

Dijital Pazarlama Kampanyalarında Müşteri Davranışlarının Dönüşüm Oranları Üzerindeki Etkisi: Veri Analitiği ve Random Forest Modeli Yaklaşımı

Bilge DOĞANLI¹

¹ Dr. Öğr. Üyesi Aydın Adnan Menderes Üniversitesi, Nazilli İİBF, bdoganli@adu.edu.tr, ORCID: 0000-0002-1985-0430

Öz: Bu çalışma, e ticaret siteleri aracılığı ile alışverişlerini gerçekleştiren ve bir dijital pazarlama kampanyasına katılan müşterilerin verilerinin analiz edilerek, dönüşüm (conversion) oranlarını etkileyen faktörlerin incelenmesi ile gerçekleştirilmiştir. Hesaplanan Keşifsel Veri Analizi (EDA) sonucunda, yaş, gelir, web sitesi etkileşimleri ve reklam harcamaları değişkenlerinin, dönüşüm üzerinde önemli etkiler yarattığı tespit edilmiştir. Modelleme aşamasında, dönüşüm oranlarını tahmin etmek için Random Forest sınıflandırma algoritması kullanılmıştır. Modelin genel doğruluk skoru %88.12 olarak hesaplanmıştır. Ancak, modelin “Dönüşüm Yok” sınıfını tahmin etmede zayıf kaldığı, bunun aksine “Dönüşüm” sınıfında yüksek bir performans sergilediği görülmüştür. Dengesiz veri dağılımından kaynaklanan bu durum, modelin iyileştirilmesi için sınıf dengesi stratejilerinin kullanılabileceğini göstermektedir. Analiz sonuçları, reklam harcamaları, web sitesi ziyaretleri ve tıklama oranlarının dönüşüm üzerinde önemli etkileri olduğunu göstermektedir. Bu bulgular, dijital pazarlama stratejilerinin kişiselleştirilmiş yaklaşımlarla optimize edilmesi gerektiğini vurgulamaktadır.

Anahtar Kelimeler: Dijital Pazarlama, Müşteri Dönüşümü, Veri Analitiği, Random Forest, Kampanya Performansı

Jel Kodları: M30, M31, C01

Atıf: Doğanlı, B. (2025). Dijital Pazarlama Kampanyalarında Müşteri Davranışlarının Dönüşüm Oranları Üzerindeki Etkisi: Veri Analitiği ve Random Forest Modeli Yaklaşımı. *Politik Ekonomik Kuram*, 9(2), 596-610. <https://doi.org/10.30586/pek.1605496>

Geliş Tarihi: 22.12.2024

Kabul Tarihi: 23.02.2025



Telif Hakkı: © 2025. (CC BY) (<https://creativecommons.org/licenses/by/4.0/>).

The Effect of Customer Behavior on Conversion Rates in Digital Marketing Campaigns: Data Analytics and Random Forest Model Approaches

Abstract: This study was conducted by analyzing the data of customers participating in a digital marketing campaign and examining the factors affecting conversion rates. As a result of the calculated Exploratory Data Analysis (EDA), it was determined that age, income, website interactions and advertising expenditure variables had significant effects on conversion. In the modeling phase, the Random Forest classification algorithm was used to estimate conversion rates. The overall accuracy score of the model was calculated as 88.12%. However, it was observed that the model was weak in predicting the “No Conversion” class, but on the contrary, it showed high performance in the “Conversion” class. This situation, which arises from the unbalanced data distribution, shows that class balance strategies can be used to improve the model. The results of the analysis show that advertising expenditures, website visits and click-through rates have significant effects on conversion. These findings emphasize that digital marketing strategies should be optimized with personalized approaches.

Keywords: Digital Marketing, Customer Conversion, Data Analytics, Random Forest, Campaign Performance

Jel Codes: M30, M31, C01

1. Giriş

Dijital pazarlama, işletmelerin hedef kitlelerine ulaşma ve müşteri davranışlarını anlamada devrim yaratan bir alandır. Geleneksel yöntemlerin aksine, dijital pazarlama analitiği, veriye dayalı karar almayı sağlayarak kampanyaların etkinliğini artırmaktadır. Örneğin, kampanyaların anlık performans verileri analiz edilerek optimize edilebilmekte ve bireysel müşterilere yönelik olarak kişiselleştirilmiş stratejiler oluşturulabilmektedir. Bu sayede, işletmeler yalnızca dönüşüm oranlarını artırmakla kalmamakta, aynı zamanda hedef kitleleriyle daha güçlü bir bağ kurabilmektedirler. Literatürde, dijital pazarlamanın analitik temellerinin işletme performansını nasıl dönüştürdüğü üzerine geniş bir tartışma bulunmaktadır (Hong, 2024; Ijomah ve diğerleri, 2024; Nwabekee ve diğerleri, 2024).

Veri analitiği, müşteri dönüşüm oranlarını anlamak ve iyileştirmek için güçlü bir araçtır. Bu yaklaşım, müşteri segmentasyonu, tahminsel analiz ve veri görselleştirme gibi yöntemlerle, işletmelere dönüşüm hedeflerine yönelik daha etkili stratejiler oluşturma imkânı sunmaktadır. Örneğin, bir e-ticaret platformunda, müşteri davranışlarına bağlı olarak oluşturulan bir model, dönüşüm oranlarını artıracak olan pazarlama kararlarını destekleyebilmektedir. Bunun sonucunda da, yatırım getirisinde önemli bir artış sağlanabilmektedir. Bilimsel çalışmalar, veri analitiğinin işletmelerin dönüşüm oranlarını artırmada kritik bir role sahip olduğunu vurgulamaktadır (Amajuoyi ve diğerleri, 2024; Doğanlı ve Çelik, 2024; Sun, 2024; Talaat ve diğerleri, 2023).

Random Forest, hem sınıflandırma, hem de regresyon problemlerinde sıklıkla tercih edilen, güçlü bir makine öğrenimi algoritmasıdır. Dijital pazarlama alanında, özellikle müşteri dönüşüm oranlarının tahmin edilmesinde ön plana çıkmaktadır. Bu model, yüksek doğruluk oranı, aşırı uyum (overfitting) sorununu önleme, değişken önem sıralaması belirleme ve dengesiz veri setlerinde etkili çalışma gibi avantajlar sunmaktadır. Örneğin, bir pazarlama kampanyasında hangi faktörlerin müşteri dönüşümünü en çok etkilediğini tespit etmek için kullanılabilir. Literatür, Random Forest modelini, dijital pazarlama da veri odaklı karar süreçlerini güçlendiren bir araç olarak, geniş bir şekilde incelemiştir (Ignatenko ve diğerleri, 2024; Liu ve diğerleri, 2024; Sun, 2024; Talaat ve diğerleri, 2023).

Dijital pazarlama, şirketlerin müşterilere ulaşmak ve hedef kitlelerini büyütmek için kullandıkları en etkili yöntemlerdendir. Artan dijitalleşme uygulamaları ile şirketler daha fazla müşteri verisi toplama ve bu verileri anlamlı bilgilere dönüştürme fırsatı bulmaktadırlar (Gürsakal ve Çelik, 2021). Bu çalışmada, dijital pazarlama kampanyalarının etkinliğini değerlendirmek ve müşteri dönüşümünü etkileyen faktörleri analiz etmek amacıyla bir veri seti üzerinde keşifsel veri analizi (EDA) ve Random Forest sınıflandırma modellemesi gerçekleştirilmiştir. Dijital pazarlama çalışmalarının başarısı, hedef kitleye uygun mesajların ve doğru kanalların seçilmesine bağlıdır (Chaffey & Smith, 2022). Veri madenciliği ve makine öğrenimi teknikleri, kampanya performansını analiz etmek ve müşteri davranışlarını tahmin etmek için güçlü araçlardır (Kotler ve diğerleri, 2016). Bu çalışma ile "digital_marketing_campaign_dataset.csv" veri seti kullanılarak müşteri dönüşümünü tahmin etmek amacıyla bir Random Forest modeli geliştirilmiştir. Geliştirilen model, dönüşüm oranlarını anlamlı bir şekilde artıracak stratejilerin belirlenmesine olanak tanımış ve işletmelerin dijital pazarlama süreçlerini optimize etmelerine katkıda bulunmuştur. Bu doğrultuda, veri analitiği ve makine öğrenimi tekniklerinin, pazarlama kampanyalarının etkinliğini artırmada kritik bir rol oynadığı sonucuna varılmıştır. Dijital pazarlama stratejilerinin kişiselleştirilmesinin gerektiği ve bu bağlamda müşteri segmentasyonu için öneriler geliştirilebileceği de ulaşılan sonuçlar arasındadır. Bunlar: Demografik Segmentasyon (Yaş, cinsiyet, gelir seviyesi veya coğrafi bölgeye dayalı ayrımlar). Davranışsal Segmentasyon (Çevrimiçi alışveriş alışkanlıkları, arama geçmişi veya sadakat düzeyine göre ayrım). Psikografik Segmentasyon (Müşterilerin ilgi alanları, değerleri veya yaşam tarzları) oluşturulması olarak özetlenebilirler. Kişiselleştirme Yöntemleri geliştirmek için kullanılabilecek yöntemlerden bazıları: E-posta ile Pazarlama (Müşterilerin geçmiş satın alma davranışlarına göre özel teklifler sunulması). Dinamik İçerik oluşturma (Web sitelerinde veya reklamlar

kampanyalarında, kullanıcıların ilgisine göre içeriklerin değiştirilmesi). Yapay Zekâ Tabanlı Öneri Sistemleri geliştirilmesi (farklı sitelerin kişiselleştirilmiş öneri algoritmalarına benzer yöntemler geliştirilmesi). Konum Tabanlı Kişiselleştirmelerin geliştirilmesi (Kullanıcıların bulunduğu coğrafi konuma göre özel kampanyalar sunulması). Sosyal Medya kullanımlarına göre kişiselleştirmeler geliştirilmesi (Kullanıcıların önceki etkileşimlerine dayalı, özelleştirilmiş reklam ve içerik önerileri geliştirilmesi) olarak özetlenebilir.

Makalede kullanılan Keşifsel Veri Analizi (Exploratory Data Analysis, EDA), çalışmanın analitik altyapısını güçlendiren temel bir adımdır. EDA'nın temel amacı, verilerdeki temel özelliklerin, ilişkilerin ve örüntülerin anlaşılmasıdır. Bu süreçle beraber, araştırmacılara ham veri üzerinde yapılan ilk incelemeler sonucunda daha derinlemesine analizler için yol haritası sunulmuş olur. Ayrıca, verilerdeki hataların, eksikliklerin veya anomalilerin tespit edilmesine de olanak tanınır. EDA'nın önemi; yalnızca veriyi anlamakla sınırlı kalmayıp, aynı zamanda daha karmaşık modelleme süreçlerine geçiş için sağlıklı bir temel oluşturmaktan kaynaklanmaktadır. Bu bağlamda, EDA, hem sayısal hem de görsel teknikleri içermektedir. Sayısal teknikler, verilerin merkezi eğilim, dağılım ve varyans gibi istatistiksel özetlerini sunarken; görsel teknikler, veri setindeki desenleri, eğilimleri ve sapmaları daha net bir şekilde göstermek için histogram, kutu grafikleri, dağılım grafikleri ve ısı haritaları gibi araçları kullanır.

Çalışmanın temel amacı, müşteri dönüşümünü etkileyen temel faktörleri belirleyerek gelecekteki pazarlama stratejilerine değerli içgörüler sunabilmektir.

1.1 Literatür Taraması

Müşteri davranışının, dijital pazarlama kampanyalarına dönüşüm oranları üzerindeki etkisi, veri analitiği ve Random Forest gibi makine öğrenimi modellerinin kullanılmasıyla daha da önemli hale gelmektedir. Müşteri etkileşimlerini ve tercihlerini anlamak, pazarlamacıların stratejilerini etkili bir şekilde uyarlamalarına ve böylece dönüşüm oranlarının artmasına olanak tanır. Bu konuya ilişkin literatürde yapılmış çeşitli çalışmalar aşağıda özetlenmiştir.

Cui ve diğerleri (2018), dijital pazarlamada, sinir ağlarını uygulayarak müşteri çevrimiçi davranışlarını modellemişlerdir. Tekrarlayan (RNN) ve Evrişimli Sinir Ağlarının (CNN) entegrasyonu, kullanıcı aramalarının ve sayfa ziyaretlerinin arkasındaki anlamsal anlamları analiz ederek dönüşüm oranlarını tahmin etmeyi amaçlamaktadır. Monte Carlo simülasyonlarıyla gelecekteki dönüşüm oranları tahmin edilebilmekte ve kapsamlı çevrimiçi davranış verilerinin pazarlama analizini iyileştirebileceği vurgulanmaktadır. Sunulan yöntem, özellikle reklam, yeniden hedefleme ve dönüşüm tahmini alanlarında etkili pazarlama stratejileri geliştirilmesine olanak sağlamaktadır. Elde edilen sonuçlar, veri odaklı pazarlama stratejilerinin optimizasyonunda bu yaklaşımın büyük bir potansiyele sahip olduğunu göstermektedir.

Yeo ve diğerleri (2020) çalışmalarında, çevrimiçi satın alma dönüşümlerini tahmin etmeye odaklanarak, müşterilerin yalnızca %2'sinin ilk ziyaretlerinde satın alma yaptığını ve dönüşüm tahmininin yeniden hedefleme için kritik olduğunu vurgulamaktadırlar. Yazarlar, müşteri ve ürün düzeyindeki modelleri birleştirerek daha doğru tahminler sunan bir çerçeve önermektedirler. Tarama süresi ve satın alma geçişleri gibi faktörlere dayalı model, bireysel davranışların öngörüsünü güçlendirmektedir. Sonuçlar, yöntemin mevcut yaklaşımlardan daha iyi performans gösterdiğini ve pazarlama stratejilerine değer kattığını göstermektedir.

Guo ve diğerleri (2023) çalışmalarında, çevrimiçi reklamcılıkta dönüşüm oranı tahmininin zorluğunu araştırmaktadırlar. Özellikle gecikmeli geri bildirimin getirdiği önyargıları ele almışlardır. Model doğruluğunu artırmak için görev belirsizliğine dayalı uyarlanabilir bir kayıp işlevi kullanan, tıklama sonrası kullanıcı davranışlarından tahmine dayalı hedefler olarak kullanan yeni bir yöntem önermektedirler. Parametrelili ölçkleme tekniğinin entegrasyonu ayrıca tahminlerdeki kalibrasyon hatalarını azaltmayı amaçlamaktadır. İki gerçek dünya veri kümesi üzerindeki deneysel sonuçlar, önerilen

yöntemin mevcut modellerden önemli ölçüde daha iyi performans gösterdiğini ve daha kalibre edilmiş dönüşüm oranı tahminleri sağladığını göstermektedir. Bu çalışma, gecikmiş geri bildirimin zorluklarının ortasında, tahmin doğruluğunu artırmak için sağlam bir çözüm sunarak literatüre katkıda bulunmaktadır.

Rogić ve Kaščelan (2023), çevrimiçi doğrudan pazarlamada düşük dönüşüm oranlarını ele alarak tahmine dayalı müşteri yanıt modellemesi için yeni bir yaklaşım sunmaktadır. Müşteri yanıt modellerinin makine öğrenimi süreçlerinde karşılaştığı önyargıları vurgulayan yazarlar, Karar Ağacı ve Random Forest gibi sınıflandırıcıların performanslarını artırmak için rastgele alt örnekleme ve Destek Vektör Makinesi yöntemlerini birleştirmektedirler. Çalışma, pazarlama stratejilerine yön verecek özellik gruplarını analiz ederek değerli bilgiler sunmaktadır. Sonuçlar, önerilen yöntemin sınıf dengesizliği problemlerini çözdüğünü ve tahmin doğruluğunu artırdığını göstermektedir. Ayrıca, müşteri yanıtlarını tahmin etmede en etkili faktörleri de belirlemektedir.

Mali ve Mangaonkar (2023) çalışmalarında, dönüşüm oranlarının güçlü tahmin edicilerini belirlemek için bir Random Forest modeli yerine, makine öğrenimi algoritmalarını, özellikle de XGBoost modelini kullanarak, kullanıcı davranışlarını ve uygulama kullanım modellerini analiz ederek, mobil uygulamalarda abonelik dönüşümlerini tahmin etmeye odaklanmışlardır.

Kristiana ve diğerleri (2024), dijital pazarlama kampanyalarında dönüşüm oranlarını artırmak amacıyla, dürtme teorisinin uygulanmasına yönelik sistematik bir literatür taraması sunmaktadırlar. Teorinin etkinliği ile pratik uygulama arasındaki boşlukları belirleyerek, birçok kampanyanın kapsamlı çerçevelerin eksikliğinden yeterince faydalanamadığını vurgulamaktadırlar. İki ana araştırma sorusunu ele alan çalışma, veri odaklı dürtmeler için gerekli bileşenleri ve stratejileri belirlemektedir. Temel bileşenler arasında veri kalitesi, kitle anlayışı, segmentasyon ve AI/ML model geliştirilmesi yer almaktadır. Sonuç olarak, makale mevcut uygulama boşluklarını kapatmayı ve dönüşüm oranlarını artırmayı amaçlayan entegre bir çerçeve önerisi sunmaktadır.

Sonuç olarak bu çalışma, dijital pazarlama kampanyalarında dönüşüm oranlarını etkileyen faktörlerin analizinde Random Forest algoritmasını kullanarak, sınıf dengesizliği sorunlarına dikkat çeken ve bunları ele almayı öneren bir yaklaşımla literatüre katkı sağlamaktadır. Mevcut literatür, genellikle dönüşüm oranlarını etkileyen genel değişkenlere odaklanırken, bu çalışma, yaş, gelir, web sitesi etkileşimleri ve reklam harcamaları gibi spesifik faktörlerin etkilerini detaylı bir şekilde analiz etmektedir. Ayrıca, Random Forest modelinin, sınıf dengesizliğiyle karşılaştığı zorluklar üzerine yapılan değerlendirme, bu alandaki iyileştirme stratejilerinin önemini vurgulamaktadır. Çalışmanın özgün yanı, yalnızca model doğruluğunu değil, aynı zamanda dönüşüm oranlarının öngörülmesinde daha dengeli ve etkili bir performans sağlamaya yönelik öneriler sunmasıdır. Bu bağlamda, elde edilen bulgular, dijital pazarlama stratejilerinin kişiselleştirilmesi ve optimize edilmesi konusunda işletmelere pratik bir yol haritası sunarak akademik ve sektörel uygulamalara değer katmaktadır.

1.2. Veri Seti

“digital_marketing_campaign_dataset.csv” veri seti

(<https://www.kaggle.com/datasets/rabieelkharoua/predict-conversion-in-digital-marketing-dataset>), dijital pazarlama kampanyalarına katılan müşterilerin demografik bilgilerini, pazarlama ve etkileşim verilerini içermektedir. Toplamda 8000 gözlem ve 20 değişken bulunmaktadır. Değişkenler üç ana kategoriye ayrılmıştır:

Demografik Bilgiler:

CustomerID: Her müşteri için benzersiz bir kimlik numarası.

Age: Müşterinin yaşı.

Gender: Müşterinin cinsiyeti.

Income: Müşterinin yıllık geliri (USD).

Pazarlama Verileri:

CampaignChannel: Pazarlama kampanyasının teslim edildiği kanal (E-posta, Sosyal Medya, SEO, vb.).

CampaignType: Kampanya türü (Farkındalık, Dönüşüm, Retention).

AdSpend: Kampanyaya harcanan miktar (USD).

ClickThroughRate ve *ConversionRate*: Müşteri etkileşim oranları.

Müşteri Etkileşim Verileri:

WebsiteVisits, *TimeOnSite*: Web sitesi kullanım istatistikleri.

SocialShares, *EmailOpens*, *EmailClicks*: Sosyal medya ve e-posta etkileşimleri.

PreviousPurchases, *LoyaltyPoints*: Geçmiş satın alma ve sadakat verileri.

Hedef Değişken:

Conversion: Müşterinin dönüşüm yapıp yapmadığını gösteren ikili değişken (1: Evet, 0: Hayır).

Bu makalede, analizler Python programı kullanılarak gerçekleştirilmiş olup, kullanılan veri seti ve kodlar açık kaynak olarak GitHub'a yüklenmiştir. Veri seti ve kodlara <https://github.com/BilgeDoganli09/Dijital-Pazarlama> adresinden ulaşılabilir.

1.3. Dönüşüm Oranı (Conversion Rate)

Dönüşüm oranı, bir işletmenin performansını ölçmek için önemli bir ölçüm olarak kabul edilmektedir (Gold, 2004, Gudigantala, ve diğerleri, 2014). Müşterinin hedeflenen bir aksiyonu gerçekleştirmesi anlamına gelen Dönüşüm, bir ürünün satın alınması, bir formun doldurulması, bir e-posta listesine kaydolma ya da bir mobil uygulamanın indirilmesi gibi farklı şekillerde gerçekleşebilmektedir. Dönüşüm oranı, bir aksiyonu gerçekleştiren müşteri sayısının toplam ziyaretçi sayısına bölünmesiyle elde edilir ve genellikle de yüzde olarak ifade edilir.

Bir E-ticaret web sitesinin dönüşüm oranı web sitesi trafiğinden türetilen bir ölçüdür (Ayanso ve Yoogalingam, 2009). E-ticaret firmalarının temel amaçlarının satış yapmak olduğu düşünüldüğünde dönüşüm oranını, web sitesine giren toplam ziyaretçiler içerisinde bir ürünü satın alanların yüzdesi şeklinde tanımlanabilmektedir (McDowell, Wilson ve Kile, 2016). Ayanso ve Yoogalingam (2009) bu oranın sektörlere bağlı olarak %5 ile %8 arasında olması gerektiğini vurgulamışlardır. Holzwarth ve diğerleri, (2006) bu oranın %2 ile %4 arasında olmasının, işletmelerin mağazalarındaki %54'lük satın almaktan vazgeçme davranışından dolayı (Söderlund ve diğerleri, 2014), oldukça düşük olduğunu vurgulamışlardır. Dönüşüm oranı, işletmeler için çok önemli bir metrik oluştururken, bu oranın yönetilmesi de Web sitesi etkinliğinin analizinde kritik bir rol üstlenmektedir (Difiatta ve diğerleri, 2018, Çolak ve diğerleri 2022).

Müşteri Davranışları ve Dönüşüm İlişkisi: Müşteri davranışları, dönüşüm oranlarını doğrudan etkilemektedir. Örneğin, bir e-ticaret sitesinde bir müşterinin bir ürünü incelemesi, sepete ürün eklemesi ve ödeme yapması gibi davranışlar dönüşüm sürecinin farklı aşamalarıdır. Davranış analizi, bu süreçte hangi aşamalarda müşteri kaybı yaşandığını anlamaya yardımcı olmaktadır.

Müşteri Davranışlarının Dönüşüm Oranlarına Etkisi

İçerik ve Mesajlar: Doğru içerik ve mesajlar müşteriyi daha fazla harekete geçirmektedir.

Kullanıcı Deneyimi: Basit ve hızlı bir deneyim dönüşüm oranlarını artırmaktadır (örneğin, kolay ödeme süreci).

Güven Faktörü: Güvenilir bir marka imajı, dönüşümleri olumlu etkiler.

Kampanyalar ve Teşvikler: İndirimler, ücretsiz kargo gibi teşvikler müşteriyi karar aşamasına yönlendirebilir.

Örnek: Bir e-ticaret sitesinde 1.0000 ziyaretçi olduğunu varsayalım ve bu ziyaretçilerden 500'ü bir ürün satın alıyor. Bu durumda dönüşüm oranı aşağıdaki şekilde hesaplanır:

$$\text{Dönüşüm Oranı} = (500/10000) \times 100 = 5\%$$

Random Forest: Random Forest (RF), hem sınıflandırma hem de regresyon görevlerinde üstün olan çok yönlü bir makine öğrenme algoritmasıdır. Rastgele veri alt kümelerinden, birden fazla karar ağacı oluşturarak ve doğruluğu ve sağlamlığı artırmak için tahminlerini toplayarak çalışmaktadır. Bu topluluk yaklaşımı, aşırı uyum ve değişken seçim yanlılığı gibi sorunları azaltır ve RF'yi tahmine dayalı modelleme ve özellik önem analizi dahil olmak üzere çeşitli uygulamalar için güçlü bir araç haline getirir (Dai ve diğerleri, 2023; Ignatenko ve diğerleri, 2024; Kumar ve diğerleri, 2024; Salman ve diğerleri, 2024).

Random Forest algoritması, toplu öğrenme yaklaşımını benimseyerek, farklı veri alt kümeleri üzerinde eğitilmiş birçok karar ağacının çıktısını birleştirerek nihai bir tahmin üretir. Ayrıca, eksik değerlere ve dengesiz sınıflara sahip veri kümelerini etkili bir şekilde işleyerek modelin güvenilirliğini artırır (Kumar ve diğerleri, 2024; Salman ve diğerleri, 2024). RF uygulamaları, farklı alanlarda tahmine dayalı analitik ve veri odaklı karar verme süreçlerinde etkili bir şekilde kullanılmaktadır. Sağlık sektöründe, hastalıkların tahmini ve özellikle kalp hastalığı gibi durumlarda %98 gibi yüksek doğruluk oranlarıyla dikkat çekmektedir (Alfajr ve Defiyanti, 2024). Eğitim alanında da okul bırakma riski taşıyan öğrencilerin tespit edilmesine yardımcı olarak, zamanında müdahaleler yapılmasını sağlamaktadır (Kumar ve diğerleri, 2024). Random Forest oldukça etkili olsa da, sınırlı verilere sahip senaryolarda veya yorumlanabilirlik çok önemli olduğunda her zaman daha basit modellerden daha iyi performans göstermeyebilir, çünkü birden fazla ağacın karmaşıklığı, içgörülerini gizleyebilmektedir.

2. Analiz Sonuçları ve Bulgular


2.1. Veri Görselleştirme ve Keşifsel Veri Analizi (Eda)

Çalışmada kullanılan hedef değişkenin kategorilere göre analizi aşağıdaki gibi verilmiştir.

Tablo 1. Hedef Değişkenin Kategorilere Göre Analizi


Conversion	Age			Income			WebsiteVisits	ClickThroughRate
	mean	Min	Max	Mean	min	Max	mean	Mean
0	43.56	18	69	83265.31	20068	149986	21.73	0.128
1	43.63	18	69	84861.30	20014	149985	25.18	0.159

Yukarıdaki tabloya göre müşteri kitlesinin demografik özellikleri incelendiğinde, yaş dağılımının geniş bir aralıkta (18-69) olduğu ve bu durumun müşteri kitlesinin çeşitliliğini yansıttığı görülmektedir. Ortalama yaşın 43.56 olması, orta yaş grubunun hedef kitlede ağırlıklı olduğunu göstermektedir ki bu da, farklı yaş gruplarına özgü kampanya içeriklerinin geliştirilmesi, müşteri bağlılığını artırabilir diye düşündürmektedir. Aşağıdaki şekilde Yaşa göre Dönüşüm Dağılımı verilmiştir.




Şekil 1. Yaşa Göre Dönüşüm Dağılımı

Dönüşüm yapan ve yapmayan kullanıcılar arasında yaş ortalamasında minimal bir fark bulunmakta ve her iki grup için yaş aralığı 18 ile 69 arasında değişmektedir. Ortalama yaşın benzer olması (dönüşüm yapmayanlarda 43.56, dönüşüm yapanlarda 43.63), yaşın dönüşüm üzerinde belirgin bir etkisinin olmadığını göstermektedir. Bu durum, yaş faktörünün dönüşüm oranını doğrudan etkilemediğini, ancak kampanya stratejilerinin farklı yaş gruplarını kapsayacak şekilde optimize edilebileceğini ortaya koymaktadır. Bu bağlamda, yaş gruplarına özgü kişiselleştirilmiş içeriklerin kullanımının, müşteri katılımını artırmada daha etkili olabileceği düşünülebilir.




Şekil 2. Gelire Göre Dönüşüm Dağılımları

Gelir açısından dönüşüm yapan kullanıcıların ortalaması (84,861 USD), yapmayanlara kıyasla (83,265 USD) daha yüksek bulunmuştur. Gelir aralığının oldukça geniş olması (20,014 - 149,986 USD), heterojen bir müşteri kitlesinin varlığına işaret etmektedir. Bu bağlamda, üst gelir gruplarının, dönüşüm oranlarına daha fazla katkıda bulunabileceği göz önüne alınarak, gelire dayalı segmentasyon stratejileri geliştirilebileceği düşünülebilir. Örneğin, premium ürün veya hizmetler, üst gelir gruplarına yönelik farklılaşmış kampanyalarla desteklenebilirken, alt gelir grupları için fiyat duyarlılığını dikkate alan stratejiler benimsenebilir. Aşağıdaki şekilde gelir (Income) ve reklam harcaması (AdSpend) değişkenlerinin dönüşümle birlikte görselleştirilmesi için 3 boyutlu scatter plot verilmiştir.




Şekil 3. Gelir ve Reklam Harcaması ile Dönüşüm

Yukarıdaki şekile göre, yüksek gelirli müşterilerin ve daha fazla reklam harcaması yapılan kampanyaların, dönüşüm oranlarının daha yüksek olabileceği gözlenmektedir. Web sitesi ziyaretlerinin dönüşüm üzerindeki etkilerini analiz etmek için kullanıcıların dönüşüm durumlarına göre ortalama ziyaret sayılarını görselleştiren sütun grafiği aşağıda oluşturulmuştur.



Şekil 4. Dönüşüm Durumlarına Göre, Ortalama Web Sitesi Ziyaret Sayıları


Dönüşüm yapan kullanıcıların ortalama web sitesi ziyaret sayılarının (25.18) dönüşüm yapmayanlara (21.73) kıyasla daha yüksek olması, müşteri katılımlarının dönüşüm üzerinde önemli bir etkisi olduğunu göstermektedir. Bu sonuç, kullanıcıların web sitesi ile daha sık etkileşimde bulunmalarının, satın alma davranışlarını teşvik edebileceğini ortaya koymaktadır. Dolayısıyla, web sitesi trafiğini artırmak amacıyla kullanıcı dostu tasarımlar, kişiselleştirilmiş içerikler ve ziyaretçilerin daha uzun süre sitede kalmalarını sağlayacak stratejiler geliştirilmelidir. Ayrıca, ziyaretçi deneyimini iyileştiren chatbotlar ve hızlı ödeme sistemleri gibi araçlar dönüşüm oranlarını artırabilir. Tıklama oranlarının dönüşüm ile ilişkisini görselleştirmek için, kullanıcıların dönüşüm durumlarına göre tıklama oranlarını gösteren bar grafiği oluşturulabilir. Aşağıdaki grafikte tıklama oranları ve reklam performansı görselleştirilmiştir.



Şekil 5. Tıklama Oranları ve Reklam Performansı

Dönüşüm yapan kullanıcıların tıklama oranı (%15.9), dönüşüm yapmayanlara (%12.8) kıyasla belirgin bir şekilde daha yüksektir. Bu durum, kullanıcıların reklamlara olan ilgisinin dönüşüm üzerinde önemli bir etkisi olduğunu göstermektedir ki, bu sonuca göre, etkili reklam tasarımlarının, hedef kitlenin dikkatini çekerek tıklama oranlarını artırdığı söylenebilir. Reklam içeriklerinin optimize edilmesi, özellikle görsel çekicilik; kullanıcıyı harekete geçiren mesajlar ve doğru zamanlama gibi faktörler göz önünde bulundurularak yapılmalıdır. Ayrıca, reklamların performansı düzenli olarak izlenmeli ve dönüşüm oranlarını artırmak için A/B testi gibi yöntemler kullanılmalıdır.

Reklam harcaması ile dönüşüm oranı arasındaki ilişkiyi anlamak ve dönüşüm sağlamak için gereken optimum reklam bütçesini belirlemek amacıyla aşağıdaki şekildeki Kampanya Türleri ve Dönüşüm Oranı grafiği çizilmiştir ve altındaki tabloda sayısal değerlere yer verilmiştir. Bu sayede, pazarlama stratejilerinin etkinliği değerlendirilebilecek ve kaynaklar daha verimli kullanılabilir.




Şekil 6. Kampanya Türleri ve Dönüşüm Oranı

Tablo 2. Reklam Harcaması ve Dönüşüm İstatistikleri


Conversion	Count	Mean	std	min	25%	50%	75%	max
0	988.0	4058.40	2684.28	100.05	1881.51	3554.55	6103.98	9977.67
1	7012.0	5133.75	2834.13	103.41	2682.53	5249.72	7555.08	9997.91

Reklam harcaması ile dönüşüm arasındaki ilişkiyi gösteren istatistikler, dönüşüm sağlayan (Conversion=1) ve sağlamayan (Conversion=0) gruplar arasında önemli farklılıklar olduğunu ortaya koymaktadır. Dönüşüm sağlamayan grubun (0) ortalama reklam harcaması yaklaşık 4058 birim iken, dönüşüm sağlayan grubun (1) ortalama harcaması 5134 birim ile daha yüksektir. Bu durum, dönüşüm oranını artırmak için reklam harcamalarının stratejik bir şekilde artırılabilirliğini düşündürmektedir. Bununla birlikte, her iki grup için de standart sapmalar oldukça yüksektir, bu da reklam harcamasında geniş bir varyasyon olduğunu göstermektedir. Dönüşüm sağlamayan grubun reklam harcamaları daha düşük bir aralıkta yoğunlaşırken, dönüşüm sağlayan grubun reklam harcamaları da daha geniştir ve üst çeyrek (75. persantil) değeri 7555 birime kadar çıkmaktadır. Medyan değerler de dönüşüm grubunda daha yüksek olup, dönüşüm sağlamak için genellikle daha fazla yatırım gerçekleştirilmesi gerektiğini ifade etmektedir. Ancak maksimum reklam harcamalarının her iki grup için de neredeyse aynı seviyelerde olması, yüksek harcamaların her zaman dönüşüm garantisi sunmadığını göstermektedir. Bu bulgular, reklam bütçesi ve dönüşüm arasındaki ilişkiyi daha iyi anlamak için harcama optimizasyonu yapılması gerektiğini vurgulamaktadır.



Şekil 7. Reklam Harcaması ve Dönüşüm Oranları

Müşterilerin web sitesi üzerindeki etkileşim davranışlarını (web sitesi ziyaretleri ve sitede geçirilen süre) dönüşüm oranlarıyla ilişkilendirmek için aşağıdaki şekildeki Boxplot grafikleri çizilmiştir. Bu sayede, dönüşüm gerçekleştiren ve gerçekleştirmeyen müşteriler arasındaki farkların ortaya konulması ve bu farkların pazarlama stratejilerinde nasıl kullanılabileceğinin belirlenmesi hedeflenmiştir.




Şekil 8. Web Sitesi Ziyaretleri ve Dönüşüm Oranı

Tablo 3. Web Ziyaretleri ve Dönüşüm Oranı

Conversion	Mean	std	Min	25%	median	75%	max
0	21.73	15.37	0.0	8.0	20.0	36.0	49.0
1	25.28	14.11	0.0	14.0	25.0	37.0	49.0

Dönüşüm gerçekleştiren müşteriler (1), dönüşüm gerçekleştirmeyenlere (0) göre ortalama olarak daha fazla web ziyareti gerçekleştirmişlerdir (25.18'e karşılık 21.73). 25. yüzdilik dilimde bile dönüşüm sağlayan müşterilerin daha yüksek bir ziyaret oranına sahip olduğu görülmektedir. Bu durum, müşteri ilgisinin yoğunluğu ile dönüşüm arasında anlamlı bir bağ olduğuna işaret etmektedir. Aşağıdaki şekilde kullanıcıların, web sitesinde harcadıkları sürelerle ve dönüşüm oranlarına yer verilmiştir.




Şekil 9. Web Sitesinde Harcadıkları Süreler ve Dönüşüm Oranları

Tablo 4. Web Sitesinde Harcanan Süre ve Dönüşüm Oranı

Conversion	Mean	Std	min	25%	Median	75%	max
0	6.27	4.23	0.51	2.74	4.97	9.64	14.94
1	7.93	4.19	0.50	4.40	7.93	11.66	14.99

Dönüşüm gerçekleştiren müşteriler, ortalama olarak web sitesinde daha fazla zaman geçirmişlerdir (7.93'e karşılık olarak 6.27). Özellikle %50 ve %75 yüzdelik dilimlerde farkın daha da belirgin olduğu gözlenmiştir. Bu durum, web sitesinde geçirilen sürenin

artmasının dönüşüm üzerinde pozitif bir etkisi olduğunu güçlü bir şekilde göstermektedir. Sonuç olarak web ziyareti ve web sitesinde harcanan süre, dönüşüm oranlarının önemli belirleyicileridir denilebilir. Ziyaret sayısının artırılması için web sitesine çekici kampanyalar ve etkinlikler entegre edilebilir. Ayrıca, kullanıcıların daha fazla zaman geçirmelerini sağlamak amacıyla içerik zenginleştirme ve kullanıcı dostu bir arayüz sağlanabilir. Bu tür optimizasyonlar, dönüşüm oranlarını artırmaya katkıda bulunabilirler. Kampanya türleri (CampaignType) ve kampanya kanalları (CampaignChannel) ile dönüşüm oranları arasındaki ilişki aşağıda çubuk grafikleriyle analiz edilmiştir.




Şekil 10. Kampanya Kanalları ve Dönüşüm Oranları

Kampanya türleri ve kanallarında, dönüşüm oranlarının farklılık gösterdiği görülmektedir. Örneğin, "Conversion" türü kampanyaların dönüşüm oranlarının, diğer kampanyalardan daha yüksek olduğu tespit edilebilmektedir. "Email" veya "Social Media" kanallarının dönüşümde daha etkili olabileceği gözlenmiştir.

3. Korelasyon Analizi

Çalışmanın veri setindeki en etkili değişkenleri belirlemek için aşağıdaki korelasyon matrisi çizilmiştir. Korelasyon analizi, veri setindeki nümerik değişkenlerin birbirleriyle olan doğrusal ilişkilerin incelenmesini sağlamaktadır. Analiz sonucunda, dönüşüm oranını (Conversion) etkileyebilecek bazı değişkenlerle anlamlı ilişkiler tespit edilmiştir. Aşağıdaki şekilde korelasyon matrisi verilmiştir.



Şekil 11. Korelasyon Matrisi

Korelasyon matrisi genel olarak değişkenler arasında düşük düzeyde ilişki olduğunu göstermektedir (çoğu $|r| < 0.3$), bu da değişkenlerin büyük ölçüde bağımsız olduğuna işaret etmektedir. Dönüşüm ile reklam harcamaları (AdSpend) arasında pozitif bir ilişki olduğu gözlenmiştir ($r=0.1247$). Bu, reklam harcamalarının artmasının dönüşüm oranlarında bir artışa yol açabileceğini düşündürmektedir. Bu durum, daha fazla reklam bütçesiyle daha geniş bir hedef kitleye ulaşılarak dönüşümlerin artırılacağı stratejik bir içgörü sunmaktadır.

Benzer şekilde, tıklanma oranı (ClickThroughRate) ile dönüşüm arasında ($r=0.1200$) orta düzeyde bir pozitif ilişki bulunmaktadır. Bu ilişki, reklamların daha etkili tıklanabilir hale getirilmesinin, dönüşümleri artırabileceğini göstermektedir. Daha iyi tasarlanmış reklam içerikleri veya hedefleme stratejileriyle bu etki güçlendirilebilir. Ayrıca, web sitesinde geçirilen süre (TimeOnSite) ile dönüşüm oranı arasında ($r=0.1296$) pozitif bir ilişki bulunmuştur. Kullanıcıların web sitesinde daha fazla zaman geçirmesi, satın alma veya hedeflenen aksiyonu gerçekleştirme olasılığını artırmaktadır. Bu, kullanıcı deneyimini optimize etmenin dönüşümleri artırabileceğine işaret etmektedir.


Sonuç olarak, analiz edilen değişkenler arasında dönüşüme en fazla etki edenlerin; reklam harcamaları, tıklanma oranları ve sitede geçirilen süreler olduğu görülmektedir. Bu bulgular, dönüşüm optimizasyonuna yönelik stratejiler geliştirilirken odaklanılması gereken önemli alanlara ışık tutmaktadır.

4. Modelleme

Çalışmada kullanılan modelleme, kullanıcı dönüşüm oranlarını tahmin etmeye yönelik bir sınıflandırma problemine çözüm üretmek amacıyla yapılmıştır. Burada amaç, bir müşterinin belirli bir kampanya veya pazarlama stratejisi sonucunda dönüşüm gösterip göstermeyeceğini (yani hedeflenen aksiyonu, örneğin bir satın alma işlemini gerçekleştirme) tahmin etmektir. Çalışmada lojistik regresyon yerine, daha karmaşık ilişkileri öğrenebilen bir Random Forest modeli kullanılmıştır. Random Forest ile dönüşüm tahmin modeli de aşağıdaki Tablo 5'teki gibidir. Şekil 12 de, Random Forest model performans sonuçlarını özetlenmiştir:

Tablo 5. Random Forest Model Performansı

Sınıf	Precision	Recall	F1-Score	Destek (Support)
0 (Dönüşüm Yok)	0.59	0.07	0.12	194
1 (Dönüşüm)	0.89	0.99	0.94	1406
Genel (Accuracy)			0.88	1600
Macro Avg	0.74	0.53	0.53	1600
Weighted Avg	0.85	0.88	0.84	1600



Şekil 12. Random Forest Karmaşıklık Matrisi

Tablo 5 ve Şekil 12 dikkate alındığında Random Forest modelinin genel doğruluk skoru %88.12 ile oldukça iyi bir performans sergilemektedir; ancak model, “Dönüşüm” (Class 1) sınıfını “Dönüşüm Yok” (Class 0) sınıfına göre, çok daha iyi tahmin etmektedir.

“Dönüşüm Yok” sınıfının recall değeri yalnızca %7’dir, bu da modelin bu sınıfı tanıma da oldukça zorlandığını göstermektedir. Diğer yandan, “Dönüşüm” sınıfındaki recall %99 ile mükemmel bir sonuç elde etmiştir. Bu durum, modelin çoğunlukla “Dönüşüm” sınıfını tahmin ederek doğruluk sağladığını ve dengesiz veri dağılımından kaynaklanan bir eğilim olduğunu ortaya koymaktadır. “Dönüşüm Yok” sınıfındaki düşük recall, modelin bu sınıfı göz ardı ettiğini göstermektedir. Bu durumu iyileştirmek için sınıf dengesini sağlamak amacıyla oversampling, undersampling veya sınıf ağırlıkları gibi teknikler de kullanılabilir.

5. Sonuç ve Öneriler

Çalışmanın sonuçları, dijital pazarlama kampanyalarının başarısını artırmak için veriye dayalı stratejilerin geliştirilmesinin önemli olduğunu ortaya koymaktadır. Bulgulara göre:

Web sitesi etkileşimleri: Dönüşümü gerçekleştiren müşterilerin, dönüşüm yapmayanlara göre, web sitelerini daha fazla ziyaret ettiği ve daha uzun süre vakit geçirdikleri belirlenmiştir. Ulaşılan sonuçlara göre; kullanıcı dostu web sitelerinin tasarımlarının ve kişiselleştirilmiş içeriklerinin, dönüşüm oranlarını artırabileceği düşünülebilir.

Reklam harcamaları ve tıklama oranları: Reklam harcamalarının artması ve tıklama oranlarının yükselmesi, dönüşüm oranlarında pozitif bir etki yaratmaktadır. Bu durum, reklam performansının düzenli olarak izlenmesini ve optimize edilmesini gerektirmektedir.

Dengesiz veri yapısı: Model “Dönüşüm Yok” sınıfı için düşük performans göstermiştir, bu durumda sınıf dengesi stratejileri uygulanarak modelin iyileştirilebileceği düşünülebilir.

Kampanya türleri ve kanalları: Dönüşüm kampanyaları, e-posta ve sosyal medya kanalları daha etkilidirler ancak; kampanyalar, hedef kitleye uygun kanallar ve mesajlarla düzenlenmelidirler.

Ayrıca çalışma sonuçları dijital pazarlama literatürüne hem uygulamalı hem de teorik anlamda katkı sağlayabilecek öneriler halinde aşağıda özetlenmiştir. Bunlar:

Kişiselleştirme Tekniklerinin Derinlemesine İncelenmesi: Yapay zekâ ve makine öğrenimi tabanlı kişiselleştirme yöntemlerinin, müşteri sadakati, satın alma eğilimleri ve marka bağlılığı üzerindeki etkileri araştırılabilir.

Sektör Bazlı Analizler: Farklı sektörlerde dijital pazarlama stratejilerinin nasıl uygulandığına dair karşılaştırmalı çalışmalar yapılabilir. Örneğin, e-ticaret, sağlık, finans ve turizm sektörlerinde kullanılan dijital pazarlama tekniklerinin başarı oranları ve müşteri davranışları üzerindeki etkileri araştırılabilir.

Tüketici Verilerinin Etik Kullanımı: Dijital pazarlamada veri odaklı stratejiler hızla artarken, bu verilerin etik kullanımına ilişkin araştırmalar önem kazanmaktadır. Araştırmacılar, tüketici gizliliği, veri güvenliği ve GDPR gibi yasal düzenlemelerin stratejilere etkisini inceleyebilirler.

Yenilikçi Araçların Etkinliği: Chatbotlar, artırılmış gerçeklik (AR), sanal gerçeklik (VR) ve metaverse gibi yeni nesil teknolojilerin pazarlama stratejilerindeki etkileri araştırılabilir. Bu araçların müşterilerle etkileşim ve marka algısı üzerindeki sonuçları değerlendirilebilir.

Sosyal Medya ve Mikro-Influencer Stratejileri: Sosyal medya pazarlamasında mikro-influencerların artan rolü üzerine çalışmalar yapılabilir. Hangi platformların daha etkili olduğu, tüketici davranışlarına olan etkileri ve ROI (yatırım getirisi) analizleri gibi konular ele alınabilir.

Çok Kanallı Pazarlama: Dijital ve fiziksel satış kanallarının birleştirilmesi, müşteri deneyimini nasıl etkileyebilir sorusuna yanıt olarak; araştırmacılar, çok kanallı stratejilerin müşterilere erişim ve marka sadakati üzerindeki rolünü inceleyebilirler.

Bölgesel ve Kültürel Farklılıklar: Dijital pazarlama stratejilerinin farklı coğrafi bölgelerde veya kültürel bağlamlarda nasıl farklılık gösterdiği araştırılabilir. Özellikle

Türkiye bağlamında tüketici davranışlarına odaklanan çalışmalar, literatüre önemli katkılar sağlayabilir.

Metrik ve Performans Ölçümleme: Dijital pazarlama stratejilerinin başarı oranlarını ölçmek için kullanılan metriklerin daha ayrıntılı analizi yapılabilir. Hangi metriklerin hangi stratejiler için daha uygun olduğu ve farklı kampanyalarda başarı ölçütlerinin karşılaştırılması araştırılabilir.

Kriz Yönelik Dijital Pazarlama Stratejileri: Pandemi gibi beklenmeyen kriz dönemlerinde dijital pazarlama stratejilerinin nasıl değiştiği ve hangi yaklaşımların başarılı olduğu üzerine daha fazla araştırma yapılabilir.

Uzun Vadeli Müşteri İlişkileri Yönetimi (CRM) Stratejileri: CRM yazılımlarının dijital pazarlamada etkin kullanımı ve müşteri yaşam boyu değerine etkisi üzerine çalışmalar yapılabilir. Özellikle müşteri verilerinin kullanımıyla sadakat programlarının geliştirilmesi ve değerlendirilmesi odak noktası olabilir.

Sonuç olarak, bu çalışma ile müşteri dönüşümünü etkileyen faktörler belirlenerek, dijital pazarlama stratejilerinin optimizasyonuna yönelik önemli içgörüler oluşturulmuştur. İlerleyen çalışmalarda, farklı modelleme teknikleri ve veri işleme yöntemleri kullanılarak daha kapsamlı analizlerin gerçekleştirilmesi planlanmıştır.

Kaynakça

- Alfajr, N. H., Defiyanti, S. (2024). Prediksi Penyakit Jantung Menggunakan Metode Random Forest Dan Penerapan Principal Component Analysis (PCA). *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3S1).
- Amajuoyi, C. P., Nwobodo, L. K., Adegbola, A. E. (2024). Utilizing Predictive Analytics to Boost Customer Loyalty and Drive Business Expansion. *GSC Advanced Research and Reviews*, 19(3), 191–202.
- Ayanso, A., Yoogalingam, R. (2009). Profiling Retail Web Site Functionalities and Conversion Rates: A Cluster Analysis. *International Journal of Electronic Commerce*, 14(1), 79–114.
- Chaffey, D., & Smith, P. (2022). *Digital Marketing Excellence*. Routledge.
- Cui, Y., Tobossi, R., Vigouroux, O. (2018). *Modelling Customer Online Behaviours with Neural Networks: Applications to Conversion Prediction and Advertising Retargeting*.
- Çolak H., Kağrıoğlu C.H., Argan M., 2022, Sosyal Medyada Etkileşim ve Dönüşüm Oranı Arasındaki İlişkinin İncelenmesine Yönelik Facebook Örneği, *Elektronik Sosyal Bilimler Dergisi*, 21(81).
- Dai, Z., Hu, Z., Shen, T., & Zhang, Y. (2023). Risk Prediction of Diabetes Based on Spark and Random Forest Algorithm. *2023 IEEE 2nd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA)*, 535–539.
- Doğanlı, B., Çelik, S. (2024). *Pazarlama Stratejileri için Veri Bilimi ve Python* (1st ed.). All Sciences Academy.
- Guo, Y., Ao, X., Liu, Q., He, Q. (2023). Leveraging Post-Click User Behaviors for Calibrated Conversion Rate Prediction Under Delayed Feedback in Online Advertising. *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*, 3918–3922.
- Gürsakar, N., Çelik, S. (2021). *Büyük Veri ve Pazarlama* (Birinci Baskı). Dora Yayınevi.
- Holzwarth, M., Janiszewski, C., Neumann, M. M. (2006). The Influence of Avatars on Online Consumer Shopping Behavior. *Journal of Marketing*, 70(4), 19–36.
- Hong, S. (2024). Data-driven Precision Marketing Strategy and Its Effect Measurement. *Transactions on Economics, Business and Management Research*, 12, 59–64.
- Ignatenko, V., Surkov, A., Koltcov, S. (2024). Random Forests with Parametric Entropy-Based Information Gains for Classification and Regression Problems. *PeerJ Computer Science*, 10, e1775.
- Ijomah, T. I., Idemudia, C., Eyo-Udo, N. L., Anjorin, K. F. (2024). Harnessing Marketing Analytics for Enhanced Decision-Making and Performance in SMEs. *World Journal of Advanced Science and Technology*, 6(1), 001–012.

- Kristiana, I., Prabowo, H., Gaol, F. L., & Qomariyah, N. N. (2024). Review of Critical Components of Data-Driven Nudge Theory on Enhancing Conversion Rates in Digital Marketing Campaigns. *2024 International Conference on Information Technology Research and Innovation (ICITRI)*, pp: 263–268.
- Kumar, D., Kothiyal, A., Kumar, R., Hemantha, C., Maranan, R. (2024). Random Forest approach optimized by the Grid Search process for predicting the dropout students. *2024 International Conference on Innovations and Challenges in Emerging Technologies (ICICET)*, 1–6.
- Liu, J., Zhou, X., Wei, Y., Lu, L. (2024). Research on Machine Learning and Financial Risk Early Warning of Listed Companies Based on Random Forest Model. *Frontiers in Humanities and Social Sciences*, 4(9), 226–229.
- Mali, M., Mangaonkar, N. (2023). Behavioral Customer Segmentation for Subscription. *2023 3rd Asian Conference on Innovation in Technology (ASIANCON)*, 1–6.
- McDowell, W. C., Wilson, R. C., Kile Jr, C. O. (2016). An Examination of Retail Website Design and Conversion Rate. *Journal of Business Research*, 69(11), 4837-4842.
- Nwabekee, U. S., Abdul-Azeez, O. Y., Agu, E. E., & Ijomah, T. I. (2024). Digital Transformation in Marketing Strategies: The Role of Data Analytics and CRM Tools. *International Journal of Frontline Research in Science and Technology*, 3(2), 055–072.
- Rogić, S., Kaščelan, L. (2023). *Decoding Customer Behaviour: Relevance of Web and Purchasing Behaviour in Predictive Response Modeling*, 369–380.
- Salman, H. A., Kalakech, A., Steiti, A. (2024). *Random Forest Algorithm Overview*. *Babylonian Journal of Machine Learning*, 69–79.
- Söderlund, M., Berg, H., Ringbo, J. (2014). When the Customer Has Left the Store: An Examination of The Potential for Satisfaction Rub-Off Effects and Purchase Versus No Purchase Implications. *Journal of Retailing and Consumer Services*, 21(4), 529-536.
- Sun, C. (2024). Data Analysis of Customer Segmentation and Personalized Strategy in the Era of Big Data. *Advances in Economics, Management and Political Sciences*, 92(1), 46–52.
- Talaat, F. M., Aljadani, A., Alharthi, B., Farsi, M. A., Badawy, M., Elhosseini, M. (2023). A Mathematical Model for Customer Segmentation Leveraging Deep Learning, Explainable AI, and RFM Analysis in Targeted Marketing. *Mathematics*, 11(18), 3930.
- Yeo, J., Hwang, S.-W., Kim, S., Koh, E., Lipka, N. (2020). Conversion Prediction from Clickstream: Modeling Market Prediction and Customer Predictability. *IEEE Transactions on Knowledge and Data Engineering*, 32(2), 246–259.

Çıkar Çatışması: Yoktur.

Finansal Destek: Yoktur.

Etik Onay: Yoktur.

Yazar Katkısı: Bilge DOĞANLI (%100)

Conflict of Interest: None.

Funding: None.

Ethical Approval: None.

Author Contributions: Bilge DOĞANLI (100%)
