



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
MODELLERİ İLE GERİATRİK ACİL SERVİS
HASTALARINDA HASTANEYE YATIŞ
ÖNGÖRÜSÜ**

Zerrin Defne DÜNDAR

YÜKSEK LİSANS TEZİ

Ocak-2026
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Zerrin Defne DÜNDAR tarafından hazırlanan “Makine öğrenmesi ve derin öğrenme modelleri ile geriatrik acil servis hastalarında hastaneye yatış öngörüsü” adlı tez çalışması 22/01/2026 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Ayşe Merve ACILAR

.....

Danışman

Doç. Dr. Kemal ÇETİN

.....

Üye

Dr. Öğr. Üyesi Vahit TONGUR

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun/.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

Prof. Dr. Hüseyin HAKLI bu tez çalışmasının ikinci danışmanıdır.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Zerrin Defne DÜNDAR

Tarih: 22.01.2026

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME MODELLERİ İLE GERİATRİK ACİL SERVİS HASTALARINDA HASTANEYE YATIŞ ÖNGÖRÜSÜ

Zerrin Defne DÜNDAR

**NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI**

Danışman: Doç. Dr. Kemal ÇETİN

2026, 90 Sayfa

Jüri

**Dr. Öğr. Üyesi Ayşe Merve ACILAR
Doç. Dr. Kemal ÇETİN
Dr. Öğr. Üyesi Vahit TONGUR**

Acil servisler, acil sağlık hizmetlerinin kesintisiz sağlanması amacıyla 7/24 çalışan özelleşmiş hizmet alanlarıdır. Acil servisten hasta akışının sağlanması için hızlı ve doğru tercihlerin yapılması gereken kritik karar noktaları vardır. Acil servislerde klinisyenlerin kullanımına sunulacak yapay zekâ tabanlı karar destek sistemlerinin geliştirilmesi problemi günümüzün en popüler araştırma konularından biridir. Bu modellerin geliştirilmesinde demografik veriler, vital bulgular, tıbbi özgeçmiş bilgileri gibi pek çok değişken kullanılmaktadır. Günümüzde beklenen yaşam süresinin artması ile birlikte acil servislere başvuran geriatrik hasta sayısı da hızla artmaktadır. Geriatrik hastalar acil servis hastaları içinde çoklu komorbidite, azalmış fizyolojik cevaplar, bilişsel ve fonksiyonel kayıplar, sosyal destek eksikliği gibi faktörler nedeniyle özellikli bir gruptur. Bu nedenlerle, tez çalışmamızda geriatrik acil servis hastalarının acil servisten hastaneye yatış sınıflandırma problemine, hemen her acil serviste kolay ve hızlı elde edilebilen değişkenler kullanılarak farklı yapay zekâ modelleri ile çözüm aranmıştır. Retrospektif, gözlemsel, tek merkezli olan tez çalışmamızın hasta popülasyonunu acil servise başvuran 3872 geriatrik hasta oluşturmuştur. Oluşturulan nihai veri setinde, bir hastanın acil servisten hastaneye yatışını öngörmek için 4 ana başlık altında 60 farklı özelliği içeren bir sınıflandırma problemi bulunmaktadır. Nihai veri seti kullanılarak LR, KNN, SMV, RF, AdaBoost, XGB ve MLP modelleri geliştirilmiştir. En yüksek makro ortalama F1 skorları LR, SVM, AdaBoost ve MLP modellerinde elde edilmiştir. En düşük makro ortalama F1 skoru ise KNN modelinde hesaplanmıştır. En düşük duyarlılık değerine sahip modelin KNN (%30) ve en yüksek duyarlılık değerine sahip modellerin LR ile MLP (%63) olduğu tespit edilmiştir. En düşük özgüllük değerine sahip modelin XGB (%76,2) ve en yüksek özgüllük değerine sahip modelin KNN (%91) olduğu tespit edilmiştir. SHAP analizlerinde ilk 20 içinde yer alan ortak özellikler oksijen saturasyonu, Glasgow koma skalası, bilinç değişikliği, dizatri/afazi, focal nörolojik defisit ve nefes darlığıdır. Geriatrik hasta grubunda hastaneye yatış kararının karmaşıklığı göz önüne alındığında, farklı metotlar ile model performansının artırılması acil hasta bakım kalitesini artıracaktır.

Anahtar Kelimeler: acil servis, derin öğrenme, geriatri, hastaneye yatış, makine öğrenmesi

ABSTRACT

MS THESIS

PREDICTION OF HOSPITAL ADMISSION IN GERIATRIC EMERGENCY DEPARTMENT PATIENTS WITH MACHINE LEARNING AND DEEP LEARNING MODELS

Zerrin Defne DÜNDAR

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES OF
NECMETTİN ERBAKAN UNIVERSITY THE DEGREE OF MASTER OF
SCIENCE IN BIOMEDICAL ENGINEERING**

Advisor: Assoc. Prof. Dr. Kemal ÇETİN

2026, 90 Pages

Jury

Asst. Prof. Dr. Ayşe Merve ACILAR

Assoc. Prof. Dr. Kemal ÇETİN

Asst. Prof. Dr. Vahit TONGUR

Emergency departments (ED) are specialized service areas that operate 7/24 to ensure the uninterrupted provision of emergency healthcare services. There are critical decision points where quick and accurate choices must be made to ensure patient flow through the ED. Developing AI-based decision support systems for clinicians in EDs is one of today's most popular research topics. Many variables, such as demographic data, vital signs, and medical history information, are used in developing these models. With the increase in life expectancy today, the number of geriatric patients visiting EDs is also rapidly increasing. Geriatric patients are a distinct group among ED patients due to factors such as multiple comorbidities, decreased physiological responses, cognitive and functional losses and lack of social support. For these reasons, our thesis study sought solutions to the problem of classifying geriatric ED patients for hospital admission using different artificial intelligence models based on variables that can be easily and quickly obtained in almost any ED. Our thesis study, which was retrospective, observational, and single-center, included a patient population of 3,872 geriatric patients who visited the ED. In the final dataset created, there is a classification problem that includes 60 different features under 4 main headings to predict a patient's admission to the hospital from the ED. Using the final dataset, LR, KNN, SMV, RF, AdaBoost, XGB, and MLP models were developed. The highest macro-average F1 scores were obtained with the LR, SVM, AdaBoost, and MLP models. The lowest macro-average F1 score was calculated with the KNN model. It was determined that the model with the lowest sensitivity value was KNN (30%) and the models with the highest sensitivity values were LR and MLP (63%). It was determined that the model with the lowest specificity value was XGB (76.2%) and the model with the highest specificity value was KNN (91%). Characteristics among the top 20 in SHAP analyses were oxygen saturation, Glasgow coma scale, altered consciousness, dysarthria/aphasia, focal neurological deficit, and shortness of breath. Considering the complexity of the hospital admission decision in the geriatric patient group, improving model performance using different methods will enhance the quality of emergency patient care.

Keywords: emergency department, deep learning, geriatrics, hospital admission, machine learning

ÖNSÖZ

Yüksek lisans eğitimim ve tez çalışmam boyunca birlikte çalışmaktan büyük keyif aldığım, değerli vakitlerini ve tecrübelerini benden esirgemeyen danışmanlarım Doç. Dr. Kemal ÇETİN hocama ve Prof. Dr. Hüseyin HAKLI hocama teşekkür ediyorum.

Tez çalışmamda makine öğrenmesi ve derin öğrenme modellerinin oluşturulmasında büyük katkısı olan Mehmet ÖNEMLİ'ye teşekkür ediyorum.

Akademik serüvenimin her anında bana eşlik eden ve desteklerini sonuna kadar hissettiğim eşim Abdullah Oktay, oğlum Hüseyin Buğra ve kızım Nur İrem'e sonsuz teşekkürlerimi sunuyorum.

Zerrin Defne DÜNDAR
KONYA-2026

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	x
KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
2.1. Acil Servis İşleyişi ve Kritik Karar Noktaları	3
2.2. Acil Servisten Hastaneye Yatış Öngörüsü	5
2.3. Acil Serviste Geriatrik Hasta Popülasyonu	7
2.4. Makine Öğrenmesi ve Derin Öğrenme	9
2.5. Acil Servisten Hastaneye Yatış Öngörüsünde Makine Öğrenmesi ve Derin Öğrenme Uygulamaları.....	14
2.5.1. Erişkin acil servis hastalarına yönelik uygulamalar	14
2.5.2. Geriatrik acil servis hastalarına yönelik uygulamalar.....	17
3. MATERYAL VE YÖNTEM.....	19
3.1. Veri Seti Oluşturulması	19
3.1.1. Hasta popülasyonu	19
3.1.2. Değişkenler	20
3.2. Ham Veri Seti Ön İşleme Basamakları	21
3.3. Nihai Veri Seti Hasta Popülasyonu Özelliklerinin İncelenmesi	23
3.4. Nihai Veri Seti Hazırlık Aşamaları.....	23
3.4.1. Eğitim ve test veri setlerinin oluşturulması	25
3.4.2. Katmanlı K-kat çapraz validasyon.....	25
3.4.3. Hiperparametre ayarları	26
3.5. Makine Öğrenmesi ve Derin Öğrenme Modelleri	28
3.5.1. Lojistik regresyon (LR)	28
3.5.2. K-en yakın komşu (KNN).....	28
3.5.3. Destek vektör makineleri (SVM).....	29
3.5.4. Rasgele orman (RF)	30
3.5.5. Uyarlanabilir artırma (AdaBoost).....	32
3.5.6. Aşırı gradyan artırma (XGB).....	33
3.5.7. Çok katmanlı algılayıcı (MLP)	34
3.6. Makine Öğrenmesi ve Derin Öğrenme Modellerinde Performans Değerlendirme Metrikleri	36

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	41
4.1. Hasta Popülasyonunun Özellikleri.....	41
4.2. Makine Öğrenmesi ve Derin Öğrenme Model Sonuçları	43
4.2.1. Lojistik regresyon (LR)	43
4.2.2. K-en yakın komşu (KNN).....	47
4.2.3. Destek vektör makineleri (SVM).....	51
4.2.4. Rasgele orman (RF)	55
4.2.5. Uyarlanabilir artırma (AdaBoost).....	59
4.2.6. Aşırı gradyan artırma (XGB).....	63
4.2.7. Çok katmanlı algılayıcı (MLP)	67
4.3. Makine Öğrenmesi ve Derin Öğrenme Modellerinin Karşılaştırılması.....	71
5. SONUÇLAR VE ÖNERİLER	78
5.1 Sonuçlar	78
5.2 Öneriler	79
6. KAYNAKLAR	80
EKLER	89

ŞEKİLLER LİSTESİ

Şekil 2.1. Acil servis hasta akış şeması	4
Şekil 2.2. Makine öğrenme metotları	11
Şekil 2.3. Tekrarlayan sinir ağı modeli.....	12
Şekil 3.1. Hasta popülasyonu oluşturma akış şeması	20
Şekil 3.2. Ham veri seti	21
Şekil 3.3. Acil servise başvuru sırasında ölçülen vital bulguların korelasyon matrisi ...	22
Şekil 3.4. Modellerde kullanılan nihai veri seti	23
Şekil 3.5. Katmanlı K-kat çapraz validasyon	26
Şekil 3.6. GridSearch ve RandomizedSearch ile hiperparametre ayarı.....	27
Şekil 3.7. Destek vektör makineleri (SVM) algoritması	30
Şekil 3.8. Rasgele orman (RF) algoritması.....	31
Şekil 3.9. Aşırı gradyan artırma (XGB) algoritması	33
Şekil 3.10. Çok katmanlı algılayıcı (MLP) algoritması.....	35
Şekil 3.11. Karışıklık matrisi	36
Şekil 3.12. ROC eğrisi ve eğri altında kalan alan.....	39
Şekil 3.13. SHAP analiz grafik örneği	40
Şekil 4.1. LR modeli sınıflandırma raporu	44
Şekil 4.2. LR modeli karışıklık matrisi.....	45
Şekil 4.3. LR modeli ROC eğrisi.....	46
Şekil 4.4. LR modeli SHAP analizi	47
Şekil 4.5. KNN modeli sınıflandırma raporu	48
Şekil 4.6. KNN modeli karışıklık matrisi	49
Şekil 4.7. KNN modeli ROC eğrisi	50
Şekil 4.8. KNN modeli SHAP analizi	51
Şekil 4.9. SVM modeli sınıflandırma raporu	52
Şekil 4.10. SVM modeli karışıklık matrisi	53
Şekil 4.11. SVM modeli ROC eğrisi	54
Şekil 4.12. SVM modeli SHAP analizi	55
Şekil 4.13. RF modeli sınıflandırma raporu	56
Şekil 4.14. RF modeli karışıklık matrisi.....	57
Şekil 4.15. RF modeli ROC eğrisi.....	58
Şekil 4.16. RF modeli SHAP analizi	59
Şekil 4.17. AdaBoost modeli sınıflandırma raporu	60
Şekil 4.18. AdaBoost modeli karışıklık matrisi.....	61
Şekil 4.19. AdaBoost modeli ROC eğrisi.....	62
Şekil 4.20. AdaBoost modeli SHAP analizi	63
Şekil 4.21. XGB modeli sınıflandırma raporu.....	64
Şekil 4.22. XGB modeli karışıklık matrisi	65
Şekil 4.23. XGB modeli ROC eğrisi	66
Şekil 4.24. XGB modeli SHAP analizi.....	67
Şekil 4.25. MLP modeli sınıflandırma raporu	68
Şekil 4.26. MLP modeli karışıklık matrisi	69
Şekil 4.27. MLP modeli ROC eğrisi.....	70
Şekil 4.28. MLP modeli SHAP analizi.....	71
Şekil 4.29. Modellerin doğruluk değerlerinin karşılaştırılması.....	72
Şekil 4.30. Modellerin kesinlik değerlerinin karşılaştırılması.....	73
Şekil 4.31. Modellerin duyarlılık ve özgüllük değerlerinin karşılaştırılması	74
Şekil 4.32. Modellerin ROC EAA değerlerinin karşılaştırılması	75

TABLÖLER LİSTESİ

Tablo 2.1. Acil servis hasta yönetimi kritik karar noktaları.....	3
Tablo 2.2. Sınıflandırma problemlerinde kullanılan makine öğrenmesi ve derin öğrenme modelleri	13
Tablo 3.1. HBYS hasta taramasından elde edilen veri parametreleri	20
Tablo 3.2. Veri setindeki özelliklerin ikili kodlamaları	22
Tablo 4.1. Hasta popülasyonunun demografik özellikleri	41
Tablo 4.2. Hasta popülasyonunun acil serviste ilk ölçülen vital bulguları	41
Tablo 4.3. Hasta popülasyonunun acil servise başvuru semptom dağılımı	42
Tablo 4.4. Hasta popülasyonunun özgeçmişinde yer alan kronik hastalık dağılımı.....	43
Tablo 4.5. Model metriklerinin karşılaştırması.....	72
Tablo 4.6. Modellerde en etkili 20 özelliğin dağılımı.....	77

KISALTMALAR

Bu çalışmada kullanılmış kısaltmalar açıklamaları ile birlikte aşağıda sunulmuştur.

KISALTMALAR

AdaBoost	Adaptive Boosting (Uyarlanabilir Artırma)
ANN	Artificial Neural Network (Yapay Sinir Ağı)
DNN	Deep Neural Network (Derin Sinir Ağı)
EAA	Eğri altında alan alan
GA	Güven aralığı
GBoost	Gradient Boosting (Gradyan Artırma)
KNN	K-Nearest Neighbors (K-En Yakın Komşu)
KOAH	Kronik Obstrüktif Akciğer Hastalığı
LR	Logistic Regression (Lojistik Regresyon)
MLP	Multi Layer Perceptron (Çok Katmanlı Algılayıcı)
OAB	Ortalama Arter Basıncı
RF	Random Forest (Rasgele Orman)
ROC	Receiver Operating Characteristic (Alıcı Operatör Karakteristiği)
SHAP	SHapley Additive Explanations
SVM	Support Vector Machines (Destek Vektör Makineleri)
XGB	Extreme Gradient Boosting (Aşırı Gradyan Artırma)

1. GİRİŞ

Acil servisler 7 gün 24 saat sağlık hizmeti sunan birimlerdir. Acil servis hizmet sunumu sırasında karşılaşılan en yaygın problemler acil servis kalabalığı, triyaj sorunları, fiziksel alan yetersizliği, malzeme ve personel eksikliğidir (Söyük ve Kurtuluş, 2017). Acil servisten hasta akışının hızlı sağlanması için doğru tercihlerin yapılması gereken kritik klinik karar noktaları vardır. 1980'lerden sonra yapay zekâ kavramının ortaya atılmasıyla bilişim teknolojilerinde yaşanan gelişmeler klinik karar destek sistemleriyle ilgili değişimlere hız kazandırmıştır (Piliuk ve Tomforde, 2023). Akıllı karar destek sistemleri, karar vermeyi desteklemek için insan benzeri akıllı davranışlar sağlamaya yönelik teknikler kullanan modern bilgisayarların gücünden yararlanmaktadır. Bu durum, geleneksel karar destek sistemlerini bir üst seviyeye taşımaktadır (Fernandes, Vieira, vd., 2020). Acil servislerde klinisyenlerin kullanımına sunulacak yapay zekâ tabanlı karar destek sistemlerinin geliştirilmesi problemi günümüzün en popüler araştırma konularından biridir.

Araştırmanın önemi

Güncel literatürde, acil hasta akışı sürecinde kullanılabilecek yapay zekâ tabanlı klinik karar destek sistemlerinin geliştirilmesi ile ilgili çalışmalar hızla artmaktadır. Yapılan çalışmalarda, yapay zekâ tabanlı sistemlerinin tanı koyma, mortalite tahmin etme, hastaneye yatış tahmin etme, hasta ciddiyet sınıfının belirleme gibi farklı klinik hedefleri vardır. Yine bu modellerde demografik veriler, vital bulgular, tıbbi özgeçmiş bilgileri, ambulans kullanımı gibi pek çok değişkene yer verilmiştir. Literatürde yer alan çalışmalarda yapay zekâ tabanlı karar destek sistemlerinin klasik karar destek sistemlerinden daha iyi performans sergilediği bildirilmektedir (Lee vd., 2021; Piliuk ve Tomforde, 2023; Raita vd., 2019).

Günümüzde beklenen yaşam süresinin artması, acil servislere başvuran geriatric hasta sayısının da hızla artmasına neden olmaktadır. Acil servis hastaları içinde geriatric yaş grubu çoklu komorbidite, çoklu ilaç kullanımı, azalmış fizyolojik cevaplar, bilişsel ve fonksiyonel kayıplar, kişisel bakım becerisinin azalması, sosyal destek eksikliği gibi faktörler nedeniyle özellikli bir gruptur (Dundar vd., 2016; Karamercan vd., 2023). Geriatric hastaların acil serviste kalış süresi, tetkik/tedavi ihtiyacı, hastaneye yatış ve mortalite oranları genç hasta gruplarına göre daha fazladır. Bahsedilen bu farklılıklar ne

deniyle geriatric hasta grubuna özel klinik karar destek sistemlerinin geliştirilmesi acil hasta yönetimi ve akışı için önem arz etmektedir.

Güncel literatürde geriatric acil servis hastalarının hastaneye yatış ihtimalini belirlemeye yönelik yapay zekâ tabanlı karar destek sistemleri ile ilgili sınırlı sayıda çalışma vardır (Buenrostro-Mariscal vd., 2025; Bunney vd., 2023; Mowbray vd., 2020). Literatürde yer alan geriatric hasta popülasyonu ile ilgili çalışmalarının ayrıntıları incelendiğinde, yapay zekâ modellerinde farklı değişkenlerin kullanıldığı ve farklı sınıflandırma problemlerine odaklanıldığı gözlemlenmiştir. Geriatric hastalarında acil servis yönetiminin iyi planlanabilmesi için, dakikalar içinde yatak başı elde edilebilecek parametreler ile ciddiyet sınıfını belirlemeye çalışmak acil tıbbın en önemli araştırma konularından birisidir. Literatürde bu popülasyonda yeterli kanıt düzeyi oluşturacak araştırma sonuçları yer almamaktadır.

Bu bağlamda, tez çalışmamızda geriatric acil servis hastalarının acil servisten hastaneye yatış sınıflandırma problemine, hemen her acil serviste hızlı elde edilebilen parametreler kullanılarak farklı yapay zekâ modelleri ile çözüm aranmıştır.

Araştırmanın amacı

Tez çalışmamızda, geriatric hasta grubunda acil servise başvurunun ilk dakikalarında yatak başı elde edilen verilerle oluşturulan, hastaların acil servisten hastaneye yatışını öngörebilecek makine öğrenmesi ve derin öğrenme model uygulamalarının yapılması amaçlanmıştır.

2. KAYNAK ARAŞTIRMASI

2.1. Acil Servis İşleyişi ve Kritik Karar Noktaları


Acil servisler, modern yataklı sağlık kuruluşlarının en hayati bileşenlerinden biridir. Acil sağlık hizmetlerinin kesintisiz sağlanması amacıyla 7 gün 24 saat esasında çalışan, poliklinik ve yataklı birimlerden oluşan özelleşmiş hizmet alanlarıdır (T.C. Sağlık Bakanlığı, 2022). Acil servis işleyişi kavramı oldukça kapsamlıdır ve hastaların kuruma ilk giriş/kayıt anından başlayarak klinik süreçlerin sonuna kadar uzanan tüm aşamaları içerir.

Acil serviste hasta akışının genel adımları, hastaların triyaj sınıflarının belirlenmesi, hastanın hekim tarafından detaylı anamnez/fizik muayene ile değerlendirilmesi, gerekli laboratuvar ve radyolojik tetkiklerinin istenmesi, hayati önem taşıyan müdahale/tedavi uygulamalarının yapılması, hastanın durumunun gözlemlenmesi ve nihayetinde hasta için acil servisten taburculuk veya hastaneye yatış kararının verilmesidir (Al Owad vd., 2018; Kang vd., 2014; Samadbeik vd., 2024). Örnek acil servis hasta akış şeması Şekil 2.1.'de gösterilmiştir.

Acil servis hasta akış şemasının yapısı incelendiğinde, acil servisten etkin hasta akışının sağlanması için sağlık çalışanları tarafından doğru tercihlerin yapılması gereken kritik karar noktaları vardır. Acil servis hasta yönetiminde yer alan kritik karar noktaları Tablo 2.1'de özetlenmiştir (Hinson vd., 2019; Kang vd., 2014).

Tablo 2.1. Acil servis hasta yönetimi kritik karar noktaları

Karar alanı	Karar noktası
Triyaj	Hastanın başvuru sırasında aciliyet derecesi (triyaj sınıfı) nedir?
Triyaj	Hasta stabil mi veya resüsitatif müdahalelere hemen ihtiyacı var mı?
Triyaj	Tetkik/tedavi edilmesi gereken hastanın alınabileceği boş sedye var mı?
Triyaj	Bekleme odasına yönlendirilen hasta ne zaman tekrar değerlendirilmeli?
Tedavi alanları	Hastanın laboratuvar tetkiklerine ihtiyacı var mı?
Tedavi alanları	Hastanın görüntüleme tetkiklerine ihtiyacı var mı?
Tedavi alanları	Hastanın oral veya paranteral tedaviye ihtiyacı var mı?
Tedavi alanları	Hastanın konsültasyon ihtiyacı var mı?
Tedavi alanları	Hastanın acil serviste gözlenmesi gerekli mi?
Tedavi/Gözlem alanları	Hastanın acil servisten hastaneye yatışı gerekli mi?
Tedavi/Gözlem alanları	Hastaneye yatması gereken hasta için boş servis/yoğun bakım yatağı var mı?
Tedavi/Gözlem alanları	Hastanın ileri bir merkeze sevkı gerekli mi?



Şekil 2.1. Acil servis hasta akış şeması (Kang vd., 2014)

Acil servislerin sürekli aktif yapısı, sunulan hizmetin içeriğinin bireye özel belirlenmesi zorunluluğu, bilinçsiz acil servis kullanımı gibi faktörler acil servis hizmet sunumunda ciddi aksaklıklara neden olabilmektedir. Literatürde sıkça belirtilen bu aksaklıkların başında acil servislerdeki aşırı kalabalık, hastaların doğru ve hızlı bir şekilde ciddiyetinin belirlenmesini zorlaştıran triyaj sorunları, klinik karar noktalarında alınan eksik/yanlış kararlar, artan hasta yükünü karşılayamayan yetersiz fiziki alanlar ve hizmet kalitesini doğrudan etkileyen malzeme/personel eksiklikleri gelmektedir. Bu problemler, acil servislerin verimli ve etkin çalışmasını engelleyen temel zorlukları oluşturmaktadır (Al Owad vd., 2018; Hinson vd., 2019; Samadbeik vd., 2024; Söyük ve Kurtuluş, 2017).

Acil servis süreçlerinde karşılaşılan temel zorluklar ve bunlara bağlı alt başlıklar, hasta hizmetlerinin iyileştirilmesi hedefiyle yürütülen bilimsel çalışmalar için ayrı birer araştırma konusudur. Tez çalışmamızda, acil servis hekimlerinin klinik karar verme mekanizmalarındaki kritik noktalardan biri olan “Hastanın acil servisten hastaneye yatışı gerekli mi?” problemine odaklanılmıştır.

2.2. Acil Servisten Hastaneye Yatış Öngörüsü

Trijaj, hastaların tıbbi durumlarının ciddiyetine ve aciliyetine göre sınıflandırılması ve önceliklendirilmesi işlemidir. Acil servis triyajı, sağlık kaynaklarının etkin yönetimi ve hasta güvenliğinin sağlanması açısından kritik öneme sahip bir klinik risk yönetim sistemidir. Bu sistematik yaklaşım, özellikle hayati tehlikesi olan hastalara derhal müdahale edilmesini güvence altına alarak morbidite ve mortalite riskini azaltmayı amaçlar. Triyaj, acil servisteki yoğun iş yükünü hafifletmeye, kaynakların gereken hastalara tahsis edilmesine ve dolayısıyla genel hasta akışının akılcı olarak yönetilmesine olanak sağlar. Literatürde, acil tıp hizmetlerinin kalitesinin artırılması amacıyla tanımlanmış pek çok triyaj sistemi bulunmaktadır (Chen vd., 2020; El Arab ve Al Moosa, 2025; Gorick, 2022; Zachariasse vd., 2019).

Acil servis triyajı sırasında hedeflenen prognostik sonuçları çeşitlidir. Triyaj renk sınıflarının belirlenmesi, yoğun bakım ihtiyacı olanların belirlenmesi, hastaneye yatış ihtiyacı olanların belirlenmesi, acil cerrahi müdahale gerekenlerin belirlenmesi ve erken mortalite riski olanların belirlenmesi gibi farklı hasta ciddiyet kriterleri kullanılabilir (Dundar vd., 2016; El Arab ve Al Moosa, 2025; Lucke vd., 2018; Zachariasse vd., 2019).

Tez çalışmamızda, acil servis hastaları için tanımlanmış prognostik sonlanım noktalarından “acil servisten hastaneye yatış kararı” problemine odaklanılmış ve kaynak araştırması bu yönde derinleştirilmiştir. Acil servis hastalarında hastaneye yatış kararını öngörmeye farklı değişkenler veya skorlama sistemleri kullanılabilir. Bu öngörü mekanizması, hastaların acil servis takibi sırasında ve farklı zaman noktalarında elde edilebilecek verilerin sistematik analizine dayanır. Demografik veriler, triyaj verileri (vital bulgular, başvuru şikâyeti), erken uyarı skorları, fizik muayene bulguları, laboratuvar tetkik sonuçları, görüntüleme tetkik sonuçları gibi veri kaynakları bu amaçla yaygın olarak kullanılır. İleri yaş, ambulans ile acil servise geliş, triyaj ciddiyet sınıfı ve başvuru şikayetleri gibi acil servis başvurusunun ilk dakikalarında elde edilebilecek veriler artmış hastaneye yatış ihtimali ile güçlü korelasyon gösterir. Fizyolojik değerlendirmede ise nabız, kan basıncı, oksijen satürasyonu gibi vital bulgulardaki anormallikler ile bilinç düzeyindeki değişiklikler klinik kritik durumun temel göstergeleri olarak kabul edilir (Brink vd., 2022; Dunder vd., 2016; Lucke vd., 2018; Usman vd., 2019).

Klinik karar verme sürecini standartlaştırmak ve desteklemek amacıyla çeşitli skorlama sistemleri de kullanılabilir. Erken uyarı skorları (MEWS, REMS, NEWS) vital bulgulara dayalı olarak hastanın kötüleşme riskini tahmin eder ve erken yatış ihtiyacını belirler (Dunder vd., 2016; Mitsunaga vd., 2019). Daha kritik hastaların durumunu öngören skorlar arasında ise APACHE II, SOFA ve qSOFA gibi ciddiyet skorları bulunur. Bu skorlama sistemleri, klinik bulgular ile laboratuvar sonuçlarını birleştirerek hastanın genel patofizyolojik durumunu ve sistemik disfonksiyon derecesini nesnel olarak değerlendirmeye olanak tanır. Tüm parametrelerin entegre kullanımı, kaynak yönetimini optimize etmek ve hasta bakım süreçlerini hızlandırmak için hekimlere fayda sağlamaktadır (Küçükceran vd., 2022; Luo vd., 2021; Usman vd., 2019; Wang vd., 2020).

Brink ve ark. tarafından 2022 yılında yapılan bir sistematik derlemede, acil servisten hastaneye yatış problemini ele alan gözlemsel çalışmalar gözden geçirilmiştir. Derlemeye dahil edilen 11 çalışmada 16 farklı model ele alınmıştır. Modellerde yaygın olarak kullanılan parametreler demografik veriler, vital bulgular, triyaj sınıfı, başvuru şikâyeti, acil servis öncesinde tıbbi değerlendirme yapıp yapılmadığı ve ambulans kullanımıdır. Çalışmalarda hastaneye yatış oranı %13 ila %47 arasında değişmektedir. Modellerin EAA değerleri 0,664 ila 0,877 arasında değişmektedir. Aynı çalışmanın geriatrik hasta popülasyonunda yapılan analizlerinde ise hastaneye yatış oranlarının

genç hasta grubuna göre daha fazla olduğu ve %30 ila %59 arasında değiştiği bildirilmiştir. Yine geriatrik hasta grubunda modellerin EAA değerlerinin genç hastalardan daha düşük olduğu ve 0,66 ila 0,77 arasında değiştiği bildirilmiştir (Brink vd., 2022). Bu sistematik derleme sonuçları hastaneye yatış öngörüsü için geliştirilen modellerde kullanılan parametrelerin çeşitli olduğunu, modellerin doğruluk oranlarının değişken olduğunu, ileri yaşlarda hastaneye yatış oranlarının arttığını ve modellerin öngörü doğruluk oranlarının azaldığını göstermektedir.

Zahid ve ark. tarafından 2023 yılında yapılan bir çalışmada, 14 yaş ve üzeri hastalarda acil servis başvurusu sırasında kolayca ulaşılabilen klinik verilere dayalı bir hastaneye yatış tahmin skorum sistemi tasarlanmıştır. Bu çalışmada kullanılan klinik parametreler yaş, cinsiyet, vital bulgular ve özgeçmişte yer alan hastalıklardır. Skorum sistemi çok değişkenli lojistik regresyon analizi ile geliştirilmiştir ve model %83,3 doğruluk düzeyine ve 0,831 ROC eğrisi altında kalan alan (EAA) değerine ulaşmıştır (Zahid vd., 2023)

Yapılan kaynak araştırması sonucunda acil servisten hastaneye yatış öngörüsü için kullanılabilecek parametrelerin çok çeşitli olduğu, farklı parametreler ile geliştirilen öngörü modellerinin farklı doğruluk oranlarına sahip olduğu ve acil serviste hastaneye yatış ihtiyacı olan hastaların erken dönemde belirlenmesinin hasta bakım kalitesini artırdığı tespit edilmiştir. Tez çalışmamızda, acil servisten hastaneye yatış öngörüsü için kullanılacak veri setinde hastaların acil servise başvurularının ilk dakikalarında elde edilebilecek ve ayrıntıları “Materyal ve Yöntem” bölümünde detaylandırılan klinik parametrelerin yer almasına karar verilmiştir.

2.3. Acil Serviste Geriatrik Hasta Popülasyonu

Küresel ölçekte yaşanan demografik değişimler ve ortalama yaşam süresinin uzaması, geriatrik popülasyonun genel hasta yükü içindeki payını giderek artırmaktadır. Bu durum acil servis başvurularında 65 yaş ve üzeri hastaların oranını yükselterek, acil tıp uzmanlarının ve sağlık sistemlerinin karşılaştığı zorlukları derinleştirmektedir (Karamercan vd., 2023; Naouri vd., 2022; Nassisi, 2023).

Geriatrik acil servis hastalarının klinik yönetimi, genç popülasyona kıyasla belirgin ölçüde karmaşıktır. Bu karmaşıklığın temel nedenleri arasında çok sayıda kronik hastalığın eş zamanlı varlığı ve akut hastalıkların atipik klinik prezentasyonu yer almaktadır. Yaşlanma ile azalan fizyolojik rezervler ve artan kırılganlık, geriatrik

popülasyonu akut hastalıklara karşı son derece hassas hale getirmektedir. Akut bir olay veya kısa süreli bir stresör, geri dönüşü zor fonksiyonel bağımlılıklara ve kalıcı engellilik durumuna yol açabilmektedir. Buna ek olarak, çoklu ilaç kullanımı ilaç-ilâç etkileşimleri ve advers ilaç reaksiyon riskini artırarak acil klinik tabloları daha da bulanıklaştırmaktadır (Alakare vd., 2021; Michalski-Monnerat vd., 2020; Pazan ve Wehling, 2021).

Geriatrik hastalarda acil servisten hastaneye yatış kararı, sadece birincil tanının ne kadar ciddi olduğuna dayanmamaktadır. Hastanın bilişsel durumuna, sosyal destek sistemlerinin yeterliliğine, mevcut fonksiyonel bağımsızlık düzeyine dayanan kapsamlı bir multidisipliner değerlendirmeyi zorunlu kılmaktadır. Ancak, acil servislerin yüksek temposu ve kısıtlı kaynakları göz önüne alındığında, bu kapsamlı değerlendirmeyi standartlaştırmak her zaman mümkün olmamaktadır (Michalski-Monnerat vd., 2020; Taylor vd., 2019). Bir yandan yanlış veya gecikmiş yatış kararları hasta güvenliğini tehlikeye atarken, diğer yandan gereksiz yatışlar hem sağlık harcamalarını artırmakta hem de hastane enfeksiyonları gibi iatrojenik komplikasyon riskini yükseltmektedir (Frost vd., 2024; Sankaran vd., 2020).

Geriatrik acil servis hastaları, gençlere kıyasla belirgin derecede yüksek hastaneye yatış oranlarına ve yüksek mortalite riskine sahiptir. Bu yoğun kaynak gereksinimi ve karmaşık bakım ihtiyacı, acil servis iş akış kapasitesi üzerinde önemli bir baskı oluşturmaktadır. Bu nedenle, geriatrik hasta grubuna özel, multidisipliner ve kapsamlı değerlendirme yaklaşımlarının geliştirilmesi zorunludur (Lucke vd., 2022).

Lucke ve ark. tarafından 2018 yılında yapılan bir çalışmada, acil servisten hastaneye yatışın erken tahmini 70 yaş altı ve üzeri hasta gruplarında incelenmiştir. 70 yaş altı hastalarda hastaneye yatış oranının %23 ve 70 yaş üzeri hastalarda yatış oranının %43 olduğu bildirilmiştir. Her iki yaş grubunda da hastaneye yatışın en güçlü bağımsız tahmin parametreleri arasında yaş, triyaj kategorisi, geliş şekli (ambulansla), kan testi yapılması ve vital bulgular yer almaktadır. Model doğruluğunun 70 yaş üzeri hastalarda daha düşük olduğu tespit edilmiştir (70 yaş altı hastalarda EAA 0,86 iken 70 yaş üzeri hastalarda EAA 0,77) (Lucke vd., 2018).

Brouns ve ark. tarafından 2019 yılında yapılan bir çalışmada, Manchester Triage Sisteminin genç ve geriatrik hasta gruplarında hastaneye yatış öngörüsü karşılaştırılmıştır. Geriatrik acil servis hastalarında hastaneye yatış oranları genç hastalardan daha fazladır (%59,4'e karşı %24,5). Çalışma sonucunda geriatrik hasta

grubunda Manchester Triyaj Sisteminin EAA değeri 0,74 olarak bulunmuştur (Brouns vd., 2019).

Schultz ve ark. tarafından 2019 yılında yapılan bir çalışmada, vital bulgular ve acil serviste istenen rutin biyokimya tetkiklerine dayalı modeller ile orta yaş ve ileri yaş gruplarında erken mortalite öngörüsü değerlendirilmiştir. Modellerin her ikisinin de 7 günlük mortalite oranını orta yaşlı hastalarda (EAA 0,88) geriatrik hastalara (EAA 0,75) kıyasla daha iyi ayırt ettiği bildirilmiştir (Schultz vd., 2019).

Karamercan ve ark. tarafından 2023 yılında yapılan bir çalışmada, Avrupa acil servislerine başvuran geriatrik hasta popülasyonunun epidemiyolojik özellikleri incelenmiştir. Bu çalışmada acil servisten hastaneye yatış oranının %43 olduğu ve ilerleyen yaşlarda hastaneye yatış ihtimalinin arttığı bildirilmiştir. Yine bu çalışmada geriatrik acil servis hastalarında komorbidite ve kronik ilaç kullanımı oranlarının çok yüksek olduğu bildirilmiştir (Karamercan vd., 2023).

Yapılan kaynak araştırması sonucunda acil servisten hastaneye yatış öngörüsünün artan yatış oranları, değişken fizyolojik cevaplar, artan kronik hastalıklar nedeniyle geriatrik hasta grubunda daha zor olduğu tespit edilmiştir. Yine güncel literatürde geriatrik hasta grubunda geliştirilen modellerin ulaştığı doğruluk oranları ile ilgili farklı sonuçlar yer almaktadır, ancak hiçbir model ideal ayrımı yapamamaktadır. Bu nedenlerle tez çalışmamızda, acil servisten hastaneye yatış öngörüsü problemi için hedef çalışma popülasyonu geriatrik hasta grubu olarak belirlenmiştir.

2.4. Makine Öğrenmesi ve Derin Öğrenme

Geriatrik hasta popülasyonunda acil servisten hastaneye yatış öngörüsü sınıflandırma problemine hangi metotlarla çözüm aranacağı noktasında kaynak araştırmasına devam edilmiştir. Güncel literatürde sınıflandırma problemlerinin çözümü için geleneksel istatistiksel metotlar ve yapay zekâ destekli modeller kullanılmaktadır (Fernandes, Vieira, vd., 2020; Lucke vd., 2018; Patel vd., 2022; Schultz vd., 2019).

Rajula ve ark. tarafından yayınlanan bir derlemede, geleneksel istatistiksel yöntemler ile makine öğrenmesi teknikleri karşılaştırılmıştır. Geleneksel istatistiksel modellerin temel amacının değişkenler arasındaki ilişkileri anlamak ve yorumlamak olduğu, buna karşılık makine öğrenmesi metotlarının odak noktasının doğru tahminler yapmak olduğu vurgulanmıştır. Geleneksel istatistiksel yöntemlerin kullanımının, az sayıda değişken ve yeterli örnekleme sahip çalışmalarda daha uygun olduğu, ancak

makine öğrenmesinin büyük ve karmaşık veri setlerinde daha esnek ve güçlü sonuçlar verebildiği bildirilmiştir. Makine öğrenmesi modelleri ile tanı süreçleri, prognoz öngörüsü, ilaç keşfi ve kişiselleştirilmiş tedavi geliştirilmesi gibi alanlarda ümit verici sonuçlar alınmaya başlanmıştır. Bununla birlikte makine öğrenmesinin yorumlanmasında zorluklar, aşırı uyum ve büyük veri seti ihtiyacı gibi dezavantajları da bulunmaktadır (Rajula vd., 2020).

Kareemi ve ark. tarafından yapılan bir sistematik derlemede acil servis hastalarında makine öğrenmesi modelleri ile klinik karar kuralları, triyaj skorları gibi geleneksel bakım yöntemleri karşılaştırılmıştır. Bu derlemede, makine öğrenmesi modellerinin hem tanısal hem de prognostik öngörülerde daha yüksek doğruluk ve EAA değerlerine sahip olduğu bildirilmiştir. Ayrıca, makine öğrenmesinin gerçekten hasta sonuçlarını iyileştirip iyileştirmediğini görmek için prospektif, klinik çalışmalar yapılması gerektiği vurgulanmıştır (Kareemi vd., 2021). Yine bir başka çalışmada makine öğrenmesi modellerinin açıklama, tahmin ve nedensel çıkarım görevlerinin her biri için kullanılabilir olduğu, ancak geleneksel istatistiksel yöntemlerin araştırma sorusuna bağlı olarak bazen daha uygun olabileceği bildirilmiştir (Jiang vd., 2020).


Bilişim teknolojilerindeki hızlı gelişim, makinelerin insana özgü bilişsel yetenekleri taklit etmesi fikrini ortaya çıkarmıştır. Yapay zekâ temel olarak makinelere düşünme, öğrenme ve problem çözme gibi yetenekler kazandırmayı hedefleyen bir disiplindir. Bu sayede sistemler karmaşık verileri analiz edebilir ve otonom kararlar alabilir (Choi vd., 2020; Kareemi vd., 2021; Piliuk ve Tomforde, 2023). Klasik programlama, bilgisayarların verileri önceden tanımlanmış algoritmalarla işlemesini gerektirirken, yapay zekâ sistemleri sunulan girdi ve çıktı veri setlerini işleyerek aralarındaki ilişkileri öğrenerek probleme uygun algoritmaları kendiliğinden geliştirir. Bilgisayar tarafından öğrenilen bu modeller, daha sonra yeni verilerin işlenmesi ve tahminlerin yapılması için temel teşkil eden adaptif bir mekanizma sunar (Choi vd., 2020).

Yapay zekâ insanlar tarafından gerçekleştirilen entelektüel görevlerin otomasyonuna odaklanırken, makine öğrenmesi ve derin öğrenme gibi özel yöntemler kullanır. Makine öğrenmesi, yapay zekânın bir alt dalıdır ve bilgisayarların veri setlerinden kendi kendine öğrenerek gelecekteki olayları tahmin etmesini sağlar. Makine öğrenmesinde kullanılan ve her biri farklı problemleri çözmek için uygun olan başlıca üç öğrenme metodu vardır (Botteghi vd., 2025; Choi vd., 2020; Rashidi vd., 2019; Sarker, 2021; Tufail vd., 2023).

1. Denetimli Öğrenme: Bu yaklaşım, algoritmanın etiketlenmiş veri setleri üzerinde eğitilmesini gerektirir. Her bir veri örneği, bir girdi vektörü ve karşılık gelen doğru hedef değişkeni ile sunulur. Algoritmanın temel görevi, bu girdi-çıkı ilişkilerini modelleyerek, gelecekteki bilinmeyen verilere yönelik güvenilir tahminler yapabilecek bir eşleştirme fonksiyonu öğrenmektir. Örneğin, bir görüntüdeki hücre morfolojisi ve biyokimyasal belirteçler kullanılarak, o görüntünün kanserli veya iyi huylu olarak sınıflandırılması denetimli öğrenme altında incelenir.

2. Denetimsiz Öğrenme: Denetimsiz öğrenmede, algoritmalar etiketlenmemiş veri kümeleriyle çalışır; bu nedenle doğru çıktının ne olduğu bilgisi sisteme sağlanmaz. Bu paradigmanın esas amacı verilerin doğal yapısını, gizli korelasyonlarını ve içsel benzerlik yapılarını keşfetmektir. Bir uygulama örneği olarak, bir web sitesi veya yayın platformundaki kullanıcıların gezinme veya izleme geçmişleri analiz edilmesi, benzer ilgi alanlarına sahip kullanıcıların otomatik olarak gruplandırılması ve kişiselleştirilmiş içerik öneri sistemlerinin oluşturulması verilebilir.


3. Pekiştirmeli Öğrenme: Belirli bir ortamda etkileşim kurarak ve bir ödül sistemi aracılığıyla optimal davranış politikasının öğrenilmesi temeline dayanır. Gerçekleştirilen eylemlerin sonucuna göre ödül veya ceza alınır. Bu sürekli geri bildirim mekanizması, uzun vadede biriken toplam ödülü maksimize eden stratejinin geliştirmesini sağlar. Örneğin, borsada işlem yapan bir yapay zekâ ajanı, başarılı alım-satım kararları için ödüllendirilirken, zarar getiren kararlar için cezalandırılır. Böylece en yüksek getiriyi sağlayacak finansal işlem stratejisini otonom olarak öğrenir. Makine öğrenmesi yöntemleri Şekil 2.2’de gösterilmiştir.



Şekil 2.2. Makine öğrenme metodları (Rashidi vd., 2019)

Derin öğrenme, makine öğrenmesinin bir alt dalıdır ve yapay sinir ağları adı verilen çok katmanlı algoritmalar kullanarak karmaşık verilerin analiz edilmesini sağlar. Bu sayede, görüntü tanıma, doğal dil işleme ve ses tanıma gibi alanlarda önemli başarılar elde edilmiştir. Derin öğrenme modelleri teknoloji, sağlık, otomotiv, finans ve daha birçok sektörde kendine uygulama alanı bulmaktadır (Choi vd., 2020; Doğan ve Türkoğlu, 2019; Fernandes, Vieira, vd., 2020; Piliuk ve Tomforde, 2023).

Yapay sinir ağı, biyolojik sinir ağlarından esinlenen bir makine öğrenme algoritmasıdır. Yapay sinir ağları diğer düğümlerle bağlantılar aracılığıyla iletişim kuran düğümler içerir. Bu yapılar canlılardaki nöron gövdeleri, aksonlar ve dendritlere benzerler. Nöronlar arasındaki sinapslarda olduğu gibi yapay sinir ağında düğümler arasındaki bağlantılar hedefe yönelik çıktıya ulaşma yeteneklerine göre ağırlıklandırılır (Choi vd., 2020; Doğan ve Türkoğlu, 2019). Örnek sinir ağı modeli Şekil 2.3'de gösterilmiştir.



Şekil 2.3. Tekrarlayan sinir ağı modeli (Doğan ve Türkoğlu, 2019)

Sağlık alanında çalışmalara konu olan pek çok makine öğrenmesi modeli vardır. Kullanılacak modelin seçimi, çözülmesi beklenen problem ve modele girdi olacak değişkenlerin yapısı ile doğrudan ilişkilidir. Tez çalışmamızda acil servisten hastaneye yatış sınıflandırma problemi ele alınmıştır. Literatürde sınıflandırma problemlerinde kullanılan makine öğrenmesi modelleri Tablo 2.2'de özetlenmiştir (Choi vd., 2020; Fernandes, Vieira, vd., 2020; Piliuk ve Tomforde, 2023).

Tablo 2.2. Sınıflandırma problemlerinde kullanılan makine öğrenmesi ve derin öğrenme modelleri

Model	Temel özellikler
Lojistik Regresyon (Logistic Regression) (LR)	Özellikler ile belirli bir sonucun olasılığı arasındaki ilişkiyi bulmayı amaçlayan bir sınıflandırma algoritmasıdır. Sınıf olasılığını tahmin etmek için lineer regresyonun ürettiği düz çizgiyi kullanmak yerine, sınıf olasılığını tahmin etmek için sigmoidal bir eğri kullanır. Hızlıdır ve yorumlanması kolaydır.
Karar Ağaçları (Decision Trees) (DT)	Veri setini, en iyi sınıflandırmayı sağlayacak şekilde, ardışık ikili kararlarla bölerek çalışır. Her bölünmenin, veriyi homojen gruplara ayırmak için başka bir özellik içeren yeni bir karar düğümüne veya sınıfı tahmin eden bir terminal düğüme bağlanan bir kenarı vardır. Sezgiseldir ve görselleştirilebilir, ancak aşırı öğrenmeye eğilimlidir.
Rastgele Orman (Random Forest) (RF)	Birden çok karar ağacının bir araya gelmesiyle oluşan bir topluluk yöntemidir. Her ağ farklı bir veri alt kümesi üzerinde eğitilir ve sonuçlar birleştirilir. Karar ağaçlarına göre daha doğru ve aşırı öğrenmeye karşı daha dirençlidir.
Destek Vektör Makineleri (Support Vector Machines) (SVM)	Veri noktalarını ayırmak için iki sınıf arasında en büyük sınıra sahip bir hiperdüzlem bulur. Aykırı değerleri göz ardı etme ve sınırı en üst düzeye çıkaran en iyi hiperdüzlemi bulma özelliğine sahiptir. Aykırı değerlere karşı dayanıklıdır.
K-En Yakın Komşu (K-Nearest Neighbors) (KNN)	Öğrenme aşaması yoktur, sadece veriyi depolar. Verilen bir girdiye en yakın "k" veri noktasını (komşuyu) bularak çalışır ve çoğunluk sınıfına veya ortalama değere dayalı tahminler yapar. Basittir ancak büyük veri setlerinde tahmin süresi yavaşlayabilir.
Naive Bayes Sınıflandırıcı	Bayes teoremine ve özelliklerin koşullu olarak bağımsız olduğu varsayımına dayandığı için olasılıksal bir sınıflandırıcı olarak da bilinir.
Gradyan Artırma (Gradient Boosting) (XGB, CatBoost, AdaBoost)	Artırma, bir dizi zayıf modeli arka arkaya birleştirerek güçlü bir öğrenme algoritması oluşturmayı hedefler. XGB, bir topluluk öğrenme yöntemi olan artırma prensibine dayanır. Yeni eklenen her model, önceki modellerin yaptığı hataları düzeltmek için eğitilir. Amaç fonksiyonu hem geleneksel kayıp fonksiyonunu hem de düzenleme terimini içerir.
Yapay Sinir Ağları (Artificial Neural Networks) (MLP, DNN)	İnsan beynindeki nöronları taklit eden katmanlı bir yapıdır. Her yapay sinir ağı diğer düğümlerle bağlantılar aracılığıyla iletişim kuran düğümler içerir. Biyolojik bir sinir ağında, nöronlar arasındaki sinapslar, nöronların çıktıları korelasyonlu olduğunda güçlendirilir. Özellikle birden fazla katmanı olan derin öğrenme modelleri, karmaşık ve yapılandırılmamış verilerde çok başarılıdır.

2.5. Acil Servisten Hastaneye Yatış Öngörüsünde Makine Öğrenmesi ve Derin Öğrenme Uygulamaları

2.5.1. Erişkin acil servis hastalarına yönelik uygulamalar

Güncel literatürde acil servis çalışanlarına, acil hasta akışı sürecinde yardımcı olacak yapay zekâ tabanlı klinik karar destek sistemlerinin geliştirilmesi ile ilgili çalışmalar hızla artmaktadır. Piliuk ve Tomforde tarafından yapılan bir sistematik derlemede, acil servis hasta popülasyonu için kullanılan yapay zekâ algoritmaları incelenmiştir. Literatürde yer alan makalelerin yıllar içinde arttığı bildirilmiştir. Makalelerde yapay zekâ tabanlı sistemlerin hedefleri tanı koyma, mortalite tahmini, hastaneye yatış tahmini, hasta ciddiyet sınıfının belirlenmesi gibi farklılıklar arz etmektedir. Çalışmada yer alan makalelerin tanı spesifik ve triyaj spesifik olmak üzere başlıca iki ana sınıfta toplandığı bildirilmiştir. Çalışmaların dizaynına göre kullanılan yapay zekâ modelleri ve değişkenler çok çeşitlidir (Piliuk ve Tomforde, 2023).

Hong ve ark. tarafından 2018 yılında yapılan bir çalışmada, triyaj verileri kullanılarak acil servisten hastaneye yatış makine öğrenmesi modelleriyle tahmin edilmeye çalışılmıştır. Çalışmada yaklaşık 550.000 acil servis başvurusu ve 972 değişken gözden geçirilmiştir. 9 farklı sınıflandırmaya yönelik makine öğrenmesi modeli karşılaştırılmış ve en başarılı modellerin LR (EAA 0,87), XGB (EAA 0,87) ve DNN (EAA 0,87) olduğu bildirilmiştir (Hong vd., 2018).

Raita ve ark. tarafından 2019 yılında yapılan bir çalışmada, acil servis hastalarında kritik bakım ihtiyacı ve hastaneye yatışı tahmin etme probleminde yapay zekâ modellerinin etkinliği değerlendirilmiştir. Modellere yaş, cinsiyet, acil servise geliş şekli, vital bulgular, ana şikayetler, özgeçmişte yer alan hastalıklar değişken olarak dahil edilmiştir. Lasso regresyon, karar ağaçları, RF ve DNN modelleri ESI triyaj sistemine dayalı referans modelle karşılaştırılmıştır. Sonuç olarak yapay zekâ destekli modellerin her iki sonlanım noktası (kritik bakım ihtiyacı ve hastaneye yatış) için referans modelden daha başarılı sınıflandırma yaptığı bildirilmiştir (Raita vd., 2019).

Fernandes ve ark. tarafından 2020 yılında yapılan bir çalışmada, acil servis hastalarının yoğun bakıma yatış problemi ele alınmış ve probleme makine öğrenmesi ile doğal dil işleme yöntemleri kullanılarak çözüm aranmıştır. Çalışmada LR, RF ve Boost algoritmaları triyaj verileri ve ana şikayetler kullanılarak eğitilmiştir. LR modelinin hem

test hem de validasyon setlerinde en yüksek performansa ulaştığı bildirilmiştir (EAA 0,91 ve 0,85) (Fernandes, Mendes, vd., 2020).

De Hond ve ark. tarafından 2021 yılında yapılan bir çalışmada, farklı makine öğrenmesi modelleriyle (RF, GBoost, DNN) acil servisten hastaneye yatış tahmini yapılmıştır. Modellerde eğitim için triyaj, vital bulgular ve laboratuvar testleri kullanılmış ve en iyi performansı GBoost modelinin sergilediği (EAA 0,86) bildirilmiştir (De Hond vd., 2021).

Lee ve ark. tarafından 2021 yılında yapılan bir çalışmada, acil servis hastalarından hastaneye yatacak olanların belirlenmesi amacıyla 11 klinik veri kullanılarak sinir ağıları metodolojisiyle uyumlu bir makine öğrenmesi modeli geliştirilmiştir. Modelin EAA değerinin 0,80, duyarlılığının %67 ve özgüllüğünün %78 olduğu bildirilmiştir. Bu çalışmada hastaneye yatış oranı % 15,8'dir (Lee vd., 2021).

Fenn ve ark. tarafından 2021 yılında yapılan bir çalışmada, acil servis hastalarının hastaneye yatışını tahmin etmek üzere hastaların geçmiş hastalık öyküleri ile endeks başvurusundaki bilgilerini birleştiren makine öğrenme modeli değerlendirilmiştir. Geliştirilen modelin yoğun bakıma yatış tahmininde servise yatış tahmininden daha başarılı olduğu bildirilmiştir (servis yatışı için EAA 0,873 ve yoğun bakıma yatış için EAA 0,951) (Fenn vd., 2021).

Feretzakis ve ark. tarafından 2022 yılında yapılan bir çalışmada, acil durumlarda klinik karar almaya yardımcı olmak için makine öğrenmesi tekniklerini kullanan bir algoritma geliştirilmiştir. Modellerde girdi olarak yaş, cinsiyet, ambulansla acil servise getirilme özelliklerine ek olarak laboratuvar sonuçları kullanılmıştır. Çalışmada 8 farklı makine öğrenmesi modelinin performansı karşılaştırılmış ve modellerin hastaneye yatış tahmininde EAA değerlerinin 0,734 ile 0,774 arasında değiştiği bildirilmiştir (Feretzakis vd., 2022).

Patel ve ark. tarafından 2022 yılında yapılan bir çalışmada, acil servis hastalarında 30, 60, 90, 120 ve 150. dakikalarda elde edilen veriler ile hastaneye yatışı XGB modeliyle farklı zaman noktaları için değerlendirilmiştir. Modelin EAA değerlerinin farklı zaman noktaları için 0,84 ile 0,88 arasında değiştiği bildirilmiştir. Ayrıca, hastaların acil serviste geçirdiği süre uzadıkça girdilerin çeşitlenmesi ile model duyarlılığında artış gözlemlendiği (30. dakika %34,8 iken 150. dakikada %45) tespit edilmiştir. Çalışmada modelin özgüllüğünün tüm zaman dilimleri için %95'in üzerinde olduğu da bildirilmiştir. Bu çalışmada hastaneye yatış oranı %19,3'dür (Patel vd., 2022).

Xiao ve ark. tarafından 2023 yılında yapılan bir çalışmada, acil servis hastalarının ciddiyet seviyesinin belirlenmesi ve hastaneye yatış kararını desteklemek üzere geliştirilen yeni bir model değerlendirilmiştir. Bu çalışmada diğer çalışmalardan farklı olarak yazılı olan triyaj kayıtlarının doğal dil işleme teknikleri ile ön hazırlığı yapılmış ve daha sonrasında yeni geliştirilen model diğer makine öğrenmesi ve derin öğrenme modelleri ile karşılaştırılmıştır. Çalışma sonucunda dil işleme tekniklerinin triyaj kayıtlarını değerlendirme ve hastaların doğru triyaj sınıfına atanması noktasında acil servis çalışanlarına değerli katkılar sağlayacağı bildirilmiştir (Xiao vd., 2023).

Tschoellitsch ve ark. tarafından 2023 yılında yapılan bir çalışmada, acil servisten servise ve yoğun bakıma yatışı tahmin için başvurunun ilk 10 dakikasında elde edilebilecek veriler ile RF ve ANN dahil makine öğrenmesi modellerinin performansları değerlendirilmiştir. Çalışma sonucunda RF ve ANN modellerinin servise yatış için 0,842 EAA değerine ulaştığı ve modelde en etkili özelliklerin yaş ve ana başvuru şikâyeti olduğu bildirilmiştir. Yoğun bakıma yatış tahmini için EAA 0,819 olarak tespit edilirken, bu sonlanım noktası için modelde en etkili özelliklerin triyaj kategorisi ve kalp hızı olduğu bildirilmiştir (Tschoellitsch vd., 2023).

Kishore ve ark. tarafından 2023 yılında yapılan bir çalışmada, 600.000 acil servis hastasının demografik ve klinik verileri incelenmiş ve hastaneye yatış tahmini için XGB metodu kullanılarak bir model geliştirilmiştir. Çalışmada ayrıca başvurunun farklı dakikalarında elde edilebilen verilerin modelin tahmin performansını nasıl etkilediği de incelenmiştir. Geliştirilen model acil servise başvurunun 30. dakikasında hastane servislerine yatışı %80 doğruluk oranı ile tahmin etmiştir. Bu çalışmada %22,6'sı servis yatışı olmak üzere hastaneye yatış oranı %41,6'dır. (Kishore vd., 2023).

Chang ve ark. tarafından 2024 yılında yapılan bir çalışmada, acil servis hastalarının hastaneye yatış tahmini problemi makine öğrenmesi modelleri ile değerlendirilmiştir. Çalışmada altı farklı makine öğrenmesi modeli karşılaştırılmış ve model girdisi olarak hasta dosyalarında yer alan tüm bilgiler yer almıştır. Ayrıca, veri seti oluşturulurken doğal dil işleme yöntemlerinden de yararlanılmıştır. Çalışma sonucunda, tüm modellerin acil servis hekimleri tarafından verilen kararlardan daha yüksek F1 skorlarına ulaştığı bildirilmiştir (Chang vd., 2024).

Zhang ve ark. tarafından 2025 yılında yapılan bir çalışmada, 18 yaş ve üzeri acil servis hastalarında acil servisten hastaneye yatış tahmini için GBoost sınıflandırıcısı ve GPT-2'nin birleştirildiği bir model geliştirilmiştir. Modelde girdi olarak hastaların demografik verileri, vital bulguları, tıbbi özgeçmiş bilgileri ve başvuru şikayetleri ile

ilgili bilgiler kullanılmıştır. Model %75,8 doğruluk oranında hastaneye yatışı tahmin edebilmiştir (Zhang vd., 2025).

Agius ve ark. tarafından 2025 yılında yapılan bir çalışmada, acil servis hastalarının triyaj sınıflarının ve acil servisten hastaneye yatış ihtimallerinin belirlenmesi için bir makine öğrenmesi modelinin etkinliği iki aşamada değerlendirilmiştir. Çalışmada sınıflandırma modellemesi XGB ile yapılmış ve birinci aşamada model girdisi olarak triyaj verileri kullanılırken ikinci aşamada model girdilerine triyaj verilerinin yanında acil servis takibi sırasında elde edilen laboratuvar sonuçları eklenmiştir. Modele laboratuvar sonuçlarının eklenmesi ile hastaneye yatış öngörüsünün %80'den %82'ye yükseldiği bildirilmiştir (Agius vd., 2025).

2.5.2. Geriatrik acil servis hastalarına yönelik uygulamalar

Güncel literatürde geriatrik acil servis hastalarının hastaneye yatış ihtimalini belirlemeye yönelik yapay zekâ tabanlı karar destek sistemleri ile ilgili sınırlı sayıda çalışma vardır.

Mowbray ve ark. tarafından 2020 yılında yapılan bir çalışmada, geriatrik acil servis hastalarında hastaneye yatışı öngörmeye yönelik beş farklı yapay zekâ modeli karşılaştırılmıştır. Modellerde değişken olarak triyaj skoru ve tıbbi özgeçmiş bilgilerinin yanında bilişsel fonksiyonlar, günlük yaşam aktiviteleri, mobilite gibi ek değişkenler kullanılmıştır. Sonuç olarak GBoost modelinin en başarılı performansı sergilediği (EAA 0,80) ve hastaneye yatışta en önemli faktörlerin evde intravenöz tedavi ihtiyacı olması, acil servis başvuru zamanı, bakıcı desteğine ihtiyaç duymak, kendi başına yürüyememek olduğu bildirilmiştir (Mowbray vd., 2020).

Brink ve ark. tarafından 2020 yılında yapılan bir çalışmada, geriatrik acil servis hastalarının hastaneye yatışını tahmin etmek için demografik bilgiler, vital bulgular, istenen tetkikler gibi klinik verileri ve geleneksel istatistiksel metotlar kullanılarak lojistik regresyon modeli oluşturulmuş ve modele etkisi olan 10 özellik ile CLEARED tahmin aracı geliştirilmiştir. Geliştirilmesinde kullanılan özelliklerin %80'i triyaj verilerine dayanan CLEARED'in validasyon veri setlerinde başarısı orta düzeyde kalmıştır (EAA 0,72 ve 0,76). Bu çalışmada geriatrik acil servis hastalarında hastaneye yatış oranı %54 bildirilmiştir (Brink vd., 2020).

Tan ve ark. tarafından 2021 yılında yapılan bir çalışmada, influenza tanısı alan geriatrik acil servis hastalarında hastaneye yatış, pnömoni riski, sepsis riski gibi

sonlanım noktaları için klinik ve laboratuvar potansiyel risk faktörleri makine öğrenmesi modelleri ile değerlendirilmiştir. Çalışmada 6 farklı makine öğrenmesi modeli değerlendirilmiş ve hastaneye yatış tahmininde en iyi sonuçlar RF (doğruluk 0,769 ve EAA 0,840) modeliyle elde edilmiştir. Çalışmada influenza tanısı alan geriatrik hasta grubunda hastaneye yatış oranı %47 olarak bildirilmiştir (Tan vd., 2021).

Bunney ve ark. tarafından 2023 yılında yapılan bir çalışmada, geriatrik acil servis hasta bakımına yeni klinik değerlendirme kriterleri eklenmesi sonrasında hastalarının acil servisten hastaneye yatış oranlarındaki değişim 6 farklı makine öğrenmesi modeliyle (LR, RF, GBoost, ANN, KNN, SVM) değerlendirilmiştir. Çalışmada en başarılı tahminlerin gradyan artırma modeliyle yapıldığı bildirilmiştir. Ayrıca, rasgele orman modelinde en fazla etkiye sahip özelliklerin ESI triyaj sınıfı, ISAR skoru, başvuru şikayeti sınıfı, triyajdaki nabız değeri ve nefes darlığı semptomu olduğu bildirilmiştir (Bunney vd., 2023).

Buenrostro-Mariscal ve ark. tarafından 2025 yılında yapılan bir çalışmada, hasta olmayan geriatrik popülasyonda ileriki dönemde hastaneye yatma olasılığını öngören yapay zekâ destekli bir model oluşturulmuştur. Diğer çalışmalardan farklı olarak hastaların akut hastalık dönemlerinden ziyade altta yatan hastalık profilleri değerlendirmeye alınmış, geriatrik popülasyonun risk faktörleri belirlenmeye çalışılmış ve bu amaçla yapay zekâ modeli olarak RF kullanılmıştır. Çalışma sonucunda kırılgenlik skoru, yaş, inme öyküsü ve eğitim düzeyinin hastaneye yatışlarda en etkili faktörler olduğu tespit edilmiştir (Buenrostro-Mariscal vd., 2025)

Yapılan tüm kaynak araştırmasından elde edilen bulgular ışığında, literatürde geriatrik acil servis hastalarında hastaneye yatış öngörüsü için geliştirilen modellerde farklı özelliklerin kullanıldığı, hastaneye yatış sınıflandırma problemi için en etkin modelin net olarak belirlenememiş olduğu, modellerde kullanılan özelliklerin modele olan katkılarının ayrıntılı olarak değerlendirilemediği görülmüştür.

Tez çalışmamızın birincil amacı, geriatrik acil servise hastalarında başvurunun ilk dakikalarında elde edilen verilerle acil servisten hastaneye yatışı öngörebilecek makine öğrenmesi ve derin öğrenme model uygulamalarının yapılmasıdır. Tez çalışmamızın ikincil amaçları, çalışma popülasyonunun klinik özelliklerinin belirlenmesi, makine öğrenmesi ve derin öğrenme modellerinde hastaneye yatış öngörüsü için en etkin olan özelliklerin belirlenmesi, makine öğrenmesi ve derin öğrenme model sonuçlarının klinik yorumlarının yapılmasıdır.

3. MATERYAL VE YÖNTEM

3.1. Veri Seti Oluşturulması

Tez çalışmamızda yer alan veri setinin oluşturulma protokolü ve çalışma metodolojisi Necmettin Erbakan Üniversitesi İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurulu 07.03.2025 tarih ve 2025/5612 sayılı kararı ile onaylanmıştır (EK-1). Ayrıca, hasta verilerine erişim izni Necmettin Erbakan Üniversitesi Tıp Fakültesi Hastanesi Başhekimliği 25.03.2025 tarih ve E-14567952-900-658503 sayılı yazısı ile onaylanmıştır (EK-2).

3.1.1. Hasta popülasyonu

Retrospektif, gözlemsel, tek merkezli olan tez çalışmamıza Necmettin Erbakan Üniversitesi Tıp Fakültesi Hastanesi Acil Servisine başvuran, aşağıda sunulan dahil edilme ve dışlanma kriterlerini sağlayan toplam 3872 hasta dahil edilmiştir.


Dahil edilme kriterleri:

- 65 yaş ve üzerinde olan
- 1-31 Ocak 2024, 1-30 Nisan 2024, 1-31 Temmuz 2024, 1-30 Ekim 2024 tarihlerinde acil servis başvurusu olan (veri setinin mevsimsel değişimlerden etkilenmemesi amacıyla)
- Acil servis yeşil alan polikliniği dışında tetkik/tedavi edilen

Dışlanma kriterleri:

- Acil servis yeşil alan polikliniğinde değerlendirilen
- Acil servise kabulü sırasında kardiyopulmoner arrestte olan
- Acil servis kabulü sırasında demografik verileri, anamnez veya vital bulgu bilgileri eksik olan
- Acil servis takibi sırasında eksitus olan
- Acil servis takibi sırasında klinisyen tarafından hastaneye yatış/taburculuk kararı verilmeden tedavi red formu imzalayarak acil servisten ayrılan

Veri seti hasta popülasyonunun oluşturulma süreci ile ilgili akış şeması Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Hasta popülasyonu oluşturma akış şeması

3.1.2. Değişkenler

Veri setine dahil edilen toplam 3872 hastanın elektronik kayıtları Necmettin Erbakan Üniversitesi Tıp Fakültesi Hastanesi Hastane Bilgi Yönetim Sistemi (HBYS) aracılığıyla taranmıştır. Veri setinde demografik veriler, anamnez bilgileri, acil servise başvuru sırasında ölçülen ilk vital bulgular, sonlanım bilgisi ana başlıkları ile ilişkili toplam 13 değişken yer almaktadır. Değişkenler Tablo 3.1’de gösterilmiştir.

Tablo 3.1. HBYS hasta taramasından elde edilen veri parametreleri

Ana başlık	Parametre
Demografik veriler	Başvuru günü
	Başvuru saat dilimi
	Yaş
	Cinsiyet
Anamnez bilgileri	Başvuru şikayetleri
	Kronik hastalıklar
Acil serviste ilk vital bulgular	Sistolik kan basıncı
	Diastolik kan basıncı
	Nabız
	Vücut ısısı
	Oksijen saturasyonu
	Glasgow koma skalası
Sonlanım bilgisi	Acil servis sonlanımı

3.2. Ham Veri Seti Ön İşleme Basamakları

Ham veri seti Python 3.11 ve kütüphaneleri (Pandas, Numpy, Matplotlib, Seaborn) kullanılarak makine öğrenmesi ve derin öğrenme modelleri için ön işleme sürecinden geçirilmiştir. Ham veri seti Şekil 3.2’de gösterilmiştir.


	Sonlanım	Başvuru Günü	Saat Dilimi	Yaş	Cinsiyet	Şikayet1	Şikayet2	Şikayet3	Şikayet4	Şikayet5
0	TABURCU	HAFTAİÇİ	00:01-08:00	88	KADIN	KAŞINTI/DÖKÜNTÜ	NaN	NaN	NaN	NaN
1	TABURCU	HAFTAİÇİ	00:01-08:00	76	ERKEK	KARIN AĞRISI	KABIZLIK	NaN	NaN	NaN
2	TABURCU	HAFTAİÇİ	00:01-08:00	91	ERKEK	DİSPNE	GÖĞÜS AĞRISI	NaN	NaN	NaN
3	TABURCU	HAFTAİÇİ	08:01-16:00	79	KADIN	DİSPNE	NaN	NaN	NaN	NaN
4	YATIŞ	HAFTAİÇİ	08:01-16:00	75	ERKEK	DİSPNE	ÖKSÜRÜK	BALGAM	NaN	NaN

Şekil 3.2. Ham veri seti (ilk 5 satır ve ilk 10 sütun)

Öncelikle ham veri seti uç değerler ve eksik veriler açısından gözden geçirilmiştir. Modelleri etkileyecek uç değere ve eksik veriye rastlanmamıştır. Sonrasında, başvuru şikayetleri ve kronik hastalıklar sütunları One Hot Encoding yöntemi kullanılarak analiz edilmiştir. Her bir başvuru şikayeti ve kronik hastalık ayrı birer özellik haline getirilmiştir. Ham veri setinde 83 ayrı başvuru şikayeti ve 37 ayrı kronik hastalık olduğu tespit edilmiştir. Başvuru şikayetleri ve kronik hastalıkların frekans ve yüzdeleri hesaplanmıştır. Gürültüyü azaltmak ve aşırı öğrenmeyi önlemek amacıyla görülme sıklığı %1’in altında olan özellikler veri setinden çıkarılmıştır. Bu işlem sonrası ham veri setinde 29 başvuru şikayeti ve 22 kronik hastalık yer almıştır.

Acil servise başvuru sırasında ölçülen ilk vital bulguların korelasyonları incelenmiştir. Özelliklerin korelasyon matrisi Şekil 3.3’de gösterilmiştir. Sistolik Kan Basıncı ve Diyastolik Kan Basıncı özellikleri arasında pozitif korelasyon ($r = 0,69$) tespit edilmiştir. Bu iki özelliğin modellere Ortalama Arter Basıncı (OAB) olarak dahil edilmesine karar verilmiş ve OAB Denklem 3.1’deki formül kullanılarak hesaplanmıştır.

$$OAB = \frac{Sistolik\ Kan\ Basıncı + (2 \times Diyastolik\ Kan\ Basıncı)}{3} \quad (3.1)$$



Şekil 3.3. Acil servise başvuru sırasında ölçülen vital bulguların korelasyon matrisi

Makine öğrenmesi ve derin öğrenme modellerinin performanslarının artırılması ve çıktıların klinik yorumlara imkân vermesi amacıyla ham veri setinde yer alan nümerik özellikler kategorik özelliklere dönüştürülmüştür. Tablo 3.2’de gösterilen kriterlere göre özelliklere ikili kodlar atanmış ve özellik adları yeniden düzenlenmiştir.

Tablo 3.2. Veri setindeki özelliklerin ikili kodlamaları

Özellik	Kod 0	Kod 1
Başvuru Günü (Hafta Sonu)	Hafta İçi	Hafta Sonu
Başvuru Saati (Mesai Dışı)	08:01-16:00	Diğer değerler
Yaş (75 ve üzeri)	65 – 74 yıl	≥ 75 yıl
Cinsiyet (Erkek)	Kadın	Erkek
Başvuru Şikayetleri (Örnek: Karın Ağrısı)	Yok	Var
Kronik Hastalıklar (Örnek: Hipertansiyon)	Yok	Var
OAB (Hipotansiyon/Hipertansiyon)	65-93 mmHg	Diğer değerler
Nabız (Bradikardi/Taşikardi)	60-100 atım/dakika	Diğer değerler
Vücut Isısı (Hipotermi/Ateş)	36,0-37,9°C	Diğer değerler
Oksijen Saturasyonu (%90'dan düşük)	≥ %90	< %90
Glasgow Koma Skalası (14'ten düşük)	14-15	<14
Sonlanım*	Taburcu	Hastaneye Yatış

* Sonlanım özelliği sınıflandırma için kullanılmıştır, OAB: Ortalama Arter Basıncı

Ön işleme aşamaları tamamlandığında nihai veri setinde toplam 60 özellik sütunu, 1 sınıflandırma sütunu ve 3872 satır yer almıştır. Modellerin eğitilmesinde kullanılan nihai veri seti Şekil 3.4’te gösterilmiştir.

Sonlanım	Başvuru Günü (Hafta Sonu)	Başvuru Saati (Mesai Dışı)	Yaş (75 ve üzeri)	Cinsiyet (Erkek)	Karın Ağrısı	Nefes Darlığı	Göğüs Ağrısı	Öksürük	Balgam
0	0	0	1	1	0	0	0	0	0
1	0	0	1	1	1	1	0	0	0
2	0	0	1	1	1	0	1	1	0
3	0	0	0	1	0	0	1	0	0
4	1	0	0	1	1	0	1	0	1

Şekil 3.4. Modellerde kullanılan nihai veri seti (ilk 5 satır ve ilk 10 sütun)

3.3. Nihai Veri Seti Hasta Popülasyonu Özelliklerinin İncelenmesi

Nihai veri setinde yer alan hasta popülasyonu özellikleri ile ilgili istatistiksel analizler SPSS 22.0 paket programı kullanılarak yapılmıştır. Bu tez çalışmasının klinik ana sonlanım noktası acil servisten hastaneye yatış olarak belirlenmiştir. Hasta popülasyonu taburcu olanlar ve hastaneye yatanlar olmak üzere iki gruba ayrılmıştır. Özelliklerin taburcu olan ve hastaneye yatan hasta gruplarındaki dağılımları incelenmiştir. Sonuçlar frekans ve yüzde olarak gösterilmiştir. İki grup arasındaki dağılımlar ki-kare testi kullanılarak karşılaştırılmıştır. $p < 0,05$ istatistiksel olarak anlamlı kabul edilmiştir.

3.4. Nihai Veri Seti Hazırlık Aşamaları

Oluşturulan nihai veri setinde, bir hastanın acil servisten hastaneye yatışını öngörmek için 4 ana başlık altında 60 farklı özelliği içeren bir sınıflandırma problemi bulunmaktadır. Bu sınıflandırma probleminin modellenmesi için literatürde yer alan ve özellikle acil servisten hastaneye yatış sonlanım noktasına odaklanan çalışmaların metodolojileri “Kaynak Araştırması” bölümünde detaylandırıldığı şekilde incelenmiştir (Chang vd., 2024; Feretzakis vd., 2022; Mowbray vd., 2020; Tschoellitsch vd., 2023). Sonuç olarak, tez çalışmamızda LR, KNN, SMV, RF, AdaBoost, XGB ve MLP modellerinin geliştirilmesine ve birbirleri ile karşılaştırılmasına karar verilmiştir.

Modellerin geliştirilmesinde Python 3.11 programlama dili ve kütüphaneleri kullanılmıştır. Python nesne yönelimli bir programlama dilidir. Özellikle veri bilimi, yapay zekâ, web geliştirme ve otomasyon gibi alanlarda güçlü bir programlama dilidir. Basit ve okunabilir sözdizimi, çok yönlü kullanım, platformlardan bağımsız oluşu, büyük bir geliştirici topluluk tarafından desteklenmesi Python'u makine öğrenmesi ve derin öğrenme model geliştirme süreçlerinde tercih edilen bir dil haline getirmiştir. Python'un gücünü artıran diğer bir önemli özelliği ise zengin kütüphaneleridir (*Welcome to Python*, 2025).

Tez çalışmamızda sayısal hesaplamalar için Numpy, veri analizi için Pandas, veri görselleştirmeler için Matplotlib ve Seaborn, makine öğrenmesi ve derin öğrenme modelleri için PyCaret 3.0 (Scikit-Learn), modellerin özelliklerinin incelenmesi için SHAP kütüphaneleri kullanılmıştır (*PyCaret 3.0*, 2023; *Scikit-learn: machine learning in Python*, 2025).

PyCaret 3.0, makine öğrenmesi iş akışını otomatikleştirmek ve basitleştirmek için Python'da yazılmış açık kaynaklı, düşük kodlu bir makine öğrenmesi kütüphanesidir. Temel amacı, prototipleme ve uçtan uca deneme döngüsünü hızlandırmaktır. PyCaret, özünde Scikit-learn, XGB, LightGBM, CatBoost, Optuna, Hyperopt, Ray gibi birçok makine öğrenmesi kütüphanesi bir araya getirmektedir. PyCaret, farklı makine öğrenmesi algoritmaları için ayrılmış modüllere sahiptir, ancak her algoritma kendi içinde benzer bir iş akışını takip etmektedir (*PyCaret 3.0*, 2023):

- **Kurulum (setup):** Veri setini ve modeli tanımlar.
- **Oluşturma/Eğitme (create_model):** Belirli bir modeli manuel olarak eğitir.
- **Hiperparametre Ayarlama (tune_model):** Hiperparametreleri optimum hale getirir.
- **Değerlendirme (evaluate_model):** Grafiksel arayüzle model performansını görselleştirir.
- **Tahmin (predict_model):** Test verisi veya yeni veriler üzerinde tahmin yapmaya olanak sağlar.


3.4.1. Eğitim ve test veri setlerinin oluşturulması

Nihai veri setinde toplam 60 özellik ve 1 sınıflandırma sütunu yer almıştır. Veri setinde tüm özellikler ikili kodlamaya sahip olduğu için ölçeklendirme işlemi yapılmamıştır. Makine öğrenmesi ve derin öğrenme modelleri için PyCaret *setup* fonksiyonu kullanılarak eğitim ve test veri setleri oluşturulmuştur. Modellerin eğitilmesinde 3 farklı eğitim/test veri seti oranı ile denemeler yapılmıştır (yüzde 70/30, 80/20 ve 90/10). Modellerde en iyi sonuçlar yüzde 90/10 oranında elde edilmiştir ve tez çalışmamızda 90/10 (eğitim/test) ile elde edilen sonuçlar sunulmuştur.

3.4.2. Katmanlı K-kat çapraz validasyon

Katmanlı K-kat çapraz validasyon temel olarak sınıflandırma problemlerinde kullanılan bir çapraz doğrulama yöntemidir. Standart K-kat çapraz validasyonun bir varyasyonudur. Katmanlı K-kat validasyonda veri seti katmanlara ayrılırken sınıf etiketlerinin orijinal veri setindeki oransal dağılımı korunur. Bu, her bir eğitim ve test katmanının, tüm veri seti sınıf dağılımının küçük ama temsili bir örneği olmasını sağlar. Katmanlı K-kat çapraz validasyon aşağıdaki aşamalarla gerçekleştirilir ve aşamaların şematize edilmesi Şekil 3.5'te gösterilmiştir (Bey vd., 2020).

- **Sınıf Dağılımının Hesaplanması:** Öncelikle, tüm veri setindeki sınıflandırma etiketinin yüzdelik oranı hesaplanır.
 - 1000 veri noktasının 650'si (%65) Sınıf 0 ve 350'si (%35) Sınıf 1 olsun.
- **Katmanlara Bölme:** Veri seti K eşit katmana ayrılırken her bir katmanın bu yüzdelik oranları koruması sağlanır.
 - K=10 ve 1000 veri noktası varsa, her katmanda 100 veri noktası olur. Bu 100 noktanın 65'inin (%65) Sınıf 0 ve 35'inin (%35) Sınıf 1 olması sağlanır.
- **Tekrarlı Eğitim ve Test:** Bu işlem K kez tekrarlanır.
 - K-1 katman eğitim seti olarak ve kalan 1 katman test/validasyon seti olarak kullanılır.
- **Performansların Ortalaması:** K iterasyonun her birinden elde edilen performans metrikleri (doğruluk, F1 skoru vb.) toplanır ve ortalaması alınarak nihai model performansı tahmini elde edilir.



Şekil 3.5. Katmanlı K-kat çapraz validasyon (K=10)

Katmanlı K-kat çapraz validasyon ile katmanlarda sınıfların oranının korunması daha az varyanslı ve daha güvenilir performans ölçümlerine olanak tanır. Böylelikle, modelin tüm sınıflarda genelleme yeteneği daha doğru bir şekilde yansıtılmış olur (Bey vd., 2020).


Tez çalışmamızda makine öğrenmesi ve derin öğrenme modelleri geliştirilirken PyCaret *setup*, *create_model* ve *tune_model* fonksiyonlarında katmanlı 10-kat çapraz validasyon (StratifiedKFold, fold = 10) metodu kullanılmıştır.

3.4.3. Hiperparametre ayarları

Makine öğrenmesinde hiperparametre ayarlama (hyperparameter tuning), bir modelin başarısını ve genelleme yeteneğini belirleyen kritik bir adımdır. Bu süreç, algoritmanın performansını maksimize etmek amacıyla, modelin öğrenme sürecinden önce tanımlanan ve veri kümesine özgü en uygun parametre kombinasyonlarını bulmayı

hedefler. Doğru hiperparametreler, modelin eğitim verilerindeki temel örüntüleri etkili bir şekilde yakalamasını sağlayarak hem aşırı hem de yetersiz öğrenmeyi engeller. Bu denge modelin daha önce görmediği yeni verilerde tutarlı ve yüksek doğrulukta sonuçlar üretme yeteneğini yani genelleme gücünü artırır. Ayrıca, bazı hiperparametrelerin dikkatli bir şekilde ayarlanması modelin eğitim süresini ve hesaplama maliyetini düşürmeye de yardımcı olur (A İlemobayo vd., 2024).

Makine öğrenmesi modellerinin sahip olduğu çok sayıda hiperparametreyi en optimum şekilde ayarlayabilmek için tanımlanmış farklı teknikler mevcuttur. En sık kullanılanları Izgara Arama (GridSearch) ve Rasgele Arama (RandomizedSearch) metotlarıdır (A İlemobayo vd., 2024; Iqbal vd., 2025; Tufail vd., 2023). İki metodun karşılaştırması Şekil 3.6'da gösterilmiştir.



Şekil 3.6. GridSearch ve RandomizedSearch ile hiperparametre ayarı (Iqbal vd., 2025)

GridSearch metodunun arama stratejisi, hiperparametre değerler ızgarasında yer alan tüm olası kombinasyonların sırayla denenmesidir. Tanımlanan parametrelerin her noktası atlanmadan denenir. Özellikle az sayıda parametre ayarı hedeflendiğinde kullanışlıdır. RandomizedSearch metodunun arama stratejisi, hiperparametre değerler ızgarasında yer alan rasgele seçilmiş belirli sayıda kombinasyonun denenmesidir. Rastgelelik nedeniyle daha az sayıda kombinasyon denenir ve bu nedenle daha hızlı sonuç alınır. Özellikle çok sayıda hiperparametre yer alan modellerde ve önemli parametrelerin sadece birkaç değere duyarlı olduğu durumlarda daha verimlidir. Her iki metot, çapraz validasyon metotları ile birlikte kullanılabilir (A İlemobayo vd., 2024; Cynthia vd., 2023; Iqbal vd., 2025; Meisenbacher vd., 2022).

Tez çalışmamızda makine öğrenmesi ve derin öğrenme modellerinin hiperparametre ayarları PyCaret *tune_model* fonksiyonu ve RandomizedSearchCV (fold = 10, n_iter = 10) metodu kullanılarak yapılmıştır. Her bir modelde kullanılan nihai hiperparametreler ilgili algoritmalar ile birlikte sunulmuştur.

3.5. Makine Öğrenmesi ve Derin Öğrenme Modelleri

3.5.1. Lojistik regresyon (LR)

LR makine öğrenmesinde, özellikle sınıflandırma problemlerinde kullanılan temel ve güçlü bir algoritmadır. LR genellikle olasılıkları tahmin etmek için lojistik bir fonksiyon kullanır. Önce girdi özelliklerinin (X) ağırlıklı toplamı (z) hesaplanır (Denklem 3.2) ve ardından bu ağırlıklı toplam (z), olasılık ($\sigma(z)$) hesabı için sigmoid fonksiyonuna aktarılır (Denklem 3.3).

$$z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (3.2)$$

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (3.3)$$

LR modelinde bu olasılık değeri bir eşik değeri kullanılarak sınıfa (0 veya 1) dönüştürülür. LR, sağlık alanında bir veya daha fazla bağımsız değişkene dayanarak ikili sınıf olasılığını değerlendirmek için yaygın olarak kullanılır (Binson vd., 2024; *Logistic Regression in Machine Learning*, 2025; Sarker, 2021).

Tez çalışmamızda LR modeli PyCaret *create_model* fonksiyonu kullanılarak oluşturulmuştur. Modelin hiperparametre ayarları PyCaret *tune_model* fonksiyonu kullanılarak yapılmıştır. LR modelinin ayarlanmış nihai hiperparametreleri şu şekildedir:

```
LogisticRegression(C=5.003, class_weight='balanced', dual=False,
                    fit_intercept=True, intercept_scaling=1, l1_ratio=None,
                    max_iter=1000, multi_class='auto', n_jobs=None, penalty='l2',
                    random_state=5944, solver='lbfgs', tol=0.0001, verbose=0,
                    warm_start=False)
```

3.5.2. K-en yakın komşu (KNN)

KNN hem sınıflandırma hem de regresyon problemleri için kullanılan basit ve etkili bir gözetimli makine öğrenmesi algoritmasıdır. KNN algoritması, tahmin yapmak

istediği yeni bir veri noktasının sınıfını, eğitim veri setindeki en yakın k komşusuna bakarak belirleyen bir yöntemdir. Algoritma, öncelikle yeni veri noktası ile eğitim setindeki tüm diğer noktalar arasındaki uzaklığı hesaplar; bunun için genellikle Öklid mesafesi (Denklem 3.4) veya Manhattan mesafesi (Denklem 3.5) kullanılır.

$$\text{Öklid mesafesi } (x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.4)$$

$$\text{Manhattan mesafesi } (x, y) = \sum_{i=1}^n |x_i - y_i| \quad (3.5)$$

Hesaplanan bu mesafelere göre, yeni noktaya en yakın olan k adet komşu veri noktası belirlenir. Eğer problem bir sınıflandırma ise, yeni nokta bu k komşunun ait olduğu sınıflara bakılarak çoğunluk oyuyla en çok oy alan sınıfa atanır. Bu basit, ancak güçlü mekanizma sayesinde, KNN algoritması, verilerin yerel yapısına dayalı tahminler yapabilir (Binson vd., 2024; *K-Nearest Neighbor Algorithm*, 2025; Sarker, 2021).


Tez çalışmamızda KNN modeli PyCaret *create_model* fonksiyonu kullanılarak oluşturulmuştur. Modelin hiperparametre ayarları PyCaret *tune_model* fonksiyonu kullanılarak yapılmıştır. KNN modelinin ayarlanmış nihai hiperparametreleri şu şekildedir:

```
KNeighborsClassifier(algorithm='auto', leaf_size=30, metric='manhattan',
metric_params=None, n_jobs=-1, n_neighbors=40, p=2,
weights='distance')
```

3.5.3. Destek vektör makineleri (SVM)

SVM'nin temel amacı, farklı sınıflara ait veri noktaları arasında en geniş aralığa sahip olan optimal bir ayırma hiperdüzlemi bulmaktır. Hiperdüzlem, veri noktalarını iki farklı sınıfa ayıran karar sınırıdır. Bir boyutun üzerindeki uzaylarda karar sınırı doğru, üç boyutlu uzayda düzlem ve daha yüksek boyutlarda hiperdüzlem olarak adlandırılır. Temel amaç, hiperdüzlem ile her bir sınıfa ait en yakın veri noktaları arasındaki marjini maksimize etmektir (Şekil 3.7). En yakın veri noktaları destek vektörleri olarak adlandırılır ve SVM yalnızca bu vektörlere bağlıdır. Marjinin maksimize edilmesi,

modelin yeni ve görülmemiş verilere karşı yüksek genelleme performansı sergilemesini sağlayarak aşırı öğrenme riskini azaltır.



Şekil 3.7. Destek vektör makineleri (SVM) algoritması (Oztornaci vd., 2024)

SVM'nin gücü, doğrusal olarak ayrılamayan veri setlerini bile işleyebilmesinde yatar. Bu yetenek, verileri daha yüksek boyutlu özellik uzaylarına eşleyerek doğrusal ayrımın mümkün olduğu bir ortam oluşturan çekirdek fonksiyonları aracılığıyla sağlanır. Doğrusal, polinomial ve radyal baz fonksiyonu gibi çekirdekler, modelin farklı veri yapılarına adaptasyonunu destekler. Ancak, veri setinin hedef sınıfların üst üste binmesi gibi yapısal karmaşıklıklar içermesi durumunda SVM'nin genelleme ve sınıflandırma yeteneği önemli ölçüde azalabilir (Binson vd., 2024; Sarker, 2021; *Support Vector Machine Algorithm*, 2025).

Tez çalışmamızda SVM modeli PyCaret *create_model* fonksiyonu kullanılarak oluşturulmuştur. Modelin hiperparametre ayarları PyCaret *tune_model* fonksiyonu kullanılarak yapılmıştır. SVM modelinin ayarlanmış nihai hiperparametreleri şu şekildedir:


```
SVC(C=11.68, break_ties=False, cache_size=200, class_weight='balanced',
    coef0=0.0, decision_function_shape='ovr', degree=3, gamma='auto',
    kernel='rbf', max_iter=-1, probability=True, random_state=5944,
    shrinking=True, tol=0.001, verbose=False)
```

3.5.4. Rasgele orman (RF)

RF karar ağacı tabanlı bir topluluk öğrenmesi yöntemidir. Algoritma, birden çok karar ağacını birleştirerek tahmin doğruluğunu artırmayı ve tek bir ağacın dezavantajı

olan aşırı öğrenme eğilimini azaltmayı amaçlar. RF her bir ağacı oluştururken iki temel rastgelelik kaynağını kullanır. Her ağaç farklı bir alt küme üzerinde eğitilir ve her bir düğümde en iyi ayrımı bulmak için özelliklerin sadece rasgele seçilmiş bir alt kümesi değerlendirilir. Bu ikili rastgelelik mekanizması, ağaçlar arasında düşük korelasyon sağlamakta kritik rol oynar ve topluluk tahmininin bireysel ağaçların hatalarını dengelemesine olanak tanır. RF esas olarak sınıflandırma ve regresyon problemlerinin çözümünde kullanılır.


RF modelinde nihai tahmin, sınıflandırma problemlerinde ağaçların ürettiği sonuçların çoğunluk oyu ile ve regresyon problemlerinde ise sonuçların ortalaması alınarak belirlenir (Şekil 3.8). Bu toplulaştırma süreci modelin hem sağlamlığını hem de tahmin gücünü önemli ölçüde artırır. Algoritmanın başlıca avantajları arasında yüksek boyutlu veri setlerinde bile etkili olması, parametre seçimine karşı nispeten dayanıklı olması ve özellik önem derecesini doğal olarak ölçebilmesi yer alır. Ancak, tek bir karar ağacına kıyasla daha fazla hesaplama kaynağı gerektirmesi ve yorumlanabilir bilgi üretme yeteneğinin düşük olması ise dezavantajlarıdır (Binson vd., 2024; *Random Forest Algorithm in Machine Learning*, 2025; Sarker, 2021).



Şekil 3.8. Rasgele orman (RF) algoritması (Gan vd., 2024; Oztornaci vd., 2024)

3.5.6. Aşırı gradyan artırma (XGB)

XGB yapılandırılmış veri setleri üzerinde yüksek performans gösteren ölçeklenebilir bir gradyan artırma algoritmasıdır. Temelde zayıf öğreniciler olan karar ağaçlarının bir araya getirilmesiyle güçlü bir tahmin modeli oluşturur. Bu yığılmalı öğrenme sürecinde, her yeni ağaç bir önceki modelin hatalarını düzeltmeye odaklanır (Şekil 3.9). XGB bu gradyan artırma çerçevesini, optimizasyon hedefine düzenlileştirme terimi ekleyerek geliştirir ve modelin aşırı uyum eğilimini kontrol altına almaya yardımcı olur. Algoritmanın performansını artıran önemli özellikleri arasında paralel hesaplama yeteneği, büyük veri kümeleri için yaklaşık bölünme bulma algoritmaları ve önbellek erişimini optimize eden mimarisi sayılabilir. Bu tasarım tercihleri XGB'yi hem sınıflandırma hem de regresyon görevlerinde etkili ve hızlı bir çözüm haline getirmiştir. XGB'nin yapısı modelin genelleme yeteneğini artırarak, eğitim veri setinden farklı yeni verilere uygulandığında bile güvenilir sonuçlar vermesini sağlar. XGB modelinin öğrenme oranı, maksimum derinlik gibi çok sayıda hiperparametresi vardır ve belirli veri setlerine göre bu hiperparametreler detaylı şekilde ayarlanabilmektedir. Bu özellikleri XGB'yi sınıflandırma problemlerinde en çok tercih edilen yöntemlerden biri haline getirmektedir (Oztornaci vd., 2024; Reddy ve Kumar, 2023; Sarker, 2021; *XGBoost*, 2025).



Şekil 3.9. Aşırı gradyan artırma (XGB) algoritması (Oztornaci vd., 2024)

AdaBoost ve XGB algoritmaları arasındaki temel ayrım, optimizasyon hedeflerinde ve mimarilerindeki ilerlemededir. AdaBoost, her bir zayıf öğrenicinin inşa edildiği ardışık yinelemelerde yanlış sınıflandırılan örneklerin ağırlıklarını doğrudan artırarak çalışır. Bu temel olarak bir örnek ağırlıklandırma mekanizmasıdır ve genellikle

üstel kayıp fonksiyonunu minimize etmeye odaklanır. Buna karşılık, XGB bu artırma çerçevesini genelleştirerek, her yeni ağacın bir önceki modelin hatalarının gradyanları üzerine kurulu gradyan artırma prensibini kullanır. En önemlisi, XGB'nin amaç fonksiyonu yalnızca kayıp terimini değil, aynı zamanda L1 ve L2 düzenlileştirme terimlerini de içerir ki bu, model karmaşıklığını ve aşırı uyum eğilimini kontrol etmede AdaBoost'a göre önemli bir avantaj sağlar (*AdaBoost in Machine Learning*, 2025; *XGBoost*, 2025; Reddy ve Kumar, 2023).

Tez çalışmamızda XGB modeli PyCaret *create_model* fonksiyonu kullanılarak oluşturulmuştur. Modelin hiperparametre ayarları PyCaret *tune_model* fonksiyonu kullanılarak yapılmıştır. XGB modelinin ayarlanmış nihai hiperparametreleri şu şekildedir:

```
XGBClassifier(base_score=None, booster='gbtree', callbacks=None,
               colsample_bylevel=None, colsample_bynode=None,
               colsample_bytree=0.6, device=None,
               early_stopping_rounds=None,
               enable_categorical=False, eval_metric=None,
               feature_types=None, gamma=1, grow_policy=None,
               importance_type=None, interaction_constraints=None,
               learning_rate=0.1, max_bin=None, max_cat_threshold=None,
               max_cat_to_onehot=None, max_delta_step=None,
               max_depth=4, max_leaves=None,
               min_child_weight=5, missing=nan,
               monotone_constraints=None, multi_strategy=None,
               n_estimators=200, n_jobs=None,
               num_parallel_tree=None, ...)
```


3.5.7. Çok katmanlı algılayıcı (MLP)

MLP temel olarak bir veya daha fazla gizli katman içeren, ileri beslemeli bir yapay sinir ağı modelidir. Girdi katmanı ile çıktı katmanı arasında konumlanan bu gizli katmanlar sayesinde, tek bir algılayıcının çözemediği ve doğrusal olarak ayıramayan karmaşık problemleri modelleyebilme yeteneğine sahiptir. Bir katmandaki her düğüm, bir sonraki katmandaki düğümlere belirli bir ağırlıkla bağlanır (Şekil 3.10).

Yapay sinir ağları, literatürde barındırdıkları gizli katman sayısına göre sığ (shallow) ve derin (deep) öğrenme modelleri olmak üzere iki temel sınıfa ayrılmaktadır. Bir veya iki gizli katmanla sınırlı olan sığ ağların karmaşık örüntüleri öğrenme kapasitesi düşük kalırken; çok sayıda katmandan oluşan derin sinir ağları, veriden hiyerarşik özellik çıkarımı yapabilme ve veriyi daha sofistike düzeylerde temsil

edebilme yeteneğine sahiptir (Mienye ve Swart, 2024). Bu bağlamda, pek çok sınıflandırma probleminde, MLP yapısı veya MLP tabanlı derin öğrenme mimarileri, derin konvolüsyonel sinir ağlarına kıyasla operasyonel verimlilikleri nedeniyle öncelikli olarak tercih edilmektedir (Du vd., 2022).

MLP'nin eğitimi, genellikle geri yayılım algoritması kullanılarak gerçekleştirilir. Bu süreçte, modelin tahminleri ile gerçek değerler arasındaki farkı ölçen bir kayıp fonksiyonu minimize edilmeye çalışılır. Geri yayılım, kaybın gradyanını hesaplayarak bu gradyanı çıktı katmanından girdi katmanına doğru geriye yayar ve bu sayede ağdaki her bir ağırlığın kayba olan katkısını belirler. Ardından, bir optimizasyon algoritması kullanılarak ağırlıklar ve sapma terimleri, gradyanın tersi yönünde ayarlanır. Bu iteratif ayarlama süreci, kayıp fonksiyonunun değerini sürekli olarak azaltır ve modelin veri üzerindeki genelleme yeteneğini geliştirir (Kruse vd., 2022; Oztornaci vd., 2024; Sarker, 2021).



Şekil 3.10. Çok katmanlı algılayıcı (MLP) algoritması (Sarker, 2021)

Tez çalışmamızda 5 katmanlı MLP modeli PyCaret *create_model* fonksiyonu kullanılarak oluşturulmuştur. Modelin hiperparametre ayarları PyCaret *tune_model* fonksiyonu kullanılarak yapılmıştır. MLP modelinin ayarlanmış nihai hiperparametreleri şu şekildedir:

```
MLPClassifier(activation='identity', alpha=0.0005, batch_size='auto',
              beta_1=0.9, beta_2=0.999, early_stopping=False, epsilon=1e-08,
              hidden_layer_sizes=[100, 50, 100], learning_rate='adaptive',
              learning_rate_init=0.001, max_fun=15000, max_iter=500,
              momentum=0.9, n_iter_no_change=10, nesterovs_momentum=True,
              power_t=0.5, random_state=5944, shuffle=True, solver='adam',
              tol=0.0001, validation_fraction=0.1, verbose=False,
              warm_start=False)
```

3.6. Makine Öğrenmesi ve Derin Öğrenme Modellerinde Performans Değerlendirme Metrikleri

Makine öğrenmesi sınıflandırıcılarını değerlendirmek için kullanılan temel metrikler, modelin tahminlerinin gerçek değerlerle ne kadar uyumlu olduğunu ölçer. Farklı algoritmalar veya hiperparametre ayarları kullanılarak oluşturulan modelleri karşılaştırmak, modellerin gerçek performansını anlamak, hata türlerinin gerçek senaryolarda karşılığını ifade etmek, modelin teknik performansının iş hedeflerine bağlamak için standartlaştırılmış metrikler gerekir (Binson vd., 2024; Choi vd., 2020; Rainio vd., 2024). Tez çalışmamızda modellerin değerlendirilmesi için kullanılan metrikler aşağıda detaylandırılmıştır.

Karışıklık matrisi (confusion matrix)

Karışıklık matrisi, bir makine öğrenmesi sınıflandırıcısının performansını görselleştiren ve özetleyen tablo yapılı bir araçtır. Esasen, modelin tahminlerinin gerçekte olması gereken sınıflarla ne kadar uyumlu olduğunu gösterir ve dört temel sonuç kategorisine ayırarak performansın detaylı analizini sağlar. İkili sınıflandırma problemi için karışıklık matrisi 2x2 bir tablo şeklinde gösterilir (Şekil 3.11).

Karışıklık Matrisi

Gerçek	Taburcu	DOĞRU NEGATİF (DN)	YANLIŞ POZİTİF (YP)
	Hastaneye yatış	YANLIŞ NEGATİF (YN)	DOĞRU POZİTİF (DP)
		Taburcu	Hastaneye yatış
		Tahmin	

Şekil 3.11. Karışıklık matrisi

Karışıklık matrisinin dört temel bileşeni vardır:

- **Doğru Pozitif (DP):** Modelin pozitif tahmin ettiği ve gerçekte de pozitif olan durumların sayısıdır. Bu bileşen doğru tahmini temsil eder.
- **Doğru Negatif (DN):** Modelin negatif tahmin ettiği ve gerçekte de negatif olan durumların sayısıdır. Bu bileşen doğru tahmini temsil eder.
- **Yanlış Pozitif (YP):** Modelin pozitif tahmin ettiği, ancak gerçekte negatif olan durumların sayısıdır. Bu bileşen Tip I hatayı temsil eder.
- **Yanlış Negatif (YN):** Modelin negatif tahmin ettiği, ancak gerçekte pozitif olan durumların sayısıdır. Bu bileşen Tip II hatayı temsil eder.

Doğruluk (accuracy)

En basit metrik olup, doğru yapılan tüm tahminlerin toplam tahmin sayısına oranını gösterir. Sınıf dağılımları dengeli olan veri setlerinde genel bir başarı ölçüsü olarak kullanılır. Dengesiz veri setlerinde yanıltıcı olabilir. Denklem 3.6'da gösterilen formül ile hesaplanır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.6)$$

Kesinlik (precision)

Modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu ölçer. Yanlış pozitiflerin maliyetinin yüksek olduğu durumlarda önemlidir. Bu duruma örnek olarak, pozitif sonucun ciddi ve pahalı takip testlerini gerektirdiği nadir bir hastalığın taranması verilebilir. Denklem 3.7'de gösterilen formül ile hesaplanır.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (3.7)$$

Duyarlılık (recall, sensitivity)

Gerçekte pozitif olan örneklerin ne kadarının model tarafından doğru pozitif olarak tahmin edildiğini ölçer. Yanlış negatiflerin maliyetinin yüksek olduğu durumlarda önemlidir. Özellikle tıbbi tarama testlerinde sıkça kullanılır. Denklem 3.8'de gösterilen formül ile hesaplanır.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3.8)$$

Özgüllük (specificity)

Gerçekte negatif olan örneklerin ne kadarının model tarafından doğru negatif olarak tahmin edildiğini ölçer. Özellikle tıbbi tanı doğrulama testlerinde sıkça kullanılır. Genellikle özgüllük ve duyarlılık birbirinin tamamlayıcısı olarak görülür. Örneğin, HIV tanısında önce ELISA (yüksek duyarlılığa sahip tarama testi) yapılır, ELISA sonucu pozitif çıkarsa Western Blot (yüksek özgüllüğe sahip doğrulama testi) ile HIV tanısı doğrulanır. Denklem 3.9'da gösterilen formül ile hesaplanır.

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3.9)$$

F1 skoru (F1 score)

Kesinlik ve duyarlılık metriklerinin harmonik ortalamasıdır. Bu iki metrik arasında bir denge kurmayı amaçlar. Özellikle dengesiz sınıf dağılımlı veri setlerinde modelin performansını özetlemek için faydalıdır. Yüksek F1 skoru, hem yüksek kesinlik hem de yüksek duyarlılık anlamına gelir. Denklem 3.10'da gösterilen formül ile hesaplanır.

$$F1 \text{ skoru} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.10)$$


ROC eğrisi ve eğri altında kalan alan

ROC eğrisi ile EAA, ikili sınıflandırma modellerinin performansını değerlendirmek için kullanılan güçlü ve kapsamlı metriklerdir. ROC eğrisi, modelin farklı sınıflandırma eşiklerinde pozitif ve negatif sınıfları ne kadar iyi ayırdığını gösterir. ROC eğrisinin y eksenini gerçek pozitif oranı (duyarlılık), x eksenini yanlış pozitif oranı (1 - özgüllük) oluşturur ve görsel bir sınıflandırma özeti sunar. Örnek ROC eğrisi Şekil 3.12'de gösterilmiştir.

EAA ise, modelin sınıfları ayırt etme yeteneğini 0 ile 1 arasında tek bir sayı ile özetler. EAA değeri 1'e ne kadar yakınsa modelin performansı o kadar iyidir ve 0,5 ise modelin rastgele tahminden farksız olduğunu gösterir. Özellikle sınıf dağılımlarının dengesiz olduğu durumlarda ve diğer metriklerin yanıltıcı olabileceği senaryolarda, EAA modelin genel ayırım gücünü objektif bir şekilde değerlendirmek için kritik öneme sahiptir.

Sınıflandırma problemleri için EAA yorumlanması şu kriterlere göre yapılabilir (Jawad vd., 2024):

- 0,50 – 0,60: Çok zayıf sınıflandırma
- 0,60 – 0,70: Zayıf sınıflandırma
- 0,70 – 0,80: Orta düzeyde (kabul edilebilir) sınıflandırma
- 0,80 – 0,90: İyi sınıflandırma
- 0,90 – 1,00: Mükemmel sınıflandırma



Şekil 3.12. ROC eğrisi ve eğri altında kalan alan (EAA)


SHAP analizi

SHAP (SHapley Additive Explanations), makine öğrenmesi modellerini yorumlamak için kullanılan ve açıklanabilir yapay zekâ kavramı ile ortaya çıkmış bir yöntemdir. Tıbbi karar verme süreçlerinde yalnızca tahmin doğruluğu değil, aynı zamanda modelin neden bu kararı verdiğinin anlaşılması da kritik öneme sahiptir. Klasik makine öğrenmesi metriklerinden olan özelliklerin önemi (feature importance) genellikle modellerin anlaşılmasında tutarsızlıklara neden olmaktadır. SHAP analizi, oyun teorisinden türetilen Shapley değerleri kavramını kullanarak, bir modelin tahmininde veri kümesindeki her bir özelliğin bireysel olarak ne kadar katkı sağladığını nicel olarak ölçer (Nohara vd., 2022; Ponce-Bobadilla vd., 2024). SHAP değerleri, modelin tahminini özelliklerin katkılarının toplamı şeklinde açıklar (Denklem 3.11).

$$Tahmin\ çıktısı = Temel\ değer + \sum Her\ bir\ özelliğin\ SHAP\ değeri \quad (3.11)$$

Temel değer, modele hiçbir özellik bilgisi eklenmeden beklenen ortalama tahmin çıktısıdır. Özellik SHAP değeri, bir özelliğin modelin temel tahmininden nihai tahmine ulaşmasında sağladığı marjinal katkısını temsil eder. Pozitif SHAP değeri olan özellik, tahmin sonucunu pozitif sınıfa doğru itmeye yardımcı olmuştur. Negatif SHAP değeri olan özellik, tahmin sonucunu negatif sınıfa doğru itmeye yardımcı olmuştur.

SHAP grafikleri model hakkında faydalı bir genel bakış sağlar (Şekil 3.13). Bu katkıları sayesinde, modellerin daha kolay yorumlanabilir hale gelmesi ve klinik verilerde gizli kalmış ilişkilerin ortaya çıkarılması amaçlanmaktadır (Nohara vd., 2022; Ponce-Bobadilla vd., 2024).



Şekil 3.13. SHAP analiz grafik örneği (Ponce-Bobadilla vd., 2024)

Python’da yer alan SHAP kütüphanesinin kullanılması önerilen ve en güncel model açıklayıcısı *shap.Explainer* fonksiyonudur. *shap.Explainer* fonksiyonu, değerlendirilen modele göre en uygun SHAP açıklama algoritmasını otomatik olarak seçmektedir. Tez çalışmamızda özelliklerin modellere olan katkıları bu fonksiyon kullanılarak analiz edilmiştir. Tüm modellerde SHAP değerleri model agnostik olan *PermutationExplainer* ile elde edilmiş ve sonuçlar grafik olarak sunulmuştur.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

4.1. Hasta Popülasyonunun Özellikleri

Tez çalışmamızın nihai veri setini oluşturan 3872 hastanın 1990'ı (%51,4) 75 yaş ve üzerindedir. Hastaların 1957'si (%50,5) erkektir ve acil servisten hastaneye yatış oranı %47'dir. Bu yatış oranı, veri setinin acil servisten hastaneye yatış öngörü modelleri için nispeten dengeli bir veri seti olduğunu desteklemektedir. Modellerde kullanılan test veri seti 388 hastadan oluşmaktadır. 388 hastanın 182'si acil servisten hastaneye yatmış ve 206'sı acil servisten taburcu edilmiştir.

Hastaneye yatan ve taburcu olan hastaların demografik özelliklerinin karşılaştırması Tablo 4.1'de gösterilmiştir. Hastaneye yatış oranlarının 75 yaş üzeri ve erkek olan hastalarda daha yüksek olduğu tespit edilmiştir (her ikisi için $p < 0,001$).

Tablo 4.1. Taburcu olan ve hastaneye yatan hastaların demografik özelliklerinin karşılaştırılması

Demografik özellikler, n (%)	Taburcu (n = 2051)	Hastaneye yatış (n = 1821)	p değeri
Yaş (75 ve üzeri)	993 (%48,4)	997 (%54,8)	<0,001
Cinsiyet (Erkek)	980 (%47,8)	977 (%53,7)	<0,001
Başvuru Günü (Hafta Sonu)	531 (%25,9)	472 (%25,9)	0,983
Başvuru Saati (Mesai Dışı)	1093 (%53,3)	1034 (%56,8)	0,029

Hastaneye yatan ve taburcu olan hastaların acil serviste ilk ölçülen vital bulgularının karşılaştırması Tablo 4.2'de gösterilmiştir. Hastaneye yatan hastalarda vital bulgu anormallik sıklığının taburcu olan hastalardan daha fazla olduğu tespit edilmiştir (hepsi için $p < 0,001$). Sadece, vital bulgulardan OAB ile ilgili anormalliklerin taburcu olan hastalarda daha sık olduğu görülmüştür ($p < 0,001$).

Tablo 4.2. Taburcu olan ve hastaneye yatan hastaların vital bulgularının karşılaştırılması

Vital bulgular, n (%)	Taburcu (n = 2051)	Hastaneye yatış (n = 1821)	p değeri
OAB (Hipotansiyon/Hipertansiyon)	1344 (%65,5)	1033 (%56,7)	<0,001
Nabız (Bradikardi/Taşikardi)	452 (%22,0)	600 (%32,9)	<0,001
Vücut Isısı (Hipotermi/Ateş)	70 (%3,4)	119 (%6,5)	<0,001
Oksijen Saturasyonu (%90'dan düşük)	168 (%8,2)	351 (%19,3)	<0,001
Glasgow Koma Skalası (14'ten düşük)	8 (%0,4)	128 (%7,0)	<0,001

OAB: Ortalama Arter Basıncı

Hastaneye yatan ve taburcu olan hastaların acil servise başvuru semptom dağılımları Tablo 4.3'te gösterilmiştir. Hastaneye yatan hastalarda nefes darlığı, oral alım bozukluğu, bilinç değişikliği, fokal nörolojik defisit gibi semptomlar taburcu olan hastalardan daha yüksek oranda tespit edilmiştir (hepsi için $p<0,001$). Taburcu olan hastalarda ise baş dönmesi, dizüri, ishal gibi semptomlar hastaneye yatan hastalardan daha yüksek oranda görülmüştür (hepsi için $p<0,001$).

Tablo 4.3. Taburcu olan ve hastaneye yatan hastaların başvuru semptomlarının karşılaştırılması

Başvuru şikayetleri, n (%)	Taburcu (n = 2051)	Hastaneye yatış (n = 1821)	p değeri
Karın Ağrısı	388 (%18,9)	319 (%17,5)	0,260
Nefes Darlığı	370 (%18,0)	508 (%27,9)	<0,001
Bulantı/Kusma	316 (%15,4)	302 (%16,6)	0,318
Göğüs Ağrısı	249 (%12,1)	228 (%12,5)	0,719
Halsizlik/Yorgunluk	168 (%8,2)	175 (%9,6)	0,121
Öksürük	155 (%7,6)	129 (%7,1)	0,573
Baş Dönmesi	147 (%7,2)	70 (%3,8)	<0,001
Düşme	137 (%6,7)	73 (%4,0)	<0,001
Ekstremitelerde Şişlik/Ağrı/Kızarıklık	122 (%5,9)	55 (%3,0)	<0,001
İshal	107 (%5,2)	55 (%3,0)	0,001
Dizüri	103 (%5,0)	46 (%2,5)	<0,001
Anormal Laboratuvar Değerleri	81 (%3,9)	105 (%5,8)	0,008
Oral Alım Bozukluğu	75 (%3,7)	146 (%8,0)	<0,001
Baş Ağrısı	75 (%3,7)	25 (%1,4)	<0,001
Balgam	74 (%3,6)	93 (%5,1)	0,022
Çarpıntı	70 (%3,4)	36 (%2,0)	0,006
Ateş	54 (%2,6)	112 (%6,2)	<0,001
Senkop	49 (%2,4)	32 (%1,8)	0,170
Hematüri	47 (%2,3)	29 (%1,6)	0,118
İdrar Yapamama	44 (%2,1)	10 (%0,5)	<0,001
Kabızlık	43 (%2,1)	18 (%1,0)	0,006
Bilinç Değişikliği	33 (%1,6)	164 (%9,0)	<0,001
Karında Şişlik/Asit	26 (%1,3)	19 (%1,0)	0,516
Fokal Nörolojik Defisit	17 (%0,8)	94 (%5,2)	<0,001
Genel Durum Bozukluğu	12 (%0,6)	42 (%2,3)	<0,001
Hematokezya	11 (%0,5)	38 (%2,1)	<0,001
Melena	10 (%0,5)	58 (%3,2)	<0,001
Dizartri/Afazi	10 (%0,5)	57 (%3,1)	<0,001
Hematemez	6 (%0,3)	51 (%2,8)	<0,001

Hastaneye yatan ve taburcu olan hastaların özgeçmişlerinde yer alan kronik hastalık dağılımları Tablo 4.4'te gösterilmiştir. Geriatrik hasta popülasyonunda en yaygın ilk üç kronik hastalık sırasıyla hipertansiyon (%56,8), diabetes mellitus (%36,2)

ve koroner arter hastalığıdır (%27,1). Hastaneye yatan hastalarda kalp yetmezliği, kronik böbrek yetmezliği, kronik karaciğer hastalığı taburcu olan hastalardan daha yüksek oranda tespit edilmiştir (hepsi için $p < 0,001$).

Tablo 4.4. Taburcu olan ve hastaneye yatan hastaların kronik hastalıklarının karşılaştırılması

Özgeçmişte yer alan hastalıklar, n (%)	Taburcu (n = 2051)	Hastaneye yatış (n = 1821)	p değeri
Hipertansiyon	1169 (%57,0)	1029 (%56,5)	0,759
Diabetes Mellitus	714 (%34,8)	686 (%37,7)	0,065
Koroner Arter Hastalığı	516 (%25,2)	534 (%29,3)	0,004
KOAH/Astım	396 (%19,3)	419 (%23,0)	0,005
Malignite	300 (%14,6)	314 (%17,2)	0,026
Kalp Yetmezliği	145 (%7,1)	205 (%11,3)	<0,001
Bening Prostat Hiperplazisi	144 (%7,0)	111 (%6,1)	0,247
Ritim Bozukluğu	140 (%6,8)	183 (%10,0)	<0,001
Hiperlipidemi	133 (%6,5)	100 (%5,5)	0,195
Serebrovasküler Olay	118 (%5,8)	141 (%7,7)	0,013
Kronik Böbrek Yetmezliği	113 (%5,5)	184 (%10,1)	<0,001
Hipo/Hipertiroidi	106 (%5,2)	92 (%5,1)	0,870
Alzheimer/Demens	64 (%3,1)	66 (%3,6)	0,385
Kalp Kapak Hastalığı	60 (%2,9)	49 (%2,7)	0,660
Romatolojik Hastalık	56 (%2,7)	46 (%2,5)	0,692
Parkinson	36 (%1,8)	28 (%1,5)	0,596
Hematolojik Malignite Dışı Hastalık	36 (%1,8)	32 (%1,8)	0,996
Kardiyak Destekleyici Cihaz	31 (%1,5)	37 (%2,0)	0,219
Psikiyatrik Hastalık	29 (%1,4)	10 (%0,5)	0,007
Vertigo	28 (%1,4)	11 (%0,6)	0,018
Kronik Karaciğer Hastalığı	23 (%1,1)	55 (%3,0)	<0,001
Hematolojik Malignite	9 (%0,4)	35 (%1,9)	<0,001

KOAH: Kronik Obstrüktif Akciğer Hastalığı


4.2. Makine Öğrenmesi ve Derin Öğrenme Model Sonuçları

Tez çalışmamızda LR, KNN, SMV, RF, AdaBoost, XGB ve MLP olmak üzere 7 farklı model uygulaması yapılmıştır. Bu bölümde modellere ait performans metrikleri sırasıyla sunulmuş ve daha sonra modellerin birbiriyle karşılaştırma sonuçlarına yer verilmiştir.

4.2.1. Lojistik regresyon (LR)

LR modeli sınıflandırma raporu Şekil 4.1’de gösterilmiştir. Sınıflandırma raporu incelendiğinde taburcu sınıfı için LR modelinin duyarlılık değeri 0,791 iken, kesinlik değeri 0,709’dur. Hastaneye yatış sınıfı için, modelin duyarlılık değeri 0,632’dir ve

taburcu sınıfından daha düşüktür. Hastane yatış sınıfı için kesinlik değeri 0,728'dir ve taburcu sınıfından daha yüksektir. LR modeli için makro ortalama F1 skoru 0,712 olarak hesaplanmıştır.




Şekil 4.1. LR modeli sınıflandırma raporu

LR modeli karışıklık matrisi Şekil 4.2’de gösterilmiştir. Karışıklık matrisi incelendiğinde LR modelinin hastaneye yatış öngörü doğruluk değeri %71,6 (%95 GA: 67,2 – 76,1), duyarlılık değeri %63,2 (%95 GA: 56,2 – 70,2) ve özgüllük değeri %79,1 (%95 GA: 73,6 – 84,7) olarak hesaplanmıştır. Bu sonuçlar LR modelinin orta düzeyde güvenilir ve dengeli bir model olduğunu göstermektedir. Literatürde acil servisten hastaneye yatış öngörüsü için geliştirilen LR model sonuçları incelendiğinde doğruluk değerlerinin %71 ila %76, duyarlılık değerlerinin %65 ila %80 ve özgüllük değerlerinin %69 ila %85 arasında değiştiği görülmektedir (Chang vd., 2024; Hong vd., 2018; Mowbray vd., 2020; Tan vd., 2021).

Tez çalışmamızda uygulanan LR modeli acil servisten taburcu olacak hastaları hastaneye yatacak hastalardan daha yüksek doğrulukla tespit edebilmektedir (taburcu sınıfı için F1 skoru 0,748 ve hastaneye yatış sınıfı için F1 skoru 0,676). Chang ve ark. tarafından yapılan çalışmada yer alan LR modeli, modelin eğitiminde kullanılan


özellikler açısından bu tez çalışmasındaki LR modeline çok benzemektedir, ancak çalışma popülasyonu 20 yaş ve üzeri yaklaşık 190,000 acil servis hastasından oluşmaktadır (Chang vd., 2024). Chang ve ark, LR modelinin duyarlılık değerinin %65 ve özgüllük değerinin %79 olduğunu bildirmiştir ve bu değerler tez çalışma bulgularımız ile hemen hemen aynıdır. Tez çalışmamızda yer alan hasta popülasyonu 3872 hastadan oluşmaktadır ve bu değer Chang ve ark. çalışmasında yer alan hastaların neredeyse %2'si büyüklüğünde bir popülasyona denk gelmektedir. Bulgularımız, acil servisten hastaneye yatış öngörüsü için LR modellerinin daha küçük veri setleri ile de benzer sonuçlar verdiğini düşündürmektedir.



Şekil 4.2. LR modeli karışıklık matrisi


LR modeli ROC eğrisi Şekil 4.3'te gösterilmiştir. LR modelinin hastaneye yatış öngörü EAA değeri 0,77 (%95 GA: 0,72 – 0,82) olarak hesaplanmıştır. Bu EAA değeri LR modelinin hastaneye yatış problemi için kabul edilebilir bir sınıflandırıcı olduğunu göstermektedir. Literatürde yer alan geriatrik hasta popülasyonunda yapılan çalışmalarda LR modelleri için EAA değeri 0,79 ve 0,80 olarak bildirilmiştir (Mowbray vd., 2020; Tan vd., 2021). Erişkin yaş grubunda yapılan çalışmalarda ise EAA değerlerinin 0,80 ila 0,91 arasında değiştiği bildirilmiştir (Chang vd., 2024; Hong vd., 2018). Tez çalışmamızda elde ettiğimiz sonuçlar literatürdeki geriatrik hasta

popülasyonunda yapılan çalışmalar ile uyumludur. Geriatrik hasta grubunda hastaneye yatış öngörüsü için LR modeli genç hasta grubuna göre daha düşük sınıflandırma başarısına sahiptir, ancak başarı oranı yine de klinik kullanıma uygun düzeydedir.



Şekil 4.3. LR modeli ROC eğrisi


LR modelinin SHAP analizi Şekil 4.4'te gösterilmiştir. SHAP analizine göre LR modeline hastaneye yatış öngörüsünde en etkili 5 özellik dizatri/afazi varlığı, melena varlığı, fokal nörolojik defisit varlığı, hematokezya varlığı ve Glasgow koma skalasının 14'ten düşük olmasıdır. Bu 5 özelliğin var olduğu hastalar özelliklerin pozitif SHAP değerleri nedeniyle hastaneye yatışın en önemli belirleyicileri olarak değerlendirilebilir. LR modelinde negatif SHAP değeri olan 2 özellik baş dönmesi varlığı ve ishal varlığıdır. Bu iki semptomu sahip hastalar acil servisten daha fazla oranda taburcu edilmiştir.



Şekil 4.4. LR modeli SHAP analizi

4.2.2. K-en yakın komşu (KNN)


KNN modeli sınıflandırma raporu Şekil 4.5'te gösterilmiştir. Sınıflandırma raporu incelendiğinde taburcu sınıfı için KNN modelinin duyarlılık değeri 0,913 iken, kesinlik değeri 0,595'dir. Hastaneye yatış sınıfı için, modelin duyarlılık değeri 0,297'dir ve taburcu sınıfından çok daha düşüktür. Hastane yatış sınıfı için kesinlik değeri 0,750'dir ve taburcu sınıfından çok daha yüksektir. KNN modelinin performans metriklerinin taburcu ve hastaneye yatış sınıflarında bu denli farklı olması modelin hastaneye yatış öngörüsü için zayıf bir model olduğunu göstermektedir. KNN modeli için makro ortalama F1 skoru 0,573 olarak hesaplanmıştır.



Şekil 4.5. KNN modeli sınıflandırma raporu


KNN modeli karışıklık matrisi Şekil 4.6’da gösterilmiştir. Karışıklık matrisi incelendiğinde KNN modelinin hastaneye yatiş öngörü doğruluk değeri %62,4 (%95 GA: 57,6 – 67,2), duyarlılık değeri %29,7 (%95 GA: 23 – 36,3) ve özgüllük değeri %91,3 (%95 GA: 87,4 – 95,1) olarak hesaplanmıştır. Bu sonuçlar KNN modelinin hastaneye yatiş öngörüsü için güvenilmez ve sınıflar arasında dengesiz bir model olduğunu göstermektedir.

Literatürde geriatrik hasta popülasyonunda acil servisten hastaneye yatiş öngörüsü için geliştirilen KNN model sonuçları incelendiğinde hem duyarlılık hem özgüllük değerlerinin yaklaşık %70 olduğu ve dengeli bir öngörü modeli olduğu bildirilmektedir (Bunney vd., 2023; Tan vd., 2021). Tez çalışmamızda elde ettiğimiz bulgular mevcut literatür bilgisi ile uyumlu değildir. Tan ve ark. çalışmasında veri setinde acil servise başvuru şikayetleri yer almamaktadır. Diğer yandan Bunney ve ark. çalışmasında veri setinde kronik hastalık öyküsü yer almamakta ve acil servis başvuru şikayetlerinden sadece en sık görülen nefes darlığı, göğüs ağrısı, karın ağrısı özellikleri yer almaktadır. Tez çalışmamızın veri setinde yer alan özellik sayısının ilgili çalışmalardan fazla olması KNN modelinde komşuluk ilişkilerinin kurulmasını zorlaştırmış olabilir.




Şekil 4.6. KNN modeli karışıklık matrisi

KNN modeli ROC eğrisi Şekil 4.7’de gösterilmiştir. KNN modelinin hastaneye yatış öngörü EAA değeri 0,69 (%95 GA: 0,64 – 0,74) olarak hesaplanmıştır. Bu EAA değeri KNN modelinin hastaneye yatış problemi için zayıf bir sınıflandırıcı olduğunu göstermektedir. Literatürde yer alan geriatrik hasta popülasyonunda yapılan çalışmalarda KNN modelleri için EAA değeri 0,74 ve 0,75 olarak bildirilmiştir (Bunney vd., 2023; Tan vd., 2021). Tez çalışmamızda elde ettiğimiz sonuçlar literatürdeki geriatrik çalışmalarından daha düşük düzeydedir. Bu düşük performans, kullanılan popülasyonun klinik heterojenitesinden veya hastaneye yatışı yeterince temsil eden ayırt edici klinik özelliklerin model tarafından yeterince iyi belirlenememiş olmasından kaynaklanabilir.



Şekil 4.7. KNN modeli ROC eğrisi


KNN modelinin SHAP analizi Şekil 4.8’de gösterilmiştir. SHAP analizine göre KNN modelinin hastaneye yatış öngörüsünde en etkili 5 özellik bilinç değişikliği varlığı, bradikardi/taşikardi varlığı, dizatri/afazi varlığı, fokal nörolojik defisit varlığı ve Glasgow koma skalasının 14’ten düşük olmasıdır. Bu 5 özelliğin var olduğu hastalar özelliklerin pozitif SHAP değerleri nedeniyle hastaneye yatışın en önemli belirleyicileri olarak değerlendirilebilir. KNN modelinde negatif SHAP değeri olan en etkili 5 özellik bening prostat hiperplazi varlığı, kalp kapak hastalığı varlığı, ekstremitelerde ağrı/şişlik/kızarıklık varlığı, ishal varlığı ve öksürük varlığıdır. Modelde en etkili 20 özelliğin 8 tanesi negatif SHAP değerine sahip özelliklerden oluşmaktadır. Bu bulgu modelin yüksek özgüllük değeri ile uyumludur.



Şekil 4.8. KNN modeli SHAP analizi


4.2.3. Destek vektör makineleri (SVM)

SVM modeli sınıflandırma raporu Şekil 4.9'da gösterilmiştir. Sınıflandırma raporu incelendiğinde taburcu sınıfı için SVM modelinin duyarlılık değeri 0,830 iken, kesinlik değeri 0,701'dir. Hastaneye yatış sınıfı için, modelin duyarlılık değeri 0,599'dur ve taburcu sınıfından daha düşüktür. Hastane yatış sınıfı için kesinlik değeri 0,757'dir ve taburcu sınıfından daha yüksektir. SVM modeli için makro ortalama F1 skoru 0,715 olarak hesaplanmıştır.




Şekil 4.9. SVM modeli sınıflandırma raporu

SVM modeli karışıklık matrisi Şekil 4.10’da gösterilmiştir. Karışıklık matrisi incelendiğinde SVM modelinin hastaneye yatış öngörü doğruluk değeri %72,2 (%95 GA: 67,7 – 76,6), duyarlılık değeri %59,9 (%95 GA: 52,8 – 67) ve özgüllük değeri %83 (%95 GA: 77,9 – 88,1) olarak hesaplanmıştır. Bu sonuçlar SMV modelinin orta düzeyde güvenilir ve dengeli bir model olduğunu göstermektedir. Literatürde acil servisten hastaneye yatış öngörüsü için geliştirilen SVM model sonuçları incelendiğinde doğruluk değerlerinin %72 ila %82, duyarlılık değerlerinin %73 ila %75 ve özgüllük değerlerinin %71 ila %75 arasında değiştiği görülmektedir (Bunney vd., 2023; Mowbray vd., 2020; Tan vd., 2021). Tez çalışmamızda elde ettiğimiz sonuçlar modelin doğruluğu açısından literatürdeki çalışmalar ile uyumludur, ancak daha düşük duyarlılık ve daha yüksek özgüllük değerine sahiptir.




Şekil 4.10. SVM modeli karışıklık matrisi

SVM modeli ROC eğrisi Şekil 4.11’de gösterilmiştir. SVM modelinin hastaneye yatış öngörü EAA değeri 0,77 (%95 GA: 0,72 – 0,82) olarak hesaplanmıştır. Bu EAA değeri SVM modelinin hastaneye yatış problemi için kabul edilebilir bir sınıflandırıcı olduğunu göstermektedir. Literatürde yer alan çalışmalarda SVM modelleri için EAA değerinin 0,79 ila 0,84 arasında değiştiği bildirilmiştir (Bunney vd., 2023; Mowbray vd., 2020; Tan vd., 2021). Tez çalışmamızda elde ettiğimiz sonuçlar literatürdeki çalışmalar ile uyumludur. SVM modelinin sınıflandırma gücünü artırmak için modele giren özelliklerin azaltılması veya birleştirilmesi gibi metotlar denenebilir. Tez çalışmamızda modellerin standart metotlarla karşılaştırılması amacıyla algoritmalara özel özellik azaltma yöntemleri uygulanmamıştır.



Şekil 4.11. SVM modeli ROC eğrisi


SVM modelinin SHAP analizi Şekil 4.12’de gösterilmiştir. SHAP analizine göre SVM modeline hastaneye yatış öngörüsünde en etkili 5 özellik dizartri/afazi varlığı, hematokezya varlığı, fokal nörolojik defisit varlığı, melena varlığı ve hematemez varlığı olmasıdır. Bu 5 özelliğin var olduğu hastalar özelliklerin pozitif SHAP değerleri nedeniyle hastaneye yatışın en önemli belirleyicileri olarak değerlendirilebilir. Hemotekazy, melena ve hematemez semptomlarının üçü de gastrointestinal sistem kanamasını işaret eden semptomlardır ve modele kümülatif etkileri nedeniyle birleştirilip tek bir özellik altında toplanması model performansını iyileştirebilir. SMV modelinde negatif SHAP değeri olan 2 özellik baş dönmesi varlığı ve öksürük varlığıdır. Bu iki semptoma sahip hastalar acil servisten daha fazla oranda taburcu edilmiştir.



Şekil 4.12. SVM modeli SHAP analizi

4.2.4. Rasgele orman (RF)

RF modeli sınıflandırma raporu Şekil 4.13'te gösterilmiştir. Sınıflandırma raporu incelendiğinde taburcu sınıfı için RF modelinin duyarlılık değeri 0,869 iken, kesinlik değeri 0,668'dur. Hastaneye yatış sınıfı için, modelin duyarlılık değeri 0,511'dir ve taburcu sınıfından çok daha düşüktür. Hastane yatış sınıfı için kesinlik değeri 0,775'dir ve taburcu sınıfından daha yüksektir. RF modeli için makro ortalama F1 skoru 0,686 olarak hesaplanmıştır.




Şekil 4.13. RF modeli sınıflandırma raporu

RF modeli karışıklık matrisi Şekil 4.14'te gösterilmiştir. Karışıklık matrisi incelendiğinde RF modelinin hastaneye yatış öngörü doğruluk değeri %70,1 (%95 GA: 65,5 – 76,6), duyarlılık değeri %51,1 (%95 GA: 43,82 – 58,4) ve özgüllük değeri %86,9 (%95 GA: 82,3 – 91,5) olarak hesaplanmıştır. Bu sonuçlar RF modelinin orta düzeyde güvenilir ve nispeten dengesiz bir model olduğunu göstermektedir. Literatürde acil servisten hastaneye yatış öngörüsü için geliştirilen RF model sonuçları incelendiğinde doğruluk değerlerinin %72 ila %78, duyarlılık değerlerinin %65 ila %79 ve özgüllük değerlerinin %73 ila %82 arasında değiştiği görülmektedir (Bunney vd., 2023; Chang vd., 2024; Mowbray vd., 2020; Tan vd., 2021).


Literatürde yer alan tüm çalışmalarda RF modelinin özgüllük değeri duyarlılık değerinden daha yüksek tespit edilmiştir ve tez çalışmamızdan elde ettiğimiz sonuçlar literatür ile uyumludur. RF modelinin algoritması, genellikle yüksek kesinlik ve dolayısıyla yüksek özgüllük eğilimi gösterir. Çünkü RF, karar ağaçlarının bir topluluğu olarak, yüksek bilgi kazancı sağlayan ayırıcı özellikleri kullanarak net karar sınırları oluşturur. Bu nedenle, bu tez çalışma sonuçlarının özgüllük açısından literatür ile uyumlu olması beklenen bir sonuçtur. Ancak, tez çalışmamızda elde ettiğimiz duyarlılık

değeri literatürde yer alan çalışmalardan yaklaşık %15 daha düşüktür. Bu tez çalışmamızda tüm modellerde olduğu gibi RF modelinin hiperparametreleri doğruluk değerini en yüksek düzeye ulaştırmak hedefiyle ayarlanmıştır ve bu hedef modelde daha yüksek özgüllük, haliyle daha düşük duyarlılık düzeylerinin ortaya çıkmasına neden olmuş olabilir.




Şekil 4.14. RF modeli karışıklık matrisi

RF modeli ROC eğrisi Şekil 4.15'te gösterilmiştir. RF modelinin hastaneye yatış öngörü EAA değeri 0,77 (%95 GA: 0,72 – 0,82) olarak hesaplanmıştır. Bu EAA değeri RF modelinin hastaneye yatış problemi için kabul edilebilir bir sınıflandırıcı olduğunu göstermektedir. Literatürde yer alan çalışmalarda RF modelleri için EAA değeri 0,78 ila 0,85 arasında değiştiği bildirilmiştir (Bunney vd., 2023; Chang vd., 2024; Mowbray vd., 2020; Tan vd., 2021). Tez çalışmamızda elde ettiğimiz sonuçlar literatürdeki geriatrik çalışmalar ile uyumludur.



Şekil 4.15. RF modeli ROC eğrisi


RF modelinin SHAP analizi Şekil 4.16’da gösterilmiştir. SHAP analizine göre RF modeline hastaneye yatış öngörüsünde en etkili 5 özellik melena varlığı, fokal nörolojik defisit varlığı, Glasgow koma skalasının 14’ten düşük olması, hematemez varlığı ve bilinç değişikliği varlığıdır. Bu 5 özelliğin var olduğu hastalar özelliklerin pozitif SHAP değerleri nedeniyle hastaneye yatışın en önemli belirleyicileri olarak değerlendirilebilir. RF modelinde negatif SHAP değeri olan tek bir özellik vardır ve bu ekstremitelerde şişlik/ağrı/kızarıklık varlığıdır. Bu semptomu sahip hastalar acil servisten daha çok taburcu edilmiştir.



Şekil 4.16. RF modeli SHAP analizi

4.2.5. Uyarlanabilir artırma (AdaBoost)


Bu tez çalışmasında iki farklı artırma algoritmasına dayanan iki farklı model geliştirilmiştir. Bu modellerden ilki olan AdaBoost sınıflandırma raporu Şekil 4.17'de gösterilmiştir. Sınıflandırma raporu incelendiğinde taburcu sınıfı için AdaBoost modelinin duyarlılık değeri 0,840 iken, kesinlik değeri 0,698'dir. Hastaneye yatış sınıfı için, modelin duyarlılık değeri 0,588'dir ve taburcu sınıfından daha düşüktür. Hastane yatış sınıfı için kesinlik değeri 0,764'tür ve taburcu sınıfından daha yüksektir. AdaBoost modeli için makro ortalama F1 skoru 0,714 olarak hesaplanmıştır.



Şekil 4.17. AdaBoost modeli sınıflandırma raporu


AdaBoost modeli karışıklık matrisi Şekil 4.18’de gösterilmiştir. Karışıklık matrisi incelendiğinde AdaBoost modelinin hastaneye yatış öngörü doğruluk değeri %72,2 (%95 GA: 67,7 – 76,6), duyarlılık değeri %58,8 (%95 GA: 51,6 – 65,9) ve özgüllük değeri %84,0 (%95 GA: 79,0 – 89,0) olarak hesaplanmıştır. Bu sonuçlar AdaBoost modelinin orta düzeyde güvenilir ve dengeli bir model olduğunu göstermektedir. Zeleke ve ark. tarafından yapılan bir çalışmada, acil servis hastalarında uzamış hastanede yatış öngörüsü problemi ele alınmış ve bu problem için AdaBoost modelinin en düşük performansı sergilediği duyarlılık ve özgüllük değerlerinin %65 olduğu bildirilmiştir (Zeleke vd., 2023). Yapıcı ve ark. tarafından yapılan bir çalışmada, erişkin hastaların demografik verileri ve triyaj vital bulguları kullanılarak geliştirilen artırma algoritmalarının acil servisten hastaneye yatış öngörü performansları karşılaştırılmış ve AdaBoost modelinin doğruluk değeri %74, duyarlılık değeri %75 ve özgüllük değeri %66 olarak bildirilmiştir (Yapıcı vd., 2024). Tez çalışma bulgularımız literatür bilgileri ile modelin doğruluğu açısından uyumludur, ancak duyarlılık ve özgüllük açısından çelişmektedir. Bu bulgular modelin veri setine duyarlılığının yüksek olduğunu ve farklı veri setlerine sahip çalışmalarla metriklerin karşılaştırmalı analizini

zorlaştırdığını düşündürmektedir. Tez çalışma sonuçlarımız benzer veri setine sahip ileri çalışmalarla tekrar değerlendirilmelidir.




Şekil 4.18. AdaBoost modeli karışıklık matrisi

AdaBoost modeli ROC eğrisi Şekil 4.19’da gösterilmiştir. AdaBoost modelinin hastaneye yatış öngörü EAA değeri 0,77 (%95 GA: 0,72 – 0,82) olarak hesaplanmıştır. Bu EAA değeri AdaBoost modelinin hastaneye yatış problemi için kabul edilebilir bir sınıflandırıcı olduğunu göstermektedir. Literatürde yer alan erişkin acil servis hastalarında yapılan iki çalışmada AdaBoost modelleri için EAA değeri 0,778 ve 0,753 olarak bildirilmiştir (Feretakis vd., 2022; Yapıcı vd., 2024). Tez çalışmamızın bulguları ilgili literatür ile benzerlik göstermektedir.



Şekil 4.19. AdaBoost modeli ROC eğrisi


AdaBoost modelinin SHAP analizi Şekil 4.20’de gösterilmiştir. SHAP analizine göre AdaBoost modeline hastaneye yatış öngörüsünde en etkili 5 özellik Glasgow koma skalasının 14’ten düşük olması, fokal nörolojik defisit varlığı, hematokezya varlığı, dizatri/afazi varlığı ve melena varlığıdır. Bu 5 özelliğin var olduğu hastalar özelliklerin pozitif SHAP değerleri nedeniyle hastaneye yatışın en önemli belirleyicileri olarak değerlendirilebilir. Adaboost modelinde negatif SHAP değeri olan tek bir özellik vardır ve bu özellik öksürük varlığıdır.



Şekil 4.20. AdaBoost modeli SHAP analizi


4.2.6. Aşırı gradyan artırma (XGB)

XGB modeli sınıflandırma raporu Şekil 4.21’de gösterilmiştir. Sınıflandırma raporu incelendiğinde taburcu sınıfı için XGB modelinin duyarlılık değeri 0,762 iken, kesinlik değeri 0,654’tür. Hastaneye yatış sınıfı için, modelin duyarlılık değeri 0,544’tür ve taburcu sınıfından daha düşüktür. Hastane yatış sınıfı için kesinlik değeri 0,669’dur ve taburcu sınıfından daha yüksektir. XGB modeli için makro ortalama F1 skoru 0,652 olarak hesaplanmıştır.




Şekil 4.21. XGB modeli sınıflandırma raporu

XGB modeli karışıklık matrisi Şekil 4.22’de gösterilmiştir. Karışıklık matrisi incelendiğinde XGB modelinin hastaneye yatış öngörü doğruluk değeri %66,6 (%95 GA: 61,3 – 70,7), duyarlılık değeri %54,4 (%95 GA: 47,2 – 61,6) ve özgüllük değeri %76,2 (%95 GA: 70,4 – 82) olarak hesaplanmıştır. Bu sonuçlar XGB modelinin düşük düzeyde güvenilir ve nispeten dengesiz bir model olduğunu göstermektedir. Literatürde acil servisten hastaneye yatış öngörüsü için geliştirilen XGB model sonuçları incelendiğinde doğruluk değerlerinin %72 ila %75, duyarlılık değerlerinin %70 ila %83 ve özgüllük değerlerinin %75 ila %92 arasında değiştiği görülmektedir (Agius vd., 2025; Hong vd., 2018; Kishore vd., 2023; Raita vd., 2019; Tan vd., 2021). Tez çalışma bulgularımız XGB modelinin literatürde yer alan modellerden daha düşük performans sergilediğini ve tezde yer alan XGB modelinin pozitif sınıfı öğrenme yeteneğinin literatürdeki çalışmalara kıyasla çok daha zayıf olduğunu göstermektedir. Bunun nedeni, XGB algoritmasının özellik sayısının fazla olduğu ve az sayıda satır içeren veri setlerinde gürültülü özellikler arasındaki ilişkileri aşırı öğrenme eğilimi olabilir. Ayrıca XGB algoritmasının zengin hiperparametreleri *RandomSearchCV* yerine daha fazla sayıda kombinasyonu deneyen *GridSearchCV* ile ayarlanarak model performansının artırılması denenebilir.



Şekil 4.22. XGB modeli karışıklık matrisi

XGB modeli ROC eğrisi Şekil 4.23'te gösterilmiştir. XGB modelinin hastaneye yatış öngörü EAA değeri 0,71 (%95 GA: 0,66 – 0,76) olarak hesaplanmıştır. Bu EAA değeri XGB modelinin hastaneye yatış problemi için kabul edilebilir bir sınıflandırıcı olduğunu göstermektedir. Literatürde yer alan geriatrik hasta popülasyonunda yapılan çalışmalarda XGB modelleri için EAA değerinin 0,80 ila 0,93 arasında değiştiği bildirilmiştir (Agius vd., 2025; Hong vd., 2018; Kishore vd., 2023; Raita vd., 2019; Tan vd., 2021). Tez çalışmamızda elde ettiğimiz EAA değeri literatürdeki çalışmalardan daha düşüktür. Hiperparametre ayarlarının iyileştirilmesi ve veri setinde özellik azaltma metotlarının kullanımı modelin performansını iyileştirebilir.




Şekil 4.23. XGB modeli ROC eğrisi

Bu tez çalışmasında geliştirilen AdaBoost ve XGB modelleri karşılaştırıldığında AdaBoost modelinin doğruluk oranı XGB modelinden %6,2 daha iyidir. Yine AdaBoost modelinin EAA değeri 0,77 iken XGB modelinde bu değer 0,71'dir. Her iki modelin de duyarlılık değerleri düşük iken (yaklaşık %55) özgüllük değerleri %75'in üzerindedir. Bu iki algoritma arasındaki önemli farklardan biri AdaBoost algoritması sıralı işlem yaparken XGB algoritmasının paralel işlem yapabilme yeteneğinin olmasıdır. Paralel işlem yeteneği XGB modellerine genellikle daha karmaşık ilişkileri çözümleme avantajı sağlar, ancak veri seti küçüldükçe ve ağaç derinliği arttıkça aşırı öğrenme riskini de beraberinde getirir. Tez çalışmamızda AdaBoost modelinde $n_esitmator = 50$ iken XGB modelinde $n_esitmator = 200$ 'dir. XGB modelinin daha düşük performansının sebeplerinden biri daha karmaşık ağaç yapısı olabilir.

XGB modelinin SHAP analizi Şekil 4.24'te gösterilmiştir. SHAP analizine göre XGB modeline hastaneye yatış öngörüsünde en etkili 5 özellik hematokezya varlığı, melena varlığı, dizartri/afazi varlığı, fokal nörolojik defisit varlığı ve hematemez varlığıdır. Bu 5 özelliğin var olduğu hastalar özelliklerin pozitif SHAP değerleri nedeniyle hastaneye yatışın en önemli belirleyicileri olarak değerlendirilebilir. XGB modelinde negatif SHAP değeri olan 3 özellik psikiyatrik hastalık varlığı, ishal varlığı


ve ekstremitelerde şişlik/ağrı/kızarıklık varlığıdır. Bu iki semptomu sahip hastalar acil servisten daha çok taburcu edilmiştir.



Şekil 4.24. XGB modeli SHAP analizi


4.2.7. Çok katmanlı algılayıcı (MLP)

MLP modeli sınıflandırma raporu Şekil 4.25'te gösterilmiştir. Sınıflandırma raporu incelendiğinde taburcu sınıfı için MLP modelinin duyarlılık değeri 0,801 iken, kesinlik değeri 0,708'dir. Hastaneye yatış sınıfı için, modelin duyarlılık değeri 0,626'dır ve taburcu sınıfından daha düşüktür. Hastane yatış sınıfı için kesinlik değeri 0,735'dir ve taburcu sınıfından daha yüksektir. MLP modeli için makro ortalama F1 skoru 0,715 olarak hesaplanmıştır.




Şekil 4.25. MLP modeli sınıflandırma raporu

MLP modeli karışıklık matrisi Şekil 4.26’da gösterilmiştir. Karışıklık matrisi incelendiğinde MLP modelinin hastaneye yatış öngörü doğruluk değeri %71,9 (%95 GA: 67,4 – 76,4), duyarlılık değeri %62,9 (%95 GA: 55,6 – 69,7) ve özgüllük değeri %80,1 (%95 GA: 74,6 – 85,5) olarak hesaplanmıştır. Bu sonuçlar MLP modelinin orta düzeyde güvenilir ve dengeli bir model olduğunu göstermektedir. Literatürde acil servisten hastaneye yatış öngörüsü için geliştirilen MLP model sonuçları incelendiğinde duyarlılık değerlerinin %70 ila %82 ve özgüllük değerlerinin %67 ila %85 arasında değiştiği görülmektedir (Bunney vd., 2023; Hong vd., 2018; Raita vd., 2019; Tan vd., 2021). Bu çalışmaların bazılarında özgüllük değerleri duyarlılık değerlerinden bir miktar yüksek iken bazılarında ise duyarlılık değerleri daha yüksek tespit edilmiştir. Tez çalışmamızda MLP modelinin özgüllük değeri duyarlılık değerinden daha yüksektir. Çalışma sonuçları arasındaki bu farklılığın muhtemel sebebi modellerin geliştirilmesinde kullanılan özelliklerin birbirinden farklı olması ve veri seti heterojenliğidir.




Şekil 4.26. MLP modeli karışıklık matrisi

MLP modeli ROC eğrisi Şekil 4.27’de gösterilmiştir. MLP modelinin hastaneye yatış öngörü EAA değeri 0,77 (%95 GA: 0,72 – 0,82) olarak hesaplanmıştır. Bu EAA değeri MLP modelinin hastaneye yatış problemi için kabul edilebilir bir sınıflandırıcı olduğunu göstermektedir. Literatürde yer alan geriatrik hasta popülasyonunda yapılan çalışmalarda MLP modelleri için EAA değeri 0,73 ila 0,78 olarak bildirilmiştir (Bunney vd., 2023; Tan vd., 2021). Erişkin yaş grubunda yapılan çalışmalarda ise EAA değerlerinin 0,74 ila 0,92 arasında değiştiği bildirilmiştir (Feretzakis vd., 2022; Hong vd., 2018; Raita vd., 2019). Tez çalışmamızda elde ettiğimiz sonuçlar literatürdeki geriatrik popülasyonda yürütülen çalışmalar ile uyumludur.



Şekil 4.27. MLP modeli ROC eğrisi

MLP modelinin SHAP analizi Şekil 4.28’de gösterilmiştir. SHAP analizine göre MLP modeline hastaneye yatış öngörüsünde en etkili 5 özellik Glasgow koma skalasının 14’ten düşük olması, fokal nörolojik defisit varlığı, dizartri/afazi varlığı, melena varlığı ve hematokezya varlığıdır. Bu 5 özelliğin var olduğu hastalar özelliklerin pozitif SHAP değerleri nedeniyle hastaneye yatışın en önemli belirleyicileri olarak değerlendirilebilir. MLP modelinde negatif SHAP değeri olan tek bir özellik vardır ve bu özellik öksürük varlığıdır.



Şekil 4.28. MLP modeli SHAP analizi

4.3. Makine Öğrenmesi ve Derin Öğrenme Modellerinin Karşılaştırılması

Tez çalışmamızda geliştirilen 7 farklı makine öğrenmesi ve derin öğrenme modellerinden en yüksek makro ortalama F1 skorları LR, SVM, AdaBoost ve MLP modellerinde elde edilmiştir (hepsi için yaklaşık 0,715). En düşük makro ortalama F1 skoru ise KNN modelinde hesaplanmıştır (0,573). Model metriklerinin karşılaştırması Tablo 4.5'te gösterilmiştir.


Literatürdeki acil servisten hastaneye yatış öngörü modellerinin karşılaştırıldığı çalışmaların büyük kısmında metrik olarak F1 skoru verilmemiştir. Feretzakis ve ark. tarafından yapılan çalışmada, bizim çalışmamızla ortak olan 4 model vardır (LR, RF, AdaBoost, MLP). Bu çalışmada F1 skoru en yüksek modelin MLP (0,707) ve en düşük modelin AdaBoost (0,685) olduğu bildirilmiştir. Tez çalışmamız ile bu çalışma arasında çalışma popülasyonu ve veri seti özellikleri açısından farklılıklar vardır. Sonuçlar arasındaki uyumsuzluğun temel sebebinin veri seti heterojenliği olduğu düşünülmüştür.

Tablo 4.5. Model metriklerinin karşılaştırması

Model	Doğruluk	EAA	Kesinlik	Duyarlılık	Özgüllük	F1 skoru*
LR	%71,6	0,77	0,728	0,632	0,791	0,712
KNN	%62,4	0,69	0,750	0,297	0,913	0,573
SVM	%72,2	0,77	0,757	0,599	0,830	0,715
RF	%70,1	0,77	0,775	0,511	0,869	0,686
AdaBoost	%72,2	0,77	0,764	0,588	0,840	0,714
XGB	%66,0	0,71	0,669	0,544	0,762	0,652
MLP	%71,9	0,77	0,735	0,629	0,801	0,715

*Makro ortalama F1 skoru
EAA: Eğri altında kalan alan


Tez çalışmamızda karşılaştırılan 7 modelden en yüksek doğruluk değerleri LR, SVM, AdaBoost ve MLP modellerinde elde edilmiştir (hepsi için yaklaşık %72). En düşük doğruluk değeri ise KNN modelinde hesaplanmıştır (%62). Makro ortalama F1 skoru ile doğruluk değerleri birbirine yakındır ve bu durum makro ortalama F1 skorunun duyarlılık ve kesinlik değerlerini dengeli şekilde yansıtması nedeniyle beklenen bir durumdur. Modellerin doğruluk oranları Şekil 4.29'da gösterilmiştir.

**Şekil 4.29.** Modellerin doğruluk değerlerinin karşılaştırılması

Mowbray ve ark. tarafından geriatrik hastalarda yapılan çalışmada, 3 modelin (SVM, LR, RF) doğruluk değerlerinin %72 olduğu bildirilmiştir (Mowbray vd., 2020). Tan ve ark. tarafından geriatrik influenza hastalarında acil servisten hastaneye yatış üzerine yapılan çalışmada, tez çalışmamız ile 6 model ortaktır. Çalışmada, en yüksek doğruluk değerine sahip model RF (%77) iken en düşük doğruluk değerine sahip model

XGB'dir (%72). Tan ve ark. çalışmasında veri setinde semptomların dikkate alınmaması ve laboratuvar sonuçlarının yer alması bakımından tez çalışmamızdan farklıdır, ancak benzer bir sınıflandırma problemine çözüm araması yönüyle değerlidir (Tan vd., 2021). Literatürde yer alan bu bilgiler ışığında tez çalışmamızda geliştirilen modellerin performansları geriatrik hasta popülasyonunda elde edilen daha önceki sonuçları doğrular niteliktedir, ancak yine de modellerin elde ettiği maksimum doğruluk %72'nin üzerine çıkarılamamıştır. Modellerin doğruluk oranları ve F1 skorlarının yükseltilmesi amacıyla özellik azaltma metotlarının denenmesi ve acil serviste elde edilecek tetkik sonuçların veri setine dahil edilmesi ileri araştırma konusudur.


Tez çalışmamızda yer alan modellerin kesinlik değerlerinin karşılaştırması Şekil 4.31'de gösterilmiştir. Modellerden en düşük kesinlik değerine sahip modelin XGB (%67) ve en yüksek kesinlik değerine sahip modelin RF (%78) olduğu tespit edilmiştir.



Şekil 4.30. Modellerin kesinlik değerlerinin karşılaştırılması


Tez çalışmamızda yer alan modellerin duyarlılık ve özgüllük değerlerinin karşılaştırması Şekil 4.32'de gösterilmiştir. Modellerden en düşük duyarlılık değerine sahip modelin KNN (%30) iken en yüksek duyarlılık değerine sahip modellerin LR ve MLP (%63) olduğu tespit edilmiştir. Modellerin hastaneye yatacak hastaları tahmin doğrulukları %72'den daha düşüktür ve klinik olarak kullanıma sunulmaları için modellerin geliştirilme yolları aranmalıdır. Modellerden en düşük özgüllük değerine sahip modelin XGB (%76,2) ve en yüksek özgüllük değerine sahip modelin KNN (%91) olduğu tespit edilmiştir. Yüksek duyarlılık/düşük özgüllük ve yüksek

özgüllük/düşük duyarlılık metriklerine sahip modellerin beraber kullanımının klinik yorumları ne kadar iyileştireceği farklı metodolojiye sahip çalışmalarla değerlendirilmelidir.



Şekil 4.31. Modellerin duyarlılık ve özgüllük değerlerinin karşılaştırılması

Tez çalışmamızda yer alan modellerin EAA değerlerinin karşılaştırması Şekil 4.30'da gösterilmiştir. Modellerin EAA değerleri incelendiğinde acil servisten hastaneye yatış öngörüsünde KNN modeli zayıf bir sınıflandırıcı olduğu ve diğer modellerin kabul edilebilir sınıflandırıcılar olduğu tespit edilmiştir. Literatürde yer alan EAA değerleri ile benzer sonuçlar elde edilmiştir (Mowbray vd., 2020; Tan vd., 2021).



Şekil 4.32. Modellerin ROC EAA değerlerinin karşılaştırılması

Sağlık alanında makine öğrenmesi ve derin öğrenme modellerinin sınıf tahmin başarısını artırma, çok fazla özelliği eş zamanlı değerlendirebilme, büyük veri setleri ile çalışmaya imkan tanıma gibi faydalarının yanında özelliklerin ilişkilerinin açık şekilde belirlenememesi ve dolayısıyla sayısal bilgilerin klinik önerilere dönüştürülebilmesi gibi sınırlılıkları vardır (Rajula vd., 2020).

Bu nedenle son yıllarda “açıklanabilir yapay zekâ” kavramı ortaya atılmıştır. Açıklanabilir yapay zekâ, karmaşık makine öğrenmesi modellerinin aldığı kararların ve ulaştığı sonuçların, insanlar tarafından anlaşılabilir, yorumlanabilir ve şeffaf olmasını sağlayan süreçler bütünüdür. Bu yaklaşım, XGB gibi yüksek performanslı ancak iç yapısı kara kutu (black box) niteliğindeki algoritmaların bir girdiyi işlerken hangi özelliklere ağırlık verdiğini ve neden belirli bir çıktıyı ürettiğini ortaya koymayı amaçlar. Böylelikle, modelin sadece doğru tahminde bulunmasını değil, aynı zamanda karar mekanizmasının mantığının da görünür kılınması amaçlanmaktadır (Barredo Arrieta vd., 2020; Rudin, 2019). Öte yandan beyaz kutu (white box) modellerin, seçilmiş problemlerde doğru özellik mühendisliği ile kara kutu modeller kadar başarılı olabileceği de belirtilmektedir (Rudin, 2019). Tez çalışma sonuçlarımız bu bağlamda gözden geçirildiğinde LR modeli (beyaz kutu) ile MLP modelinin (kara kutu) performans metriklerinin hemen hepsinin birbirine çok benzer olduğu görülmektedir. Yine, LR ve MLP modellerinin SHAP analizleri karşılaştırıldığında en yüksek etkili 20 özelliğin 18’inin ortak olduğu görülmüştür. Bu sonuçlarımız, acil servisten hastaneye

yatış öngörü problemi için görece daha basit algoritmalara sahip makine öğrenmesi modellerinin problemin çözümü için yeterince etkin olabileceğini düşündürmektedir.

Tez çalışmamızda tüm modellerin açıklanabilir ve klinik yorumlanabilir hale getirilebilmesi için model agnostik SHAP analizi yapılmıştır. Modellerin tahmin yapma performanslarına en fazla etki eden 20 özelliği içeren grafikler değerlendirilmiştir (Tablo 4.6). Tüm modellerde ilk 20 içinde yer alan özellikler oksijen satürasyonu ve Glasgow koma skalası, bilinç değişikliği, dizatri/afazi, fokal nörolojik defisit ve nefes darlığıdır. Bu sonuçlarımız geriatrik hasta grubunda santral sinir sistemi ve pulmoner sistem ile ilgili belirti/bulgusu olan hastaların hastaneye yatış ihtimallerinin diğer hastalardan daha yüksek olduğunu göstermektedir. Literatürde geriatrik hasta popülasyonunda acil servisten hastaneye yatış sınıflandırma probleminde 7 farklı model için aynı metodu kullanarak özellik etkilerini karşılaştıran başka çalışmaya rastlanmamıştır.

Tablo 4.6. Modellerde en etkili 20 özelliğin dağılımı

	LR	KNN	SVM	RF	AdaBoost	XGB	MLP
Vital Bulgular							
Nabız (Bradikardi/Taşikardi)		•		•	•		
Vücut Isısı (Hipotermi/Ateş)	•		•	•	•		•
Oksijen Saturasyonu	•	•	•	•	•	•	•
Glasgow Koma Skalası	•	•	•	•	•	•	•
Kronik Hastalıklar							
Bening Prostat Hiperplazisi		○					
Diabetes Mellitus		•					
Hematolojik Malignite	•		•	•	•	•	•
Hipertansiyon		○					
Kalp Kapak Hastalığı		○		•			
Kronik Böbrek Yetmezliği	•		•	•	•	•	•
Kronik Karaciğer Hastalığı	•		•	•	•	•	•
Malignite		•					
Psikiyatrik Hastalık						○	
Ritim Bozukluğu						•	•
Serebrovasküler Olay		•				•	
Başvuru Şikayetleri							
Anormal Laboratuvar	•		•	•	•	•	•
Ateş	•		•	•	•	•	•
Balgam	•		•				•
Baş dönmesi	○	○	○				
Bilinç Değişikliği	•	•	•	•	•	•	•
Bulantı/Kusma		•					
Dizartri/Afazi	•	•	•	•	•	•	•
Dizüri		○					
Eklemlerde Şişlik/Ağrı/Kızarıklık		○		○			
Fokal Nörolojik Defisit	•	•	•	•	•	•	•
Genel Durum Bozukluğu	•		•	•	•		•
Göğüs Ağrısı							
Hematemez	•		•	•	•	•	•
Hematokezya	•		•	•	•	•	•
İshal	○	○				○	
Karın Ağrısı		•			•		
Melena	•		•	•	•	•	•
Nefes Darlığı	•	•	•	•	•	•	•
Oral Alım Bozukluğu	•		•	•	•	•	•
Öksürük		○	○		○		○

• Modelde pozitif SHAP değerine sahip özellikler, ○ Modelde negatif SHAP değerine sahip özellikler

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Tez çalışmamızda geriatrik acil servis hastalarının hastaneye yatış öngörüsü problemine yönelik LR, KNN, SMV, RF, AdaBoost, XGB ve MLP olmak üzere 7 farklı model uygulaması yapılmıştır.

Modellerin performans metrikleri incelendiğinde en yüksek makro ortalama F1 skorları LR, SVM, AdaBoost ve MLP modellerinde elde edilmiştir (yaklaşık 0,715). En düşük makro ortalama F1 skoru ise KNN modelinde hesaplanmıştır (0,573). En yüksek doğruluk değerleri LR, SVM, AdaBoost ve MLP modellerinde elde edilmiştir (yaklaşık %72). En düşük doğruluk değeri ise KNN modelinde hesaplanmıştır (%62). Modellerin klinik olarak kullanıma sunulmaları için modellerin doğruluk değerleri için geliştirilme yolları aranmalıdır. En düşük duyarlılık değerine sahip modelin KNN (%30) ve en yüksek duyarlılık değerine sahip modellerin LR ile MLP (%63) olduğu tespit edilmiştir. En düşük özgüllük değerine sahip modelin XGB (%76,2) ve en yüksek özgüllük değerine sahip modelin KNN (%91) olduğu tespit edilmiştir. Yüksek duyarlılık/düşük özgüllük ve yüksek özgüllük/düşük duyarlılık metriklerine sahip modellerin beraber kullanımının klinik yorumları ne kadar iyileştireceği farklı metodolojiye sahip çalışmalarla değerlendirilmelidir.

Tez çalışmamızda tüm modellerin açıklanabilir ve klinik yorumlanabilir hale getirilebilmesi için model agnostik SHAP analizi yapılmıştır. Tüm modellerde ilk 20 içinde yer alan özellikler vital bulgulardan oksijen satürasyonu ve Glasgow koma skalası, başvuru şikayetlerinden bilinç değişikliği, dizartri/afazi, fokal nörolojik defisit ve nefes darlığıdır. Bu sonuçlarımız geriatrik hasta grubunda santral sinir sistemi ve pulmoner sistem ile ilgili belirti ve bulgusu olan hastaların hastaneye yatış ihtimallerinin diğer hastalardan daha yüksek olduğunu göstermektedir.

LR modeli (beyaz kutu) ile MLP modelinin (kara kutu) performans metriklerinin hemen hepsinin birbirine çok benzer olduğu görülmektedir. Bu sonuçlarımız, acil servisten hastaneye yatış öngörü problemi için görece daha basit algoritmalara sahip makine öğrenmesi modellerinin problemin çözümü için yeterince etkin olabileceğini düşündürmektedir.

5.2 Öneriler

Tez çalışmamızın tartışma bölümünde detaylandırılan bulgular, performans metrikleri ve model agnostik analiz sonuçları doğrultusunda, geriatrik acil servis hasta yönetiminde yapay zekâ tabanlı karar destek sistemlerinin geliştirilmesi ile ilgili aşağıdaki öneriler sunulmuştur:

Tez çalışmamızda kullanılan ve sadece yatak başı ilk verileri içeren modellerin duyarlılık değerlerinin %65 seviyesinin altında kalması, klinik kullanım için tek başına yeterli olmayabileceğini göstermiştir. Geriatrik hasta grubunda hastaneye yatış kararının karmaşıklığı göz önüne alındığında, gelecek çalışmalarda modellere laboratuvar tetkik sonuçları, görüntüleme tetkik sonuçları ve geriatrik kırılabilirlik skorlarının eklenmesi ile performanslarının artırılması denenebilir. Bu amaçla, birden fazla makine öğrenmesi algoritmasının birlikte kullanan hibrit modellerin kullanımı da düşünülebilir.

Tez çalışmamızda yer alan KNN modeli gibi düşük duyarlılığına karşın %90'ı aşan özgüllük düzeylerine ulaşan modeller ile yüksek duyarlılığına karşın düşük özgüllüğe sahip modellerin hastaneye yatış kararı vermek veya taburculuk kararı doğrulamak amacıyla birlikte klinik kullanımı düşünülebilir. Bu bağlamda acil servis yoğunluğunu azaltmak adına, klinisyenin taburcu etmeyi düşündüğü hastalar için yanlış taburculukları engelleyecek algoritmalar üzerine yoğunlaşılabilir.

Tez çalışmamızda beyaz kutu niteliğindeki LR modeli ile karmaşık kara kutu niteliğindeki MLP'nin benzer performans göstermesi önemli bir bulgudur. Klinik pratikte hekimlerin yapay zekâ kararlarına güven duyması için modelin neden bu kararı verdiğini anlaması esastır. Bu nedenle, işlem yükü daha hafif olan ve özellik etkileri klinik olarak yorumlanabilen makine öğrenmesi algoritmalarının klinik pratiğe entegre edilmesi acil hasta bakım kalitesini artıracaktır.

Tez çalışmamız retrospektif ve tek merkezli verilere dayanmaktadır. Geliştirilen modellerin farklı coğrafi bölgelerdeki ve farklı sosyodemografik özelliklere sahip geriatrik popülasyonlarda da geçerli olup olmadığının test edilmesi gerekmektedir. Modellerin gerçek zamanlı klinik karar üzerindeki etkisini ölçmek amacıyla prospektif ve çok merkezli çalışmaların yapılması klinisyenlerin yapay zekâ teknolojilerine güvenini artıracaktır.

6. KAYNAKLAR

- A Ilemobayo, J., Durodola, O., Alade, O., J Awotunde, O., T Olanrewaju, A., Falana, O., Ogungbire, A., Osinuga, A., Ogunbiyi, D., Ifeanyi, A., E Odezuligbo, I., ve E Edu, O. (2024). Hyperparameter Tuning in Machine Learning: A Comprehensive Review. *Journal of Engineering Research and Reports*, 26(6), 388-395. <https://doi.org/10.9734/jerr/2024/v26i61188>
- AdaBoost in Machine Learning. (2025, Kasım 14). GeeksforGeeks. <https://www.geeksforgeeks.org/machine-learning/AdaBoost-in-Machine-Learning/>
- Agius, S., Cassar, V., Magri, C., Khan, W., Obe, D. A.-J., Caruana, G., ve Topham, L. (2025). Predicting Emergency Severity Index (ESI) level, hospital admission, and admitting ward in an emergency department using data-driven machine learning. *BMC Medical Informatics and Decision Making*, 25(1), 281. <https://doi.org/10.1186/s12911-025-02941-9>
- Al Owad, A., Samaranayake, P., Karim, A., ve Ahsan, K. B. (2018). An integrated lean methodology for improving patient flow in an emergency department – case study of a Saudi Arabian hospital. *Production Planning & Control*, 29(13), 1058-1081. <https://doi.org/10.1080/09537287.2018.1511870>
- Alakare, J., Kemp, K., Strandberg, T., Castrén, M., Jakovljević, D., Tolonen, J., ve Harjola, V.-P. (2021). Systematic geriatric assessment for older patients with frailty in the emergency department: A randomised controlled trial. *BMC Geriatrics*, 21(1), 408. <https://doi.org/10.1186/s12877-021-02351-2>
- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., ve Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Bey, R., Goussault, R., Grolleau, F., Benchoufi, M., ve Porcher, R. (2020). Fold-stratified cross-validation for unbiased and privacy-preserving federated learning. *Journal of the American Medical Informatics Association: JAMIA*, 27(8), 1244-1251. <https://doi.org/10.1093/jamia/ocaa096>
- Binson, V. A., Thomas, S., Subramoniam, M., Arun, J., Naveen, S., ve Madhu, S. (2024). A Review of Machine Learning Algorithms for Biomedical Applications. *Annals of Biomedical Engineering*, 52(5), 1159-1183. <https://doi.org/10.1007/s10439-024-03459-3>
- Botteghi, N., Poel, M., ve Brune, C. (2025). Unsupervised Representation Learning in Deep Reinforcement Learning: A Review. *IEEE Control Systems*, 45(2), 26-68.

- Brink, A., Alisma, J., Brink, H. S., de Gelder, J., Lucke, J. A., Mooijaart, S. P., Zietse, R., Schuit, S. C. E., ve Lingsma, H. F. (2020). Prediction admission in the older population in the Emergency Department: The CLEARED tool. *The Netherlands Journal of Medicine*, 78(6), 357-367.
- Brink, A., Alisma, J., van Attekum, L. A., Bramer, W. M., Zietse, R., Lingsma, H., ve Schuit, S. C. (2022). Predicting in-hospital admission at the emergency department: A systematic review. *Emergency Medicine Journal: EMJ*, 39(3), 191-198. <https://doi.org/10.1136/emered-2020-210902>
- Buenrostro-Mariscal, R., Montesinos-López, O. A., ve Gonzalez-Gonzalez, C. (2025). Predicting Hospitalization in Older Adults Using Machine Learning. *Geriatrics (Basel, Switzerland)*, 10(1), 6. <https://doi.org/10.3390/geriatrics10010006>
- Bunney, G., Tran, S., Han, S., Gu, C., Wang, H., Luo, Y., ve Dresden, S. (2023). Using Machine Learning to Predict Hospital Disposition With Geriatric Emergency Department Innovation Intervention. *Annals of Emergency Medicine*, 81(3), 353-363. <https://doi.org/10.1016/j.annemergmed.2022.07.026>
- Chang, Y., Lin, Y., Huang, F., Chen, D., Chung, Y., Chen, W., ve Wang, C. (2024). Using machine learning and natural language processing in triage for prediction of clinical disposition in the emergency department. *BMC Emergency Medicine*, 24(1). <https://pubmed.ncbi.nlm.nih.gov/39695961/>
- Chen, W., Linthicum, B., Argon, N. T., Bohrmann, T., Lopiano, K., Mehrotra, A., Travers, D., ve Ziya, S. (2020). The effects of emergency department crowding on triage and hospital admission decisions. *The American Journal of Emergency Medicine*, 38(4), 774-779. <https://doi.org/10.1016/j.ajem.2019.06.039>
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., ve Campbell, J. P. (2020). Introduction to Machine Learning, Neural Networks, and Deep Learning. *Translational Vision Science & Technology*, 9(2), 14. <https://doi.org/10.1167/tvst.9.2.14>
- Cynthia, E. P., Mohamad Samuri, S. B., Li, W. S., Ismanto, E., Afriyanti, L., ve Arifandy, M. I. (2023). Improved Machine Learning Algorithm for Heart Disease Prediction Based on Hyperparameter Tuning. *2023 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET)*, 176-181. <https://ieeexplore.ieee.org/abstract/document/10291753>
- De Hond, A., Raven, W., Schinkelshoek, L., Gaakeer, M., Ter Avest, E., Sir, O., Lameijer, H., Hessels, R. A., Reijnen, R., De Jonge, E., Steyerberg, E., Nickel, C. H., ve De Groot, B. (2021). Machine learning for developing a prediction model of hospital admission of emergency department patients: Hype or hope? *International Journal of Medical Informatics*, 152, 104496.

- Doğan, F., ve Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), Article 2. <https://doi.org/10.24012/dumf.411130>
- Du, K.-L., Leung, C.-S., Mow, W. H., ve Swamy, M. N. S. (2022). Perceptron: Learning, Generalization, Model Selection, Fault Tolerance, and Role in the Deep Learning Era. *Mathematics*, 10(24), 4730. <https://doi.org/10.3390/math10244730>
- Dundar, Z. D., Ergin, M., Karamercan, M. A., Ayranci, K., Colak, T., Tuncar, A., Cander, B., ve Gul, M. (2016). Modified Early Warning Score and VitalPac Early Warning Score in geriatric patients admitted to emergency department. *European Journal of Emergency Medicine: Official Journal of the European Society for Emergency Medicine*, 23(6), 406-412.
- El Arab, R. A., ve Al Moosa, O. A. (2025). The role of AI in emergency department triage: An integrative systematic review. *Intensive & Critical Care Nursing*, 89, 104058. <https://doi.org/10.1016/j.iccn.2025.104058>
- Fenn, A., Davis, C., Buckland, D. M., Kapadia, N., Nichols, M., Gao, M., Knechtle, W., Balu, S., Sendak, M., ve Theiling, B. J. (2021). Development and Validation of Machine Learning Models to Predict Admission From Emergency Department to Inpatient and Intensive Care Units. *Annals of Emergency Medicine*, 78(2), 290-302. <https://doi.org/10.1016/j.annemergmed.2021.02.029>
- Feretzakis, G., Karlis, G., Loupelis, E., Kalles, D., Chatzikyriakou, R., Trakas, N., Karakou, E., Sakagianni, A., Tzelvels, L., Petropoulou, S., Tika, A., Dalainas, I., ve Kaldis, V. (2022). Using Machine Learning Techniques to Predict Hospital Admission at the Emergency Department. *The Journal of Critical Care Medicine*, 8(2), 107-116. <https://doi.org/10.2478/jccm-2022-0003>
- Fernandes, M., Mendes, R., Vieira, S. M., Leite, F., Palos, C., Johnson, A., Finkelstein, S., Horng, S., ve Celi, L. A. (2020). Predicting Intensive Care Unit admission among patients presenting to the emergency department using machine learning and natural language processing. *PloS One*, 15(3), e0229331.
- Fernandes, M., Vieira, S. M., Leite, F., Palos, C., Finkelstein, S., ve Sousa, J. M. C. (2020). Clinical Decision Support Systems for Triage in the Emergency Department using Intelligent Systems: A Review. *Artificial Intelligence in Medicine*, 102, 101762. <https://doi.org/10.1016/j.artmed.2019.101762>
- Frost, S. A., Ni Chroinin, D., Mc Evoy, L., Francis, N., Deane, V., Bonser, M., Wilson, C., Perkins, M., Shepherd, B., Vueti, V., Shekhar, R., Mayahi-Neysi, M., ve Hillman, K. M. (2024). Most Hospital-Acquired Complications among Older Adults Are Associated with Frailty: The South-Western Sydney Frailty and Hospital-Acquired Complications Study. *The Journal of Frailty & Aging*, 13(4), 522-528. <https://doi.org/10.14283/jfa.2024.60>

- Gan, J., Du, Z., Li, Q., Shao, H., Lin, J., Pan, Y., Wen, Z., ve Wang, S. (2024). Cost-Effective RF Fingerprinting Based on Hybrid CVNN-RF Classifier with Automated Multi-Dimensional Early-Exit Strategy (arXiv:2406.14869). *arXiv*. <http://arxiv.org/abs/2406.14869>
- Gorick, H. (2022). Factors that affect nurses' triage decisions in the emergency department: A literature review. *Emergency Nurse: The Journal of the RCN Accident and Emergency Nursing Association*, 30(3), 14-19.
- Hinson, J. S., Martinez, D. A., Cabral, S., George, K., Whalen, M., Hansoti, B., ve Levin, S. (2019). Triage Performance in Emergency Medicine: A Systematic Review. *Annals of Emergency Medicine*, 74(1), 140-152. <https://doi.org/10.1016/j.annemergmed.2018.09.022>
- Hong, W. S., Haimovich, A. D., ve Taylor, R. A. (2018). Predicting hospital admission at emergency department triage using machine learning. *PloS One*, 13(7), e0201016. <https://doi.org/10.1371/journal.pone.0201016>
- Iqbal, S., Qureshi, A. N., Aurangzeb, K., Alhussein, M., Haider, S. I., ve Rida, I. (2025). AMIAC: Adaptive medical image analyzes and classification, a robust self-learning framework. *Neural Computing and Applications*, 37(25), 20451-20479.
- Jawad, B. N., Altintas, I., Eugen-Olsen, J., Niazi, S., Mansouri, A., Rasmussen, L. J. H., Schultz, M., Iversen, K., Normann Holm, N., Kallemose, T., Andersen, O., ve Nehlin, J. O. (2024). Prospective and External Validation of Machine Learning Models for Short- and Long-Term Mortality in Acutely Admitted Patients Using Blood Tests. *Journal of Clinical Medicine*, 13(21), 6437.
- Jiang, T., Gradus, J. L., ve Rosellini, A. J. (2020). Supervised Machine Learning: A Brief Primer. *Behavior Therapy*, 51(5), 675-687.
- Kang, H., Nembhard, H. B., Rafferty, C., ve DeFlitch, C. J. (2014). Patient flow in the emergency department: A classification and analysis of admission process policies. *Annals of Emergency Medicine*, 64(4), 335-342.e8. <https://doi.org/10.1016/j.annemergmed.2014.04.011>
- Karamercan, M. A., Dündar, D. Z., Slagman, A., Ergin, M., Janssens, K. A. C., Fabbri, A., Bjornsen, L. P., Somodi, S., Adam, V. N., Polyzogopoulou, E., Demir, H. A., Laribi, S., ve Investigators, on behalf of the E. study. (2023). Epidemiology of geriatric patients presenting to emergency departments in Europe: EGERs study. *European Journal of Emergency Medicine*, 30(2), 117. <https://doi.org/10.1097/MEJ.0000000000000997>
- Kareemi, H., Vaillancourt, C., Rosenberg, H., Fournier, K., ve Yadav, K. (2021). Machine Learning Versus Usual Care for Diagnostic and Prognostic Prediction in the Emergency Department: A Systematic Review. *Academic Emergency Medicine*, 28(2). <https://doi.org/10.1111/acem.14190>

- Kishore, K., Braitberg, G., Holmes, N. E., ve Bellomo, R. (2023). Early prediction of hospital admission of emergency department patients. *Emergency Medicine Australasia: EMA*, 35(4), 572-588. <https://doi.org/10.1111/1742-6723.14169>
- K-Nearest Neighbor Algorithm. (2025, Ağustos 23). <https://www.geeksforgeeks.org/machine-learning/k-nearest-neighbours/>
- Kruse, R., Mostaghim, S., Borgelt, C., Braune, C., ve Steinbrecher, M. (2022). Multi-layer Perceptrons. R. Kruse, S. Mostaghim, C. Borgelt, C. Braune, ve M. Steinbrecher (Ed.), *Computational Intelligence: A Methodological Introduction* (ss. 53-124). Springer International Publishing.
- Küçükceran, K., Ayrancı, M. K., Dündar, Z. D., Keklik, M. İ., ve Vatansev, H. (2022). The Role of NEWS2 + Lactate + D-Dimer in Predicting Intensive Care Unit Admission and In-Hospital Mortality of COVID-19 Patients. *Journal of Acute Medicine*, 12(2), 60-70. [https://doi.org/10.6705/j.jacme.202206_12\(2\).0003](https://doi.org/10.6705/j.jacme.202206_12(2).0003)
- Lee, J.-T., Hsieh, C.-C., Lin, C.-H., Lin, Y.-J., ve Kao, C.-Y. (2021). Prediction of hospitalization using artificial intelligence for urgent patients in the emergency department. *Scientific Reports*, 11(1), 19472. <https://doi.org/10.1038/s41598-021-98961-2>
- Logistic Regression in Machine Learning. (2025, Ağustos 2). GeeksforGeeks. <https://www.geeksforgeeks.org/machine-learning/understanding-logistic-regression/>
- Lucke, J. A., de Gelder, J., Clarijs, F., Heringhaus, C., de Craen, A. J. M., Fogteloo, A. J., Blauw, G. J., Groot, B. de, ve Mooijaart, S. P. (2018). Early prediction of hospital admission for emergency department patients: A comparison between patients younger or older than 70 years. *Emergency Medicine Journal: EMJ*, 35(1), 18-27. <https://doi.org/10.1136/emered-2016-205846>
- Lucke, J. A., Mooijaart, S. P., Heeren, P., Singler, K., McNamara, R., Gilbert, T., Nickel, C. H., Castejon, S., Mitchell, A., Mezera, V., Van der Linden, L., Lim, S. E., Thaur, A., Karamercan, M. A., Blomaard, L. C., Dündar, Z. D., Chueng, K. Y., Islam, F., de Groot, B., ve Conroy, S. (2022). Providing care for older adults in the Emergency Department: Expert clinical recommendations from the European Task Force on Geriatric Emergency Medicine. *European Geriatric Medicine*, 13(2), 309-317. <https://doi.org/10.1007/s41999-021-00578-1>
- Luo, Y., Wang, Z., ve Wang, C. (2021). Improvement of APACHE II score system for disease severity based on XGBoost algorithm. *BMC Medical Informatics and Decision Making*, 21(1), 237. <https://doi.org/10.1186/s12911-021-01591-x>
- Meisenbacher, S., Turowski, M., Phipps, K., Rätz, M., Müller, D., Hagenmeyer, V., ve Mikut, R. (2022). Review of automated time series forecasting pipelines. *WIREs Data Mining and Knowledge Discovery*, 12(6), e1475.

- Michalski-Monnerat, C., Carron, P.-N., Nguyen, S., Büla, C., ve Mabire, C. (2020). Assessing Older Patients' Vulnerability in the Emergency Department: A Study of InterRAI ED Screener Accuracy. *Journal of the American Geriatrics Society*, 68(12), 2914-2920. <https://doi.org/10.1111/jgs.16829>
- Mienye, I. D., ve Swart, T. G. (2024). A Comprehensive Review of Deep Learning: Architectures, *Recent Advances, and Applications*. *Information*, 15(12), 755. <https://doi.org/10.3390/info15120755>
- Mitsunaga, T., Hasegawa, I., Uzura, M., Okuno, K., Otani, K., Ohtaki, Y., Sekine, A., ve Takeda, S. (2019). Comparison of the National Early Warning Score (NEWS) and the Modified Early Warning Score (MEWS) for predicting admission and in-hospital mortality in elderly patients in the pre-hospital setting and in the emergency department. *PeerJ*, 7, e6947.
- Mowbray, F., Zargoush, M., Jones, A., de Wit, K., ve Costa, A. (2020). Predicting hospital admission for older emergency department patients: Insights from machine learning. *International Journal of Medical Informatics*, 140, 104163. <https://doi.org/10.1016/j.ijmedinf.2020.104163>
- Naouri, D., Pelletier-Fleury, N., Lapidus, N., ve Yordanov, Y. (2022). The effect of direct admission to acute geriatric units compared to admission after an emergency department visit on length of stay, postacute care transfers and ED return visits. *BMC Geriatrics*, 22(1), 555. <https://doi.org/10.1186/s12877-022-03241-x>
- Nassisi, D. (2023). Care of the Geriatric Patient. R. Walls, R. Hockberger, M. Gausche-Hill, T.B. Erickson ve S.R. Wilcox (Eds). *Rosen's Emergency Medicine: Concepts and Clinical Practice (10th ed)* (ss. 2318-2324). Elsevier.
- Nohara, Y., Matsumoto, K., Soejima, H., ve Nakashima, N. (2022). Explanation of machine learning models using shapley additive explanation and application for real data in hospital. *Computer Methods and Programs in Biomedicine*, 214, 106584. <https://doi.org/10.1016/j.cmpb.2021.106584>
- Oztornaci, B., Ata, B., ve Kartal, S. (2024). Analysing Household Food Consumption in Turkey Using Machine Learning Techniques. *Agris On-Line Papers in Economics and Informatics*, 2(June), 97-105.
- Patel, D., Cheetirala, S. N., Raut, G., Tamegue, J., Kia, A., Glicksberg, B., Freeman, R., Levin, M. A., Timsina, P., ve Klang, E. (2022). Predicting Adult Hospital Admission from Emergency Department Using Machine Learning: An Inclusive Gradient Boosting Model. *Journal of Clinical Medicine*, 11(23), 6888.
- Pazan, F., ve Wehling, M. (2021). Polypharmacy in older adults: A narrative review of definitions, epidemiology and consequences. *European Geriatric Medicine*, 12(3), 443-452. <https://doi.org/10.1007/s41999-021-00479-3>

- Piliuk, K., ve Tomforde, S. (2023). Artificial intelligence in emergency medicine. A systematic literature review. *International Journal of Medical Informatics*, 180, 105274. <https://doi.org/10.1016/j.ijmedinf.2023.105274>
- Ponce-Bobadilla, A. V., Schmitt, V., Maier, C. S., Mensing, S., ve Stodtmann, S. (2024). Practical guide to SHAP analysis: Explaining supervised machine learning model predictions in drug development. *Clinical and Translational Science*, 17(11), e70056. <https://doi.org/10.1111/cts.70056>
- PyCaret 3.0. (2023, Mart 19). <https://pycaret.gitbook.io/docs>
- Rainio, O., Teuho, J., ve Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1), 6086. <https://doi.org/10.1038/s41598-024-56706-x>
- Raita, Y., Goto, T., Faridi, M. K., Brown, D. F. M., Camargo, C. A., ve Hasegawa, K. (2019). Emergency department triage prediction of clinical outcomes using machine learning models. *Critical Care (London, England)*, 23(1), 64. <https://doi.org/10.1186/s13054-019-2351-7>
- Rajula, H. S. R., Verlato, G., Manchia, M., Antonucci, N., ve Fanos, V. (2020). Comparison of Conventional Statistical Methods with Machine Learning in Medicine: Diagnosis, Drug Development, and Treatment. *Medicina*, 56(9), 455.
- Random Forest Algorithm in Machine Learning. (2025, Ekim 31). GeeksforGeeks. <https://www.geeksforgeeks.org/machine-learning/random-forest-algorithm-in-machine-learning/>
- Rashidi, H. H., Tran, N. K., Betts, E. V., Howell, L. P., ve Green, R. (2019). Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods. *Academic Pathology*, 6, 2374289519873088.
- Reddy, S. N., ve Kumar, S. (2023). A Comparative Analysis of XGBoost Model and AdaBoost Regressor for Prediction of Used Car Price. *Proceedings of the 1st International Conference on Artificial Intelligence for Internet of Things: (AI4IoT 2023)*, 441-446. <http://www.scitepress.org/Papers/2023/125107>
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206-215. <https://doi.org/10.1038/s42256-019-0048-x>
- Samadbeik, M., Staib, A., Boyle, J., Khanna, S., Bosley, E., Bodnar, D., Lind, J., Austin, J. A., Tanner, S., Meshkat, Y., de Courten, B., ve Sullivan, C. (2024). Patient flow in emergency departments: A comprehensive umbrella review of solutions and challenges across the health system. *BMC Health Services Research*, 24(1), 274. <https://doi.org/10.1186/s12913-024-10725-6>

- Sankaran, R., Gulseren, B., Nuliyalu, U., Dimick, J. B., Sheetz, K., Arntson, E., Chhabra, K., ve Ryan, A. M. (2020). A comparison of estimated cost savings from potential reductions in hospital-acquired conditions to levied penalties under the CMS Hospital Acquired Conditions Reduction Program. *Joint Commission Journal on Quality and Patient Safety*, 46(8), 438-447.
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>
- Schultz, M., Rasmussen, L. J. H., Carlson, N., Hasselbalch, R. B., Jensen, B. N., Usinger, L., Eugen-Olsen, J., Torp-Pedersen, C., Rasmussen, L. S., ve Iversen, K. K. (2019). Risk assessment models for potential use in the emergency department have lower predictive ability in older patients compared to the middle-aged for short-term mortality—A retrospective cohort study. *BMC Geriatrics*, 19(1), 134. <https://doi.org/10.1186/s12877-019-1154-7>
- Scikit-learn: Machine learning in Python. (2025). <https://scikit-learn.org/stable/>
- Söyük, S., ve Kurtuluş, S. A. (2017). Acil Servislerde Yaşanan Sorunların Çalışanlar Gözünden Değerlendirilmesi. *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi*, 6(4), Article 4.
- Support Vector Machine Algorithm. (2025, Kasım 13). GeeksforGeeks. <https://www.geeksforgeeks.org/machine-learning/support-vector-machine-algorithm/>
- Tan, T., Hsu, C., Chen, C., Hsu, S., Liu, T., Lin, H., Wang, J., Liu, C., ve Huang, C. (2021). Predicting outcomes in older ED patients with influenza in real time using a big data-driven and machine learning approach to the hospital information system. *BMC Geriatrics*, 21(1). <https://doi.org/10.1186/s12877-021-02229-3>
- Taylor, A., Broadbent, M., Wallis, M., ve Marsden, E. (2019). The predictive validity of the interRAI ED screener for predicting re-presentation within 28 days for older adults at a regional hospital emergency department. *Australasian Emergency Care*, 22(3), 149-155. <https://doi.org/10.1016/j.auec.2019.04.005>
- T.C. Sağlık Bakanlığı. (2022). Yataklı Sağlık Tesislerinde Acil Servis Hizmetlerinin Uygulama Usul ve Esasları Hakkında Tebliğ. <https://www.resmigazete.gov.tr/eskiler/2022/09/20220913-5.htm>
- Tschoellitsch, T., Seidl, P., Böck, C., Maletzky, A., Moser, P., Thumfart, S., Giretzlehner, M., Hochreiter, S., ve Meier, J. (2023). Using emergency department triage for machine learning-based admission and mortality prediction. *European Journal of Emergency Medicine*, 30(6), 408-416. <https://doi.org/10.1097/MEJ.0000000000001068>

- Tufail, S., Riggs, H., Tariq, M., ve Sarwat, A. I. (2023). Advancements and Challenges in Machine Learning: A Comprehensive Review of Models, Libraries, Applications, and Algorithms. *Electronics*, 12(8), 1789.
- Usman, O. A., Usman, A. A., ve Ward, M. A. (2019). Comparison of SIRS, qSOFA, and NEWS for the early identification of sepsis in the Emergency Department. *The American Journal of Emergency Medicine*, 37(8), 1490-1497. <https://doi.org/10.1016/j.ajem.2018.10.058>
- Wang, H., Kang, X., Shi, Y., Bai, Z.-H., Lv, J.-H., Sun, J.-L., ve Pei, H. H. (2020). SOFA score is superior to APACHE-II score in predicting the prognosis of critically ill patients with acute kidney injury undergoing continuous renal replacement therapy. *Renal Failure*, 42(1), 638-645.
- Welcome to Python. (2025). Python.Org. <https://www.python.org/about/>
- XGBoost. (2025, Ekim 24). GeeksforGeeks. <https://www.geeksforgeeks.org/machine-learning/xgboost/>
- Xiao, Y., Zhang, J., Chi, C., Ma, Y., ve Song, A. (2023). Criticality and clinical department prediction of ED patients using machine learning based on heterogeneous medical data. *Computers in Biology and Medicine*, 165, 107390. <https://doi.org/10.1016/j.compbiomed.2023.107390>
- Yapıcı, M. E., Hızıroğlu, A., ve Erdoğan, A. M. (2024). Comparing the Performance of Ensemble Methods in Predicting Emergency Department Admissions Using Machine Learning Techniques. *Artificial Intelligence Theory and Application*, 4(1), 11-21.
- Zachariasse, J. M., van der Hagen, V., Seiger, N., Mackway-Jones, K., van Veen, M., ve Moll, H. A. (2019). Performance of triage systems in emergency care: A systematic review and meta-analysis. *BMJ Open*, 9(5), e026471. <https://doi.org/10.1136/bmjopen-2018-026471>
- Zahid, M., Khan, A. A., Ata, F., Yousaf, Z., Naushad, V. A., Purayil, N. K., Chandra, P., Singh, R., Kartha, A. B., Elzouki, A. Y. A., Al Mohanadi, D. H. S. H., ve Al-Mohammed, A. A. A. A. (2023). Medical Admission Prediction Score (MAPS); a simple tool to predict medical admissions in the emergency department. *PloS One*, 18(11), e0293140. <https://doi.org/10.1371/journal.pone.0293140>
- Zelege, A. J., Palumbo, P., Tubertini, P., Miglio, R., ve Chiari, L. (2023). Machine learning-based prediction of hospital prolonged length of stay admission at emergency department: A Gradient Boosting algorithm analysis. *Frontiers in Artificial Intelligence*, 6. <https://doi.org/10.3389/frai.2023.1179226>
- Zhang, X., Wang, H., Yu, G., ve Zhang, W. (2025). Machine learning-driven prediction of hospital admissions using gradient boosting and GPT-2. *Digital Health*, 11.

EKLER**EK-1 Etik kurul onayı**

T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ
İLAÇ VE TIBBİ CİHAZ DIŞI ARAŞTIRMALAR ETİK KURUL KARARI

Toplantı Sayısı: 215

Toplantı Tarihi: 07 Mart 2025

Karar Sayısı:2025/5612:(Başvuru ID: 23751) Necmettin Erbakan Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği Bölümünden Doç. Dr. Kemal ÇETİN'in "Makine Öğrenmesi ve Derin Öğrenme Modelleri ile Geriatrik Acil Servis Hastalarında Hastaneye Yatış Öngörüsü" başlıklı yüksek lisans tez çalışması ile ilgili dilekçesi ve ekleri görüşüldü. Öğrencisi Zerrin Defne DÜNDAR'ın yüksek lisans tez çalışmasının Necmettin Erbakan Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği Bölümünden Doç. Dr. Kemal ÇETİN'in sorumluluğunda yürütülmesinin uygun olduğuna oybirliği ile karar verilmiştir.

Not: Çalışma ile ilgili gerekli izinlerin alınması ve yasal sorumluluk araştırmacılara aittir.

Sorumlu Araştırmacı: Doç. Dr. Kemal ÇETİN

Yardımcı Araştırmacılar: Yüksek Lisans Öğrencisi Zerrin Defne DÜNDAR, Doç. Dr. Hüseyin HAKLI, Mehmet ÖNEMLİ

ASLI GIBİDİR
07.03.2025

Prof. Dr. Ayşe Saide ŞAHİN
İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurul Başkanı

EK-2 Necmettin Erbakan Üniversitesi Tıp Fakültesi Hastanesi Başhekimlik Onayı

	T.C. NECMETTİN ERBAKAN ÜNİVERSİTESİ REKTÖRLÜĞÜ Tıp Fakültesi Hastanesi Başhekimliği	 2025 AİLE YILI
Sayı : E-14567952-900-658503 Konu : Tez Çalışması Hakkında		25.03.2025
Sayın Prof.Dr. Zerrin Defne DÜNDAR		
İlgi : 24.03.2025 tarihli dilekçeniz. İlgi tarihli dilekçenize istinaden, "Makine Öğrenmesi ve Derin Öğrenme Modelleri ile Geriatrik Acil Servis Hastalarında Hastane Yatış Öngörüsü" başlıklı yüksek lisans tez çalışmanızda kullanmak üzere hasta verilerine erişim sağlamanız uygun görülmüştür. Bilgilerinize rica ederim.		
e-imzalıdır Doç. Dr. Hasan KÜÇÜKKENDİRCİ Başhekim		
Bu belge, güvenli elektronik imza ile imzalanmıştır		
Belge Doğrulama Kodu : 8Z1K-76HI-0IVY		Belge Doğrulama Adresi : https://www.turkiye.gov.tr/necmettin-erbakan-ebys
Adres: Hocaiah Mahallesi Sultan Abdülhamit Han Caddesi No:3 Selçuklu/ Konya Telefon No : 0332 223 60 01		Bilgi İçin :Pınar Abalı Sekreter
e-Posta : Internet Adresi : http://www.erbakan.edu.tr		Telefon No:0332 223 60 01
		