



Overbooking models based on personal data analysis

Tuğçe Yavuz^{ID}, Onur Kaya*^{ID}

Department of Industrial Engineering, Eskişehir Technical University, Eskişehir, 26555, Turkey

Highlights:

- Determination of optimal overbooking limit with personal show probabilities
- Formation of prediction models with past booking records
- Probability estimation with Monte Carlo simulation

Keywords:

- Overbooking
- Monte Carlo simulation
- Data mining
- Forecasting algorithms

Article Info:

Research Article
Received: 05.09.2019
Accepted: 27.01.2021

DOI:

10.17341/gazimmfd.615952

Correspondence:

Author: Onur Kaya
e-mail:
onur_kaya@eskisehir.edu.tr
phone:+90 222 321 3550

Graphical/Tabular Abstract

Developing Dynamic Overbooking Models with Personal Data Analysis

Literature review and a review of classical overbooking models

Details of how the proposed dynamic approach can be applied to overbooking models

Prediction of Personal Show Probabilities

Naive Bayes, Logistic Regression and Random Forest algorithms are used for prediction

Monte Carlo Simulation when No-Show Probabilities are Taken on a Personal Basis

Monte Carlo simulation is used to calculate the optimal booking limits when show probability of each customer is taken differently on a personal basis

Determination of the optimal overbooking policy

Finding optimal overbooking limits considering personal no-show probabilities

Numerical experiments show higher gains can be obtained with the dynamic approach

Figure A. The framework of the study

Purpose: The study aims to find the optimal overbooking policy considering personal show probabilities that are estimated through data analysis and machine learning methods, in order to minimize unused capacity and maximize profits.

Theory and Methods:

In this study, dynamic overbooking models have been created, and personal show probabilities have been predicted with machine learning algorithms. Monte Carlo simulation is used to calculate the optimal booking limits when show probability of each customer is taken differently on a personal basis. Using personal no-show probabilities, optimal overbooking policies for dynamic models are determined.

Results:

Experimental studies show that the dynamic overbooking approach can provide up to 35.29% more net gain under different parameter settings in comparison with the classical approach.

Conclusion:

In this study, prediction of personal show probabilities and determination of overbooking policies are addressed together. Optimal overbooking policies are determined and it has been observed that the use of personal show probabilities in the determination of overbooking limits makes companies more competitive compared to the classical approach.



Bireysel verilere dayalı kapasite üzeri rezervasyon modelleri

Tuğçe Yavuz^{ID}, Onur Kaya^{ID}

Eskişehir Teknik Üniversitesi, Endüstri Mühendisliği Bölümü, Eskişehir, 26555, Türkiye

Ö N E Ç İ K A N L A R

- Kapasite üzeri rezervasyon limitinin kişisel olasılıklarla belirlenmesi
- Geçmiş rezervasyon kayıtları ile tahmin modellerinin oluşturulması
- Monte Carlo simülasyonu ile olasılık tahminlemesi

Makale Bilgileri

Araştırma Makalesi
Geliş: 05.09.2019
Kabul: 27.01.2021

DOI:

10.17341/gazimmfd.615952

Anahtar Kelimeler:

Kapasite üzeri rezervasyon,
Monte Carlo simülasyonu,
veri madenciliği,
tahmin algoritmaları

ÖZ

Gelir yönetiminin bir parçası olan kapasite üzeri rezervasyon uygulaması günümüzde, kullanılmayan kapasitenin depolanmadığı birçok sektörde uygulanmaktadır. Rezervasyon yapan müşterilerden bazılarının rezervasyonuna gelmemesi durumunda firmanın karşılaşacağı atıl kapasite maliyetini giderebilmek için kapasitenin üzerinde rezervasyon aldığı bu uygulamanın amacı, atıl kapasiteyi azaltırken kazanç miktarını en büyükmektir. Literatürdeki klasik yaklaşımda, rezervasyon yapan her müşterinin rezervasyonuna gelme olasılığının aynı olduğu kabul edilmektedir. Bu çalışmada farklı olarak, rezervasyon yapan her müşterinin rezervasyonuna gelme olasılığının kişiye bağlı olarak belirlenmesi önerilmiştir. Önerilen yaklaşım için ihtiyaç duyulan kişisel olasılıklar, tahmin algoritmaları kullanılarak, geçmiş rezervasyon bilgilerinden elde edilmiştir. Her müşterinin farklı gelme olasılıklarının olması, farklı sayılarda müşterilerin rezervasyonlarına gelme olasılıklarının klasik yöntemle hesaplanmasını zorlaştırmıştır. Optimum rezervasyon limitini belirlemede kullanılan bu olasılık değerleri Monte Carlo simülasyonu ile elde edilmiştir. Çalışma sonucunda, önerilen dinamik yapıli rezervasyon modelleri ile klasik yaklaşıma oranla çok daha yüksek kazançlar elde edilebileceği görülmüştür.

Overbooking models based on personal data analysis

H I G H L I G H T S

- Determination of overbooking limit with personal show probabilities
- Formation of prediction models with past booking records
- Probability estimation with Monte Carlo simulation

Article Info

Research Article
Received: 05.09.2019
Accepted: 27.01.2021

DOI:

10.17341/gazimmfd.615952

Keywords:

Overbooking,
Monte Carlo simulation,
data mining,
forecasting algorithms

ABSTRACT

Overbooking policy, which is part of revenue management, is applied in many sectors today where unused capacity cannot be stored. The purpose of this application, in which the company receives reservation over the capacity in order to cover the spoilage cost it will encounter because of no-show customers, is to maximize the amount of earnings while reducing spoilage costs. In the classical approach, the show probability of each customer is assumed to be the same. In this study, unlike the classical approach, the show probability of each reservation is estimated on a personal basis. Personal probabilities needed for the suggested approach are obtained from historical booking information using forecasting algorithms. The fact that each customer has different show probability makes it difficult to calculate the total number of no-shows in the classical way. For this reason, Monte Carlo simulation is used to calculate the optimal booking limit when show probability of each customer is taken differently on a personal basis. As a result of the study, it is seen that with the proposed dynamic models, higher gains can be achieved compared to the classical approach.

1. GİRİŞ (INTRODUCTION)

Gelir yönetimi, günümüzde birçok sektörde firmaların gelir ve karlılıklarını arttırmak amacıyla geliştirdikleri ve kullandıkları farklı uygulamaları kapsayan bir kavramdır. Gelir yönetimi genelde üç başlık altında incelenmektedir: kapasite yönetimi, dinamik fiyatlandırma ve kapasite üzeri rezervasyon [1]. Kapasite üzeri rezervasyon uygulaması, gelir yönetiminin esas amacı olan kar maksimizasyonunu kapasitenin etkin kullanımı ile sağlamaya çalışmaktadır. Bu amaçla, bir rezervasyonun satışa dönüşme riskine karşılık müşteri hareketlerinin tahmini doğrultusunda kapasitenin üzerinde rezervasyon alınmasına izin verilmektedir. Kapasite üzeri rezervasyon uygulamasının literatürde geçen klasik yaklaşımında, rezervasyon yapan her müşterinin sisteme gelme olasılığı sabit bir değer olarak kabul edilmektedir. Dolayısıyla, klasik yaklaşımda müşterilerin rezervasyonlarına gelme olasılıkları kişilerden bağımsız olarak ele alınmaktadır. Klasik yaklaşımdaki bu varsayımın aksine, rezervasyon yapan her müşterinin kişisel özelliklerine bağlı olarak sisteme gelme olasılıklarının farklı olmasının daha gerçekçi olduğu düşünülmektedir. Büyük verilerin işlenerek faydalı bilgilere ve bağlantılara erişimi mümkün kılan günümüz teknolojisi ile geçmiş rezervasyon kayıtlarının içerdiği müşteri bilgileri kullanılarak, her müşterinin rezervasyonuna gelme olasılığını tahmin etmek de mümkündür. Klasik yaklaşımdaki varsayımın gerçekçi olmaması ve kişisel olasılıkların geçmiş veriler yardımıyla tahmininin mümkün olması bu çalışmanın çıkış noktası olmuştur. Çalışmada, kapasite üzeri rezervasyon limitinin kişisel olasılıklar kullanılarak belirlenmesi ve böylece elde edilen kazancın artırılması amaçlanmıştır.

Çalışmada farklı varsayımlara sahip 3 farklı rezervasyon sistemi incelenmiş ve bu sistemlerde kapasite üzeri rezervasyonun nasıl uygulanacağı açıklanmıştır. Önerilen dinamik rezervasyon modellerinin girdileri olan kişisel olasılıkların geçmiş veriler kullanılarak tahmin edilmesi için 3 farklı makine öğrenmesi algoritması önerilmiştir. Tahmin algoritmalarıyla belirlenen kişisel olasılıklar ile Monte Carlo simülasyonu uygulanmış ve simülasyon çıktıları kullanılarak optimum rezervasyon limiti elde edilmiştir. Önerilen bu yaklaşımla, müşterilerin rezervasyonlarına gelme olasılıklarının aynı ve sabit olduğu klasik yaklaşıma oranla daha başarılı sonuçlar elde edilebildiği görülmüştür. Çalışmanın devamında, literatürde bu alanda yapılmış çalışmaların incelendiği “Literatür Taraması” kısmından sonra çifte rezervasyon uygulaması için klasik yaklaşımın ve önerilen dinamik modellerin açıklandığı, önerilen dinamik modellerde kullanılan veri madenciliği yöntemleri ile Monte Carlo simülasyonunun çalışmada neden ve nasıl kullanıldığının anlatıldığı “Yöntemler” kısmı yer almaktadır. Bu kısma kadar teorik yapısı anlatılan çalışmanın MATLAB (R2015a) programı aracılığıyla gerçekleştirilen uygulaması ve dinamik modelin klasik modele karşı başarısını ölçmek için yapılan karşılaştırma testi “Uygulama” bölümünde anlatılmıştır. Son olarak “Sonuçlar ve Tartışmalar” kısmına yer verilmiştir.

2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Gelir yönetimi kapsamında, farklı hizmet sektörlerinde gerçekleştirilmiş çeşitli kapasite üzeri rezervasyon uygulaması çalışmaları bulunmaktadır. Coughlan [2] çalışmasında, farklı sınıf ücretleri olan bir uçuş için kabin seviyesinde bir kapasite üzeri rezervasyon modeli sunulmuştur. Feng ve Xiao [3] tarafından tek güzergahlı uçuşlarda koltuk envanteri ve çifte rezervasyon politikalarını birleştiren bir sürekli zamanlı model sunulmuştur. Mookherjee ve Friesz [4] tarafından yapılan çalışmada, literatürdeki çalışmalardan farklı olarak, gelir yönetiminin birer parçası olan fiyatlandırma, kaynak tahsisi ve kapasite üzeri rezervasyon uygulamalarını belirsiz talep durumunda birlikte ele alan genel bir model analiz edilmiştir. Çalışmada ele alınan problem için çözüm önerileri sunulmuştur. Erdelyi ve Topaloğlu [5] çalışmasında, bir havayolu ağı üzerinde kapasite tahsisi ve kapasite üzeri rezervasyon kararlarını bir arada ele alan bir gelir yönetimi modeli sunulmuştur. Çalışmada, kapasite tahsisi ve kapasite üzeri rezervasyon problemi dinamik programlama ile modellenmiş ve çözüm yaklaşımları sunulmuştur. Topaloğlu vd. [6] tarafından yapılan çalışmada, net geliri en büyükmek amacıyla birden fazla ücret sınıflı, tek güzergahlı bir uçuş için çifte rezervasyon ve kapasite kontrol problemi incelenmiştir. Aydın vd. [7] tarafından tek güzergahlı uçuşlarda optimum kapasite üzeri rezervasyon limitini belirlemek için statik ve dinamik yapıları farklı rezervasyon modelleri geliştirilmiştir. Huang vd. [8] çalışmasında, gelir yönetiminin parçası olan kapasite yönetimi ve kapasite üzeri rezervasyon uygulaması bir arada ele alınmıştır. Aynı güzergahta uçan farklı kalkış saatli ve birden fazla ücret sınıfı olan uçuşlar için koltuk envanteri kontrolü yapan ve kapasite üzeri optimum rezervasyon limitini belirleyen dinamik bir yaklaşım önerilmiştir. Phumchusri ve Maneesophon [9] tarafından kapasite üzeri rezervasyonun uygulama alanlarından bir diğeri olan otel işletmeciliği üzerine çalışılmıştır. Çalışmada, bir ve iki tip oda içeren oteller için optimum kapasite üzeri rezervasyon limitini belirlemek amacıyla müşterilerin gelmeme ve geç iptal olasılıklarını dikkate alan çifte rezervasyon uygulamasının matematiksel modelleri oluşturulmuştur. Yine otel işletmeciliği alanında Ivanov [10] tarafından yapılan çalışmada, üç farklı oda tipi olan bir otelde çeşitli varsayımlar altında kapasite üzeri optimal rezervasyon limitlerini belirlemek için bir matematiksel model geliştirilmiştir. Soomboon ve Amaruchkul [11] çalışmasında, bir uçuş için rezervasyon kapasitesinin ve kapasite üzeri rezervasyon limitinin eş zamanlı olarak belirlenmesini sağlayan bir matematiksel model oluşturulmuştur.

Optimal kapasite üzeri rezervasyon limitinin belirlenmesindeki en önemli adımlardan biri, rezervasyonların gerçekleşmeme ve iptal olasılıklarının doğru tahminlenmesidir. Son zamanlarda, bu olasılıkların tahmininde makine öğrenmesi algoritmaları sıklıkla kullanılmaktadır. Hueglin ve Vannotti [12] tarafından havayolu endüstrisinde kapasite üzeri rezervasyon

konusunda yapılan çalışmada, yolcuların rezervasyonlarına gelme olasılıklarını tahmin etmek için Lojistik Regresyon ve Karar Ağacı algoritmaları kullanılmıştır. Lawrence vd. [13] çalışmasında, iki farklı sınıf içeren bir uçuşun yolcularının rezervasyonlarına gelme olasılıklarının yolcu bazında tahmini için C4.5, ProbE ve APMR algoritmaları kullanılmıştır. Garrow ve Koppelman [14] tarafından yapılan çalışmada, yolcu ve güzergah bilgileri kullanılarak rezervasyonların nasıl sonuçlanacağı (gelme ya da gelmeme) ve hizmet alamayan yolcuların bir sonraki uçuş için davranışları (bekleme ya da bekleme) tahmin edilmiştir. Bu tahminler için Multinomial Logit modelleri kullanılmıştır. Zenkert [15] yüksek lisans tezinde, havayolu endüstrisinde yolcuların rezervasyonlarına gelme olasılıklarının tahmini için geçmiş rezervasyon bilgileri kullanılarak 3 farklı algoritma (Gradyan Artırma, Karar Ağacı, Yapay Sinir Ağları) yardımıyla tahmin modelleri oluşturulmuştur.

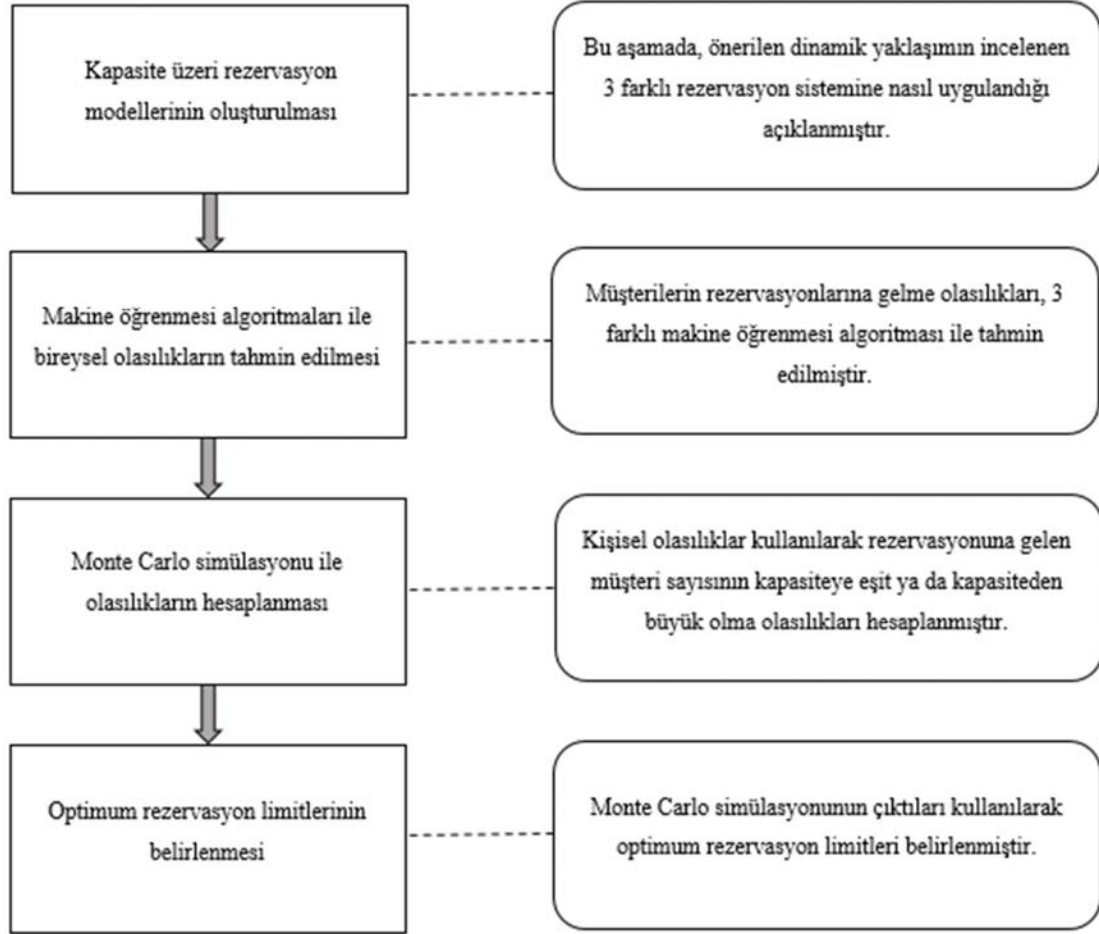
Literatürde, kapasite üzeri rezervasyon limitinin optimum değerini belirlemeye yönelik yapılmış çalışmaların dışında, kapasite üzeri rezervasyon uygulamasının başarısını arttırmak için müşteri hareketlerinin tahminlerini iyileştirmeye yönelik yapılmış çok sayıda çalışma da mevcuttur. Bu çalışmada, literatürdeki çalışmalardan farklı

olarak müşteri hareketlerinin tahmini ve optimum rezervasyon limitinin belirlenmesi amaçları bir arada ele alınmıştır. Müşteri hareketlerinin tahmininde kişisel veriler kullanan ve tahmin edilen müşteri hareketleri doğrultusunda optimum rezervasyon limitini belirlemeyi amaçlayan kapasite üzeri rezervasyon modelleri ve bu modellerin en iyi çözümleri sunulmuştur.

3. YÖNTEMLER (METHODS)

İncelenen rezervasyon sistemleri için önerilen dinamik rezervasyon modelleri ve bu modelleri uygulamak için kullanılan yöntemler bu başlık altında açıklanmıştır. Şekil 1'de çalışmanın metodolojisi özetlenmiştir.

Bu çalışmada, geçmiş rezervasyon bilgileri kullanılarak yeni rezervasyonlar için tahminler yapılmakta ve bu tahminler kullanılarak optimum rezervasyon limitleri belirlenmektedir. Kabul edilmiş rezervasyonların kaç tanesinin gelmeyeceğine yönelik olasılık tahminleri yapılarak, kapasite üzeri yeni rezervasyon taleplerinin kabul edilip edilmeyeceğine karar verilmektedir. Oluşturulan modellerde bir kişinin rezervasyonuna gelme olasılığının tahmini için, sadece o kişinin geçmiş verileri değil, geçmişte yapılan farklı rezervasyonlardaki farklı kişilerin özellikleri ve



Şekil 1. Çalışmanın metodolojisi (Methodology of the study)

rezervasyonlarına gelip gelmeme durumları kullanılmaktadır. Rezervasyon yaptırmak isteyen kişilerin özellikleri gözetilerek tüm geçmiş veriler doğrultusunda bu kişilerin rezervasyonlarına gelip gelmeyeceğine yönelik tahminler yapılmakta ve bu tahminler doğrultusunda yeni rezervasyon taleplerinin kabul edilip edilmemesi gerektiğine karar verilmektedir.

3.1. Kapasite Üzeri Rezervasyon Modelleri (Overbooking Models)

Kapasite üzeri rezervasyon modellerini açıklamada kullanılacak notasyonlar aşağıda verilmiştir:

- b : rezervasyon limiti
- C : mevcut sistem kapasitesi
- p : kişi başı ödenen hizmet ücreti
- t : bir kişiyi reddetme maliyeti
- a : reddedilen kişiye ödenen miktar (geri ödenen hizmet ücreti hariç tutar) ($t-p$)
- D : toplam rezervasyon talebi
- $s(b)$: rezervasyon limiti b iken rezervasyonuna gelen müşteri sayısı
- ρ : rezervasyon yapan müşterinin sisteme gelme olasılığı
- R : net gelir

Kapasite üzeri rezervasyon için belirlenecek limit değerinin, elde edilen net kazancı en büyükleme istenmektedir. Bu nedenle, rezervasyon politikasının amaç fonksiyonu net kazancın maksimizasyonu şeklinde ifade edilmektedir. Net kazanç değerini hesaplamak için önce toplam kazanç ile toplam maliyet değerlerini hesaplamak gerekmektedir. Rezervasyon limiti b iken s kadar kişinin sisteme gelmesi durumunda, gelen müşterilerden elde edilecek toplam kazanç $p(\min(s(b), C))$ ile hesaplanmaktadır. Sisteme gelen kişi sayısının kapasiteden büyük olması halinde, gelen müşteri sayısı ile kapasite arasındaki fark kadar kişiye hizmeti reddetme maliyeti olan a tutarı ödenmektedir. Bu durumda, kapasitenin üzerinde gelen kişilere ödenen toplam hizmeti reddetme maliyeti $a(s(b) - C)^+$ şeklinde hesaplanmaktadır. $(x)^+$ ifadesi, x ile 0 değerlerinden büyük olanını ifade etmektedir. Elde edilen toplam kazanç ile katlanılan toplam maliyet arasındaki fark alınarak, yapılan b kadar rezervasyondan elde edilen net kazanç hesaplanmaktadır. Eş. 1'de verilen net kazancın beklenen değerinin en büyükleme, kapasite üzeri rezervasyon uygulamasının amaç fonksiyonunu ifade etmektedir.

$$\text{Max } E [p(\min(s(b), C)) - a(s(b) - C)^+] \quad (1)$$

Hesaplama kolaylığı sağlamak için Eş. 1'deki $\min(s(b), C)$ ifadesi yerine $C - (C - s(b))^+$ ifadesini yazmak mümkündür. Bu durumda denklem;

$$\text{Max } E [pC - p(C - s(b))^+ - a(s(b) - C)^+] \quad (2)$$

şeklinde olmaktadır. Eş. 2'deki pC ifadesi sabittir. Bu sabit denklemden çıkarıldığında rezervasyon modelinin amaç fonksiyonu:

$$\text{Min } E [p(C - s(b))^+ + a(s(b) - C)^+] \quad (3)$$

şeklini almaktadır. Eş. 3'te minimizasyon problemi olarak tanımlanan amaç fonksiyonu, rezervasyonuna gelecek kişi sayısının belirsizliğinden kaynaklanan maliyetin en küçüklenmesi amacını ifade etmektedir.

Kapasite üzeri rezervasyon modelinin kazancı en büyükleme olan amacına ulaşmak için atıl kapasiteyi en küçükleme gerekmektedir. Atıl kapasite, gerçekleşmeyen rezervasyonların bir sonucudur ve firma için bir maliyettir. Bu maliyet gerçekleşecek rezervasyon sayısının bilinmemesinden kaynaklanmaktadır. Alınan rezervasyonların sonuçlarının belirsizliğinin neden olduğu bu maliyet çalışmada 'belirsizlik maliyeti' olarak adlandırılmıştır ve çalışmada kapasite üzeri rezervasyon uygulamasının amaç fonksiyonu, belirsizlik maliyetinin minimizasyonu olarak Eş. 3'te verildiği şekliyle kullanılmıştır.

Amaç fonksiyonunu bu şekilde belirledikten sonraki adım rezervasyon limitinin belirlenmesidir. Rezervasyon limiti, kapasite kadar rezervasyonun üzerine ek rezervasyonlarla birlikte izin verilen toplam rezervasyon sayısıdır. Burada belirlenmesi gereken ek rezervasyon sayısı olduğu için, başlangıçta b değeri sistemin kapasitesine eşit kabul edilmekte ($b = C$) ve optimum değerine ulaşılan kadar b değeri birer birer arttırılmaktadır. Ulaşılan optimum b değerinin elde edilen kazancı en büyükleme istenmektedir.


Kapasitenin üzerinde alınacak her rezervasyondan, atıl kapasiteyi azaltarak firmaya kazanç sağlaması beklenmektedir. Bu nedenle rezervasyon limitinde yapılan her artış için ($b \rightarrow b+1$) marjinal fayda ve maliyet değerleri hesaplanmakta ve ikisi arasındaki ilişkiye bakılmaktadır. Eğer $b+1$ için marjinal maliyet değeri fayda değerinden daha yüksekse rezervasyon limiti arttırılmamakta ve b olarak bırakılmaktadır. Eğer limitteki bir birimlik artışın marjinal faydası daha yüksekse yeni rezervasyon limiti ($b = b+1$) olarak belirlenmektedir. Rezervasyon limiti b iken bu değer $b+1$ 'e çıkartıldığında açılan 1 birimlik fazla rezervasyon için karşılaşılması olası durumlar ve bu durumların net kazanç üzerindeki etkisi Şekil 2'deki karar ağacında analiz edilmiştir.

Kapasite üzeri rezervasyon limitinin optimum değerini belirlerken, her limit arttırımında ($b \rightarrow b+1$), Şekil 2'de verilen marjinal etki değerleri kullanılarak marjinal fayda ve maliyet değerleri hesaplanmalıdır. Eş. 4 ve Eş. 5'te verilen marjinal fayda ve maliyet hesaplamalarında marjinal etkisi 0 olan durumlar dikkate alınmamıştır.

$$\text{Marjinal fayda} = P(D > b)P(s(b) < C | D > b)\rho p \quad (4)$$

$$\text{Marjinal maliyet} = P(D > b)P(s(b) \geq C | D > b)\rho(t - p) \quad (5)$$

Eş. 4 ve Eş. 5'i kullanarak, b değerini $b+1$ 'e çıkarma kararı alınırken sağlanması gereken koşulu Eş. 6'daki gibi ifade etmek mümkündür:



Şekil 2. Rezervasyon limitindeki artışın marjinal etki analizi (Marginal impact analysis of the increase in reservation limit)

$$\frac{P(D > b)P(s(b) < C|D > b)\rho p}{P(D > b)P(s(b) \geq C|D > b)\rho(t - p)} \geq \quad (6)$$

Eş. 6’da verilen eşitsizlik düzenlenerek b değerini $b+1$ ’e çıkartmak için sağlanması gereken koşulun son hali Eş. 7’de verilmiştir.

$$P(s(b) \geq C|D > b) \leq \frac{p}{t} \quad (7)$$

Eş. 7’deki koşul sağlanıyorsa b değeri 1 artırılır. Aksi halde rezervasyon limitinin artırılması kazançtan daha fazla maliyete neden olacağı için rezervasyon limiti b olarak kalır. Rezervasyon limitinin b ’den $b+1$ ’e çıkartılması durumunda Eş. 7’deki koşul sağlanmıyorsa, optimum rezervasyon limitinin b ’nin mevcut değeri olduğu anlaşılmaktadır.

Rezervasyon limitinin Eş. 7 yardımıyla belirlenebilmesi için, ilgili b değeri kadar rezervasyon içerisinde gelen müşteri sayısının kapasiteden büyük ya da kapasiteye eşit olma olasılığının hesaplanması gerekmektedir. Her müşterinin rezervasyonuna gelme olasılığı aynı kabul edildiğinde, yapılan b kadar rezervasyon içerisinde s kadar müşterinin rezervasyonuna gelmesi olayı binom dağılımı göstermektedir. Bu nedenle klasik yaklaşımda, gelen müşteri sayısının kapasiteden büyük veya kapasiteye eşit olması olasılığının hesaplanmasında genellikle binom dağılımı kullanılmaktadır. Bu olasılık Eş. 8’deki gibi hesaplanmaktadır:

$$P(s(b) \geq C|D > b) = \sum_{s=C}^b \binom{b}{s} \rho^s (1 - \rho)^{(b - s)} \quad (8)$$

Rezervasyon limiti belirlendikten sonra bu limit değeri için beklenen getiri miktarı Eş. 9 kullanılarak hesaplanabilir:

$$E[R|b] = pE[s(b)] - tE[(s(b) - C)^+] \quad (9)$$

Eş. 9’deki $E[s(b)]$ ifadesi b kadar rezervasyon içinden gerçekleşen rezervasyon sayısının beklenen değerini,

$E[(s(b) - C)^+]$ ifadesi de kapasite üzerinde gelen kişi sayısının beklenen değerini ifade etmektedir. Beklenen getiri değeri, sisteme gelen herkesten hizmet ücreti alındığı ve reddedilen müşterilere hizmet ücreti ile birlikte reddetme maliyetinin de ödendiği varsayımı ile hesaplanmaktadır. Yukarıda anlatılan genel rezervasyon uygulamasında (rezervasyon modeli-1), rezervasyonuna gelmeyen müşterilerin herhangi bir ceza ödemediği ve rezervasyonsuz müşterilerin sisteme gelmediği veya sisteme kabul edilmediği varsayılmaktadır. Aşağıdaki 3.1.1. ve 3.1.2. alt bölümlerinde ise, bu varsayımlar kaldırılarak, yukarıda açıklanan modelin daha geliştirilmiş iki farklı versiyonu ele alınmaktadır. Bu rezervasyon modellerinin amaç fonksiyonları, optimum rezervasyon limiti için eşik değerleri ve beklenen getiri miktarlarının hesaplanma şekilleri aşağıda detaylı olarak açıklanmaktadır.

3.1.1. Rezervasyonuna gelmeyen müşterilerin ceza ödemediği sistem (Overbooking with no-show penalty)

Bu sistemde rezervasyonuna gelmeyen müşterilerin c kadar ceza ödemediği göz önüne alınmış ve bu şekilde oluşturulan kapasite üzeri rezervasyon modeli, rezervasyon modeli-2 olarak isimlendirilmiştir. Bu modelde rezervasyon limiti b iken s kadar kişinin rezervasyonuna gelmesi halinde, rezervasyonuna gelen müşterilerden elde edilen kazanç miktarı $p(\min(s(b), C))$ şeklinde hesaplanmaktadır. Rezervasyonuna gelmeyen $b-s(b)$ kadar kişinin ödeyeceği toplam ceza miktarı ise $c(b - s(b))$ kadardır. Bu durumda b kadar rezervasyondan s kadar kişi geldiğinde firmanın toplam kazancı $p(\min(s(b), C)) + c(b - s(b))$ olmaktadır. Gelen kişi sayısının kapasiteden fazla olması halinde firmanın katlanacağı maliyet de $a(s(b) - C)^+$ şeklinde hesaplanmaktadır. Hesaplanan toplam kazanç ile toplam maliyet arasındaki fark, firmanın net kazancını vermektedir. Net kazancı en büyükmek amacı taşıyan rezervasyon modeli-2’nin amaç fonksiyonu Eş. 10’da verilmiştir.

$$\text{Max } E [p(\min(s(b), C)) + c(\min(D, b) - s(b)) - a(s(b) - C)^+] \quad (10)$$

Eş. 10’da verilen amaç fonksiyonu, bir önceki modelde olduğu gibi düzenlendiğinde rezervasyon modeli-2 için kapasite üzeri rezervasyon uygulamasının amaç fonksiyonu Eş. 11’deki hali almaktadır.

$$\text{Min } E [p(C - s(b))^+ - c(\min(D, b) - s(b)) + a(s(b) - C)^+] \quad (11)$$

Eş. 11’de verilen amaç fonksiyonu, belirsizlik maliyetinin minimizasyonunu ifade etmektedir. Ancak bu modelde amaç fonksiyonundaki $c(b - s(b))$ ifadesi, belirsizlik maliyetinin negatif çıkmasını mümkün kılmaktadır. Gerçekleşen kazancın maksimum kazanç değerinden uzaklığını ifade eden belirsizlik maliyeti, gerçekleşmeyen rezervasyonlardan elde edilen kazancın etkisiyle negatif çıkabilmektedir. Dolayısıyla bu model için hesaplanan belirsizlik maliyetlerindeki negatiflik, varsa, biçimseldir.

Rezervasyon limiti 1 birim arttırıldığında karşılaşılabilecek durumların marjinal etkileri Şekil 3’te verilmiştir.

Şekil 3’teki karar ağacı yardımıyla rezervasyon limitinin 1 birim arttırılmasının marjinal faydası ve marjinal maliyeti Eş. 12 ve Eş. 13 kullanılarak hesaplanmaktadır:

$$\text{Marjinal fayda} = P(D > b)[P(s(b) < C|D > b)(\rho p + (1 - \rho)c) + P(s(b) \geq C|D > b)(1 - \rho)c] \quad (12)$$

$$\text{Marjinal maliyet} = P(D > b)P(s(b) \geq C|D > b)\rho(t - p) \quad (13)$$

Eş. 13 kullanılarak hesaplanan rezervasyon limitini b ’den $b+1$ ’e çıkartmanın marjinal maliyeti, Eş. 12 ile hesaplanan marjinal faydadan küçükse, rezervasyon limiti 1 arttırılır. Rezervasyon limitini arttırmada kontrol edilmesi gereken bu koşul düzenlendiğinde Eş. 14 elde edilmektedir.

$$P(s(b) \geq C|D > b) \leq \frac{p-c}{t} + \frac{c}{\rho t} \quad (14)$$


Eğer Eş. 14’teki koşul sağlanıyorsa, rezervasyon limiti $b+1$ ’e çıkartılmalıdır, aksi halde rezervasyon limiti b olarak bırakılmalıdır. Eş. 15’teki ρ parametresinin değeri, klasik yaklaşımda sabitken, önerilen dinamik model için değişkendir. Bu nedenle rezervasyon modeli-2 için önerilen dinamik modelin kullanımında ρ parametresi, rezervasyon talebi değerlendirilen müşterinin rezervasyonuna gelme olasılığını ifade etmektedir. Rezervasyon limiti b iken gelen herhangi bir rezervasyon talebi Eş. 14’teki koşulu sağlamazken, daha sonra gelen herhangi bir talebin bu koşulu sağlaması mümkündür. Bu durumda, koşulu sağlamayan ilk $b+1$ ’e ulaşıldığında b değeri optimum rezervasyon limiti olmaktan çıkmaktadır. Daha sonra gelen rezervasyonlar değerlendirilmeye devam edilebilir. Ancak bu şekilde gelen rezervasyon taleplerinin değerlendirilmesi belirsizlik içeren bir süreç olduğu ve herhangi bir sınırlama içermediği için bu çalışmada koşulu sağlamayan ilk $b+1$ değerine ulaşıldığında durulmuş ve rezervasyon limiti daha fazla arttırılmamıştır. Rezervasyon modeli-2 için beklenen getiri miktarı Eş. 15’de verilmiştir.

$$E[R|b] = pE[s(b)] + cE[\min(D, b) - s(b)] - tE[(s(b) - C)^+] \quad (15)$$

Eşitlikteki $E[\min(D, b) - s(b)]$ ifadesi, rezervasyonuna gelmeyen kişi sayısının beklenen değeridir. Klasik modelden farklı olarak beklenen getiri hesaplamasına, rezervasyonuna gelmeyen müşterilerin ödeyeceği ceza miktarının beklenen değeri $cE[\min(D, b) - s(b)]$ de eklenmiştir.

3.1.2. Rezervasyonsuz müşterilerin kabul edildiği sistem (Overbooking with walk-up customers)

Çalışmada ele alınan bir diğer model, rezervasyonsuz gelen müşterilerin de sisteme kabul edildiği durumda uygulanan kapasite üzeri rezervasyon modelidir. Bu model, çalışmada



Şekil 3. Rezervasyon modeli-2 için marjinal etki analizi (Marginal impact analysis for reservation model-2)

rezervasyon modeli-3 olarak isimlendirilmiştir. Böyle bir sistemde, gerçekleşmeyen rezervasyonlardan kaynaklanan atıl kapasite miktarı, sadece yapılan fazla rezervasyonla değil rezervasyonsuz gelen müşterilere verilen hizmet ile de azaltılabilmektedir. Bu nedenle, rezervasyon limitini belirlerken olası rezervasyonsuz müşterileri de göz önünde bulunduran bir rezervasyon modeli oluşturulmuştur. Rezervasyon yapan b kadar kişi içerisinde s kadar kişinin rezervasyonuna gelmesi halinde firmanın kazanacağı toplam miktar $p(\min(s(b), C))$ kadardır. Atıl kapasite miktarında rezervasyonsuz müşteriye hizmet verilebileceği için rezervasyonsuz gelen müşterilerden elde edilen kazanç ise $(\min(w, C - s(b)))p_w$ ile hesaplanmaktadır. Burada w notasyonu, rezervasyonsuz gelen müşteri sayısını, p_w notasyonu ise rezervasyonsuz gelen bir müşterinin ödeyeceği hizmet ücretini ifade etmektedir. Bu durumda rezervasyon modeli-3 için toplam kazanç $p(\min(s(b), C)) + (\min(w, C - s(b)))p_w$ şeklinde hesaplanmaktadır. Rezervasyon limiti b iken toplam maliyet ise $a(s(b) - C)^+$ kadar olacaktır. Rezervasyon modeli-3 için bu şekilde hesaplanan toplam kazanç ile toplam maliyet arasındaki farkın maksimizasyonu, modelin amaç fonksiyonunu ifade etmektedir (Eş. 16).

Max E
 $[p(\min(s(b), C)) + (\min(w, C - s(b)))p_w - a(s(b) - C)^+]$ (16)

Eş. 16'da verilen amaç fonksiyonu önceki modelde olduğu gibi düzenlendiğinde, kapasite üzeri rezervasyon uygulamasının rezervasyon modeli-3 için amaç fonksiyonu Eş. 17'deki hali almaktadır:

Min E
 $[p(C - s(b))^+ - (\min(w, C - s(b)))p_w + a(s(b) - C)^+]$ (17)

Bu modelin de amacı rezervasyon modeli-1 ve rezervasyon modeli-2'de olduğu gibi belirsizlik maliyetinin en küçüklenmesidir.

Rezervasyon limiti b 'nin $b+1$ 'e çıkartılması durumunda karşılaşılabilecek durumlar ve bu durumların rezervasyon modeli-3 için marjinal etkileri Şekil 4'te analiz edilmiştir.

Yapılan bu analizdeki marjinal etkiler kullanılarak rezervasyon modeli-3 için kapasite üzeri rezervasyon limitindeki 1 birimlik artışın marjinal faydası ve marjinal maliyeti Eş. 18 ve Eş. 19 kullanılarak hesaplanmaktadır:

Marjinal fayda = $P(D > b)P(s(b) < C | D > b)\rho$
 $[(p - p_w(P(w \geq C - s(b) | D > b, s(b) < C)))]$ (18)

Marjinal maliyet = $P(D > b)P(s(b) \geq C | D > b)\rho(p - t)$ (19)

Rezervasyon modeli-3 için marjinal fayda ve marjinal maliyet kullanılarak oluşturulan rezervasyon limitini artırma koşulu Eş. 20'de verilmiştir.


$$\frac{P(s(b) \geq C | D > b) \leq p - p_w [P(w \geq C - s(b) | D > b, s(b) < C)]}{t}$$
 (20)

Eş. 20'de verilen eşitsizlikteki $P(w \geq C - s(b) | D > b, s(b) < C)$ olasılığı, $s(b)$ 'nin alabileceği tüm değerler için rezervasyonsuz gelecek hizmet alabilecek sayıda müşterinin sisteme gelme olasılıklarının toplamıdır. Rezervasyonsuz bir müşterinin hizmet alabilmesi için en az 1 kişilik atıl kapasite olması gerekmektedir. Bu nedenle bu olasılığın hesabında $s(b)$, 0'dan $C-1$ 'e kadar değer alabilmektedir (Eş. 21).

$$P(w \geq C - s(b) | D > b, s(b) < C) = \sum_{x=0}^{C-1} [P(w \geq C - x)P(s(b) = x)]$$
 (21)

Eş. 21'de verilen $P(w \geq C - s(b) | D > b, s(b) < C)$ olasılığı, Eş. 20'de yerine yazıldığında limit artırımında kontrol edilmesi gereken koşul Eş. 22'deki hali almaktadır:

$$P(s(b) \geq C | D > b) \leq \frac{p - p_w \sum_{x=0}^{C-1} [P(w \geq C - x)P(s(b) = x)]}{t}$$
 (22)



Şekil 4. Rezervasyon modeli-3 için marjinal etki analizi (Marginal impact analysis for reservation model-3)

Bu çalışmadaki sayısal denemelerde, rezervasyonsuz müşterilerin sisteme gelişlerinin Poisson (λ) dağılımına uyduğu varsayılmış ve gelme olasılıkları hesaplanırken bu dağılımdan yararlanılmıştır. Eş. 22'deki $P(w \geq C-x)$ olasılığı, Poisson dağılımının olasılık fonksiyonu kullanılarak hesaplanmıştır. Bu hesaplamalarda λ parametresi bir gün içinde rezervasyonsuz gelen ortalama kişi sayısını ifade etmektedir.

Son olarak rezervasyon modeli-3 için beklenen getiri hesabı Eş. 23'teki gibi formüle edilebilir:

$$E[R|b] = pE[s(b)] + p_w E[\min(w, C - s(b))] - tE[(s(b) - C)^+] \quad (23)$$

Eş. 23'te verilen beklenen getiri hesabındaki $E[\min(w, C - s(b))]$ ifadesi, rezervasyonsuz gelen müşteriler içinde hizmet alabilecek müşteri sayısının beklenen değeridir. Gerçekleşen rezervasyon sayısı, kapasite değerine eşit ya da kapasite değerinden küçükse rezervasyonsuz gelen müşteriler hizmet alabilmektedir. Rezervasyonsuz gelen müşterilerden elde edilmesi beklenen getiri miktarı da $p_w E[\min(w, C - s(b))]$ şeklinde hesaplanmaktadır. Bu çalışmada, incelenen üç rezervasyon modeli için de kapasite üzeri rezervasyon limiti belirlenirken kişisel olasılıkların kullanılması önerilmektedir. Klasik yaklaşımda müşterilerin rezervasyonlarına gelme olasılıklarının eşit ve sabit kabul edilmesi, rezervasyon limitinin rezervasyon alınma başlanmadan önce belirlenmesine olanak sağlamaktadır. Ancak dinamik modellerde rezervasyon limitinin rezervasyon yapan müşterilerin rezervasyonlarına gelme olasılıklarına bağlı olarak belirlenmesi nedeniyle rezervasyon limiti önceden belirlenememekte, bunun yerine gelen rezervasyon talepleri için kabul ya da ret kararı verilmektedir. Dinamik modellerde, kabul ya da ret kararı verilirken kontrol edilen koşullardaki $P(s(b) \geq C | D > b)$ olasılığının Monte Carlo simülasyonu ile hesaplanması önerilmektedir.

3.2. WEKA ile Kişisel Olasılıkların Tahmini (Prediction Show Probabilities with WEKA)

Çalışmada, müşterilerin rezervasyonlarına gelme olasılıklarının geçmiş rezervasyon bilgilerinden çıkarımlarda bulunularak tahmin edilmesi amacıyla veri madenciliği yöntemleri kullanılmıştır. Rezervasyon yapan müşterilerin rezervasyonlarına gelip gelmeme durumunun ve bu durumun gerçekleşme olasılığının tahmini için Lojistik Regresyon, Rassal Orman ve Yalın Bayes olmak üzere 3 farklı algoritma kullanılmıştır. Bu algoritmaların, sınıf bilgisinin yanında olasılık değerlerini de tahmin edebilen yöntemler olması, tercih edilme nedenleridir.

Lojistik Regresyon yöntemi sigmoid ya da logit adıyla da bilinen lojistik fonksiyonu kullanan istatistiksel bir yöntemdir. Lineer Regresyonun ikili sınıflandırma yapacak şekilde genelleştirilmiş hali olan bu yöntemde, bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki doğrusal ilişki kullanılarak sınıflandırma yapılmaktadır [16]. Sınıflandırma ve regresyon problemlerinde kullanılabilen Rassal Orman algoritması, karar ağaçlarından büyük bir küme oluşturan ve daha sonra bu karar ağaçları ile elde edilen sonuçların en iyisini ya da ortalamasını alan torbalama (*bagging*) yönteminin bir modifikasyonudur [17]. Yalın Bayes ise Bayes teoremini temel alan olasılıklı bir sınıflandırma yöntemidir. Bireysel olasılıkların tahmininde kullanılan bu algoritmalar, açık kaynak kodlu bir makine öğrenmesi yazılımı olan WEKA 3.8 ile uygulanmıştır [18].

Önerilen dinamik rezervasyon modeli için gerekli olan bireysel olasılıkların tahmin edilmesinde bir hastanenin geçmiş randevu kayıtları kullanılmıştır [19]. 70.000 randevu kaydı içeren veri seti 13 özelliğe sahiptir. Tahmin edilmek istenen sınıf etiketi, hastanın randevusuna gelme ya da gelmeme bilgisini içermektedir. Veri setini oluşturan özellikler Tablo 1'de özetlenmiştir. Veri setindeki 70.000 kayıttan 50.000'i algoritmalar ile tahmin modelleri oluşturulmasında kullanılmıştır. Eğitim verisi dışında kalan

Tablo 1. Veri setini oluşturan özellikler (Properties of data set)

Özellik	Kategoriler	Açıklama
Hasta kayıt numarası	...	Her hasta için farklı bir tanımlayıcı sayı dizisidir.
Cinsiyet	1,2	1: kadın, 2: erkek
Yaş	0,...	Hastanın yaş bilgisini verir.
Randevu günü	1,2,3,4,5	Her rakam pazartesiden cumaya sırasıyla bir günü temsil etmektedir.
Randevunun alındığı saat	1,2,3,4,5,6,7,8	Her rakam bir günün 3'er saatlik bir dilimini temsil etmektedir.
Gün farkı	0,...	Randevunun alındığı gün ile randevu günü arasındaki gün farkıdır.
Yaşanılan bölge	1,2,...,87	Her sayı şehirdeki bir bölgeyi temsil etmektedir.
Sağlık sigortası		
Hipertansiyon		
Diyabet	0,1	0: yok, 1: var
Alkolizm		
Engel durumu		
Bilgi mesajı	0,1	0: gönderilmedi, 1: gönderildi
Sınıf bilgisi	0,1	0: hasta randevuya gelmedi, 1: hasta randevuya geldi

Adım 1: $b=C$;
Adım 2: $n=1$;
Adım 3: $i(n)=1$ ve $s(n)=0$;
Adım 4: *Rassal sayı (a) üret $a \in [0,1]$;*
Adım 5: *Eğer $a < i(n)$.müşterinin olasılığı ise;*
 n. gündeki i.müşterinin sınıfını "1" olarak belirle;
 $s(n)=s(n)+1$;
 Değilse;
 n. gündeki i.müşterinin sınıfını "0" olarak belirle;
Adım 6: *Eğer $i(n)=b$ ise;*
 Adım 7'e git
 Değilse;
 $i(n)=i(n)+1$ ve *Adım 4'e git;*
Adım 7: *Eğer $n=N$ ise;*
 Adım 8'e git;
 Değilse;
 $n=n+1$ ve *Adım 3'e git;*
Adım 8: *N iterasyon içinde her $x=1..b$ için $s(n)=x$ olan n'leri say ve bu sayının N'e oranını, x müşteri gelme olasılığı, $(P(s(b)=x | D > b))$, olarak kaydet;*
Adım 9: *Adım 8 ile hesaplanan C'den büyük veya C'ye eşit x değerlerinin olasılıklarını toplayarak, $P(s(b) \geq C | D > b)$ değerini hesapla ve bu değeri P'ye eşitle;*
Adım 10: *Eğer $P \leq$ ilgili rezervasyon modelinin limit artırma koşulu ise;*
 $b=b+1$ ve *Adım 2'ye dön;*
 Değilse;
 Optimum rezervasyon limiti b'dir.

Şekil 5. Monte Carlo simülasyonuna ait sözde kod (Pseudo code of Monte Carlo simulation)

20.000 verinin, bireysel olasılıklı kapasite üzeri rezervasyon modelinin girdisi olarak kullanılmak üzere sınıf ve olasılık değerleri hesaplanmıştır ve aynı zamanda bu veri, tahmin modellerinin test verisi olarak kullanılmıştır.

3.3. Monte Carlo Simülasyonu (Monte Carlo Simulation)

Çalışmada önerilen bireysel olasılıkların kullanıldığı dinamik rezervasyon modellerinde, müşterilerin rezervasyonlarına gelme olasılıklarının sabit olmaması, rezervasyonuna gelen kişi sayısının kapasiteye eşit ya da kapasiteden büyük olma olasılıklarının hesaplanışında bazı farklılıklar gerektirmiştir. Kapasite üzeri rezervasyon limitinin belirlenmesinde ihtiyaç duyulan $P(s(b) \geq C | D > b)$ olasılığı, klasik yaklaşımda binom dağılımı yardımıyla Eş. 8'deki gibi hesaplanabilmektedir. Ancak, her müşteri için farklı gelme olasılığı kullanan dinamik modellerde, gelen müşteri sayısının kapasiteye eşit ya da kapasiteden büyük olma olasılığının klasik yaklaşımdaki gibi binom dağılımı yardımıyla elde edilmesi oldukça zordur. Örneğin, 10 kişi kapasiteli bir sistemde rezervasyon limitinin değerinin 15 olduğu varsayılın. Dinamik modelde bu 15 kişinin her birinin rezervasyonuna gelme olasılığı farklıdır. Bu durumda, $P(s(b) \geq C | D > b)$ olasılığı binom dağılımı ile hesaplanmak istenirse; 15 kişi içerisinden tüm 10,11,12,13,14 kişilik kombinasyonların ve

son olarak 15 kişinin tamamının rezervasyonuna gelme olasılıklarının hesaplanması gerekmektedir. Toplamda $\binom{15}{10} + \binom{15}{11} + \binom{15}{12} + \binom{15}{13} + \binom{15}{14} + \binom{15}{15} = 4944$ farklı kombinasyon içeren bu işlemde her kombinasyonun olasılık değeri, ilgili kombinasyonda yer alan tüm müşterilerin rezervasyonlarına gelme olasılıklarının çarpımları ile hesaplanmaktadır. Kapasitenin 100 olduğu durumda hesaplanması gereken olasılık sayısı çok daha fazla olmakta, işlem sayısı ve süresi üssel artmaktadır. Bu nedenle dinamik modelde $P(s(b) \geq C | D > b)$ olasılıklarının hesaplanmasında binom dağılımı kullanılamamaktadır. Bu çalışmada, söz konusu olasılıkların hesaplanmasında binom dağılımı yerine Monte Carlo simülasyonu kullanılmıştır. Yapılan simülasyonun işleyişini anlatmak için, MATLAB üzerinde oluşturulan algoritmanın sözde kodu Şekil 5'te verilmiştir.

4. UYGULAMA (APPLICATION)

Çalışmada incelenen kapasite üzeri rezervasyon modelleri için rezervasyon limitleri ve belirsizlik maliyetleri, MATLAB programının R2015a sürümü ile kodlanarak hesaplanmıştır. Rezervasyon modeli-1 için oluşturulan kodun akışı Şekil 6'te verilen sözde kod ile özetlenmiştir.

Çalışmada incelenen rezervasyon modellerinin amaç fonksiyonları, belirsizlik maliyetlerinin minimizasyonudur.

Adım 1: $b=C$, $E_1 = E_2 = E_1^* = E_2^* = 0$;

Adım 2: Eş. 7'de verilen olasılık değerini (P), Eş.8'i kullanarak hesapla.

Adım 3: Eğer $P \leq p/t$ ise

$b = b+1$ ve Adım 2'ye dön.

Değilse;

Sabit olasılıklı durum için optimum rezervasyon limitini b' 'dir, ($b_2=b$).

Adım 4: Kişisel olasılıkları kullanarak Monte Carlo simülasyonunu gerçekleştir.

Adım 5: $g = 1$ (G günlük simülasyon başlat);

Adım 6: g . gün için Monte Carlo simülasyonunun sonuçlarını kullanarak, $b_1 =$ Kişisel olasılıklı modelin optimum rezervasyon limiti belirlenir.

Adım 7: g . gün için belirlenen b_1 kadar rezervasyon içinden farklı sayılarda müşterilerin rezervasyonlarına gelme olasılıklarını Monte Carlo simülasyonunun sonuçlarından çek. Bu olasılıkları kullanarak kişisel olasılıklı model için g . günün belirsizlik maliyetinin beklenen değerini hesapla (Eş. 9). $E_1 = E_1 + g$. günün belirsizlik maliyetinin beklenen değeri olarak güncelle.

Adım 8: Adım 7'deki işlemleri b_2 ve E_2^* 'yi kullanarak gerçekleştir.

Adım 9: g . gün için belirlenen b_1 kadar rezervasyonu alınan müşterilerin tahmin edilen sınıf değerlerini (0-1) kullanarak kişisel olasılıklı model için gerçekleşen belirsizlik maliyetini hesapla. $E_1^* = E_1^* + g$. günün gerçekleşen belirsizlik maliyeti olarak güncelle.

Adım 10: Adım 9'daki işlemleri b_2 ve E_2^* 'i kullanarak gerçekleştir. $g=g+1$ olarak güncelle.

Eğer $g=G$ ise;

Adım 11'e git.

Değilse;

Adım 6'ya dön.

Adım 11: $R_1 = [(E_2 - E_1)/E_1] \times 100$ ve $R_2 = [(E_2^* - E_1^*)/E_1^*] \times 100$ değerlerini hesapla.

Şekil 6. Rezervasyon modeli-1'e ait sözde kod (Pseudo code of reservation model-1)

En küçüklenmek istenen belirsizlik maliyetleri sözde kodda E_1 , E_2 , E_1^* ve E_2^* olarak gösterilmiştir. Bunlardan E_1 ve E_2 sırasıyla kişisel olasılıklı ve sabit olasılıklı modellerin beklenen belirsizlik maliyetlerini, E_1^* ve E_2^* da sırasıyla kişisel olasılıklı ve sabit olasılıklı modellerin gerçekleşen belirsizlik maliyetlerini ifade etmektedir. Bu amaç fonksiyonlarının değerleri hesaplanırken elde edilebilecek en büyük getiri miktarından beklenen ve gerçekleşen getiri miktarı çıkartılmış ve böylece belirsizlik maliyetinin beklenen (E_1 ve E_2) ve gerçekleşen (E_1^* ve E_2^*) değerleri elde edilmiştir. Burada bahsedilen en büyük kazanç değeri, yapılan fazla rezervasyonla birlikte sadece kapasite kadar kişinin rezervasyonuna gelmesi durumunda elde edilebilecek kazanç miktarıdır. Yani sistem kapasitesinin tamamı kullanılmakta ve firma, hiçbir müşteriye reddetmek zorunda kalmadığı için herhangi bir maliyete katlanmamaktadır. Örneğin, C kişilik kapasitesi olan ve müşterinin ödediği hizmet ücretinin p olduğu bir sistemde, G günün sonunda elde edilebilecek en büyük kazanç miktarı C , G ve p değerlerinin çarpımı ile hesaplanmaktadır.

4.1. Karşılaştırma Testi (Comparison Test)

Çalışmada önerilen kişisel olasılıkların kullanıldığı kapasite üzeri rezervasyon modellerinin sabit olasılıklı modele göre başarısını ölçmek için bir karşılaştırma testi yapılmıştır. Dinamik modellerde kullanılan kişisel olasılıklar, bir hastanenin randevu sistemine ait geçmiş verilerden tahmin

algoritmaları ile elde edilmiştir. Dinamik ve klasik rezervasyon modellerini karşılaştıran bu test, çalışmada incelenen 3 farklı rezervasyon sistemi için uygulanmıştır. Karşılaştırmada kullanılan parametre değerleri sabit tutulmuştur. 100 kişilik kapasitesi olan bir sistemde hizmet ücretinin 60, reddetme maliyetinin 80 birim ücret olduğu varsayılmıştır. İncelenen ikinci rezervasyon modelindeki ceza oranı hizmet ücretinin %50'si olarak kabul edilmiştir. İncelenen üçüncü modelde, rezervasyonsuz gelen kişi sayısı kapasitenin %10'u olarak belirlenmiştir ve bu sayı $C = 100$ için 10 kişidir. Sabit olasılıklı model için gerekli olan sabit olasılık değeri (herhangi bir müşterinin rezervasyonuna gelme olasılığı) 0,795 olarak belirlenmiştir. Bu değer, tahmin algoritmalarında kullanılan eğitim verisinde rezervasyonuna gelen kişi yüzdesidir. Rezervasyon modeli-1 ve rezervasyon modeli-3 için yapılan karşılaştırmalarda kullanılmak üzere R_1 ve R_2 değerleri hesaplanmıştır. Bu oran değerleri, dinamik modellerin klasik modele kıyasla amaç fonksiyonunun değerinde sağladıkları iyileşmeyi ifade etmektedir.

$$R_1 = (E_2 - E_1)/E_1 \times 100 \quad (24)$$

$$R_2 = (E_2^* - E_1^*)/(E_1^*) \times 100 \quad (25)$$

Ancak rezervasyon modeli-2 için hesaplanan belirsizlik maliyetlerinin negatif değerler alabilmesi nedeniyle bu model için yapılan karşılaştırmalarda Eş. 24 ve Eş. 25'teki

oran değerleri kullanılmamıştır. Rezervasyon modeli-2 için dinamik modelin sağladığı fayda, belirsizlik maliyetleri arasındaki uzaklık hesaplanarak belirlenmiştir. Sabit parametre değerleri ($C=100$, $p=60$, $t=80$) ile yapılan 100 günlük simülasyonların sonuçları aşağıdaki tablolarda özetlenmiştir.

Tablo 2. Rezervasyon modeli-1 için simülasyon sonuçları
(Results of simulation of reservation model-1)

	Yalın Bayes	Rassal Orman	Lojistik Regresyon
E_1	11035,6	10737,1	11488,7
E_2	12302,9	11997,2	11817,8
R_1 (%)	11,48	11,74	2,86
E_1^*	12880	12000	12400
E_2^*	13100	12720	12500
R_2 (%)	1,71	6,00	0,81

Tablo 2'deki sonuçlar incelendiğinde rezervasyon modeli-1 için kişisel olasılıkların kullanımı ile daha düşük maliyetlere ulaşıldığı ve Rassal Orman algoritması ile yapılan olasılık tahminleriyle daha başarılı sonuçlar elde edildiği görülmektedir.

Tablo 3. Rezervasyon modeli-2 için simülasyon sonuçları
(Results of simulation of reservation model-2)

	Yalın Bayes	Rassal Orman	Lojistik Regresyon
E_1	-59440	-59050	-56970
E_2	-58580	-58030	-56590
d_1	860	1020	380
E_1^*	-61370	-63230	-61920
E_2^*	-59830	-60900	-61190
d_2	1540	2330	730

Rezervasyon modeli-2 için belirsizlik maliyetleri, oran değerleri yerine d_1 ve d_2 olarak adlandırılan fark değerleri ile karşılaştırılmıştır. Beklenen belirsizlik maliyetleri arasındaki mutlak fark d_1 ve gerçekleşen belirsizlik maliyetleri arasındaki mutlak fark d_2 ile ifade edilmiştir. Tablo 3'teki değerler incelendiğinde, kişisel olasılıklar kullanılarak daha fazla kazanç elde edilebildiği ve yine Rassal Orman algoritması ile tahmin edilen olasılıklarla daha yüksek faydalar sağlandığı görülmektedir.

Tablo 5. Rassal Orman algoritması ile yapılan duyarlılık analizlerinin sonuçları
(Results of sensitivity analysis with Random Forest algorithm)

p, t	Rezervasyon modeli-1		Rezervasyon modeli-2		Rezervasyon modeli-3	
	E_1^*	E_2^*	E_1^*	E_2^*	E_1^*	E_2^*
60, 120	22020	24300	-53010	-49500	3060	4140
60, 100	19280	20560	-55730	-53630	3900	4880
60, 80	12000	12720	-61370	-59830	2780	3240
45, 80	14985	15660	-40050	-38180	3250	4025
30, 80	13150	14170	-23080	-22340	2260	2730

Tablo 4. Rezervasyon modeli-3 için simülasyon sonuçları
(Results of simulation of reservation model-3)

	Yalın Bayes	Rassal Orman	Lojistik Regresyon
E_1	1984	1856	2210
E_2	7351	6914	4450
R_1 (%)	270,50	272,50	100,95
E_1^*	2720	2780	3080
E_2^*	2780	3240	3200
R_2 (%)	2,20	16,50	3,90

Rezervasyon modeli-3 için yapılan karşılaştırmalarda, yine kişisel olasılıklar kullanılarak hesaplanan beklenen ve gerçekleşen belirsizlik maliyetleri daha düşüktür. Sabit olasılık kullanımına göre farklı olasılık kullanımının sağladığı gerçekleşen fayda oranları; Yalın Bayes algoritması ile % 2,20, Rassal Orman algoritması ile % 16,50 ve Lojistik Regresyon algoritması ile % 3,90 olarak hesaplanmıştır. Tablo 4 incelendiğinde yine Rassal Orman algoritması ile hesaplanan kişisel olasılıklarla yapılan hesaplamaların nispeten daha başarılı sonuçlar verdiği görülmektedir. Sabit parametre değerleri ile yapılan karşılaştırma testine ek olarak, parametrelerin farklı değerleri için önerilen dinamik modellerin sağlayacağı iyileşmeler de analiz edilmiştir. Tablo 5'te Rassal Orman algoritması ile tahmin edilen olasılık değerleri kullanılarak üç farklı rezervasyon modeli için farklı p ve t parametre değerleriyle yapılan duyarlılık analizlerinin sonuçları özetlenmiştir.

Tablo 5'teki E_1^* ve E_2^* değerleri sırasıyla, ilgili model için kişisel ve sabit olasılık kullanımıyla hesaplanan belirsizlik maliyetinin gerçekleşen değerlerini ifade etmektedir. Bu değerler incelendiğinde, önerilen kişisel olasılıklı dinamik modellerin sabit olasılıklı klasik modele kıyasla daha başarılı sonuçlar verdiği görülmektedir. Duyarlılık analizi, çalışmada kullanılan diğer iki tahmin algoritmasının elde ettiği olasılık değerleri için de gerçekleştirilmiş ve Tablo 5'dekine benzer sonuçlar elde edilmiştir. Yapılan tüm analizler, farklı parametre değerleri için de önerilen modellerin klasik modellere göre önemli iyileştirmeler sağladığını göstermektedir. Tablo 5'deki değerlere bakıldığında ilk modelde %10,35'e, ikinci modelde 3510 birime ve üçüncü modelde %35,29'e varan iyileşmeler görülmektedir. Fakat, parametre değerlerindeki değişim ile gerçekleşen iyileşmeler arasında belirgin bir örüntü görülmemiştir.

5. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Hizmet sektöründe uygulanan gelir yönetiminin önemli bir parçası olan kapasite üzeri rezervasyon uygulaması firmaların rekabet gücüne önemli katkılar sağlamaktadır. Sistemin mevcut kapasitesi üzerinde rezervasyon alımına izin veren bu uygulama, yapılan ek rezervasyonlarla atıl kapasiteyi azaltarak, firmaların olası kayıplarını kazanca dönüştürmektedir. Dolayısıyla bu uygulamadaki en önemli adım, atıl kapasitenin mümkün olduğunca doğru tahmin edilmesidir. Atıl kapasitenin tahmin edilmesi aslında müşteri hareketlerinin tahmini anlamına gelmektedir. Bu çalışmada, klasik kapasite üzeri rezervasyon modelinin aksine, müşteri hareketlerinin tahmininde kişisel olasılıklar kullanılması ve optimum rezervasyon limitinin belirlenmesinde ihtiyaç duyulan olasılık değerlerinin Monte Carlo simülasyonu ile hesaplanması önerilmiştir. Müşterilerin rezervasyonlarına gelme olasılıkları, geçmiş rezervasyon kayıtları kullanılarak, tahmin algoritmaları (Lojistik Regresyon, Yalın Bayes ve Rassal Orman) ile birey bazında belirlenmiştir.

Literatürdeki kapasite üzeri rezervasyon uygulaması üzerine yapılmış çalışmalardan farklı olarak bu çalışmada, müşterilerin rezervasyonlarına gelme olasılıklarının makine öğrenmesi algoritmaları ile tahmini ve bu olasılıklar kullanılarak optimum rezervasyon limitinin belirlenmesi amaçları bir arada ele alınmıştır. Çalışma sonucunda, kapasite üzeri rezervasyon limitinin belirlenmesinde, kişisel olasılık kullanımının atıl kapasiteyi azaltmada klasik yaklaşımdan çok daha başarılı olduğu görülmüştür. Kullanılan algoritmalar içerisinde Rassal Orman algoritmasının en iyi tahminleri ve sonuçları oluşturduğu görülmekte ve rezervasyon modeli bazında bakıldığında, temel parametre değerleri ile yapılan denemelerde kişisel olasılık tahminlerinin kullanımı ile ilk modelde %6,00 oranında, ikinci modelde 2230 birim ve üçüncü modelde %16,50 oranında daha fazla getiri sağlanabildiği görülmüştür. Ayrıca, farklı parametre değerleri ile yapılan denemelerde, klasik yaklaşıma göre, ilk modelde %10,35'e, ikinci modelde 3510 birime ve üçüncü modelde %35,29'e varan iyileştirmeler görülmüştür.

İlerideki çalışmalarda, kişisel olasılıkların belirlenmesi için kullanılan algoritmaların geliştirilebileceği, daha fazla sayıda ve etkin nitelik içeren bir veri seti kullanılabilirliği düşünülmektedir. Bu çalışmada sunulan modeller, herhangi bir hizmet sektörü baz alınarak oluşturulmamıştır. Yine ilerideki çalışmalarda, dinamik yapıdaki kapasite üzeri rezervasyon uygulamasının sektörel bazda ele alınarak incelenmesi önerilmektedir.

KAYNAKLAR (REFERENCES)

1. Yiğit, F. ve Esnaf, Ş., Gelir yönetiminde kapasite üzeri rezervasyon için bir karma dinamik model önerisi, İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Yönetim Dergisi, 24, 105-120, 2013.
2. Coughlan, J., Airline overbooking in the multi-class case, J. Oper. Res. Soc., 50 (11), 1098-1103, 1999.
3. Feng, Y. ve Xiao, B., A continuous-time seat control model for single-leg flights with no-shows and optimal overbooking upper bound, Eur. J. Oper. Res., 174, 1298-1316, 2006.
4. Mookherjee, R. ve Friesz, T.L., Pricing, allocation, and overbooking in dynamic service network competition when demand is uncertain, Production and Operations Management, 17 (4), 455-474, 2008.
5. Erdelyi, A. ve Topaloğlu, H., A dynamic programming decomposition method for making overbooking decisions over an airline network, Inform Journal on Computing, 22 (3), 443-456, 2010.
6. Topaloglu, H., Birbil, S.İ., Frenk, J. ve Noyan, N., Tractable open loop policies for joint overbooking and capacity control over a single flight leg with multiple fare classes, Transportation Science, 46 (4), 460-481, 2012.
7. Aydın, N., Birbil, Ş.İ., Frenk, J.B.G. ve Noyan, N., Single-leg airline revenue management with overbooking, Transportation Science, 47 (4), 560-583, 2013.
8. Huang, Y., Ge, Y., Zhang, X. ve Xu, Y., Overbooking for parallel flights with transference, Int. J. Prod. Econ, 144 (2), 582-589, 2013.
9. Phumchusri, N. ve Maneesophon, P., Optimal overbooking decision for hotel rooms revenue management, Journal of Hospitality and Tourism Technology, 5 (3), 261-277, 2014.
10. Ivanov, S.H., Optimal overbooking limits for a hotel with three room types and with upgrade and downgrade constraints, Tourism Economics, 21 (1), 223-240, 2015.
11. Somboon, M. ve Amaruchkul, K., Applied two-class overbooking model in thailand's passenger airline data, The Asian Journal of Shipping and Logistics, 33 (4), 189-198, 2017.
12. Hueglin, C. ve Vanotti, F., Data Mining Techniques to Improve Forecast Accuracy in Airline Business, Bilgi Keşfi ve Veri Madenciliği Konulu 7. Uluslararası ACM SIGKDD Konferansı, San Francisco-California, 438-442, Ocak, 2001.
13. Lawrence, R.D., Hong, S.J. ve Cherrier, J., Passenger-based predictive modeling of airline no-show rates, Bilgi Keşfi ve Veri Madenciliği Konulu 9. Uluslararası ACM SIGKDD Konferansı, Washington-USA, 397-406, 24-27 Ağustos, 2003.
14. Garrow, L. A. ve Koppelman, F. S., Predicting air travelers' no-show and standby behaviour using passenger and directional itinerary information, Journal of Air Transport Management, 10, 401-411, 2004.
15. Zenkert, D., No-show forecast using passenger booking data, Yüksek Lisans Tezi, Lund Teknik Üniversitesi, Matematiksel Bilimler Merkezi, Lund, 2017.
16. Murphy, K. P., Machine Learning: A Probabilistic Perspective, The MIT Press, London, England, 2012.
17. Hastie, T., Tibshirani, R. ve Friedman, J., The Elements of Statistical Learning: Data Mining, Inference, and Prediction, 2. baskı, Springer, 2017.

18. Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P. ve Witten, I. H., The WEKA data mining software: An update, SIGKDD Explorations, 11 (1), 10-18, 2009.
19. Medical Appointment No Shows Data Set. <https://www.kaggle.com/joniarroba/noshowappointments>. Yayın tarihi Mayıs, 2016. Erişim tarihi Aralık 2, 2019.