



**T.C.
ÇUKUROVA ÜNİVERSİTESİ
TIP FAKÜLTESİ
GÖĞÜS CERRAHİSİ ANABİLİM DALI**

**KÜÇÜK HÜCRELİ DIŞI AKCİĞER KANSERİ TANILI
AKCİĞER REZEKSİYONU YAPILAN HASTALARIN
YAPAY ZEKA İLE POSTOPERATİF BAŞARI VE RİSK
ANALİZİ**

Dr. Çağlayan Atakan BİLGİN

UZMANLIK TEZİ

**TEZ DANIŞMANI
Dr. Öğr. Üye İsmail Can KARACAOĞLU**

ADANA-2025



**T.C.
ÇUKUROVA ÜNİVERSİTESİ
TIP FAKÜLTESİ
GÖĞÜS CERRAHİSİ ANABİLİM DALI**

**KÜÇÜK HÜCRELİ DIŞI AKCİĞER KANSERİ TANILI
AKCİĞER REZEKSİYONU YAPILAN HASTALARIN
YAPAY ZEKA İLE POSTOPERATİF BAŞARI VE RİSK
ANALİZİ**

Dr. Çağlayan Atakan BİLGİN

UZMANLIK TEZİ

**TEZ DANIŞMANI
Dr. Öğr. Üye İsmail Can KARACAOĞLU**

ADANA-2025

TEŞEKKÜR

Teşekkürlerime hayatımda hiçbir zaman bana olan güvenlerinden ve sevgilerinden şüphe duymadığım, desteklerine ve fedakarlıklarına olan borcumu ödeyemeyeceğim Sevgili annem Kamer BİLGİN'e ve Saygıdeğer babam Fikri BİLGİN'e,

Sevgisi ile kalbime, güzel yüzü ile gönlüme ışık saçan, birlikte yürüdüğümüz yollarda çiçekler açtıran pek kıymetli eşim İrem BİLGİN'e,

Sonsuz merhameti ve sevgisi ile beni her alanda gururlandıran, başımın tatlı belası sevgili kardeşim İrem BİLGİN'e,

Çukurova Üniversitesi Göğüs Cerrahisi Anabilim dalındaki zorlu ihtisas eğitimim süresince yardımlarını, fedakarlıklarını, hocalığını, abiliğini ve dostluğunu unutamayacağım, hoşgörüsünü ve desteğini eksik etmeyen, tez hazırlık sürecim boyunca bana destek ve cesaret veren, yol gösteren sayın Dr. Öğr. Üye. İsmail Can KARACAOĞLU'na,

Desteğinin ve dik duruşunun bir an olsun eksikliğini hissetmediğim, cerrahi ve hekimlik tecrübelerinden faydalandığım, eğitimimde sonsuz katkıları olan çok kıymetli hocam sayın Prof. Dr. Cemal ÖZÇELİK'e,

Bilgisinin ve tecrübesinin ışığında aydınlık yollarda yürüdüğüm, cerrahi ve hekimlik tecrübelerinden faydalandığım, eğitimimde sonsuz katkıları olan, anabilim dalı başkanımız hocam sayın Prof. Dr. Suat GEZER'e,

Cerrahi perspektifimi ve becerilerimi bir adım ileri taşımama verdiği destek ve önemi unutamayacağım, hocalığı kadar abiliği de çok kıymetli olan sayın hocam Doç. Dr. Alper AVCI'ya

Kendileri ile çalışmaktan kıvanç duyduğum Göğüs Cerrahi kliniğimizdeki tüm doktor, hemşire, personel ve sekreter arkadaşlarıma,

Tez sürecimde desteklerini esirgemeyen mühendis arkadaşlarıma,

Ve son olarak: hayata daha güzel bakmamı sağlayan, babasının prensesi kızım Umay BİLGİN'e teşekkürlerimi sunarım.

Dr. Çağlayan Atakan BİLGİN

İÇİNDEKİLER

Sayfa No:

TEŞEKKÜR	i
İÇİNDEKİLER	ii
TABLolar LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
SİMGE ve KISALTMALAR	vi
ÖZET	viii
ABSTRACT	ix
1. GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER	3
2.1. Akciğer Kanseri	3
2.2. Akciğer Kanseri Epidemiyolojisi	3
2.3. Akciğer Kanseri Etiyolojisi	3
2.4. Akciğer Kanserin Histopatolojik Sınıflandırılması	4
2.5. Küçük Hücre Dışı Akciğer Kanseri (KHDAK)	6
2.6. Küçük Hücreli Dışı Akciğer Kanseri Evreleme	8
2.7. Küçük Hücreli Dışı Akciğer Kanseri Tedavi	11
3. KÜÇÜK HÜCRELİ DIŞI AKCİĞER KANSERİ CERRAHİSİ SONRASI PULMONER KOMPLİKASYONLAR, YOĞUN BAKIM GEREKSİNİMİ VE HASTANEDE KALIŞ SÜRECİ	13
3.1. Postoperatif Pulmoner Komplikasyonlar	13
3.2. Ameliyat Sonrası Yoğun bakım Yatışı ve Yoğun Bakım Yatışı Gerekliliğinin Değerlendirilmesi	14
4. DERİN ÖĞRENME VE YAPAY ZEKA ALGORİTMALARI	15
4.1. Lineer Regresyon	16
4.2. Radial Basis Fonksiyonu	16
4.3. Random Forest (RF)	16
4.4. Synthetic Minority Over-Sampling Technique (SMOTE)	16
4.5. Support Vector Machine (SVM)	17
4.6. Yapay Zeka İşleme Biçimleri ve Dengesiz Verisetleri	17

5. GEREÇ VE YÖNTEM	20
6. BULGULAR	22
6.1. Yapay Zeka Uygulamaları ile Postoperatif Yoğun Bakım Yatış Gereksinimi Tahmini.....	25
6.2. Lineer Kernel-SVM Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)	26
6.3. Lineer Regresyon Yöntemi Tahmin Sonuçları (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)	30
6.4. Radial Basis SVM Korele Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)	31
6.5. Random Forest Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)	33
6.6. Lineer Kernel SVM ve SMOTE Korele Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)	36
6.7. SMOTE Sonrası Random FOREST Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)	39
7. TARTIŞMA	42
8. SONUÇ VE ÖNERİLER	47
KAYNAKÇA	48

TABLÖLAR LİSTESİ

<u>Tablo No</u>	<u>Sayfa No</u>
Tablo 1. Dünya Sağlık Örgütü akciğer kanseri histopatolojik sınıflandırması	5
Tablo 2. Küçük hücre dışı akciğer karsinomlarının sınıflandırması	7
Tablo 3. TNM evrelemesi T faktörü.....	9
Tablo 4. TNM evrelemesi N faktörü	10
Tablo 5. TNM evrelemesi M faktörü.....	10
Tablo 6. TNM Evrelerinin Sınıflandırılması	11
Tablo 7. Demografik Veriler.....	22
Tablo 8. Hastalara ait solunum parametreleri verileri	23
Tablo 9. SVM-Linear Kernel Yöntemi için sınıflandırma parametreleri sonucu	27
Tablo 10. Lineer Regresyon Yöntemi için sınıflandırma parametreleri sonucu	30
Tablo 11. Radial Basis SVM Korele Yöntemi için sınıflandırma parametreleri sonucu	31
Tablo 12. Random Forest Yöntemi için sınıflandırma parametreleri sonucu	33
Tablo 13. Lineer Kernal SVM ve SMOTE korele yöntemi için sınıflandırma parametreleri sonucu	36
Tablo 14. SMOTE Sonrası Random FOREST yöntemi için sınıflandırma parametreleri sonucu.....	39

ŞEKİLLER LİSTESİ

Şekil No	Sayfa No
Şekil 1. Giriş parametreleri, çıkış parametreleri, makine öğrenme modeli.....	25
Şekil 2. Çıkan sonuçlar	26
Şekil 3. Accuary (Doğruluk) hesaplanmasının formülü.....	26
Şekil 4. Veri seti ile eğitilmiş Lineer Kernal-SVM yöntemli Yoğun Bakım Tahmini için Confussion Matriksi.....	27
Şekil 5. Lineer Kernal-SVM yöntemi için Receiver Operating Characteristic Curve (ROC) eğrisi.	28
Şekil 6. Lineer Kernal-SVM için karar ilişkili yoğunlaşma sonuç şekli	28
Şekil 7. Lineer Kernal-SVM için Eigen vektör ısı haritası	29
Şekil 8. Veri seti ile eğitilmiş Lineer Regresyon yöntemli Yoğun Bakım Tahmini için Confussion Matriksi.....	30
Şekil 9. Veri seti ile eğitilmiş Lineer Regresyon yöntemli Yoğun Bakım Tahmini için Eğri Altında kalan alan grafiği	31
Şekil 10. Veri seti ile eğitilmiş Radial Basis SVM Korele yöntemli Yoğun Bakım Tahmini için Confussion Matriksi.....	32
Şekil 11. Veri seti ile eğitilmiş Radial Basis SVM Korele yöntemli Yoğun Bakım Tahmini için Eğri Altında kalan alan grafiği.....	32
Şekil 12. Radial Basis SVM Korele karar ilişkili yoğunlaşma sonuç şekli.....	33
Şekil 13. Veri seti ile eğitilmiş Random Forest yöntemli Yoğun Bakım Tahmini için Confussion Matriksi.....	34
Şekil 14. Random Forest Yöntemi için ROC eğrisi	35
Şekil 15. Random Forest yöntemi için girdi parametrelerin ağırlıkları	35
Şekil 16. Random Forest yöntemi için girdi parametrelerin sonuca etki ağırlıkları.....	36
Şekil 17. Lineer Kernal SVM ve SMOTE korele yöntemi için Confussion Matriksi	37
Şekil 18. Lineer Kernal SVM ve SMOTE korele yöntemi için ROC eğrisi.....	37
Şekil 19. Lineer Kernal SVM ve SMOTE korele karar ilişkili yoğunlaşma sonuç şekli.	38
Şekil 20. Lineer Kernal SVM ve SMOTE Korele Eigen vektör ısı haritası.....	38
Şekil 21. Veri seti ile eğitilmiş SMOTE Sonrası Random FOREST Yöntemi Yoğun Bakım Tahmini için Confussion Matriksi.....	39
Şekil 22. SMOTE Sonrası Random FOREST yöntemi için ROC eğrisi.....	40
Şekil 23. SMOTE Sonrası Random FOREST yöntemi için girdi parametrelerin ağırlıkları.....	40
Şekil 24. SMOTE Sonrası Random FOREST yöntemi için girdi parametrelerin sonuca etki ağırlıkları.....	41

SİMGE ve KISALTMALAR

AI	: Artificial Intelligence- Yapay Zeka
AIDS	: Kazanılmış Bağışıklık Yetersizliği Sendromu
AJCC	: Amerikan Kanser Ortak Komitesi
BT	: Bilgisayarlı Tomografi
BPF	: Bronkoplevral Fistül
CCI	: Charlson Komorbidite İndeksi
CGM	: Conjugate Gradient Method -Eşlenik Eğitim
DL	: Deep Learning- Derin Öğrenme
DLCO	: Karbonmonoksit Difüzyon Kapasitesi
DLCO/VA	: Alveolar Volümün Her Ünitesi İçin Difüzyon Kapasitesi
DT	: Decision Tree- Karar Ağaçları
DSÖ	: Dünya Sağlık Örgütü
ERAS	: Enhanced Recovery After Surgery- İyileştirilmiş Cerrahi Sonrası Bakım
FEV1	: 1. Saniyedeki Zorlu Ekspiratuar Hacim
FEV1/FVC	: 1. saniyedeki zorlu ekspiratuar hacmin zorlu vital kapasiteye oranı
FVC	: Zorlu Vital Kapasite
IASLC	: International Association for the Study of Lung Cancer
KHDAK	: Küçük Hücreli Dışı Akciğer Kanseri
KNN	: K-Nearest Neighbors – K- (En Yakın Komşular)
KOAH	: Kronik Obstrüktif Akciğer Hastalığı
KT	: Kemoterapi
LM	: Levenberg-Marquardt Algoritması LND: Lenf Nodu Diseksiyonu
ML	: Machine Learning- Makine Öğrenmesi
PET	: Pozitron Emisyon Tomografi
PNET	: Küçük Mavi Yuvarlak Hücreli Tümör
RATS	: Robot Yardımlı Göğüs Cerrahisi
RF	: Random Forest- Rastgele Orman
RL	: Reinforcement Learning – Destekli Öğrenme
RNN	: Recurrent Neural Network- Rekürren Nöral Ağ

ROC Eğrisi	: Receiver Operating Characteristic Curve – Doğru Pozitif Oran ve Yanlış Pozitif Oran Grafiği
RT	: Radyoterapi
SBRT	: Stereotaktik Vücut Radyasyon Tedavisi
SMOTE	: Synthetic Minority Over-Sampling Technique
SCG	: Scaled Conjugate Gradient – Ölçeklendirilmiş Eşlenik Gradyan
SL	: Supervised Learning – Denetimli Öğrenme
SUV max	: Standartized Uptake Volume (PET/BT'de maksimum tutulum değeri)
SVM	: Support Vector Machine – Destek Vektör Makinesi
TNM	: Tümör Özelliği, Lenf Nodu Özelliği, Uzak Metastaz Özelliğinin İfade edildiği Evreleme İfadesi
UL	: Unsupervised Learning – Denetimsiz Öğrenme
VATS	: Video Yardımlı Göğüs Cerrahisi
YZ	: Yapay Zeka

ÖZET

Küçük Hücreli Dışı Akciğer Kanseri Tanılı Akciğer Rezeksiyonu Yapılan Hastaların Yapay Zeka İle Postoperatif Başarı Ve Risk Analizi

Her cerrahi branş gibi göğüs cerrahisi branşı da ameliyat öncesinde ince elenip sık dokunan hazırlıklarla dolu risk analizleri, ameliyat esnasında ciddi bir emek ve konsantrasyon, ameliyat sonrası her adımın dikkatle takip edilmesi gereken doğru kararlar verme bütünüdür. Küçük hücreli dışı akciğer kanseri (KHDAK) histopatolojik tip olarak akciğer kanserleri içinde en sık görülenidir. Çalışmamız bu süreçler içinde ameliyat sonrası aşamalar başta olmak üzere tüm adımlarda hastalara ve hekimlere yardımcı olmayı hedeflemektedir. 9. TNM evreleme sistemi günümüzde IASLC tarafından önerilen ve kullanılan evreleme sistemidir. Erken evre ve rezektabl lokal ileri evre KHDAK grubunda cerrahi tedavi etkindir. Akciğer rezeksiyonu ve sistematik mediastinal lenf nodu diseksiyonu KHDAK cerrahisinin temelini oluşturur. Ameliyat sonrası dönemde görülen komplikasyonlar, ileri tedavi ve bakım gerektiren yoğun bakım yatışlarının olması, hastanede kalış süresinin uzaması başta mortalite, morbidite, maliyet, hastane enfeksiyonları, sürdürülebilirlik ve sosyal etkenler açısından önem arz etmektedir. Bu aşamalarda yoğun bakım gerekliliğinin değerlendirilmesi konusunda objektif, düşük maliyetli, kolay kullanımı olan, kendini geliştirebilen, günlük pratiğe uyarlanabilir, hasta özelinde çalışan ve doğruluk oranı yüksek şekilde sonuç veren bir uygulama ya da değerlendirme ölçütü bulunmamaktadır. Yapay zeka uygulamaları hekimliğe yardımcı alanlar, sağlık sistemlerinde ve diğer alanlarda veri toplama, sınıflandırma, saklama, öğrenme, öğretme gibi özellikleri ile karar vermeye yardımcı algoritmalar olarak hayatımızda yer bulmaktadır.

Çalışmamızda KHDAK sebebiyle opere edilen hastalarda post op süreçleri elimizdeki veriler ile tahmin etmeyi amaçladık. Çalışmamızda 1471 hastanın verileri retrospektif olarak incelenerek geniş veri setleri oluşturuldu. 6 adet farklı yapay zeka algoritması kullanılarak hastalara ait 14 parametre ile hastaların postoperatif klinik süreçleri ve yoğun bakıma çıkıp çıkmayacakları yüksek doğruluk ve başarı oranı ile tahmin edilmesi amaçlandı. Bu algoritmalar: SVM-Linear Kernel, Random Forest sınıflandırma, SMOTE Sonrası SVM-Linear Kernel, SMOTE Sonrası Random Forest sınıflandırma, Lineer Regresyon ve Radial Basis SVM Korele Yöntemi idi.

Yoğun bakıma çıkacak hastaları tahmin etmede en başarılı algoritmamız SMOTE Sonrası Random Forest sınıflandırma oldu ve F1 ortalama skoru %91, yoğun bakıma çıkmayacak hastaları tahmin etmede en başarılı algoritmamız SMOTE Sonrası Random Forest sınıflandırma oldu ve F1 ortalama skoru %91 olarak hesaplandı. SMOTE Sonrası Random Forest sınıflandırma yöntemi için ortalama çapraz doğrulama puanı 0.9232, çapraz doğrulama puanının standart sapması ise 0.0165 olarak hesaplandı. En başarılı algoritmamızda ROC eğrisinde eğri altında kalan alan %86 idi.

Yapay zeka algoritmaları sayesinde KHDAK cerrahisi sonrası postoperatif klinik tahminler, yüksek doğruluk ve başarı oranlarıyla gerçekleştirilebilmekte olup, gelecekte klinik pratikte daha yaygın bir şekilde kullanılması beklenmektedir.

Anahtar Sözcükler: Küçük Hücreli Dışı Akciğer Karsinomu, NSCLC, Postoperatif Komplikasyon, Yoğun Bakım Ünitesi, Yoğun bakım, Yapay Zeka, SMOTE, Lineer Regresyon, SVM, Support Vector Machine, Lineer Kernal, Radial Basis, Random Forest, Göğüs cerrahisi.

ABSTRACT

Postoperative Success and Risk Analysis of Patients with Non-Small Cell Lung Cancer Undergoing Lung Resection Using Artificial Intelligence

Thoracic surgery is a comprehensive process that involves meticulous preoperative preparations filled with detailed risk analyses, significant effort and concentration during the operation, and careful postoperative follow-up requiring precise decision-making at every step. Non-small cell lung cancer (NSCLC) is the most common histopathological type among lung cancers. Our study aims to assist both patients and physicians throughout these processes, with a particular focus on the postoperative stages. The 9th edition of the TNM staging system, currently recommended and used by the IASLC, is the standard for staging. Surgical treatment is effective in early-stage and resectable locally advanced NSCLC. Lung resection and systematic mediastinal lymph node dissection form the foundation of NSCLC surgery. Postoperative complications, the need for intensive care requiring advanced treatment and care, and prolonged hospital stays are critical factors that impact mortality, morbidity, cost, hospital-acquired infections, sustainability, and social factors. Currently, there is no objective, low-cost, easy-to-use, self-improving, and highly accurate evaluation tool or application tailored to individual patients that can predict the necessity of intensive care during these stages. Artificial intelligence (AI) applications are increasingly integrated into healthcare systems and other fields, aiding decision-making through data collection, classification, storage, learning, and teaching capabilities. In our study, we aimed to predict postoperative processes in patients undergoing surgery for NSCLC using available data.

We retrospectively analyzed data from 1,471 patients to create extensive datasets. Using six different AI algorithms, we predicted postoperative clinical outcomes and the need for intensive care with high accuracy and success rates based on 14 patient-specific parameters. The algorithms used were: SVM-Linear Kernel, Random Forest Classification SVM-Linear Kernel with SMOTE, Random Forest Classification with SMOTE, Linear Regression, Radial Basis SVM Correlation Method.

The most successful algorithm for predicting patients requiring intensive care was Random Forest Classification with SMOTE, achieving an F1 score of 91%. The same algorithm also excelled in predicting patients not requiring intensive care, with an F1 score of 91%. For this method, the average cross-validation score was 0.9232, with a standard deviation of 0.0165. The area under the ROC curve for the most successful algorithm was 86%.

Thanks to AI algorithms, postoperative clinical predictions for NSCLC surgery can now be made with high accuracy and success rates, and their widespread use in clinical practice is anticipated in the future.

Keywords: Non-Small Cell Lung Cancer, NSCLC, Postoperative Complications, Intensive Care Unit, Intensive Care, Artificial Intelligence, SMOTE, Linear Regression, SVM, Support Vector Machine, Linear Kernel, Radial Basis, Random Forest, Thoracic Surgery

1. GİRİŞ VE AMAÇ

Akciğer kanseri, dünya çapında en yaygın görülen ve en yüksek ölüm oranına sahip kanser türlerinden biridir. Hem gelişmiş hem de gelişmekte olan ülkelerde önemli bir sağlık sorunu olan bu hastalık, özellikle sigara kullanımı ve çevresel maruziyet gibi faktörlerle ilişkilendirilmiştir.¹

Dünya Sağlık Örgütü (DSÖ) verilerine göre, her yıl yaklaşık iki milyon yeni vaka teşhis edilmekte ve bu durum akciğer kanserini küresel bir halk sağlığı krizi haline getirmektedir.² Tanı ve tedavi süreçlerindeki teknolojik ilerlemelere rağmen, hastalığın erken evrede tespit edilmesi ve doğru tedavi yöntemlerinin belirlenmesi, post op süreçte doğru ve etkili yönetim hâlâ önemli zorluklar içermektedir. Bu noktada, yapay zeka (YZ) teknolojileri, büyük veri analitiği ve derin öğrenme yöntemleri, akciğer kanseri araştırmalarında çığır açan bir potansiyel sunmaktadır.³ Yapay zeka, insan aklı ile bağdaştırılan algılama, analiz etme, problem çözme, düşünme, fikir beyan etme, sorunları çözme, iletişim kurma, çıkarımlarda bulunma, karar verme gibi işlevleri bulunan yazılım teknolojilerini tanımlamak için kullanılır. 21. yüzyılda tıp alanında görüntü işlemede yapay zeka ve yapay zekanın bir alt dalı olan çoklu derin öğrenme metotlarının kullanımı hızla artmıştır.^{4,5}

Derin öğrenme modelleri, büyük miktardaki tıbbi veriyi işleyerek hem tanı koyma hızını artırmakta hem de insan hatasını minimize etmektedir. Ayrıca, genomik analizlerde ve tedaviye yanıt öngörülerinde YZ algoritmalarının kullanılması, akciğer kanseri yönetiminde kişiselleştirilmiş tıp anlayışını güçlendirmektedir.^{5,6}

Bu çalışmanın amacı, akciğer kanserinde yapay zeka teknolojilerinin tanı, tedavi prognoz ve ameliyat sonrası süreçlerindeki rolünü, yoğun bakım ihtiyacı özelinde kapsamlı bir şekilde değerlendirmektir. Çalışma, preop hastaya ait spesifik verileri kullanarak ameliyat sonrası süreçte doğru, maliyet etkin etkin ve nesnel bir biçimde hastaların yoğun bakım ihtiyaçlarının olup olmayacağını gösterecek bir yapay zeka algoritmasının oluşturulmasını hedeflemektedir. Ayrıca, bireyselleştirilmiş tedavi uygulamalarında yapay zeka destekli modellerin uygulanabilirliği ve bu modellerin klinik pratiğe entegrasyonu ele alınacaktır.

Bu araştırma, yapay zeka ve akciğer kanseri arasındaki etkileşimi derinlemesine inceleyerek, tıbbi tanı ve tedavi süreçlerine yenilikçi çözümler sunmayı amaçlamaktadır. Elde edilen bulguların, akciğer kanseri hastalarının yaşam kalitesini artırmaya yönelik önemli katkılar sağlayacağı öngörülmektedir.



2. GENEL BİLGİLER

2.1. Akciğer Kanseri

Primer akciğer karsinomu, trakeobronşiyal yapılar veya akciğer dokusundaki hücrelerden farklılaşan, kontrolsüz bölünüp çoğalma yolu ile çevre doku ve organlara invazyon yapabilen, lenf yolu ve hematogen yol ile uzak organlara metastaz yapabilen hastalığın genel adıdır. Malignite denilmesi için belirtilen özellikler: diferansiyasyon, mitoz hızı, lokal invazyon ve metastaz olarak tanımlanmıştır.⁷

2.2. Akciğer Kanseri Epidemiyolojisi

Yirminci yüzyılın başlarında ender rastlanan bir hastalık olan akciğer kanseri günümüzde artış göstermektedir.⁸ Akciğer kanserinin görülme sıklığının diğer malignitelere göre daha fazla artması, sigara tüketimindeki artış ile ilişkilendirilmektedir. Akciğer kanseri 1985'ten itibaren dünya çapında en çok ölüme sebep olan kanser tipidir. Yeni tanı alan kanserlerin %13'ünü, kansere bağlı tüm ölümlerin %20'sini akciğer kanseri ile ilişkilendirmek mümkündür. Akciğer kanseri görülen tüm vakaların %58'i gelişmekte olan ülkelerde görülmektedir.^{9,10}

2.3. Akciğer Kanseri Etiyolojisi

Sigara içmek, akciğer kanseri görülme sıklığında 25-35 kat artış görülmesine neden olmaktadır ve son 40 yıl içinde akciğer kanseri görülme sıklığındaki artış, sigara içme alışkanlığındaki artışa paralel seyretmektedir.¹¹ Sigara dumanında bulunan kimyasal maddelerden bugüne kadar 70'ten fazlası, kanser yapıcı etkiye sahip maddeler olarak tanımlanmıştır. Dünya çapında 1,2 milyar insanın sigara içicisi olduğu tespit edilmiştir. Bu miktarın 2025 yılında 1,6 milyara yükselmesi beklenmektedir. Sigara, akciğer kanserinde ana risk faktörü olarak kabul edilmektedir. Akciğer kanseri mevcudiyetinde, erkeklerde %90 kadınlarda %80 sigara içiciliği ya da sekonder maruziyeti hikayesi bulunmaktadır.¹² Akciğer maligniteleri meslek sebepli kanserler arasında en sık görülen kanser türüdür. Meslekle ilişkili kanserlerin seyri diğer sebeplerden dolayı oluşanlardan farklı değildir. Ancak meslek ilişkili olmayan gruplara göre daha erken yaşlarda görülür. Mesleki maruziyet erkeklerde daha sık olduğundan, meslekle ilişkili kanserler de erkeklerde daha sık görülür.¹² Asbest ve sigara gibi birden fazla kanserojene maruz

kalanlarda maruziyete baėlı kanserler daha fazla g r l rl r. Bu maddelerin kanser oluřumunda sinerjistik tesir ettiėi  ng r lmektedir.¹³ Akciėer kanseri hastalarında ortalama yař 70, akciėer kanseri ile iliřkili  l mlerde ortalama yař 72'dir. Opere edilebilen hastaların oranı yař arttık a azalmaktadır. Erken dekatlarda g r lme sıklıėı az olmakla birlikte, son yıllarda bu d nemlerde de g r lme sıklıėı artıř g stermektedir.^{14,15} Akciėer kanseri; t t n  r nleri ile iliřkili olarak, kadınlara nazaran erkeklerde daha sık g r l r. Histopatolojik alt tipler de ise kadın ve erkek cinsiyette farklılık g sterir. Kadınlarda adenokarsinom alt tip daha sık g r lmektedir. Kadınlarda t t n  r nlerinin negatif etkilerine daha fazla duyarlı olma durumu, daha d ř k DNA onarım kapasitesi, t m r baskılayıcı genlerdeki artmıř mutasyon g r lme sıklıėı ve hormon d zeyinde farklılıklar, histolojik alt tiplere ve g r lme oranlarına etki etmektedir.¹⁶

2.4. Akciėer Kanserinin Histopatolojik Sınıflandırılması

Genetik  alıřmalar, molek ler d zeyde arařtırmalar ve immunohistokimyasal ilerlemelerin sonu ları ile eř zamanlı deėerlendirilerek 2015 yılında D nya Saėlık  rg t  (World Health Organization) ve Uluslararası Akciėer Kanseri Arařtırma Birliėi (International Association for the Study of Lung Cancer/IASLC)'nin beraber  alıřması ile akciėer kanserinde histopatolojik sınıflandırılma oluřturulmuřtur. (Tablo 1) ¹⁷

Tablo 1. Dünya Sağlık Örgütü akciğer kanseri histopatolojik sınıflandırması¹⁸

A. Epitelyal tümörler	
1. Adenokarsinom	Adenoid kistik karsinom
Lepidik adenokarsinom	Epitelyal-miyoepitelyal karsinom
Asiner adenokarsinom	8. Papillom
Papiller adenokarsinom	Yassı epitel hücreli papillom
Mikropapiller adenokarsinom	Glandüler papillom
Solid adenokarsinom	Mikst skuamöz ve glandüler papillom
İnvaziv müsinöz adenokarsinom	9. Adenomlar
Mikst invaziv müsinöz ve non müsinöz	Sklerozan pnömositom
Kolloid Adenokarsinom	Alveoler adenom
Fetal adenokarsinom	Papiller adenom
Enterik adenokarsinom	Müsinöz kistadenom
Minimal invaziv adenokarsinom	Müköz gland adenomu
Nonmüsinöz	B. Mezenkimal tümörler
Müsinöz	Pulmoner hamartom
Preinvaziv lezyonlar	Kondroma
Atipik adenomatöz hiperplazi	PEComatöz tümörler
Adenokarsinoma in situ	Lenfangiomyomatozis
	PEComa, benign
	Berrak hücreli tümör
	PEComa, malign
2. Yassı epitel hücreli karsinom	Konjenital miyofibroblastik tümör
Keratinize yassı epitel hücreli karsinom	Diffüz pulmoner lenfanjiomatozis
Nonkeratinize yassı epitel hücreli karsinom	
Bazaloid yassı epitel hücreli karsinom	İnflamatuvar miyofibroblastik tümör
Preinvaziv lezyonlar	Epiteloid hemanjiyoendotelyoma
In situ skuamöz hücreli karsinoma	Plevropulmoner blastom
3. Nöroendokrin tümörler	Sinovyal sarkom
Küçük hücreli karsinom	Pulmoner arter intimal sarkom
Kombine küçük hücreli karsinom	Pulmoner miksoid sarkom
Büyük hücreli nöroendokrin karsinom	Miyoepitelyal tümörler
Kombine büyük nöroendokrin karsinom	Miyoepitelyoma
Karsinoid Tümörler	Miyoepitelyal karsinoma
Tipik karsinoid tümör	C. Lenfohistiositik tümörler
Atipik karsinoid tümör	MALT lenfoma
Preinvaziv lezyonlar	Diffüz büyük hücreli lenfoma
Diffüz nöroendokrin hücre hiperplazisi	Lenfomatoid granülomatozis
4. Adenoskuamöz karsinom	Intravasküler büyük B hücreli lenfoma
5. Sarkomatoid karsinomlar	Pulmoner Langerhans hücreli histiositoz
Pleomorfik karsinom	Erdheim-Chester hastalığı
İgşi hücreli karsinom	D. Ektopik kökenli tümörler
Dev hücreli karsinom	Germ hücreli tümörler
Karsinosarkom	Teratom, matür
Pulmoner blastom	Teratom, immatür
6. Diğer ve sınıflandırılmayan karsinomlar	Intrapulmoner timoma
Lenfoepitelyoma benzeri karsinom	Melanom
NUT karsinom	Meningiom
7. Tükürük bezi tipi tümörler	E. Metastatik tümörler
Mukoepidermoid karsinom	

2.5.Küçük Hücre Dışı Akciğer Kanseri (KHDAK)

Akciğer kanseri tipleri içerisinde %80 görülme oranı ile en görülen sık alt tipi olarak tespit edilmiştir⁸. Akciğer kanserinden ölüm nedeni açısından karşılaştırıldığında en sık sebep yine KHDAK'dır. ⁸Sigara ve bilumum tütün ürünlerinin pasif ya da aktif olarak kullanımı akciğer kanseri görülme riskini anlamlı olarak artırmaktadır.¹⁹

Soy geçmişte akciğer kanseri öyküsünün bulunması, aromatik hidrokarbonlar, asbeste maruz kalınması, radyoaktif maruziyet, kronik akciğer hastalıkları öyküsü, soy gaz(radon) maruziyeti, vücutta birikimi olan metallerle maruziyet gibi faktörler de akciğer kanseri riskini artıran faktörler arasında bulunmaktadır.^{8,19} Cinsiyet faktöründe ise erkeklerde görülme sıklığı kadınlara oranla daha fazladır.^{8,20} Yaş faktörü ele alındığında 65 yaş ve üzeri grup tüm grubun %50 den fazlasını teşkil etmektedir.^{8,20,21} Küçük hücreli dışı akciğer kanseri tespit edilen vakaların yarısından fazlası 4.evre ya da ileri evre olarak nitelendirilmektedir.²¹KHDAK vakalarının toplamda %40'ını oluşturan alt tip adenokarsinomdur.^{21,22} Adenokarsinomları da alt tiplerine ayırdığımızda; minimal invaziv adenokarsinom (müsinöz olmayan, müsinöz), invaziv non-müsinöz adenokarsinom (lepidik, asiner, papiller, mikropapiller, solid), invaziv müsinöz adenokarsinom olarak sınıflanmaktadır. Skuamöz hücreli karsinom da ikinci en sık görülen tip olarak karşımıza çıkmaktadır.^{21,22} Keratinize, non-keratinize ve bazaloid tip karsinomlar skuamöz hücreli karsinomun başlıca alt gruplarıdır.^{23,24} Akciğer kanserinin diğer alt grupları ise ;büyük hücreli akciğer karsinomu, adenoskuamöz karsinom, sarkomatoid karsinom (pleomorfik karsinom, karsinosarkom), karsinoid tümör (tipik karsinoid, atipik karsinoid), nöroendokrin karsinomadır. (Büyük hücreli nöroendokrin karsinoma)^{18,23,24}.

(Tablo 2)

Tablo 2. Küçük hücre dışı akciğer karsinomlarının sınıflandırması tabloda belirtilmiştir.¹⁹

A. Epitelyal Tümörler
1. Adenokarsinom
a. Minimal İnvaziv Adenokarsinom
Non-Müsinöz Minimal İnvaziv Adenokarsinom Müsinöz Minimal İnvaziv Adenokarsinom
b. İnvaziv Non-Müsinöz Adenokarsinom
Lepidik Adenokarsinom
Asiner Adenokarsinom
Papiller Adenokarsinom Mikropapiller Adenokarsinom Solid Adenokarsinom
c. İnvaziv Müsinöz Adenokarsinom
Mikst invaziv Müsinöz ve Non-Müsinöz Adenokarsinom
d. Kolloid Adenokarsinom
e. Fetal Adenokarsinom
f. Adenokarsinom, enterik Tip
g. Adenokarsinom, alt tip belirtilmemiş
2. Skuamöz Hücreli Karsinom
a. Keratinize Tip
b. Non-Keratinize Tip
c. Bazaloid Tip
3. Büyük Hücreli Karsinom 4. Adenoskuamöz Hücreli Karsinom 5. Sarkomatoid Karsinom
a. Pleomorfik Karsinom
b. Karsinosarkom
6. Tükürük Bezi Tipi Karsinomlar
a. Mukoepidermoid Karsinom b. Adenoid Kistik Karsinom
B. Nöroendokrin Tümörler
1. Karsinoid Tümör
a. Tipik Karsinoid / Nöroendokrin Tümör Grade 1
b. Atipik Karsinoid / Nöroendokrin Tümör Grade 2
2. Nöroendokrin Karsinom

2.6. Küçük Hücreli Dışı Akciğer Kanseri Evreleme

TNM evreleme sistemi küçük hücreli dışı akciğer kanseri evrelemesinde kullanılmaktadır.²⁵

“T” faktörü, tümörün boyutu ile karakteristik özelliklerini (tx, T0, Tis, T1a(mi), T1, T2, T3, T4), “N” lenf düğümünün özelliklerini (Nx, N0, N1, N2, N3) ve “M” uzak metastaz durumunu (M0, M1a, M1b, M1c) ifade eder (Tablo 4), (Tablo 5).²⁵⁻²⁷ Günümüzde IASLC ve AJCC çalışmaları sonucu 9.TNM evrelemesi kullanılmaktadır. (Tablo 3), (Tablo 4), (Tablo 5), (Tablo 6)^{27,28} TNM evreleme sistemindeki amaç akciğer kanserli hastalarda sağkalım ve hastalığın seyrini doğru tahmin etmek, evrelemeyi doğru yapmak ile en iyi tedavi seçeneklerini ortaya koymaktır.^{26,27,29} Dokuzuncu evrelemede T faktöründe T1 ve T2 için 1'er santimetre aralıklarla artışlar için alt gruplar oluşturulmuştur^{28,30} T3 tanımı 5cm'den büyük tümörler için , T4 kavramı 7 cm'den büyük tümörler için kullanılmıştır.^{27,29,30} (Tablo 3) T, N ve M faktörleri kullanılarak hastalık evrelemesi yapılmaktadır. (Tablo 4)

Tablo 3. TNM evrelemesi T faktörü gösterilmiştir.²⁸

Tx	Tümörün değerlendirilememesi,
T0	Primer tümör kanıtı yok
Tis	Karsinoma İn Situ
T1	Tümör, akciğer veya visseral plevra ya da uzak periferik bronşla sınırında (ana lob bronşunda değil).
T1mi	Minimal İnvaziv Adenokarsinom
T1a	≤1 cm
T1b	>1 cm ile ≤2 cm aralığı
T1c	>2 cm ile ≤3 cm aralığı
T2	>3 cm ile ≤5 cm aralığında, Karinaya mesafesinden bağımsız ana bronş invazyonu olması, Visseral plevra invazyonu olması, Hiler bölgeye uzanan atelektazi veya obstrüktif pnömoni
T2a	>3 cm ile ≤4 cm aralığı
T2b	>4 cm ile ≤5 cm aralığı
T3	>5 cm ile ≤7 cm aralığı, Göğüs duvarı, frenik sinir, parietal plevra, azygos ven, perikardiyum invazyonu, stellat ganglionda ya da intratorasik sinir zincirinde tutulum, Aynı lobda farklı nodüller
T4	>7 cm Diyafagma, timus, kalp, trakea, mediasten, büyük damarlar, rekürren laringeal sinir, vertebral gövde, özefagus, vagus siniri, brakial pleksus, karina invazyonu, Aynı taraf farklı lobda nodüller

Tablo 4. TNM evrelemesi N faktörü gösterilmiştir.²⁸

Nx	Bölgesel Lenf Düğümlerinin Değerlendirilememesi
N0	Bölgesel Lenf Düğümü Metastazı yok
N1	İpsilateral peribronşiyal ve/veya İpsilateral hiler ve/veya, İntrapulmoner lenf düğümlerine metastaz veya direkt invazyon
N2	İpsilateral mediastinal ve/veya Subkarinal lenf düğümlerine metastaz
N2A	Tek bir ipsilateral mediastinalde veya subkarinal nodal istasyonda metastaz(lar)
N2B	Subkarinal nodal istasyonun tutulumu olan veya olmayan birden fazla ipsilateral mediastinal lenf nodunda metastazlar
N3	Kontralateral mediastinal/hiler, ipsilateral/kontralateral skalen ya da supraklavikular metastaz

Tablo 5. TNM evrelemesi M faktörü gösterilmiştir.²⁸

M0	Uzak metastaz yok
M1	Uzak metastaz var
M1A	Karşı akciğerde ayrı tümör nodül veya/nodülleri Plevral veya perikardiyal nodüller Malign plevral veya perikardiyal efüzyon
M1B	Tek ekstremitasik organda tek metastaz
M1C1	Tek veya multipl organda multipl ekstratorasik metastaz Tek bir organda çoklu ekstratorasik metastazlar
M1C2	Birden fazla organda çoklu ekstratorasik metastaz

Tablo 6. TNM Evrelerinin Sınıflandırılması²⁹

T/M	Alt Grup	N0	N1	N2A	N2B	N3
T1	T1a	IA1	IIA	IIB	IIIA	IIIB
	T1b	IA2	IIA	IIB	IIIA	IIIB
	T1c	IA3	IIA	IIB	IIIA	IIIB
T2	T2a	IB	IIB	IIIA	IIIB	IIIB
	T2b	IIA	IIB	IIIA	IIIB	IIIB
T3	T3	IIB	IIIA	IIIA	IIIB	IIIC
T4	T4	IIIA	IIIA	IIIB	IIIB	IIIC
M1	M1a	IVA	IVA	IVA	IVA	IVA
	M1b	IVA	IVA	IVA	IVA	IVA
	M1c1	IVB	IVB	IVB	IVB	IVB
	M1c2	IVB	IVB	IVB	IVB	IVB

2.7. Küçük Hücreli Dışı Akciğer Kanseri Tedavi

Küçük hücreli dışı akciğer kanseri tedavi açısından temel olarak erken evre (Evre 1 ve 2) ve lokal ileri evre (Evre 3) olarak gruplandırılır.^{31,32} Rehberlerde klinik olarak erken evre küçük hücreli dışı akciğer kanseri olma durumunda solunum fonksiyon testi(SFT) ve klinik açıdan engel bir durum yok ise tedavi seçenekleri arasında cerrahinin yeri büyüktür.^{9,33,34} SFT yada klinik olarak uygunsuz durumlarda ise stereotaktik vücut radyasyon tedavisi (SBRT) ve kemoterapi tedavi seçeneği olarak öne çıkmaktadır.^{9,33,34} Evre 1-2 erken dönem hastalıkta standart olarak önerilen cerrahi prosedür lenf nodu diseksiyonu ile birlikte anatomik akciğer rezeksiyonlarıdır.^{9,31,32} Anatomik olmayan sublobar wedge(kama) rezeksiyon ise lobektomiden ve segmentektomiden daha kötü onkolojik sonuçlar sunmaktadır.³⁵ Bazı çalışmalarda küçük hücreli dışı akciğer kanseri evre 1A anatomik rezeksiyona solunum rezervi elverişli olmayan hastalarda wedge

rezeksiyon uygulanabilir bir prosedür olarak gösterilmiştir.^{35,36} Parankim koruyucu prosedürler son zamanlarda artan sıklıkla uygulanmasına rağmen hiler yerleşimli ve aynı zamanda parankim koruyucu cerrahiler için teknik olarak uygun olmayan hastalarda pnömonektomi seçeneği mevcuttur.^{37,38} Solunum testleri sonucu elverişli olmayan hastalarda santral yerleşimli KHDAK varlığında pnömonektomiden kaçınmak için sleeve lobektomi seçeneği mevcuttur.^{37,39} Cerrahi sınır negatif sleeve rezeksiyonlarda genel sağkalım, nüksüz sağkalım onkolojik sonuçları pnömonektomi ile örtüşmektedir.^{39,40} Lobektomi KHDAK cerrahi tedavisinde altın standarttır ve cerrahi yaklaşım olarak torakotomiler ilk uygulanan cerrahi yaklaşımdır.⁴¹ Minimal invaziv bir cerrahi prosedür olan video yardımcı göğüs cerrahisi (VATS) 1990'larda sahalara girmiştir ve torakotomiye göre daha az ağrılı olması, iyileşme süresinin daha kısa olması , postoperatif ağrı durumunda kaydedilmiş iyileşme avantajları ile standart kullanım haline gelmiştir.⁴¹⁻⁴³ RATS'ın (Robot yardımcı göğüs cerrahisi) VATS ve torakotomiye üstünlüğü ifade edilmektedir, daha iyi bir ergonomiye sahip olması, üç boyutlu yüksek kalitede görüntü elde edilmesi, alet açılarının daha iyi manevra kabiliyeti için uygun olması temel üstünlüklerindendir ancak operasyon süresinde uzama , yüksek maliyet ise RATS için temel engellerdir.^{44,45} KHDAK'larında evre Lokal ileri ise tedavi, tümörün rezektabl olup olmadığına göre planlanmalıdır. Rezektabl lokal ileri evre KHDAK'ne cerrahi prosedürü takiben adjuvan onkolojik tedavi (Kemoterapi ve/veya İmmünoterapi ve/veya Radyoterapi) planlanması multidisipliner konseyler ile alınmalıdır.^{34,46,47} Rezektabl olmayan lokal ileri evre KHDAK hastalar için neoadjuvan (cerrahi öncesi) tedavi ardından (Kemoterapi ve/veya İmmünoterapi ve/veya Radyoterapi) yeni görüntülemeler ile cerrahi açıdan tümörün rezektabl hale gelip gelmediği değerlendirilmelidir.^{34,48,49} Evre 3A ve seçilmiş özellikli Evre 3B hastalar cerrahi prosedür için uygun olabilir.^{50,51}

3. KÜÇÜK HÜCRELİ DIŞI AKCİĞER KANSERİ CERRAHİSİ SONRASI PULMONER KOMPLİKASYONLAR, YOĞUN BAKIM GEREKSİNİMİ VE HASTANEDE KALIŞ SÜRECİ

3.1. Postoperatif Pulmoner Komplikasyonlar

Göğüs cerrahisi ameliyatları sonrasında yoğun bakım ihtiyacı ve komplikasyon oluşma durumunu öngörmek konusunda uzlaşılmış bir fikir birliği bulunmamaktadır.^{52,53} Primer küçük hücreli dışı ve küçük hücreli akciğer kanseri nedeni göğüs cerrahisi ameliyatları sonrasında ERAS (Enhanced Recovery After Surgery- Cerrahi Sonrası İyileştirilmiş Bakım) protokolünün gerçekleştirilmesi ve preop postop pulmoner rehabilitasyon uygulanması ile morbidite ve mortalitenin azaldığı yönünde kanıtlar gösterilmiştir.^{54,55} Albümin düzeylerinde düşüklük , immün sistem zayıflığı, yeterli beslenememe, sigara ve tütün ürünleri kullanımı, ileri yaş, komorbid ek durumlar, kronik obstrüktif akciğer hastalığı(KOAH) öyküsü ve uzamış cerrahi süresi postoperatif veya genel komplikasyonlar açısından risk faktörleridir. ^{53,56-59} Yardımcı solunum kasları ve ana solunum kas gücünde zayıflama, operasyon bölgesinde ağrı ve sekresyon retansiyonu KHDAK nedeniyle minimal invaziv cerrahi ameliyat yapılması durumunda dahi postoperatif pulmoner ya da genel komplikasyon oranının %20-60 gibi geniş bir değer aralığında bulunmasına sebep gösterilebilir.^{52,60-63}

Ameliyat sonrası pulmoner yada genel komplikasyonlar KHDAK nedeni ile opere edilen hastalarda ,uzamış hava kaçağı, lobar yada tam pnömoni, atelektazi, sekresyon tıkaçları oluşması ve retansiyonu, bronkoplevral fistül ve organizma ilişkili ampiyem şeklinde en sık olarak karşımıza çıkmaktadır.^{58,59} Uzamış hava kaçağı ameliyattan sonra 5 ila 7 günden daha uzun süren hava kaçaklarının devam etmesi olarak tanımlanır ve akciğer ameliyatları sonrası %8-15 oranında görülmektedir.^{64,65} Hava kaçağı miktarı bronkoplevral fistül gibi masif değil, alveolar- plevral boşluklar sebebi ile daha az olmaktadır.⁶⁶ Uzamış hava kaçakları göğüs tüpü uygulanma süresinin uzamasına, hastanede yatış süresinin uzamasına ,hastane sebepli enfeksiyonlarının (ampiyem vb.) ortaya çıkmasına ve toplam hastane maliyetlerinde artışa sebep olan postoperatif komplikasyonlardandır.^{65,67} Ameliyat sonrası pnömoni oluşma riski aktif tütün ürünleri kullanım öyküsü olan, ileri yaş, erkek , KOAH'lı, düşük solunum fonksiyon değerlerine sahip, torakotomi ile cerrahi yapılan, neoadjuvan tedavi almış, diyabet öyküsü olan, kanda

düşük albümin seviyeleri ölçülen, yüksek C-Reaktif protein değerlerine sahip hastalarda artmaktadır.^{58,68-72} Cerrahi profilaksi için antibiyotik grubu seçiminde birinci kuşak sefalosporinler cerrahi alan enfeksiyonu için en iyi seçenek olarak gösterilebilir.⁷³ Ağrı, solunum kaslarında hasarlanma, öksürme yetisinde azalma, merkezi ve periferik sinir sisteminin anestezi ilaçları ile depresyonu, solunum sıklığında artma, operasyon sırasında tek akciğer ventilasyonu, tidal volüm ve fonksiyonel rezidüel kapasitede azalma akciğer rezeksiyonu yada toraks cerrahilerini takiben gelişen atelektazinin başlıca görülme nedenleri olarak sayılabilir.^{74,75} Bronş güdüğü ve plevral boşluk arasındaki fistül oluşumu olarak tanımlanan bronkoplevral fistül KHDAK nedeni ile yapılan ameliyatlardan sonrası geliştiğinde ciddi postoperatif komplikasyonlar arasında sayılmaktadır.⁷⁶ Başlıca risk faktörleri: Pnömonektomi, neoadjuvan tedavi, kontrolsüz diyabet, bronş güdüğünün uzun bırakılması, bronş güdüğünün beslenememesi, bronkoplevral fistül gelişimi için başlıca risk faktörleridir.^{76,77} . Çapı 8mm'den küçük bronkoplevral fistül (BPF) varlığında bronkoskopi ile sklerozan ajanlar, silikon stent vb. uygulanabilirken bronkoplevral fistül çapı 8mm'den büyükse cerrahi önerilmektedir.^{76,78-80}

3.2 Ameliyat Sonrası Yoğun bakım Yatışı ve Yoğun Bakım Yatışı Gerekliliğinin Değerlendirilmesi

Küçük hücreli dışı akciğer kanseri ameliyatları sonrası majör ve minör komplikasyonlar açısından yoğun bakım takibi gerekebilmektedir.⁸¹ Ağır tütün ürünleri içicisi, koroner arter hastalığı olan, KOAH tedavisi alan gibi çeşitli komorbid durumların eşlik ettiği yüksek riskli hasta grubu genellikle KHDAK için opere olan hasta grubunun genel profilini temsil etmektedir.⁸² ASA (American Society of Anesthesiologist), CCI (Charlson Comorbidity Index), kardiyak risk indeksi gibi pulmoner riskleri değerlendirmede kullanılan yöntemler komorbid durumları değerlendirmek ve yoğun bakım yatış gerekliliğini incelemek için kullanılır.⁸²⁻⁸⁷

4. DERİN ÖĞRENME VE YAPAY ZEKA ALGORİTMALARI

İnsanın öğrenme sürecinin matematiksel modellemesi sonucu ortaya çıkan yapay zeka kavramı ilk olarak 1940'larda ortaya atılmıştır.⁸⁸ John McCarty'nin yaptığı tanım ile “Akıllı makineler mühendisliği ve bilimi” şeklinde ilk kez 1956'da ifade edilmiştir.⁸⁹ Bu sektörde temel amaç yapay zeka ile insan tarafından üretilen makinelerin insan gibi davranmasıdır.⁹⁰ Yapay zekanın son dönemlerde artan bir süratle gelişmesi ile IBM firmasının Deep Blue ürünü 1997'de Dünya satranç federasyonu şampiyonu Garry Kasparov'u yenerken, son zamanlarda sıklıkla kullanılan Siri, Alexa, ChatGPT gibi konuşma bazlı yazılımlar hayatımızda fazlaca yer edinerek yapay zeka teknolojisinin geliştiğini, değerli teknolojiler arasında yer edindiğini ve potansiyel değer ivmelenmesinin giderek artırdığını ortaya koymaktadır.^{90,91} Yapay zeka yazılım algoritma örnekleri için çeşitli yazılım dilleri kullanılabilir, örnek olarak Python, MATLAB, SaaS, C++, JavaScript gösterilebilir.⁸⁹ Makine bazlı öğrenme(ML) eldeki verilerden işleme başlayarak istenen eylem ve mevcut eylem arasındaki hatayı en aza düşürmeye odaklı yapay zeka yöntemlerinden bir alt gruptur.^{89,90,92} Oluşturulan algoritmalar eldeki verileri öğrenmek ve hazırlanan modelin kendi başına alabileceği tüm kararları haritalandırmak amaçlı tanımlanan istatistiki tekniklerden oluşan kurallar bütünüdür ve modeller ise yazılan algoritma sonucu ortaya çıkan matematiksel birer denklemdir.⁸⁹ Denklemleri beslemek için eldeki eğitim verilerinin makine bazlı öğrenme modellerini eğitmek için kullanılan kısmı tüm verilerin %80'i, test verileri ise makine bazlı öğrenme modellerini eğittikten sonra test etmek için kullanılan kısımdır.^{89,91} Modeli oluşturmak ve eğitmek sonrasında da test etmek için veri setlerinin hazırlanmasının ardından makine bazlı öğrenim için model yada modeller oluşturulur, doğrulama ve test verileri ile model en uygun hale getirildikten sonra makine öğrenme modelinin doğruluğu, doğruluk ve hata verisi ile değerlendirilir.⁸⁹ Makine bazlı öğrenme özünde denetim ile (supervised) ve denetim olmadan (unsupervised) ve desteklenerek (reinforcement) öğrenme türlerinden oluşur.^{89,93,94} Etiketli veriler ile denetim ile öğrenmede eğitim gerçekleştirilir, sınıflandırma ve regresyon problemlerinin çözümü için kullanılabilen bir yöntemdir, linear regresyon, karar ağaçları (Decision Trees-DT), lojistik regresyon, rastgele orman (Random Forest), naif bayes sınıflandırma (Naive Bayes Classifier), destekli vektör makineleri (Support Vector Machine), KNN(K-Nearest Neighbors) denetimli öğrenme ile uygulanabilen algoritmalarlardır.⁸⁹

4.1 Lineer Regresyon

Lineer regresyon, y ile gösterilen sayısal bir bağımlı değişken ile x ile ifade edilen bir veya daha fazla bağımsız değişken arasındaki ilişkiyi analiz etmek için kullanılan istatistiksel bir yöntemdir. Eğer modelde yalnızca bir bağımsız değişken bulunuyorsa, bu durumda model "basit doğrusal regresyon" olarak adlandırılır. Ancak, modelde birden fazla bağımsız değişken yer alıyorsa, bu tür modeller "çoklu doğrusal regresyon" olarak tanımlanır.⁹⁵ Doğrusal regresyon analizinde, bağımlı değişkenin mutlaka sayısal bir değer olması gerekmektedir. Ayrıca, regresyon modelinin güvenilir olabilmesi için, modeldeki her bir bağımsız değişken için en az 10 gözlem (olgu) bulunması önerilir. Bu, modelin istatistiksel olarak anlamlı ve tutarlı sonuçlar üretebilmesi için önemli bir gerekliliktir.⁹⁶

4.2 Radial Basis Fonksiyonu

Radial basis fonksiyonu, gerçek değerli bir girdi alıp, giriş değerinin başka bir yere yerleştirilen hayali sabit bir noktadan uzaya izdüşümüne olan uzaklığa bağlı olarak gerçek değerli bir çıktı üreten matematiksel bir fonksiyondur.⁹⁷

4.3 Random Forest (RF)

Rastlantısal orman (Random Forest), hiper parametre kestirimi yapılmadan da iyi sonuçlar vermesi hem regresyon hem de sınıflandırma problemlerine uygulanabilir olmasından dolayı popüler makine öğrenmesi modellerinden biri. Rastgele oluşturulmuş birden çok karar ağacının çıktısını birleştiren, regresyon ve sınıflandırma problemlerini çözmek için kullanılan bir makine öğrenme algoritmasıdır. RF algoritması, karar ağaçlarının tahminlerinden yola çıkarak sonuca ulaşmayı sağlar. Ormandaki ağaç sayısının artması algoritma sonucunun kesinliğini artırır. RF algoritması ormandaki karar ağaçları üzerinde rastgele ve sürekli olarak işlem gerçekleştirdiği için paralel mimaride platformlar üzerinde çalıştırılması ile olumlu sonuçlar elde edilebilir.⁹⁸

4.4 Synthetic Minority Over-Sampling Technique (SMOTE)

Dengesiz sınıflandırmanın bir sorunu, bir modelin karar sınırını etkili bir şekilde öğrenebilmesi için azınlık sınıfına ait çok az örnek olmasıdır. Bu sorunu çözmenin bir yolu, azınlık sınıfındaki örnekleri aşırı örneklemeaktır. Bu, bir modele uymadan önce eğitim veri kümesindeki azınlık sınıfından örnekleri çoğaltarak elde edilebilir. Bu, sınıf

dağılımını dengeleyebilir ancak modele herhangi bir ek bilgi sağlamaz. Azınlık sınıfından örnekleri çoğaltmada bir iyileştirme, azınlık sınıfından yeni örnekler sentezlemektir. Bu, tablo verileri için bir tür veri artırmadır ve çok etkili olabilir.⁹⁹ SMOTE tekniği eldeki verisetini çoğaltmak yerine genişletmeyi hedefler. Karşılaştırılacak 2 grup arasında azınlık olan tarafı çoğunluk olan tarafla dengelemek şeklinde de yorumlanabilir. Sonuca etki etmez ve taraf tutmaz.^{100,101}

4.5 Support Vector Machine (SVM)

SVM, bir sınıflandırıcı oluşturmak için güçlü bir yöntemdir. Bir veya daha fazla özellik vektöründen sonuçların tahmin edilmesini sağlayan iki sınıf arasında bir karar sınırı oluşturmayı amaçlar. Hiper düzlem olarak bilinen bu karar sınırı, her bir sınıftan en yakın veri noktalarından mümkün olduğunca uzakta olacak şekilde yönlendirilir. Bu en yakın noktalara destek vektörleri denir.¹⁰²

4.6 Yapay Zeka İşleme Biçimleri ve Dengesiz Verisetleri

Linear regresyonda X düzleminde bağımsız değişken değerleri, Y düzleminde ise bağımsız olmayan değişken öngörülerinin yer aldığı yöntemdir.⁸⁹ Lojistik regresyon ise bağımlı değişkenin kategorize olduğu durumda kullanılmaktadır.^{89,92} DT özünde bir sınıflama algoritma aracıdır, potansiyel tüm sonuçları içerir ve akış şeması biçiminde bir diyagramdır.^{89,90} RF'nın algoritması çoklu DT'den oluşur ve daha fazla kesinlik ve doğruluk ile tahminler elde edilir.^{89,91} Naif bayes sınıflandırıcısı, sınıflandırma problemlerini olasılıksal olarak çözmeyi hedefleyen bayes teoremini temel alan bir algoritmadır ve değişkenler arasındaki korelasyonu dikkate almaz ve tıbbi modeller için çok uygun değildir.⁹⁰ KNN eldeki bilgileri en yakın bulunduğu konuma göre sınıflandırır.⁸⁹ Support Vector Machine – Destek Vektör Makinesi (SVM) kategorizasyon için lineer bir ayrıştırma değil, pozitif ve negatif verileri en iyi şekilde ayırmak için mutlak bir hiperdüzlem oluşturulması işlemidir.^{89,103} Denetimli olmayan öğrenme biçiminde ise etiketli olmayan veriler ve yönlendirilmemiş bilgiler ile eğitim gerçekleştirilir. Lineer Regresyon ile Problem çözmek için sürekli veri setleri iyi bir seçimdir, kategorik veriler elinizde mevcut ise sınıflandırma için kullanılan yöntemler seçilmelidir, KNN, lojistik regresyon, SVM, gibi algoritmalar ile uygulanması mümkündür, kümelemeye yarayan yöntemler ise verilerin yetersiz yada tamamlanamamış olduğu kategorik veri setleri için

iyi bir yöntemdir^{89,104}. Destekli öğrenme (RL-Reinforcement Learning) ödüllendirme temelli sorunların çözümünde deneme yanılma metodunun kullanıldığı yöntemdir.⁸⁹ Derin öğrenme (DL-Deep Learning) birden fazla katmandan oluşan sinir ağları ile kompleks, yapılandırılma yapılmamış verileri içeren sorunları çözmede efektif olan makine öğrenmesinin bir alt grubudur.^{89,94,103} DL'de çoklu kaynaklardan veri girişini alan girdi katmanı ve çıktıları veren çıktı katmanı mevcuttur, girdi ve çıktı katmanlarının arasında ise birden fazla sayıda gizli katmanlar vardır^{93,94,103,104}. Ara katmanların sayısı ve ara katmanlardaki algılayıcı işleyicilerin sayısı sorunun karakterine göre değişmektedir.⁸⁹ Birden fazla katmandan oluşan yapay sinir ağlarında en az bir ara katman vardır, verilerin ağırlıkları ve sonuca etki etme oranları değişkendir ve sürekli güncellenir, bu değişkenlik bir önceki işlemede elde edilen yanılma oranına göre geri yayılma usulü ile ayarlanır, bu sayede hata miktarları azaltılır ve modelin doğruluğu, güvenilirlik derecesi artırılır⁸⁹. CGM (Conjugate Gradient Method, Eşlenik Eğitim Metodu) kompleks denklemlerin ve nonlinear optimizasyon sorunlarının çözümlendirilmesinde uygulanabilecek en iyi yöntemlerdendir, temel hedef ağırlık oranlarının art arda güncellemeler ile en iyi hale getirilmesidir, SCG (Scaled Conjugate Gradient) CGM'nin daha ileriye taşınmış halidir ve eğitimi daha hızlı yapıyor olması avantajına sahiptir^{105,106}. SCG basamak büyüklüğünü ölçeklendirmek için Levenberg- Marquardt (LN) prosedürünü kullanır ve daha düşük bilgisayar gücü ihtiyacı ve güçlü yakınsama değişkenleri ile pratiklik sağlar¹⁰⁵⁻¹⁰⁷. Levenberg-Marquardt algoritması birden fazla katmanlı algılayıcılarda işlenen klasik bir eğitim metodudur¹⁰⁷ Medikal alanda yapay zeka kullanım sahalarına Watson bilgisayarı örnek gösterilebilir, veri setlerinin geldiği yerler klinik kontrollü çalışmalar, araştırma makaleleri, tedavi rehberleridir.⁸⁹ Tıp ve ilişkili alanlarda yapay zeka, makine öğrenmesine ve derin öğrenmeye ihtiyaç duyulan başlıklar, elektronik medikal kayıtların dijital ortama aktarılması, verilerdeki yönelimlerin ve önemli veri setlerinin ortaya çıkarılması, zamanlama planlaması, istatistiki açıdan değerli emsaller oluşturma, karar verme ve doğru risk tahmininde optimizasyon, karmaşık problemlerin çözümü olarak belirtilebilir, bu önemli konularda yapay zeka ile geliştirilen teknolojiler hekimlere destek olmaktadır⁸⁹. Datasetler her zaman dengeli olarak dağılmazlar. Bankacılık gibi günde yüzbinlerce yapılan işlemlerin pek çok azı sadece sahtekarlık ve dolandırıcılık işlemlerinden oluşur. Böyle durumlarda çeşitli yöntemler kullanılarak veri setleriyle başa çıkılmaktadır. Resampling, class weight, sentetik veri

üretilmesi Synthetic Minority Over-Sampling Technique (SMOTE) gibi yöntemler kullanılmaktadır. ¹⁰⁰ SMOTE, sanılanın aksine eldeki verisetini çoğaltmak yerine genişletmeyi hedefler. Bunu yaparken de aritmetik ortalama, mod, medyan, standart sapma gibi sonuca etki edebilecek sabitlere sadık kalarak makine öğrenmesine sunulan örneklemin yetersiz kaldığı durumlarda verisetini düzeltmeden, özelleştirmeden, istenilen sonucun ne olduğunu bilmeden genişletir.^{100,101,108,109}



5. GEREÇ VE YÖNTEM

Çalışmamız retrospektif olarak planlanmış olup çalışmaya 2011-2023 yılları arasında Çukurova Üniversitesi Tıp Fakültesi Hastanesi'nde anatomik akciğer rezeksiyonu (wedge rezeksiyon, sağ üst lobektomi, orta lobektomi, sağ alt lobektomi, bilobektomi süperior, bilobektomi inferior, sağ pnömonektomi, sol üst lobektomi, sol alt lobektomi, sol pnömonektomi, segmentektomi ve wedge rezeksiyon) yapılan toplan 1471 hasta dahil edilmiştir. 14 hastanın preoperatif solunum fonksiyon değerlerine ulaşamadığı için çalışma dışı bırakılmıştır. Toplamda 1457 hasta veri seti oluşturmak için istatistiki analize alındı.

Retrospektif planlanan çalışma sonucunda hasta dosyaları hastane bilgi yönetim sistemi üzerinden incelendi. Çalışmaya dahil edilen tüm vakaların epidemiyolojik özellikleri yaş, cinsiyet, ek hastalık, KOAH, koroner arter hastalığı(KAH),operasyon süresi, hastanede kalış süreleri, yoğun bakım yatış süreleri, patolojik tümör boyutları,N0,N1,N2 lenf nodu durumları, solunum fonksiyon testi sonuçları (FEV1-FVC-FEV1/f-FVC),diyabet, hipertansiyon, sigara(paket/yıl) öyküsü, neoadjuvan tedavi öyküsü(KT ve/veya RT),uzamış hava kaçağı olup olmadığı, tümörün yerleşim yeri, tümöre ait Pozitron Emisyon Tomografisi ve Bilgisayarlı Tomografi(PET-BT) de tümöre ait Standartized Uptake Volume(SUV) değerleri, PET-BT de mediasten lenf nodları SUV tutulumları, cerrahi sınırların tümöre uzaklıkları, tümör çapı, minimal invaziv cerrahi VATS yada torakotomi uygulanma durumu, lenfovasküler invazyon varlığı yada yokluğu, yapılan anatomik rezeksiyonun biçimi gibi klinik özellikleri not edildi. (Tablo:6)

Cerrahi sonrası patolojik tanı tümör yok(KT-RT sonrası) adenokarsinom, skuamöz hücreli karsinom, karsinoid tümör, küçük hücreli dışı akciğer karsinomu, büyük hücreli karsinom, karsinoid tümör, pleomorfik karsinom, nöroendokrin karsinom, lenfoma,mikst tip karsinom, metastazlar, küçük mavi yuvarlak hücreli tümör(PNET), soliter fibröz tümör, hemanjiyo endotelyoma,fibroblastik neoplazi,mukoepidermoid tip karsinom, plöropulmoner blastom,küçük hücreli akciğer kanseri, karsinosarkom ve diğer olmak üzere gruplandırıldı.

TNM evrelemesindeki patolojik N lenf nodlarının durumu N0, N1, N2 şeklinde kaydedildi. Patolojik TNM evrelemesi 9. Akciğer Kanseri Evreleme sistemine uygun şekilde yapıldı. Cerrahi sınırların pozitif olması ve cerrahi sınıra en yakın uzaklık not

edildi. Plevral invazyon, lenfatik invazyon, damar invazyonları ek patolojik kriterler olarak not edildi.

Ameliyat sonrası veriler olarak ise komplikasyon oluşup oluşmama durumu, yoğun bakım yatış olup olmadığı, olduysa kaç gün olduğu hastanede kalma gün sayısı ve kaydedildi. Tüm veriler hastane elektronik veri tabanı ve hasta dosyalarından elde edildi. Hastalara ek bir işlem uygulanmadı. Yapay zeka altyapıları için MATLAB R2022a (MathWorks Inc., Natick, Massachusetts, United States) ve Python 3.8.2 (Van Rossum G, Drake Jr FL, Amsterdam, Holland) programları kullanıldı. Verilerin %80'i eğitim için %20'si test için kullanıldı

Çalışmamızın etik kurul onayı 08.11.2024 tarihli Çukurova Üniversitesi Tıp Fakültesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu 149 sayılı toplantısında alınmıştır.

6. BULGULAR

2011-2023 tarihleri arasında KHDAK nedeni ile klinik merkezimizde opere edilen 1457 hastanın ortalama yaşı $57,7 \pm 10,8$ idi. Hastaların %80,1'i erkek cinsiyette (1167 hasta), %19,9'i kadın cinsiyette (290 hasta) idi. (Tablo 5)

Tablo 7. Demografik Veriler (Ortalama Değerler, Standart Deviasyon Değerleri ve Oranlar verilmiştir.)

Yaş	57.7±10.8
Cinsiyet	
-Erkek	1167 (%80,1)
-Kadın	290 (%19,9)

Tablo 8. Hastalara ait solunum parametreleri verileri, DM, HT, KOAH, KAH hastalıkları durumu, histopatolojik ve klinik veriler, tümör ve lenf nodu, yoğun bakım yatış ihtiyacı özelliklerini, tümör yerleşim yerlerini, uygulanan cerrahi rezeksiyon tipini, neoadjuvan kt ve/veya rt durumunu içeren non-kategorik veriler (Ortalama Değerler ve Standart Deviasyon Değerleri verilmiştir.)

Sigara İçen	866(%59,4)
Sigara İçmeyen	591(%40,6)
Sigara Öyküsü (paket/yıl)	24.16 ± 37.8
FEV1(ml)	2070 ±710
FVC (ml)	3200 ±540
FEV1/FVC %	%69,2
PET/BT’de Tümörün Maksimum FDG Tutulumu (Suvmax: Maksimum Standardize Uptake Volüm)	12.5
PET/BT’de Lenf Nodunun Maksimum FDG Tutulumu (Suvmax: Maksimum Standardize Uptake Volüm)	6.52
Cerrahi Sınır Pozitif %	%8
Tümör Çapı (cm)	3.73 ±1.96
Postoperatif Hastanede Yatış Günü (Gün)	7.7±2.6
KOAH Öyküsü (Var)	%9,5
Hipertansiyon Öyküsü (Var)	%30,4
Diyabet Öyküsü (Var)	%19,8
Neoadjuvan Kemoterapi ve/veya Radyoterapi Öyküsü (Var)	%11,2
-Minimal İnvaziv Cerrahi	%27,6
-Açık Cerrahi	%72,4

Tablo 8. Hastalara ait solunum parametreleri verileri, DM, HT, KOAH, KAH hastalıkları durumu, histopatolojik ve klinik veriler, tümör ve lenf nodu, yoğun bakım yatış ihtiyacı özelliklerini, tümör yerleşim yerlerini, uygulanan cerrahi rezeksiyon tipini, neoadjuvan kt ve/veya rt durumunu içeren non-kategorik veriler (Ortalama Değerler ve Standart Deviasyon Değerleri verilmiştir.)(devamı)

Cerrahi Rezeksiyon Tipi	
-Lobektomi	%56,6
-Bilobektomi	%4,2
-Pnöminektomi	%12,7
-Wedge	%25,4
-Segmentektomi	%1,1
Tümörün Yerleşim Yeri	
-Sağ	%68,4
-Sol	%31,6
Bilateral	%7,7
Tümörün Yerleşim Yeri	
-Sağ Akciğer Üst Lob	%39,4
-Sağ Akciğer Orta Lob	%2,8
-Sağ Akciğer Alt Lob	%19,7
-Sol Akciğer Üst Lob	%24,4
-Sol Akciğer Alt Lob	%13,7
Lenf Nodu Durumu	
-N0	%65,2
-N1	%18,1
-N2	%16,7
Patoloji Tanısı	
Adenokarsinom	%38,5
Skvamöz Hücreli Karsinom	%31,1
3- Metastaz	%14,5
4-KHDAK	%8,8
5-Büyük Hücreli Karsinom	%1,4
6-Karsinoid Tümör	%0,8
7-Pleomorfik Karsinom	%0,4
8-Nöroendokrin Karsinom	%0,3
9-Diğer	%1,9
10-Mikst	%1,6
Lenfovasküler İnvazyon Varlığı%	%59,4
Yoğun Bakım Yatış İhtiyacı%	%9,33

6.1 Yapay Zeka Uygulamaları ile Postoperatif Yoğun Bakım Yatış Gereksinimi Tahmini

Hasta sayısı: 1457

Toplam yoğun bakım yatışı: 156


Eğitim: %80

Test: %20

Giriş Parametreleri:

1.Yaş, 2.Cinsiyet, 3.Sigara (P/Y)), 4.DM, 5.KOAH, 6.KAH, 7.HT, 8.Neoadjuvan tedavi alıp almadığı, 9.PLT/VATS (torakotomi mi VATS mı yapıldığı, 10.Operasyon tipi (rezeksiyon tipi), 11.LND (lenf nodu diseksiyonu) yapılıp yapılmaması, 12.FEV1, 13.FEV1/FVC, 14.FVC olarak 14 adet belirlendi.

Çıkış parametreleri: Yoğun bakım yatışı (yatar(1)/yatmaz(0)) olarak 1 adet belirlendi.



Şekil 1. Giriş parametreleri, çıkış parametreleri, makine öğrenme modeli.

		Predicted Class	
		P	N
Actual Class	P	True Positives (TP)	False Negatives (FN)
	N	False Positives (FP)	True Negatives (TN)

Şekil 2. Çıkan sonuçlar True positives (Doğru pozitifler, TP), False negatives (Yanlış yanlışlar, FN) False positives (yanlış pozitifler, FP) ve True negatives (Doğru yanlışlar, TN) şeklinde de ifade edilecektir.

$$Accuracy = \frac{TP + TN}{FP + FN + TP + TN}$$

Şekil 3. Accuracy (Doğruluk) hesaplanmasının formülü verilmiştir.


Recall: Pozitif durumların ne kadar başarılı tahmin edildiğini gösterir.

Precision: Pozitif olarak tahmin edilen bir durumdaki başarıyı gösteren durumlar


6.2. Lineer Kernel-SVM Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)

Tablo 9. SVM-Linear Kernel Yöntemi için sınıflandırma parametreleri sonucu. Yoğun bakıma yatmayacak hastaları belirlemede %95 başarılı olurken yatacak olan hastaları belirlemede başarılı olamadı. Doğruluk sonucu %91 olarak belirlendi.


	Precision	Recall	F1-Score	Support
Hayır-0	0.91	1.00	0.95	267
Evet-1	0.00	0.00	0.00	27
Doğruluk			0.91	294
Makro Ortalama	0.45	0.50	0.48	294
Ağırlıklı Ortalama	0.82	0.91	0.86	294




Şekil 4. Veri seti ile eğitilmiş Lineer Kernel-SVM yöntemi Yoğun Bakım Tahmini için Confussion Matriksi belirtilmiştir.



Şekil 5. Lineer Kernal-SVM yöntemi için Receiver Operating Characteristic Curve (ROC) eğrisi. Eğri altında kalan alan (EAA):0.59



Şekil 6. Lineer Kernal-SVM için karar ilişkili yoğunlaşma sonuç şekli. Vektörler arası ilişki doğrusal yorumlandı.




Şekil 7. Lineer Kernel-SVM için Eigen vektör ısı haritası. Sıcak renkler daha etkili olarak yorumlandı.

Lineer Kernel-SVM algoritması için cross validation uygulandı ve ortalama çapraz doğrulama puanı 0.8945, çapraz doğrulama puanının standart sapması ise 0.0038 oldu.


6.3. Lineer Regresyon Yöntemi Tahmin Sonuçları (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)

Tablo 10. Lineer Regresyon Yöntemi için sınıflandırma parametreleri sonucu. Yoğun bakıma yatmayacak hastaları belirlemede %94 başarılı olurken yatacak olan hastaları belirlemede %45 başarılı oldu. Doğruluk sonucu %89 olarak belirlendi.

	Precision	Recall	F1-Score	Support
Hayır-0	0.90	0.98	0.94	173
Evet-1	0.69	0.33	0.45	27
Doğruluk			0.89	200
Makro Ortalama	0.80	0.66	0.69	200
Ağırlıklı Ortalama	0.88	0.89	0.87	200



Şekil 8. Veri seti ile eğitilmiş Lineer Regresyon yöntemli Yoğun Bakım Tahmini için Confussion Matriksi




Şekil 9. Veri seti ile eğitilmiş Lineer Regresyon yöntemli Yoğun Bakım Tahmini için Eğri Altında kalan alan grafiği. Eğri altında kalan alan (EAA):0.86


6.4. Radial Basis SVM Korele Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)

Tablo 11. Radial Basis SVM Korele Yöntemi için sınıflandırma parametreleri sonucu. Yoğun bakıma yatmayacak hastaları belirlemede %92 başarılı olurken yatacak olan hastaları belirlemede %30 başarılı oldu. Doğruluk sonucu %86 olarak belirlendi.


	Precision	Recall	F1-Score	Support
Hayır-0	0.89	0.96	0.92	173
Evet-1	0.46	0.22	0.30	27
Doğruluk			0.86	200
Makro Ortalama	0.67	0.59	0.61	200
Ağırlıklı Ortalama	0.83	0.86	0.84	200



Şekil 10. Veri seti ile eğitilmiş Radial Basis SVM Korele yöntemli Yoğun Bakım Tahmini için Confussion Matriksi



Şekil 11. Veri seti ile eğitilmiş Radial Basis SVM Korele yöntemli Yoğun Bakım Tahmini için Eğri Altında kalan alan grafiği. Eğri altında kalan alan (EAA):0.72




Şekil 12. Radial Basis SVM Korele karar ilişkili yoğunlaşma sonuç şekli.

Random Forest algoritması için cross validation uygulandı ve ortalama çapraz doğrulama puanı 0.8463, çapraz doğrulama puanının standart sapması ise 0.0196 oldu.


6.5. Random Forest Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)

Tablo 12. Random Forest Yöntemi için sınıflandırma parametreleri sonucu. Yoğun bakıma yatmayacak hastaları belirlemede %95 başarılı olurken yatacak olan hastaları belirlemede %12 başarılı oldu. Doğruluk sonucu %90 olarak belirlendi.


	Precision	Recall	F1-Score	Support
Hayır-0	0.91	0.98	0.95	267
Evet-1	0.29	0.07	0.12	27
Doğruluk			0.90	294
Makro Ortalama	0.60	0.53	0.53	294
Ağırlıklı Ortalama	0.86	0.90	0.87	294




Şekil 13. Veri seti ile eğitilmiş Random Forest yöntemli Yoğun Bakım Tahmini için Confussion Matriksi



Şekil 14. Random Forest Yöntemi için ROC eğrisi. Eğri altında kalan alan (EAA):0.39



Şekil 15. Random Forest yöntemi için girdi parametrelerinin ağırlıkları



Şekil 16. Random Forest yöntemi için girdi parametrelerinin sonuca etki ağırlıkları.


Random Forest algoritması için cross validation uygulandı ve ortalama çapraz doğrulama puanı 0.8979, çapraz doğrulama puanının standart sapması ise 0.0132 oldu.

6.6. Linear Kernal SVM ve SMOTE Korele Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)


Tablo 13. Lineer Kernal SVM ve SMOTE korele yöntemi için sınıflandırma parametreleri sonucu.

Yoğun bakıma yatmayacak hastaları belirlemede %79 başarılı olurken yatacak olan hastaları belirlemede %80 başarılı oldu. Doğruluk sonucu %79 olarak belirlendi.


	Precision	Recall	F1-Score	Support
Hayır-0	0.83	0.76	0.79	271
Evet-1	0.76	0.83	0.80	257
Doğruluk			0.79	528
Makro Ortalama	0.80	0.79	0.79	528
Ağırlıklı Ortalama	0.80	0.79	0.79	528




Şekil 17. Lineer Kernal SVM ve SMOTE korele yöntemi için Confussion Matriksi



Şekil 18. Lineer Kernal SVM ve SMOTE korele yöntemi için ROC eğrisi. Eğri altında kalan alan (EAA):0.86



Şekil 19. Lineer Kernal SVM ve SMOTE korele karar ilişkili yoğunlaşma sonuç şekli.




Şekil 20. Lineer Kernal SVM ve SMOTE Korele Eigen vektör ısı haritası.

SVM algoritması için cross validation uygulandı ve ortalama çapraz doğrulama puanı 0,7943, çapraz doğrulama puanının standart sapması ise 0,0211 oldu.


6.7. SMOTE Sonrası Random FOREST Yöntemi (F1 skorları, doğruluk değeri, EAA, Çapraz doğrulama Puanı ve Çapraz Doğrulama Puanı Standart Sapması)

Tablo 14. SMOTE Sonrası Random FOREST yöntemi için sınıflandırma parametreleri sonucu. Yoğun bakıma yatmayacak hastaları belirlemede %91 başarılı olurken yatacak olan hastaları belirlemede %91 başarılı oldu. Doğruluk sonucu %91 olarak belirlendi.


	Precision	Recall	F1-Score	Support
Hayır-0	0.94	0.89	0.91	271
Evet-1	0.89	0.94	0.91	257
Doğruluk			0.91	528
Makro Ortalama	0.91	0.91	0.91	528
Ağırlıklı Ortalama	0.91	0.91	0.91	528




Şekil 21. Veri seti ile eğitilmiş SMOTE Sonrası Random FOREST Yöntemi Yoğun Bakım Tahmini için Confussion Matriksi



Şekil 22. SMOTE Sonrası Random FOREST yöntemi için ROC eğrisi. Eğri altında kalan alan (EAA):0,74 olarak hesaplandı.



Şekil 23. SMOTE Sonrası Random FOREST yöntemi için girdi parametrelerin ağırlıkları.



Şekil 24. SMOTE Sonrası Random FOREST yöntemi için girdi parametrelerin sonuca etki ağırlıkları.

SVM algoritması için cross validation uygulandı ve ortalama çapraz doğrulama puanı 0.9232, çapraz doğrulama puanının standart sapması ise 0.0165 oldu.

7. TARTIŞMA

Göğüs cerrahisi tarafından KHDAK tanısı ile opere edilen, akciğer rezeksiyonu yapılan hastaların ameliyat sonrası periyotta yoğun bakım ihtiyaçlarının olup olmamasının tespitinin doğru ve güvenilir biçimde yapılabilmesi mortalite, morbidite, sürdürülebilirlik, maliyet, hastane enfeksiyonları ve sosyal açılardan önem taşımaktadır.^{52,59,67,81,87}

İnsansı yapay zeka yazılımları, amaca yönelik geliştirilmiş makine öğrenme mekanizmaları medikal alanda, cerrahi alanda artan sıklıkla kullanımları ile hekimlere sahada yardımcı olmaktadır.^{3,89-91} Bu çalışma, küçük hücreli dışı akciğer kanseri (KHDAK) cerrahisi sonrası postoperatif süreçte yoğun bakım gereksinimini tahmin etmek amacıyla yapay zeka (YZ) algoritmalarının kullanımını incelemektedir. Çalışmada, 1456 hastanın retrospektif verileri kullanılarak 6(altı) farklı yapay zeka algoritması test edilmiş ve bu algoritmaların yoğun bakım yatışı gerekliliği üzerindeki tahmin performansları yüksek doğruluk ve güvenilirlikle tespit edilmiştir. Elde edilen bulgular, YZ teknolojilerinin göğüs cerrahisinde ameliyat sonrası süreçte önemli bir rol oynayabileceğini göstermektedir. Yoğun bakım yatışının doğru ve güvenilir tahmin edilme durumu, özellikle ameliyat sonrası süreçte etkili olmak üzere ameliyat öncesi süreci de kapsayarak erken, doğru ve güvenli karar verilmesinde önemli olabilir.^{110,111} Göğüs cerrahisi ameliyatlarından sonra hasta takibinin dikkatli ve özenli yapılması gerekmektedir ve postoperatif yoğun bakım ihtiyacı gerekliliği hastanın ek komorbiditeleri, yapılan cerrahi ve hekim kararına göre değişmektedir.^{52,72,74,81,83,85} . Ameliyat öncesi dönemde, yoğun bakım yatış ihtiyacının objektif kriterlere dayalı olarak tahmin edilmesi, yoğun bakım ünitesinin hazırlanmasına ve hasta ile yakınlarının bu sürece psikolojik ve fiziksel olarak hazırlanmasına önemli katkılar sağlar. Göğüs cerrahisi sonrası yoğun bakım gereksinimi, zaman içinde değişiklik göstermiştir. Örneğin, 1990'larda göğüs cerrahisi geçiren tüm hastalar ileri düzey yoğun bakım ünitelerinde takip edilirken, günümüzde bu hastaların büyük bir kısmı ara düzey yoğun bakım üniteleri olarak adlandırılan (PACU-Anestezi Sonrası Bakım Ünitesi) birimlerde takip edilmektedir. Bu değişim, tıbbi yaklaşımların ve teknolojinin gelişmesiyle birlikte ortaya çıkmıştır.^{52,81} . Göğüs cerrahisinde ERAS protokollerinin yaygınlaşmasıyla birlikte, yoğun bakım ihtiyacı olmayan hastaların yoğun bakıma alınmasının gereksiz olduğu ve hatta ek

komplikasyonlara yol açabileceği görüşü de savunulmaktadır¹¹⁰. Ancak unutulmamalıdır ki yoğun bakım yatışı ihtiyacı olan hastaların bu hizmeti almamaları morbidite ve mortalitede artışa neden olacaktır^{52,81}. Postoperatif dönemde komplikasyon gelişme riski yüksek olan hastalarda, ameliyat öncesi süreçte pulmoner rehabilitasyona ve ameliyat hazırlığına özel bir önem verilebilir ve bu titizlik ameliyat sonrası dönemde de korunabilir.⁷² Derin öğrenme algoritmaları, yüksek doğruluk ve başarı oranıyla postoperatif pulmoner komplikasyonların ortaya çıkma olasılığını öngörerek, hastaların ameliyat öncesi dönemde düşük riskli ve yüksek riskli gruplar halinde sınıflandırılmasına önemli bir katkı sağlar. Düşük riskli olarak belirlenen hastalarda, standart ERAS protokollerinin uygulanması sayesinde komplikasyon riski en aza indirilerek, sorunsuz bir postoperatif süreç tamamlanabilir.^{55,110}. Tahmin sonrası yüksek riskli tespit edilen hastalar için preoperatif, perioperatif ve postoperatif dönemde daha dikkatli davranılmalıdır. Preoperatif dönemde cerrahiye daha dikkatli hazırlık yapılmalıdır, hastaya ait mevcut risklerin ortadan kaldırılması sağlanmalıdır, örneğin aktif sigara kullanan hastanın cerrahiden önce sigara kullanımını sonlandırması sağlanmalıdır⁵⁵. Ameliyat sırasında, cerrahi yöntemlerin ve kullanılan malzemelerin seçiminde dikkatli davranılabilir⁶⁷. Ameliyat sonrasında ise hastaların erken mobilizasyonu ve solunum fizyoterapisinin zamanında başlatılması gibi önlemlerle, yüksek risk grubundaki hastalarda akciğer komplikasyonlarının önüne geçilebilir veya bu sorunların etkisi hafifletilebilir.^{56,72} Minimal invaziv yöntemlerin veya parankim koruyucu tekniklerin akla getirilmesi, kullanılacaksa kalın doku zımbalarının kullanılması, pulmoner doku yapıştırıcılarının, doku örtülerin kullanılması unutulmamalıdır^{64,65,67}.

Bütün sebeplerden ötürü hastaların yoğun bakıma çıkıp çıkmayacaklarını doğru, güvenilir, sürdürülebilir ve pratikte uygulanabilir şekilde tahmin etmek çok önemlidir. Hastalara ait, Yaş, cinsiyet, sigara (p/y), DM, KOAH, KAH, HT, neoadjuvan tedavi alıp almadığı, PLT/VATS(torakotomi mi VATS mı yapıldığı), Rezeksiyon tipi, LND(lenf nodu diseksiyonu) yapılıp yapılmaması, FEV1, FEV1/FVC, FVC girdi değerleri kullanılarak, SVM-Linear Kernel , Random Forest sınıflandırma, SMOTE Sonrası SVM-Linear Kernel, SMOTE Sonrası Random FOREST yöntemi, Lineer Regresyon ve Radial Basis SVM Korele Yöntemleri ile veri setlerimizi değerlendirmek için 6 farklı yapay zeka algoritması denedik. Her biri kendi içerisinde analiz, sınıflandırma ve sonuç aşamalarını doğru olarak ilerletti. Çalışmamızda SVM-Linear Kernel yöntemi için F1 skoru yoğun

bakıma yatmayacak hastaları belirlemede %95, yoğun bakıma yatacak hastaları belirlemede %0 başarı gösterdi. Doğruluk oranı %91, ROC ise %59 idi. Random Forest sınıflandırma yöntemi için F1 skoru yoğun bakıma yatmayacak hastaları belirlemede %95, yoğun bakıma yatacak hastaları belirlemede %12 başarı gösterdi. Doğruluk oranı %90, ROC ise %39 idi. SMOTE Sonrası SVM-Linear Kernel yöntemi için F1 skoru yoğun bakıma yatmayacak hastaları belirlemede %79, yoğun bakıma yatacak hastaları belirlemede %80 başarı gösterdi. Doğruluk oranı %79, ROC ise %86 idi. Lineer Regresyon yöntemi için F1 skoru yoğun bakıma yatmayacak hastaları belirlemede %94, yoğun bakıma yatacak hastaları belirlemede %45 başarı gösterdi. Doğruluk oranı %84 idi. Radial Basis SVM Korele yöntemi için F1 skoru yoğun bakıma yatmayacak hastaları belirlemede %92, yoğun bakıma yatacak hastaları belirlemede %30 başarı gösterdi. Doğruluk oranı %86, ROC ise %72 idi. SMOTE Sonrası Random Forest sınıflandırma yöntemi için F1 skoru yoğun bakıma yatmayacak hastaları belirlemede %91, yoğun bakıma yatacak hastaları belirlemede %91 başarı gösterdi. Doğruluk oranı %91, ROC ise %75 idi. SMOTE Sonrası Random FOREST sınıflandırma yöntemi için girdi parametrelerinde ağırlık derecesinde ilk sıralarda SİĞARA, FEV, FVC, KOAH ve YAŞ tespit edildi. (Şekil 23). SMOTE Sonrası Random FOREST sınıflandırma yöntemi için girdi parametrelerin sonuca etki ağırlıklarında ise Kadın cinsiyette olmanın, yüksek FEV1 değerine sahip olmanın(yüksek solunum kapasitesi) yüksek FEV/FVC değerine sahip olmanın(KOAH tanısından uzaklaştırmaktadır olarak yorumlandı.⁶²),neoadjuvan tedavi almış olmanın, minimal invaziv cerrahi yöntem uygulanmasının yoğun bakıma çıkmama yönünde sonuca etki ettiği bunlara karşılık erkek olmanın, ileri yaşta olmanın, sigara içiyor olmanın, DM hastası olmanın, KOAH hastası olmanın sonuca yoğun bakıma çıkma yönünde etki ettiği belirlenmiştir.

SMOTE (Synthetic Minority Over-Sampling Technique) ile birlikte Random Forest sınıflandırma yöntemi, postoperatif pulmoner komplikasyon tahmini için değerinin %91 olması ve ROC eğrisinde eğri altında kalan alanın %75 olması, ortalama çapraz doğrulama puanının 0.9232 olması, standart sapmasının ise 0.0165 olması bu algoritmanın diğerleri ile kıyaslandığında daha yüksek doğruluk ve daha yüksek başarı değerleri ile daha doğru tahmin gerçekleştirdiğini göstermektedir. Bu sonuçlar, SMOTE Sonrası Random Forest algoritmasının dengesiz veri setlerinde bile yüksek performans gösterdiğini ve özellikle azınlık sınıfını (yoğun bakıma yatacak hastalar) doğru bir şekilde

tahmin etme konusunda tarafsız biçimde başarılı olduğunu göstermektedir.^{100,101,109} Diğer algoritma yöntemleri de kabul edilebilir doğruluk oranları sunmuştur. Ancak, bu algoritmalar özellikle yoğun bakıma yatacak hastaları tahmin etmede daha düşük performans göstermiştir. Örneğin, Lineer Regresyon yöntemi, yoğun bakıma yatmayacak hastaları %94 doğrulukla tahmin ederken, yatacak hastaları yalnızca %45 doğrulukla tahmin edebilmiştir. Bu durum, dengesiz veri setlerinde Lineer Regresyon gibi geleneksel yöntemlerin sınırlı kaldığını göstermektedir⁹⁵. SMOTE tekniği, dengesiz veri setlerinde azınlık sınıfını dengelemek için kullanılan etkili bir yöntemdir.^{100,109} Elimizdeki verisetinde yoğun bakıma yatacak olan hasta sayısının yatmayacak olanlara olan oranı sonucu ortaya çıkan dengesizlik durumu yapay zeka eğitim ve karar verme mekanizmalarını olumsuz etkilemiştir. Bu sorunu ortadan kaldırmak için kullandığımız SMOTE yöntemi eldeki verisetini çoğaltmak yerine genişletmeyi hedefler. Bunu yaparken de aritmetik ortalama, mod, medyan, standart sapma gibi sonuca etki edebilecek sabitlere sadık kalarak makine öğrenmesine sunulan örneklemin yetersiz kaldığı durumlarda verisetini düzeltmeden, özelleştirmeden, istenilen sonucun ne olduğunu bilmeden genişletir.^{100,101,109} Karşılaştırılacak 2 grup arasında azınlık olan tarafı çoğunluk olan tarafla dengelemek şeklinde de yorumlanabilir. Sonuca etki etmez ve taraf tutmaz.^{100,101} İyi olarak nitelendirilebilecek özelliklerinin yanı sıra YZ modellerinin klinik uygulamalara entegrasyonu bazı zorluklar da barındırmaktadır. Öncelikle, bu modellerin eğitimi için büyük ve kaliteli veri setlerine ihtiyaç vardır. Ayrıca, modellerin doğruluğu ve güvenilirliği, farklı hasta popülasyonlarında test edilmelidir. Bu çalışmada kullanılan veri seti, tek bir merkezden toplanmıştır ve bu nedenle genellenebilirliği sınırlı olabilir. Gelecekte, daha geniş ve çok merkezli veri setleri kullanılarak YZ modellerinin performansı daha da artırılabilir.⁵

Bu çalışmada, KHDAK ameliyatları sonrası yoğun bakım ihtiyacının belirlenmesinde SMOTE sonrası kullanılan algoritmaların performansı, dengesiz veri setlerinde daha iyi sonuçlar vermiştir. Özellikle, SMOTE Sonrası kullanılan Random Forest algoritması hem yoğun bakıma yatacak hem de yatmayacak hastaları yüksek doğrulukla tahmin edebilmiştir. Bu bulgular, SMOTE'un dengesiz veri setlerinde YZ modellerinin performansını artırmada önemli bir araç olduğunu göstermektedir. Ortaya çıkardığımız YZ modeli ile genel kaniya varan ölçüm ve tahmin araçlarından ziyade hastaya spesifik, her hastayı kendi özelinde değerlendirebilen nesnel, tekrarlanabilir,

ulařılabilirlięi ve srdrlebilirlięi yksek, maliyet etkin bir algoritma oluřturmaya alıřırken gvenilirlięi ve doęruluęu n planda tutma amacımız elde ettięimiz sonularla desteklenmektedir. Bu alıřma, YZ algoritmalarının KHDAK cerrahisi sonrası postoperatif sreteki komplikasyonları ve yoęun bakım gereksinimini tahmin etmede etkili bir ara olabileceęini gstermektedir. zellikle, SMOTE Sonrası kullanılan Random Forest algoritması, dengesiz veri setlerinde yksek doęruluk oranları sunmuřtur. Bu tr modeller, klinisyenlere cerrahi ncesi ve sonrası dnemde hastaların risk profillerini belirlemede yardımcı olabilir ve postoperatif yoęun bakım kararlarını optimize edebilir. YZ modellerinin klinik uygulamalara entegrasyonu iin daha fazla arařtırma ve geliřtirme alıřmasına ihtiya vardır. zellikle, ok merkezli ve geniř hasta poplasyonlarını ieren veri setleri kullanılarak modellerin doęruluęu ve gvenilirlięi artırılmalıdır. Ayrıca, bu modellerin klinik pratikte nasıl kullanılacağına dair protokoller ve rehberler geliřtirilmelidir. Sonu olarak, YZ teknolojileri, gęs cerrahisi sonrası postoperatif sreteki komplikasyonları ve yoęun bakım gereksinimini tahmin etmede nemli bir potansiyele sahiptir. Bu tr modeller, klinisyenlere karar verme srelerinde destek olabilir zamanın ve kaynakların doęru, efektif kullanılmasına katkı saęlayabilir, hastalar ve hekimler iin daha objektif somut veriler oluřturulmasını saęlayabilir ve hastaların yařam kalitesini artırabilir.

8. SONUÇ VE ÖNERİLER

Erken evre, rezektabl lokal ileri evre KHDAK grubunda cerrahi tedavi etkindir. Akciğer rezeksiyonu ve sistematik mediastinal lenf nodu diseksiyonu KHDAK cerrahisinin temelini oluşturur. Bu durumla beraber ortaya çıkan ameliyat sonrası dönem için yoğun bakım ihtiyacı titizlikle değerlendirilmelidir.

Göğüs cerrahisi tarafından KHDAK tanısı ile akciğer rezeksiyonu yapılan hastaların ameliyat sonrası periyotta yoğun bakım ihtiyaçlarının olup olmamasının tespitinin doğru ve güvenilir biçimde yapılabilmesi mortalite, morbidite, sürdürülebilirlik, maliyet, hastane enfeksiyonları ve sosyal açılardan önem taşımaktadır.

Hedef odaklı olarak tasarlanan makine öğrenme sistemleri ve insansı yapay zeka yazılımları, tıp ve cerrahi alanlarında giderek artan bir şekilde kullanılarak hekimlere pratikte önemli fayda sağlamaktadır. Perioperatif, preoperatif ve post operatif süreçlerin etkin ve güvenilir biçimde yönetilmesinde derin öğrenme uygulamaları, makine bazlı öğrenme mekanizmaları katkı sağlamaktadır.

Ameliyat sonrası dönemde özellikle yüksek riskli gruptaki hastalar için hayati önem arz eden, yanlış karar verilmesi durumunda morbidite ve mortaliteyi artıran yoğun bakım ihtiyacı durumunun doğru ve güvenilir olarak tahmin edilmesinde modellerimiz yüksek doğrulukla tahmin oranı göstererek objektif, düşük maliyetli, hastaya spesifik, sürdürebilir ve başarılı oldukları gösterilmiştir. Aynı zamanda karar verilmesi zor hastalarda ve gereksiz yoğun bakım yatışlarının değerlendirilmesinde de etkin biçimde rol oynayarak kaynakların doğru kullanılmasına katkı sağlar.

Çalışmamızda elde edilen veriler doğrultusunda KHDAK nedeni ile opere edilen hastaların yoğun bakım ihtiyaçlarının belirlenmesi için geliştirilen makine bazlı yapay zeka öğrenme mekanizmaları hekimlere yardımcı olacak ve klinik pratikte uygulanabilir olan arayüzü ile günlük rutinde yer alacaktır.

Çalışmamız, multidisipliner alanların dahil edilmesi, daha güncel teknolojilerin kullanılması ve zamanla daha yüksek sayıda ve yeni başlıklarda veri girişinin yapılabilmesi ile iyileştirilip amacına daha iyi hizmet etmeye devam edecektir.

KAYNAKÇA

1. **Schabath, M. B. & Cote, M. L.** Cancer Progress and Priorities: Lung Cancer. *Cancer Epidemiol Biomarkers Prev* **28**, 1563–1579 (2019).
2. **Bray Bsc, F. et al.** Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA Cancer J Clin* **74**, 229–263 (2024).
3. **Bhinder, B., Gilvary, C., Madhukar, N. S. & Elemento, O.** Artificial Intelligence in Cancer Research and Precision Medicine. *Cancer Discov* **11**, 900–915 (2021).
4. **Singh, S. P. et al.** 3D Deep Learning on Medical Images: A Review. *Sensors (Basel)* **20**, 1–24 (2020).
5. **khan, B. et al.** Drawbacks of Artificial Intelligence and Their Potential Solutions in the Healthcare Sector. *Biomedical Materials and Devices* vol. 1 731–738 Preprint at <https://doi.org/10.1007/s44174-023-00063-2> (2023).
6. **Esteva, H., Marchevsky, A., Núñez, T., Luna, C. & Esteva, M.** Neural networks as a prognostic tool of surgical risk in lung resections. *Ann Thorac Surg* **73**, 1576–1581 (2002).
7. **Vineis, P.** Definition and classification of cancer: monothetic or polythetic? *Theor Med* **14**, 249–256 (1993).
8. Epidemiology of lung cancer-Web of Science Core Collection. <https://www.webofscience.com/wos/woscc/full-record/WOS:000262352900003>.
9. **Tandberg, D. J., Tong, B. C., Ackerson, B. G. & Kelsey, C. R.** Surgery versus stereotactic body radiation therapy for stage I non-small cell lung cancer: A comprehensive review. *Cancer* **124**, 667–678 (2018).
10. **Allemani, C. et al.** Global surveillance of cancer survival 1995-2009: analysis of individual data for 25,676,887 patients from 279 population-based registries in 67 countries (CONCORD-2). *Lancet* **385**, 977–1010 (2015).
11. **Sheng, L. et al.** A meta-analysis of the relationship between environmental tobacco smoke and lung cancer risk of nonsmoker in China. *Medicine* **97**, (2018).
12. **Laisaar, T., Sarana, B., Benno, I. & Laisaar, K. T.** Surgically treated lung cancer patients: do they all smoke and would they all have been detected with lung cancer screening? *ERJ Open Res* **4**, 00001–02018 (2018).
13. **Rota, M., Bosetti, C., Boccia, S., Boffetta, P. & La Vecchia, C.** Occupational exposures to polycyclic aromatic hydrocarbons and respiratory and urinary tract cancers: an updated systematic review and a meta-analysis to 2014. *Arch Toxicol* **88**, 1479–1490 (2014).
14. **Tesema, G. A. et al.** Geographic variation in delay to surgical treatment among non-small cell lung cancer patients. *Lung Cancer* **199**, (2025).
15. **Bade, B. C. & Dela Cruz, C. S.** Lung Cancer 2020: Epidemiology, Etiology, and Prevention. *Clin Chest Med* **41**, 1–24 (2020).
16. **Rivera, M. P. & Stover, D. E.** Gender and lung cancer. *Clin Chest Med* **25**, 391–400 (2004).
17. **Risch, A. & Plass, C.** Lung cancer epigenetics and genetics. *Int J Cancer* **123**, 1–7 (2008).

18. **Tsao, M. S., Nicholson, A. G., Maleszewski, J. J., Marx, A. & Travis, W. D.** Introduction to 2021 WHO Classification of Thoracic Tumors. *Journal of Thoracic Oncology* **17**, e1–e4 (2022).
19. **Alexander, M., Kim, S. Y. & Cheng, H.** Update 2020: Management of Non-Small Cell Lung Cancer. *Lung* **198**, 897–907 (2020).
20. **Chen, P., Liu, Y., Wen, Y. & Zhou, C.** Non-small cell lung cancer in China. *Cancer Commun (Lond)* **42**, 937–970 (2022).
21. **Ganti, A. K., Klein, A. B., Cotarla, I., Seal, B. & Chou, E.** Update of Incidence, Prevalence, Survival, and Initial Treatment in Patients With Non-Small Cell Lung Cancer in the US. *JAMA Oncol* **7**, 1824–1832 (2021).
22. **Neumann, J. M. et al.** Subtyping non-small cell lung cancer by histology-guided spatial metabolomics. *J Cancer Res Clin Oncol* **148**, 351–360 (2022).
23. **Nicholson, A. G. et al.** The 2021 WHO Classification of Lung Tumors: Impact of Advances Since 2015. *Journal of Thoracic Oncology* **17**, 362–387 (2022).
24. **Relli, V., Trerotola, M., Guerra, E. & Alberti, S.** Abandoning the Notion of Non-Small Cell Lung Cancer. *Trends Mol Med* **25**, 585–594 (2019).
25. **Goldstraw, P. et al.** The IASLC Lung Cancer Staging Project: Proposals for Revision of the TNM Stage Groupings in the Forthcoming (Eighth) Edition of the TNM Classification for Lung Cancer. *J Thorac Oncol* **11**, 39–51 (2016).
26. **Feng, S. H. & Yang, S. T.** The new 8th TNM staging system of lung cancer and its potential imaging interpretation pitfalls and limitations with CT image demonstrations. *Diagn Interv Radiol* **25**, 270–279 (2019).
27. **Rami-Porta, R. et al.** The International Association for the Study of Lung Cancer Lung Cancer Staging Project: Proposals for Revision of the TNM Stage Groups in the Forthcoming (Ninth) Edition of the TNM Classification for Lung Cancer. *Journal of Thoracic Oncology* **19**, 1007–1027 (2024).
28. **Detterbeck, F. C. et al.** The Proposed 9th Edition TNM Classification of Lung Cancer. *Chest* **166**, 882–895 (2024).
29. **Huang, J. et al.** The International Association for the Study of Lung Cancer Staging Project for Lung Cancer: Proposals for the Revision of the N Descriptors in the Forthcoming Ninth Edition of the TNM Classification for Lung Cancer. *J Thorac Oncol* **19**, 766–785 (2024).
30. **Chansky, K. et al.** The IASLC Lung Cancer Staging Project: External Validation of the Revision of the TNM Stage Groupings in the Eighth Edition of the TNM Classification of Lung Cancer. *J Thorac Oncol* **12**, 1109–1121 (2017).
31. **Petrella, F. et al.** Stage III Non-Small-Cell Lung Cancer: An Overview of Treatment Options. *Current Oncology* **30**, 3160 (2023).
32. **Postmus, P. E. et al.** Early and locally advanced non-small-cell lung cancer (NSCLC): ESMO Clinical Practice Guidelines for diagnosis, treatment and follow-up. *Ann Oncol* **28**, iv1–iv21 (2017).
33. **Chaft, J. E. et al.** Evolution of systemic therapy for stages I-III non-metastatic non-small-cell lung cancer. *Nat Rev Clin Oncol* **18**, 547–557 (2021).
34. **Dohopolski, M., Gottumukkala, S., Gomez, D. & Iyengar, P. Radiation** Therapy in Non-Small-Cell Lung Cancer. *Cold Spring Harb Perspect Med* **11**, (2021).

35. Hill, M. A. & Gibney, B. C. Wedge resection—finding its place in early-stage non-small cell lung cancer? *J Thorac Dis* **15**, 2902–2904 (2023).
36. Bian, D. *et al.* The efficacy and safety of wedge resection for peripheral stage IA lung adenocarcinoma: a real-world study based on a single center. *J Thorac Dis* **15**, 54–64 (2023).
37. Matsuo, T. *et al.* Outcomes and pulmonary function after sleeve lobectomy compared with pneumonectomy in patients with non-small cell lung cancer. *Thorac Cancer* **14**, 827–833 (2023).
38. Alexiou, C. *et al.* Pneumonectomy for non-small cell lung cancer: predictors of operative mortality and survival. *Eur J Cardiothorac Surg* **20**, 476–480 (2001).
39. Bagan, P. *et al.* Sleeve lobectomy versus pneumonectomy: tumor characteristics and comparative analysis of feasibility and results. *Ann Thorac Surg* **80**, 2046–2050 (2005).
40. Deslauriers, J. *et al.* Sleeve lobectomy versus pneumonectomy for lung cancer: A comparative analysis of survival and sites of recurrences. *Annals of Thoracic Surgery* **77**, 1152–1156 (2004).
41. Zhang, O. *et al.* Complications of Robotic Video-Assisted Thoracoscopic Surgery Compared to Open Thoracotomy for Resectable Non-Small Cell Lung Cancer. *J Pers Med* **12**, (2022).
42. Wei, S., Chen, M., Chen, N. & Liu, L. Feasibility and safety of robot-assisted thoracic surgery for lung lobectomy in patients with non-small cell lung cancer: a systematic review and meta-analysis. *World J Surg Oncol* **15**, (2017).
43. Zhu, M., Fu, X. N. & Chen, X. Lobectomy by video-assisted thoracoscopic surgery (VATS) for early stage of non-small cell lung cancer. *Front Med* **5**, 53–60 (2011).
44. Veronesi, G. Robotic thoracic surgery: technical considerations and learning curve for pulmonary resection. *Thorac Surg Clin* **24**, 135–141 (2014).
45. Chung, J. H. *et al.* Uniportal video-assisted thoracoscopic lobectomy: An alternative to conventional thoracoscopic lobectomy in lung cancer surgery? *Interact Cardiovasc Thorac Surg* **20**, 813–819 (2015).
46. Molina, J. R., Yang, P., Cassivi, S. D., Schild, S. E. & Adjei, A. A. Non-small cell lung cancer: epidemiology, risk factors, treatment, and survivorship. *Mayo Clin Proc* **83**, 584–594 (2008).
47. Burdett, S. *et al.* Adjuvant chemotherapy for resected early-stage non-small cell lung cancer. *Cochrane Database Syst Rev* **2015**, (2015).
48. Kang, J., Zhang, C. & Zhong, W. Z. Neoadjuvant immunotherapy for non-small cell lung cancer: State of the art. *Cancer Commun (Lond)* **41**, 287–302 (2021).
49. Lahiri, A. *et al.* Lung cancer immunotherapy: progress, pitfalls, and promises. *Mol Cancer* **22**, (2023).
50. Remon, J., Soria, J. C. & Peters, S. Early and locally advanced non-small-cell lung cancer: an update of the ESMO Clinical Practice Guidelines focusing on diagnosis, staging, systemic and local therapy. *Ann Oncol* **32**, 1637–1642 (2021).
51. Cortiula, F. *et al.* Immunotherapy in unresectable stage III non-small-cell lung cancer: state of the art and novel therapeutic approaches. *Annals of Oncology* **33**, 893–908 (2022).
52. Fontana, V. *et al.* [The role of the intensive care unit after thoracic surgery]. *Rev Mal Respir* **39**, 40–54 (2022).

53. Rotman, J. A. *et al.* Postoperative complications after thoracic surgery for lung cancer. *Clin Imaging* **39**, 735–749 (2015).
54. Templeton, R. & Greenhalgh, D. Preoperative rehabilitation for thoracic surgery. *Curr Opin Anaesthesiol* **32**, 23–28 (2019).
55. Rogers, L. J. *et al.* The impact of enhanced recovery after surgery (ERAS) protocol compliance on morbidity from resection for primary lung cancer. *Journal of Thoracic and Cardiovascular Surgery* **155**, 1843–1852 (2018).
56. Hata, A., Sekine, Y., Kota, O., Koh, E. & Yoshino, I. Impact of combined pulmonary fibrosis and emphysema on surgical complications and long-term survival in patients undergoing surgery for non-small-cell lung cancer. *Int J Chron Obstruct Pulmon Dis* **11**, 1261–1268 (2016).
57. Saji, H. *et al.* A proposal for a comprehensive risk scoring system for predicting postoperative complications in octogenarian patients with medically operable lung cancer: JACS1303. *Eur J Cardiothorac Surg* **53**, 835–841 (2018).
58. Lugg, S. T. *et al.* Long-term impact of developing a postoperative pulmonary complication after lung surgery. *Thorax* **71**, 171–176 (2016).
59. Okada, S. *et al.* Clinical significance of postoperative pulmonary complications in elderly patients with lung cancer. *Interact Cardiovasc Thorac Surg* **35**, ivac153 (2022).
60. Su, X. E. *et al.* Recent advances in postoperative pulmonary rehabilitation of patients with non-small cell lung cancer (Review). *Int J Oncol* **61**, 156 (2022).
61. Yasuura, Y. *et al.* Quantitative computed tomography for predicting cardiopulmonary complications after lobectomy for lung cancer in patients with chronic obstructive pulmonary disease. *Gen Thorac Cardiovasc Surg* **67**, 697–703 (2019).
62. Stolz, D. *et al.* Towards the elimination of chronic obstructive pulmonary disease: a Lancet Commission. *The Lancet* vol. 400 921–972 Preprint at [https://doi.org/10.1016/S0140-6736\(22\)01273-9](https://doi.org/10.1016/S0140-6736(22)01273-9) (2022).
63. Kepičová, M. *et al.* Risk Factors and Postoperative Complications of Lobectomy for Non-Small Cell Lung Cancer: An Exploratory Analysis of Premedication and Clinical Variables. *Medicina (Kaunas)* **60**, (2024).
64. Ng, T., Ryder, B. A., Machan, J. T. & Cioffi, W. G. Decreasing the incidence of prolonged air leak after right upper lobectomy with the anterior fissureless technique. *J Thorac Cardiovasc Surg* **139**, 1007–1011 (2010).
65. Li, S. J. *et al.* Fat-free mass index is superior to body mass index as a novel risk factor for prolonged air leak complicating video-assisted thoracoscopic surgery lobectomy for non-small-cell lung cancer. *J Thorac Dis* **11**, 2006–2023 (2019).
66. Cerfolio, R. J. Advances in thoracostomy tube management. *Surg Clin North Am* **82**, 833–848 (2002).
67. Brunelli, A., Cassivi, S. D. & Halgren, L. Risk factors for prolonged air leak after pulmonary resection. *Thorac Surg Clin* **20**, 359–364 (2010).
68. Simonsen, D. F., Søgaard, M., Bozi, I., Horsburgh, C. R. & Thomsen, R. W. Risk factors for postoperative pneumonia after lung cancer surgery and impact of pneumonia on survival. *Respir Med* **109**, 1340–1346 (2015).

69. Lee, J. Y. *et al.* Risk Factors of Postoperative Pneumonia after Lung Cancer Surgery. *J Korean Med Sci* **26**, 979 (2011).
70. Parsons, A., Daley, A., Begh, R. & Aveyard, P. Influence of smoking cessation after diagnosis of early stage lung cancer on prognosis: systematic review of observational studies with meta-analysis. *BMJ* **340**, 251 (2010).
71. Yao, L. *et al.* Risk factors for postoperative pneumonia and prognosis in lung cancer patients after surgery: A retrospective study. *Medicine* **100**, e25295 (2021).
72. Pu, C. Y. *et al.* Effects of Preoperative Breathing Exercise on Postoperative Outcomes for Patients With Lung Cancer Undergoing Curative Intent Lung Resection: A Meta-analysis. *Archives of Physical Medicine and Rehabilitation* vol. 102 2416-2427.e4 Preprint at <https://doi.org/10.1016/j.apmr.2021.03.028> (2021).
73. Berriós-Torres, S. I. *et al.* Centers for Disease Control and Prevention Guideline for the Prevention of Surgical Site Infection, 2017. *JAMA Surg* **152**, 784–791 (2017).
74. Zhao, Y., Zheng, R., Xiang, W., Ning, D. & Li, Z. Systematic review and meta-analysis on perioperative intervention to prevent postoperative atelectasis complications after thoracic surgery. *Ann Palliat Med* **10**, 10726–10734 (2021).
75. Villeneuve, P. J. Interventions to avoid pulmonary complications after lung cancer resection. *J Thorac Dis* **10**, S3781–S3788 (2018).
76. Tokunaga, Y., Kita, Y. & Okamoto, T. Analysis of Risk Factors for Bronchopleural Fistula after Surgical Treatment of Lung Cancer. *Annals of Thoracic and Cardiovascular Surgery* **26**, 311 (2020).
77. Seok, Y., Cho, S. & Lee, E. Bronchial stump coverage with fibrin glue-coated collagen fleece in lung cancer patients who underwent pneumonectomy. *Ann Thorac Cardiovasc Surg* **20**, 117–122 (2014).
78. Yang, Y. H. *et al.* Postoperative bronchopleural fistula repair: Surgical outcomes and adverse factors for its success. *Thorac Cancer* **13**, 1401–1405 (2022).
79. M, L. & M, N. Bronchopleural fistulas: an overview of the problem with special focus on endoscopic management. *Chest* **128**, 76–79 (2005).
80. Bribriesco, A. & Patterson, G. A. Management of Postpneumonectomy Bronchopleural Fistula: From Thoracoplasty to Transsternal Closure. *Thorac Surg Clin* **28**, 323–335 (2018).
81. Okiror, L. *et al.* Predicting risk of intensive care unit admission after resection for non-small cell lung cancer: a validation study. *Interact Cardiovasc Thorac Surg* **14**, 31–33 (2012).
82. Etienne, H. & Assouad, J. Thoracic surgery and co-morbid patients. *Rev Mal Respir* **38**, 743–753 (2021).
83. Wolters, U., Wolf, T., Stützer, H. & Schröder, T. ASA classification and perioperative variables as predictors of postoperative outcome. *Br J Anaesth* **77**, 217–222 (1996).
84. Charlson, M. E., Pompei, P., Ales, K. L. & MacKenzie, C. R. A new method of classifying prognostic comorbidity in longitudinal studies: development and validation. *J Chronic Dis* **40**, 373–383 (1987).
85. Mazo, V. *et al.* Prospective external validation of a predictive score for postoperative pulmonary complications. *Anesthesiology* **121**, 219–231 (2014).

86. Lee, T. H. *et al.* Derivation and prospective validation of a simple index for prediction of cardiac risk of major noncardiac surgery. *Circulation* **100**, 1043–1049 (1999).
87. Muñoz de Cabo, C., Hermoso Alarza, F., Cossio Rodriguez, A. M. & Martín Delgado, M. C. Perioperative management in thoracic surgery. *Med Intensiva* **44**, 185–191 (2020).
88. McCulloch, W. S. & Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys* **5**, 115–133 (1943).
89. Lidströmer, N., Aresu, F. & Ashrafiyan, H. Basic Concepts of Artificial Intelligence: Primed for Clinicians. *Artif Intell Med* 3–20 (2022) doi:10.1007/978-3-030-64573-1_1.
90. Gupta, R. *et al.* Artificial intelligence to deep learning: machine intelligence approach for drug discovery. *Molecular Diversity* 2021 25:3 **25**, 1315–1360 (2021).
91. Haug, C. J. & Drazen, J. M. Artificial Intelligence and Machine Learning in Clinical Medicine, 2023. *N Engl J Med* **388**, 1201–1208 (2023).
92. Badillo, S. *et al.* An Introduction to Machine Learning. *Clin Pharmacol Ther* **107**, 871–885 (2020).
93. Aggarwal, M. & Murty, M. N. Deep Learning. *SpringerBriefs in Applied Sciences and Technology* 35–66 (2021) doi:10.1007/978-981-33-4022-0_3.
94. Schmidhuber, J. Deep Learning in neural networks: An overview. *Neural Networks* **61**, 85–117 (2015).
95. Kowatsch, D., Müller, N. M., Tschärke, K., Sperl, P. & Böttinger, K. Imbalance in Regression Datasets. (2024).
96. Kilic, S. Linear regression analysis. *Journal of Mood Disorders* **3**, 90 (2013).
97. Powell, M. J. D. Restart procedures for the conjugate gradient method. *Math Program* **12**, 241–254 (1977).
98. Kumral, C. D., Topal, A., Ersoy, M., Çolak, R. & Yiğit, T. Performing Performance Analysis by Implementing Random Forest Algorithm on FPGA. *El-Cezeri Journal of Science and Engineering* **9**, 1315–1327 (2022).
99. Denil, M. & Trappenberg, T. Overlap versus imbalance. in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* vol. 6085 LNAI 220–231 (2010).
100. Sreejith, S., Khanna Nehemiah, H. & Kannan, A. Clinical data classification using an enhanced SMOTE and chaotic evolutionary feature selection. *Comput Biol Med* **126**, (2020).
101. Zeng, M., Zou, B., Wei, F., Liu, X. & Wang, L. Effective prediction of three common diseases by combining SMOTE with Tomek links technique for imbalanced medical data. in *Proceedings of 2016 IEEE International Conference of Online Analysis and Computing Science, ICOACS 2016* 225–228 (Institute of Electrical and Electronics Engineers Inc., 2016). doi:10.1109/ICOACS.2016.7563084.
102. Evgeniou, T. & Pontil, M. Support vector machines: Theory and applications. in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* vol. 2049 LNAI 249–257 (Springer Verlag, 2001).
103. Angermueller, C., Pärnamaa, T., Parts, L. & Stegle, O. Deep learning for computational biology. *Mol Syst Biol* **12**, (2016).

- 104. Poggio, T. & Liao, Q.** Theory I: Deep networks and the curse of dimensionality. *Bulletin of the Polish Academy of Sciences: Technical Sciences* (2018).
- 105. Aggarwal, H. K., Mani, M. P. & Jacob, M.** MoDL: Model-Based Deep Learning Architecture for Inverse Problems. *IEEE Trans Med Imaging* **38**, 394–405 (2019).
- 106. Möller, M. F.** A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks* **6**, 525–533 (1993).
- 107. Alihodzic, A., Mujezinovic, A. & Turajlic, E.** Electric and Magnetic Field Estimation under Overhead Transmission Lines Using Artificial Neural Networks. *IEEE Access* **9**, 105876–105891 (2021).
- 108. Li, K. M. & Li, E. C.** Skin Lesion Analysis Towards Melanoma Detection via End-to-end Deep Learning of Convolutional Neural Networks. (2018).
- 109. Kivrak, M., Avci, U., Uzun, H. & Ardic, C.** The Impact of the SMOTE Method on Machine Learning and Ensemble Learning Performance Results in Addressing Class Imbalance in Data Used for Predicting Total Testosterone Deficiency in Type 2 Diabetes Patients. *Diagnostics (Basel)* **14**, (2024).
- 110. Turna, A. et al.** Can postoperative complications be reduced by the application of ERAS protocols in operated non-small cell lung cancer patients? *Turkish Journal of Thoracic and Cardiovascular Surgery* **31**, 256–268 (2023).
- 111. Licker, M. & Navarro, R.** Prehabilitation in thoracic surgery. in *Anesthesia in Thoracic Surgery: Changes of Paradigms* 33–47 (Springer International Publishing, 2020). doi:10.1007/978-3-030-28528-9_3.