

OTELLERE DAİR MÜŞTERİ TATMİNİNİN TAHMİNLENMESİ: MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE BİR UYGULAMA

Atilla SUNCAK ¹

Fatma Selin SAK ²

Hilal ÖZTAY ÇAĞAN ³

ÖZ

Yapay zekâ algoritmalarının pek çok alanda kullanımının yaygınlaşmasıyla birlikte, pazarlama çalışmalarındaki kullanımı da gündeme gelmeye başlamıştır. Bu çalışmanın amacı bir yapay zekâ uygulaması olan makine öğrenmesi tekniklerinin pazarlamada kullanımına dair bir örnek sunmaktır. Bu amaçla müşteri tatmininin makine öğrenme teknikleri ile tahminlenmesinin hangi başarı düzeyi ile mümkün olduğu araştırılmıştır. Araştırmada, dünyadaki en büyük seyahat platformu olma özelliğini taşıyan Tripadvisor web sitesinden elde edilen veriler kullanılmıştır. 993 otele ait özellikler ve bu otellerin tatmin skorları araştırmacılar tarafından kayıt altına alınmıştır. Otel özellikleri ile tatmin skoru arasındaki ilişkiler dikkate alındığında; ‘işletme olanak sayısı’, ‘odalardaki özellik sayısı’, ‘oda türü sayısı’, ‘yer skoru’, ‘temizlik skoru’, ‘değer skoru’ ve ‘yorum sayısı’ ile tatmin skoru arasında orta düzeyde ilişki olduğu; ‘hizmet skoru’ ile de yüksek düzeyde ilişki olduğu sonuçları elde edilmiştir. Veri seti, % 70 eğitim verisi, % 30 test verisi olacak şekilde ikiye ayrılmıştır. Modeller, eğitim verisi ile eğitilmiş, sonra da model başarıları test verileri ile ortaya konmuştur. İlgili değişkenlere dayalı olarak en düşük % 71, en yüksek % 81 başarı oranıyla otellere dair tahminlemenin yapılmasının mümkün olduğu sonuçları elde edilmiştir.

Anahtar kelimeler: Müşteri tatmini, Otel müşteri değerlendirmeleri, Yapay zekâ, Makine öğrenmesi

Doi: 10.15659/ppad.17.3.1497396

1 Öğr. Gör. Dr., Kastamonu Üniversitesi, Kastamonu Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü- Bilgisayar Programcılığı, atillasuncak@kastamonu.edu.tr,
ORCID NO: 0000-0003-0282-2377

2 Dr. Öğr. Üyesi, Giresun Üniversitesi, Sivil Havacılık Yüksekokulu-Havacılık Yönetimi Bölümü,
selin.sak@giresun.edu.tr,
ORCID NO: 0000-0001-7105-7387

3 Dr. Öğr. Üyesi, Kastamonu Üniversitesi, Araç Rafet Vergili Meslek Yüksekokulu, Tıbbi Tanıtım ve Pazarlama Programı, hoztay@kastamonu.edu.tr,
ORCID NO: 0000-0002-1904-7963, Sorumlu Yazar

Geliş Tarihi / Received: 07.07.2024, Kabul Tarihi / Accepted: 04.09.2024

PREDICTING CUSTOMER SATISFACTION REGARDING HOTELS: AN APPLICATION USING MACHINE LEARNING TECHNIQUES

ABSTRACT

With the increasing use of artificial intelligence (AI) algorithms in many areas, applying AI in marketing studies has also begun to emerge. The aim of this study is to present an example of the use of machine learning techniques, an artificial intelligence application, in marketing. For that purpose, the accuracy rate of predicting customer satisfaction with machine learning techniques was investigated. In this research, data obtained from the Tripadvisor website, which is the largest travel platform in the world, was used. The features of 993 hotels and their satisfaction scores were recorded by the researchers. Considering the correlations of hotel features with satisfaction score; while medium level of correlation was observed with 'number of amenities', 'number of room features', 'number of room types', 'location score', 'cleanliness score', 'value score', and 'number of reviews'; high level of correlation was found with the 'service score'. The dataset was divided into 70% training data and 30% test data. Models were trained with the training data and then their performance was tested with the test data. Using these variables, it was found that it is possible to predict satisfaction with accuracy rates ranging from a minimum of 71% to a maximum of 81% through various machine learning methods.

Keywords: Customer satisfaction, Hotel customer reviews, Artificial intelligence, Machine learning

1. Giriş

Harcanabilir gelirlerin artması, iletişim ve ulaşım olanaklarının gelişmesiyle birlikte küresel bir eğilim haline gelen turizm, günümüzde birçok ülke için önemli ekonomik kaynaklardan biri olarak nitelendirilebilir. Türkiye, büyük ölçekli turizm ekonomilerinden biri olarak turizm sektöründe önemli bir potansiyele sahiptir ve 21. Yüzyıl'da küresel sıralamada 20. sıradan 16. sıraya yükselerek iyi bir artış göstermiştir. Gelişen teknolojiye ve dijitalleşmeye bağlı olarak turizm altyapısının teknolojik hale getirilmesi bu alandaki önemli trendlerden biri olarak görülmektedir (İstikbal, 2022). Etkisi göz önünde bulundurulduğunda turizme doğrudan ya da dolaylı olarak etki eden gelişmelerin takip edilmesi önemli bir sorun haline almaktadır. Bu açıdan değerlendirildiğinde nispeten yeni bir uygulama olan yapay zekânın kullanımının giderek yaygınlaşması ve farklı alanlardaki kullanımı dikkat çekmektedir. Turizm pazarlaması alanında da kullanım örneklerine rastlanmaktadır. Ancak bunlar daha çok duygu analizi, otel özelliklerinin belirlenmesi, talep tahminleri, rezervasyon iptallerinin tahmin edilmesi (Akyol, 2021; Chen vd, 2023; Nguyen vd, 2023; Pereira ve Cerqueira, 2022; Singgalen, 2024) amaçlarıyla yürütülen çalışmalarla sınırlıdır ve yapay zeka uygulamalarının turizm pazarlamasındaki kullanım alanlarının genişletilmesine katkı sağlayacak pek çok çalışmaya ihtiyaç vardır.

Turizmle ilgili bilgi teknolojisi, bir pazarlama aracı olarak kullanılmaktan öte bilgiye dayalı bir yaratım aracına dönüşmüştür (Suyunchaliev vd., 2020). Bilgi teknolojilerinin kullanımı geniş kitleler tarafından benimsedikçe, internet tabanlı sosyal ağların kullanımı artmıştır. Bu sayede çevrim içi siteler aracılığıyla geçmiş müşteri deneyimlerinin incelenmesini sağlayan çeşitli bilgi edinme platformları ortaya çıkmıştır (Kafa ve Demircioğlu, 2022). Kullanıcıların görüşlerini internet tabanlı uygulamalar vasıtasıyla daha fazla yayınlamasıyla, bu platformların kitlesel etki yaratma rolü de giderek artmaktadır. Bu platformlar kullanıcıların ürün ve hizmetlerle ilgili deneyimlerini az bir maliyetle çevrimiçi topluluklara etkili bir şekilde yaymalarına olanak tanır (Banerjee ve Chua, 2016). Deneyimi yayma motivasyonları, hizmet tesislerine olanaklarını iyileştirmeleri konusunda yardımcı olacak öneriler sunmak, diğer tüketicilerin karar vermelerine yardımcı olmak ya da tatmini ifade etmek şeklinde sıralanabilir (Gretzel ve Yoo, 2008; Hennig-Thurau vd., 2004). Oteller hakkında yapılan değerlendirmelerin müşterilerin otel seçimi üzerinde önemi bir etkiye sahip olması, kullanıcılar tarafından oluşturulan içeriklerin incelenmesi gerekliliğini beraberinde getirmektedir (Ergüt, 2019). Günümüzde, tüketicilerin ürünler hakkındaki görüşlerini sosyal ağlarda ifade etmesinin gücüne tanıklık edilen bir süreç söz konusudur (Araque vd., 2017). TripAdvisor, otellerle ilgili bilgi arayışı amacıyla en fazla ziyaret edilen web sitelerinden birisidir (Banerjee ve Chua, 2016). Bu çalışma ile makine öğrenmesi teknikleri ile otellerin müşteri tatminini tahmin edilebilir mi? sorusuna cevap aranmıştır. Bunun için TripAdvisor'da müşteri deneyimlerine dayalı olarak oluşturulan bilgiler incelenerek müşteri tatminini etkileyen parametreler

belirlenmeye alıřılmıřtır. alıřmanın amacı, tüketicilerin gelecek davranıřlarını kestirebilme becerisine sahip yapay zekâ algoritmalarının iřlerliđini belirlemektir. Son yıllardaki önemli yeniliklerden biri olan yapay zekâ sayesinde müşteri verileri kullanarak gelecek davranıřların tespit edilmesi mümkün olduđundan önemine vurgu yapılması gereken bir konu haline gelmiřtir (Bayuk ve Demir, 2019). Yapay zekâ algoritmaları tüketicilerin gelecekteki davranıřlarını öngörebilme yeteneđine sahiptir. Bu sayede pazarlama uzmanlarının müşteri davranıřlarını daha dođru bir şekilde anlaması mümkün hale gelmektedir (Aktař ve avuřođlu, 2023). alıřma kapsamında makine öđrenme (ML) yoluyla tatmini belirleyen parametrelere ait gerek müşteri deneyimlerine dayalı olarak elde edilen veriler iřlenmiřtir. Parametrelere ait belirli özellikleri taşıyan konaklama iřletmelerinin gelecekteki müşteriler tarafından hangi puanlarla dereceleneceđinin başarılı şekilde tahmin edilip edilmeyeceđi belirlenmiřtir.

2. Literatür Taraması

2.1. Müřteri Tatmini

Müřteri tatmini, pazarlama literatüründe ve uygulamasında merkezi bir rol oynamaktadır (Yi vd., 2021) ve iřletme sadakati için önemli bir olgudur (Khan vd., 2022; Nguyen vd., 2020). Müřterilerin tatmin olmaları halinde, tekrar alıřveriř yapmaları ve başkalarına da aynı yerden alıřveriř yapmalarını tavsiye etmeleri mümkün olmaktadır (Purba vd., 2022). Tatmin olan bir müşteri olumlu ađızdan ađıza bilgi yayarak, iřletme adına gönüllü tanıtımlar yapmakta ve yeni müşteri ekme maliyetini düřürmektedir (Wulandari, 2022). Bu bağlamda büyük veya küçük bir iřletmede tatmin, iřletmenin başarısına yol aan ana faktördür ve her iřletme için ok önemli bir hedeftir. Öyle ki, iřletmeler arasındaki rekabet yalnızca ürün kalitesinde deđil, aynı zamanda satıř öncesinde, sırasında ve sonrasında gösterilen özen konusunda giderek řiddetlenmektedir (Tien vd., 2021). Bu aıdan müřterinin nasıl tatmin olacađının anlařılması önemli bir ihtiya haline gelmektedir.

Müřteri tatmini en genel anlamıyla; performansın beklentiler ile uyumlu olması veya beklentileri ařması durumudur. Aksi halde müřterinin tatminsizliđi söz konusu olmaktadır (Sao Mai ve Tri Cuong, 2021; Bi vd., 2020; Yi vd., 2021). Müřteri tatmini aynı zamanda bir ürün veya hizmetin başarısını anlamak için kullanılan bir ölçüdür. Müřterilerin deđerlendirmeleri ile müřteri tatminine yönelik seviye öngörülebilir ve buna uygun ürün veya hizmetler sunulabilir (Khairawati, 2020). Özellikle konaklama sektöründe müřteri tatmini, müřteri sadakati, tekrar satın alma, olumlu ađızdan ađıza iletiřim ve nihayetinde daha yüksek karlılık ve otellerin finansal performansını iyileřtirmeye büyük ölçüde katkıda bulunduđu için ilgi eken bir konu olarak kabul edilmiřtir (Zhang ve Kim, 2021). Müřteri tatmini otel hizmetlerinin mükemmelliđinin bir göstergesi olarak görülmekte ve tüketici bakıř aısına göre üretilen hizmetlerin performans ölçüsü olarak kullanılmaktadır (Kim ve Chung, 2020).

Otel sektöründe müşteri tatminine yönelik yakın zamanda yapılan çalışmalara bakıldığında kalite (Nunkoo vd., 2020; Jacksen vd., 2021), verimlilik (Kim ve Chung, 2020; Firman ve Ilyas, 2021), deneyim (Kim ve Kim, 2022; Nguyen ve Ho, 2023), sadakat (Rahmah vd., 2021; Tabelessy vd., 2023), yenilikçilik (Truong vd., 2020; Cabral ve Marques, 2023), katılım (Han ve Anderson, 2022; Sharma ve Singh, 2021), değerler birlikte yaratılması (Jin ve Chen, 2021; Bouchriha vd., 2023) gibi konular dikkati çekmektedir ve bu çalışmalar, müşteri tatmininin otel işletmelerine olumlu olarak katkıda bulunduğunu doğrulamaktadır.

Müşteri geri bildirim ve tatmini, konaklama sektöründe başarının kritik göstergeleridir. Müşteri yorumlarının diğer müşterilerin ziyaret kararları ve otellerin marka itibarı üzerindeki etkisi, otel yöneticilerinin müşteri tatminini kapsamlı bir şekilde araştırmasını gerektirmektedir (Shu vd., 2023). TripAdvisor gibi çevrimiçi platformlar müşterilerin algısını şekillendirirken, rezervasyon kararlarını etkilemektedir (Kaludewa ve Abeywickrama, 2023). Mevcut müşterilerin yaşadıkları deneyim sonucunda görüş ve yorumlarını paylaşmaları, potansiyel müşteriler için alternatiflerin belirlenmesi ve değerlendirilmesinde yol gösterici olmakta ve dolayısıyla işletmelerin eksik ya da geliştirilmesi gereken yönlerinin belirlenmesinde önem taşımaktadır. Böylece işletmelerin hizmetlerini iyileştirmeleri için doğru adımların atılması ile müşteri tatmini sağlanabilmektedir (Yılmaz, 2020).

2.2. Müşteri Deneyimlerinin Değerlendirilmesi

Bilgi teknolojilerinin kullanımı geniş kitleler tarafından benimsendikçe internet ağlarına ulaşım imkânı artmıştır, bu sayede çevrim içi siteler aracılığıyla geçmiş müşteri deneyimlerinin incelenmesini sağlayan çeşitli bilgi edinme imkânları ortaya çıkmıştır (Kafa ve Demircioğlu, 2022). İşletmelerin tek taraflı bilgi üreten rolünün benimsendiği anlayış terk edilmiş yerine tüketicilerin de bilgiyi ürettiği, yönettiği ve deneyimleriyle ortak bilgi üretici rolü üstlendiği anlayış ortaya çıkmıştır (Arıca ve Çorbacı, 2019). Sonuçta, turistlerin deneyim öncesi araştırmalar yapmak, seyahatlerini planlamak ve deneyim sonrası bilgi paylaşmak gibi faaliyetlere katılabileceği mecralar söz konusu olmuştur (Hyde, 2008). Bu mecralardaki paylaşımlar tüketicilerin duygularını, düşüncelerini ve tutumlarını paylaştıkları zengin içerikli değerlendirmelere ve tavsiyelere dönüşmüştür. Kullanıcıların bu alanlarda oluşturdukları içerik gün geçtikçe genişlemektedir (Berezina vd., 2016). Buna paralel olarak bu platformlardaki müşteri paylaşımlarının sayısı (Arıca ve Çorbacı, 2019) ve otel rezervasyonu yapmadan önce çevrimiçi değerlendirme platformlarından bilgi edinen müşteri sayısı artış göstermektedir (Anderson, 2012).

Gerçekleşmiş müşteri deneyimlerine dayalı değerlendirmeler potansiyel müşterilerin seyahat kararlarını önemli ölçüde şekillendirmektedir (Arıca ve Çorbacı, 2019; Erdem, 2020; Kafa ve Demircioğlu, 2022; Narangajavana vd., 2017). Tüketici değerlendirmelerine bağlı olarak otellere dair değerlendirme puanlarının,

diđer tüketicilerin otel rezervasyon niyetini önemli biçimde etkilediđini ortaya koyan çalışmalar söz konusudur. Oteller hakkındaki olumlu deđerlendirmeler fazla olduđuunda tüketicilerin rezervasyon niyetleri artış gösterirken, deđerlendirmelerin olumsuz olması tüketicinin söz konusu otele rezervasyon yaptırma niyeti önünde bir engel oluşturmaktadır (Chan vd., 2017). Puana dayalı deđerlendirmelere ilave olarak olumlu yorumların da tüketici güvenini arttırdığı ortaya konmuřtur (Sparks ve Browning, 2011).

TripAdvisor, otellerle ilgili bilgi arayışı amacıyla en fazla ziyaret edilen web sitelerinden birisidir. Bu web sitesinde kullanıcıların oluşturduđu içerik ve deđerlendirmeler yer almaktadır. (Banerjee ve Chua, 2016). Tripadvisor her ay 463 milyon müşteriye ulaşabilen dünyadaki en büyük seyahat platformudur. 8,6 milyon konaklama yeri hakkında deđerlendirme ve yorumlara ulaşabilme imkânı sunmaktadır (tripadvisor.com, 2024). Bu yönüyle TripAdvisor platformu tüketicileri ciddi şekilde etkileme potansiyeline sahiptir. TripAdvisor benzeri deđerlendirme platformları, turistlerin deneyim öncesi bilgi edindiđi ve hizmet sonrası deneyime katılabilecekleri alanlardır. Otel seçimlerine dair karar süreçlerinde başka müşterilerin ürettiđi bilgiyi kullanırlar, deneyim sonrası ise kendileri de içeriđi geliřtirmeye katkı sağlayabilirler (Ak ve Altunöz Sürücü, 2018).

Bazı tüketiciler tutumlarını ve tatminlerini yansıtmının bir yolu olarak, bazıları ise diđer tüketicilere yardımcı olmak amacıyla deđerlendirmeler yapabilirler. Hizmet sağlayıcıların olanaklarının iyileřtirilmesi konusunda iřletmeye öneri sunmak amacıyla deđerlendirmeler yapılması da söz konusu olmaktadır (Hennig-Thurau vd., 2004; Gretzel ve Yoo, 2008). İřletmeler de müşterilerin memnuniyetlerini arttırabilmek adına elde edilen bu yorumlar ile pazarlama faaliyetlerini yeniden deđerlendirebilmekte ve iyileřtirme çalışmaları yapabilmektedir (Arıca ve Çorbacı, 2019; Zhao vd., 2019; Kafa ve Demirciođlu, 2022). İřletmelere sağladıđı fayda açısından deđerlendirildiđinde tüketici deneyimlerine dayanan yorumlar etkili şekilde ve az bir maliyetle yapılabilen iřletme reklamları olarak ifade edilebilir (Ünal, 2019).

Geliřen teknoloji, yapay zekâ uygulamaları sayesinde deneyimlerin paylaşılmına olanak sağlamaktan da öteye gitmektedir. Yapay zekâ kavramı makinelerin düşünebilmesi ve düşünerek hareket edebilmesi yeteneđini kazandıran teknoloji şeklinde açıklanabilir. Bu özelliklere sahip makinelerin ve yazılımların kullanımı, insanlara ve iřletmelere yardımcı olabilmektedir (Ercan, 2020). Çeřitli çalışmalarda yapay zekâ uygulamalarıyla seyahatler hakkında karar süreçlerine dair belirsizliklerin giderilmesinde, turizm ve akıllı sistemlerin birbirlerini tamamlayan nitelikte olduđu ortaya konmuřtur. Müřteri iliřkileri yönetimi, satın alma karar desteđi, ödeme sistemleri ve seyahat danıřmanlıkları bu uygulamalara örnek olarak gösterilebilir (Zlatanov ve Popesku, 2019). Yapay zekâ, pazarlama alanında kişiselleřtirme, gerçekçi kestirimlerde bulunma, yeniden hedefleme, yeniden pazarlama, programatik reklamcılık, pazar bölümlendirme, yerelleřtirme ve görüntü tanıma gibi birçok uygulama alanında kullanılabilir (Aktaş ve

Çavuşoğlu, 2023). Bir yapay zekâ uygulaması olan makine öğrenme yöntemleri ise büyük ölçekli ve yapılandırılmamış verileri işleyebilmektedir ve güçlü bir tahmin performansına sahiptir. Makine öğrenme ile metinler, görseller, videolar ya da sesler gibi yapılandırılmamış şekildeki verilerin ya da ağ verilerinin işlenmesi mümkündür. Tahminleme amacıyla da etkili olarak kullanılabilen bir uygulamadır (Ma ve Sun, 2020). Turizm alanındaki çalışmalar değerlendirildiğinde yapay zekâ uygulamaları ile otellerdeki olası iptal durumlarının tahmin edilebileceği ortaya konmuştur. Bu sayede doğru iptal tahminleri ile yönetsel karar süreçlerinde pratik katkılar sağlanması amaçlanmıştır. Elde edilen doğru ve yorumlanabilir iptal tahmini, otelcilere yönetsel karar alma süreçlerinde pratik çıkarımlar sunmaya daha da katkıda bulunmaktadır (Chen vd., 2023). Makine öğrenmesi teknikleri ile otellere dair duygu analizlerinin yapılması son yıllarda örnekleri görülen bir uygulamadır. Nguyen vd. (2023) Agado ve Booking platformlarındaki müşteri yorumlarını temel alarak yürüttükleri çalışma ile mutlu depresif, kızgın ve umutlu olacak şekilde müşteri duygularının ön plana çıktığını belirlemiştir. Müşterilerin gerçek hizmet deneyimleri sonucu ortaya çıkan memnuniyet durumları bu analiz ile tespit edilebilmektedir. Müşterilerin duygularının tanımlanması ile taleplerin keşfedilmesi ve hizmetlerin iyileştirilmesi mümkün olabilmektedir. Bir başka çalışmada da makine öğrenmesi uygulamalarıyla otellere taleplerin belirlenmesinin geleneksel tahmin yöntemlerinden daha iyi sonuçlara ulaştırdığını ortaya koymuştur (Pereira ve Cerqueira, 2022). Makine öğrenmesi yöntemlerinin iyi tahmin yapabilme yeteneği göz önünde bulundurulduğunda müşteri tatmininin belirlenmesi konusunda da katkı sağlama potansiyeli olduğu düşünülmektedir.

3. Yöntem

Bu çalışmada sayısal verilere dayalı olarak değerlendirme yapılarak niceliksel araştırma yaklaşımı benimsenmiştir. Çalışmanın amacı otellerde konaklamış müşterilerin deneyim sonrası tatminlerini (tripadvisor skorlarını) belirleyen değişkenlere bağlı olarak, makine öğrenmesi teknikleriyle, müşteri tatmininin tahmin edilmesinin mümkün olup olmadığını ortaya koyacak örnek bir uygulama yapmaktır.

3.1. Verilerin Toplanması

Çalışmanın verilerini Tripadvisor sitesinde yer alan Antalya bölgesindeki otellerin müşteri değerlendirmeleri oluşturmaktadır. Veriler 22.01.2024-02.02.2024 tarihleri arasında, araştırmacılar tarafından kayda alınmıştır. Otel araması yapılırken en fazla otel sayısına sahip yerlerden biri olduğu için veri sayısını maksimum tutmak adına Antalya şehri tercih edilmiş ve her lokasyonun ziyaret edilme amacı ve beklenen özellikleri farklı olduğu için araştırma bu şehirle sınırlı tutulmuştur. 15.02.2024 - 15.03.2024 tarihleri olacak şekilde belirli bir tarih aralığı için arama yapılmıştır. 993 otele ait veriler kullanılarak çalışma yürütülmüştür. Değerlendirmeye alınan değişkenler; otel yıldız sınıfı, oda sayısı, konuşulan dil sayısı, işletme olanak sayısı, odaların özellik sayısı, oda türü sayısı, yer skoru, hizmet skoru, temizlik skoru, değer skoru, yürünebilirlik, 1 km içerisindeki

restoran sayısı, 1 km ierisindeki gezilecek yer sayısı ve yorum sayısı; tatmin deęiřkeni olarak da tripadvisor skoru gibi sistematik olarak ulařılabilen tm bilgileri kapsamaktadır.

3.2. Verilerin Analizi


Tatmin deęiřkeni hakkında tahmin yapabilmek iin bir yapay zekâ teknięi olan makine renme sınıflandırıcılarından faydalanılmıřtır. Uygulamaya hazırlık olarak, tm deęiřkenlerin tatmin ile olan iliřkileri hakkında fikir verebilmesi iin korelasyon analizi Python programlama dili ile yapılmıř ve ısı haritası ile gsterilmiřtir. Veri seti normal daęılım gstermedięi iin Spearman korelasyon katsayısı kullanılarak (Bykztrk, 2015) sonu deęiřkeni ile (tatmin) dřk, orta ve yksek iliřkili deęiřkenler tespit edilmiřtir. Orta ve yksek dzeydeki iliřkiler ile makine renmesi uygulamasına geilmiřtir.

Makine renmesi, temel olarak verilerin, verilere ait sınıf etiketlerine (tatmin skoru) gre doęru sınıflandırılmasına dayanmaktadır. Bunu gerekleřtirebilmek iin temel prensip řu řekildedir; ncelikle tm veriler eęitim ve test verisi olmak zere ikiye ayrılır (Genelde %20-30 arası test verisi). Eęitim verileri, sınıf etiketleriyle birlikte makine renmesi algoritmasına girdi verisi olarak verilir. Algoritma, veriler ile ait oldukları sınıflar arasında rntler ıkarır ve bu rntleri kullanarak bir eęitilmiř model oluřturulur. Sonrasında test verileri, eęitilmiř modele girdi olarak verilir ve renmiř olduęu rntleri kullanarak her bir verinin sınıf tahminini yapar. Daha sonra, modelin tahminleri ile gerek sınıf etiketleri karılařtırılır ve karmařıklık matrisi oluřturulur. Bu matristen yola ıkararak, deęerlendirme metrikleri yardımı ile modelin bařarısı lmlmř olur.

alıřmada Destek Vektr Makinesi (Support Vector Machine - SVM), Rastgele Orman (Random Forest - RF), K-En Yakın Komřuluk (K-Nearest Neighbor - KNN) ve Karar Aęaları (Decision Tree) makine renme algoritmaları ile sınıflandırmalar gerekleřtirilmiřtir. Son olarak SPSS aracılıęı ile korelasyon analizleri uygulanmıř ve sonuların tutarlı olup olmadıęı, makine renme uygulamasında kullanılan deęiřkenlerin sonu deęiřkeni zerinde anlamlı etkilerinin olup olmadıęı tespit edilmiřtir.


3.3.Makine renmesi Yntemleri

Destek Vektr Makinesi veya Support Vector Machine (SVM), Vapnik (1999) tarafından sınıflandırma ve regresyon amacıyla kullanılan denetimli bir renme yntemidir. SVM'ler, gl bir yapısal risk minimizasyonu teorisinden tretilmiř, eęitim sırasındaki kayıplar yerine yapısal riskleri azaltmayı amalamaktadır (Vapnik, 1998; Suykens ve Vandewalle, 1999). SVM algoritmasının teknik amaı, farklı sınıfların veri noktalarını ayırt etmeye yarayan bir hiperdzlem tanımlamaktır (řekil 1) ve bu sayede veri sınıflandırma, regresyon, kmeleme gibi uygulamalarda, kabul edilebilir verimliliklerinden dolayı yaygın olarak kullanılmaktadır (Sun vd., 2009; Garla vd., 2013; Fayed ve Atiya, 2021).



Şekil 1. SVM Tarafından Örnek Uzayda Veri Sınıflandırması Amacıyla Tanımlanan Bir Hiperdüzlem [Xia vd., 2015]


Rastgele Orman veya Random Forest (RF), Breiman (2001) tarafından tanıtilan ve sınıflandırma, regresyon gibi amaçlar için sıkça tercih edilen, bir topluluk öğrenme modeli ve gelişmiş bir karar ağacı yöntemidir (Aria vd., 2021). Yapısı gereği RF modelleri, sınıflandırma esnasında her bir düğümünde farklı örnek kümeleri barındıran birçok karar ağacı oluşturmaktadır (Şekil 2) ve oluşturulan her bir ağacın performanslarının ortalaması sayesinde daha doğru bir nihai doğruluk elde ettiğinden dolayı, RF algoritması sıklıkla tercih edilmektedir (Liang ve Zhao, 2019).



Şekil 2. Rastgele Orman Algoritmasının Genel Mimarisi (Witten ve Frank, 2002)


K-En Yakın Komşuluk veya K-Nearest Neighbor (KNN), makine öğrenmesinde parametrik olmayan ve örnek tabanlı, en kolay yaklaşımlı bir sınıflandırıcı modelidir [Zhang vd., 2017a; Zhang vd., 2017b]. KNN ilk olarak her bir test verisi için uzaklık hesaplaması kullanarak, eğitim setindeki en yakın k sayıdaki komşu örnekleri bulur (Zhu vd., 2014). Daha sonra en yakın k sayıdaki eğitim verisi arasından ana sınıfı

sahip örnekleri temel olarak, test verilerinin atanması gereken sınıflarını tahmin eder [Deng vd., 2016]. Şekil 3'te, $k=3$ (en içteki daire) ve $k=5$ (dıştaki daire) olmak üzere, yeşil verinin sınıf etiketinin tahminlenmesi gösterilmiştir.



Şekil 3. KNN Sınıflandırması Örneği ($k=3$ (içteki daire) ve $k=5$ (dıştaki daire) olmak üzere) (Prasatha vd., 2017)

Karar Ağaçları veya Decision Trees (DT), veri sınıflandırma uygulamalarında kullanılan en önemli makine öğrenimi sınıflandırıcılarından biridir. Genelde yukarıdan aşağıya (tümden gelim) bir yaklaşım ile özyinelemeli ve böl-ve-fethet mantığı ile sınıflandırma işlemini gerçekleştirir (Breiman, 2017; Witten ve Frank, 2002). Ağaç yapısı bir kök ve bu köke bağlı düğümler ile yapraklardan oluşmaktadır. Her düğüm, bir özneliği temsil eder ve örnekler (veriler), düğümü oluşturan özneliğin varsaydığı değerler tarafından belirlenen alt dallara bölünür (Witten ve Frank, 2002; Colledani vd., 2023). Ağacı sonuna gelindiğinde her bir ulaşılan yaprak düğüm, o verinin atanacak sınıfını temsil etmektedir (Şekil 4).



Şekil 4. Karar Ağacı Örneği (www.edrawmax.com)

3.3.1. Hiperparametre Optimizasyon Tekniđi

Grid Search, makine öğrenmesi modellerinin hiperparametre optimizasyonu için yaygın olarak kullanılan bir tekniktir. Hiperparametrelerin tüm kombinasyonlarının bir tabloda tanımlanması ve kapsamlı bir şekilde denenmesinin basit bir yaklaşım olduğu bilinmektedir [Michalski vd., 1984]. Her ne kadar tüm hiperparametre kombinasyonlarının hesaplanacağı garanti edilse de; hesaplama açısından son derece zaman maliyetli olması, gözlemlenen sonuca uyum sağlayamaması ve hesaplama sayısını sınırlayamaması gibi önemli dezavantajları da bulunmaktadır. Ayrıca hiperparametre sayısı arttıkça kombinasyon sayısı da katlanarak artar ve bu da verimsiz performanslara neden olur (Pontes vd., 2016; Ensor ve Glynn, 1997).

3.3.2. Deđerlendirme Metrikleri

Her bir modelin performansını ölçmek için; Accuracy (Dođruluk), Precision (Kesinlik), Recall (Duyarlılık) ve F1 Score (f1 puanı) metrikleri uygulanmıştır. Metriklerin formülleri sırasıyla (1) - (2) - (3) - (4) denklemlerinde gösterilmiştir. TP, TN, FP ve FN kısaltmaları sırasıyla True-Positive (Dođru-pozitif), True-Negative (Dođru-negatif), False-Positive (Yanlış-pozitif) ve False-Negative (Yanlış-negatif) anlamına gelmektedir.

$$\text{Dođruluk} = \frac{\text{Dođru tahminlerin sayısı}}{\text{Tüm tahminlerin sayısı}} \quad (1)$$

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

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

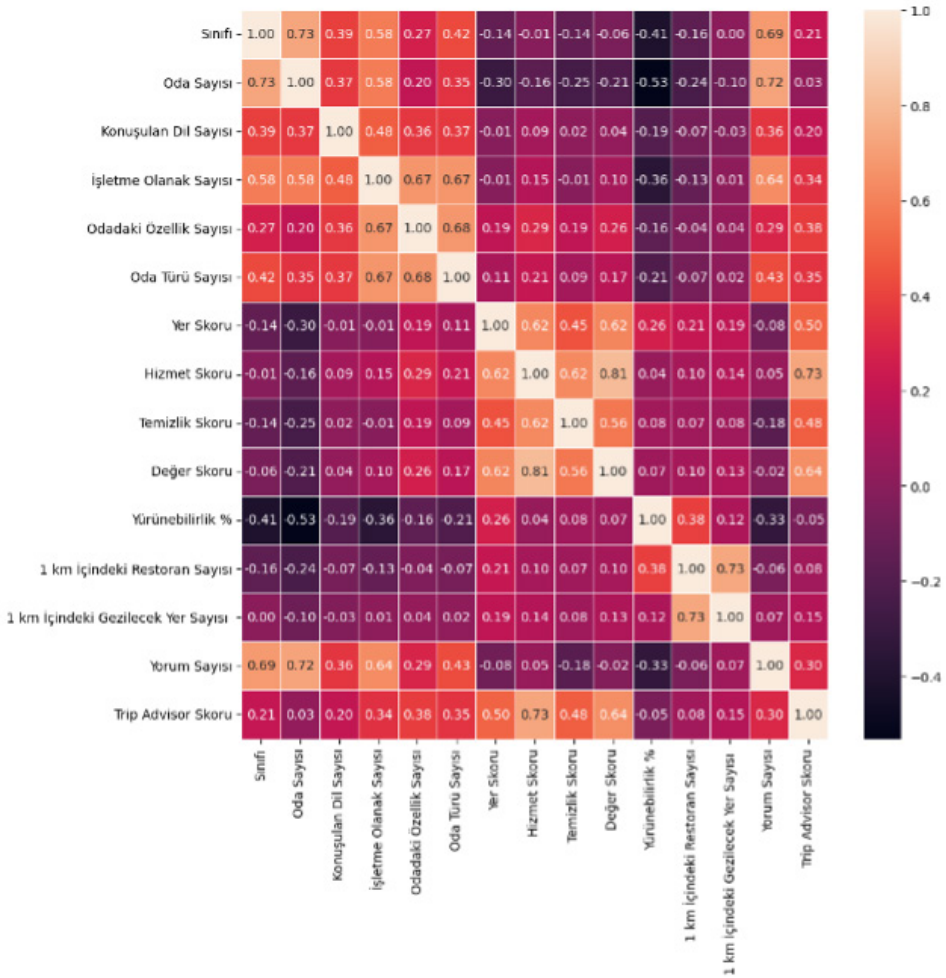
$$\text{F1 Puanı} = \frac{2 * \text{kesinlik} * \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (4)$$

4. Bulgular

4.1. Isı Haritasının Oluşturulması

Çalışmaya dâhil edilen tüm deđişkenlerin tripadvisor skoru ile olan korelasyonunun belirlenebilmesi için Python Programlama Dili ile Spearman Sıra Farkları Korelasyon Katsayısı kullanılarak ısı haritası oluşturulmuştur. İlişkilerin düzeyine

karar verebilmek için Büyüköztürk (2015) tarafından önerilen aralıklar kriter olarak kabul edilmiştir. Şekil 5'te verilen ısı haritasına göre tripadvisor skoru ile otel sınıfı, oda sayısı, konuşulan dil sayısı, yürünebilirlik, 1 km içerisindeki restoran sayısı, 1 km içerisindeki gezilecek yer sayısı arasında düşük düzeyde ilişki olduğu; işletme olanak sayısı, odalardaki özellik sayısı, oda türü sayısı, yer skoru, temizlik skoru, değer skoru, yorum sayısı arasında orta düzeyde ilişki olduğu, hizmet skoru ile de yüksek düzeyde ilişki olduğu sonuçları elde edilmiştir. Buna göre sonuç değişkeni üzerindeki nispi etkileri dikkate alınarak orta ve yüksek düzeyde ilişkileri olduğu tespit edilen değişkenlerle makine öğrenme uygulaması gerçekleştirilmiştir.



Şekil 5. Isı Haritası

4.2. Makine Öğrenme Uygulamalarına Ait Bulgular

Verilerin doğru sınıflandırılması ve başarılarının yüksek olması, makine öğrenmesi sınıflandırıcılarının optimum seviyede modellenmesiyle mümkün olmaktadır. Bu optimum modelleme ise, hiperparametrelerin en uygun şekilde atanması ile sağlanmaktadır. Bu sebeple, çalışmada kullanılan her bir makine öğrenmesi modeline, Grid Search hiperparametre optimizasyonu uygulanmış ve en optimum modeller oluşturularak, makine öğrenmesi uygulaması yapılmıştır.

Veri seti; %70 eğitim ve %30 test verisi olmak üzere ikiye ayrılmıştır. Eğitim verileri ile modeller eğitilmiş; test verileri ile model başarıları sınanmıştır. Test verileri sonrası model başarıları *doğruluk*, *kesinlik*, *duyarlılık* ve *f1 puanı* değerlendirme metrikleri yardımı ile ölçülmüş ve her bir modelin performansı analiz edilmiştir.

Tablo 1, SVM modeline ait performans sonuçlarını göstermektedir. Tabloya göre; tatmin skoru 2 ve 3 olan otel verilerine ait sonuçlarda, modelin oldukça doğru şekilde eğitildiği görülmektedir. Modelin genel başarı ise %76 doğruluk oranında sonuçlanmıştır. Bu durumda SVM modeli ile tatmini tahmin etme başarısının % 76 olduğu söylenebilir.

Tablo 1. SVM Modelinin Değerlendirme Sonuçları

Tatmin Skoru	Kesinlik	Duyarlılık	F1 Puanı	Doğruluk
2	0,95	0,96	0,95	
3	0,90	0,83	0,87	
4	0,76	0,41	0,54	0,76
5	0,53	0,85	0,66	
Ortalama	0,79	0,76	0,75	

Tablo 2, Random Forest modeline ait performans sonuçlarını göstermektedir. Bu modelde, tüm skorlardaki otellerin verilerinin oldukça başarılı bir şekilde eğitilebildiği görülmektedir. Modelin genel başarı ise %81 doğruluk oranında sonuçlanmıştır. Random Forest modelinin tatmini tahmin etme başarısının % 81 oranı ile en başarılı model olduğu görülmektedir.

Tablo 2. Random Forest Modelinin Değerlendirme Sonuçları

Tatmin Skoru	Kesinlik	Duyarlılık	F1 Puanı	Doğruluk
2	0,85	0,95	0,90	
3	0,85	0,81	0,83	
4	0,78	0,62	0,69	0,81
5	0,76	0,88	0,82	
Ortalama	0,81	0,82	0,81	

Tablo 3, KNN modeline ait performans sonuçlarını göstermektedir. Analiz sonuçlarına göre, başarısı en düşük olan model KNN modeli olmuřtur. Bunun sebeplerinden biri, tatmin skoru 4 ve 5 olan otel verilerinin, model eğitime olumsuz yönde etki etmesidir. Modelin genel başarı ise %71 doğruluk oranında sonuçlanmıştır.

Tablo 3. KNN Modelinin Deęerlendirme Sonuçları

Tatmin Skoru	Kesinlik	Duyarlılık	F1 Puanı	Doęruluk
2	0,86	0,99	0,92	
3	0,70	0,87	0,78	
4	0,58	0,45	0,50	0,71
5	0,61	0,52	0,56	
Ortalama	0,69	0,71	0,69	

Tablo 4, Decision Tree modeline ait performans sonuçlarını göstermektedir. Tablodan da anlaşılacağı üzere; tatmin skoru 2, 3 ve 5 olan otel verilerine ait sonuçlar, modelin doğru şekilde eğitildiğini göstermektedir. Modelin genel başarı ise %76 doğruluk oranında sonuçlanmıştır.

Tablo 4. Decision Tree Modelinin Deęerlendirme Sonuçları

Tatmin Skoru	Kesinlik	Duyarlılık	F1 Puanı	Doęruluk
2	0,85	0,89	0,86	
3	0,76	0,81	0,78	
4	0,68	0,61	0,64	0,76
5	0,73	0,72	0,73	
Ortalama	0,75	0,76	0,75	

Tüm sonuçlar deęerlendirildiğinde, mevcut veri seti için en başarılı ve uygun olan makine öğrenmesi modelinin Random Forest modeli olduğu; en başarısız modelin ise KNN modeli olduğu görülmektedir.

4.3. SPSS Uygulamalarına Ait Bulgular

Makine öğrenme uygulamasıyla tahmin başarısının belirlenmesinde tatmin ile orta ve yüksek korelasyonu olduğu görülen deęişkenler ele alınmıştır. Ancak burada deęişkenlerin anlamlı ya da anlamsız olan etkileri belirlenmemektedir. Bu uygulamaların pazarlama arařtırmalarındaki kullanımları oldukça yeni olduğu için alanda kullanılan klasik yöntemlerle karşılaştırma yapılarak tutarlı sonuçlara ulaşıp ulaşılmayacağının belirlenmesi gerekli görülmüřtür. Bu amaçla SPSS programı ile de korelasyon analizi gerçekleştirilmiştir.

Gerçekleştirilen normallik testi ile veri setinin normal dağılım göstermediği için nanparametrik veri setinde kullanılması önerilen Spearman Brown Sıra

Farkları korelasyon katsayısı kullanılmıştır. Bu katsayı önceki aşamada Python programlama dilinde de kullanılan ile aynıdır. Korelasyon analizi sonuçları Tablo 5’de gösterilmektedir.

Tablo 5. Korelasyon Analizi Sonuçları

	Tripadvisor skoru		
	r	R ²	p
İşletme olanak sayısı	,337	,11	,00***
Odalardaki özellik sayısı	,379	,14	,00***
Oda türü sayısı	,351	,12	,00***
Yer skoru	,500	,25	,00***
Hizmet skoru	,728	,52	,00***
Temizlik skoru	,482	,23	,00***
Değer Skoru	,643	,41	,00***
Yorum sayısı	,301	,09	,00***

***p≤,001

Tablo incelendiğinde tripadvisor skoru ile işletme olanak sayısı arasında orta düzeyde pozitif ve anlamlı bir ilişki olduğu (p<,001); odalardaki özellik sayısı ile orta düzeyde pozitif ve anlamlı bir ilişki olduğu (p<,001); oda türü sayısı ile orta düzeyde pozitif ve anlamlı bir ilişki olduğu (p<,001); Yer skoru ile orta düzeyde pozitif ve anlamlı bir ilişki olduğu (p<,001); hizmet skoru ile yüksek düzeyde pozitif ve anlamlı bir ilişki olduğu (p<,001); temizlik skoru ile orta düzeyde pozitif ve anlamlı bir ilişki olduğu (p<,001); değer skoru ile orta düzeyde pozitif ve anlamlı bir ilişki olduğu (p<,001); yorum sayısı ile orta düzeyde pozitif ve anlamlı bir ilişki olduğu (p<,001) sonuçları elde edilmiştir.

Determinasyon sayısı (R²) değerlendirildiğinde ise tatmindeki varyansın % 11’inin işletmelerdeki olanak sayısından, % 14’ünün odalardaki özellik sayısından, % 12’sinin oda türü sayısından, % 25’inin yer skorundan, % 52’sinin hizmetten, % 23’ünün temizlikten, % 41’inin değerden, % 9’unun yorum sayısından kaynaklandığı görülmektedir. Tüm değişkenlerle tripadvisor skoru arasında pozitif yönlü bir ilişki olduğu görüldüğünden değişkenlerin sayısal değerleri arttıkça tripadvisor skorunun artış gösterdiği, azaldıkça da düşüş gösterdiği söylenebilir.

5. Sonuç

Yapay zekâ teknolojilerinin kullanım alanları ve kullanım yoğunlukları her geçen gün artış göstermektedir. Son yıllarda turizm pazarlaması alanındaki çeşitli kullanımları da söz konusu olmaya başlamıştır. Turizm hizmetlerinin pazarlanmasında makine öğrenme algoritmalarının daha çok duygu analizi çalışmalarında kullanıldığı görülmekle birlikte (Acar ve Uğur, 2021; Ahmetoğlu

ve Dař, 2020; İnan, 2019; Nguyen vd, 2023; Singgalen, 2024), otellerde en çok etkisi olan özelliklerin belirlenmesinde (Akyol, 2021), otellere yönelik talebin tahmin edilmesinde (Pereira ve Cerqueira, 2022), rezervasyon iptallerinin tahmin edilmesinde (Chen vd, 2023) kullanılabileceğini gösteren çalışmalar da bulunmaktadır.

Çalışmada elde edilen sonuçlara göre işletme olanak sayısı, odalardaki özellik sayısı, oda türü sayısı, yer skoru, temizlik skoru, hizmet skoru, değer skoru ve yorum sayısı ile tripadvisor skorları arasında orta ve yüksek düzeyde ilişkiler belirlenmiştir. Bu değişkenler kullanılarak, çeşitli makine öğrenme yöntemleri ile en düşük %71, en yüksek ise %81 başarı oranlarıyla tatminin tahmin edilmesinin mümkün olduğu görülmektedir. Gerçekleştirilen uygulamalar genel olarak başarılı olsa da sınırlı bir bakış açısı sunmaktadır. Bu uygulamaların pazarlama arařtırmalarında kullanılabileceğini ifade edebilmek için alanda sıklıkla kullanılan diğer uygulamalarla da karşılaştırılması yapılmıştır. Analizler sonucunda makine öğrenme yoluyla tahmin yapmada kullanılan değişkenlerin sonuç değişkeni olan tatmin ile orta ve yüksek düzeyde ilişki içerisinde olduğu ve bu değişkenlerin tatmini pozitif ve anlamlı şekilde etkilediği görülerek sonuçların makine öğrenme uygulaması ile tutarlı olduğu bulunmuştur. Bu ilave çalışmalar sonucunda tahminleme yapmak amacıyla gerçekleştirilecek çalışmalarda Random Forest yönteminin kullanılabileceği ifade edilebilir. Görülmektedir ki belirli parametrelere dair veriler mevcut olduğunda, makine öğrenme modelleri başarılı şekilde tahminleme yapma potansiyeline sahiptir.

Teknolojinin gelişmesiyle birlikte turizm işletmelerinin yöneticileri için de çeşitli fırsatlar söz konusu olmaktadır. Turistlerin tatillerinden memnun ve tatmin olmuş olarak ayrılması bu kişilerin tripadvisor gibi web sayfalarında oteli yüksek şekilde puanlanmasına neden olarak diğer tüketicileri etkilemektedir. Ayrıca turizm işletmelerine geri bildirim sağlayarak iyileştirmelerin yapılabilmesine olanak sağlamaktadır. Yeni uygulama araçlarının gelişmesiyle birlikte ise gerçekleşmiş deneyimlerden hareketle henüz gerçekleşmemiş deneyimlerin tahmin edilebilmesi mümkün olmaktadır. Çalışma sonuçlarına göre işletmeler daha iyi olanaklara sahip olduklarında, odaların özellik ve tür sayısı fazla olduğunda ya da daha temiz otellere sahip olduklarında müşteri tatmininin artmasını sağlayabilirler.

Sayıca ve anlamca tutarlı olan veri setleri ile yürütülecek gelecek çalışmalarda, model başarılarının artış göstereceği de ifade edilebilir. Ayrıca makine öğrenmesi sınıflandırıcılarına ek olarak sayıca daha büyük veri setleri ile uygulanan derin öğrenme yöntemlerinin kullanımı ile tahmin etme performansları daha başarılı olan modeller geliştirilerek arařtırma kısıtları ortadan kaldırılabilir.

Makine öğrenmesi yöntemleri, önemli arařtırma konularının ele alınmasına yardımcı olma konusunda büyük bir potansiyele sahiptir. Önümüzdeki on yıllar, makine öğrenmesi yöntemleriyle desteklenen otomatik yapay zekâ araçlarının teknoloji, büyük veri ve rekabetin etkisiyle iş ve pazarlamanın her alanında

yaygınlaşması beklenmektedir (Ma ve Sun, 2020). Bu ve benzeri çalışmaların araştırmacılar tarafından uygulanmasıyla birlikte yapay zeka uygulamalarının pazarlamada hangi alanlarda kullanılabileceğinin belirlenmesi önemlidir. Bu çalışma ile önemli sonuçlar elde edilmiş olmakla birlikte yeni bir bakış açısı sunduğundan dolayı sınırlı yönleri olduğu göz önünde bulundurularak değerlendirildiğinde daha faydalı olacağı unutulmamalıdır. Büyük potansiyeline rağmen turizm pazarlaması araştırmalarındaki kullanım alanlarının sınırlı olduğu dikkat çekmektedir. Bu çalışma ile makine öğrenme uygulamalarının turizm pazarlamasındaki kullanım alanlarının genişletilmesine katkı sağlamak amaçlanmıştır.

Kaynakça

- Acar, A., & Uęur, İ. (2021). Uluslararası zincir otellere yönelik Tripadvisor yorumlarının duygu analizi yöntemi ile deęerlendirilmesi: Ankara rneęi. *Türk Turizm Arařtırmaları Dergisi*, 5(3), 1803-1814. doi:<https://doi.org/10.26677/TR1010.2021.820>
- Ahmetoęlu Ak, S., & Altunöz Sürücü. (2018). Termal otel işletmelerinin çevrimiçi tüketici deęerlendirmeleri bağlamında incelenmesi: Tripadvisor örneęi. *19. Ulusal Turizm Kongresi*. Afyonkarahisar.
- Aktaş, M., & Çavuşoęlu, S. (2023). Pazarlamada yapay zekâ. E. S. Yılmaz içinde, *Dijitalleşme ve Pazarlama Arařtırmaları*. Gaziantep: Özgür Yayınları.
- Akyol, M. (2021). Clustering Hotels and analyzing the importance of their features by machine learning techniques. *Journal of Computer Science and Technologies*, 2(1), 16-23.
- Anderson, C. K. (2012). The Impact Of social media on lodging performance. *Cornell Hospitality Report*, 12(15), 6-12.
- Araque, O., Corcuera-Platas, I., Sánchez-Rada, J. F., & Iglesias, C. A. (2017). Enhancing deep learning sentiment analysis with ensemble techniques in social applications. *Expert Systems with Applications*, 77(1), 236-246. doi:<https://doi.org/10.1016/j.eswa.2017.02.002>
- Aria, M., Cuccurullo, C., & Gnasso, A. (2021). A comparison among interpretative proposals for random forests. *Machine Learning with Applications*, 6, 1-8. doi:<https://doi.org/10.1016/j.mlwa.2021.100094>
- Arıca, R., & Çorbacı, A. (2019). Turizm sektöründe müşterilerin bilgi üretici rolü: Adıyaman'daki turistik çekiciliklere yönelik Tripadvisor sitesinde yer alan yorumlar üzerine bir arařtırma. *Seyahat ve Otel İşletmecilięi Dergisi*, 16(3), 437-455. doi:<https://doi.org/10.24010/soid.655292>
- Banerjee, S., & Chua, A. Y. (2016). In search of patterns among travellers' hotel ratings in TripAdvisor. *Tourism Management*(53), 125-131. doi:<https://doi.org/10.1016/j.tourman.2015.09.020>
- Bayuk, M. N., & Demir, B. N. (2019). Endüstri 4.0 kapsamında yapay zekâ ve pazarlamanın geleceęi. *International Journal Of Social, Humanities and Administrative Sciences*, 5(19), 781-799. doi: <http://dx.doi.org/10.31589/JOSHAS.163>
- Berezina, K., Bilgihan, A., Çobanoęlu, C., & Okumuş, F. (2016). Understanding satisfied and dissatisfied hotel customers: text mining of online hotel reviews. *journal of hospitality marketing & management*, 25(1), 1-24. doi:<https://doi.org/10.1080/19368623.2015.983631>

- Bi, J.-W., Liu, Y., Fan, Z.-P., & Zhang, J. (2020). Exploring asymmetric effects of attribute performance on customer satisfaction in the hotel industry. *Tourism Management*, 77(104006), <https://doi.org/10.1016/j.tourman.2019.104006>.
- Bouchriha, Z., Farid, S., & Ouiddad, S. (2023). Enhancing value co-creation behaviors through customer engagement in the moroccan hotel context: how does it influence customer satisfaction and brand image? *Journal of Quality Assurance in Hospitality & Tourism*, 1-26. <https://doi.org/10.1080/1528008X.2023.2165595>.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32. doi:<https://doi.org/10.1023/A:1010933404324>
- Breiman, L. (2017). *Classification and regression Tree*. New York: Routledge.
- Büyüköztürk, Ş. (2015). *Sosyal bilimler için veri analizi el kitabı* (21. b.). Ankara: Pegem Akademi.
- Cabral, A., & Marques, J. (2023). How innovation can influence customer satisfaction– case study of The Saccharum Hotel in Madeira. *International Journal of Innovation Science*, 15(1), 80-93. <https://doi.org/10.1108/IJIS-03-2021-0061>.
- Chan, I. C., Lam, L. W., Chow, C. W., Fong, L. H., & Law, R. (2017, Ekim). The effect of online reviews on hotel booking intention: the role of reader-reviewer similarity. *International Journal of Hospitality Management*, 66, 54-65. doi:<https://doi.org/10.1016/j.ijhm.2017.06.007>
- Chen, S., Ngai, E. W., Ku, Y., Xu, Z., Gou, X., & Zhang, C. (2023, July). Prediction of hotel booking cancellations: integration of machine learning and probability model based on interpretable feature interaction. *Decision Support Systems*, 170, 1-14. doi:<https://doi.org/10.1016/j.dss.2023.113959>
- Colledani, D., Anselmi, P., & Robusto, E. (2023). Machine learning-decision tree classifiers in psychiatric assessment: An application to the diagnosis of major depressive disorder. *Psychiatry Research*, 322, 1-7. doi:<https://doi.org/10.1016/j.psychres.2023.115127>
- Deng, Z., Zhu, X., Cheng, D., Zong, M., & Zhang, S. (2016). Efficient KNN classification algorithm for big data. *Neurocomputing*, 195, 143-148. doi:<https://doi.org/10.1016/j.neucom.2015.08.112>
- Ensor, K. B., & Glynn, P. W. (1997). Stochastic optimization via grid search. *Lectures in Applied Mathematics-American Mathematical Society*, 33, 89-100.
- Ercan, F. (2020). Turizm pazarlamasında yapay zekâ teknolojilerinin kullanımı ve uygulama örnekleri. *AHBVÜ Turizm Fakültesi Dergisi*, 23(2), 394-410. doi:10.34189/tfd.23.02.009

- Erdem, B. (2020). Çevrimiçi yorumların davranıřsal niyete etkisi: Google haritaları örneęi. *International Social Mentality and Research Thinkers Journal*, 6(30), 357-364. doi:http://dx.doi.org/10.31576/smryj.477
- Ergüt, Ö. (2019). Otel yorumlarının metin madencilięi teknikleri ile incelenmesi. *International Congress Of Management Economy And Policy 2019 Autumn Proceedings Book*, (s. 103-114). İstanbul.
- Fayed, H. A., & Atiya, A. F. (2021). Decision boundary clustering for efficient local SVM. *Applied Soft Computing Journal*, 110. doi:https://doi.org/10.1016/j.asoc.2021.107628
- Firman, A., & Ilyas, G. (2021). The effect of kaizen strategy on customer satisfaction: empirical study on budget hotels in Makassar City. *Point of View Research Management*, 2(1), 1-9.
- Garla, V., Taylor, C., & Brandt, C. (2013). Semi-supervised clinical text classification with laplacian SVMS: An application to cancer case management. *Journal of Biomedical informatics*, 46(5), 869-875. doi:https://doi.org/10.1016/j.jbi.2013.06.014
- Gretzel, U., & Yoo, K.-H. (2008). Use and impact of online travel reviews. *Information and Communication Technologies in Tourism 2008* (s. 35-46). Vienna: Springer. doi:DOI: 10.1007/978-3-211-77280-5_4 · Source: DBLP
- Han, S., & Anderson, C. (2022). The dynamic customer engagement behaviors in the customer satisfaction survey. *Decision Support Systems*, 154, https://doi.org/10.1016/j.dss.2021.113708.
- Hennig-Thurau, T., Gwinner, K. P., Walsh, G., & Gremler, D. D. (2004). Electronic word-of-mouth via consumer-opinion platforms: What motivates consumers to articulate themselves on the internet? *Journal of Interactive Marketing*, 18(1), 35-52. doi:https://doi.org/10.1002/dir.10073
- Hyde, K. F. (2008). Information processing and touring planning theory. *Annals of Tourism Research*, 35(3), 712-731. doi:https://doi.org/10.1016/j.annals.2008.05.001
- İnan, h. e. (2019). otel yorumlarının sınıflandırılmasında makine öğrenmesi algoritmalarının karşılaştırılması ve Eskişehir otellerine yönelik yorumların duygu analizi. *20.Ulusal Turizm Kongresi Bildiriler Kitabı* (s. 1106-1111). Eskişehir: Anadolu Üniversitesi Basımevi.
- İstikbal, D. (2022). *Türkiye'nin turizm ekonomisi: Kazanımlar ve beklentiler*. İstanbul: Seta Yayınları.
- Jacksen, Chandra, T., & Putra, R. (2021). Service quality and brand image on customer satisfaction and customer loyalty at Pesonna Hotel Pekanbaru. *Journal of Applied Business and Technology (JABT)*, 2(2), 142-153.

- Jin, R., & Chen, K. (2021). Impact of value cocreation on customer satisfaction and loyalty of online car-hailing services. *Journal of Theoretical and Applied Electronic Commerce Research*, 16(3), 432-444. <https://doi.org/10.3390/jtaer16030027>.
- Kafa, N., & Demircioğlu, E. (2022). Gökçeada'daki konaklama işletmelerine yönelik çevrimiçi müşteri değerlendirmelerinin incelenmesi: Tripadvisor örneği. *Journal of Recreation and Tourism Research /JRTR*, 9(2), 52-69. doi:DOI: <https://doi.org/10.5281/zenodo.6774476>
- Kaludewa, N., & Abeywickrama, K. (2023). Customer expectations and satisfaction: An analysis of negative customer reviews on tripadvisor for classified hotels in Western Province . *2nd International Research Symposium on Management* (s. 466-469). Faculty of Management Studies, Rajarata University of Sri Lanka.
- Khairawati, S. (2020). Effect of customer loyalty program on customer satisfaction and its impact on customer loyalty. *International Journal of Research in Business & Social Science*, 9(1), 15-23. <https://doi.org/10.20525/ijrbs.v9i1.603>.
- Khan, R., Salamzadeh, Y., Iqbal, Q., & Yang, S. (2022). The impact of customer relationship management and company reputation on customer loyalty: The mediating role of customer satisfaction. *Journal of Relationship Marketing*, 21(1), 1-26. <https://doi.org/10.1080/15332667.2020.1840904>.
- Kim, C., & Chung, K. (2020). Measuring customer satisfaction and hotel efficiency analysis: An approach based on data envelopment analysis. *Cornell Hospitality Quarterly*, 63(2), 1-10. <https://doi.org/10.1177/1938965520944914>.
- Kim, Y.-J., & Kim, H.-S. (2022). The impact of hotel customer experience on customer satisfaction through online reviews. *Sustainability*, 14(2), <https://doi.org/10.3390/su14020848>.
- Liang, Y., & Zhao, P. (2019). A machine learning analysis based on big data for eagle ford shale formation. *SPE Annual Technical Conference and Exhibition*. Calgary, Alberta. doi:<https://doi.org/10.2118/196158-MS>
- Ma, L., & Sun, B. (2020). Machine learning and AI in marketing – connecting computing power to human insights. *International Journal of Research in Marketing*, 37(3), 481-504. doi:<https://doi.org/10.1016/j.ijresmar.2020.04.005>
- Michalski, R. S., Carbonel, J. G., & Mitchell, T. M. (2013). *Machine learning: An artificial intelligence approach*. Springer Science & Business Media.

- Narangajavana, Y., Fiol, L. J., Tena, M. Á., Artola, R. M., & García, J. S. (2017). The influence of social media in creating expectations. An empirical study for a tourist destination. *Annals of Tourism Research*(65), 60-70. doi:<https://doi.org/10.1016/j.annals.2017.05.002>
- Büyüköztürk, D., Pham, V., Tran, D., & Pham, D. (2020). Impact of service quality, customer satisfaction and switching costs on customer loyalty. *Journal of Asian Finance, Economics and Business*, 7(8), 395-405. <https://doi.org/10.5267/j.msl.2019.12.034>.
- Nguyen, N., Nguyen, T.-H., Nguyen, Y.-N., & Doan, D. (2023). Machine learning-based model for customer emotion detection in hotel booking services. *Journal of Hospitality and Tourism Insights*. doi:<https://doi.org/10.1108/JHTI-03-2023-0166>
- Nguyen, V.-H., & Ho, T. (2023). Analyzing online customer experience in hotel sector using dynamic topic modelling and net promoter score. *Journal of Hospitality and Tourism Technology*, 14(2), 258-277. <https://doi.org/10.1108/JHTT-04-2021-0116>.
- Nunkoo, R., Teeroovengadum, V., Ringle, C., & Sunnassee, V. (2020). Service quality and customer satisfaction: The moderating effects of hotel star rating. *International Journal of Hospitality Management*, 91, <https://doi.org/10.1016/j.ijhm.2019.102414>.
- Pereira, L. N., & Cerqueira, V. (2022). Forecasting hotel demand for revenue management using machine learning regression methods. *Current Issues in Tourism*, 25(17), 2733-2750. doi:[10.1080/13683500.2021.1999397](https://doi.org/10.1080/13683500.2021.1999397)
- Pontes, F. J., Amorim, G. F., Balestrassi, P. P., Paiva, A. P., & Ferreira, J. R. (2016). Design of experiments and focused grid search for neural network parameter optimization. *Neurocomputing*, 186, 22-34. doi:<https://doi.org/10.1016/j.neucom.2015.12.061>
- Prasatha, S. V., Alfeilat, H. A., Hassanat, A. B., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., & Salman, H. S. (2019). Effects of distance measure choice on KNN classifier performance - A review. *ArXiv*.
- Purba, J., Juliana, J., Budiono, S., Purwanto, A., Pramono, R., & Djakasaputra, A. (2022). The relationship between hotel service quality and customer satisfaction: An empirical study of spa hotels in Indonesia. *International Journal of Entrepreneurship*, 26(1), 1-11.
- Rahmah, N., Kara, M., Bakry, M., & Muin, R. (2021). Effect of service quality on customer loyalty with customer satisfaction as an intervening variable in Shariah Hotel (Study at Pesonna Hotel in Makassar, South Sulawesi). *International Journal of Multicultural and Multireligious Understanding*, <http://dx.doi.org/10.18415/ijmmu.v8i4.2479>.

- Sao Mai, D., & Tri Cuong, D. (2021). Relationships between service quality, brand image, customer satisfaction, and customer loyalty. *The Journal of Asian Finance, Economics and Business*, 8(3), 585-593. <https://doi.org/10.13106/jafeb.2021.vol8.no3.0585>.
- Sharma, D., & Singh, B. (2021). Understanding the relationship between customer satisfaction, customer engagement and repeat purchase behaviour. *Vision: The Journal of Business Perspective*, 27(4), 449-457. <https://doi.org/10.1177/0972262921992593>.
- Shu, Z., Torralba, M., Carrasco, R., & López, M. (2023). Assessing customer satisfaction of London luxury hotels with the AHP method and the servperf scale: A case study of customer reviews on TripAdvisor. *Procedia Computer Science*, 221, 73-80. <https://doi.org/10.1016/j.procs.2023.07.011>.
- Singgalen, Y. A. (2024). Sentiment classification of robot hotel content using NBC and SVM algorithm. *Journal of Computer System and Informatics*, 5(2), 442-453. doi:<https://doi.org/10.47065/josyc.v5i2.4924>
- Sparks, B. A., & Browning, V. (2011). the impact of online reviews on hotel booking intentions and perception of trust. *Tourism Management*, 32(6), 1310-1323. doi:<https://doi.org/10.1016/j.tourman.2010.12.011>
- Sun, A., Lim, E.-P., & Liu, Y. (2009). On strategies for imbalanced text classification using SVM: A comparative study. *Decision Support Systems*, 48(1), 191-201. doi:<https://doi.org/10.1016/j.dss.2009.07.011>
- Suykens, J. A., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural Processing Letters*, 9, 293-300. doi: <https://doi.org/10.1023/A:1018628609742>
- Tabelessy, W., Sitaniapessy, R., & Lekatompessy, D. (2023). Establishing customer satisfaction to increase customer loyalty in Collin Beach Hotel. *Indonesian Journal of Contemporary Multidisciplinary Research*, 2(2), 165-176. <https://doi.org/10.55927/modern.v2i2.3431>.
- Tien, N., Anh, D., Dung, H., On, P., Anh, V., Dat, N., & Tam, B. (2021). Factors impacting customer satisfaction at Vietcombank in Vietnam. *Himalayan Economics and Business Management*, 2(4), 44-51.
- Truong, N., Dang-Pham, D., McClelland, R., & Nkhoma, M. (2020). Exploring the impact of innovativeness of hospitality service operation on customer satisfaction. *Operations and Supply Chain Management*, 13(3), 307-319. <http://doi.org/10.31387/oscm0420272>.
- Ünal, A. (2019). Otel müşterilerinin e-şikâyetlerinin sınıflandırılmasına yönelik bir çalışma. *International Journal of Management Economics & Business*, 15(2), 561-581. doi:<http://dx.doi.org/10.17130/ijmneb.2019252111>

- Vapnik, V. (1998). The support vector method of function estimation. J. A. Suykens, & J. Vandewalle (Dü) içinde, *Nonlinear Modeling* (s. 55-85). Boston, MA.: Springer. doi:https://doi.org/10.1007/978-1-4615-5703-6_3
- Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE Transactions On Neural Networks*, 10(5), 988-999. doi:10.1109/72.788640
- Witten, I. H., & Frank, E. (2002). Data mining: Practical machine learning tools and techniques with Java implementations. *ACM SIGMOD Record*, 31(1), 76-77. doi:<https://doi.org/10.1145/507338.507355>
- Wulandari, D. (2022). Customer satisfaction as A priority in excellent banking services. *Jurnal Manajemen Organisasi dan Industri*, 1(1), 27-34.
- www.tripadvisor.com. (2024, Mart 30.03.2024). Tripadvisor: <https://tripadvisor.mediaroom.com/tr-about-us> adresinden alındı
- Xia, S.-y., Xiong, Z.-y., Luo, Y.-g., & Dong, L.-m. (2015). A method to improve support vector machine based on distance to hyperplane. *Optik*, 126(20), 2405-2410. doi:<https://doi.org/10.1016/j.ijleo.2015.06.010>
- Yi, H.-T., Yeo, C., Amenuvor, F., & Boateng, H. (2021). Examining the relationship between customer bonding, customer participation, and customer satisfaction. *Journal of Retailing and Consumer Services*, 62(102598), 102598. doi:<https://doi.org/10.1016/j.jretconser.2021.102598>.
- Yılmaz, E. (2020). The effects on consumer behavior of hotel related comments on the Tripadvisor website: An Istanbul case. *Advances in Hospitality and Tourism Research (AHTR)*, 8(1), 1-29. <https://doi.org/10.30519/ahtr.536303>.
- Zhang, S., Li, X., Zong, M., Zhu, X., & Cheng, D. (2017a). Learning K for KNN classification. *ACM Transactions on Intelligent Systems and Technology*, 8(3), 1-19. doi:<https://doi.org/10.1145/2990508>
- Zhang, S., Li, X., Zong, M., Zhu, X., & Wang, R. (2017b). Efficient KNN classification with different numbers of nearest neighbors. *IEEE Transactions on Neural Networks and Learning Systems*, 29(5), 1774-1785. doi:10.1109/TNNLS.2017.2673241
- Zhang, X., & Kim, H.-S. (2021). Customer experience and satisfaction of Disneyland Hotel through big data analysis of online customer reviews. *Sustainability*, 13, 1-17. <https://doi.org/10.3390/su132212699>.
- Zhao, Y., Xu, X., & Wang, M. (2019). Predicting overall customer satisfaction: big data evidence from hotel online textual reviews. *International Journal of Hospitality Management*, 76, 111-121. doi:<https://doi.org/10.1016/j.ijhm.2018.03.017>

- Zhu, X., Suk, H.-I., & Shen, D. (2014). A novel matrix-similarity based loss function for joint regression and classification in AD diagnosis. *NeuroImage*, 100, 91-105. doi:<https://doi.org/10.1016/j.neuroimage.2014.05.078>
- Zlatanov, S., & Popescu, J. (2019). Current applications of artificial intelligence in tourism and hospitality. *International Scientific Conference on Information Technology and Data Related Research*, (s. 84-90). doi:<https://doi.org/10.15308/Sinteza-2019-84-90>

EXTENDED ABSTRACT

PREDICTING CUSTOMER SATISFACTION REGARDING HOTELS: AN APPLICATION USING MACHINE LEARNING TECHNIQUES

1. Introduction

This study aims to identify customer satisfaction parameters by examining information derived from customer experiences on TripAdvisor. The study aims to determine the effectiveness of artificial intelligence algorithms in predicting consumers' future behaviors. Emphasizing the importance of this topic is essential since artificial intelligence, one of the significant innovations in recent years, enables the identification of future behaviors using customer data (Bayuk & Demir, 2019). Artificial intelligence algorithms have the capability of predicting consumers' future behaviors. Consequently, marketing experts can understand customer behaviors better (Aktař & Çavuřođlu, 2023). This study processed the data obtained from actual customer experiences that determine satisfaction parameters using machine learning (ML) techniques. The main goal is to accurately predict the ranks of accommodations that possess certain characteristics of parameters for future customers.

2. Conceptual Framework

Customer satisfaction, in its broadest sense, occurs when performance aligns with or exceeds expectations; otherwise, customer dissatisfaction arises (Sao Mai & Tri Cuong, 2021; Bi, Liu, Fan, & Zhang, 2020; Yi, Yeo, Amenuvor, & Boateng, 2021). Customer satisfaction is also a measure used to understand the success of a product or service. The level of customer satisfaction can be observed through customer evaluations, and appropriate products or services can be offered accordingly (Khairawati, 2020). In the hospitality industry, customer satisfaction is considered an important topic because it significantly contributes to customer loyalty, repeat purchases, positive word-of-mouth communication and ultimately, higher profitability and improved financial performance of hotels (Zhang & Kim, 2021). Customer satisfaction is seen as an indicator of the excellence of hotel services and is used as a performance measure of the services produced from the consumer's perspective (Kim & Chung, 2020).

Some consumers write reviews to reflect their attitudes and satisfaction, while others do so to help other consumers. Reviews can also be made to provide suggestions to improve the service providers' facilities (Hennig-Thurau et al., 2004; Gretzel & Yoo, 2008). Review platforms such as TripAdvisor are the platforms where tourists can gather information before their experiences and participate in post-service experiences. They use the information produced by other customers in their decision-making processes regarding hotel choices and

contribute to the development of content themselves after their experiences (Ak & Altunöz Sürücü, 2018).

3. Method

This study adopted a quantitative research approach by evaluating numerical data. The study aims to demonstrate, through an exemplary application, whether it is possible to predict customer satisfaction (TripAdvisor scores) using machine learning techniques based on variables that determine the post-experience satisfaction of customers who have stayed in hotels.

The data for the study consists of customer reviews of hotels in the Antalya region found on the TripAdvisor website. The researchers recorded the data between January 22, 2024 and February 2, 2024. The hotel search was limited to Antalya, and searches were conducted on a specific date range from February 15, 2024, to March 15, 2024. The study was conducted using data from 993 hotels. The evaluated variables include hotel star rating, number of rooms, number of languages spoken, number of amenities, number of room features, number of room types, location score, service score, cleanliness score, value score, walkability, number of restaurants within 1 km, number of attractions within 1 km and the number of reviews. The TripAdvisor score represents the satisfaction variable, encompassing all systematically accessible information.

Machine learning classifiers, an artificial intelligence technique, were utilized to predict the satisfaction variable. As a preparatory step for the application, a correlation analysis was conducted using the Python programming language and Google Colab platform to provide insights into the relationships between all variables and satisfaction, visualized through a heat map. Since the dataset did not exhibit a normal distribution, the Spearman correlation coefficient was used to identify variables with low, medium and high correlations with the outcome variable (satisfaction) (Büyüköztürk, 2015). Consequently, machine learning applications were then performed with medium and high-level relationships.

Advancing technology goes beyond enabling the sharing of experiences through artificial intelligence applications. The concept of artificial intelligence can be explained as the technology that endows machines with the ability to think and act intelligently. Machine learning methods, an artificial intelligence application, can process large-scale and unstructured data and possess strong predictive performance. It is possible to process unstructured data such as texts, images, videos or sounds, as well as network data, using machine learning. It is an application that can be effectively used for prediction purposes (Ma & Sun, 2020).

4. Analyses and Findings

4.1. Creation of the Heat Map

According to the heat map, a low correlation was found between the TripAdvisor

score and variables such as hotel star rating, number of rooms, number of languages spoken, walkability, number of restaurants within 1 km, and number of attractions within 1 km. A medium level of correlation was observed with the number of amenities, number of room features, number of room types, location score, cleanliness score, value score, and number of reviews. A high level of correlation was found with the service score. Based on these relative effects on the outcome variable, a machine learning application was performed using the variables identified to have medium and high levels of correlation.

4.2. Findings from Machine Learning Applications

The dataset was divided into 70% training data and 30% test data. Models were trained with the training data, and their performance was tested with the test data. After testing, model performance was measured using evaluation metrics such as accuracy, precision, recall and F1 score so that the performance of each model was analyzed.

According to the performance results of the Support Vector Machine (SVM) model, it was observed that the model was trained quite accurately for hotel data with satisfaction scores of 2 and 3. The overall success of the model resulted in an accuracy rate of 76%. Therefore, it can be said that the success rate of predicting satisfaction with the SVM model is 76%. For the Random Forest (RF) model, it was observed that it could successfully train the hotel dataset with all scores. The overall success of the model resulted in an accuracy rate of 81%. The Random Forest model was the most successful model, with an 81% success rate in predicting satisfaction. According to the results of the analysis, the K-Nearest Neighbor (KNN) model was the least successful. One of the reasons for this is that hotel data with satisfaction scores of 4 and 5 negatively affected the model training. The overall success of the model resulted in an accuracy rate of 71%. The performance results of the Decision Tree (DT) model indicate that the model was accurately trained for hotel data with satisfaction scores of 2, 3, and 5. The overall success of the model resulted in an accuracy rate of 76%.

Considering all results, it is observed that the most successful and suitable machine learning model for the existing dataset is the RF model, while the least successful model is the KNN model.

4.3. Findings from SPSS Applications

A normality test was conducted, and since the dataset did not exhibit a normal distribution, the Spearman-Brown Rank Correlation Coefficient, which is recommended for non-parametric datasets, was used. This coefficient is the same as the one used in the previous stage with the Python programming language.

A moderate positive and significant relationship was found between the number of amenities and the TripAdvisor score ($p < .01$). When the coefficient of determination

(R2) is evaluated, it is observed that the number of amenities explains 11% of the variance in satisfaction. A moderate positive and significant relationship was found between the number of room features and the TripAdvisor score ($p < .01$). It is observed that the number of room features explains 14% of the variance in satisfaction. A moderate positive and significant relationship was found between the number of room types and the TripAdvisor score ($p < .01$). It is observed that the number of room types explains 12% of the variance in satisfaction. A moderate positive and significant relationship was found between the location score and the TripAdvisor score ($p < .01$). It is observed that the location score explains 25% of the variance in satisfaction. A high positive and significant relationship was found between the service score and the TripAdvisor score ($p < .01$). It is observed that the service score explains 52% of the variance in satisfaction. A moderate positive and significant relationship was found between the cleanliness score and the TripAdvisor score ($p < .01$). It is observed that the cleanliness score explains 23% of the variance in satisfaction. A moderate positive and significant relationship was found between the value score and the TripAdvisor score ($p < .01$). It is observed that the value score explains 41% of the variance in satisfaction. A moderate positive and significant relationship was found between the number of reviews and the TripAdvisor score ($p < .01$). It is observed that the number of reviews explains 9% of the variance in satisfaction.

Since there is a positive relationship between all variables and the TripAdvisor score, it can be said that as the numerical values of the variables increase, the TripAdvisor score also increases.

5. Conclusions and Recommendations

The results identified moderate to high-level relationships between the number of amenities, room features, room types, location score, cleanliness score, service score, value score, and the number of reviews with the TripAdvisor scores. Using these variables, it was found that it is possible to predict satisfaction with accuracy rates ranging from a minimum of 71% to a maximum of 81% through various machine learning methods. Although the applications carried out were generally successful, they provide a limited perspective. To assert that these applications can be used in marketing research, comparisons were made with other commonly used applications in the field. The analyses revealed that the variables used in machine learning prediction have moderate to high-level relationships with the outcome variable, satisfaction and that these variables positively and significantly affect satisfaction, making the results consistent with the machine learning application. Consequently, it can be suggested that the Random Forest method could be used for predictive studies. It is evident that when data on certain parameters are available, machine learning models have the potential to make successful predictions. Furthermore, it can be stated that in future studies conducted with numerically and semantically consistent datasets, model success rates will improve. Additionally, using deep learning methods applied to larger datasets can develop models with

better prediction performance.

Machine learning methods hold great potential in addressing important research topics from all these perspectives. The coming decades are expected to see the proliferation of automated artificial intelligence agents supported by machine learning methods across all areas of business and marketing, driven by technology, big data and competition (Ma & Sun, 2020). Determining the areas in marketing where artificial intelligence applications can be used through the implementation of such studies by researchers is crucial. Although significant results have been obtained with this study, it is important to remember that it offers a new perspective and should be evaluated with its limitations in mind to be more beneficial.