian vd. (2015) 10 tane çevrimiçi forum sitesinde 115,000 adet yorum üzerinde duygu analizi yaparak, tüketicilerin, çevrimiçi bir topluluk ortamında şirketin tüketiciden tüketiciye konuşmaların aktif katılımına nasıl tepki verdiğinin incelemiştir. Baek vd. (2012) Amazon.com'dan edindikleri 75,726 adet yorum üzerinde çevrimiçi değerlendirmelerin yararlılığını belirleyen faktörleri ve hangi faktörlerin yararlı çevrimiçi değerlendirmeler için daha önemli olduğunu araştırmıştır.

Bu çalışmaların çeşitliliği, müşteri yorumlarının işletmeler için ne kadar önemli bir veri kaynağı olduğunu ve doğru analiz yöntemleri kullanıldığında değerli içgörüler sağlayabileceğini göstermektedir (van Kleef vd., 2005). Bu yöntemlerin pazarlama alanındaki kullanımları yaygınlaştıkça, işletmelerin müşteri geri bildirimlerini daha etkili bir şekilde anlamalarına ve ürün ve hizmetlerini iyileştirmek için bilgilendirilmiş kararlar almalarına yardımcı olabilir.

3.3. Veri ve Metodoloji

Amazon Alexa, Amazon tarafından geliştirilen, yapay zekâ temelli bir sanal asistandır. Bu platformun donanım alt yapısını sağlayan Amazon Echo ise, çeşitli görevleri gerçekleştirmek için kullanıcılarından sesli komutlar alabilen bulut özellikli ilk kablosuz hoparlördür. Bu sistemler kullanıcın sesi vasıtasıyla, bir soruyu yanıtlama, önerilerde bulunma gibi eylemler gerçekleştirerek kullanıcılara yardım sağlamaktadır. (Hauswald vd., 2015). Bu çalışmada kullanılan veriler, Haziran 2020 ve Temmuz 2021 tarihleri arasında Best Buy platformunda yer alan Amazon Echo Show 5 ve bir üst modeli olan Amazon Echo Show 8 ürününe ilişkin müşteri yorumlarından elde edilmiştir. Best Buy platformu, ABD'deki en büyük elektronik perakendecilerinden biridir. Ayrıca platform, müşteri ve uzmanlar tarafından yazılan incelemeler, yıldızlar, puanlar ve ürün kalitesi, kullanım kolaylığı ve değerinin nicel analiziyle birlikte, ürüne dair artılar ve eksiler listesi de dahil olmak üzere çok boyutlu yorum bilgileri sağlamaktadır.

Veri toplama Temmuz 2021'de gerçekleştirilmiştir. Tüm veri toplama ve analiz işlemleri Python programlama dilinde yapılmıştır (Guido & Drake, 2009). Müşteri

yorumları internette halka açıktır ve erişilebilir. Best Buy'dan veri çekmek için Pandas (McKinney, 2011) ve BeautifulSoup (Richardson, 2019) Python kütüphaneleri kullanılmıştır. Web sitesi kazıma (Web site scraping) yöntemiyle ihtiyaç duyulan veriler alınmış ve excel dosyası olarak kaydedilmiştir.

Şekil 24: Amazon Echo Show 5 Görseli



Amazon Echo Show 5 ürününe dair 12,452 yorum çekilmiştir. Bunların 56 adedi, muhtemelen sistemsel bir hata nedeniyle veri kümesinde iki kere yer aldığı için mükerrer olarak kalmıştır. O nedenle dosyadan 58 adet mükerrer olan yorum silinmiştir. Veri analizinde 12,452-56=12,394 müşteri yorumu kullanılmıştır.

Şekil 25: Amazon Echo Show 8 Görseli



Amazon Echo Show 8 ürününe dair 5,386 yorum çekilmiştir. Bunların 22 adedi, muhtemelen sistemsel bir hata nedeniyle veri kümesinde iki kere yer aldığı için mükerrer olarak kalmıştır. O nedenle dosyadan 22 adet mükerrer olan yorum silinmiştir. Veri analizinde 5,386-22=5,364 müşteri yorumu kullanılmıştır.

Bu iki farklı veri kümesi üzerinde yapılan tüm analizler, Google Colab programı üzerinde, 3.8.8 sürümlü (*Python 3.8.8*, 2021) Python dili kullanılarak yapılmıştır. Tezin ilk çalışmasında, en uygun konu modelleme yöntemi olarak belirlenen BERTopic yöntemi kullanılmıştır. BERTopic konu modelleme tekniği ve duygu analizi teknikleri kullanılarak iki veri seti karşılaştırılmıştır.

3.3.1. BERTopic Konu Modelleme Tekniği

Çevrimiçi bilgi biriktikçe, bu bilgi içindeki temel konuları veya temaları anlamak öncelikli bir sorun haline gelmiştir. Konu modelleme tekniği, metin madenciliğinin bir alt dalıdır. Bir metinde yer alan gizli veya açık yapıları ortaya çıkarmak zor bir iştir ve konu modelleme bunu yapmaya olanank sağlayan bir tekniktir (Blei vd., 2003; Hannigan vd., 2019; Ozansoy Çadırcı vd., 2022). Konu modelleme, genel olarak, araştırmacıların büyük ölçekli veri setlerinin, özellikle de metinsel verilerin bağlamını düzenlemelerine ve tanımlamalarına yardımcı olur (Vayansky & Kumar, 2020). Ayrıca, bu algoritmalar bu belgelerin konular şeklinde bir özetini oluşturur (Churchill & Singh, 2022).

En eski ve en sık uygulanan konu modelleme yöntemlerinden biri, 2003 yılında Blei, Ng ve Jordan tarafından geliştirilen "Latent Dirichlet Allocation" (LDA) yöntemidir (Blei vd., 2003). LDA, her kelimeyi tek bir vektör olarak temsil eden ve her belgenin farklı konuların bir kombinasyonu olduğunu varsayan bir kelime bulutu yaklaşımı kullanır. Kelime bulutu yaklaşımı güçlü olmasına rağmen, kelimeler arasındaki olası anlamsal ilişkilerin göz ardı edilmesi gibi belirli sorunlar yaratmaktadır (Grootendorst, 2022; Ren vd., 2016).

Son yıllarda, nöral konu modelleri, mevcut konu modelleme yöntemlerini geliştirmek için nöral ağların kullanılmasında giderek daha etkili olmaktadır (Grootendorst, 2022; Larochelle & Lauly, 2012; H. Zhao vd., 2021). Sinirsel konu modelleri, sinir ağlarını olasılıksal üretken süreçlerle birleştirerek daha kolay hesaplama sağlar ve LDA gibi klasik tekniklerin optimizasyon sorununun üstesinden gelir (Doan & Hoang, 2021). Gömme modellerine odaklanan konu modelleme yöntemlerindeki son gelişmeler,

gömme tabanlı konu modelleme yöntemlerinin potansiyelini göstermektedir (Bianchi vd., 2021; Dieng vd., 2020; Grootendorst, 2022; Thompson & Mimno, 2020). Yerleştirme tabanlı bir konu modelleme tekniği olan BERT, her çıkış öğesini her giriş öğesine bağlamak için cümle yapısını her iki yönden de kullanan ve bu bağlantıya bağlı olarak ağırlıkları dinamik olarak ayarlayan bir dil modelidir. BERTopic, konu açıklamalarında önemli kelimeleri tutarken kolay yorumlanabilir konulara izin veren yoğun kümeler oluşturmak için BERT yerleştirmelerini ve c-TF-IDF'yi kullanan bir konu modelleme tekniğidir (Grootendorst, 2021). BERTopic tekniği üç aşamada gerçekleşmektedir:

1- Belge Yerleştirme: İlk olarak, doküman seviyesinde bilgi elde etmek için, önceden eğitilmiş dil modeli kullanarak doküman yerleştirmeleri yaratılır (Reimers & Gurevych, 2019).

2- Belge Kümeleme: İkinci olarak, her biri ayrı bir konuyu ifade eden dokümanların semantik olarak benzer kümelerini yaratmadan önce, doküman yerleştirmelerinin boyutu düşürülür. Yerleştirme boyutunu azaltmak için Düzgün Manifold Yaklaşım ve Projeksiyonu (UMAP) (McInnes vd., 2018) ve semantik olarak benzer belgeleri kümelemek için HDBSCAN (McInnes vd., 2017) kullanılır.

3- Konu Temsili Oluşturma: Üçüncü olarak, merkez tabanlı perspektifi aşmak için, her bir konudan, konu temsillerini çıkarabilmek için sınıf tabanlı c-TF-IDF ile konular ayıklanır ve azaltılır (Grootendorst, 2022).

Yerleştirme modeli olarak, iyi bir kalite sağlayan ve 1 milyardan fazla eğitim çiftinden oluşan geniş ve çeşitli bir veri kümesinde eğitilen ve en hızlı olan, 384 boyutlu "all-MiniLM-L6-v2" modeli kullanılmıştır. Sonrasında, doküman vektörlerinin daha düşük boyutlu yerleştirmelerini yaratabilmek için umap-learn 0.5.3 paketi uygulanmıştır. Bu çalışmada vektörler 10 boyuta düşürülmüş ve veri noktaları arasındaki mesafe kosinüs benzerliği ile ölçülmüştür. Pek çok deneme sonrası en yakın komşu değerinin 50 olarak belirlendiğinde en iyi sonuç vermesi nedeniyle, bu değer ile ilerlenmiştir. Kümeleme işlemi içinse, hdbscan 0.8.29 paketi kullanılmış ve en düşük küme değerini 45 olarak belirlenmiştir. Modelin daha iyi çalışmasında rol oynayabileceğinden, Bricken'in (2021) önerdiği üzere hafif bir temizleme yapılmıştır. Bu aşamada, belirlenmiş olarak durak kelimeler çıkarılmıştır. Son olarak c-TF-IDF kullanılarak, oluşturulan kümelerdeki en önemli kelimelerin ortaya çıkması

sağlanmıştır. Sonuç olarak bu çalışmada yapılan analizde Echo Show 5 veri seti için konu sayısı, 35'ten 18'e, Echo Show 8 veri seti için konu sayısı 29'dan 13'e azalmıştır.

3.3.2. Duygu Analizi Tekniği

Duygu analizi, bir metin parçasını analiz etme ve yazarının tutumunu belirleme sürecidir (S. Liu, 2020). Modern doğal dil işleme (NLP) teknikleri kullanılarak, metinde sunulanlara dayanarak yazarın taşıdığı en olası duygusal ton tahmin edilebilir. Kullanıcı yorumlarını toplamak, analiz etmek ve duyguları, tutumları, gerçek niyetleri anlayabilmek için güçlü bir araç haline gelen duygu analizi (Sankar vd., 2020), dünyanın dört bir yanındaki şirketler tarafından müşteri memnuniyetini değerlendirmek, pazar araştırması yapmak ve marka itibarını izlemek için yaygın olarak kullanılmaktadır (S. Liu, 2020).

Duygu analizi teknikleri sözlük tabanlı, metin sınıflandırma tabanlı ve derin öğrenme tabanlı olarak üç farklı yaklaşımda belirlenebilir (Jeong vd., 2017). Sözlük tabanlı yaklaşım, duygu sözcüklerini ve bunlara karşılık gelen duygu değerlerini tanımlayan önceden tanımlanmış sözlükleri kullanır ve belgedeki sözcüklerin veya ifadelerin anlamsal yönelimine dayalı olarak bir belgenin duygusal yönelimini belirler (Turney, 2002). Metin sınıflandırma tabanlı yaklaşım, etiketlenmiş metin veya cümle örneklerini kullanarak bir sınıflandırıcı oluşturur ve ardından denetimli öğrenme ile oluşturulan sınıflandırıcıya dayalı olarak belirli bir belgenin duygusal yönelimini değerlendirir (Pang vd., 2002; Taboada vd., 2011). Son olarak, derin öğrenme tabanlı yaklaşım, metin belgesindeki konuşma hissini analiz etmek için derin bir sinir ağı modeli kullanır (Dos Santos & Gatti, 2014; Glorot vd., 2011).

Bu çalışmada, belirli bir ürüne dair tüketici yaptığı yorumlar incelenerek, müşteri memnuniyetini ölçmek için derin öğrenme tabanlı bir yaklaşım kullanmaktadır. Bu yaklaşımın kullanılmasının nedeni, derin öğrenme tabanlı yaklaşımın müşteri yorumları gibi nispeten kısa metinlerin duygu analizi için etkili bir şekilde kullanılmış olmasıdır (Dos Santos & Gatti, 2014).

Python kütüphanelerinden TextBlob, verilerin duyarlılığını (pozitif-negatif-nötr) açıklamak için kullanılırken; duygular, Text2Emotion modeli kullanılarak açıklanmıştır (Aslam vd., 2022). Echo Show 5 ve Echo Show 8 veri setine duyarlılık analizi yapabilmek için TextBlob 0.17.11 (PYTeam, 2020); duygu analizi yapabilmek text2emotion 0.0.5 (PYTeam, 2020) paketi kullanılmıştır. İlgili paket, duyguları 5

tonda incelemektedir: Mutlu (Happy), Sürpriz (Suprise), Korku (Fear), Üzgün (Sad) ve Kızgın (Angry). TextBlob ise, yorumların, pozitif, negatif veya nötr olup olmadığına dair çıktı sunabilmektedir.

3.4. Bulgular

Çalışmaya konu olan Amazon Echo Show 5 ve Amazon Echo Show 8 ürünlerine dair yapılan konu modelleme ve duygu analizinin sonuçları aşağıda verilmiştir.

3.4.1. Konu Modelleme Sonuçları

Amazon Echo Show 5ürününe dair yapılan BERTopic konu modellemesi sonucunda çıkan kelimelere istinaden 18 konu belirlenmiştir.

Tablo 15: Amazon Echo Show 5 Konu Modelleme Sonuçlar

Konu 1	**Kapı Zili Kullanımı**	zil, kapı zili, aşk, harika, çalışır, kullanmak, beğenmek, ekran, müzik
Konu 2	**Hediyeleşme**	hediye, ürün, yılbaşı, satın aldım, aşk, harika, satın almak, seviyor, fiyat
Konu 3	**Alarm-Saat**	saat, alarm, kullanım, harika, hava, müzik, gece, zaman, yatak, başucu
Konu 4	**Kolay Kurulum**	kolay, ayarlamak, kullanmak, kurulum, yüklemek, harika, ürün, çalışır, iyi, cihazlar
Konu 5	**Video Arama**	aile, görüntülü, sohbet, konuşma, çocuklar, iletişim, satın aldım, harika, aşk, aramalar
Konu 6	**Ses Kalitesi**	ses, hoparlör, iyi, kalite, harika, küçük, resim, güzel, ekran, boyut
Konu 7	**Mutfakta Kullanım**	mutfak, yemek tarifleri, yemek pişirme, müzik, kullanım, harika, aşk, sayaç, yemek tarifi, videolar
Konu 8	**Daha İyi Ekran**	ekran, görüntü, küçük, daha büyük, açık, güzel, boyut, iyi, beğenmek, harika
Konu 9	**Kapı Zili-Kamera Entegrasyonu**	zil, ücretsiz, çalışır, geldi, kamera, sistemi, harika, kameralar, ürün, kullanın
Konu 10	**Ekran Boyutu**	ekran, daha, küçük, inç, oda, seviyorum, beğenmek, satın almak, boyutu, harika, daha, iyi
Konu 11	**Cihaz Entegrasyonu**	cihaz, gadget, cihazlar, havalı, harika, küçük, eğlenceli, kullan, tavsiye, aşk
Konu 12	**Müzik Dinleme**	müzik, dinlemek, oynamak, çalar, dinlemek, şarkılar, harika, oynamak, aşk, şarkı sözleri
Konu 13	**Akıllı Ev Entegrasyonu**	akıllı, ev, cihazlar, ev, harika, cihaz, hub, güvenlik, çalışır, eklenti
Konu 14	**Arlo Güvenlik Kamerası**	kameralar, kamera, güvenlik, çalışır, harika, kullanım, arlo, iyi, görünüm, cihaz
Konu 15	**Sesli Komut Özelliği**	ses, komutları, tanıma, komut, ürün, çalışır, seçer, iyi, aktivasyon, uzak

Konu 16	**Yatak Odasında Kullanım**	boyut, komidin, mükemmel, gece, masası, sağ, standı, yatak, odası, harika
Konu 17	**Blink Güvenlik Kamerası**	blink, kamera, kameralar, sistemi, mini, var, çalışır, güvenlik, harika, ücretsiz
Konu 18	**Cihaz Boyutu**	boyut, küçük, harika, görünüyor, daha küçük, kompakt, küçük, düşünce, çalışır, mükemmel

Amazon Echo Show 8 ürününe dair yapılan BERTopic konu modellemesi sonucunda çıkan kelimelere istinaden 13 konu belirlenmiştir.

Tablo 16: Amazon Echo Show 8 Konu Modelleme Sonuçları

Konu 1	**Multimedya**	aşk, harika, ekran, kullanım, gibi, müzik, ses, video, cihazlar, ev
Konu 2	**Ses Kalitesi**	ses, ekran, iyi, kalite, harika, hoparlör, görüntü, net, mükemmel, güzel
Konu 3	**Fiyat**	ürün, satın, harika, fiyat, iyi, tavsiye, hizmet, kolay, kullanım, satın alma
Konu 4	**Mutfakta Kullanım**	mutfak, yemek tarifleri, yemek pişirme, müzik, yemek tarifi, harika, bak, kullan, dinle
Konu 5	**Hediyeleşme**	hediye, Noel, aldım, seviyor, aşk, sevdi, kızım, aldım, doğum günü, anne
Konu 6	**Kolay Kurulum**	kolay, ayarla, kurulum, kullan, harika, yükle, ürün, güzel, basit, çalışır
Konu 7	**Pandemide Aile İletişimi**	aile, dokun, covid, konuş, iletişim, pandemi, satin almak, anne, yol, büyükanne
Konu 8	**Akıllı Ev Entegrasyonu**	cihaz, akıllı, ev, cihazlar, harika, aşk, kullanım, kontrol, çalışır, ev
Konu 9	**Daha İyi Ekran**	inç, daha, iyi, 10, ekran, harika, boyut, aşk, sürüm, ses, daha, büyük
Konu 10	**Kapı Zili-Kamera Entegrasyonu**	zil, kapı, kapı zili, çalışır, zil, kameralar, kamera, aşk, harika, ürün
Konu 11	**Alarm-Saat**	alarm, saat, hava, müzik, alarmlar, kullanım, ekipman, gece, aşk, uyandırma
Konu 12	**Blink Güvenlik Kamerası**	kameralar, kamera, göz kırpma, güvenlik, kullanım, izle, bebek, aşk, sahip, bak
Konu 13	**Video Arama**	görüntülü, sohbet, satin almak, çalışır, kızım, harika, anne, aile, aramalar, anne

İki veri setinde 'Daha İyi Ekran', 'Alarm-Saat', 'Video Arama', 'Ses Kalitesi', 'Akıllı Ev Entegrasyonu', 'Kolay Kurulum', 'Hediyeleşme', 'Blink Güvenlik Kamerası', ‘Kapı Zili-Kamera Entegrasyonu’ ve 'Mutfakta Kullanım' olmak üzere 10 konunun ortak olduğu tespit edilmiştir.

3.4.1.1. Konular Arası Mesafe Haritası

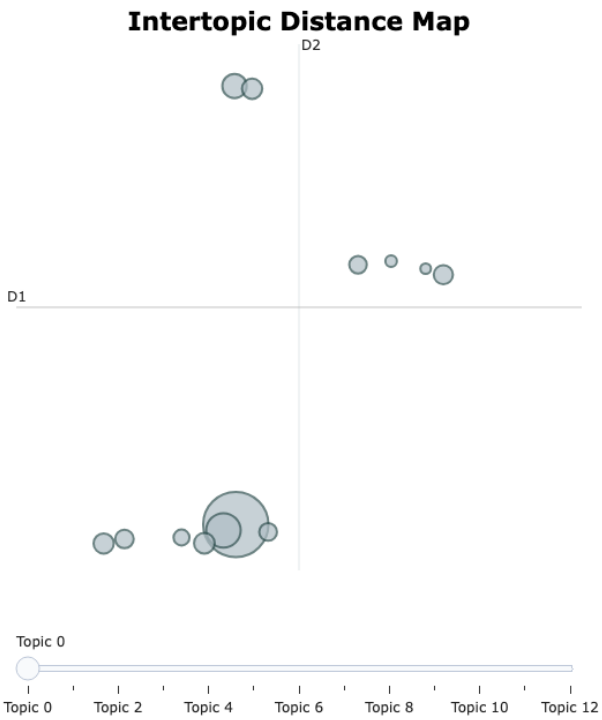
Konular arasındaki mesafe haritası, BERTopic'in temel bir özelliğidir ve temelde farklı konular arasındaki ilişkileri görselleştirmek için kullanılır, her bir konunun vektörel bir gösterimini kullanarak, konular arasındaki benzerlikleri ve farklılıkları ölçer. Bu harita, genellikle çok boyutlu veriyi iki boyuta indirgeyerek oluşturulur. Bu şekilde, farklı konular arasındaki ilişkiler görsel olarak temsil edilir. Bu mesafe haritası, kullanıcıya bir metin veri setindeki konuların dağılımını anlamasına yardımcı olur. Örneğin, yakın konular birbirine benzer içeriklere sahip olabilirken, uzak konular arasında daha az benzerlik olabilir. Bu harita, metin verilerindeki karmaşık yapıyı anlamak ve keşfetmek için önemli bir araç sağlar.

Algoritmanın çıkardığı konuların 2 boyutlu bir temsilini oluşturmak için "visualize_topics() parametresi çağırabilmektedir. Ortaya çıkan grafik, HTML'ye dönüştürülebilen etkileşimli bir grafiktir. Konuyu seçmek için grafiğin altında yer alan kaydırıcıyı kullanılabilir, hangi konunun üzerine gelinirse, grafikte ilgili konu kırmızı renkte yanar. Bir konunun üzerine gelindiğinde, konunun boyutu ve karşılık gelen kelimeler de dahil olmak üzere konu hakkında genel bilgiler verilir.

Şekil 26: Amazon Echo Show 5 Konular Arası Mesafe Haritası



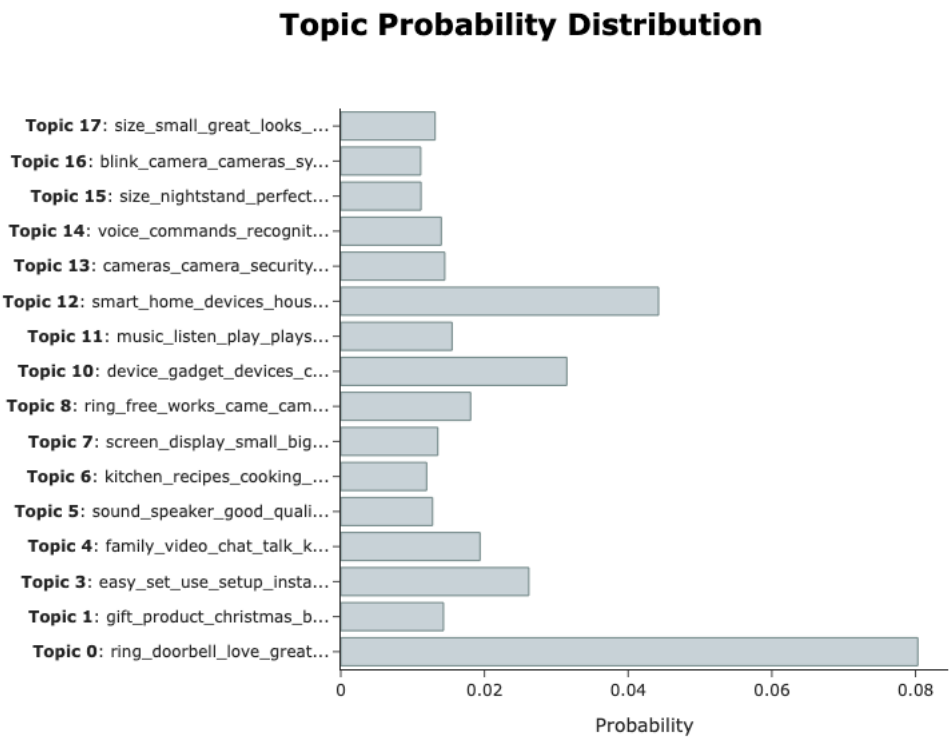
Şekil 27: Amazon Echo Show 8 Konular Arası Mesafe Haritası



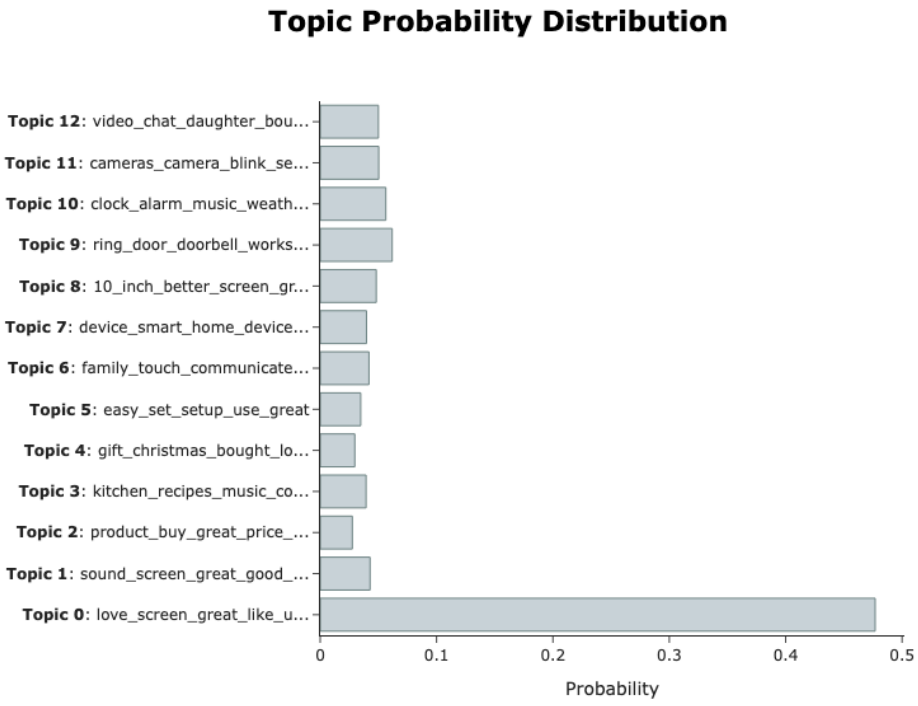
3.4.1.2. Konu Olasılık Dağılımı

BERTopic tarafından oluşturulan konu modellemesi sonucunda her belgenin hangi konulara ait olduğunu gösteren bir olasılık dağılımıdır. Bu dağılım, her belgenin her bir konuya ait olma olasılığını belirtir. transform() veya fit_transform() işlemlerinden döndürülen değişken olasılıkları, BERTopic'in bir dokümanda belirli konuların bulunabileceğinin ne kadar güvenilir olduğunu anlamak için kullanılabilir.

Şekil 28: Amazon Echo Show 5 Konu Olasılık Dağılımı



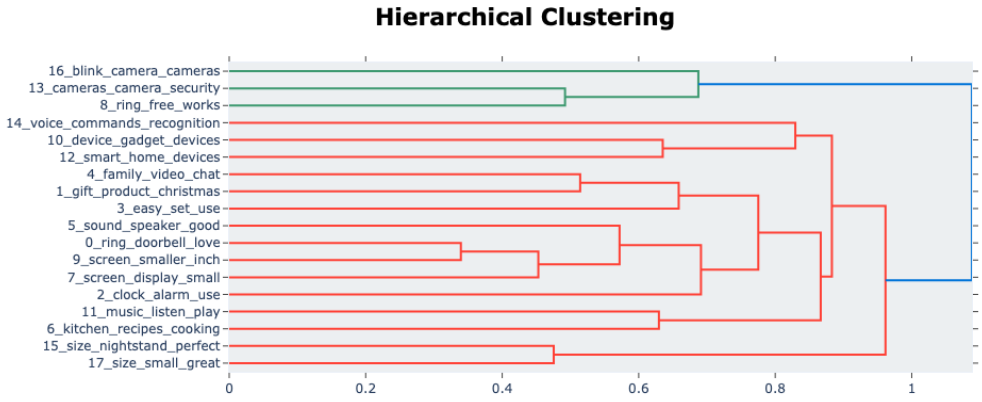
Şekil 29: Amazon Echo Show 8 Konu Olasılık Dağılımı



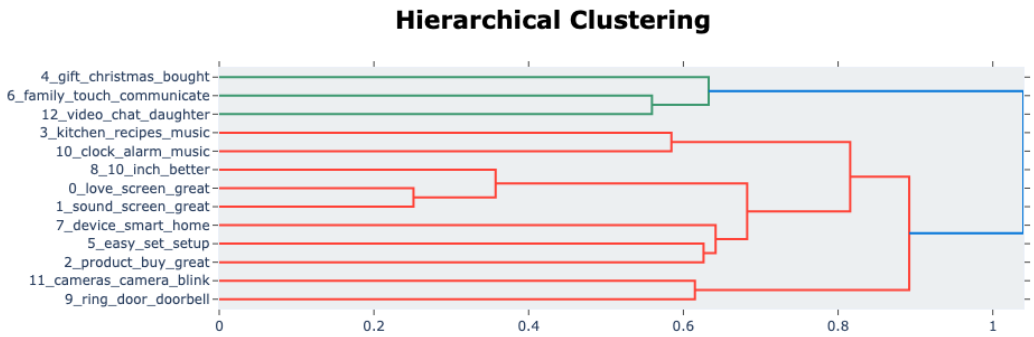
3.4.1.3. Hiyerarşik Kümeleme

Hiyerarşik kümeleme, veri kümesindeki öğeleri birbirlerine olan benzerlikleri veya uzaklıkları temelinde gruplamak için kullanılan bir kümeleme yöntemidir (Schwarz vd., 2020). Scipy kütüphanesinin scipy.cluster.hierarchy modülü, hiyerarşik kümeleme yöntemlerini uygulamak için kullanılır. Bu yöntemler, belirli bir veri kümesindeki benzer öğeleri bir araya getirerek hiyerarşik bir ağaç yapısı oluşturur. Bu ağaç yapısı daha sonra görselleştirilebilir ve Şekil 31 ve Şekil 32'de gösterildiği gibi konuların nasıl birbirine bağlı olduğunu anlamak için kullanılabilir. Oluşturulan konular hiyerarşik olarak indirgenebilir. Bu, oluşturulan konuların sayısını azaltırken uygun bir konu sayısı (nr_topics) seçilmesine olanak sağlar.

Şekil 30: Amazon Echo Show 5 Hiyerarşik Kümeleme



Şekil 31: Amazon Echo Show 8 Hiyerarşik Kümeleme

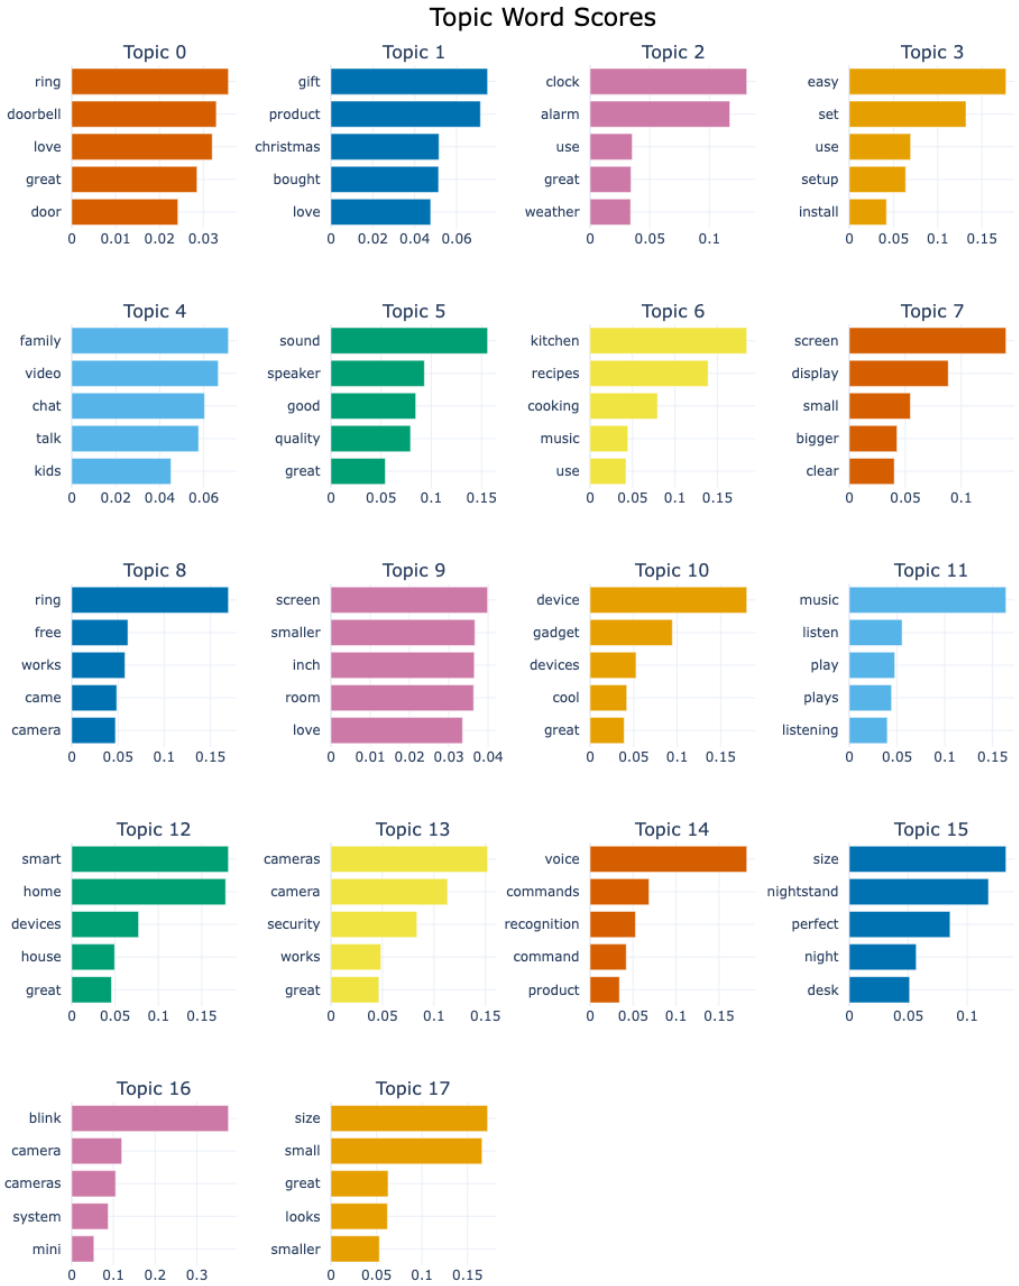


3.4.1.4. Konu Kelime Puanları

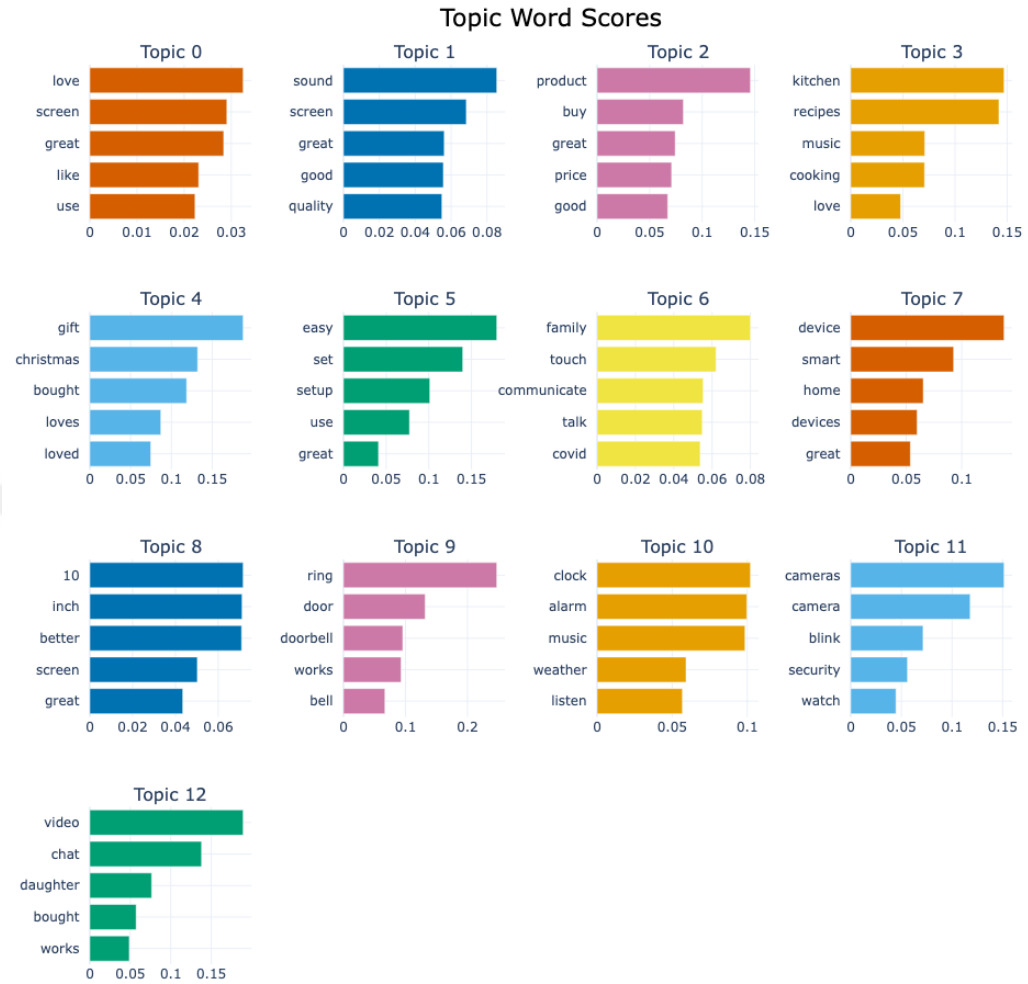
BERTopic'te konu kelime puanları, her bir konunun belirli kelimelerle ilişkili olma olasılığını temsil eder. Bu puanlar, bir konunun temsil ettiği konsept veya tema hakkında daha fazla içgörü sağlar. Örneğin, bir konunun "teknoloji" ile ilişkili olduğunu düşünelim. Bu konunun "yapay zekâ", "makine öğrenimi", "veri analizi" gibi teknolojiyle ilgili kelimelerle yüksek bir kelime puanına sahip olması beklenir. Bu da ilgili konunun teknoloji konseptini iyi temsil ettiğini gösterir.

Konu kelime puanları, BERTopic modelinin oluşturduğu her bir konunun içeriğini daha iyi anlamak için kullanılabilir. Ayrıca, belirli konuların hangi kelimelerle güçlü bir şekilde ilişkilendirildiğini belirleyerek, konu başlıklarını daha anlamlı bir şekilde tanımlamak için de kullanılabilir. Bu sayede, BERTopic'in sunduğu konuların içeriği hakkında daha detaylı bir görünüm elde edilir. Her bir konu temsili için c-TF-IDF skorlarından çubuk grafikler oluşturarak tüm konular için seçilen terimler Şekil 33 ve Şekil 34'te olduğu gibi tek bir grafikte görselleştirilebilir.

Şekil 32: Amazon Echo Show 5 Konu Kelime Puanları



Şekil 33: Amazon Echo Show 8 Konu Kelime Puanları



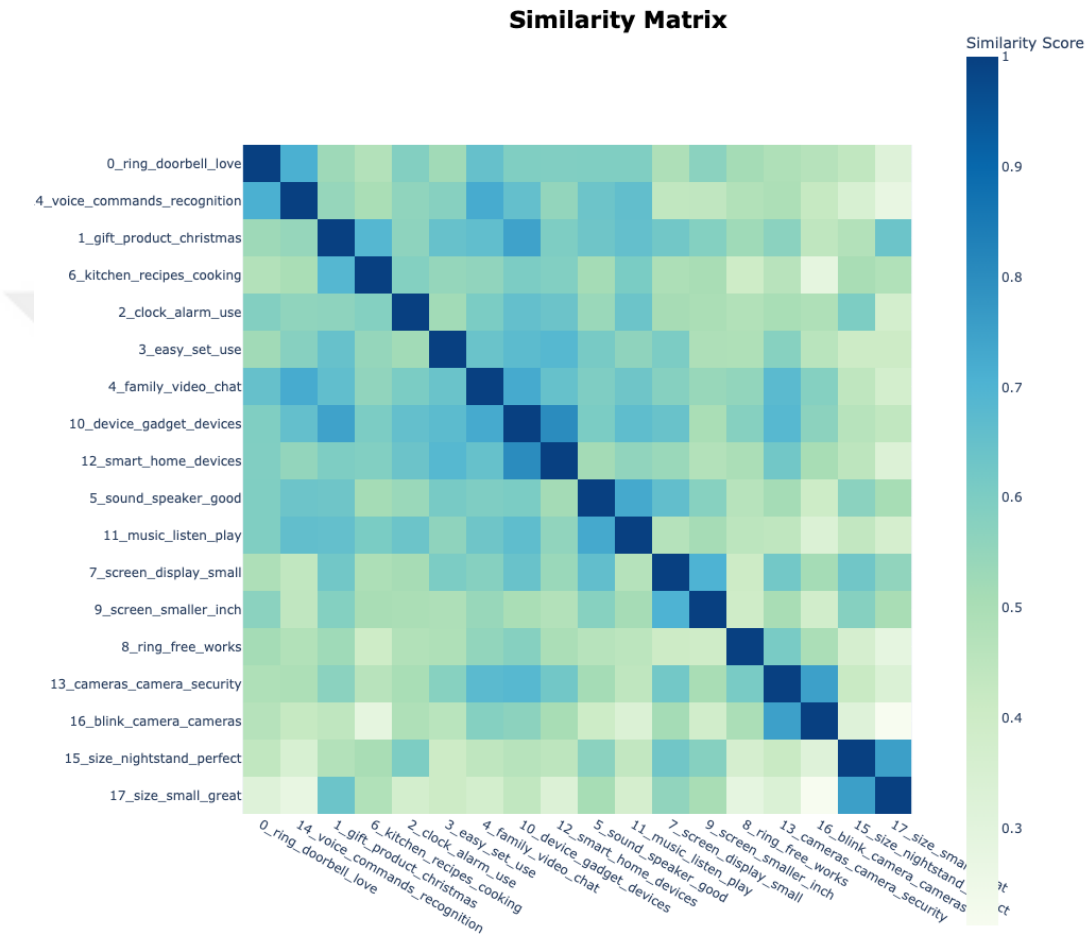
3.4.1.5. Benzerlik Matrisi

BERTopic'in benzerlik matrisi, BERTopic tarafından oluşturulan konular arasındaki benzerlikleri ölçen bir matristir. Bu matris, her bir konunun diğer konulara göre ne kadar benzer olduğunu gösterir. Hem c-TF-IDF hem de yerleştirmeler aracılığıyla konu yerleştirmeleri oluşturduktan sonra, bu konu yerleştirmelerine kosinüs benzerliği veya başka bir benzerlik ölçüsü uygulanarak hesaplanır. Sonuç, belirli konuların birbirlerine ne kadar benzer olduğunu gösteren bir matris olacaktır.

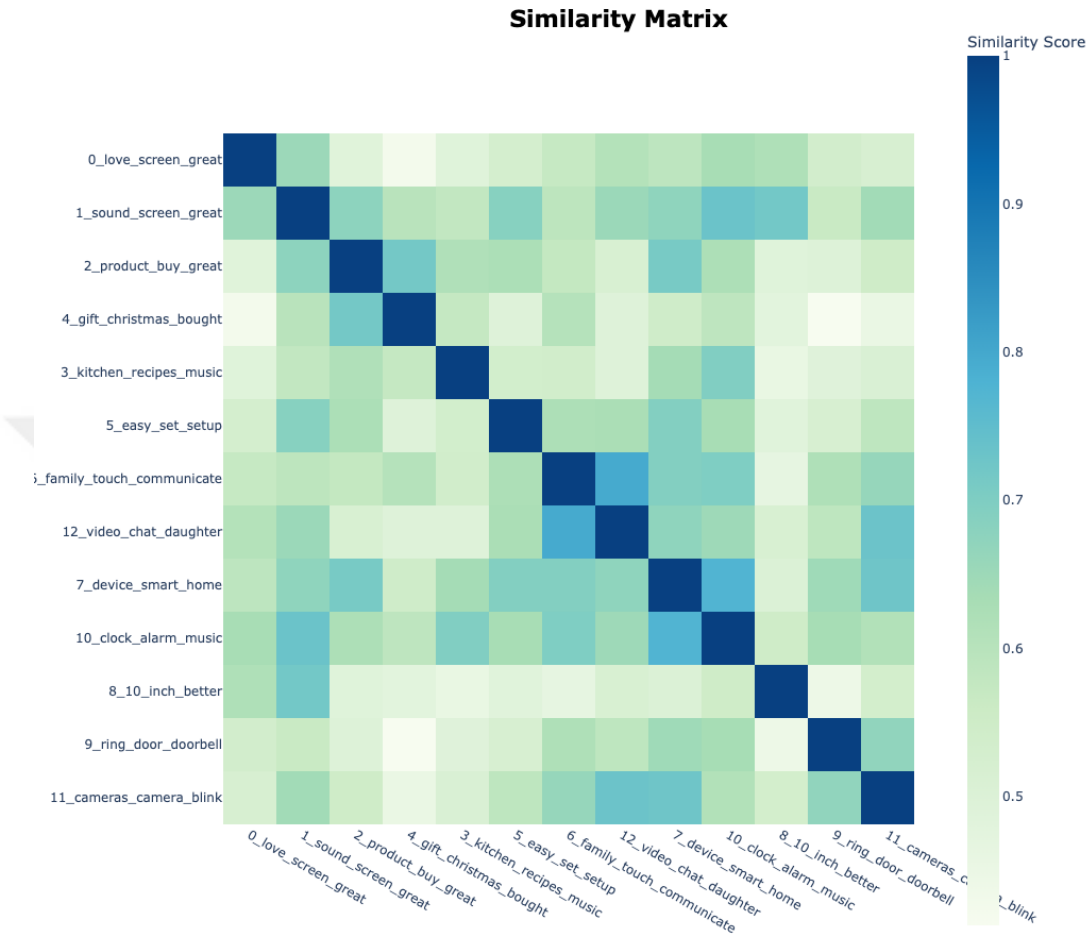
Benzerlik matrisi, genellikle kare bir matris olarak temsil edilir, burada her bir satır ve sütun bir konuyu temsil eder. Matrisin her bir hücresi, karşılık gelen iki konunun benzerlik puanını içerir. Bu benzerlik matrisi, BERTopic tarafından belirlenen konuların birbirleriyle nasıl ilişkilendirildiğini ve gruplandırıldığını daha iyi

anlamamıza yardımcı olur. Ayrıca, konular arasındaki ilişkileri görselleştirmek için kullanılabilir.

Şekil 34: Amazon Echo Show 5 Benzerlik Matrisi



Şekil 35: Amazon Echo Show 8 Benzerlik Matrisi



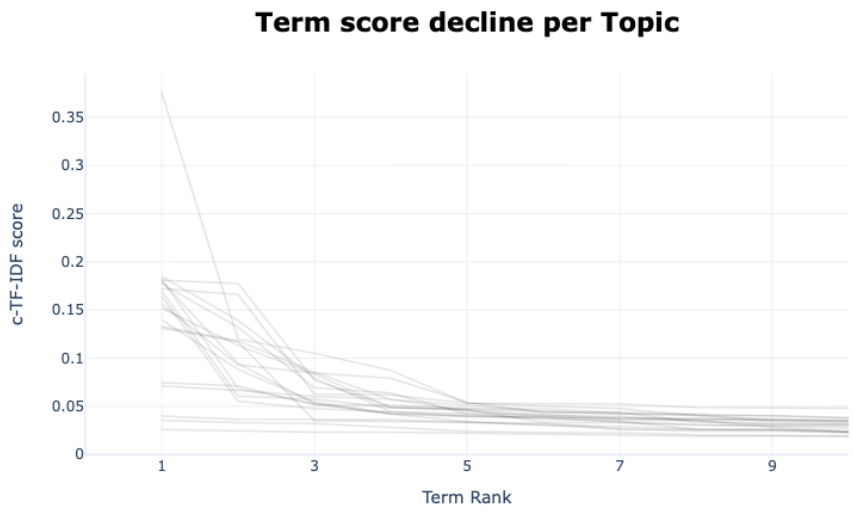
3.4.1.6. Konu Başına Kelime Puan Düşüşü

Konular, en iyi temsil eden kelimeden başlayarak bir dizi kelime ile temsil edilir. Her kelime bir c-TF-IDF puanı ile temsil edilir. Puan ne kadar yüksekse, bir kelime konuyu o kadar iyi temsil eder. Konu kelimeleri c-TF-IDF puanlarına göre sıralandığından, eklenen her kelimeyle puanlar yavaşça düşer. Bir noktada, konu temsiline kelime eklemek toplam c-TF-IDF puanını yalnızca marjinal olarak artırır ve temsil için faydalı olmaz.

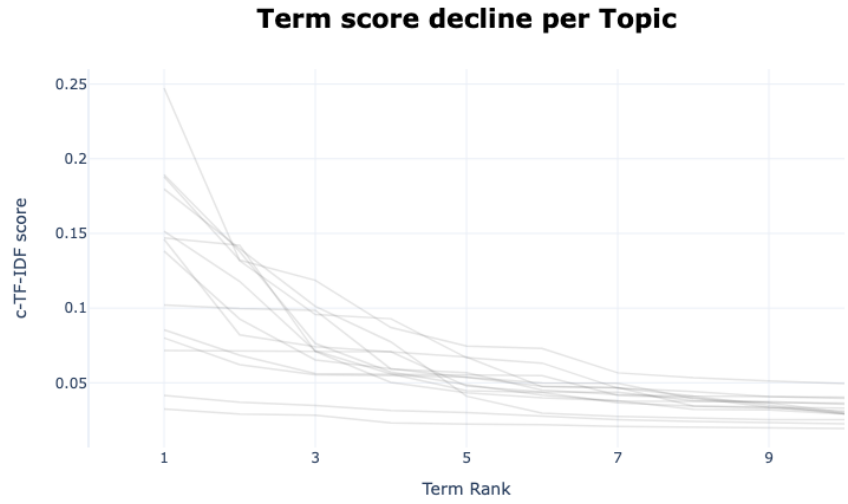
Bu etkiyi görselleştirmek için, her bir konu için c-TF-IDF puanlarını her bir kelimenin terim sırasına göre çizilmektedir. Başka bir deyişle, en yüksek c-TF-IDF puanına sahip

kelimelerin 1 sıralamasına sahip olacağı kelimelerin konumu (terim sıralaması) x eksenine yerleştirilecektir. Y ekseni ise c-TF-IDF skorları ile doldurulacaktır. Sonuç, konu temsiline kelime eklerken c-TF-IDF skorunun düşüşünü gösteren bir görselleştirmedir. Dirsek yöntemini kullanarak bir konudaki en iyi kelime sayısının seçilmesine olanak tanır.

Şekil 36: Amazon Echo Show 5 Konu Başına Kelime Puan Düşüşü



Şekil 37: Amazon Echo Show 8 Konu Başına Kelime Puan Düşüşü

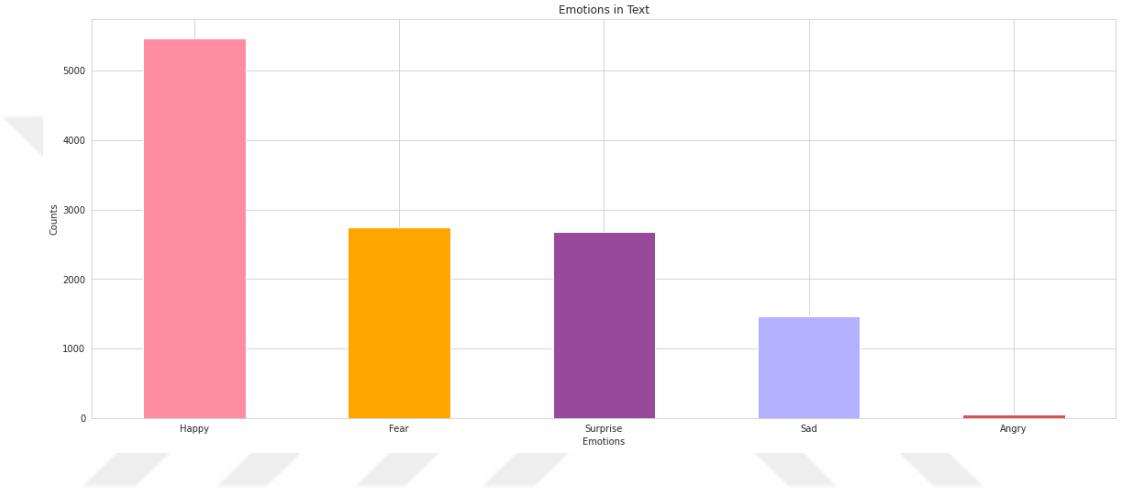


3.4.2. Duygu ve Duyarlılık Analizi Sonuçları

3.4.2.1. Duygu Analizi Sonuçları

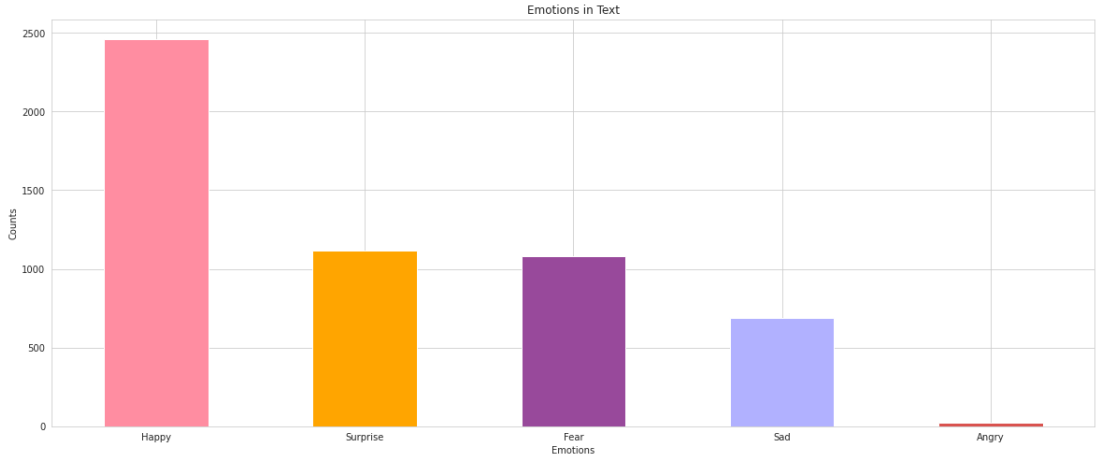
Amazon Echo Show 5 ürününe dair yapılan duygu analizi sonrası elde edilen çıktılar şu şekildedir. 12.394 adet yorumdan oluşan veri seti, 5467 mutlu, 2740 korku, 2672 sürpriz, 1460 üzgün, 55 kızgın hisli olarak ayrışmıştır.

Şekil 38: Amazon Echo Show 5 Duygu Analizi Sonuçları



Amazon Echo Show 8 ürününe dair yapılan duygu analizi sonrası elde edilen çıktılar ise şu şekildedir: 5.364 adet yorumdan oluşan veri seti, 2462 mutlu, 1117 korku, 1079 sürpriz, 686 üzgün, 20 kızgın hisli olarak ayrışmıştır.

Şekil 39: Amazon Echo Show 8 Duygu Analizi Sonuçları

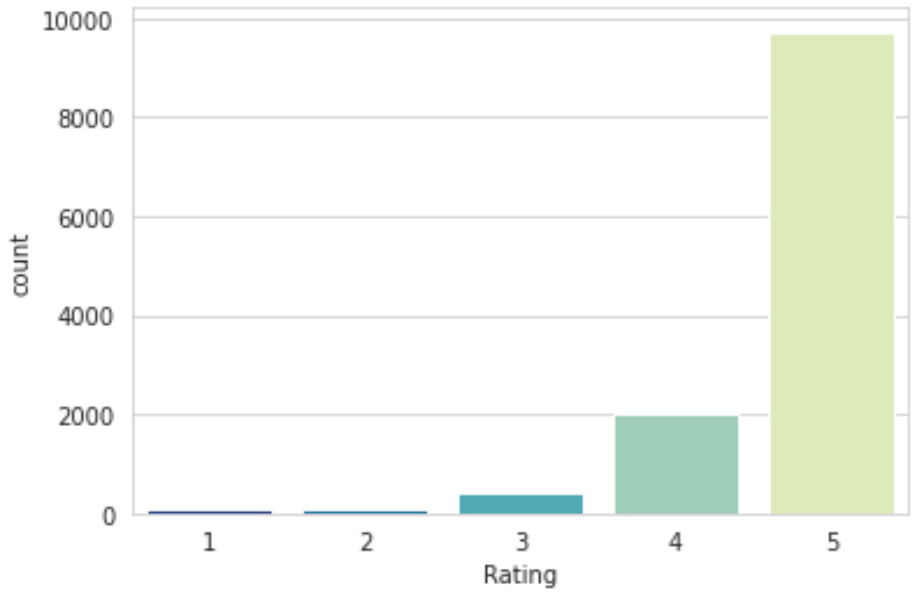


Derlemi incelediğimizde, hem Echo Show 5 hem de Echo Show 8 ile ilgili en çok çağrıştırılan duygu mutlu olurken, onu hemen ardından izleyen duygunun iki ürün için farklı olduğu görülmektedir. Echo Show 5 ürünü için ikinci duygu korku olurken, Echo Show 8 ürünü için ikinci duygu sürpriz olarak öne çıkmıştır. En az hissedilen duygu ise, her iki üründe de kızgın olarak gözükmektedir.

3.4.2.2. Puanlama Sonuçları

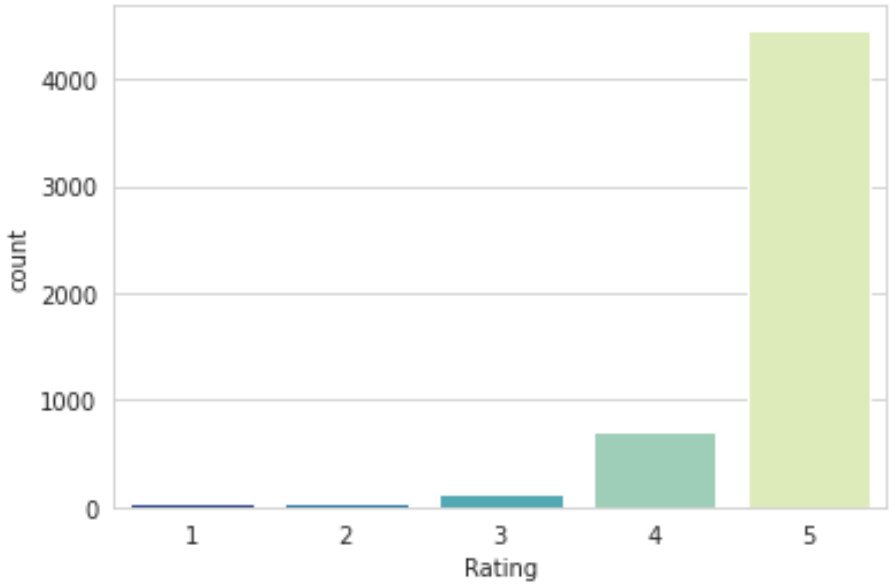
Amazon Echo Show 5 ürünü için müşterilerin 5 üzerinden ürüne verdikleri puanlar Şekil 41'deki grafikte gösterilmiştir.

Şekil 40: Amazon Echo Show 5 Puanlama Sonuçları



Amazon Echo Show 8 ürünü için müşterilerin 5 üzerinden ürüne verdikleri puanlar Şekil 42'deki grafikte gösterilmiştir.

Şekil 41: Amazon Echo Show 8 Puanlama Sonuçları



3.4.2.3. Pozitif Yorumların Sözcük Bulutu

Amazon Echo Show 5 ürünü için yapılan pozitif yorumların oranı %87,6'dır ve ortaya çıkan sözcük bulutu Şekil 43'de gösterilmektedir.

Şekil 42: Amazon Echo Show 5 Pozitif Kelime Bulutu



Amazon Echo Show 8 ürünü için ise yapılan pozitif yorumların oranı %90,2'dir ve ortaya çıkan sözcük bulutu Şekil 44'te gösterilmektedir.

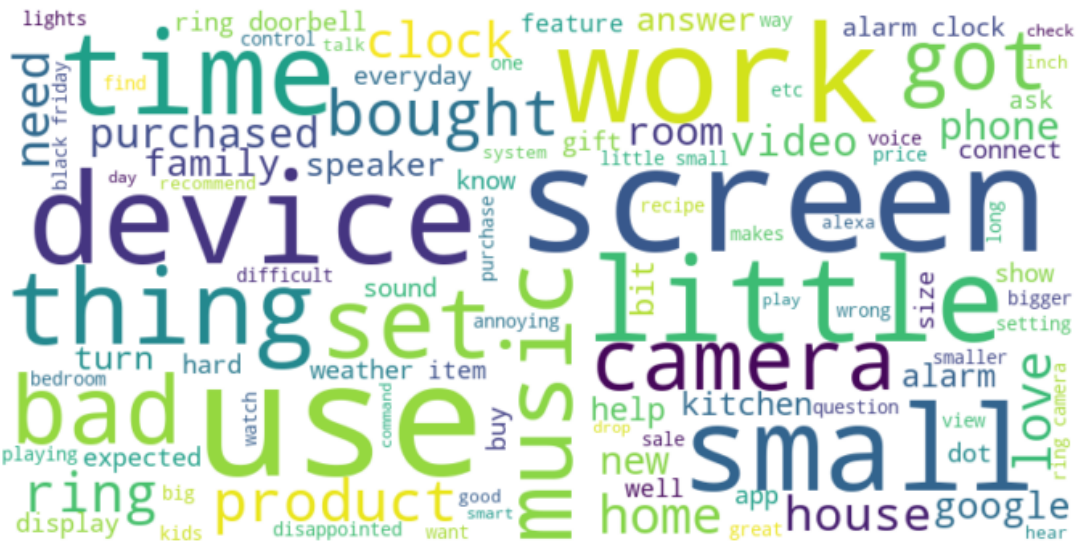
Şekil 43: Amazon Echo Show 8 Pozitif Kelime Bulutu



3.4.2.4. Negatif Yorumların Sözcük Bulutu

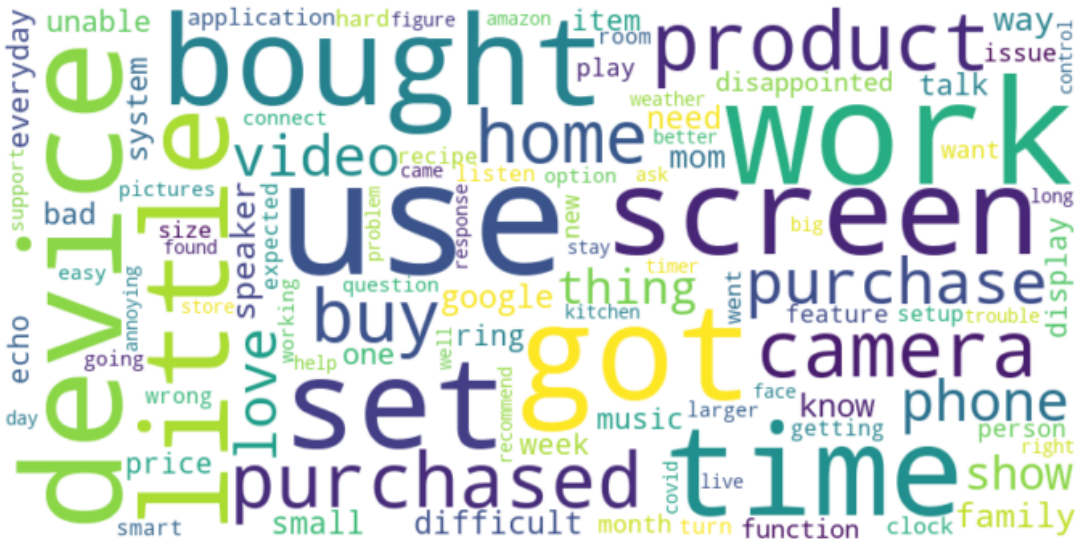
Amazon Echo Show 5 ürünü için yapılan negatif yorumların oranı %4'tür ve ortaya çıkan sözcük bulutu Şekil 45'te gösterilmiştir.

Şekil 44: Amazon Echo Show 5 Negatif Kelime Bulutu



Amazon Echo Show 8ürünü için yapılan negatif yorumların oranı %3,2'dir ve ortaya çıkan sözcük bulutu Şekil 46'da gösterilmiştir.

Şekil 45: Amazon Echo Show 8 Negatif Kelime Bulutu



3.4.2.5. Nötr Yorumların Sözcük Bulutu

Amazon Echo Show 5 ürünü için yapılan nötr yorumların oranı %8,4'tür ve ortaya çıkan sözcük bulutu Şekil 47'de gösterilmektedir.

Şekil 46: Amazon Echo Show 5 Nötr Kelime Bulutu



Amazon Echo Show 8 ürünü için yapılan nötr yorumların oranı %6,6'dır ve ortaya çıkan sözcük bulutu Şekil 48'de gösterilmektedir.

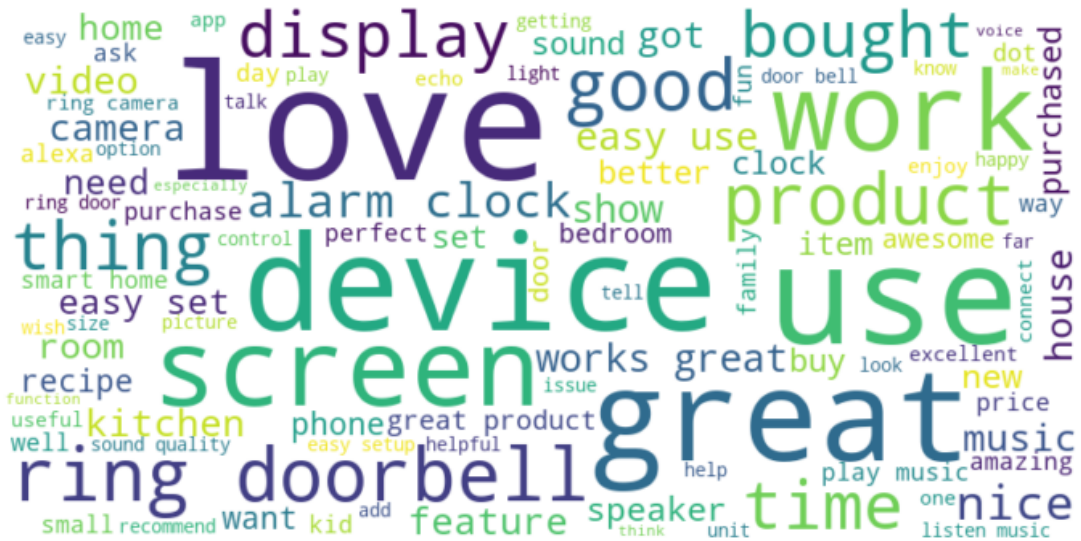
Şekil 47: Amazon Echo Show 8 Nötr Kelime Bulutu



3.4.2.6. Genel Kelime Bulutu

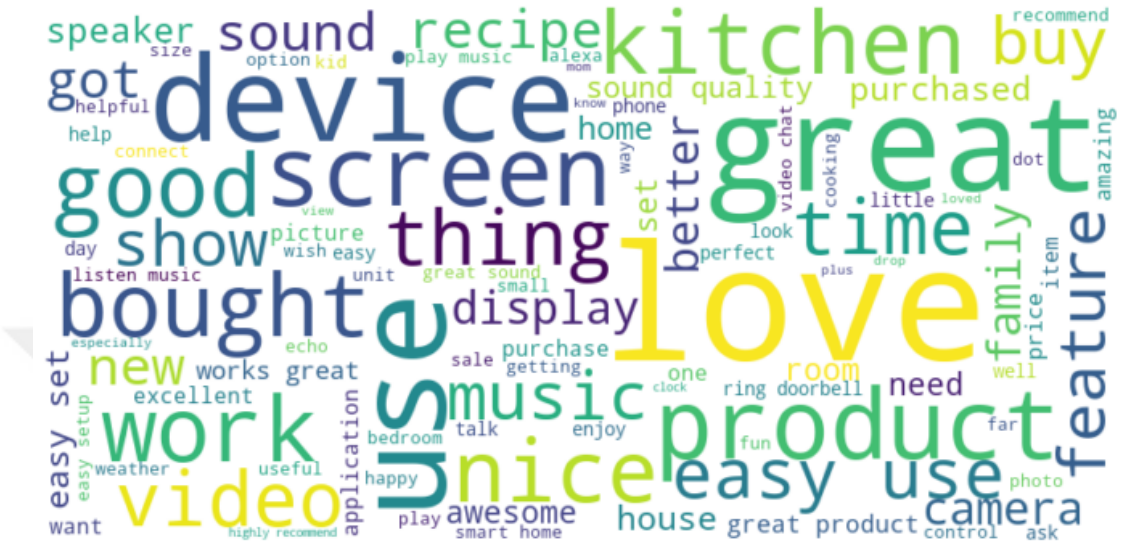
Amazon Echo Show 5 ürünü için yapılan tüm yorumların duygu ayırmaksızın ortaya çıkan sözcük bulutu Şekil 49'da gösterilmektedir.

Şekil 48: Amazon Echo Show 5 Kelime Bulutu



Amazon Echo Show 8 ürünü için yapılan tüm yorumların duygu ayırmaksızın ortaya çıkan sözcük bulutu Şekil 50'de gösterilmektedir.

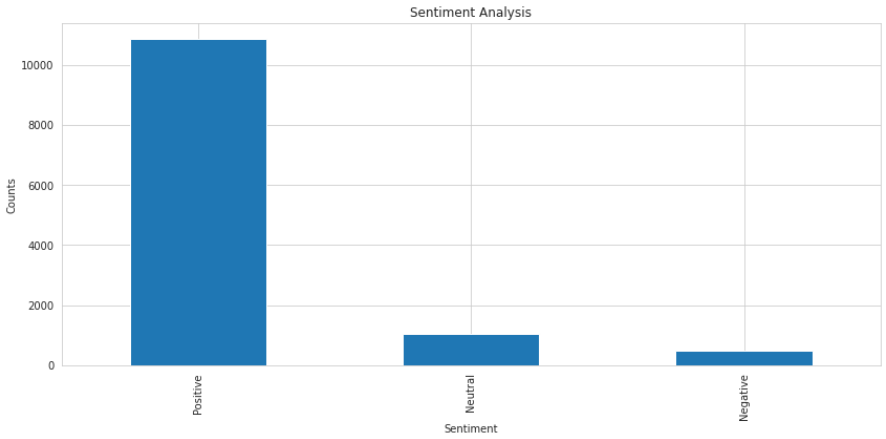
Şekil 49: Amazon Echo Show 8 Kelime Bulutu



3.4.2.7. Duyarlılık Analizi (Yorum Sayısı)

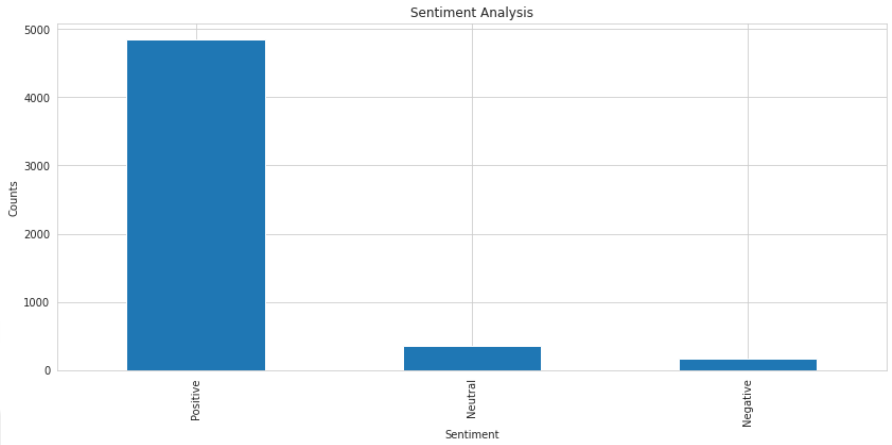
Duyarlılık analizi, yorumların olumlu, olumsuz veya pozitif oluşunu değerlendirmektedir (Bigne vd., 2023). Amazon Echo Show 5 ürünü için ortaya çıkan duyarlılıkların yorum sayısı üzerinden değerlendirildiğinde elde edilen grafik Şekil 51'de verilmiştir.

Şekil 50: Amazon Echo Show 5 Duyarlılık Analizi (Yorum Sayısı)



Amazon Echo Show 8 ürünü için ise ortaya çıkan duyarlıkların yorum sayısı üzerinden değerlendirildiğinde elde edilen grafik Şekil 52'de verilmiştir.

Şekil 51: Amazon Echo Show 8 Duyarlılık Analizi (Yorum Sayısı)

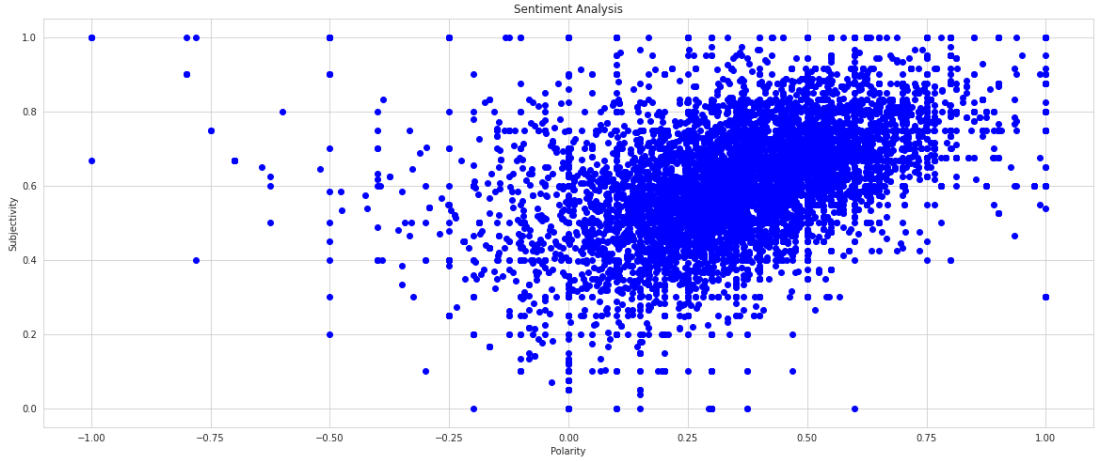


3.4.2.8. Duyarlılık Analizi (Polarite-Öznellik)

Duyarlılık analizi polarite-öznellik grafiği, bir metin veri kümesinde bulunan belgelerin duygusal içeriğini görselleştirmek için kullanılan bir araçtır. Bu grafik, belgelerin duygusal polaritesini (olumlu, olumsuz veya nötr) ve duygusal öznelliğini (nesnel veya öznel) gösterir (Bigne vd., 2023). Polarite, belgelerin duygusal yönünü ifade eder. Olumlu polarite, pozitif duyguları (örneğin mutluluk, sevinç) içeren belgeleri; olumsuz polarite ise negatif duyguları (örneğin üzüntü, endişe) içeren belgeleri temsil eder. Nötr polarite ise duygusal bir eğilim göstermeyen belgeleri ifade eder. Öznellik ise, belgelerin duygusal ifadelerinin nesnel veya öznel olma derecesini ifade eder. Nesnel belgeler genellikle gerçekler, bilgi veya açık ifadeler içerirken, öznel belgeler daha kişisel görüşleri, duygusal tepkileri veya yorumları yansıtır.

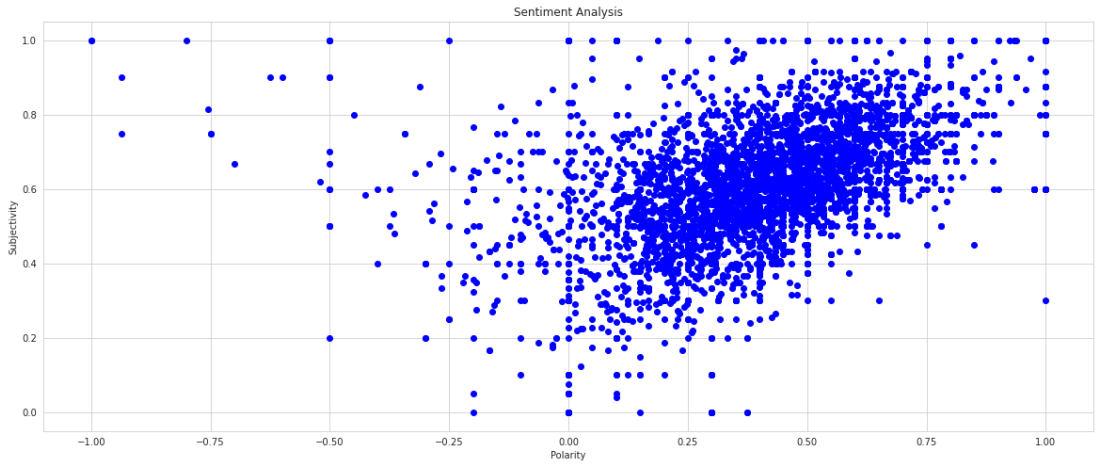
Bir duyarlılık analizi polarite-öznellik grafiği, bir ürün incelemeleri veri kümesindeki incelemelerin duygusal tonunu ve öznelliğini görselleştirebilir, böylece ürünün genel algısını değerlendirebilir. Amazon Echo Show 5 ve Amazon Echo Show 8 ürünleri için polarite öznellik grafiği Şekil 53 ve Şekil 54'te verilmiştir.

Şekil 52: Amazon Echo Show 5 Duyarlılık Analizi (Polarite-Öznellik)



Amazon Echo Show 8 ürünü için polarite öznellik grafiği aşağıda verilmiştir.

Şekil 53: Amazon Echo Show 8 Duyarlılık Analizi (Polarite-Öznellik)

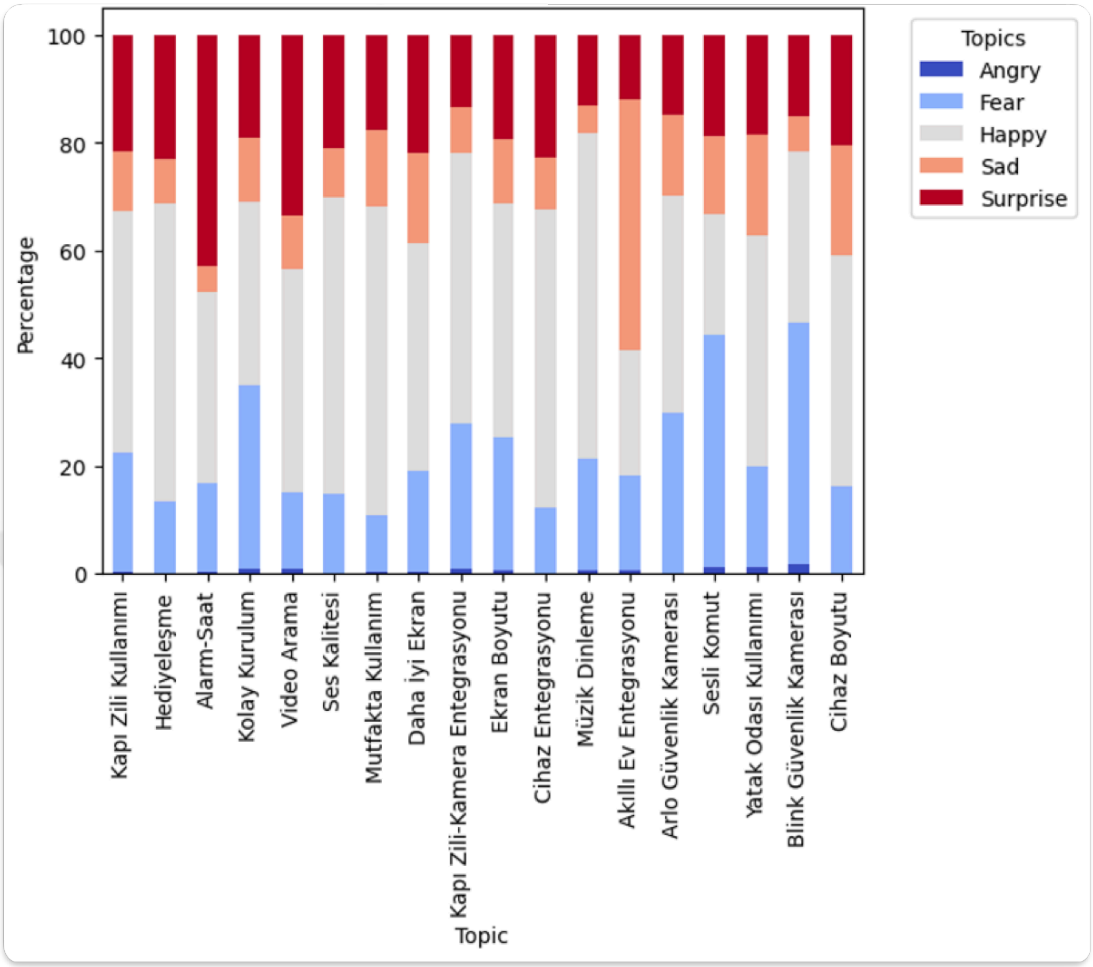


3.4.2.9. Konu Bazlı İnceleme Değeri

Duygu analizinin değeri, müşterilerin nelere olumlu yaklaştığını ortaya çıkarması ve müşterilerin rahatsızlık duyduğu konular hakkında bilgi vermesinde yatmaktadır (Ozansoy Çadırcı vd., 2022). Amazon Echo Show 5 ve Amazon Echo Show 8 ürünlerine dair müşterilerin son derece olumlu olduğu görülmektedir.

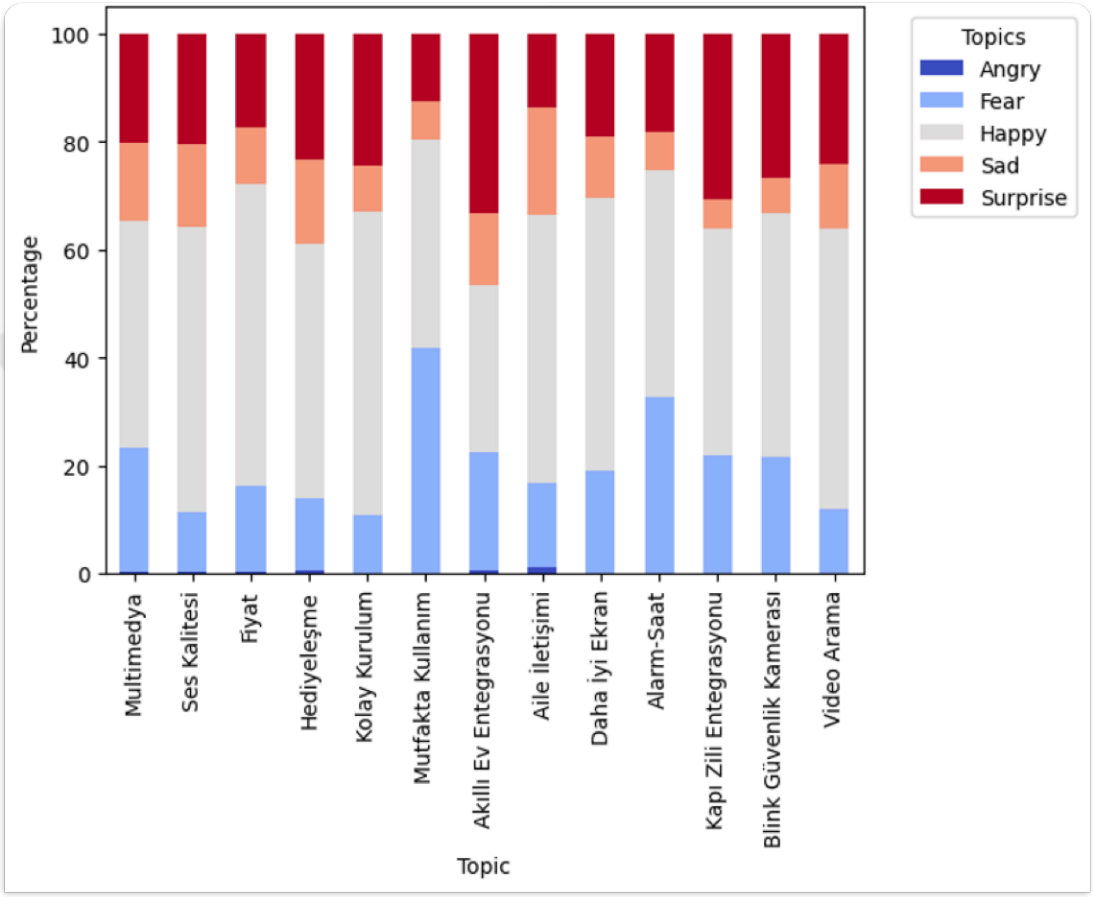
Amazon Echo Show 5 ürününün konularına dair hissedilen duyguların konu tabanlı grafiği Şekil 55'te verilmiştir.

Şekil 54: Amazon Echo Show 5 Ürününde Konulara Dair Duygu Dağılımı



Echo Show 8 ürününün konularına dair hissedilen duyguların konu tabanlı grafiği Şekil 56'da verilmiştir.

Şekil 55: Amazon Echo Show 8 Ürününde Konulara Dair Duygu Dağılımı



3.4.3. Fırsat Analizi

Fırsat analizi, bir işletmenin belirli bir pazar veya sektördeki fırsatları tanımlamak, değerlendirmek ve bu fırsatları değerlendirerek stratejik kararlar almalarına yardımcı olan bir süreçtir. Bu bölümde iki farklı model incelenerek sanal asistan ürünlerin, yeni ürün/özellik geliştirme yönündeki fırsat iyileştirmelerinin analizi yapılmaktadır. Ulwick (2002) tarafından önerildiği gibi bu fırsatları tanımlamak için iki boyut kullanılmıştır. İlk boyut, müşteri tarafından atfedilen önem düzeyi, ikincisi ise ürünün yarattığı memnuniyet düzeyidir. Önem düzeyi, konu oranları kullanılarak hesaplanmıştır. Bir konunun yoğunluğu arttıkça, öneminin de artması beklenir.

Memnuniyet düzeyi ise duygu puanları kullanılarak hesaplanır. Ortalama duyarlılık puanı -1 ile 1 arasında bir değer alır; burada sürekliliğin karşıt ucu memnuniyetsizlik, diğer ucu ise yüksek düzeyde memnuniyet anlamına gelir. Her bir konunun önem ve memnuniyet skoru, Ulwick (2002) tarafından önerilen, Fırsat Denklemi kullanılarak, 0-10 arasında normalleştirilmiştir (Jeong vd., 2017) (Ozansoy Çadırcı vd., 2022). BERTopic tarafından çıkarılan Konu -1, aykırı veya bir konu ile güçlü bir bağlantısı olmayan belgeleri ifade ettiğinden, iki boyut için de analizlerde kullanılmamaktadır.

$$\text{Fırsat} = \text{Önem} + (\text{Önem-Memnuniyet})$$

Tablo 17, Echo Show 5 ürününe dair her bir özelliğin önemini ve memnuniyet düzeylerini, hesaplanan fırsat puanlarıyla birlikte özetlemektedir.

Tablo 17: Amazon Echo Show 5 Fırsat Analizi Sonuçları

Konular	**Önem**	**Memnuniyet**	**Fırsat**
Kapı Zili Kullanımı	10	5,568035	14,431965
Hediyeleşme	4,079073	8,484977	-0,326831
Alarm-Saat	1,388601	5,703692	-2,92649
Kolay Kurulum	1,305018	6,901805	-4,291769
Video Arama	1,015745	7,218814	-5,187324
Ses Kalitesi	0,877502	7,496775	-5,741771
Mutfakta Kullanım	0,819655	7,813783	-6,174473
Daha İyi Ekran	0,752167	2,49579	-0,991456
Kapı Zili-Kamera Entegrasyonu	0,707149	9,636115	-8,221817
Ekran Boyutu	0,376084	4,572102	-3,819934
Cihaz Entegrasyonu	0,337479	7,217533	-6,542575
Müzik Dinleme	0,337479	6,712772	-6,037814
Akıllı Ev Entegrasyonu	0,321424	6,325941	-5,683093
Arlo Güvenlik Kamerası	0,231427	10	-9,537146
Sesli Komut	0,131789	0	0,263578
Yatak Odasında Kullanım	0,118921	9,75759	-9,519748
Blink Güvenlik Kamerası	0,035338	5,528545	-5,457869
Cihaz Boyutu	0	3,151867	-3,151867

Fırsat analizi haritası incelenirken, genellikle dört ana başlık altında analiz yapılabilir (Caroli, 2023). Yüksek Önem/Yüksek Memnuniyet alanı, güçlü yönleri temsil eder ve

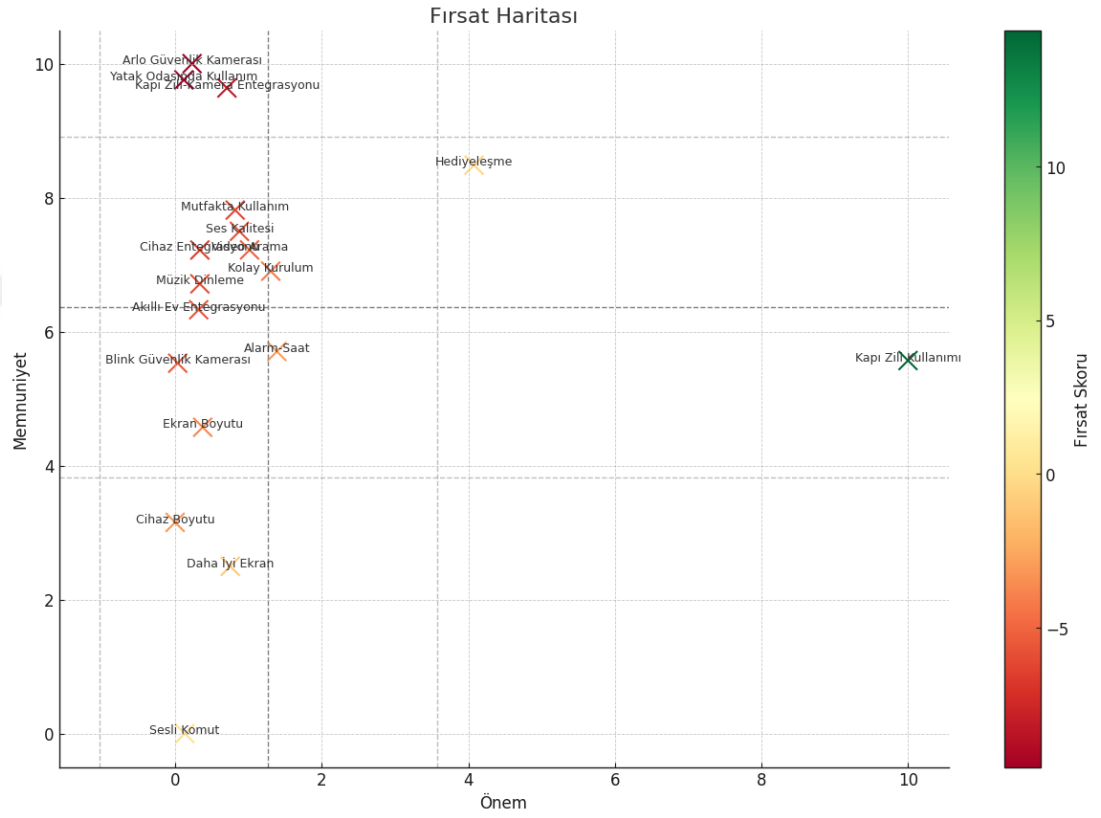
korunmalıdır. Yüksek Önem/Düşük Memnuniyet alanı iyileştirme için en kritik alanlardır ve öncelikli dikkat gerektirir. Düşük Önem/Yüksek Memnuniyet alanı çok fazla kaynak harcanmadan korunmalıdır. Düşük Önem/Düşük Memnuniyet alanı ise, genellikle düşük önceliklidir ve kaynak tahsisi açısından en az dikkate alınan alanlardır.

Önem düzeyine göre sıralandığında, ilk üç hizmet boyutunun Kapı Zili Kullanımı, Hediyeleşme ve Alarm-Saat özelliği olduğu görülmektedir. Memnuniyet düzeyine göre sıralandığında ise, kullanıcıların en çok tatmin olduğu özellikler, Arlo Güvenlik Kamerası, Yatak Odasında Kullanım ve Kapı Zili-Kamera Entegrasyonudur. Kullanıcıları en az tatmin eden özellikler ise, Sesli Komut, Daha İyi Ekran ve Cihaz Boyutu özellikleri olarak karşımıza çıkmaktadır. Ancak kullanıcıları en az memnun eden özellikler bunlar olmasına rağmen, kullanıcıların gözünde önemli olmadığı da görülmektedir. Hem memnuniyet hem de önem açısından düşük puan alan bir konu, tipik olarak şirketin aksiyon alması için düşük öncelikli olduğunu gösterir. İlgili konu, hedef kitle tarafından önemli olmadığında, bu konunun iyileştirilmesinin genel memnuniyetleri veya deneyimleri üzerinde önemli bir olumlu etki yaratması pek olası değildir. Bir konunun önem derecesinin sıfır olması, konunun hedef kitleyle ilgili olmadığı anlamına da gelebilir. Örneğin önem derecesi 0 çıkmış olan, Sesli komut özelliği, Amazon Alexa ürününün en temel bileşenidir. Sesli komut özelliği, Amazon Echo gibi ürünler için o kadar temel bir beklenti haline gelmiş olabilir ki, kullanıcılar tarafından artık farklı bir değer olarak görülmüyor olabilir. Bu, kullanıcıların sesli komut özelliğini bir ürünün olmazsa olmazı olarak kabul ettiklerini ve bu nedenle bu özelliğe yönelik özel bir takdir veya önem atfetmediklerini gösterebilir. Bazı durumlarda, düşük önem ve memnuniyete sahip konular, pazarda farklılaşma fırsatı bulunan niş alanları temsil edebilir. Bir işletme böyle bir konuyu ilgili ve önemli hale getirmenin bir yolunu bulabilirse, benzersiz bir satış önerisi yaratabilir.

Memnuniyet düzeyine göre kullanıcıların en çok tatmin eden Arlo Güvenlik Kamerası, Yatak Odasında Kullanım ve Kapı Zili-Kamera Entegrasyonu özellikleri şirkete, kaynakların etkin kullanımı ve sürekli iyileştirme için fırsatlar sunabilir. Öncelikli olarak bu konular şirkete öğrenme ve uygulama açısından fırsatlar sunmaktadır. Yüksek memnuniyet sağlayan bu unsurlar analiz edilerek, elde edilen bu başarının fırsat geliştirmenin diğer alanlarına nasıl uygulanabileceği değerlendirilebilir. Bu, genel performansı artırmak için iyi bir fırsat sunmaktadır. Ayrıca tüm konuların

dengeli bir şekilde ele alınması önemlidir. Bazı konular şu anda düşük öneme sahip olsa da bu durum gelecekte değişebilir. Bu nedenle, bu tür konuları tamamen göz ardı etmemek ve düzenli olarak gözden geçirmek iyi bir yaklaşım olacaktır.

Şekil 56: Amazon Echo Show 5 Ürünü İçin Fırsat Ortamı



Yüksek öneme ve düşük memnuniyete sahip olan ürün özellikleri, bir fırsat analizi yapılırken özellikle dikkate alınması gereken kritik alanlardır. Bu tür özellikler, müşteri memnuniyetini ve ürünün genel başarısını önemli ölçüde etkileyebilir. İlk olarak karşımıza çıkan “Kapı Zili Kullanımı” özelliği, genel bir teknoloji kullanımına işaret etmektedir. Amozan Alexa ürününün pek çok ürün, uygulama ve teknoloji ile entegrasyonu bulunmaktadır. Şekil 57’deki fırsat haritasında görüldüğü gibi, kullanıcılar diğer entegrasyon özellikleri söz konusu olduğunda memnuniyetlerini dile getirirken, bu özellikte kullanıcılar nezdinde bir memnuniyetsizlik, firma nezdinde ise bir fırsat gözükmektedir. Bu da kullancılar tarafından Amazon Alexa ürünü ile genel bir Kapı Zili Kullanım özelliğinin karıştırıldığı anlamına gelebilir. "Çalışır" ve "kullanmak" kelimeleri, müşterilerin ürünün işlevselliğine önem verdiğini gösterir. Kapı zilinin güvenilirliği, dayanıklılığı ve kullanım kolaylığı gibi temel işlevsel

özelliklere dikkat çeker. "Ekran" ve "müzik" kelimeleri, kullanıcıların kapı zili kullanımı konusunda dikkat çektiği teknolojik özellikleri belirtir. Kapı zilleri, özelleştirilebilir melodi seçenekleri, dokunmatik ekranlar ve hatta video görüntüleme gibi özelliklerle donanmıştır. "Aşk" ve "harika" gibi kelimeler, kullanıcıların estetik ve tasarım beklentileri konusundaki memnuniyetini yansıtır. Kapı zilinin tasarımı, modern ev dekorasyonu ile uyumlu ve görsel olarak çekici olacak şekilde güncellenmelidir. Bu Amazon sanal asistanın birlikte çalıştığı başka bir ürün olduğundan, firma bu konuda kullancıların "Kapı Zili Kullanımı" konusunda ne beklediğini net olarak anlamalı, buna uygun olarak ilgili potansiyel iş birliklerini ve ürün promosyonlarını gözden geçirmelidir.

Bir diğer fırsat alanı da "Hediyeleşme" olarak karşımıza çıkmaktadır. Müşterilerin "hediye" ve "ürün" kelimeleriyle ilgili memnuniyetsizlik yaşaması, ürün çeşitliliği veya kalitesiyle ilgili olabilir. Firma, ürün yelpazesini genişleterek ve kaliteyi artırarak müşteri beklentilerini daha iyi karşılayabilir. "Fiyat" kelimesi, müşterilerin satın alma kararlarında önemli bir faktördür. Şirketin fiyatlandırma stratejisi, müşteri algıları ve piyasa koşulları göz önünde bulundurularak yeniden değerlendirilmelidir. "Satın aldım" ve "satın almak" kelimeleri, satın alma sürecinin önemine işaret eder. Firma, satın alma sürecini basitleştirebilir, çevrimiçi ve çevrimdışı alışveriş deneyimini iyileştirebilir. "Aşk" ve "seviyor" kelimeleri, hediye almanın ve vermenin duygusal yönüne vurgu yapar. Şirketin pazarlama ve reklam kampanyaları bu duygusal bağı güçlendirerek, ürünlerinin "harika" bir hediye seçeneği olduğunu vurgulayabilir. "Yılbaşı" kelimesi, özel günlerde hediyeleşmenin popüler olduğunu gösterir. Şirketin yılbaşı gibi özel günlerde özel promosyonlar ve kampanyalar düzenlemesi müşteri ilgisini ve satışları artırabilir, ayrıca tekrar satın alma oranlarını yükseltmek için sadakat programları ve ödüllendirme sistemleri oluşturulabilir.

Kalan tüm diğer özellikler, düşük öncelik ve orta düzeyde memnuniyet alanına işaret etmektedir. Bu özelliklerinin, fazla kaynak harcamadan korunması gerekmektedir.

Tablo 18, Echo Show 8 ürününe dair her bir özelliğinin önemini ve memnuniyet düzeylerini, hesaplanan fırsat puanlarıyla birlikte özetlemektedir.

Tablo 18: Amazon Echo Show 8 Fırsat Analizi Sonuçları

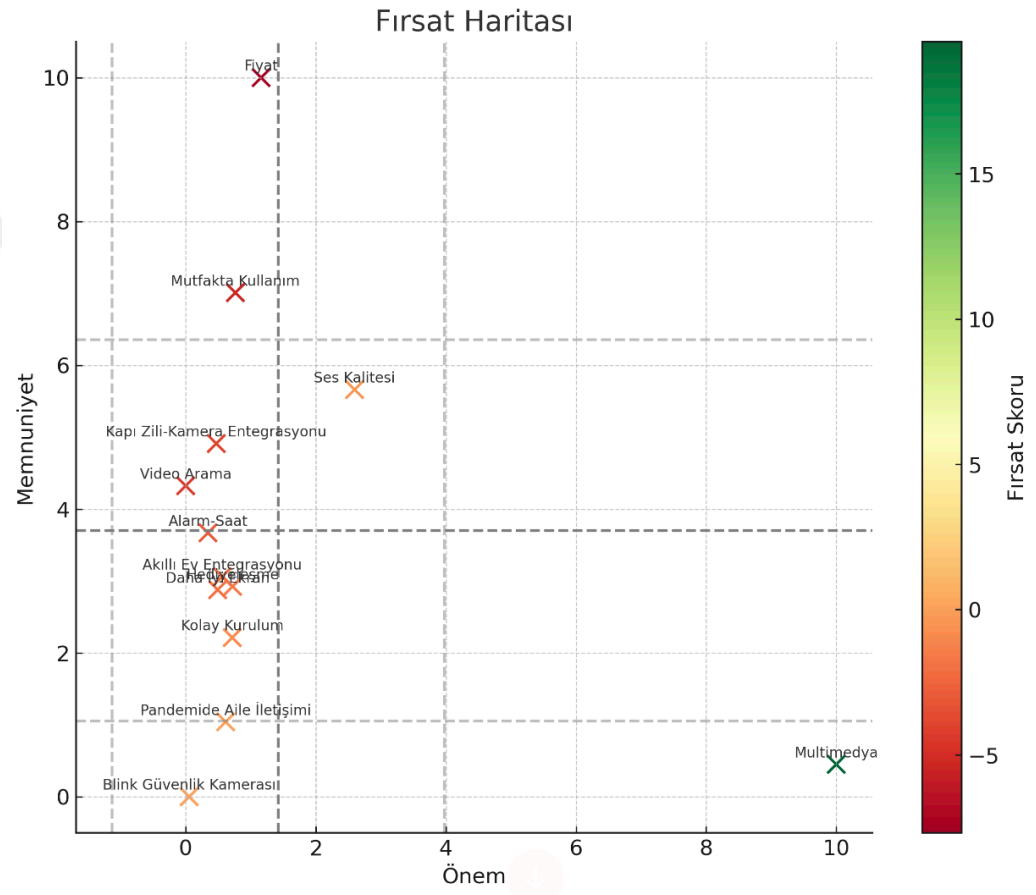
Konular	Önem	Memnuniyet	Fırsat
Multimedya	10	0,450415296	19,5495847
Ses Kalitesi	2,596153848	5,661498212	-0,469190517
Fiyat	1,159188021	10	-7,681623958
Mutfakta Kullanım	0,763888872	7,009482318	-5,481704573
Hediyeleşme	0,721153839	2,924887068	-1,482579391
Kolay Kullanım	0,715811959	2,212953499	-0,781329581
Pandemide Aile İletişimi	0,614316225	1,040843297	0,187789153
Akıllı Ev Entegrasyonu	0,560897433	3,061757069	-1,939962202
Daha İyi Ekran	0,491453003	2,878405827	-1,89549982
Kapı Zili – Kamera Entegrasyonu	0,470085458	4,911458363	-3,971287448
Alarm-Saat	0,341880328	3,669285793	-2,985525137
Blink Güvenlik Kamerası	0,053418792	0	0,106837584
Video Arama	0	4,324082716	-4,324082716

Önem düzeyine göre sıralandığında, ilk üç hizmet boyutunun Multimedya, Ses Kalitesi ve Fiyat özelliği olduğu görülmektedir. Memnuniyet düzeyine göre sıralandığında ise, kullanıcıların en çok tatmin olduğu özellikler, Fiyat, Mutfakta Kullanım ve Kapı Zili-Kamera Entegrasyonudur. Kullanıcıları en az tatmin eden özellikler ise, Blink Güvenlik Kamerası, Multimedya ve Pandemide Aile İletişimi konulu özelliklerdir. Bu özelliklerden Blink Güvenlik Kamerası, Amazon Alexa ürünüyle entegre olan Blink adlı markanın güvenlik kamerasıdır. Bu noktada kullanıcıların bu özelliğe pek fazla önem atfetmese de memnuniyetlerinin hiç olmadığı görülmektedir. Tıpkı Echo Show 5 modelinde, "Kapı Zili Kullanımı" özelliğinde önerildiği gibi, şirketin bu noktada entegre olduğu ürün seçimini gözden geçirmesi beklenebilir. Pandemide Aile İletişimi, kullanıcıların ürüne dair algılarının, pandeminin en yaygın olduğu zamanlardaki hassasiyetleri de göz önüne alınarak yeterince objektif olamadıkları anlamına gelebilir.

Memnuniyet düzeyine göre kullanıcıların en çok tatmin eden Fiyat, Mutfakta Kullanım, Kapı Zili-Kamera Entegrasyonu özellikleri şirkete, kaynakların etkin kullanımı ve sürekli iyileştirme için fırsatlar sunabilir. Firma, rekabetçi fiyatlandırma stratejilerini koruyarak ve maliyet etkin üretim yöntemleri geliştirerek, fiyat avantajını sürdürebilir veya artırabilirler. Mutfakta kullanıma yönelik ürün özelliklerini daha da geliştirerek ve teknolojik mutfak aletleriyle entegrasyonu iyileştirerek kullanıcı

deneyimini artırabilir ve ayrıca güvenlik özelliklerini güçlendirerek ve daha fazla akıllı ev cihazıyla entegrasyonu sağlayarak ürünün kullanım alanını genişletebilirler. Son olarak, bu üç özellik, pazarlama ve reklam kampanyalarında vurgulanabilecek, potansiyel müşteriler için çekici olabilecek anahtar satış noktaları olarak kullanılabilir.

Şekil 57: Amazon Echo Show 8 Ürünü İçim Fırsat Ortamı



Şekil 58'de gösterildiği gibi, "Multimedya" konusunun fırsat analizinde en çok geliştirilmesi gereken alan olarak belirlenmesi, Amazon Alexa gibi akıllı bir asistan ürününde, kullanıcıların sesli komutlarla multimedya içeriklerini yönetme deneyimini iyileştirmenin potansiyel bir fırsat olduğunu ifade eder. Kullanıcıların kişisel zevklerine ve tercihlerine göre multimedya önerileri sunulabilir. Kullanıcıların geçmiş dinleme ve izleme alışkanlıklarına dayalı özelleştirilmiş çalma listeleri ve içerik önerileri yapılabilir. Ayrıca farklı multimedya uygulama ve servisleriyle daha geniş entegrasyon sağlanarak, kullanıcıların sevdikleri içeriklere kolayca ulaşmaları

hedeflenebilir. Spotify, YouTube, Netflix gibi popüler platformların Alexa ile entegrasyonu bu açıdan önemlidir. Alexa'nın ses tanıma kabiliyetlerinin geliştirilmesi, kullanıcıların sesli komutlarla multimedya içeriklerini daha etkin bir şekilde kontrol etmelerini sağlayabilir. Son olarak, Alexa'nın ekranlı modellerinde, kullanıcı arayüzü daha sezgisel ve etkileşimli hale getirilebilir. Multimedya içeriklerin aranması ve yönetilmesi için görsel olarak zengin ve kullanımı kolay bir arayüz tasarlanabilir. Bir diğer geliştirilme fırsatı mevcut olan özellik ise Ses Kalitesidir. Kullanıcılar, müzik ve video oynatımında yüksek ses kalitesi beklerler. Amazon Alexa'nın entegre olduğu hoparlörlerin ses kalitesinin artırılması veya harici ses sistemleriyle daha iyi entegrasyon sağlanması üzerinde çalışılabilir.

3.5. Tartışma

Olasılıksal yöntemlerin doğası gereği BERTopic algoritması her çalıştırıldığında farklı bir çıktı verebilir. Ancak tüm çıktılar aynı şartlar altında tek seferde alındığı için, konuların karşılaştırılmasında bir sakınca bulunmamaktadır. Echo Show 5 ve Echo Show 8 modellerine dair yapılan konu modelleme tekniğinde 10 konunun iki ürün modelinde ortak olması sonuçların anlamlılığına işaret etmektedir.

3.5.1. Müşteri İçgörüleri ve Tercihleri

Tablo 19, Echo Show 5 ve Echo Show 8 modelleri için yapılan duygu analizi sonuçlarını içermektedir.

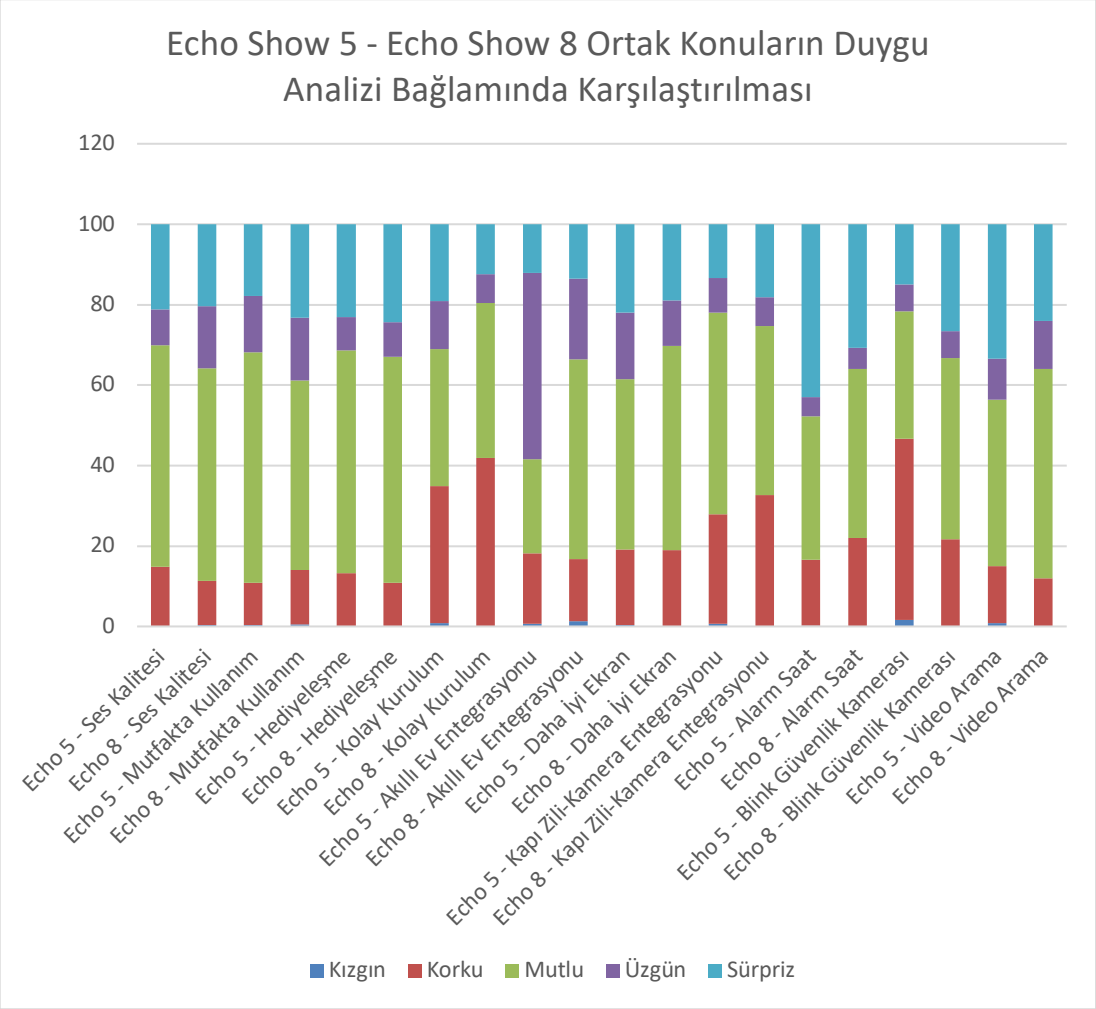
Tablo 19: Amazon Echo Show 5 ve Amazon Echo Show 8 Ürünlerinde Duyguların Karşılaştırılması

Konular	Kızgın	Korku	Mutlu	Üzgün	Sürpriz
Echo Show 5 - Ses Kalitesi	0	14,90683	54,96894	9,006211	21,11801
Echo Show 8 - Ses Kalitesi	0,373134	11,00746	52,79851	15,48507	20,33582
Echo Show 5 - Mutfakta Kullanım	0,328947	10,52632	57,23684	14,14474	17,76316
Echo Show 8 - Mutfakta Kullanım	0,518135	13,4715	47,15026	15,54404	23,31606
Echo Show 5 - Hediyeleşme	0,075873	13,20182	55,38695	8,270106	23,06525
Echo Show 8 - Hediyeleşme	0	10,81081	56,21622	8,648649	24,32432
Echo Show 5 - Kolay Kurulum	0,879121	34,06593	34,06593	11,86813	19,12088
Echo Show 8 - Kolay Kurulum	0	41,84783	38,58696	7,065217	12,5

Echo Show 5 - Akıllı Ev Entegrasyonu	0,671141	17,44966	23,48993	46,30872	12,08054
Echo Show 8 - Akıllı Ev Entegrasyonu	1,290323	15,48387	49,67742	20	13,54839
Echo Show 5 - Daha İyi Ekran	0,353357	18,72792	42,40283	16,60777	21,90813
Echo Show 8 - Daha İyi Ekran	0	19,01408	50,70423	11,26761	19,01408
Echo Show 5 - Kapı Zili-Kamera Entegrasyonu	0,743494	27,13755	50,18587	8,550186	13,3829
Echo Show 8 - Kapı Zili-Kamera Entegrasyonu	0	32,6087	42,02899	7,246377	18,11594
Echo Show 5 - Alarm Saat	0,2079	16,42412	35,55094	4,781705	43,03534
Echo Show 8 - Alarm Saat	0	21,92982	42,10526	5,263158	30,70175
Echo Show 5 - Blink Güvenlik Kamerası	1,666667	45	31,66667	6,666667	15
Echo Show 8 - Blink Güvenlik Kamerası	0	21,66667	45	6,666667	26,66667
Echo Show 5 - Video Arama	0,821918	14,24658	41,36986	10,13699	33,42466
Echo Show 8 - Video Arama	0	12	52	12	24

Ortak konular tek tek kıyaslandığında ortaya çıkan grafik, Şekil 59'da verilmiştir. Bir bakışta konuların duygularının nasıl değiştiğini gösteren başarılı bir çıktı sergilemektedir.

Şekil 58: Amazon Echo Show 5 ve Amazon Echo Show 8 Modellerinde Ortak Konuların Duygu Analizi Bağlamında Karşılaştırılması



Konular tek tek incelendiğinde, **"Ses Kalitesi"** bağlamında modeller arasında çarpıcı bir fark söz konusudur. Ancak bunun şirketin aleyhine olduğu görülmektedir. Echo Show 5 modelinde müşterilerde hiç "kızgın" olma durumu gözlenmemişken, Echo Show 8 modelinde bu duygu çıkmış hatta mevcut mutluluk duygusunda azalma gerçekleşmiştir. Sürpriz ve üzüntü duygularında artış beklenmedik özelliklere veya iyileştirilmesi gereken alanlara işaret ediyor olabilir.

"Mutfakta Kullanım" konusu söz konusu olduğunda müşteriler nezdinde Echo Show 8 modelinde olumsuz bir deneyime doğru ilerleme görülmektedir.

"Hediyeleşme" konusundaki korku duygusu Echo Show 5 ürününe göre, Echo Show 8 ürününde düşük çıkmış, buna karşın sürpriz ve mutlu duygularında artış

gözlenmiştir. Üzüntü duygusunda çok minör bir artış gözlemlense de kızgın duygusu Echo Show 8 ürününde hiç çıkmamıştır.

"Kolay Kurulum" konusunda kızgınlık duygusu Echo Show 8 modelinde çıkmamıştır. Korku duygusu artmasına rağmen, üzüntünün azalıp mutluluğun artması, cihaz kurulumlarının insanları ilk adımda doğal olarak kaygıya sürüklemesi, ancak sonuçtan memnun kaldıkları şeklinde yorumlanabilir.

"Akıllı Ev Entegrasyonu" söz konusu olduğunda Echo Show 8 modelinde mutlu ve sürpriz duygularında artış, korku ve üzgün duygularında düşüş gerçekleşmiştir. Kızgın duygusunda minör bir artış olsa da şirketin bu konuda müşteri beklentisi yönünde olumlu bir adım attığı söylenebilir.

"Daha İyi Ekran" konusunda, söz konusu olduğunda müşterilerin beklentilerinin neredeyse tamamının karşılandığı söylenebilir. Korku duygusunda çok minör bir artış gerçekleşse de pozitif duyguların artması, negatif duyguların azalması ve kızgın duygusunun tamamen sıfırlanması şirketin yeni modelinde kullanıcılarını memnun ettiği şeklinde yorumlanabilir.

"Kapı Zili – Kamera Entegrasyonu" konusunda yine Echo Show 5 ürününe göre Echo Show 8 ürününde kızgın duygusu hiç çıkmamış, mutlu ve sürpriz duygularında artış gözlenirken, üzgün duygusunda azalma olmuştur. Ancak korku duygusunda bir artış mevcuttur. Bu da teknolojik cihazların entegrasyonu söz konusu olduğunda müşterilerin doğal olarak bir korku duyduğu için, şirkete entegrasyon konularında daha anlaşılır ve yardımcı olması gerektiği konusunda bir işaret niteliğindedir.

"Alarm-Saat" özelliği dikkate alındığında iki model arasında kızgın duygusu yeni modelde sıfır çıkmış ve mutluluk duygusunda majör bir artış gözlemlenmiştir.

"Blink Güvenlik Kamerası Entegrasyonu" söz konusu olduğunda kızgın duygusu tamamen sıfırlanmış, mutlu ve sürpriz duygularda çarpıcı bir artış gözlenirken, korku duygusu azalmıştır. Bu da müşterilerin artık kamera entegrasyonu söz konusu olduğunda kendilerini güvende hissettiği, beklentilerinin tamamen karşılandığı şeklinde yorumlanabilir.

"Video Arama" konusunda yine kızgın duygusu Echo Show 8 modelinde sıfır çıkmış ve mutlu duygusunun Echo Show 5'e oranla epey yüksek olduğu görülmüştür. Bu da kullanıcıların arama özellikleriyle ilgili yeni modelde beklentilerinin karşılandığını göstermektedir.

Sonuçların tümüne bakıldığında, 7 özellikte kızgın olma durumunun tamamen sıfırlanmış olduğunu görmek anlamlıdır. Şirketin müşterilerini dinlediğini ve kızgın oldukları noktalarda önlem aldığını göstermektedir. Ayrıca 10 ortak özelliğin 8'indeki mutlu duygusunun artması da şirketin yeni modelde iyileştirici faaliyetlerde bulunduğunu ve müşterilerinin beklentilerini karşılamaya yönelik aksiyonlar aldığını göstermektedir. Amazon Echo ürünlerinin iki modeline dair incelenen büyük veri kümelerindeki bu anlamlılık, ağızdan ağıza pazarlamanın şirketler tarafından ürün geliştirme, hizmet iyileştirme, yeni özellik ekleme gibi pek çok aktivitesini desteklediğini göstermektedir. Sonuç olarak, bu konuları EAAP merceğinden analiz etmek, Echo serisinin güçlü yönlerini ve potansiyel büyüme alanlarını ortaya koymaktadır. Şirketler, yinelemeli tasarım süreçlerine rehberlik etmesi için EAAP'yi dikkatle takip etmeli ve bu sayede müşterileriyle birlikte yaratım fırsatını değerlendirmelidir. Her yeni modelde tüketicilerin gelişen beklentilerini karşılamakla kalmayıp, memnuniyetini sağlamalıdır.

3.5.2. Stratejik Pazar Fırsatları

Tablo 20, Echo Show 5 ve Echo Show 8 modelleri için yapılan fırsat analizi sonuçlarını içermektedir.

Tablo 20: Amazon Echo Show 5 ve Amazon Echo Show 8 Ürünleri İçin Fırsat Analizi

Konular	Önem	Memnuniyet	Fırsat
Echo Show 5 - Ses Kalitesi	0,877502	7,496775	-5,741771
Echo Show 8 - Ses Kalitesi	2,59615385	5,66149821	-0,4691905
Echo Show 5 - Mutfakta Kullanım	0,819655	7,813783	-6,174473
Echo Show 8 - Mutfakta Kullanım	0,76388887	7,00948232	-5,4817046
Echo Show 5 - Hediyeleşme	4,079073	8,484977	-0,326831
Echo Show 8 - Hediyeleşme	0,72115384	2,92488707	-1,4825794
Echo Show 5 - Kolay Kurulum	1,305018	6,901805	-4,291769
Echo Show 8 - Kolay Kurulum	0,71581196	2,2129535	-0,7813296
Echo Show 5 - Akıllı Ev Entegrasyonu	0,321424	6,325941	-5,683093
Echo Show 8 - Akıllı Ev Entegrasyonu	0,56089743	3,06175707	-1,9399622
Echo Show 5 - Daha İyi Ekran	0,752167	2,49579	-0,991456
Echo Show 8 - Daha İyi Ekran	0,491453	2,87840583	-1,8954998

Echo Show 5 - Kapı Zili-Kamera Entegrasyonu	0,707149	9,636115	-8,221817
Echo Show 8 - Kapı Zili-Kamera Entegrasyonu	0,47008546	4,91145836	-3,9712874
Echo Show 5 - Alarm Saat	1,388601	5,703692	-2,92649
Echo Show 8 - Alarm Saat	0,34188033	3,66928579	-2,9855251
Echo Show 5 - Blink Güvenlik Kamerası	0,035338	5,528545	-5,457869
Echo Show 8 - Blink Güvenlik Kamerası	0,05341879	0	0,10683758
Echo Show 5 - Video Arama	1,015745	7,218814	-5,187324
Echo Show 8 - Video Arama	0	4,32408272	-4,3240827

Echo Show 5 modelinde **"Ses Kalitesi"** için önem oranı düşükken ve memnuniyet oranı yüksekken (-5.74 fırsat skoru), Echo Show 8'de bu oranlar önemli ölçüde değişmiş ve fırsat skoru -0.46'ya yükselmiştir. Bu durum, kullanıcıların ses kalitesine daha fazla önem verdiği halde memnuniyetin düştüğüne ilişkin bulgu sunmaktadır. Yeni modelde ses kalitesindeki eksikliğe dair firmanın konu hakkında daha detaylı analiz yaparak aksiyon alması gerekmektedir.

"Mutfakta Kullanım" için Echo Show 5'teki fırsat skoru -6.17 iken, Echo Show 8'de bu skor -5.48'e yükselmiştir. Bu, Echo Show 8'in Mutfakta kullanım konusunda bir miktar daha iyi performans gösterdiğini işaret etmekte, ancak hala bir fırsat alanı kaldığını göstermektedir.

Echo Show 5 modelinde **"Hediyeleşme"** özelliği yüksek önem ve memnuniyet puanlarına sahipken, Echo Show 8 modelinde bu değerler düşmüştür. Bu düşüş, hediyeleşmenin Echo Show 8 için daha az önemli bir konu olduğunu ve çünkü Echo Show 8 modelindeki diğer özelliklerin daha fazla ön plana çıktığını gösterebilir. Bu, iyileştirme için daha az aciliyeti olan bir alandır, ancak memnuniyeti korumak için aksiyon alınması gereklidir.

Echo Show 5'te kullanıcılar **"Kolay Kurulum"** konusuna yüksek önem göstermişken Echo Show 8'de bu konuda önemli bir gerileme görülmektedir. Önem düzeyinin düşmesi fırsat alanını ortadan kaldırırken, memnuniyet düzeyinde azalma gelecekteki modeller için daha kullanıcı dostu bir kurulum sürecine ihtiyaç olduğunu göstermektedir.

Echo Show 5 için **"Akıllı Ev Entegrasyonu"** düşük bir fırsat alanıyken (-5.68 fırsat skoru), Echo Show 8'de memnuniyet seviyesi düşmüştür. Bu, Echo Show 8'in bu

alanda bazı kullanıcı beklentilerini karşılamakta yetersiz kaldığını gösterebilir. Yine de unutulmamalıdır ki, entegrasyon söz konusu olduğunda, yalnızca Amazon Echo'dan değil, Amazon Echo'ya entegre olan tüm bileşenlerden söz edilmelidir. Bu da tamamen firmayla ilintili olmayan konuları kapsayabilir. Ancak bu noktada da entegre edilecek bileşenlerle ilgili kalite ve test sürecini şirketin daha iyi takip etmesi gerektiği anlamı çıkabilir.

Echo Show 5'te **"Daha İyi Ekran"** konusunda orta düzeyde bir fırsat varken, Echo Show 8'de memnuniyet artmış ve fırsat skoru düşmüştür. Bu, şirketin ekran kalitesi özelliğinde Echo Show 8 modelinde iyileştirmeler yaptığını ve kullanıcıların bu değişikliklerden memnun olduğunu göstermektedir.

Echo Show 5'te **"Kapı Zili-Kamera Entegrasyonu"** özelliği için çok yüksek bir fırsat skoru varken, Echo Show 8'de bu skor azalmıştır. Ancak, hala negatif bir fırsat skoru bulunduğu için, bu özellikte daha fazla iyileştirme yapılması gerektiği anlaşılmaktadır. Karışık duygular, bu özellikle ilgili farklı kullanıcı deneyimlerini yansıtmakta ve daha rafine bir entegrasyon ve işlevsellik ihtiyacını ortaya koymaktadır.

"**Alarm-Saat"** özelliğinde kullanıcıların memnuniyet düzeyi azalmış olsa da bu özelliğe atfettikleri önem değerinde de azalma görülmektedir. Bu durum kullanıcı beklentileri tam olarak karşılanamasa da şirketin belli ölçüde iyileştirmeler yaptığını göstermektedir.

"Blink Güvenlik Kamerası" özelliği Echo Show 5 modelinde az önem derecesine ve yüksek memnuniyete sahipken, Echo Show 8 modelinde, önem derecesi çok az bir seviye yükselmişken, memnuniyet tamamen sıfırlanmıştır. Bu durum, önem derecesi düşük olsa da şirketin yeterli kaynak ayırıp ilgili özelliklere dair memnuniyet derecelerini belli bir seviyede tutmaya yönelik kaynak planlaması yapması gerektiğini bir kez daha göstermiştir.

"Video Arama" özelliğinde Echo Show 5'te video arama konusunda yüksek memnuniyet seviyesi varken, Echo Show 8'de bu özellik için önem derecesi sıfıra inmiştir. Bu, Echo Show 8'de video aramanın önceki modelde olduğu kadar vurgulanmadığını ve artık yeni özelliklerin tanıtımı yapıldığı şeklinde yorumlanabilir.

Sonuç olarak, Fırsat Analizi, önem ve memnuniyet seviyelerini ölçerek şirketler için stratejik bir içgörü katmanı yaratmakta ve böylece gelecekteki ürün geliştirme döngülerinde çabaların ve kaynakların nereye yoğunlaştırılması gerektiğine rehberlik

etmektedir (A. Ulwick, 2005). Bu ortak konuların gelişimi, EAAP'nin sürekli inovasyon sürecini şekillendirmedeki dönüştürücü gücünün bir kanıtıdır.

3.6. Sonuç

Amazon Echo Show modelleri üzerinden yapılan duygu ve fırsat analizleri, müşteri geri bildirimlerinin ve birlikte yaratım pratiklerinin, ürün geliştirme süreçlerinde oynadığı merkezi role dair değerli içgörüler sunmaktadır. Duygu Analizi, müşterilerin her bir ürün modelinde neler hissettiğini belirgin bir şekilde gözler önüne sererken (Gao vd., 2018), Fırsat Analizi şirketin ürüne yönelik stratejik gelişim alanlarını ortaya çıkarmaktadır (A. W. Ulwick, 2002).

Duygu analizi sayesinde şirketler, müşterilerinin olumlu ve olumsuz duygularını değerlendirerek, müşterileri ile karşılıklı bir etkileşime girerler (Black & Veloutsou, 2017). Genel olarak daha olumlu duygulara sahip bir ürün, muhtemelen müşteri ihtiyaçlarını, olumsuz duygulara sahip bir üründen daha etkili bir şekilde karşılamaktadır. Bir ürün modelindeki belirli bir özelliğe yönelik olumlu duyguların diğerine göre daha yüksek olması rekabet avantajına işaret edebilir. Ayrıca duygu analizi, müşteri beklentilerinin ne ölçüde karşılandığı konusunda şirketlere yol gösterebilir (Healy & McDonagh, 2013). Bir ürünün yeni bir modeli öncekinden daha az olumlu görüş alıyorsa, bu yeni modelin önceki model tarafından belirlenen müşteri beklentilerini karşılamadığını gösterebilir. Bunun yanısıra, bir üründe değişiklikler veya iyileştirmeler yapılırsa, duygu analizi bu değişikliklerin müşteri memnuniyeti üzerindeki etkisini ölçebilir. Duygu analizinden elde edilen bilgiler, gelecekteki modellerde hangi özelliklerin korunması, iyileştirilmesi veya muhtemelen kaldırılması gerektiğini vurgulayarak gelecekteki ürün geliştirme süreçlerine bilgi sağlayabilir (Mingione vd., 2020).

Fırsat Analizi sayesinde, şirketler, bir ürünün önemli olan ancak şu anda müşteri memnuniyetinde düşük performans gösteren özelliklerini veya yönlerini belirleyerek, bu alanları iyileştirme için önceliklendirebilir, ayrıca tüketicinin gözünde hangi özelliklerin veya faydaların daha önemli hale geldiğini ortaya çıkararak ürün geliştirmenin pazar talebiyle uyumlu hale getirilmesine yardımcı olabilir (A. Ulwick, 2005). Hangi alanların müşteri memnuniyeti ve satışlar üzerinde en büyük etki fırsatını sunduğuna bakarak, gelecek modeller için içgörüler geliştirebilir, buna uygun kaynak tahsisi yapabilir (Christensen vd., 2016). Bir ürün modelinin basit bir güncellemeye

mi, tamamen yeniden tasarlanmaya mı ihtiyacı olduğunu ya da üretimden kaldırılıp kaldırılmayacağını ortaya çıkararak stratejik karar alma sürecine yardımcı olabilir. Farklı modellerle fırsatların nerede yattığını anlamak, müşteriler için önemli olan ihtiyaçları ve sorunları ele alarak müşteri sadakatini ve elde tutmayı artıracak stratejiler oluşturmaya yardımcı olabilir (Cooper, 2019). Fırsat analizi, potansiyel sorunları daha büyük sorunlara dönüşmeden önce tespit ederek markanın itibarını koruyarak bir risk yönetimi biçimi de olabilir (Enkel vd., 2005). Sonuç olarak, Duygu Analizi ve Fırsat Analizi, işletmelerin müşteri odaklı yaklaşımlarını güçlendirmeleri, pazar dinamiklerine hızla uyum sağlamaları ve teknoloji endüstrisinde rekabetçi kalmaları için değerli araçlar olarak öne çıkmaktadır (Ozansoy Çadırcı vd., 2022).

Bu çalışmanın vurguladığı gibi, teknolojik ürünlerin hızla değişen pazarlarındaki rekabet avantajı ve müşteri sadakati, müşterilerle etkileşim ve onların geri bildirimlerine önem vermekle doğrudan ilişkilidir (Brill vd., 2019). EAAP gibi araçlar aracılığıyla yapılan birlikte yaratım, işletmeler için stratejik bir avantaj sağlamakta ve müşteri beklentileriyle ürünler arasında önemli bir köprü kurmaktadır (Gruen vd., 2006). Bu süreçte, müşterilerin geribildirimleri ve katılımları, ürün geliştirme ve inovasyon süreçlerinde kritik bir rol oynamaktadır. Müşteriler, kendi deneyimleri ve ihtiyaçları doğrultusunda yaptıkları yorumlarla, şirketlerin ürünlerini ve hizmetlerini nasıl geliştirebilecekleri konusunda değerli içgörüler sunmaktadır. Bu etkileşim, müşterilerin şirketle ve ürünle daha güçlü bir bağ kurmasına olanak tanıyarak birlikte yaratım sürecini desteklemektedir (Ahn vd., 2019; Iglesias vd., 2013).

3.6.1. Sınırlılıklar ve Gelecek Araştırmalar

Her araştırma gibi bu çalışma da belirli sınırlılıklara sahiptir. Amazon Echo Show 5 ürünü 2018'de, Amazon Echo Show 8 ürünü ise ilk olarak 2019 sonunda pazara sunulmuştur (Wikipedia, 2024). Çalışmaya konu olan veri kümeleri, verinin çekildiği andaki erişilebilir olan versiyonların müşteri yorumlarından oluşmaktadır. Her bir ürünün zamanla farklı versiyonları pazara sürülmüştür. O nedenle, aynı ürünün farklı versiyonları arasında karşılaştırmalar da yapılabilir. Bu şirketlere, daha kırılımlı ve detaylı bir bakış açısı sağlayacaktır.

Kullanıcı deneyimi üzerine odaklanan detaylı çalışmalar yapılabilir. Kullanıcı yorumlarındaki duygu analizinin ötesine geçerek, kullanıcıların ürünle etkileşimleri sırasında karşılaştıkları zorlukları daha iyi anlamak için kullanıcı testleri ve gözlem

çalışmaları yapılabilir. Örneğin, müşterilere yapılandırılmış anketler gönderilerek versiyon özelinde daha detaylı geri bildirimler elde edilebilir. Ayrıca, bu çalışma yalnızca bir ürün üzerine odaklanmıştır. Çalışmanın, farklı ürün kategorileri veya markalar arasında genişletilmesi elde edilen bulguların genel geçerliliğini test etmeye ve sektörel farklılıkları ortaya koymaya yardımcı olabilir.

Bu çalışmada, müşterileri yorumlarının incelenmesinde ve anlamlandırılmasında yeni bir teknik olan BERTopic konu modelleme yöntemi kullanılmıştır. Bu tez kapsamında yapılan birinci çalışmada, pazarlama perspektifi açısından semantik anlamlılığı en iyi yöntem olarak BERTopic önerilse de bunun veri kümesi ile ilişkili olabileceği ifade edilmiştir. Gelecekteki çalışmalar, farklı veri kümeleri ile çalıştıklarında farklı konu modelleme tekniklerinin etkinliğini sınayabilir. Bununla birlikte veri kümelerinde dil perspektifinden bakıldığında, bu araştırma yalnızca İngilizce dilinde yazılmış kullanıcı yorumlarını içermekte, diğer tüm dil verilerini hariç tutmaktadır. Bu durum, kullanıcıların tercihlerine ilişkin önemli bilgilerin göz ardı edilmesine yol açabilir. Gelecek araştırmalar, çeşitli dillerdeki kullanıcı yorumlarını içerecek şekilde genişletilmiş veri kümelerini analiz ederek, küresel çapta daha kapsayıcı ve holistik bir müşteri görüşü sunabilir.

Ayrıca bu çalışmada yalnızca bir pazaryerinden edinilmiş müşteri yorumları analiz edilmiştir. Gelecek araştırmalar, ilgili ürünün sosyal medya verilerini de içerecek daha geniş bir veri seti üzerinde incelenebilir. Sosyal medya analitiği ve çeşitli medya platformlarından elde edilen verilerin entegrasyonu, müşteri tercihleri ve eğilimlerinin daha derinlemesine anlaşılmasını sağlayarak, şirketlere müşteri odaklı stratejiler geliştirmede rehberlik edebilir. Bu, EAAP iletişiminin etkisini daha net bir şekilde ortaya koyacak ve şirketlerin müşteri ilişkileri yönetimini geliştirmelerine yardımcı olacaktır.

4. TEKNOLOJİ ETKİLEŞİMİ: SANAL ASİSTANLAR ÜZERİNDEN MEVCUT MÜŞTERİ VERİSİYLE MODEL ÖNERİSİ

4.1. Giriş

Artık sadece dijital araçlar değil, aynı zamanda yapay zekâ uygulamaları da insanların hayatlarını kolaylaştıran önemli bir platform olarak karşımıza çıkmaktadır. Yapay zekâ, insanlar yerine düşünebilmekte, insan davranışlarını öğrenip taklit edebilmekte ve en önemlisi insanlar gibi karar verebilmekte olan program, algoritma, sistem ve makineleri ifade etmektedir (Shankar, 2018).

Amazon Alexa, Amazon tarafından geliştirilen, yapay zekâ temelli bir sanal asistandır. Bu platformun donanım alt yapısını sağlayan Amazon Echo, çeşitli görevleri gerçekleştirmek için kullanıcılarından sesli komutlar alabilen bulut özellikli ilk kablosuz hoparlördür. Bu sistemler kullanıcın sesi vasıtasıyla, bir soruyu yanıtlama, önerilerde bulunma gibi eylemler gerçekleştirerek kullanıcılara yardım sağlamaktadır. (Hauswald vd., 2015). Özellikle akıllı telefonlarda (örneğin Apple Siri, Google Now veya Microsoft Cortana) diğer sesle etkinleştirilen yardımcılar zaten mevcut olsa dahi, Amazon Echo ev ortamları için tasarlanmıştır ve medyada sıklıkla "geleceğin bilgisayarı" olarak anılmaktadır (Kelly, 2014). Kullanıcıların, mevcut pazar liderleri tarafından sunulanlar da (örneğin Apple Siri, Google Now, Amazon Alexa) dahil olmak üzere dijital asistanları hızla benimsediği tespit edilmiştir (Goksel Canbek & Mutlu, 2016). Hatta kullanıcılar, Amazon Echo'yu sadece elektronik bir cihaz olarak değil, aynı zamanda günlük yaşamlarında bir karakter olarak gördükleri, bazılarının Amazon Echo ile yakın bir ilişki geliştirerek "ona" en iyi arkadaşı, kız arkadaşı veya aile üyesi gibi davrandığı ortaya konulmuştur (Gao vd., 2018).

Amazon Alexa, kullanıcının isteğine göre müzik çalan, hava durumu sorgularına cevap veren, alarm kurmakta kullanılan ve ev ortamında mevcut olan diğer cihazları kontrol etmekte faaliyet göstermektedir. Kullanıcı tarafından belirlenen, genellikle “Hey, Alexa” şeklinde bir hitap cümlesi ile kullanıcı direktiflerini almaya hazır hale gelmektedir. Bu işlevleri yerine getirebilmek için ev ortamında bulunan bir Wifi

modem ile internete bağlanmaktadır (Lopatovska vd., 2019). Kısaca, kullancılar için ev ortamında asistanlık yapan bir yapay zekâ cihazıdır. Giderek artan bir şekilde, insanlar sanal asistan cihazlara sahip olmakta ve internete erişmektedir. Kullanıcılar özellikle sosyal medya ve sosyal ticaret platformlarında çevrimiçi olarak cihazlarla ilgili bilgilerini, deneyimlerini, endişelerini paylaşmak için birbirleriyle bağlantı kurmaktadırlar. Amazon, eBay ve Best Buy gibi elektronik pazarlar, kullanıcılarının deneyimlerini geri bildirimler ve derecelendirmeler (ratings) yoluyla paylaşmalarına olanak tanımaktadır (Kar & Dwivedi, 2020). Bu tür büyük verilerin erişilebilirliği, veri odaklı çalışmalar yapılmasını kolaylaştırmakla beraber (Grover vd., 2020) teori inşa etmede hala eksikler olduğu görülmektedir (Kar & Dwivedi, 2020).

Bu çalışma, kullanıcılar tarafından oluşturulan içeriklerin analizine dayalı büyük veri araştırmalarıyla, Kar & Dwivedi (2020) tarafından önerilen gelecek çalışma alanlarından biri olan teknoloji etkileşimini açıklama amacını gütmektedir. Teknoloji etkileşimi, kullanıcıların teknoloji ile etkileşimini ve benimseme süreçlerini kapsayan bir kavramdır. Teknoloji alanında etkileşim, bireyin herhangi bir teknolojiyle etkileşime girdiğinde meydana gelen son derece keyifli bir deneyimle odaklanmış bir dahil olma ve derin katılım durumu olarak kavramsallaştırılmıştır (Agarwal & Karahanna, 2004; Calvo-Porral & Pesqueira-Sanchez, 2022). Yapay zekanın hayatımıza girmesiyle birlikte, Kaartemo & Helkkula (2018), Teknoloji Etkileşimini, otonom alışveriş cihazları için yeni bir müşteri etkileşim formu olarak ifade etmektedir. Pazarlama araştırmacıları bu alana giderek daha fazla ilgi duymakta, kullanıcıların sürükleyici teknolojileri nasıl benimsediğini, kullandığını, deneyimlediğini ve bunlara nasıl tepki verdiğini araştırmaktadır (Dwivedi vd., 2021; R. P. Kumar vd., 2023). Enginkaya & Esen'e (2014) göre, müşteri memnuniyeti, müşterinin ürün ya da hizmetlere ilişkin deneyimlerinin beklentileri ile kıyaslamalarına bağlı ortaya çıkan psikolojik durumları ifade etmektedir. Müşteri memnuniyeti, müşteri etkileşimi, teknoloji kabulü, teknoloji etkileşimi gibi kavramlar çok yönlü, birbirleriyle içiçe geçmiş kavramlardır. Bazı çalışmalarda teknoloji etkileşiminin memnuniyeti arttırdığı gösterilirken, bazı çalışmalarda, müşteri memnuniyetinin teknoloji etkileşimi sağladığı önerilmektedir. Örneğin, R. P. Kumar vd. (2023) müşteri bağlılığını (duygusal ve rasyonel) anlamada, teknoloji kabul modelinin müşteri memnuniyeti üzerindeki etkisini incelemişlerdir. Busalim vd. (2020) tarafından yapılan çalışmaya göre ise müşteri memnuniyeti, müşteri

etkileşiminin oluşmasında pozitif etkilidir. Sun, (2016) tarafından yapılan çalışmada memnuniyet, algılanan tutarlılık/algılanan uyarlanabilirlik ile mobil hizmetlerin benimsenmesi arasında bir aracı olarak ele alınmıştır.

Bu çalışmada, teknoloji etkileşiminin müşteri memnuniyetini arttırdığı öne sürülmüştür. Teknoloji kabul modelinin müşteri memnuniyeti ve bağlılığı üzerindeki etkisi bilinmektedir (R. P. Kumar vd., 2023) ancak yapay zekâ destekli ürünlerde kullanıcının ürünü benimsemesinde daha etkin olan Teknoloji Etkileşimi kavramı önerilmiştir. Teknoloji Etkileşimi, "Kullanım Kolaylığı", "Kalite" ve "Değer" değişkenlerinden oluşmaktadır. Yapay zekâ destekli ürünlerin kabulüne ilişkin önerilen bu model literatürde ilk defa kullanılmaktadır.

Bu çalışma, literatüre çeşitli yenilikler sunmaktadır. Öncelikle, sanal asistan kullanıcılarını, kalite, değer ve kullanım kolaylığı ölçütleri üzerinden homojen gruplara ayıran bir segmentasyon uygulanmıştır. Bu segmentasyon, müşteri memnuniyetinin daha iyi anlaşılmasında kritik bir rol oynamaktadır. İkinci olarak, araştırma, müşteri memnuniyetini artırmanın anahtarının Teknoloji Etkileşimi olduğunu ileri sürmektedir. Bu kavram literatürde nispeten yeni olup, büyük veri analiziyle ele alınan ilk çalışmalardan biridir. Üçüncüsü, kullanıcıların teknolojiyi kullanmaya devam ettikçe Teknoloji Etkileşimi ve dolayısıyla müşteri memnuniyetinin arttığını göstermiştir. Nihayetinde, çalışma, ürün sahipliği süresinin hangi müşteri grupları üzerinde etkili olabileceğini analiz ederek, şirketlere ürün geliştirme ve pazarlama stratejilerinde odaklanmaları gereken hedef segmentler hakkında değerli bilgiler sağlamıştır. Ayrıca, kullanıcıların iki farklı ürün sahibi olma sürelerine göre, algılanan kalite, değer ve kullanım kolaylığındaki değişimleri açığa çıkarmış ve böylece yapay zekâ kullanıcılarının ürüne bakış açılarını detaylı bir şekilde ortaya koymuştur.

4.2. Literatür Taraması

4.2.1. Sanal Asistanlar

Sanal asistanlar, modern dijital ekosistemlerin ayrılmaz bileşenleri olarak ortaya çıkmış ve kişisel üretkenlik, müşteri hizmetleri ve akıllı ev otomasyonu gibi çeşitli alanlarda önemli roller üstlenmiştir (García de Blanes Sebastián vd., 2022). Bu literatür taraması, sanal asistanların evrimi, mevcut uygulamaları ve hızla ilerleyen bu

alanda beklenen gelecek trendleri hakkında kapsamlı bir genel bakış sağlamayı amaçlamaktadır.

Sanal Asistanlar doğal dil işleme ve yapay zekâ algoritmaları kullanarak teknoloji ile etkileşimimizi yeniden tanımlamaktadır (Kudina, 2021). Amazon Alexa ile ilgili yaptıkları çalışmada Lopatovska vd. (2019) 19 katılımcıdan veri toplamak için çevrimiçi anketler ve günlük yönteminleri kullanmış ve görev tercihleri, zamansal eğilimler ve kullanıcı memnuniyeti dinamikleri dahil olmak üzere Amazon Alexa kullanımındaki kalıpları ortaya çıkarmıştır. Pitardi & Marriott (2021) yaptıkları çalışmada, İnsan-Bilgisayar Etkileşimi Teorileri ve Para-Sosyal İlişki Teorisini entegre ederek, kullanıcılar ve sanal asistanlar arasındaki ilişkilerde güven oluşumunu araştırmıştır. Karma bir yöntem yaklaşımı kullanan araştırma, ilk olarak 466 katılımcıyla Kovaryans Tabanlı Yapısal Eşitlik Modellemesi aracılığıyla önerilen modeli nicel olarak incelemiş, ardından nitel bir çalışma ile dört ana tema belirleyerek işlevsel unsurların kullanıcıların tutumlarını yönlendirdiğini, sosyal niteliklerin, özellikle de sosyal mevcudiyet ve sosyal bilişin güven geliştirmede benzersiz öncüller olduğunu ortaya koymuştur. Bir başka araştırmada sanal asistanların kullanımına ilişkin kavramsal bir model sunmuş ve 724 kullanıcıdan oluşan bir örneklem ile Yapısal Eşitlik Modellemesi kullanılarak modelin ampirik bir doğrulamasını yapmıştır (McLean & Osei-Frimpong, 2019). Bulgular, bireylerin sanal asistanlar tarafından sağlanan (1) faydacı faydalar, (2) sembolik faydalar ve (3) sosyal faydalar tarafından motive edildiğini göstermiştir. Sonuçlar, hedonik faydaların yalnızca daha küçük hanelerde sanal asistan kullanımını motive ettiğini gösterirken, algılanan gizlilik risklerinin ise, sanal asistanların kullanımını azaltmada ve olumsuz yönde etkilemede aracı bir rol oynadığını ortaya koymuştur. Soegijapranata Katolik Üniversitesi tarafından geliştirilen sanal asistan Vanika'nın öğrenciler ve aday öğrenciler arasındaki kabulünü araştıran bir çalışmada (Gunadi vd., 2019), 200 anket analiz edilmiş ve "Bilgi Hizmet Kalitesi", "Algılanan Kullanım Kolaylığı" ve "Algılanan Kullanışlılığın" "Davranışsal Niyet" ile ilişkili olduğu önerilmiştir. Sadece "Bilgi Hizmet Kalitesinin", "Davranışsal Niyet" üzerinde istatistiksel olarak anlamlı bir doğrudan etkisi ortaya konmuştur. Aday öğrenciler üniversite bilgilerini aramak için öğrencilerden daha fazla zaman harcamaktadır, ancak öğrenciler Vanika'nın kullanımını daha kolay bulmaktadır. Ayrıca, erkeklerin bilgi aramak için daha fazla zaman harcadığı ve kadınların Vanika'yı kullanmak için daha fazla niyet ifade ettiği

cinsiyet farklılıkları gözlemlenmiştir. Kudina (2021), çalışmasında özellikle dijital sesli asistanlar örneği üzerinden, teknolojinin benimsenmesi sırasındaki ahlaki dinamikleri inceleyerek, yapay zekâ destekli bu cihazların ahlaki eğilimleri, kararları ve değerleri nasıl etkilediğini araştırmıştır. Sanal asistanların yaygın olarak benimsenmesi, tüketici karar verme süreçlerinde rutin görevlerin ötesine geçerek satın alma kararlarını da içeren bir değişime yol açmaktadır. Dellaert vd. (2020) tarafından hazırlanan makalede, geleneksel çevrimiçi satın alma işlemlerinden yapay zekâ destekli ses tabanlı diyaloglara geçerken tüketicilerin karar verme süreçlerindeki potansiyel değişiklikleri detaylandıran önermeler ortaya koyulmuştur Tüketici-firma etkileşiminin bu dinamik alanında daha fazla akademik araştırmayı teşvik etmeyi amaçlayan makale, aynı zamanda pazarlama yöneticilerine, sanal asistanların tüketici kararları üzerindeki gelişen etkileri üzerine öneriler sunmaktadır. Sanal asistanların kullanımının artması aynı zamanda güvenlik ve mahremiyet konularını da gündeme taşımaktadır. Sanal asistanların her ne kadar kullanıcıya büyük bir kolaylık sağlasa da bu sistemler kullanıcı verilerini buluta aktardığı ve depoladığı için gizlilik ve güvenlik endişelerini de beraberinde getirmektedir. Bolton vd. (2021), sanal asistanlara dair mevcut güvenlik açıklarını, kötü niyetli saldırıları ve yetkisiz ses kayıtlarıyla ilgili endişeleri vurgulayarak, güvenlik ve gizlilik sorunları hakkında literatürün kapsamlı bir incelemesini yapmıştır. Dunin-Underwood (2020), çalışmasında sanal asistanların Amerikalıların günlük yaşamlarına entegrasyonunu ve özellikle gönüllü olarak paylaşılan bilgileri yöneten geleneksel üçüncü taraf doktrini ile ilgili olarak mahremiyet üzerindeki etkilerini araştırmıştır. Akıllı cihazlar daha sofistike hale geldikçe, bireyler üçüncü taraflarla kapsamlı kişisel veriler paylaşmakta, bu da üçüncü taraf doktrininin sanal asistanlar bağlamında uygulanabilirliği hakkında sorular ortaya çıkarmaktadır. 55.502 incelemenin analiz edildiği bir başka araştırmada içerik analizi ve duygu analizi teknikleri kullanılmıştır. Bulgular, önemli sayıda yorumcunun Amazon Alexa'yı bir asistan, arkadaş veya aile üyesi olarak kişileştirdiğini, hatta bazılarının eşleriyle kıyaslamalar yaptığını ortaya koymuştur (Gao vd., 2018).

Teknoloji gelişmeye devam ettikçe, sanal asistanların bireylerin dijital ortamlarla etkileşim biçimlerini şekillendirmede giderek daha önemli roller oynaması muhtemeldir; bu da bu alanda devam eden araştırmaları, ortaya çıkan zorlukları ele almak ve yeni olasılıkların kilidini açmak için gerekli kılmaktadır.

4.2.2. Teknoloji Etkileşimi

Hızla gelişen teknolojik ortamda, teknoloji etkileşimi kavramı, kullanıcı deneyimlerini şekillendirmede ve dijital yeniliklerin başarısını etkilemede giderek daha önemli hale gelmiştir. Kullanıcıların teknolojik çözümlerle nasıl etkileşime girdiğini ve bunları nasıl benimsediğini anlamak, kullanıcılarda yankı uyandıran ürünler yaratmak isteyen işletmeler ve geliştiriciler için giderek daha büyük bir önem kazanmaktadır. Teknoloji etkileşimini neyin yönlendirdiğini anlamak, kullanıcı merkezli deneyimler yaratmanın merkezinde yer almaktadır. Bu çalışmada, kullanıcıların belirli bir teknolojiyi benimseme ve kullanmaya devam etme kararlarını etkilemede önemli rol oynayan temel belirleyiciler, kullanım kolaylığı, algılanan değer ve kalite olarak tanımlanmaktadır.

Teknoloji Etkileşimini tanımlamadan önce, teknoloji literatüründe en sık başvurulan modellere değinmek gerekir. Teknolojinin benimsenmesine ilişkin pazarlama alanındaki baskın teoriler arasında, Gerekçeli Eylem Teorisi (Fishbein & Ajzen, 1977), Teknoloji Kabul Modeli (Davis vd., 1989), Teknoloji Kabul Modeli 2 (Venkatesh & Davis, 2000), Teknoloji Kabul Modeli 3 (Venkatesh & Bala, 2008), Planlı Davranış Teorisi (Ajzen, 1991), Yeniliklerin Yayılımı Teorisi (Rogers, 1983) ve Birleşik Teknoloji Kabul ve Kullanım Teorisi (Venkatesh vd., 2003) yer almaktadır. Teknoloji kabul modeli, yeni teknolojilerin kabulünde kullanıcıların davranışsal sorunlarını tanımlamaktadır (Venkatesh, 2000; Venkatesh vd., 2003). Teknoloji Kabul Modeli, Gerekçeli Eylem Teorisinden türetilmiştir ancak Gerekçeli Eylem Teorisi davranışsal teorilere odaklanırken, Teknoloji Kabul Modeli daha çok bilgi sistemlerine özgüdür (Erkan, 2018). Ancak diğer yandan, Teknoloji Kabul Modeli çok önemli bir model olarak kabul edilmekle birlikte, sınırlı açıklama gücü nedeniyle de yaygın olarak eleştirilmektedir (Bagozzi, 2007), özellikle de bilginin farklı bireyler tarafından üretildiği EAAP bağlamında Teknoloji Kabul Modeli, kullanıcıların tutum ve niyetlerine ilişkin yeterli bir anlayış sunamamaktadır (Ayeh, 2015). Teknoloji Kabul Modeli 2, sosyal etki işleme faktörleri ve bilişsel araçsal işleme faktörleri olarak iki grup yeni faktör getirmektedir ancak, tüketicilerin tüm eylemlerinin gönüllülük esasına göre yapılması gerektiğini varsaydığı için bazı dış faktörleri ihmal etmektedir (Tarhini vd., 2015). Buna ek olarak, Teknoloji Kabul Modeli 2 algılanan kullanım kolaylığının öncüllerini göz ardı ederken, çoğunlukla algılanan kullanışlılığa odaklanmaktadır. Bu kısıtlamaların bir sonucu olarak, (Venkatesh vd., 2003) bu

modelin yeni bir versiyonunu önermiştir: Birleştirilmiş Teknoloji Kabul ve Kullanım Teorisi (UTAUT). Bu model, teknolojiyi kabul etmek için gerekli olan dört faktör olduğunu varsayar: performans beklentisi, çaba beklentisi, kolaylaştırıcı koşullar ve sosyal etki (Venkatesh vd., 2003). Önemli bir model olarak kabul edilen ve farklı araştırma bağlamlarında test edilen bu modele yönelik en büyük eleştiri, Teknoloji Kabul Modeline dayandığı için dikkate değer hale geldiği ve yapılan sistematik literatür taraması sonuçlarına göre, UTAUT'ye atıfta bulunan makalelerin neredeyse %90'ı modeli test etmek ya da geliştirmek yerine sadece ondan bahsetmekte olduğu yönündedir (Williams vd., 2011). Teknoloji Kabul Modeli 2'deki kullanım kolaylığı bileşenini geliştiren Teknoloji Kabul Modeli 3 (Venkatesh & Bala, 2008), kullanım kolaylığı bileşeninin detaylandırılması ile kabul ve adaptasyonu öngörmede katkı sağlamaktadır. Her ne kadar en gelişmiş Teknoloji Kabul Modeli bu olsa da hala nispeten yeni bir modeldir ve pratik araştırmaya ihtiyaç duyulmaktadır (Williams vd., 2011). Belirtilen eleştirilere dayanarak, Teknoloji Kabul modelinin bazı temel bileşenleri kullanılmış olsa da bu çalışma mevcut müşteri verisi üzerinden analiz gerçekleştirdiği için, kendi araştırma modeli olan Teknoloji Etkileşimi modelini önermektedir.

Teknoloji etkileşimi, kullanıcıların teknoloji ile etkileşimini ve benimseme süreçlerini kapsayan, kullanım kolaylığı, algılanan değer ve genel deneyim gibi unsurları içeren bir kavramdır. Parameswaran vd. (2015) tarafından önerilen modele göre Teknoloji Etkileşimini arttıran faktörler, ilgili teknolojinin bilinmesi ve onunla geçirilen süreden oluşmaktadır. Diğer yandan müşteri memnuniyeti, bir ürün veya hizmetten duyulan memnuniyeti ölçen bir metriktir. (Bag vd., 2022) tarafından yapılan çalışmaya göre yapay zekâ teknolojileri, kullanıcı deneyimini geliştirerek bir tatmin geliştirmekte ve yeniden satın alımı sağlamaktadır. Bu nedenle yapay zekâ destekli bir ürün olan sanal asistanlar, kullanıcı etkileşimini arttırabilecek potansiyele sahip en önemli ürünlerden sayılabilir.

4.2.2.1. Algılanan Kullanım Kolaylığı

Sanal asistanlar daha önce de belirtildiği gibi, kabul edilebilirliği henüz kapsamlı bir şekilde araştırılmamış yeni bir teknolojidir. Bununla birlikte, temel teknoloji kabul modellerini kullanarak sanal asistanların kabulünü araştıran birkaç çalışma da bulunmaktadır (Burbach vd., 2019).

Bireyler arasında teknolojinin avantajlı olma potansiyeline sahip olduğu konusunda bir fikir birliği vardır, ancak basitlik düzeyi konusunda daha büyük bir belirsizlik söz konusudur. Bireylerin teknolojik bir nesneye yatırmayı öngördükleri ek çaba miktarı konusunda belirli inançlara sahip oldukları olguya genellikle "algılanan kullanım kolaylığı" adı verilir (R. P. Kumar vd., 2023).

Kääriä, (2017) çalışmasında, antropomorfizmin, yani insan özelliklerinin cihazlara atfedilmesinin, yapay zekâ destekli sistemlerin kabulü üzerindeki etkisini değerlendirmiştir. Kullanım kolaylığı ve sistemin genel kalitesinin antropomorfizmden çok daha önemli olduğunu bulmuştur. Algılanan kullanım kolaylığı, yeni teknolojilerin kullanımı ve öğrenilmesinde harcanan çabayla doğrudan ilgilidir. Bu konu, teknoloji kabulü ve benimsenmesi üzerine kapsamlı araştırmalara konu olmuştur (Venkatesh, 2000). Sanal asistanların kullanımının kabulüne ilişkin teorik bir model, Du vd. (2021) tarafından geliştirilmiştir. Yapay zekâ destekli bu cihazların karmaşık ve kafa karıştırıcı tasarımını anlamak için daha fazla bilgi gerekir. Bu artan iş yükü ve çaba genellikle kullanıcıları olumsuz etkilemektedir. Bu nedenle, algılanan kullanım kolaylığı sanal asistanların kullanımını olumlu yönde etkileyecektir.

Pitardi & Marriott (2021) tarafından yapılan çalışmada, kişisel asistanları kullanma niyetinin öncüllerine yönelik bir model önerilmiş ve kullanım kolaylığının tüketicilerin ürünü kullanımında önemli bir etken olduğu ispat edilmiştir. McLean vd. (2021) tarafından önerilen modelde ise, kullanıcıların kişisel asistanları kabul etme ve kullanma niyetlerinin öncülleri tüketici-marka etkileşimi üzerinden modellenmiştir. Bu çalışmada önerilen öncüllerden biri olan kullanım kolaylığı değişkenin, teknoloji kabulünü arttıran ve tüketici etkileşimini gerçekleştiren bir öneme sahip olduğu ortaya konulmuştur. Sanal asistanların tüketicilere son derece faydalı ve kullanımı kolay bir deneyim sunduğu ve böylece tüketicilerin birlikte yaratımı destekledikleri ve daha da geliştirmelerini sağladığı görülmektedir (McLean vd., 2021).

4.2.2.2. Algılanan Değer

Zeithaml (1988), tarafından yapılan keşifsel çalışma, algılanan değer kavramının anlaşılması ve tanımlanmasında önemli bir kilometre taşıdır. Algılanan değer, tüketicilerin bir ürün veya hizmeti değerlendirirken dikkate aldıkları öznel bir değerlendirme olup, genellikle maliyet ve fayda analizi ile ilişkilendirilir. Keşifsel

çalışmada, yanıt kalıpları dört terimde gruplandırılabilir: (1) düşük fiyat, (2) bir üründe istediğim her şey, (3) ödediğim fiyat karşılığında aldığım kalite ve (4) verdiğim şey karşılığında aldığım şey. Dodds vd. (2013), algılanan değeri, algılanan fayda ve fedakârlık arasındaki bilişsel bir değiş tokuş olarak açıklamıştır. Bir başka deyişle, algılanan değer, tüketicinin ne aldığı ve ne verdiğine ilişkin algısına dayalı olarak bir ürünün faydasına ilişkin genel değerlendirmesi olarak tanımlanabilir (H. Yang vd., 2015).

Değer kavramı, literatürde yaygın olarak, "müşterinin fedakarlıklarına (fiyat ve ilişki maliyetleri açısından) karşılık elde ettiği faydalar (temel çözüm ve ek hizmetler açısından)" olarak tanımlanmaktadır (Grönroos, 1997). Kavram, alıcı-satıcı arasındaki etkileşimde müşterinin elde ettiği faydalara karşın ne gibi maliyetlere katlandığını karşılaştırmaktadır (Samudro vd., 2020).

Zeithaml (1988), ürün ve hizmet kalitesinin yanı sıra fiyat gibi müşteri memnuniyetine yönelik temel faktörleri entegre eden bir memnuniyet modeli geliştirmiştir. Teknoloji çağında tüm insanlığın belki de en önemli hazinesi zamandır. Bu nedenle zaman, çaba ve arama maliyetlerini azaltmak için ürünlere yerleştirilebilecek her şey, algılanan fedakarlığı azaltabilir ve böylece algılanan değeri arttırır (Zeithaml, 1988). Bu sayede kullanıcılar, bir ürün veya hizmet için, faydaların maliyetlerden daha ağır bastığına inandıklarında algılanan değer artar.

Algılanan değer, tüketici değeri bağlamında çok boyutlu bir yapı olarak ele alınmış, Sweeney & Soutar (2001) tarafından geliştirilen ölçekte, dört farklı değer boyutu ortaya çıkmıştır. Bunlar şu şekilde adlandırılmıştır: Duygusal, sosyal, kalite/performans ve fiyat/paranın karşılığı.

Literatürde yer alan pek çok araştırma, algılanan değerin yüksek müşteri memnuniyeti gibi olumlu sonuçlarla ilişkili olduğunu göstermektedir (Hsu & Lin, 2015; Shankar, 2018; Dovaliene vd., 2015 ; Susanti vd., 2019). Kullanıcıların bir ürün veya hizmete dair algıladıkları değer, memnuniyetlerini arttıracaktır.

4.2.2.3. Algılanan Kalite

Zeithaml, (1988) algılanan kaliteyi, objektif kaliteden farklı olan genel ürün üstünlüğüne ilişkin, müşterinin sübjektif yargısı olarak tanımlamıştır. Steenkamp, 1989), algılanan kaliteyi, bir tüketicinin ürün niteliklerine ilişkin öznel değerlendirmesinin tüketicinin algılarına, ihtiyaçlarına ve hedeflerine nasıl bağlı

olduğuna atıfta bulunarak, kalitenin ne mutlak ne de nesnel olduğunu öne sürerek tanımlamıştır. Aynı zamanda hem kalite ipuçlarını (içsel ve dışsal ipuçları) hem de kalite niteliklerini (deneyim ve güven nitelikleri) birleştiren Kalite Algılama Süreci Modeli'ni geliştirerek literatüre katkıda bulunmuştur. Algılanan kalite her zaman tüketicilerin çeşitli nitelik setlerine ilişkin davranışsal yargılarına dayanır (Kim vd., 2014). Ayrıca Parasuraman vd. (1985) kalite bağlamında, hizmet kalitesi (SERVQUAL) üzerine çalışmış, müşterilerin beklentileri ile bir hizmetten algıladıkları performans arasındaki fark olarak tanımlamıştır.

Literatürde yapılan pek çok çalışma algılanan kalitenin memnuniyeti arttırdığını göstermektedir. Müşterilerin algıladıkları kalitenin, yüksek teknoloji ürünü satın almaları üzerinde önemli bir etkiye sahip olan önemli bir birincil tutum olduğu düşünülmektedir (Kim vd., 2014). Eğer satıcı hem algılanan kalitenin hem de algılanan değerin müşteri memnuniyeti üzerindeki etkisini arttırabilirse, o zaman satıcı öyle bir fiyat esnekliği yaratabilir ki, müşterinin bakış açısına göre algılanan kalitenin çok güçlü olması durumunda müşteride daha yüksek fiyat ödeme isteği bile oluşabilmektedir (Vera, 2015). Kuo vd. (2009) katma değerli mobil pazar üzerinde çalışma yapmış, kalitenin hem algılanan değeri hem de müşteri memnuniyetini arttırdığı ortaya koymuşlardır. Bir başka çalışma, algılanan kalite ve müşteri bağlılığının İspanyol fitness merkezlerinin kullanıcılarının sadakati üzerindeki etkisini incelemiştir. Çalışma, özellikle spor hizmetleri ve fitness sektöründe algılanan kalite, memnuniyet ve müşteri bağlılığı arasındaki pozitif ilişkiyi vurgulamıştır (Gálvez-Ruiz vd., 2023) Başka bir araştırma da algılanan kalitenin farklı hizmet aşamalarında müşteri memnuniyeti üzerindeki etkisine odaklanmıştır. Hizmet aşamalarına dayalı bir müşteri memnuniyeti modeli oluşturmuş ve modeli çoklu doğrusal regresyon yoluyla ampirik olarak test etmiştir (Xie & Sun, 2021). Son olarak, marka deneyiminin Bekasi'deki öğrencilere yönelik çevrimiçi satıcıların kaliteli hizmetleriyle müşteri bağlılığı üzerindeki etkisini ele almıştır. Hizmet kalitesi, müşteri memnuniyeti ve müşteri bağlılığı arasındaki ilişkiyi araştırmış ve algılanan hizmet kalitesi ile müşteri bağlılığı arasında müşteri memnuniyetinin aracı rolünü vurgulamıştır (Merdiaty & Aldrin, 2022).

Bu çalışmalar, algılanan kalite ve müşteri etkileşimi arasındaki dinamiklere ilişkin değerli bilgiler sunmakta ve müşteri memnuniyetinin iyileştirilmesinde algılanan kalite faktörünün anlaşılmasının öneminin altını çizmektedir.

4.2.3. Müşteri Memnuniyeti

Müşteri memnuniyeti işletmeler için kritik bir başarı faktörüdür ve pazarlama araştırmalarında kapsamlı olarak incelenmiştir. Cardozo, (1965) tarafından müşteri çabaları ve beklentileri üzerine yapılan ilk araştırmalar, müşteri memnuniyetinin anlaşılması için zemin hazırlamıştır. Haines vd. (1970) bu kavramı, memnuniyetin tüketicinin bilişsel durumundan ve satın alma sonrası değerlendirmesinden kaynaklandığını öne süren alıcı davranışı teorisi aracılığıyla daha da detaylandırmıştır. Beklenti Karşılanmama Teorisi (Oliver, 1980) memnuniyetin, gerçek performans beklentileri aştığında veya beklentilerin altında kaldığında ortaya çıkan onaylamama deneyiminin bir sonucu olduğunu ileri sürmektedir. Planlı Davranış Teorisi (Ajzen, 1991) de müşteri memnuniyetine uygulanmıştır ve memnuniyetin gelecekteki satın alma niyetlerini ve davranışlarını etkileyebileceğini öne sürmektedir.

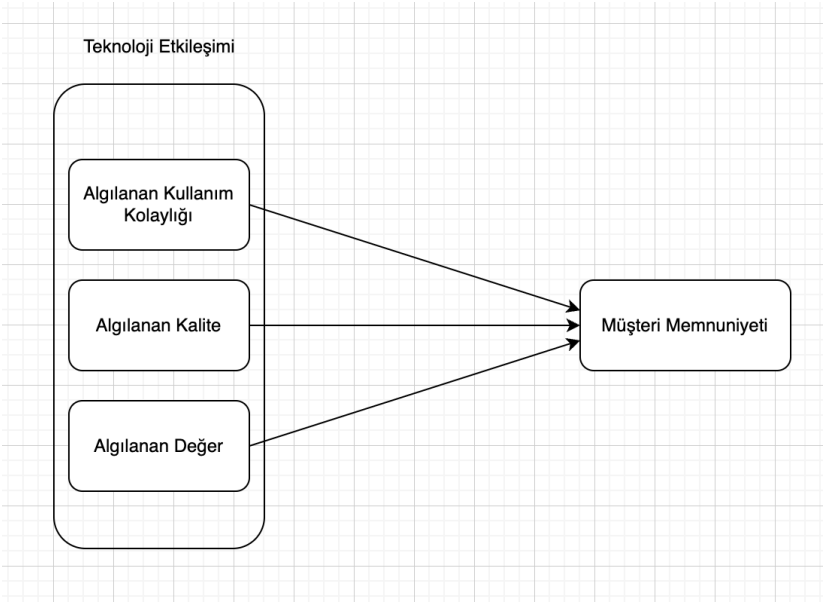
Oliver, (2010) memnuniyeti, tüketicinin tatmin tepkisi olarak tanımlamaktadır. Bir ürün/hizmet özelliğinin veya ürün ya da hizmetin kendisinin, eksik veya fazla tatmin seviyeleri de dahil olmak üzere, tüketimle ilgili zevkli bir tatmin seviyesi sağladığına dair bir yargı olduğunu söylemiştir. R. P. Kumar vd. (2023) çalışmalarında müşteri memnuniyetini, karşılanmamış beklentileri çevreleyen duygulardan ve tüketicilerin deneyimleri hakkındaki hislerinden kaynaklanan psikolojik durum olarak tanımlamaktadır. Mevcut pazarlama literatürü, çok çeşitli boyutları ve uygulamaları (değer, kalite ve sadakat gibi) yansıtan çok sayıda müşteri memnuniyeti tanımı sunmaktadır (Brill vd., 2019). Bu boyutlar nedeniyle, müşteri memnuniyetinin her şeyi kapsayan, evrensel olarak kabul edilmiş bir tanımı yoktur (Giese, 2000). Dijital çağın gelişiyle birlikte, müşteri memnuniyeti araştırmaları çevrimiçi ortamlara doğru genişlemiştir. Parasuraman vd. (2005) tarafından yapılan çalışmalar e-hizmet kalitesinin önemini vurgularken, Smith vd. (2012), sosyal medyada kullanıcı tarafından oluşturulan içeriklerin müşteri etkileşimden önemli ölçüde etkilendiği göstermiştir.

Teknoloji Etkileşimi, zorluk, estetik ve duyusal çekicilik, geri bildirim, yenilik, etkileşim, algılanan kontrol ve zaman, farkındalık, motivasyon, ilgi ve etki ile karakterize edilen teknoloji ile kullanıcı deneyimlerinin kalitesidir (O'Brien & Toms, 2008). Yapay zekâ destekli ürünler, bu deneyimleri kişiselleştirerek, süreçleri kolaylaştırarak ve sorunlara daha hızlı çözümler sunarak müşteri memnuniyetinde

önemli ölçüde iyileşme sağlamaktadır (Wirtz vd., 2018). Özellikle tüketicilerin günlük hayatlarına dahil olmasıyla, 7/24 desteğe, rutin soruların ve hatta karmaşık etkileşimlerin ele alınmasına, zaman içinde öğrenmeye ve gelişmeye olanak tanımaktadır. Bu da müşterilerin uzun süre beklemeden istedikleri zaman ihtiyaç duydukları yardımı alabilmelerini sağlayarak memnuniyeti büyük ölçüde arttırmaktadır. Ayrıca yapay zekâ uygulamaları, müşteri deneyimi ve müşteri etkileşimi için duygusal analizler sağlayabilir (Huang & Rust, 2018). Ruan & Mezei (2022) tarafından yapılan araştırmaya göre, ürün niteliği deneyimsel olduğunda müşteri hizmetleri çalışanları daha yüksek müşteri memnuniyetine yol açsa da ürün niteliği işlevsel olduğunda yapay zekâ sohbet robotları müşteri hizmetlerinden daha iyi performans göstermektedir. Bu durumda, komutlarla çalışan, entegrasyonel özellikleri bulunan, işlevsel performans gösteren Alexa gibi yapay zekâ destekli ürünlerin müşteri memnuniyeti üzerinde pozitif bir etkisi söz konusu olmalıdır.

Önerilen modelde Algılanan Kullanım Kolaylığı, Algılanan Kalite ve Algılanan Değer Teknoloji Etkileşimini oluşturmaktadır ve Teknoloji Etkileşiminin Müşteri Memnuniyeti üzerinde pozitif etkisi bulunmaktadır.

Şekil 59: Teknoloji Etkileşimi Modeli



Buna göre önerilen hipotezler şu şekildedir:

H1: Algılanan kullanım kolaylığının, müşteri memnuniyeti üzerinde pozitif etkisi bulunmaktadır.

H2: Algılanan kalitenin, müşteri memnuniyeti üzerinde pozitif etkisi bulunmaktadır.

H3: Algılanan değerin, müşteri memnuniyeti üzerinde pozitif etkisi bulunmaktadır.

4.3. Veri ve Metodoloji

Bu çalışmada kullanılan veriler, Haziran 2020 ve Temmuz 2021 tarihleri arasında Best Buy platformunda yer alan Amazon Echo ürününe ilişkin müşteri yorumlarından elde edilmiştir. Best Buy platformu, ABD'deki en büyük elektronik perakendecilerinden biridir. Ayrıca platform, müşteri ve uzmanlar tarafından yazılan incelemeler, yıldızlar, puanlar ve ürün kalitesi, kullanım kolaylığı ve değerinin nicel analiziyle birlikte, ürüne dair artılar ve eksiler listesi de dahil olmak üzere çok boyutlu yorum bilgileri sağlamaktadır. Veri toplama Temmuz 2021'de gerçekleştirilmiştir. Tüm veri toplama ve analiz işlemleri Python programlama dilinde yapılmıştır (Guido & Drake, 2009). Müşteri yorumları internette halka açıktır ve erişilebilir. Best Buy'dan veri çekmek için Pandas (McKinney, 2011) ve BeautifulSoup (Richardson, 2019) Python kütüphaneleri kullanılmıştır. Web sitesi kazıma (Web site scraping) yöntemiyle ihtiyaç duyulan veriler alınmış ve excel dosyası olarak kaydedilmiştir.

Amazon Echo Show 5 ürününe dair 12,452 yorum çekilmiştir. Bunların 56 adedi, muhtemelen sistemsel bir hata nedeniyle veri kümesinde iki kere yer aldığı için mükerrer olarak kalmıştır. O nedenle dosyadan 56 adet mükerrer olan yorum silinmiştir. Son durumda Echo Show 5 veri kümesine dair 12,452-56=12,394 müşteri yorumu kullanılmıştır. Amazon Echo Show 8 ürününe dair 5,386 yorum çekilmiştir. Bunların 22 adedi, muhtemelen sistemsel bir hata nedeniyle veri kümesinde iki kere yer aldığı için mükerrer olarak kalmıştır. O nedenle dosyadan 22 adet mükerrer olan yorum silinmiştir. Son durumda Echo Show 8 veri kümesine dair 5,386-22=5,364 müşteri yorumu kullanılmıştır. Bu çalışmada toplam veri seti üzerinden analiz yapılmıştır. Echo Show 5 ve Echo Show 8 ürünlerine dair toplam 17.758 yorum incelenmiştir. Bu bölümde birden fazla analiz gerçekleştirilmiştir. Veri kümesi üzerinde yapılan tüm analizler, Google Colab üzerinden, Python yazılım dili (*Python 3.8.8*, 2021) kullanılarak yapılmıştır.

Çalışmada kullanılan verilerin tanımlayıcı istatistikleri Tablo 21'de özetlenmiştir. "Kalite", "Değer", "Kullanım Kolaylığı", "Derecelendirme" ve "Ürüne Sahip Olma Süresi" değişkenleri kullanılmıştır. "Ürüne Sahip Olma Süresi" değişkenine ait eksik veri bulunduğundan, ilgili satırlar çıkarılmış ve toplam 15.152 adet veri üzerinden analiz yapılmıştır. Veri setinin normal dağılım sergilemediği Çarpıklık ve Basıklık değerleri ile gözlemlenebilmektedir. Çarpıklık dağılımın çoğunlukla olumlu yorumlar lehine olduğunu göstermektedir.

Tablo 21: Tanımlayıcı İstatistikler

	Kalite	Değer	Kullanım Kolaylığı	Derecelendirme	Sahiplik Süresi
N	15152	15152	15152	15152	15152
Eksik Veri	0	0	0	0	0
Ortalama	4.77	4.71	4.69	4.74	
Std. hata ort.	0.00464	0.00533	0.00562	0.00497	
Medyan	5.00	5.00	5.00	5.00	
Standard Sapma	0.571	0.656	0.692	0.611	
Minimum	1	1	1	1	
Maximum	5	5	5	5	
Çarpıklık	-3.34	-2.87	-2.85	-3.06	
Std. hata çarpıklık	0.0199	0.0199	0.0199	0.0199	
Basıklık	14.1	9.66	9.29	11.5	
Std. hata basıklık	0.0398	0.0398	0.0398	0.0398	

Bu analizin yapısı, istatistiksel analiz yöntemlerinin uygulanmasıyla müşteri bölümlendirme, memnuniyet değerlendirmesi ve ürünle olan etkileşim sürelerinin etkilerinin incelenmesi üzerine kuruludur. İlk adımda, müşteri bölümlendirmesi için "Kalite", "Değer", ve "Kullanım Kolaylığı" kriterlerine dayanarak kümeleme analizi gerçekleştirilmiştir. Bu kriterler, müşteri deneyimini ve ürün algısını değerlendirmek için 5'li Likert ölçeği ile ölçülmüştür. "Ürüne Sahip Olma Süresi" ise zaman bazında (hafta, ay, yıl) kategorize edilerek, 1 ay ve daha kısa süreler "düşük", 1 aydan uzun süreler "yüksek" olarak yeniden kodlanmıştır. Çalışmada, farklı müşteri gruplarının ürüne sahip olma süresine ve memnuniyet düzeylerine bağlı olarak aralarında

istatistiksel olarak anlamlı bir fark olup olmadığını tespit etmek için bağımsız iki örneklem t-testi uygulanmıştır. Müşteri memnuniyeti, "Derecelendirme" adı verilen ve 5'li Likert ölçeği ile ölçülen bir değişken aracılığıyla değerlendirilmiştir. Gruplar arası memnuniyet değişikliklerini değerlendirmek için ANOVA (Tek Yönlü Varyans Analizi) kullanılmıştır. Bu analiz, "Kalite", "Değer", "Kullanım Kolaylığı" gibi değişkenlerin "Derecelendirme" (memnuniyet) üzerindeki etkilerini karşılaştırmak için yapılmıştır. Ayrıca, bu bağımsız değişkenler ile "Derecelendirme" arasındaki ilişkiyi daha detaylı analiz etmek amacıyla regresyon analizi uygulanmıştır. Bu sayede, değişkenlerin memnuniyet üzerindeki etki büyüklüğü ve yönü tespit edilmiştir. Ürüne sahip olma süresinin "düşük" ve "yüksek" olarak ayrıldığı iki farklı veri kümesi üzerinde gerçekleştirilen regresyon analizleriyle, modelin bu iki alt grup için açıklama gücü (R^2 değerleri) karşılaştırılmıştır. Bu analiz, ürüne sahip olma süresinin müşteri memnuniyeti üzerindeki etkisinin anlaşılması ve modelin her iki durumda ne kadar etkili olduğunun değerlendirilmesi amacıyla yapılmıştır.

4.3.1.1. Kümeleme Analizi

Kümeleme analizi, bir veri kümesindeki verileri belirli yakınlık ölçütlerine göre farklı gruplarda toplanması amacıyla uygulanan çok değişkenli bir istatistik analizdir. Benzer özelliklere sahip veriler bir arada homojen bir şekilde bulunurken, aralarında ise heterojenlik sağlanmaktadır (Heuvel & Devasagayam, 1999). Kümeleme analizi, pazarlama araştırmalarında bölümlendirme çalışmalarında kullanılmaktadır (Ozansoy, 2009). Bu nedenle, öncelikle sanal asistan pazarının bölümlendirilmesine yönelik olarak kümeleme analizi yapılmıştır.

Kümeleme analizi keşfedici bir çalışmadır. Kümeleme performansını ölçmek için çeşitli yöntemlerden faydalanılabilir. Bu çalışmada Calinski-Harabasz indeksi kullanılmıştır. Bu yöntemde, k adet kümeye bölünmüş bir verinin kümeleme geçerliliğini ölçmek için aşağıdaki eşitlik kullanılır:

$$ch = \frac{tr(B_k)\ x\ (n_E - k)}{tr(W_k)\ x\ (k-1)}$$

$tr(B_k)$ = kümeler içi kareler toplamı

$tr(W_k)$ = kümeler arası kareler toplamı

Bu formüle istinaden en yüksek ch değeri en iyi kümeyi ifade etmektedir (Caliñski & Harabasz, 1974) . Bu yönteme istinaden belirlenen küme sayısı ile K-ortalamalar

tekniği kullanılarak kümeler oluşturulmuştur. K-ortalamalar tekniği, sürekli olarak kümelerin iteratif olarak güncellendiği ve en uygun çözüme ulaşana kadar devam eden döngüsel bir algoritmadır. Bu algoritma, kullanıcının belirttiği optimal K değerine göre, toplam veriyi kümelere ayırmaktadır.

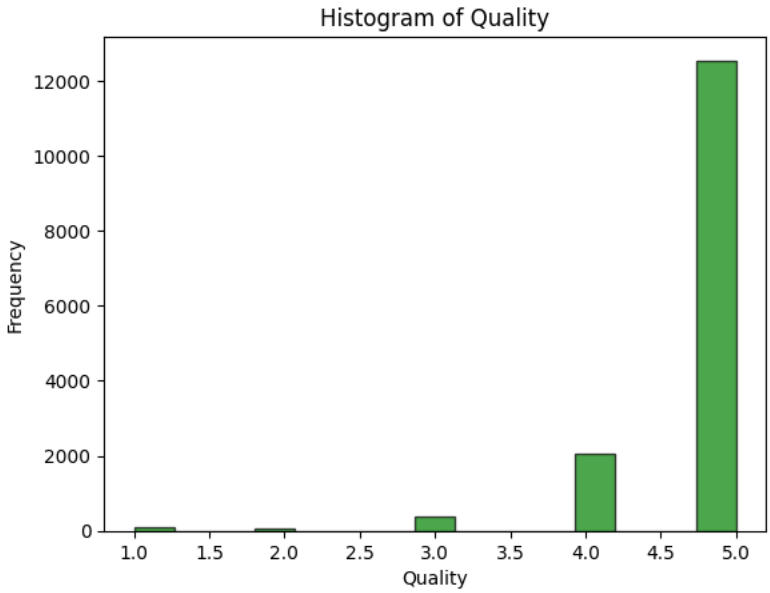
Kümeleme analizi, "Kalite", "Değer", "Kullanım Kolaylığı" kriterleri üzerinden yapılmıştır. Kümeleme algoritmasında kullanılan, "Kalite", "Değer", "Kullanım Kolaylığı" değişkenleri 5'li Likert ölçeği ile ölçülmüştür. Veri kümesinin ilk halinde 17.758 kullanıcı bulunmaktadır. İleriki analizlerde kullanılacak olan "Ürüne Sahip Olma Süresi" kriterinde eksik veri olmasından ötürü, analizin güvenirliliği için eksik veri girişi bulunan satırlar veri kümesinden elenmiştir. Bu nedenle, son durumda 15.152 kullanıcı üzerinden analiz gerçekleştirilmiştir.

4.3.1.2. Regresyon Analizi

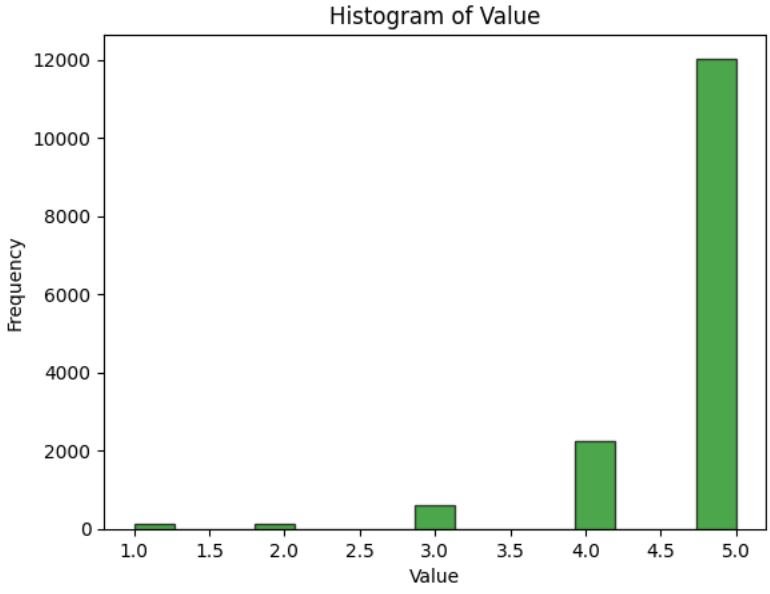
Regresyon analizi, bağımlı değişkenlerin bir veya daha fazla bağımsız değişkenle ilişkisini modellemek için kullanılan bir istatistiksel yöntemdir. Bu analiz, bağımlı değişkenin bağımsız değişkenlerin bir fonksiyonu olarak nasıl değiştiğini anlamaya yardımcı olur.

Öncelikle, regresyon analizi için önemli olan regresyon varsayımları değerlendirilmektedir. Bu varsayımlar arasında verilerin normal dağılıma sahip olması da yer alır. Verilerin normal dağılıma sahip olup olmadığını değerlendirmek için Shapiro-Wilk testi gibi istatistiksel testler kullanılabilir. Bu test, bir değişkenin normal dağılıma uygun olup olmadığını belirlemek için kullanılan bir yöntemdir. Veri kümemizde yer alan değişkenler şunlardır. "Kalite", "Değer", "Kullanım Kolaylığı" ve "Derecenlendirme". Python'da, verilerin normal dağılıma uygunluğunu test etmek için scipy kütüphanesinde bulunan shapiro() fonksiyonunu kullanılmıştır. Bu fonksiyon, veri setinin normal dağılıma uygun olup olmadığını belirlemek için istatistiksel bir test gerçekleştirmektedir. Aşağıda her bir değişkenin histogram grafiklerine yer verilmiştir.

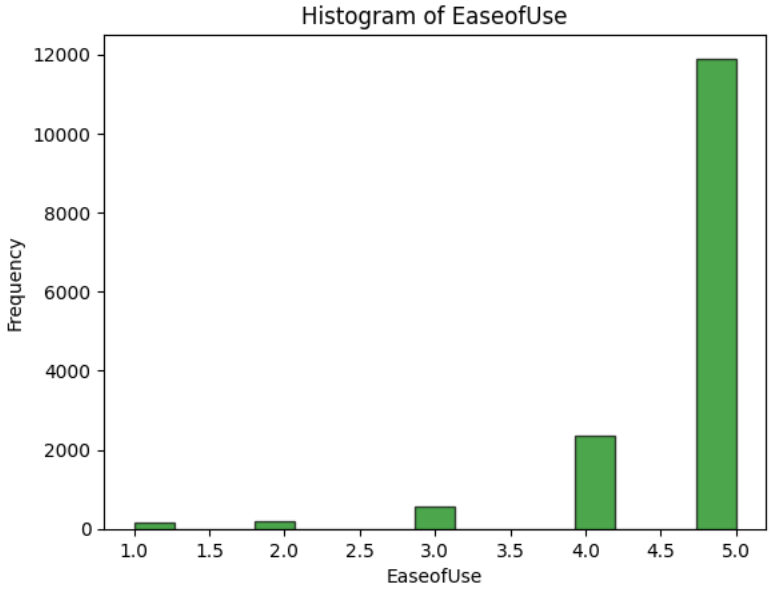
Şekil 60: Kalite Değişkeninin Histogramı



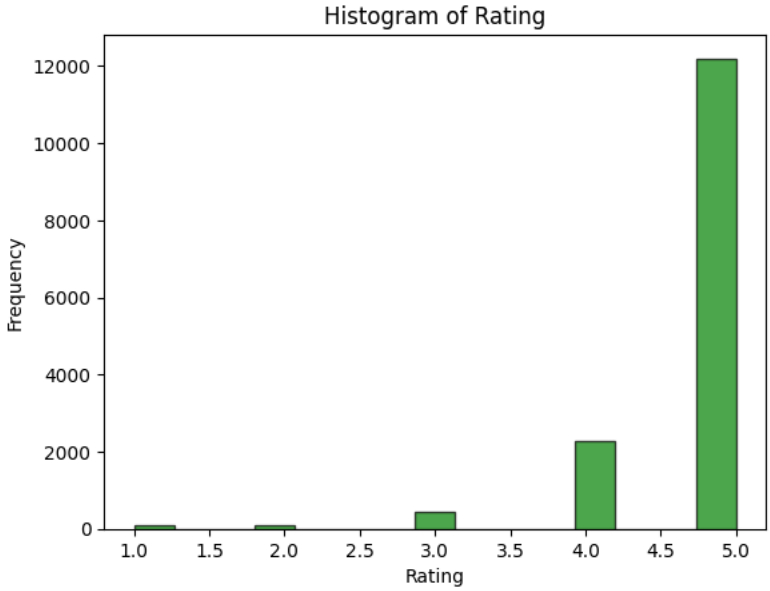
Şekil 61: Değer Değişkeninin Histogramı



Şekil 62: Kullanım Kolaylığı Değişkeninin Histogramı



Şekil 63: Derecelendirme Değişkeninin Histogramı



Veri setinin incelenmesi sonucunda, bağımsız değişkenlerin ve bağımlı değişkenin normal dağılıma sahip olmadığı gözlemlenmiştir. Bu nedenle, regresyon analizi için normal dağılım varsayımının sağlanmadığı bir durumla karşı karşıya kalınmıştır. Bunun üzerine, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi değerlendirmek için non-parametrik bir yaklaşım olan Random Forest Regresyon modeli (Brieman & Cutler, t.y.) kullanılmıştır. Random Forest tekniği (Breiman,

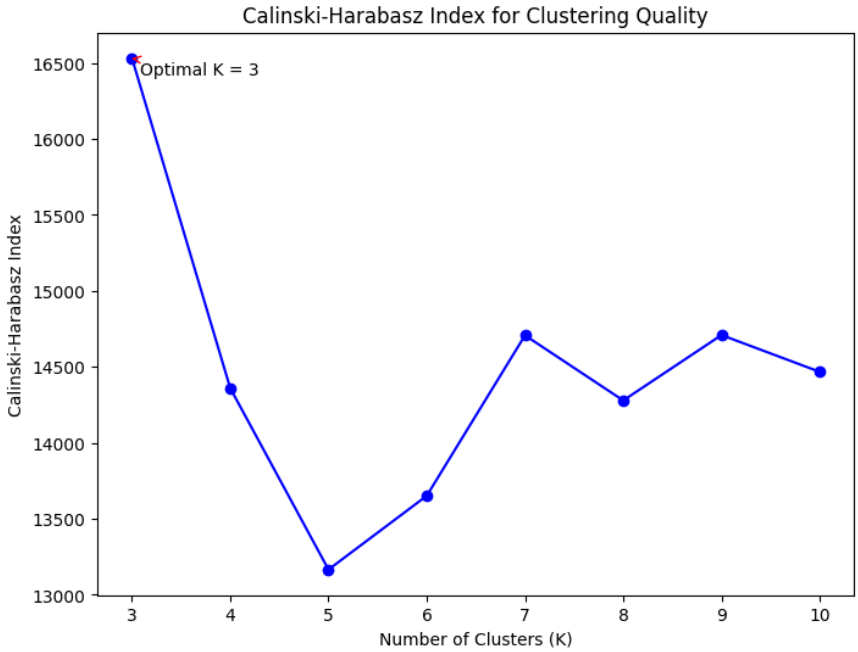
2001), Breiman tarafından tanıtılan bir sınıflandırma ve regresyon yöntemidir (Palmer vd., 2007). Bu teknik, yüksek derecede tahmin doğruluğu elde etmek için önyükleme toplaması ve tahmin edicilerin rastgeleleştirilmesini kullanmakta (Rigatti, 2017), sürekli bir değişkenin tahmininin tüm ağaçların tahminlerinin ortalaması olarak sağlandığı bir karar ağaçları topluluğuna dayanmaktadır (Palmer vd., 2007). Bu çalışmadaki gibi, normal dağılım sergilemeyen veya objektif ve son derece öznel cümlelerin bir karışımını içeren veri kümelerinde, Random Forest modelinin özellikle tercih edilmesi yararlı bulunmaktadır (Ghose & Ipeirotis, 2011; Roshani vd., 2023). Bunun için Python'da, scikit kütüphanesindeki RandomForestRegressor modeli kullanılmıştır (Pedrogosa vd., 2011). Modelin performansı, ortalamaya kare hatası (MSE), kök ortalamaya kare hatası (RMSE) ve R-kare (R^2) değerleri üzerinden değerlendirilmiştir. Elde edilen sonuçlar, modelin verilere iyi uyum sağladığını ve bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini belirlemede başarılı olduğunu göstermiştir. Bu doğrultuda, Random Forest Regresyon modeli veri setindeki karmaşık ilişkileri ve etkileşimleri yakalama yeteneği ile dikkat çekmiştir.

4.4. Bulgular

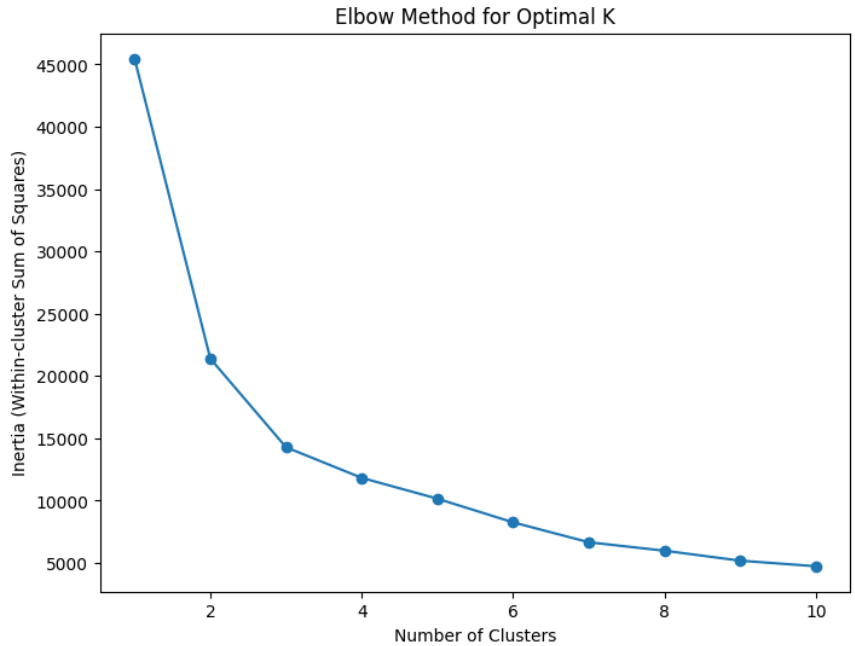
4.4.1.1. Kümeleme Sonuçları

Öncelikle analiz yapılacak veri kümesi Google Colab arayüzünden, sisteme import edilmiştir. Python sklearn kütüphanesi kullanılmıştır (Pedrogosa vd., 2011). Kümeleme için ilgili değişkenler seçildikten sonra optimal küme sayısı belirlenmesi için iki ayrı metottan faydalanılmıştır. İlki Calinski-Harabasz indeksi; ikincisi ise dirsek metodudur. Optimal k değeri Şekil 65'deki grafikte görüldüğü üzere 3 olarak belirlenmiştir. Şekil 66'da gösterildiği gibi dirsek metotundan faydalanıldığında da 3 kümenin oluşmasının anlamlı olduğu görülmektedir.

Şekil 64: Calinski-Harabasz Metodu Tarafından Önerilen Optimal Küme Sayısı Grafiği



Şekil 65: Dirsek Metodu Tarafından Önerilen Optimal Küme Sayısı Grafiği



Ardından K-ortalamalar yöntemi ile optimal küme sayısı 3 olarak giriş yapılarak kod çalıştırılmış ve aşağıdaki sonuç elde edilmiştir:

Kümelerin birim değerleri Tablo 22'de verilmiştir.

Tablo 22: Kümelerin Birim Değerleri

0	12115
1	2604
2	426

Tablo 23 incelendiğinde, gerçekleştirilen kümeleme analizi sonrasında oluşan cevaplayıcı kitlelerini şu şekilde tanımlamak mümkündür:

Tablo 23: Küme Ortalamaları

Küme	Kalite	Değer	Kullanım Kolaylığı
0	4.208525	3.992704	3.928187
1	4.974825	4.952621	4.947090
2	2.586605	2.355658	2.205543

Birinci grup, ***Ilımlılar (n=12115)*** grubudur. Ürünü yüksek oranda kaliteli, ortalamanın biraz üzerinde değerli ve kullanımını kolay bulan kişilerdir.

İkinci grup, ***Hayranlar (n=2611)*** *grubudur.* Ürünle ilgili tamamen pozitif düşünen ve ürünü kaliteli ve değerli, kullanımı kolay bulan kişilerdir.

Üçüncü grup tüketiciler, ***Hoşnutsuzlar (n=426)*** grubudur; genel memnuniyeti düşüktür, ürünü kullanmaktan tatmin duymamaktadırlar.

Kümeleme analizi sonuçları, küme büyüklüklerinin birbirinden farklı olduğunu göstermektedir. Ancak, bu durum, küme analizinin doğruluğuyla ilgili bir husus değildir. Gruplar arası farklılıkların ortaya konulmasında bilindiği gibi ANOVA analizinden faydalanılmaktadır. Gerçekleştirilen küme analizinin geçerliliğini değerlendirmek için kümeleme analizinde yer almayan ve kümeler arasında fark yaratacağı düşünülen değişkenler test edilebilir. Bu değişkenler temel alındığında kümeler arasında farklılıklar saptanırsa, kümeleme analizinin tahmin geçerliliğine sahip olduğu söylenebilir (Hair vd., 2010). Bu amaç doğrultusunda, tüketicilerin ürüne

dair verdikleri “Derecelendirme” puanı temel alınarak kümeler arasında fark olup olmadığı Python kodu ve çıktısı üzerinden incelenmiştir:

```
ANOVA for Rating:
F-statistic: 7622.836010820352
P-value: 0.0
The means of 'Rating' are significantly different across clusters.
```

ANOVA for Rating:

F-statistic: 7622.836010820352

P-value: 0.0

The means of 'Rating' are significantly different across clusters.

Derecelendirme puanı baz alındığında kümeler arası farklılığın anlamlı olduğu gözlemlenmiştir.

Son olarak, ortaya konan farklı kümeler arasında “Ürüne Sahip Olma Süresi”nin ürüne verilen puanı değiştirip değiştirmediği gözlenmek istenmiştir. Bu nedenle farklı gruplar arasında, “Ürüne Sahip Olma Süresi” ve “Derecelendirme” arasında T-test uygulanmıştır. Sonuçlar çarpıcıdır:

Cluster 1 T-Test Results:
t-statistic: 4.026581625955862
p-value: 5.8207558650565464e-05
There is a statistically significant difference in 'Rating' between the two levels of 'Length_of_Ownership'.

Cluster 2 T-Test Results:
t-statistic: -0.7589659432250653
p-value: 0.4478876978752492
There is no statistically significant difference in 'Rating' between the two levels of 'Length_of_Ownership'.

Cluster 3 T-Test Results:
t-statistic: 0.0642002232371104
p-value: 0.9488410557701804
There is no statistically significant difference in 'Rating' between the two levels of 'Length_of_Ownership'.

Ürüne sahip olma süresinin, derecelendirme üzerinde artış yarattığı tek grup ***Ilımlılar*** grubudur. ***Hayranlar*** ve ***Hoşnutsuzlar*** grupları için ürüne sahip olma süresi ve memnuniyet arasında anlamlı bir fark yoktur. Çünkü ***Hayranlar*** grubunun memnuniyetleri zaten yüksektir ve ***Hoşnutsuzlar*** grubunun da ürüne dair duydukları

memnuniyet konusunda fikri değişmemektedir. Ürüne sahip olmaya devam ettikçe memnuniyetlerinde fark edilir bir artış olmamaktadır. Ancak ***Ilımlılar***, ürüne sahip oldukça, ürünü kullandıkça, ürüne karşı anlamlı bir tatmin geliştirmişlerdir. Bu sonuç, fazlasıyla uç noktada olmayan müşteri kitlesi için, ürüne sahip olma süresi arttıkça, ürüne dair memnuniyetin arttığını göstermektedir.

4.4.2. Regresyon Sonuçları

Yapay zekâ destekli ürünlerde teknoloji etkileşiminin, müşteri memnuniyeti üzerindeki etkisini incelemek amacıyla yapılan regresyon analizinde tüm ilişkiler anlamlı bulunmuştur. "Teknoloji Etkileşimi" boyutlarının "Müşteri Memnuniyeti" üzerindeki etkisini ortaya koymak amacıyla yapılan regresyon analizinde modelin istatistiksel olarak anlamlı olduğu görülmektedir. Modelin Ortalama Kare Hatası (MSE): 0.12613411288988582 ve Modelin Kök Ortalama Kare Hatası (RMSE): 0.35515364687679307 çıkmıştır.

```
Modelin Ortalama Kare Hatası (MSE): 0.12613411288988582
Modelin Kök Ortalama Kare Hatası (RMSE): 0.35515364687679307
Modelin R kare (R^2) değeri: 0.6356856656347332
```

MSE, modelin gerçek verilerle ne kadar iyi uyum sağladığını ölçen bir metriktir. Bu değer, modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu gösterir (M. Lee, 2021). Y_i gözlemlenen değer, X_i tahmin edilen değer ve n gözlemlenen değerlerin sayısı olmak üzere ortalama kare hatası aşağıdaki şekilde formülize edilmektedir.

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(X_i - Y_i)^2$$

MSE'nin düşük olması, modelin daha iyi performans gösterdiğini gösterir. Bu durumda, 0.126 olan MSE değeri oldukça düşüktür, bu da modelin gerçek verilere oldukça yakın tahminler yaptığını gösterir.

RMSE, MSE'nin kareköküdür ve hata terimlerinin ölçü birimiyle aynıdır. RMSE genellikle MSE'den daha çok tercih edilen performans ölçüsüdür çünkü MSE gerçekte olduğundan daha büyük görünen karesel bir biçime sahiptir MSE'ye benzer şekilde, RMSE'nin düşük olması modelin daha iyi performans gösterdiğini belirtmektedir (B. Liu vd., 2020). RMSE aşağıda ifade edilmiştir.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(X_i - Y_i)^2}$$

Bu durumda, 0.355 olan RMSE değeri de oldukça düşüktür ve modelin gerçek verilere yakın tahminler yaptığını gösterir.

Sonuç olarak, elde edilen MSE ve RMSE değerleri, Random Forest Regresyon modelinin verilere oldukça iyi uyum sağladığını ve verileri tahmin etmek için etkili bir şekilde kullanılabileceğini göstermektedir. Bu değerlerin düşük olması, modelin gerçek verilere oldukça yakın tahminler yapabildiğini gösterir. Bu açıklamalar doğrultusunda H1, H2 ve H3 hipotezlerinin doğrulandığı ifade edilebilir.

Wright, (1921) tarafından tanıtılan ve genellikle R^2 ile gösterilen orijinal formülasyonu, bağımlı değişkenin bağımsız değişkenler tarafından ne kadar belirlendiğini varyans cinsinden ölçmektedir (Chicco vd., 2021). R^2 değeri 1'e ne kadar yakınsa, bir regresyon modelinin projeksiyon performansı o kadar iyidir (B. Liu vd., 2020; Montogomery vd., 2012). $\bar{Y}$, gerçek değerlerin ortalamasını göstermek üzere, R^2 aşağıda ifade edilmektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(X_i - Y_i)^2}{\sum_{i=1}^{n}(\bar{Y}_i - Y_i)^2}$$

Modelin R kare (R^2) değeri: 0.6356856656347332 çıkmıştır. Bu durumda müşteri memnuniyetinin %63,5 oranını teknoloji etkileşimi boyutları açıklamakta olduğu gösterilmiştir.

Random Forest Regresyon modeli, "özellik önemi" (feature importance) olarak bilinen, her bağımsız değişkenin modelin tahmin yeteneği üzerindeki etkisini gösteren benzersiz bir özellik sağlamakta ve modelin tahmin performansına katkısını ölçmektedir (Ghose & Ipeirotis, 2011; Menze vd., 2009). Dolayısıyla, Random Forest Regresyon modeliyle elde edilen "özellik önemi" değerlerine bakarak, her bir bağımsız değişkenin model üzerindeki etkisi belirlenebilmektedir (Aakash & Gupta Aggarwal, 2022).

Bu çalışmada, “Kalite” en önemli değişken olarak öne çıkarılmış, ardından “Kullanım Kolaylığı” ve “Değer” sırasıyla önem sıralamasına dahil edilmiştir. Özellik önem dereceleri şöyledir: “Kalite” model tahminlerinde %75,4'lük bir etkiye sahipken, “Kullanım Kolaylığı”, %18,1 ve “Değer”, %6,4 oranında etkili bulunmuştur. Bu

sıralama, müşteri memnuniyeti üzerindeki etkilerine göre değişkenlerin göreceli önemini yansıtmaktadır.

```
Quality: 0.7541024252146714
Value: 0.06470003629136364
EaseofUse: 0.18119753849396503
```

Çalışmanın bu bölümünde, ürün sahip olma süresinin kısa ve uzun olması durumlarında, bağımlı değişken üzerindeki etkileri daha detaylı bir şekilde anlamak için regresyon analizleri yeniden gerçekleştirilmiştir. Ürüne sahip olma süresinin düşük olduğu durumda, bağımsız değişkenler bağımlı değişkeni %64 oranında açıklayabilmiştir. En yüksek etki "Kalite" algısı tarafından sağlanmakta olup %73, "Değer" algısı ise %7, "Kullanım Kolaylığı" %18 oranında ortaya çıkmıştır. Python çıktıları da şu şekildedir:

Results for LOO 2coded Level 1:
R-squared for LOO 2coded Level 1: 0.6428727185751448
Feature Importances for LOO 2coded Level 1: [0.73875516 0.07326215 0.18798269]

Ürüne sahip olma süresinin yüksek olduğu durumda ise, teknoloji etkileşiminin müşteri memnuniyetini açıklama oranı %71'e yükselmiştir. En yüksek etki yine "Kalite" algısı tarafından sağlanmakta olup önceki analize oranla bir düşüş gözlenmiştir (%67). "Değer" algısı ise %11'e, "Kullanım Kolaylığı" ise %21'e yükselmiştir.

Results for LOO 2coded Level 2:
R-squared for LOO 2coded Level 2: 0.719595725552097
Feature Importances for LOO 2coded Level 2: [0.67137263 0.116217 0.21240947]

Tablo 24: Önem Özelliği ve Modelin Tahmin Gücü Değerleri

	Ürüne Sahip Olma Süresi Düşük	Ürüne Sahip Olma Süresi Yüksek	Tüm Veri Kümesi
Algılanan Kalite	73,8%	67,1%	75,4%
Algılanan Kullanım Kolaylığı	18,7%	21,2%	18,1%
Algılanan Değer	7,3%	11,6%	6,4%
Modelin Tahmin Gücü	64,2%	71,9%	63,5%

Tablo 24'te özetlendiği gibi sonuçlar, kullanıcının ürünü kullanmaya devam ettikçe memnuniyetinin, kullanım kolaylığı algısının ve ürünü değerli bulma algısının arttığını göstermektedir. Artan memnuniyet ve ürünü daha değerli bulma algısı, kullanıcının ürünle olan deneyimini zamanla iyileştirdiğini ve ürün hakkında olumlu bir algı geliştirdiğini gösterebilir. Kullanım kolaylığına verilen önem, ürünün kullanıcı dostu olmasının ve kullanıcının ihtiyaçlarını karşılamasının bir sonucu olabilir. Bu olumlu gelişmeler, ürünün kullanıcılar tarafından daha çok benimsenmesi ve tercih edilmesiyle sonuçlanabilir. Kullanıcıların ürünü daha değerli bulması, ürünün sunduğu faydaların kullanıcılar için önemli ve anlamlı olduğunu göstermektedir. Kullanım kolaylığının artması ise, ürünün kullanıcı deneyimini olumlu yönde etkileyerek, kullanıcıların üründen daha fazla memnun kalmasına katkıda bulunur. Artan kullanıcı memnuniyeti ve ürüne verilen değer, ürünle ilgili olumlu geri bildirimlerin artmasına ve dolayısıyla ürünün piyasadaki konumunun güçlenmesine yardımcı olabilir. Bu nedenle, kullanıcı deneyimini sürekli olarak iyileştirmeye odaklanmak ve ürünün kullanıcı dostu özelliklerini geliştirmek, firmalar için stratejik bir önem taşımaktadır. Kullanıcı geri bildirimlerini düzenli olarak izleyerek, bu olumlu algıyı daha da güçlendirmek ve kullanıcı memnuniyetini sürekli olarak artırmak, firmalar için önemli bir adım olacaktır.

4.5. Sonuç

Bu çalışma, teknoloji etkileşimi ve müşteri memnuniyeti arasındaki ilişkiyi derinlemesine inceleyerek, algılanan kalite, algılanan değer ve algılanan kullanım kolaylığı boyutları üzerinden müşteri memnuniyetinin nasıl artırılabileceğini ortaya koyan yenilikçi bir model geliştirmiştir. Müşterilere sunulan teknolojik ürün/hizmet aynı zamanda yapay zekâ destekli bir ürün ise, müşterilerin bu ürünü kabul etmesi ve benimsemesi diğer teknolojik ürünlere göre daha kolay ve hızlı olacaktır (Bag vd., 2022). Yapay zekâ teknolojilerinin kullanılmasının kullanıcı katılımını ve dönüşümünü olumlu yönde etkilediğini ifade eden önceki araştırmaların bulgularıyla uyumlu olarak (Bag vd., 2022; Rahman vd., 2023; Wijayati vd., 2022), bu çalışma da yapay zekâ destekli ürün ve hizmetlerin, müşteri memnuniyetini önemli ölçüde artırdığını göstermiştir.

Önerilen model, teknoloji etkileşiminin, müşterilerin ürünlerle ilgili algıları üzerinden müşteri memnuniyetini artırabileceği hipotezini test etmiş ve bu üç boyutun (Algılanan

Kalite, Algılanan Değer, Algılanan Kullanım Kolaylığı) müşteri memnuniyeti üzerinde önemli ve pozitif etkileri olduğunu doğrulamıştır. Regresyon analizi, müşterilerin ürünle etkileşimlerinin devamlılığı arttıkça, memnuniyet üzerindeki pozitif etkilerinin güçlendiğini göstermiştir. Bu bulgular, yapay zekâ ürünlerinin yaygınlaşmasıyla müşteri memnuniyetinin artacağı ve ürünlerle olan etkileşimin her geçen gün daha olumlu bir deneyime dönüşeceği yönünde önemli bir kanıt sunmaktadır.

Ayrıca yapılan müşteri segmentasyonu analizi, farklı kullanıcı gruplarının memnuniyet düzeyleri ve ürün kullanım süreleri arasındaki ilişkiyi ele almıştır. Ilımlılar, Hayranlar ve Memnuniyetsizler olarak adlandırılan üç farklı müşteri grubu belirlenmiş ve bu grupların, teknoloji etkileşiminin algılanan boyutlarına göre farklı tepkiler sergilediği ortaya konmuştur. Özellikle, ılımlı memnuniyet düzeyine sahip kullanıcıların, ürünü daha uzun süre kullanmaya devam ettikçe memnuniyetlerinin arttığı görülmüştür. Bu, müşteri deneyiminin zamanla ve sürekli kullanım ile nasıl gelişebileceğinin bir göstergesi olup, ürün ve hizmetlerin sürekli iyileştirilmesi gerekliliğini vurgulamaktadır (Z. Yang & Fang, 2004). Bu bulgular, şirketlerin müşteri ilişkileri yönetimi ve pazarlama stratejileri için önemli olup, hangi müşteri gruplarına odaklanmaları ve onların memnuniyetini artırmak için hangi alanlara yatırım yapmaları gerektiği konusunda yol gösterici bilgiler sunmaktadır.

4.6. Sınırlılıklar ve Gelecek Araştırmalar

Bu çalışma, her araştırmanın kaçınılmaz olarak içerdiği sınırlılıklara sahiptir. En önemli sınırlılık, araştırmanın kapsamının yalnızca sanal asistan ürünleriyle sınırlı olmasıdır. Bu nedenle, yapay zekânın müşteri memnuniyeti üzerindeki etkisini daha geniş bir yapay zekâ destekli ürün yelpazesinde değerlendirmek, teknolojik etkileşim ile müşteri memnuniyeti arasındaki ilişkiyi daha kapsamlı bir biçimde ortaya koymak adına yararlı olacaktır. Bu çerçevede, çeşitli sanal asistan ürünleri kullanılarak gerçekleştirilecek ilave çalışmalar, hipotezlerimizin genel geçerliğini ve kapsamını artırarak, alandaki bilgi birikimini zenginleştirebilir.

Bu araştırmanın önemli bir eksikliği, büyük veri kullanımıyla sınırlı kalmış ve yalnızca mevcut veriler üzerinden analiz yapılmış olmasıdır. Alternatif yaklaşımlar olarak, öncelikli olarak birincil veri toplama yöntemleri düşünülebilir. Anketler, odak grupları veya derinlemesine mülakatlar yoluyla elde edilecek birincil veriler, müşteri tercihleri

ve deneyimleri hakkında daha ayrıntılı ve bağlamsal bilgiler sunabilir. Ayrıca, deneysel tasarımlar veya uzun dönemli panel çalışmaları, yapay zekâ ürünlerinin müşteri memnuniyeti üzerindeki etkilerini zaman içinde ve kontrollü bir şekilde incelemek için kullanılabilir. Bu yöntemler, büyük veri analizinin sunduğu geniş kapsamlı trendlerle bütünleşerek, daha detaylı ve neden-sonuç ilişkilerini anlamaya yönelik zengin veriler sunabilir. Bu çalışmanın gelecekteki genişletilmiş versiyonları, bu tür birincil veri toplama yöntemlerini ve deneysel tasarımları içerecek şekilde tasarlanabilir.

Bu çalışma, teknoloji etkileşiminin, özellikle yapay zekâ gibi ileri teknoloji ürünlerinde, müşteri memnuniyetini artırmada merkezi bir rol oynadığını göstermekte ve bu teknolojik etkileşim boyutlarının daha derinlemesine anlaşılması gerektiğini vurgulamaktadır. Gelecekteki araştırmalar, bu modelin çeşitli endüstrilerde ve farklı türdeki yapay zekâlı teknolojik ürünler için geçerliliğini test edebilir ve işletmelerin müşteri memnuniyetini maksimize etmek için hangi stratejilerin en etkili olduğunu belirleyebilir. Bu çalışmanın bulguları, müşteri memnuniyetini artırma stratejilerini şekillendirme ve işletmelerin rekabet avantajını geliştirme konusunda yol gösterici olabilir.

5. GENEL DEĞERLENDİRME VE SONUÇ

Bu tez, yapay zekâ destekli sanal asistanlar üzerine odaklanarak, müşteri yorumlarının ürün inovasyon sürecine ve müşteri memnuniyetine nasıl katkı sağladığını derinlemesine incelemiştir. Büyük veri ve makine öğrenimi tekniklerini kullanarak, müşterilerle ortak yaratımın bu süreçteki önemini vurgulamıştır. Üç bölüm boyunca ele alınan konular, müşteri deneyimini anlamak ve iyileştirmek için teknolojinin ve müşteri geri bildirimlerinin nasıl etkin kullanılabileceğine dair derinlemesine bir bakış açısı sunmaktadır.

Farklı konu modelleme tekniklerinin karşılaştırmalı analizi, müşteri yorumlarından anlamlı içgörüler elde etmenin önemini ortaya koymuştur. Bu içgörüler, pazarlama stratejilerinin ve ürün iyileştirmelerinin şekillendirilmesinde kritik rol oynamaktadır (Davenport vd., 2020). İşletmeler, müşteri yorumlarını ve geri bildirimlerini daha etkin bir şekilde toplamak ve analiz etmek için gelişmiş veri analizi yöntemlerini benimsemelidir (Ordenes vd., 2014). Bu yöntemler, şirketlerin ürün ve hizmetlerini müşteri ihtiyaçlarına daha iyi uyum sağlayacak şekilde ayarlamalarına olanak tanır. Müşteri yorumlarından elde edilen verilerin analizi, ürün geliştirme süreçlerinde kritik öneme sahiptir (Sawhney vd., 2005). Şirketler, geri bildirim mekanizmalarını daha dinamik hale getirerek, müşterilerden gelen yorumları gerçek zamanlı olarak analiz etmeli ve hızlı bir şekilde eyleme geçmeli ayrıca, Elektronik Ağızdan Ağıza Pazarlama'nın yeni ürün geliştirme süreçlerindeki etkinliğini artırmak için tüketiciler, tasarımcılar ve mühendisler arasında iş birliği ağları kurmalıdır (Füller, 2010). Bu ağlar, fikirlerin serbestçe paylaşılmasını ve müşteri ihtiyaçlarına daha uygun ürünlerin hızlı bir şekilde geliştirilmesini sağlayacaktır. Bu anlayış, aynı zamanda rekabet avantajı elde etme ve pazar liderliğini sürdürme konusunda şirketlere yardımcı olacaktır (X. Bai vd., 2017). Yapay zekâ destekli sanal asistanlar, müşterilerin teknolojiyle etkileşimlerini zenginleştirerek, müşteri etkileşimi yaratmaktadır (Shah vd., 2024). Etkileşim, perakendeciler tarafından müşterileri çekmek için yapay zekâ teknolojisi ile elde edilebilecek önemli stratejilerden biridir (Pillai vd., 2020). Kullanıcıların bu teknolojiyi benimseme hızına bakıldığında, yapay zekayı ürünlerine

entegre etmek konusunda geç kalmamaları gerekmektedir. Şirketler, yapay zekâ teknolojilerinin müşteri etkileşimi ve memnuniyeti üzerindeki pozitif etkilerini daha da artırmak için, müşteri deneyimlerini sürekli olarak analiz etmeli ve iyileştirmelidir. Çünkü yapay zekâ teknolojisinin kendisi de birlikte yaratımın önemli bir bileşenidir. Amazon Alexa, yapay zekâ destekli bir sesli asistan olarak, kullanıcılarla sürekli bir etkileşim içinde olduğundan, birlikte yaratım süreçlerine doğal bir şekilde destek verebilir (Paschen vd., 2021). Bu destek, kullanıcıların geri bildirimlerini toplama, kullanıcı ihtiyaçlarını anlama ve bu ihtiyaçlara yönelik yenilikler geliştirme yoluyla sağlanabilir. Alexa'nın kullanıcı davranışlarını öğrenme yeteneği sayesinde, her kullanıcının tercihlerine göre kişiselleştirilmiş deneyimler sunabilir (Huang & Rust, 2018). Geliştiriciler, Alexa'nın yeteneklerini genişletmek için yeni uygulamalar oluşturabilirler. Kullanıcı geri bildirimleri, hangi yeni becerilerin ve uygulamaların geliştirileceğine dair yol gösterici olabilir. Bu süreç, kullanıcıların doğrudan katılımıyla şekillenen yenilikçi çözümlerin ortaya çıkmasını sağlayabilir. Alexa, kullanıcılara anketler veya oylamalar yoluyla katılım imkânı sunarak, onların görüşlerini belirli özellikler veya yenilikler hakkında ifade etmelerine olanak tanıyabilir. Bu şekilde, kullanıcıların tercihleri doğrudan ürün geliştirme sürecine dahil edilir. Sonuç olarak bu tez, müşteri yorumları ve yapay zekâ destekli teknolojilerin, birlikte yaratımın temel unsurları olarak işlev görebileceğini ve şirketlerin müşteri memnuniyetini artırmak, müşteri beklentileri ile ürün arasında etkili bir köprü kurmak için bu unsurlardan nasıl faydalanabileceğini vurgulamaktadır.

Bu tezin literatüre katkısı beş ana başlıkta incelenebilir. İlk olarak, sosyal bilimlerde sıklıkla kullanılan klasik anket yöntemlerinden farklı olarak, büyük veri üzerinde analizler gerçekleştirilmiştir. İlk bölümde LDA, Sentence-BERT, BERTopic ve Top2Vec olmak üzere dört farklı konu modelleme tekniği kullanılmıştır. İkinci bölümde, Duygu Analizi, Duyarlılık Analizi ve Fırsat Analizi yöntemlerinden faydalanılmıştır. Üçüncü bölümde, Regresyon, t-test, ANOVA ve kümeleme yöntemleri kullanılmıştır. Python üzerinde yapılan tüm bu analizler, güçlü metodolojik yaklaşımı ile literatüre katkı sağlamakta, gelecek araştırmalara için pazarlama akademisyenlerine yol göstermektedir. İkinci olarak, çevrimiçi müşteri yorumları üzerinden, bir ürünün iki farklı modeli üzerinde analiz gerçekleştirerek müşteri geri bildirimlerini konu modelleme, duygu analizi ve fırsat analizi yöntemleri ile derinlemesine incelemekte ve bu bilgilerin yeni ürün geliştirme süreçlerinde nasıl

kullanılabileceğini ortaya koymaktadır. Yapılan kapsamlı araştırma sonrası, EAAP vasıtasıyla ürün geliştirme süreçlerininin etkinliğini, bir ürünün iki farklı modeli üzerine analiz yaparak ortaya koyan ilk çalışma olduğu söylenebilir. Üçüncü olarak, literatürde Teknoloji Etkileşimi kavramı kullanılmaya başlanmış olsa da yapay zekalı ürünler kapsamında müşteri memnuniyetini arttırdığı öne sürülen ilk model önerisi bu çalışma kapsamında kullanılmıştır. Dördüncü olarak, ürün kullanım süresi arttıkça müşteri memnuniyetinin arttığı gösterilmiştir. Yapay zekalı ürünlerde etkileşimin önemini ortaya koymuş müşteri deneyiminin zamanla ve sürekli kullanım ile gelişebileceğini ortaya koymuştur. Son olarak, müşteri segmentasyonu analizi ile sadece orta düzeyde memnuniyeti olan müşteri segmentinin, ürünün uzun süre kullanılması halinde, memnuniyetlerinin arttığı tespit edilmiştir. Bu bulgular, şirketlerin müşteri ilişkileri yönetimi ve pazarlama stratejileri için önemli olup, hangi müşteri gruplarına odaklanmaları ve onların memnuniyetini artırmak için hangi alanlara yatırım yapmaları gerektiği konusunda yol gösterici bilgiler sunmaktadır.

KAYNAKÇA

Aakash, A., & Gupta Aggarwal, A. (2022). Assessment of Hotel Performance and Guest Satisfaction through eWOM: Big Data for Better Insights. *International Journal of Hospitality and Tourism Administration*, *23*(2), 317-346. https://doi.org/10.1080/15256480.2020.1746218

Abbasi, A., Li, J., Adjeroh, D., Abate, M., & Zheng, W. (2019). Don't mention it? Analyzing user-generated content signals for early adverse event warnings. *Information Systems Research*, *August*. https://doi.org/10.2139/ssrn.2880774

Abdelrazek, A., Eid, Y., Gawish, E., Medhat, W., & Hassan, A. (2022). Topic modeling algorithms and applications: A survey. *Information Systems*, *112*(October), 102131. https://doi.org/10.1016/j.is.2022.102131

Agarwal, R., & Karahanna, E. (2004). Time Files When You're Fun: Cognitive Absorption and Beliefs about Information Technology Usage. *MIS Quarterly*, *18*(4), 695-704.

Agrawal, S. R., & Mittal, D. (2022). Optimizing customer engagement content strategy in retail and E-tail: Available on online product review videos. *Journal of Retailing and Consumer Services*, *67*, 102966. https://doi.org/10.1016/J.JRETCONSER.2022.102966

Ahmad, S. N., & Laroche, M. (2023). Extracting marketing information from product reviews: a comparative study of latent semantic analysis and probabilistic latent semantic analysis. *Journal of Marketing Analytics*, *0123456789*. https://doi.org/10.1057/s41270-023-00218-6

Ahn, J., Lee, C. K., Back, K. J., & Schmitt, A. (2019). Brand experiential value for creating integrated resort customers' co-creation behavior. *International Journal of Hospitality Management*, *81*(February), 104-112. https://doi.org/10.1016/j.ijhm.2019.03.009

Aizawa, A. (2003). An information-theoretic perspective of tf–idf measures. *Information Processing & Management*, *39*(1), 45-65. https://doi.org/10.1016/S0306-4573(02)00021-3

Ajzen, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, *50*(2), 179-211. https://doi.org/10.1016/0749-5978(91)90020-T

Akman, H., Plewa, C., & Conduit, J. (2019). Co-creating value in online innovation communities. *European Journal of Marketing*, *53*(6), 1205-1233. https://doi.org/10.1108/EJM-12-2016-0780

Albalawi, R., Yeap, T. H., & Benyoucef, M. (2020). Using Topic Modeling Methods for Short-Text Data: A Comparative Analysis. *Frontiers in Artificial Intelligence*, *3*(July), 1-14. https://doi.org/10.3389/frai.2020.00042

Alfeo, A. L., Cimino, M. G. C. A., & Vaglini, G. (2021). Technological troubleshooting based on sentence embedding with deep transformers. *Journal of Intelligent Manufacturing*, *32*(6), 1699-1710. https://doi.org/10.1007/s10845-021-01797-w

Alhaj, F., Al-Haj, A., Sharieh, A., & Jabri, R. (2022). Improving Arabic Cognitive Distortion Classification in Twitter using BERTopic. *International Journal of Advanced Computer Science and Applications*, *13*(1), 854-860. https://doi.org/10.14569/IJACSA.2022.0130199

Alzate, M., Arce-Urriza, M., & Cebollada, J. (2021). Online Reviews and Product Sales: The Role of Review Visibility. *Journal of Theoretical and Applied Electronic Commerce Research*, *16*(1), 638-669. https://doi.org/10.3390/jtaer16010038

Andreassen, T. W., & Streukens, S. (2009). Service innovation and electronic word of mouth: Is it worth listening to? *Managing Service Quality: An International Journal*, *19*(3), 249-265. https://doi.org/10.1108/09604520910955294

Angelov, D. (2020). *TOP2VEC: DISTRIBUTED REPRESENTATIONS OF TOPICS.*

Angelov, D., & Clendenning, G. (2020). Top2Vec. *Github*. https://github.com/ddangelov/Top2Vec

Aslam, N., Rustam, F., Lee, E., Washington, P. B., & Ashraf, I. (2022). Sentiment Analysis and Emotion Detection on Cryptocurrency Related Tweets Using Ensemble LSTM-GRU Model. *IEEE Access*, *10*, 39313-39324. https://doi.org/10.1109/ACCESS.2022.3165621

Ayeh, J. K. (2015). Travellers' acceptance of consumer-generated media: An integrated model of technology acceptance and source credibility theories. *Computers in Human Behavior*, *48*, 173-180. https://doi.org/10.1016/j.chb.2014.12.049

Baek, H., Ahn, J., & Choi, Y. (2012). Helpfulness of online consumer reviews: Readers' objectives and review cues. *International Journal of Electronic Commerce*, *17*(2), 99-126. https://doi.org/10.2753/JEC1086-4415170204

Bafna, P., Pramod, D., & Vaidya, A. (2016). Document clustering: TF-IDF approach. *International Conference on Electrical, Electronics, and Optimization Techniques, ICEEOT 2016*, *November 2019*, 61-66. https://doi.org/10.1109/ICEEOT.2016.7754750

Bag, S., Kumar, S. K., & Tiwari, M. K. (2019). An efficient recommendation generation using relevant Jaccard similarity. *Information Sciences*, *483*, 53-64. https://doi.org/10.1016/j.ins.2019.01.023

Bag, S., Srivastava, G., Bashir, M. M. Al, Kumari, S., Giannakis, M., & Chowdhury, A. H. (2022). Journey of customers in this digital era: Understanding the role of artificial intelligence technologies in user engagement and conversion. *Benchmarking*, *29*(7), 2074-2098. https://doi.org/10.1108/BIJ-07-2021-0415

Bagozzi, R. P. (2007). The legacy of the technology acceptance model and a proposal for a paradigm shift. *Journal of the Association for Information Systems*, *8*(4), 244-254. https://doi.org/10.17705/1jais.00122

Bai, S., He, H., Han, C., Yang, M., Yu, D., Bi, X., Gupta, B. B., Fan, W., & Panigrahi, P. K. (2023). Exploring thematic influences on theme park visitors' satisfaction:

An empirical study on Disneyland China. *Journal of Consumer Behaviour*, *January*, 1-17. https://doi.org/10.1002/cb.2157

Bai, X., Marsden, J. R., Ross, W. T., & Wang, G. (2017). How e-WOM and local competition drive local retailers' decisions about daily deal offerings. *Decision Support Systems*, *101*, 82-94. https://doi.org/10.1016/j.dss.2017.06.003

Baka, V. 2016. The becoming of user-generated reviews: Looking at the past to understand the future of managing reputation in the travel sector. Tourism Management 53: 148–162. https:// doi. or g/ 10. 1016/j. tourm an. 2015. 09. 004.

Barde, B. V., & Bainwad, A. M. (2017). An overview of topic modeling methods and tools. *Proceedings of the 2017 International Conference on Intelligent Computing and Control Systems, ICICCS 2017*, *2018-Janua*, 745-750. https://doi.org/10.1109/ICCONS.2017.8250563

Bhaiswar, R., Meenakshi, N., & Chawla, D. (2021). Evolution of Electronic Word of Mouth: A Systematic Literature Review Using Bibliometric Analysis of 20 Years (2000–2020). *FIIB Business Review*, *10*(3), 215-231. https://doi.org/10.1177/23197145211032408

Bianchi, F., Terragni, S., Hovy, D., Nozza, D., & Fersini, E. (2021). Cross-lingual contextualized topic models with zero-shot learning. *EACL 2021 - 16th Conference of the European Chapter of the Association for Computational Linguistics, Proceedings of the Conference*, 1676-1683. https://doi.org/10.18653/v1/2021.eacl-main.143

Bigne, E., Ruiz, C., Perez-Cabañero, C., & Cuenca, A. (2023). Are customer star ratings and sentiments aligned? A deep learning study of the customer service experience in tourism destinations. Içinde *Service Business* (C. 17, Sayı 1). Springer Berlin Heidelberg. https://doi.org/10.1007/s11628-023-00524-0

Bird, S., Klien, E., & Loper, E. (2001). *Analyzing Text with the Natural Language Toolkit*. https://www.nltk.org/book/

Black, I., & Veloutsou, C. (2017). Working consumers: Co-creation of brand identity, consumer identity and brand community identity. *Journal of Business Research*, *70*, 416-429. https://doi.org/10.1016/j.jbusres.2016.07.012

Blair, S. J., Bi, Y., & Mulvenna, M. D. (2020). Aggregated topic models for increasing social media topic coherence. *Applied Intelligence*, *50*(1), 138-156. https://doi.org/10.1007/s10489-019-01438-z

Blei, D., Ng, A., & Jordan, M. (2003). Latent Dirichlet Allocation. *Journal of Machine Learning Research*, *3*, 993-1022. https://doi.org/10.1016/B978-0-12-411519-4.00006-9

Bolton, T., Dargahi, T., Belguith, S., Al-Rakhami, M. S., & Sodhro, A. H. (2021). On the security and privacy challenges of virtual assistants. *Sensors*, *21*(7), 1-19. https://doi.org/10.3390/s21072312

Breiman, L. (2001). Random Forest. *Journal of Machine Learning*, *45*, 5-32.

Bricken, A. (2021). *Does BERT Need Clean Data? Part 1: Data Cleaning.* https://towardsdatascience.com/part-1-data-cleaning-does-bert-need-clean-data-6a50c9c6e9fd

Brieman, L., & Cutler, A. (t.y.). *Random Forest Website*. https://www.stat.berkeley.edu/users/breiman/RandomForests/

Brill, T. M., Munoz, L., & Miller, R. J. (2019). Siri, Alexa, and other digital assistants: a study of customer satisfaction with artificial intelligence applications. *Journal of Marketing Management*, *35*(15-16), 1401-1436. https://doi.org/10.1080/0267257X.2019.1687571

Burbach, L., Halbach, P., Plettenberg, N., Nakayama, J., Ziefle, M., & Calero Valdez, A. (2019). Acceptance-relevant factors of virtual voice-assistants. *IEEE International Professional Communication Conference (ProComm)*.

Büschken, J., & Allenby, G. M. (2016). Sentence-based text analysis for customer reviews. *Marketing Science*, *35*(6), 953-975. https://doi.org/10.1287/mksc.2016.0993

Caliñski, T., & Harabasz, J. (1974). A Dendrite Method Foe Cluster Analysis. *Communications in Statistics*, *3*(1), 1-27. https://doi.org/10.1080/03610927408827101

Calvo-Porral, C., & Pesqueira-Sanchez, R. (2022). Does the use of technology create technology engagement? Comparing three structural models. *Spanish Journal of Marketing - ESIC*, *26*(3), 385-404. https://doi.org/10.1108/SJME-03-2022-0033

Campbell, J. C., Hindle, A., & Stroulia, E. (2015). Latent Dirichlet Allocation: Extracting Topics from Software Engineering Data. *The Art and Science of Analyzing Software Data*, 139-159. https://doi.org/10.1016/B978-0-12-411519-4.00006-9

Canali, S. (2016). Big Data, epistemology and causality: Knowledge in and knowledge out in EXPOsOMICS. *Big Data and Society*, *3*(2). https://doi.org/10.1177/2053951716669530

Cardozo, R. N. (1965). An Experimental Study of Customer Effort, Expectation, and Satisfaction. *Journal of Marketing Research*, *2*(3), 244. https://doi.org/10.2307/3150182

Caroli, P. (2023). *Opportunity scoring (importance vs. satisfaction)*. https://caroli.org/en/opportunity-scoring/

Casaló, L. V., Flavián, C., Guinalíu, M., & Ekinci, Y. (2015). Avoiding the dark side of positive online consumer reviews: Enhancing reviews' usefulness for high risk-averse travelers. *Journal of Business Research*, *68*(9), 1829-1835. https://doi.org/10.1016/j.jbusres.2015.01.010

Chatterjee, P. (2001). *Online Reviews : Do Consumers Use Them ? Please cite as : Chatterjee , Patrali (2001), " Online Reviews – Do Consumers Use Them ?" ACR 2001 Online Reviews : Do Consumers Use Them ? Patrali Chatterjee Faculty of Management Rutgers University*. *May 2006*, 1-21.

Cheng, H., Liu, S., Sun, W., & Sun, Q. (2023). A Neural Topic Modeling Study Integrating SBERT and Data Augmentation. *Applied Sciences (Switzerland)*, *13*(7). https://doi.org/10.3390/app13074595

Cheng, V. T. P., & Loi, M. K. (2014). Handling Negative Online Customer Reviews: The Effects of Elaboration Likelihood Model and Distributive Justice. *Journal of Travel and Tourism Marketing*, *31*(1), 1-15. https://doi.org/10.1080/10548408.2014.861694

Cheng, Y. H., & Ho, H. Y. (2015). Social influence's impact on reader perceptions of online reviews. *Journal of Business Research*, *68*(4), 883-887. https://doi.org/10.1016/j.jbusres.2014.11.046

Cheung, C. M. K., & Thadani, D. R. (2012). The impact of electronic word-of-mouth communication: A literature analysis and integrative model. *Decision Support Systems*, *54*(1), 461-470. https://doi.org/10.1016/j.dss.2012.06.008

Chevalier, J. A., & 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

Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, *7*, 1-24. https://doi.org/10.7717/PEERJ-CS.623

Christensen, C. M., Hall, T., Dillon, K., & Duncan, D. S. (2016). Know your customers' "jobs to be done": is innovation inherently a hit-or-miss endeavor? Not if you understand why customers make the choices they do. *Harvard Business Review*, *94*(9), 54-62.

Christodoulides, G., Jevons, C., & Bonhomme, J. (2012). The impact of user generated content on consumer based brand equity. *Journal of Advertising Research*, *52*(1), 53-64. https://doi.org/10.2501/JAR-52-1-053-064

Chung, J., Lee, J., & Yoon, J. (2022). Understanding music streaming services via text mining of online customer reviews. *Electronic Commerce Research and Applications*, *53*, 101145. https://doi.org/10.1016/J.ELERAP.2022.101145

Churchill, R., & Singh, L. (2022). The Evolution of Topic Modeling. *ACM Computing Surveys*, *54*(10s), 1-35. https://doi.org/10.1145/3507900

Constantinides, E., Brünink, L. A., & Romero, C. L. (2015). Customer motives and benefits for participating in online co-creation activities. *International Journal of Internet Marketing and Advertising*, *9*(1), 21. https://doi.org/10.1504/IJIMA.2015.068346

Constantinides, E., & Lorenzo-Romero, C. (2015). Customer data and co-creation: a primer on the Big Data Innovation Model. *European Marketing Academy Conference*, *September 2017*, 1-7.

Cooper, R. G. (2019). The drivers of success in new-product development. *Industrial Marketing Management*, *76*(January 2018), 36-47. https://doi.org/10.1016/j.indmarman.2018.07.005

Dam, N. A. K., Le Dinh, T., & Menvielle, W. (2019). A systematic literature review of big data adoption in internationalization. *Journal of Marketing Analytics*, *7*(3), 182-195. https://doi.org/10.1057/s41270-019-00054-7

Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, *48*(1), 24-42. https://doi.org/10.1007/s11747-019-00696-0

Davis, F. D., Bagozzi, R. P., Warshaw, P. R., & Davis, Fred D; Bagozzi, Richard P.; Warshaw, P. R. (1989). User acceptance of computer technology: A comparison of two theoretical models. *Management Science*, *35*(8), 982-1003.

Dellaert, B. G. C., Shu, S. B., Arentze, T. A., Baker, T., Diehl, K., Donkers, B., Fast, N. J., Häubl, G., Johnson, H., Karmarkar, U. R., Oppewal, H., Schmitt, B. H., Schroeder, J., Spiller, S. A., & Steffel, M. (2020). Consumer decisions with artificially intelligent voice assistants. *Marketing Letters*, *31*(4), 335-347. https://doi.org/10.1007/s11002-020-09537-5

Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL HLT 2019 - 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Proceedings of the Conference*, *1*(Mlm), 4171-4186.

Dieng, A. B., Ruiz, F. J. R., & Blei, D. M. (2020). Topic modeling in embedding spaces. *Transactions of the Association for Computational Linguistics*, *8*, 439-453. https://doi.org/10.1162/tacl_a_00325

DiMaggio, P. (2015). Adapting computational text analysis to social science (and vice versa). *Big Data and Society*, *2*(2), 1-5. https://doi.org/10.1177/2053951715602908

Doan, T. N., & Hoang, T. A. (2021). Benchmarking Neural Topic Models: An Empirical Study. *Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021*, 4363-4368. https://doi.org/10.18653/v1/2021.findings-acl.382

Dodds, W. B., Monroe, K. B., & Grewal, D. (2013). Effects of Price, Brand, and Store Information on Buyers' Product Evalutions. *Journal of Marketing*, *28*(3), 307-319.

Dos Santos, C. N., & Gatti, M. (2014). Deep convolutional neural networks for sentiment analysis of short texts. *COLING 2014 - 25th International Conference on Computational Linguistics, Proceedings of COLING 2014: Technical Papers*, 69-78.

Dovaliene, A., Masiulyte, A., & Piligrimiene, Z. (2015). The relations between customer engagement perceived value and satisfaction: the case of mobile applications. *Procedia - Social and Behavioral Sciences*, *213*, 659-664. https://doi.org/10.1016/j.sbspro.2015.11.469

Du, X., Zhao, X., Wu, C.-H., & Feng, K. (2021). Functionality, Emotion, and Acceptance of Artificial Intelligence Virtual Assistants. *Journal of Global Information Management*, *30*(7), 1-21. https://doi.org/10.4018/jgim.290418

Duan, W., Gu, B., & Whinston, A. B. (2008). Do online reviews matter? - An empirical investigation of panel data. *Decision Support Systems*, *45*(4), 1007-1016. https://doi.org/10.1016/j.dss.2008.04.001

Dunin-Underwood, A. (2020). Alexa, can you keep a secret? Applicability of the third-party doctrine to information collected in the home by virtual assistants. *Information and Communications Technology Law*, *29*(1), 101-119. https://doi.org/10.1080/13600834.2020.1676956

Dwivedi, Y. K., Ismagilova, E., Hughes, D. L., Carlson, J., Filieri, R., Jacobson, J., Jain, V., Karjaluoto, H., Kefi, H., Krishen, A. S., Kumar, V., Rahman, M. M., Raman, R., Rauschnabel, P. A., Rowley, J., Salo, J., Tran, G. A., & Wang, Y. (2021). Setting the future of digital and social media marketing research:

Perspectives and research propositions. *International Journal of Information Management*, *59*. https://doi.org/10.1016/j.ijinfomgt.2020.102168

Egger, R. (2022). Text Representations and Word Embeddings. *Applied Data Science in Tourism*, 335-361. https://doi.org/10.1007/978-3-030-88389-8_16

Egger, R., & Yu, J. (2021). Identifying hidden semantic structures in Instagram data: a topic modelling comparison. *Tourism Review*, *October*. https://doi.org/10.1108/TR-05-2021-0244

Egger, R., & Yu, J. (2022). A Topic Modeling Comparison Between LDA, NMF, Top2Vec, and BERTopic to Demystify Twitter Posts. *Frontiers in Sociology*, *7*(May), 1-16. https://doi.org/10.3389/fsoc.2022.886498

Ellway, B. P. W., & Dean, A. (2020). Habitus as a value lens to link customer engagement and value cocreation. *Journal of Service Theory and Practice*, *30*(1), 57-77. https://doi.org/10.1108/JSTP-04-2019-0093

Elragal, A., & Klischewski, R. (2017). Theory-driven or process-driven prediction? Epistemological challenges of big data analytics. *Journal of Big Data*, *4*(1), 1-20. https://doi.org/10.1186/s40537-017-0079-2

Enkel, E., Perez-Freije, J., & Gassmann, O. (2005). Minimizing Market Risks Through Customer Integration in New Product Development: Learning from Bad Practice. *Creativity and Innovation Management*, *14*(4), 425-437. https://doi.org/10.1111/j.1467-8691.2005.00362.x

Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, *69*(2), 897-904. https://doi.org/10.1016/j.jbusres.2015.07.001

Erkan, I. (2018). The Influence of Electronic Word of Mouth in Social Media on Consumers' Purchase Intentions. *Computers in Human Behavior*, *61*, 47-55.

Filieri, R., Lin, Z., Li, Y., Lu, X., & Yang, X. (2022). Customer Emotions in Service Robot Encounters: A Hybrid Machine-Human Intelligence Approach. *Journal of Service Research*, *25*(4), 614-629. https://doi.org/10.1177/10946705221103937

Fishbein, M., & Ajzen, I. (1977). Belief, Attitude, Intention and Behavior: An Introduction to Theory and Research. *Contemporary Sociology*, *6*(2), 244. https://doi.org/10.2307/2065853

Fisk, R. P., Dean, A. M., Alkire (née Nasr), L., Joubert, A., Previte, J., Robertson, N., & Rosenbaum, M. S. (2018). Design for service inclusion: creating inclusive service systems by 2050. *Journal of Service Management*, *29*(5), 834-858. https://doi.org/10.1108/JOSM-05-2018-0121

Fu, Z., & Zhou, Y. (2020). Research on human–AI co-creation based on reflective design practice. *CCF Transactions on Pervasive Computing and Interaction*, *2*(1), 33-41. https://doi.org/10.1007/s42486-020-00028-0

Füller, J. (2006). Why consumers engage in virtual new product developments initiated by producers. *Advances in Consumer Research*, *33*(March), 639-646. https://doi.org/43008804

Füller, J. (2010). Refining virtual co-creation from a consumer perspective. *California Review Management*, *52*(2), 98-122.

Gallagher, R. J., Reing, K., Kale, D., & Ver Steeg, G. (2017). Anchored Correlation Explanation: Topic Modeling with Minimal Domain Knowledge. *Transactions of the Association for Computational Linguistics*, *5*, 529-542. https://doi.org/10.1162/tacl_a_00078

Gálvez-Ruiz, P., Calabuig, F., Grimaldi-Puyana, M., González-Serrano, M. H., & García-Fernández, J. (2023). The effect of perceived quality and customer engagement on the loyalty of users of Spanish fitness centres. *Academia Revista Latinoamericana de Administracion*, *36*(4), 445-462. https://doi.org/10.1108/ARLA-01-2023-0014

Gao, Y., Pan, Z., Wang, H., & Chen, G. (2018). Alexa, My Love: Analyzing reviews of amazon echo. *Proceedings - 2018 IEEE SmartWorld, Ubiquitous Intelligence and Computing, Advanced and Trusted Computing, Scalable Computing and Communications, Cloud and Big Data Computing, Internet of People and Smart City Innovations, SmartWorld/UIC/ATC/ScalCom/CBDCo*, 372-380. https://doi.org/10.1109/SmartWorld.2018.00094

García de Blanes Sebastián, M., Sarmiento Guede, J. R., & Antonovica, A. (2022). Application and extension of the UTAUT2 model for determining behavioral intention factors in use of the artificial intelligence virtual assistants. *Frontiers in Psychology*, *13*. https://doi.org/10.3389/fpsyg.2022.993935

Gensler, S., Völckner, F., Egger, M., Fischbach, K., & Schoder, D. (2015). Listen to your customers: Insights into brand image using online consumer-generated product reviews. *International Journal of Electronic Commerce*, *20*(1), 112-141. https://doi.org/10.1080/10864415.2016.1061792

Ghose, A., & Ipeirotis, P. G. (2011). Estimating the helpfulness and economic impact of product reviews: Mining text and reviewer characteristics. *IEEE Transactions on Knowledge and Data Engineering*, *23*(10), 1498-1512. https://doi.org/10.1109/TKDE.2010.188

Glorot, X., Bordes, A., & Bengio, Y. (2011). Domain adaptation for large-scale sentiment classification: A deep learning approach. *Proceedings of the 28th International Conference on Machine Learning, ICML 2011*, *1*, 513-520.

Goksel Canbek, N., & Mutlu, M. E. (2016). On the track of Artificial Intelligence: Learning with Intelligent Personal Assistants. *International Journal of Human Sciences*, *13*(1), 592. https://doi.org/10.14687/ijhs.v13i1.3549

Griffin, A., & Hauser, J. (1993). The voice of the customer. *Marketing Science*, *12*(3), 1-27. https://doi.org/10.4324/9780080496313-9

Grootendorst, M. (2020). *Bertopic: Leveraging bert and c-tf-idf to create easily interpretable topics*.

Grootendorst, M. (2021). *BERTopic*. https://maartengr.github.io/BERTopic/index.html

Grootendorst, M. (2022). *BERTopic: Neural topic modeling with a class-based TF-IDF procedure*.

Grover, P., Kar, A. K., & Dwivedi, Y. K. (2020). Understanding artificial intelligence adoption in operations management: insights from the review of academic literature and social media discussions. Içinde *Annals of Operations Research* (Sayı 0123456789). Springer US. https://doi.org/10.1007/s10479-020-03683-9

Gruen, T. W., Osmonbekov, T., & Czaplewski, A. J. (2006). eWOM: The impact of customer-to-customer online know-how exchange on customer value and loyalty. *Journal of Business Research*, *59*(4), 449-456. https://doi.org/10.1016/j.jbusres.2005.10.004

Guido, V. R., & Drake, F. L. (2009). *Python 3 Reference Manual*. CreateSpace. www.python.org

Gunadi, D., Sanjaya, R., & Harnadi, B. (2019). Examining the Acceptance of Virtual Assistant - Vanika for University Students. *ICICOS 2019 - 3rd International Conference on Informatics and Computational Sciences: Accelerating Informatics and Computational Research for Smarter Society in The Era of Industry 4.0, Proceedings*, 1-4. https://doi.org/10.1109/ICICoS48119.2019.8982513

Guo, J., Wang, X., & Wu, Y. (2020). Positive emotion bias: Role of emotional content from online customer reviews in purchase decisions. *Journal of Retailing and Consumer Services*, *52*(July 2019). https://doi.org/10.1016/j.jretconser.2019.101891

Guo, Y., Barnes, S. J., & Jia, Q. (2017). Mining meaning from online ratings and reviews: Tourist satisfaction analysis using latent dirichlet allocation. *Tourism Management*, *59*, 467-483. https://doi.org/10.1016/j.tourman.2016.09.009

Gupta, H., & Patel, M. (2021). Method of Text Summarization Using Lsa and Sentence Based Topic Modelling with Bert. *Proceedings - International Conference on Artificial Intelligence and Smart Systems, ICAIS 2021*, 511-517. https://doi.org/10.1109/ICAIS50930.2021.9395976

Gupta, P., & Harris, J. (2010). How e-WOM recommendations influence product consideration and quality of choice: A motivation to process information perspective. *Journal of Business Research*, *63*(9-10), 1041-1049. https://doi.org/10.1016/j.jbusres.2009.01.015

Gupta, R. K., Agarwalla, R., Naik, B. H., Evuri, J. R., Thapa, A., & Singh, T. D. (2022). Prediction of research trends using LDA based topic modeling. *Global Transitions Proceedings*, *3*(1), 298-304. https://doi.org/10.1016/j.gltp.2022.03.015

Haines, G. H., Howard, J. A., & Sheth, J. N. (1970). The Theory of Buyer Behavior. *Journal of the American Statistical Association*, *65*(331), 1406. https://doi.org/10.2307/2284311

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). Multivariate Data Analysis. Içinde *Analysis*. https://doi.org/10.1016/j.ijpharm.2011.02.019

Hannigan, T. R., Haan, R. F. J., Vakili, K., Tchalian, H., Glaser, V. L., Wang, M. S., Kaplan, S., & Jennings, P. D. (2019). Topic modeling in management research: Rendering new theory from textual data. *Academy of Management Annals*, *13*(2), 586-632. https://doi.org/10.5465/annals.2017.0099

Hauswald, J., Laurenzano, M. A., Zhang, Y., Li, C., Rovinski, A., Khurana, A., Dreslinski, R. G., Mudge, T., Petrucci, V., Tang, L., & Mars, J. (2015). Sirius: An Open End-to-End Voice and Vision Personal Assistant and Its Implications for Future Warehouse Scale Computers. *ACM SIGPLAN Notices*, *50*(4), 223-238. https://doi.org/10.1145/2775054.2694347

Healy, J. C., & McDonagh, P. (2013). Consumer roles in brand culture and value co-creation in virtual communities. *Journal of Business Research*, *66*(9), 1528-1540. https://doi.org/10.1016/j.jbusres.2012.09.014

Heberle, H., Meirelles, V. G., da Silva, F. R., Telles, G. P., & Minghim, R. (2015). InteractiVenn: A web-based tool for the analysis of sets through Venn diagrams. *BMC Bioinformatics*, *16*(1), 1-7. https://doi.org/10.1186/s12859-015-0611-3

Hendry, D., Darari, F., Nurfadillah, R., Khanna, G., Sun, M., Condylis, P. C., & Taufik, N. (2021). Topic Modeling for Customer Service Chats. *International Conference of Advanced Science and Information Systems*, 1-6.

Heng, Y., Gao, Z., Jiang, Y., & Chen, X. (2018). Exploring hidden factors behind online food shopping from Amazon reviews: A topic mining approach. *Journal of Retailing and Consumer Services*, *42*(October 2017), 161-168. https://doi.org/10.1016/j.jretconser.2018.02.006

Hennig-Thurau, T., & Walsh, G. (2003). Electronic word-of-mouth: Motives for and consequences of reading customer articulations on the internet. *International Journal of Electronic Commerce*, *8*(2), 51-74. https://doi.org/10.1080/10864415.2003.11044293

Heuvel, V. D., & Devasagayam, R. (1999). Multivariate Cluster Analytic Model of Benefit-Based Market Segmentation: A Case Study From The Recreation and Leisure Industry. *MBAA Cenference Proccedings*.

Hoffman, M. D., Blei, D. M., Wang, C., & Paisley, J. (2013). Stochastic variational inference. *Journal of Machine Learning Research*, *14*, 1303-1347.

Homburg, C., Ehm, L., & Artz, M. (2015). Measuring and Managing Consumer Sentiment in an Online Community Environment. *Journal of Marketing Research*, *52*(5), 629-641.

Hong, L., & Davison, B. D. (2010). Empirical study of topic modeling in Twitter. *SOMA 2010 - Proceedings of the 1st Workshop on Social Media Analytics*, 80-88. https://doi.org/10.1145/1964858.1964870

Honnibal, M., & Montani, I. (2017). *spaCy 2*.

Houda Elafdel. (2019). *Electronic Word of Mouth Through Technology Acceptance Model | Request PDF*. *August*.

How Does Drop In Work? (2023). https://www.amazon.com/gp/help/customer/display.html?nodeId=GS3WRTSRKD2U6MCK#:~:text=Drop In is an optional, or with your Alexa contacts.

Hsu, C., & Lin, J. C. (2015). What drives purchase intention for paid mobile apps? – An expectation confirmation model with perceived value. *Electronic Commerce Research and Applications*, *14*(1), 46-57. https://doi.org/10.1016/j.elerap.2014.11.003

Hu, X., & Yang, Y. (2020). What makes online reviews helpful in tourism and hospitality? a bare-bones meta-analysis. *Journal of Hospitality Marketing and Management*, 1-20. https://doi.org/10.1080/19368623.2020.1780178

Huang, M. H., & Rust, R. T. (2018). Artificial Intelligence in Service. *Journal of Service Research*, *21*(2), 155-172. https://doi.org/10.1177/1094670517752459

Huifeng, P., Ha, H. Y., & Lee, J. W. (2020). Perceived risks and restaurant visit intentions in China: Do online customer reviews matter? *Journal of Hospitality and Tourism Management*, *43*(November 2019), 179-189. https://doi.org/10.1016/j.jhtm.2020.04.005

Iacobucci, D., Petrescu, M., Krishen, A., & Bendixen, M. (2019). The state of marketing analytics in research and practice. *Journal of Marketing Analytics*, *7*(3), 152-181. https://doi.org/10.1057/s41270-019-00059-2

Iglesias, O., Ind, N., & Alfaro, M. (2013). The organic view of the brand: A brand value co-creation model. *Journal of Brand Management*, *20*(8), 670-688. https://doi.org/10.1057/bm.2013.8

Jacobs, T., & Tschötschel, R. (2019). Topic models meet discourse analysis: a quantitative tool for a qualitative approach. *International Journal of Social Research Methodology*, *22*(5), 469-485. https://doi.org/10.1080/13645579.2019.1576317

Jeon, E., Yoon, N., & Sohn, S. Y. (2023). Exploring new digital therapeutics technologies for psychiatric disorders using BERTopic and PatentSBERTa. *Technological Forecasting and Social Change*, *186*(PA), 122130. https://doi.org/10.1016/j.techfore.2022.122130

Jeong, B., Yoon, J., & Lee, J. M. (2017). Social media mining for product planning: A product opportunity mining approach based on topic modeling and sentiment analysis. *International Journal of Information Management*, *48*(August 2017), 280-290. https://doi.org/10.1016/j.ijinfomgt.2017.09.009

Jia, S. S. (2018). Behind the ratings: Text mining of restaurant customers' online reviews. *International Journal of Market Research*, *60*(6), 561-572. https://doi.org/10.1177/1470785317752048

Jones, T. O., & Sasser, W. E. (2009). Why Satisfied Customers Defect. *Journal Harvard Business*, 1-12. http://hbr.harvardbusiness.org/1995/11/why-satisfied-customers-defect/ar/pr

Kääriä, A. (2017). Technology Acceptance of Voice Assistants: Anthropomorphism As a Factor. *University of Jyväskylä*, 1-61. https://jyx.jyu.fi/bitstream/handle/123456789/54612/URN%3ANBN%3Afi%3Ajyu-201706202988.pdf?sequence=1%0Ahttps://jyx.jyu.fi/dspace/bitstream/handle/123456789/54612/URN%3ANBN%3Afi%3Ajyu-201706202988.pdf?sequence=1

Kaartemo, V., & Helkkula, A. (2018). A Systematic Review of Artificial Intelligence and Robots in Value Co-creation: Current Status and Future Research Avenues. *Journal of Creating Value*, *4*(2), 211-228. https://doi.org/10.1177/2394964318805625

Kar, A. K., & Dwivedi, Y. K. (2020). Theory building with big data-driven research – Moving away from the "What" towards the "Why". *International Journal of Information Management*, *54*(July), 102205. https://doi.org/10.1016/j.ijinfomgt.2020.102205

Karakaya, F., & Barnes, N. G. (2010). Impact of online reviews of customer care experience on brand or company selection. *Journal of Consumer Marketing*, *27*(5), 447-457. https://doi.org/10.1108/07363761011063349

Kauffmann, E., Peral, J., Gil, D., Ferrández, A., Sellers, R., & Mora, H. (2019). A framework for big data analytics in commercial social networks: A case study on sentiment analysis and fake review detection for marketing decision-making. *Industrial Marketing Management*, *August*, 1-15. https://doi.org/10.1016/j.indmarman.2019.08.003

Kawaf, F., & Istanbulluoglu, D. (2019). Online fashion shopping paradox: The role of customer reviews and facebook marketing. *Journal of Retailing and Consumer Services*, *48*(January), 144-153. https://doi.org/10.1016/j.jretconser.2019.02.017

Kelly, H. (2014). *Why Amazon's Echo is the computer of the future*. https://edition.cnn.com/2014/11/12/tech/innovation/amazon-echo-always-listening/

Kherwa, P., & Bansal, P. (2019). Topic Modeling: A Comprehensive Review EAI Endorsed Transactions on Scalable Information Systems. *EAI Endorsed Transactions on Scalable Information Systems*, *7*(24), 1-16.

Kiliç, S., & Çadirci, T. O. (2022). An evaluation of airport service experience: An identification of service improvement opportunities based on topic modeling and sentiment analysis. *Research in Transportation Business and Management*, *43*(xxxx), 100744. https://doi.org/10.1016/j.rtbm.2021.100744

Kim, J. Y., Yuan, X., Kim, S. Y., & Lee, Y. J. (2014). How perceived quality works in new technology adoption process: A cross-national comparison among China, Korea and Japan. *Journal of Global Information Management*, *22*(2), 23-47. https://doi.org/10.4018/jgim.2014040102

King, R. A., Racherla, P., & Bush, V. D. (2014). What we know and don't know about online word-of-mouth: A review and synthesis of the literature. *Journal of Interactive Marketing*, *28*(3), 167-183. https://doi.org/10.1016/j.intmar.2014.02.001

Knudsen, M. P. (2007). The relative importance of interfirm relationships and knowledge transfer for new product development success. *Journal of Product Innovation Management*, *24*(2), 117-138. https://doi.org/10.1111/j.1540-5885.2007.00238.x

Kohli, R., & Johnson, S. (2011). Digital Transformation in Latecomer. *MIS Quarterly Executive*, *10*(4), 141-156.

Krishen, A. S., & Petrescu, M. (2017). The world of analytics: Interdisciplinary, inclusive, insightful, and influential. *Journal of Marketing Analytics*, *5*(1), 1-4. https://doi.org/10.1057/s41270-017-0016-4

Kudina, O. (2021). "Alexa, who am I?": Voice Assistants and Hermeneutic Lemniscate as the Technologically Mediated Sense-Making. *Human Studies*, *44*(2), 233-253. https://doi.org/10.1007/s10746-021-09572-9

Kumar, R. P., Banerjee, A., Al-Salti, Z., & Ananda, S. (2023). Technology acceptance model and customer engagement: mediating role of customer satisfaction. *Journal of Financial Services Marketing*. https://doi.org/10.1057/s41264-023-00256-2

Kumar, S., Kar, A. K., & Ilavarasan, P. V. (2021). Applications of text mining in services management: A systematic literature review. *International Journal of Information Management Data Insights*, *1*(1), 100008. https://doi.org/10.1016/j.jjimei.2021.100008

Kundu, S., & Chakraborti, S. (2020). A comparative study of online consumer reviews of Apple iPhone across Amazon, Twitter and MouthShut platforms. *Electronic Commerce Research*, *0123456789*. https://doi.org/10.1007/s10660-020-09429-w

Kunz, W., Aksoy, L., Bart, Y., Heinonen, K., Kabadayi, S., Ordenes, F. V., Sigala, M., Diaz, D., & Theodoulidis, B. (2017). Customer engagement in a Big Data world. *Journal of Services Marketing*, *31*(2), 161-171. https://doi.org/10.1108/JSM-10-2016-0352

Kuo, Y., Wu, C., & Deng, W. (2009). The relationships among service quality, perceived value, customer satisfaction, and post-purchase intention in mobile value-added services. *Computers in Human Behavior*, *25*(4), 887-897.

Larochelle, H., & Lauly, S. (2012). A neural autoregressive topic model. *Advances in Neural Information Processing Systems*, *4*, 2708-2716.

Lazer, D., & Radford, J. (2017). Annual Review of Sociology Data ex Machina: Introduction to Big Data. *The Annual Review of Sociology is online at*, *43*, 19-39. https://doi.org/10.1146/annurev-soc-060116-

Le, Q., & Mikolov, T. (2014). Distributed representations of sentences and documents. *31st International Conference on Machine Learning, ICML 2014*, *4*, 2931-2939.

Lee, M. (2021). *Artificial intelligence for hospitality big data analytics: developing a prediction model of restaurant review helpfulness for customer decision-making*. *33*(6), 2117-2136. https://doi.org/10.1108/IJCHM-06-2020-0587

Lee, S., & Choeh, J. Y. (2020). Using the social influence of electronic word-of-mouth for predicting product sales: The moderating effect of review or reviewer helpfulness and product type. *Sustainability (Switzerland)*, *12*(19). https://doi.org/10.3390/SU12197952

Levy, S. E., Duan, W., & Boo, S. (2013). An Analysis of One-Star Online Reviews and Responses in the Washington, D.C., Lodging Market. *Cornell Hospitality Quarterly*, *54*(1), 49-63. https://doi.org/10.1177/1938965512464513

Li, H., Ye, Q., & Law, R. (2013). Determinants of Customer Satisfaction in the Hotel Industry: An Application of Online Review Analysis. *Asia Pacific Journal of Tourism Research*, *18*(7), 784-802. https://doi.org/10.1080/10941665.2012.708351

Li, L., Fu, L., & Zhang, W. (2022). Impact of Text Diversity on Review Helpfulness: A Topic Modeling Approach. *Interdisciplinary Journal of Information, Knowledge, and Management*, *17*, 087-100. https://doi.org/10.28945/4922

Liu, B., Gao, L., Bryan, B. A., & Marcos-martinez, B. L. R. (2020). Nonparametric machine learning for mapping forest cover and exploring influential factors. *Landscape Ecology*, *35*(7), 1683-1699. https://doi.org/10.1007/s10980-020-01046-0

Liu, S. (2020). *Sentiment Analysis of Yelp Reviews: A Comparison of Techniques and Models*. http://arxiv.org/abs/2004.13851

Lo Presti, L., & Maggiore, G. (2021). Vulnerability on collaborative networks and customer engagement: defending the online customer experience from fake reviews. *Quality and Quantity*, *0123456789*. https://doi.org/10.1007/s11135-021-01249-w

Lopatovska, I., Rink, K., Knight, I., Raines, K., Cosenza, K., Williams, H., Sorsche, P., Hirsch, D., Li, Q., & Martinez, A. (2019). Talk to me: Exploring user interactions with the Amazon Alexa. *Journal of Librarianship and Information Science*, *51*(4), 984-997. https://doi.org/10.1177/0961000618759414

Lopez, A., Guerra, E., Gonzalez, B., & Madero, S. (2020). Consumer sentiments toward brands: the interaction effect between brand personality and sentiments on electronic word of mouth. *Journal of Marketing Analytics*, *8*(4), 203-223. https://doi.org/10.1057/s41270-020-00085-5

Lu, W., & Stepchenkova, S. (2015). User-Generated Content as a Research Mode in Tourism and Hospitality Applications: Topics, Methods, and Software. *Journal of Hospitality Marketing and Management*, *24*(2), 119-154. https://doi.org/10.1080/19368623.2014.907758

Lucini, F. R., Tonetto, L. M., Fogliatto, F. S., & Anzanello, M. J. (2020). Text mining approach to explore dimensions of airline customer satisfaction using online customer reviews. *Journal of Air Transport Management*, *83*(December 2019), 101760. https://doi.org/10.1016/j.jairtraman.2019.101760

Luo, J. M., Vu, H. Q., Li, G., & Law, R. (2020). Topic modelling for theme park online reviews: analysis of Disneyland. *Journal of Travel and Tourism Marketing*, *37*(2), 272-285. https://doi.org/10.1080/10548408.2020.1740138

Ma, P., Zeng-Treitler, Q., & Nelson, S. J. (2021). Use of two topic modeling methods to investigate covid vaccine hesitancy. *14th International Conference on ICT, Society, and Human Beings, ICT 2021, 18th International Conference on Web Based Communities and Social Media, WBC 2021 and 13th International Conference on e-Health, EH 2021 - Held at the 15th Multi-Conference on Comp*, 221-226. https://doi.org/10.33965/eh2021_202106c030

Marandi, A., Tasavori, M., & Najmi, M. (2023). New insights into hotel customer's revisiting intentions, based on big data. *International Journal of Contemporary Hospitality Management*, *May*. https://doi.org/10.1108/IJCHM-06-2022-0719

Martínez-Garmendia, J. (2023). Machine learning for product choice prediction. *Journal of Marketing Analytics*, *0123456789*. https://doi.org/10.1057/s41270-023-00217-7

Mascarenhas, O. A., Kesavan, R., & Bernacchi, M. (2006). Lasting customer loyalty: A total customer experience approach. *Journal of Consumer Marketing*, *23*(7), 397-405. https://doi.org/10.1108/07363760610712939

matplotlib. (2003). Equal Contribution. https://matplotlib.org/stable/index.html

McFadden, D. L., & Train, K. E. (1996). Consumer's evaluation of new products learning from self and others. *Journal of Political Economy*, *104*(4), 683-703.

McGuirk, M. (2021). Performing social media analytics with Brandwatch for Classrooms: a platform review. *Journal of Marketing Analytics*, *9*(4), 363-378. https://doi.org/10.1057/s41270-021-00128-5

McInnes, L., Healy, J., & Astels, S. (2017). Accelerated Hierarchical Density Based Clustering. *IEEE International Conference on Data Mining Workshops, ICDMW*, *2017-Novem*, 33-42. https://doi.org/10.1109/ICDMW.2017.12

McInnes, L., Healy, J., Saul, N., & Großberger, L. (2018). UMAP: Uniform Manifold Approximation and Projection. *Journal of Open Source Software*, *3*(29), 861. https://doi.org/10.21105/joss.00861

McKinney, W. (2011). pandas: a Foundational Python Library for Data Analysis and Statistics. *Python for high performance and scientific computing*, *14*(9), 1-9. https://doi.org/10.1002/mmce.20381

McLean, G., & Osei-Frimpong, K. (2019). Hey Alexa … examine the variables influencing the use of artificial intelligent in-home voice assistants. *Computers in Human Behavior*, *99*(April), 28-37. https://doi.org/10.1016/j.chb.2019.05.009

McLean, G., Osei-Frimpong, K., & Barhorst, J. (2021). Alexa, do voice assistants influence consumer brand engagement? – Examining the role of AI powered voice assistants in influencing consumer brand engagement. *Journal of Business Research*, *124*(April 2019), 312-328. https://doi.org/10.1016/j.jbusres.2020.11.045

Menze, B. H., Kelm, B. M., Masuch, R., Himmelreich, U., Bachert, P., Petrich, W., & Hamprecht, F. A. (2009). A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data. *BMC Bioinformatics*, *10*, 1-16. https://doi.org/10.1186/1471-2105-10-213

Merdiaty, N., & Aldrin, N. (2022). Effect of Brand Experience on Customer Engagement Through Quality Services of Online Sellers to Students in Bekasi. *Frontiers in Psychology*, *12*(January), 1-8. https://doi.org/10.3389/fpsyg.2021.801439

Messner, W. (2022). Understanding the influence of culture on customer engagement and recommendation intentions. *Journal of Strategic Marketing*, *30*(8), 782-806. https://doi.org/10.1080/0965254X.2020.1849363

Mimno, D., Wallach, H. M., Talley, E., Leenders, M., & McCallum, A. (2011). Optimizing semantic coherence in topic models. *EMNLP 2011 - Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, *2*, 262-272.

Mingione, M., Cristofaro, M., & Mondi, D. (2020). "If I give you my emotion, what do I get?" Conceptualizing and measuring the co-created emotional value of the brand. *Journal of Business Research*, *109*(November 2019), 310-320. https://doi.org/10.1016/j.jbusres.2019.11.071

Montogomery, D. C., Peck, E. A., & Vining, G. G. (2012). Introduction to linear regression analysis. Içinde *John Wiley & Sons* (C. 821). https://revistas.ufrj.br/index.php/rce/article/download/1659/1508%0Ahttp://hipatiapress.com/hpjournals/index.php/qre/article/view/1348%5Cnhttp://www.tandfonline.com/doi/abs/10.1080/09500799708666915%5Cnhttps://mckinseyonsociety.com/downloads/reports/Educa

Moore, S. G. (2015). Attitude predictability and helpfulness in online reviews: The role of explained actions and reactions. *Journal of Consumer Research*, *42*(1), 30-44. https://doi.org/10.1093/jcr/ucv003

Mosteller, J. R., & Mathwick, C. (2016). Online Reviewer Engagement: A Typology Based on Reviewer Motivation. *Journal of Service Research*, *20*(2). https://doi.org/https://doi.org/10.1177/1094670516682088

Mustak, M., Salminen, J., Plé, L., & Wirtz, J. (2021). Artificial intelligence in marketing: Topic modeling, scientometric analysis, and research agenda. *Journal of Business Research*, *124*(January 2020), 389-404. https://doi.org/10.1016/j.jbusres.2020.10.044

Nawaz, Z., Zhao, C., Nawaz, F., Safeer, A. A., & Irshad, W. (2021). Role of artificial neural networks techniques in development of market intelligence: a study of sentiment analysis of ewom of a women's clothing company. *Journal of Theoretical and Applied Electronic Commerce Research*, *16*(5), 1862-1876. https://doi.org/10.3390/jtaer16050104

Niksirat, K. S., Sarcar, S., Bardzell, J., Oulasvirta, A., Sun, H., Silpasuwanchai, C., Law, E. L. C., Light, A., Clemmensen, T., & Ren, X. (2018). Approaching engagement towards human-engaged computing. *Conference on Human Factors in Computing Systems - Proceedings*, *2018-April*, 1-4. https://doi.org/10.1145/3170427.3185364

Nilashi, M., Abumalloh, R. A., Samad, S., Alrizq, M., Alyami, S., & Alghamdi, A. (2023). Analysis of customers' satisfaction with baby products: The moderating role of brand image. *Journal of Retailing and Consumer Services*, *73*(February), 103334. https://doi.org/10.1016/j.jretconser.2023.103334

Noraini, S., Agnes Kanyan, Mohamad Fitri Nazrin, Sa'ait, N., Kanyan, A., Nazrin, M. F., S'aita, N., Kanyan, A., & Nazrin, M. F. (2016). The Effect of E-WOM on Customer Purchase Intention. *International Academic Research Journal of Social Science*, *2*(1), 73-80.

O'Brien, H. L., & Toms, E. G. (2008). What is User Engagement? A Conceptual Framework for Defining User Engagement with Technology. *Journal of the American Society for Information Science and Technology*, *59*(6), 938-955. https://doi.org/10.1002/asi

Ogawa, S. (1998). Does sticky information affect the locus of innovation? Evidence from the Japanese convenience-store industry. *Research Policy*, *26*(7-8), 777-790. https://doi.org/10.1016/S0048-7333(97)00047-4

Oliver, R. L. (1980). A Cognitive Model of the Antecedents and Consequences of Satisfaction Decisions. *Journal of Marketing Research*, *17*(4), 460-469.

Oliver, R. L. (2010). *Satisfaction: A Behavioral Perspective on the Consumer*. Routledge. https://doi.org/https://doi.org/10.4324/9781315700892

Ordenes, F. V., Theodoulidis, B., Burton, J., Gruber, T., & Zaki, M. (2014). Analyzing Customer Experience Feedback Using Text Mining: A Linguistics-Based Approach. *Journal of Service Research*, *17*(3), 278-295. https://doi.org/10.1177/1094670514524625

Ozansoy Çadırcı, T., Sağkaya Güngör, A., & Kılıç, S. (2022). The Voice of the Consumer on sVoD Systems During Covid-19: A Service Opportunity Mining

Approach. *International Journal of Marketing, Communication and New Media*, 5-29. https://doi.org/10.54663/2182-9306.2022.sn11.5-29

Ozansoy, T. (2009). *Moda Ürünlerinin Pazarlanmasında Sosyo-Psikolojik Faktörlerin Tüketici Tercihleri İle İlişkisi Üzerine Bir Pilot Araştırma*. İstanbul Üniversitesi.

Palmer, D. S., O'Boyle, N. M., Glen, R. C., & Mitchell, J. B. O. (2007). Random forest models to predict aqueous solubility. *Journal of Chemical Information and Modeling*, *47*(1), 150-158. https://doi.org/10.1021/ci060164k

Pang, B., Lee, L., & Vaithyanathan, S. (2002). Thumbs up? Sentiment Classification using Machine Learning Techniques. *Proceedings of the 2002 Conference on Empirical Methods in Natural Language Processing, EMNLP 2002*, *July*, 79-86.

Pantano, E., Giglio, S., & Dennis, C. (2019). Making sense of consumers' tweets: Sentiment outcomes for fast fashion retailers through Big Data analytics. *International Journal of Retail and Distribution Management*, *47*(9), 915-927. https://doi.org/10.1108/IJRDM-07-2018-0127

Pantelidis, I. S. (2010). Electronic meal experience: A content analysis of online restaurant comments. *Cornell Hospitality Quarterly*, *51*(4), 483-491. https://doi.org/10.1177/1938965510378574

Parameswaran, S., Kishore, R., & Li, P. (2015). Within-study measurement invariance of the UTAUT instrument: An assessment with user technology engagement variables. *Information and Management*, *52*(3), 317-336. https://doi.org/10.1016/j.im.2014.12.007

Parasuraman, A., Zeithaml, V. A., & Berry, L. L. (1985). A Conceptual Model of Service Quality and Its Implications for Future Research. *Journal of Marketing*, *49*(4), 41-50.

Parasuraman, A., Zeithaml, V. A., & Malhotra, A. (2005). E-S-QUAL a multiple-item scale for assessing electronic service quality. *Journal of Service Research*, *7*(3), 213-233. https://doi.org/10.1177/1094670504271156

Park, C., & Lee, T. M. (2009). Antecedents of Online Reviews' Usage and Purchase Influence: An Empirical Comparison of U.S. and Korean Consumers. *Journal of Interactive Marketing*, *23*(4), 332-340. https://doi.org/10.1016/j.intmar.2009.07.001

Park, D. H., Lee, J., & Han, I. (2007). The effect of on-line consumer reviews on consumer purchasing intention: The moderating role of involvement. *International Journal of Electronic Commerce*, *11*(4), 125-148. https://doi.org/10.2753/JEC1086-4415110405

Park, H., & Yoon, J. (2015). A chance discovery-based approach for new product–service system (PSS) concepts. *Service Business*, *9*(1), 115-135. https://doi.org/10.1007/s11628-013-0222-x

Paschen, J., Paschen, U., Pala, E., & Kietzmann, J. (2021). Artificial intelligence (AI) and value co-creation in B2B sales: Activities, actors and resources. *Australasian Marketing Journal*, *29*(3), 243-251. https://doi.org/10.1016/j.ausmj.2020.06.004

Passos, A., Wallach, H. M., & Mccallum, A. (2011). Correlations and Anticorrelations in LDA Inference. *Proceedings of the Neural Information Processing Systems*

Workshop on "Challenges in Learning Hierarchical Models: Transfer Learning and Optimization", 1-5.

Pedrogosa, F., Varoquaux, G., Gramfort, A., & Michel, V. (2011). Scikit-learn: Machine Learning in Python. *JMLR*, *12*(85), 2825-2830. https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html

Petrescu, M., & Krishen, A. S. (2023). A decade of marketing analytics and more to come: JMA insights. *Journal of Marketing Analytics*, *11*(2), 117-129. https://doi.org/10.1057/s41270-023-00226-6

Pillai, R., Sivathanu, B., & Dwivedi, Y. K. (2020). Shopping intention at AI-powered automated retail stores (AIPARS). *Journal of Retailing and Consumer Services*, *57*(March 2019), 102207. https://doi.org/10.1016/j.jretconser.2020.102207

Piris, Y., & Gay, A.-C. (2021). Customer satisfaction and natural language processing. *Journal of Business Research*, *124*(January 2020), 264-271. https://doi.org/10.1016/j.jbusres.2020.11.065

Pitardi, V., & Marriott, H. R. (2021). Alexa, she's not human but… Unveiling the drivers of consumers' trust in voice-based artificial intelligence. *Psychology and Marketing*, *38*(4), 626-642. https://doi.org/10.1002/mar.21457

Plisson, J., Lavrac, N., & Mladenić, Dr. D. (2004). A rule based approach to word lemmatization. *Proceedings of the 7th International Multiconference Information Society (IS'04)*, 83-86. http://eprints.pascal-network.org/archive/00000715/

Prahalad, C. K., & Ramaswamy, V. (2004). Co-creation experiences: The next practice in value creation. *Journal of Interactive Marketing*, *18*(3), 5-14. https://doi.org/10.1002/dir.20015

PYTeam. (2020). *text2emotion 0.0.5*. https://pypi.org/project/text2emotion/

Python 3.8.8. (2021). https://www.python.org/downloads/release/python-388/

Qaiser, S., & Ali, R. (2018). Text Mining: Use of TF-IDF to Examine the Relevance of Words to Documents. *International Journal of Computer Applications*, *181*(1), 25-29. https://doi.org/10.5120/ijca2018917395

Rahman, M. S., Bag, S., Gupta, S., & Sivarajah, U. (2023). Technology readiness of B2B firms and AI-based customer relationship management capability for enhancing social sustainability performance. *Journal of Business Research*, *156*(December 2022), 113525. https://doi.org/10.1016/j.jbusres.2022.113525

Ramaswamy, V. (2009). Co-creation of value — towards an expanded paradigm of value creation. *Marketing Review St. Gallen*, *26*(6), 11-17. https://doi.org/10.1007/s11621-009-0085-7

Ramaswamy, V., & Ozcan, K. (2018). What is co-creation? An interactional creation framework and its implications for value creation. *Journal of Business Research*, *84*(November 2017), 196-205. https://doi.org/10.1016/j.jbusres.2017.11.027

Rathore, A. K., & Ilavarasan, P. V. (2020). Pre- and post-launch emotions in new product development: Insights from twitter analytics of three products. *International Journal of Information Management*, *50*(October 2018), 111-127. https://doi.org/10.1016/j.ijinfomgt.2019.05.015

Rehurek, R. (2018). *Gensim 3.6.0*. https://pypi.org/project/gensim/3.6.0/

Reimers, N. (2022). *Pretrained Models*. https://www.sbert.net/docs/pretrained_models.html

Reimers, N., & Gurevych, I. (2019). *Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks*. http://arxiv.org/abs/1908.10084

Reisenbichler, M., & Reutterer, T. (2019). Topic modeling in marketing: recent advances and research opportunities. *Journal of Business Economics*, *89*(3), 327-356. https://doi.org/10.1007/s11573-018-0915-7

Ren, Y., Wang, R., & Ji, D. (2016). A topic-enhanced word embedding for Twitter sentiment classification. *Information Sciences*, *369*, 188-198. https://doi.org/10.1016/j.ins.2016.06.040

Richardson, L. (2019). Beautiful Soup Documentation Release 4.4.0. *Media.Readthedocs.Org*, 1-72.

Rigatti, S. J. (2017). Random Forest. *Journal of Insurance Medicine*, *47*, 31-39. https://doi.org/10.1007/978-3-030-85040-1_265

Rizvi, R. F., Wang, Y., Nguyen, T., Vasilakes, J., Bian, J., He, Z., & Zhang, R. (2019). Analyzing social media data to understand consumer information needs on dietary supplements. *Studies in Health Technology and Informatics*, *264*(August), 323-327. https://doi.org/10.3233/SHTI190236

Rogers, E. M. (1983). *Diffusion of Innovations* (Third Edit). The Three Press-A divison of publishing co., inc.

Roozen, I., & Raedts, M. (2020). The power of negative publicity on the fast fashion industry. *Journal of Global Fashion Marketing*, *11*(4), 380-396. https://doi.org/10.1080/20932685.2020.1798802

Roshani, Sajjad, H., Saha, T. K., Rahaman, M. H., Masroor, M., Sharma, Y., & Pal, S. (2023). Analyzing trend and forecast of rainfall and temperature in Valmiki Tiger Reserve, India, using non-parametric test and random forest machine learning algorithm. *Acta Geophysica*, *71*(1), 531-552. https://doi.org/10.1007/s11600-022-00978-2

Ruan, Y., & Mezei, J. (2022). When do AI chatbots lead to higher customer satisfaction than human frontline employees in online shopping assistance? Considering product attribute type. *Journal of Retailing and Consumer Services*, *68*(March). https://doi.org/10.1016/j.jretconser.2022.103059

Saks, A. M. (2006). Antecedents and consequences of employee engagement. *Journal of Managerial Psychology*, *21*(7), 600-619. https://doi.org/10.1108/02683940610690169

Samudro, A., Sumarwan, U., Simanjuntak, M., & Yusuf, E. Z. (2020). Assessing the effects of perceived quality and perceived value on customer satisfaction. *Management Science Letters*, *10*(5), 1077-1084. https://doi.org/10.5267/j.msl.2019.11.001

Sánchez-Franco, M. J., & Rey-Moreno, M. (2021). Do travelers' reviews depend on the destination? An analysis in coastal and urban peer-to-peer lodgings. Içinde *Psychology and Marketing* (C. 39, Sayı 2, ss. 441-459). https://doi.org/10.1002/mar.21608

Sankar, H., Subramaniyaswamy, V., Vijayakumar, V., Arun Kumar, S., Logesh, R., & Umamakeswari, A. (2020). Intelligent sentiment analysis approach using edge computing-based deep learning technique. *Software - Practice and Experience*, *50*(5), 645-657. https://doi.org/10.1002/spe.2687

Sawhney, M., Verona, G., & Prandelli, E. (2005). Collaborating to create: The internet as a platform for customer engagement in product innovation. *Journal of Interactive Marketing*, *19*(4), 4-17. https://doi.org/10.1002/dir.20046

Schuckert, M., Liu, X., & Law, R. (2015). Hospitality and Tourism Online Reviews: Recent Trends and Future Directions. *Journal of Travel and Tourism Marketing*, *32*(5), 608-621. https://doi.org/10.1080/10548408.2014.933154

Schwarz, J. S., Chapman, C., & Feit, E. M. D. (2020). Python for Marketing Research and Analytics. Içinde *Python for Marketing Research and Analytics*. https://doi.org/10.1007/978-3-030-49720-0

Sena, J. (2023). *Intelligent Virtual Assistant Market Size, Share, Growth Report 2030*. https://www.linkedin.com/pulse/intelligent-virtual-assistant-market-size-share-growth-jon-sena-co3wf/

Seo, J., Lee, S., Liu, L., & Choi, W. (2022). TA-SBERT: Token Attention Sentence-BERT for Improving Sentence Representation. *IEEE Access*, *10*, 39119-39128. https://doi.org/10.1109/ACCESS.2022.3164769

Serra Cantallops, A., & Salvi, F. (2014). New consumer behavior: A review of research on eWOM and hotels. *International Journal of Hospitality Management*, *36*, 41-51. https://doi.org/10.1016/j.ijhm.2013.08.007

Shah, T. R., Kautish, P., & Walia, S. (2024). Linking technology readiness and customer engagement: an AI-enabled voice assistants investigation. *Foresight*, *26*(1), 136-154. https://doi.org/10.1108/FS-10-2021-0195

Shankar, V. (2018). How Artificial Intelligence (AI) is Reshaping Retailing. *Journal of Retailing*, *94*(4), vi-xi. https://doi.org/10.1016/s0022-4359(18)30076-9

Shen, X.-L., Zhang, K. Z. K., & Zaho, S. J. (2015). Herd Behavior in Consumers' Adoption of Online Reviews. *JOURNAL OF THE ASSOCIATION FOR INFORMATION SCIENCE AND TECHNOLOGY*, *67*(December), 2754-2765. https://doi.org/10.1002/asi

Sia, S., Dalmia, A., & Mielke, S. J. (2020). Tired of topic models? Clusters of pretrained word embeddings make for fast and good topics too! *EMNLP 2020 - 2020 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 1728-1736. https://doi.org/10.18653/v1/2020.emnlp-main.135

Sievert, C., & Shirley, K. (2015). *LDAvis: A method for visualizing and interpreting topics*. 63-70. https://doi.org/10.3115/v1/w14-3110

Singh, J. P., Irani, S., Rana, N. P., Dwivedi, Y. K., Saumya, S., & Kumar Roy, P. (2017). Predicting the "helpfulness" of online consumer reviews. *Journal of Business Research*, *70*, 346-355. https://doi.org/10.1016/j.jbusres.2016.08.008

Smith, A. N., Fischer, E., & Yongjian, C. (2012). How Does Brand-related User-generated Content Differ across YouTube, Facebook, and Twitter? *Journal of Interactive Marketing*, *26*(2), 102-113. https://doi.org/10.1016/j.intmar.2012.01.002

Spacy. (2015). Equal Contribution. https://spacy.io/

Steenkamp, J.-B.-E.-M. (1989). *Product quality: An investigation into the concept and how it is perceived by consumers*. Van Gorcum Ltd.

Sun, Y. et al. (2016). STANDARDIZATION OR ADAPTATION DURING THE WEB – MOBILE SERVICE TRANSITION: UNDERSTANDING THE MODERATING ROLE OF GENDER Yongqiang Sun School of Information Management Wuhan University Economics and Management School Wuhan University 299 Bayi Road, Wuhan. *Journal of Electronic Commerce Research*, 266-280.

Susanti, V., Sumarwan, U., Simanjuntak, M., & Yusuf, E. Z. (2019). How to Manage Customer Satisfaction through Brand Association and Perceived Value Strategy. *GATR Journal of Management and Marketing Review*, *4*(3), 184-193. https://doi.org/10.35609/jmmr.2019.4.3(3)

Sweeney, J. C., & Soutar, G. N. (2001). Consumer perceived value: The development of a multiple item scale. *Journal of Retailing*, *77*, 203-220.

Taboada, M., Brooke, J., Tofiloski, M., Voll, K., & Stede, M. (2011). Lexicon-basedmethods for sentiment analysis. *Computational Linguistics*, *37*(2), 267-307. https://doi.org/10.1162/COLI_a_00049

Taecharungroj, V., & Mathayomchan, B. (2019). Analysing TripAdvisor reviews of tourist attractions in Phuket, Thailand. *Tourism Management*, *75*(June), 550-568. https://doi.org/10.1016/j.tourman.2019.06.020

Tahmasebi, N. (2018). A study on Word2Vec on a historical swedish newspaper corpus. *CEUR Workshop Proceedings*, *2084*, 25-37.

Tarhini, A., Arachchilage, N. A. G., Masa'deh, R., & Abbasi, M. S. (2015). A Critical Review of Theories and Models of Technology Adoption and Acceptance in Information System Research. *International Journal of Technology Diffusion*, *6*(4), 58-77. https://doi.org/10.4018/ijtd.2015100104

Thakur, N., Reimers, N., Daxenberger, J., & Gurevych, I. (2021). Augmented SBERT: Data Augmentation Method for Improving Bi-Encoders for Pairwise Sentence Scoring Tasks. *NAACL-HLT 2021 - 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Proceedings of the Conference*, 296-310. https://doi.org/10.18653/v1/2021.naacl-main.28

Thakur, R. (2018). Customer engagement and online reviews. *Journal of Retailing and Consumer Services*, *41*(February 2017), 48-59. https://doi.org/10.1016/j.jretconser.2017.11.002

Thieme, R. J., Song, M., & Calantone, R. J. (2016). *Artificial Neural Network Decision Support Systems for New Product Development Project Selection*. *37*(4), 499-507.

Thompson, L., & Mimno, D. (2020). *Topic Modeling with Contextualized Word Representation Clusters*. http://arxiv.org/abs/2010.12626

Tian, G., Lu, L., & McIntosh, C. (2021). What factors affect consumers' dining sentiments and their ratings: Evidence from restaurant online review data. *Food Quality and Preference*, *88*(August 2020), 104060. https://doi.org/10.1016/j.foodqual.2020.104060

Top2Vec Release 1.0.27. (2022).

Turney, P. D. (2002). Thumbs Up or Thumbs Down? Semantic Orientation Applied to Unsupervised Classification of Reviews. *In Proceedings of the 40th annual meeting on association for computational linguistics*, 8.

Ulwick, A. (2005). *WHAT CUSTOMERS WANT: Using Outcome-Driven Innovation to Create Breakthrough Products and Services*. The McGraw-Hill Companies.

Ulwick, A. W. (2002). Turn customer input into innovation. *Harvard business review*, *80(1)*, 91-98. https://hbr.org/2002/01/turn-customer-input-into-innovation

V. Wangenheim, F., & Bayón, T. (2007). The chain from customer satisfaction via word-of-mouth referrals to new customer acquisition. *Journal of the Academy of Marketing Science*, *35*(2), 233-249. https://doi.org/10.1007/s11747-007-0037-1

Van Auken, S. (2015). From consumer panels to big data: An overview on marketing data development. *Journal of Marketing Analytics*, *3*(1), 38-45. https://doi.org/10.1057/jma.2015.2

van Kleef, E., van Trijp, H. C. M., & Luning, P. (2005). Consumer research in the early stages of new product development: A critical review of methods and techniques. *Food Quality and Preference*, *16*(3), 181-201. https://doi.org/10.1016/j.foodqual.2004.05.012

Vargo, S. L., & Lusch, R. F. (2014). Evolving to a new dominant logic for marketing. *The Service-Dominant Logic of Marketing: Dialog, Debate, and Directions*, *January 2004*, 3-28.

Vasudeva Raju, S., Kumar Bolla, B., Nayak, D. K., & Jyothsna, K. H. (2022). Topic Modelling on Consumer Financial Protection Bureau Data: An Approach Using BERT Based Embeddings. *2022 IEEE 7th International conference for Convergence in Technology, I2CT 2022*. https://doi.org/10.1109/I2CT54291.2022.9824873

Vayansky, I., & Kumar, S. A. P. (2020). A review of topic modeling methods. *Information Systems*, *94*, 101582. https://doi.org/10.1016/j.is.2020.101582

Venkatesh, V. (2000). Determinants of perceived ease of use: integrating perceived behavioral control, computer anxiety and enjoyment into the technology acceptance model. *Information Systems Research*, *11*(1), 3-11. vvenkate@rhsmith.umd.edu

Venkatesh, V., & Bala, H. (2008). Technology acceptance model 3 and a research agenda on interventions. *Decision Sciences*, *39*(2), 273-315. https://doi.org/10.1111/j.1540-5915.2008.00192.x

Venkatesh, V., & Davis, F. D. (2000). Theoretical extension of the Technology Acceptance Model: Four longitudinal field studies. *Management Science*, *46*(2), 186-204. https://doi.org/10.1287/mnsc.46.2.186.11926

Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, *27*(3), 425-478.

Ventre, I., & Kolbe, D. (2020). The Impact of Perceived Usefulness of Online Reviews, Trust and Perceived Risk on Online Purchase Intention in Emerging

Markets: A Mexican Perspective. *Journal of International Consumer Marketing*, *32*(4), 287-299. https://doi.org/10.1080/08961530.2020.1712293

Vera, J. (2015). Perceived brand quality as a way to superior customer perceived value crossing by moderating effects. *Journal of Product and Brand Management*, *24*(2), 147-156. https://doi.org/10.1108/JPBM-04-2014-0551

Wang, W., Wang, H., & Song, Y. (2017). Ranking product aspects through sentiment analysis of online reviews. *Journal of Experimental and Theoretical Artificial Intelligence*, *29*(2), 227-246. https://doi.org/10.1080/0952813X.2015.1132270

Wang, Y., Lu, X., & Tan, Y. (2018). Impact of product attributes on customer satisfaction: An analysis of online reviews for washing machines. *Electronic Commerce Research and Applications*, *29*, 1-11. https://doi.org/10.1016/j.elerap.2018.03.003

Wedel, M., & Kannan, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, *80*(6), 97-121. https://doi.org/10.1509/jm.15.0413

Wei, W., Miao, L., & Huang, Z. (2013). Customer engagement behaviors and hotel responses. *International Journal of Hospitality Management*, *33*(1), 316-330. https://doi.org/10.1016/j.ijhm.2012.10.002

Westbrook, R. A. (1987). Product/Consumption-Based Affective Responses and Postpurchase Processes. *Journal of Marketing Research*, *24*(3), 258-270. https://doi.org/10.1177/002224378702400302

Wijayati, D. T., Rahman, Z., Fahrullah, A., Rahman, M. F. W., Arifah, I. D. C., & Kautsar, A. (2022). A study of artificial intelligence on employee performance and work engagement: the moderating role of change leadership. *International Journal of Manpower*, *43*(2), 486-512. https://doi.org/10.1108/IJM-07-2021-0423

Wikipedia. (2024). *Amazon Echo Show*. https://en.wikipedia.org/wiki/Amazon_Echo_Show

Williams, M. D., Rana, N. P., Dwivedi, Y. K., & Lal, B. (2011). Is UTAUT really used or just cited for the sake of it? A systematic review of citations of UTAUT's originating article. *19th European Conference on Information Systems, ECIS 2011*, *May 2014*.

Wirtz, J., Patterson, P. G., Kunz, W. H., Gruber, T., Lu, V. N., Paluch, S., & Martins, A. (2018). Brave new world: service robots in the frontline. *Journal of Service Management*, *29*(5), 907-931. https://doi.org/10.1108/JOSM-04-2018-0119

Wright, S. (1921). Correlation and causation. *Journal of Agricultural Research*, *20*, 557-585.

Wu, J. J., & Chang, S. T. (2020). Exploring customer sentiment regarding online retail services: A topic-based approach. *Journal of Retailing and Consumer Services*, *55*(January), 102145. https://doi.org/10.1016/j.jretconser.2020.102145

Xiang, Z., Du, Q., Ma, Y., & Fan, W. (2017). Information and Communication Technologies in Tourism 2017. *Information and Communication Technologies in Tourism 2017*. https://doi.org/10.1007/978-3-319-51168-9

Xiao, L., & Li, Y. (2019). Examining the effect of positive online reviews on consumers' decision making: The valence framework. *Journal of Global*

Information Management, *27*(3), 159-181. https://doi.org/10.4018/JGIM.2019070109

Xie, C., & Sun, Z. (2021). Influence of perceived quality on customer satisfaction in different stages of services. *Nankai Business Review International*, *12*(2), 258-280.

Xu, Z., Vail, C., Kohli, A. S., & Tajdini, S. (2021). Understanding changes in a brand's core positioning and customer engagement: a sentiment analysis of a brand-owned Facebook site. *Journal of Marketing Analytics*, *9*(1), 3-16. https://doi.org/10.1057/s41270-020-00099-z

Yang, H., Yu, J., Zo, H., & Choi, M. (2015). User acceptance of wearable devices : An extended perspective of perceived value. *Telematics and Informatics*, *August*. https://doi.org/10.1016/j.tele.2015.08.007

Yang, M., Ren, Y., & Adomavicius, G. (2019). Understanding user-generated content and customer engagement on Facebook business pages. *Information Systems Research*, *30*(3), 839-855. https://doi.org/10.1287/isre.2019.0834

Yang, Z., & Fang, X. (2004). Online service quality dimensions and their relationships with satisfaction: A content analysis of customer reviews of securities brokerage services. *International Journal of Service Industry Management*, *15*(3), 302-326. https://doi.org/10.1108/09564230410540953

Zeithaml, V. A. (1988). Consumer Perceptions of Price, Quality, and Value: A Means-End Model Synthesis of Evidence. *Journal of Marketing*, *52*(3), 2-22.

Zhang, N., Liu, R., Zhang, X. Y., & Pang, Z. L. (2021). The impact of consumer perceived value on repeat purchase intention based on online reviews: by the method of text mining. *Data Science and Management*, *3*(June), 22-32. https://doi.org/10.1016/j.dsm.2021.09.001

Zhang, Z., Li, H., Yang, Y., & Xu, Y. (2021). Not all words are beneficial: The impact of management response contents on customer engagement behavior. *International Journal of Hospitality Management*, *93*(December 2020), 102805. https://doi.org/10.1016/j.ijhm.2020.102805

Zhao, H., Phung, D., Huynh, V., Jin, Y., Du, L., & Buntine, W. (2021). Topic Modelling Meets Deep Neural Networks: A Survey. *IJCAI International Joint Conference on Artificial Intelligence*, 4713-4720. https://doi.org/10.24963/ijcai.2021/638

Zhao, Y., Wang, L., Tang, H., & Zhang, Y. (2020). Electronic word-of-mouth and consumer purchase intentions in social e-commerce. *Electronic Commerce Research and Applications*, *41*(February), 100980. https://doi.org/10.1016/j.elerap.2020.100980

Zhou, L., Pan, S., Wang, J., & Vasilakos, A. V. (2017). Machine learning on big data: Opportunities and challenges. *Neurocomputing*, *237*(61272509), 350-361. https://doi.org/10.1016/j.neucom.2017.01.026