



Araştırma Makalesi  
Research Article

Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi  
Yıl: 2022 Cilt-Sayı: 15(4) ss: 998–1022

Academic Review of Economics and Administrative Sciences  
Year: 2022 Vol-Issue: 15(4) pp: 998–1022

<http://dergipark.org.tr/tr/pub/ohuiibf>

ISSN: 2564-6931

DOI: 10.25287/ohuiibf.1149801

Geliş Tarihi / Received: 16.09.2022

Kabul Tarihi / Accepted: 16.09.2022

Yayın Tarihi / Published: 24.10.2022

## VERİ VE METİN MADENCİLİĞİ İLE HAVA YOLU İŞLETMELERİNİN COVID-19 ÖNCESİ VE SONRASI SOSYAL MEDYA YORUM VE SKORLARININ DEĞERLENDİRİLMESİ

İbrahim BUDAK <sup>1</sup>

Arzu ORGAN <sup>2</sup>

### Öz

Veri ve metin madenciliği, anlamlı ilişkileri ve eğilimleri ayırt etmek için kullanıcıların taleplerine göre yapılandırılmış, yarı yapılandırılmış ve yapılandırılmamış büyük bir veri miktarını analiz etme sürecidir. İşletmeler, veri ve metin madenciliği teknikleri kullanarak hem kendi işletmeleri içerisinde hem de rakipleri ile rekabette yaşadıkları sorunlarına etkili çözümler üretebilmektedirler. Böylece elde ettikleri bilgiyi rekabet avantajına çevirebilmektedirler. Bu çalışmada, veri ve metin madenciliği algoritmaları kullanılarak rekabete dayalı pazarda müşterilerin istek ve ihtiyaçlarına göre hava yolu firmalarının üstün ve zayıf yönlerinin değerlendirilmesi amaçlanmıştır. Bu çalışmada, sosyal medya sitelerinden olan TripAdvisor'daki çevrimiçi seyahat incelemeleri araştırma kapsamına alınmıştır. Star Alliance küresel hava yolu birliğine üye 26 hava yolu firması değerlendirilmiştir. Çalışmada kullanılan kriterler; her bir kullanıcının yorum ve skorları temel alınarak belirlenmiştir. Duygu Analizi ile müşteri yorumlarından polariteleri belirlendikten sonra Destek Vektör Makineleri, Naive Bayes, Derin Öğrenme Algoritmaları ile sınıflandırma ve tahminleme yapılarak elde edilen sonuçlar karşılaştırılmıştır. Bunun yanı sıra sonuçlar, Covid-19 pandemisi öncesi ve sonrası olarak da karşılaştırılmıştır. Yapılan karşılaştırmada Derin Öğrenmenin daha iyi sonuç verdiği saptanmıştır.

**Anahtar kelimeler** : Veri ve Madenciliği, Hava Yolu, Destek Vektör Makineleri, Naive Bayes, Derin Öğrenme

**JEL Sınıflandırılması** : C52, C53, C8, M1

<sup>1</sup> Dr. Öğr. Gör., Kastamonu Üniversitesi, ibrahimbudak04@gmail.com, ORCID: 0000-0001-7762-6114.

<sup>2</sup> Prof. Dr., Pamukkale Üniversitesi İktisadi ve İdari Bilimler Fakültesi, aorgan@pau.edu.tr, ORCID: 0000-0002-2400-4343.

### Atıf/Citation (APA 6):

Budak, İ., & Organ, A. (2022). Veri ve metin madenciliği ile hava yolu işletmelerinin COVID-19 öncesi ve sonrası sosyal medya yorum ve skorlarının değerlendirilmesi. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(4), 998–1022. <http://doi.org/10.25287/ohuiibf.1149801>.

# EVALUATION OF SOCIAL MEDIA COMMENTS AND SCORES OF AIRLINE COMPANIES BEFORE AND AFTER COVID-19 WITH DATA AND TEXT MINING

## Abstract

Data and text mining is the process of analyzing a large amount of semi-structured, unstructured and structured data based on users' demands to distinguish meaningful relationships and trends. By using the data and text mining techniques, companies can produce effective solutions to the problems within their business and with their competitors. Thus, they can turn this information into competitive advantage. In this study, it is aimed to evaluate the strengths and weaknesses of airline companies in competitive market according to the demands and needs of customers through using the data and text mining algorithms. In this research, online user reviews on TripAdvisor which is one of the social media sites was included in this research. 26 airlines which are the members of Star Alliance Global Airline Association were evaluated. The criteria used in this research was determined based on the comments and scores of each user. After determining the polarities from customer comments with Sentiment Analysis, the results obtained by classification and estimation with Support Vector Machines, Naive Bayes, Deep Learning Algorithms were compared. In addition, the results were compared before and after the Covid-19 pandemic. In the comparison made, it was determined that Deep learning gives better results.

**Keywords** : Data and Mining, Airline, Support Vector Machines, Naive Bayes, Deep Learning

**JEL Classification** : C52, C53, C8, M1.

## GİRİŞ

Dünya ekonomisinde ulaşım sektörü önemli bir konuma sahiptir. Katma değeri yüksek ve ulaşım sektöründe stratejik bir öneme, ülkelerin refah düzeyine ulaşmasında ve rekabet gücünde etken bir güce sahip olan hava yolu şirketleri bütün dünyadaki ekonomik büyümeyi, küreselleşmeyi ve liberalleşmeyi geliştirmektedir. Dünya hava yolu trafiği, 2002 yılından beri ücretli yolcu/km açısından %49 oranında artış göstermiştir. Son yıllarda Türkiye’de hava yolu taşımacılığı daha hızlı gelişmekle birlikte %20'lere varan artışlar ile büyümeye devam etmektedir. Ülkemizdeki bakanlıkların siyasi çabaları sonucunda son on yedi yılda hava yolu şirketlerinin uçak sayısı %237, koltuk kapasitesi %276, kargo kapasitesi %659 artmış, yurt içi ve yurt dışı uçulan nokta sayısı 384'e ulaşmıştır (Sivil Havacılık Genel Müdürlüğü, 2021).

Hava yolu taşımacılığında pazar payının artması ile birlikte hava yolu taşımacılığında yoğun bir rekabet söz konusudur. Bu bağlamda hava yolu şirketleri müşteri için en iyi hizmeti sunmak istemektedirler. Müşteriler, hava yolu şirketlerinin sunduğu en iyi hizmetlerden ve fırsatlardan yararlanmak için çevrim içi müşteri değerlendirmelerine önem vermektedirler. Yapılan bu değerlendirmeler doğrultusunda müşteriler kendilerine en uygun olan hava yolu şirketini seçebilmektedirler. Müşteri değerlendirmelerinin tamamına ulaşmak ve bir arada ele alıp karar vermek için modern teknolojik yöntemlere ihtiyaç duyulmaktadır.

Teknolojik ilerleme ile büyük miktarda verinin verimli bir şekilde depolanmasını ve alınmasını sağladığını göz önünde bulundurarak, artık mevcut odak noktası artık bilgi edinilmesi ve ham kaynaklardan bilgi yaratma yöntemlerine odaklanması olduğu bilinmektedir. Çevrim içi siteler büyük veri bağlamında gelişmekte olan zorlu bir sektörü temsil etmektedir. İnsanların doğal dil ifadeleri kısa metin mesajları ile kolayca raporlanabilir, karar vermek için eyleme geçirilebilir bilgi oluşturmak için etkili bir şekilde analiz edilmesi gereken büyük boyutlarda benzersiz içerikler hızla oluşturulabilir.

Bilgi ve iletişim teknolojilerindeki gelişmelere paralel olarak, insanların çoğu tüm işlemlerini internet tabanlı bir sistemde gerçekleştirmeye başlamıştır. Bu durumda çoğu insan için, çevrim içi olarak daha fazla iş yapılmasıyla birlikte yeni yaşam tarzları oluşmaktadır. Örneğin, bir müşteri çevrim içi bir ürün satın alması durumunda ürün hakkında duygu ve düşüncelerini belirten bir inceleme notu bırakabilir. Bu söz konusu inceleme notları, ürünler, filmler ve tatiller gibi birçok farklı alanlar için kullanılabilir. Günümüzde bu müşteri tarafından yapılan değerlendirmeler ürün veya hizmetlerle ilgili görüşleri ifade etmenin popüler bir yoludur ve ayrıca kişi ürün ve hizmetler hakkında diğer görüşleri inceleyerek bilgi edinmesi söz konusudur. Bu, yalnızca genel bir derecelendirme ile etiketlenmiş olan inceleme miktarında bir artışa neden olmaktadır. İncelemeleri bütünüyle elde etmek ve değerlendirmek için veri ve metin madenciliği tekniklerinden yararlanılmaktadır. Bu teknikler her müşterinin yaptığı incelemeye ulaşmada kullanılarak analiz edilmesinde fayda sağlamaktadır. Aynı zamanda incelemeleri analiz etmekte kullanılan teknikler araştırmacıya bir öngörü sunmaktadır.

İnceleme sitelerinde yer alan müşteri değerlendirmeleri, ürün veya hizmetin farklı yönlerine yönelik görüşler de dâhil olmak üzere, genel bir derecelendirmeden çok daha faydalı bilgiler içermektedir. Bir film incelemesi, genel olarak 5 yıldıza sahip olabilir, ancak eleştirmen yine de özelliklerinden birine karşı olumsuz bir duygu ifade edebilir. Mevcut tüm değerlendirmeleri okumak çok zaman alabilmektedir ve karşılaştırma yapmak zor olabilir. Bu nedenle, müşteri değerlendirmelerinin otomatik olarak sınıflandırılması, yönlerinin ve duyarlılığının algılanması, karşılaştırma yapılmasına ihtiyaç duyulmaktadır. Dolayısıyla, veri/metin madenciliğindeki algoritmaların kullanımı bu çerçevede yardımcı olmaktadır.

Veri/metin madenciliği teknikleri ile rekabete dayalı müşterilerin istek ve ihtiyaçlarına göre hava yollarını değerlendirmeye yönelik bu araştırmada, sosyal medya seyahat inceleme web sitesi olan TripAdvisor'daki çevrimiçi müşteri incelemeleri araştırma kapsamına alınmıştır. TripAdvisor, küresel internet trafiğinde ve son 90 gündeki etkileşimde 396. sıradadır (Alexa, 2020). Bu değerlendirmeler doğrultusunda veri/metin madenciliğinde kullanılan algoritmalar ile Star Alliance küresel havacılık sektörünün 26 üye hava yollarının karşılaştırılması yapılmıştır. Değerlendirmede veri/metin madenciliği tekniklerinden Duygu Analizi, Destek Vektör Makineleri, Naive Bayes ve Derin Öğrenme kullanılmıştır. Duygu Analizi ile müşteri değerlendirmeleri analiz edilerek polarite (pozitif, negatif, nötr) etiketleri çıkarılmıştır. Yapılan analizlerde Covid-19 öncesi ve sonrası sonuçlar karşılaştırılmıştır.

## I. LİTERATÜR TARAMASI

Literatürde Duygu Analizi, Destek Vektör Makineleri, Naive Bayes Algoritması ve Derin Öğrenme ile ilgili önde gelen çalışmaların bazıları aşağıdaki gibidir:

Kharde ve Sonawane (2016) tarafından yapılan çalışmada, Twitter verilerinin Duygu Analizi için bir teknik araştırma ele alınmıştır. Bu çalışma esas olarak, görüşlerin oldukça yapılandırılmamış, heterojen olduğu ve bazı durumlarda pozitif, negatif veya nötr olduğu tweetlerdeki bilgileri analiz etmeye yardımcı olan Twitter verilerinin Duygu Analizine odaklanmaktadır. Çalışma sonucunda, Naive Bayes, Maksimum Entropi ve DVM gibi çeşitli makine öğrenme algoritmaları kullanılarak, Twitter veri akışları hakkında performans karşılaştırması yapılmıştır (Kharde & Sonawane, 2016: 5–15).

Kuhamanee ve ark. (2017) tarafından yapılan çalışmada, çevrim içi sosyal ağlar üzerinden veri madenciliği yaklaşımını kullanarak Tayland, Bangkok'a yabancı turistlerin duyarlılığını analiz etmektedir. 2017 yılında Twitter'dan 10.000 veri seti kullanılarak İngilizce dili esas alınmıştır. Bangkok'u ziyaret etmek için gelen kişiler seyahat, iş, aile ziyareti, eğitim ve sağlık, tedavi olarak beş kategoride sınıflandırılmıştır. Ardından metindeki duygulara yönelik etiketler çıkartıldıktan sonra Karar Ağacı, Naive Bayes, DVM ve YSA ile test edilip analiz edilmiştir. RapidMiner uygulaması ile yapılan analiz sonucunda en yüksek doğruluğa sahip algoritmaların YSA (%80,33) ve DVM (%80, 11) olduğu görülmüştür (Kuhamanee ve ark., 2017: 1068–1073).

Povoda ve ark. (2016) tarafından yapılan çalışmada, DVM ve büyük verilere dayalı Duygu Analizi yapılmıştır. Metin belgelerine dayanan bu çalışmada birden fazla web sayfasında yer alan farklı ürün segmentinde geri bildirimler otomatik olarak elde edilmiştir. İngilizce, Almanca, Çekçe ve İspanyolca olmak üzere farklı dillerdeki metin verileri derlenmiştir. İlgili metinler Duygu Analizi ile pozitif ve negatif olarak etiketlenmiştir. Ardından Makine Öğrenme Algoritmalarından DVM ile 7000 örnek eğitilip test edilmiştir. Her bir dil için test sonucunda elde edilen başarı %86'nın üstünde olduğu görülmüştür (Povoda, Burget, Dutta, 2016: 543–545).

BholaneSavita ve Gore (2016) tarafından yapılan çalışmada, DVM kullanarak Twitter verilerinde Duygu Analizi incelenmiştir. Çalışmada, E-ticaretin en önemli kısımlarından biri Duygu Analizi olarak gösterilmektedir. Bu çalışmada, Twitter kullanılarak Duygu, LDA (Latent Dirichlet Allocation) ve DVM analizleri yapılmıştır. Duygu Analizinden çıkarılan pozitif ve negatif etiketlerin yanı sıra, LDA ile Duygu Analizdeki değişimlerin arkasındaki nedenler araştırılmıştır. Son olarak, DVM analiz ile Duygu Analizinden çıkan etiketler eğitilip test edilmiştir. Test sonucunda başarı %97,54 olarak bulunmuştur (BholaneSavita & Gore, 2016: 365–370).

Harisinghaney ve ark. (2014) tarafından çalışmada, KNN, Naive Bayes ve Reverse DBSCAN algoritmaları kullanılarak metin ve görüntü tabanlı spam e-posta sınıflandırması yapılmıştır. Çeşitli e-posta sağlayıcıların e-postaları, spam ve jambonlara göre filtrelemek için algoritmalar kullanılmaktadır. Bu çalışmada, Enron veri kümesindeki e-postalar ve spamlar ele alınmıştır. KNN (%83), Naive Bayes (%87) ve Reverse DBSCAN (%74) algoritmalarının doğruluk oranlarının tatmin edici olduğu görülmüştür (Harisinghaney, Dixit, Gupta, Arora, 2014: 153–155).

An ve ark. (2017) tarafından yapılan çalışmada, şarkı sözlerine dayalı duygu sınıflandırması için Naive Bayes Algoritması tercih edilmiştir. Çalışmada, Baidu müzik adlı popüler bir web sitesi üzerinden dört farklı veri seti şeklinde toplam 3316 şarkı sözü derlenerek dört farklı sınıflandırma etiketi kullanılmıştır. Metin sınıflandırma yöntemlerinden algoritmalarından birisi olan Naive Bayes Algoritması ile veriler eğitilip test edilmiştir. Çalışmanın sonucunda her bir sınıflandırma ile elde edilen başarının %60'nın üstünde olduğu görülmüştür (An, Sun, Wang, 2017: 635–638).

Day ve Lin (2017) tarafından yapılan çalışmada, Google Play tüketici incelemesinde Duygu Analizi için Derin Öğrenme ele alınmıştır. Çince Google Play tüketici incelemeleri ele alınmıştır. Google Play'de 196.651 yorumu toplamak için bir web madenciliği tekniği uygulanmıştır. Çalışmanın sonucunda Duygu Analizi için DVM, Naive Bayes ve bir Derin Öğrenme Algoritması kullanılarak başarı oranları karşılaştırılmıştır. En iyi performansı Derin Öğrenmenin Algoritmasının verdiği görülmüştür (Day & Lin, 2017: 382–388).

Zhang ve ark. (2018) tarafından yapılan çalışmada, Derin Öğrenmeye genel bir bakış açısı sunarak Duygu analizindeki uygulamalar için bir araştırma yapılmıştır. Yapılan araştırmanın sonucunda, Derin Öğrenme Algoritmalarının birçoğu, Duygu Analizi için en gelişmiş sonuçları verdiği gözlemlenmiştir. Yakın gelecekte Derin Öğrenme konusundaki ilerlemelerle Duygu Analizi için heyecan verici çalışmalar verilebileceği öngörülmüştür (Zhang, Wang, Liu 2018: e1253).

Tsao ve ark. (2019). TripAdvisor kullanıcılarının Duygu Analizi ile incelenmesi ilgili yaptığı çalışmada, Gözden Geçirme değerleri ile derecelendirme arasındaki ilişki incelenmiştir. Asimetrik bir ilişki var mı? Çalışma, marka gücünü, önemli bir moderatör rolü olarak görmektedir. Çalışmanın amacı, yorumun içeriği ile derecelendirme arasındaki asimetrik bir ilişkinin marka gücüne bağlı olacağını iddia etmektir. Çalışmanın sonucunda; “Güçlü bir marka için negatif içeriğin sayısal değeri, pozitif içeriğin sayısal değerinden daha büyüktür. Zayıf bir marka için ise, pozitif içeriğin sayısal değeri, negatif içeriğin sayısal değerinden daha büyüktür” şeklinde bilgiler elde edilmiştir (Tsao, Chen, Lin, Ma, 2019: 283–300).

Karamanlı (2019). Metin madenciliği ve Duygu Analizi ile müşteri deneyiminin Makine Öğrenme Algoritmaları kullanılarak geliştirilmesi ile ilgili çalışmada, E-ticaret sitelerinin birinden en çok satılan üç marka akıllı cep telefonu ile ilgili değerlendirmeler alınıp metin madenciliği ile fikir veya duygu barındırıp barındırmadığı ve olumlu-olumsuz yorumlar olup olmadığı saptanmıştır. Veri seti

eğitim ve test veri seti olarak ayrılıp, Makine Öğrenmesi sınıflandırma algoritmalarıyla yapılacak yeni yorumun Duygu Analiz sonucu tahmin edilmiştir. DVM (%74,19), Naive Bayes (%67,52) ve KNN Algoritmaları (%81,45) kullanılmıştır. Pozitif ve negatif yorum tahminlemesi yapılmıştır (Karamanlı, 2019: 1–65).

## II. METODOLOJİ

### II.I. Veri ve Metin Madenciliği ile Sınıflandırma ve Tahminleme

Veri madenciliği, mevcut veritabanlarından anlamlı öngörülerin deşifre edilmesi ve işletme kullanıcıları tarafından tüketilmek üzere sonuçların analiz edilmesi süreci olarak tanımlanabilir. Çeşitli kaynaklardan gelen verileri analiz etmek ve anlamlı bilgiler halinde özetlemek, istatistiksel bilgi keşfinin bir parçasıdır. Bu durum sadece işletme kullanıcılarına değil, aynı zamanda istatistiksel analistler, danışmanlar ve veri bilimcileri gibi birden fazla topluluğa da yardımcı olmaktadır. Çoğu zaman, veritabanlarından bilgi keşif süreci beklenmedik sonuçlar çıkarabilir ve bu sonuçlar birçok farklı şekilde yorumlanabilir. Artan sayıda cihaz, tablet, akıllı telefon, bilgisayar, sensör ve diğer çeşitli dijital cihazlar, veri üretmek ve her zamankinden daha hızlı bir şekilde veri toplamaya yardımcı olmaktadır. Günümüz bilgisayarlarının kabiliyetiyle, artan veriler, herhangi bir işin karar verme süreciyle ilgili çeşitli soruları cevaplamak için önceden işlenebilir ve modellenir. Veri madenciliği, istatistiksel metodolojiler, makine öğrenme teknikleri, görselleştirme ve örüntü tanıma teknolojileri kullanılarak ayrık veri tabanları ve bilgi havuzları arasında bilgi yoğun bir arama olarak ortaya çıkmaktadır (Makhabel, Mishra, Danneman, Heimann, 2017: 8).

Bilgi yoğun bir arama olan veri madenciliği teknikleri problemler için karar desteği sağlayabileceği gibi metin madenciliği teknikleri de karar desteği sağlamak adına iyi ve öngörülebilir interaktif yazılımlar kullanmaktadır. Bunun yanı sıra, metin madenciliği gelecekteki eğilimlerin başarılı bir tahmin yapılması konusunda önemli adımlar atmaktadır. Şöyle ki, metin madenciliği teknikleri bilgiyi daha verimli kullanarak, pazarda meydana gelen değişiklikleri, pazardaki ürünün düşük veya yüksek performansı ile ilgili önleyici kararlar alarak iş zekâsı ile koordine çalışmaya olanak tanımaktadır. Bu bağlamda, metin madenciliği, işletme yönetiminin optimum kararlar verebilmesinde satış, istihdam memnuniyeti, pazarlama stratejisi, rekabet yarışında üstünlük sağlayabilmesi gibi birçok açıdan avantajlar sağlayabilmesi için tasarlanmıştır (Melek, 2012: 33).

### II.II. Duygu Analizi

Fikir madenciliği olarak da adlandırılan Duygu Analizi, kişilerin yazılı metinlerde ifade edilen varlıklara yönelik fikirleri, duyguları, değerlendirmeleri, tutumları ve duyguları analiz eden çalışma alanıdır. Varlıklar; ürünler, hizmetler, kuruluşlar, bireyler, etkinlikler, sorunlar veya konular olabilir. Bu alan, geniş bir problem alanını temsil etmektedir. Fikir madenciliği, fikir analizi, fikir çıkarma, öznellik analizi, etki analizi ve inceleme madenciliği artık Duygu Analizi çatısı altındadır. Duygu Analizi terimi ilk olarak Nasukawa ve Yi'de (2003), fikir madenciliği terimi önce Dave ve ark. (2003) tarafından ortaya atıldığı bilinmektedir (Liu, 2015: 1–3). Nasukawa ve Yi çalışmasında, Duygu Analizini duygu ifadeleri, duygu ifadelerinin kutupluğu ve gücü, duygu ifadelerinin konu ile ilişkisinin olduğunu ortaya koymuşlardır. Örneğin, "XXX YYY'yi yener" cümlesinde, "yener" ifadesi XXX'e karşı olumlu bir duygu ve YYY'ye karşı olumsuz bir duygu anlamına gelir. Bu örnek çerçevesinde Duygu Analizinin temeli atılmıştır (Hogenboom ve ark., 2013: 706–707). Dave ve ark. çalışmasında ise, yakınlık ölçüleri ve kelime listelerini kullanarak verileri şablonlara sığdırmak ve kullanıcı görüşlerini modellemek için ortaya koymuşlardır (Nasukawa & Yi, 2003: 71). Ancak, duygu ve fikir madenciliğine yönelik araştırmalar daha önce başlamıştır. Yıllar geçtikçe, web'deki sosyal medya sistemleri yeni katılımcılarla birlikte birçok platform oluşturmakta ve gelişmektedir. YouTube, Facebook ve Twitter başta olmak

üzere birçok farklı blog ve forumlara kullanıcılar tarafından görüşler yazılmaktadır. Duygu Analizi bu görüşlerin nasıl işlenip yarar sağlayacağı konusunda fikir vermektedir (Liu, 2015: 1–3).

Duygu Analizi skoru belirlenmeden önce cümle içerisinde geçen duygu ifadeleri, duygu taşıyan sözcükler, duygu değişimleri bir dizi ön işlemde geçirilmektedir. Tespit edilebilecek aksan ve özel karakterler kaldırılmaktadır. Ardından duygu değişimine neden olabilecek kelime türleri belirlenmektedir. Duygu taşıyan kelimelerin ortalama duygu skorunu hesaplamak için sözcük tabanlı bir duygu skoru ile derecelendirme yapılmaktadır. Bu doğrultuda, bir ‘d’ belgesindeki ‘s<sub>i</sub>’ bölümündeki ‘i’. Duygu skoru, ‘s<sub>i</sub>’ bölümündeki her bir ‘e<sub>ij</sub>’ duygu ifadesinin duygu skor fonksiyonu ile hesaplanabilir. Ya da ‘s<sub>i</sub>’ bölümündeki her bir duygu taşıyan ‘w<sub>ij</sub>’ ve o duyguyu değiştiren ‘m<sub>ij</sub>’ (eğer bu değişken metinde bulunduğu da varsayılan olarak ‘1’ alınır) ile duygu skoru hesaplanabilir. Eşitlik 1’de bir metin bölümündeki duygu skoru formüle edilmiştir.

$$sent(s_i) = \begin{cases} \frac{\sum_{j=1}^{v_i} sent(e_{ij})}{v_i} & \text{if } v_i > 0, \\ \frac{\sum_{j=1}^{t_i} (sent(w_{ij}).sent(m_{ij}))}{t_i} & \text{else (varsa),} \end{cases} \quad (1)$$

Burada; ‘v<sub>i</sub>’: metin bölümündeki duyguyu ifade eden görsel (emoji) ipucuların sayısını; ‘t<sub>i</sub>’: metin bölümündeki duygu taşıyan metinsel ipucu sayısını göstermektedir.

Her bir metin bölümü tarafından iletilen duygu skoru belirlendikten sonra, tüm metin bölümleri tek bir belgede yeniden birleştirilir. Dokümanın duygu skoru daha sonra tüm bölüm seviyesinde duygu skorlarının ağırlıklı ortalaması alınarak hesaplanmaktadır. Burada ağırlıklar ilgili bölümdeki duygu taşıyan kelime veya ifadelerin sayısının nispi oranlarına karşılık gelmektedir. Böylelikle bir ‘d’ dokümanı için duygu skoru Eşitlik (2)’deki gibi hesaplanmaktadır.

$$sent(d) = \frac{\sum_{i=1}^p (sent(s_i).(v_i+(a_i.t_i)))}{\sum_{i=1}^p (v_i+(a_i.t_i))} \quad (2)$$

Burada; ‘p’: d belgesindeki bölüm sayısını; ‘a<sub>i</sub>’: s<sub>i</sub> metin bölümünün ipucuları üzerinde tam bir Duygu Analizi yapılmasının gerekli olup olmadığını belirten bir Boolean değişkenini (0 veya 1) ifade etmektedir. Eşitlik (3), Boolean değişkenini göstermektedir.

$$a_i = \begin{cases} 0 & \text{if } v_i > 0, \\ 1 & \text{else.} \end{cases} \quad (3)$$

Böylece belgenin duygu skoru elde edilmektedir. Negatif bir puan tipik olarak negatif bir belgeyi ‘-1’ gösterirken, diğer puanlar ‘1’ pozitif bir sınıflandırma sağlamaktadır. Belgenin pozitif veya negatif sınıflandırma formülasyonu Eşitlik (4)’deki gibidir (Dave, Lawrence, Pennock, 2003: 520).

$$class(d) = \begin{cases} 1 & \text{if } sent(d) \geq 0, \\ -1 & \text{else.} \end{cases} \quad (4)$$

### II.III. Destek Vektör Makineleri

Destek Vektör Makineleri (DVM), 1992’de Vapnik ve arkadaşları tarafından hem regresyon hem de örüntü tanıma için uygulanan yeni bir evrensel öğrenme makinesi önerilmiştir. DVM, girdi alanındaki verileri, sorunun doğrusal olarak ayrılabilirliği yüksek boyutlu bir özellik alanına eşlemek için çekirdek (kernel) eşleme adı verilen bir aygıt kullanmaktadır. Bir DVM’nin karar fonksiyonu sadece destek vektörlerin sayısı ve ağırlıkları ile değil, destek vektörü kernel olarak adlandırılan “apriori” ile de ilgilidir (Zhang, Zhou, Jiao, 2004; 34). DVM temel bir Makine Öğrenme teknolojisidir. Güçlü teorik temelleri ve mükemmel ampirik başarılarla sahiptir. El yazısı karakterler, basamak tanımlama, nesne tanıma ve metin sınıflandırma gibi görevlere uygulanmıştır (Tong & Chang, 2001: 108).

DVM, istatistiksel öğrenme teorisine dayanır ve örüntüleri tanıma yeteneğine sahiptir. DVM, yapısal risk minimizasyonu çerçevesinde ve Vapnik-Chervonenkis (VC) sınırları teorisinde yeni öğrenme tekniklerini temsil etmektedir. DVM, sınıflandırma, regresyon, zaman serisi tahmini ve fonksiyon tahmin problemlerini çözmek için çeşitli uygulamalarda başarıyla kullanılmaktadır. DVM ile yapılan sınıflandırma ve regresyon performansı diğer sınıflandırma ve regresyon tekniklerinden daha iyi olduğu görülmektedir. DVM’nin uygulanması, popüler bir DVM sınıflandırma ve regresyon yazılımı olan LIBSVM yazılımı kullanılarak gerçekleştirilmektedir (Terzic, Terzic, Nagarajah, Alamgir, 2013: 4–5).

DVM ile yapılan bir uygulamadaki veriler daha yüksek boyutları ile eşleştirilerek optimum bir ayırma köprüsü oluşturulur. Bu temelde sinir ağı mimarileri için birçok yerel minimum varlığı tanımda muzdarip iken DVM, kuadratik programlama problemlerinin çözülmesini mümkün kılmaktadır. İşlevler ve parametreler bir boyuttaki bağlantı sayısını minimize edecek şekilde seçilmektedir. Ardından yöntem, fonksiyonun tahmin problemini çözmek için genişletilmektedir. Bu amaçla, Vapnik’in epsilon duyarsız kayıp fonksiyonu ve Huber’in kayıp fonksiyonu kullanılmaktadır. Doğrusal durumun yanı sıra, polinomlara, spline'lara, radyal tabanlı fonksiyon ağlarına ve çok katmanlı algılayıcılara dayanan DVM'ler başarıyla uygulanmaktadır (Suykens & Vandewalle, 1999: 293).

### II. IV. Naive Bayes Algoritması

Naive Bayes Algoritması, veri boyutunun yüksek olduğu, kriterlerin bağımsız olduğu veya hesaplamaları basitleştirmek adına kriterlerin bağımsız varsayıldığı, diğer yöntemlere kıyasla daha verimli sonuçlar beklenildiği, büyük veritabanlarına uygulandığında yüksek doğruluk ve hız sağlanması istenildiği durumlarda tercih edilmektedir (Cherian & Bindu, 2017: 70). Bir sınıflandırma yöntemi olarak Naive Bayes, düşük sapma ile çalışabilen, yeni eğitim verileri elde edildikçe hızlı güncellenebilen, veri kümesindeki gürültüyü işleme yeteneği yüksek, veri kümesindeki eksik değerleri işleme yeteneği olan diğer sınıflandırma yöntemleri ile kıyaslandığında yüksek hesaplama verimliliği gibi özelliklerle atfedilmektedir. Ayrıca, Naive Bayes uygulamasında gerekli ayarlama parametreleri veya etki alanı bilgisi bulunmamaktadır. Naive Bayes'in en büyük dezavantajı sadece özelliklerin bağımsızlığı varsayımında yatmaktadır. Buna rağmen, yöntem genellikle rekabetçi sınıflandırma doğruluğu sağlar ve pratikte özellikle kıyaslama sonuçları olarak yaygın olarak uygulanmaktadır (Taha, Mustapha, Chen, 2013: 3).

Bayes Teoremi, belirli koşullu olasılıkların hesaplanmasına izin veren olasılık tabanlı bir sınıflandırma yöntemidir. Koşullu olasılıklar, bir olayın başka bir olayın olasılığı üzerindeki etkisini yansıtan olasılıklardır. Bayes teoreminde genellikle kullanılan terim, gerçek olasılık ve koşullu olasılıktır. Bir hipotez veya olayın önceki olasılığı, herhangi bir ek bilgiye ihtiyaç duyulmadığında elde ediliyorsa gerçek olasılıktır. Koşullu olasılık ise, elde edilen bazı ek bilgiler veya kanıtlar kullanılarak hipotezin gözden geçirilmiş olasılığıdır. Bayes teoremi Eşitlik (5)'deki gibi yazılabilir:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (5)$$

Burada:  $P(A)$ ,  $A$  olayının gerçekleşme olasılığı;  $P(B)$ ,  $B$  olayının gerçekleşme olasılığı;  $P(A \setminus B)$ ,  $B$  olayı gerçekleştiğinde  $A$  olayının gerçekleşme olasılığı;  $P(A \setminus B)$ ,  $A$  olayı gerçekleştiğinde  $B$  olayının gerçekleşme olasılığını göstermektedir.  $A$  hipotezi doğru veya yanlış olabileceğinden, Bayes teoremi Eşitlik (6)'deki gibi yazılabilir (Sharma, Singh, Singh, 2015: 705–706):

$$P(A \setminus B) = \frac{P(B \setminus A)P(A)}{P(B \setminus A)} * P(A) + P(B - A) * P(-A) \quad (6)$$

Naive Bayes sınıflandırıcıları, ister sürekli ister kategorik olsun, rastgele sayıda bağımsız değişkeni işleyebilir.  $X = (x_1, x_2, x_3, \dots, x_d)$  veri seti verildiğinde, bir dizi olası sonuç olan  $C = (c_1, c_2, c_3, \dots, c_d)$  veri seti arasından  $C_j$  koşullu olasılığını oluşturmak istenebilir. Daha açık bir ifade ile  $X$ , belirleyicidir ve  $C$ , bağımlı değişkende bulunan kategorik düzeyler kümesidir. Bu doğrultuda Bayes kuralı Eşitlik (7)'deki gibi oluşturulabilir.

$$p(C_j | x_1, x_2, \dots, x_d) \propto p(x_1, x_2, \dots, x_d | C_j) p(C_j) \quad (7)$$

Burada;  $p(C_j | x_1, x_2, \dots, x_d)$  sınıf üyeliğinin koşullu olasılığıdır. Bir başka deyişle,  $X$ 'in  $C_j$ 'ye ait olma olasılığıdır. Naive Bayes, bağımsız değişkenlerin koşullu olasılıklarının istatistiksel olarak bağımsız olduğunu varsaydığından, bir terimde yer alan ürünün olasılığını Eşitlik (8) ve koşullu olasılığını Eşitlik (9)'deki gibi ayrıştırabiliriz:

$$p(X | C_j) \propto \prod_{k=1}^d p(x_k | C_j) \quad (8)$$

$$p(C_j | X) \propto p(C_j) \prod_{k=1}^d p(x_k | C_j) \quad (9)$$

Yukarıdaki Bayes kuralını kullanarak, en yüksek koşullu olasılığa ulaşan  $C_j$  sınıfında yeni bir  $X$  durumu etiketlenebilir (Tripathi, Vishwakarma, Lala, 2015: 669).

Buna ek olarak Naive Bayes, metin sınıflandırmalarında iyi çalışma eğiliminde olan ve genellikle DVM gibi modellere kıyasla eğitilmesi için daha az zaman alan çok basit bir olasılıksal modeldir. Naive Bayes sınıflandırma, güçlü bağımsızlık varsayımı ile birlikte Bayes kuralına dayanmaktadır. Naive Bayes modeli, koşullu bir bağımsızlık varsayımı içermektedir. Bu varsayım, metin sınıflandırmasındaki doğruluğu çok fazla etkilememektedir. Ancak problem için hızlı sınıflandırma algoritmalarını uygulanabilir kılmaktadır. Naive Bayes'in metin sınıflandırma üzerindeki performansı Eşitlik (10)'de gösterilmektedir (Narayanan, Arora, Bhatia, 2013: 195).

$$P(x_i \setminus c) = \frac{\text{Count of } x_i \text{ in documents of class } c}{\text{Total no of words in documents of class } c} \quad (10)$$


Burada: *Count of  $x_i$  in documents of class  $c$* :  $c$  sınıfı belgelerde  $x_i$  sayısı;  
*Total no of words in documents of class  $c$* :  $c$  sınıfı belgelerdeki toplam kelime sayısını göstermektedir.



## II.V. Derin Öğrenme

Derin Öğrenme, çoklu işlem katmanlarından oluşan hesaplama modellerinin, çoklu soyutlama seviyesine sahip verilerin temsillerini öğrenmesine olanak tanımaktadır. Bu modeller görsel nesne tanıma, konuşma tanıma, nesne algılama ve ilaç keşfi gibi diğer birçok alandaki son teknolojiye uyarlanıp geliştirilmektedir. Derin Öğrenme, bir makinenin her katmandaki temsili yapıyı hesaplamak için kullanılan iç parametrelerin önceki katmandaki temsilindeki yapının nasıl değiştirmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfetmektedir. Derin evrimsel ağlar video, görüntü, konuşma ve sesin işlenmesinde önemli roller oynarken, tekrarlanan (recurrent) ağlar, metin ve konuşma gibi sıralı verilere ışık tutmaktadır (LeCun, Bengio, Hinton, 2015: 436).

Derin öğrenmenin içinde yer alan ileri beslemeli ağlar ise, iletişim ağı veya ağ olarak adlandırılmaktadır. Çünkü tipik olarak birçok farklı fonksiyonun bir araya getirilmesiyle oluşmaktadır. Model, fonksiyonların nasıl bir araya getirildiğini açıklayan yönlendirilmiş bir döngüsüz (çevrimsiz) grafik ile ilişkilidir. Örneğin,  $f(x) = f^{(3)}(f^{(2)}(f^{(1)}(x)))$  oluşturmak için bir zincire bağlı üç  $f^{(1)}$ ,  $f^{(2)}$  ve  $f^{(3)}$  fonksiyonuna sahip olduğunu düşünelim. Bu zincir yapıları sinir ağlarının en sık kullanılan yapılarıdır. Bu durumda,  $f^{(1)}$  ağın ilk katmanı olarak adlandırılır,  $f^{(2)}$  ikinci katman olarak adlandırılır ve bu böyle devam etmektedir. Zincirin toplam uzunluğu modelin derinliğini vermektedir. Bu terminolojiden, “Derin Öğrenme” adı doğmaktadır. İleri beslemeli bir ağın son katmanına çıktı katmanı denmektedir. İleri beslemeli sinir ağlarının çoğunda kullanılması tavsiye edilen etkinleştirme işlevi ‘Rectified doğrusal aktivasyon fonksiyonu’dur. Tavsiye edilen fonksiyon  $g(z) = \max\{0, z\}$  olarak tanımlanır ve Şekil 1’deki gibi gösterilmektedir (Goodfellow, Bengio, Courville, 168–175):



Şekil 1. Rectified Doğrusal Aktivasyon Fonksiyonu

Rectified Derin Öğrenme Ağları görüntü tanıma ve metin sınıflandırma görevlerinde çok daha iyi performans göstermektedir. Rectified fonksiyonunun matematiksel modeli Eşitlik (11)’de verilmektedir.

$$h^{(i)} = \max(w^{(i)T}x, 0) = \begin{cases} w^{(i)T}x & w^{(i)T}x > 0 \\ 0 & \text{else} \end{cases} \quad (11)$$

Rectified fonksiyonu 0’ın üzerinde etkinleştirildiğinde, kısmi türevi 1’dir. Bu doğrultuda, Rectified fonksiyonu tam olarak 0 ile doyurulmaktadır. Böylelikle fonksiyon, sınıflandırma yapılırken gizli katmana bağlanacak her giriş katmandaki kriterlere yardımcı olmaktadır (Maas, Hannun, Ng, 2013: 3–4). Son katmanda ise, Derin Öğrenmenin sınıflandırma problemlerine yönelik çözüm için ‘softmax’

fonksiyonu kullanılır. Softmax fonksiyonu  $\sum_{k=1}^K p_k$  olarak adlandırılan K sınıfları için ayrı bir olasılık dağılımı belirtir. Bir sinir ağının sondan bir önceki katmanında ‘x’ gibi bir aktivasyon ve softmax katmanındaki ağırlık parametrelerini ‘ $\theta$ ’ alındığında, softmax katmanının girişi Eşitlik 12’deki gibi gösterilebilir.

$$c = \sum_i^{n-1} \theta_i x_i \quad (12)$$

Tahmin edilecek sınıf için son olarak Eşitlik (13) ve Eşitlik (14) kullanılarak aşağıdaki gibi formüle edilebilir (Agarap, 2018):

$$p_k = \frac{e^{c_k}}{\sum_{k=0}^{n-1} e^{c_k}} \quad (13)$$

$$\hat{y} = \arg \max p_i \quad i \in 1, \dots, N \quad (14)$$

Rectified etkinleştirme fonksiyonu, bir ağın kolayca aralıklı (sparse) gösterimler elde etmesini sağlamaktadır. Örneğin, giriş katmanındaki ağırlıkların homojen olarak verilmesinden sonra, gizli katmandaki birimlerin yaklaşık % 50’si sürekli çıktı katmandaki birimlere gönderilerek sıfırlanmaktadır. Ardından bu katman (fraksiyon), aralıklı olarak (sparse) sonuç çıkartan düzenleme ile kolayca arttırılabilmektedir.

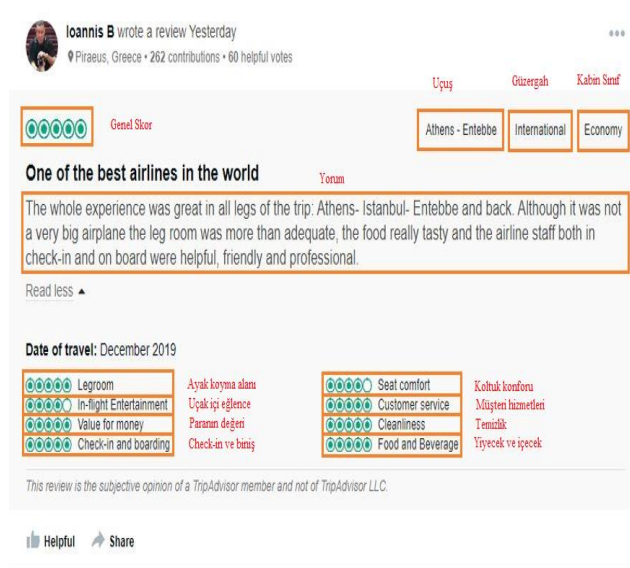
### III. UYGULAMA

Veri ve metin madenciliği ile hava yolu işletmelerinin sosyal medya yorum ve skorlarının covid-19 öncesi ve sonrasına yönelik değerlendirilme yapılmıştır. Değerlendirmede, çevrimiçi müşteri yorumlarından polarite ve polarite değerleri bulunarak veri/metin madenciliği algoritmaları ile sınıflandırılması ve tahmin edilmesi amaçlanmaktadır. Bu doğrultuda, dünyanın en büyük hava yolu topluluğu olan Star Alliance küresel hava yolu birliğinin 26 üye hava yolundan alınmış ve seyahat platformu olan TripAdvisor’da müşterilerin yaptığı yorumlar değerlendirilmiştir (Haddaway, 2015: 188). Alınan yorumların Duygu Analizi yapılarak polarite (pozitif, negatif veya nötr) etiketleri belirlenmiştir. Veri ve metin madenciliği algoritmalarından DVM, Naive Bayes, Derin Öğrenme ile polarite (sınıflandırma) performans değerleri belirlenmiştir. TripAdvisor’da incelenen hava yolları Tablo 1’de verilmiştir.

**Tablo 1. Star Alliance Hava yolu Üyeleri**

No	Hava Yolları	No	Hava Yolları
1	Aegean Airlines,	14	Eva Air
2	Air Canada	15	Air India
3	Air China	16	LOT Polish Airlines
4	Air New Zealand	17	Lufthansa
5	Ana Nippon Airways (ANA)	18	Scandinavian Airlines (SAS)
6	Asiana Airlines	19	Shenzhen Airlines
7	Austrian Airlines	20	Singapore Airlines
8	Avianca	21	South African Airways
9	Brussels Airlines	22	Swiss International Air Lines
10	Copa Airlines	23	Tap Portugal
11	Croatia Airlines	24	Thai
12	Egyptair	25	Türk Hava Yolları (THY)
13	Ethiopian	26	United Airlines

Tablo 1’deki tüm hava yollarına ilişkin TripAdvisor sitesinde Covid-19 öncesi 2020 yılına kadar yapılan toplam 197690 ve Covid-19 sonrası 2022 yılına kadar toplam 16028 müşteri yorumu incelenmiştir. Bu yorumların yanı sıra müşteriler tarafından yapılan farklı değerlendirme skorları araştırmaya dâhil edilmiştir. Bu değerlendirme kriterleri şunlardır: genel skor, ayak koyma alanı, koltuk konforu, uçak içi eğlence (wifi, tv, filmler vb.), müşteri hizmetleri, fiyat/fayda oranı (paranın karşılığı/değeri), temizlik, check-in ve biniş, yiyecek ve içecek’tir. Kriterlere verilen değerlendirme puanları 10-50 arasında değişmektedir. Şekil 2’de TripAdvisor’da bir müşteriye ait hava yolu değerlendirilmesi verilmiştir.



Şekil 2. Bir Müşteriye Ait Hava yolu Değerlendirmesi

Şekil 2’de TripAdvisor seyahat inceleme sitesinde hava yolu için değerlendirme yapan bir müşteriye ait değerlendirme verilmiştir. Müşterinin yaptığı yorumdan polarite etiketleri üretilerek DVM, Naive Bayes ve Derin Öğrenme Algoritmalarıyla analizler yapılmıştır.

Müşteri yorumlarının derlenerek veritabanına aktarılmasında WebHarvy 6.0.1.173 programı kullanılmıştır. WebHarvy, görsel bir web kazıma aracıdır. Verileri kazımak için kesinlikle herhangi bir komut dosyası veya kod yazmaya gerek yoktur. Web sayfalarında gezinmek için WebHarvy'nin yerleşik tarayıcısı kullanılabilir. Kazınacak veriler, fare tıklamaları ile seçilebilir (Liu & Cocea, 2017: 358). Kazınacak verileri kolay bir şekilde derlemek için ‘kurallı ifadeler (regular expression)’ kullanılmıştır. Bu kurallı ifadeler Tablo 2’de gösterilmiştir.

Tablo 2. Kurallı İfadeler

Kriterler	Kurallı İfadeler
Genel skor	bubble_{(\d)+}
Müşteri yorumu	wrote a review ([^<]*)</span>
Ayak koyma alanı	bubble_{(\d)+}[a-zA-Z </;:="]*Legroom
Uçak içi eğlence	bubble_{(\d)+}[a-zA-Z </;:="]*In-flight Entertainment
Paranın değeri	bubble_{(\d)+}[a-zA-Z </;:="]*Value for money
Check-in ve biniş	bubble_{(\d)+}[a-zA-Z </;:="]*Check-in and boarding
Koltuk konforu	bubble_{(\d)+}[a-zA-Z </;:="]*Seat comfort
Müşteri hizmetleri	bubble_{(\d)+}[a-zA-Z </;:="]*Customer service
Temizlik	bubble_{(\d)+}[a-zA-Z </;:="]*Cleanliness
Yiyecek ve içecek	bubble_{(\d)+}[a-zA-Z </;:="]*Food and Beverage

Yorum ve kriterlerin değerlendirilip analiz edilmesinde ise, açık kaynak kodlu RapidMiner 9.6.0 uygulaması kullanılmıştır.

Araştırmada, hava yolu firmaları için yapılan müşterilerin yorumları WebHarvy programı ile derlenmiştir. Yorumlar derlenirken ortak dünya dili olan İngilizce yorumlar baz alınmıştır. Edinilen veriler doğrultusunda 213718 müşteri yorumunun polaritesi etiketleri RapidMiner programında yer alan ‘Operator Toolbox’ aracı ile çıkarılmıştır. Çıkarılan polarite etiketlerine göre algoritmalarından çıkan sonuçlar analiz edilmiştir. Analiz yapılırken verilerin %70’i eğitim, kalan %30’u test için seçilmiştir. Veriler karıştırılmış örnekleme ile seçilmiştir (Hussein, Ali, Kasiran, 2012: 258).

### III.I. Hava Yollarının Duygu Analizi

TripAdvisor’dan edilen yorumlar baz alınarak Duygu Analizi ile her bir hava yolunun polaritesi (pozitif, negatif, nötr) ve polarite sayısı çıkarılmıştır. Tablo 3’te her bir hava yoluna ait Covid-19 öncesi polarite (pozitif, negatif ve nötr) yorum sayıları verilmiştir.

**Tablo 3. Hava Yolları Yorumlarının Polarite Sayıları (Covid-19 Öncesi)**

Hava yolu	Pozitif	Negatif	Nötr	Toplam
ANA	2500	324	124	2948
Aegean	3661	731	152	4544
Asiana	1198	240	92	1530
Austrian	2328	910	177	3415
Avianca	2018	1242	156	3416
Brussels	1332	961	139	2432
Canada	11163	8922	1051	21136
China	1487	1271	306	3064
Copa	1996	790	147	2933
Croatia	425	207	35	667
Egypt	1422	661	170	2253
Ethiopian	2022	1080	206	3308
EVA	3396	449	180	4025
India	3511	2285	382	6178
LOT	1257	1081	139	2477
Lufthansa	11046	4265	874	16185
New Zealand	9699	1645	475	11819
SAS	3199	1205	305	4709
Shenzhen	100	54	17	171
Singapore	15607	2431	846	18884
South African	2339	1064	251	3654
Swiss	4179	1484	288	5951
TAP	3240	2582	308	6130
Thai	6535	1531	593	8659
THY	10086	3630	643	14359
United	24127	16585	2131	42843

Tablo 3’te görüldüğü üzere, hava yollarından en fazla yorum alan hava yolu United (42843), en az yorum alan Shenzhen (171)’dir. THY ise toplam 14359 yorum almıştır. Tüm hava yollarında pozitif yorum sayısı, negatif veya nötr yorum sayısından fazla olduğu görülmektedir. En yüksek pozitif yorum oranı ANA hava yolları iken; en düşük ise China hava yolları olacaktır. Tablo 4’te her bir hava yoluna ait Covid-19 sonrası polarite (pozitif, negatif ve nötr) yorum sayıları verilmiştir.

**Tablo 4. Havayolları Yorumlarının Polarite Sayıları (Covid-19 Sonrası)**

Hava yolu	Pozitif	Negatif	Nötr	Toplam
ANA	164	17	0	181
Aegean	221	188	3	412
Asiana	54	17	1	72
Austrian	124	131	4	259
Avianca	164	278	8	450
Brussels	89	100	4	193
Canada	824	768	18	1610
China	66	41	0	107
Copa	235	235	9	479
Croatia	26	15	0	41
Egypt	163	130	2	295
Ethiopian	208	166	3	377
EVA	207	50	0	257
India	297	434	2	733
LOT	154	217	4	375
Lufthansa	751	761	15	1527
New Zealand	418	115	2	535
SAS	171	165	2	338
Shenzhen	9	1	0	10
Singapore	828	169	2	999
South African	106	36	2	144
Swiss	271	177	4	452
TAP	441	737	15	1193
Thai	308	78	5	391
THY	812	846	16	1674
United	1980	917	27	2924

Tablo 4’te görüldüğü üzere, hava yollarından en fazla yorum alan hava yolu United (2924), en az yorum alan Shenzhen (10)’dir. THY ise toplam 1674 yorum almıştır. En yüksek pozitif yorum oranı ANA hava yolları iken; en düşük ise Avianca hava yolları olacaktır. Tablo 5’te hava yollarına ait bir kısım müşteri yorumlarının polarite etiketleri verilmiştir.

**Tablo 5. Hava Yollarının Müşteri Yorumlarına Ait Polariteleri**

Hava Yolu	Yorum	Polarite
Aegean	Perfect in all occasion! The best after Turkish airlines. Helpful crew, the doos is excellent and you don't have to pay it.	Pozitif
ANA	Old and dated plane, air hostess, forgot to complete meal service and laughed it off. Did not feel welcome at all.	Negatif
Asiana	Traveling with Asiana is a breeze. The FAS are very warm and helpful and the amenities are ok. In terms of food, it's average.	Nötr
Austrian	1 hour late out of Tirana. Missed my connection and no other options available so had to stay overnight in Vienna.	Negatif
Avianca	This airport is one of their hubs. It is much better staffed that at the origin of my flight. Nicer people working for Avianca	Pozitif
Brussels	Flight left on time and arrived slightly early in Manchester. Very efficient staff. Leg room ok for economy. The service needs to be improved. To much money for extra leg space. Limited quantity of soft drinks.	Nötr
Canada	Routine service.	Pozitif
China	Poor quality of comfort, service, cleanliness with average meals. Got impression staff wanted to be invisible	Negatif
Copa	Flight was crowded, I supposed due to the good deals they offered flying from Brazil. Nothing special about it, regular service, food was not so good.	Nötr
Croatia	Direct flight and frendly crew. Snack was innovative and nice. A little bit more space for legs will be appreciated.	Pozitif
Egypt	Avoid. Stoppo. Passengers are treated as if they are an inconvenience. The flight was however cheap.	Negatif
Ethiopian	Manutention of the plane was poor. Service average. Entertainment average. Staff good. Seats needs refurbishing. The best value in my opinion. I always used to fly Thai but their prices are too high for me now. Good service, food and drink. Normally ontime.	Nötr
EVA	Great staff, pleasant aircraft. What more could you wann?	Pozitif
India	Flight got delayed by 3 hours or even more. Way too annoyed with the service. This sucks, you can't waste our time like this.	Negatif
LOT	Good legroom comfortable for long journey. Entertainment system is average food is above average but not the best.	Nötr
Lufthansa	Really good flight with a well known airline. Boarding was prompt, didn't go by groups, waited a bit in the bus since the aircraft wasn't ready yet.	Pozitif
New Zealand	found staff to be rude, food very ordinary. plane was old and not in good repair. interior very worn.	Negatif
SAS	Late to take off but made up time en route. Jet was fine, crew were very friendly Small plane but okay.	Nötr
Shenzhen	Great experience	Pozitif
Singapore	once did they ask us did we want water, English was very poor and hard to understand food not to bad, very old plane	Negatif
South African	Very pleased with flight. Food was okay service was satisfactory. Entertainment was relatively good. Left and came back on schedule	Nötr
Swiss	In combination with their Edelweiss service this was a very good and cheap option to visit Vietnam. Good service, decent aircraft.	Pozitif
TAP	It's gets you there but they are bad about luggage. Carry on your bag. If they lose it, they don't care.	Negatif
Thai	Nothing out of place. Boarded on time. In-flight service average: average food, average seats, average cleanliness, outdated films on the server, no internet. All-in-all very average.	Nötr
THY	Turkish Airlines... Always good specially because of its connection flights to almost every country.	Pozitif
United	Pretty ordinary service in a very cramped regional aircraft. Useless in flight wifi with no internet connection available.	Negatif

Tablo 5’te 26 hava yolunun pozitif, negatif ve nötr yorumların polarite etiketleri örnek olarak verilmiştir. Polarite (pozitif, negatif ve nötr) üç sınıftan oluşmaktadır. DVM, Naive Bayes ve Derin Öğrenme algoritmaları kullanarak hava yollarına yönelik polariteye göre sınıflandırma tahmini analiz edilerek hava yollarına yönelik sonuçlar karşılaştırılmıştır.

### III.II. Destek Vektör Makineleri ile Hava Yolu Polarite Analizi

DVM ile her bir hava yolunun polarite sonuçlarının sınıflandırılmasından önce özellik seçimi yapılmıştır. Kullanılan algoritma, eksik veri ile işlem yapamadığından dolayı, eksik veriler için bulunduğu sütundaki ortalama değer hesaplanarak analiz edilmiştir. Genel skor, ayak koyma alanı, koltuk konforu, uçak içi eğlence (wifi, tv, filmler vb.), müşteri hizmetleri, fiyat/fayda oranı, temizlik, check-in ve binış, yiyecek ve içecek, polarite (pozitif, negatif, nötr) kriterleri performans ölçümü için kullanılmıştır. Buradaki kriterlerden polarite etiketi bağımlı değişken olarak seçilmiştir. Araştırmada, THY verilerinin analizine odaklanarak geniş perspektifte değerlendirmesi yapılmıştır. THY’den ortaya çıkan performans sonuçları ile diğer Star Alliance kuruluşu hava yollarının sonuçları karşılaştırılmıştır. Tablo 6’da Covid-19 öncesi THY’nin DVM algoritması ile sınıflandırma performans sonucu verilmiştir.

**Tablo 6. THY’nin DVM ile Performans Sınıflandırma Sonucu (Covid-19 Öncesi)**

Doğruluk Performans Sonucu: %86,51	Gerçek Pozitif (GP)	Gerçek Negatif (GN)	Gerçek Nötr (GNÖ)	Sınıf Doğruluk
Tahmin Pozitif (TP)	2907	245	152	87,98%
Tahmin Negatif(TN)	144	820	40	81,67%
Tahmin Nötr (TNÖ)	0	0	0	00,00%
Sınıf Geribildirim	95,28%	77,00%	00,00%	

Tablo 6’de sınıflandırmanın başarı değeri %86,51 ve sınıflandırmanın hata değeri %13,49 olarak bulunmuştur. Tablo 7’de Covid-19 sonrası THY’nin DVM algoritması ile sınıflandırma performans sonucu verilmiştir.

**Tablo 7. THY’nin DVM ile Performans Sınıflandırma Sonucu (Covid-19 Sonrası)**

Doğruluk Performans Sonucu: %85,66	Gerçek Pozitif (GP)	Gerçek Negatif (GN)	Gerçek Nötr (GNÖ)	Sınıf Doğruluk
Tahmin Pozitif (TP)	251	53	4	81,49%
Tahmin Negatif(TN)	14	179	1	92,27%
Tahmin Nötr (TNÖ)	0	0	0	00,00%
Sınıf Geribildirim	94,72%	77,16%	00,00%	

Tablo 7’de sınıflandırmanın başarı değeri %85,66 ve sınıflandırmanın hata değeri %14,34 olarak bulunmuştur. Tablo 6 ve 7’deki performans sonucundaki doğruluk, Gerçek Pozitif (GP), Gerçek Negatif (GN) ve Gerçek Nötr (GNÖ) toplam sınıflandırma sayısı üzerindeki orandır. Köşegen sayıları ile hesaplanan karşılık matrisi üzerindeki toplam elemanlar doğruluk oranını göstermektedir. Doğruluk oranı, Eşitlik 15’de gösterilmiştir [35].

$$\text{Doğruluk} = (GP + GN + GNÖ) / (GP + GN + GNÖ + TP + TN + TNÖ) \quad (15)$$

DVM algoritmasının Covid-19 öncesi tüm hava yollarına ait polarite sınıflandırma doğruluk sonuçları ve sınıflandırma hata değeri Tablo 8’de verilmiştir.

**Tablo 8. DVM ile Tüm Hava yollarının Performans Sınıflandırma Sonucu (Covid-19 Öncesi)**

Hava Yolları	Sınıflandırma Performans Değeri %	Sınıflandırma Hata Değeri %	Sıralama
EVA	89,81	10,19	1
Aegean	89,07	10,93	2
ANA	88,46	11,54	3
New Zealand	87,51	12,49	4
Singapore	86,95	13,05	5
THY	86,51	13,49	6
Autrian	85,94	14,06	7
Asiana	85,84	14,16	8
Avianca	84,88	15,12	9
Swiss	83,87	16,13	10
Copa	83,52	16,48	11
Thai	83,03	16,97	12
Lufthansa	82,97	17,03	13
TAP Portugal	82,38	17,62	14
Ethiopian	81,25	18,75	15
Brussels	80,14	19,86	16
Canada	79,62	20,38	17
SAS	79,19	20,81	18
Egypt	79,14	20,86	19
India	78,95	21,05	20
South African	78,28	21,72	21
LOT	77,93	22,07	22
United	77,72	22,28	23
Croatia	76,00	24,00	24
China	74,65	25,35	25
Shenzhen	58,82	41,18	26

Tablo 8’de DVM algoritması ile sınıflandırma performans değerinin en yüksek (%89,81) ve en düşük hata değeri (%10,19) olan hava yolu EVA iken; performans değerinin en düşük (%58,82) ve sınıflandırma hata değerinin en yüksek (%41,18) olan hava yolu Shenzhen olduğu görülmüştür. THY’nin performans değeri ise %86,51 iken, sınıflandırma hata değeri % 13,49’dur. DVM algoritmasının Covid-19 sonrası tüm hava yollarına ait polarite sınıflandırma doğruluk sonuçları ve sınıflandırma hata değeri Tablo 9’de verilmiştir.

**Tablo 9. DVM ile Tüm Hava Yollarının Performans Sınıflandırma Sonucu (Covid-19 Sonrası)**

Hava Yolları	Sınıflandırma Performans Değeri %	Sınıflandırma Hata Değeri %	Sıralama
Singapore	90,00	10,00	1
EVA	88,31	11,69	2
SAS	88,12	11,88	3
THY	85,66	14,34	4
ANA	85,19	14,81	5
United	84,95	15,05	6
New Zealand	84,38	15,62	7
Austrian	83,33	16,67	8
Thai	82,91	17,09	9
Swiss	82,35	17,65	10
Aegean	82,26	17,74	11
Lufthansa	79,69	20,31	12
Ethiopian	79,65	20,35	13
India	79,09	20,91	14
Canada	78,88	21,12	15
Copa	78,47	21,53	16
TAP Portugal	77,93	22,07	17
Brussels	77,59	22,41	18
South African	76,74	23,26	19
LOT	75,00	25,00	20
Egypt	73,86	26,14	21
Avianca	73,33	26,67	22
China	71,88	28,12	23
Shenzhen	66,67	33,33	24
Asiana	63,64	36,36	25
Croatia	58,33	41,67	26

Tablo 9’de DVM algoritması ile sınıflandırma performans değerinin en yüksek (%90,00) ve en düşük hata değeri (%10,00) olan hava yolu Singapore iken; performans değerinin en düşük (%58,33) ve sınıflandırma hata değerinin en yüksek (%41,67) olan hava yolu Croatia olduğu görülmüştür. THY’nin performans değeri ise %85,66 iken, sınıflandırma hata değeri % 14,34’dur.

### III.III. Naive Bayes ile Hava Yolu Polarite Analizi

Olasılık hesaplamasına dayalı olarak performans değerlendirmesi yapan Naive Bayes Algoritması ile hava yollarının başarı değeri hesaplanmıştır. Kullanılan algoritma, olasılık tabanlı olduğu için eksik veri ile işlem yapabilmektedir. Genel skor, ayak koyma alanı, koltuk konforu, uçak içi eğlence (wifi, tv, filmler vb.), müşteri hizmetleri, fiyat/fayda oranı, temizlik, check-in ve biniş, yiyecek ve içecek, polarite (pozitif, negatif, nötr) kriterleri performans ölçümü için kullanılmıştır. Buradaki kriterlerden polarite etiketi bağımlı değişken olarak seçilmiştir. Araştırmada, THY verilerinin analizine odaklanarak geniş perspektifte değerlendirmesi yapılmıştır. THY'den ortaya çıkan performans sonuçları ile diğer Star Alliance kuruluşu hava yollarının sonuçları karşılaştırılmıştır. Tablo 10'da Covid-19 öncesi THY'nin Naive Bayes algoritması ile sınıflandırma performans sonucu verilmiştir.

**Tablo 10. THY'nin Naive Bayes ile Performans Sınıflandırma Sonucu (Covid-19 öncesi)**

Doğruluk Performans Sonucu: % 83,52	Gerçek Pozitif (GP)	Gerçek Negatif (GN)	Gerçek Nötr (GNÖ)	Sınıf Doğruluk
Tahmin Pozitif (TP)	2724	173	102	90,83%
Tahmin Negatif (TN)	212	841	57	75,77%
Tahmin Nötr (TNÖ)	115	51	33	16,58%
Sınıf Geribildirim	89,28%	78,97%	17,19%	

Tablo 10'da sınıflandırmanın başarı değeri %83,52 ve sınıflandırmanın hata değeri %16,48 olarak bulunmuştur. Tablo 11'de Covid-19 sonrası THY'nin Naive Bayes algoritması ile sınıflandırma performans sonucu verilmiştir.

**Tablo 11. THY'nin Naive Bayes ile Performans Sınıflandırma Sonucu (Covid-19 Sonrası)**

Doğruluk Performans Sonucu: % 86,06	Gerçek Pozitif (GP)	Gerçek Negatif (GN)	Gerçek Nötr (GNÖ)	Sınıf Doğruluk
Tahmin Pozitif (TP)	252	57	0	81,55%
Tahmin Negatif (TN)	13	175	0	93,09%
Tahmin Nötr (TNÖ)	0	0	5	100%
Sınıf Geribildirim	95,09%	75,43%	100%	

Tablo 11'da sınıflandırmanın başarı değeri %86,06 ve sınıflandırmanın hata değeri %13,94 olarak bulunmuştur. Naive Bayes Algoritması ile Covid-19 öncesi tüm hava yollarına ait polarite sınıflandırma doğruluk sonuçları ve sınıflandırma hata değeri Tablo 12'de verilmiştir.

**Tablo 12. Naive Bayes ile Tüm Hava Yollarının Performans Sınıflandırma Sonucu (Covid-19 Öncesi)**

Hava Yolları	Sınıflandırma Performans Değeri %	Sınıflandırma Hata Değeri %	Sıralama
EVA	87,49	12,51	1
Aegean	86,21	13,79	2
ANA Nippon	85,07	14,93	3
New Zealand	85,03	14,97	4
Singapore	84,06	15,94	5
THY	83,52	16,48	6
Austrian	83,30	16,70	7
Avianca	83,22	16,78	8
Asiana	82,14	17,86	9
Swiss	82,02	17,98	10
Copa	81,48	18,52	11
TAP Portugal	81,19	18,81	12
Lufthansa	80,49	19,51	13
Thai	79,91	20,09	14
Brussels	79,59	20,41	15
Canada	79,06	20,94	16
India	78,58	21,42	17
Croatia	78,50	21,50	18
Ethiopian	78,12	21,88	19
LOT	77,12	22,88	20
United	76,50	23,50	21
South African	76,46	23,54	22
SAS	75,94	24,06	23
Egypt	74,26	25,74	24
China	72,69	27,31	25
Shenzhen	60,78	39,22	26



Tablo 12’de Naive Bayes Algoritması ile sınıflandırma performans değerinin en yüksek (%87,49) ve en düşük hata değeri (%12,51) olan hava yolu EVA iken; performans değerinin en düşük (%60,78) ve sınıflandırma hata değerinin en yüksek (%39,22) olan hava yolu Shenzhen olduğu görülmüştür. THY’nin performans değeri ise %83,52 iken, sınıflandırma hata değeri % 16,48’dir. Naive Bayes Algoritması ile Covid-19 sonrası tüm hava yollarına ait polarite sınıflandırma doğruluk sonuçları ve sınıflandırma hata değeri Tablo 13’te verilmiştir.

**Tablo 13. Naive Bayes ile Tüm Hava Yollarının Performans Sınıflandırma Sonucu (Covid-19 sonrası)**

Hava Yolları	Sınıflandırma Performans Değeri %	Sınıflandırma Hata Değeri %	Sıralama
EVA	96,10	3,90	1
Austrian	93,59	6,41	2
Thai	88,89	11,11	3
SAS	88,12	11,88	4
Singapore	87,67	12,33	5
New Zealand	87,50	12,50	6
Asiana	86,36	13,64	7
Aegean	86,29	13,71	8
Brussels	86,21	13,79	9
THY	86,06	13,94	10
India	85,00	15,00	11
LOT	84,82	15,18	12
Avianca	84,44	15,56	13
Swiss	83,82	16,18	14
TAP Portugal	81,84	18,16	15
Egypt	81,82	18,18	16
Ethiopian	81,42	18,58	17
Lufthansa	81,00	19,00	18
Canada	80,95	19,05	19
Copa	80,56	19,44	20
United	80,5	19,5	21
China	78,12	21,88	22
Croatia	75,00	25,00	23
South African	74,42	25,58	24
ANA Nippon	68,52	31,48	25
Shenzhen	66,67	33,33	26

Tablo 13’de Naive Bayes Algoritması ile sınıflandırma performans değerinin en yüksek (%96,10) ve en düşük hata değeri (%3,90) olan hava yolu EVA iken; performans değerinin en düşük (%66,67) ve sınıflandırma hata değerinin en yüksek (%33,33) olan hava yolu Shenzhen olduğu görülmüştür. THY’nin performans değeri ise %86,06 iken, sınıflandırma hata değeri % 13,94’tür.

### III.IV. Derin Öğrenme ile Hava Yolu Polarite Analizi

Derin Öğrenme Algoritmasından, Rectified doğrusal aktivasyon fonksiyonu kullanılarak hava yollarının performans değerlendirmesi yapılmıştır. Kullanılan algoritma, aktivasyon fonksiyonu yardımıyla eksik veri ile işlem yapabilmektedir. Genel skor, ayak koyma alanı, koltuk konforu, uçak içi eğlence (wifi, tv, filmler vb.), müşteri hizmetleri, fiyat/fayda oranı, temizlik, check-in ve biniş, yiyecek ve içecek, polarite (pozitif, negatif, nötr) kriterleri performans ölçümü için kullanılmıştır. Buradaki kriterlerden polarite etiketi bağımlı değişken seçilmiştir. Araştırmada, THY verilerinin analizine odaklanarak geniş perspektifte değerlendirmesi yapılmıştır. THY’den ortaya çıkan performans sonuçları ile diğer Star Alliance kuruluşu hava yollarının sonuçları karşılaştırılmıştır. Tablo 14’te Covid-19 öncesi THY’nin Derin Öğrenme Algoritması ile sınıflandırma performans sonucu verilmiştir.

**Tablo 14. THY’nin Derin Öğrenme ile Performans Sınıflandırma Sonucu (Covid-19 Öncesi)**

Doğruluk Performans Sonucu: %85,96	Gerçek Pozitif (GP)	Gerçek Negatif (GN)	Gerçek Nötr (GNÖ)	Sıf Doğruluk
Tahmin Pozitif (TP)	2930	292	161	86,61%
Tahmin Negatif (TN)	121	773	31	83,57%
Tahmin Nötr (TNÖ)	0	0	0	0,00%
Sıf Geribildirim	96,00%	72,58%	0,00%	

Tablo 14’te sınıflandırmanın başarı değeri %85,96 ve sınıflandırmanın hata değeri %16,48 olarak bulunmuştur. Tablo 15’te Covid-19 sonrası THY’nin Derin Öğrenme Algoritması ile sınıflandırma performans sonucu verilmiştir.

**Tablo 15. THY’nin Derin Öğrenme ile Performans Sınıflandırma Sonucu (Covid-19 sonrası)**

Doğruluk Performans Sonucu: %98,41	Gerçek Pozitif (GP)	Gerçek Negatif (GN)	Gerçek Nötr (GNÖ)	Sıf Doğruluk
Tahmin Pozitif (TP)	264	2	2	98,51%
Tahmin Negatif (TN)	0	230	3	98,71%
Tahmin Nötr (TNÖ)	1	0	0	0,00%
Sıf Geribildirim	99,62%	99,14%	0,00%	

Tablo 15’de sınıflandırmanın başarı değeri %98,41 ve sınıflandırmanın hata değeri %1,79 olarak bulunmuştur. Derin Öğrenme Algoritması ile Covid-19 öncesi tüm hava yollarına ait polarite sınıflandırma doğruluk sonuçları ve sınıflandırma hata değeri Tablo 16’da verilmiştir.

**Tablo 16. Derin Öğrenme ile Tüm Hava Yollarının Performans Sınıflandırma Sonucu (Covid-19 Öncesi)**

Hava Yolları	Sınıflandırma Performans Değeri %	Sınıflandırma Hata Değeri %	Sıralama
EVA	90,97	09,03	1
Aegean	89,14	10,86	2
ANA Nippon	88,69	11,31	3
New Zealand	87,42	12,58	4
Asiana	87,15	12,85	5
Singapore	86,97	13,03	6
THY	85,96	14,04	7
Avianca	85,17	14,83	8
Austrian	84,38	15,62	9
Swiss	84,20	15,80	10
Copa	83,41	16,59	11
Lufthansa	83,17	16,83	12
TAP Portugal	82,87	17,13	13
Thai	82,83	17,17	14
Croatia	81,00	19,00	15
Brussels	80,96	19,04	16
Ethiopian	80,34	19,66	17
India	79,49	20,51	18
SAS	79,33	20,67	19
Canada	79,10	20,90	20
LOT	78,87	21,13	21
South African	78,74	21,26	22
United	77,76	22,24	23
Egypt	77,22	22,78	24
China	74,43	25,57	25
Shenzhen	62,75	37,25	26

Tablo 16’da Derin Öğrenme Algoritması ile sınıflandırma performans değerinin en yüksek (%90,97) ve en düşük hata değeri (%9,03) olan hava yolu EVA iken; performans değerinin en düşük (%62,75) ve sınıflandırma hata değerinin en yüksek (%37,25) olan hava yolu Shenzhen olduğu görülmüştür. THY’nin performans değeri ise %85,96 iken, sınıflandırma hata değeri %14,04’dır. Derin Öğrenme Algoritması ile Covid-19 sonrası tüm hava yollarına ait polarite sınıflandırma doğruluk sonuçları ve sınıflandırma hata değeri Tablo 17’de verilmiştir.

**Tablo 17. Derin Öğrenme ile Tüm Hava Yollarının Performans Sınıflandırma Sonucu (Covid-19 Sonrası)**

Hava Yolları	Sınıflandırma Performans Değeri %	Sınıflandırma Hata Değeri %	Sıralama
THY	98,21	1,79	1
Canada	98,14	1,86	2
SAS	98,02	1,98	3
Singapore	97,67	2,33	4
United	97,61	2,39	5
TAP Portugal	97,49	2,51	6
Lufthansa	97,38	2,62	7
India	97,27	2,73	8
Copa	96,53	3,47	9
LOT	96,43	3,57	10
EVA	96,1	3,9	11
Ethiopian	95,58	4,42	12
Aegean	95,16	4,84	13
Austrian	94,87	5,13	14
Avianca	94,81	5,19	15
Swiss	94,12	5,88	16
Thai	94,02	5,98	17
ANA Nippon	92,59	7,41	18
Egypt	92,05	7,95	19
Brussels	91,38	8,62	20
New Zealand	91,25	8,75	21
South African	86,05	13,95	22
Croatia	83,33	16,67	23
Asiana	81,82	18,18	24
China	81,25	18,75	25
Shenzhen	66,67	33,33	26

Tablo 17’de Derin Öğrenme Algoritması ile sınıflandırma performans değerinin en yüksek (%98,21) ve en düşük hata değeri (%1,79) olan hava yolu THY iken; performans değerinin en düşük (%66,67) ve sınıflandırma hata değerinin en yüksek (%33,33) olan hava yolu Shenzhen olduğu görülmüştür.


### III.V. Tüm Hava Yollarının Sınıflandırma Sonuçlarının Karşılaştırılması

Her bir hava yolunun Covid-19 öncesi DVM, Naive Bayes ve Derin Öğrenme Algoritmaları ile yapılan sınıflandırma başarı sonuçları ve ortalamaları Tablo 18’de verilmiştir.

**Tablo 18. Tüm Hava Yollarının Performans Sonuçlarının Karşılaştırılması (Covid-19 öncesi)**

Hava Yolları	DVM %	Naive Bayes %	Derin Öğrenme %	Ortalama Skor %	Sıralama
EVA	89,81	87,49	90,97	89,42	1
Aegean	89,07	86,21	89,14	88,14	2
ANA Nippon	88,46	85,07	88,69	87,41	3
New Zealand	87,51	85,03	87,42	86,65	4
Singapore	86,95	84,06	86,97	85,99	5
THY	86,51	83,52	85,96	85,33	6
Asiana	85,84	82,14	87,15	85,04	7
Autrian	85,94	83,30	84,38	84,54	8
Avianca	84,88	83,22	85,17	84,42	9
Swiss	83,87	82,02	84,20	83,36	10
Copa	83,52	81,48	83,41	82,80	11
Lufthansa	82,97	80,49	83,17	82,21	12
TAP Portugal	82,38	81,19	82,87	82,15	13
Thai	83,03	79,91	82,83	81,92	14
Brussels	80,14	79,59	80,96	80,23	15
Ethiopian	81,25	78,12	80,34	79,90	16
Canada	79,62	79,06	79,10	79,26	17
India	78,95	78,58	79,49	79,01	18
Croatia	76,00	78,50	81,00	78,50	19
SAS	79,19	75,94	79,33	78,15	20
LOT	77,93	77,12	78,87	77,97	21
South African	78,28	76,46	78,74	77,83	22
United	77,72	76,50	77,76	77,33	23
Egypt	79,14	74,26	77,22	76,87	24
China	74,65	72,69	74,43	73,92	25
Shenzhen	58,82	60,78	62,75	60,78	26

Tablo 18’de algoritmalarından çıkan sınıflandırma performans değerleri karşılaştırılmıştır. Algoritmaların başarı değerlerinin ortalaması dikkate alınarak sıralama yapılmıştır. Performans başarı değeri en yüksek (%89,42) EVA hava yolu iken, en düşük (%60,78) performans başarı değeri Shenzhen hava yoludur. Üç algoritmanın ortalamasına göre THY’nin performans başarı değeri ise %85,33 olarak hesaplanmıştır. Bunun yanı sıra Shenzhen hava yolu dışında diğer tüm hava yollarının başarı ortalaması birbirine yakın ve %70’in üzerinde olduğu görülmektedir. Covid-19 öncesi Shenzhen hava yolunun diğer hava yollarının performans başarı değerinden düşük olmasının sebebi olarak bu hava yoluna yapılan İngilizce yorum sayısının (171) diğer hava yollarından düşük olduğu düşünülmektedir. Şekil 3’te, Tablo 18’deki verilerin görselleştirilmesi yapılmıştır.




Şekil 3. Algoritmaların Performans Sonuçlarının Karşılaştırılması (Covid-19 öncesi)

Şekil 3’te DVM, Naive Bayes ve Derin Öğrenme Algoritmalarının ortalamaları çubuk grafiği olarak çizilmiştir. Genel olarak hava yolları için yapılan polarite tahmin sonucunda çizgi grafiğinin üstünde kalan en yüksek başarı değeri ile tahmin eden algoritmaların DVM ve Derin Öğrenme olduğu görülmektedir. Her bir hava yolunun Covid-19 sonrası DVM, Naive Bayes ve Derin Öğrenme Algoritmaları ile yapılan sınıflandırma başarı sonuçları ve ortalamaları Tablo 19’de verilmiştir.

Tablo 19. Tüm Hava Yollarının Performans Sonuçlarının Karşılaştırılması (Covid-19 Sonrası)

Hava Yolları	DVM %	Naive Bayes %	Derin Öğrenme %	Ortalama Skor %	Sıralama
EVA	88,31	96,1	96,1	93,50	1
Singapore	90	87,67	97,67	91,78	2
SAS	88,12	88,12	98,02	91,42	3
Austrian	83,33	93,59	94,87	90,60	4
THY	85,66	86,06	98,21	89,98	5
Thai	82,91	88,89	94,02	88,61	6
Aegean	82,26	86,29	95,16	87,90	7
New Zealand	84,38	87,5	91,25	87,71	8
United	84,95	80,5	97,61	87,69	9
India	79,09	85	97,27	87,12	10
Swiss	82,35	83,82	94,12	86,76	11
Lufthansa	79,69	81	97,38	86,02	12
Canada	78,88	80,95	98,14	85,99	13
TAP Portugal	77,93	81,84	97,49	85,75	14
Ethiopian	79,65	81,42	95,58	85,55	15
LOT	75	84,82	96,43	85,42	16
Copa	78,47	80,56	96,53	85,19	17
Brussels	77,59	86,21	91,38	85,06	18
Avianca	73,33	84,44	94,81	84,19	19
Egypt	73,86	81,82	92,05	82,58	20
ANA	85,19	68,52	92,59	82,10	21
South African	76,74	74,42	86,05	79,07	22
Asiana	63,64	86,36	81,82	77,27	23
China	71,88	78,12	81,25	77,08	24
Croatia	58,33	75	83,33	72,22	25
Shenzhen	66,67	66,67	66,67	66,67	26

Tablo 19’da algoritmalarından çıkan sınıflandırma performans değerleri karşılaştırılmıştır. Algoritmaların başarı değerlerinin ortalaması dikkate alınarak sıralama yapılmıştır. Performans başarı değeri en yüksek (%93,50) EVA hava yolu iken, en düşük (%66,67) performans başarı değeri Shenzhen hava yoludur. Üç algoritmanın ortalamasına göre THY’nin performans başarı değeri ise %89,98 olarak hesaplanmıştır. Bunun yanı sıra Shenzhen hava yolu dışında diğer tüm hava yollarının başarı ortalaması birbirine yakın ve %70’in üzerinde olduğu görülmektedir. Covid-19 sonrası Shenzhen, Croatia, China, Asiana, South African, ANA hava yolları diğer hava yollarının performans başarı değerinden düşük olmasının sebebi olarak bu hava yoluna yapılan İngilizce yorum sayısının diğer hava yollarından düşük olduğu düşünülmektedir. Şekil 4’te, Tablo 19’deki verilerin görselleştirilmesi yapılmıştır.



Şekil 4. Algoritmaların Performans Sonuçlarının Karşılaştırılması (Covid-19 sonrası)

Şekil 4’te DVM, Naive Bayes ve Derin Öğrenme Algoritmalarının ortalamaları çubuk grafiği çizilmiştir. Genel olarak hava yolları için yapılan polarite tahmin sonucunda çizgi grafiğinin üstünde kalan en yüksek başarı değeri ile tahmin eden algoritmanın Derin Öğrenme olduğu görülmektedir.

## SONUÇ VE DEĞERLENDİRME

Veri ve metin madenciliği sayesinde işletmeler, karmaşık ve büyük veri kümelerini basit, hızlı ve etkili bir şekilde analiz etmektedirler. Aynı zamanda şirketler, manuel ve tekrar eden görevlerinin bir kısmını azaltmak için bu güçlü araçtan yararlanmaktadırlar. Böylelikle ekiplerine değerli zamanlar kazandırmakta ve müşteri destek temsilcilerinin daha iyi yaptıkları işe odaklanmalarına izin vermektedirler. İşletme müşterilerinin elektronik ortamda neyi beğendiğini veya neyi eleştirdiğini anlamak isteyebilmektedir. Bu bağlamda veri/metin madenciliği teknikleri müşteri yorumlarında ortaya çıkan en popüler konuları ve insanların işletmeler hakkında ne düşündüğünün tespit edilmesinde yardımcı olmaktadır. Buradan da işletmeler, eksik ve zayıf yönlerini görerek kendi hizmet standartlarını düzenleyip rekabet durumundaki rakiplerine karşı avantaj sağlayabilirler.

Metin madenciliği tekniklerinden Duygu Analizi ile müşteri yorumlarının ‘pozitif mi, negatif mi yoksa nötr mü?’ sorularına cevap verilebilmektedir. Ayrıca belirli konuyla ilgili olarak müşteriler tarafından bahsedilen ana anahtar kelimeleri de bulmaya yardımcı olmaktadır. Veri madenciliği tekniklerinden özellikle DVM, Naive Bayes ve Derin Öğrenme Algoritmaları kullanılarak sınıflandırma ve tahmin yapılabilmektedir. Veri ve metin madenciliği, işletmelerin verilerinden en iyi şekilde yararlanmasına yardımcı olmaktadır ve bu durum daha iyi veri odaklı iş kararlarına yol açmaktadır.

İş dünyasında doğru karar vermek ve uygun politikalar geliştirmek için hız faktörünün önemli olduğu bir sektörde hava yolu taşımacılığıdır. Hava yolu taşımacılığı, hız avantajının yanı sıra sürekli artan kapasite, uzun menzil ve emniyet özellikleriyle çağdaş bir ulaşım sistemidir. Hava yolu endüstrisi özel coğrafi yollara ihtiyaç duymadan, yeryüzüyle en az temas yoluyla, yolcuları ve kargoları çıkış noktasından varış noktasına ulaştırmaktadır. Ulaştırma türleri içinde en son keşfedilen ve en hızlı gelişen hava yolu taşımacılığı, uzun mesafede yolcu ve acil değerli kargo taşımacılığında neredeyse tek seçenektir. Coğrafi sahası geniş, yerleşim yerleri dağınık, doğal koşulları yüzey ulaşım ağı için elverişli olmayan yerlerde hava yolu taşımacılığı bütünlendirici bir faktör olarak görülmektedir.

Seyahatlerinde uçak yolculuğunu tercih eden kişilerin ihtiyaçlarına daha kusursuz bir şekilde yanıt verebilmek ve hizmet kalitesini her geçen gün bir adım daha öteye taşıyabilmek amacı ile kurulmuş olan Star Alliance 26 hava yolu üyesi ile bu çalışmada ele alınmıştır. Hava yollarını değerlendirmek ve karşılaştırmak için seyahat inceleme sitelerinden olan TripAdvisor'daki müşterilerin yapmış olduğu İngilizce yorumlar ve sayısal skorlar kriter olarak alınmıştır. Bunlar: genel skor, ayak koyma alanı, koltuk konforu, uçak içi eğlence (wifi, tv, filmler vb.), müşteri hizmetleri, fiyat/fayda oranı, temizlik, check-in ve binış, yiyecek ve içecek'tir. Kriterlere verilen değerlendirme puanları 10-50 arasında değişmektedir. Bu kriterlere ek olarak yorumlardan elde edilen polarite (pozitif, negatif, nötr), kriteri uygulamada kullanılmıştır.

Araştırmada, ele alınan kriterler bağlamında veri ve metin madenciliği tekniklerinden Duygu Analizi, DVM, Naive Bayes ve Derin Öğrenme Algoritmaları kullanılmıştır. İlk olarak Duygu Analizi ile müşteri yorumlarını temel alınarak hava yollarının polarite (pozitif, negatif, nötr) etiketi çıkarılmıştır.

Covid-19 öncesi duygu analizinden çıkan polarite etiketlerinin sınıflandırma tahmini için DVM, Naive Bayes ve Derin Öğrenme Algoritmaları kullanılmıştır. DVM algoritmaları ile yapılan performans doğruluk sonucunda EVA (%89,81) ilk sıradayken, Shenzhen (%58,82) son sırada yer almaktadır. THY (%86,51) ise, altıncı sırada yer almaktadır. Naive Bayes Algoritmaları ile yapılan performans doğruluk sonucunda EVA (%87,49) ilk sıradayken, Shenzhen (%60,78) son sırada yer almaktadır. THY (%83,52) ise, altıncı sırada yer almaktadır. Derin Öğrenme Algoritmaları ile yapılan performans doğruluk sonucunda EVA (%90,97) ilk sıradayken, Shenzhen (%62,75) son sırada yer almaktadır. THY (%85,96) ise, yedinci sırada yer almaktadır.

Covid-19 sonrası duygu analizinden çıkan polarite etiketlerinin sınıflandırma tahmini için DVM, Naive Bayes ve Derin Öğrenme Algoritmaları kullanılmıştır. DVM algoritmaları ile yapılan performans doğruluk sonucunda Singapore (%90,00) ilk sıradayken, Asiana (%63,64) son sırada yer almaktadır. THY (%85,66) ise, dördüncü sırada yer almaktadır. Naive Bayes Algoritmaları ile yapılan performans doğruluk sonucunda EVA (%96,10) ilk sıradayken, Shenzhen (%66,67) son sırada yer almaktadır. THY (%86,06) ise, onuncu sırada yer almaktadır. Derin Öğrenme Algoritmaları ile yapılan performans doğruluk sonucunda THY (%98,21) ilk sıradayken, Shenzhen (%66,67) son sırada yer almaktadır. Covid-19 öncesi ve sonrası üç algoritmanın performans değerlendirme sonucunda genel olarak en iyi algoritmanın Derin Öğrenme Algoritması olduğu görülmektedir.

İleriki çalışmalarda, veri/metin madenciliği teknikleri kullanılarak seyahat sitesi dışında farklı veriler de kullanılarak karşılaştırma yapılabilir. Veriler sohbetler, e-postalar, anketler, elektronik tablolar, veritabanları, sosyal medya, inceleme siteleri, haber kaynakları ve diğer web sitelerinden bilgiler olabilir. Araştırmada kullanılan kriterlerin yanı sıra farklı kriterler de eklenebilir ve farklı algoritmaların kullanımıyla analiz zenginleştirilebilir. Ayrıca bu çalışmada, global bir bakış açısı sağlamak adına İngilizce dili esas alınmıştır. Müşterilerin işletmelere yönelik yaptığı İngilizce dildeki yorumlar dışında diğer dillerde yapılan yorumlar da analiz edilip çalışmaya dâhil edilebilir. Araştırmada kullanılan algoritmalar irdelendiğinde veri boyutu büyüdüğünde genel olarak derin öğrenmenin daha iyi sonuç verdiğini ve ileriki çalışmalara katkı sunacağı düşünülmektedir.

## KAYNAKÇA

- Agarap, A. F. (2018). Deep learning using rectified linear units (ReLU). *arXiv preprint arXiv:1803.08375*.
- Alexa. (2020, 2 Mayıs) [https://www.alexandata.com/siteinfo/tripadvisor.com#section\\_traffic](https://www.alexandata.com/siteinfo/tripadvisor.com#section_traffic) (02.05.2020).
- An, Y., Sun, S., & Wang, S. (2017, May). Naive Bayes classifiers for music emotion classification based on lyrics. In *2017 IEEE/ACIS 16th International Conference on Computer and Information Science (ICIS)* (pp. 635–638). IEEE.
- BholaneSavita, D., & Gore, D. (2016). Sentiment analysis on twitter data using support vector machine. *International Journal of Computer Science Trends and Technology (IJCT)*, 4, 365–370.
- Cherian, V., & Bindu, M. S. (2017). Heart disease prediction using Naïve Bayes algorithm and Laplace smoothing technique. *International Journal of Computer Science Trends and Technology (IJCT)*, 5(2), 68–73.
- Dave, K., Lawrence, S., & Pennock, D. M. (2003, May). Mining the peanut gallery: Opinion extraction and semantic classification of product reviews. In *Proceedings of the 12th international conference on World Wide Web* (pp. 519–528).
- Day, M. Y., & Lin, Y. D. (2017, August). Deep learning for sentiment analysis on google play consumer review. In *2017 IEEE international conference on information reuse and integration (IRI)* (pp. 382–388). IEEE.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Haddaway, N. R. (2015). The use of web-scraping software in searching for grey literature. *Grey Journal*, 11(3), 186–190.
- Harisinghaney, A., Dixit, A., Gupta, S., & Arora, A. (2014, February). Text and image-based spam email classification using KNN, Naïve Bayes and Reverse DBSCAN algorithm. In *2014 International Conference on Reliability Optimization and Information Technology (ICROIT)* (pp. 153–155). IEEE.
- Hogenboom, A., Bal, D., Frasinca, F., Bal, M., de Jong, F., & Kaymak, U. (2013, March). Exploiting emoticons in sentiment analysis. In *Proceedings of the 28th annual ACM symposium on applied computing* (pp. 703–710).
- Hussein, S. M., Ali, F. H. M., & Kasiran, Z. (2012, May). Evaluation effectiveness of hybrid IDs using snort with naive Bayes to detect attacks. In *2012 Second International Conference on Digital Information and Communication Technology and its Applications (DICTAP)* (pp. 256–260). IEEE.
- Karamanlı, E. (2019). Makine öğrenmesi algoritmaları kullanarak metin madenciliği ve duygu analizi ile müşteri deneyiminin geliştirilmesi. (Yüksek Lisans Tezi). İstanbul Üniversitesi, İstanbul, Türkiye.
- Kharde, V., & Sonawane, P. (2016). Sentiment analysis of twitter data: A survey of techniques. *arXiv preprint arXiv:1601.06971*, 5–15.
- Kuhamanee, T., Talmongkol, N., Chaisuriyakul, K., San-Um, W., Pongpisuttinun, N., & Pongyupinpanich, S. (2017, July). Sentiment analysis of foreign tourists to Bangkok using data mining through online social network. In *2017 IEEE 15th International Conference on Industrial Informatics (INDIN)* (pp. 1068–1073). IEEE.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Liu, B. (2015). *Sentiment analysis: Mining opinions, sentiments, and emotions*. Cambridge University Press.
- Liu, H., & Cocea, M. (2017). Semi-random partitioning of data into training and test sets in granular computing context. *Granular Computing*, 2(4), 357–386.
- Maas, A. L., Hannun, A. Y., & Ng, A. Y. (2013, June). Rectifier nonlinearities improve neural network acoustic models. In *Proc. ICML* (Vol. 30, No. 1, p. 3–8).
- Makhabel, B., Mishra P., Danneman, N. & Heimann, R. (2017). *R: Mining spatial, text, web, and social media data*. Packt Publishing.
- Melek, C. (2012). *Metin madenciliği teknikleri ile şirketlerin vizyon ifadelerinin analizi*. (Yüksek Lisans Tezi). DEÜ Sosyal Bilimleri Enstitüsü, İzmir, Türkiye.
- Narayanan, V., Arora, I., & Bhatia, A. (2013, October). *Fast and accurate sentiment classification using an enhanced Naive Bayes model*. In *International Conference on Intelligent Data Engineering and Automated Learning* (pp. 194–201). Springer, Berlin, Heidelberg.
- Nasukawa, T., & Yi, J. (2003, October). Sentiment analysis: Capturing favorability using natural language processing. In *Proceedings of the 2nd international conference on Knowledge capture* (pp. 70–77).

- Povoda, L., Burget, R., & Dutta, M. K. (2016, June). Sentiment analysis based on support vector machine and big data. In *2016 39th International Conference on Telecommunications and Signal Processing (TSP)* (pp. 543–545). IEEE
- Sharma, P., Singh, D., & Singh, A. (2015, February). Classification algorithms on a large continuous random dataset using rapid miner tool. In *2015 2nd International Conference on Electronics and Communication Systems (ICECS)* (pp. 704–709). IEEE.
- Sivil Havacılık Genel Müdürlüğü, <http://web.shgm.gov.tr/> (17.01.2021).
- Suykens, J. A., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural processing letters*, 9(3), 293–300.
- Taha, A. M., Mustapha, A., & Chen, S. D. (2013). Naive Bayes-guided bat algorithm for feature selection. *The Scientific World Journal*, 1–10.
- Terzic, J., Terzic, E., Nagarajah, R., & Alamgir, M. (2013). *Ultrasonic fluid quantity measurement in dynamic vehicular applications*. Springer International Pu.
- Tong, S., & Chang, E. (2001, October). Support vector machine active learning for image retrieval. In *Proceedings of the ninth ACM international conference on Multimedia* (pp. 107–118).
- Tripathi, P., Vishwakarma, S. K., & Lala, A. (2015, December). Sentiment analysis of english tweets using rapid miner. In *2015 International Conference on Computational Intelligence and Communication Networks (CICN)* (pp. 668–672). IEEE.
- Tsao, H. Y., Chen, M. Y., Lin, H. C. K., & Ma, Y. C. (2019). The asymmetric effect of review valence on numerical rating: A viewpoint from a sentiment analysis of users of TripAdvisor. *Online Information Review*, 43(2), 283–300.
- Zhang, L., Wang, S., & Liu, B. (2018). Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1253.
- Zhang, L., Zhou, W., & Jiao, L. (2004). Wavelet support vector machine. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 34(1), 34–39.



---

<b>Etik Beyanı</b>	: <i>Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder. Aksi bir durumun tespiti halinde ÖHÜİBF Dergisinin hiçbir sorumluluğu olmayıp, tüm sorumluluk çalışmanın yazar(lar)ına aittir.</i>
<b>Yazar Katkıları</b>	: <i>1. yazarın katkı payı: %60, 2. yazarın katkı payı: %40</i>
<b>Çıkar Beyanı</b>	: <i>Yazarlar arasında çıkar çatışması yoktur.</i>
<b>Teşekkür (Varsa)</b>	: <i>Yayın sürecinde katkısı sağlayan hakemlere, editöre ve yardımcı editöre teşekkür ederiz.</i>
<b>Ethics Statement</b>	: <i>The authors declare that ethical rules are followed in all preparation processes of this study. In case of detection of a contrary situation, ÖHÜİBF Journal does not have any reponsibility and all reponsibility belongs to the authors of the study.</i>
<b>Author Contributions</b>	: <i>1st author's contribution rate: 60%, 2nd author's contribution rate: 40%</i>
<b>Conflict of Interest</b>	: <i>There is no conflict of interest between the authors.</i>
<b>Acknowledgement</b>	: <i>We would like to thank the referees, editör and assistant editör who contributed to the publication process.</i>

---