

İçgöründen eyleme: Pazarlamada artımlı modelleme ile öngörücü analitiğin gücü

From insight to action: The power of prescriptive analytics with uplift modelling in marketing

Meltem Sanisoğlu¹ 

Şebnem Burnaz² 

¹ Dr., İstanbul Teknik Üniversitesi, İstanbul, Türkiye, senelm@itu.edu.tr

ORCID: 0000-0001-6087-4656

² Prof. Dr., İstanbul Teknik Üniversitesi, İstanbul, Türkiye, burnaz@itu.edu.tr

ORCID: 0000-0002-4845-4031

Sorumlu Yazar/Corresponding Author:

Meltem Sanisoğlu,

İstanbul Teknik Üniversitesi, İstanbul, Türkiye, senelm@itu.edu.tr

Başvuru/Submitted: 19/02/2025

Revizyon/ Revised: 24/03/2025

Kabul/Accepted: 10/04/2025

Yayın/Online Published: 25/06/2025

Atıf/Citation: Sanisoğlu, M., & Burnaz, Ş., İçgöründen eyleme: pazarlamada artımlı modelleme ile öngörücü analitiğin gücü, bmij (2025) 13 (2): 494-514 doi: <https://doi.org/10.15295/bmij.v13i2.2518>

Öz

Bu çalışma, işletme yönetiminde ticari değer yaratarak daha hızlı ve etkili karar alınmasını sağlayan veri analitiğine odaklanarak işletmelerin bir öngörücü analitik yöntemi olan artımlı modellemeden yararlanmaları için değerli içgörüler sağlamayı amaçlamaktadır. Pazarlama alanında kullanılan analitik yaklaşımlara genel bir bakış sunularak veri analitiğinin modern işletme yönetimindeki önemi çeşitli örnekler ile ortaya konulmakta ve öngörücü analitik yöntemi olan artımlı modellemeye odaklanılmaktadır. İki model yaklaşımı, sınıf değişkeni dönüşümü ve doğrudan artımlı modelleme yöntemleri ayrıntılı olarak incelenerek işletmelerin artımlı modelleme kullanımı için yararlanmaları öngörülen veri toplama, hazırlık ve model performansı değerlendirme aşamaları sunulmaktadır. Sonuç olarak iş uygulamaları ve gelecekteki araştırma yönelimleri için önerilerde bulunulmakta ve çalışmanın sunduğu düşünülen temel katkıları hem akademi hem de endüstri açısından vurgulanmaktadır.

Anahtar Kelimeler: Pazarlama Analitiği, Öngörücü Analitik, Artımlı Modelleme

Jel Kodları: M31, M39

Abstract

This study aims to provide valuable insights for businesses to benefit from uplift modelling, a prescriptive analytics method, by focusing on data analytics that enables faster and more effective decision-making, thereby creating commercial value in business management. It provides an overview of analytical approaches used in marketing, demonstrates the importance of data analytics in modern business management with several examples, and focuses on uplift modelling as a prescriptive analytics method. The two-model approach, class variable transformation, and direct uplift modelling methods are examined in detail, and the data collection, pre-processing, and model performance evaluation phases that businesses should utilise for uplift modelling are presented. In conclusion, recommendations are provided for business applications and future research directions, and the key contributions of the study are highlighted for both academic and industrial audiences.

Keywords: Marketing Analytics, Prescriptive Analytics, Uplift Modelling

Jel Codes: M31, M39

Extended Abstract

From insight to action: The power of prescriptive analytics with uplift modelling in marketing

Literature

Research subject

Uplift modelling, a data-driven approach in marketing analytics, aims to identify the actual impact of marketing interventions on customer behaviour. Unlike traditional predictive models that focus on overall customer responses, uplift modelling differentiates between customers who are positively influenced, those who remain indifferent, and those who might react negatively. This technique is particularly relevant in personalised marketing strategies, customer retention programs, and targeted advertising, ensuring that businesses allocate resources efficiently.

Research purpose and importance

This study examines the application of uplift modelling in marketing analytics and its potential benefits compared to traditional predictive methods. While existing research has explored various predictive analytics techniques, a gap remains in understanding the comparative efficiency of uplift modelling across different industries. The importance of this study lies in evaluating how uplift modelling enhances decision-making processes by targeting the right customer segments, resulting in cost-effective marketing efforts and increased customer engagement.

Contribution of the article to the literature

This paper contributes to the literature by systematically analysing the applications of uplift modelling in marketing, identifying its strengths and limitations, and discussing its implications for businesses. While previous research has primarily focused on theoretical aspects, this study bridges the gap by examining real-world applications and addressing industry-specific challenges. Additionally, it provides a comparative assessment of uplift modelling techniques, offering valuable insights for researchers and practitioners seeking to optimise marketing strategies.

Furthermore, even though traditional descriptive and predictive analytics have been widely explored in marketing literature, to the best of our knowledge, no other work in Turkish literature has specifically examined uplift modelling as a prescriptive analytics method in marketing. This study stands out as a pioneering effort, offering valuable insights into the emerging field of prescriptive analytics. While prescriptive analytics has only recently begun gaining attention in the international literature, this study makes a significant contribution to understanding its potential benefits for businesses. In addition to introducing uplift modelling to the Turkish marketing context, this study provides a straightforward roadmap for companies looking to implement this innovative approach. It details the essential steps needed to adopt uplift modelling, making it accessible and practical for business practitioners. By filling a gap in both the Turkish and broader marketing literature, this research not only highlights the importance of prescriptive analytics but also serves as a guide for businesses aiming to enhance their decision-making processes and optimise their marketing strategies through uplift modelling.

Design and method

Research type

This study presents a conceptual and theoretical review of the role of uplift modelling in marketing analytics. Unlike empirical studies that apply statistical tests to real-world data, this research synthesises findings from existing literature to evaluate the effectiveness, applications, and challenges of uplift modelling.

Research problems

The primary research problems addressed in this study include:

1. How does uplift modelling compare to traditional predictive analytics in marketing decision-making?
2. What are the key challenges businesses face when implementing uplift modelling?
3. How can uplift modelling be optimised to enhance customer targeting efficiency?

Data collection method

Since this is a conceptual study, the data collection process relies on **secondary sources**, including academic journals, industry reports, and case studies related to uplift modelling. The analysis involves reviewing recent advancements, theoretical discussions, and applied research in the field of marketing analytics.

Quantitative/qualitative analysis

As this is a **theoretical review**, no direct quantitative or qualitative analysis is conducted. However, the study systematically categorises and compares different uplift modelling techniques, their impact, and practical applications using a literature synthesis approach. This review article focuses on the prescriptive analytics method of uplift modelling. It examines in detail the two-model approach, class variable transformation and direct uplift modelling as uplift modelling methods. The two-model approach involves building two separate predictive models for treated and untreated groups, allowing for a comparison of their performance and the measurement of the incremental impact of treatment. Class variable transformation modifies the target variable to capture the direct effect of treatment within the model, simplifying the process of distinguishing between treatment and control predictions. Lastly, direct uplift modelling integrates treatment effects into a single model, optimising the estimation of treatment impact without needing separate models for different groups.

In addition to these methods, the article explores essential data pre-processing steps crucial for effective uplift modelling. These steps include comprehensive data collection, which ensures a robust dataset that accurately reflects the target population. Handling noisy or missing data is also discussed, as this can significantly affect model accuracy and reliability. The article emphasises the importance of balancing class distributions to avoid biases that could skew results and highlights strategies for addressing multicollinearity among variables, which can complicate model interpretation and performance.

To evaluate model performance, the article introduces the Qini curve, a graphical tool used to assess the effectiveness of uplift models. It explains how the Qini curve illustrates the additional benefit of applying the model compared to a random intervention, providing a visual representation of the model's impact. The interpretation of the Qini curve is crucial for understanding the practical value of uplift modelling in real-world scenarios.

Research model

Instead of an empirical model, this study develops a comparative framework that highlights key dimensions of uplift modelling, including its strengths, limitations, and potential improvements. The framework serves as a basis for understanding how uplift modelling can be leveraged effectively in marketing.

Research hypotheses

Since this study is conceptual, no formal hypotheses are tested. However, it assumes that uplift modelling provides more precise customer targeting compared to traditional predictive models and offers greater efficiency in resource allocation for marketing strategies.

Findings and discussion

Findings as a result of the analysis

A review of the literature reveals that uplift modelling is increasingly being recognised as a superior approach to customer targeting in marketing analytics. Unlike traditional predictive models that focus solely on the likelihood of customer actions, uplift modelling distinguishes between different customer response groups, allowing businesses to optimise their marketing interventions. The rise of prescriptive analytics, particularly uplift modelling, is transforming how businesses approach marketing strategies by helping them determine the most effective actions to achieve better results. This paper examines the role of prescriptive analytics in business, with a specific focus on how uplift modelling can enhance marketing practices. Unlike traditional forecasting models, which predict general outcomes, uplift modelling takes a more precise approach by identifying individuals who are most likely to respond positively to a specific action. This targeted method makes marketing efforts more efficient and effective, making it an essential tool for modern business strategies. Uplift modelling is versatile and valuable in many areas. It works by categorising customers into four key groups: persuadable, who are likely to respond positively to an intervention; do-not-disturb, who might react negatively if targeted; lost causes, who are unlikely to respond regardless of the effort; and sure things, who will take the desired action even without any treatment. By understanding these groups, businesses can better allocate resources and tailor their marketing strategies for maximum impact.

In direct marketing, it helps identify persuadable, increasing return on investment by focusing on those most likely to respond to offers. In managing customer churn, it identifies those who should not be targeted, as well as those who can be persuaded and retained with specific actions. It also plays a key role in content targeting, ensuring that the right messages reach the persuadable and those who are certain. Additionally, uplift modelling supports revenue growth by guiding resource allocation to focus on the most impactful groups. In conclusion, this paper emphasises the crucial role of prescriptive analytics with a focus on uplift modelling in making marketing strategies more effective and efficient. The ability to identify and influence key customer segments makes uplift modelling a valuable tool in the evolving field of business analytics.

Hypothesis test results

Since this study is conceptual, no direct hypothesis testing has been conducted. However, a comparative evaluation of the literature suggests strong support for the notion that uplift modelling outperforms traditional predictive models in terms of customer segmentation, intervention efficiency, and return on marketing investment.

Discussing the findings with the literature

The findings are summarised as being aligned with previous research, which indicates that uplift modelling enhances decision-making processes by identifying the true causal impact of marketing interventions (Hansotia & Rukstales, 2002; Devriendt et al., 2018; Gubela ve Less, 2021). Unlike regression-based predictive models that assume uniform customer responses, uplift modelling is designed to capture heterogeneous treatment effects, making it more suitable for personalised marketing strategies (Zhao et al., 2017; Munting, 2020). However, there are contrasting views in the literature regarding the feasibility of uplift modelling. Some researchers argue that while it provides more precise targeting, it requires significant computational resources and high-quality customer interaction data, which may not always be available (Guelman et al., 2012). Additionally, ethical concerns have been raised regarding its potential to reinforce biases in customer segmentation. Overall, the discussion suggests that while uplift modelling presents a transformative opportunity for marketing analytics, its application requires careful consideration of data availability, model complexity, and ethical implications.

Conclusion, recommendation and limitations

Results of the article

This study highlights the advantages of uplift modelling in marketing analytics, emphasising its ability to measure the actual impact of marketing interventions. Unlike traditional predictive models, uplift modelling allows businesses to identify and target customers who are most likely to be influenced, leading to better resource allocation and higher returns on investment. However, its application does not necessarily require sophisticated computational capabilities; rather, it depends on having suitable data with clearly defined control and treatment groups, along with moderate computational resources for effective implementation.

Suggestions based on results

To enhance the implementation of uplift modelling in marketing, the following recommendations are proposed:

1. Improved Data Strategies – Businesses should focus on collecting high-quality customer interaction data with clearly defined control and treatment groups to maximise the effectiveness of uplift modelling.
2. Understanding the Strategic Advantages of Uplift Modelling – Unlike traditional forecasting models, uplift modelling focuses on identifying the individuals most likely to be positively affected by a specific treatment. This targeted approach enables businesses to tailor their actions to these key individuals, resulting in more efficient resource allocation and informed data-driven decision-making.

3. Practical Applications for Marketing Professionals – The implications of uplift modelling for marketing are significant. By applying uplift modelling techniques, marketers can optimise customer targeting, improve campaign performance, and boost return on investment (ROI). This method enables businesses to concentrate their marketing efforts on the most responsive customer segments, maximising overall campaign impact.
4. Optimisation through Evaluation Techniques – To refine uplift modelling applications, marketers should leverage evaluation techniques such as Qini curves, which allow for better model performance assessment and strategy optimisation. These tools help marketers fine-tune their approach and achieve higher efficiency.
5. Encouraging Academic and Industry Collaboration – Fostering collaboration between academia and industry will further advance research in uplift modelling, leading to innovative applications and improved methodologies. Investing in data collection, pre-processing, and rigorous model evaluation will be essential for businesses aiming to fully utilise the potential of prescriptive analytics in marketing.

By leveraging prescriptive analytics techniques, such as uplift modelling, marketers can make more informed decisions and achieve greater success in today's dynamic and competitive business landscape.

Limitations of the article

This study is a conceptual review, meaning that no empirical validation has been conducted. Additionally, the effectiveness of uplift modelling varies by industry and dataset availability, which may limit its applicability in specific sectors. This study focuses explicitly on uplift modelling as a key approach within prescriptive analytics. While uplift modelling offers a powerful tool for targeting and optimising marketing efforts, it is essential to recognise that no single method can provide a universal solution for all business challenges. Therefore, businesses are encouraged to experiment with various algorithms and techniques to determine which one best aligns with their specific goals and needs. By testing different methods, companies can gain insights into the strengths and limitations of each approach, enabling them to choose the most effective strategy for their objectives. Lastly, the rapid evolution of machine learning techniques means that future advancements may further refine and uplift modelling methodologies.

Giriş

İş analitiği genel olarak ticari değer yaratarak işletmeleri daha hızlı, etkili ve akıllıca kararlar almaları için güçlendirmeyi amaçlar. Betimsel (descriptive) ve kestirimsel (predictive) analitik hem akademide hem de işletmelerdeki çalışmalarda ana odaktadır (Jeyanthi, Choudhury, Hack-Polay, Singh ve Abujar, S., 2022). Bununla birlikte, ileriye dönük en uygun aksiyonu arayan öngörücü (prescriptive) analitik, son zamanlarda araştırmacıların giderek daha fazla ilgisini çekmektedir. Öngörücü analitik, veri analitiği alanında bir sonraki gelişme olarak görülmekte ve kurumsal performansı artırmak için optimize edilmiş karar verme araçları sunmaktadır (Lepeniotti, Bousdekis, Apostolou ve Mentzas, 2020). Öngörücü analitik yöntemlerinden olan artımlı modelleme (uplift modelling) tekniği, pazarlama uygulamasının artan etkisinin en olumlu etkileyeceği müşteri segmentini belirleyebilmekte, bu sayede işletmeler için pazarlama çalışmalarının optimizasyonunu sağlamada önemli fırsatlar sunmaktadır (Cao, Xu ve Gu, 2017; Olaya, Vásquez, Maldonado, Miranda ve Verbeke, 2020).

Bu çalışma, işletme yönetiminde veri analitiğine odaklanarak işletmelerin bir öngörücü analitik yöntemi olarak artımlı modellemenin kullanımını incelemekte ve bu yöntemin işletmelerin karar alma süreçlerine sunduğu katkıyı ortaya koymayı amaçlamaktadır. Literatür incelendiğinde, geleneksel kestirimsel analitik yaklaşımlarının çoğunlukla müşteri davranışlarını öngörmeye odaklandığı ancak belirli pazarlama müdahalelerinin gerçek etkisini değerlendirmede yetersiz kaldığı görülmektedir (Radcliffe ve Simpson, 2008; Devriendt, Moldovan ve Verbeke, 2018). Artımlı modelleme, geleneksel analitik yaklaşımlarından farklı olarak bir pazarlama aksiyonunun özellikle hangi müşteri gruplarında anlamlı bir fark yaratabileceğini belirlemeye odaklanarak stratejik karar alma sürecini daha etkin hale getirebilecek bir yöntem olarak öne çıkmasına rağmen, literatürde bu uygulamanın uygulanmasına dair sistematik bir inceleme eksikliği bulunmaktadır. Özellikle farklı artımlı modelleme yaklaşımlarının etkinlikleri arasındaki farklar, hangi sektörlerde daha verimli kullanılabileceği ve işletmelerin hangi verileri toplaması gerektiği konularında çok az karşılaştırmalı çalışma yapılmıştır. Çeşitli çalışmalar farklı artımlı modelleme tekniklerini çalışarak etkinliğini karşılaştırmış (Radcliffe ve Simpson, 2008; Rzepakowski ve Jaroszewicz, 2012; Guelman, Guillén ve Pérez-Marín, 2015; Gutierrez ve Gerardy, 2017); e-ticaret (Hansotia ve Rukstales, 2002; Goldenberg, Albert, Bernardi ve Estevez, 2020), finans (Siegel, 2011), sağlık hizmetleri (Jaskowski ve Jaroszewicz, 2012), siyasi kampanya yönetimi (Robins ve Rotnizky, 2004) gibi kısıtlı sektörlerde artımlı modelleme teknikleri uygulanmıştır. Bu boşluktan hareketle, bu çalışmanın temel amacı, farklı artımlı modelleme yöntemlerini inceleyerek, pazarlama analitiğinde bu yöntemin etkin kullanımına dair akademik ve sektörel bir yol haritası sunmaktır.

Bu bağlamda çalışma şu araştırma sorularına odaklanmaktadır:

- i. Artımlı modelleme geleneksel kestirimsel analitik yaklaşımlara kıyasla ne gibi avantajlar sunmaktadır?
- ii. Farklı artımlı modelleme yöntemleri arasında nasıl farklar vardır?
- iii. Artımlı modellemenin işletmeler tarafından uygulanabilmesi için hangi veri toplama ve ön işleme adımları önemlidir?
- iv. Pazarlama uygulamalarında artımlı modellemenin kullanımı sektörel bazda nasıl farklılıklar göstermektedir?

Bu sorular çalışmanın akademik katma değerini ve sektör uygulamalarına olan etkisini daha net bir şekilde ortaya koymayı amaçlamaktadır. Sonuç olarak, bu çalışma pazarlama analitiği alanındaki mevcut bilgi birikimine önemli bir katkı sağlayarak, işletmelerin karar alma süreçlerinde veriye dayalı daha etkin stratejiler oluşturmalarına rehberlik edecektir.

Bu makalede öncelikle pazarlama alanında kullanılan analitik yaklaşımlara genel bir bakış sunulmakta ve veri analitiğinin modern işletme yönetimindeki önemi çeşitli örnekler ile ortaya konulmaktadır. İkinci bölümde, öngörücü analitik yöntemi olan artımlı modellemeye odaklanılmakta ve farklı artımlı modelleme yöntemleri ayrıntılı olarak incelenmektedir. Daha sonra, işletmelerin artımlı modelleme kullanımı için yararlanmaları öngörülen veri toplama, hazırlık ve model performansı değerlendirme aşamaları özetlenmektedir. Çalışmanın sonuç bölümünde ise, iş uygulamaları ve gelecekteki araştırma yönelimleri için önerilerde bulunulmakta ve çalışmanın sunduğu düşünülen temel katkıları hem akademi hem de endüstri açısından vurgulanmaktadır.

Pazarlamada analitik

Pazarlamada analitik, müşteri davranışları, pazar eğilimleri ve genel pazarlama performansı hakkında bilgi edinmek için veri toplama, analiz etme ve yorumlama sürecini ifade eder (Fan, Lau ve Zhao, 2015). Bu bilgiler pazarlamacıların veriye dayalı kararlar almalarına, pazarlama stratejilerini optimize

etmelerine ve kampanyalarının etkinliğini artırmalarına yardımcı olur. Analitiğin pazarlamadaki rolü, pazarlama çabalarını optimize etmek, müşteri hedeflemesini iyileştirmek, mesajları kişiselleştirmek ve pazarlama kampanyalarının başarısını ölçmek için kullanılabilecek değerli bilgiler sağlamak şeklinde ifade edilebilir (Hauser, 2007). Benzer şekilde Wedel, Kannan ve Tyser (2016) da analitiğin pazarlamacıların hedef kitlelerini anlamalarına, eğilimleri ve tüketim kalıplarını belirlemelerine, pazarlama kampanyalarının etkinliğini ölçmelerine ve veriye dayalı kararlar almalarına yardımcı olmada önemli rol oynadığını ileri sürmüşlerdir.

İşletmelerin karar alma süreçlerini yönlendirmek için kullandıkları temelde üç tür analitik vardır. Bunlar, işletmelere halihazırda ne olduğunu söyleyen betimsel analitik ne olabileceğini gösteren tahmine dayalı kestirimsel analitik ve son olarak, işletmelere gelecekte ne olması gerektiğini bildiren öngörücü analitik şeklinde sıralanabilir.

Betimsel analitik

Pazarlamada betimsel analitik, pazarlama performansının mevcut durumunu anlamak ve açıklamak için geçmiş verilerin kullanılmasını içerir. Geçmişte neler olduğuna dair içgörü sağlamak için verilerin özetlenmesine ve bir araya getirilmesine odaklanır. İşletmelerin karşılaştırma yapmasına yardımcı olmak için çeşitli geçmiş veri setlerinin nasıl kullanıldığını açıklar (Wedel et al., 2016). Ekonomik ölçümler dikkate alınırsa, en yaygın olarak raporlanan finansal ölçütler betimsel analitiğin sonucudur. Bunlara örnek olarak yıldan yıla fiyat değişiklikleri, aydan aya satış büyümesi, müşteri sayısı ve her bir kullanıcının/abonenin toplam geliri verilebilir. Bu ölçümler, işletmeleri belirli bir zaman dilimi içinde neler olduğu konusunda bilgilendirmeyi amaçlar. Yöneticiler, çalışanlar, yatırımcılar ve müşteriler de dahil olmak üzere bir dizi paydaş için faydalı olan bulgular elde etmek için ham verileri inceler (Investopedia, 2023).

Betimleyici analitikte, veri madenciliği ve veri birleştirme çok önemli süreçlerdir. Veri kümelerinin etkili bir şekilde ele alınabilmesi için öncelikle verilerin toplanması ve düzenlenmesi amacıyla veri birleştirme işlemi gerçekleştirilir. Daha sonra, veri madenciliği ile önemli veriler çıkarılır. Bulunan örüntüleri tanımak ve anlamak için bazı akıllı teknikler uygulanır. Verilerin işlenmesi, sıralanması ve değerlendirilmesinden sonra, verilerin görsel temsili anlamlı olur (Cooksey, 2020). Bu şekilde betimleyici analitik, gerçekleşen eylemlere dayalı olarak işletmenin mevcut durumunu değerlendirmek amacıyla hassas ölçümler ve iş hedefleri oluşturmak için kullanılır (Sharma, Sharma, Purohit, Rout ve Sharma, 2022).

Günümüzde işletmeler giderek daha fazla veri tarafından yönlendirilmektedir. Bu veriler, fikirlerini, duygularını, deneyimlerini ve bakış açılarını kendi istekleriyle paylaşan kişiler tarafından sağlanmakta ve işletmelerin müşterilerinin ne düşündüğünü anlamasını kolaylaştırmaktadır (Zhang, Xu ve Zhang, 2024). Örneğin, betimsel analitik ile çevrim içi bir ürün incelemesi yorumuna kaç müşterinin katıldığı değerlendirilebilir. Ayrıca belirli bir müşterinin ürün inceleme yorumu yapma sıklığını belirlemek için de kullanılabilir. Pazarlama kampanyalarında, satış ve operasyonel rakamlar gibi geçmiş verilerin incelenmesi bir diğer kullanım örneği olarak verilebilir (Ferguson, 2020; Lee, Chung ve Park, 2024). Diğer yandan, üreticilerin belirli bir ayda üretilen toplam parça sayısını ve her ürün grubunun elde ettiği gelirin analiz edilmesi için ürün sınıflarına odaklı betimsel analizler gerçekleştirilebilir (Sharma et al., 2022).

Betimsel analitiğin işletmeler için geçmiş verilerdeki eğilimleri ve kalıpları belirleme, zaman içindeki ilerlemeyi takip etme, karar verme sürecini geçmiş verileri sunarak iyileştirme, süreçleri optimize etme, sayısal verilerle ilgili iletişimi kolaylaştırma, performansı rekabete karşı veya ürün grupları arasında karşılaştırma ve ekipleri yeni hedeflere ulaşmak için motive etmeye yardımcı olma gibi pek çok avantajı vardır (Hwang ve Chen, 2017; Hurwitz, Kaufman, Bowles, Nugent, Kobielski ve Kowolenko, 2015; Charles, Garg, Gupta ve Agarwal, 2023; Shmueli, Bruce, Deokar ve Patel, 2023, Wolniak, 2023).

Betimsel analitik kullanımının çeşitli faydaları olsa da işletmelerin ve kuruluşların farkında olması gereken bazı potansiyel dezavantajları ve sorunları vardır. Eğilimleri ve kalıpları belirlemek için analiz etmeye odaklandığı geçmiş veriler, bilinçli kararlar almak için faydalı olsa da sınırlı tahmin gücüne sahiptir (Downie ve Starry, 2019). Betimsel analitik, gelecekteki olayları veya sonuçları tahmin edemez, yalnızca onu analiz etmek için kullanılan veriler kadar iyidir. Veriler eksik, yanlış veya önyargılıysa, betimsel analizler tarafından üretilen içgörüler kusurlu veya yanıltıcı olabilir (Murphy, 2021). Bununla birlikte, betimsel analitik yorumlanması zor olabilecek büyük miktarda veri üretebilir. Özellikle deneyimli bir veri analitiği ekibi olmayan işletmeler için hangi içgörülerin durumla en ilgili ve faydalı olduğunu belirlemek zor olabilir. Büyük miktarda verinin depolanması ve işlenmesi de maliyetli olabilir. Son olarak, işletmelerin topladıkları verilere, bu verilerin nasıl kullanıldığına ve bu verilere

kimlerin erişebildiğine de veri gizliliği düzenlemelerine uyum temelinde dikkat etmeleri gerekir (Wolniak, 2023).

Betimsel analitik işletmeler için birçok fayda sunsa da göz önünde bulundurulması gereken dezavantajların da olduğu unutulmamalıdır. Bunlardan en önemlisi, daha fazla analiz ve yorumlama gerçekleştirilmeden eyleme dönüştürülebilir içgörüler sağlayamamasıdır (Downie ve Starry, 2019). Bu nedenle, verilerin sonuçlarını tam olarak anlamak ve bilinçli kararlar almak için kestirimsel ve öngörücü analitik gibi diğer analitik türleriyle tamamlanması gerekir.

Kestirimsel analitik

Kestirimsel analitik ya da diğer yaygın kullanım adıyla tahmine dayalı analitik; gelecekteki veri değerlerini, olayları veya gelecekte ortaya çıkabilecek kalıpları tahmin etmek için geçmiş veriler üzerinde veri odaklı modelleme, veri madenciliği ve öğrenme yöntemleri kullanan bir grup analitik yöntemi tanımlamaktadır (Çetintemel, 2018). İşletme yönetiminde kestirimsel analitik, bilinçli kararlar almak ve operasyonel verimliliği artırmak için kullanılır. Örneğin, geçmiş verilere dayanan tahminlerde bulunarak bir sonraki ay ayrılacak müşterileri veya bir sonraki hafta doğrudan posta gönderisine yanıt verme olasılığı en yüksek olan müşteriler bulunabilir. Ayrıca hangi müşterilerin bir banka kredisinde temerrüde düşme ihtimalinin daha yüksek olduğu belirlenebilir ya da üretim alanındaki makinelerin ne zaman bozulacağı tahmin edilebilir. Kestirimsel analitik şu anda en yaygın olarak pazarlama alanında kullanılmakta; sadakat uygulamaları, çapraz satış, kampanya yönetimi, müşteri edinme ve bütçeleme modelleri ile uygulama açısından öne çıkmaktadır (Eckerson, 2007).

Kestirimsel analitik ile mevcut ve geçmiş verilere dayanarak bir tahmin yapabilmek için izlenmesi gereken birkaç adım vardır. Kestirimsel analitik ile bir tahmin modeli geliştirmeden önce tahminin amacını belirlemek ve modeli oluşturmak için hangi verilere ihtiyaç duyulacağı belirlenmelidir. Tahmine dayalı modeli oluşturacak olan veri analistinin, gerekli olan veri kümelerini çeşitli kaynaklardan toplaması ve topladığı bilgileri bulunduğu yerde doğrulaması gerekir (Elkan, 2013). Veri analistleri, toplanan bilgileri analiz ederek model kullanımı için hazırlar. Bu süreçte, yapılandırılmamış veriler yapılandırılmış bir formata dönüştürülür. Veriler bütünüyle elde edildikten ve düzenlendikten sonra kalitesi incelenir. Verilerin kalitesi, kestirimsel modelin ne kadar iyi performans göstereceği üzerinde doğrudan bir etkiye sahiptir. Ham verinin analiz için gereken formata dönüştürülmesini ifade eden "verinin işlenmesi" terimi analiz adımını tanımlamak için kullanılır. Kestirimsel analitik sürecinde kullanılan çok sayıda istatistiksel ve makine öğrenimi tekniği vardır. Regresyon analizi ve olasılık teorisine dayanan yöntemler yaygın olarak kullanılırken (Kalaian, Kasim ve Kasim, 2017); yapay sinir ağları, karar ağaçları ve destek vektör makineleri gibi makine öğrenimi yöntemleri (Detienne ve Detienne, 2017) de çeşitli kestirimsel analitik uygulamalarında sıklıkla kullanılmaktadır. Her tahmine dayalı analitik modeli, makine öğrenimi ve/veya istatistiksel yöntemler kullanılarak oluşturulur (Ajiga, Okeleke, Folorunsho ve Ezeigweneme, 2024). Örnek veri kümesi ve istatistiksel ve makine öğrenimi yaklaşımları kullanılarak bir kestirimsel model oluşturulur. Modelin geçerli olduğundan emin olmak için birincil veri kümesinin bir alt kümesi olan bir test veri kümesi kullanılarak değerlendirilir ve başarılı ise modelin uygun olduğu kabul edilir. Bu aşamadan sonra sisteme yeni girilen verileri model tahmin edebilir. Modelin başarılı bir şekilde test edilmesinin ardından, model düzenli tahmin ve karar verme süreçlerinde kullanılabilir. Modelin doğru tahminler ve doğru sonuçlar ürettiğinden emin olmak için sürekli olarak gözlemlenmesi önemlidir (Kumar ve Garg, 2018). Açıklandığı üzere, kestirimsel analitik geleceği tahmin etmeye yönelik tek adımlı bir süreçten daha fazlasıdır ve metodik bir süreç izler.

Tahmine dayalı analitik, şirketlerin gelecekteki tahminlere ve modellere dayalı olarak bilinçli kararlar almasına olanak tanıdığı için işletme yönetimi ve pazarlamada değerli bir araçtır (Puri, Sehgal ve Sharma, 2013). Bu kapsamda işletmelere geçmiş verilere ve modellere dayalı içgörüler ve tahminler sağlayarak veri odaklı karar alınmasına yardımcı olma, müşteriler hakkında daha derin bir anlayış kazandırma, potansiyel riskleri tanımlama ve proaktif olarak azaltılmasına olanak tanıma ve işletme operasyonlarını optimize ederek maliyet tasarrufu etmelerine olanak sağlama gibi temel avantajlar sunmaktadır (Attaran ve Attaran, 2018).

Bu faydaların yanında, kestirimsel analitiğin bazı zorlukları da vardır. Kestirimsel analitik büyük ölçüde kullanılan verilerin kalitesine ve doğruluğuna dayanır. Analiz için kullanılan veriler eksik, eski veya yanlışsa, yanlış tahminlere veya içgörülere yol açabilir. Ayrıca, tam bağlamı yakalayamayan veya dış faktörleri dikkate almayan algoritmalara ve geçmiş verilere dayanarak yanlış veya eksik sonuçlar elde edilmesine sebep olabilir. Aynı zamanda, gizlilik ve veri kullanımına ilişkin etik kaygılar da kestirimsel analitiğin gündemindedir (Parmar, Sharma ve Agarwal, 2023). Örneğin, işletmeler kişisel verileri uygun izin olmadan veya gizliliği ihlal edecek şekilde toplar ve analiz ederse, itibarlarına zarar verebilir, yasal ve düzenleyici sonuçlarla karşılaşabilir (Bradlow, Gangwar, Kopalle, ve Voleti, 2017).

Kestirimsel analitik, sağlık, üretim, pazarlama, perakende ve finans dahil olmak üzere çeşitli sektörlerde geniş bir uygulama alanına sahiptir (Wiravan, 2023; Valli, 2024; Hu ve Wen, 2024). En iyi bilinen uygulamalardan biri de hava tahminidir (Hu ve Wen, 2024). Bunların dışında seçimlerin sonuçları (Awais, Hassan ve Ahmed, 2021), hastalıkların yayılma hızı (Venkatesh, Balasubramanian ve Kaliappan, 2019) ve iklim değişikliğinin etkileri (Mehendale, 2022) de kestirimsel analitik kullanılarak tahmin edilmektedir. İş dünyasında kestirimsel analitik yeni ürünlerin geliştirilmesine, yeni pazarların belirlenmesine, bütçelerin yönetilmesine, müşteri memnuniyetinin iyileştirilmesine ve iş, pazarlama ve fiyatlandırma stratejilerinin oluşturulmasına yardımcı olur. Örneğin, bir sigorta şirketinin otomobil sigortası kapsamının maliyetini ve onayını belirlerken yaş, cinsiyet, konum, araç türü ve sürüş geçmişi gibi sürüş güvenliğiyle ilgili kriterleri göz önünde bulundurması muhtemeldir (Tucci, 2021). Banka ve finansal kuruluşlar riski azaltmak için, bir alıcının veya bir hizmet tüketicisinin temerrüde düşme olasılığını kestirimsel analitik uygulayarak önceden değerlendirebilir. Söz konusu değerlendirme kapsamında kredi puanı, kişinin kredibilitesi ile ilgili tüm veriler kullanılarak kestirimsel model tarafından oluşturulur (Nahar, Hossain, Rahman ve Hossain, 2024). Pazarlama kampanyası optimizasyonunu amaçlayan bir işletme ise müşterilerinin bir ürünü satın alma konusundaki tepkilerini, kestirimsel analitik uygulayarak tahminleyebilir ve çapraz satış fırsatlarını teşvik etmek için bu modellemeyi kullanabilir. Farklı örnekler temelinde ele alındığında, kestirimsel modelleme uygulayarak bir üniversite, başvuru verilerine ve kabul geçmişine göre bir öğrencinin kaydolmayı seçip seçmeyeceğini tahmin edebilir; bir hastanedeki araştırma grubu, pediatrik beyin tümörlerini sınıflandırma ve tedavi etme becerisini geliştirebilir; bir havayolu şirketi, bir uçuşa gelmeyecek yolcu sayısını daha iyi tahmin ederek gelirini ve müşteri memnuniyetini artırabilir (Kumar ve Garg, 2018).


Kestirimsel analitik, geçmiş verilere dayalı değerli tahminler ve içgörüler sağlarken işletmelere istenen sonuçları etkilemek için hangi eylemi gerçekleştirmeleri gerektiğini önerme konusunda yetersiz kalmaktadır (Nunes, Santos ve Rocha, 2023). İşletmeler, yalnızca tahmine dayalı analitikle ilişkili sınırlamaları ve etik hususları gidermek için hem kestirimsel hem de öngörücü analitiğin güçlü yönlerini bir araya getirerek veriye dayalı karar verme sürecinin tüm potansiyelinden yararlanabilir.

Öngörücü analitik

Öngörücü analitik, veriye dayalı içgörülere dayalı olarak en iyi eylem planını belirlemek veya önermek için pazarlama yönetiminde gelişmiş analitik tekniklerinin uygulanmasını ifade eder. İş analitiğinin en gelişmiş türü olan öngörücü analitik, işletmeler tarafından geleceğin öngörüldüğü şekilde değerlendirilebilmesi için veri zenginliğini kullanarak işletmelere en uygun aksiyonu önermektedir (Lepeniotti et al., 2020). Bunu başarmak için, uyarlanabilir, otomatik, sınırlı, zamana bağlı ve optimal kararlar sağlamak üzere olasılığa dayalı bir çerçeve içinde uzman sistemler, yapay zekâ ve optimizasyon algoritmalarıyla birlikte tahmine dayalı kestirimsel analitik çıktıları kullanır (Engel, Etzion ve Feldman, 2012; Gartner, 2017).

Öngörücü analitik son yıllarda pazarlama yönetiminde karar alma ve strateji için güçlü bir araç haline gelmiştir. İşletmelerin stratejik karar alma ve pazarlama çabalarını optimize etmek için verilerden yararlanmanın değerini fark etmesiyle pazarlama yönetiminde daha yaygın kullanılmaya başlanmıştır. Öngörücü analitik, büyük verilerden ve makine öğrenimi gibi gelişmiş analitik tekniklerinden yararlanarak pazarlamacıların yalnızca geçmiş ve mevcut pazarlama verilerini analiz etmelerini değil, aynı zamanda gelecekteki müşteri davranışlarını ve sonuçlarını tahmin etmelerini de sağlar (Artun ve Levin, 2015). Şirketler, pazarlama stratejilerine öngörücü analitiği dâhil ederek, içgörü ve önerilerle desteklenen veri odaklı kararlar alarak rekabet avantajı elde edebilirler.

Betimsel, kestirimsel ve öngörücü analitik, iş analitiğinin üç aşamasıdır ve Şekil 1’de gösterildiği üzere farklı zorluk, değer ve bilgi seviyeleri ile karakterize edilir.



Şekil 1: İş Analitiğinin Üç Aşaması

Kaynak: Gartner, 2017

Şekil 1’de en soldan başlayarak betimsel analitik, şu anda neyin meydana geldiğini ve neyin değiştirilmesi veya hafifletilmesi gerektiğini belirlemek için olayın altında yatan nedenlerle ilgili verileri toplar ve analiz eder. Bu verilere dayanarak kestirimsel analitik bir olayın meydana gelme olasılığını, yaklaşık zamanlamasını ve nedenini tahmin edebilir. Şekil 1’de gösterildiği gibi, kestirimsel analitiğin iş değerini önemli ölçüde artırdığı tespit edilmiştir. Bununla birlikte, bu durum yapılan seçimler ve gerçekleştirilen eylemlerle yakından ilişkilidir. Optimum karar verme için, kestirimsel analitik, öngörücü analitik ile birlikte kullanılabilir. Ancak bu senaryoda bile karar vermede yaşanacak gecikmeler, kestirimsel analitiğin işletmeler tarafından tam olarak kullanılamamasına sebep olabilir. Şekil 1’de görüldüğü gibi öngörücü analitik, kestirimsel analitiğin sonuçlarına dayanarak proaktif önerilerde bulunur (Lepeniotti et al., 2020).

Öngörücü analitik, betimsel ve kestirimsel analitiğin aksine, karar vericilerin öngörülen gelecekte faydalanmak için en iyi hareket tarzını aktif bir şekilde önermesini ve her seçeneğin sonuçlarını göstermesini sağlamaktadır. Ayrıca karar vericilerin sorunları ve fırsatları (geçmiş, bugünü veya geleceği inceleyerek) belirlemelerini sağlayan en gelişmiş iş analitiği türü olup işletmelere en fazla içgörü ve faydayı sağlayabilir (Şikšnys ve Pedersen, 2018). Öngörücü analitik; (1) veri toplama ve birleştirme, (2) bilgi çıkarma, (3) tahmin, (4) optimizasyon, (5) görselleştirme ve (6) önce tahminler yapmak ve daha sonra bu tahminlere dayanarak (a) zamana bağlı en uygun kararları önermek ve (b) her bir karar seçeneğinin sonuçlarını göstermek için ‘olursa-ne olur analizi’ faaliyetlerini kapsar.

Öngörücü analitik, pazarlama yönetiminde çeşitli avantajlar sunar. En önemli avantajlardan biri, veri temelli içgörülere dayalı olarak en iyi eylem planı için öneriler sunarak pazarlama çabalarını optimize etme yeteneğidir (Lepeniotti et al., 2020). Bu sayede gelişkin hedefleme, kişiselleştirilmiş mesajlaşma ve kaynakların daha etkili bir şekilde tahsis sağlanabilir. Ayrıca, gelecekteki müşteri davranışlarını ve sonuçlarını tahmin etmeye yardımcı olarak pazarlamacıların stratejilerini ve kampanyalarını hedef kitlelerinin ihtiyaçlarını karşılayacak şekilde proaktif olarak uyarlamalarına olanak tanır (Chen, 2024). Bu proaktif yaklaşım, müşteri memnuniyetinin ve sadakatın artmasını sağlayabilir. Öngörücü analitikten yararlanan kuruluşlar, veriye dayalı içgörüler ve önerilerle desteklendikleri için stratejik kararları daha yüksek bir güvenle alabilirler. Bu da daha başarılı pazarlama girişimleri sağlayabilir ve nihayetinde pazarda rekabet avantajı elde edilmesine katkıda bulunabilir (Sharma et al., 2022). İşletmeler için çığır açan avantajlarının yanında yine de öngörücü analitik yanılmaz değildir. Etkili olabilmesi için işletmelerin hangi soruları soracaklarını ve yanıtlara nasıl karşılık vereceklerini bilmeleri gerekir. Bu nedenle yalnızca girdileri geçerli olduğunda işlevsel olduğuna dikkat çekmek gerekir. Girdi varsayımları yanlış ise çıktı bulguları da doğru olmayacaktır. Öngörücü veri analitiği ile uzun vadeli kararlar alırken şirketlerin, çıktıların etkililiğini zamana göre değerlendirmesi gerekmektedir (Segal, 2022).

Öngörücü analitik örnekleri

Öngörücü analitik ile işletmeler olası senaryoları gözden geçirebilir ve bir uygulamanın artan etkisini değerlendirebilir, farklı stratejileri simüle edebilir ve bunların gelir, maliyet tasarrufu ve müşteri

memnuniyeti gibi temel ölçütler üzerindeki potansiyel etkilerini değerlendirebilir (Sanisoglu, Burnaz ve Kaya, 2023). Bu şekilde öngörücü analitik kullanımı istenen sonuçlara ulaşmak için en etkili aksiyonun belirlenmesine yardımcı olur.

Sağlık, satış, yükseköğrenim, spor, finans, insan kaynakları, politika ve pazarlama gibi pek çok alanda işletmelerin değişen pazar koşullarına, müşteri davranışlarına ve diğer dış faktörlere göre stratejilerini dinamik olarak ayarlamalarını sağlamak üzere öngörücü analitik yöntemleri kullanılmaya başlanmıştır (Sanisoglu vd., 2023). Örneğin, yakınlarda bir orman yangını varken yerel bir itfaiyenin bölge sakinlerinden belirli bir alanı tahliye etmelerini isteyip istemeyeceğini değerlendirmek; ilgili konulardaki aramalar ve sosyal paylaşımlar hakkındaki verilere dayanarak belirli bir konudaki bir makalenin okuyucular arasında popüler olup olmayacağını tahminlemek; çalışanın her bir derse nasıl tepki verdiğine bağlı olarak çalışan eğitim programını gerçek zamanlı olarak ayarlamak; hangi hastalarının yeniden kabul edilme riskinin en yüksek olduğunu analiz etmek ve bir havayolu şirketinin müşteri talebi, hava durumu ve benzin fiyatları gibi çok sayıda faktöre göre bilet fiyatlarını ve kullanılabilirliğini otomatik olarak ayarlamak için öngörücü analitik kullanılmaktadır (Segal, 2022).

Pazarlama alanında da öngörücü analitiğin kritik bir öneme sahip olduğu görülmektedir. Örnek olarak, pazarlamacılar öngörücü analitik yöntemlerini kullanarak ABD’de her yıl düzenlenen Amerikan futbol ligi şampiyonluk maçı Superbowl sırasında belirli bir demografik gruba reklam vermek gibi belirli zamanlarda belirli müşterileri hedefleyen etkili kampanyalar oluşturmaktadır (Cote, 2021). Şirketler ayrıca farklı müşterilerle nasıl etkileşim kuracaklarını ve mal ve hizmetlerini nasıl etkili bir şekilde fiyatlandırıp indirim yapacaklarını da öngörücü analitik yöntemleri ile belirlemektedir. Ayrıca satış süreci boyunca sayfa görüntüleme, e-posta etkileşimleri, site aramaları ve benzeri eylemlere bir puan değeri atayarak öngörücü analitik algoritmaları ile müşteri adaylarını müşteriye dönüşme olasılıklarına göre sıralanmasını sağlamaktadır. Sosyal medya platformlarından TikTok da daha yüksek müşteri etkileşim oranları, artan müşteri memnuniyeti ve müşterileri davranışsal geçmişlerine dayalı reklamlarla yeniden hedefleme potansiyelini arttırmak için öngörücü analitik yöntemlerinden faydalanmaktadır (TikTok, n.d).

Öngörücü analitik ve artımlı modelleme


Öngörücü analitik, kontrol değişkenlerinin fonksiyonu olarak geleceği simüle ederek, işletmeler için beklenen sonucu en üst düzeye çıkaran (veya en aza indiren) kontrol değişkenlerinin ayarlarını optimize etmeye olanak sağlamaktadır. Artımlı modellemesi, bir pazarlama kampanyasının müşterinin davranışı üzerindeki etkilerine bakmaya imkân sağladığı için öngörücü pazarlama ve müşteri analitiği alanında temel bir yaklaşımdır. Artımlı modellemesi bir öngörücü analitik yöntemi olarak sonuçlar üzerindeki artan etkiyi tahmin ederek müdahalelerin veya tedavilerin etkinliğini en üst düzeye çıkarmayı amaçlar (Cao et al., 2017). Yalnızca sonuçları tahmin etmeye odaklanan geleneksel kestirimsel tahmin modellerinin aksine artımlı modellemesi, özellikle pazarlama iletişimi gibi belirli bir işletme müdahalesinden pozitif yönde etkilenme olasılığı en yüksek olan bireyleri tanımlar. Bu hedefli yaklaşım, işletmelerin eylemlerini olumlu yanıt verme olasılığı en yüksek olan bireylere göre uyarlamalarına olanak tanıyarak genel etkiyi ve yatırım getirisini en üst düzeye çıkarmaktadır. Artımlı modellemesi, işletmelerin kaynaklarını daha verimli bir şekilde tahsis etmelerine yardımcı olduğu için öngörücü analitikte tercih edilen ve sonuçta daha iyi karar alma ve daha iyi sonuçlar elde edilmesini sağlayan bir yöntemdir (Devriendt et al., 2018; Gubela ve Lessman, 2021).

Milenyumun başlarında literatüre girmesinden bu yana, artımlı modelleme bir dizi aksiyon arasından mümkün olan en iyi sonucu verecek adayın seçilmesi gerektiği konusunu vurgular (Zhao, Fang ve Simchi-Levi, 2017). Artımlı modelleri, işletmelerin bir pazarlama iletişim aksiyonunda bulunduğu her bir müşteri grubundan elde edilen sonucu, kontrol grubundan elde edilen sonuçtan çıkararak, iki veya daha fazla farklı birbirini dışlayan sınıfın koşullu ortalama etkisini simüle etmeye çalışır. İşletmelerin yalnızca doğrudan pazarlama kampanyasına olumlu yanıt verme olasılığı en yüksek olan müşterileri hedefleme amacı olduğunda, artımlı modelleme doğrudan iletişim eylemini ve ilgili zaman ve harcanan masrafları optimize etmek için kullanılabilir (Munting, 2020). Böylece, işletmeler telesatış, e-posta ve mobil bildirim gönderimi gibi bir iletişim aksiyonu gerçekleştirmeden önce hangi müşterilerin bu iletişimden etkilenerek satın alma olasılığını yükselteceğini belirleyebilir ve örneklemin daha az bir kısmını hedefleyerek pazarlama giderlerinden tasarruf sağlayabilir ve gelirlerini arttırabilir (Siegel, 2011).

Artımlı modelleme

Artımlı modelleme, bir müşterinin aynı anda hem deney grubu hem de kontrol grubunda olamamasının yarattığı temel sorunu çözmeye olanak sağlayan bir öngörücü analitik yöntemidir. Şekil 2’de gösterildiği üzere, artımlı modelleme örneklemini dört grupta tanımlayarak, bir aksiyon alınan veya

kontrol grubunda bulunan müşterilerin satın alma davranışlarını tahmin eder. Yukarıdan aşağıya doğru, ilk boyut hangi müşterilerin iletişime geçildiğinde yanıt vereceğini, ikinci boyut ise hangi müşterilerin iletişime geçilmese bile satın alma yapacağını kategorize etmektedir (Kane, Lo ve Zheng, 2014).



Şekil 2: Artımlı Modelleme Sınıfları

Kaynak: Kane, Lo ve Zheng, 2014

Şekil 2'nin sağ alt bölümü, pazarlama kampanyası için temas kurulduğunda satın alım yapacak olan ancak iletişime geçilmezse satın almayacak olan "İkna Edilebilir" müşteri grubunu temsil etmektedir (Siegel, 2011). Bu grupta bulunan müşteri kitlesi doğrudan pazarlama uygulaması ile hedeflenerek, satın alma yanıtını işletmeye fayda sağlayacak şekilde değiştirmek amaçlanır. Sol alttaki bölümde, söz konusu mal ya da hizmeti, bir doğrudan pazarlama iletişimi olsa da olmasa da her koşulda satın alacak müşterilerden oluşan, "Kesin Olanlar" tanımlanmaktadır. Şekil 2'nin sağ üst kısmında yer alan "Kayıp Vakalar" ise tam tersi doğrudan pazarlama iletişimi olsa da olmasa da satın alma işlemi yapmayacak olan müşterileri içermektedir (Karlsson, 2019). Bu nedenle, "Kesin olanlar" ve "Kayıp vakalar" grubuna giren müşteri kitleleri için doğrudan pazarlama çabası sarf edilmemelidir, çünkü alınan aksiyon satın alma kararlarında etkisiz olacaktır. Son olarak, "Rahatsız edilmemesi gerekenler", uygulamadan rahatsız olacak ve satın alma kararını olumsuz yönde değiştirecek olan müşterileri temsil etmektedir. Bu grup için alınan pazarlama aksiyonları, amaçlarının tersine bir etkiye neden olacağı için işletmeler müşteri kaybını önlemek adına uygulamalarında bu müşterileri hedeflemekten kaçınmalıdır (Siegel, 2011; Rzepakowski ve Jaroszewicz, 2012). Artımlı modelleme, biri kontrol grubunu, diğeri de doğrudan pazarlama aksiyonu alınan deney grubunu içeren iki veri seti kullanarak koşullu sınıf olasılıkları arasındaki farkı modellemeyi amaçlamaktadır. Bu sayede, pazarlama kampanyasının verimliliğini arttırmak için uygulama yapılacak "İkna edilebilirler" kitlesini tanımlamaktadır.

Matematiksel olarak artımlı modelleme denklem 1 ile tanımlanmaktadır. Aksiyon alınan ve bir işlem yapılan kitle, deney grubu olarak adlandırılır ve "T" ile simgelenmektedir. Kontrol grubu ise "C" ile ifade edilmektedir. Deney ve kontrol gruplarındaki satın alma olasılıkları sırasıyla P^T ve P^C olarak gösterilmektedir. Girdi değişkenleri, deney ve kontrol grubu verilerini içeren tüm modeller için aynıdır. Satın alma faaliyetinin sonucunu gösteren yanıt değişkeni $Y \in \{0,1\}$ olarak değer alır; burada 1 ürünün satın alınması yanıtı iken; 0 ise ürünün satın alınmaması olarak olumsuz yanıtı ifade eder. Girdi değişkenleri $X \in \{X_1, \dots, X_p\}$ olarak gösterilir; burada p verideki değişkenlerin sayısına karşılık gelirken x tek bir gözlemi temsil eder. M^U deney ve kontrol gruplarının koşullu olasılıkları arasındaki fark olarak tanımlanan beklenen artımlı için kullanılan gösterimdir:

$$M^U = P^T(Y = 1, X = x) - P^C(Y = 1, X = x) \quad (1)$$

Bu denklem sonucunun negatif olması, kontrol grubunda yer alan müşterinin satın alma yapma olasılığının, uygulama yapılan müşteriden daha yüksek olduğunu ifade etmektedir (Börthas ve Sjölander, 2020). Dolayısıyla, kampanyanın müşteriler üzerinde olumsuz bir etkisi olduğunu gösterir.

Artımlı modellemenin kullanım alanları

Literatürde son birkaç yılda, çeşitli alanlarda artımlı modelleme yaklaşımları ve algoritmaları uygulanmaktadır. Doğrudan pazarlama kampanyalarında doğru kitleyi hedefleyerek pazarlama etkisini en üst düzeye çıkarmak ve maliyetleri en aza indirmek için artımlı modellemenin çeşitli yöntemleri kullanılmış ve ilgili çalışmalarda artımlı modellemenin pozitif etkisi ortaya konmuştur (Cao et al., 2017; Goldenberg et al., 2020; Hansotia ve Rukstales, 2002; Lo, 2002; Shimizu et al., 2019; Hu, 2023;


Sanisoglu vd., 2023). Ayrıca işletmelerin müşteri kaybı yönetimi uygulamalarını optimize etmek için de çeşitli çalışmalar tarafından gerçek ve o edilen veri setleri ile uygulanarak sonuçları tartışılmıştır (Radcliffe ve Simpson, 2008; Guelman, Guillén ve Pérez-Marín, 2012; De Caigny, Coussement, Verbeke, Idbenjra ve Phan, 2021; Devriendt et al. 2018; Olaya et al., 2020). Doğrudan pazarlama ve müşteriye elde tutma uygulamaları dışında diğer çalışmalarda etkili içerik hedefleme (Zhao et al., 2022), optimum kanal seçimi, dinamik fiyatlandırma ve indirim, kredi riski belirleme (Siegel, 2011), seçim politikası ve kişiselleştirilmiş ilaç tedavisi uygulamaları (Robins ve Rotnitzky, 2004; Jakowski ve Jaroszewicz, 2012) için artımlı modelleme öngörücü analitik yöntemi olarak geliştirilerek çalışılmıştır. Son yıllarda ise, artımlı modellerin finansal hedefleri karşılamak için gelir artırma modelleme yaklaşımlarında da kullanılması dikkat çekmektedir (Goldenberg ve Albert, 2022; Gubela ve Lessmann, 2021; Proença ve Moraes, 2023).

Artımlı modellemenin yöntemleri

Artımlı modelleme için birçok yaklaşım vardır. Bu bölümde, artımlı modelleme probleminin formülasyonu ile üç yaygın artımlı modelleme yaklaşımı tanıtılmakta ve değerlendirme tekniği açıklanmaktadır.

İki model yaklaşımı

Artımlı modellemeye yönelik en basit yaklaşım iki model yaklaşımıdır. Bu yöntem ile deney ve kontrol grubu gözlemleri tarafından ayrı ayrı eğitilen iki ayrı model oluşturulur. İlk model, deney grubunda doğrudan pazarlama uygulaması yapılan gözlemler üzerinden eğitilir, ikinci model ise uygulama yapılmayan kontrol grubundaki müşteri gözlemleri üzerinden eğitilir. Eşitlik 1’de gösterildiği üzere, deney grubu verilerini içeren model tarafından tahmin edilen sınıf olasılıklarından kontrol grubu verilerini içeren model tarafından tahmin edilen sınıf olasılıkları çıkartılır ve aradaki “artım” hesaplanır (Radcliffe ve Simpson, 2008). Şekil 3’de üç adımda gerçekleşen süreç gösterilmektedir. Buna göre ilk adımda kontrol grubu verilerinden bir model oluşturulmakta, ikinci adımda ise deney grubu verilerinden benzer bir model oluşturulmaktadır. Son adımda, bir model skorunun diğerinden çıkartılmasıyla aradaki artış hesaplanmaktadır.



Şekil 3: İki Model Yaklaşımı

Kaynak: Yazarlar tarafından üretilmiştir.

İki model yaklaşımı literatürde çeşitli çalışmalarda uygulanmıştır. Hansotia ve Rukstales (2002), gerçek bir promosyon kampanyasında iki model yaklaşımını uygulamış ve ziyaret etme olasılığı olmayan bir müşteriden ek bir ziyaret yaratılabildiğini göstererek doğrudan pazarlama yatırımının getirisini artırıp kampanya tasarımını optimize etmeyi başarmışlardır. Benzer şekilde, Cao et al. (2017) bir pazarlama kampanyasında artan işlem adedi ve satın alma yaratacak müşterileri belirlemek için iki model yaklaşımını kullanmış ve yalnızca en yüksek yanıt oranına sahip müşterilerin seçilmesinin her zaman maksimum kazanç sağlamadığını göstermiştir. Goldenberg et al. (2020); Goldenberg ve Albert (2020,); Baier ve Stöcker (2022) ve Sanisoglu vd. (2023) tarafından yürütülmüş daha güncel çalışmalarda, iki model yaklaşımı diğer artımlı modelleme yöntemleri ile karşılaştırılmıştır.

İki model yaklaşımı herhangi bir sınıflandırma problemine uygulanabilirliği ve doğrudan pazarlama kampanyalarının çoğunda artışı tahmin etme açısından uygulanması kolay bir öngörücü analitik yöntemi olarak ön plana çıkmaktadır. Ancak, literatürde bu yaklaşımının oldukça kusurlu bir yöntem olduğu da tartışılmaktadır. Hiçbir model mükemmel bir tahmin yapamadığından, iki iyi modelden elde edilen sonuçların çıkarılmasının iyi bir artımlı model olacağının garantisi yoktur (Radcliffe, 2007; Rzepakowski ve Jaroszewicz, 2012). İki model yaklaşımı, artımlı modellemeyi uygulamak için pratik bir başlangıç yöntemi olarak işletmeler tarafından denemeye tabi tutulurken, diğer artımlı modelleme yöntemleri ile desteklenmesi ve karşılaştırılması önerilmektedir.

Sınıf değişkeni dönüşümü

Sınıf değişkeni dönüşümü ilk olarak Jaskowski ve Jaroszewicz (2012) tarafından önerilen bir artımlı modelleme yöntemidir. Bu yöntemde, iki model yaklaşımında olduğu gibi deney ve kontrol grupları için iki ayrı model oluşturmak yerine, doğrudan artışı modelleyen tek bir model oluşturulmaktadır. Grup aidiyeti (deney ve kontrol grubu) ve satın alma davranışı dikkate alınarak tek bir değişkene (Z) dönüştürülür. Eşitlik 2’de gösterildiği gibi eğer gözlem deney grubunda ise ve bir satın alma işlemi gerçekleştirmişse ($Y=1$ ve T), bu birey ya kesin olanlar ya da ikna edilebilirler grubundadır (bkz. Şekil 2) ve bu durumda Z , 1 değerini alır. Diğer açıdan, eğer birey kontrol grubunda ise ve bir satın alma işlemi gerçekleştirmemişse ($Y=0$ ve C), bu birey ya kayıp vakalar ya da ikna edilebilirler gruplarındadır ve Z değerini yine 1 olarak tanımlanır. Diğer tüm koşullarda, Z değeri 0 olarak ayarlanır ve bu da bu koşuldaki tüm gözlemlerin rahatsız edilmemesi gerekenler grubuna ait olmasını sağlar ve bu kitleye doğrudan pazarlama uygulaması yapılması riskini ortadan kaldırır (Jaskowski ve Jaroszewicz, 2012).

$$Z = \{Y = 1 \text{ ve } T \text{ ise, } 1 ; Y = 0 \text{ ve } C \text{ ise, } 1 ; \text{ diğer tüm durumlarda } 0\} \quad (2)$$

Sınıf değişkeni dönüşümü, iki model yaklaşımından farklı olarak, yalnızca ikna edilebilirler grubuna odaklanmamaktadır ve bu nedenle bu yöntem sadece bu grubu hedeflemek için kullanılamaz. Jaskowski ve Jaroszewicz (2012) tarafından önerilen bu dönüşüm, ikili bir sonuç varsa ve deney ile kontrol grubunun büyüklüğü dengeliyse, dönüştürülmüş Z değişkeni ve eşitlik (2) ile artışın modellenebileceğini göstermiştir. Bu yöntem tek doğrusal bir modelin uygulanması ve her bir değişkenin artış üzerindeki etkisinin yönü ve gücünü tek bir katsayı seti ile verimli bir şekilde belirleyebilmesi açısından işlevsel olarak avantajlıdır (Jaskowski ve Jaroszewicz, 2012). Sınıf değişkeni dönüşümü yaklaşımının bir diğer avantajı da dönüştürülen sınıfın (Z), koşullu sınıf olasılıklarını tahmin etmek için herhangi bir istatistiksel makine öğrenimi yöntemiyle modellenebilmesidir.

Sınıf değişkeni dönüşümü, klinik çalışmalarda tedavinin en faydalı olacağı hasta gruplarını keşfetmede (Jaskowski ve Jaroszewicz, 2012); bir doğrudan pazarlama kampanyasında, kuponların potansiyel en karlı müşterilere dağıtılarak maliyet düşüşü elde edilmesinde (Shimizu et al., 2019, sf.1748); en uygun müşteri grubuna doğrudan pazarlama iletişimi gerçekleştirilerek kampanya etkinliğinin artırılmasında (Sanisoglu vd., 2023) ve yakın tarihli diğer çalışmalarda da yatırımın geri dönüşü kısıtlamalarına tabi olarak gerçek promosyon kampanyalarında sonucu optimize etmede (Goldenberg et al., 2020; Röbler, Tilly ve Schoder, 2021; Gubela ve Lessman, 2021) kullanılmıştır.

Doğrudan artımlı modelleme

Artımlı modellemede yaygın olarak kullanılan bir başka yaklaşım, mevcut makine öğrenimi algoritmalarını uyarlayarak artışı doğrudan ağaç tabanlı yöntemlerle modellemektir. Bu yaklaşım, verileri alt popülasyonlara ayırmak ve sınıflandırmak için ağaç tabanlı algoritmalar uygular ve onları deney ve kontrol grubu arasındaki farklılığı modellemek için kullanışlı hale getirir (Radcliffe ve Surry, 2011). Karar ağaçlarındaki bölme kriterleri, bu farklılıkların doğrudan artışın modellenmesi için uygun olmasını sağlar.

Artımın tespit edilmesini sağlamak için ağaç tabanlı algoritmada bölme kriteri uygulanmaktadır. Literatürde, artışı en iyi şekilde tahmin etmek için bölme kriterine uyum sağlamak üzere önerilen çok sayıda yöntem olsa da hangi yöntemin en etkili olduğu konusunda bir fikir birliği bulunmamaktadır. En yaygın olarak kullanılan bölme kriterleri olarak Rzepakowski ve Jaroszewicz (2012) tarafından geliştirilen Kullback-Leibler uzaklığı (KL) ve kareli Öklid uzaklığı (ED) aşağıda açıklanmaktadır.

$$KL(P:Q) = \sum p_i \log p_i q_i \quad (3)$$

$$ED(P : Q) = \sum (p_i - q_i)^2 \quad (4)$$

Eşitlik 3 ve 4’de gösterildiği üzere i , ikili sınıflandırmada 1 ve 2 olarak satın alma davranışını temsil etmekte; p_1 ve p_2 deney grubundaki olasılıkları, q_1 ve q_2 ise kontrol grubundaki olasılıkları ifade etmektedir. Bölme kriterleri, iki olasılığın birbirinden ne kadar farklı olduğunu ölçmenin bir yolu olarak koşullu dağılım farklılığına (Kullback-Leibler ve Öklid uzaklığı) dayanmaktadır. Bu yöntem ile ağacın her seviyesinde test grubu seçilerek bir bölme gerçekleştirildikten sonra deney ve kontrol gruplarındaki sınıf dağılımları arasındaki farkın maksimize edilmesi amaçlanır (Rzepakowski ve Jaroszewicz, 2012).

Artımın doğrudan modellenmesi için ağaç tabanlı algoritmalar literatürde çeşitli çalışmalarda kullanılmıştır (Hansotia ve Rukstales, 2002; Radcliffe ve Surry, 2011; Rzepakowski ve Jaroszewicz, 2012; Guelman et al., 2015; Röbler et al., 2021; Devriendt et al., 2021; Goldenberg ve Albert, 2021; Sanisoglu vd., 2023). Doğrudan artımlı modellemenin en önemli avantajı hem ikili hem de sürekli hedef değişkeni

için kullanılabilir olmasıdır (Radcliffe, 2007). Bir müşterinin satın alma davranışını alabileceği iki değere göre tahminlemekte kullanılabileceği gibi, bir müşterinin bir satın alma işlemi için harcayacağı tutarı sürekli bir hedef değeri olarak tahmin etmek için de kullanılabilir.


Artımlı modellemenin değerlendirilmesi

Artımlı modellerin değerlendirilmesi, modelin bir kontrol grubuna kıyasla bir pazarlama müdahalesinin bireysel müşteriler üzerindeki artan etkisini doğru bir şekilde tahmin etme kabiliyetinin değerlendirilmesini içerir. Bu değerlendirme, genellikle belirli bireylerin hedeflenmesinden elde edilen ek faydayı ölçen artış metriklerini içerir. Qini eğrisi, belirli uygulamaların veya eylemlerin ek artış etkisini ölçmek için artımlı modellemede öne çıkan bir değerlendirme yöntemidir.

Qini eğrisi

Qini eğrisi, artımlı modellerin değerlendirilmesinde kullanılan grafiksel bir gösterimdir. Bir uygulama veya müdahaleye yanıt verme olasılığı en yüksek olan bireylerin belirlenmesinde bir modelin artan etkinliğini ölçer. Qini eğrisi, bir popülasyondaki bireylerin tahmin edilen artış değerlerine göre sıralanması ve ardından model sıralamaları %0'dan %100'e yükseldikçe kümülatif yanıt oranının hesaplanmasıyla oluşturulur. Qini eğrisi, pozitif yanıt potansiyeli en yüksek olan bireyleri seçme kabiliyetlerine göre farklı modellerin karşılaştırılmasına olanak tanıdığı için özellikle artımlı modellemenin değerlendirmesinde faydalıdır (Kane et al., 2014).

Qini eğrisinin bir örneği Şekil 4'de gösterilmektedir. Qini eğrisinin y eksenini, artan satın alımların kümülatif sayısını, x eksenini ise doğrudan pazarlama uygulaması yapılan segmentlerin büyüklüğünü göstermektedir. Bu şekilde, Qini eğrisi pazarlama uygulamasının potansiyel olumsuz etkisinin gösterilmesini sağlamaktadır.



Şekil 4: Örnek Qini Eğrisi

Kaynak: Yazar tarafından üretilmiştir.

Mavi eğri, tüm kesin olanların, ikna edilebilir olduğu varsayımı ile ikna edilebilecek her bir bireyin belirlendiği, teorik olarak bir pazarlama uygulaması ile mümkün olan en iyi sonucu temsil eden optimum eğriyi göstermektedir. Mor diyagonal eğri, tüm bireylere rastgele sırayla uygulama yapılması durumunda ortaya çıkacak sonucu temsil eden rastgele eğridir. Kırmızı ve yeşil eğriler iki artımlı modeli temsil etmekte olup, yeşil eğri ile gösterilen model 2, kırmızı eğri ile temsil edilen diğer modelden daha iyi performans göstermektedir. Örnekten de görülebileceği gibi, tüm örneklemin bir kampanya iletişimi için hedeflenmesi durumunda, artımlı model ve rastgele dağıtım aynı sonucu vermektedir. İdeal bir artımlı modelinde "İkna Edilebilirler" en yüksek puanı, "Rahatsız Edilmemesi gerekenler" ise en düşük puanı almalıdır (Karlsson, 2019).

Tüm potansiyel müşteri kitlesinin bir alt grubu hedeflendiğinde, kampanya geri dönüşleri açısından daha yüksek bir artışı gösteren bir Qini eğrisi, iyi bir model performansının göstergesidir (Radcliffe, 2007). Şekil 4'deki örnek Qini eğrisinde, popülasyon için toplam satın alma oranı %5'tir, yani hedef gruptaki müşterilerin yalnızca %5'i kampanya iletişiminin olumsuz bir etkisi olmadan satın alma yapmaktadır veya hedef gruptaki müşterilerin %8'inin satın alma yapması ve %3'ünün bu iletişim nedeniyle satın almamaya karar vermesi mümkün olabilir. Dolayısıyla, artımlı model ile satın almayacak olan müşterileri hedef gruptan çıkararak iletişim kitlesi büyüklüğünü azaltmak ve daha yüksek bir satın alma oranı elde etmek mümkündür. Şekil 4'deki örnekte, mümkün olan en yüksek satın alma oranı (%6,5), model 2 ile hedeflenen grubun yaklaşık %65'ine kampanya iletişimi gerçekleştirerek mümkün olabilir.

Qini eğrisi, pazarlamacıların hiç kimseyi hedeflememeye kıyasla (taban çizgisi) nüfusun belirli bir yüzdesini hedeflemekten elde edilen artan faydayı görselleştirmelerine olanak tanır. Qini eğrisi ile rastgele model eğrisi arasındaki alan ise Qini değeri olarak tanımlanır. İyi bir model performansı için pozitif bir Qini değeri amaçlanmaktadır. Negatif bir Qini değeri, işletmeler için belirli bir eylemde bulunmanın hiçbir şey yapmamaktan daha kötü sonuçlar getireceğini belirtmektedir (Guelman, 2014). Özetle, Qini eğrisi ve Qini değeri artımlı modellerin etkinliğini değerlendirmek ve hedefli pazarlama kampanyalarında karar verme sürecine rehberlik etmek için değerli bir araçtır.

Artımlı modelleme için veri gereksinimi

Artımlı modelleme için kullanılacak verilerin, ayrı deney grubu ve kontrol grupları olarak düzenlenmesi gerekmektedir. Deney grubu, pazarlama müdahalesini veya uygulamasını alan müşterilerden oluşurken, kontrol grubu bu uygulamayı almayan müşterilerden oluşur. Her bir grubun büyüklüğü istatistiksel değerlendirmelere dayalı olarak belirlenmeli ve artış etkisini tespit etmek için yeterli güç hedeflenmelidir. Genel olarak, deney grubunun büyüklüğü, popülasyonun dengeli bir şekilde temsil edilmesini sağlarken istatistiksel anlamlılığı sağlayacak kadar büyük olmalıdır. Önyargıları azaltmak ve uygulama etkisinin doğru tahmin edilmesini kolaylaştırmak için karşılaştırılabilir büyüklükte bir kontrol grubuna sahip olunması önemlidir. Bir artımlı modeli oluşturabilmek için, kontrol grubu gözlem büyüklüğünün, deney grubundan 10 kat daha fazla olması önerilmektedir (Radcliffe ve Surry, 2011).

Veri ön işleme adımları

Artımlı modelleme öncesinde veri üzerinde birçok ön işleme adımı uygulanması önemlidir. Gerçek işletme verileri çoğunlukla mükemmel değildir ve eksik ya da aykırı değerler gibi birçok hata içerir. Veri ön işlemede kirli veriler çıkartılarak veya eksik veriler çeşitli yöntemlerle doldurularak veri kümesinin modelleştirmeye uygun hale getirilmesi amaçlanır (Radcliffe ve Surry, 2011). Veri setindeki değişkenlerin sağa veya sola çarpıklığı incelenerek, eksik değerler ortalama veya medyan değeri ile doldurulabilmektedir. Veri ön işlemede dikkat edilmesi gereken önemli adımlardan bir diğeri ise, veri içerisindeki dengesiz sınıf dağılımlarıdır. Bir pazarlama kampanyası iletişimi sonucunda satın alım yapanların sayısının, satın alım yapmayanlardan önemli ölçüde daha az olduğu durumlarda dengesiz sınıf dağılımının yaratacağı potansiyel zorlukların önüne geçmek için alt örnekleme, aşırı örnekleme ve bu tekniklerin kombinasyonu gibi yöntemler kullanarak verinin ele alınması önerilir (Nyberg ve Klami, 2023). Literatürde hangi yöntemin en iyi örnekleme metodu olduğunu belirleyen net bir kanıt bulunamamıştır. Dolayısıyla verinin yapısına göre satın alım yapacak olan müşterilerin tahmin edilmesinde daha etkili olan sonucu temsil edecek şekilde doğruluk ve kesinlik skorları karşılaştırılarak alt örnekleme, aşırı örnekleme ya da kombinasyonu olan teknikler arasından bir karar verilebilmektedir.

Veri setindeki sınıf dağılımları dengeli hale getirildikten sonra bir diğer önemli adım ise değişken seçimidir. Altta yatan veri modeli tam olarak bilinemediği için değişken seçimi gerçek işletme problemlerinde çok önemlidir. Yetersiz, gereksiz veya ilgisiz değişkenler aşırı uyuma yol açabilir ve modelin yorumlanabilirliğini sınırlayabilirken, ek değişkenler tahmine yeni veriler ekleyebilir. Bu nedenle, değişkenlerin seçilmesi veri ön işlemede kritik bir adımdır. Çoklu doğrusallık, bir veri kümesindeki iki veya daha fazla bağımsız değişkenin birbiriyle yüksek oranda ilişkili olduğu istatistiksel modelleme ve makine öğreniminde yaygın bir sorundur. Bu sorun, model katsayılarının önyargılı ve istikrarsız tahminlerine neden olabilir, dolayısıyla model tahminlerinin yanlışlığına yol açabilir. Çoklu doğrusallık, korelasyon matrisi, ısı haritası ve varyans şişirme faktör skorları (VIF) gibi literatürde yaygın olarak kullanılan çeşitli yöntemlerle tespit edilebilir ve ele alınabilir. VIF değeri 5'in üzerinde olan değişkenlerin, aralarında yüksek korelasyon olduğu için veri setinden çıkartılması önerilmektedir (James, Witten, Hastie ve Tibshirani, 2013).

Performans değerlendirmesi

Veri ön işleme adımları tamamlandıktan sonra, veri seti deney ve kontrol grupları içerisinde de eğitim ve test veri seti olarak ikiye ayrılır. Her model eğitim veri setleri üzerinde eğitilir ve test setleri üzerinde doğrulanır. Ardından her bir modelin performansı, Qini eğrileri ile değerlendirilir. Literatürde önceki araştırmalarda, herhangi bir artımlı modelleme yönteminin, bir diğerinden daha tutarlı bir şekilde daha iyi performans göstermediği belirtildiğinden dolayı, hangi tür artımlı modellemenin elde olan problem için en iyi olduğunu belirlemek amacıyla çeşitli algoritmaların denenmesi ve değerlendirilmesi önerilmektedir (Guelman vd., 2012; Jaskowski ve Jaroszewicz, 2012).

Her bir model için çizdirilen Qini eğrileri ve rastgele model ile aralarındaki alan hesaplanarak modeller arasındaki performans karşılaştırması yapılabilmektedir. Qini eğrisinin eğimi ne kadar dik olursa, modelin pazarlama uygulamasına yanıt verme olasılığı en yüksek olan bireylere öncelik verme becerisi

o kadar iyi olur. Daha yüksek Qini değerleri de üstün model performansına işaret eder ve modelin uygulamaya en olumlu yanıt veren bireyleri etkili bir şekilde belirlediğini gösterir. Toplam satın alıcı kitlesi, tüm uygulama gruplarına uygulama yapılmaksızın artımlı modelleme teknikleri ile önemli ölçüde artırılabilir. Artış eğrisindeki en yüksek nokta optimum artışa neden olur ve uygulama yapılması gereken grubun optimum oranını verir.

Şekil 4'de gösterilen örnek üzerinden yorumlamak gerekirse, artımlı modelleme uygulayan bir pazarlamacı daha yüksek Qini değeri olan ve dik eğimli Qini eğrisi çizen model 2'yi tercih ederek pazarlama kampanyasının hedef kitlesini belirlemelidir. Bu sayede, pazarlama kampanyası iletişimini toplam müşteri kitlesinin %65'ine yönelik gerçekleştirerek, rastgele hedefleme yapılsaydı satın alım yapacak olan %5 yerine, toplam müşteri kitlesinin %6,5'unun satın alım yapmasını sağlayıp kampanya performansında %1,5'luk bir artışa ulaşabilmektedir. Bu durum, artımlı modelleme ile sadece ikna edilebilirler grubunun hedeflenmesi ile gerçekleştirilmektedir.

Sonuç ve öneriler

Pazarlamada analitik kullanımı, işletmeler için hedef müşteri kitlesini anlama, pazarlama aksiyonlarını optimize etme, kampanya etkinliğini ve başarısını ölçme ve veriye dayalı kararlar alınmasını sağlama açısından kritik önem taşımaktadır. İşletmelerin karar alma süreçlerinin geliştirilmesinde betimsel, kestirimsel ve öngörücü analitik değerli bilgiler sağlamaktadır. Betimsel analitik geçmiş performansla ilişkin içgörüler sağlarken, tahmine dayalı kestirimsel analitik gelecekteki eğilimleri tahmin etmekte ve öngörücü analitik eylem rehberlik etmektedir (Hauser, 2007; Wedel, 2016). Artımlı modelleme de dahil olmak üzere öngörücü analitiğin ortaya çıkışı, işletmelerin sonuçları en üst düzeye çıkarmak için etkili eylemleri belirlemelerine olanak tanıyarak pazarlama stratejilerinde devrim yaratmaktadır (Devriendt vd., 2018; Gubela ve Lessman, 2021). Bu çalışma iş analitiği alanına girerek pazarlama stratejilerinin optimize edilmesinde öngörücü analitiğin, özellikle de artımlı modellemenin önemine ışık tutmaktadır.

Öngörücü analitik içinde bir yöntem olarak artımlı modelleme, belirli müdahalelerin müşteri davranışları üzerindeki etkisini daha hassas bir şekilde ölçme imkânı sunarak, geleneksel kestirimsel modellerin ötesine geçmekte ve pazarlama uygulamalarının istenen sonuçlar üzerindeki etkisini en üst düzeye çıkarmak için hedefe yönelik bir yaklaşım sunmaktadır (Zhao vd., 2017). Geleneksel tahmin modellerinden farklı olarak artımlı modelleme, belirli bir müdahaleden olumlu etkilenme olasılığı en yüksek olan bireyleri belirlemeye odaklanır. İşletmeler, eylemleri bu bireylere göre uyarlayarak kaynaklarını optimize edebilir ve karar alma süreçlerini iyileştirebilir. Ayrıca, artımlı modellemenin çok yönlülüğü, doğrudan pazarlama kampanyaları, müşteri kaybı yönetimi, içerik hedefleme ve gelir artırma modellemesi dahil olmak üzere çeşitli uygulamaları aracılığıyla sergilenmektedir (Munting, 2020).

Artımlı modellemenin pazarlama uzmanları için pratik sonuçları önemlidir. Pazarlamacılar, artımlı modelleme tekniklerini uygulayarak kaynakları etkin bir şekilde tahsis edebilir, müşteri hedeflemesini geliştirebilir ve kampanya performansını artırabilir (Siegel, 2011). Ayrıca, Qini eğrileri gibi yöntemler aracılığıyla artımlı modellemenin değerlendirilmesi ve optimizasyonu, pazarlamacıların stratejilerine ince ayar yapmalarına ve yatırım getirisini en üst düzeye çıkarmalarına olanak tanır (Karlsson, 2019). Bununla birlikte, belirli iş hedeflerine en uygun yaklaşımı belirlemek için çeşitli algoritmaları test etmenin ve değerlendirmenin önemini vurgulayarak, tek bir artımlı modelleme yönteminin diğerlerinden sürekli olarak daha iyi performans göstermediğini kabul etmek ve buna göre denemeler yaparak sonuçları probleme uygun şekilde değerlendirmek işletmelerin iş sonuçları açısından önemlidir.

İleriye dönük olarak pazarlama uzmanlarının pazarlama çabalarını optimize etmek için güçlü bir araç olarak öngörücü analitiği, özellikle de artımlı modellemeyi benimsemeleri önerilmektedir. Veri toplama ve ön işleme yatırım yapmanın yanı sıra kapsamlı model değerlendirmesi de başarılı bir uygulama için gerekli olacaktır. Buna ek olarak, akademi ve endüstri arasındaki iş birliği, yenilikçi uygulamaların ve gelişmiş metodolojilerin önünü açarak artımlı modellemedeki araştırmaları daha da ilerletebilir. Pazarlamacılar, artımlı modelleme gibi öngörücü analitik tekniklerinden yararlanarak günümüzün dinamik iş dünyasında daha iyi kararlar alabilir ve daha iyi sonuçlar getiren başarılar elde edebilirler.

Literatürde artımlı modellemenin farklı uygulama alanlarında da başarıyla kullanıldığı sınırlı sayıda çalışma mevcuttur. Sağlık sektöründe, hastaların belirli tedavilere vereceği tepkileri öngörmek adına artımlı modelleme teknikleri kullanılmıştır (Robins ve Rotnitzky, 2004). Benzer şekilde, finans sektöründe, müşterilerin kredi risk derecelendirmesi ve politik seçim çalışmalarında da bu modellerden yararlanılmıştır (Siegel, 2011). Ancak farklı sektörlerde ve uygulamalarda artımlı modellemenin etkinliği konusunda daha fazla araştırmaya ihtiyaç vardır. Özellikle hangi modelleme tekniklerinin

hangi koşullar altında daha etkili olduğu ve bu modellerin uygulanmasında karşılaşılan zorluklar gibi konular, literatürde yeterince ele alınmamıştır.

Bu çalışma mevcut literatürdeki boşluğu değerlendirerek artımlı modellemenin pazarlama analitiği alanındaki potansiyelini ve bu potansiyeli değerlendirmek için atılması gereken adımları ortaya koymuştur. Gelecekteki araştırmaların artımlı modellemenin farklı tekniklerinin uygulandığı, sonuçlarının karşılaştırıldığı ve bu modellerin uygulanmasında karşılaşılan zorlukları ele alması önerilmektedir. Ayrıca akademi ve endüstri iş birliği ile artımlı modellemenin etkin kullanımına yönelik yenilikçi uygulamaların geliştirilmesine katkı sağlamayı amaçlayacak veri toplama ve ön işleme süreçlerini optimize etme de önem taşımaktadır. Sonuç olarak, artımlı modelleme, pazarlama analitiği alanında önemli bir potansiyele sahiptir ve bu alandaki araştırmaların derinleştirilmesi, işletmelerin pazarlama stratejilerini daha etkili bir şekilde planlamalarına yardımcı olacaktır.

Hakem Değerlendirmesi / Peer-review:

Dış bağımsız

Externally peer-reviewed

Çıkar Çatışması / Conflict of interests:

Yazarlar çıkar çatışması bildirmemiştir.

The authors have no conflict of interest to declare.

Finansal Destek / Grant Support:

Yazarlar bu çalışma için finansal destek almadığını beyan etmiştir.

The authors declared that this study has received no financial support.

Yazar Katkıları / Author Contributions:

Fikir/Kavram/Tasarım - *Idea/Concept/ Design*: **M.S., Ş.B.**, Analiz ve/veya Yorum - *Analysis and/or Interpretation*: **M.S.**, Kaynak Taraması - *Literature Review*: **M.S, Ş.B.**, Makalenin Yazımı - *Writing the Article*: **M.S, Ş.B.** Eleştirel İnceleme - *Critical Review*: **M.S, Ş.B.** Onay - *Approval*: **M.S, Ş.B.**

Kaynakça / References

- Ajiga, D., Okeleke, P., Folorunsho, S., ve Ezeigweneme, C. (2024). Predictive analytics for market trends using AI: A study in consumer behavior. *International Journal of Engineering Research Updates*. doi: 10.53430/ijeru.2024.7.1.0032.
- Artun, O. ve Levin, D. (2015). *Predictive marketing: Easy ways every marketer can use customer analytics and big data*. New Jersey: John Wiley & Sons.
- Attaran, M. ve Attaran, S. (2018). Opportunities and challenges of implementing predictive analytics for competitive advantage. *International Journal of Business Intelligence Research*, 9(2), 1–26. doi:10.4018/ijbir.2018070101
- Awais, M., Hassan, S. U. ve Ahmed, A. (2021). Leveraging big data for politics: predicting general election of Pakistan using a novel rigged model. *Journal of Ambient Intelligence and Humanized Computing*, 12, 4305–4313 (2021). doi: 10.1007/s12652-019-01378-z
- Baier, D. ve Stöcker, B. (2022). Profit uplift modelling for direct marketing campaigns: approaches and applications for online shops. *Journal of Business Economics*, 92(4), 645-673. doi:10.1007/s11573-021-01068-3
- Börthas, L. ve Sjölander, J.K. (2020). Machine learning based prediction and classification for uplift modelling (Yüksek lisans tezi, KTH Royal Institute of Technology, İsveç) Erişim adresi: <https://www.diva-portal.org/smash/get/diva2:1386196/FULLTEXT01.pdf>
- Bradlow, E. T., Gangwar, M., Kopalle, P. ve Voleti, S. (2017). The role of big data and predictive analytics in retailing. *Journal of Retailing*, 93(1), 79–95. doi:10.1016/j.jretai.2016.12.004

- Cao, Y., Xu, C. ve Gu, H. (2017). Untangle customers' incrementality using uplift modelling with a case study on direct marketing. MWSUG, Paper BF03. Erişim adresi: <https://mwsug.org/proceedings/2017/BF/MWSUG-2017-BF03.pdf>
- Charles, V., Garg, P., Gupta, N. ve Agarwal, M. (Eds.). (2023). Data analytics and business intelligence: Computational frameworks, practices, and applications. Boca Raton: CRC Press.
- Chen, S. (2024). Application and Effectiveness Evaluation of Business Data Analytics in Marketing Strategy. *Frontiers in Business, Economics and Management*. doi: 10.54097/qe8n6k67.
- Cooksey, R. (2020). Descriptive Statistics for Summarising Data. Illustrating Statistical Procedures: Finding Meaning in Quantitative Data, 61 - 139. doi:10.1007/978-981-15-2537-7_5.
- Cote, C. (2021, 2 Kasım). What is prescriptive analytics? 6 examples: HBS Online. [Blog yazısı]. Erişim adresi: <https://online.hbs.edu/blog/post/prescriptive-analytics>
- Çetintemel, U. (2018). Predictive analytics. Liu, L. ve Özsu, M.T. (Ed.), *Encyclopedia of Database Systems*, (s. 2782–2783) içinde. New York: Springer. doi:10.1007/978-1-4614-8265-9_80669
- De Caigny, A., Coussement, K., Verbeke, W., Idbenjra, K. ve Phan, M. (2021). Uplift modelling and its implications for B2B customer churn prediction: A segmentation-based modelling approach. *Industrial Marketing Management*, 99, 28-39. doi: 10.1016/j.indmarman.2021.10.001
- Detienne, K., & Detienne, D. (2017). Neural networks in strategic marketing: exploring the possibilities. *Journal of Strategic Marketing*, 25, 289 - 300. doi: 10.1080/0965254X.2015.1076881.
- Devriendt, F., Moldovan, D. ve Verbeke, W. (2018). A literature survey and experimental evaluation of the state-of-the-art in uplift modelling: A stepping stone toward the development of prescriptive analytics. *Big Data*, 6(1), 13–41. doi:10.1089/big.2017.0104
- Downie, N., & Starry, A. (2019). Descriptive and Inferential Statistics. *Companion Encyclopedia of Psychology*. doi: 10.4135/9781473920446.n5.
- Eckerson, W. W. (2007). Predictive analytics. Extending the Value of Your Data Warehousing Investment. TDWI Best Practices Report, 1, 1-36. Erişim adresi: http://download.101com.com/pub/tdwi/files/pa_report_q107_f.pdf
- Elkan, C. (2013). Predictive analytics and data mining (Vol. 600). San Diego: University of California.
- Engel, Y., Etzion, O. ve Feldman, Z. (2012, Temmuz). A basic model for proactive event-driven computing. *Proceedings of the 6th ACM International Conference on Distributed Event-Based Systems*. doi: 10.1145/2335484.2335496
- Fan, S., Lau, R. Y. K. ve Zhao, J. L. (2015). Demystifying big data analytics for business intelligence through the lens of marketing mix. *Big Data Research*, 2(1), 28–32. doi:10.1016/j.bdr.2015.02.006
- Ferguson, R. (2020). Data-driven decision making via sales analytics: introduction to the special issue. *Journal of Marketing Analytics*. doi: 10.1057/s41270-020-00088-2.
- García, S., Ramírez-Gallego, S., Luengo, J., Benítez, J. M. ve Herrera, F. (2016). Big data pre-processing: methods and prospects. *Big data analytics*, 1, 1-22. doi:10.1186/s41044-016-0014-0.
- Gartner (2017). Forecast Snapshot: Prescriptive Analytics, Worldwide. Erişim adresi: <https://www.gartner.com/en/documents/3698935>
- Goldenberg, D., Albert, J., Bernardi, L. ve Estevez, P. (2020, Eylül). Free lunch! retrospective uplift modelling for dynamic promotions recommendation within roi constraints. *Proceedings of the 14th ACM Conference on Recommender Systems* (pp. 486-491). doi: 10.1145/3383313.3412215
- Goldenberg, D. ve Albert, J. (2022, Eylül). Personalising benefits allocation without spending money: Utilising uplift modelling in a budget constrained setup. *Proceedings of the 16th ACM Conference on Recommender Systems* (pp. 464-465). doi: 10.1145/3523227.3547381
- Gubela, R. M. ve Lessmann, S. (2021). Uplift modelling with value-driven evaluation metrics. *Decision Support Systems*, 150, 113648. doi: 10.1016/j.dss.2021.113648
- Guelman, L. (2014). Uplift: Uplift modelling. R package version 0.3.5. Erişim adresi: <https://cran.r-project.org/package=uplift>.
- Guelman, L., Guillén, M. ve Pérez-Marín, A. M. (2012, Mayıs). Random forests for uplift modelling: an insurance customer retention case. *International conference on modelling and simulation in*

- engineering, economics and management (pp. 123-133). Berlin, Heidelberg: Springer Berlin Heidelberg. doi: 10.1007/978-3-642-30433-0_13
- Guelman, L., Guillen, M. ve Perez-Marin, A.M. (2015). Uplift random forests. *Cybernetics and Systems*, 46 (3-4), 230-248. doi: 10/1080/01969722.2015.1012892
- Gutierrez, P. ve Gerardy, J.Y. (2017). Causal inference and uplift modelling: A review of literature. *International conference on predictive applications and APIs*, 1-13. Cambridge:PMLR.
- Hansotia, B. ve Rukstales, B. (2002). Incremental value modelling. *Journal of Interactive Marketing*, 16(3), 35-46. doi: 10.1002/dir.10035
- Hauser, W. J. (2007). Marketing analytics: the evolution of marketing research in the twenty-first century. *Direct Marketing: An International Journal*, 1(1), 38-54. doi: 10/1108/17505930710734125
- Hu, J. (2023). Customer feature selection from high-dimensional bank direct marketing data for uplift modelling. *Journal of Marketing Analytics*, 11(2), 160-171. doi: 10.1057/s41270-022-00160-z
- Hu, C., & Wen, H. (2024). The Studies Based on the Application of Predictive Analytics Models. *Advances in Economics, Management and Political Sciences*. doi: 10.54254/2754-1169/2024.ga18543.
- Hurwitz, J., Kaufman, M., Bowles, A., Nugent, A., Kobielski, J. G. ve Kowolenko, M. D. (2015). *Cognitive computing and big data analytics* (Vol. 288). Indianapolis: Wiley.
- Hwang, K. ve Chen, M. (2017). *Big-data analytics for cloud, IoT and cognitive computing*. John Wiley & Sons.
- Investopedia (2023). Descriptive analytics: What they are and related terms. Erişim adresi: <https://www.investopedia.com/terms/d/descriptive-analytics.asp#:~:text=Descriptive%20analytics%20is%20an%20important,intelligence%20a%20company%20will%20use>
- James, G., Witten, D., Hastie, T. ve Tibshirani, R. (eds.). (2013). *An introduction to statistical learning: with applications in R*. New York: Springer.
- Jaskowski, M. ve Jaroszewicz, S. (2012, Haziran). Uplift modelling for clinical trial data. *ICML workshop on clinical data analysis* (Vol. 46, pp. 79-95). Erişim adresi: https://people.cs.pitt.edu/~milos/icml_clinicaldata_2012/Papers/Oral_Jaroszewicz_ICML_Clinical_2012.pdf
- Jeyanthi, P.M., Choudhury, T., Hack-Polay, D., Singh, T.P. ve Abujar, S. (2022). *Decision Intelligence Analytics and the Implementation of Strategic Business Management*, Springer. doi: 10.1007/978-3-030-82763-2.
- Kalaian, S., Kasim, R., ve Kasim, N. (2017). A Conceptual and Pragmatic Review of Regression Analysis for Predictive Analytics. , 1761-1776. doi: 10.4018/978-1-5225-0654-6.CH014.
- Kane, K., Lo, S. ve Zheng, J. (2014). Mining for the truly responsive customers and prospects using true-lift modelling: comparison of new and existing methods. *Journal of Marketing Analytics*, 2, 218-238. doi: 10.1057/jma.2014.18
- Karlsson, H. (2019). Uplift modelling: identifying optimal treatment group allocation and whom to contact to maximise return on investment (Yüksek lisans tezi). Erişim adresi: <https://www.diva-portal.org/smash/get/diva2:1328437/FULLTEXT01.pdf>
- Kumar, V. ve Garg, M. L. (2018). Predictive analytics: a review of trends and techniques. *International Journal of Computer Applications*, 182(1), 31-37. Erişim adresi: https://www.researchgate.net/profile/Vaibhav-Kumar-16/publication/326435728_Predictive_Analytics_A_Review_of_Trends_and_Techniques/links/5c484f6692851c22a38a6027/Predictive-Analytics-A-Review-of-Trends-and-Techniques.pdf
- Lee, Y., Chung, S., & Park, J. (2024). Online Review Analysis from a Customer Behavior Observation Perspective for Product Development. *Sustainability*. doi: 10.3390/su16093550.
- Lepeniotti, K., Bousdekis, A., Apostolou, D. ve Mentzas, G. (2020). Prescriptive analytics: Literature review and research challenges. *International Journal of Information Management*, 50, 57-70. doi: 10.1016/j.ijinfomgt.2019.04.003
- Lo, V. S. (2002). The true lift model: a novel data mining approach to response modelling in database marketing. *ACM SIGKDD Explorations Newsletter*, 4(2), 78-86. doi: 10.1145/772862.772872

- Mehendale, P. (2022). AI for Climate Change Mitigation: Predictive Analytics and Sustainable Solutions, *European Journal of Advances in Engineering and Technology*, 9(5), 140-144. Erişim adresi: https://www.researchgate.net/profile/Pushkar-Mehendale/publication/384232328_AI_for_Climate_Change_Mitigation_Predictive_Analytics_and_Sustainable_Solutions/links/66ef30f619c9496b1fb52001/AI-for-Climate-Change-Mitigation-Predictive-Analytics-and-Sustainable-Solutions.pdf
- Munting, M. (2020). An explorative study towards the feasibility of uplift modelling within a direct marketing setting and a web-based setting (Yüksek lisans tezi). Erişim adresi: https://essay.utwente.nl/85430/1/Munting_BA_BMS.pdf
- Murphy, K. (2021). In praise of Table 1: The importance of making better use of descriptive statistics. *Industrial and Organisational Psychology*, 14, 461 - 477. doi: 10.1017/iop.2021.90.
- Nahar, J., Hossain, M. S., Rahman, M. M., ve Hossain, M. A. (2024). Advanced Predictive Analytics For Comprehensive Risk Assessment In Financial Markets: Strategic Applications And Sector-Wide Implications. *Global Mainstream Journal of Business, Economics, Development & Project Management*, 3(4), 39-53. doi: 10.62304/jbedpm.v3i4.148
- Nunes, P., Santos, J., ve Rocha, E. (2023). Challenges in predictive maintenance – A review. *CIRP Journal of Manufacturing Science and Technology*. doi: 10.1016/j.cirpj.2022.11.004.
- Nyberg, O. ve Klami, A. (2023). Exploring uplift modelling with high class imbalance. *Data Mining and Knowledge Discovery* 37: 736–766. doi: 10.1007/s10618-023-00917-9
- Olaya, D., Vásquez, J., Maldonado, S., Miranda, J. ve Verbeke, W. (2020). Uplift modelling for preventing student dropout in higher education. *Decision Support Systems*, 134, 113320. doi: 10.1016/j.dss.2020.113320
- Parmar, A., Sharma, P., ve Agarwal, L. (2023). Predictive analytics for business. *International Journal of Food and Nutritional Sciences*. doi: 10.48047/ijfans/v11/iss7/333.
- Proença, H. M. ve Moraes, F. (2023). Incremental profit per conversion: a response transformation for uplift modelling in e-commerce promotions. *arXiv preprint arXiv:2306.13759*. doi: 10.48550/arXiv.2306.13759
- Puri, S., Sehgal, V. ve Sharma, V. (2013). Customer centricity with predictive analytics in Indian retailing. *International Journal of Intercultural Information Management*, 3(3), 207. doi: 10.1504/ijiim.2013.057738
- Radcliffe, N. (2007). Using control groups to target on predicted lift: Building and assessing uplift model. *Direct Marketing Analytics Journal*, 3, 14-21. Erişim adresi: <https://www.research.ed.ac.uk/en/publications/using-control-groups-to-target-on-predicted-lift-building-and-ass>
- Radcliffe, N. J. ve Simpson, R. (2008). Identifying who can be saved and who will be driven away by retention activity. *Journal of Telecommunications Management*, 1(2). Erişim adresi: <https://openurl.ebsco.com/EPDB%3Aagcd%3A6%3A18830742/detailv2?sid=ebsco%3Aplink%3AAscholar&id=ebsco%3Aagcd%3A33061287&crl=c>
- Radcliffe, N.J. ve Surry, P.D. (2011). Real-world uplift modelling with significance based uplift trees. Edinburgh: Portrait Technical Report TR-2011-1, Stochastic Solutions. Erişim adresi: <https://www.stochasticolutions.com/pdf/sig-based-up-trees.pdf>
- Robins, J. ve Rotnitzky, A. (2004). Estimation of treatment effects in randomised trials with non-compliance and a dichotomous outcome using structural mean models. *Biometrika*, 91(4), 763-783. doi: 10.1093/biomet/91.4.763
- Röbler, J., Tilly, R. ve Schoder, D. (2021). To treat, or not to treat: reducing volatility in uplift modelling through weighted ensembles. 54th Hawaii international conference on system sciences. doi: 10.24251/HICSS.2021.193
- Rzepakowski, P. ve Jaroszewicz, S. (2012). Decision trees for uplift modelling with single and multiple treatments. *Knowledge and Information Systems*, 32, 303–327. doi: 10.1007/s10115-011-0434-0
- Sanisoglu, M., Burnaz, S. ve Kaya, T. (2023). A gateway toward truly responsive customers: Using the uplift modelling to increase the performance of a B2B marketing campaign. *Journal of Marketing Analytics*. doi: 10.1057/s41270-023-00254-2

- Segal, T. (2022). What is prescriptive analytics? how it works and examples. Erişim adresi: <https://www.investopedia.com/terms/p/prescriptive-analytics.asp>
- Sharma, A. K., Sharma, D. M., Purohit, N., Rout, S. K. ve Sharma, S. A. (2022). Analytics techniques: descriptive analytics, predictive analytics, and prescriptive analytics. *Decision Intelligence Analytics and the Implementation of Strategic Business Management*, 1-14. doi: 10.1007/978-3-030-82763-2_1
- Shimizu, A., Togashi, R., Lam, A. ve Van Huynh, N. (2019, Kasım). Uplift modelling for cost effective coupon marketing in c-to-c e-commerce. 2019 IEEE 31st international conference on tools with artificial intelligence (ICTAI) (pp. 1744-1748). doi: 10.1109/ICTAI.2019.00259
- Shmueli, G., Bruce, P. C., Deokar, K. R. ve Patel, N. R. (2023). *Machine learning for business analytics: Concepts, techniques, and applications with analytic solver data mining*. John Wiley & Sons.
- Siegel, E. (2011). Uplift modelling: Predictive analytics can't optimise marketing decisions without it. Prediction Impact white paper sponsored by Pitney Bowes Business Insight. Erişim adresi: <https://www.predictiveanalyticsworld.com/machinelearningtimes/uplift-modelling-predictive-analytics-cant-optimize-marketing-decisions-without-it/5372/>
- Šikšnys, L. ve Pedersen, T. B. (2016). Prescriptive analytics. *Encyclopedia of Database Systems*, 1-2. doi: 10.1007/978-1-4899-7993-3_80624-1
- Sołtys, M., Jaroszewicz, S. ve Rzepakowski, P. (2015). Ensemble methods for uplift modelling. *Data mining and knowledge discovery*, 29, 1531-1559. doi: 10.1007/s10618-014-0383-9
- TikTok. (n.d.). Creator Academy. Erişim adresi: <https://www.tiktok.com/creator-academy>
- Tucci, L. (2021, Aralık). What is predictive analytics? an enterprise guide. [Blog yazısı]. Erişim adresi: <https://www.techtarget.com/searchbusinessanalytics/definition/predictive-analytics>
- Valli, L. (2024). A succinct synopsis of predictive analysis applications in the contemporary period. *International Journal of Multidisciplinary Sciences and Arts*. doi: 10.47709/ijmdsa.v3i4.4625.
- Venkatesh, R., Balasubramanian, C. ve Kaliappan, M. (2019). Development of Big Data Predictive Analytics Model for Disease Prediction using Machine learning Technique. *Journal of Medical Systems*, 43, 272. doi: 10.1007/s10916-019-1398-y
- Wedel, M., Kannan, P. K. ve Tyser, R. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(6), 97-121. doi:10.1509/jm.15.0413
- Wirawan, P. (2023). Leveraging Predictive Analytics in Financing Decision-Making for Comparative Analysis and Optimization. *Advances in Management & Financial Reporting*. doi: 10.60079/amfr.v1i3.209.
- Wolniak, R. (2023). The concept of descriptive analytics. *Scientific Papers of Silesian University of Technology. Organization & Management/Zeszyty Naukowe Politechniki Slaskiej. Seria Organizacji i Zarzadzanie*, (172). doi: 10.29119/1641-3466.2023.172.42
- Zhang, Y., Xu, Z., ve Zhang, Z. (2024). Review on the Use of Data Analysis for Customer Segmentation and Personalization in Marketing. *Advances in Economics, Management and Political Sciences*. doi: 10.54254/2754-1169/97/20231519.
- Zhao, Y., Fang, X. ve Simchi-Levi, D. (2017). Uplift modelling with multiple treatments and general response types. *Proceedings of the 2017 SIAM International Conference on Data Mining*, 588-596. doi: 10.1137/1.9781611974973.66
- Zhao, Y., Zhang, H., Lyu, S., Jiang, R., Gu, J. ve Zhang, G. (2022, Ekim). Multiple instance learning for uplift modelling. *Proceedings of the 31st ACM International Conference on Information & Knowledge Management* (pp. 4727-4731). doi: 10.1145/3511808.355765