



**BİREYSEL VERİLERE DAYALI KAPASİTE
ÜZERİ REZERVASYON MODELLERİ**

Yüksek Lisans Tezi

Tuğçe YAVUZ

Eskişehir 2019

**BİREYSEL VERİLERE DAYALI KAPASİTE ÜZERİ REZERVASYON
MODELLERİ**

Tuğçe YAVUZ

YÜKSEK LİSANS TEZİ

**Endüstri Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Onur KAYA**

**Eskişehir
Eskişehir Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Haziran 2019**

JÜRİ VE ENSTİTÜ ONAYI

Tuğçe Yavuz'un "Bireysel Verilere Dayalı Kapasite Üzeri Rezervasyon Modelleri" başlıklı tezi 28/06/2019 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Endüstri Mühendisliği Anabilim dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvanı - Adı Soyadı

İmza

Üye (Tez Danışmanı)

: Prof. Dr. Onur KAYA

Üye

: Doç. Dr. Gürkan ÖZTÜRK

Üye

: Dr. Öğr. Üyesi Sinan AYDIN

.....

Prof. Dr. Murat TANIŞLI

Lisansüstü Eğitim Enstitüsü Müdürü

ÖZET

BİREYSEL VERİLERE DAYALI KAPASİTE ÜZERİ REZERVASYON MODELLERİ

Tuğçe YAVUZ

Endüstri Mühendisliği Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Haziran 2019

Danışman: Prof. Dr. Onur KAYA

Gelir yönetiminin bir parçası olan kapasite üzeri rezervasyon politikası, günümüzde kullanılmayan kapasitenin depolanmadığı birçok sektörde uygulanmaktadır. Bu uygulamanın amacı; atıl kapasiteyi azaltırken kazanç miktarını en büyükmektir. Özellikle havayolu endüstrisi, otel ve restoran işletmeciliği gibi rekabetin yüksek olduğu hizmet sektörlerinde, kapasite üzeri rezervasyon limitinin firmaya sağladığı kazanç miktarı önem arz etmektedir. Literatürde kapasite üzeri rezervasyon limitinin optimum değerini belirlemeye yönelik farklı yaklaşımlar mevcuttur. Klasik yaklaşımda, rezervasyon yapan müşterilerinin rezervasyonlarına gelme olasılıkları aynı kabul edilmektedir. Bu çalışmada klasik yaklaşımdan farklı olarak rezervasyon yapan her müşterinin rezervasyonunu gerçekleştirme olasılığının kişiye bağlı olarak belirlenmesi önerilmiştir. Önerilen yaklaşım için ihtiyaç duyulan kişisel olasılıklar, tahmin algoritmaları kullanılarak geçmiş rezervasyon bilgilerinden elde edilmiştir. Her müşterinin farklı geliş olasılıklarının olması, farklı sayılardaki rezervasyonların gerçekleşmesi olasılıklarının klasik yöntemle hesaplanmasını zorlaştırmıştır. Bu nedenle farklı sayılarda rezervasyonların gerçekleşme olasılıklarının hesaplanmasında Monte Carlo simülasyonu kullanılmıştır. Çalışma sonucunda, önerilen dinamik modeller ile klasik yaklaşıma oranla çok daha yüksek kazançlar elde edilebileceği görülmüştür. Yapılan performans ölçümü ile tahmin algoritmalarının doğruluk ve modele uygunluk oranları, duyarlılık analizi ile de önerilen modellerin parametre değerlerindeki değişime nasıl tepki verdiği incelenmiştir.

Anahtar Kelimeler: Kapasite üzeri rezervasyon, Monte Carlo simülasyonu, Veri madenciliği, Tahmin algoritmaları

ABSTRACT

OVERBOOKING MODELS BASED ON PERSONAL DATA ANALYSIS

Tuğçe YAVUZ

Department of Industrial Engineering

Eskişehir Technical University, Institute of Graduate Programs, June 2019

Supervisor: Prof. Onur KAYA

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 is to maximize the amount of earnings while reducing spoilage costs. Especially in the service sectors where the competition is high, such as the airline industry, hotel and restaurant management, it is important that the overbooking limit brings the company closer to the maximum gain. There are different approaches in the literature to determine the optimal value of the overbooking limit. 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 probabilities of different number of bookings 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. The optimal reservation limit and expected revenue are calculated with the total show probabilities obtained as a result of the simulation. 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. Accuracy and conformity rates of the forecasting algorithms are analyzed for performance measurement and the changes in the results of the proposed models with respect to the changes in parameter values are researched through a detailed sensitivity analysis.

Keywords: Overbooking, Monte Carlo simulation, Data mining, Forecasting algorithms

TEŞEKKÜR

Bu tez üzerinde çalıştığım tüm süre boyunca bilgisini ve deneyimlerini benimle paylaşan, hep daha iyiye yönlendiren ve desteğini hissettiren sayın hocam Prof. Dr. Onur KAYA'ya minnettarlığımı ve teşekkürlerimi sunarım.

Tüm hayatım boyunca olduğu gibi bu çalışma süresince de bana güvenen ve destekleyen sevgili aileme; her zorluğumda yanımda olan kıymetli dostlarım Hatice AY, Mustafa GÜNER, Büşra YAZICI ve Tunahan ÇINAR'a teşekkür ederim.



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “ bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “ intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

.....

Tuğçe YAVUZ

İÇİNDEKİLER

	<u>Sayfa</u>
BAŞLIK SAYFASI.....	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
ÖZET	iii
ABSTRACT.....	iv
TEŞEKKÜR	v
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	vi
İÇİNDEKİLER	vii
TABLolar DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI	3
3. KAPASİTE ÜZERİ REZERVASYON MODELLERİ.....	10
3.1. Rezervasyonuna Gelmeyen Müşterilerin Ceza Ödediği Sistem (RM-2).....	16
3.2. Rezervasyonsuz Müşterilerin Kabul Edildiği Sistem (RM-3).....	20
4. YÖNTEMLER	25
4.1. Veri Madenciliği ile Sınıflandırma ve Tahmin	25
4.1.1. WEKA ile kişisel olasılıkların tahmini	28
4.2. Monte Carlo Simülasyonu	29
5. SAYISAL DENEYLER.....	33
5.1. Karşılaştırma Testleri.....	34
5.1.1. Rassal atanan kişisel olasılıklar ile karşılaştırma testi	35
5.2. Hastane Randevu Sistemi Üzerine Bir Uygulama: Tahmin Edilen Kişisel Olasılıklar ile Karşılaştırma Testi.....	39
5.2.1. Tahmin modellerinin performans ölçümü	42
5.3. Duyarlılık Analizi.....	45
5.3.1. Rassal olasılık değerleri ile duyarlılık analizleri	46
5.3.2. Tahmin edilen olasılık değerleri ile duyarlılık analizleri	50
5.3.2.1. Rezervasyon modeli-1 için duyarlılık analizi.....	51
5.3.2.2. Rezervasyon modeli-2 için duyarlılık analizi.....	60
5.3.2.3. Rezervasyon modeli-3 için duyarlılık analizi.....	87

	<u>Sayfa</u>
6. SONUÇ VE ÖNERİLER	97
KAYNAKÇA.....	99
ÖZGEÇMİŞ	



TABLÖLER DİZİNİ

	<u>Sayfa</u>
Tablo 4.1. Veri setini oluşturan özellikler.....	28
Tablo 5.1. 100 günlük simülasyon sonuçları	38
Tablo 5.2. 1000 günlük simülasyon sonuçları.....	38
Tablo 5.3. Rezervasyon modeli-1 için simülasyon sonuçları	40
Tablo 5.4. Rezervasyon modeli-2 için simülasyon sonuçları	41
Tablo 5.5. Rezervasyon modeli-3 için simülasyon sonuçları	41
Tablo 5.6. Sınıflandırma sonuçlarının analizi	42
Tablo 5.7. Algoritmaların performans ölçüm değerleri	44
Tablo 5.8. Duyarlılık analizlerinde kullanılan parametreler ve değerleri.....	45
Tablo 5.9. Model-2 için duyarlılık analizi parametre değerleri	45
Tablo 5.10. Model-1 için rassal olasılıklar ile duyarlılık analizi	46
Tablo 5.11. Model-2 için rassal olasılıklar ile duyarlılık analizi ($r=0.2$).....	47
Tablo 5.12. Model-2 için rassal olasılıklar ile duyarlılık analizi ($r=0.5$).....	48
Tablo 5.13. Model-2 için rassal olasılıklar ile duyarlılık analizi ($r=0.8$).....	49
Tablo 5.14. Model-3 için rassal olasılıklar ile duyarlılık analizi	50
Tablo 5.15. Lojistik Regresyon ile model-1 için duyarlılık analizi.....	51
Tablo 5.16. Naive Bayes ile model-1 için duyarlılık analizi	54
Tablo 5.17. Random Forest ile model-1 için duyarlılık analizi	57
Tablo 5.18. Lojistik Regresyon ile model-2 için duyarlılık analizi ($r=0.2$).....	60
Tablo 5.19. Naive Bayes ile model-2 için duyarlılık analizi ($r=0.2$).....	63
Tablo 5.20. Random Forest ile model-2 için duyarlılık analizi ($r=0.2$).....	66
Tablo 5.21. Lojistik Regresyon ile model-2 için duyarlılık analizi ($r=0.5$).....	69
Tablo 5.22. Naive Bayes ile model-2 için duyarlılık analizi ($r=0.5$).....	72
Tablo 5.23. Random Forest ile model-2 için duyarlılık analizi ($r=0.5$).....	75
Tablo 5.24. Lojistik Regresyon ile model-2 için duyarlılık analizi ($r=0.8$).....	78
Tablo 5.25. Naive Bayes ile model-2 için duyarlılık analizi ($r=0.8$).....	81
Tablo 5.26. Random Forest ile model-2 için duyarlılık analizi ($r=0.8$).....	84
Tablo 5.27. Lojistik Regresyon ile model-3 için duyarlılık analizi sonuçları.....	87
Tablo 5.28. Naive Bayes ile model-3 için duyarlılık analizi sonuçları	90
Tablo 5.29. Random Forest ile model-3 için duyarlılık analizi sonuçları	93

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1. Rezervasyon limitindeki artışın marjinal etkisinin analizi	13
Şekil 3.2. Rezervasyon modeli-2 için limitteki artışın marjinal etkisinin analizi.....	18
Şekil 3.3. Rezervasyon modeli-3 için limitteki artışın marjinal etkisinin analizi.....	21
Şekil 5.1. Rezervasyon modeli-1 için 100 günlük rezervasyon limitleri	36
Şekil 5.2. Rezervasyon modeli-2 için 100 günlük rezervasyon limitleri	37
Şekil 5.3. Rezervasyon modeli-3 için 100 günlük rezervasyon limitleri	37
Şekil 5.4. Lojistik Regresyon ile model-1 için R_1 ve R_2 oranları ($C=10$)	52
Şekil 5.5. Lojistik Regresyon ile model-1 için R_1 ve R_2 oranları ($C=20$)	52
Şekil 5.6. Lojistik Regresyon ile model-1 için R_1 ve R_2 oranları ($C=50$)	53
Şekil 5.7. Lojistik Regresyon ile model-1 için R_1 ve R_2 oranları ($C=100$)	53
Şekil 5.8. Naive Bayes ile model-1 için R_1 ve R_2 oranları ($C=10$).....	55
Şekil 5.9. Naive Bayes ile model-1 için R_1 ve R_2 oranları ($C=20$).....	55
Şekil 5.10. Naive Bayes ile model-1 için R_1 ve R_2 oranları ($C=50$).....	56
Şekil 5.11. Naive Bayes ile model-1 için R_1 ve R_2 oranları ($C=100$)	56
Şekil 5.12. Random Forest ile model-1 için R_1 ve R_2 oranları ($C=10$).....	58
Şekil 5.13. Random Forest ile model-1 için R_1 ve R_2 oranları ($C=20$).....	58
Şekil 5.14. Random Forest ile model-1 için R_1 ve R_2 oranları ($C=50$).....	59
Şekil 5.15. Random Forest ile model-1 için R_1 ve R_2 oranları ($C=100$).....	59
Şekil 5.16. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.2$)	61
Şekil 5.17. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.2$)	61
Şekil 5.18. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.2$)	62
Şekil 5.19. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.2$).....	62
Şekil 5.20. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.2$)	64
Şekil 5.21. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.2$)	64
Şekil 5.22. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.2$)	65
Şekil 5.23. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.2$)	65
Şekil 5.24. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.2$)	67
Şekil 5.25. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.2$)	67
Şekil 5.26. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.2$)	68
Şekil 5.27. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.2$)	68
Şekil 5.28. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.5$)	70

Şekil 5.29. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.5$)	70
Şekil 5.30. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.5$)	71
Şekil 5.31. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.5$).....	71
Şekil 5.32. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.5$)	73
Şekil 5.33. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.5$)	73
Şekil 5.34. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.5$)	74
Şekil 5.35. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.5$)	74
Şekil 5.36. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.5$)	76
Şekil 5.37. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.5$)	76
Şekil 5.38. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.5$)	77
Şekil 5.39. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.5$)	77
Şekil 5.40. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.8$)	79
Şekil 5.41. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.8$)	79
Şekil 5.42. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.8$)	80
Şekil 5.43. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.8$).....	80
Şekil 5.44. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.8$)	82
Şekil 5.45. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.8$).....	82
Şekil 5.46. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.8$)	83
Şekil 5.47. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.8$)	83
Şekil 5.48. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.8$)	85
Şekil 5.49. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.8$)	85
Şekil 5.50. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.8$)	86
Şekil 5.51. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.8$)	86
Şekil 5.52. Lojistik Regresyon ile model-3 için R_1 ve R_2 oranları ($C=10$)	88
Şekil 5.53. Lojistik Regresyon ile model-3 için R_1 ve R_2 oranları ($C=20$)	88
Şekil 5.54. Lojistik Regresyon ile model-3 için R_1 ve R_2 oranları ($C=50$)	89
Şekil 5.55. Lojistik Regresyon ile model-3 için R_1 ve R_2 oranları ($C=100$)	89
Şekil 5.56. Naive Bayes ile model-3 için R_1 ve R_2 oranları ($C=10$)	91
Şekil 5.57. Naive Bayes ile model-3 için R_1 ve R_2 oranları ($C=20$)	91
Şekil 5.58. Naive Bayes ile model-3 için R_1 ve R_2 oranları ($C=50$)	92
Şekil 5.59. Naive Bayes ile model-3 için R_1 ve R_2 oranları ($C=100$)	92
Şekil 5.60. Random Forest ile model-3 için R_1 ve R_2 oranları ($C=10$)	94

Sayfa

Şekil 5.61. Random Forest ile model-3 için R_1 ve R_2 oranları ($C=20$).....	94
Şekil 5.62. Random Forest ile model-3 için R_1 ve R_2 oranları ($C=50$).....	95
Şekil 5.63. Random Forest ile model-3 için R_1 ve R_2 oranları ($C=100$).....	95



1. GİRİŞ

Gelir yönetimi; günümüzde birçok sektörde firmaların gelir ve karlılıklarını arttırmak amacıyla geliştirdikleri ve kullandıkları farklı uygulamaları kapsayan bir kavramdır. Firmaları rekabetçi kılan, teknolojik ve bilimsel gelişmelerden beslenen bu sofistike yöntemin temelinde, müşteri hareketlerinin tahmin edilmesi yer almaktadır.

Gelir yönetiminin ilk uygulama alanlarından olan havayolu endüstrisinde bu yöntem kapasitenin etkin kullanım oranının arttırılması amacıyla uygulanmaktadır. Benzer şekilde, kullanılmayan kapasitenin geri dönüşünün olmadığı otel, restoran işletmeciliği, karayolu taşımacılığı, araç kiralama gibi hizmet sektörlerinde de kapasite yönetimi amacıyla kullanılmaktadır.

Gelir yönetimi genelde üç başlık altında incelenmektedir: kapasite yönetimi, dinamik fiyatlandırma ve kapasite üzeri rezervasyon (Yiğit ve Esnaf, 2013, s.107). Bu çalışmada üzerinde durulan kapasite üzeri rezervasyon uygulaması ilk olarak 1960'lı yıllarda havayolu firmaları tarafından resmi olarak kullanılmaya başlanmıştır. Firmaların rekabetçi kalmalarını sağlayan bu uygulama, zaman geçtikçe evrenselleşmiş ve farklı sektörlerde de uyarlanmıştır.

Kapasite üzeri rezervasyon uygulaması, gelir yönetimin esas amacı olan kar maksimizasyonunu kapasitenin etkin kullanımı ile sağlamaya çalışmaktadır. Bu amaçla, bir rezervasyonun satışa dönüşmeme riskine karşılık müşteri hareketlerinin tahmini doğrultusunda kapasitenin üzerinde rezervasyon alımına izin verilmektedir. Rekabetin zorlu olduğu hizmet sektörlerinde, firmaların tercih ettikleri fazla rezervasyon stratejileri önem arz etmektedir. Bu çalışmada, müşteri hareketlerinin tahmini için klasik yaklaşıma kıyasla daha başarılı olduğu düşünülen farklı bir yöntem sunulmaktadır.

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

yardımla tahmininin mümkün olması bu çalışmanın çıkış noktası olmuştur. Çalışmada, kapasite üzeri rezervasyon limitinin kişisel olasılıklar kullanılarak belirlenmesi ve böylece elde edilen kazancın artırılması amaçlanmıştır.

Geçmiş veriler yardımıyla rezervasyonu olan müşterilerin sisteme gelişleri hakkında yapılan gerçekçi tahminler sayesinde rezervasyonuna gelmeyecek kişi sayısını tahmin ederek atıl kapasiteyi belirlemek ve belirlenen atıl kapasite kadar fazla rezervasyon alarak bu olası maliyeti kazanca çevirmek mümkündür. Bu yaklaşımla, çalışmada kişisel olasılıklar kullanılmıştır ve kişisel bilgiler kullanılarak belirlenen rezervasyon limitinin daha gerçekçi olması nedeniyle klasik yaklaşıma kıyasla daha yüksek kazançlar elde edilebileceği görülmüştür.

Çalışmada farklı varsayımlara sahip 3 farklı rezervasyon sistemi incelenmiş ve bu sistemlerde kapasite üzeri rezervasyonun nasıl uygulanacağı açıklanmıştır. Kişisel olasılıkların kullanılmasıyla dinamik bir yapı kazanan rezervasyon modellerinin hesaplamalarında meydana gelen farklar anlatılmıştır. Oluşturulan dinamik rezervasyon modellerinin girdileri olan kişisel olasılıkların tahmini için 3 farklı makine öğrenme 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”, çifte rezervasyon uygulaması için klasik yaklaşımın ve önerilen dinamik modellerin tanıtıldığı “Kapasite Üzeri Rezervasyon Modelleri”, önerilen dinamik modellerde kullanılan veri madenciliği yöntemlerinin ve Monte Carlo simülasyonunun çalışmada neden ve nasıl kullanıldığının anlatıldığı “Yöntemler” kısımları yer almaktadır. Bu kısma kadar teorik yapısı anlatılan çalışmanın MATLAB (R2015a) programı aracılığıyla gerçekleştirilen uygulaması, dinamik modelin klasik modele karşı başarısını ölçmek için yapılan karşılaştırma testleri ve duyarlılık analizleri “Sayısal Deneyler” bölümünde anlatılmıştır. Son olarak “Sonuç ve Öneriler” kısmına yer verilmiştir.

2. LİTERATÜR TARAMASI

Literatür taraması kapsamında incelenen çalışmalar, kapasite üzeri rezervasyon modelleri geliştiren ve kapasite üzeri rezervasyon uygulamasında tahmin yöntemlerinin kullanımını konu alan çalışmalar olmak üzere iki kısma ayrılmıştır.

Gelir yönetimi kapsamında farklı hizmet sektörlerinde gerçekleştirilmiş çeşitli kapasite üzeri rezervasyon uygulaması çalışmaları vardır. Kapasite üzeri rezervasyon uygulaması üzerine ilk bilimsel çalışma Beckmann (1958) tarafından yapılmıştır. Bu çalışmada, geç iptallerin, rezervasyonuna gelmeyen ve hizmet için beklemekte olan müşterilerin olasılık dağılımları bilindiği varsayımlarıyla optimum rezervasyon limiti tartışılmıştır. Thompson (1961), iki farklı ücret sınıfı içeren uçuşlarda her ücret sınıfı için ayrı olarak kapasite üzeri rezervasyon limitini belirlemeyi amaçlamıştır. Rothstein (1985) tarafından yapılan çalışmada, kapasite üzeri rezervasyon yapmayı gerektiren sorunlar, havayolu endüstrisinde çifte rezervasyon uygulamaları ve yöneylem araştırmasının bu alandaki katkıları analiz edilmiştir. Chatwin (1998), tek güzergah ve tek ücret sınıflı uçuşlar için optimum rezervasyon limitlerini belirlemeye yönelik farklı koşullar sunmuştur. Yine Chatwin (1999) tarafından yapılan başka bir çalışmada, rezervasyonlarına gelmeyen müşterilere ve iptallere izin verilen bir kapasite üzeri rezervasyon modeli analiz edilmiştir. Çalışmada ele alınan rezervasyon süreci bir sürekli doğum-ölüm süreci olarak modellenmiştir. Coughlan (1999) çalışmasında, farklı sınıf ücretleri olan bir uçuş için kabin seviyesinde bir kapasite üzeri rezervasyon modeli sunmuştur. Optimum rezervasyon limitinin belirlenmesi amacı taşıyan modelin uygulandığı firmada daha önce kullanılan yöntemlere göre iyileşme sağladığı görülmüştür. Karaesmen ve van Ryzin (2004) tarafından yapılan çalışmada, birden fazla rezervasyon ve envanter sınıfı içeren hizmetler için kapasite üzeri rezervasyon modeli sunulmuştur. Çalışmada önerilen modelde, ilgili rezervasyonun ikame seçenekleri de göz önüne alınarak rezervasyon limiti belirlenmiştir. Bu yaklaşımın gelir ve maliyet üzerinde düşük seviyede bir etkisi olduğu gösterilmiştir. Feng ve Xiao (2006) tarafından, tek güzergahlı uçuşlarda koltuk envanteri ve çifte rezervasyon politikalarını birleştiren bir sürekli zamanlı model sunulmuştur. Suzuki (2006) tarafından yapılan çalışmada, havayolu endüstrisinde uygulanan çifte rezervasyon politikasının net faydası ile brüt faydası arasındaki ilişki irdelenmiş, yoğun ve yoğun olmayan uçuşlarda uygulanan çifte rezervasyonun gelir üzerindeki etkileri incelenerek bu yöntemin yararı araştırılmıştır. Yapılan bir dizi simülasyon sonucunda net faydanın çoğunlukla brüt faydadan daha düşük

olduğu görülmüştür. Klopheus ve Pölt (2007), satışa dönüşen rezervasyonların sayısını binom dağılımı ile tanımlayan bir çifte rezervasyon modeli kullandıkları çalışmalarında, atıl koltuk maliyetlerinin zamana göre değiştiğini varsaymış ve bu koltukların ücretini en düşük sınıfın ücret seviyesine (müşterilerin ödeme isteklerine denk gelen) eşit olarak belirlemişlerdir. Çalışmada, bu varsayımlar altında oluşturulan rezervasyon modelinin gelir potansiyeli, simülasyonlarla incelenmiştir. Mookherjee ve Friesz (2008) 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 Topaloglu (2010), çalışmalarında bir havayolu ağı üzerinde kapasite tahsisi ve kapasite üzeri rezervasyon kararlarını bir arada ele alan bir gelir yönetimi modeli sunmuşlardır. Çalışmada, kapasite tahsisi ve kapasite üzeri rezervasyon problemi dinamik programlama ile modellenmiş ve çözüm yaklaşımları sunulmuştur. Lan vd. (2011) çalışmalarında, hizmet sağlayıcının optimum kararı verememesinden kaynaklı yaşayacağı pişmanlık düzeyini dikkate alan bir çifte rezervasyon modeli geliştirmişlerdir. Topaloğlu vd. (2012) 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. (2013) tarafından, tek güzergahlı uçuşlarda optimum kapasite üzeri rezervasyon limitini belirlemek için statik ve dinamik yapıları farklı rezervasyon modelleri geliştirilmiştir. Huang vd. (2013) çalışmalarında gelir yönetiminin parçası olan kapasite yönetimi ve kapasite üzeri rezervasyon uygulamasını bir arada ele almışlardır. 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 önermişlerdir. Yiğit ve Esnaf (2013) tarafından yapılan çalışmada, kapasite üzeri rezervasyon uygulamasının kısa ve uzun vadeli etkilerini dengelemek amacıyla bir karma dinamik çifte rezervasyon modeli önerilmiştir. Önerilen karma model, beklenen kazancın negatif olmaması ve hizmet düzeyinin belirli bir seviyenin altına düşmemesi kısıtları ile oluşturulmuş iki farklı çifte rezervasyon modeliyle karşılaştırılmıştır. Sonuçlar, önerilen modelin kazanç optimizasyonu modeline göre %33,13, hizmet düzeyi modeline göre %38,70 oranında iyileşme sağladığını göstermiştir. Zhang vd. (2014) çalışmalarında, gerçekleşmeyen rezervasyon sayısının olasılık dağılımını belirlemek için ihtiyaç duyulan geçmiş verinin olmadığı durumlarda uygulanabilecek bir kapasite üzeri rezervasyon

modeli önermişlerdir. Çalışmada, bir havayolu firmasının geçmiş verisi olmayan tek seferlik bir uçuş açtığı ve indirimli fiyat uyguladığı varsayılmıştır. Bu durumda, optimum rezervasyon limitini belirlemek için rezervasyon sayısının belirsiz bir değişken olarak ele alındığı belirsiz programlama teorisine dayanan bir çifte rezervasyon modeli oluşturulmuştur. Phumchusri ve Maneesophon (2014) kapasite üzeri rezervasyonun uygulama alanlarından bir diğeri olan otel işletmeciliği üzerine çalışmıştır. 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 (2015) tarafından yapılan çalışmada, üç farklı oda tipi olan bir otelde çeşitli varsayımlar altında kapasite üzeri optimal rezervasyon limitlerini belirlemek için bir matematiksel model geliştirilmiştir. Çalışmada; düşük, orta ve yüksek ücretli olarak tanımlanan üç farklı oda tipi için iptal, gelmeme ve erken çıkış durumlarının farklı kombinasyonları üzerine uygulamalar yapılmıştır. Önerilen matematiksel modelle yapılan uygulamalarda kapasite üzeri rezervasyon limiti ve maliyeti belirlenmiştir. Wannakrairot ve Phumchusri (2016) tarafından yapılan çalışmada hava kargolarında optimum rezervasyon limitinin belirlenmesi üzerinde durulmuştur. Toplam maliyeti en küçükleyecek optimum rezervasyon limitinin belirlenmesi için çoklu regresyon modeli ve yalın yöntem şeklinde anılan bir model önerilmiştir. Çalışmada, önerilen iki modelin en iyi sonuçları verdiği parametre değerleri tespit edilmiştir. Soomboon ve Amaruchkul (2017) çalışmalarında bir uçuş için rezervasyon kapasitesinin ve kapasite üzeri rezervasyon limitinin eş zamanlı olarak belirlenmesini sağlayan bir matematiksel model oluşturmuşlardır. Gerçek hayat verileri ile yapılan simülasyon sonucunda, yüksek ve düşük olmak üzere iki sınıflı çifte rezervasyon modeli ile elde edilen gelirin sabit rezervasyon limiti olan duruma göre daha iyi sonuçlar verdiği görülmüştür.

Kapasite üzeri rezervasyon uygulamasının çokça kullanıldığı alanlardan biri medikal alanıdır. Zeng vd. (2010) rezervasyonunu gerçekleştirme olasılıkları farklı olan hastalar için çifte rezervasyonlu klinik çizelgeleme problemi üzerinde çalışmışlardır. Çalışmada, öncelikle çizelgeleme problemini tanımlayan matematiksel model oluşturulmuş ardından bu modeli çözmek için yerel bir arama algoritması önerilmiştir. Çalışma sonucunda, hastaların rezervasyonlarına gelme olasılıklarının farklı olduğu durum için oluşturulan çizelgelerin daha başarılı olduğu gösterilmiştir. Yine medikal alanında Sahro vd. (2015) tarafından yapılan çalışmada, çoklu hizmet noktası içeren

klinalerde ayakta tedavi edilen hastalar iin kapasite zeri rezervasyon limitini optimize etmek ve beklenen getiriyi en byklemek iin bir izelgeleme modeli nerilmiřtir. Deneysel sonular, oklu hizmet saėlayıcı ieren kapasite zeri rezervasyon modelinin, tekli hizmet saėlayıcı ieren modele oranla beklenen karı %19-24 ve planlanan hasta sayısını %4.5-9 oranında arttırdığını gstermiřtir.

Birok alıřma, dinamik yapıdaki kapasite zeri rezervasyon modellerini tanımlamak iin Markov Karar Sreci'ni kullanmıřtır. Rothstein (1971), beklenen geliri en bykleyecek optimum rezervasyon limitini belirlemek iin Markov Karar Srecini kullanmayı nermiřtir. Alstrup (1986)'ın alıřmasında, iki sınıflı bir uuř iin rezervasyonuna gelmeyen mřterilere, iptallere ve sınıf deėiřikliklerine izin veren bir kapasite zeri rezervasyon modeli aıklanmıř ve bu model homojen olmayan Markov Karar Sreci ile zlmřtir. Subramanin vd. (1999) tarafından, havayolu endstrisinde gelir ynetimi zerine yapılan alıřmada farklı cret sınıfları ieren kapasite zeri rezervasyon uygulaması, rezervasyonların iptal olma ve gerekleřmeme durumlarıyla birlikte ele alınmıř ve bu sre bir Markov Karar Zinciri ile formle edilmiřtir. Kapasite zeri rezervasyon limitinin belirlenmesinde dinamik programlamanın nasıl kullanılacağı alıřmada aıklanmıřtır. nerilen model ile rezervasyonların iptal ve gerekleřmeme durumlarının dikkate alınmadığı eřdeėer bir modele kıyasla %9 daha fazla kazan elde edilebildiėi gsterilmiřtir. Sulima (2012) alıřmasında, bir uuř iin bilet satıř srecini matematiksel modelle aıklamıř ve atıl kapasiteyi azaltmak amacıyla fazladan satılması gereken bilet sayısının tahmini iin ayrıık zamanlı bir Markov Karar Zinciri kullanmıřtır. Schtz ve Kolisch (2013), farklı hizmetler iin rezervasyon yapabilen farklı mřterilerin olduėu ve hizmet saėlayıcının rezervasyon talebine anında kabul ya da ret řeklinde geri dnř yapmasını gerektiren bir sistem zerinde alıřmıřlardır. Makalede, ele alınan sistem iin ifte rezervasyon ieren optimum randevu izelgesini oluřturmak amacıyla yinelemeli stokastik dinamik programlamayla zlebilecek ayrıık zamanlı bir Markov Karar Sreci modellenmiřtir. alıřmada, nerilen yaklařımın mevcut yaklařıma oranla daha bařarılı olduėu gsterilmiřtir.

Optimal kapasite zeri rezervasyon limitinin belirlenmesindeki en nemli adımlardan biri rezervasyonların gerekleřmeme ve iptal olasılıklarının doėru tahminlenmesidir. Son zamanlarda, bu olasılıkların tahmininde makine ėrenme algoritmaları sıklıkla kullanılmaktadır. Hueglin ve Vannotti (2001) havayolu endstrisinde kapasite zeri rezervasyon zerine yaptıkları alıřmalarında, yolcuların

rezervasyonlarına gelmeme olasılıklarını tahmin etmek için Lojistik Regresyon ve Karar Ağacı algoritmalarını kullanmışlardır. Olasılıkların tahmininde geçmiş uçuşlara ait PNR kayıtlarının kullanıldığı çalışmada, kişisel olasılıkların bu şekilde geçmiş verilerden tahmin algoritmaları ile elde edilmesinin, her yolcu için ortalama bir gelmeme olasılığı belirlenmesinden daha başarılı olduğu savunulmaktadır. Lawrence vd. (2003) çalışmalarında, iki farklı sınıf içeren bir uçuş için yolcuların rezervasyonlarına gelmeme olasılıklarının tahmininde kullanılmak üzere iki farklı model geliştirmişlerdir. Geliştirilen modellerden ilkinde rezervasyonların gerçekleşmeme olasılıkları yolcu bazında ele alınmıştır ve geçmiş veriler kullanarak her yolcunun rezervasyonuna gelmeme olasılığı kişisel olarak tahmin edilmiştir. Bu olasılıkların tahmininde C4.5, ProbE ve APMR algoritmaları kullanılmıştır. İkinci modelde, rezervasyonların gerçekleşmeme olasılıkları kabin seviyesinde ele alınmıştır. Kabin seviyesinde rezervasyonların gerçekleşmeme oranı regresyon problemi olarak modellenmiş ve lineer regresyon ile çözülmüştür. Çalışma sonucunda, kişisel bilgiler kullanılarak yapılan tahminlerin geleneksel istatistiksel yöntemlere kıyasla daha başarılı olduğu gösterilmiştir. Yine havayolu endüstrisinde müşterilerin rezervasyonlarını gerçekleştirmeme olasılıklarını tahmin etmeyi amaçlayan çalışmalardan biri de Garrow ve Koppelman (2004) tarafından yapılmıştır. Yazarlar, yolcu ve güzergah bilgilerini kullanarak rezervasyonların nasıl sonuçlanacağını (gerçekleşme veya gerçekleşmeme) ve hizmet alamayan yolcuların bir sonraki uçuş için davranışlarını (bekleme ya da beklememe) tahmin etmişlerdir. Bu tahminler için Multinomial Logit modellerini kullanmışlardır. Bu çalışmada yolcu ve güzergah bilgilerinin kullanımı ile daha doğru sonuçlar veren tahmin modelleri oluşturulabileceği gösterilmiştir. Morales ve Wang (2010) çalışmalarını hizmet sektöründe rezervasyon iptallerinin oranının tahmininde veri madenciliği yöntemlerinin kullanılması üzerine yapmışlardır. Rezervasyonun yapıldığı zaman ile hizmet zamanı arasındaki herhangi bir t anında gerçekleşmesi beklenen iptal oranını tahmin etmeyi amaçlayan çalışmada, kullanılan iki sınıflı olasılık tahminleyici modeller ile bir 'iptal eğrisi' elde edilmiştir. Dupuis vd. (2012) tarafından yine havayolu taşımacılığında kapasite üzeri rezervasyon uygulaması üzerine yapılan çalışmada yolcuların rezervasyonlarının nasıl sonuçlanacağı tahminini iyileştirmeyi amaçlayan bir yaklaşım sunulmuştur. Çalışmada kullanılan 30'dan fazla özellik içeren nitelik vektörleri, daha önce aynı güzergahta seyahat etmiş müşteri bilgileri kullanılarak oluşturulmuştur. Farklı özelliklerin kombinasyonlarına dayalı sınıflandırma modelleri yardımıyla rezervasyon

yapan müşterinin rezervasyonuna gelip gelmeyeceği tahmin edilmeye çalışılmıştır. Tahmin hatası, çalışmanın gerçekleştirildiği firmanın uyguladığı yöntem için %14.3 iken önerilen yöntemle %3.6'ya düşmüştür. Zenkert (2017), yüksek lisans tezinde, havayolu endüstrisinde yolcuların rezervasyonlarına gelmeme olasılıklarının tahmini için zaman serisi yöntemleri yerine makine öğrenme algoritmalarını kullanmıştır. Çalışmada, iki sınıflı uçuşlara ait geçmiş PNR kayıtları kullanılarak 3 farklı algoritma yardımıyla tahmin modelleri oluşturulmuştur. Elde edilen sonuçlar, klasik zaman serisi yaklaşımının sonuçları ile karşılaştırılmıştır. Kullanılan algoritmalarından Karar Ağacı en iyi sonucu verirken Yapay Sinir Ağı en kötü sonucu veren algoritma olmuştur. Boz vd. (2018) tarafından yapılan çalışmada, bir otelin rezervasyonlarındaki iptal oranının tahmini için makine öğrenme algoritmalarından yararlanılmıştır. Geçmiş kayıtlar kullanılarak Random Fores, Destek Vektör Makineleri, k-En Yakın Komşu ve C4.5 Karar Ağacı algoritmaları ile tahmin modelleri oluşturulmuştur. Kullanılan algoritmalarda en yüksek doğruluk oranını veren algoritma %73 ile C4.5 Karar Ağacı algoritması olmuştur. Leeuwen (2018), çalışmasında bir otelin geçmiş rezervasyon kayıtlarını kullanarak müşterilerin rezervasyonlarını iptal etme olasılıklarını tahmin etmiştir. Bu tahminde Naive Bayes, Karar Ağacı, Random Forest ve Lojistik Regresyon tahmin algoritmaları kullanılmıştır. Doğruluk, hassasiyet ve F-ölçütü değerleri açısından yapılan karşılaştırmada Random Forest yöntemi ile daha başarılı tahminler yapılabildiği görülmüştür.

Muthuraman ve Lawley (2008) tarafından medikal alanında yapılan çalışmada, hastaların rezervasyonlarına gelmeme olasılıklarını dikkate alan stokastik bir çifte rezervasyon modeli oluşturulmuş ve bu model ile ayakta tedavi edilen hastalar için bir randevu planlama politikası geliştirilmiştir. Sands vd. (2011) çifte rezervasyonlu bir klinik çizelgeleme probleminde hastaların rezervasyonlarını gerçekleştirmeme olasılıklarını Lojistik Regresyon yöntemiyle tahmin etmişlerdir. Tahmin edilen olasılık değerleri kullanılarak iki farklı yöntemle iki farklı randevu çizelgesi oluşturulmuştur. Kullanılan yöntemlerden ilki randevu başına bir hasta atayan geleneksel yöntem, ikincisi Muthuraman ve Lawley (2008) tarafından geliştirilen (hastaların gelmeme olasılıklarını dikkate alan) yöntemdir. Kullanılan ikinci çizelgeleme modeli ile birinci modele göre randevu süresi aşılmadan %12 daha fazla hastanın muayene olabileceği gösterilmiştir. Huang ve Hanauer (2014) çalışmalarında Sands vd. (2011)'e benzer şekilde geçmiş hasta kayıtlarını kullanarak Lojistik Regresyon yöntemiyle ileriye dönük tahminler yapmış ve

bu tahminler ile kapasite üzeri rezervasyon uygulamasını iyileştirmeyi amaçlamışlardır. Çalışmada tahmin edilen rezervasyonların gerçekleşme olasılıkları ile belirlenen rezervasyon limitinin başarısı, literatürde geçen iki kapasite üzeri rezervasyon yaklaşımı ile karşılaştırılmıştır. Önerilen yaklaşımla oluşturulan hasta randevu çizelgesi ile hastaların ortalama bekleme süresinin %6-8 arasında daha az, çalışanların fazla mesai miktarının %24-29 arasında daha fazla olacağı belirlenmiştir. Topuz vd. (2018) çalışmalarında bir pediatri kliniğinde hastaların rezervasyonlarına gelmeme olasılıklarının tahmini için bir metodoloji önermişlerdir. Verilerin hazırlanması, değişken seçimi ve Bayes tahmin modelinin uygulanması aşamalarından oluşan metodolojide değişken seçimi için Elastik Ağ (EN) yöntemi uygulanmıştır. Son aşamada da Bayesian Belief Network algoritması ile hastaların rezervasyonlarına gelmeme olasılıkları tahmin edilmiştir.

Literatürdeki çalışmalar incelendiğinde, kapasite üzeri rezervasyon uygulamasının çeşitli sektörlerde uygulanabildiği ve hizmet sektöründe oldukça önemli bir uygulama olduğu görülmektedir. 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 bir çifte rezervasyon modeli yaklaşımı sunulmuştur.

3. KAPASİTE ÜZERİ REZERVASYON MODELLERİ

Gelir yönetiminin bir parçası olan kapasite üzeri rezervasyon uygulaması, rezervasyonla çalışan bir firmanın mevcut kapasitesinin üzerinde rezervasyon alması işlemidir. Uygulamanın amacı, olası atıl kapasite maliyetini yapılan fazla rezervasyonlarla dengelemektir. Bu uygulama, kapasitenin kısıtlı olduğu, rezervasyonların müşterilerin gelmemesi ya da iptali ile sonuçlanabildiği, rezervasyonu olan bir müşteriye hizmet vermeyi reddetme maliyetinin nispeten düşük olduğu sektörlerde uygulanabilmektedir (Phillips, 2005, s.210).

Kapasite üzeri rezervasyon uygulaması, hizmeti reddetme maliyetinin hizmet ücretinden büyük olması durumunda anlam kazanmaktadır. Aksi halde rezervasyon limitini sonsuz olarak belirlemek mümkün olacak ve ek rezervasyon sayısı arttıkça net kazanç artmaya devam edecektir.

Farklı sektörler için özelleştirilen kapasite üzeri rezervasyon modelleri için bazı ortak yönler ve kabuller söz konusudur:

- Sabit bir kapasite için rezervasyon alınır.
- Rezervasyon alımına başlanmadan önce rezervasyon limiti belirlenir.
- Toplam rezervasyon limitine ulaşılan kadar gelen rezervasyon talepleri kabul edilir.
- Rezervasyon ücretsizdir. Rezervasyonuna gelen her müşteri hizmet ücretini öder.
- Kapasite sayısına kadar müşteri kabul edilir. Kapasitenin üzerinde gelen müşteri varsa, bu müşterilere reddetme maliyeti kadar ödeme yapılır ve bu müşteriler geri çevrilir.

Kapasite üzeri rezervasyon uygulamalarında ulaşılmak istenilen optimum durum, rezervasyonuna gelmeyecek kişi sayısının doğru oranda belirlenmesi ve bu sayede alınan kapasite üzeri rezervasyon ile birlikte sadece kapasite sayısı kadar kişinin sisteme giriş yapmasını sağlamaktır. Bu şekilde hizmet satışından elde edilen gelir en büyüklenirken maliyetler –müşteri reddetme ve atıl kapasite maliyetleri- en küçüklendiği için gerçekleşen kazanç miktarı olabilecek maksimum düzeye yaklaşır. Bu maksimum kazanç düzeyine ulaşmak için ilk adım atıl kapasite miktarını tahmin etmektir. Bu sayede tahmin edilen atıl kapasiteyi yapılacak fazla rezervasyon ile dengelemek mümkün olacaktır.

Kapasite üzeri rezervasyon modelini 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.

Denklem (3.1)'de verilen net kazancın beklenen değerinin en büyüklenmesi kapasite üzeri rezervasyon uygulamasının amaç fonksiyonunu ifade etmektedir.

$$\text{Max } E[p(\min(s(b), C) - a(s(b) - C)^+)] \quad (3.1)$$

Hesaplama kolaylığı sağlamak için Denklem (3.1)'deki $\min(s(b), C)$ ifadesi yerine $C - (C - s(b))^+$ ifadesini yazmak mümkündür. Bu durumda denklem;

$$\begin{aligned} \text{Max } E[p(C - (C - s(b))^+) - a(s(b) - C)^+] \\ \text{Max } E[pC - p(C - s(b))^+ - a(s(b) - C)^+] \end{aligned} \quad (3.2)$$

şeklinde olmaktadır. Denklem (3.2)'deki pC ifadesi sabittir. Bu sabit denklemden çıkarıldığında rezervasyon modelinin amaç fonksiyonu:

$$\text{Min } E[p(C - s(b))^+ + a(s(b) - C)^+] \quad (3.3)$$


şeklini almaktadır. Denklem (3.3)'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 büyükmek olan amacına ulaşmak için atıl kapasiteyi en küçüklemek 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 Denklem (3.3)'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 edilir ($b=C$) ve optimum değerine ulaşılan kadar b değeri birer birer arttırılır. Ulaşılan optimum b değerinin elde edilen kazancı en büyükmek 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 3.1'deki karar ağacında analiz edilmiştir.



Şekil 3.1. Rezervasyon limitindeki artışın marjinal etkisinin analizi

Şekil 3.1'deki karar ağacında b değeri $b+1$ 'e çıkartıldığında karşılaşılan ilk düğüm toplam rezervasyon talebinin mevcut rezervasyon limiti karşısındaki durumudur. Eğer toplam rezervasyon talebi D , rezervasyon limiti b 'den küçük ya da b 'ye eşitse; açılan fazla rezervasyon için herhangi bir talep olmayacak dolayısıyla bu 1 kişilik ek rezervasyondan kaynaklı herhangi bir fayda ya da maliyetle karşılaşılmayacaktır. Bu durumda b 'yi 1 arttırmanın marjinal etkisi 0 olacaktır. D değeri b 'den büyükse, ikinci bir düğüm oluşmaktadır. Bu düğüm noktasında, b kadar rezervasyon içerisinde gerçekleşen rezervasyon sayısı s 'nin kapasite (C) karşısındaki durumu analiz edilmektedir. Eğer $s(b)$ değeri, C 'den küçükse; rezervasyon limitinin $b+1$ olması ile rezervasyon yapan son müşteri ρ olasılıkla rezervasyonuna gelir ya da $(1-\rho)$ olasılıkla rezervasyonunu gerçekleştirmez. $D > b$ ve $s(b) < C$ iken rezervasyon yapan son müşterinin ρ olasılıkla rezervasyonuna gelmesi durumunda kapasite aşımı olmayacağı için firma bu müşteriden p kadar net kazanç sağlar. $D > b$ ve $s(b) < C$ iken rezervasyon yapan son müşterinin $(1-\rho)$ olasılıkla rezervasyonuna gelmemesi halinde firmanın kazancı ya da kaybı olmayacağı için bu durumun marjinal etkisi 0 olacaktır. Rezervasyon talebinin b değerinden büyük olduğu durumda $s(b) \geq C$ iken; rezervasyon yapan son müşteri ρ olasılıkla sisteme gelir ya da $(1-\rho)$ olasılıkla rezervasyonunu gerçekleştirmez. $D > b$ ve $s(b) \geq C$ iken son rezervasyon ρ olasılıkla gerçekleşirse kapasite aşımı olacağı için bir müşteri geri çevrilir ve bu müşteriye hizmeti reddetme maliyeti ödenir. Böyle bir durumun marjinal etkisini $p-t$ ile ifade etmek mümkündür. $D > b$ ve $s(b) \geq C$ iken rezervasyon yapan son müşterinin $(1-\rho)$ olasılıkla sisteme gelmemesi durumunda firmanın herhangi bir kazanç ya da kaybı olmayacağı için bu durumun marjinal etkisi 0 olur.

Kapasite üzeri rezervasyon limitinin optimum değerini belirlerken her limit arttırımında ($b \rightarrow b+1$) yukarıda açıklanan marjinal etki değerleri kullanılarak marjinal fayda ve maliyet değerleri hesaplanmalıdır. Denklem (3.4) ve Denklem (3.5)'te verilen marjinal fayda ve maliyet hesaplamalarında marjinal etkisi 0 olan durumlar dikkate alınmamıştır.

$$\text{Marjinal fayda} = P(D > b)P(s(b) < C|D > b)\rho p \quad (3.4)$$

$$\text{Marjinal maliyet} = P(D > b)P(s(b) \geq C|D > b)\rho(t - p) \quad (3.5)$$

b değeri 1 arttırıldığında alınacak son rezervasyonun sağlayacağı marjinal fayda, marjinal maliyette eşit ya da marjinal maliyetten daha yüksekse rezervasyon limiti b 'den $b+1$ 'e çekilmelidir. Aksi halde, b değeri daha fazla arttırılmamalıdır. Bu durumda, b değerini $b+1$ 'e çıkarma kararı alınırken sağlanması gereken koşulu Denklem (3.6)'daki gibi ifade etmek mümkündür:

$$\begin{aligned} P(D > b)P(s(b) < C|D > b)\rho p &\geq \\ P(D > b)P(s(b) \geq C|D > b)\rho(t - p) \end{aligned} \quad (3.6)$$

Denklem (3.6)'da verilen eşitsizlik aşağıdaki gibi ilerletilerek b değerini $b+1$ 'e çıkartmak için sağlanması gereken koşulun indirgenmiş hali Denklem (3.7)'de verilmiştir.

$$\begin{aligned} [P(s(b) < C|D > b)]p &\geq P(s(b) \geq C|D > b)(t - p) \\ [1 - P(s(b) \geq C|D > b)]p &\geq P(s(b) \geq C|D > b)(t - p) \\ P(s(b) \geq C|D > b) &\leq \frac{p}{t} \end{aligned} \quad (3.7)$$

Denklem (3.7)'deki koşul sağlanıyorsa yani toplam rezervasyon talebi mevcut rezervasyon limiti b 'den büyük iken gelen müşteri sayısının kapasiteden büyük ya da kapasiteye eşit olma olasılığı, p/t oranından küçük ya da bu orana eşitse; b değeri 1 arttırılır. Aksi halde rezervasyon limitinin arttırılması kazançtan daha fazla maliyete neden olacağı için rezervasyon limiti b olarak kalır. Rezervasyon limitinin b 'den $b+1$ 'e çıkartılması durumunda Denklem (3.7)'deki koşul sağlanmıyorsa optimum rezervasyon limitinin b 'nin mevcut değeri olduğu anlaşılmaktadır.

Rezervasyon limitinin Denklem (3.7) yardımıyla belirlenebilmesi için ilgili b değeri kadar rezervasyon içerisinden 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 içerisinden s kadar

müşterinin rezervasyonuna gelmesi olayı binom dağılımı göstermektedir. Bu nedenle klasik yaklaşımda, gelen müşteri sayısının kapasiteden büyük veya kapasiteye eşit olması olasılığının hesaplanmasında binom dağılımı kullanılmaktadır. Bu olasılık Denklem (3.8)'deki gibi hesaplanmaktadır:

$$P(s(b) \geq C | D > b) = \sum_{s=C}^b \binom{b}{s} \rho^s (1 - \rho)^{(b-s)} \quad (3.8)$$

Müşterilerin rezervasyonlarına gelme olasılıklarının sabit kabul edildiği durumda $P(s(b) \geq C | D > b)$ olasılıklarını binom dağılımı ile hesaplamak mümkündür ancak, bu çalışmada önerilen her müşteri için farklı gelme olasılıklarının kullanıldığı durumda söz konusu olasılıkların binom dağılımı ile hesaplanması zorlaşmaktadır. Bu nedenle, önerilen dinamik modelde $P(s(b) \geq C | D > b)$ olasılıklarının binom dağılımı yerine Monte Carlo simülasyonu kullanılarak hesaplanması önerilmektedir. Dinamik modelde bu olasılıklarının binom dağılımı ile hesaplanmasında karşılaşılan zorluklar ve Monte Carlo simülasyonunun önerilmesinin nedenleri Bölüm 4.2'de anlatılmıştır.

Klasik yaklaşım için Denklem (3.8)'de verilen formülasyonla $P(s(b) \geq C | D > b)$ olasılığı hesaplandıktan sonra, bu olasılık değeri kullanılarak Denklem (3.7)'deki koşulu sağlayan son b değeri belirlenmekte ve bu b değeri optimum rezervasyon limiti olmaktadır. Rezervasyon limiti belirlendikten sonra bu limit değeri için beklenen getiri miktarı Denklem (3.9) kullanılarak hesaplanabilir:

$$E[R|b] = pE[s(b)] - tE[(s(b) - C)^+] \quad (3.9)$$

Denklem (3.9)'daki $E[s(b)]$ 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.

Bu bölümde açıklanan kapasite üzeri rezervasyon yaklaşımı, çalışmada rezervasyon modeli-1 (RM-1) olarak adlandırılmıştır. Rezervasyon modeli-1 dışında, iki farklı sistem için de kapasite üzeri rezervasyon modelleri oluşturulmuştur.

Çalışmada, klasik rezervasyon uygulamasındaki değeri 0 olan farklı parametrelerin alabildikleri değerlerin genelleştirilmesiyle elde edilen iki farklı rezervasyon modeli

incelenmiş ve bu rezervasyon modellerinde amaç fonksiyonu, optimum rezervasyon limiti için eşik değeri ile beklenen getiri miktarlarının hesaplanma şekilleri açıklanmıştır.

Klasik yaklaşımda rezervasyonuna gelmeyen bir müşterinin herhangi bir ceza ödemesi gerekmemektedir. Bu durumda klasik yaklaşımda ceza parametresinin değeri 0'dır. Ceza parametresinin, farklı değerler alabilecek şekilde genelleştirilmesiyle rezervasyonuna gelmeyen müşterilerin ceza ödediği bir rezervasyon modeli elde edilmektedir ve bu model çalışmada rezervasyon modeli-2 (RM-2) olarak adlandırılmaktadır. Yine klasik yaklaşımda rezervasyonsuz gelen müşteriler sisteme kabul edilmemektedir. Dolayısıyla sisteme rezervasyonsuz gelen müşteri parametresinin değeri 0'dır. Rezervasyonsuz gelen müşteri parametresinin farklı değerler alabilecek şekilde genelleştirilmesiyle rezervasyonsuz gelen müşterilerin de sisteme kabul edildiği bir rezervasyon modeli elde edilmektedir ve bu model çalışmada rezervasyon modeli-3 (RM-3) olarak adlandırılmaktadır.

3.1. Rezervasyonuna Gelmeyen Müşterilerin Ceza Ödediği Sistem (RM-2)

Klasik kapasite üzeri rezervasyon modelinde, rezervasyonuna gelmeyen müşterilerin herhangi bir ceza ödemediği varsayılmıştır. Bu varsayımın aksine, müşterilerin rezervasyonlarını gerçekleştirmediği durumda hizmet ücretinin belirli bir tutarı kadarını firmaya ödemek zorunda olduğu sistemlerde kapasite üzeri rezervasyon modelinin nasıl uygulanabileceği bu başlık altında incelenmiştir.

Rezervasyonuna gelmeyen müşterilerin hizmet ücretinin belli bir oranında ceza ödediği bir sistemde, yapılan kapasite üzeri rezervasyonlarla elde edilen net kazancın en büyüklmesi istenmektedir. Net kazancı hesaplayabilmek için öncelikle toplam kazanç ve toplam maliyet değerleri hesaplanmalıdır. Bu modelde rezervasyonuna gelmeyen bir müşterinin ödeyeceği ceza miktarı c notasyonu ile gösterilmektedir.

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 Denklem (3.10)'da verilmiştir.

$$\text{Max } E[p(\min(s(b), C)) + c(\min(D, b) - s(b)) - a(s(b) - C)^+] \quad (3.10)$$

Denklem (3.10)'da $\min(s(b), C)$ yerine $C - (C - s(b))^+$ yazılırsa fonksiyon;

$$\text{Max } E[pC - p(C - s(b))^+ + c(\min(D, b) - s(b)) - a(s(b) - C)^+] \quad (3.11)$$


halini almaktadır. Sabit olan pC değeri fonksiyondan çıkarıldığında amaç fonksiyonu;

$$\text{Min } E[p(C - s(b))^+ - c(\min(D, b) - s(b)) + a(s(b) - C)^+] \quad (3.12)$$

olmaktadır. Denklem (3.12)'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 varsa negatiflik, biçimseldir.

Bu modelde de kapasite üzeri rezervasyon limitinin net kazancı maksimum kazanç değerine yaklaştırması istenmektedir ve bu doğrultuda kapasitenin üzerinde yapılan her rezervasyonun toplam getiriye pozitif katkı sağlaması beklenmektedir. Bu nedenle rezervasyon limitinin değeri b 'den $b+1$ 'e çıkartılırken karşılaşılabilecek olası durumlar analiz edilmeli ve marjinal fayda ile marjinal maliyet değerleri hesaplanarak rezervasyon limitindeki 1 birimlik artışın net kazanç üzerindeki etkisi ölçülmelidir.

Marjinal maliyet ve marjinal fayda değerlerinin hesaplanabilmesi için Şekil 3.1'de verilen karşılaşılabilecek olası durumların rezervasyon modeli-2 için marjinal etkileri Şekil 3.2'de verilmiştir.



Şekil 3.2. Rezervasyon modeli-2 için limitteki artışın marjinal etkisinin analizi

Toplam rezervasyon talebinin mevcut rezervasyon limiti b değerinden küçük ya da bu değere eşit olması ($D \leq b$) halinde; b değeri $b+1$ 'e çıkartıldığında açılan yeni rezervasyon için herhangi bir talep olmayacaktır, bu nedenle bu durumun net kazanca marjinal etkisi 0'dır. Eğer, toplam rezervasyon talebi mevcut rezervasyon limiti b 'den büyükse olası iki durum ile karşılaşilmektedir. $D > b$ ve b rezervasyon içerisinde gerçekleşen rezervasyon sayısı s , sistem kapasitesinden küçükse ($s(b) < C$); rezervasyon yapan son müşteri ρ olasılıkla sisteme gelir ve bu durumun marjinal etkisi p olur. Aynı şartlarda rezervasyon yapan son müşterinin $1-\rho$ olasılıkla rezervasyonuna gelmemesi halinde net kazanç üzerindeki marjinal etki müşterinin ödeyeceği ceza miktarı kadar yani c değeri kadar olacaktır. $D > b$ ve $s(b) \geq C$ iken, rezervasyon yapan son müşterinin ρ olasılıkla rezervasyonuna gelmesinin marjinal etkisi kapasite aşımından kaynaklı olarak $p-t$ kadar olacaktır. Eğer aynı şartlar altında son müşteri $1-\rho$ olasılıkla rezervasyonuna gelmezse marjinal etki yine ceza tutarı yani c kadar olacaktır. Yapılan bu analiz yardımıyla rezervasyon limitinin 1 birim arttırılmasının marjinal faydası ve marjinal maliyeti Denklem (3.13) ve Denklem (3.14) kullanılarak hesaplanmaktadır:

$$\begin{aligned} \text{Marjinal fayda} = & P(D > b)[P(s(b) < C | D > b)(\rho p + (1 - \rho)c) \\ & + P(s(b) \geq C | D > b)(1 - \rho)c] \end{aligned} \quad (3.13)$$

$$\text{Marjinal maliyet} = P(D > b)P(s(b) \geq C | D > b)\rho(t - p) \quad (3.14)$$

Denklem (3.14) kullanılarak hesaplanan, rezervasyon limitini b 'den $b+1$ 'e çıkartmanın marjinal maliyeti, Denklem (3.13) ile hesaplanan marjinal faydadan küçükse

rezervasyon limiti 1 arttırılır. Rezervasyon limitini arttırmada kontrol edilmesi gereken bu koşul, rezervasyon modeli-2 için aşağıdaki gibi ifade edilebilir:

$$\begin{aligned} P(s(b) < C|D > b)(\rho p + (1 - \rho)c) + P(s(b) \geq C|D > b)(1 - \rho)c \\ \geq P(s(b) \geq C|D > b)\rho(t - p) \end{aligned} \quad (3.15)$$

Denklem (3.15) düzenlendiğinde;

$$P(s(b) \geq C|D > b) \leq \frac{p - c}{t} + \frac{c}{\rho t} \quad (3.16)$$

eşitsizliği elde edilmektedir. Eğer Denklem (3.16)'daki koşul sağlanıyorsa rezervasyon limiti $b+1$ 'e çıkartılmalıdır, aksi halde rezervasyon limiti b olarak bırakılmalıdır.

Denklem (3.16)'daki 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 limitinin belirlenmesinde kullanılan koşulun rezervasyon talebinde bulunan müşterinin gelme olasılığına bağlı olması yapının dinamikliğini göstermektedir. Rezervasyon limiti b iken gelen herhangi bir rezervasyon talebinin Denklem (3.16)'daki 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.

Denklem (3.16)'nın hesaplanabilmesi için $P(s(b) \geq C|D > b)$ olasılığına ihtiyaç vardır. Bu olasılık değeri klasik yaklaşımda Denklem (3.8)'de verilen binom dağılımı ile hesaplanırken, önerilen dinamik model için Monte Carlo simülasyonu ile hesaplanmaktadır.

Rezervasyon modeli-2'de beklenen getiri hesabı için klasik modeldeki (Denklem 3.9) yerine Denklem (3.17)'deki eşitlik kullanılır:

$$E[R|b] = pE[s(b)] + cE[\min(D, b) - s(b)] - tE[(s(b) - C)^+] \quad (3.17)$$

Eşitlikteki $E[\min(D, b) - s(b)]$ ifadesi, rezervasyonuna gelmeyen kişi sayısının beklenen değeridir. Klasik modelden farklı olarak beklenen getiri hesabına,

rezervasyonuna gelmeyen müşterilerin ödeyeceği ceza miktarının beklenen değeri $cE[\min(D, b) - s(b)]$ de eklenmiştir

Müşterilerin rezervasyonlarını gerçekleştirme halinde ödemek zorunda kaldıkları cezanın caydırıcı etkisi olabileceği düşünülmüştür. Bu etki hesaplamalarda, müşterinin rezervasyonunu gerçekleştirme olasılığında belli bir oranda azalış olarak ifade edilmiştir. Söz konusu azalış miktarı, r notasyonu ile ifade edilen ceza tutarının hizmet ücretindeki oranına bağlı olarak belirlenmiştir.

3.2. Rezervasyonsuz Müşterilerin Kabul Edildiği Sistem (RM-3)

Çalışmada ele alınan bir diğer model, rezervasyonsuz gelen müşterilerin de sisteme kabul edildiği durumda uygulanan kapasite üzeri rezervasyon modelidir. 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 limiti belirlenirken olası rezervasyonsuz müşterileri de göz önünde bulunduran bir rezervasyon modeli oluşturulmuştur.

İncelenen bu rezervasyon modelinin amaç fonksiyonu oluşturulurken, diğer iki modelde olduğu gibi öncelikle toplam kazanç ve toplam maliyet değerleri, ardından da bu iki değer arasındaki farka eşit olan net kazanç hesaplanmalıdır. Rezervasyon yapan b kadar kişi içerisinde s kadar kişinin rezervasyonuna gelmesi halinde firmanın kazanacağı toplam miktar $p(\min(s(b), C))$ kadardır. Rezervasyonsuz gelen müşterilerden elde edilen kazanç ise atıl kapasite miktarında rezervasyonsuz müşteriye hizmet verilebileceği için $(\min(w, C - s(b)))p_w$ 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 için 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 (Denklem (3.18)).

$$\text{Max } E[p(\min(s(b), C)) + (\min(w, C - s(b)))p_w - a(s(b) - C)^+] \quad (3.18)$$

Denklem (3.18)'deki $\min(s(b), C)$ ifadesi yerine $C - (C - s(b))^+$ yazılırsa fonksiyon:


$$\text{Max } E[pC - p(C - s(b))^+ + (\min(w, C - s(b)))p_w - a(s(b) - C)^+] \quad (3.19)$$

Denklem (3.19)'daki sabit pC değeri çıkartılırsa fonsiyonun son hali;

$$\text{Min } E[p(C - s(b))^+ - (\min(w, C - s(b)))p_w + a(s(b) - C)^+] \quad (3.20)$$

şeklini almaktadır. Böylece rezervasyon modeli-3 için amaç fonksiyonu Denklem (3.20)'deki gibi ifade edilebilmektedir. Bu modelin de amacı rezervasyon modeli-1 ve rezervasyon modeli-2'de olduğu gibi belirsizlik maliyetinin en küçüklenmesidir.

Rezervasyon modeli-3 için optimum kapasite üzeri rezervasyon limitinin belirlenebilmesi için diğer modellerde olduğu gibi limit değerindeki her artışın neden olabileceği olası durumlar analiz edilmelidir. Rezervasyon limiti b 'nin $b+1$ 'e çıkartılması durumunda karşılaşılabilecek durumlar ve bu durumların rezervasyon modeli-3 için marjinal etkileri Şekil 3.3'te analiz edilmiştir.



Şekil 3.3. Rezervasyon modeli-3 için limitteki artışın marjinal etkisinin analizi

Toplam rezervasyon talebi D 'nin mevcut rezervasyon limiti b 'ye eşit ya da b 'den küçük olduğu durumda ($D \leq b$), b 'yi attırmanın marjinal etkisi 0'dır. Eğer $D > b$ ise rezervasyon limiti 1 arttırıldığında, iki olası durum söz konusu olmaktadır. $D > b$ iken b rezervasyon içerisinde gerçekleşen rezervasyon sayısı kapasiteden küçükse ($s(b) < C$), rezervasyon yapan son müşteri p olasılıkla rezervasyonuna gelir ya da $(1-p)$ olasılıkla müşteri rezervasyonunu gerçekleştirmez. Gerçekleşen rezervasyon sayısı kapasitenin altındayken rezervasyon yapan son müşterinin sisteme gelmesiyle bu müşteriden p kadar kazanç sağlanır. Ancak, bu müşterinin rezervasyonunu gerçekleştirmesi nedeniyle

sisteme rezervasyonsuz gelmesi olası bir kişiden elde edilebilecek hizmet ücreti kaybedilir. Sisteme rezervasyonsuz gelecek toplam kişi sayısının atıl kapasiteye eşit ya da atıl kapasiteden büyük olduğu durumda, b değeri $b+1$ yapılır ve son rezervasyonu yapan müşteri sisteme gelirse, rezervasyonsuz gelen bir müşteri geri çevrilmek durumunda kalınır ve bu müşteriden elde edilecek p_w kadar kazanç kaybolur. Böyle bir durum için beklenen kayıp değeri $p_w \left(P(w \geq C - s(b)) \right)$ ile hesaplanmaktadır. Bu durumda b değeri 1 arttırıldığında $D > b$ ve $s(b) < C$ iken son müşterinin rezervasyonuna gelmesinin marjinal etkisi $p - p_w \left(P(w \geq C - s(b)) \right)$ olur. $D > b$ ve $s(b) < C$ iken rezervasyon yapan son müşterinin $(1-\rho)$ olasılıkla rezervasyonuna gelmemesi halinde marjinal etki 0 olur. $D > b$ ve b rezervasyon içerisinde gerçekleşen rezervasyon sayısı kapasiteye eşit ya da kapasiteden büyük iken ($s(b) \geq C$), rezervasyon yapan son müşterinin ρ olasılıkla rezervasyonuna gelmesi halinde marjinal etki $p-t$ kadar olur. $D > b$ ve $s(b) \geq C$ iken son müşterinin $(1-\rho)$ olasılıkla rezervasyonuna gelmemesi halinde marjinal etki 0 olur.

Yapılan bu analizdeki marjinal etkiler kullanılarak rezervasyon modeli-3 için kapasite üzeri rezervasyon limitindeki 1 birimlik artışın marjinal faydası ve maliyeti Denklem (3.21) ve Denklem (3.22) kullanılarak hesaplanmaktadır:

$$\begin{aligned} \text{Marjinal fayda} &= P(D > b)P(s(b) < C | D > b)\rho \\ &[(p - p_w(P(w \geq C - s(b) | D > b, s(b) < C)))] \end{aligned} \quad (3.21)$$

$$\text{Marjinal maliyet} = P(D > b)P(s(b) \geq C | D > b)\rho(p - t) \quad (3.22)$$

Rezervasyon modeli-3 için marjinal fayda ile marjinal maliyet kullanılarak hesaplanan, rezervasyon limitinin değeri arttırılırken sağlanması gereken koşul Denklem (3.23)'te verilmiştir.

$$P(s(b) \geq C | D > b) \leq \frac{p - p_w[P(w \geq C - s(b) | D > b, s(b) < C)]}{t} \quad (3.23)$$

Denklem (3.23)'te verilen eşitsizlikteki $P(w \geq C - s(b) | D > b, s(b) < C)$ olasılığı, $s(b)$ 'nin alabileceği tüm değerler için rezervasyonsuz gelerek 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 (Denklem 3.24).

$$P(w \geq C - s(b) | D > b, s(b) < C) = \sum_{x=0}^{C-1} [P(w \geq C - x)P(s(b) = x)] \quad (3.24)$$

Denklem (3.24)'te verilen $P(w \geq C - s(b) | D > b, s(b) < C)$ olasılığı , Denklem (3.23)'te yerine yazılırsa limit arttırımında kontrol edilmesi gereken koşul Denklem (3.25)'teki hali alır:

$$P(s(b) \geq C | D > b) \leq \frac{p - p_w \sum_{x=0}^{C-1} [P(w \geq C - x)P(s(b) = x)]}{t} \quad (3.25)$$

Mevcut rezervasyon limiti b 'den $b+1$ 'e çıkartıldığında Denklem (3.25)'teki koşul sağlanıyorsa yeni rezervasyon limiti $b+1$ olmalıdır, aksi halde rezervasyon limiti b olarak kalmalıdır.

Rezervasyon modeli-3 için oluşturulan eşik değerindeki $P(s(b) \geq C | D > b)$ olasılığı, sabit olasılıklı model için binom dağılımı ile hesaplanmaktadır. Ancak, önerilen kişisel olasılıklı dinamik model için bu olasılık değerinin hesaplanmasında Monte Carlo simülasyonu kullanılmaktadır.

Çalışmada, rezervasyonsuz müşterilerin sisteme gelişlerinin Poisson (λ) dağılımına uyduğu varsayılmış ve gelme olasılıkları hesaplanırken bu dağılımdan yararlanılmıştır. Denklem (3.25)'teki $P(w \geq C-x)$ olasılığı Denklem (3.26)'da verilen Poisson dağılımının olasılık fonksiyonu kullanılarak hesaplanmıştır. Bu hesaplamalarda λ parametresi bir gün içinde rezervasyonsuz gelen ortalama kişi sayısını ifade etmektedir ve bu değer sistem kapasitesinin %10'u olarak belirlenmiştir.

$$P(k) = \frac{e^{-\lambda}(\lambda^k)}{k!} \quad (3.26)$$

Son olarak rezervasyon modeli-3 için beklenen getiri hesabı Denklem (3.27)'deki gibi formüle edilebilir:

$$E[R|b] = pE[s(b)] + p_w E[\min(w, C - s(b))] - tE[(s(b) - C)^+] \quad (3.27)$$

Denklem (3.27)'de 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 limitinin belirlenmesinde kişisel olasılıkların kullanılması önerilmektedir. Müşterilerin rezervasyonlarına gelme olasılıklarının kişisel olması rezervasyon modellerine dinamik bir yapı kazandırmaktadır. Önerilen dinamik kapasite üzeri rezervasyon modellerinde sabit olasılıklar yerine kişisel olasılıklar kullanılması bazı farklılıklar gerektirmektedir. Klasik yaklaşımda müşterilerin rezervasyonlarına gelme olasılıklarının eşit ve sabit kabul edilmesi, rezervasyon limitinin rezervasyon alımına başlanmadan önce belirlenmesine olanak sağlamaktadır. Ancak dinamik modellerde rezervasyon limiti 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. Gelen rezervasyon talebinin kabul edilebilmesi için bu rezervasyonun neden olacağı marjinal maliyetin sağlayacağı marjinal faydadan küçük olması gerekmektedir. Bu şekilde gelen her rezervasyon talebi, talepte bulunan müşterinin rezervasyonuna gelme olasılığı kullanılarak hesaplanan marjinal maliyet ile marjinal faydaya bakılarak kabul ya da ret edilmektedir. Dinamik modellerde, kabul ya da ret kararı verilirken kontrol edilen koşullardaki $P(s(b) \geq C | D > b)$ olasılığının ρ parametresinin her müşteri için farklı değer alması nedeniyle Denklem (3.8) ile hesaplanmasını zorlaştırmaktadır. Rezervasyon yapan b kadar kişi içerisinde farklı gelme olasılıklarına sahip s kadar kişinin rezervasyonuna gelme olasılığının binom dağılımı ile hesaplanabilmesi için; tüm s değerleri için tüm $\binom{b}{s}$ kombinasyonlarının ilgili ρ değerleri ile hesaplanması gerekmektedir. Ayrıca, bu hesaplamalardaki kombinasyon sayısı kapasite değeri arttıkça üssel olarak artmaktadır. Oldukça uzun ve nispeten karmaşık olan bu hesaplamalar yerine, dinamik rezervasyon modelinde b kadar kişi içerisinde s kadar kişinin rezervasyonuna gelme olasılığının Monte Carlo simülasyonu ile hesaplanması ve Monte Carlo simülasyonunda kullanılacak kişisel olasılıkların tahmini için üç farklı tahmin algoritması önerilmektedir. Kullanılan sınıflandırma ve tahmin algoritmaları ve Monte Carlo simülasyonu bir sonraki bölümde anlatılmaktadır.

4. YÖNTEMLER

Bölüm 3’te açıklanan kapasite üzeri rezervasyon modelleri için önerilen dinamik yaklaşımında kullanılan yöntemler bu başlık altında toplanmıştır. Önerilen dinamik yaklaşımında ihtiyaç duyulan müşterilerin rezervasyonlarına gelme olasılıkları geçmiş verilerden tahmin algoritmaları ile elde edilmiştir. Rezervasyona gelen müşteri sayısının kapasiteye eşit ya da kapasiteden büyük olma olasılıkları dinamik yaklaşımda Monte Carlo simülasyonu kullanılarak hesaplanmıştır.

4.1. Veri Madenciliği ile Sınıflandırma ve Tahmin

Globalleşen dünyada değişen ve gelişen ihtiyaçlara paralel olarak, kaliteli bilgiye kısa sürede ulaşmak ve bu bilginin işlevsel kullanımı önem kazanmaktadır. İhtiyaç duyulan bilgiye kısa sürede erişebilmek, bilgi birikiminin üssel artması ve bu artışın neden olduğu kirlilik nedeniyle zorlaşmıştır ancak günümüz teknolojisinin geldiği nokta itibariyle bu zorluk aşılabilmektedir. Geliştirilen makine öğrenmesi teknolojileri ile büyük boyutlu veriler içinde istenilen bilgiye erişim, bilgiler arası bağlantılar kurma, çıkarımda bulunma, analiz yapma gibi işlemler kısa sürelerde yapılabilmektedir. Bu amaçlarla kullanılan yöntemlerin tamamına ‘Veri Madenciliği’ denmektedir. Kısaca veri madenciliği ile erişimi ve kullanımı verimli bilgiler elde etmek mümkündür. Zamandan ve emekten tasarruf sağlayan çeşitli veri madenciliği teknikleri ile farklı türlerde bilgileri istenilen özellikler kapsamında işlemek olanaklı hale gelmiştir (Savaş vd., 2012).

Veri madenciliği, doğrudan bir çözüm yöntemi değil çözüm için ihtiyaç duyulan bilgilere ulaşmayı sağlayan bir teknolojidir. Veri madenciliğinin kullanıldığı problemleri dört başlık altında toplamak mümkündür:

Sınıflandırma problemi: hedef parametresi sınırlı sayıda etiketli veri içeren problemler,

Tahmin problemi: hedef parametresi sürekli değerler alabilen problemler,

Kestirim problemi: tahmin problemi olmayan ve hedef parametresi sabit değerler alan problemler,

Kümeleme problemi: hedef parametresi olmayan problemler.

Verinin belli özelliklere sahip sınıf kategorilerinden uygun olanına atanması işlemine ‘sınıflandırma’ denir. Sürekli veya kesikli değişkenlerle çalışan birçok farklı sınıflandırma algoritması mevcuttur. Algoritmaların genel çalışma prensibi, geçmiş verilerin özellik ve sınıf bilgileri kullanılarak oluşturulan sınıflandırma modeli yardımıyla

yeni verinin ait olduđu sınıfın belirlenmesi şeklindedir. Karar Ağacı, k-En Yakın Komşu, Yapay Sinir Ağı çokça kullanılan sınıflandırma algoritmalarıdır.

Tahmin problemlerinde amaç geleceğe yönelik çıkarımlarda bulunmaktır. Bu amaca ulaşmada yine geçmiş verilerden yararlanılır. Sınıflandırma problemlerinden farklı olarak ulaşmak istenilen tahmini değerler yani hedef parametre etiketli verilerden oluşmaz. Bunun yerine algoritmalar ile yapılan tahminler, sürekli değerler alabilmektedir.

Bu çalışmada, önerilen dinamik rezervasyon modellerinin rezervasyon limitlerinin belirlenmesinde ihtiyaç duyulan sınıf ve olasılık değerleri, makine öğrenme algoritmalarından Lojistik Regresyon, Naive Bayes ve Random Forest algoritmaları kullanılarak tahmin edilmiştir. Bu üç algoritmanın ortak özelliği, sınıflandırma yaparken yeni veri için belirlenen sınıfın hangi olasılıkla gerçekleşeceğini de hesaplamalarıdır. Yani bu algoritmalar, rezervasyon yapan bir müşteriyi randevusuna gelecek ya da gelmeyecek olmasına göre sınıflandırmakta ayrıca bu olayın olasılığını da tahmin etmektedir.

Doğrusal Regresyon analizi, geleceğe yönelik tahminlemelerde kullanılan bir yöntemdir. Bu yöntemde, değeri tahmin edilmek istenilen bağımlı değişkenin bağımsız bir değişken ile ilişkisi kullanılarak bir eğilim eğrisi elde edilmektedir. Bu eğri yardımıyla geleceğe yönelik tahminlerde bulunmaktadır.

Lojistik Regresyon analizi, 0 ve 1 gibi iki değer alabilen ikili bağımlı değişkenlerin modellenmesinde kullanılan bir yöntemdir. Bu yöntem, logaritmik ilerleyen logit fonksiyonunu kullanmaktadır (Denklem (4.1)). Amacı, eldeki veriler ile fonksiyon eğrisine maksimum uyumlu tahminlerde bulunabilen bir model oluşturmaktır. Bağımlı değişken ile bağımsız değişken arasındaki ilişkiyi açıklayan bu model ile öngörülme istenilen değerler tahmin edilebilmektedir.

$$\Sigma(t) = \frac{e^t}{e^t + 1} \quad (4.1)$$

Lojistik Regresyon ile sınıfı tahmin edilmek istenilen değişken için bir olasılık değeri hesaplanmaktadır. Değişkenin sınıfı belirlenirken hesaplanan olasılık değeri eşik değeri ile kıyaslanmaktadır. Olasılık değeri eşik değerinden yüksekse değişkenin sınıfı '1', küçükse değişkenin sınıfı '0' olarak atanmaktadır. Bu şekilde değişkenin hangi olasılıkla hangi sınıfta olacağı tahmin edilmektedir.

Bu çalışmada, Lojistik Regresyon ile belirlenen olasılık değerleri müşterilerin rezervasyonlarını gerçekleştirme ya da gerçekleştirme olasılıklarıdır. Geçmiş veriler kullanılarak oluşturulan modeldeki eşik değerinin altında kalan olasılıkların sınıfları '0',

eşik deęerini geen olasılıkların sınıfları ‘1’ olarak belirlenmektedir. Bu sınıflandırmada ‘0’ müşterinin rezervasyonuna gelmemesi durumunu, ‘1’ de müşterinin rezervasyonuna gelme durumunu temsil etmektedir.

Bir olayın gerekleşme olasılığının, kendinden bağımsız olarak gerekleşmiş başka bir olay ile ilişkisini kuran teoreme “Bayes Teoremi” denmektedir. Bu teoreme göre, iki olaydan ilki (A) gerekleştiğinde ikinci olayın (B) gerekleşme olasılığı $P(A/B) = [P(B/A).P(A)] / P(B)$ şeklinde hesaplanmaktadır.

Naive Bayes algoritması, Bayes teoremini temel alan bir sınıflandırma algoritmasıdır. Algoritma sınıf bilgisini tahmin etmek için eldeki verilerin özelliklerinin (etiket) frekans deęerlerini ve sınıf kategorilerinin gerekleşme olasılıklarını kullanmaktadır. Bu sayede sayısal ve sayısal olmayan veriler üzerinde uygulanabilmektedir.

Algoritmanın uygulama adımları aşağıdaki gibi sıralanabilir:

1. Sınıfı tahmin edilmek istenilen verinin özellikleri doğrultusunda ilgili etiketlerin ilgili deęerinin her sınıf kategorisi için gerekleşme olasılığı (frekansı) hesaplanır.
2. Sınıf kategorilerinin gerekleşme olasılıkları hesaplanır.
3. Tahmin edilmek istenilen senaryonun her bir sınıf kategorisi için ayrı ayrı olasılıkları 1 ve 2 adımlarındaki deęerler kullanılarak hesaplanır.
4. Bir önceki adımda hesaplanan olasılıklar ile her sınıf kategorisinin dięer kategoriler içerisinde gerekleşme olasılıkları elde edilir.

Algoritma sonucunda öngörölmek istenilen deęer, net olarak bir sınıfa atanmamaktadır. Bunun yerine lojistik regresyonda olduęu gibi verinin hangi olasılıkla hangi sınıfa ait olabileceęi bilgisine ulaşılmaktadır.

Karar ağaları, sınıflandırma problemlerinde sıka kullanılan algoritmalaradır. Temel mantığı, gemiş verilerden bazı kurallar elde ederek bir sınıflandırma modeli oluşturmaktır. Model oluşturulduktan sonra verilen herhangi bir veri setinin özellikleri doğrultusunda sağladığı koşullara uygun olan sınıf kategorisi belirlenebilmektedir. Random Forest algoritması, karar ağalarında sıka karşılaşılan aşırı öğrenme problemine engel olacak şekilde çok sayıda karar ağacı oluşturarak daha karmaşık bir sınıflandırma modeli belirlemektedir. Oluşturulan her bir karar ağacı bireysel tahminlerde bulunmaktadır. Nihai sonuca, problemin türüne göre bu karar ağalarındaki sonuçların ortalaması hesaplanarak veya en çok tekrar edileni belirlenerek ulaşılmaktadır.

Bu çalışmada ele alınan problem itibariyle algoritmanın verdiği her iki sonuç da - sınıf bilgisi ve olasılık değerleri- kullanılmaktadır.

4.1.1. WEKA ile kişisel olasılıkların tahmini

Her müşterinin, rezervasyonda alınan bazı bilgiler yardımıyla gelecek rezervasyonunu gerçekleştirme olasılığını veri madenciliği teknikleri ile tahmin etmek mümkündür. Bu aşamada üç farklı tahmin algoritması kullanılarak olasılık hesaplamaları ve sınıf tahminleri yapılmıştır.

Önerilen dinamik rezervasyon modeli için gerekli olan kişisel olasılıkların tahmin edilmesinde bir hastanenin geçmiş randevu kayıtları kullanılmıştır (http-2). 70.000 randevu kaydı içeren veri seti 13 özellikten oluşmaktadır. Tahmin edilmek istenen sınıf etiketi, hastanın randevusuna gelme ya da gelmeme bilgisini içermektedir. Veri setini oluşturan özellikler Tablo 4.1’de özetlenmiştir.

Tablo 4.1. Veri setini oluşturan özellikler

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 pazartesi 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 Alkolizm Engel durumu	0,1	0: yok, 1:var
Bilgi mesajı	0,1	0:gönderilmedi, 1:gönderildi
Sınıf bilgisi	0,1	0:hasta randevuya gelmedi, 1:hasta randevuya geldi

Tabloda verilen özelliklerden her biri sırasıyla veri setinden çıkartılarak algoritmaların sonuçları kontrol edilmiştir. Sonuç üzerinde etkisi olmayan özelliklerin tespiti için yapılan bu uygulama sonucunda veri setini oluşturan tüm özelliklerin kullanılması uygun görülmüştür.

Veri setindeki 70.000 kayıttan 50.000'i algoritmalar ile tahmin modelleri oluşturulmasında kullanılmıştır. Eğitim verisi dışında kalan 20.000 verinin, dinamik yapıdaki kapasite üzeri rezervasyon modelinin girdisi olarak kullanılmak üzere sınıf ve olasılık değerleri hesaplanmış aynı zamanda bu veri tahmin modellerinin test verisi olarak kullanılmıştır.

Gelecek rezervasyonların sınıf etiketinin (0-1) ve olasılık değerlerinin belirlenmesinde Lojistik Regresyon, Random Forest ve Naive Bayes algoritmaları açık kaynak kodlu bir makine öğrenme yazılımı olan WEKA 3.8 (Hall vd. 2009) ile uygulanmıştır.

4.2. Monte Carlo Simülasyonu

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. Klasik yaklaşımda, müşterilerin rezervasyonlarına gelme olasılıkları sabit olduğu için yapılan b kadar rezervasyon içerisinde s kadar kişinin rezervasyonuna gelme olasılığı binom dağılımı göstermektedir. Dolayısıyla, kapasite üzeri rezervasyon limitinin belirlenmesinde ihtiyaç duyulan $P(s(b) \geq C | D > b)$ olasılığı klasik yaklaşımda binom dağılımı yardımıyla Denklem (3.8)'teki gibi hesaplanabilmektedir. Ancak, her müşteri için farklı gelme olasılığı kullanılan dinamik modellerde, gelen müşteri sayısının kapasiteye eşit ya da kapasiteden büyük olma olasılığının klasik yaklaşımdaki gibi binom dağılımı yardımıyla elde edilmesi işlem yükü fazla hesaplamalar gerektirmektedir.

Örneğin, 10 kişi kapasiteli bir sistemde rezervasyon limitinin değerinin 15 olduğu varsayalım. Dinamik modelde bu 15 kişinin her birinin rezervasyonuna gelme olasılığı farklıdır. $P(s(b) \geq C | D > b)$ olasılığını hesaplamak için rezervasyonuna gelen kişi sayısının 10'a eşit ya da 10'dan büyük olma olasılıklarının hesaplanması gerekmektedir. Bu olasılıklar binom dağılımı ile hesaplanmak istenirse; 15 kişi içerisinde 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. Örneğin, 15 kişi içerisinde 10 farklı kişinin rezervasyonuna gelmesi 3003 farklı kombinasyonla mümkündür ve her bir sayı rezervasyonuna gelen farklı bir müşteriyi temsil etmek üzere (1,2,3,4,5,6,7,8,9,10) kombinasyonu, bu kombinasyonlardan sadece biridir. 15 kişi içerisinde rezervasyon yapan ilk 10 müşterinin rezervasyonuna gelme olasılığı; bu 10 müşterinin rezervasyonlarına gelme olasılıklarının çarpımı ile hesaplanmaktadır. Bu şekilde 3003 kombinasyonun her biri için hesaplanan olasılıkların toplanmasıyla 15 kişi içerisinde 10 kişinin rezervasyonuna gelme olasılığı elde edilmektedir.

10 kişi kapasiteli ve 15 kişi rezervasyon limiti olan bu örnekte 4944 farklı olasılık hesabı gerekmektedir. 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 simülasyonunun kullanılması önerilmektedir.

Monte Carlo simülasyonu, günümüzde yaygın olarak kullanılan rassal bir simülasyon modelidir. Bu yöntem, modellenen süreçteki rassal değişkenlerden kaynaklanan belirsizlik nedeniyle sürecin tahminlenmesi zor olan farklı sonuçlarının olasılıklarının tahmininde kullanılmaktadır. Diğer simülasyon modellerinde olduğu gibi bu yöntemde de amaç optimum sonuca ulaşmak değil, sistemi anlamaktır. Monte Carlo simülasyonu, tahmin modellerindeki risk ve belirsizliğin etkisini anlamayı sağlamaktadır (http-1).

Monte Carlo simülasyon yöntemi, süreçteki rassal değişkenlere herhangi bir varsayımsal olasılık dağılımıyla yaklaşmak yerine değişkenin kendi dağılımını kullanmaktadır (Wild, 1984, s.639). Her değişkenin olasılık dağılımını belirleyebilmek için yöntemde genellikle geçmiş verilerden yararlanılmaktadır. Belirlenen olasılık dağılımları ile sürecin farklı sonuç senaryolarının gerçekleşme olasılıkları tahmin edilmektedir. Monte Carlo simülasyonu, işleyişinden de anlaşılacağı üzere analitik çözümlerin olmadığı ya da fazla maliyetli ve karmaşık olduğu problemlerde kullanılmaktadır (Kavcar, 2004, s.64).

Bu çalışmada Monte Carlo simülasyonu, tahmin algoritmaları ile elde edilen kişisel olasılıklar kullanılarak uygulanmıştır. Farklı gelme olasılıklarına sahip müşterilerin her biri için 0 ile 1 arasında rastgele bir sayı atanmıştır. Eğer müşterinin gelme olasılığı atanan rastgele sayıdan büyükse müşterinin rezervasyonuna geldiği, küçükse müşterinin

rezervasyonuna gelmediği kabul edilmiştir. Rezervasyonu alınmış her müşterinin bu şekilde sınıflandırıldığı 10.000 iterasyon yapılmıştır. Farklı sayıda müşterinin rezervasyonlarını gerçekleştirme olasılıkları, iterasyonlar içindeki tekrar sayılarının 10.000'e bölünmesiyle elde edilmiştir. $P(s(b) \geq C | D > b)$ olasılığı hesaplanırken $s(b)$ değerinin C 'den b 'ye kadar alabileceği tüm değerlerin Monte Carlo simülasyonu ile elde edilen olasılıkları toplanmıştır.

Yapılan simülasyonun işleyişini anlatmak için, MATLAB üzerinde oluşturulan algoritmanın sözde kodu verilmiştir:

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 arttırma koşulu;

$b=b+1$ ve Adım 2'ye dön;

Değilse;

Optimum rezervasyon limiti b 'dir.

Yukarıda optimum rezervasyon limitini belirlerken kullanılan olasılıkların Monte Carlo simülasyonu ile nasıl elde edildiği ve bu olasılıklar ile rezervasyon limitinin nasıl belirlendiği sözde kod yardımıyla özetlenmiştir. Monte Carlo simülasyonu ile belirlenen olasılıklar çalışmada ayrıca klasik ve dinamik modeller için beklenen kazanç değerlerinin hesaplanmasında kullanılmıştır.



5. SAYISAL DENEYLER

Çalışmada incelenen kapasite üzeri rezervasyon modelleri için rezervasyon limitleri ve belirsizlik maliyetleri, MATLAB programının R2015a sürümü ile kodlanarak hesaplanmıştır. Yapılan kodlamaların temel işleyişi ve akışı bu bölümde açıklanmıştır.

Oluşturulan kodlar ile rezervasyonların gerçekleşme olasılıklarının sabit ve kişisel olduğu iki durum için kapasite üzeri rezervasyon limiti belirlenmektedir. Belirlenen rezervasyon limitleri ile beklenen ve gerçekleşen belirsizlik maliyetleri hesaplanmaktadır. Kodların işleyişinde izlenen genel adımları aşağıdaki gibi özetlemek mümkündür:

- Sabit olasılık değeri için rezervasyon limiti belirlenir.
- G günlük bir simülasyon başlatılır.
- Kişisel olasılıklar kullanılarak gerçekleştirilen 10.000 tekrarlı Monte Carlo simülasyonu ile farklı sayı ve kombinasyonlarda kişilerin rezervasyonlarını gerçekleştirme olasılıkları belirlenir.
- Kişisel olasılıklar ve Monte Carlo simülasyonunun çıktıları kullanılarak günlük optimum rezervasyon limitleri belirlenir.
- Her gün için sabit olasılıkla ve kişisel olasılıklarla belirlenen rezervasyon limiti kadar rezervasyon alındığı varsayılır ve bu rezervasyonlardan kaç tanesinin hangi olasılıkla gerçekleşeceği Monte Carlo simülasyonunun sonuçlarından elde edilir.
- Monte Carlo simülasyonu sonucunda belirlenen olasılıklar ile G günlük simülasyonun her günü için belirlenen günlük rezervasyon limiti doğrultusunda beklenen belirsizlik maliyetleri hesaplanır.
- Belirlenen rezervasyon limitleri için gerçek sınıf (0-1) verileri kullanılarak her gün için gerçekleşen belirsizlik maliyetleri hesaplanır.
- Sabit ve kişisel olasılıklı iki durum için G günün sonunda elde edilen toplam belirsizlik maliyetleri hesaplanır.

Rezervasyon limitleri belirlenirken kullanılan rezervasyon modelinin rezervasyon limitini arttırma koşulu dikkate alınmıştır.

Monte Carlo simülasyonu bir önceki bölümde açıklandığı gibi işleyecek şekilde kodlanmıştır. Simülasyonun çıktısı, rezervasyon limiti kadar satır ve iki sütundan oluşan bir matris şeklindedir. İlk sütunda 0'dan rezervasyon limitine kadar sayılar yer

almaktadır. Bu sayılar, bir gün için yapılan rezervasyonlar içinden gerçekleşecek rezervasyon sayısını ifade etmektedir. İkinci sütundaki değerler de ilk sütundaki sayı kadar kişinin rezervasyonuna gelme olasılığını göstermektedir.

Çalışmada incelenen rezervasyon modellerinin amaç fonksiyonları belirsizlik maliyetlerinin minimizasyonudur. Bu amaç fonksiyonlarının değerleri hesaplanırken elde edilebilecek en büyük getiri miktarından beklenen ve gerçekleşen getiri miktarı çıkartılmış ve böylece belirsizlik maliyetinin beklenen ve gerçekleşen 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 kapasitenin tamamı kullanılır ve firma, hiçbir müşteriyi reddetmek zorunda kalmadığı için bir maliyete katlanmaz. 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.

Çalışmada incelenen üç farklı rezervasyon modeli için beklenen getiri miktarlarının formülasyonları Bölüm 3'teki ilgili kısımlarda açıklanmıştır. Her model için açıklanan şekilde hesaplanan beklenen getiri miktarı, en büyük kazanç miktarından çıkartılarak beklenen belirsizlik maliyetinin değeri elde edilmiştir. Kod ile belirlenen rezervasyon limiti için gerçek veriler kullanılarak hesaplanan kazanç miktarının maksimum kazanç miktarından çıkartılmasıyla da gerçekleşen belirsizlik maliyeti hesaplanmıştır. Bu şekilde belirlenen amaç fonksiyonunun tahmin edilen ve gerçekleşen değerleri kullanılarak bir sonraki bölümde açıklanan karşılaştırma testleri yapılmıştır.

5.1. Karşılaştırma Testleri

Çalışmada önerilen kişisel olasılıklı kapasite üzeri rezervasyon modellerinin sabit olasılıklı modele göre başarısını ölçmek için karşılaştırma testleri yapılmıştır. Kişisel olasılıkların farklı şekillerde elde edildiği iki karşılaştırma testi kullanılmıştır. İlk karşılaştırma testinde kişisel olasılıklar rassal olarak türetilirken ikinci karşılaştırma testinde gerçek hayat verileriyle tahmin edilen olasılık değerleri kullanılmıştır.

Kişisel olasılıkların rassal olarak türetildiği birinci karşılaştırma testinde 100 günlük ve 1000 günlük olmak üzere iki farklı simülasyon ile karşılaştırmalar yapılmıştır. Gerçek hayat verilerinin kullanıldığı ikinci karşılaştırma testinde ise, eldeki verinin boyutunun 100 gün için yeterli olması nedeniyle 100 günlük bir simülasyonla farklı ve sabit olasılıklı rezervasyon modelleri karşılaştırılmıştır. İki karşılaştırma testinin 100

günlük simülasyonları, rassal ve tahmini olasılıklarla çalışılan rezervasyon modellerini karşılaştırmaya olanak sağlamıştır. Ek olarak, rassal olasılıklar ile yapılan 1000 günlük simülasyon ile klasik ve dinamik rezervasyon modellerinin karşılaştırılmasının daha gerçekçi olduğu düşünülmektedir.

Karşılaştırma testlerinde 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 ve buna bağlı olarak rezervasyon yapan kişilerin rezervasyonlarına gelmeme olasılığındaki azalış oranı %12.5 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 rezervasyonunu gerçekleştirme olasılığı) 0.795 olarak belirlenmiştir. Bu değer, tahmin algoritmalarında kullanılan eğitim verisindeki rezervasyonunu gerçekleştiren kişi yüzdesidir.

Kişisel olasılıkların kullanıldığı dinamik rezervasyon modellerinin sabit olasılık kullanan klasik rezervasyon modeline kıyasla sağladığı faydayı ölçmek için Bölüm 3'te açıklanmış ilgili amaç fonksiyonları kullanılmıştır. Belirsizlik maliyetinin minimizasyonu şeklinde ifade edilmiş amaç fonksiyonlarının değerleri, kişisel ve sabit olasılık değerleri kullanılarak belirlenmiş rezervasyon limitleri için hesaplanmıştır. Bu şekilde hesaplanan belirsizlik maliyetleri karşılaştırılarak, kişisel olasılıklarla belirlenen rezervasyon limitinin sağladığı fayda ölçülmüştür.

Karşılaştırmada kullanılan belirsizlik maliyetleri:

E_1 : kişisel olasılık değerleri ile belirlenen b değeri kullanılarak hesaplanmış beklenen belirsizlik maliyeti

E_2 : sabit olasılık değeri ile belirlenen b değeri kullanılarak hesaplanmış beklenen belirsizlik maliyeti


olmak üzere E_1 ve E_2 ile ifade edilmiştir. Dinamik ve klasik rezervasyon modellerini karşılaştıran bu testler, çalışmada incelenen 3 farklı rezervasyon sistemi için uygulanmıştır.

5.1.1. Rassal atanan kişisel olasılıklar ile karşılaştırma testi


Bu karşılaştırmada, farklı olasılıklı durum için her hastanın rezervasyonuna geliş olasılığı, ortalaması sabit olasılık değerine (0.795) eşit olan düzgün dağılım ile 0.99 ile

0.60 arasında türetilmiştir. Rassal olasılıklar kullanılarak diğer parametrelerin sabit tutulduğu 100 günlük ve 1000 günlük karşılaştırmalar yapılmıştır. Bu karşılaştırmalarda her gün için, rezervasyonu olan ve kapasitenin üzerinde rezervasyon talebinde bulunan her hastaya farklı bir gelme olasılığı atanmıştır. Bu olasılıklar ile her gün için farklı rezervasyon limitleri hesaplanmıştır. Belirlenen limitler doğrultusunda alınan rezervasyonlar ile belirsizlik maliyetinin beklenen değerleri hesaplanmıştır. Bu değerler, sabit olasılıklı rezervasyon modelinin beklenen belirsizlik maliyeti ile karşılaştırılmıştır.


Rassal olasılıklar kullanılarak yapılan 100 kişi kapasiteli 100 günlük simülasyonların sonucunda her gün için farklı bir rezervasyon limiti belirlenmiştir. Çalışmada incelenen üç farklı rezervasyon modeli için farklı ve sabit olasılıklar ile belirlenen rezervasyon limitleri aşağıdaki grafiklerde verilmiştir.



Şekil 5.1. Rezervasyon modeli-1 için 100 günlük rezervasyon limitleri



Şekil 5.2. Rezervasyon modeli-2 için 100 günlük rezervasyon limitleri



Şekil 5.3. Rezervasyon modeli-3 için 100 günlük rezervasyon limitleri

Bu grafiklerde b_1 değeri kişisel olasılıklar ile belirlenen günlük rezervasyon limitlerini, b_2 sabit olasılık ile belirlenen günlük rezervasyon limitlerini göstermektedir. Rezervasyonun gerçekleşme olasılığını rezervasyon yapan kişiden bağımsız olarak ele alan sabit olasılıklı rezervasyon modelleri için belirlenen rezervasyon limitlerinde değişiklik olmadığı görülmektedir. Bunun tersine, her üç rezervasyon modelinde de kişisel olasılıklar kullanıldığında belirlenen rezervasyon limitleri farklılık

göstermektedir. Rezervasyon limitinde kişisel olasılık kullanımının sağladığı bu değişkenlik, beklenen getiriye maksimum kazanca yaklaştırmaktadır. Belirlenen bu rezervasyon limitleri ile 100 günün sonunda her üç model için hesaplanan toplam belirsizlik maliyetleri ve dinamik modelin klasik yaklaşıma kıyasla sağladığı fayda miktarları aşağıdaki tabloda verilmiştir.

Tablo 5.1. 100 günlük simülasyon sonuçları

	E_1	E_2	Fayda
Rezervasyon modeli-1	11277	11634	357
Rezervasyon modeli-2	-47340	-45440	1900
Rezervasyon modeli-3	2097	4246	2149

Tablo 5.1’de 100 günlük simülasyon sonucunda önerilen kişisel olasılıklı rezervasyon modellerinin beklenen belirsizlik maliyetinin (E_1) sabit olasılıklı modellerin beklenen belirsizlik maliyetinden (E_2) daha düşük olduğu görülmektedir. Dinamik modelin sabit olasılık kullanan klasik modele kıyasla 100 günde sağladığı fayda miktarı; rezervasyon modeli-1 için 357 birim, rezervasyon modeli-2 için 1900 birim ve rezervasyon modeli-3 için 2149 birim olmuştur. Rezervasyon limitlerinin kişisel olasılıklar kullanılarak belirlenmesi ile sabit olasılık kullanımına göre fayda miktarı kadar daha düşük maliyet sağlanmıştır.

Rassal olarak belirlenen kişisel olasılıkların kullanıldığı durum ile sabit olasılıklı durumun karşılaştırıldığı 1000 günlük simülasyonun sonuçları Tablo 5.2’de verilmiştir.

Tablo 5.2. 1000 günlük simülasyon sonuçları

	E_1	E_2	Fayda
Rezervasyon modeli-1	113260	118780	5520
Rezervasyon modeli-2	-477000	-458670	18330
Rezervasyon modeli-3	21204	47923	26719

Tablo 5.2’deki değerler incelendiğinde, kişisel olasılıkların kullanımı ile rezervasyon modelleri için sağlanan fayda miktarları sırasıyla; 5520 birim, 18330 birim ve 26719 birim olmuştur.

Rassal olasılıklar kullanılarak yapılan 100 ve 1000 günlük simülasyon sonuçları, önerilen dinamik modellerin sağladığı faydanın kendi içinde tutarlı olduğunu göstermektedir. Bu durumda, farklı olasılık kullanımı ile en fazla faydanın rezervasyon modeli-3 için elde edildiği görülmektedir.

5.2. Hastane Randevu Sistemi Üzerine Bir Uygulama: Tahmin Edilen Kişisel Olasılıklar ile Karşılaştırma Testi

Bu karşılaştırmada kişisel olasılıklar bir hastanenin randevu sistemine ait geçmiş veriler kullanılarak tahmin algoritmaları ile belirlenmiştir. Algoritmalar ile tahmin edilen rezervasyonların gerçekleşme olasılıkları kullanılarak hesaplanan rezervasyon limiti için beklenen belirsizlik maliyetleri, sabit olasılık ile hesaplanan değerler ile karşılaştırılmıştır. Bu modelde de sabit olasılık değeri 0.795 olarak alınmıştır.

Bu testte eldeki gerçek veriler kullanılarak belirsizlik maliyetlerinin gerçek değerleri hesaplanmıştır. Böylelikle belirsizlik maliyetlerinin beklenen değerlerinin yanısıra gerçekleşen değerleri de karşılaştırılmıştır. Belirsizlik maliyetlerinin gerçekleşen değerleri üzerinden yapılan karşılaştırmada;

E_1^* : farklı olasılık değerleri ile belirlenen b değeri için gerçekleşen belirsizlik maliyeti

E_2^* : sabit olasılık değeri için belirlenen b değeri için gerçekleşen belirsizlik maliyeti

olarak tanımlanan iki değer kullanılmıştır. Gerçekleşen belirsizlik maliyetlerini ifade eden bu iki değer hesaplanışında kişisel olasılıkların algoritmalar ile tahmininde kullanılan test verisi kullanılmıştır. Oluşturulan algoritma ile belirlenen rezervasyon kapasitesi için gerçek rezervasyon sonuçları (0-1 sınıf değerleri) kullanılarak gerçekleşen belirsizlik maliyetleri hesaplanmıştır.

Rezervasyon modeli-1 ve rezervasyon modeli-3 için yapılan karşılaştırmalarda kullanılmak üzere; belirsizlik maliyetlerinin beklenen değerleri E_1 ve E_2 kullanılarak R_1 değeri ve belirsizlik maliyetlerinin gerçekleşen değerleri E_1^* ve E_2^* kullanılarak R_2 değeri hesaplanmıştır. Bu oran değerleri, dinamik modellerin klasik modele kıyasla amaç fonksiyonunun değerinde sağladıkları iyileşmeyi ifade etmektedir.

$$R_1 = (E_2 - E_1)/E_1 \times 100 \quad (5.1)$$

$$R_2 = (E_2^* - E_1^*)/(E_1^*) \times 100 \quad (5.2)$$

Ancak rezervasyon modeli-2 için hesaplanan belirsizlik maliyetlerinin negatif değerler alabilmesi nedeniyle bu model için yapılan karşılaştırmalarda Denklem (5.1) ve Denklem (5.2)'deki oran değerleri kullanılmamıştır. Rezervasyon modeli-2 için dinamik modelin sağladığı fayda, belirsizlik maliyetleri arasındaki uzaklık hesaplanarak belirlenmiştir.

Bu karşılaştırma testinde yukarıda açıklanan 4 farklı maliyet değerine ek olarak E^* olarak gösterilen bir başka belirsizlik maliyeti de hesaplanmıştır. Bu değer hesaplanışında rezervasyon limiti, tahmin edilen olasılık değerleri yerine tahmin edilen sınıf değerleri kullanılarak doğrudan belirlenmiştir. Yani, rezervasyon talebinde bulunan kişinin rezervasyonuna gelme ya da gelmeme durumu tahmin edilen sınıf kategorisine göre belirlenmiş ve bu bilgiler doğrultusunda rezervasyon limiti hesaplanmıştır. Tahmini sınıf değerleri ile belirlenen rezervasyon limiti için yine gerçek hayat verileri kullanılarak kazanç miktarı hesaplanmış ve bu kazanç sonucu açığa çıkan belirsizlik maliyeti hesaplanmıştır.

Kişisel olasılıkların tahmininde Bölüm 4.1'de anlatılan üç farklı makine öğrenme algoritması kullanılmıştır. Söz konusu üç algoritmadan elde edilen farklı kişisel olasılık değerleri ile rezervasyon limitleri ve belirsizlik maliyetleri hesaplanmıştır. Sabit parametre değerleri ($C=100$, $p=60$, $t=80$) ile yapılan 100 günlük simülasyonların sonuçları aşağıdaki tablolarda özetlenmiştir.

Tablo 5.3. *Rezervasyon modeli-1 için simülasyon sonuçları*

	Naive Bayes	Random Forest	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
E^*	86700	84120	110280

Tablo 5.3'teki sonuçlar incelendiğinde rezervasyon modeli-1 için kişisel olasılıkların kullanımı ile daha düşük maliyetlere ulaşıldığı ve Random Forest algoritması ile yapılan olasılık tahminleriyle daha başarılı sonuçlar elde edildiği görülmektedir.

Çalışmada incelenen diğer iki rezervasyon sistemi için de aynı karşılaştırma testi tekrarlanmıştır. Elde edilen sonuçlar Tablo 5.4 ve Tablo 5.5 ile özetlenmiştir.

Tablo 5.4. *Rezervasyon modeli-2 için simülasyon sonuçları*

	Naive Bayes	Random Forest	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
E^*	25230	22290	51240

Rezervasyon modeli-2 için belirsizlik maliyetleri oran değerleri yerine d_1 ve d_2 olarak adlandırılan uzaklık değerleri ile karşılaştırılmıştır. Beklenen belirsizlik maliyetleri arasındaki uzaklık d_1 ve gerçekleşen belirsizlik maliyetleri arasındaki uzaklık d_2 ile ifade edilmiştir. Tablo 5.4'teki değerler incelendiğinde, kişisel olasılıklar kullanılarak daha fazla kazanç elde edilebildiği ve yine Random Forest algoritması ile tahmin edilen olasılıklarla daha yüksek faydalar sağlandığı görülmektedir.

Tablo 5.5. *Rezervasyon modeli-3 için simülasyon sonuçları*

	Naive Bayes	Random Forest	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
E^*	39660	43740	53520

Rezervasyonsuz gelen müşterilerin de sisteme kabul edildiği durumu ifade eden 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; Naive

Bayes algoritması ile %2.20, Random Forest algoritması ile %16.50 ve Lojistik Regresyon algoritması ile %3.90 olarak hesaplanmıştır. Tablo 5.5 incelendiğinde yine Random Forest algoritması ile hesaplanan kişisel olasılıklarla yapılan hesaplamaların nispeten daha başarılı sonuçlar verdiği görülmektedir.

5.2.1. Tahmin modellerinin performans ölçümü

Çalışmada, müşterilerin rezervasyonlarını gerçekleştirme olasılıklarının ve rezervasyon sonuçlarının tahmininde kullanılan algoritmaların sınıflandırma başarısını değerlendirmek için performans ölçümü yapılmıştır. Söz konusu performans ölçümü için doğruluk oranı, Kappa istatistiği, kesinlik, duyarlılık, F-ölçütü ve ROC eğrisinin altında kalan ifade eden ROC Area kriterlerinden yararlanılmıştır.

Algoritmalar ile yapılan sınıflandırmanın sonuçları; doğru pozitif (*DP*), yanlış pozitif (*YP*), doğru negatif (*DN*) ve yanlış negatif (*YN*) olmak üzere dört kümeye ayrılmaktadır. Yapılan sınıflandırmanın uygun olduğu küme Tablo 5.6’da gösterildiği gibi belirlenmektedir.

Tablo 5.6. Sınıflandırma sonuçlarının analizi

		Tahmini Sınıf	
		Sınıf = 0	Sınıf = 1
Gerçek Sınıf	Sınıf = 0	DN	YN
	Sınıf = 1	YP	DP

Performans ölçüm kriterlerinden doğruluk; doğru sınıflandırılmış örnek sayısının (*DN+DP*) toplam örnek sayısına (*DN+YN+YP+DP*) oranıdır (Denklem (5.3)).

$$\text{Doğruluk} = \frac{DN + DP}{DN + YN + YP + DP} \quad (5.3)$$

Kesinlik ölçütü; doğru pozitif örnek sayısının, sınıfı 1 olarak belirlenmiş toplam örnek sayısına (*YN+DP*) oranıdır (Denklem (5.4)).

$$\text{Kesinlik} = \frac{DP}{YN + DP} \quad (5.4)$$

Duyarlılık ölçütü; doğru sınıflandırılmış pozitif örnek sayısının (DP), toplam pozitif örnek sayısına ($DP+YP$) oranıdır (Denklem (5.5)).

$$\text{Duyarlılık} = \frac{DP}{DP + YP} \quad (5.5)$$

Kesinlik ve duyarlılık ölçütlerini bir arada değerlendirmeyi sağlayan F -ölçütü, bu iki değerin harmonik ortalamasıdır (Denklem (5.6)).

$$F - \text{Ölçütü} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5.6)$$

İkili sınıflandırmada, verinin sınıfının belirlenebilmesi için bir eşik değerine ihtiyaç duyulmaktadır. Eşik değerinin alacağı farklı değerler, farklı sınıflandırmalara neden olacağı için tek bir eşik değeri belirlemek yerine eşik değerlerinin alabileceği değerlere karşılık doğru sınıflandırma başarısını ifade eden ROC eğrilerinden yararlanılmaktadır. ROC eğrisi; dikey ekseninde doğru pozitiflerin (duyarlılık) yatay ekseninde ise yanlış pozitiflerin (1-özgüllük) oranlarının yer aldığı bir eğridir. Bu eğri üzerindeki her bir nokta farklı bir eşik değerine karşılık gelen duyarlılık ve (1-özgüllük) oranlarını ifade etmektedir. Sınıflandırmanın başarısı, ROC eğrisinin altında kalan alan ile ölçülmektedir. Bu alan değeri ne kadar büyükse, sınıflandırma da o ölçüde başarılıdır. ROC eğrisini oluşturmada kullanılan özgüllük değeri; doğru negatiflerin, sınıfı 0 olarak belirlenen toplam örnek sayısına oranıdır (Denklem (5.7)).

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (5.7)$$

ROC Area değerinin 1'e yaklaşması pozitif örneklerin negatif örneklerden daha iyi ayrıldığı anlamına gelmektedir.

Kappa istatistiği; iki veya daha fazla gözlemcinin yaptığı değerlendirmeler arasındaki uyumu ölçmekte kullanılmaktadır. Bu uyum hesaplanan Kappa katsayısı ile ifade edilmektedir (Denklem (5.8)). Kappa katsayısı hesaplanırken $Pr(a)$ ve $Pr(e)$ ile gösterilen iki olasılık kullanılmaktadır. $Pr(a)$; iki gözlemci arasındaki uyumun toplam orantısını, $Pr(e)$ ise gözlemciler arasındaki uyumun şansa bağlı olarak ortaya çıkma olasılığını ifade etmektedir (Kılıç, 2015). Bu iki olasılık kullanılarak Kappa katsayısı aşağıdaki denklem ile hesaplanmaktadır.

$$\kappa = \frac{Pr(a) - Pr(e)}{1 - Pr(e)} \quad (5.8)$$

Kappa katsayısı, (-1) ile (+1) arasında değer almaktadır. (-1) değeri, gözlemcilerin değerlendirmelerinin tamamen zıt olduğu, (+1) değeri de gözlemcilerin tamamen uyumlu değerlendirmelerde bulunduğu anlamına gelmektedir. Kappa katsayısının (0) değerini alması ise, gözlemciler arasındaki uyumun tamamen şansa bağlı olarak ortaya çıktığı anlamına gelmektedir.

Yukarıda açıklanan ölçütler, Lojistik Regresyon, Naive Bayes ve Random Forest algoritmaları için çalışmada kullanılan test verisi üzerinden WEKA 3.8 yazılımı ile hesaplanmıştır. Elde edilen sonuçlar Tablo 5.7’de verilmiştir.

Tablo 5.7. Algoritmaların performans ölçüm değerleri

	Lojistik Regresyon	Random Forest	Naive Bayes
Doğruluk Oranı	0.794	0.788	0.778
Kappa İstatistiği	0.017	0.127	0.059
Kesinlik	0.713	0.737	0.708
Duyarlılık	0.794	0.788	0.778
F-Ölçütü	0.712	0.743	0.724
ROC Area	0.662	0.717	0.656

Tabloda verilen değerler incelendiğinde, doğruluk oranları birbirine yakın değerlerdir. Lojistik Regresyon diğer algoritmalarla kıyasla biraz daha yüksek bir doğrulukla sınıflandırma yapmıştır. Kappa katsayılarına bakıldığında her üç algoritmanın da sifıra yakın değerler aldığı görülmektedir. Bu durumda, algoritmaların doğru sınıflandırmalarını şans eseri yaptığı yorumu getirilebilir. Kappa katsayılarının sifıra yakın çıkmasının nedenini de verinin rassallığı ile açıklamak mümkündür. En yüksek duyarlılık oranını 0.794 ile Lojistik Regresyon vermiştir. Kesinlik, F-ölçütü ve ROC Area değerlerine bakıldığında da Random Forest algoritmasının daha iyi sonuçlar verdiği görülmektedir. Tablo genel olarak yorumlandığında, üç algoritmanın sonuçları birbirine oldukça yakın değerler içermektedir ve verilerin rassallığından kaynaklı olarak Kappa katsayıları sifıra yakın değerler almaktadır. Sonuç olarak, algoritmaların sınıflandırma başarıları arasında ciddi farklar görülmemektedir.

5.3. Duyarlılık Analizi

Çalışmada incelenen üç farklı rezervasyon sisteminde kişisel olasılıklar kullanan dinamik model ve sabit olasılık kullanan klasik model ile hesaplanan belirsizlik maliyetlerinin farklı parametre değerleri için verdikleri sonuçlar yapılan duyarlılık analizleriyle incelenmiştir. Bu analizlerde incelenen üç rezervasyon modeli için ortak olarak kullanılan parametreler ve aldıkları değerler aşağıdaki tabloda özetlenmiştir:

Tablo 5.8. *Duyarlılık analizlerinde kullanılan parametreler ve değerleri*

Parametre	Değerler
Hizmet ücreti (p) (birim ücret)	30, 45, 60
Reddetme maliyeti (t) (birim ücret)	80, 100, 120
Sistem kapasitesi (C) (kişi sayısı)	10, 20, 50, 100

Hizmet ücretinin ve hizmeti reddetme maliyetinin aldığı değerler, karşılaştırma testlerinde sabit kabul edilen parametre değerleri olan 60 ve 80 birim ücret üzerinden belirlenmiştir. Hizmet ücretinin değeri %25 ve %50 oranlarında azaltılarak 30 ve 45 değerleri; reddetme maliyetinin değeri %25 ve %50 oranlarında artırılarak da 100 ve 120 değerleri elde edilmiştir. Duyarlılık analizleri, t' nin p' den büyük olduğu ikili değerler için yapılmıştır.

Çalışmada önerilen ikinci rezervasyon modelinin duyarlılık analizinde Tablo 5.8'de verilen parametrelerin dışında n parametresi de kullanılmıştır. Rezervasyonuna gelmeyen müşterinin ödeyeceği ceza miktarını ifade eden c parametresinin değeri, yine sabit hizmet ücretinin (60 birim ücret) farklı oranları olarak belirlenmiştir. Ceza tutarının oranına bağlı olarak belirlenen müşterinin rezervasyonuna gelmeme olasılığındaki azalış oranı da c parametresinin değerleri ile birlikte Tablo 5.9'da verilmiştir:

Tablo 5.9. *Model-2 için duyarlılık analizi parametre değerleri*

Ceza oranı (r)	Ceza tutarı (c)	Azalış oranı
%20	12,5	%5
%50	30	%12,5
%80	48	%20

Karşılaştırma testlerinde olduğu gibi duyarlılık analizleri de rassal atanan olasılıklar ve tahmin algoritmaları ile belirlenen olasılıklar kullanılarak iki farklı şekilde yapılmıştır.

5.3.1. Rassal olasılık değerleri ile duyarlılık analizleri

Bu analizde, dinamik modellerde kullanılan kişisel olasılıklar rassal olarak türetilerek farklı parametre değerleri için belirsizlik maliyetlerinin beklenen değerleri hesaplanmıştır. Rassal veriler kullanılması nedeniyle belirsizlik maliyetlerinin gerçekleşen değerleri (E_1^* ve E_2^*) hesaplanamamıştır. Bu nedenle sadece R_1 oranındaki değişim incelenmiştir.

Çalışmada ele alınan üç farklı rezervasyon modeli için elde edilen sonuçlar aşağıdaki tablolarda özetlenmiştir.

Tablo 5.10. *Model-1 için rassal olasılıklar ile duyarlılık analizi*

	p,t	E_1	E_2	R_1
C=10	60,120	6334	6649	4.97
	60,100	5352.7	5511.3	2.96
	60,80	3703.5	3913.9	5.68
	45,80	4232.7	4536.9	7.19
	30,80	3836.7	3948.5	2.92
C=20	60,120	9138.2	9493.2	3.88
	60,100	7536.8	7962.6	5.65
	60,80	5123.5	5392.8	5.26
	45,80	6083	6321.5	3.92
	30,80	5670.5	5881.8	3.73
C=50	60,120	14531	15309	5.36
	60,100	12028	12609	4.84
	60,80	8064.1	8391.9	4.06
	45,80	9713.4	10192	4.92
	30,80	9039.9	9352.6	3.46
C=100	60,120	20765	21491	3.50
	60,100	16841	17451	3.62
	60,80	11277	11634	3.17
	45,80	13697	14271	4.19
	30,80	12951	13426	3.66

Rezervasyon modeli-1 için rassal olasılıklar kullanılarak yapılan duyarlılık analizleri incelendiğinde, parametre değerlerindeki değişimle R_1 değerlerindeki değişim arasında herhangi bir örüntü olmadığı görülmektedir.

Rezervasyon modeli-1 için yapılan analizler, rezervasyon modeli-2'deki ceza oranı parametresinin üç farklı değeri için tekrarlanmıştır. Tablo 5.11 ile Tablo 5.14 arasında rezervasyon modeli-2 için yapılan duyarlılık analizlerinin sonuçları verilmiştir. Karşılaştırma testlerinde olduğu gibi duyarlılık analizlerinde de rezervasyon modeli-2 için dinamik modelin sağladığı fayda, oran değeri yerine uzaklık değeri ile ölçülmüştür.

Tablo 5.11. Model-2 için rassal olasılıklar ile duyarlılık analizi ($r=0.2$)

	p,t	E_1	E_2	d_1
C=10	60,120	3365.90	3548.50	182.60
	60,100	2282.00	2593.70	311.70
	60,80	569.56	762.07	192.51
	45,80	2017.90	2404.20	386.30
	30,80	2363.00	2592.50	229.50
C=20	60,120	3307.60	3772.90	465.30
	60,100	1682.30	1949.90	267.60
	60,80	-774.27	-418.02	356.26
	45,80	1652.00	1828.30	176.30
	30,80	2723.40	2916.10	192.70
C=50	60,120	514.98	1449.20	934.22
	60,100	-2378.90	-1848.90	530.00
	60,80	-6251.70	-5778.90	472.80
	45,80	-967.19	-214.89	752.30
	30,80	2014.50	2543.10	528.60
C=100	60,120	-7357.20	-6052.70	1304.50
	60,100	-11440.00	-10162.00	1278.00
	60,80	-17280.00	-16797.00	483.00
	45,80	-7471.90	-6592.20	879.70
	30,80	-1096.60	-523.85	572.75

Tablo 5.11'deki değerler incelendiğinde yine parametre değerlerindeki değişim ile d_1 değerleri arasında doğrudan bir ilişki görülmemektedir.

Tablo 5.12. *Model-2 için rassal olasılıklar ile duyarlılık analizi ($r=0.5$)*

	p,t	E_1	E_2	d_1
C=10	60,120	148.28	255.27	107.00
	60,100	-1038.40	-529.29	509.11
	60,80	-2911.00	-2716.40	194.60
	45,80	-429.39	-397.01	32.38
	30,80	714.68	1127.00	412.32
C=20	60,120	-2937.40	-2725.20	212.20
	60,100	-4812.80	-4588.10	224.70
	60,80	-7352.80	-6900.40	452.40
	45,80	-3074.60	-2618.50	456.10
	30,80	-576.20	-100.32	475.88
C=50	60,120	-15188.00	-13910.00	1278.00
	60,100	-17408.00	-16235.00	1173.00
	60,80	-22100.00	-21501.00	599.00
	45,80	-12542.00	-11236.00	1306.00
	30,80	-5721.20	-4725.70	995.50
C=100	60,120	-37221.00	-33290.00	3931.00
	60,100	-41992.00	-38759.00	3233.00
	60,80	-47614.00	-45737.00	1877.00
	45,80	-30400.00	-28109.00	2291.00
	30,80	-16003.00	-12023.00	3980.00

Ceza oranı parametresinin %50 değeri için yapılan analizlerde dinamik model ile sağlanan faydanın parametrelerdeki değişimlerle orantılı olmadığı Tablo 5.12’de görülmektedir. Bunun yanı sıra, Tablo 5.11 ile Tablo 5.12’deki d_1 değerleri karşılaştırıldığında, $r=0.5$ değeri ile dinamik model ile sağlanan faydanın $C=50$ ve $C=100$ için $r = 0.2$ değerine kıyasla çoğunlukla daha fazla olduğu görülmektedir.

Çalışmada rezervasyon modeli-2’de r parametresinin için belirlenen değerlerden üçüncü ve sonuncusu %80’dir. Ceza tutarının hizmet ücretinin %80’i olduğu durumlar için yapılan duyarlılık analizlerinin sonuçları Tablo 5.13’te verilmiştir.

Tablo 5.13. *Model-2 için rassal olasılıklar ile duyarlılık analizi ($r=0.8$)*

	p,t	E_1	E_2	d_1
C=10	60,120	-2211.10	-2091.80	119.30
	60,100	-3152.70	-2266.20	886.50
	60,80	-5014.10	-4790.30	223.80
	45,80	-1966.40	-1896.60	69.80
	30,80	-429.91	-421.71	8.20
C=20	60,120	-7035.90	-6244.40	791.50
	60,100	-8630.70	-7576.20	1054.50
	60,80	-11407.00	-11213.00	194.00
	45,80	-6016.80	-4836.10	1180.70
	30,80	-2463.60	-2188.30	275.30
C=50	60,120	-24904.00	-22592.00	2312.00
	60,100	-26855.00	-25017.00	1838.00
	60,80	-30727.00	-29470.00	1257.00
	45,80	-19658.00	-17604.00	2054.00
	30,80	-10564.00	-8653.50	1910.50
C=100	60,120	-55329.00	-48232.00	7097.00
	60,100	-58835.00	-52740.00	6095.00
	60,80	-65877.00	-63441.00	2436.00
	45,80	-43998.00	-39745.00	4253.00
	30,80	-25356.00	-18398.00	6958.00

Rezervasyon modeli-2 ile önceki iki r değeri için yapılan analizlerde olduğu gibi Tablo 5.13'teki d_1 değerleri ile parametrelerdeki değişim arasında herhangi bir bağıntı bulunmamaktadır. Tablo 5.11, Tablo 5.12 ve Tablo 5.13'teki fayda değerleri karşılaştırıldığında ise özellikle $C=50$ ve $C=100$ için r parametresinin 0.8 değeri için yapılan hesaplamalarda, dinamik model ile klasik modele kıyasla çoğunlukla daha fazla fayda sağlanabildiği görülmektedir.

Rezervasyonsuz müşterilerin de sisteme kabul edildiği son rezervasyon modeli için farklı parametre değerleri ile hesaplanan belirsizlik maliyetleri ve karşılaştırma oranları Tablo 5.14'te verilmiştir.

Tablo 5.14. *Model-3 için rassal olasılıklar ile duyarlılık analizi*

	p,t	E_1	E_2	R_1
C=10	60,120	2949	3339	13.22
	60,100	2560	3113	21.62
	60,80	1996	2368	18.67
	45,80	2059	2474	20.17
	30,80	1694	2123	25.38
C=20	60,120	3705	4446	20.01
	60,100	3206	4342	35.46
	60,80	2326	2946	26.68
	45,80	2578	3397	31.75
	30,80	2169	2655	22.39
C=50	60,120	4104	5824	41.90
	60,100	3494	4951	41.71
	60,80	2573	3747	45.64
	45,80	2758	4033	46.24
	30,80	2501	3383	35.28
C=100	60,120	3446	6032	75.00
	60,100	2864	4451	55.39
	60,80	2125	4655	119.07
	45,80	2320	3592	54.86
	30,80	2094	3288	57.00

Rezervasyon modeli-3 için yapılan duyarlılık analizlerinin sonuçları incelendiğinde, parametre değerlerindeki değişim ile kişisel olasılık kullanımının sağladığı fayda arasında herhangi bir örüntü olmadığı görülmektedir.

5.3.2. Tahmin edilen olasılık değerleri ile duyarlılık analizleri

Geçmiş verilerden tahmin algoritmaları ile elde edilen kişisel olasılıkların kullanıldığı dinamik rezervasyon modellerinin sabit olasılıklı rezervasyon modellerine kıyasla sağladığı iyileşmenin parametre değerlerindeki değişime karşı tepkisi yapılan analizlerle ölçülmüştür.

5.3.2.1. Rezervasyon modeli-1 için duyarlılık analizi

Daha önce açıklanan tahmin algoritmaları ile belirlenen olasılık ve sınıf değerleri kullanılarak parametrelerin farklı kombinasyonları için rezervasyon modeli-1'in çıktıları hesaplanmıştır.


Lojistik Regresyon algoritması ile elde edilen değerler kullanılarak hesaplanan çıktılar aşağıdaki tabloda verilmiştir.

Tablo 5.15. *Lojistik Regresyon ile model-1 için duyarlılık analizi*


	p,t	E_1	E_2	R_1	E_1^*	E_2^*	R_2	E^*
C=10	60,120	6453	6668	3.33	6420	6480	0.93	10440
	60,100	5379	5509	2.42	5440	5500	1.10	10380
	60,80	3722	3901	4.81	3680	4100	11.41	10320
	45,80	4335	4525	4.38	4295	4515	5.12	7800
	30,80	3894	3980	2.21	3900	4000	2.56	5280
C=20	60,120	9276	9514	2.57	9660	10080	4.35	21300
	60,100	7646	7953	4.02	8120	8220	1.23	21300
	60,80	5262	5428	3.15	4980	5240	5.22	21300
	45,80	6215	6414	3.20	6380	6405	0.39	15975
	30,80	5696	5816	2.11	6420	6610	2.96	10650
C=50	60,120	14879	15380	3.37	14220	14520	2.11	55620
	60,100	12161	12568	3.35	12660	13120	3.63	55620
	60,80	8211	8631	5.12	7880	8000	1.52	55620
	45,80	9867	10224	3.62	10005	10050	0.45	41715
	30,80	9216	9515	3.24	8560	8660	1.17	27810
C=100	60,120	21038	21753	3.40	22380	23220	3.75	110280
	60,100	17161	17711	3.20	17800	18140	1.91	110280
	60,80	11489	11818	2.86	12400	12500	0.81	110280
	45,80	10953	14399	31.46	14175	14615	3.10	82710
	30,80	13149	13504	2.70	12760	13300	4.23	55140

Tablo 5.15'te, parametre değerlerinin kombinasyonları için hesaplanan beklenen belirsizlik maliyetleri E_1 , E_2 ve E_1^* 'in E_2^* 'ye oranla amaç fonksiyonunda sağladığı iyileşme oranı olan R_1 değerleri ve benzer şekilde gerçekleşen belirsizlik maliyetleri E_1^* , E_2^* ile R_2 oranları verilmiştir. Tablo 5.15'teki değerler incelendiğinde, dinamik modelin sabit olasılıklı modele göre daha düşük belirsizlik maliyetlerine yol açtığı görülmektedir.


Parametrelerdeki deęişimin sonuçlar üzerindeki etkisini daha kolay görebilmek için R_1 ve R_2 deęerlerinin kapasite parametresi baz alınarak hazırlanan grafikleri aşıęıda verilmiştir. (Şekil 5.4-Şekil 5.7).




Şekil 5.4. Lojistik Regresyon ile model-1 için R_1 ve R_2 oranları ($C=10$)



Şekil 5.5. Lojistik Regresyon ile model-1 için R_1 ve R_2 oranları ($C=20$)



Şekil 5.6. Lojistik Regresyon ile model-1 için R_1 ve R_2 oranları ($C=50$)



Şekil 5.7. Lojistik Regresyon ile model-1 için R_1 ve R_2 oranları ($C=100$)

Tablo 5.15 incelendiğinde p değeri sabit tutulup t değeri azaltıldığında tüm C değerleri için beklenen ve gerçekleşen belirsizlik maliyetlerinin de azaldığı görülmektedir. Ancak R_1 ve R_2 değerleri ile parametre değerlerindeki değişim arasında herhangi bir ilişki olmadığı grafiklerde görülmektedir.


Olasılık ve sınıf değerlerinin tahmininde kullanılan bir diğer yöntem olan Naive Bayes ile elde edilen değerler kullanılarak yapılan duyarlılık analizinin sonuçları Tablo 5.16’da verilmiştir.

Tablo 5.16. *Naive Bayes ile model-1 için duyarlılık analizi*


	p, t	E_1	E_2	R_1	E_1^*	E_2^*	R_2	E^*
C=10	60,120	6179	6783	9.78	6420	6540	1.87	9360
	60,100	5150	5500	6.80	5600	5720	2.14	9040
	60,80	3564	3915	9.85	3780	3960	4.76	8720
	45,80	4127	4468	8.26	4415	4690	6.23	6860
	30,80	3735	4011	7.39	4580	4730	3.28	5000
C=20	60,120	9941	9669	-2.74	9120	9480	3.95	17160
	60,100	7371	8095	9.82	8100	8160	0.74	17020
	60,80	5039	5483	8.81	5380	5560	3.35	16880
	45,80	5964	6483	8.70	6180	6280	1.62	12800
	30,80	5486	5996	9.30	6530	6660	1.99	8720
C=50	60,120	14242	15707	10.29	16080	16200	0.75	43080
	60,100	11675	12744	9.16	11740	12580	7.16	43080
	60,80	7870	9019	14.60	8100	8300	2.47	43080
	45,80	9469	10704	13.04	10980	11240	2.37	32310
	30,80	8874	9916	11.74	9750	9900	1.54	21540
C=100	60,120	20221	21882	8.21	23040	24360	5.73	86700
	60,100	16493	18274	10.80	20140	20900	3.77	86700
	60,80	11036	12303	11.48	12880	13100	1.71	86700
	45,80	13402	15119	12.81	16685	16700	0.09	65025
	30,80	12646	13576	7.35	14020	14520	3.57	43350

Tablo 5.16’da $C=20$, $p=60$ ve $t=120$ değerleri için R_1 değerinin negatif çıktığı görülmektedir. Buradaki negatiflik, ilgili parametre değerleri için sabit olasılıklı modelin dinamik modele kıyasla daha başarılı olduğu anlamına gelmektedir. Bunun dışındaki R_1 ve R_2 oranları pozitif çıkmıştır, yani dinamik model sabit olasılıklı modele kıyasla daha düşük belirsizlik maliyetlerine ulaşmıştır.


Tablodaki oran değerlerinin kapasite parametresine göre değişimlerini gösteren grafikler Şekil 5.8 ile Şekil 5.11 arasında verilmiştir.




Şekil 5.8. Naive Bayes ile model-1 için R_1 ve R_2 oranları ($C=10$)



Şekil 5.9. Naive Bayes ile model-1 için R_1 ve R_2 oranları ($C=20$)



Şekil 5.10. Naive Bayes ile model-1 için R_1 ve R_2 oranları ($C=50$)



Şekil 5.11. Naive Bayes ile model-1 için R_1 ve R_2 oranları ($C=100$)

Tablo 5.16'daki değerler ve ilgili grafikler incelendiğinde Lojistik Regresyon ile yapılan analizlere benzer sonuçlara ulaşılmaktadır. R_1 ve R_2 oranları ile parametre değerlerindeki değişim arasında herhangi bir ilişki görülmemektedir.


Çalışmada kullanılan üçüncü ve son tahmin algoritması olan Random Forest ile elde edilen değerler kullanılarak rezervasyon modeli-1 için yapılan duyarlılık analizinin sonuçları Tablo 5.17’de verilmiştir.

Tablo 5.17. *Random Forest ile model-1 için duyarlılık analizi*


	p,t	E_1	E_2	R_1	E_1^*	E_2^*	R_2	E^*
C=10	60,120	5982	6648	11.13	6000	6120	2.00	8580
	60,100	4988	5389	8.04	4860	5380	10.70	8460
	60,80	3558	3912	9.95	3720	3960	6.45	8340
	45,80	3998	4478	12.01	4295	4610	7.33	6375
	30,80	3641	3951	8.51	3800	4010	5.53	4410
C=20	60,120	8668	9435	8.85	9480	9540	0.63	17220
	60,100	7137	7797	9.25	7000	7720	10.29	17140
	60,80	5040	5477	8.67	5320	5500	3.38	17060
	45,80	5781	6510	12.61	6520	6640	1.84	12875
	30,80	5362	5756	7.35	5630	5690	1.07	8690
C=50	60,120	13936	15229	9.28	15180	16020	5.53	43200
	60,100	11673	12729	9.05	11940	12640	5.86	43200
	60,80	7881	9027	14.54	8100	8300	2.47	43200
	45,80	9252	10238	10.66	11020	11045	0.23	32400
	30,80	8676	9672	11.48	9890	10090	2.02	21600
C=100	60,120	19798	21860	10.42	22020	24300	10.35	84120
	60,100	16094	18014	11.93	19280	20560	6.64	84120
	60,80	10737	11997	11.74	12000	12720	6.00	84120
	45,80	13097	14757	12.67	14985	15660	4.50	63090
	30,80	12389	13596	9.74	13150	14170	7.76	42060

Tablo 5.17’deki değerler incelendiğinde dinamik model ile hesaplanan belirsizlik maliyetlerinin sabit olasılıklı model ile hesaplanan belirsizlik maliyetlerinden daha düşük olduğu görülmektedir. Dolayısıyla dinamik modelin sabit olasılıklı modele kıyasla sağladığı faydayı ifade eden oran değerlerinin tamamı pozitifdir.


Tablodaki R_1 ve R_2 değerlerinin kapasite parametresi baz alınarak hazırlanan değişim grafikleri Şekil 5.12 ile Şekil 5.15 arasında verilmiştir.




Şekil 5.12. *Random Forest ile model-1 için R_1 ve R_2 oranları ($C=10$)*



Şekil 5.13. *Random Forest ile model-1 için R_1 ve R_2 oranları ($C=20$)*



Şekil 5.14. Random Forest ile model-1 için R_1 ve R_2 oranları ($C=50$)



Şekil 5.15. Random Forest ile model-1 için R_1 ve R_2 oranları ($C=100$)

Tablo 5.17'deki değerler ve ilgili grafikler incelendiğinde, beklenen ve gerçekleşen belirsizlik maliyetleri ile R_1 ve R_2 oranlarının parametre değerlerindeki artış veya azalış ile orantılı olmadığı görülmektedir.

Rezervasyon modeli-1 için üç farklı algoritmanın tahmin verileri kullanılarak tekrarlanan duyarlılık analizlerinin sonuçları karşılaştırıldığında, Random Forest

algoritmasının tahmin ettiği olasılık ve sınıf değerleri kullanıldığında dinamik modelin sabit olasılıklı modele kıyasla sağladığı faydanın daha yüksek değerler alabildiği görülmektedir.

5.3.2.2. Rezervasyon modeli-2 için duyarlılık analizi

Rezervasyon modeli-1 için yapılan duyarlılık analizleri rezervasyon modeli-2'deki üç farklı ceza oranı değeri için ayrı ayrı yapılmıştır. Her bir ceza oranı için üç farklı tahmin algoritması ile elde edilen veriler kullanılarak gerçekleştirilen duyarlılık analizlerinin sonuçları Tablo 5.18 ile Tablo 5.20 arasında verilmiştir.


Tablo 5.18. Lojistik Regresyon ile model-2 için duyarlılık analizi ($r=0.2$)

	p,t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	3418	3577	159.00	4380	4776	396.00	8232
	60,100	2286	2438	152.00	2408	2568	160.00	8172
	60,80	512	662	150.00	576	672	96.00	8112
	45,80	2028	2254	226.00	2017	2196	179.00	6144
	30,80	2431	2529	98.00	2404	2402	-2.00	4176
C=20	60,120	3260	3530	270.00	4428	4680	252.00	16692
	60,100	1460	1840	380.00	1720	2400	680.00	16620
	60,80	-1090	-920	170.00	-716	-528	188.00	16692
	45,80	1641	1809	168.00	1901	2128	227.00	12519
	30,80	2736	2848	112.00	3022	3120	98.00	8346
C=50	60,120	-80	300	380.00	-1524	-912	612.00	43680
	60,100	-2950	-2570	380.00	-3200	-2730	470.00	43680
	60,80	-7220	-6960	260.00	-7460	-6960	500.00	43680
	45,80	-1420	-1120	300.00	-1850	-1720	130.00	32760
	30,80	1880	2090	210.00	2210	2470	260.00	21840
C=100	60,120	-8490	-7820	670.00	-10060	-9050	1010.00	86664
	60,100	-12600	-12100	500.00	-11880	-11530	350.00	86664
	60,80	-18680	-18310	370.00	-17900	-17020	880.00	86664
	45,80	-8300	-7950	350.00	-8400	-7740	660.00	64998
	30,80	-1480	-1140	340.00	-2630	-2180	450.00	43332


Rezervasyon modeli-1 için yapılan, r parametresinin %20 olduğu ve Lojistik Regresyon ile tahmin edilen değerlerin kullanıldığı analizin sonuçları Tablo 5.18'de verilmiştir. Tabloda negatif değerler olduğu görülmektedir. Belirsizlik maliyetlerindeki negatiflik rezervasyon modeli-2'de açıklandığı şekilde maksimum kazancın üzerinde elde edilen getiriye ifade etmektedir. d_1 ve d_2 değerleri incelendiğinde ise tüm değerler

pozitifdir. Yani incelenen parametre kombinasyonları için dinamik model sabit modelden daha düşük belirsizlik maliyetleri sağlamıştır.


Tablo 5.18'deki d_1 ve d_2 değerlerinin parametrelere göre değişimini gösteren grafikler Şekil 5.16 ile Şekil 5.19 arasında verilmiştir.




Şekil 5.16. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.2$)



Şekil 5.17. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.2$)



Şekil 5.18. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.2$)



Şekil 5.19. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.2$)

Tablo 5.18'deki değerler ve grafikler incelendiğinde parametrelerdeki değişim ile dinamik modelin sağladığı fayda arasında herhangi bir bağlantı olmadığı görülmektedir.


Yine rezervasyon modeli-2 ve r parametresinin %20 değeri için, Naive Bayes algoritması ile elde edilen değerler kullanılarak yapılan analizin sonuçları Tablo 5.19'da verilmiştir.

Tablo 5.19. *Naive Bayes ile model-2 için duyarlılık analizi ($r=0.2$)*


	p, t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	3073	3631	558.00	3360	3780	420.00	6996
	60,100	1972	2288	316.00	2460	2908	448.00	6676
	60,80	269	630	361.00	780	1064	284.00	6356
	45,80	1778	2130	352.00	2399	2763	364.00	5087
	30,80	2218	2484	266.00	2614	2696	82.00	3818
C=20	60,120	2710	3480	770.00	4310	4630	320.00	12324
	60,100	1080	1890	810.00	2360	2990	630.00	12184
	60,80	-1500	-1040	460.00	-660	-530	130.00	12044
	45,80	1261	1789	528.00	2201	2758	557.00	9173
	30,80	2443	2850	407.00	3182	3320	138.00	6302
C=50	60,120	1356	2280	924.00	-890	-310	580.00	43680
	60,100	-3870	-2550	1320.00	-2910	-790	2120.00	30600
	60,80	-8040	-7110	930.00	-7520	-6210	1310.00	30600
	45,80	-2410	-1190	1220.00	-1170	-110	1060.00	22950
	30,80	1300	2050	750.00	1310	1740	430.00	15300
C=100	60,120	-10180	-8490	1690.00	-8100	-7010	1090.00	62112
	60,100	-14140	-12850	1290.00	-12440	-10620	1820.00	62112
	60,80	-20060	-19010	1050.00	-18220	-16690	1530.00	62112
	45,80	-9480	-8250	1230.00	-7290	-6250	1040.00	46584
	30,80	-2420	-1010	1410.00	-2230	-1330	900.00	31056

Tablo 5.19'daki beklenen ve gerçekleşen belirsizlik maliyetlerinin incelenen parametre değerleri için dinamik model ile daha düşük çıktığı görülmektedir. d_1 ve d_2 değerleri de dinamik modelin sağladığı faydayı ifade ettiği için tamamı pozitif değerler almıştır.


Parametrelerdeki değişimin sonuçlar üzerindeki etkisini daha kolay görebilmek için dinamik model ile sağlanan faydanın beklenen ve gerçekleşen değerlerinin kapasite parametresine bağlı olarak değişimi Şekil 5.20 ile Şekil 5.23 arasında verilmiştir.




Şekil 5.20. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.2$)



Şekil 5.21. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.2$)



Şekil 5.22. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.2$)



Şekil 5.23. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.2$)

Tablo 5.19'daki değerler ve ilgili grafikler incelendiğinde parametrelerdeki değişimin d_1 ve d_2 değerleri üzerinde herhangi bir etkisi olmadığı görülmektedir.


Rezervasyon modeli-2 için Random Forest algoritması ile $r=0.2$ için tahmin edilen değerler kullanılarak yapılan analizin sonuçları Tablo 5.20'de verilmiştir.

Tablo 5.20. *Random Forest ile model-2 için duyarlılık analizi ($r=0.2$)*


	p,t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	2975	3529	554.00	4104	4512	408.00	6228
	60,100	1902	2436	534.00	2372	2696	324.00	6108
	60,80	222	647	425.00	836	976	140.00	5988
	45,80	1730	2204	474.00	2094	2540	446.00	4611
	30,80	2173	2512	339.00	1998	2536	538.00	3234
C=20	60,120	2650	3360	710.00	3400	4080	680.00	12360
	60,100	980	1860	880.00	1710	2780	1070.00	12316
	60,80	-1490	-1030	460.00	-760	-270	490.00	12236
	45,80	1217	1654	437.00	1622	2068	446.00	9257
	30,80	2396	2735	339.00	2984	3216	232.00	6278
C=50	60,120	-1160	-90	1070.00	-860	890	1750.00	30720
	60,100	-3900	-2930	970.00	-2560	-1320	1240.00	30720
	60,80	-7920	-7270	650.00	-7270	-6430	840.00	30720
	45,80	-2160	-1320	840.00	-1351	-476	875.00	23040
	30,80	1230	1930	700.00	1230	2060	830.00	15360
C=100	60,120	-10350	-8280	2070.00	-9770	-7270	2500.00	59388
	60,100	-14290	-12660	1630.00	-12460	-10340	2120.00	59388
	60,80	-19900	-18690	1210.00	-19060	-16660	2400.00	59388
	45,80	-9620	-8290	1330.00	-7900	-5950	1950.00	44541
	30,80	-2530	-1110	1420.00	-3450	-2160	1290.00	29694

Tablo 5.20'deki değerler incelendiğinde, rezervasyon modeli-2 için yapılan önceki iki analizde olduğu gibi negatif ve pozitif belirsizlik maliyetleri olduğu görülmektedir. Yani, maksimum kazancın üstünde ve altında kazanç değerleri hesaplanmıştır. d_1 ve d_2 değerlerinin pozitif olması ilgili parametre değerleriyle dinamik modelin daha başarılı olduğunu ifade etmektedir.


Tablo 5.20'deki dinamik model ile sağlanan fayda değerlerinin kapasite parametresi baz alınarak hazırlanan grafikleri Şekil 5.24 ile Şekil 5.27 arasında verilmiştir.




Şekil 5.24. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.2$)



Şekil 5.25. Random Forest ile model-2 için d_1 ve d_2 değerleri $C=20$, $r=0.2$)



Şekil 5.26. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.2$)



Şekil 5.27. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.2$)

Tablo 5.20'deki değerler ve ilgili grafikler incelendiğinde, parametre değerlerindeki değişim ile dinamik modelin sağladığı fayda arasında herhangi bir örüntü olmadığı görülmektedir.


Tablo 5.21'de r parametresinin %50 değeri için Lojistik Regresyon algoritması ile tahmin edilen değerler kullanılarak yapılan analizin sonuçları verilmiştir.

Tablo 5.21. *Lojistik Regresyon ile model-2 için duyarlılık analizi ($r=0.5$)*


	p, t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	-491	-359	132.00	-1230	-600	630.00	4920
	60,100	-1664	-1468	196.00	-1880	-1750	130.00	4860
	60,80	-3627	-3454	173.00	-3810	-3630	180.00	4800
	45,80	-901	-687	214.00	-1360	-438	922.00	3660
	30,80	524	682	158.00	470	500	30.00	2520
C=20	60,120	-4450	-4070	380.00	-4710	-3300	1410.00	9780
	60,100	-6280	-6090	190.00	-7200	-6400	800.00	9780
	60,80	-9220	-9030	190.00	-10520	-10270	250.00	9780
	45,80	-4205	-4043	162.00	-4567	-4317	250.00	7335
	30,80	-1044	-880	164.00	-1400	-1510	-110.00	4900
C=50	60,120	-19040	-18610	430.00	-23130	-21750	1380.00	25770
	60,100	-22060	-21710	350.00	-25830	-24420	1410.00	25770
	60,80	-26820	-26490	330.00	-30060	-28140	1920.00	25770
	45,80	-15720	-15460	260.00	-17880	-17610	270.00	19330
	30,80	-7520	-7310	210.00	-9490	-9340	150.00	12885
C=100	60,120	-45920	-45390	530.00	-50040	-48540	1500.00	51240
	60,100	-50310	-49910	400.00	-55780	-54980	800.00	51240
	60,80	-56970	-56590	380.00	-61920	-61190	730.00	51240
	45,80	-36520	-36090	430.00	-41000	-39690	1310.00	38430
	30,80	-20050	-19620	430.00	-22530	-22340	190.00	25620

Tablo 5.21’de $C=20$, $p=30$ ve $t=80$ değerleri için d_2 negatif çıkmıştır. Bu negatifliğin nedeni, ilgili parametre değerleri için sabit olasılıklı modelle hesaplanan belirsizlik maliyetinin gerçekleşen değerinin dinamik modelle hesaplanan belirsizlik maliyetinin gerçekleşen değerinden daha düşük olmasıdır. Diğer d_1 ve d_2 değerlerinin pozitif olması da ilgili parametre değerleri için dinamik modelin sabit olasılıklı modele kıyasla daha başarılı olduğunu göstermektedir.


Dinamik modelin sağladığı faydanın parametrelere göre değişimi Şekil 5.28 ile Şekil 5.31 arasındaki grafiklerde verilmiştir.




Şekil 5.28. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.5$)



Şekil 5.29. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.5$)



Şekil 5.30. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.5$)



Şekil 5.31. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.5$)

Tablo 5.21'deki değerler ve ilgili grafikler incelendiğinde dinamik model ya da sabit olasılıklı model ile sağlanan faydanın parametrelerdeki değişimle orantılı olmadığı görülmektedir.


Naive Bayes algoritması ile tahmin edilen değerler kullanılarak model-2'de r parametresinin %50 değeri için yapılan analizin sonuçları Tablo 5.22'de verilmiştir.

Tablo 5.22. *Naive Bayes ile model-2 için duyarlılık analizi ($r=0.5$)*


	p,t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	-912	-505	407.00	-450	570	1020.00	3450
	60,100	-2064	-1573	491.00	-1420	-710	710.00	3130
	60,80	-3974	-3611	363.00	-3770	-3390	380.00	2810
	45,80	-1216	-742	474.00	-468	750	1218.00	2427
	30,80	263	580	317.00	1240	1245	5.00	2045
C=20	60,120	-5160	-4270	890.00	-4800	-2850	1950.00	5070
	60,100	-6970	-6340	630.00	-7380	-6010	1370.00	4930
	60,80	-9850	-9380	470.00	-9790	-9080	710.00	4790
	45,80	-4774	-4238	536.00	-4488	-3865	623.00	3732
	30,80	-1449	-1031	418.00	-850	-550	300.00	2675
C=50	60,120	-20550	-19120	1430.00	-21930	-20100	1830.00	11880
	60,100	-23650	-22430	1220.00	-23690	-20800	2890.00	11880
	60,80	-28190	-27320	870.00	-29760	-27090	2670.00	11880
	45,80	-16820	-16060	760.00	-18700	-17270	1430.00	8910
	30,80	-8280	-7570	710.00	-8770	-8230	540.00	5940
C=100	60,120	-48860	-46740	2120.00	-53010	-49500	3510.00	25230
	60,100	-52900	-51620	1280.00	-55730	-53630	2100.00	25230
	60,80	-59440	-58580	860.00	-61370	-59830	1540.00	25230
	45,80	-38480	-37280	1200.00	-40050	-38180	1870.00	18920
	30,80	-21450	-20640	810.00	-23080	-22340	740.00	12615

Tablo 5.22'deki değerler incelendiğinde, Naive Bayes algoritması ile tahmin edilen değerler kullanıldığında dinamik modelin incelenen tüm parametre değerleri için sabit olasılıklı modelden daha başarılı olduğu görülmektedir.


Dinamik model ile sabit modele kıyasla sağlanan faydanın parametrelere göre değişimi Şekil 5.32 ile Şekil 5.35 arasında verilmiştir.




Şekil 5.32. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.5$)



Şekil 5.33. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.5$)



Şekil 5.34. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.5$)



Şekil 5.35. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.5$)

Tablo 5.22'deki analiz sonuçları ve ilgili grafikler incelendiğinde, dinamik model ile sağlanan faydanın parametre değerlerindeki değişimle orantılı olmadığı görülmektedir.


Aynı parametre değerleri için Random Forest algoritması ile tahmin edilen değerler kullanılarak yapılan analizin sonuçları Tablo 5.23'te verilmiştir.

Tablo 5.23. *Random Forest ile model-2 için duyarlılık analizi ($r=0.5$)*


	p,t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	-859	-305	554.00	-1170	150	1320.00	2700
	60,100	-2028	-1559	469.00	-1830	-1560	270.00	2580
	60,80	-3979	-3395	584.00	-3990	-2960	1030.00	2460
	45,80	-1183	-704	479.00	-930	358	1288.00	1965
	30,80	270	736	466.00	590	765	175.00	1470
C=20	60,120	-5030	-4230	800.00	-4650	-2730	1920.00	5160
	60,100	-6810	-6240	570.00	-7090	-5960	1130.00	5080
	60,80	-9610	-9100	510.00	-10100	-9340	760.00	5000
	45,80	-4584	-4157	427.00	-4500	-4245	255.00	3830
	30,80	-1372	-896	476.00	-1075	-745	330.00	2660
C=50	60,120	-20290	-19070	1220.00	-22680	-20850	1830.00	12000
	60,100	-23270	-22360	910.00	-25140	-22730	2410.00	12000
	60,80	-27740	-27010	730.00	-30130	-28650	1480.00	12000
	45,80	-16610	-15840	770.00	-18070	-16830	1240.00	9000
	30,80	-8230	-7600	630.00	-9260	-8620	640.00	6000
C=100	60,120	-48400	-46450	1950.00	-53880	-50340	3540.00	22290
	60,100	-52830	-51230	1600.00	-55730	-53730	2000.00	22290
	60,80	-59050	-58030	1020.00	-63230	-60900	2330.00	22290
	45,80	-38290	-37090	1200.00	-41460	-38830	2630.00	16720
	30,80	-21370	-20340	1030.00	-23480	-22340	1140.00	11145

Tablo 5.23'te belirsizlik maliyetlerinin beklenen ve gerçekleşen değerleri incelendiğinde dinamik model ile elde edilen kazancın sabit olasılıklı model ile elde edilen kazançtan daha yüksek olduğu görülmektedir.


Dinamik model ile sağlanan faydanın parametre değerlerine göre değişimi kapasite baz alınarak hazırlanan grafiklerle Şekil 5.36 ile Şekil 5.39 arasında verilmiştir.




Şekil 5.36. *Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.5$)*



Şekil 5.37. *Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.5$)*



Şekil 5.38. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.5$)



Şekil 5.39. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.5$)

Tablo 5.23'teki değerler ve ilgili grafikler incelendiğinde rezervasyon modeli-2 için $r=0.5$ iken dinamik modelin sağladığı fayda ile parametre değerlerindeki değişim arasında herhangi bir örüntü olmadığı görülmektedir.


Tablo 5.24'te r parametresinin %80 değeri ile rezervasyon modeli-2 için Lojistik Regresyon algoritmasının tahmin ettiği değerler kullanılarak yapılan analizin sonuçları verilmiştir.

Tablo 5.24. *Lojistik Regresyon ile model-2 için duyarlılık analizi ($r=0.8$)*


	p,t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	-3596	-3497	99.00	-3984	-3456	528.00	1608
	60,100	-4862	-4568	294.00	-6144	-5980	164.00	1548
	60,80	-6959	-6762	197.00	-8148	-7948	200.00	1488
	45,80	-3258	-3152	106.00	-3711	-2667	1044.00	1176
	30,80	-991	-793	198.00	-1292	-308	984.00	864
C=20	60,120	-10600	-10410	190.00	-12520	-11090	1430.00	2868
	60,100	-12510	-12330	180.00	-15350	-15030	320.00	2868
	60,80	-15600	-15330	270.00	-19530	-17120	2410.00	2868
	45,80	-8860	-8600	260.00	-11340	-11470	-130.00	2151
	30,80	-4077	-3932	145.00	-4720	-3810	910.00	1434
C=50	60,120	-34030	-33650	380.00	-41900	-40480	1420.00	7860
	60,100	-37200	-36810	390.00	-44960	-42620	2340.00	7860
	60,80	-42380	-42000	380.00	-50870	-50430	440.00	7860
	45,80	-26980	-26760	220.00	-31920	-31500	420.00	5895
	30,80	-14990	-14790	200.00	-18400	-18020	380.00	3930
C=100	60,120	-75420	-74840	580.00	-88420	-86100	2320.00	15816
	60,100	-80060	-79630	430.00	-92760	-92390	370.00	15816
	60,80	-87170	-86830	340.00	-104690	-103600	1090.00	15816
	45,80	-58730	-58320	410.00	-69780	-68220	1560.00	11862
	30,80	-34780	-34370	410.00	-40390	-40810	-420.00	7908

Tablo 5.24'teki değerler incelendiğinde, $C=100$, $p=30$ ve $t=80$ değerleri için belirsizlik maliyetinin gerçekleşen değeri negatif çıkmıştır. Bu değerdeki negatiflik ilgili parametre değerleri için sabit olasılıklı modelin dinamik modelden daha yüksek kazanç sağladığını göstermektedir. Bunun dışında tablodaki diğer belirsizlik maliyetlerinin pozitifliği dinamik modelin daha başarılı olduğunu göstermektedir.


d_1 ve d_2 değerlerinin parametrelere göre değişimi Şekil 5.40 ile Şekil 5.43 arasında verilmiştir.




Şekil 5.40. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.8$)



Şekil 5.41. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.8$)



Şekil 5.42. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.8$)



Şekil 5.43. Lojistik Regresyon ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.8$)

Lojistik Regresyon ile tahmin edilen değerler kullanılarak yapılan analizin sonuçları incelendiğinde, d_1 ve d_2 değerlerindeki değişimin parametre değerlerindeki değişim ile orantılı olmadığı görülmektedir.


Naive Bayes algoritması ile tahmin edilen değerler kullanılarak tekrar edilen analizin sonuçları Tablo 5.25'te verilmiştir.

Tablo 5.25. *Naive Bayes ile model-2 için duyarlılık analizi ($r=0.8$)*


	p,t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	-4150	-3731	419.00	-3792	-2520	1272.00	-96
	60,100	-5358	-4780	578.00	-5596	-5408	188.00	-416
	60,80	-7383	-6942	441.00	-8432	-7772	660.00	-736
	45,80	-3649	-3350	299.00	-3563	-2396	1167.00	-232
	30,80	-1290	-823	467.00	-890	574	1464.00	272
C=20	60,120	-11510	-10860	650.00	-13270	-11500	1770.00	-2184
	60,100	-13460	-12810	650.00	-15020	-14070	950.00	-2324
	60,80	-16450	-15840	610.00	-19600	-16940	2660.00	-2464
	45,80	-9550	-8990	560.00	-10550	-9980	570.00	-1708
	30,80	-4552	-4061	491.00	-4926	-3604	1322.00	-952
C=50	60,120	-35810	-34550	1260.00	-41470	-38580	2890.00	-6840
	60,100	-39000	-37780	1220.00	-45170	-41900	3270.00	-6840
	60,80	-44210	-43370	840.00	-50560	-49420	1140.00	-6840
	45,80	-28430	-27700	730.00	-32380	-31320	1060.00	-5130
	30,80	-15940	-15230	710.00	-18390	-17100	1290.00	-3420
C=100	60,120	-78890	-77060	1830.00	-89720	-84950	4770.00	-11652
	60,100	-83540	-82410	1130.00	-95680	-93310	2370.00	-11652
	60,80	-90470	-89840	630.00	-103520	-102140	1380.00	-11652
	45,80	-61310	-60170	1140.00	-69160	-66190	2970.00	-8739
	30,80	-36520	-35620	900.00	-41330	-40760	570.00	-5826

Tablo 5.25'teki analiz sonuçları incelendiğinde, ilgili parametre değerleri için dinamik model ile sabit olasılıklı modele kıyasla daha fazla kazanç sağlandığı görülmektedir. Bu nedenle d_1 ve d_2 değerlerinin tamamı pozitifdir.


d_1 ve d_2 değerlerinin parametrelere göre değişimini analiz etmek için oluşturulan grafikler Şekil 5.44 ve Şekil 5.47 arasında verilmiştir.




Şekil 5.44. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.8$)



Şekil 5.45. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.8$)



Şekil 5.46. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.8$)



Şekil 5.47. Naive Bayes ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.8$)


Tablo 5.25'teki analiz sonuçları ve ilgili grafikler incelendiğinde dinamik model ile sağlanan faydanın parametre değerlerindeki değişim ile orantılı olmadığı görülmektedir.

Rezervasyon modeli-2 için yapılan son analiz, Random Forest algoritması ile tahmin edilen değerler kullanılarak ve r parametresinin %80 değeri için yapılmıştır. Analizin sonuçları Tablo 5.26'da verilmiştir.


Tablo 5.26. *Random Forest ile model-2 için duyarlılık analizi ($r=0.8$)*

	p,t	E_1	E_2	d_1	E_1^*	E_2^*	d_2	E^*
C=10	60,120	-3947	-3550	397.00	-3828	-2796	1032.00	-828
	60,100	-5217	-4623	594.00	-5868	-5640	228.00	-948
	60,80	-7327	-6729	598.00	-8540	-7700	840.00	-1068
	45,80	-3531	-3016	515.00	-4392	-2563	1829.00	-681
	30,80	-1188	-762	426.00	-1460	-218	1242.00	-294
C=20	60,120	-11140	-10560	580.00	-13220	-11830	1390.00	-2076
	60,100	-13080	-12470	610.00	-15280	-14500	780.00	-2156
	60,80	-16080	-15610	470.00	-19540	-17710	1830.00	-2236
	45,80	-9270	-8660	610.00	-11160	-10520	640.00	-1597
	30,80	-4403	-3980	423.00	-5064	-3814	1250.00	-958
C=50	60,120	-35430	-34310	1120.00	-40920	-38120	2800.00	-6720
	60,100	-38500	-37450	1050.00	-46100	-42670	3430.00	-6720
	60,80	-43400	-42760	640.00	-50480	-50320	160.00	-6720
	45,80	-28090	-27310	780.00	-33540	-31610	1930.00	-5040
	30,80	-15780	-15100	680.00	-18090	-16990	1100.00	-3360
C=100	60,120	-78160	-76610	1550.00	-91280	-87130	4150.00	-14808
	60,100	-82820	-81390	1430.00	-95290	-92550	2740.00	-14808
	60,80	-90050	-89110	940.00	-102600	-101820	780.00	-14808
	45,80	-60760	-59540	1220.00	-69420	-65580	3840.00	-11106
	30,80	-36240	-35300	940.00	-41580	-40800	780.00	-7404


Tablo 5.26'daki d_1 ve d_2 değerlerinin pozitif olması, ilgili parametre değerleri için dinamik modelin sabit olasılıklı modele kıyasla daha başarılı sonuçlar verdiğini göstermektedir. Dinamik model ile sağlanan faydanın farklı parametre değerleri için aldığı değerleri gösteren grafikler Şekil 5.48 ile Şekil 5.51 arasında verilmiştir.




Şekil 5.48. *Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=10$, $r=0.8$)*



Şekil 5.49. *Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=20$, $r=0.8$)*



Şekil 5.50. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=50$, $r=0.8$)



Şekil 5.51. Random Forest ile model-2 için d_1 ve d_2 değerleri ($C=100$, $r=0.8$)

Rezervasyon modeli-2 için yapılan son analizin sonuçları incelendiğinde, parametre değerlerindeki değişimin d_1 ve d_2 değerleri üzerinde doğru ya da ters yönlü bir etkisi olmadığı görülmektedir.

Rezervasyon modeli-2 için r parametresinin üç farklı değeri ile yapılan analizlerin sonuçları karşılaştırıldığında da r parametresindeki değişim ile analiz sonuçları arasında herhangi bir ilişki olmadığı görülmektedir.

5.3.2.3. Rezervasyon modeli-3 için duyarlılık analizi

Rezervasyon modeli-3 için üç farklı tahmin algoritması ile elde edilen değerler kullanılarak yapılan analizlerin sonuçları bu bölümde incelenmiştir. Bu analizlerde de model-1 için yapılan analizlerde olduğu gibi dinamik modelin sabit olasılıklı modele kıyasla sağladığı fayda R_1 ve R_2 oran değerleri ile hesaplanmıştır.

Lojistik Regresyon ile tahmin edilen değerler kullanılarak yapılan analizin sonuçları Tablo 5.27’de verilmiştir.


Tablo 5.27. Lojistik Regresyon ile model-3 için duyarlılık analizi sonuçları

	p, t	E_1	E_2	R_1	E_1^*	E_2^*	R_2	E^*
C=10	60,120	3003	3354	11.70	4500	4500	0.00	6960
	60,100	2630	3051	16.01	4000	4120	3.00	7080
	60,80	1985	2265	14.12	2760	2880	4.35	6900
	45,80	2093	2343	11.90	2790	2770	-0.07	5505
	30,80	1714	2095	22.20	2830	2830	0.00	3450
C=20	60,120	3788	4335	14.40	6060	6060	0.00	12780
	60,100	3280	4200	28.19	4700	4780	1.70	12960
	60,80	2440	3190	30.57	3120	3180	1.92	13740
	45,80	2605	3091	18.70	3830	3960	3.40	10350
	30,80	2231	2662	19.30	3430	3450	0.60	6240
C=50	60,120	4231	5320	25.80	3780	3840	1.60	29160
	60,100	3570	4510	26.34	4940	5240	6.07	29280
	60,80	2640	3560	34.82	3740	3780	1.07	30900
	45,80	2874	4183	45.50	2995	3055	2.00	22680
	30,80	2561	3370	31.50	3200	3230	0.90	16830
C=100	60,120	3557	5431	52.70	3660	4260	16.40	59220
	60,100	2997	4882	62.90	3180	3720	17.00	54120
	60,80	2210	4450	100.95	3080	3200	3.90	53520
	45,80	2407	3671	52.5	2635	3270	24.10	37260
	30,80	2176	3374	55.00	1820	1890	3.80	26190


Tablo 5.27’deki değerler incelendiğinde $C=10$, $p=45$ ve $t=80$ değerleri için gerçekleşen belirsizlik maliyetinin sabit olasılıklı modelle hesaplanan değerinin (E_2^*) dinamik modelle hesaplanan değerden (E_1^*) daha küçük olduğu görülmektedir. Bu nedenle bu parametre değerleri için hesaplanan R_2 oranı negatif çıkmıştır. Bunun dışında diğer parametre değerleri için hesaplanan belirsizlik maliyetlerinde dinamik modelin klasik modelden daha düşük sonuçlar elde ettiği Tablo 5.27’de görülmektedir.

Lojistik Regresyon algoritması ile rezervasyon modeli-3’te dinamik model


kullanımının sağladığı faydanın parametrelere göre değişimi Şekil 5.52 ile Şekil 5.55 arasında verilmiştir.




Şekil 5.52. Lojistik Regresyon ile model-3 için R_1 ve R_2 oranları ($C=10$)



Şekil 5.53. Lojistik Regresyon ile model-3 için R_1 ve R_2 oranları ($C=20$)



Şekil 5.54. Lojistik Regresyon ile model-3 için R_1 ve R_2 oranları ($C=50$)



Şekil 5.55. Lojistik Regresyon ile model-3 için R_1 ve R_2 oranları ($C=100$)

Tablo 5.27'deki sonuçlar ve ilgili grafikler incelendiğinde, R_1 ve R_2 değerlerindeki değişim ile parametre değerlerindeki değişim arasında herhangi bir bağıntı olmadığı görülmektedir.


Rezervasyon modeli-3 için Naive Bayes algoritması ile tahmin edilen değerler kullanılarak yapılan analizin sonuçları Tablo 5.28'de verilmiştir.

Tablo 5.28. *Naive Bayes ile model-3 için duyarlılık analizi sonuçları*


	p, t	E_1	E_2	R_1	E_1^*	E_2^*	R_2	E^*
C=10	60,120	2806	3620	29.00	5160	5340	3.50	6660
	60,100	2476	3522	42.30	3820	3840	0.50	6280
	60,80	1889	2478	31.10	2920	2920	0.00	5720
	45,80	1959	2532	29.30	2975	3015	1.30	4655
	30,80	1616	2373	46.80	2780	2830	1.80	3650
C=20	60,120	3512	5008	42.60	6300	6180	-1.90	10380
	60,100	3019	4737	56.90	5740	5720	-0.30	10300
	60,80	2259	3846	70.30	3700	3860	4.30	11420
	45,80	2406	3605	49.80	4430	4460	0.70	7805
	30,80	2108	3106	47.30	3470	3620	4.30	5750
C=50	60,120	3884	7282	87.50	6420	6360	-0.90	21420
	60,100	3293	5830	77.00	5060	5280	4.30	24300
	60,80	2426	4825	98.90	3380	3500	3.60	25740
	45,80	2641	5501	108.30	3790	3700	-2.40	17055
	30,80	2343	4224	80.30	2860	2880	0.70	10560
C=100	60,120	3184	8906	179.70	4860	5640	16.00	38280
	60,100	2697	7471	177.00	6000	6240	4.00	39240
	60,80	1984	7351	270.50	2720	2780	2.20	39660
	45,80	2155	5390	150.10	3785	4265	12.70	27765
	30,80	1946	4825	147.90	3270	3370	3.10	20610

Tablo 5.28’de görüldüğü üzere; $C=20$ ve $p=60$ iken t parametresinin 120 ve 100 değerleri ve $C=50$ iken $p=60$, $t=120$ ve $p=45$, $t=80$ değerleri için R_2 değerleri negatiftir. Bu veriler, rezervasyon modeli-3’te Naive Bayes ile tahmin edilen değerler kullanıldığında ilgili parametre değerleri için sabit olasılıklı modelle dinamik modelden daha düşük belirsizlik maliyetlerinin elde edildiğini ifade etmektedir. Tablodaki diğer oran değerlerinin pozitif olması da dinamik modelin çoğunlukla daha başarılı olduğu anlamına gelmektedir.


Tablo 5.28’deki R_1 ve R_2 değerlerinin parametrelere göre değişimini gösteren grafikler Şekil 5.56 ile Şekil 5.59 arasında verilmiştir.




Şekil 5.56. Naive Bayes ile model-3 için R_1 ve R_2 oranları ($C=10$)



Şekil 5.57. Naive Bayes ile model-3 için R_1 ve R_2 oranları ($C=20$)



Şekil 5.58. Naive Bayes ile model-3 için R_1 ve R_2 oranları ($C=50$)



Şekil 5.59. Naive Bayes ile model-3 için R_1 ve R_2 oranları ($C=100$)

Tablo 5.28'deki değerler ve oran değerlerindeki değişimlerin gösterildiği grafikler incelendiğinde bu değişimler ile parametre değerleri arasında herhangi bir ilişki olmadığı görülmektedir.


Naive Bayes algoritması ile tahmin edilen değerler kullanılarak rezervasyon modeli-3 için yapılan analizlerin sonuçları Tablo 5.29'da verilmiştir.

Tablo 5.29. *Random Forest ile model-3 için duyarlılık analizi sonuçları*


	p, t	E_1	E_2	R_1	E_1^*	E_2^*	R_2	E^*
C=10	60,120	2737	3539	29.30	4020	4620	14.90	5820
	60,100	2413	3471	43.80	4020	3980	-1.00	5640
	60,80	1813	2610	44.00	2620	2880	9.90	5460
	45,80	1869	2448	31.00	3300	3390	2.70	4710
	30,80	1575	2272	44.30	2600	2700	3.80	2580
C=20	60,120	3368	4591	36.30	5280	5520	4.50	9300
	60,100	2898	4394	51.60	4320	4360	0.90	10180
	60,80	2159	3390	57.10	3460	3500	1.20	10280
	45,80	2330	3475	49.10	3680	3700	0.50	8240
	30,80	2018	2930	45.20	3530	3550	0.60	5090
C=50	60,120	3692	6518	76.60	5040	5400	7.10	26580
	60,100	3157	5402	71.10	4060	4620	13.80	22800
	60,80	2310	4348	88.30	3260	3620	11.00	22920
	45,80	2516	4973	97.70	4255	4410	3.60	17640
	30,80	3347	4051	80.30	3170	3310	4.40	11670
C=100	60,120	2988	8096	171.00	3060	4140	35.30	40260
	60,100	2539	7191	183.20	3900	4880	25.10	36000
	60,80	1856	6914	272.50	2780	3240	16.50	43740
	45,80	2028	4933	143.30	3205	4025	25.60	26280
	30,80	1837	4691	155.40	2260	2730	20.80	17100

Yapılan analizlerde $C=10$, $p=60$ ve $t=100$ değerleri için hesaplanan R_2 değeri hariç tüm oran değerleri pozitifdir. Sonuç olarak Tablo 5.29 incelendiğinde çoğunlukla dinamik modelle sabit olasılıklı modele kıyasla daha düşük belirsizlik maliyetlerine ulaşıldığı sonucuna varmak mümkündür.


Dinamik model kullanımının sabit olasılıklı modele oranla sağladığı faydanın parametrelere göre değişimini gösteren grafikler Şekil 5.60 ile Şekil 5.63 arasında verilmiştir.




Şekil 5.60. Random Forest ile model-3 için R_1 ve R_2 oranları ($C=10$)



Şekil 5.61. Random Forest ile model-3 için R_1 ve R_2 oranları ($C=20$)



Şekil 5.62. *Random Forest ile model-3 için R_1 ve R_2 oranları ($C=50$)*



Şekil 5.63. *Random Forest ile model-3 için R_1 ve R_2 oranları ($C=100$)*

Tablo 5.29 ve ilgili grafikler incelendiğinde parametre değerlerindeki değişim ile oran değerlerindeki değişim arasında herhangi bir ilişki olmadığı görülmektedir.

Çalışmada parametre değerlerindeki değişimin dinamik modeller ile sağlanan fayda üzerindeki etkisini ölçmek için yapılan duyarlılık analizleri sonucunda, dinamik model ile sağlanan faydanın parametre değerlerinden etkilenmediği ortaya çıkmıştır. Yapılan analizlerin geneline bakıldığında; hesaplanan belirsizlik maliyetlerinin (E_1 , E_2 , E_1^* , E_2^* ,

E^*) beklenen ve gerçekleşen değerleri arasında büyük ya da küçük farklar olduğu görülmektedir. Ayrıca, aynı p ve t değerleri için farklı kapasitede hesaplanan değerler arasında ya da aynı parametre değerleri için farklı algoritmalar ile hesaplanan değerler arasında ciddi farklar olabildiği görülmektedir. Duyarlılık analizleri sonucunda gözlemlenen bu farkların, çalışmada kullanılan verinin rassallığından kaynaklandığını söylemek mümkündür. Ayrıca parametrelerdeki değişim ile sağlanan fayda miktarı arasında bir model oluşturabilecek herhangi bir ilişkinin olmaması da yine temelde verinin rassallığından kaynaklanmaktadır.

Duyarlılık analizleriyle yapılan bu çıkarımlar dışında dinamik modelin klasik yaklaşıma kıyasla büyük çoğunlukla daha başarılı olduğunu sonucuna varmak da mümkündür. İncelenen üç rezervasyon modeli için de kişisel olasılıklar kullanılarak belirlenen rezervasyon limiti değerleri için hesaplanan belirsizlik maliyetleri verinin rassallığına rağmen daha düşüktür. Parametre değerlerinin farklı kombinasyonları ve farklı algoritmalar ile tahmin edilen değerler için tekrarlanan analizlerin sonuçları, çalışmanın başlangıcında açıklanan rezervasyon limitinin kişisel olasılıklar kullanılarak belirlenmesi önerisinin daha başarılı sonuçlar vereceği düşüncesinin sayısal göstergeleri olmuştur.

6. SONUÇ VE ÖNERİLER

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 kapasitesinin mümkün olduğunca doğru tahmin edilmesidir. Atıl kapasitenin tahmin edilmesi aslında müşteri hareketlerinin tahmini anlamına gelmektedir. Literatürdeki klasik kapasite üzeri rezervasyon uygulamasında, çoğunlukla geçmiş rezervasyon kayıtlarına bakılarak rezervasyonuna gelen müşteri sayısının toplam rezervasyon sayısı içerisindeki oranı, herhangi bir müşterinin rezervasyonuna gelme olasılığı olarak kabul edilmektedir. Özetle, rezervasyon yapan her müşterinin sisteme gelme olasılığı eşit ve sabit kabul edilmektedir. Rezervasyon yapan kişiden bağımsız olarak belirlenen bu olasılık değerinin gerçekçi olmadığı düşünülmüştür ve bu nedenle bu çalışmada optimum rezervasyon limitini belirlemek için kişisel olasılıkların kullanılması önerilmiştir.

Çalışmada, klasik kapasite üzeri rezervasyon modelinin kişisel olasılık kullanımı ile nasıl dinamik bir modele dönüştürülebileceği anlatılmıştır. Bunun dışında, iki farklı kapasite üzeri rezervasyon modeli incelenmiş ve bu iki model için de kişisel olasılık kullanımının gerektirdiği değişiklikler analiz edilmiştir. Önerilen dinamik yapıdaki rezervasyon modellerinde kişisel olasılıkların kullanılması nedeniyle optimum rezervasyon limitinin belirlenmesinde ihtiyaç duyulan bazı olasılık değerlerinin klasik yöntemler yerine Monte Carlo simülasyonu ile hesaplanması önerilmiştir.

Rezervasyon yapan her müşterinin rezervasyonuna gelme olasılığının belirlenmesinde müşterinin rezervasyon sırasında alınan kişiye ve rezervasyona dair kişisel bilgileri kullanılmıştır. Geçmiş rezervasyon kayıtları kullanılarak tahmin algoritmaları ile oluşturulan tahmin modelleri ile rezervasyon yapan müşterinin sisteme gelme olasılığı kişisel bilgileri doğrultusunda belirlenmiştir. Çalışmada, kişisel olasılıkların tahmininde Lojistik Regresyon, Naive Bayes ve Random Forest olmak üzere üç farklı makine öğrenme algoritması kullanılmıştır. Dinamik rezervasyon modellerinin rezervasyon limitleri, algoritmalar ile tahmin edilen kişisel olasılıklar kullanılarak belirlenmiştir. Daha sonra belirlenen rezervasyon limitleri için beklenen kazanç değerleri hesaplanmıştır.

Literatürde geçen klasik kapasite üzeri rezervasyon modeli ile bu çalışmada önerilen dinamik yapıli kapasite üzeri rezervasyon modelini kıyaslamak için karşılaştırma testleri yapılmıştır. Sabit parametre değeri ile yapılan bu testlerde, kişisel ve sabit olasılık değeri ile hesaplanan beklenen ve gerekleşen belirsizlik maliyetleri karşılaştırılmıştır ve kişisel olasılıklar kullanılarak hesaplanan belirsizlik maliyetinin beklenen ve gerekleşen değeriinin sabit olasılık kullanılarak hesaplanan değeriiden daha düşük olduđu görölmüştür. Karşılaştırma testleri üç farklı tahmin algoritmasının tahmin ettiđi kişisel olasılıklar ile tekrarlanmış ve yapılan her karşılaştırmada kişisel olasılık kullanımının daha fazla kazanç sağladığı görölmüştür.

Çalışmada kullanılan tahmin algoritmalarının performanslarını değeriendirmek için farklı istatistiksel ölçümler yapılmıştır. Yapılan ölçümler sonucunda üç algoritmanın tahmin başarılarının birbirine oldukça yakın olduđu görölmüştür.

İncelenen rezervasyon modellerinin, parametrelere göre değerişimini gözlemlemek için duyarlılık analizleri yapılmıştır. Yapılan analizler sonucunda, parametrelerdeki değerişimin sonuçlar üzerinde sistematik bir etkisi olmadığı görölmüştür. Karşılaştırma testlerinde ve duyarlılık analizlerinde gözlemlenen beklenen ve gerekleşen değeriiler arasındaki farkların ve duyarlılık analizlerinde parametrelerdeki değerişimin etkisizliğinin verinin rassallığından kaynaklandığı sonucuna varılmıştır.

Kapasite üzeri rezervasyon uygulaması üzerine yapılmış literatürdeki çalışmalardan farklı olarak bu çalışmada, müşterilerin rezervasyonlarına geliş olasılıklarının makine öğrenme algoritmaları ile tahmini ve bu olasılıklar kullanılarak optimum rezervasyon limitinin belirlenmesi amaçlarını bir arada ele alan bir yaklaşım sunulmuştur. Çalışma sonucunda, kapasite üzeri rezervasyon limitinin belirlenmesinde kişisel olasılık kullanımının atıl kapasiteyi azaltmada klasik yaklaşımdan çok daha başarılı olduđu görölmüştür. İlerideki çalışmalarda, kişisel olasılıkların belirlenmesi için kullanılan algoritmaların geliştirilebileceđi, daha fazla sayıda ve etkin nitelik içeren bir veri seti kullanılabileceđi düşünölmektedir. Bu çalışmada sunulan modeller herhangi bir hizmet sektörü baz alınarak oluşturulmamıştır. Yine ilerideki çalışmalarda, dinamik yapıdaki kapasite üzeri rezervasyon uygulamasının sektörler bazda ele alınarak incelenmesi önerilmektedir.

KAYNAKÇA

- Alstrup, J., Boas, S., Madsen, O. B. G. ve Vidal, R. V. V. (1986). Booking policy for flights with two types of passengers. *European Journal of Operational Research*, 27(3), 274–288.
- Aydın, N., Birbil, Ş.İ., Frenk, J.B.G. ve Noyan, N. (2013). Single-leg airline revenue management with overbooking. *Transportation Science*, 47(4), 560-583.
- Beckmann, J. M. (1958). Decision and team problems in airline reservations. *Econometrica*, 26(1), 134–145.
- Boz, M., Canbazoğlu, E., Özen, Z. ve Gülseçen, S. (2018). Otel rezervasyon iptallerinin makine öğrenmesi yöntemleri ile tahmin edilmesi. *Veri Bilimi Dergisi*, 1(1), 7-14.
- Chatwin, R. E. (1998). Multi-period airline overbooking with a single fare class. *Operations Research*, 46(6), 805–819.
- Chatwin, R. E. (1999). Continuous-time airline overbooking with time dependent fares and refunds. *Transportation Science*, 33(2), 182–191.
- Coughlan, J. (1999). Airline overbooking in the multi-class case. *Journal of the Operational Research Society*, 50(11), 1098–1103.
- Dupuis, C., Gamache, M. ve Pagé, J.F. (2012). Logical analysis of data for estimating passenger show rates at Air Canada. *Journal of Air Transport Management*, 18, 78-81.
- El-Sharo, M., Zheng, B., Yoon, S. W. ve Khasawneh, M. T. (2015). An overbooking scheduling model for outpatient appointments in a multi-provider clinic. *Operations Research for Health Care*, 6, 1-10.
- Erdelyi, A. ve Topaloğlu, H. (2010). A dynamic programming decomposition method for making overbooking decisions over an airline network. *Inform Journal on Computing*, 22(3), 443-456.
- Feng, Y. ve Xiao, B. (2006). A continuous-time seat control model for single-leg flights with no-shows and optimal overbooking upper bound. *European Journal of Operational Research*, 174, 1298-1316.
- Garrow, L. A. ve Koppelman, F. S. (2004). Predicting air travelers' no-show and standby behaviour using passenger and directional itinerary information. *Journal of Air Transport Management*, 10, 401-411.

- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P. ve Witten, I. H. (2009). The WEKA data mining software: An update. *SIGKDD Explorations*, 11(1), 10-18.
- Huang, Y., Ge, Y., Zhang, X. ve Xu, Y. (2013). Overbooking for parallel flights with transference. *International Journal of Production Economics*, 144(2), 582-589.
- Huang, Y. ve Hanauer, D. A. (2014). Patient no-show predictive model development using multiple data sources for an effective overbooking approach. *Applied Clinical Informatics*, 5, 836-860.
- Hueglin, C. ve Vanotti, F. (2001). Data mining techniques to improve forecast accuracy in airline business. *Bilgi Keşfi ve Veri Madenciliği Konulu 7. Uluslararası ACM SIGKDD Konferansının Bildirileri*, San Francisco, California, 438-442.
- Ivanov, S.H. (2015). Optimal overbooking limits for a hotel with three room types and with upgrade and downgrade constraints. *Tourism Economics*, 21(1), 223-240.
- Karaesmen, I. ve van Ryzin, G. J. (2004). Overbooking with substitutable inventory classes. *Operations Research*, 52 (1), 83–104.
- Kavcar, B. (2004). *Simülasyon yöntemi kullanılarak satış tahminleriyle satış bütçesi hazırlanması*. Yayımlanmamış Yüksek Lisans Tezi. Ankara: Ankara Üniversitesi, Sosyal Bilimler Enstitüsü.
- Kılıç, S. (2015). Kappa test. *Journal of Mood Disorders*, 5(3), 142-144.
- Klophaus, R. ve Pölt, S. (2007). Airline overbooking with dynamic spoilage costs. *Journal of Revenue and Pricing Management*, 6, 9-18.
- Lan, Y., Ball, M. O. ve Karaesmen, I. Z. (2011). Regret in overbooking and fare-class allocation for single leg. *Manufacturing & Service Operations Management*, 13(2), 194–208.
- Lawrence, R.D., Hong, S.J. ve Cherrier, J. (2003). Passenger-based predictive modeling of airline no-show rates. *Bilgi Keşfi ve Veri Madenciliği Konulu 9. Uluslararası ACM SIGKDD Konferansının Bildirileri*, Washington, D.C., 397-406.
- Leeuwen, R. V. (2018). *Cancellation predictor for revenue management*, Amsterdam: Vrije Universiteit Amsterdam Business Analytics.
- Mookherjee, R. ve Friesz, T.L. (2008). Pricing, allocation, and overbooking in dynamic service network competition when demand is uncertain. *Production and Operations Management*, 17(4), 455-474.

- Morales, D. R. ve Wang, J. (2010). Forecasting cancellation rates for services booking revenue management using data mining. *European Journal of Operational Research*, 202, 554-562.
- Muthuraman K. ve Lawley, M. (2008). A stochastic overbooking method for outpatient scheduling with no-shows. *IIE Transactions*, 40, 820-837.
- Phillips, R. (2005). *Pricing and revenue of optimization*. Stanford: Stanford University Press.
- Phumchusri, N. ve Maneesophon, P. (2014). Optimal overbooking decision for hotel rooms revenue management. *Journal of Hospitality and Tourism Technology*, 5(3), 261-277.
- Rothstein, M. (1971). An airline overbooking model. *Transportation Science*, 5(2), 180–192.
- Rothstein, M. (1985). OR and the airline overbooking problem. *Operations Research*, 33, 237–248.
- Sands, L. P., Daggy, J. K., Lawley, M., Willis, D. ve Thayer, D. (2011). Using no-show modeling to improve clinic performance. *Health Informatics Journal*, 16(4), 246-259.
- Savaş, S., Topaloğlu, N. ve Yılmaz, M. (2012). Veri madenciliği ve Türkiye'deki uygulama örnekleri. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 11(21), 1-23.
- Schütz, H. J. ve Kolisch, R. (2013). Capacity allocation for demand of different customer-product-combinations with cancellations, no-shows, and overbooking when there is a sequential delivery of service. *Annals of Operations Research*, 206, 401-423.
- Somboon, M. ve Amaruchkul, K. (2017). Applied two-class overbooking model in thailand's passenger airline data. *Tha Asian Journal of Shipping and Logistics*, 33(4), 189-198.
- Subramanian, J., Stidham, S. ve Lautenbacher, C. J. (1999). Airline yield management with overbooking cancellations, and no-shows. *Transportation Science*, 33(2), 147-167.
- Sulima, N. (2012). Probabilistic model of overbooking for an airline. *Automatic Control and Computer Sciences*, 46(1), 49-56.
- Suzuki, Y. (2006). The net benefit of airline overbooking. *Transportation Research*, 42, 1-19.

- Thompson, H. R. (1961). Statistical problems in airline reservation control. *Operational Research Quarterly*, 12(3), 167–185.
- Topaloglu, H., Birbil, S.İ., Frenk, J. ve Noyan, N. (2012). 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.
- Topuz , K., Öztekin, A. ve Yıldırım, M. B. (2018). Predicting pediatric clinic no-shows: A decision analytic framework using elastic net and Bayesian Belief Network. *Annals Operations Research*, 263, 479-499.
- Wannakrairot, A. ve Phumchusri, N. (2016). Two-dimensional air cargo overbooking models under stochastic booking request level show-up rate and booking request density. *Computer & Industrial Engineering*, 100, 1-12.
- Wild, R. (1979). *Production and Operations Management: Principles and Techniques*. Canada: Holt, Rinehart and Winston of Canada.
- Yiğit, F. ve Esnaf, Ş. (2013). Gelir yönetiminde kapasite üzeri rezervasyon için bir karma dinamik model önerisi. *İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Yönetim Dergisi*, 24, 105-120.
- Zeng, B., Türkcan, A., Lin, J. ve Lawley, M. (2010). Clinic scheduling models with overbooking for patients with heterogeneous no-show probabilities. *Annals Operations Research*, 178, 121-144.
- Zenkert, D. (2017). *No-show forecast using passenger booking data*. Yayınlanmamış Yüksek Lisans Tezi. Lund: Lund University, Mathematical Statistic.
- Zhang, C., Guo, C. ve Yi, S. (2014). Airline overbooking problem with uncertain no-shows. *Journal of Applied Mathematics*, 2014.
- http-1:** <https://www.investopedia.com/terms/m/montecarlosimulation.asp>
(Erişim tarihi: 23.03.2019)
- http-2:** <https://www.kaggle.com/joniarroba/noshowappointments>
(Erişim tarihi: 12.02.2019)

ÖZGEÇMİŞ

Adı Soyadı : Tuğçe YAVUZ
Yabancı Dil : İngilizce
Doğum Yeri ve Yılı : Trabzon/1994
E-Posta : yavuz_tgc@hotmail.com

Eğitim Geçmişi:

- 2017, Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği, Endüstri Mühendisliği Anabilim Dalı.

Yayınlar:

- 2017, Özet Bildiri, An efficient resource planning software proposal for Small Medium Enterprises (SMEs): A case study in a factory, *International Conference on Computational and Statistical Methods in Applied Sciences*, Samsun: On Dokuz Mayıs Üniversitesi, s.14.