

BERTopic Konu Modelleme Tekniği Kullanılarak Müşteri Şikayetlerinin Sınıflandırılması*

Classification of Customer Complaints Using BERTopic Topic Modelling Technique

Kutan KORUYAN¹

Öz

Müşteri şikâyetlerinin analizi işletmeler açısından geçmişte yaptıkları hataları düzeltme, marka değerini koruma ve yeni müşteriler edinmeleri açısından önemli bir kavramdır. Özellikle şikâyet verisinin büyüklüğü arttıkça verinin sınıflandırılması ve tahminlenmesi için makine öğrenmesi tekniklerinden yararlanmak zaman ve maliyet açısından karar vericilere avantaj sağlamaktadır. Bu yüzden çalışmada, müşteri şikayetlerinin ürün bazında ve genel anlamda hangi farklı konularda dağılım gösterdiğinin bulunması amacıyla güncel bir yaklaşım olan BERTopic konu modelleme tekniğinden yararlanılmıştır. Buna yönelik olarak da veri seti olarak 2020 yılına ait bir tüketici elektroniği perakende şirketine yapılan şikayetler kullanılmış ve sınıflandırılmıştır. Bunun yanında, şikayetlerin aylık olarak zaman içindeki değişimi de dinamik konu modelleme kullanılarak incelenmiştir. Sonuçlara göre en fazla şikâyet kargolama, televizyon, cep telefonu, dizüstü bilgisayar, kulaklık, tablet, mağaza çalışanları, sipariş iptali konularında yoğunlaşmıştır.

Anahtar Kelimeler: Müşteri Şikayetleri, Konu Modelleme, BERTopic, Dinamik Konu Modelleme

Abstract

The analysis of customer complaints enables companies to amend mistakes, protect brand value and attract new customers. Utilizing machine learning techniques for data classification and prediction provide decision makers with time and cost benefits, particularly with increased complaint data size. Therefore, this study employed BERTopic topic modelling technique, a contemporary approach, to examine customer complaint distribution with respect to distinct topics, by product and in general. In the study, the complaints submitted to a consumer electronics retailer in 2020 were adopted and classified. The monthly variation of the complaints was also investigated with dynamic topic modelling. The results showed that the complaints concentrated more heavily on shipping, television, mobile phone, laptop, earphones, tablets, store clerks and order cancellation topics.

Keywords: Customer Complaints, Topic Modelling, BERTopic, Dynamic Topic Modelling

1. GİRİŞ

Müşteri şikayetleri; müşteri beklentilerinin karşılanmaması sonucu ortaya çıkan ve ürün veya hizmet satışına ilişkin önemli bilgilerin doğrudan işletmeye iletilmesine olanak tanıyan müşteri davranışdır (Alabay, 2012). Şikayetler genellikle, ürün değiştirme, onarım, iade hakkında ve ürünle ilgili herhangi bir sorunu açıklama şeklinde olmakta veya çalışan nezaketsizliği, uygunsuz fiziksel ortam, satışta gecikmeler ve satılan ürünün tedarik edilmemesi sonucu ortaya çıkmaktadır (Aşkun, 2008; Faed, 2010).

Müşteriler ürün veya hizmetten memnun olmaması durumunda işletme ile bağlarını keser ve müşterilerin diğer insanlara olumsuz görüşler ifade etme olasılığı vardır (Richins, 1983). Tabii ki bu işletmeler açısından istenilen bir durum değildir. Bazı şirketler şikayetleri düzeltilmesi gereken sorunlar olarak görürken, bazıları ise şikayetler üzerine savunma mekanizmalarına başvururlar (Homburg ve Fürst, 2007). Esasen, şikayetler işletmeler için problem değil bir fırsat olarak değerlendirilmelidir. Çünkü müşterilerden gelen şikayetler doğrultusunda ürün veya hizmet politikalarının değiştirilmesi mümkün olup, gözden kaçmış hatalar giderilebilmektedir (Demirel, 2017). Ayrıca,

* In this article, the principles of scientific research and publication ethics were followed. / Bu makalede bilimsel araştırma ve yayın etiği ilkelerine uyulmuştur.

¹ Kutan KORUYAN

ORCID ID: 0000-0002-3115-5676

Dr. Öğr. Üyesi, Dokuz Eylül Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, İzmir, Türkiye. kutan.koruyan@deu.edu.tr

Assist. Prof. Dr., Dokuz Eylül University, Faculty of Economics and Administrative Sciences, Department of Management Information Systems, İzmir, Turkey.

kutan.koruyan@deu.edu.tr

Geliş Tarihi/Received : 27.08.2022

Kabul Tarihi/Accepted : 03.10.2022

Çevrimiçi Yayın/Published : 04.10.2022

Makale Atf Önerisi /Citation (APA):

Koruyan, K. (2022). BERTopic Konu Modelleme Tekniği Kullanılarak Müşteri Şikayetlerinin Sınıflandırılması. *İzmir Sosyal Bilimler Dergisi*, 4(2), 66-79. DOI:10.47899/ijss.1167719

şirketler için rekabet avantajı, sunulan hizmetten öte, müşteri şikâyet ve çözümlerine gösterilen özen ile artmaktadır (Ghazzawi ve Alharbi, 2019).

Müşteri ilişkileri yönetiminin bir bileşeni olan müşteri şikâyet yönetimi yeni müşterileri çekmek kadar düzenli müşterileri elde tutmak için kullanılmakta, müşteri şikâyetlerinin alınması, araştırılması, çözümlenmesi ve önlenmesini sağlamaktadır (Galitsky, 2020; Goodman, 1992; Johnston, 2001). Bununla birlikte, işletmeler ürün veya hizmetlerini iyileştirme ve ürün performansını arttırma çabalarını göz önünde bulundurarak, müşteri şikâyetlerini teşvik etmek için bazı kanallar da geliştirirler (Yang vd., 2018). Şikâyetler klasik anlamda mektup, e-posta, çağrı merkezi yoluyla veya işletmeyi ziyaret ederek sözlü olarak alınmakta iken günümüzde, çevrimiçi bloglar, mesaj panoları, tüketici forumları, tüketici yorum/şikâyet siteleri ve sosyal ağlar birer potansiyel şikâyet kanalı olarak kullanılmaktadır (Dwivedi vd., 2007; Garding ve Bruns, 2015; Halstead ve Dröge, 1991).

Özellikle internette yer alan platformlarda ürün veya hizmet hakkındaki olumlu/olumsuz yorum ve değerlendirmeler aslında müşterileri etkilemede önemli kaynaklardan biri olan ağızdan ağıza iletişimin çevrimiçi halidir. Ağızdan ağıza iletişimin geleneksel haline göre yorum ve şikâyetler, internet yoluyla daha hızlı yayılmakta ve geniş bir etki alanına sahiptir (Yakut Ayman, 2011). Müşteri ve firma açısından iki taraflı olarak bakıldığında ise çevrimiçi şikâyet platformları şikâyetlerin gerçek zamanlı olarak takibi açısından da önemlidir. Çünkü, hizmetler gerçek zamanlı tartışılabilen, firmalar şikâyetleri takip edip, müşterilerine sorunun çözüldüğüne dair bilgilendirme yapabilmektedirler (Sarı vd., 2013). Ayrıca çevrimiçi şikâyet platformları hızlı geribildirim özelliğinden dolayı müşteriler tarafından tercih edilmektedir (Oly Ndubisi ve Yin Ling, 2006).

İşletmeler açısından şikâyet sayıları arttıkça bunların hangi soruna ilişkin olduklarının hızlıca belirlenmesi ve buna göre çözüm önerilerinin üretilmesi zaman alır. Bu yüzden, şikâyetlerin sınıflandırılıp doğru kanala yönlendirilmesi hızlı harekete geçmeyi kolaylaştıracaktır. Literatürde bazı çalışmalarda, işletmelerin müşteri şikâyetlerini belirlemesi, yorumlaması ve çözümler üretmesine yönelik içerik analizi yönteminden yararlanılmıştır (Örneğin; Bal, 2014; Çağlar Çetinkaya, 2020; Oğuzlar, 2007; Tanrıseven, 2018;). Bu çalışmalarda çoğunlukla gözleme dayalı, az sayıda veya örneklem alınarak verinin analizi gerçekleştirilmiştir. Şikâyet verisi büyüdükçe değerlendirmenin zorlaşacağı göz önünde bulundurulduğunda ise metinsel veri olan müşteri şikâyetlerinin analizi ve hangi konu ile ilgili olduklarının belirlenmesine için tahminleme, sınıflandırma ve konu modelleme (TM) yöntemlerinden yararlanılarak denetimli,

yarı denetimli veya denetimsiz ML algoritmalarından yararlanılmaktadır.

Bu çalışmada, müşteri şikâyet verisinin sınıflandırılmasına yönelik olarak literatürdeki klasik Türkçe metin sınıflandırma algoritmalarından farklı, başlangıçta sınıf sayısı belirlenmeden, önceden eğitilmiş dil modelleri (PLM) yaklaşımı kullanılarak, sınıf tabanlı Terim Frekansı-Ters Doküman Frekansı'ndan (c-TF-IDF) faydalanan, dinamik konu modellemeyi (DTM) destekleyen ve güncel bir yaklaşım olan BERTopic TM tekniğinden yararlanılmıştır. Buna yönelik olarak da 2020 yılına ait Türkiye'de faaliyet gösteren, tüketici elektroniği perakende firmalarından biri olan Teknosa'ya ait şikâyetvar.com sitesinden edinilen Türkçe şikâyet verileri konulara göre sınıflandırılmıştır. Sınıflandırmadan sonra şikâyet sınıfları altında yer alan kelimeler ile ürün veya şikâyet nedeni gibi şikâyet ayrıntıları belirlenmiştir. Ayrıca DTM ile şikâyet konularının zaman içindeki değişimi incelenmiştir. Çalışmada kullanılan yöntemin, büyük miktardaki şikâyet verisinin hızlı bir şekilde sınıflandırılması avantajının yanı sıra, işletmelere ürün veya hizmetlerinde nerede ne sorun olduğu ve bu sorunun hangi zaman aralığında oluştuğunu belirlenmesi ve işletmelerin sorunu çözmesi için mümkün olduğunca erken önlem alması açısından yararlı olduğu düşünülmektedir. Ayrıca bu çalışma, Türkçe dili özelinde BERTopic kullanılarak yapılan ilk çalışma olduğundan literatüre katkı sağlayacaktır.

2. LİTERATÜR

Literatürde çeşitli sektörlere yönelik yabancı dilde veya Türkçe dilindeki müşteri şikâyetlerinin ML algoritmaları kullanılarak sınıflandırılması üzerine birçok çalışma mevcuttur. Denetimsiz ML yaklaşımlarından biri olan BERTopic TM ise nispeten literatüre yeni giren bir tekniktir. Bu bölümde, müşteri şikâyetlerinin ML ile sınıflandırılmasına yönelik literatürden güncel örnekler verilecek, ardından BERTopic TM tekniği tanıtılacaktır.

2.1 Müşteri Şikâyetlerinin Sınıflandırılması

Son yıllardaki denetimli ML kullanılarak yapılan çalışmalara örnekler vermek gerekirse, HaCohen-Kerner vd.'nin (2019) Bayes Ağları, Tek Değişkenli Lojistik Regresyon, Ardışık Asgari Eniyileme ve Rassal Orman (RF) algoritmaları kullanılarak çok çeşitli kategorilerdeki İbranice müşteri şikâyetlerinin otomatik sınıflandırılması gerçekleştirilmiştir. Greedharry vd.'nin (2019) çalışmalarında ise bir mobil uygulama yardımı ile kullanıcıların girdikleri şikâyetin hangi merci ile ilgili olduğunu belirtmek zorunda kalmadan, şikâyetlerin Evrişimli Sinir Ağları (CNN) kullanılarak ilgili kuruluşa otomatik iletilebildiği anlatılmaktadır. Gupta vd.'nin (2021) yaptıkları başka bir çalışmada ise Hindistan Demiryolları'na gelen büyük miktardaki müşteri şikâyet

verisinin sınıflandırılması için CNN ve Uzun-Kısa Vadeli Bellek (LSTM) modelleri kullanılmıştır. Sann vd.'nin (2021) çalışmalarında turistik otellerin yıldız derecelerine göre aldıkları şikayetler Karar Ağacı Algoritması kullanılarak sınıflandırılmıştır.

Denetimsiz ML kullanılarak şikayetlerin sınıflandırılması çalışmalarında çoğunlukla TM tekniği kullanılmış, buna yönelik olarak da literatürde en fazla Gizli Dirichlet Ayrımı (LDA) olasılık modelinden yararlanılmıştır. LDA kullanılarak müşteri yorum ve şikayetlerinin hangi konularla ilgili olduğunun tespit edilmesine yönelik son yıllarda yapılan çalışmalara örnek vermek gerekirse, Karami ve Pendergraft (2018) sigorta müşterilerinin şikayetlerini sınıflandırmıştır. Kirilenko vd. (2021) ise Çin'deki Qin Terra-Cotta Savaşçıları ve Atları Müzesi ile ilgili TripAdvisor'daki kullanıcı yorumları kullanılarak şikayetlerin neler oldukları incelenmişlerdir.

Türkçe müşteri şikayetlerinin denetimli veya denetimsiz sınıflandırılması çalışmalarına örnek vermek gerekirse, Bayrak vd. (2021) bir turizm firmasına iletilen müşteri yorumlarının şikâyet olup olmadığı belirlenmiş, daha sonra ise şikayetler LSTM kullanılarak hizmet, yemek, yüzme gibi kategorilere ayrılarak sınıflandırılmıştır. Bozyiğit vd. (2022) çalışmalarında ambalajlı gıda ürünlerine ilişkin müşteri şikayetlerini TF-IDF ve Word2Vec özellik temsil stratejilerini Lineer Regresyon, Naive Bayes, k-En Yakın Komşu, Destek Vektör Makinaları, RF ve Aşırı Gradyan Arttırma kullanarak sınıflandırmışlardır. İlhan Omurca vd. (2021) ise şikayetvar.com sitesinden elde ettikleri şikâyet verilerini Dirichlet Çok Terimli Karma modeli için LDA, GenSim LDA, Mallet LDA ve Gibbs Örnekleme ile analiz etmiş ve performanslarını karşılaştırmışlardır. Akbiyık ve Arı (2022) bir e-ticaret platformundaki kablosuz kulaklık ürününe yapılan yorumların faydalı olabilecek olanlarını lojistik regresyon kullanarak tahminlemesini gerçekleştirmişlerdir.

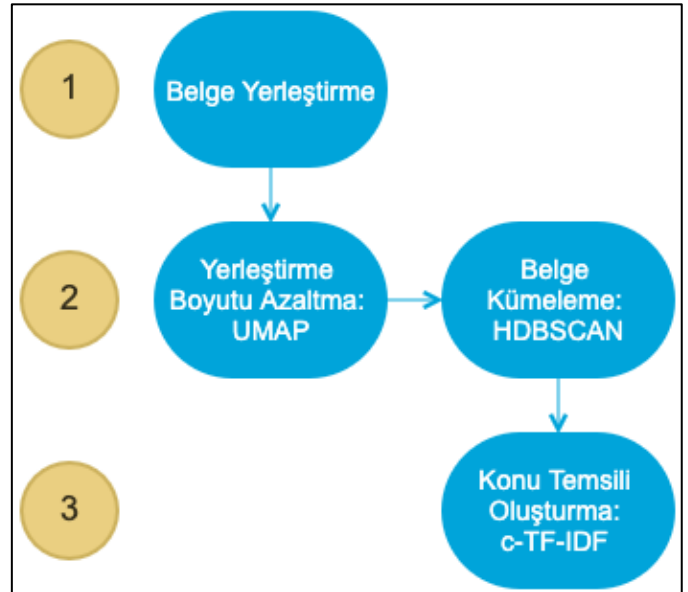
2.2 Konu Modelleme: BERTopic

TM, metin verisi içinde yer alan gizli başlık veya konuları bulmak için kullanılan bir istatistiksel metin madenciliği tekniğidir (Altıntaş vd., 2021). Bunun yanında, büyük metinsel veriyi organize etmeye, anlamaya, özetlemeye ve belgeler arasında farklılık gösteren gizli konuları keşfetmeye yarar (Abuzayed ve Al-Khalifa, 2021). Bu teknik ile bir metin içindeki konular denetimsiz olarak sınıflandırılabilir. TM, bir dizi belge için temel konuları (kelime dağılımları açısından) ve her belgenin bu konulara olan yakınlıklarını öğrenen bir yaklaşımdır (Nikolenko vd., 2017). Literatürde TM üzerine Gizli Anlam Analizi (LSA) (Deerwester vd., 1990), Olasılıksal Gizli Anlam Analizi (PLSA) (Hofmann, 1999), Negatif Olmayan Matris Ayrıştırma (NMF) (Lee ve Seung, 2000), Gizli Dirichlet Ayrımı (LDA) (Blei vd., 2003) gibi farklı ve popüler

yaklaşımlar bulunmaktadır. Bu yaklaşımlarda denetimli ML'de olduğu gibi etiketleme gerekmemekte fakat kategori sayılarının önceden belirlenmesi gerekmektedir.

Diğer yandan, PLM'ler çeşitli doğal dil işleme çalışmalarında sıklıkla kullanılan büyük sinir ağlarıdır ve önceden eğitim ve ince ayar yaklaşımı ile çalışmaktadır (Elazar vd., 2021). PLM'leri kullanan TM tekniklerinden bir tanesi ise BERTopic'dir (Grootendorst, 2022). BERTopic 2020 yılında Maarten Grootendorst tarafından geliştirilen ve algoritmik yapı olarak Top2Vec'e (Angelov, 2020) benzeyen, cümle yerleştirme (gömme) yaratarak anlamsal olarak benzer cümlelerden oluşan kümeler meydana getirmekte ve Top2Vec'den farklı olarak c-TF-IDF ile konu temsili oluşturma prosedürüne dayanmaktadır.

BERTopic TM kabaca üç aşamada gerçekleşmektedir (Şekil 1): (1) Belge yerleştirme: Belge yerleştirmeleri çıkartılır. (2) Belge kümeleme: Yerleştirme boyutunu azaltmak için Düzgün Manifold Yaklaşım ve Projeksiyonu (UMAP) (McInnes vd., 2018) ve semantik olarak benzer belgeleri kümelemek için HDBSCAN (Campello vd., 2013) kullanılır. (3) Konu temsili oluşturma: c-TF-IDF ile konular ayıklanır ve azaltılır.



Şekil 1. BERTopic Konu Modelleme Adımları

Şekil 1'de gösterilen BERTopic'in birinci aşaması olan belge yerleştirmede, vektör uzayında anlamsal olarak karşılaştırılabilecek temsiller oluşturulur. Aynı konuyu içeren belgelerin anlamsal olarak benzer olduğu varsayılır ve yerleştirme adımının gerçekleştirilmesi için Sentence-BERT'den (Reimers ve Gurevych, 2019) yararlanır. Sentence-BERT, cümle dönüştürücülerin yani PLM'lerin kullanılması suretiyle cümleleri ve paragrafları yoğun vektör temsillerine dönüştürülmesini sağlar (Grootendorst, 2022). PLM'ler için belgenin konusu veya diline göre istenilen dönüştürücü seçilebilmektedir.

İkinci aşamada yerleştirme boyutunu azaltmak için UMAP, boyutu azaltılmış bu yerleştirmeleri kümelemek ve anlamsal olarak benzer belge kümeleri oluşturmak için HDBSCAN algoritmasından istifade edilir (Şekil 1, ikinci adım). Kümeleme algoritmalarının, yüksek boyutlu uzayda verileri kümelemesi zorlu olduğu, UMAP'in yüksek boyutlu verilerin yerel ve küresel özelliklerinin çoğunu daha düşük boyutlarda koruduğu ve UMAP'in farklı boyutsal alana sahip dil modelleri arasında kullanılabilirliği göz önünde bulundurularak BERTopic'de belgeler kümelemeden önce, UMAP kullanılarak oluşturulan yerleştirmelerin boyutu azaltılmaktadır (Grootendorst, 2022; McInnes vd., 2018). Ayrıca BERTopic'de, kümeleri oluşturmak ve aykırı değerlerin (veri kümelerinden önemli ölçüde farklı olan veriler) belirlenmesi için yoğunluk temelli bir kümeleme tekniği olan HDBSCAN'den yararlanılmaktadır. HDBSCAN, DBSCAN'i hiyerarşik bir kümeleme algoritmasına dönüştürerek değişen yoğunluktaki kümeleri bulan DBSCAN'in bir uzantısıdır (Grootendorst, 2022).

Üçüncü aşamada ise (Şekil 1, üçüncü adım) konu temsili oluşturmak için c-TF-IDF'den yararlanılır. Klasik anlamda TF-IDF uygulandığında, belgeler arasındaki kelimelerin önemi karşılaştırılır. Eğer, tek bir kategorideki tüm belgeler tek bir belge olarak ele alınarak TF-IDF uygulanırsa, bir küme içindeki kelimeler için önem puanları ortaya çıkacaktır. Böylece, bir küme içinde ne kadar önemli kelime varsa, o konuyu o kadar iyi temsil edecektir. Başka bir ifadeyle, küme başına en önemli kelimeler çıkartılırsa, konuların açıklamaları da ortaya çıkacaktır, bu da c-TF-IDF

olarak adlandırılmaktadır (Grootendorst, 2022). c-TF-IDF, $W_{x,c} = tf_{x,c} \cdot \log(1 + A / f_x)$ ile hesaplanır. Burada; $tf_{x,c}$: c sınıfındaki x kelimesinin frekansı, A: her sınıf için ortalama kelime sayısı, f_x : tüm sınıflardaki x kelimesinin frekansdır. Böylece, her küme bir dizi belge yerine tek bir belgeye dönüştürülür. Ardından, c sınıfındaki x kelimesinin frekansı çıkarılır. Burada c daha önce oluşturulan kümeyi ifade eder ve bu da sınıf tabanlı tf temsiliyle sonuçlanır. Ardından, A sınıfı başına ortalama kelime sayısı tüm sınıflardaki x kelimesinin frekansına bölünüp, değerlerin pozitif sayı olması için 1 eklenir. Böylece IDF hesaplanmış olur. c-TF-IDF prosedürü, tek tek belgeler yerine kümelerdeki sözcüklerin önemini modellemekte, her bir belge kümesi için konukelime dağılımlarının oluşturulmasını sağlamaktadır (Grootendorst, 2022).

Elliden fazla dili destekleyen BERTopic'in önemli bir avantajı konu sayısının önceden ayarlanmasının gerekmediğidir. Bunun yanında, BERTopic tweet ve müşteri yorumları gibi kısa metinlerde LDA'nın aksine daha iyi sonuçlar vermektedir (Alhaj vd., 2022; Sánchez-Franco ve Rey-Moreno, 2021). Bu yüzden, BERTopic'in yönlendirmeli TM, DTM veya sınıf bazlı konu modelleme, hiyerarşik konu azaltmayı ve ayrıca Top2Vec'e göre daha geniş yerleştirme modellerini de desteklemesi gibi avantajları bulunmakta, buna karşılık, yerleştirme yaklaşımının her konunun yoğun bir şekilde incelenmesini gerektiren çok fazla konuya neden olabileceği ve objektif değerlendirme metrikleri eksikliği gibi konuların modelin dezavantajları olarak belirtilmiştir (Egger ve Yu, 2022).

Tablo 1. BERTopic Kullanılan Çalışmalar

Yazarlar (Yıl)	Konu
Ebeling vd. (2021)	Brazilya'daki siyasi iki grubun sosyal izolasyon üzerine Twitter paylaşımları kullanılarak siyasi kutuplaşmaya olan etki araştırılmıştır. BERTopic ve LDA kullanılmıştır.
Chong ve Chen (2021)	COVID-19 salgını sırasında Twitter'da #Chinavirus, #Chinesevirus ve en çok paylaşılan komşu hashtag'ler incelenerek, konular çıkarılmış ve sosyal ağ katılımcılarının dünya ve ABD eyaletlerindeki mekânsal analizi gerçekleştirilmiştir. BERTopic ve kalitatif yöntemler kullanılmıştır.
Hendry vd. (2021)	Bir e-ticaret şirketinin müşterileri ile sohbet robotu arasındaki konuşmalar veri kaynağı olarak kullanılarak önceden belirlenen konular dışında farklı konuların var olup olmadığı araştırılmıştır. BERTopic, Top2Vec ve LDA kullanılmıştır.
Bayram (2022)	Uluslararası gazete makaleleri veri kaynağı olarak kullanılarak, pandeminin sebep olduğu sonuçlar araştırılmıştır. BERTopic, LDA ve ağ analizi kullanılmıştır.
Du vd. (2022)	Twitter'da paylaşılan COVID-19 ile ilgili tweet'lerde doğrulanmış ve sıradan kullanıcıların kendilerini ifşa etme davranışları araştırılmıştır. BERTopic kullanılmıştır.
Zhunis vd. (2022)	COVID-19 pandemisi öncesi ve sonrası kullanıcıların Twitter'da paylaştıkları tweet'lerdeki duygu durumunu incelemiştir. BERTopic kullanılmıştır.
Salmi vd. (2022)	COVID-19 pandemisi sırasında Hollanda'da intihar önleme yardım hatlarına gelen çağrılar veri kaynağı olarak kullanılarak pandeminin intiharla ilgili problemlerdeki değişikliklerle ilişkili olup olmadığı araştırılmıştır. BERTopic kullanılmıştır.
Filieri vd. (2022)	CTrip ve TripAdvisor'daki müşteri yorumları kullanılarak müşterilerin servis robotlarına olan duyguları incelenmiştir. BERTopic, XLNet, Destek Vektör Makinaları, Lojistik Regresyon, Naive Bayes, RF kullanılmıştır.
Baird vd. (2022)	Twitter verileri kullanılarak kullanıcıların ruh sağlığı ve madde kullanımı araştırılmıştır. BERTopic kullanılmıştır.
Özçınar ve Öztürk (2022)	Web of Science'da taranan makaleler veri kaynağı olarak kullanılarak eğitim bilimlerinde hangi alt alanlarda ağ yaklaşımının kullanıldığı araştırılmıştır.

BERTopic yeni bir yaklaşım olduğundan literatürde diğer TM eserlerine nazaran yapılan çalışmalar çok sayıda değildir. 2020 yılından bugüne, BERTopic üzerine literatür özellikle COVID-19 salgın dönemine denk geldiği için araştırmaların çoğu pandemiyle ilişkili veya alakalıdır. Tablo 1’de BERTopic kullanılarak yapılan TM çalışmaları verilmektedir. Türkçe dili özelinde yapılan çalışmalara literatürde rastlanmamıştır.

3. YÖNTEM

Bu çalışmada, Türkiye’de faaliyet gösteren ve bir tüketici elektroniği perakende firması olan Teknosa’ya ait 2020 yılı müşteri şikâyet verileri BERTopic v0.11.0 kullanılarak analiz edilmiştir. Çalışmanın akış şeması Şekil 2’de gösterilmektedir. Çalışmada kullanılan yöntem (veya parametreler) yazar tarafından önceden yapılan birçok deneyin sonuçları temel alınarak, en doğru ve en iyi sonucu verecek şekilde tasarlanmıştır. Değiştirilen parametrelerin dışındaki parametreler varsayılan şeklindedir (bkz: Grootendorst, 2021).


Çalışmada kullanılan veriler Türkiye’nin önde gelen şikâyet platformlarından biri olan sikayetvar.com sitesinden veri kazıma metoduyla elde edilmiştir. Teknosa’ya ait veri, 1 Ocak 2020 ve 31 Aralık 2020 tarihleri arası 7743 şikâyeti barındırmakta, Şikâyet Konusu, Tarih, Zaman ve Şikâyet verilerinden oluşmaktadır. Çalışmada sadece şikâyetler ve tarih verisi kullanılmıştır.

TM işleminden önce veri, noktalama işaretlerinden temizlenmiş, metin etkisiz kelimelerden arındırılmıştır ve küçük harfe dönüştürülmüştür. Algoritma sonuçlarında kötü sonuçlar verdiği için kelimelerin köklerine ayırma işlemi yapılmamıştır.

Doğal dil işleme literatürüne 2018 yılında giren dönüştürücü tabanlı yapılardan olan BERT modeli (Devlin

vd., 2018) metinlerin sınıflandırılması için kullanılan açık kaynaklı bir modeldir. Dönüştürücülerden çift yönlü kodlayıcı gösterimleri içeren bu model ile Türkçe doğal dil işlemede metin sınıflandırma üzerine de çalışmalar bulunmaktadır (Örn; Taşar vd., 2021). Bu yüzden model kurulumunda ilk adım, cümle dönüştürücüler kullanarak bir dizi belgeden belge yerleştirmeleri oluşturma işlemidir. Çalışmada BERT modelinin farklı bir versiyonu olan, Türkçe de dahil olmak üzere elliden fazla dil için önceden eğitilen ve belge veya cümle yerleştirmeleri oluşturmak için kullanılan paraphrase-multilingual-mpnet-base-v2 (Reimers ve Gurevych, 2019) modeli kullanılmıştır. BERTopic modelinde önerilen diğer PLM’lerden istenilen verim alınamamıştır.

Python Sklearn kütüphanesi kullanılarak oluşturulan *vectorizer model*’de kelime bazlı *n-gram* parametresi (1,2) şeklinde ayarlanmıştır. Bu, özellikle Türkçe’de sıkça kullanılan isim tamlamaları göz önünde bulundurularak seçilmiştir. BERTopic modeli sonuçlarında bazen aykırı konular (model sonucunda -1 olarak tanımlanan konular) tüm konular arasında yüksek bir oranda çıkabilmekte, bundan kaçınmak için ise model eğitildikten sonra konulara aykırı değerler atanabilmektedir. Bunun için *calculate probabilities: True* olarak ayarlanmış ve *probability threshold* değeri 0,01 olarak belirlenerek herhangi bir konuya ait bir belgenin olasılığı hesaplanarak aykırı konular yüksek olasılığa sahip olan konuya atanabilmekte, böylece aykırı konu sayısı azaltılmaktadır. Model parametrelerinde başlangıçta ne kadar konu üretildiğinin gözlemlenmesi açısından *number of topics* parametresi *none* olarak ayarlanmış, daha sonra konu sayısının azaltılması aşamasında *number of topics: auto* olarak belirlenmiştir. Algoritmanın her çalıştığında konu sayısı farklı sonuçlar verse de en uygun konular ve konu sayıları bulunana kadar algoritma tekrarlanmıştır.



Şekil 2. Akış Şeması

Çalışmada bir yıllık şikâyetlerin sınıflandırılması yanında bir de şikâyet konularının aylık değişimi incelenmiştir. Bunun için de DTM yöntemi kullanılmıştır. DTM, konuların belirli bir zaman aralıklarında nasıl değişim gösterdiğini ve konunun zaman içinde nasıl temsil edildiğinin anlaşılmasına olanak tanımaktadır. DTM'de bir zaman adımındaki konuların tahmini, bir önceki zaman adımındaki tahmine bağlıdır ve herhangi bir zamanda bir konunun ne kadar iyi temsil edildiğinin gözlemlenmesini sağlamaktadır (Gropp vd., 2019). Çalışmada her konu için aylık bir ayırım da yapılmıştır. Modelde *topics over time* (ToT) parametrelerinden *global tuning*, *t* zaman damgasında belgelerde bulunamayan konu temsillerindeki sözcükleri önlemek istendiği, *evolution tuning* ise c-TF-IDF matrisinin *t-1* zaman damgasında c-TF-IDF matrisiyle ortalamasını alarak *t* zaman damgasında her konu gösteriminde ince ayar yapılması için işleme alınmamıştır. Bir başka deyişle, *global tuning* ile global temsilin yerel gösterimle ortalaması alınmakta, böylece herhangi bir kelime bu zaman damgasında olabilmektedir. *evolution tuning* ile ise *t-1*'deki temsilin ortalaması *t* ile alınmakta, bu nedenle kelimeler


muhtemelen bunların bir kombinasyonu olacaktır. Son olarak, çalışmada şikâyet konularının her 12 ayda nasıl bir değişim gösterdiğini belirlemek için ToT için *number of bins* 12 olarak ayarlanmıştır.

4. BULGULAR

Deneylerde her defasında yaklaşık konu sayısı Metodoloji bölümünde bahsedilen parametreler de kullanılarak 50-60 arası çıkmaktadır. Bu çalışmada verilen konu sayısı bu deney sonuçlarından biri olan 58'dir. Bunun yanında ilave olarak, algoritma sonucu ortaya çıkan, -1 olarak belirlenmiş, hiçbir konuya ait olmayan aykırı konular bulunmaktadır ve tüm konular içinde yaklaşık %3'lük bir paya sahiptir (Tablo 2). Tablo 2'de şikâyet konularını temsil eden kelimeler, şikâyet konularının hangi sıklıkta geçtikleri (frekans), toplam konu sayısına oranları ve yazar tarafından modelin oluşturduğu konulara ait şikâyetlerin incelenmesi suretiyle şikâyet açıklamaları yer almaktadır. Şekil 3'te ilk on konuya ait kelimelerin c-TF-IDF puanları verilmektedir. Tablo 3'te ise Tablo 1'e istinaden ilk sıradaki beş konuya ait örnek şikâyetler verilmektedir.

Tablo 2. BERTopic Konu Modelleme Sonuçları: Şikâyet Konuları ve Şikâyet Sayıları

ID	Kelimeler	Frekans	Oran (%)	Şikâyet Açıklaması
0	ürün, gün, sipariş, kargoya	2013	26,00	Kargo (Genel)
1	tv, televizyon, lg, servis	625	8,07	Televizyon
2	telefon, telefonu, samsung, telefonun	605	7,81	Cep telefonu (Genel)
3	laptop, bilgisayar, bilgisayar, gün	516	6,66	Dizüstü bilgisayar (Genel)
4	kulaklık, kulaklığı, ses, bluetooth	508	6,56	Kulaklık
5	ups, türkiye, ups türkiye, istanbul	228	2,94	Kargo (UPS)
6	tablet, casper, tableti, kasko	192	2,48	Tablet bilgisayar (Genel)
7	iphone, tl, telefon, apple	172	2,22	iPhone (Şarj)
8	iphone, apple, telefonu, telefon	154	1,99	iPhone (Servis)
9	avm, personel, mağaza, çalışan	128	1,65	Personel
10	iptal, sipariş, iptal etmek, siparişimi	120	1,55	Sipariş İptali (Genel)
11	mouse, logitech, mouse aldım, gün	108	1,39	Fare (Genel)
12	tıraş, saç, makinesi, tıraş makinesi	107	1,38	Tıraş Makinası
13	huawei, lite, garanti, huawei smart	90	1,16	Huawei
14	şarj, pil, aleti, şarj aleti	85	1,10	Şarj ve Pil
15	müşteri, iptal, gün, sipariş	79	1,02	Sipariş İptali (Para İadesi)
16	modem, tp, tp link, link	78	1,01	Modem
17	telefon, müşteri, telefon almak, dakika	71	0,92	Müşteri Hizmetleri
18	fiyat, tl, etiket, kasaya	70	0,90	Fiyat
19	akıllı, watch, saati, saat	70	0,90	Akıllı Saat (Genel)
20	hediye, çeki, hediye çeki, amazon	70	0,90	Hediye Çeki
⋮	⋮	⋮	⋮	⋮
57	apple watch, watch, apple, teslim	16	0,21	Akıllı Saat (Apple Watch)
-1	ürünü, ürün, aldım, telefon	229	2,96	Aykırı Konular
Toplam		7743	100,00	



Şekil 3: İlk On Konu ve c-TF-IDF Puanları

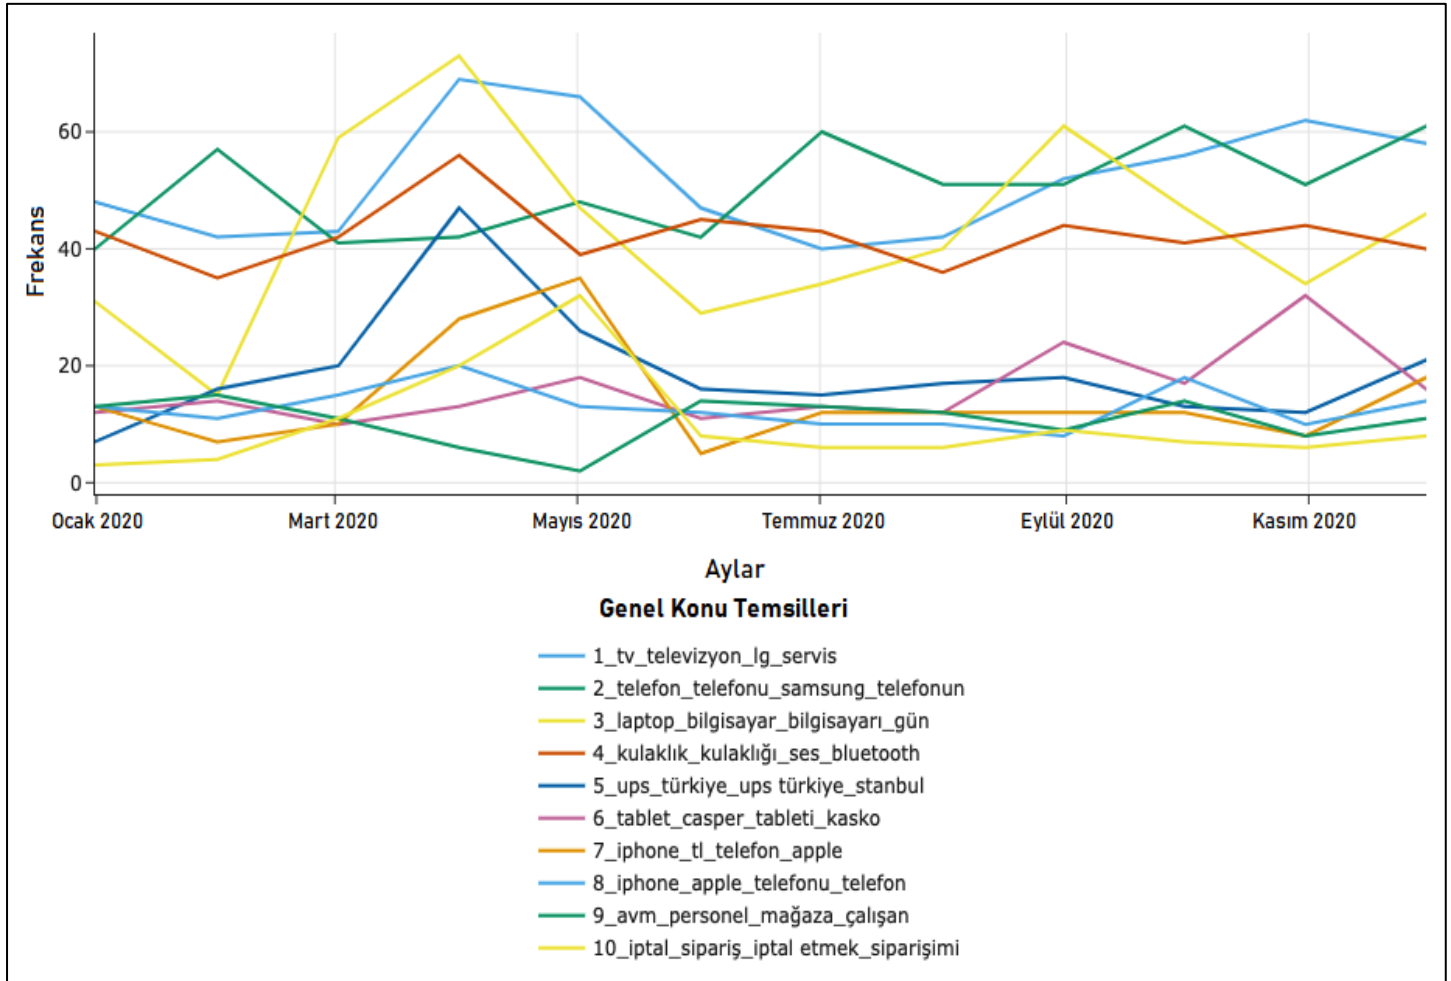
Tablo 3. İlk Beş Şikâyet Konusu Örneği

Konu No	Şikâyet
0	teknosa.com'dan cuma günü sipariş verdik. Şipariş no ***. Siparişimi netten kontrol ettiğim halde ürün hazırlanıyor denmektedir Ürün ulaşma süreci 1-5 gün arası demişsiniz ama hiçbir hareket olmaz mı? Ürün kargoya bile verilmemiş. Acil bu durumun çözülmesini ve acil şekilde ürünümün ulaştırılmasını, hızlandırılmasını talep ediyorum.
1	Teknosa'dan aldığım Grundig 32 VLE 6830 BP Smart TV'yi sipariş ederken yaşadığım ödeme sorunları üzerine, şimdi de fotoğrafta da görüldüğü üzere ücretsiz kurulum olması gerekirken, Grundig servisini aradığımda kurulumun ücretli olacağı yalnızca Teknosa'nın iletişime girmesi halinde ücretsiz kurulum yapılabileceği söylendi. Bunun üzerine Teknosa müşteri temsilcileriyle görüştüğümde kurulumun ücretsiz olduğu konusunda hemfikir olduklarını ama bununla ilgili kendilerinin bir yönlendirme hizmeti verilemediğini beyan ettiler, tekrar Grundig'i aramamı istediler ve aynı süreç, aynı bilgi 2 kez Grundig Teknosa arasındaki konuşmadan sonra, aynı çözümsüzlükle kaldım elimde. Böyle olacağını bilsem direkt firmadan alırdım ürünü. Tam bir çile.
2	Telefonumu garantiye verdim, geldi, hoparlörde sorun vardı. Halledilmiş sözde ama telefon geldiğinde aramalara cevap veremiyorum. Telefon biri aradığında kilitleniyor ve bu da sizin suçunuz. Garantiden geldi böyle bir sorun ortaya çıktı ve bu zamanda her taraf kapalı. Sizin yüzünüzden çok mağdurum.
3	Dizüstü bilgisayara 6300 lira para verip internetten aldık. Teslim aldığımızda sorun yok gibiydi ancak ufak bir hasar almış olduğunu sonradan fark edince ertesi gün başvurduk değişim için fakat teslim alırken fark etmemiz gerekiyormuş. Değişim yapmadılar. Teknosa'dan da olsa gözünle görmeden almamak lazımmış. Firma sağlam dedik, güvenimiz boşa çıktı.
4	12 Mart tarihinde Teknosa Beşiktaş şubesinde satın aldığım JPL Bluetooth kulaklık ürününü şarj olmadığı için kullanamadığım. Ürünü takip no *** ile Beşiktaş şubeye servise vermiştim. Ürün gerçekten işim gereği çok fazla ihtiyaç duyduğum bir ürün. Bu ürün arızası cihaz kaynaklı olduğu için teknik servis dönüşünü 1 ay 8 gündür bekliyorum. Artık bir dönüş almak istiyorum. Bu kadar uzamaması gerekiyor. Ayrı mal olduğu çok bariz belli.

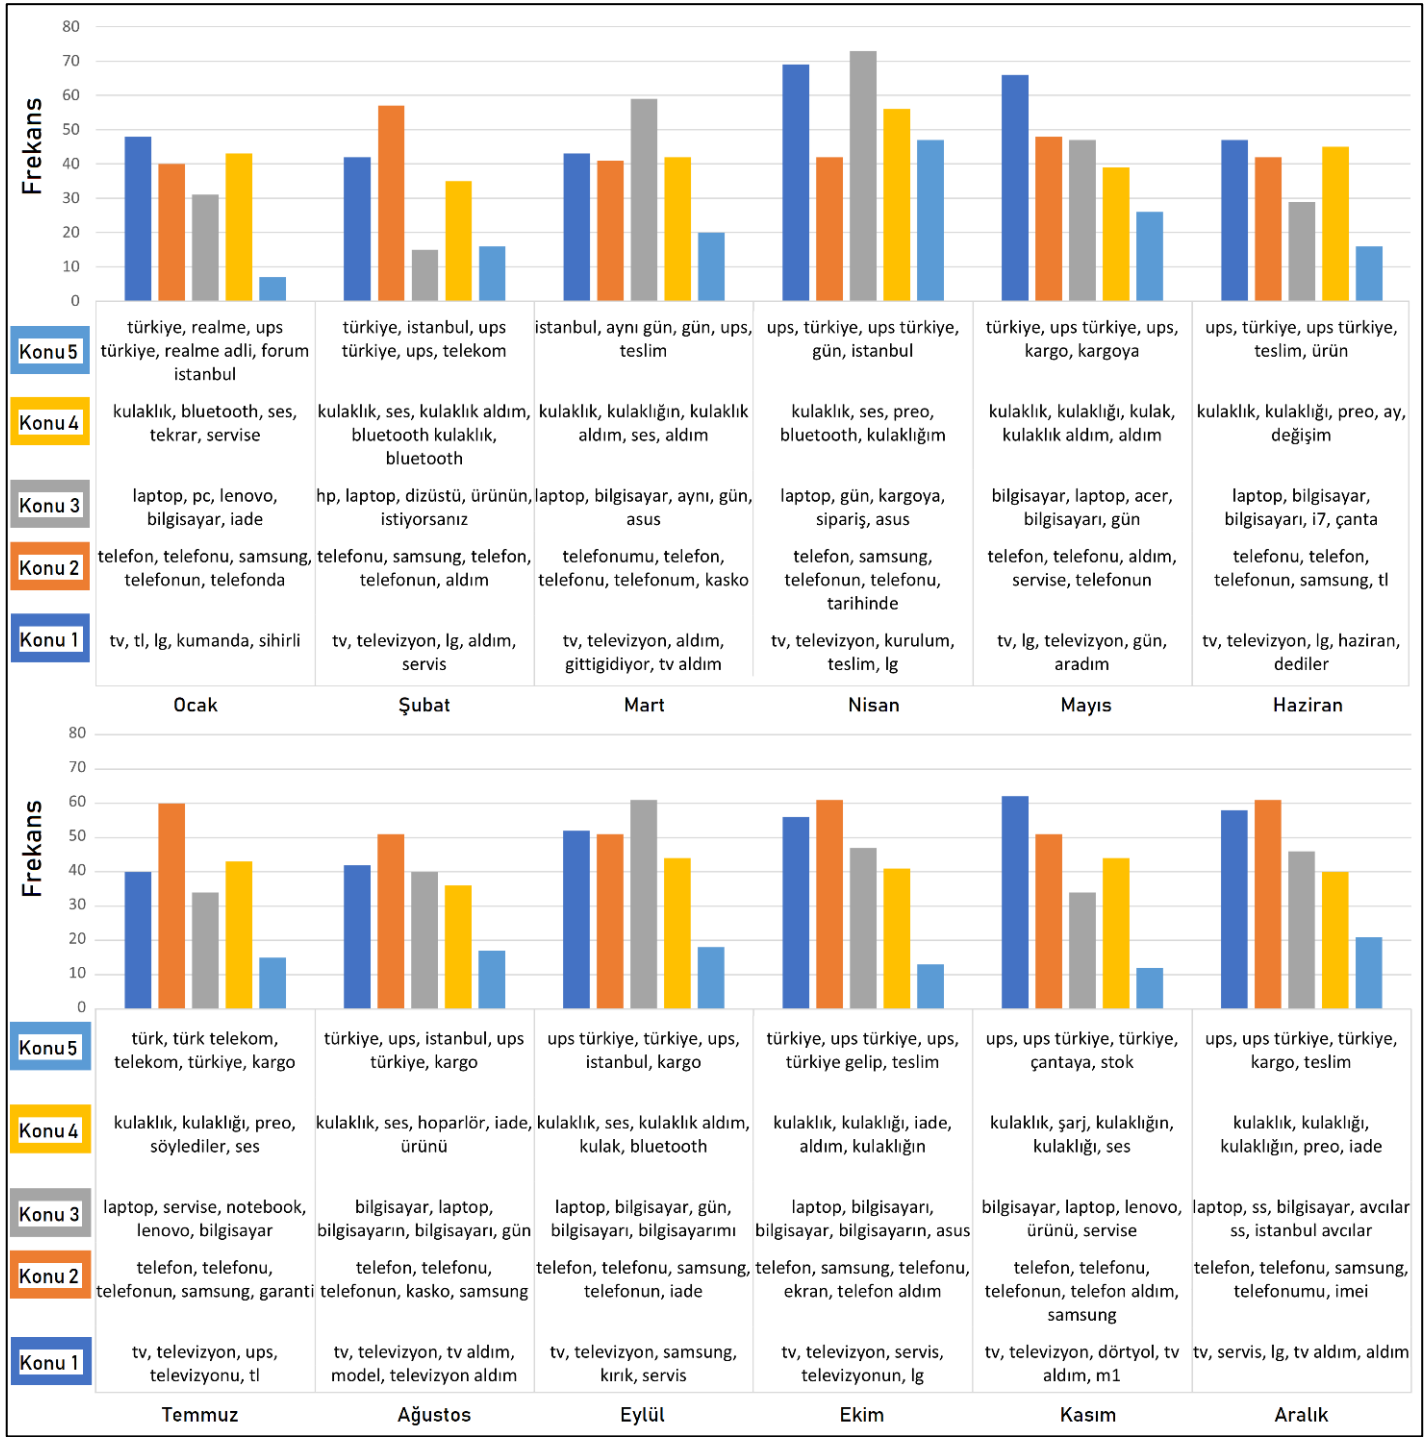
Model sonucunda ortaya çıkan sonuçlara göre bir yıl boyunca şikayetlerin hangi ürün veya konu üzerine olduğu gözlemlenebilmektedir (Tablo 2). Örneğin, en fazla şikâyet kargo konusu üzerinedir. Yani, 7743 şikâyet arasından 2013 adet şikâyet sadece kargo ile ilgilidir ve toplam şikayetler içindeki oranı %26'dır. Bu yüksek şikâyet oranı özellikle 2010 yılı pandemi koşullarında müşterilerin internet alışverişini arttırdıkları ve bir süre kargo işlemlerinde sıkıntılar yaşandığının göstergesidir. Bunun yanında, para iadesi, fiyatlandırma, müşteri hizmetleri gibi diğer ana şikayetler de konular arasındadır. Ayrıca, ürün bazlı yani, özellikle televizyon, cep telefonu, dizüstü bilgisayar ve kulaklık konuları ile ilgili şikayetler de tüm şikayetler içinde önemli bir kısmı oluşturmaktadır.

En çok şikâyet alan ilk beş konuya ait DTM grafiği Şekil 4'te verilmekte, Şekil 5'te ise her ay için ilk beş şikâyet konusuna yönelik ilgili kelimeler grafikte yer almaktadır.

DTM'nin bir avantajı dönemsel olarak şikayetlerdeki değişimin gözlemlenebilmesidir. Örneğin, Şekil 4'ten görüldüğü üzere, özellikle Nisan ve Haziran ayları arasında televizyon, cep telefonu, dizüstü bilgisayar, kulaklık ve kargo konularında gözle görülür bir şikayet artışı söz konusudur. Aynı zamanda, özellikle Mayıs ayında personel şikayetlerinde azalma gözlemlenmektedir. Bunun da pandemi süresince kapanmalardan dolayı mağazalara giden müşteri sayısındaki azalmadan kaynaklandığı düşünülmektedir. Ayrıca, Eylül ayında dizüstü bilgisayar şikayetlerindeki artış, 2020-2021 öğretim yılında uzaktan eğitimin devam ettiği hesaba katıldığında, bir anlam ifade etmektedir. Aynı zamanda, Şekil 5'te konuların aylık değişimi kelimeler bazında izlenebilmektedir. Örneğin, kulaklık ile ilgili şikayetlerde Haziran, Ağustos, Ekim ve Aralık aylarında iade/değişim ile ilgili şikayetler öne çıkarken, telefon şikayetlerinde ise Mart ve Ağustos aylarında telefon kaskosu ile ilgili şikayetler gözlemlenmektedir.



Şekil 4. İlk On Şikâyet Konusuna Ait Aylık Değişim



Şekil 5. 12 Aylık İlk Beş Şikâyet Konusu Değişimi

5. SONUÇLAR VE TARTIŞMALAR

İşletmelerin karlılıklarını arttırabilmeleri ve marka değerlerini koruyabilmeleri müşteri memnuniyetine bağlıdır. Müşteri memnuniyetinin göstergesi ise müşterinin şikâyetle bulunmaması veya bir kusur varsa bunun bir an önce düzeltilebilmesidir. Ayrıca işletmeler imajını korumak ve potansiyel yeni müşteriler kazanmak için de şikâyetleri en aza indirme veya şikâyet varsa hatalarına çözüm önerileri üretme eğilimde olmalıdır. Bu

yüzden, müşteri şikâyet verilerinin etkin bir şekilde analiz edilmesi ve sorunun nerede olduğunun belirlenmesi gerekmektedir. Bunun yanında, şikâyet verilerinin büyüklüğü göz önünde bulundurulduğunda, özellikle ML ile sınıflandırma, tahminleme veya TM tekniklerinin kullanımı işletmelere büyük kolaylıklar sağlayacaktır. Bu yüzden, bu çalışmada işletmeler açısından “geçmişte ne hata yaptık?” ve “bunu nasıl düzeltebiliriz?” sorularına çözüm bulmak amacıyla, müşteri şikâyet analizinde ML yöntemi temel alınarak TM tekniklerinden biri olan BERTopic önerilmiştir.

Klasik ML yöntemlerinin aksine BERTopic tekniğinde cümle dönüştürücü olarak önceden eğitilmiş modellerin kullanılması, model çalıştırıldığında eğitim aşamasının kısa bir sürede tamamlanmasına olanak tanımakta ve zamandan tasarruf sağlanmaktadır. Fakat, önceden eğitilmiş uygun bir modelin kullanılması ancak yapılacak deneylerle veya çalışılan konuya özgü cümle dönüştürücü bir model ile sağlanabilecektir. Ayrıca, BERTopic tekniğinde konu sayısının önceden belirlenmemesi ayrı bir avantajdır. Uygun parametreler ve modelin birkaç defa çalıştırılmasıyla kullanıcı konu sayısının kaç olacağını gözlemleyebilmektedir. Buna ek olarak, konu azaltma yönteminin de modelde çıkabilecek fazla sayıdaki konuların azaltmasında etkili olduğu gözlenmiştir.

Çalışmada kullanılan veri seti bir tüketici elektroniği perakende firmasına ait şikayetlerden oluştuğundan, model, genel şikayetlerin konu ayrımından daha çok satılan ürünlere özgü olan şikayetleri ortaya çıkıştır. Genel anlamdaki şikayetler incelendiğinde ürünün zamanında gönderilmemesi, ürün servisi, kasko, mağaza çalışanları, sipariş iptali ve geri ödemelerde gecikmeler, müşteri hizmetleri ve fiyatlandırma şeklinde sıralanmaktadır. Ürün bazında incelendiğinde ise gelen şikayetler en çok televizyon, cep telefonu, dizüstü bilgisayar, kulaklık, tablet ürünlerini içermekte olup yaklaşık %39'luk bir paya sahiptir. Esasen, bir tüketici elektroniği firmasının en çok sattığı ürünler düşünüldüğünde, bu ürünlerin satış miktarları ile şikâyet sayılarının orantılı olduğu düşünülmektedir. Bununla beraber, TM ile bu ürünlere ait şikâyet detayları kelime bazlı olarak da incelenebilmektedir (Örneğin, cep telefonu şarj sorunları veya bir televizyonun servis kalitesi ile ilgili şikayetler). Ayrıca, şikâyet konularının zamanla değişim gösterebileceği düşünülerek DTM yardımıyla aylık değişim de incelenmiştir. Bunun da işletmelere şikayetlerin dönemsel olarak nasıl bir değişim gösterdiğine ilişkin bir bakış açısı getireceği düşünülmektedir. Çünkü, şikâyetten dolayı bir ürünlerdeki sorun düzeltilindiğinde, gelecekte aynı ürün için başka bir şikâyet gelmesi olasıdır.

Kullanılan veri setinde yer alan şikayetlerin bazılarında anlamsal olarak iki hatta üç şikâyet konusu tek bir şikâyet satırında yer almaktadır. Örneğin, şikayetini yapan müşteri sipariş iptali yapmış, para iadesi gecikmiş ve müşteri hizmetlerine ulaşamadığından veya müşteri temsilcisinin kendi ile yeterince ilgilenmediğinden bahsedebilmektedir. Bu yüzden, model şikâyetin hangi konu içinde yer alacağını belirlemede bazen istenilen sonucu vermeyebilmektedir.

Bu çalışmada kullanılan yöntem depolanmış veya devamlı akan veri için de kullanılabilir bir yapıdadır. Bu yüzden bu çalışma, özellikle devamlı akan verinin analizi düşünüldüğünde, işletmelerin müşteri şikayetleri hakkında

anında yeni bilgiler edinip hızlı çözüm önerileri üretmeleri, mevcut müşterileri koruma ve yeni müşteriler edinme kapsamında karlılık oranlarının artırılmasına katkı sağlayacaktır.

BERTopic tekniğinin denetimli öğrenme tekniklerinden farkı, ön etiketlemeye ihtiyaç duymadan, girdilerin kendi içerisindeki temsillerinden yola çıkarak ürettiği etiketler üzerinden analiz yapabilme becerisidir. Denetimli ML'nde etiketli veri oluşturmak maliyetli ve zaman alan bir süreçtir. Gerçekleştirilen çalışma ise çok da fazla ön işleme ihtiyaç duymadan hızlı bir şekilde faydalı ve kullanılabilir bilgi çıkarımı yapılabildiğini göstermektedir. Bunun da işletmelerin veriyi (veya büyük veriyi) verimli ve hızlı bir şekilde, dönemsel ve döngüsel olarak oluşturulan modelden istifade ederek metin analizleri yapabilmelerini sağlaması açısından büyük önem taşımaktadır.

Çalışmanın BERTopic tekniği kullanılarak Türkçe için yapılan ilk çalışma olduğu göz önünde bulundurularak, ileride yapılacak çalışmalarda çalışmada kullanılan yöntemlerden farklı olarak, güdümlü (guided) veya yarı denetimli olarak da denenmesi ve ayrıca boyut azaltma için Temel Bileşenler Analizi (PCA) veya kümeleme için k-ortalamlar yöntemlerinin de kullanılması yararlı olacaktır. Ayrıca farklı Türkçe veri setlerinden yararlanarak modelin kullanılabilirliğinin test edilmesinin önem taşıdığı düşünülmektedir.

KAYNAKÇA

- Abuzayed, A., & Al-Khalifa, H. (2021). BERT for Arabic topic modeling: An experimental study on BERTopic technique. *Procedia Computer Science*, 189, 191–194. <https://doi.org/10.1016/j.procs.2021.05.096>
- Akbıyık, A., & Arı, O. (2022). Lojistik regresyon ile faydalı müşteri yorumlarını tahminleme. *Journal of Research in Business*, 7, IMISC 2021 Special Issue, 15–32. <https://doi.org/10.54452/jrb.1024602>
- Alabay, M. N. (2012). Müşteri şikâyetleri yönetimi. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(16), 137–157.
- 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>
- Altıntaş, V., Albayrak, M., & Topal, K. (2021). Kanser hastalığı ile ilgili paylaşımlar için Dirichlet ayrımı ile gizli konu modelleme. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 36(4), 2183–2196 <https://doi.org/10.17341/gazimmfd.734730>

- Angelov, D. (2020). Top2Vec: Distributed representations of topics. *arXiv*. <https://doi.org/10.48550/ARXIV.2008.09470>
- Aşkun, O. (2015). Şikâyet iletilerinin örgütsel öğrenme üzerine etkisi. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 24(1), 221–243.
- Baird, A., Xia, Y., & Cheng, Y. (2022). Consumer perceptions of telehealth for mental health or substance abuse: A Twitter-based topic modeling analysis. *JAMIA Open*, 5(2), 1–8. <https://doi.org/10.1093/jamiaopen/ooac028>
- Bal, V. (2014). Online satış girişimcilerinin karşılaştıkları müşteri şikâyetlerinin analizi. *AİBÜ Sosyal Bilimler Enstitüsü Dergisi*, 14(1), 59–74.
- Bayrak, A. T., Türker, B. B., Yıldız, E., & Özbek, E. E. (2021). Complaint detection and classification of customer reviews. *SIU, 29th Signal Processing and Communications Applications Conference*, 9-11 June 2021, İstanbul, Türkiye, pp. 1–4. <https://doi.org/10.1109/siu53274.2021.9478016>
- Bayram, U. (2022). Revealing the reflections of the pandemic by investigating COVID-19 related news articles using machine learning and network analysis. *Bilişim Teknolojileri Dergisi*, 15(2), 209–220. <https://doi.org/10.17671/gazibtd.949599>
- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent dirichlet allocation. *Journal of Machine Learning Research*, 3, 993–1022.
- Bozyiğit, F., Doğan, O., & Kılınc, D. (2022). Categorization of customer complaints in food industry using machine learning approaches. *Journal of Intelligent Systems: Theory and Applications*, 5(1), 85–91. <https://doi.org/10.38016/jista.954098>
- Campello, R. J., Moulavi, D. & Sander, J. (2013). Density-based clustering based on hierarchical density estimates. *PAKDD 2013, 17th Pacific-Asia Conference*, April 2013, Gold Coast, Australia, pp. 160–172.
- Chong, M., & Chen, H. (2021). Racist framing through stigmatized naming: A topical and geo-locational analysis of #chinavirus and #chinesevirus on Twitter. *84th Annual Meeting of the Association for Information Science & Technology*, 29 October – 3 November 2021, Salt Lake City, USA, pp. 70–79. <https://doi.org/10.1002/pra2.437>
- Çağlar Çetinkaya, N. (2020). Hizmet kalitelerine ilişkin müşteri şikâyetleri: Bir içerik analizi. *Selçuk 2. Uluslararası Sosyal Bilimler Kongresi*, 7 Haziran 2020, Konya, pp. 39–54.
- Deerwester, S., Dumais, S. T., Furnas, G. W., Landauer, T. K., & Harshman, R. (1990). Indexing by latent semantic analysis. *Journal of the American Society for Information Science*, 41(6), 391–407. [https://doi.org/10.1002/\(sici\)1097-4571\(199009\)41:6<391::aid-asi1>3.0.co;2-9](https://doi.org/10.1002/(sici)1097-4571(199009)41:6<391::aid-asi1>3.0.co;2-9)
- Demirel, Y. (2017). Müşteri ilişkileri yönetimi: Teori, uygulama, ölçüm, 3. Baskı. Ankara: Seçkin Yayıncılık.
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of deep bidirectional transformers for language understanding (Version 2). *arXiv*. <https://doi.org/10.48550/ARXIV.1810.04805>
- Du, T., Umar, P., Rajtmajer, S., & Squicciarini, A. (2022). The contribution of verified accounts to self-disclosure in COVID-related Twitter conversations. *Sixteenth International AAAI Conference on Web and Social Media*, 6-9 June 2022, Atlanta, Georgia, USA, pp. 1393-1397.
- Dwivedi, M., Shibu, T. P., & Venkatesh, U. (2007). Social software practices on the internet. *International Journal of Contemporary Hospitality Management*, 19(5), 415–426. <https://doi.org/10.1108/09596110710757570>
- Ebeling, R., Córdova Sáenz, C. A., Nobre, J., & Becker, K. (2021). The effect of political polarization on social distance stances in the Brazilian COVID-19 scenario. *Journal of Information and Data Management*, 12(1). <https://doi.org/10.5753/jidm.2021.1889>
- Egger, R., & Yu, J. (2022). A topic modeling comparison between LDA, NMF, Top2Vec, and BERTopic to demystify Twitter posts. *Frontiers in Sociology*, 7, 886498. <https://doi.org/10.3389/fsoc.2022.886498>
- Elazar, Y., Kassner, N., Ravfogel, S., Ravichander, A., Hovy, E., Schütze, H., & Goldberg, Y. (2021). Measuring and improving consistency in pretrained language models. *Transactions of the Association for Computational Linguistics*, 9, 1012–1031. https://doi.org/10.1162/tacl_a_00410
- Faed, A. (2010). Handling e-complaints in customer complaint management system using FMEA as a qualitative system, *IMS 2010, 6th International Conference on Advanced Information Management and Service*, 30 November - 02 December 2010, Seoul, Korea, pp. 205–209.
- 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, 109467052211039. <https://doi.org/10.1177/10946705221103937>
- Galitsky, B. (2020). Artificial intelligence for customer relationship management, Springer International Publishing, Cham. <https://doi.org/10.1007/978-3-030-52167-7>
- Garding, S., & Bruns, A. (2015). Complaint management and channel choice, Springer International Publishing, Cham. <https://doi.org/10.1007/978-3-319-18179-0>
- Ghazzawi, A., & Alharbi, B. (2019). Analysis of customer complaints data using data mining techniques. *Procedia Computer Science*, 163, 62–69. <https://doi.org/10.1016/j.procs.2019.12.087>
- Goodman, J. (1992). Leveraging the customer database to your competitive advantage, *Journal of Direct Marketing*, 55, 26–27.
- Greedharry, M., Seewoogobin, V., & Gooda Sahib-Kaudeer, N. (2019). A smart mobile application for complaints in Mauritius. *Advances in Intelligent Systems and Computing*, Springer Singapore, Singapore. https://doi.org/10.1007/978-981-13-3338-5_32
- Grootendorst, M. (2021). BERTopic. <https://maartengr.github.io/BERTopic/api/bertopic.html>
- Grootendorst, M. (2022). BERTopic: Neural topic modeling with a class-based TF-IDF procedure. *arXiv*. <https://doi.org/10.48550/ARXIV.2203.05794>
- Gropp, C., Herzog, A., Safro, I., Wilson, P. W., & Apon, A. W. (2016). Scalable dynamic topic modeling with clustered latent dirichlet allocation (CLDA) (Version 3). *arXiv*. <https://doi.org/10.48550/ARXIV.1610.07703>
- Gupta, M., Singh, A., Jain, R., Saxena, A., & Ahmed, S. (2021). Multi-class railway complaints categorization using Neural Networks: RailNeural. *Journal of Rail Transport Planning and Management*, 20, 100265. <https://doi.org/10.1016/j.jrtpm.2021.100265>
- HaCohen-Kerner, Y., Dilmon, R., Hone, M., & Ben-Basan, M. A. (2019). Automatic classification of complaint letters according to service provider categories. *Information Processing and Management*, 56(6), 102102. <https://doi.org/10.1016/j.ipm.2019.102102>
- Halstead, D., & Dröge, C. (1991). Consumer attitudes toward complaining and the prediction of multiple complaint responses. *Advances in Consumer Research*, 18(1), 210–216.
- Hendry, D., Darari, F., Nurfadillah, R., Khanna, G., Sun, M., Condylis, P. C., & Taufik, N. (2021). Topic modeling for customer service chats. *ICACIS, International Conference on Advanced Computer Science and Information Systems*, 23-25 October 2021, Depok, Indonesia, pp. 1–6. <https://doi.org/10.1109/icacsis53237.2021.9631322>
- Hofmann, T. (1999). Probabilistic latent semantic indexing. *SIGIR '99, 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, August 1999, New York, USA, pp. 50–57. <https://doi.org/10.1145/312624.312649>
- Homburg, C., & Fürst, A. (2007). See no evil, hear no evil, speak no evil: a study of defensive organizational behavior towards customer complaints. *Journal of the Academy of Marketing Science*. 35(4), 523–536. <https://doi.org/10.1007/s11747-006-0009-x>
- İlhan Omurca, S., Ekinci, E., Yakupoğlu, E., Arslan, E., & Çapar, B. (2021). Automatic detection of the topics in customer complaints with artificial intelligence. *Balkan Journal of Electrical and Computer Engineering*, 9(3), 268–277. <https://doi.org/10.17694/bajece.832274>
- Johnston, R. (2001). Linking complaint management to profit. *International Journal of Service Industry Management*, 12(1), 60-69. <https://doi.org/10.1108/09564230110382772>
- Karami, A., & Pendergraft, N. M. (2018). Computational analysis of insurance complaints: GEICO case study. *arXiv*. <https://doi.org/10.48550/ARXIV.1806.09736>
- Kirilenko, A. P., Stepchenkova, S. O., & Dai, X. (2021). Automated topic modeling of tourist reviews: Does the Anna Karenina principle apply?. *Tourism Management*, 83, 104241. <https://doi.org/10.1016/j.tourman.2020.104241>
- Lee, D. D., & Seung, H. S. (2000). Algorithms for non-negative matrix factorization. *NIPS 2001, Advances in neural information processing systems*, 3-8 December 2001, Vancouver, Canada.
- McInnes, L., Healy, J., & Melville, J. (2018). UMAP: Uniform manifold approximation and projection for dimension reduction (Version 3). *arXiv*. <https://doi.org/10.48550/ARXIV.1802.03426>
- Nikolenko, S. I., Koltcov, S., & Koltsova, O. (2017). Topic modelling for qualitative studies. *Journal of*

- Information Science*, 43(1), 88–102.
https://doi.org/10.1177/0165551515617393
- Oğuzlar, A. (2007). Analitik hiyerarşi süreci ile müşteri şikayetlerinin analizi. *Akdeniz İİBF Dergisi*, 7(14), 122–134.
- Oly Ndubisi, N., & Yin Ling, T. (2006). Complaint behaviour of Malaysian consumers. *Management Research News*, 29(1/2), 65–76.
https://doi.org/10.1108/01409170610645457
- Özçınar, H., & Öztürk, T. (2022). Eğitim bilimleri çalışmalarında kullanılan ağ yaklaşımının kavramsal haritalanması. *Pamukkale University Journal of Education*.
https://doi.org/10.9779/pauefd.1087757
- Reimers, N., & Gurevych, I. (2019). Sentence-BERT: Sentence embeddings using siamese BERT-Networks (Version 1). *arXiv*.
https://doi.org/10.48550/ARXIV.1908.10084
- Richins, M. L. (1983). Negative word-of-mouth by dissatisfied consumers: a pilot study. *Journal of Marketing*, 47(1), 68–78.
https://doi.org/10.2307/3203428
- Salmi, S., Mérelle, S., Gilissen, R., van der Mei, R., & Bhulai, S. (2022). Detecting changes in help seeker conversations on a suicide prevention helpline during the COVID-19 pandemic: in-depth analysis using encoder representations from transformers. *BMC Public Health*, 22(530).
https://doi.org/10.1186/s12889-022-12926-2
- 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. *Psychology and Marketing*, 39(2), 441–459.
https://doi.org/10.1002/mar.21608
- Sann, R., Lai, P.-C., Liaw, S.-Y., & Chen, C.-T. (2021). Modelling online complaining behaviour in the hospitality industry: An application of data mining algorithms. *APacCHRIE 2021 Conference*, 2-4 June 2021, Singapore, pp. 699–702.
- Sarı, F. Ö., Alikılıç, Ö., & Onat, F. (2013). E-Complaining: Analysis of lodging customers' e-complaints from a Turkish internet website. *ICIBET-2013, International Conference on Information, Business and Education Technology*, 14-15 March 2013, Beijing, China, pp. 561–565. https://doi.org/10.2991/icibet.2013.183
- Tanrısever, C. (2018). Paket tur satın alan müşterilerin şikâyet analizi. *Turizm Akademik Dergisi*, 5(1), 114–123.
- Taşar, D. E., Ozan, Ş., Özdil, U., Akça, M. F., Ölmez, O., Gülüm, S., Kutal, S., & Belhan, C. (2021). Kısa konuşma cümlelerinin dönüştürücü yöntemleriyle otomatik etiketlenmesi. *ASYU, 2021 Akıllı Sistemlerde Yenilikler ve Uygulamaları Konferansı*, 6-8 Ekim 2021, Elazığ, Türkiye.
https://doi.org/10.1109/asyu52992.2021.9598957
- Yakut Ayman, Ş. (2011). Yerli turistlerin internet ortamındaki şikayetlerinin satınalma kararlarına etkileri. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 14(25), 218–238.
- Yang, Y., Xu, D.-L., Yang, J.-B., & Chen, Y.-W. (2018). An evidential reasoning-based decision support system for handling customer complaints in mobile telecommunications. *Knowledge-Based Systems*, 162, 202–210.
https://doi.org/10.1016/j.knosys.2018.09.029
- Zhunis, A., Lima, G., Song, H., Han, J., & Cha, M. (2022). Emotion bubbles: Emotional composition of online discourse before and after the COVID-19 outbreak. *WWW '22, ACM Web Conference*, 25-29 April 2022, Virtual Event, Lyon, France, pp. 2603–2613.
https://doi.org/10.1145/3485447.3512132



© 2019 & 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY NC) license.
(https://creativecommons.org/licenses/by-nc/4.0/).

EXTENDED ABSTRACT

Customer complaint is a customer behaviour that occurs as a result of failing to meet customer expectations and that provides information about the sale of products or services to the business. Complaints are usually made in the form of product replacement, repair and return due to any problem about the purchased product, or employee discourtesy, inappropriate physical environment, delays in sales and non-supply of the product. Businesses should not regard customer complaints as a problem, and the analysis of complaints should be considered as an opportunity to correct past mistakes, protect their brand value and acquire new customers. There are various methods for the analysis of complaint data; however, as data size increases, the utilisation of machine learning techniques to classify and predict data provides an advantage to decision makers in terms of time and cost. In recent years, numerous supervised and unsupervised machine learning techniques have been employed to solve different problems. The BERT model, a converter-based structure, has gained importance in natural language processing research. Therefore, in the study, BERTopic, a contemporary approach to topic modelling, was adopted to investigate the distribution of customer complaints in general and by distinct subjects. BERTopic is an up-to-date approach to support dynamic topic modelling, leveraging class-based TF-IDF, using pre-trained language models without initially specifying the number of classes. Furthermore, in this model, UMAP is used to reduce the size of the embeddings, the HDBSCAN algorithm is used to cluster these embeddings and create semantically similar document clusters. Notwithstanding the limited number of studies on BERTopic topic modelling technique in the literature, past research has shown that this technique produced successful results. In this study, 7743 complaints submitted to a consumer electronics retail company operating in Turkey in 2020 were used as data source. Complaint data was obtained from *sikayetvar.com* one of Turkey's leading complaints websites by data scraping and complaint and date parts of the data were used. Prior to classification, the text data was cleaned of stop words and punctuation and then converted to lowercase. In the model, n-gram was chosen as (1,2), taking into account the noun phrases frequently used in Turkish. Sometimes, outliers in the classification results can be encountered at a high rate among all topics. To avoid this, the probabilities were calculated, and the probability threshold was set at 0.01. Thus, by calculating the probability of a document belonging to any topic, after training the model, outliers can be assigned to a topic with a high probability, reducing the number of outliers. After classification, 58 different topics that were obtained emerged as mostly product-based complaints. According to the results, the majority of the complaints focused on shipping, television, mobile phone, laptop, headset, tablet, store employees, and order cancellation. In addition, the monthly variation of complaints was examined via dynamic topic modelling. According to the dynamic topic modelling results, there is a noticeable increase in complaints about television, mobile phones, laptop computers, headphones, and shipping, especially between April and June. At the same time, a decrease is observed in employee complaints in May. This is attributed to the decrease in the number of customers conducting their shopping at stores due to the lockdown during the COVID-19 pandemic. Moreover, the increase in laptop complaints in September is a sensible finding, given that distance education was resumed in the 2020-2021 academic year. In addition, a word-based analysis of the monthly variation in the topics showed that, while complaints about the return and replacement of headphones stood out in June, August, October and December, warranty complaints for mobile phones were prevalent in March and August. The method adopted in this study can also be implemented for stored or continuously streaming data. Therefore, this study will enable businesses to instantly obtain new information about customer complaints and produce quick solution suggestions, especially in the analysis of constantly flowing data. Furthermore, it is of critical importance in terms of enabling businesses to analyse data efficiently and quickly, periodically and cyclically, by making use of unsupervised machine learning techniques. The difference of the BERTopic technique from supervised learning techniques is its ability to analyse through the labels it produces based on the representations of the inputs within themselves, without the need for pre-labelling. Creating labelled data in supervised machine learning is a costly and time-consuming process. This study shows that useful and usable information can be extracted quickly without a considerable need for pre-processing. Considering that this is the first study for Turkish adopting the BERTopic technique, it will be useful to utilise guided or semi-supervised models and to employ Principal Component Analysis (PCA) for dimension reduction or k-means for clustering, in future studies. In addition, the usability of the model must be assessed via different Turkish data sets.