

T.C.

Atatürk Üniversitesi Tıp Fakültesi

Ortopedi ve Travmatoloji Anabilim Dalı

**BİPOLAR PARSİYEL PROTEZ
UYGULANMIŞ KALÇA KIRIKLI
HASTALARDA MAKİNE ÖĞRENME
YÖNTEMLERİ İLE PERİOPERATİF
PROGNOZ VE MALİYET ANALİZİ**

Dr. Kemal ZENCİRLİ

UZMANLIK TEZİ

Danışmanlar

Prof. Dr. Ömer Selim YILDIRIM

Dr. Öğr. Üyesi Muhammed Çağatay ENGİN

ERZURUM- 2020

T.C.
ATATÜRK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞINA

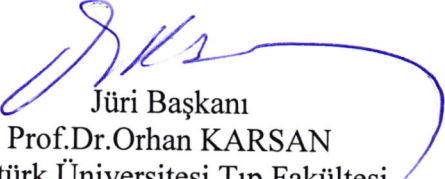
İLGİ: 25/12/2019 tarih ve E.1900371955 sayılı yazınız.

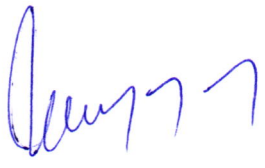
TIPTA UZMANLIK TEZ SAVUNMA TUTANAĞI


Atatürk Üniversitesi Tıp Fakültesi Ortopedi ve Travmatoloji Anabilim Dalı tıpta uzmanlık öğrencisi Arş. Gör. Dr. Kemal ZENCİRLİ'nin "Bipolar Parsiyel Protez Uygulanmış Kalça Kırıklı Hastalarda Makine Öğrenme Yöntemleri ile Perioperatif Prognoz ve Maliyet Analizi" konulu tezini incelemek üzere oluşturulan tez jürisine üye olarak seçildiğimiz ilgi yazınızla bildirilmesi üzerine jüri üyeleri, 10/01/2020 tarihinde toplanmış ve ilgili öğrenci tez savunmasına alınmıştır.

Tıpta ve Diş Hekimliğinde Uzmanlık Eğitimi Yönetmeliğinin 19. maddesi gereğince yapılan tez savunmasının tamamlanması sonucunda adı geçen tezi jüri üyelerince oy birliği ile kabul edilmiştir.

Bilgilerinize arz ederiz.


Jüri Başkanı
Prof. Dr. Orhan KARSAN
Atatürk Üniversitesi Tıp Fakültesi
Ortopedi ve Travmatoloji ABD Başkanı


Jüri Üyesi
Prof. Dr. Ömer Selim YILDIRIM
Atatürk Üniversitesi Tıp Fakültesi
Ortopedi ve Travmatoloji ABD.
Öğretim Üyesi


Jüri Üyesi
Dr. Öğr. Üyesi Murat TOPAL
Kastamonu Üniversitesi
Eğitim ve Araştırma Hastanesi
Ortopedi ve Travmatoloji ABD.
Öğretim Üyesi

İÇİNDEKİLER

TABLolar DİZİNİ	iii
ŞEKİLLER DİZİNİ	v
SİMGELER VE KISALTMALAR DİZİNİ	vi
TEŞEKKÜR	vii
ÖZET	ix
ABSTRACT	x
1. GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER	3
2.1. Yapay Zeka (Artificial Intelligence).....	3
2.2. Yapay Zeka Tarihiçesi	4
2.3. Makine Öğrenmesi (Machine Learning)	6
2.3.1. Denetimli Öğrenme (Supervised Learning).....	8
2.3.2. Denetimsiz Öğrenme (Unsupervised Learning)	9
2.4. Makine öğrenme teknikleri.....	10
2.4.1. Sınıflandırma (Classification).....	10
2.4.1.1.Sınıflandırma modellerinin değerlendirilmesi	11
2.4.2. Regresyon (Regression)	15
2.4.2.1. Regresyon modellerinin değerlendirilmesi	16
2.4.3. Kümeleme (Clustering).....	17
2.4.4. İlişkilendirme (Assosiation).....	17
2.5. Makine Öğrenme Modelleri veya Algoritmaları	17
2.5.1. Lineer(doğrusal) Regresyon (Linear Regression).....	18
2.5.2. Destek Vektör Makineleri (Support Vector Machine).....	18
2.5.3. Karar Ağacı (Decision Tree).....	19
2.5.4. Naive Bayes (Naive Bayesian)	20
2.5.5. Yapay Sinir Ağları ya da Derin Öğrenme (Artificial Neural Networks, Deep Learning)	22
2.6. WEKA (Waikato Environment for Knowledge Analysis)	25
3. GEREÇ VE YÖNTEMLER	27
3.1. Kullanılan Parametreler	27
3.2. Perioperatif Bakım.....	34
3.3. Cerrahi Teknik.....	34
4. BULGULAR	35
4.1. Ölüm Analiz Modelleri Ve Sonuçları	35
4.1.1. Naive Bayes	36

4.1.2. Destek Vektör Makineleri (SGD)	37
4.1.3. Destek Vektör Makineleri (SMO)	39
4.1.4. Karar Ağacı (J48).....	41
4.1.5. Yapay Sinir Ağları	43
4.2. Revizyon Analiz Modelleri ve Sonuçları.....	44
4.2.1. Naive Bayes	45
4.2.2. Destek Vektör Makineleri (SGD)	46
4.2.3. Destek Vektör Makineleri (SMO)	48
4.2.4. Karar Ağacı (J48).....	50
4.2.5. Yapay Sinir Ağları	51
4.3. Hastanede Kalım Süresi Analiz Modelleri Ve Sonuçları	52
4.3.1. Lineer Regresyon.....	52
4.3.2. Destek Vektör Makineleri (SMOReg)	53
4.3.3. Karar Ağacı (Decision Stump).....	54
4.4. Maliyet Analiz Modelleri Ve Sonuçları	55
4.4.1. Lineer Regresyon.....	55
4.4.2. Destek Vektör Makineleri (SMOReg)	56
4.4.3. Karar Ağacı (Decision Stump).....	57
5. TARTIŞMA	58
6. SONUÇ VE ÖNERİLER.....	78
7. KAYNAKLAR	80

TABLolar DİZİNİ

Tablo 1. Konfüzyon Matris Modeli.....	12
Tablo 2. WEKA arff notepad dosya örneđi.....	26
Tablo 3. Ölüm analiz sonucu-Naive Bayes Modeli	36
Tablo 4. Ölüm analiz sonucu-Destek Vektör Makineleri (SGD) Modeli	37
Tablo 5. Tablo 4 ün devamı	38
Tablo 6. Ölüm analiz sonucu-Destek Vektör Makineleri (SMO) Modeli.....	39
Tablo 7. Tablo 6'nın devamı	40
Tablo 8. Ölüm analiz sonucu-Karar Ağacı (J48) Modeli.....	41
Tablo 9. Ölüm analiz sonucu-Yapay Sinir Ağları Modeli	43
Tablo 10. Revizyon analiz sonucu-Naive Bayes Modeli.	45
Tablo 11. Revizyon analiz sonucu-Destek Vektör Makineleri (SGD) Modeli	46
Tablo 12. Tablo 11'in devamı	47
Tablo 13. Revizyon analiz sonucu-Destek Vektör Makineleri (SMO) Modeli	48
Tablo 14. Tablo 13'ün devamı	49
Tablo 15. Revizyon analiz sonucu-Karar Ağacı (J48) Modeli.....	50
Tablo 16. Revizyon analiz sonucu-Yapay Sinir Ağları Modeli	51
Tablo 17. Hastanede Kalım Süresi Analiz Sonucu-Linear Regresyon Modeli	52
Tablo 18. Hastanede Kalım Süresi Analiz Sonucu-Destek Vektör Makineleri (SMOreg) Modeli.....	53
Tablo 19. Hastanede Kalım Süresi Analiz Sonucu-Karar Ağacı (Decision Stump) Modeli	54
Tablo 20. Maliyet Analiz Sonucu-Linear Regresyon Modeli	55
Tablo 21. Maliyet Analiz Sonucu-Destek Vektör Makineleri (SMOreg) Modeli	56
Tablo 22. . Maliyet Analiz Sonucu-Karar Ağacı (Decision Stump) Modeli..	57
Tablo 23. Ölüm analizi için tüm modellerin karşılaştırmalı sonuçları.....	58
Tablo 24. Revizyon analizi için tüm modellerin karşılaştırmalı sonuçları.....	58

Tablo 25. Hastanede kalım süresi analizi için tüm modellerin karşılaştırılmalı sonuçları	59
Tablo 26. Maliyet analizi için tüm modellerin karşılaştırılmalı sonuçları	59



ŞEKİLLER DİZİNİ

Şekil 1. Şematik ROC Analiz Modelleri	15
Şekil 2. Şematik Lineer Regresyon Modeli	18
Şekil 3. Şematik Destek Vektör Makineleri Modeli	19
Şekil 4. Şematik Karar Ağacı Modeli	20
Şekil 5. Şematik Naive Bayesian Modeli ve Örnek Çözüm	21
Şekil 6. Şematik Nöron Yapısı	22
Şekil 7. Şematik Yapay Sinir Ağları Modeli.....	23
Şekil 8. Şematik Yapay Sinir Ağları Basit Çalışma Prensipleri.....	23
Şekil 9. Şematik Olarak Veri Miktarı Ve Başarı Oranı İle İlgili Geleneksel Algoritmalar Ve Yapay Sinir Ağları Farkı.....	25
Şekil 10. DORR sınıflaması	29
Şekil 11. Protez pozisyonu	29
Şekil 12. Bacak boyu uzunluk ölçümü	30
Şekil 13. Kalça kırığına ek kırıklar	31
Şekil 14. Şematik Kalça kırık tipleri	31
Şekil 15. Trokanter major tespiti	32
Şekil 16. Protez tipi	33
Şekil 17. Ölüm analizi için kullanılan parametreler ve oransal değerleri	35
Şekil 18. Karar Ağacı Analizin Model Görüntüsü	42
Şekil 19. Revizyon analizi için kullanılan parametreler ve oransal değerleri	44

SİMGELER VE KISALTMALAR DİZİNİ

YZ	: Yapay Zeka
MÖ	: Makine Öğrenme
YSA	: Yapay Sinir Ağları
NB	: Naive Bayes
DVM	: Destek Vektör Makineleri
KA	: Karar Ağacı
YSA	: Yapay Sinir Ağları
ROC	: Receiver Operator Characteristic
AUC	: Area Under Curve
LR	: Lineer Regresyon
OA	: Osteoartrit
k-NN	: K-nearest neighbors
ROI	: Region of Interest
ÖÇB	: Ön Çapraz Bağ
AÇB	: Arka Çapraz Bağ

TEŞEKKÜR

Ortopedi asistanlığımdan uzmanlık sürecine kadar bizlerin yetişmesinde çok büyük emeği olan ve makine öğrenmesi ile ilgili tez yazmam için beni sonuna kadar destekleyen ve cesaret veren saygıdeğer hocam Prof.Dr. Ömer Selim YILDIRIM'a,

Asistanlık döneminde de beraber çalışma fırsatı bulduğum ve o zamandan beri disiplinli kişiliği ve çalışkanlığı ile bizlere yol gösteren değerli hocam Dr. Öğr. Üyesi M. Çağatay ENGİN'e,

Asistanlık dönemimizde hata yaptığımızda hatalarımızdan ders almamızı sağlayan ve bunu bizlere en kibar şekilde ileten bölüm başkanımız saygıdeğer hocam Prof. Dr. Orhan KARSAN'a,

Babacan tavırları ve sakinliği sebebiyle bizlere ortopedinin yanında hayat dersi de veren saygıdeğer hocam Prof.Dr. Naci EZİRMİK'e,

Onu gördüğümde ortopedi açısından hep kendimi eksik hissettiğimden ve bu eksikliği gidermem için bakışlarıyla dahi bizleri ortopediye heveslendiren hemşehrim saygıdeğer hocam Doç.Dr. Ali AYDIN'a,

Asistanlığa başladığım günden beri hocalıktan ziyade bir dost gibi davranan ve sabrıyla kendisini örnek aldığım saygıdeğer hocam Dr.Öğr.Üyesi Sinan YILAR'a,

Biz asistanların gelişimine katkı sağlamak için birçok meselemizle yakından ilgilenen ve bunun için ciddi çaba sarfeden saygıdeğer hocam Dr.Öğr.Üyesi Mehmet KÖSE'ye,

Kliniğimizin ilerlemesi için kendi alanı ile ilgili farklılıklar getiren ve bunu asistanların gelişmesine vesile kılan saygıdeğer hocam Dr.Öğr.Üyesi Kutsi TUNCER'e

Uzmanlık süresince üzerimde hakkı olan asistan arkadaşlarım, hemşire ve personelimize,

Yapay zeka ile ilgili düşüncelerini benimle paylaşan ve tez fikrinde bana yol gösteren, ayrıca çalışmanın her aşamasında bana yardımcı olan sevgili ağabeyim Ahmet ZENCİRLİ'ye,

Asistanlık sürecinden önce de ve asistanlık sürecinde de bana en büyük desteği veren, her daim bıkmadan usanmadan yanımda olan ve çocuklarımın annesi sevgili eşim Nurgül'e teşekkür ederim.

Dr. Kemal Zencirli

Erzurum, 2020

ÖZET

Bipolar Parsiyel Protez Uygulanmış Kalça Kırıklı Hastalarda Makine Öğrenme Yöntemleri ile Perioperatif Prognoz ve Maliyet Analizi

Amaç: Bipolar parsiyel protez uygulanmış kalça kırıklı hastalarda hastaya ait perioperatif prognostik faktörlerin ve maliyet analizinin makine öğrenmesi teknikleri kullanarak belirlemek.

Gereç ve Yöntemler: 2010-2018 yılları arası kliniğimizde kalça kırığı sebebiyle bipolar parsiyel protez uygulanmış 150 hasta çalışmamıza dahil edilmiştir. Hastaların yaş, cinsiyet, travma derecesi, travma esnasındaki ek kırık durumu, başvuru anındaki kan tahlilleri(böbrek, karaciğer ve tiroit fonksiyonu için), kronik hastalık varlığı (kronik obstrüksif akciğer hastalığı, diyabet, hipertansiyon, kronik böbrek yetmezliği ve kronik kalp yetmezliği), kırık sınıflaması, kemik kalitesi, uygulanan protez tipi, protez yerleşimi, trokanterik major tespiti, bacak uzunluk farkı, başvuru tarihinden operasyon tarihine kadar geçen süre, ameliyat süresi, kan transfüzyonu, postoperatif revizyon durumu ve takip esnasındaki ölümler kaydedilmiştir. Hastanın ölümüne, revizyon durumuna, taburculuk süresine ve son olarak da toplam maliyete etki eden faktörler belirlenerek seçilmiştir. Daha sonra bu veriler değerlendirilerek makine öğrenmesi yöntemleri olan naive bayes (NB), destek vektör makineleri(DVM), karar ağacı(KA) ve yapay sinir ağları (YSA) ile tahminler gerçekleştirilmiştir.

Bulgular: Performans karşılaştırmaları için doğruluk, F-ölçüm, ROC ve hata oranları (MAE) değerlendirilmiştir. Ölüm tahmini için en iyi model KA olmuştur. Revizyon tahmini için en iyi model DVM olmuştur. Hem hastanede kalım süresini hem de maliyeti en az hata ile en iyi tahmin eden model DVM olmuştur.

Sonuç: Ölüm için kreatinin (revizyon için de önemli bir parametre) ve kronik hastalık varlığı modellerin genelde en fazla ağırlık verdiği parametreler olmuştur. Kalça kırığı sebebiyle parsiyel protez uygulanacak hastalarda bu 2 parametre yakın takip edilmeli ve gerekli konsültasyonların vakit kaybedilmeden yaptırılması gerekmektedir. Ayrıca protez uygulanırken intraoperatif olarak dikkat edilmesi gereken parametreler bacak uzunluk farkı, protez tipi(ementli) ve trokanterik tespit olarak belirlenmiştir. Bu nedenle parsiyel protez uygulanırken bu parametreler özellikle dikkate alınmalıdır. Bacak uzunluk farkı için gerekirse protez deneme aparatı ile intraoperatif röntgen çekilmelidir. Hastanede kalım süresine ve maliyete etki eden en önemli parametre ise başvuru tarihi ile ameliyat olduğu tarih arasındaki süre(ortalama 4.02 gün) olarak belirlenmiştir. Sonuç olarak bu hastalar ameliyata mümkün olan en kısa sürede ameliyata hazır hale getirilmeli ve en uygun zamanda opere edilmelidirler.

Anahtar Kelimeler: Yapay Zeka, Makine Öğrenme, Kalça Kırıkları

ABSTRACT

Perioperative Prognosis and Cost Analysis in Patients Who Have Undergone Bipolar Hemiarthroplasty with Hip Fracture by using Machine Learning Algorithms

Aim: To determine the perioperative prognostic factors and cost analysis of hip fracture patients using bipolar hemiarthroplasty by using machine learning techniques.

Materials and Methods: Between 2010 and 2018, 150 patients who underwent bipolar hemiarthroplasty for hip fractures were included in our study. Age, gender, degree of trauma, additional fracture at the time of the trauma, blood tests (for renal, liver and thyroid function), presence of chronic disease (chronic obstructive pulmonary disease, diabetes, hypertension, chronic renal failure and chronic heart failure), fracture classification, bone quality, type of prosthesis, prosthesis placement, trochanteric major fixation, leg length difference, time from admission to operation date, operative time, blood transfusion, postoperative revision status and deaths during follow-up were recorded. Factors affecting the patient's death, revision status, duration of discharge and finally the total cost were determined and selected. Afterwards, these data were evaluated and predictions were made with machine learning methods, including naive bayes (NB), support vector machines (SVM), decision tree (DT) and artificial neural networks (ANN).

Results: Accuracy, F-measure, ROC and mean absolute error (MAE) were evaluated for performance comparisons. The best model for estimating death was DT. The best model for revision estimation was SVM. SVM was the best predictor of both hospitalization time and cost with minimal errors.

Conclusion: Creatinine (also an important parameter for revision) and the presence of chronic disease for death were the most commonly used parameters in the models. These two parameters should be closely monitored in patients who will undergo hemiarthroplasty due to hip fracture and necessary consultations should be made immediately. In addition, parameters to be considered intraoperatively during prosthesis application were determined as leg length difference, prosthesis type (cemented) and trochanteric fixation. If necessary, intraoperative X-ray should be performed with prosthesis test apparatus. Therefore, these parameters should be taken into consideration when applying hemiarthroplasty. The most important parameter affecting the length of hospital stay and cost was determined as the period between the date of admission and the date of surgery (average 4.02 days). As a result, these patients should be prepared for surgery as soon as possible and should be operated as soon as possible.

Keywords: Artificial Intelligence, Machine Learning, Hip Fractures

1. GİRİŞ VE AMAÇ

Yapay zeka (YZ) bilgisayarlara işlem yaptırarak onları daha zeki yapmaya yarayan bir bilgisayar bilimidir. Zeki insan davranışlarını taklit ederek mantıklı karar verme ve anlamlı şekilde cevaplama yapabilen bir makine öğretisidir. Bunları yapmak için temel gereksinim öğrenimdir. Yıllarca birçok bilim adamı öğrenme olmadan bilgisayar zekasının birşeye yaramayacağını düşünmüşler. Fakat bu anlayış makine öğrenmesi ve ardından derin öğrenmenin keşfedilmesi ile değişmiş ve hızla gelişmiştir (1).

Yapay zekanın alt dallarından olan makine öğrenmesi ise geniş veri setlerinden anlamlı bilgiler bulma konuları ile ilgili en önemli alanlardan biri haline gelmektedir. Günümüz teknoloji gelişmeleri ile birlikte makine öğrenme alanları giderek artmaktadır. Çünkü verilerin sayısı ve karmaşıklığı günden güne artmaktadır. Büyük ve kompleks verileri analiz etmek her zamankinden daha da zorlaşmaktadır. Böyle bir durumda yapay zekanın veya makine öğrenmesinin kullanılması kaçınılmaz bir hale gelmektedir.

Günümüzde pazarlama, otomotiv, eğlence ve sağlık sektörü gibi pek çok alanda makine öğrenme kullanılmaktadır(2). Her sektörde önemli olduğu kadar sağlık sektöründe de makine öğrenmesinin uygulamaya konulması hastaların prognoz tahmini açısından oldukça önem arz etmektedir. Zira sağlık alanındaki amaç, hastaların daha uzun ve kaliteli ömür süreleri için performans ortaya koymaları gerekliliğidir (3).

Yapay zeka veya makine öğrenmesi günlük hayatımızın bir parçası olma yolunda hızla ilerlemektedir. Bu hızlı ilerlemeye ayak uydurma her alanda ihtiyaç olduğu gibi ortopedi ve travmatoloji gibi çok büyük bir sağlık sektörünü ilgilendiren bir bölüm için de zorunluluk arz etmektedir. Zira bununla alakalı olarak ortopedi ve travmatoloji bölümünde makine öğrenme kullanımının sınırlı olduğu görülmektedir. Bu sebeple ortopedi ve yapay zeka alanlarını sentez eden bir tez yazılarak gelecek çalışmalar için ışık tutulması amaçlanmıştır.

Bu tezin amacı bipolar parsiyel protez uygulanmış kalça kırıklı hastalarda hastaya ait perioperatif prognostik faktörlerin ve maliyet analizinin makine öğrenmesi teknikleri kullanılarak belirlenebilmesidir. Özellikle yaşlı hastalarda kalça kırıklarına ilişkin literatürde daha önceden prognoza ait risk faktörleri belirlenmiş olup(4-7) bu çalışmada ise perioperatif süreçte hangi parametrelerin ne derecede önemli olduğu makine öğrenmesi yöntemleri ile hem detaylandırılmış hem de tahminlerde bulunulmuştur. Hastanın ölümüne, revizyon durumuna, taburculuk süresine ve son olarak da toplam maliyete etki eden faktörler değerlendirilmiş ve tahminler gerçekleştirilmiştir. Regresyon (Regression) ve sınıflandırma (Classification) gibi yöntemler kullanılarak farklı modeller oluşturulmuştur. Modellerin performansları değerlendirilerek doğrusal bir tespit yapılmaya çalışılmıştır.

Ayrıca belirtmek gerekir ki makine öğrenme modelleri tanıtılırken matematik alanına ayrıntılı girilmeden kullanılan yöntemlerin mantığının anlaşılmasına önem verilmiştir.

Son olarak, tezimde kullandığım ifadelerin ve terimlerin türkçe yazılması için ciddi çaba içerisinde bulunulmuş fakat literatürde yaygın kullanımlarından dolayı parentez içerisinde ingilizce ifadelerine yer verilmiştir.

2. GENEL BİLGİLER

2.1. Yapay Zeka (Artificial Intelligence)

Yapay Zeka terimi ilk olarak 1955'te Dartmouth Yaz Yapay Zeka Araştırmaları Projesi'nde John McCarthy tarafından kullanılmıştır. Yapay zeka makinelerin insanlar ve hayvanlar tarafından gösterilen doğal zekanın tam aksine, zekayı öğrenme ve gösterme yeteneği olarak tanımlanmaktadır(2). YZ o zamandan beri hızla ve kademeli olarak kişisel ve sosyal yaşamımıza nüfuz etmiştir. Son yıllarda, bilgisayar gücü, bellek, veri depolama ve büyük miktarlardaki verilerle çalışan bilgisayarlar, giderek daha karmaşık bir şekilde başarılı öğrenme görevlerini yerine getirmektedir (8). Günlük hayatta kullanılan YZ uygulamaları arasında konuşma tanıma (9), yüz tanıma (10), oyun yapay zekası (11), akıllı ses yardımcısı (12) ve kendi kendine sürüş araçları (13) sayılabilir. Hiç şüphesiz YZ uygulamalarının daha hızlı, daha akıllı ve daha erişilebilir olacağına kuşku yok. Bununla birlikte, mevcut YZ uygulamalarının aralığı hala çok dardır. İlerlemelere rağmen, evrenselliği sağlamak hala önemli bir zorluktur(14).

YZ genel olarak şöyle sınıflandırılabilir: genel YZ, insan düşüncesini, duygusunu ve aklını çoğaltan makineler (şimdilik bilim kurgu) ve dar YZ, insanlarda olduğu gibi veya onlardan daha iyi olarak belirli görevleri yerine getirebilecek teknolojilerdir(15).

Tıp alanında son yıllarda atılımlar, bireylerden, biyolojik deneylerden, hastanelerden ve çevresel faktörlerden elde edilen biyomedikal verilerin hacminde ve karmaşıklığında çarpıcı bir artışa neden olmuştur (16) ve klinik aktivitelerde zorluklar yaratmıştır. Mevcut biyomedikal verilerin patlayıcı artışı, geleneksel istatistiksel yöntemleri kullanarak, karmaşık hastalıklar hakkında içgörü kazanmak için doktorların tüm anlamlı verileri çıkartabilme kabiliyetini aşmıştır. Bu, hekimlerin verileri etkili bir şekilde analiz etmelerine yardımcı olmak için daha yüksek düzeyde bir analiz yöntemi gerektirir(8, 16, 17).

YZ, karmaşık algoritmalar kullanarak büyük miktarda biyolojik verideki potansiyel ilişkileri öğrenir ve bu bilgileri klinik aktivitelere yardımcı olmak için kullanır. Ayrıca doğruluğunu arttırmak için başarılı klinik vakalardan ve klinik kılavuzlardan yeni tıbbi bilgiler edinebilir.

YZ, insan klinik uygulamalarında tanı ve tedavide kaçınılmaz hataları azaltabilir ve sağlık riski konusunda gerçek zamanlı tahminler yapabilir (18-20). Geniş olarak tıp alanında, radyoloji, kardiyoloji ve onkoloji spektrumu YZ uygulamasından fayda sağlamıştır (14, 21-23).

Bilgisayar biliminin bir parçası olan yapay zeka aslında içerisinde birçok alt branş ihtiva etmektedir. Bilgisayarlı görü, bulanık hesaplama, uzman sistemler, doğal dil işleme, robotik ve makine öğrenmesi gibi birçok alanda YZ kullanılmaktadır. Yapay zeka, geçtiğimiz birkaç yıl içinde, tıp dahil çeşitli alanlarda deneysel uygulama aşamasına geçerek hızlı bir büyüme göstermiştir. Öğrenme algoritmaları ve teorilerindeki gelişmeler, büyük veri setlerinin mevcudiyeti ve bilgi işlem gücündeki gelişmeler mevcut YZ uygulamalarındaki atılımlara katkıda bulunmuştur.

2.2. Yapay Zeka Tarihçesi

Yapay zekanın temelleri 1232-1316 yılları arasında yaşamış katalan filozof ve teolog olan Ramon Llull tarafından atıldığı düşünülür. Çünkü eserlerinde yeni bir bilgi türü olan kavramların kombinasyonundan bahsetmiş kendisine göre mantıksal doktrinler üretmiş ve yapay zekanın kavramsallaştırılmasını öngörmüştür(24-26).

1666 yılında Gottfried Leibniz ise yayınladığı kitabında insan düşüncesinin alfabesi olabileceği ve bunun da basit kavramların sentezinden ortaya çıkabileceğini öne sürmüştür(27).

Thomas Bayes 1763 te olayların olasılık ihtimallerini öngörmüş ve bu çıkarımı onu yapay zekanın öncüleri arasına sokmuştur(28, 29).

1815-1864 yılları arasında yaşamış olan matematiğin babalarından sayılan George Boole ise matematik ve mantık üzerine kavramlar ortaya çıkarmıştır.

Çalışmaları ölümünden sonra bilgisayar biliminde uygulama alanı bulmuş ve bilgisayarda matematiksel işlemlerin bir nevi öncüsü olmuştur(30).

1898 yılında Nikola Tesla New York'taki Madison Square Garden'daki bir süs havuzunda ufak bir maket gemiyi radyo dalgalarıyla hareket ettirerek bir alıcı ve verici arasındaki iletişimi sağlayan ilk kişi oldu. Kendisi bu durumu "ödünç alınmış bilinç" olarak tarifledi(31, 32).

İspanyol mühendis ve matematikçi olan Leonardo Torres y Quevedo otomatik hesabın gerçek öncülerindendir. Cebirsel denklemi çözebilecek makineler ve 1914 te satranç oynayan bir otomat yaptı. Hareketlere Hertz dalgalarıyla uzaktan kumanda etmeyi başaran ilk bilim adamlarından biri oldu(33). 1921 yılında literatüre "robota" kelimesini üreten Karel Čapek adlı çek bilim adamıydı(34).

1929 yılında Japonya'nın Osaka kentinde japonların yaptığı ilk robot olan "Gakutensoku" doğa yasalarından öğrenme mantığı ile çalışmaktaydı. Hava basınç mekanizması ile çeşitli hareketlerde bulunabilmekteydi(35).

1943 yılında Warren S. McCulloch ve Walter Pitts "Sinir ağlarının mantıksal hesabının istatistiksel bir sonucu" ve "Sinirsel aktiviteye hazır olan fikirlerin mantıksal bir hesabı" makaleleri ile nöronların yapısını matematikselleştirerek nispeten derin öğrenme temellerini atmışlardır(36, 37).

1956 yılında Alan Turing "Makine düşünebilir mi?" diyerek bu alanda çığır açmış, yapay zekanın ve makine öğrenmesinin gerçekliğe dönüşmesinde önderlik etmiştir(38).

1969 yılında Marvin Minsky ve Seymour Papert "Perceptrons" adlı kitapları ile algılayıcıların yapay zeka üzerindeki etkilerini araştırmış ve Marvin Minsky ilk defa yapay zeka laboratuvarı kurmuştur(39). Frank Rosenblatt, iki katmanlı bir bilgisayar öğrenme ağına dayanan kalıp tanımayı sağlayan erken bir yapay sinir ağı olan Perceptron'u geliştirmiştir(40).

1950-1990 yılları arası John McCarthy birçok yayınında yapay zeka üzerine matematik mantığını anlamaya çalışmış ve "Yapay zeka" terimini ilk defa 1956 yılında kullanmıştır(41-44).

1986 yılında Geoffrey Hinton ve arkadaşları “Geriye Yayılım” algoritması ile önemli bir adım attı. Bu adımla beraber bilgisayarın tecrübelerden faydalanan bir sistemini geliştirmiştir(45).

1997 yılında IBM şirketinin geliştirdiği “Deep Blue” yazılımı dünya satranç şampiyonu Garry Kasparovu yenerek yapay zekanın laboratuvarlardan çıkarak pratikte de işe yarayabileceğini göstermiştir(46).

1998 yılında Yann Le Cun ve arkadaşları 0-9 arası rakamları CNN ile sınıflandırmayı başarmış ve derin öğrenme için büyük bir adım atmıştır(47).

2009 yılında Fei Fei Li imajenet ile en büyük görüntü veri kümesini ücretsiz olarak kullanıma açmıştır. 2012 yılında Geoffrey Hinton ve arkadaşları imajenet yarışmasında büyük başarı sağlamıştır.

2011 yılında “siri” ile Apple sanal asistanı tanıtmıştır.

2014 yılında Yoshua Bengio ve Ian Goodfellow çekişmeli üretici ağlar ile büyük ses getirmiştir ve derin öğrenmeyi kitap haline getirmişlerdir(48).

2017 yılında Google DeepMind şirketi AlphaGo yazılımı ile dünyanın en zor oyunu olarak kabul edilen oyunda dünya şampiyonunu yenerek ciddi ilerleme katetmiştir(49, 50).

2.3. Makine Öğrenmesi (Machine Learning)

Yapay zekanın bir alt dalı olarak da bilinen makine öğrenmesi yazılım programlarının açık bir şekilde programlanmadan sonuçları tahmin etmede daha doğru olmasını sağlayan bir algoritma içeren bir bilim dalıdır. Amaç geçmişteki verileri kullanarak gelecek için tahminlerde bulunmaktır. Makine öğrenmesinin temel dayanağı, giriş verisini alabilen algoritmalar oluşturmak ve çıktılarını yeni veriler ortaya çıktıkça güncellerken bir çıktıyı tahmin etmek için istatistiksel analiz kullanmaktır. Makine öğrenmesinde girdi ve çıktı verileri sağlanır ve daha sonra makine, verilen girdilerin etiketlenen çıktı verilerini ürettiği süreci belirler. Makine öğrenmesi için benzetme yapacak olursak; bir çocuk beyninin başkalarından öğrenmesi veya benzerlikleri ayırt etme gibi modellemeleri esas alan ve bunları matematiksel olarak işleyen bir modeller dizisidir.

MÖ geniş veri setlerinden anlamlı bilgiler bulma konuları ile ilgili en önemli alanlardan biridir. Verinin incelenip, içerisinden ise yarayan bilginin çıkarılmasına da Veri Madenciliği (data mining) adı verilir. Bilinmeyen ve değerli bilgileri belirlemek için etkili bir yöntem olduğu için sağlık alanında da kullanımı gittikçe artmaktadır. MÖ medikal tedavi metodları tespit etmede, hastalıkların sebeplerini belirlemede, hastalara en uygun ve en düşük maliyetli medikal çözüm üretmede ve sağlık alanlarında dolandırıcılıkları engellemede etkili bir yöntemdir. Aynı zamanda etkili sağlık politikaları yapmak ve sağlık araştırmacıları için bireysel sağlık profilleri oluşturmaya yardımcı olmaktadır. Sağlık bilimciler tarafından üretilen veriler hastane, hasta, medikal kayıtlar ve tedavi ile ilgili olduğu için genelde çok karışık ve komplekstir. Böylesi zor ve karmaşık verilerden önemli bilgiler çıkarmak ve güçlü analizler yapmak için MÖ bir ihtiyaçtır. Benzer hastalık ve benzer problemleri en kolay, uygun ve ucuz hale getirir. MÖ aynı zamanda hastaların kültürel, sosyal ve ekonomik durumlarını da inceleyebilmekte ve analiz edebilmektedir(51).

MÖ uygularken bazı zorluklar karşımıza çıkmaktadır. En önemli zorluklardan biri kaliteli ve güvenilir medikal veriler sağlamaktır. Çünkü sağlık verileri laboratuvarın medikal verilerinden doktor ve hastanın geniş kapsamlı incelenmesine kadar olan karmaşık verilerdir. Ve bu verileri elde etmek kolay değildir. Hasta kayıtlarının düzgün tutulmaması, hastaların takiplerinin yeteri kadar yapılmaması(veya hastaların takibe gelmemesi) ve hastane alt yapısının veri eldesi için uygun olmaması sebebiyle veri toplamada aksaklıklar yaşanmaktadır. Bu sebeple verilerin tam ve eksiksiz olarak elde edilmesi makine öğrenmesi için daha doğru sonuçlar almamıza imkan tanıyacaktır(52).

MÖ uygulamak için aslında tek bir yöntem yoktur(53). Bilgi çeşitliliğine ve miktarına göre kullanılacak yöntem değişebilir(54). Ayrıca kullanılacak yöntemlerin avantaj ve dezavantajları olabilmektedir.

Medikal prognoz doğru prognoz tayininde uzun zaman kayıplarından dolayı doktor için zor bir iştir. Makine öğrenme hem diagnostik problemler hem de prognostik tahminler için kullanışlıdır. Doğru tahmin etmenin yanında sınıflayıcıların açıklama yetenekleri oldukça önemlidir. Hergün pratikte prognostik süreci

desteklemek için doktorlar kararlarını açıklayabilecek sınıflayıcılara ihtiyaç duyarlar. Böyle şeffaf kararlar doktorlar için çok daha kabul edilebilir olur. Tüm bu çalışmaların sonucunda doktorlar prognostik faktörler için belirleyici problemleri tespit edebilirler ve hasta prognozu hakkında ön fikre sahip olabilir. Bu da ileride prognozu olumsuz etkileyen durumları düzeltme ve gerekebilecek ek testleri istemelerini veya hasta prognozu açısından aileleri daha doğru bilgilendirme fırsatı doğurur(55).

Genel olarak sağlık alanı ile ilgili olarak aşağıdaki faydaları vardır;

- Hastane kaynaklarında etkili yönetim,
- En iyi hasta ilişkisi,
- Hastane enfeksiyon kontrolü,
- Daha akıllı tedavi teknikleri,
- Geliştirilmiş hasta bakımı,
- Hastane derecelendirilmesi,
- Yüksek riskli hasta tanımlaması,
- Sağlık politikası planlanması,
- Sağlıkta dolandırıcılıkların azaltılması(52)

Makine öğrenmesi, büyük veri kümelerinden faydalı kalıpları öğrenebilen ve bunun sonucunda yararlı bilgiler sağlayabilen sistemler oluşturur. Bu sistemleri oluştururken uygun bir maliyet ile eğitim, geçerleme ve test ortaya koyar. Ayrıca gerçek dünyada da performansının iyi olması gerekmektedir. Normal algoritmalarından farklı olarak, 'makineye' iyi cevabın 'ne olduğunu söyleyen ve açık programlama olmadan öğrenmenin gerçekleştiği verileri elde etmek için çalışmaktadır. MÖ problemleri denetimli öğrenme veya denetimsiz öğrenme olarak sınıflandırılabilir(56)

2.3.1. Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme verilerin etkileşimli sistemlerden alınarak belirli bir düzende organize edilmesidir. Bu öğrenme modelinde girdi(input) ve çıktı(output) bellidir. Genellikle risk tahmini elde etmek için kullanılır. Denetimli öğrenme bilinen

bir çıktı veya hedefi öngörme hedefi ile başlamaktadır. Yeni bir veri örneğini en iyi şekilde tanımlamak için alt gruplar arasında seçim yapmayı ve bilinmeyen bir parametreyi tahmin etmeyi de içeren öngörmeyi içerir. Bireysel katılımcıların ortak veri kümelerindeki performanslarına göre değerlendirildiği makine öğrenmesinin bu yöntemi, tekrarlanan denetimli öğrenme problemleri arasında el yazısı tanıma (el yazısı rakamları tanıma gibi), nesnelerin görüntülerini sınıflandırma (ör. Bu bir kedi mi köpek mi?) ve döküman sınıflandırması (örneğin, bu kalp yetmezliği veya finansal rapor ile ilgili klinik bir çalışma mı?) gibi problemlerin çözümlerine odaklanmaktadır. Özellikle, bunların hepsi eğitilmiş bir kişinin iyi yapabileceği görevlerdir ve bu yüzden bilgisayar genellikle insan performansını yaklaştırılmaya çalışılmaktadır. Modellemede bilgisayar sadece hekim becerilerine yaklaşmakla kalmıyor, aynı zamanda model insanlara kolayca görünmeyen yeni ilişkiler bulabilmektedir.

Tıpta denetimli öğrenmeye dair bazı örnekler neler olabilir? Belki bir kardiyolog tarafından görülen en yaygın örnek, sınırlı bir tanı dizisinden (örneğin bir sınıflandırma görevi) seçim yapmak için tanının yapıldığı EKG'nin otomatik yorumlanmasıdır. Radyolojide, bir akciğer nodülünün bir göğüs röntgeninden otomatik olarak algılanması da denetimli öğrenmeyi temsil etmektedir. Her iki durumda da bilgisayar, eğitilmiş bir doktorun zaten yüksek hassasiyetle yapabileceklerini yansıtmaktadır. Koroner kalp hastalığı için Framingham Risk Score, tıpta denetimli öğrenmenin en sık kullanılan örneği olabilir(8).

2.3.2. Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenme sınıf bilgisi barındırmayan verilerin içerisindeki grupların irdelenmesidir. Denetimsiz öğrenmede, tahmin edilecek çıktı yoktur. Bunun yerine, verilerde doğal olarak oluşan desenleri veya gruplamaları bulmaya çalışır. Bu, doğası gereği, değerlendirme yapmak için daha zorlu bir görevdir ve genellikle denetimsiz öğrenme yoluyla öğrenilen bu tür grupların değeri, sonraki denetimli öğrenme görevlerindeki performansı ile değerlendirilebilmektedir.

Bu tür yaklaşımlar tıpta ne zaman kullanılabilir? Belki de en ikna edici yönü başlangıç ilaç seçmedeki rolü olabilir. En yaygın hastalıklarda doğal heterojenite ile ilgili hayal kırıklığı nedeniyle, hastalığın patofizyolojik mekanizmalara göre yeniden

tanımlanması için artan bir çaba vardır ve bu da tedaviye yeni yollar sağlayabilir. Ancak karmaşık multifaktöriyel hastalıklar için bu tür mekanizmaları tanımlamak kolay olmayabilir.

Miyokardit gibi heterojen bir durumla kardiyak hastalıkta denetimsiz öğrenmeyi bu sonuca nasıl uygulayabileceğimizi düşünelim. Açıklanamayan akut sistolik kalp yetmezliği olan hastalara miyokard biyopsileri yapılabilir ve her numunenin hücresel kompozisyonu immün boyama gibi bir teknikle karakterize edilebilir. Örneğin, bir numune için lenfosit, nötrofil, makrofaj, eozinofil vb. Hangi sellüler komponent rekürrensi varsa keşfetmek için mekanizmalar ve rehber terapiler önerebilir. Yani subgruplar oluşturmaya olanak sağlayabilir. Denetimli öğrenmenin aksine herhangi bir tahmin yoktur(8).

Bu 2 öğrenme modeli dışında Yarı Denetimli Öğrenme (Semi-supervised learning)(57, 58) ve Takviyeli Öğrenme (Reinforcement learning)(59, 60) gibi öğrenme modelleri de vardır.

2.4. Makine öğrenme teknikleri

Makine öğrenme kullanım açısından sıklıkla şu 4 kategoride incelenmektedir;

- 1) Sınıflandırma (Classification)**
- 2) Regresyon (Regression)**
- 3) Kümeleme (Clustering)**
- 4) İlişkilendirme(Assosiation)**

Çalışmamız regresyon ve sınıflandırma üzerine olacağından bu 2 yöntem biraz daha detaylı incelenecektir.

2.4.1. Sınıflandırma (Classification)

Veri örneklerini hedef sınıflara ayıran en sık kullanılan metodlardan biridir. Özellikle de sağlık alanında kullanımı sıklıktır. Her veri noktası için hedef sınıfı tahmin eder. Örneğin; hastaları hastalık paternine göre “yüksek riskli” veya “düşük riskli” diye sınıflandırabilir. Bunun için kullanılan yöntemler arasında Lojistik Regresyon

(Logistic Regression), k-En Yakın Komşu (K-Nearest Neighbour), Karar Ağacı (Decision Tree), Destek Vektör Makinesi (Support Vector Machine), Yapay Sinir Ağı (Artificial Neural Network), Bayesian Yöntemleri (Bayesian Methods) ve Gradyan İniş Yöntemi (Gradient Descent Method) sayılabilir. Bu yöntemde denetimli öğrenme modeli kullanılır(51, 61).

2.4.1.1.Sınıflandırma modellerinin değerlendirilmesi

Konfüzyon matrisi (Confusion Matrix)

Sınıflandırma yöntemlerinin doğruluğunu test etmek kullanılan yöntem “Konfüzyon (Hata) Matrisi (Confusion Matrix)” tir. Doğruluk (Accuracy) tek başına kullanıldığında her zaman anlamlı olmayabilir. Çünkü gruplar arası homojen dağılım olmayabilir. Bu durumda daha ayrıntılı analiz edebileceğimiz ölçümlere ihtiyaç duyulur. Örnek verecek olursak; Çiftliğimizde 95 i koyun, 5 i inek 100 adet hayvanımız olsun. Oluşturduğumuz model 95 koyunun hepsini doğru bilsin. Ama hiç inek bilemesin. Doğruluk oranımız % 95 olmasına rağmen hiç inek tahmin edemediğimiz için sadece doğruluk oranı modelimiz için iyi bir sonuca sahip olmayabilir. Yani doğruluk daha sık major sınıflama performansları için kullanılmaktadır, minör sınıflamaları göz ardı edebilmektedir(62). O sebeple konfüzyon matrisi bu problemi ortadan kaldırmak için kullanışlı bir yöntem olmuştur. Bu yöntemde “Precision” ve “Recall” gibi performans ölçücüler kullanılmaktadır.

Aşağıda örnek bir **konfüzyon matrisi** modeli gösterilmiştir(tablo 1);

Tablo 1. Konfüzyon Matris Modeli

Tahmini Değer	Gerçek Değer			
	Pozitif	Negatif	Toplam	
	Pozitif	Doğrupozitif(dp)	Yanlış pozitif(yp)	tPoz
	Negatif	Yanlış negatif(yn)	Doğru negatif(dn)	tNeg
		Poz	Neg	M

Poz : Gerçek Pozitif Toplamı

Neg : Gerçek Negatif Toplamı

tPoz : Tahmin Edilen Pozitif Toplamı

tNeg : Tahmin Edilen Negatif Toplamı

M : Toplam Örneklem Sayısı

Doğruluk (Accuracy) : Tahmin ile gerçek talep arasındaki farkın, gerçek talebin bir yüzdesi olarak hesaplanması sonucunda bulunan bir matematiksel değerdir. Sağlık alanında hasta ve sağlam kişilerin yüzde kaçının önerilen yöntemle tanınabildiğini gösterir.

Aşağıdaki gibi formülize edilir;

$$\text{Doğruluk (accuracy)} = \frac{dp + dn}{M}$$

Doğru Pozitif Oranı (True Positive Rate), **Recall**, Duyarlılık, Sensitivite : Pozitif bir test örneğini doğru tespit etme olasılığını gösterir. Doğru sınıflandırılan pozitif örneklerin toplam pozitif örnek sayısına oranıdır. Medikal uygulama alanında test duyarlılığını ifade eder.

Doğru Negatif Oranı (True Negative Rate), **Spesifite**, Özgüllük : Spesifite doğru sınıflandırılan negatif örneklerin toplam negatif örnek sayısına oranıdır. Spesifite negatif bir test numunesinin doğru tespit edilme olasılığını gösterir. Yani tanı testinin gerçekte hasta olanlar arasından hastaları ayırt edebilme olasılığıdır. Hastalığın gerçekten var olduğu bilinen kişilerden yüzde kaçının önerilen yeni yöntemle tanınabildiğini gösterir(62).

$$\text{Recall (Duyarlılık)} = dp / dp + yn$$

$$\text{Spesifite (Özgüllük)} = dn / dn + yp$$

Gerçekte negatif olan ancak pozitif olarak sınıflandırılmış örneklerin, tüm negatif etiketli örneklere oranı **yanlış pozitif oranı** (false positive rate); gerçekte pozitif olan ancak negatif olarak sınıflandırılmış örneklerin, tüm pozitif etiketli örneklere oranı da **yanlış negatif oranı** (false negative rate) olarak adlandırılmaktadır(63).

$$\text{Yanlış pozitif oranı (FPR)} = 1 - \text{spesifite}$$

$$\text{Yanlış negatif oranı (FNR)} = 1 - \text{recall}$$

Precision (Pozitif Kestirim Değeri (Positive Predictive Value)) : Tespit edilen pozitiflerin kesirinin gerçekte ne kadar doğru olduğunu gösterir. Doğru sınıflandırılan

pozitif örneklerin toplam pozitif tahmin edilen örneklere oranına eşittir. Genel olarak saklı kalmış olasılığı etkin bir şekilde tahmin eder ve bu nedenle nadir olayları tespit ederken anlamlı bir performans ölçütüdür. Aynı zamanda saflık (Purity) olarak veya tıbbi uygulamalarda pozitif öngörü değeri olarak da adlandırılır(62). Ayrıca doğru sınıflandırılan negatif sınıf etiketine sahip örneklerin toplam negatif tahmin edilen örneklere oranına negatif kestirim değeri (negative predictive value) olarak adlandırılmaktadır. Her 2 sinin de formülize şekli aşağıdaki gibidir;

$$\text{Pozitif Kestirim Değeri (PKD)} = dp / t\text{Poz}$$

$$\text{Negatif Kestirim Değeri (NKD)} = dn / t\text{Neg}$$

F-ölçüsü (F-measure) : Kesinlik (Precision) ve duyarlılık (Recall) performans değerlendirme ölçülerinin harmonik ortalamasıdır ve amaç daha doğru bir ölçüm için her iki ölçünün birlikte ele alınmasını sağlamaktadır. Aşağıdaki gibi formülize edilir;

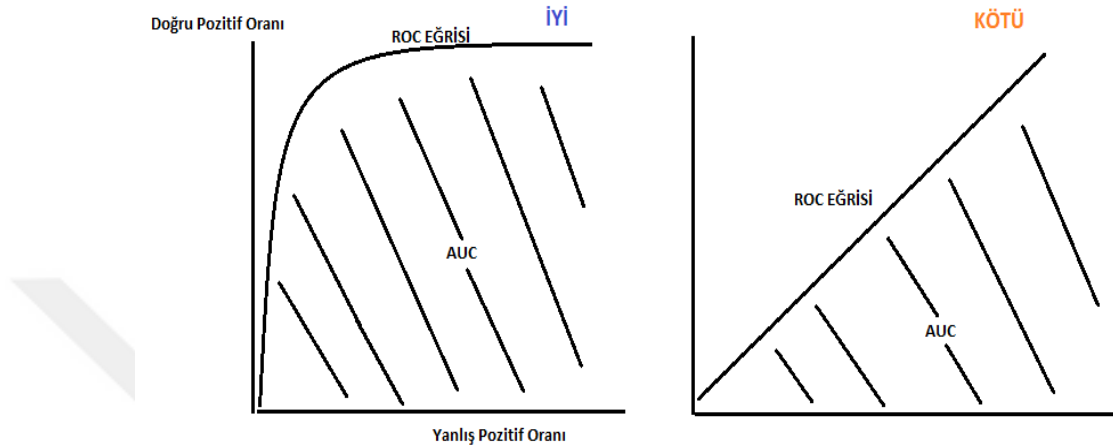
$$\text{F-ölçüsü} = 2 * \text{Precision} * \text{Recall} / \text{Precision} + \text{Recall}$$

Alıcı İşlem Karakteristikleri (Receiver Operating Characteristic - ROC)

Eğrileri:

Yukarıda bahsedilen ölçücülerin eğrilerinin varlığında Receiver Operator Characteristic (ROC) analiz metodu uygulanmaktadır. “y” ekseninde “doğru pozitif oranı ile “x” ekseninde yanlış pozitif oranlarının çizilmesi ile elde edilmektedir. ROC analizi, bu alandaki sınıflandırıcıların değerlendirilmesi için yararlı ve iyi çalışılmış bir araç haline gelmiştir. ROC bir tanı testinin performansını değerlendirmek için veya birden fazla tanı testinin performanslarını karşılaştırmak için kullanılabilir. Eğri Altında Kalan Alan (Area Under the Curve, AUC) bir tanı testi sonucunda tıp alanında hastalarla sağlıklıların birbirinden ne kadar iyi ayrıldığı ölçen performans

ölçüsüdür. ROC eğrisinin altındaki alanın (AUC), genel doğrulukla karşılaştırıldığında, bir sınıflandırma performans ölçütü olarak arzu edilen bir dizi özellik gösterdiği ifade edilmiştir(64). Aşağıda iyi ve kötü ROC analizini veren bir çizim gösterilmiştir(şekil 1);



Şekil 1. Şematik ROC Analiz Modelleri

Normalizasyon (Normalization)

Veri setinde yer alan nümerik değerlerin tümü aynı aralıklarda bulunmayabilir. Örneğin ameliyat süresi 30 ile 400 dakika arasında değişirken, başvuru süresi ile ameliyat olduğu süre arasındaki nitelik 1 ile 30(50) arasında değişebilmektedir. Bu durum, niteliklerin aldığı değerler arasında dengesizliğe veya büyük değerlere sahip bir niteliğin hedef değerleri domine etmesine neden olabilmektedir. Bu problemi ortadan kaldırabilmek için normalizasyon kavramı geliştirilmiştir. Çalışmamızda tüm nümerik değerler max-min normalizasyon tekniği ile “0” ile “1” arasına sıkıştırılarak normalizasyon işlemi gerçekleştirilmiştir.

2.4.2. Regresyon (Regression)

Değişkenler arasındaki korelasyonu açıklamak için kullanılan bir yöntemdir. Matematiksel model eğitilmiş veri üzerinde kullanılır. “X” ve “Y, Z vs.” gibi biri

bağımlı diğerleri bağımsız 2 veya daha fazla değişken arasında istatistiksel bir model oluşturur. Lineer veya nonlineer olmak üzere 2 ye ayrılır. Yani değişkenler arasında ya doğrusal ya da doğrusal olmayan ilişkiler kurar. Bunun için kullanılan yöntemler arasında lineer regresyon (Linear regression), multipl lineer regresyon (Multipl Linear regression), polinomial lineer regresyon (Polynomial Linear regression), karar ağacı regresyon (Decision Tree Regression) ve rasgele orman regresyon (Random Forest Regression) modelleri sayılabilir. Bu yöntemde denetimli öğrenme modeli kullanılır(51, 61).

2.4.2.1. Regresyon modellerinin değerlendirilmesi

Regresyon modellerinin yaptığı tahmin sonuçlarının ne kadar doğru olduğunu tespit etmek için kullanılan bir yöntem **Mean Absolute Error (MAE)** ve **Root Mean Squared Error (RMSE)** dir. Bu yöntemlerde hata (error) payı oluşturularak tüm örneklerin hata payının hesaplanması hedeflenmektedir. MAE her bir örnek için hata payını gösterir ve “residüel” olarak ifade edilen y (gerçek değer)- y_{head} (tahmin edilen değer) olarak formülize edilir. MAE bu değerlerin toplamının örnek sayısına bölünmesi ile bulunur. Fakat hata payları pozitif veya negatif çıkabilmektedir. Böyle bir durumda pozitif ve negatiflerin toplamı “0(sıfır)” çıkabilmektedir. Halbuki uygulanan modelde hatalar vardır ve “0” çıkmasının imkanı yoktur. Bunu engellemek için hataların karesinin karekökü alındığı RMSE yöntemi geliştirilmiştir. Bu yöntemde ise residülin karesi alınarak karekökü için her bir örnekte hata değeri hesaplanır. Her 2 sinin de kabaca formülize edilmiş şekli aşağıdadır;

$$MAE = \frac{\text{toplam } (y - y_{head})}{n}$$

y = gerçek değer

y_{head} = tahmin edilen

n = örnek sayısı

$$RMSE = \sqrt{\frac{\text{toplam } (y - y_{head})^2}{n}}$$

2.4.3. Kümeleme (Clustering)

Denetimsiz öğrenme modeli kullanarak sınıflama yönteminden ayrılmaktadır. Kümelemede sınıflamanın aksine önceden etiketlenmiş herhangi bir veri yoktur. Tanımlanmamış geniş verileri alt gruplara veya kümelere ayırır. Veriler arasında benzerlikleri tanımlamak için kullanılır. Bunun için kullanılan yöntemler arasında Bölümlenmiş Kümeleme (Partitioned Clustering), Hiyerarşik Kümeleme (Hierarchical Clustering), Yoğunluk Bazlı Kümeleme (Density Based Clustering) sayılabilir(51, 61).

2.4.4. İlişkilendirme (Assosiation)

Veri deposundaki bir dizi veri ögesi arasındaki sıklık paternleri ve ilginç ilişkileri bulmak için kullanılan en önemli yaklaşımlarından biridir. Aynı zamanda, satın alınan ürün veya müşterilerin bilinmeyen satış modelleri arasındaki ilişkiyi bir işlem veritabanında keşfetme kabiliyetinden dolayı pazar sepeti analizi (market basket analysis) olarak da bilinir. Örneğin, bir müşteri bilgisayar alıyorsa, virüsten koruma yazılımı satın alma şansı yüksektir. Bu bilgi, kat sahibinin satışlarını daha da arttırmasına yardımcı olabilmektedir. Bunun için kullanılan yöntemler arasında Apriori Algoritması (Apriori Algorithm) ve Sık Desen Ağacı Algoritması (Frequent Pattern Tree Algorithm) sayılabilir(51, 61).

2.5. Makine Öğrenme Modelleri veya Algoritmaları


Tez çalışmamda kullandığım algoritmalar aşağıda daha ayrıntılı olarak tanımlanacaktır.

- 1) Destek Vektör Makineleri (Support Vector Machine)
- 2) Karar Ağacı (Decision Tree)

- 3) Naive Bayes (Naive Bayesian)
- 4) Yapay Sinir Ağları (Artificial Neural Networks)

2.5.1. Lineer(doğrusal) Regresyon (Linear Regression)

İstatistiklerde, lineer regresyon, bir bağımlı değişken (y) ile bir veya daha fazla bağımsız değişken (X) arasındaki ilişkiyi modellemeye yönelik doğrusal bir yaklaşımdır. Lineer regresyonda girdi ile hedef arasında doğrusal bir denklem mevcuttur. İlişkiler bilinmeyen model parametrelerinin verilerden elde ettiği lineer tahmin fonksiyonları ile kullanılmaktadır. Lineer Regresyon, makine öğreniminde en popüler algoritmalarından biridir. Bunun nedeni göreceli basitliği ve iyi bilinen özellikleri sebebiyledir. Aşağıdaki şematik şekli ve formülü(şekil 2);



$$y = b + W1 * X$$

y = hedef (tahmin) değer

x = girdi (input)

W = ağırlık (weight)

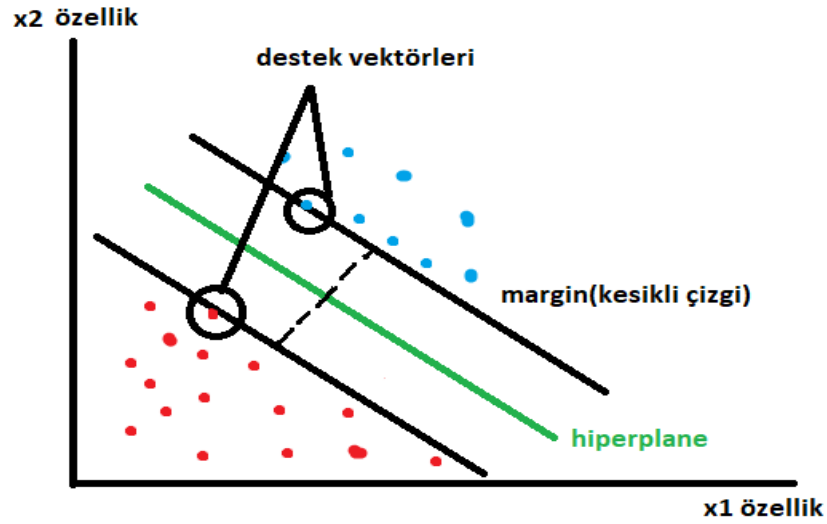
b = sabit (bias)

Şekil 2. Şematik Lineer Regresyon Modeli

2.5.2. Destek Vektör Makineleri (Support Vector Machine)

Destek vektör makineleri (DVM), bileşik sınıflandırma, sıralama ve regresyona dayalı özellik değeri tahminini kolaylaştırmak için denetimli makine öğrenme algoritmalarıdır. Klasik olarak DVM ler ikili sınıflar için tahminde kullanılır. Gruplar doğrusal olarak ayrılabilir hale geldiğinde, iki bileşik sınıfı bu özellik alanında bir hiper düzlem ile ayırılır. Aslında, sonsuz sayıda bu tür hiperplanlar vardır ve DVM,

alan büyüdükçe, bilinmeyen verilerle uğraşırken sınıflandırıcının hatası düştüğü varsayımı üzerine iki sınıf arasındaki marjini maksimize eden hiper düzlemi seçer. Bu marjları tanımlayan hiper düzlemlere "destek hiperplanları" denir ve bu hiper düzlemlerde bulunan veri noktaları "destek vektörleri" olarak adlandırılır(şekil 3). Tam olarak sınıflandırılmayan bir durum söz konusu olduğunda, yanlış sınıflandırılmış hiper düzlem uygulanabilir, bu da yanlış sınıflandırılmış örneklerin sayısını minimumda tutarken kenar boşluğunu maksimuma çıkarır(65). Ayrıca modelin daha iyi performans göstermesi için Stochastic gradient descent (SGD) ve Sequential Minimal Optimization (SMO) optimizasyon yöntemleri kullanılmaktadır(66, 67).

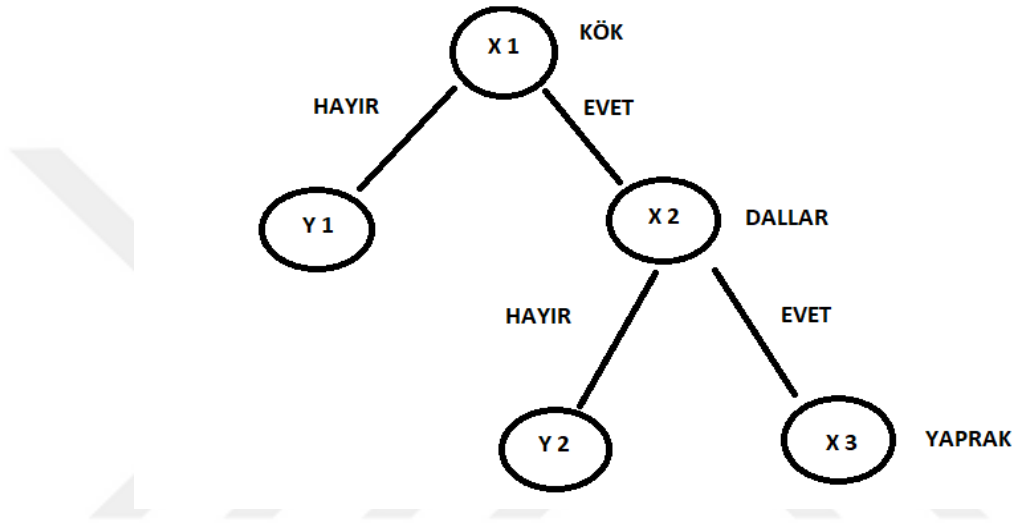


Şekil 3. Şematik Destek Vektör Makineleri Modeli

2.5.3. Karar Ağacı (Decision Tree)

Karar ağacı (KA) belirli parametrik özelliklerin veya tanımlayıcı değerlerin ilgilenilen faaliyet veya özellik ile ilişkilendirilmesi için araç sağlayan bir dizi 'kural' içerir. Belirli aktiviteleri öngörme ve bazı belirli bileşik profil verileri oluşturma gibi sorunlara uygulanır. Bu metod sadece özelliklerin yapısını tanımlama için değil aynı zamanda içeriğini sınıflandırma için de kullanılır. Bir KA genel olarak, en üstünde kök ve altında yaprak olan bir ağaç olarak tasvir edilir. Kökten başlayarak, ağaç tek bir gövdeden iki veya daha fazla dallara ayrılır. Her dal kendi başına iki veya daha fazla

dallara bölünebilir. Bu, daha fazla bölünmeyen bir düğüm olan bir yaprak elde edilinceye kadar devam eder. Dalın bölünmesi ağacın iç düğümü olarak adlandırılır. Kök ve yapraklar ayrıca düğüm olarak da adlandırılır(şekil 4). Bilinmeyen bir durum, bir dizi sorudan (düğümler) geçtikten sonra ulaştığı yaprak düğümüne ve kök düğümünden gelen ilk sorudan başlayarak cevaplara (hangi dalların alınacağına karar verilir) dayalı olarak sınıflandırılır(65). Kök aslında bu modelin en fazla ağırlık atadığı parametredir.



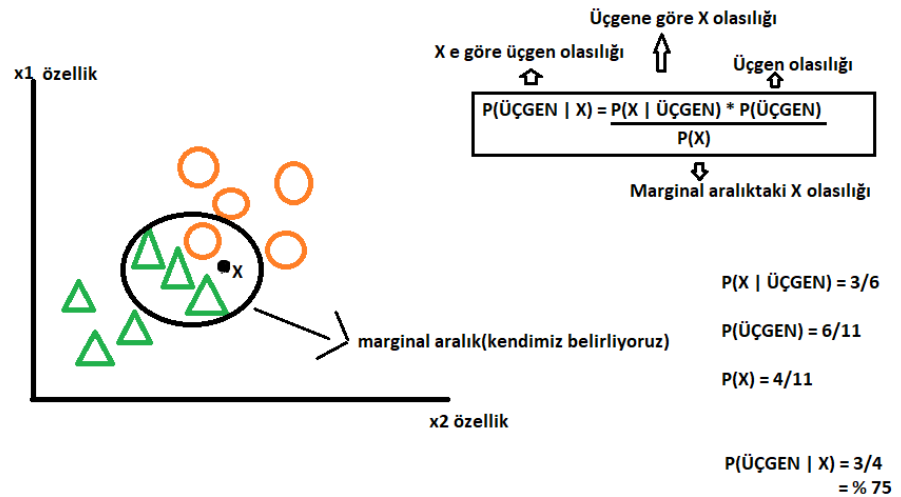
Şekil 4. Şematik Karar Ağacı Modeli

2.5.4. Naive Bayes (Naive Bayesian)

Bayesian yöntemleri, iki ya da daha fazla nedenden herhangi birinin sonucu olabilecek bir olayı açıklamak için matematiksel bir çerçeve sunan Bayes teoremine dayanmaktadır(68). Bu denklem, belirli bir B durumu için mevcut olan A durumu için P olasılığını tanımlar. Olasılığını hesaplamak için, Bayes, A'nın var olduğu düşünüldüğünde, A'nın var olma olasılığı ile çarpılmış ve B'nin var olma ihtimaliyle normalize edilmiş olan B olasılığını kullanır. Kuşkusuz bu karmaşık açıklama şu şekilde yorumlanabilir: Mevcut bir B durumu için, B durumunun A durumundan kaynaklanma olasılığı nedir? Bu teoremin önemi, eğer $P(B / A)$, $P(A)$ ve $P(B)$ hakkında bilgi mevcutsa, $P(A / B)$ hakkında belirli bir bilgi olmadan olasılıkların elde edilebileceğidir. Formülize şekli aşağıdadır;

$$P(A/B) = \frac{P(B/A) * P(A)}{P(B)}$$

Bayes yaklaşımının özü, bir hipotezin yeni kanıtlar ışığında nasıl değiştiğini açıklayan matematiksel bir kural sağlamaktır. Bir Bayesian analizinde, bir dizi gözlem fikrini değiştiren bir şey olarak görülmelidir. Başka bir deyişle, Bayesian teorisi, bilim adamlarının yeni verileri mevcut bilgileri veya uzmanlıklarıyla birleştirmelerini sağlar. Bir Bayesian yöntemi, birbirlerini doğrudan etkileyen değişkenler arasındaki bağımlılığı modellemek için kullanılabilir. Değişkenlerin geri kalanı koşullu olarak bağımsız kabul edilir(65). Bu durumu bir örnekle açıklayacak olursak; Üçgenler ve yuvarlaklar diye 2 ayrı sınıfımız olsun. Bunları temsil eden “x”(x2) ve “y”(x1) eksenini üzerinde ayrı 2 parametremiz olsun. Bu parametleri kullanarak üçgen olma olasılığını hesaplayalım. 6 adet üçgen 5 adet ise yuvarlağımız olsun. Bu iki sınıf arasında eksen üzerinde herhangi bir “ X ”noktası işaretleyelim. Bu işaretin etrafından kendi belirlediğimiz bir margin(sınır) belirleyelim. Soru şu olsun; İşaretlediğimiz noktanın üçgen gelme ihtimali nedir? Aşağıdaki örnek bir naive bayesian modeline göre tahmin sonucu % 75 çıkmıştır(şekil 5).

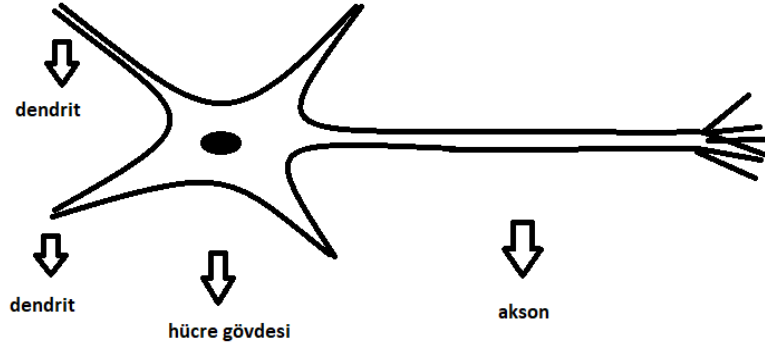


Şekil 5. Şematik Naive Bayesian Modeli ve Örnek Çözüm

2.5.5. Yapay Sinir Ağları ya da Derin Öğrenme (Artificial Neural Networks, Deep Learning)

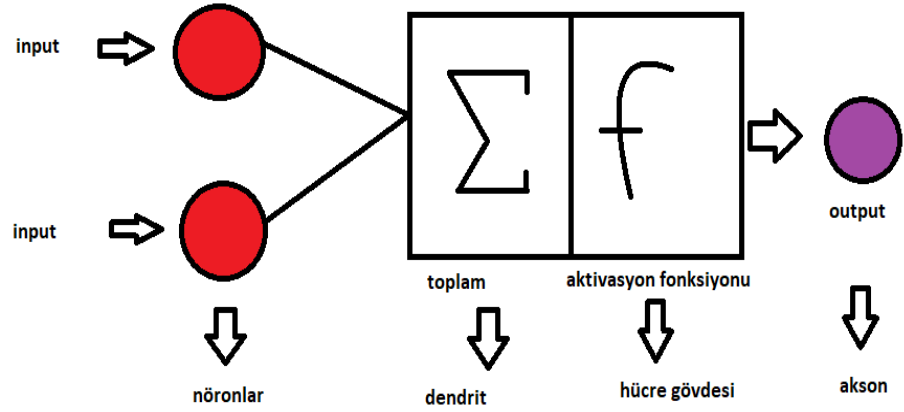
Yapay sinir ağları (YSA) günümüzde en yaygın kullanılan makine öğrenme algoritmalarından biridir. Zamanla sinir ağların diğer algoritmaların doğruluk ve hızda daha iyi performans gösterdiği kesin olarak kanıtlanmıştır. CNN (Konvolüsyonel Sinir Ağları), RNN (Tekrarlayan Sinir Ağları), AutoEncoderlar, Derin Öğrenme vb. gibi YSA'lar yavaş yavaş veri bilimcileri veya makine öğrenimi uygulayıcıları için yaygın hale gelmiştir. Bu tip uygulamaları ve sinir ağlarını öğrenme onların kullanım alanlarını ve sınırlarını anlamak için zorunlu hale gelmiştir.

İnsanoğlunun sinir mimarisinden ilham alınarak isimlendirilen bu algoritmalar insan beynindeki temel yapı taşı olan nöronları taklit eder. Nöronların yapısı kabaca dendrit, hücre gövdesi ve aksondan oluşmaktadır(şekil 6).




Şekil 6. Şematik Nöron Yapısı

Ana mekanizma aynı nöronlarda olduğu gibi bir veri girdisinin(input) ve ardından veri çıktısının(output) oluşmasıdır. Şekil 7’de görüldüğü gibi bir veya birçok nörondan gelen inputlar tek bir nöronun dendritinde toplanır ve hücre gövdesinde işlenir. Ardından akson tarafından bir output olarak işlenir. Girişlerin ve ona uygun çıkışların makine ortamında matematikselleştirilmesi de sinir ağların temelini oluşturur(69-72).



Şekil 7. Şematik Yapay Sinir Ağları Modeli

Ayrıca girdiler ve çıktılar arasında gizli(hidden) katmanlar mevcuttur(şekil 8).



Şekil 8. Şematik Yapay Sinir Ağları Basit Çalışma Prensibi

Makine öğrenme ve yapay sinir ağları arasında her ne kadar benzerlik olsa da bazı farklılıklar da vardır. Bu farklılıklar ve benzerlikler genel olarak aşağıda sıralanmıştır;

1)**Geleneksel Algoritmalar** (k-En Yakın Komşu, Karar Ağacı, Destek Vektör Makinesi, Naive Bayes Yöntemleri vs.)

-Belirlenen kurallar eşliğinde çıkışlar elde edilir

-Datalar ve algoritmalar kesindir

-Belli inputlara belli output verir

-Hata toleransı yoktur

-Nispeten hızlıdır ancak daha az veri ile başarısı yüksektir

2)**Yapay Sinir Ağları** (Yapay Sinir Ağları, Konvolüsyonel Sinir Ağları, Tekrarlayan Sinir Ağları vs.)


-Öğrenme esnasında giriş çıkış işlemleri ile sistem eğitilir

-Deneyimden yararlanır

-Olayları öngörebilir bu sebeple insan gibi hata toleransı vardır

-Çok fazla işlem gücüne ihtiyaç duyar

-Çok büyük verilerde de başarı şansı yüksektir(şekil 9)



Şekil 9. Şematik Olarak Veri Miktarı Ve Başarı Oranı İle İlgili Geleneksel Algoritmalar Ve Yapay Sinir Ağları Farkı

2.6. WEKA (Waikato Environment for Knowledge Analysis)

Yeni Zelanda Waikato Üniversitesi tarafından java kullanılarak açık kaynak kodlu olarak veri ön işleme (data preprocessing), regresyon (regression), sınıflandırma (classification), gruplandırma (clustering), ilişkilendirme (association), özellik seçimi ve özellik çıkarımı gibi nitelikleri barındıran bir veri işleme programıdır. Weka çalışma alanı en gelişmiş makine öğrenme algoritmalarının ve veri ön işleme araçlarının organize bir koleksiyonlarından biridir (53). WEKA üzerinde makine öğrenmesi ve istatistik ile ilgili pekçok kütüphane hazır olarak gelmektedir. Dosya uzantısı olarak “ARFF” (Attribute Relationship File Format) formatı kullanılmaktadır(73). Aşağıda WEKA için kullandığımız bir veri setinin arff şeklindeki dosyanın notepad görünümü (tablo 2);

Tablo 2. WEKA arff notepad dosya örneği

<pre>@relation olum @attribute 'KRONİK HASTALIK(YOK-0, VAR-1)' {0,1} @attribute AML_DK numeric @attribute BASVURU_AML_GUN numeric @attribute 'KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-İTFF STABİL, 2-İTFF İNSTABİL, 3-SUBTROKANTERİK' {0,1,2,3} @attribute 'PROTEZ TİPİ(0-SEMENTSİZ, 1-SEMENTLİ)' {0,1} @attribute 'DORR TIPI(A-0, B-1, C-2)' {0,1,2} @attribute 'YARALANMA MEKANIZMASI(0-DÜŞÜK, 1-YÜKSEK)' {0,1} @attribute 'EK KIRIK(0-YOK, 1-VAR)' {0,1} @attribute 'KAN TRANSFÜZYONU(0-YOK, 1-VAR)' {0,1} @attribute CINSİYET {K,E} @attribute YAS numeric @attribute HGB numeric @attribute KREATININ numeric @attribute GLUKOZ numeric @attribute TSH numeric @attribute T4 numeric @attribute NA numeric @attribute K numeric @attribute AST numeric @attribute ALT numeric @attribute OLUM {0,1} @data 0,95,3.7,1,0,1,0,0,0,K,60,14.2,0.92,76,1.2,1.2,144,4.8,23,33,0</pre>
--

3. GEREÇ VE YÖNTEMLER

2010-2018 yılları arası kliniğimizde kalça kırığı sebebiyle bipolar parsiyel protez uygulanmış 665 hasta tespit edilmiştir. Hastaların takipleri göz önüne alındığında ve bilgileri eksiksiz şekilde değerlendirildiğinde 150 hasta çalışmamıza dahil edilmiştir. Çünkü hastaların veri kaybının olması algoritma performansını olumsuz yönde etkileyebilmektedir(74, 75). Yani hastaların kayıp bilgi (missing data) leri yoktur. Hastaların yaş, cinsiyet, travma derecesi, travma esnasındaki ek kırık durumu, başvuru anındaki kan tahlilleri(böbrek, karaciğer ve tiroit fonksiyonu için), kronik hastalık varlığı (kronik obstrüktif akciğer hastalığı, diyabet, hipertansiyon, kronik böbrek yetmezliği ve kronik kalp yetmezliği), kırık sınıflaması, kemik kalitesi, uygulanan protez tipi, protez yerleşimi, trokanterik major tespiti, bacak uzunluk farkı, başvuru tarihinden operasyon tarihine kadar geçen süre, ameliyat süresi, kan transfüzyonu, postoperatif revizyon durumu ve takip esnasındaki ölümler kaydedilmiştir. Hastanın ölümüne, revizyon durumuna, taburculuk süresine ve son olarak da toplam maliyete etki eden faktörler belirlenerek seçilmiştir. Daha sonra bu veriler değerlendirilerek makine öğrenmesi yöntemleri ile tahminler gerçekleştirilmiştir. Etik kurul onayı alınmıştır(toplantı sayısı 07-karar no 13).

3.1. Kullanılan Parametreler

Hemoglobin(Hg) kırmızı kan hücrelerinde bulunan bir proteindir. Görevi oksijeni vücut dokularına karbondioksidi akciğerlere getirmektir. Düşük Hg seviyeleri anemi anlamına gelir ancak travma hastalarında düşmesi vücudun herhangi bir yerinde kanama olduğu anlamına gelmektedir. Düşük Hg seviyeleri ayrıca yara iyileşmesini olumsuz yönde etkilemektedir(76). Hemoglobin referans aralığı hastanemizde 13,6-17,2 g/dL dir.

Glukoz şekerin basit bir yapı taşı olup dokuların beslenme için ilk kullandığı enerji kaynağıdır(77). Yükselmesi şeker hastalığının bir göstergesidir. Ayrıca yüksek glukoz değerleri protez sonrası enfeksiyon oranlarını artırmaktadır(78, 79). Glukoz referans aralığı hastanemizde 74(75)-106(110) mg/dLdir.

Kreatinin kreatin fosfattan üretilen özellikle kas kitlelerinde depolanan ve böbrekten itrah olan bir yıkım ürünüdür. Yüksek kreatinin özellikle böbrek hastalıkları

için önem arz eder ve hasta hayatını riske eden bir durumdur(80). Kreatinin referans aralığı hastanemizde 0,51(0,67)-0,95(1,17) mg/dL dir.

Sodyum(Na) ve Potasyum(K) kan serumunda bulunan elektrolitlerdir. Kanda yükselmeleri veya düşmeleri birçok hastalığa işaret edebilir. Travma hastalarında özellikle kanda sodyum yükselmesi dehidratasyon bulgusu olabilir ve bu da hasta hayatını tehdit eden embolik olaylara sebep olabilir. Bu durum özellikle yaşlı hastalarda sıkça görülmektedir(81). Potasyumun ise hem yükselmesi hem de düşmesi ciddi kardiyak problemlere yol açabilmektedir. Potasyumun kanda yükselmesi ayrıca böbrek fonksiyonunu gösteren diğer bir parametredir(82). Sodyum referans aralığı hastanemizde 136-145 mmol/Ldir. Potasyum(K) referans aralığı hastanemizde 3,5-5,1 mmol/Ldir.

Karaciğer vücudun en önemli protein üretim ve metabolik atık yapım merkezidir. Bu sebeple vücudumuzun hayati organlarından biridir(83). Aspartat Aminotransferaz (AST) ve Alanin Aminotransferaz (ALT) karaciğer fonksiyonun gösteren hassas enzimlerdir. Karaciğer fonksiyonunun bozulduğu durumlarda(travma, enfeksiyon, kanser...vb.) kan serum düzeyleri artabilir(84). AST referans aralığı hastanemizde 1-50 U/L dir. ALT referans aralığı hastanemizde 1-45 U/L dir.

Tiroit hormonları iskelet büyümesinde ve kemik mineral dengesinde önemli rol oynar. Çocuklarda hipotiroidizm kemik matürasyonunda gecikmeye sebep olurken, yetişkinlerde aşırı artmış tiroit hormonları kemik kaybına ve ciddi şekilde kemik mineral bozukluğuna yol açar(85). Tiroit fonksiyonları için en sık bakılan parametreler serum TSH ve FT4 değerleridir. TSH referans aralığı hastanemizde 0,27(0,34)-4,2(5,6) µIU/mLdir. FT4 referans aralığı hastanemizde 0,61(0,93)-1,12(1,7) ng/dLdir.

Kronik hastalıkların kalça kırıkları için risk faktörleri bildirilmiştir. Ancak uygulanan tedavi sonrası prognozu nasıl etkilediği ile ilgili literatür yetersizdir. Bu sebeple çalışmamıza kronik hastalığı olan hastaları (kronik akciğer hastalığı, kronik böbrek hastalığı, diyabet, hipertansiyon ve kronik kalp hastalığı vs.) ekledik.


Dorr sınıflaması proksimal femur kemik kalitesini ve yapısını belirlemek için kullanılan bir sınıflamadır(86). Tip A'da trokanter minörün sonlanma yerinden başlayan kortikal kalınlık "huniye benzer" şekilde görünür ve diafiz kanal dardır.

Tip B’de diafizyal kanalda genişleme ve kortikal incelik mevcuttur. Tip C’de ise önemli ölçüde genişleyen diafizyal kanal “soba borusu” görünümünü alır(şekil 10). Dorr tip B ve C intraoperatif kırıklar için bir risk faktörüdür(87).




Şekil 10. DORR sınıflaması sırasıyla; tip A, B ve C

Protez durumunu belirlemek için kullanılan parametrelerden biri protezin pozisyonudur. Bu da protezin valgus veya varus pozisyonu olarak adlandırılır(şekil 11). Varus veya valgus pozisyon periprotetik kırıklar için risk faktörü olup klinik sonucu olumsuz etkileyebilmektedir. Çünkü kemik yapıda stres oluşturarak protezin kemiğin dışına çıkmasıyla revizyona sebep olabilmektedir(88, 89). Şekil 11’de kendi klinik hastalarımızdan normal, varus ve valgus pozisyonundaki protezlerin durumu gözükmektedir.



Şekil 11. Protez pozisyonu sırasıyla; normal, varus ve valgus pozisyon

Kalça restorasyonu için kullanılan parsiyel protezler için önemli diğer parametre bacak boyu uzunluğudur. Protez uygulanırken bacak boyu eşitliliğinin sağlanması gerekir. Aksi takdirde gluteus medius kas kısılması veya uzamasına sebep olarak manivela etkisi ile kalça dislokasyonuna sebep olabilmektedir(90). Bacak boyu uzunluk için pelvis anterior-posterior grafide birkaç ölçüm tekniği mevcuttur. Birincisi bi-iskial çizgi ile her iki trokanter minörün merkezi arası uzunluk farkı(91), ikincisi ise radyolojik ölçülen gözyaşı çizgileri ile her iki trokanter minörün merkezi arası uzunluk farkıdır(şekil 12)(92). Çalışmamızda her 2 yöntem de kullanıldı ve ölçümler “milimetre(mm)” cinsinden ölçülerek numerik olarak kaydedildi.



Şekil 12. Bacak boyu uzunluk ölçümü; gözyaşı çizgisi ile trokanter minör orta noktası veya bi-iskial çizgi ile trokanter minör orta hat dik uzaklık ölçümü

Yaralanma mekanizmaları için birçok sınıflama olmasına rağmen çalışmamızda düşük ve yüksek enerjili travma diye 2 ye ayırdık. Düşük enerjili travma sonrası kişide doku hasarı daha sınırlı ve küçük iken, yüksek enerjili travmalarda doku hasarı daha büyük ölçekli ve sınırları daha geniş olabilmektedir. Düşük enerjili travmalarda yaşlı hastalar daha sık zarar görürken, yüksek enerjili travmalarda her yaşta kişi zarara uğrayabilmektedir(93).

Kalça kırıklarının büyük bir kısmı izole olmasına rağmen yaklaşık %3-5 hastada özellikle radius distal ve humerus proksimal kırıklarına(şekil 13) rastlanılmaktadır(94). Bu sebeple ek kırık varlığının sonuçları etkileyip etkilemeyeceğini ölçmek istediğimiz için çalışmamıza dahil ettik.



Şekil 13. Kalça kırığına ek kırıklar sırasıyla; radius distal kırığı ve humerus proksimal kırığı

Kalça kırıkları literatürde proksimal femur diye bahsedilen femur baş kırıkları, femur boyun kırıkları, intertrokanterik femur kırıkları ve subtrokanterik femur kırıklarını (trokanter minörün 5 cm kadar aşağısı) içerir(şekil 14). Cerrahi operasyon gerektiren yetişkin ortopedik travma hastalarının yaklaşık % 12 sini oluşturur(95). Biz çalışmamızda femur baş kırığı sebebiyle bipolar parsiyel protez yapmadığımız için femur baş kırıklarını parametre olarak kullanmadık.



Şekil 14. Şematik Kalça kırık tipleri

Kalça kırıklı hastalarda deplase olmuş trokanter major kırıkları tespit etmek(şekil 15) gerekebilmektedir. Çeşitli tespit seçenekleri olmakla beraber çalışmamızda sadece tespit edilip edilmediğine bakarak parametrelerimizi genişlettik.




Şekil 15. Trokanter major tespiti uygulanmış bir hasta

Yaş ve cinsiyette kalça kırıklarında risk faktörü olarak belirlenmiştir(4, 5). Biz de çalışmamıza bu faktörlerin sonucu nasıl etkilediğini tespit etmek için 2 ayrı parametre olarak belirledik. Yaş numerik olarak kaydedildi.

Kan transfüzyonları travmaya bağlı kanaması olan hastalarda preoperatif veya postoperatif dönemde ihtiyaç olabilmektedir. Fakat kan transfüzyyonlarının ateş, alerjik reaksiyonlar, solunum problemler vb. ciddi komplikasyonları olabilmektedir(96). Bu sebeple de hasta hayatında olumsuz sonuçlara yol açabilmektedir. Hastaların takiplerinde preoperatif veya postoperatif kan transfüzyonu alıp almadığı tespit edilerek sonuçlara parametre olarak eklendi.

Bipolar parsiyel protez uygulanırken sementli(çimentolu) ve sementsiz(çimentosuz) olarak 2 çeşit yöntem mevcuttur(şekil 16). Sement kullanımı daha sıklıkla kemik kalitesi kötü hastalarda tercih edilmektedir(97). Sement kullanımında literatürde mikroemboliye bağlı ciddi kardiyopulmoner problemler veya ısıya bağlı dokularda nekroz alanları gibi olumsuz komplikasyonlar bildirilmiştir(98, 99). Bu sebeple sementli ve sementsiz olarak 2 ye ayırarak parametre olarak çalışmamıza ekledik.



Şekil 16. Protez tipi sırasıyla; sementsiz ve sementli

Hastaların erken mobilizasyonları açısından kırığın oluştuğu tarih ile opere olduğu tarih arasındaki süre önemlidir. Çünkü 4 gün içerisinde yapılan operasyonların hasta üzerinde daha olumlu etkileri mevcuttur. Bu süre arttıkça mortalite oranları artmaktadır(100). Bu sebeple bu süre de parametre olarak değerlendirildi ve numerik olarak kaydedildi.

Operasyon süreleri hastanın anestezi maruziyeti açısından önemlidir. Literatürde anestezi için kullanılan ilaçlarının zararları bildirilmiştir(101-103). Bu sebeple bu süre de parametre olarak değerlendirildi ve numerik olarak kaydedildi.

Ölüm analizi için kullanılan parametreler yaş, cinsiyet, travma derecesi, travma esnasındaki ek kırık durumu, başvuru anındaki kan tahlilleri(böbrek, karaciğer ve tiroit fonksiyonu), kronik hastalık varlığı, kırık sınıflaması, uygulanan protez tipi, kemik kalitesi, başvuru tarihinden operasyon tarihine kadar geçen süre, ameliyat süresi, kan transfüzyonudur.

Revizyon analizi için kullanılan parametreler yaş, cinsiyet, travma derecesi, travma esnasındaki ek kırık durumu, başvuru anındaki kan tahlilleri(böbrek, karaciğer ve tiroit fonksiyonu), kronik hastalık varlığı, kırık sınıflaması, kemik kalitesi, uygulanan protez tipi, protez yerleşimi, trokanterik major tespiti, bacak uzunluk farkı,

başvuru tarihinden operasyon tarihine kadar geçen süre, ameliyat süresi, kan transfüzyonudur.

Hastanede kalım süresini ve maliyeti değerlendirmek için kullanılan parametreler yaş, cinsiyet, travma derecesi, travma esnasındaki ek kırık durumu, başvuru anındaki kan tahlilleri(böbrek, karaciğer ve tiroit fonksiyonu), kronik hastalık varlığı, kırık sınıflaması, kemik kalitesi, uygulanan protez tipi, başvuru tarihinden operasyon tarihine kadar geçen süre, ameliyat süresi, kan transfüzyonudur.

Algoritmaların karşılaştırılması için tüm modeller için 10 kat çapraz geçişleme (k-cross fold validation) kullanılmıştır. Numerik değerler min-max yöntemi ile normalize (0 ile 1 aralığında) edilmiştir. Kırık sınıflaması ve DORR sınıflaması nominal olarak değiştirilmiştir.

3.2. Perioperatif Bakım

Perioperatif bakım hastanın ameliyat öncesi hazırlanması, ameliyat sırasında anestezinin verilmesi, ameliyat sona erdiğinde anestezinin sonlandırılması ve eski fonksiyonlarını kazanana kadar tedavisinin ve bakımının yapılmasıdır. Perioperatif bakımın amacı cerrahi müdahalenin hasta için en güvenli şekilde, en az riskle ve operasyondan yüksek yarar sağlayacak şekilde gerçekleştirilmesidir. Perioperatif analiz de bu süre içerisinde hasta prognozunu etkileyecek faktörleri en doğru şekilde tespit edilmesidir.

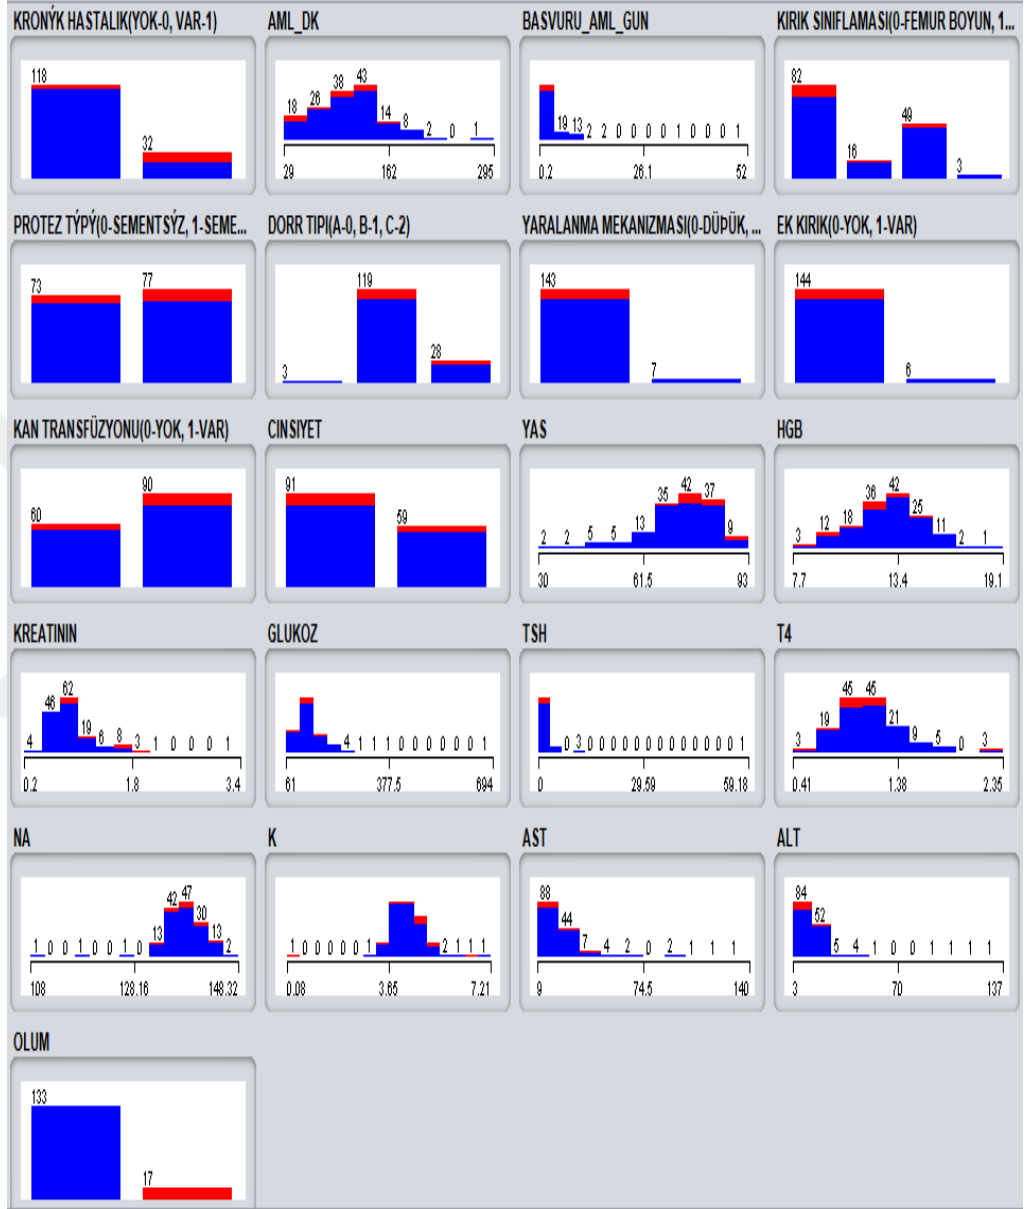
3.3. Cerrahi Teknik

Hastaların tamamına lateral dekübit pozisyonunda kalçaları steril bir şekilde boyanıp örtülerek pozisyon verildi. Posterolateral insizyonla cilt ciltaltı fasya geçildi. Dış rotatorlar işaretlenerek femur yapışma yerinden sıyrıldı. Daha sonra trokanter major üzerinden eklem kapsülüne kadar periostla birlikte sıyrıldı. Kalça eklem kapsülü insize edilerek kırık başa ulaşıldı. Kırık baş veya boyun çıkarıldı. Asetabulum etrafı yumuşak dokulardan izole edildi. Daha sonra femura geçildi. Femoral anteversiyona uygun şekilde raspalandı. Uygun femoral komponent (sementli veya sementsiz) açılarak femur medullasına anteversiyona uygun bir şekilde çakıldı. Trokanter Major tespit gerektiren hastaların kırık hattı redükte edilerek en uygun materyal (serklaj teli, cable vs.) ile tespit edildi.

4. BULGULAR

4.1. Ölüm Analiz Modelleri Ve Sonuçları

Ölüm analizi için kullanılan parametreler ve oransal değerler aşağıda verilmiştir(şekil 17).



Şekil 17. Ölüm analizi için parametreler ve oransal değerleri(mavi-ölüm(-), kırmızı-ölüm(+))

4.1.1. Naive Bayes

Tablo 3. Ölüm analiz sonucu-Naive Bayes Modeli

```
=== Stratified cross-validation ===  
=== Summary ===  
  
Correctly Classified Instances   130      86.6667 %  
Incorrectly Classified Instances  20      13.3333 %  
Kappa statistic                  -0.0352  
Mean absolute error              0.1737  
Root mean squared error         0.3165  
Relative absolute error         84.49 %  
Root relative squared error     99.7307 %  
Total Number of Instances       150  
  
=== Detailed Accuracy By Class ===  
  
Class      TP Rate  FP Rate  Precision  Recall  F-Measure  MCC    ROC Area  PRC Area  
0          0.977   1.000   0.884     0.977   0.929     -0.051  0.714    0.933  
1          0.000   0.023   0.000     0.000   0.000     -0.051  0.714    0.226  
Weighted Avg. 0.867   0.889   0.784     0.867   0.823     -0.051  0.714    0.853  
  
=== Confusion Matrix ===  
  
a  b  <-- classified as  
130 3 | a = 0  
17  0 | b = 1
```

Naive bayes modeli ile % 86.6 ile doğruluk elde edilmiştir. Ortalama olarak precision 0.784, recall 0.867, F-ölçüm 0.823 ve ROC 0.714 bulunmuştur(tablo 3).

4.1.2. Destek Vektör Makineleri (SGD)

Tablo 4. Ölüm analiz sonucu-Destek Vektör Makineleri (SGD) Modeli

OLUM
2.1592 (normalized) KRONİK HASTALIK(YOK-0, VAR-1)=1
+ -2.7844 (normalized) AML_DK
+ -4.6595 (normalized) BASVURU_AML_GUN
+ 0.1 (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABYL, 2-YTFF YNSTABYL, 3-SUBTROKANTERYK=0
+ -0.2799 (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABYL, 2-YTFF YNSTABYL, 3-SUBTROKANTERYK=1
+ -0.6997 (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABYL, 2-YTFF YNSTABYL, 3-SUBTROKANTERYK=2
+ -0.1099 (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABYL, 2-YTFF YNSTABYL, 3-SUBTROKANTERYK=3
+ 0.8996 (normalized) PROTEZ TYPY(0-SEMENTSYZ, 1-SEMENTLY)=1
+ -0.6597 (normalized) DORR TIPI(A-0, B-1, C-2)=0
+ -0.3098 (normalized) DORR TIPI(A-0, B-1, C-2)=1
+ -0.02 (normalized) DORR TIPI(A-0, B-1, C-2)=2
+ -0.1699 (normalized) YARALANMA MEKANIZMASI(0-DUPUK, 1-YUKSEK)=1
+ 0.9097 (normalized) EK KIRIK(0-YOK, 1-VAR)=1
+ -0.2199 (normalized) KAN TRANSFUZYONU(0-YOK, 1-VAR)=1
+ -0.3898 (normalized) CINSIYET=E
+ 0.9451 (normalized) YAS
+ -2.1907 (normalized) HGB
+ 2.7818 (normalized) KREATININ
+ -0.6948 (normalized) GLUKOZ
+ -0.2318 (normalized) TSH
+ -0.6367 (normalized) T4
+ 0.0852 (normalized) NA
+ 0.1138 (normalized) K
+ 0.253 (normalized) AST
+ 0.5754 (normalized) ALT
- 0.99

Tablo 5. Tablo 4 ün devamı

```
=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances   133      88.6667 %
Incorrectly Classified Instances  17      11.3333 %
Kappa statistic                  0.3531
Mean absolute error              0.1133
Root mean squared error          0.3367
Relative absolute error          55.1373 %
Root relative squared error      106.0683 %
Total Number of Instances       150

=== Detailed Accuracy By Class ===

```

Class	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area
0	0.955	0.647	0.920	0.955	0.937	0.360	0.654	0.919
1	0.353	0.045	0.500	0.353	0.414	0.360	0.654	0.250
Weighted Avg.	0.887	0.579	0.873	0.887	0.878	0.360	0.654	0.843

```

=== Confusion Matrix ===

 a  b  <-- classified as
127  6 | a = 0
 11  6 | b = 1

```

Destek vektör makinesi SGD optimizasyon modeli ile % 88.6 doğruluk oranı elde edilmiştir. Ortalama olarak precision 0.873, recall 0.887, F-ölçüsü 0.878 ve ROC 0.654 bulunmuştur. Ağırlık olarak pozitif yönde ilk 3 parametre kreatinin (2.7818), kronik hastalık (2.1592) ve yaş (0.9451) tespit edilmiştir(tablo4-5).

4.1.3. Destek Vektör Makineleri (SMO)

Tablo 6. Ölüm analiz sonucu-Destek Vektör Makineleri (SMO) Modeli

BinarySMO
Machine linear: showing attribute weights, not support vectors.
1.0201 * (normalized) KRONÝK HASTALIK(YOK-0, VAR-1)=1
+ -1.0397 * (normalized) AML_DK
+ -1.1057 * (normalized) BASVURU_AML_GUN
+ 0.2301 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-ÝTFF STABÝL, 2-ÝTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=0
+ 0 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-ÝTFF STABÝL, 2-ÝTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=1
+ -0.2301 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-ÝTFF STABÝL, 2-ÝTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=2
+ 0 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-ÝTFF STABÝL, 2-ÝTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=3
+ 0.5001 * (normalized) PROTEZ TÝPÝ(0-SEMENTSÝZ, 1-SEMENTLÝ)=1
+ -0.2113 * (normalized) DORR TIPI(A-0, B-1, C-2)=0
+ -0.0821 * (normalized) DORR TIPI(A-0, B-1, C-2)=1
+ 0.2934 * (normalized) DORR TIPI(A-0, B-1, C-2)=2
+ -0.0569 * (normalized) YARALANMA MEKANIZMASI(0-DÜPÜK, 1-YÜKSEK)=1
+ 0.4009 * (normalized) EK KIRIK(0-YOK, 1-VAR)=1
+ -0.0887 * (normalized) KAN TRANSFÜZYONU(0-YOK, 1-VAR)=1
+ -0.2113 * (normalized) CINSIYET=E
+ 0.3604 * (normalized) YAS
+ -0.5543 * (normalized) HGB
+ 1.4928 * (normalized) KREATININ
+ -0.1306 * (normalized) GLUKOZ
+ -0.0983 * (normalized) TSH
+ -0.5441 * (normalized) T4
+ -0.1419 * (normalized) NA
+ 0.1558 * (normalized) K
+ 0.1029 * (normalized) AST
+ 0.5188 * (normalized) ALT
- 1.5395

Tablo 7. Tablo 6 nın devamı

```
=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances   133      88.6667 %
Incorrectly Classified Instances  17      11.3333 %
Kappa statistic                  0.1539
Mean absolute error              0.1133
Root mean squared error          0.3367
Relative absolute error          55.1373 %
Root relative squared error      106.0683 %
Total Number of Instances       150

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area
Class
                0.985  0.882  0.897   0.985  0.939   0.202  0.551  0.897  0
                0.118  0.015  0.500   0.118  0.190   0.202  0.551  0.159  1
Weighted Avg.   0.887  0.784  0.852   0.887  0.854   0.202  0.551  0.813

=== Confusion Matrix ===

 a  b  <-- classified as
131  2 | a = 0
 15  2 | b = 1
```

Destek vektör makinesi SMO optimizasyon modeli ile % 88.6 doğruluk oranı elde edilmiştir. Ortalama olarak precision 0.852, recall 0.887, F-ölçüsü 0.854 ve ROC 0.551 bulunmuştur. Ağırlık olarak pozitif yönde ilk 3 parametre kreatinin (1.4928), kronik hastalık (1.0201) ve ALT (0.5188) tespit edilmiştir(tablo6-7).

4.1.4. Karar Ağacı (J48)

Tablo 8. Ölüm analiz sonucu-Karar Ağacı (J48) Modeli

```

J48 pruned tree
KRONÝK HASTALIK(YOK-0, VAR-1) = 0
| KREATININ <= 0.25: 0 (90.0)
| KREATININ > 0.25
| | GLUKOZ <= 0.060032: 1 (3.0)
| | GLUKOZ > 0.060032: 0 (25.0/2.0)
KRONÝK HASTALIK(YOK-0, VAR-1) = 1
| BASVURU_AML_GUN <= 0.098456: 1 (12.0/2.0)
| BASVURU_AML_GUN > 0.098456: 0 (20.0/2.0)
Number of Leaves :      5

Size of the tree : 9
=== Stratified cross-validation ===
=== Summary ===

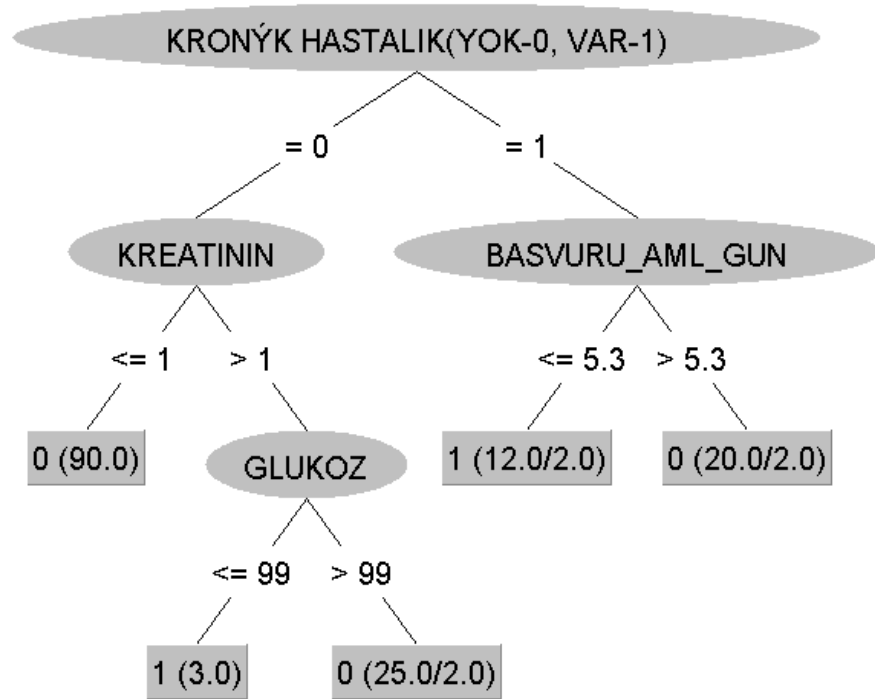
Correctly Classified Instances   137      91.3333 %
Incorrectly Classified Instances  13      8.6667 %
Kappa statistic                  0.4744
Mean absolute error              0.1136
Root mean squared error         0.2839
Relative absolute error         55.2665 %
Root relative squared error     89.4585 %
Total Number of Instances      150

=== Detailed Accuracy By Class ===
                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area
Class
                0.977  0.588  0.929  0.977  0.952  0.495  0.790  0.957  0
                0.412  0.023  0.700  0.412  0.519  0.495  0.790  0.429  1
Weighted Avg.  0.913  0.524  0.903  0.913  0.903  0.495  0.790  0.897

=== Confusion Matrix ===
 a  b  <-- classified as
130  3 | a = 0
 10  7 | b = 1

```

Karar ağacı modeli ile % 91.3 doğruluk oranı elde edilmiştir. Ortalama olarak precision 0.903, recall 0.913, F-ölçüsü 0.903 ve ROC 0.790 bulunmuştur. Model ağacın en tepesine kronik hastalık yerleştirmiş ve sonrasında kreatinin ve başvuru tarihi ile ameliyat edildiği tarih arasındaki süreyi dallandırmıştır(şekil 18). Kronik hastalık yoksa kreatinine, kronik hastalık varsa başvuru tarihi ile ameliyat edildiği tarih arasındaki süreye ağırlık vermiştir(tablo 8).



Şekil 18. Karar Ağacı Analizin Model Görüntüsü

4.1.5. Yapay Sinir Ağları

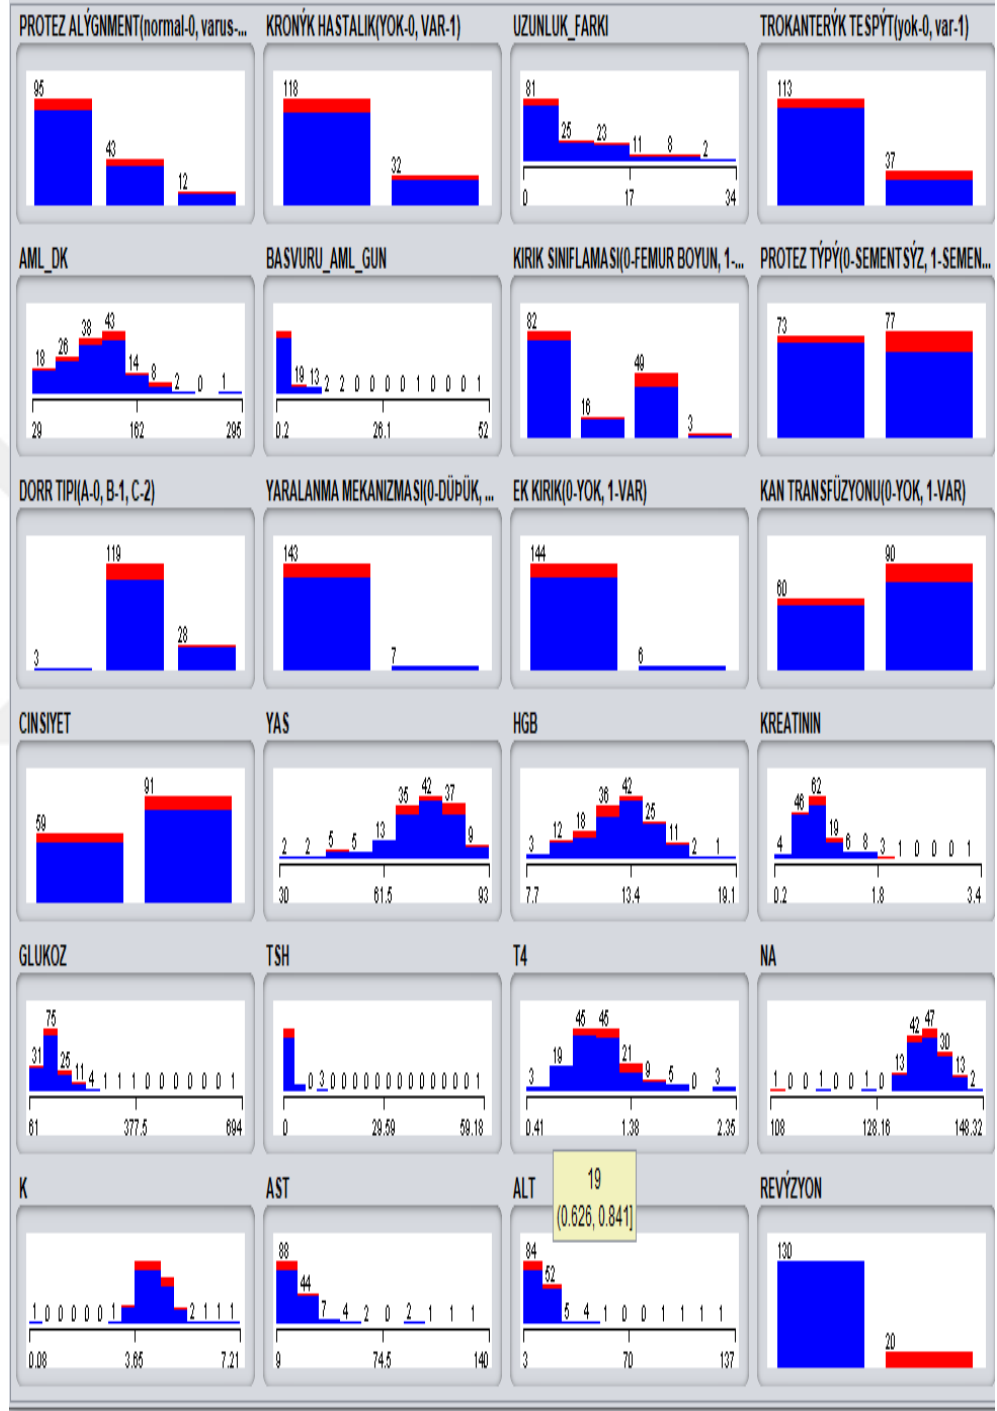
Tablo 9. Ölüm analiz sonucu-Yapay Sinir Ağları Modeli

```
=== Stratified cross-validation ===  
=== Summary ===  
  
Correctly Classified Instances   127      84.6667 %  
Incorrectly Classified Instances  23      15.3333 %  
Kappa statistic                 0.2561  
Mean absolute error             0.152  
Root mean squared error         0.3477  
Relative absolute error         73.9511 %  
Root relative squared error     109.5485 %  
Total Number of Instances      150  
  
=== Detailed Accuracy By Class ===  
Class      TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area  
0          0.910   0.647   0.917     0.910   0.913     0.256  0.737   0.949  
1          0.353   0.090   0.333     0.353   0.343     0.256  0.737   0.363  
Weighted Avg. 0.847  0.584  0.851     0.847   0.849     0.256  0.737  0.882  
  
=== Confusion Matrix ===  
  
a  b  <-- classified as  
121 12 | a = 0  
11  6 | b = 1
```

Yapay sinir ağ modeli ile % 84.6 ile doğruluk elde edilmiştir. Ortalama olarak precision 0.851, recall 0.847, F-ölçüsü 0.849 ve ROC 0.737 bulunmuştur(tablo 9).

4.2. Revizyon Analiz Modelleri ve Sonuçları

Revizyon analizi için kullanılan parametreler ve oransal değerleri aşağıda verilmiştir(şekil 19).



Şekil 19. Revizyon analizi için parametreler ve oransal değerleri(mavi-rev(-), kırmızı-rev(+))

4.2.1. Naive Bayes

Tablo 10. Revizyon analiz sonucu-Naive Bayes Modeli.

```
=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances   122      81.3333 %
Incorrectly Classified Instances  28      18.6667 %
Kappa statistic                 -0.0825
Mean absolute error             0.247
Root mean squared error         0.3724
Relative absolute error         105.1024 %
Root relative squared error     109.539 %
Total Number of Instances      150

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area
Class
                0.938  1.000  0.859   0.938  0.897   -0.093  0.551  0.875  0
                0.000  0.062  0.000   0.000  0.000   -0.093  0.551  0.152  1
Weighted Avg.   0.813  0.875  0.745   0.813  0.777   -0.093  0.551  0.779

=== Confusion Matrix ===

 a  b  <-- classified as
122  8 | a = 0
 20  0 | b = 1
```

Naive bayes modeli ile % 81,3 ile doğruluk elde edilmiştir. Ortalama olarak precision 0.745, recall 0.813, F-ölçüsü 0.777 ve ROC 0.551 bulunmuştur(tablo 10).

4.2.2. Destek Vektör Makineleri (SGD)

Tablo 11. Revizyon analiz sonucu-Destek Vektör Makineleri (SGD) Modeli

REVZYON =	-0.1999 (normalized) PROTEZ ALYGNMENT(normal-0, varus-1, valgus-2)=0
+	-0.2899 (normalized) PROTEZ ALYGNMENT(normal-0, varus-1, valgus-2)=1
+	-0.1699 (normalized) PROTEZ ALYGNMENT(normal-0, varus-1, valgus-2)=2
+	0.03 (normalized) KRONYK HASTALIK(YOK-0, VAR-1)=1
+	0.2931 (normalized) UZUNLUK_FARKI
+	0.11 (normalized) TROKANTERYK TESPYT(yok-0, var-1)=1
+	-0.2586 (normalized) AML_DK
+	-0.494 (normalized) BASVURU_AML_GUN
+	-0.1499 (normalized) KIRIK SINIFLAMASI =0
+	-0.5098 (normalized) KIRIK SINIFLAMASI=1
+	-0.0599 (normalized) KIRIK SINIFLAMASI=2
+	0.06 (normalized) KIRIK SINIFLAMASI =3
+	0.1999 (normalized) PROTEZ TYPY(0-SEMENTSYZ, 1-SEMENTLY)=1
+	-0.1399 (normalized) DORR TIPI(A-0, B-1, C-2)=0
+	-0.1799 (normalized) DORR TIPI(A-0, B-1, C-2)=1
+	-0.3398 (normalized) DORR TIPI(A-0, B-1, C-2)=2
+	-0.1199 (normalized) YARALANMA MEKANIZMASI(0-DUPUK, 1-YUKSEK)=1
+	0.1099 (normalized) EK KIRIK(0-YOK, 1-VAR)=1
+	0.09 (normalized) KAN TRANSFUZYONU(0-YOK, 1-VAR)=1
+	-0.03 (normalized) CINSIYET=K
+	0.0792 (normalized) YAS
+	0.1844 (normalized) HGB
+	0.5296 (normalized) KREATININ
+	0.4176 (normalized) GLUKOZ
+	-0.3227 (normalized) TSH
+	0.3204 (normalized) T4
+	-0.3054 (normalized) NA
+	-0.1604 (normalized) K
+	0.3313 (normalized) AST
+	0.2371 (normalized) ALT
-	0.66

Tablo 12. Tablo 11'in devamı

```
=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances   128      85.3333 %
Incorrectly Classified Instances  22      14.6667 %
Kappa statistic                  -0.0248
Mean absolute error              0.1467
Root mean squared error          0.383
Relative absolute error          62.4017 %
Root relative squared error      112.6462 %
Total Number of Instances       150

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area
Class
                0.985   1.000   0.865     0.985   0.921     -0.046  0.492   0.865   0
                0.000   0.015   0.000     0.000   0.000     -0.046  0.492   0.133   1
Weighted Avg.   0.853   0.869   0.750     0.853   0.798     -0.046  0.492   0.767

=== Confusion Matrix ===

 a  b  <-- classified as
128 2 | a = 0
 20 0 | b = 1
```

Destek vektör makinesi SGD optimizasyon modeli ile % 85.3 doğruluk oranı elde edilmiştir. Ortalama olarak precision 0.750, recall 0.853, F-ölçüsü 0.798 ve ROC 0.492 bulunmuştur. Ağırlık olarak pozitif yönde ilk 3 kreatinin (0.5296), glukoz (0.4176) ve AST (0.3313) tespit edilmiştir(tablo 11-12).

4.2.3. Destek Vektör Makineleri (SMO)

Tablo 13. Revizyon analiz sonucu-Destek Vektör Makineleri (SMO) Modeli

BinarySMO
0 * (normalized) PROTEZ ALÝGNMENT(normal-0, varus-1, valgus-2)=0
+ -0.0004 * (normalized) PROTEZ ALÝGNMENT(normal-0, varus-1, valgus-2)=1
+ 0.0004 * (normalized) PROTEZ ALÝGNMENT(normal-0, varus-1, valgus-2)=2
+ -0.0007 * (normalized) KRONÝK HASTALIK(YOK-0, VAR-1)=1
+ 0.0014 * (normalized) UZUNLUK_FARKI
+ 0.0008 * (normalized) TROKANTERÝK TESPÝT(yok-0, var-1)=1
+ -0.0009 * (normalized) AML_DK
+ 0.0013 * (normalized) BASVURU_AML_GUN
+ 0.0003 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABÝL, 2-YTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=0
+ -0.0012 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABÝL, 2-YTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=1
+ 0.0006 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABÝL, 2-YTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=2
+ 0.0002 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABÝL, 2-YTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=3
+ 0.0003 * (normalized) PROTEZ TÝPÝ(0-SEMENTSÝZ, 1-SEMENTLÝ)=1
+ -0.0011 * (normalized) DORR TIPI(A-0, B-1, C-2)=0
+ 0.0004 * (normalized) DORR TIPI(A-0, B-1, C-2)=1
+ 0.0006 * (normalized) DORR TIPI(A-0, B-1, C-2)=2
+ -0.0007 * (normalized) YARALANMA MEKANIZMASI(0-DÜPÜK, 1-YÜKSEK)=1
+ 0.0006 * (normalized) EK KIRIK(0-YOK, 1-VAR)=1
+ 0 * (normalized) KAN TRANSFÜZYONU(0-YOK, 1-VAR)=1
+ 0.0002 * (normalized) CINSİYET=K
+ -0.0006 * (normalized) YAS
+ 0.0024 * (normalized) HGB
+ 0.0028 * (normalized) KREATININ
+ 0.0017 * (normalized) GLUKOZ
+ -0.0232 * (normalized) TSH
+ 0.0004 * (normalized) T4
+ -0.0008 * (normalized) NA
+ -0.0005 * (normalized) K
+ 0.0073 * (normalized) AST
+ -0.0055 * (normalized) ALT
- 1.0022

Tablo 14. Tablo 13'ün devamı

```

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances   130      86.6667 %
Incorrectly Classified Instances  20      13.3333 %
Kappa statistic                  0
Mean absolute error              0.1333
Root mean squared error          0.3651
Relative absolute error          56.7288 %
Root relative squared error      107.4039 %
Total Number of Instances       150

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area
Class
    1.000  1.000  0.867    1.000  0.929  ?    0.500  0.867  0
    0.000  0.000  ?      0.000  ?      ?    0.500  0.133  1
Weighted Avg.  0.867  0.867  ?      0.867  ?      ?    0.500  0.769

=== Confusion Matrix ===

  a  b  <-- classified as
130  0  |  a = 0
 20  0  |  b = 1

```

Destek vektör makinesi SMO optimizasyon modeli ile % 86.6 doğruluk oranı elde edilmiştir. Ortalama olarak precision belirsiz, recall 0.867, F-ölçüsü belirsiz ve ROC 0.500 bulunmuştur. Ağırlık olarak pozitif yönde ilk 3 parametre AST (0.0073), kreatinin (0.0028) ve hemogloblin (0.0024) tespit edilmiştir(tablo13-14).

4.2.4 Karar Ağacı (J48)

Tablo 15. Revizyon analiz sonucu-Karar Ağacı (J48) Modeli

```
J48 pruned tree
-----
: 0 (150.0/20.0)

Number of Leaves :      1

Size of the tree : 1

Time taken to build model: 0.03 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances   122      81.3333 %
Incorrectly Classified Instances  28      18.6667 %
Kappa statistic                  -0.0244
Mean absolute error              0.2266
Root mean squared error          0.3949
Relative absolute error          96.4225 %
Root relative squared error      116.1495 %
Total Number of Instances       150

=== Detailed Accuracy By Class ===

      TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area  Class
      0.931  0.950  0.864    0.931  0.896    -0.026  0.510  0.869    0
      0.050  0.069  0.100    0.050  0.067    -0.026  0.510  0.144    1
Weighted Avg.   0.813  0.833  0.762    0.813  0.786    -0.026  0.510  0.772

=== Confusion Matrix ===
 a  b  <-- classified as
121  9 | a = 0
 19  1 | b = 1
```

Karar ağacı modeli ile % 81,3 doğruluk oranı elde edilmiştir. Ortalama olarak precision 0.762, recall 0.813, F-ölçüsü 0.786 ve ROC 0.510 bulunmuştur(tablo 15).

4.2.5. Yapay Sinir Ağları

Tablo 16. Revizyon analiz sonucu-Yapay Sinir Ağları Modeli

```

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances   117      78 %
Incorrectly Classified Instances  33      22 %
Kappa statistic                 -0.1174
Mean absolute error             0.2257
Root mean squared error         0.4483
Relative absolute error         96.0298 %
Root relative squared error     131.8508 %
Total Number of Instances      150

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area
Class
                0.900   1.000   0.854     0.900   0.876     -0.121  0.417   0.858   0
                0.000   0.100   0.000     0.000   0.000     -0.121  0.417   0.114   1
Weighted Avg.   0.780   0.880   0.740     0.780   0.760     -0.121  0.417   0.759

=== Confusion Matrix ===

a b <-- classified as
117 13 | a = 0
20  0 | b = 1

```

Yapay sinir ađ modeli ile % 78 ile dođruluk elde edilmiřtir. Ortalama olarak precision 0.740, recall 0.780, F-ölçüsü 0.760 ve ROC 0.417 bulunmuřtur(tablo16).

4.3. Hastanede Kalım Süresi Analiz Modelleri Ve Sonuçları

4.3.1. Linear Regresyon

Tablo 17. Hastanede Kalım Süresi Analiz Sonucu-Linear Regresyon Modeli

```
Linear Regression Model

T_TOPLAMGUNSAAT =

77.7364 * BASVURU_AML_GUN +
12.7485 * NA +
-3.5139

Time taken to build model: 0.02 seconds

=== Cross-validation ===
=== Summary ===

Correlation coefficient      0.6439
Mean absolute error        4.6599
Root mean squared error    8.9056
Relative absolute error    77.1243 %
Root relative squared error 75.5442 %
Total Number of Instances  150
```

Linear regresyon modeli 4.65 MAE ve 8.90 RMSE hatası ile çalışmıştır. Başvuru tarihi ile ameliyat olduđu tarih arasındaki süreyi en fazla ađırlık verdiđi parametre olarak belirlemiřtir(tablo 17).

4.3.2. Destek Vektör Makineleri (SMOReg)

Tablo 18. Hastanede Kalım Süresi Analiz Sonucu-Destek Vektör Makineleri (SMOReg) Modeli

SMOreg
weights (not support vectors):
+ 0.0041 * (normalized) KRONÝK HASTALIK 0-YOK, 1-VAR=1
- 0.0012 * (normalized) AML_DK
+ 0.7108 * (normalized) BASVURU_AML_GUN
- 0.0076 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABÝL, 2-YTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=0
+ 0.0022 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABÝL, 2-YTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=1
+ 0.0067 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABÝL, 2-YTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=2
- 0.0014 * (normalized) KIRIK SINIFLAMASI(0-FEMUR BOYUN, 1-YTFF STABÝL, 2-YTFF ÝNSTABÝL, 3-SUBTROKANTERÝK=3
- 0.0169 * (normalized) PROTEZ TÝPÝ(0-SEMENTSÝZ, 1-SEMENTLÝ)=1
+ 0.0025 * (normalized) DORR TIPI(A-0, B-1, C-2)=0
- 0.0097 * (normalized) DORR TIPI(A-0, B-1, C-2)=1
+ 0.0073 * (normalized) DORR TIPI(A-0, B-1, C-2)=2
+ 0.0139 * (normalized) YARALANMA MEKANIZMASI(0-DÜPÜK, 1-YÜKSEK)=1
+ 0.007 * (normalized) EK KIRIK(0-YOK, 1-VAR)=1
+ 0.0055 * (normalized) KAN TRANSFÜZYONU(0-YOK, 1-VAR)=1
- 0.0078 * (normalized) CINSIYET=E
+ 0.0097 * (normalized) YAS
+ 0.0297 * (normalized) HGB
+ 0.0167 * (normalized) KREATININ
- 0.0266 * (normalized) GLUKOZ
+ 0.0233 * (normalized) TSH
- 0.0109 * (normalized) T4
+ 0.0118 * (normalized) NA
+ 0.0108 * (normalized) K
+ 0.0761 * (normalized) AST
- 0.0123 * (normalized) ALT
- 0.0141

=== Cross-validation ===	
=== Summary ===	
Correlation coefficient	0.713
Mean absolute error	3.4874
Root mean squared error	8.4684
Relative absolute error	57.7187 %
Root relative squared error	71.8356 %
Total Number of Instances	150

Destek vektör makinesi SMO optimizasyon modeli 3.48 MAE ve 8.46 RMSE hatası ile çalışmıştır. Başvuru tarihi ile ameliyat olduğu tarih arasındaki süreyi en fazla ağırlık verdiği parametre olarak belirlemiştir(tablo18-19).

4.3.3. Karar Ağacı (Decision Stump)

Tablo 19. Hastanede Kalım Süresi Analiz Sonucu-Karar Ağacı (Decision Stump) Modeli

Decision Stump	
Classifications	
BASVURU_AML_GUN <= 0.4893822393822394 : 10.75792432432432	
BASVURU_AML_GUN > 0.4893822393822394 : 70.65554999999986	
BASVURU_AML_GUN is missing : 11.556559333333334	
=== Cross-validation ===	
=== Summary ===	
Correlation coefficient	0.3677
Mean absolute error	6.0115
Root mean squared error	11.6982
Relative absolute error	99.4941 %
Root relative squared error	99.2337 %
Total Number of Instances	150

Karar ağacı modeli 6.01 MAE ve 11.69 RMSE hatası ile çalışmıştır. Başvuru tarihi ile ameliyat olduğu tarih arasındaki süreyi en fazla ağırlık verdiği parametre olarak belirlemiştir(tablo 19).

4.4. Maliyet Analiz Modelleri Ve Sonuçları

4.4.1. Lineer Regresyon

Tablo 20. Maliyet Analiz Sonucu-Lineer Regresyon Modeli

Linear Regression Model	
T_TUTAR =	
-624.39 * KRONÝK HASTALIK 0-YOK, 1-VAR=1 +	
11833.8866 * BASVURU_AML_GUN +	
457.659 * PROTEZ TÝPÝ(0-SEMENTSÝZ, 1-SEMENTLÝ)=0 +	
394.3674 * KAN TRANSFÜZYONU(0-YOK, 1-VAR)=1 +	
-1278.6034 * HGB +	
-1125.2091 * T4 +	
1351.237 * ALT +	
5439.6335	
Time taken to build model: 0.11 seconds	
=== Cross-validation ===	
=== Summary ===	
Correlation coefficient	0.601
Mean absolute error	984.0617
Root mean squared error	1460.3196
Relative absolute error	95.1005 %
Root relative squared error	80.3078 %
Total Number of Instances	150

Lineer regresyon modeli 984.0 MAE ve 1460.3 RMSE hatası ile çalışmıştır. Başvuru tarihi ile ameliyat olduğu tarih arasındaki süreyi en fazla ağırlık verdiği parametre olarak belirlemiştir. ALT ve protez tipi (sementsiz) daha sonraki ağırlıklar olarak belirlemiştir(tablo 20).

4.4.2. Destek Vektör Makineleri (SMOReg)

Tablo 21. Maliyet Analiz Sonucu-Destek Vektör Makineleri (SMOreg) Modeli

SMOreg	
weights (not support vectors):	
-	0.0089 * (normalized) KRONÝK HASTALIK 0-YOK, 1-VAR=1
+	0.0432 * (normalized) AML_DK
+	0.7317 * (normalized) BASVURU_AML_GUN
+	0.0214 * (normalized) KIRIK SINIFLAMASI =0
+	0.0165 * (normalized) KIRIK SINIFLAMASI =1
+	0.0208 * (normalized) KIRIK SINIFLAMASI =2
-	0.0588 * (normalized) KIRIK SINIFLAMASI =3
-	0.006 * (normalized) PROTEZ TÝPÝ(0-SEMENTSÝZ, 1-SEMENTLÝ)=1
+	0.0398 * (normalized) DORR TIPI(A-0, B-1, C-2)=0
-	0.0122 * (normalized) DORR TIPI(A-0, B-1, C-2)=1
-	0.0276 * (normalized) DORR TIPI(A-0, B-1, C-2)=2
+	0.0396 * (normalized) YARALANMA MEKANIZMASI(0-DÜBÜK, 1-YÜKSEK)=1
+	0.0128 * (normalized) EK KIRIK(0-YOK, 1-VAR)=1
+	0.0321 * (normalized) KAN TRANSFÜZYONU(0-YOK, 1-VAR)=1
-	0.0247 * (normalized) CINSIYET=E
-	0.0208 * (normalized) YAS
-	0.0079 * (normalized) HGB
+	0.0418 * (normalized) KREATININ
+	0.0109 * (normalized) GLUKOZ
+	0.0088 * (normalized) TSH
-	0.0936 * (normalized) T4
-	0.0974 * (normalized) NA
+	0.0172 * (normalized) K
-	0.0489 * (normalized) AST
+	0.0698 * (normalized) ALT
+	0.28

=== Cross-validation ===	
=== Summary ===	
Correlation coefficient	0.6529
Mean absolute error	868.1687
Root mean squared error	1374.6645
Relative absolute error	83.9005 %
Root relative squared error	75.5973 %
Total Number of Instances	150

Destek vektör makinesi SMO optimizasyon modeli 868.1 MAE ve 1374.6 RMSE hatası ile çalışmıştır. Başvuru tarihi ile ameliyat olduğu tarih arasındaki süreyi en fazla ağırlık verdiği parametre olarak belirlemiştir(tablo 21).

4.4.3. Karar Ağacı (Decision Stump)

Tablo 22. . Maliyet Analiz Sonucu-Karar Ağacı (Decision Stump) Modeli

Decision Stump	
BASVURU_AML_GUN <= 0.3011583011583012 : 5629.275510204083	
BASVURU_AML_GUN > 0.3011583011583012 : 14057.469999999945	
BASVURU_AML_GUN is missing : 5797.839399999998	
=== Cross-validation ===	
=== Summary ===	
Correlation coefficient	0.4951
Mean absolute error	962.4406
Root mean squared error	1584.6889
Relative absolute error	93.011 %
Root relative squared error	87.1472 %
Total Number of Instances	150

Karar ağacı modeli 962.4 MAE ve 1584.6 RMSE hatası ile çalışmıştır. Başvuru tarihi ile ameliyat olduğu tarih arasındaki süreyi en fazla ağırlık verdiği parametre olarak belirlemiştir(tablo 22).

5. TARTIŞMA

Tartışma kısmında çalışmamızda elde ettiğimiz sonuçları 2 basamaklı olarak inceleyeceğiz. Birincisi; kullanılan modellerin performansların karşılaştırmasını yapacağız, ikincisi ise modellerin analizleri sonucunda en fazla ağırlık tespit edilen parametrelerin sonuç üzerine etkilerini yorumlayacağız.

Ölüm ve revizyon tahmini için naive bayes, destek vektör makineleri (SMO ve SGD), karar ağacı (J48) ve yapay sinir ağları modelleri kullanılmıştır. Performans karşılaştırmaları için doğruluk, F-ölçüm, ROC ve hata oranları (MAE) değerlendirilmiştir. Ölüm tahmini için en iyi model KA (J48) olmuştur(tablo 23). Revizyon tahmini için en iyi model DVM(SMO) olmuştur(tablo 24).

Tablo 23. Ölüm analizi için tüm modellerin karşılaştırmalı sonuçları

	NB	DVM(SGD)	DVM(SMO)	KA(J48)	YSA
Doğruluk(%)	86.6	88.6	88.6	91.3	84.6
F-ölçüsü	0.823	0.878	0.854	0.903	0.849
ROC	0.714	0.654	0.551	0.790	0.737
MAE	0.173	0.113	0.113	0.113	0.152

Tablo 24. Revizyon analizi için tüm modellerin karşılaştırmalı sonuçları

	NB	DVM(SGD)	DVM(SMO)	KA(J48)	YSA
Doğruluk(%)	81.3	85.3	86.6	81.3	78
F-ölçüsü	0.777	0.798	-	0.786	0.760
ROC	0.551	0.492	0.500	0.510	0.417
MAE	0.247	0.146	0.113	0.226	0.225

Hastanede kalım süresi (Taburculuk süresi) ve maliyet tahmini için lineer regresyon, destek vektör makineleri (SMOreg) ve karar ağacı (Decision Stump) modelleri kullanılmıştır. Performans karşılaştırmaları için MAE ve RMSE ölçüleri

değerlendirilmiştir. Hem hastanede kalım süresini hem de maliyeti en az hata ile en iyi tahmin eden model DVM(SMOreg) olmuştur (tablo 25-26).

Tablo 25. Hastanede kalım süresi analizi için tüm modellerin karşılaştırılmalı sonuçları

	LR	DVM(SMOreg)	KA(Decision Stump)
MAE	4.65	3.48	6.01
RMSE	8.90	8.46	11.6

Tablo 26. Maliyet analizi için tüm modellerin karşılaştırılmalı sonuçları

	LR	DVM(SMOreg)	KA(Decision Stump)
MAE	984.0	868.1	962.4
RMSE	1460.3	1374.6	1584.6

Ölüme pozitif yönde (ölüme yaklaştıran) etki eden ilk 3 parametre değerlendirildiğinde, DVM(SGD); kreatinin, kronik hastalık ve yaşa, DVM(SMO); kreatinin, kronik hastalık ve ALT'ye, KA(J48) ise kronik hastalık, kreatinin ve başvuru tarihi ile ameliyat olduğu tarih arasındaki süreye en fazla önem vermiştir. Sonuç olarak 3 modelin en fazla ağırlık verdiği 2 parametre kreatinin (ortalama 0,9 mg/dL) ve kronik hastalık varlığı olmuştur.

Revizyona etki eden parametreler değerlendirildiğinde, DVM(SGD); kreatinin, glukoz ve AST, DVM(SMO) ise AST, kreatinin ve hemoglobin en fazla ağırlık alan parametrelerdir. İntraoperatif protez ile ilgili ise en önemli parametreler bacak uzunluk farkı, protez tipi(ementli) ve trokanterik major tespiti öne çıkmaktadır. Hastanede kalım süresine ve maliyete etki eden en önemli parametre başvuru tarihi ile ameliyat olduğu tarih arasındaki süre olmuştur. Hastanın ameliyat hazırlığı olarak da bilinen bu süre ortalama 4.02 gün olarak tespit edilmiştir. Bu sürenin daha kısa hale getirilmesi hem maliyetleri azaltacaktır hem de ilk 1 yıl içindeki ölüm oranlarını azaltacaktır.

Literatür tarandığında özellikle de makine öğrenmesinin belirgin gelişim gösterdiği son 20-25 yılda ortopedi kullanım alanlarının giderek artan ancak istenilen düzeye gelmemiş olduğu görüldü. Bu makine öğrenme yöntemleri sıklıkla osteoartrit tespit ve tahmininde, omurga patoloji saptamada, kemik ve kırıkta görüntüleme segmentasyonunda, iskelet kemik yaşı tespitinde, protez kontrolünde ve patolojik yürüme paterninde kullanılmıştır. Daha az sıklıkta ise kırık tespit ve tahmininde, ön-arka çapraz bağ tespitinde, optimal enfeksiyon nokta belirlenmesinde, artroplasti sonrası opioid kullanımı, tümörler sonrası sağ kalım tahmini ve omuz güçlendirme değerlendirilmesinde kullanılmıştır(104).

Birçok makine öğrenme yöntemi olmakla beraber literatürde ortopedi açısından en sık kullanılan yöntemlerin DVM ve derin öğrenme olduğu tespit edilmiştir. K-means Clustering, karar ağacı, k-en yakın komşu (k-Nearest Neighbors), Lineer regresyon gibi yöntemler de diğer kullanılan yöntemlerdir. Aşağıda bu yöntemlerin ortopedi alanında kullanımları güncel literatür destekli örnekler verilerek öncelikle özgün ortopedi dergilerinde yayınlanan makaleler tartışılacak daha sonra multidisipliner yaklaşımlı dergilerde yayınlanan makaleler tartışılacaktır.

Karhade ve ark. tarafından 2018 yılında 265 spinal kordomalı hastaların 5 yıllık sağ kalım tahminleri 4 farklı makine öğrenmesi yöntemi ile yapılmıştır. Tahmin için kullanılan değişkenler tanı yaşı, tümör boyutu, tümör yeri, tümörün yayılma derecesi ve ameliyatın kapsamı olarak ele alınmıştır. Spinal kordoma hastalarının bu analizi ile, nadir görülen patolojilerde hayatta kalma tahmini için makine öğrenme modellerinin geliştirilebileceği ve kullanılabilmesi gösterilmiştir. Gelecekteki çalışmaların bu metodolojiyi diğer patolojilere çevirerek ve bu analizde oluşturulan algoritmaların genelleştirilebilirliğini doğrulayarak bu çalışma üzerine inşa edilebilir sonucuna varılmıştır(105).

Han ve ark. tarafından 2018 yılında 242 sinovyal sarkomlu hastaların 5 yıllık sağ kalım tahminleri üç makine öğrenme yöntemi ile uygulanmıştır. Tümör boyutu, başlangıç metastazı ve marjin bağımsız prognostik faktörleri olarak belirlenmiştir. 194(%80) hasta verileri eğitilerek 48(%20) hasta verileri test edilmiştir. Sağ kalımda sinir ağları yöntemi, Cox proportional hazard modelinden daha doğru bulunmuştur(106).

Olczak ve ark. tarafından 2017 yılında kırıkların otomatik tespiti için derin öğrenme modelleri kullanılmıştır. Bu çalışmada, X-ışını görüntülerinde kırıkları, vücut bölümlerini, muayene görüntü tipi (anterior-posterior, lateral, oblik vs.) ve lateraliteyi (sağ veya sol) tanımlamak için serbestçe temin edilebilen çok katmanlı sinir ağları eğitilmiştir. Bu amaçla 250.000'den fazla ayak bileği, el bileği ve el radyografileri analiz edilmiştir. Kırılma teşhisi X-ışınlarından elde edilmiş yazılı raporlardan çıkarılabilirken, lateralite, muayene görünüm tipi ve vücut kısmı için etiketler görüntü meta verilerinden kolayca elde edilmiştir. Eğitimli ağların her birine, sınıflandırma hatalarını en aza indirerek görsel ve meta veri özelliklerini bilmek ve ayırt etmek için her görüntünün stokastik gradyan iniş algoritmasına tabi tutulduğu birkaç işlem yapılmıştır. Bundan sonra, en iyi performans gösteren ağ, 16 katmanlı Görsel Geometri Grubu CNN, iki uzman ortopedi tarafından aynı anda kırık tespiti için analiz edilen test setinin ilk 400 görüntüsünü inceleyerek hatalar için manuel olarak kontrol edilmiştir. Bu aşamada 400 görüntüde ağ performansını ölçmek için bir referans olarak altın standart kullanılmıştır. Kırık tespitinde en iyi doğruluk % 83 bulunmuştur. İkincil sonuçlarda ise vücut kısmında (% 99), muayene görünüm tipinde (% 95) ve lateralitede (% 90) elde edilen sonuçlar tespit edilmiştir. Hem gözlemciler arasında hem de gözlemciler içerisinde ve en iyi performans gösteren ağ arasındaki gözlemciler arası güvenilirlik skoru hesaplanmıştır. Gözlemciler arası skor % 90'a ulaşırken, gözlemciler ile en iyi performans gösteren ağ arasındaki güvenilirlik endeksi % 86'ya ulaşmıştır(107).

Karhade ve ark. tarafından 2019 yılında total kalça artroplastisi sonrası reçete edilen uzun süreli opioid kullanımını preoperatif tahmini için makine öğrenme yöntemleri ile ilgili çalışma yapılmıştır. Yaş, opioid maruz kalma süresi, preoperatif hemoglobin ve preoperatif ilaçlar (antidepresanlar, benzodiazepinler, nonsteroidal antiinflamatuar ilaçlar ve beta-2-agonistleri) gibi ameliyat sonrası uzun süre için reçete edilen opioid uzamasının öngörülmesi için belirlenen faktörler 5 farklı MÖ yöntemi kullanılmıştır. En iyi yöntem logistic regresyon yöntemi tespit edilmiştir. Bu yöntem hem iyi bir tahmin hem de iyi bir açıklayıcı yöntem olarak bulunmuştur(108).

Karnuta ve ark. tarafından 2019 yılında 3 farklı düzenleyici kullanan geleneksel çok katmanlı algılayıcı (MLP) ve yeni yoğun sinir ağı (DenseNet)

kullanılarak primer total kalça artroplastisi (TKA) ve total diz artroplastisi (TDA) uygulanmış yatan hastalarda yüksek maliyetli olanlar incelenmiştir. TKA ve TDA maliyet tahmininde yeni yoğun sinir ağının geleneksel çok katmanlı algılayıcı dan daha iyi performansı gösterdiği ortaya konulmuştur. Gelecek çalışmaların bu yöntemlerle yapılması önerilmiştir(109).

Navarro ve ark. tarafından 2018 yılında Naive Bayes yöntemi kullanılarak total kalça artroplastisi uygulanmış 141,446 hastada hastanede kalım ve yatan hastalarda ödemeler için tahminde bulunulmuştur. Makine öğrenmesi için yaş, ırk, cinsiyet ve komorbidite skorları kaydedilmiştir. Ve sonuçta mükemmel bir değerlilik elde edilmiştir(110). Benzer çalışmada Ramkumar ve ark. 2019 yılında total kalça artroplastisi uygulanmış 122,334 hastada Naive Bayes yöntemi kullanılarak hastanede kalım ve yatan hastalarda ödemeler için tahminde bulunulmuştur. Makine öğrenmesi için yaş, ırk, cinsiyet ve komorbidite skorları kaydedilmiştir. Sonuç olarak hastanede kalım ve yatan hastalarda ödemeler için mükemmel geçerlilik, güvenilirlik ve duyarlılık tahmini elde edilmiştir(111).

Ramkumar ve ark. tarafından 2019 yılındaki diğer çalışmasında ise 25 total diz artroplastisi uygulanmış ve seçilmiş hastada uzak hasta izleme (RPM) sisteminin veri kesintilerinin sıklığı ve hasta kabul sıklığı açısından uygulanabilirliği test edilmiştir. Bunun için şu 5 ölçüm değerlendirilmiştir; (1) hareketlilik; (2) diz hareket açıklığı, (3) hasta tarafından bildirilen sonuç ölçütleri (PROM); (4) opioid kullanımı ve (5) evde egzersiz programı (HES) uyumu. TKA hastaları için sürekli veri elde etme yeteneğini belirlenmiştir. Uzaktan hasta takibi yöntemi, TKA uygulanan hastaları hareketlilik ve rehabilitasyona uygunluk açısından daha iyi değerlendirme olanağı sunmuştur. Klinik önemi belirlemek için daha fazla hastayla çalışmak gerektiği belirtilmiştir(112).

Bini ve ark. tarafından 2019 yılında total eklem artroplastisi uygulanmış 22 hastada klinik sonuçları geliştirmek için sağlık verilerinden üretilen hasta (PGHD) izlem kullanılmıştır. Bu veriler makine öğrenme yöntemi ile kombine edilmiştir. Ameliyattan sonra hastalardan 4 hafta ila 6 hafta sonra 35 özellik toplanmıştır. Kalça ve Diz Engellilik ve Osteoartrit Sonuç Skoru, Diz Osteoartrit Sonuç Skoru ve Gaziler RAND 12-Madde Sağlık Araştırması Fiziksel Bileşen Skoru kullanılmıştır. Bu küçük ancak kritik kavram kanıtı çalışması, 6 haftalık PGHD verilerini total eklem artroplastisi

ameliyatından sonraki 11 gün kadar erken tahmin etmek için MÖ'nün PGHD ile kombinasyon halinde kullanılabilmesi gösterilmiştir. Bu bulguları ve klinik değerlerini doğrulamak için daha fazla çalışmaya ihtiyaç olduğu belirtilmiştir(113).

Karhade ve ark. tarafından 2019 yılında Spinal Epidural Abse (SEA) 'de hastane içi ve 90 günlük taburculuk sonrası mortalite tahmini için makine öğrenme algoritmaları kullanılmıştır. 1993'ten 2016'ya kadar üç farklı hastaneden radyolojik olarak doğrulanmış 1,053 SEA tanısı almış ve yatışı olan yetişkin hastalar çalışmada kullanılmıştır. Beş makine öğrenme algoritması (elastic-net penalized logistic regression, random forest, stochastic gradient boosting, neural network, and support vector machine) diskriminasyon, kalibrasyon, genel performans ve karar eğrisi analizi ile geliştirilmiş ve değerlendirilmiştir. Ciddiyet sırasına göre sıralanan 90 günlük mortalite tahmininde kullanılan değişkenler yaş, albümin, trombosit sayısı, nötrofil lenfosit oranı, hemodiyaliz, aktif malignite ve diyabet idi. Makine öğrenmesi algoritmaları, SEA'da 90 günlük mortalite tahmini için dahili doğrulama konusunda umut verdiği belirtilmiştir(114).

Benzer çalışmada Shah ve ark. tarafından 2019 yılında 18 ve üstü 367 hastayı 5 farklı makine öğrenme modeli ile test edilmiştir. Spinal epidural apse (SEA) 'de nonoperatif tedavi başarısızlığı riskine ilişkin yapılan çalışmada kullanıcı dostu ve açık erişimli bir dijital arayüzde ayırt edici ve iyi kalibre edilmiş bir model oluşturularak, klinik karar vermeyi gerçek zamanlı olarak bilgilendirmek için kullanılacak bir prognostik araç sağlamak amaçlanmıştır(114).

Karhade ve ark. tarafından 2019 yılında Anterior servikal diskektomi ve füzyon (ACDF) sonrasında sürekli opioid reçetesinin preoperatif tahmini için makine öğrenme algoritmaları geliştirmek amaçlanmıştır. Ameliyat sonrası en az 90-180 güne kadar uzayan reçeteli opioid kullanımı değerlendirilmiştir. Sürekli opioid reçetesinin öngörülmesi için belirlenen değişkenler erkek cinsiyeti, çok düzeyli cerrahi, miyelopati, tütün kullanımı, sigorta durumu, preoperatif opioid kullanım süresi ve ilaçlar (antidepresanlar, benzodiazepinler, beta-2-agonist, anjiyotensin dönüştürücüler, enzim inhibitörleri, gabapentin.) olarak belirlenmiştir. 5 farklı makine öğrenme modeli ile test edilmiştir. En iyi yöntem stochastic gradient boosting

olarak tespit edilmiştir. Sigorta durumu, postoperatif opioid reçetesinin sürdürülmesinin en önemli belirleyicileri olarak ifade edilmiştir(115).

Karhade ve ark. tarafından 2019 yılında lomber disk herniasyonu için ameliyat sonrası uzamış opioid reçetesinin öngörülmesi için algoritmalar geliştirmek amaçlanmıştır. Opioid reçetesinin ameliyat sonrası en az 90 ila 180 güne kadar devam etmesi sonuçları ölçülmüştür. 5,413 hastada en önemli üç belirteç: enstrümantasyon, preoperatif opioid reçetesinin süresi ve depresyon komorbiditesi olarak tespit edilmiştir(116).

Karhade ve ark. tarafından 2019 yılında spinal metastatik hastalık nedeniyle ameliyat edilmiş 176 hasta mortalite sebebiyle SORG makine öğrenme yöntemi ile incelenmiştir. Bu hastaların 44'ü (% 22.7) 90 günlük mortalite, 99'u (% 56.2) bir yıllık mortalite tespit edilmiştir. Primer tümör histolojisi, metastatik tümör yükü, önceki sistemik tedavi, genel komorbidite yükü ve ameliyat öncesi laboratuvar özellikleri değerlendirilmiştir. Spinal metastatik hastalıkta sağkalım tahmini için bu dijital karar yardımcılarının klinik uygulamadaki potansiyel faydalarını gösterilmiştir(117).

Ashinsky tarafından 2015 ve 2017 yılında morfolojiyi temsil eden bir algoritma ile ağırlıklı bir k-Nearest Neighbors(kNN) yöntemi kullanılmış ve eklem kırık taramalarının MR'larında osteoartrit (OA) saptama problemi üzerine uygulanmıştır. Bu araç, bir eğitim seti görüntüsünden özellikler çıkaran ve bunları ayırım düzenine göre ağırlıklandıran bir resim sınıflandırıcısıdır. WND-CHRM tarafından çıkarılan özellikler, resim dokuları, piksel istatistikleri, polinom ayrışımı ve yüksek kontrast özellikleri gibi sayısal görüntü içeriği tanımlayıcıları, ayrıca görüntü dönüşümleri ve bu dönüşümlerin çift biçimli kombinasyonlarıdır. İki çalışmanın ilkinde bu teknik ikili sınıflandırma için kullanılmıştır(118, 119).

Pritzker ve ark. tarafından 2006 yılında her bir kırık dolgusunu puanlamak için multipl linear least-square modelinin son çıktısı kullanılmıştır. Bu puanlama aynı görüntü grubunda iki uzman görüşü tarafından manuel olarak değerlendirilmiş ve her iki puan da lineer regresyon prosedürünün temeli olarak kullanılmıştır. En iyi ayırma görevi, T2 ağırlıklı (T2W) ölçümlerden (orijinal MRI'dan alınan farklı tarama

ölçümleri arasında) % 97 doğruluk, % 94 duyarlılık, % 100 özgüllük ile çıkarılarak elde edilmiştir(120).

Matic ve ark. tarafından 2016 yılında ön çapraz bağ (ÖÇB) eksikliğinin kullanışlı bir model olduğu göstermek için yürüyüş analizi oluşturulmuştur. ÖÇB eksikliğinin ana göstergeleri anterior posterior translasyon (APT) ve internal eksternal rotasyonlarda (IER) tespit edilmiştir. Yürüyüş analizi çalışmasına ÖÇB eksikliği olan 35 erkek katılmıştır. Anterior posterior translasyon (APT) ve internal dış rotasyon (IER) için patolojik parametreler ve bunların kinematik veri değerleri, bir yürüyüş analizi 3D sisteminden elde edilmiştir. Floresan işaretleyicilerin pozisyonları zamanla kaydedilerek hareket eğrileri elde edilmiştir. ÖÇB yaralanmasının ciddiyeti ve buna bağlı eksiklik hakkındaki kararları desteklemek için bir makine öğrenme algoritması olarak lojistik regresyon geliştirilmiştir. Bu çalışma, sıralı patolojik parametreler çiftlerinin oluşturulmasının, ÖÇB eksikliğinin daha geniş bir resmini verdiğini ve böyle bir algoritmanın, hastaların hem muayene edilmesini hem de tedavisini iyileştirebileceğini göstermiştir (121).

Phinyomark ve ark. tarafından 2016 yılında OA olan ve olmayan, erkek ve kadın denekler arasında yürüyüş kinematiği ve sağlıklı cinsiyetle eşleştirilen denekler arasında, OA meslektaşlarına kıyasla farklılıkları incelemek için bir çalışma tasarlanmıştır. Çalışmaya diz OA'lı (45 erkek ve 55 kadın) yüz denek ve 43 sağlıklı erkek (18 erkek ve 25 kadın) katılmıştır. Principal component analysis (PCA) and destek vektör makineleri (DVM) yöntemleri kullanılmıştır. OA ve sağlıklı kadınlar, erkek meslektaşlarına kıyasla anlamlı derecede daha fazla diz abduksiyon ve kalça adduksiyon açısı göstermiştir. Hem erkek hem de kadın grubundaki sağlıklı denekler ile OA arasında herhangi bir ayrı yürüme kinematik değişkeni arasında anlamlı bir fark bulunmamıştır. PCA ve DVM yaklaşımları kullanılarak, cinsiyet grupları arasında ve OA grupları arasında % 98-100 oranında sınıflandırma doğruluğu tespit edilmiştir(122).

Thong ve ark. tarafından 2016 yılında Adolesan İdiyopatik Skolyoz'un (AIS) otomatik tespitinde hem derin öğrenme hem de kümeleme teknikleri uygulanmıştır. Bir dizi otomatik kodlayıcı mimarisine sahip yapay bir sinir ağı, 915 çift kanatlı radyografik görüntülerin bir kohortundan yeniden yapılandırılan 3D omurga model

vektörlerinin kodlama-kod çözme işlemini optimize etmek için eğitilmiştir. AIS Lenke tipleri için en göze çarpan işaretlerin kodlanmasından sonra, kod çözme vektörleri, AIS sınıflandırma için en eksiksiz morfolojik bilgi çeşitleriyle en düşük çözünürlüklü özellik kümesi oluşturulmuştur. Sinir ağına uygulanan yinelemeli bir optimizasyon tekniği, kodlanmış giriş vektörleri ve kodu çözülmüş çıkış vektörleri arasındaki farkı en aza indirmeyi amaçlanmıştır. İkinci bir aşamada, önceki aşamada elde edilen 3B omurga gösterimi vektörlerine k-araçlarına dayalı denetimsiz bir kümeleme yöntemi uygulanmış ve onbir küme standart geometrik 3B omurga indekslerine (örneğin, Cobb açısı, kifoz ve lordoz açıları, pelvik insidans, vb.) karşı oluşturulmuş ve doğrulanmıştır. Uzman bir cerrah tarafından manuel olarak klinik değerlendirilmesiyle önemli farklılıklar için test edilmiştir. Algoritma AIS kümelerini, Lenke tip 5-6 özelliklerinin ana torasik ve torako-lomber deformasyonları, Lenke tiplerini 1-4 özellik gösteren tek, çift ve üçlü ana eğrileri tanımlamasına yardımcı olmuştur(123).

Jamaludin ve ark. tarafından 2017 yılında hastaların bel ağrısı tanısındaki lomber intervertebral disk (IVD) durumunun derecelendirmesini otomatikleştirmek için MRI vertebral görüntülerine bir MÖ yöntemi uygulanmıştır. T2 sagittal MRG ile T12 ila S1 vertebra gövdelerini etiketleyen “nesnelerin algılanması için kısmi modeller” adlı görüntü analizi tekniğine dayanan bir görüntü analizi algoritması oluşturulmuştur. Bu görüntüler önceden her IVD için sekiz radyolojik skorla uzman bir spinal radyolog tarafından açıklanmıştır. Bir evrişimsel sinir ağı (CNN), daha sonra açıklamalı disklerden ve manuel skorlardan başlayarak çıktı derecelendirmesini tahmin etmek için toplam altı özellik için kullanılan radyolojik özellikleri öğrenmek ve derecelendirmeyi tahmin etmek için eğitilmiştir. Her bir özelliğe, patolojinin özelliğine bağlı olarak ikili mevcut / mevcut olmayan bir sınıf veya çok sınıflı bir sınıf tarafından derecelendirilmiştir. Pfirrmann Dereceleme ve Disk Darlığı çok noktalı bir ölçek çıkışı olarak atanmış ve spondilolistezis, santral kanal darlığı, endplate defektleri ve kemik iliği sinyali varyasyonlarının var olduğu veya olmadığı tahmin edilmiştir. Bu yaklaşım dört farklı önlem kullanılarak değerlendirilmiş: uzman radyoloğun sınıf ortalaması puanlayıcı güvenilirliği, otomatik işlem ile radyolog arasındaki doğruluk, uzman radyolog ve sistem ile radyolog arasındaki puanlayıcı güvenilirliği katsayısı. Spondilolistezi öngörmede en iyi doğruluk oranı (% 95) elde edilmiştir(124).

Kotti ve ark. tarafından 2017 yılındaki yayınlarında hem sağlıklı olanlardan osteoartrit (OA) denekleri sınıflandırmak hem de yazarlara göre net bir sınıflandırma çıktısı ile karşılaştırılması hemde sonuçların klinik olarak yorumlanabilirliğini sağlamaya çalışmak için bir OA patolojisinin ilerici doğasını daha iyi taklit etmesi gereken sürekli bir regresyon çıktısının sağlanması yoluyla Random Forest (RF) kullanılmıştır. Yazarlar, zemin reaksiyon kuvvetleri parametrelerini (GRF) içeren hastalardan kinematik veriler topladılar ve üç yol ekseninin (X, Y ve Z) her birinin çıkarılmış özelliklerini topladılar. En bilgilendirici GRF parametreleri, üç yol boyunca elimine edilen gözlemlerin tahmin hatası toplanarak hesaplanmıştır. Böylece topluluğun nihai sonucunun hata yanlılığı da dikkate alınarak uygun bir şekilde ortalaması alınabildi. Her bir eksen özelliği grubu ve üçünün birleşimi için duyarlılık, özgüllük, doğruluk bildirildi. Üç eksen için çapraz değerlendirme, ortalama % $72,61 \pm 4,24$ oranında doğruluk göstermiştir(125).

Madelin ve ark. tarafından 2015 yılında random forest yöntemi kullanarak OA denekleri, sıvı baskılanmış tekniğinin uygulanmasından önce ve sonra radyal 3D kazanımlara dönüşen diz eklemlerinin sodyum(Na) MRG'leri kullanılarak sınıflandırılmıştır. Daha sonra her denek, ilgilenilen görüntü bölgelerinden çıkarılan 12 küresel özellik ve bunlardaki sodyum konsantrasyonundaki ortalama ve standart sapma istatistiklerine göre tarif edilmiştir. Sınıflandırma görevi 16 farklı sınıflandırıcı ile test edilmiştir. Tree Bagging yöntemi için çapraz doğrulama ile doğruluk açısından performans % 74'ten düşük bulunmuştur(126).

Mirzaalian ve ark. tarafından 2013 yılında 3B vertebra Bilgisayarlı Tomografi (BT) omurga görüntülerine sağlam bir segmentasyon yöntemi bulmak için random forest kullanılmıştır. Bu segmentasyon, istatistiksel şekil modelleme teknikleri ile çıkarılan ve her bir omurun sınır dedektörü öğrenici kullanarak bir kutu ile uygun şekilde çevreleyen her omur şekli hakkındaki bilgilerle desteklenmiştir. Her test görüntüsü için eğitilen algoritma, vertebra şeklini çıkarılan özellikler üzerinde ortalama bir şekil kullanarak ve bunlara sınır detektörünü uygulayarak tahmin etmiştir. Sınıflandırma adımı, $1,37 \pm 0,37$ mm değerinde olan minimum hata ile değerlendirilmiştir(127).

Bellamy ve ark. tarafından 1988 yılında deneklerden alınan MRG taramalarında OA'nın ilerlemesini tahmin etmek için kNN kullanılmıştır. OA ilerlemesi, anketi hastalara son MR'larından üç yıl sonra uygulayarak tahmin edilmiştir. WOMAC anketi ağrı ölçekleri, birkaç günlük aktiviteyi gerçekleştirmedeki sertlik ve belirli fiziksel fonksiyonların değerlendirilmesi ile ilgili 24 soru içermektedir. Ankete katılanların her anket için birer adet anket formu kullanmasına izin verilmiştir. Kazanılan doğruluk % 75 olarak tespit edilmiştir. (128).

Dolatabadi ve ark. tarafından 2017 yılında yürüyüş paternleri açısından, sağlıklı ve patolojik olarak yürüyüşlerin sınıflandırılmasının örnek tabanlı bir ayırıcı olan kNN ve diğer yöntemler ile karşılaştırılması planlanmıştır. Kinetik iskelet izlemesinden elde edilen yürüyüş özellikleri, kendi hızına(self pace), çift göreve(dual task) ve hızlı hıza(fast pace) ayrılmış ve iki öngörücüyü farklı türlerde tek veya çoklu yürüyüş dizileri gözlemlenmelerine izin vererek eğitmek için kullanılmıştır(129).

Pedoi ve ark. tarafından 2018 yılında makine öğrenmesini kantitatif kompozisyon MRG, yürüyüş analizi ve osteoartriti (OA) incelemek için çok boyutlu veri analizini birleştirme amaçlanmıştır. Sunulan analiz, çok boyutlu bir yaklaşım kullanarak eklem dejenerasyonunu ve OA'yı tanımlayan karmaşık çok-boyutlu biyokimyasal ve biyomekanik etkileşimlerin bazılarını göstermiştir ve potansiyel olarak erken OA için bir görüntüleme biyolojik belirleyicisi olabileceğini gösterilmiştir(130).

Nagarajan ve ark. tarafından 2014 yılında OA'da kondrosit yapılarını en iyi şekilde tanımlayan geometrik özellikleri, sağlıklı hastaların ROI (region of interest)'lerini ve aynı görüntü grubunun elle eklenmiş ROI'lerinden gri seviye istatistiksel özellikleri tespit etmek için kontrastlı X-Ray BT görüntüleri kullanılmıştır. İlk geometrik özellikler kümesi için, nokta dağılım analizi için bir ölçeklendirme indeksi yöntemi (SIM) kullanılmış ve gri seviye kalıpları için istatistiksel bir analiz yapılmıştır. Kondrosit paternleri ile eğitilmiş DVM'nin doğruluğu % 95'e ulaşırken, diğer istatistiksel paternlerle eğitilmiş DVM'nin oranı % 93'e ulaşmıştır. Bu sonuçlar, bu tür geometrik özelliklerin, kıkırdak matrisindeki kondrosit organizasyonunun, otomatik ve subjektif olmayan bir şekilde ayrıntılı bir şekilde tanımlanmasını sağlarken, aynı zamanda, kıkırdakın sağlıklı veya osteoartritik olarak yüksek

hassasiyetle sınıflandırılmasını sağlamıştır. Bu özellikler potansiyel olarak osteoartrit ilerlemesini ve bunun farklı terapötik müdahale stratejilerine tepkisini değerlendirmek için görüntüleme belirteçleri olarak hizmet edebileceği sonucu ortaya konulmuştur (131).

Zhang ve ark. tarafından 2013 yılında kas iskelet sistemi hastalıklarının veya ani yaralanmaların neden olduğu diz patolojisinin değerlendirilmesinde çok önemli olan kantitatif kıkırdak ölçümlerini elde etmek ve diz kıkırdağının doğru segmentasyonu gerekliliğini belirtmek için DVM ve discriminative random field (DRF) kullanılmıştır. Önerilen tekniğin etkinliği, çok kontrastlı MR görüntülerinin bir veritabanında doğrulanmıştır. Geliştirilen segmentasyon tekniği, altın standart segmentasyonlara kıyasla iyi bir performans sergilenmiş ve en gelişmiş otomatik kıkırdak segmentasyon çalışmalarından daha yüksek ortalama Dice similarity coefficient (DSC) değerleri elde edilmiştir(132).

Stajduhar ve ark. tarafından 2017 yılında İnsan dizinde ön çapraz bağ (ÖÇB) yaralanmasının varlığını saptama problemi ile ilgilenmek için DVM yöntemi kullanılmıştır. Yalnız diz eklemi MR hacimlerini gözlemleyerek yarı otomatik ÖÇB-yaralanma teşhisi yapma sorunu zor olsa da, deneysel sonuçlar hem hafif yaralanmaların tespiti hem de tam yırtılmaların tespit edilmesi için bilgisayar destekli karar vermenin potansiyel klinik uygulamasını göstermiştir (133).

Oktay ve ark. tarafından 2014 yılında Lomber intervertebral diskler dejenerasyon teşhisi problemini otomatikleştirmek için Bilgisayar Destekli Tanı (CAD) sistemi kullanılmıştır. Bu yaklaşım, farklı özellik tipleri elde etmek için hem T1 hem de T2 ağırlıklı MR görüntülerinden analiz ve özellik çıkarımına dayandırılmıştır. Yoğunluk, doku, düzlemsel şekil ve içerik gibi özellikler işlenmiştir. Doku verilerinin, disk özelliklerinin anomalileri hakkında önemli bilgiler ortaya çıkarması beklenmiştir. Lomber intertebral disk patolojilerini otomatik olarak saptamak için uygulanan DVM, % 92.8 doğruluk, % 94.6 duyarlılık ve % 89.8 özgüllük ile değerlendirilmiştir(134).

Silver ve ark. tarafından 2006 yılında En Küçük Kareler DVM (LS-SVM) kullanılarak omuz gücünün sağlıklı için değerlendirilmesi ve post-operatif omuz fonksiyonunda rotator manşet patolojisi hastalarına omuz kuvvet skoru araştırılması amaçlanmıştır. İlk deney için toplanan veriler ameliyat öncesi, ameliyattan 6 ay ve 12 ay sonraki farklı noktalarda omuz kuvveti (izometrik ölçümler) ölçümleri alınmıştır. İkinci deney için, dahil edilmemiş hastaların preoperatif omuz verileriyle farklı bir LS-SVM eğitilmiştir. Ardından bu veriler ve dahil olan hastalar arasında geometrik bir mesafe hesaplanmış ve SVM'nin sadece ameliyat sonrası hastalar arasında (p değeri <0.004) ve dahil edilmemiş ve ameliyat öncesi dahil edilmiş hastalar arasında (p değeri <0.001) ayırım yapabildiğini gösterilmiştir(135).

Zarychta tarafından 2015 yılında T1 ağırlıklı MRG taramalarında ÖÇB ve AÇB'nin lokalizasyon problemi, fuzzy C-means yönteminin bir varyansı uygulanarak ele alınmıştır(Bu yöntemde görüntünün komşu piksellerinin yoğunluğundaki farkı vurgulayan bulanıklık entropisini ölçmüştür). Sağlıklı ve patolojik ÖÇB ve AÇB'nin etkileyici ölçümlerinin bir özellik vektörü iki uzman radyolog tarafından çıkarılmış ve değerlendirilmiştir. Çıkarılan özellikler arasında ÖÇB ve AÇB alanlarının yüzeyi ve çevresi, çıkarılan alan ile ROI alanı arasındaki oran, A uzunluğu (iskeletin maksimum başlangıç ve bitiş mesafesi) ve B uzunluğu (üst ve alt iskelet arasındaki maksimum mesafe) ve A uzunluk / B uzunluk oranı belirtilmiştir. Aynı radyologlar, vakaların % 89'unda hem ÖÇB hem de AÇB segmentasyonunun ve özellik çıkarımının doğru tanımlandığını belirtilmiştir(136).

Dam ve ark. tarafından 2015 yılında Diz Görüntülerinin Segmentasyonu için OA başlangıcındaki MR'ları otomatik kemik ve kırık segmentasyonu gerçekleştirmek diz görüntü verileri kullanılmıştır. Performans en iyi doğrulukla ölçülmüş ve en yüksek sonuç OA başlangıcı için geçerlilik % 86.6 bulunmuştur(137).

Atkinson ve ark. tarafından 2012 yılında Gradient Boost Machines (GBM) kullanılarak kırık tahmini sonucunu iyileştirebilecek güçlü prediktörleri bulmak için standart areal kemik mineral yoğunluğu (aBMD) özellikleri toplamak veya bir kombinasyonunu sağlanması amaçlanmıştır. Daha sonra, hem distal önkol kırıklarının

(DFF) hem de vertebral kırıkların (VF) kantitatif bilgisayarlı tomografi (QCT) görüntülerinden üç değişken seti çıkarılmıştır. Aynı veriler iki rastgele kontrol grubu için toplanmıştır. Bunlar, aşağıdaki özelliklerle ilgili değişkenlerdir: çift enerjili X-Ray absorpsiyoniyometrisi (DXA) ile elde edilen kemik yoğunluğu (aBMD); kortikal ve trabeküler kemiklerin hacimsel kemik mineral yoğunluğunun (vBMD) spiral QCT ekstraksiyonları ile elde edilen kemik geometrisi ve yüksek çözünürlüklü periferik QCT görüntüleme (HRpQCT) ile türetilen kemik mikro yapıları olarak kaydedilmiştir. Bu özellikler, değişkenlerin her birindeki ROC sonuçlarına göre ayarlanmış ve değerlendirilmiştir. GBM ve lojistik regresyon modellerini beslemek için farklı kombinasyonlarda kullanılmıştır. Aşırı uyumu önlemek için, VF yanıt değişkenlerini ve bunun tersini tahmin etmek için DFF GBM de kullanılmıştır. Sonuçlar, tüm değişkenler kümesiyle (267) bir model kullanılmasının 1.0 ROC verdiği gösterilmiştir. Ayrıca DXA 0.95, HRpQCT 0.96 ve spiral QCT 1.0 olarak bulunmuştur(138).

Kruse ve ark. tarafından 2017 yılında Gradient Boost Machines (GBM) kullanılarak kalça kırığı tahminini için DXA verilerini kullanarak ve 24 farklı öğreneni eğiterek değerlendirmek amaçlanmıştır. Bunlar arasında karar ağaçlarına dayanan esnek bir ayırmacı analiz (bagFDA) modelini ve aşırı Gradyan Artırma (xgbTree) modeli kullanılmıştır. İki yaklaşım için çeşitli öngörücüler hesaplanmış ve birleştirilmiştir. Hem (kadınlar için 11 değişken, erkekler için 9 değişken) hem de ayırmacılık gücü (ROC açısından değerlendirilen) arasında bir denge kurmayı hedeflemiş ve olasılıkların en iyi kalibrasyonu ile olasılık değerinin % 95 güven aralığına ait olarak yorumlanabileceği ifade edilmiştir. Kadın kohortunun sonuçları erkek kohortunununkine zıt olarak bulunmuş; birinci grup için, bagFDA yaklaşımı ile duyarlılık % 88 ve özgüllük % 81 en iyi seçim sonucunu vermiştir. İkinci grup için, xgbTree sonucu olarak duyarlılık % 100 ve özgüllük % 69 ile ve ayırmacılık ile kalibrasyonu arasındaki en iyi denge ile en iyi performans gösteren yaklaşım olarak kabul edilmiştir(139).

Cunha ve ark. tarafından 2014 yılında iskelet matürite değerlendirme problemine ilişkin topluluk yöntemleri uygulanmıştır. El kemiği ROI lerinin toplam 338 özelliği birkaç regresyon şemasına kaydedilmiştir. Doğrusal regresyon ve kurala

dayalı regresyon (M5P) sonuçlarının torbalama yoluyla ortalaması alınmış ve ortalama mutlak hata (MAE) ile değerlendirilmiş ve M5P için 10.16'nın bir sonucunu ortaya çıkarmıştır. Sonuç olarak topluluk şemalarının tek bir regresyon yöntemine göre daha az bağımlı bir şemaya dayanabileceğini ve bunları her bir ROI'de kullanmanın sonuçları küçük bir hesaplama maliyetiyle iyileştirebileceğini ortaya koymuştur(140).

Marques ve ark. tarafından 2013 yılında OA tanısı ve kıkırdak kaybı riskinin prognozu için LDA kullanılmıştır. İki yıl önce ve sonra alınan her iki diz MRG taramasını 30 ila 72 yaşları arasındaki yaklaşık 150 denekten analiz etmek için kullanılmıştır. Aynı taramalar, Kellgren Lawrence derecelerini(141) kullanarak puan alan uzman radyologlar tarafından manuel olarak değerlendirilmiştir. Medial tibial kıkırdak hacmi, hem segmentasyon işleminden sonra hem de trabeküler kemik yapısını temsil eden ROI'lerin çıkarılmasından sonra her iki görüntü grubunda da tahmin edilmiş ve çıkarılan özellikler, kemik yapı markörlerini kıkırdak hacmi kaybının öngörülmesiyle ilişkilendirmek için en iyi kombinasyonunu seçebilen bir LDA sınıflandırıcısını eğitmek için kullanılmıştır. MÖ çıktısının sonuçları, sağlıklı OA'dan etkilenenlere göre doğru sınıflandırma için 0.92'lik bir ROC ile ve kemik yapısını ölçerek kıkırdak kaybı hacminin tahmini için olasılık oranı ile değerlendirilmiştir. Dikey trabekülerizasyonun, en fazla kıkırdak kaybı progresyonuna bağlı olduğu gösterilmiştir(142).

Marques ve ark. tarafından 2012 yılında trabeküler kemik yapısını analiz etmek ve OA risklerini ölçmek için altı farklı MÖ sınıflandırıcı kullanılmıştır. En iyi yaklaşımlar LDA (0.82 ROC) ve ağırlıklı k-NN (0.81 ROC) bulunmuştur. Aynı yaklaşım, aynı çalışmada test edilen 20'den fazla makine öğrenme metodu arasında iskelet olgunluğu değerlendirmesi görevinde en iyi performans gösterenlerden biri olarak tespit edilmiştir(143).

Lee ve ark. tarafından 2016 yılında servikal omurga bozukluğunun değerlendirilmesinde ve el motor bozuklukların modellenmesinde üç farklı makine öğrenmesi ile bu modellerin geçerliliğini değerlendirmeyi amaçlayan bir başka

çalışma yapılmıştır. Ameliyat öncesi hastalara, iki dalga formunu izleyebilen bir el kavrama cihazı ile bir test uygulanmıştır. El kas hareketlerini ölçmek için sinüs dalga şekli ve dalga biçimli el kavrama kuvveti adımını gösteren diğer özellikler kullanılmıştır. Makine öğrenme yöntemleri ile 0.89 c-statistic, 0.83 gerçek pozitif oranı ve 0.87 gerçek negatif oranı bulunmuştur. Bu sonuçlar, sunulan sistemin kullanımını, el motor fonksiyon bozukluğunun ve cerrahi sonuçların objektif ve doğru bir değerlendirmesini sağlamak için bir araç olarak onaylanmıştır(144).

Kadoury ve ark. tarafından 2017 yılında biplanar X-ışını görüntülerinden yeniden oluşturulan 3-boyutlu spinemodellerden yetişkin idiyopatik skolyozunun ilerlemesini öngörmek için yeni bir yaklaşım sunulmuştur. Makine öğrenimindeki son gelişmeler sınıflandırma ve prognoz oranlarını iyileştirmeye izin verdiği, ancak verilerdeki belirsizliği ölçmek için olasılıksal bir çerçeveye sahip olmadığı belirtilmiştir. Skolyoz tanılı hastaların ilerleyici (P) ve ilerleyici olmayan (NP) grupları arasındaki ayrımı en üst düzeye çıkarmak için bir ayırıcı bitişik matris oluşturulmuştur. İlerleme hızı, omurga esnekliğinden ve 3-boyutlu omurga deformasyonunun eğri büyüklüğünden modüle edilmiştir. Yöntem, omurganın boyuna 3-D rekonstrüksiyonları kullanılarak 133 kişiden 745 rekonstrüksiyon üzerinde test edilmiştir. Metod daha yüksek bir tahmin doğruluğu sağlamış ve yüksek derecede deforme olmuş omurgalardaki spatiotemporal morfolojik değişikliklerin diğer öğrenme metotlarına kıyasla modellenmesi geliştirilmiştir. (145).

Forsberg ve ark. tarafından 2017 yılında her vertebra için etiketlenmiş klinik açıklamalı MRG'lere dayanan benzer bir yaklaşım ile, biri servikal diğeri lomber vertebra tespiti ve etiketlemesi için iki derin öğrenme eğitme için kullanılmıştır. Genel ve daha spesifik vertebra özelliklerini tespit etmek için iki CNN kullanılmıştır. Ayrıca, hatalı pozitifleri filtrelemek ve her bir vertebra'yı doğru şekilde etiketlemek için katmanlı bir grafiğe dayalı bir parça tabanlı grafik model oluşturulmuştur. Bu grafikte, her katman tespit edilen vertebraları ve daha önce tespit edilen ve etiketlenmiş vertebra konfigürasyonları kullanılmıştır. Bu derin öğrenme yaklaşımının en yüksek performansı, 99.8 duyarlılık, 100 özgüllük ve tespit görevi için % 99.8 ve etiketleme görevi için % 97 hassasiyet gösterilmiştir(146).

Al-Helo ve ark. tarafından 2013 yılında bir sinir ağı ve bir k-NN yöntemi yaklaşımı uygulanılarak segmentasyon ve tahmin için BT görüntü etiketlemesinden lomber wedge kırığı tanıları öğrenmeye çalışılmıştır. Sinir ağının lomber kırıkların tespiti için ortalama olarak % 93.2'lik bir kesinliğe ulaşılmış, kümeleme yönteminin ise ortalama olarak % 98'lik bir kesinliğe ulaşılmış, böylece % 99'un üzerinde bir duyarlılık ve % 87.5'lik bir özgüllük gösterilmiştir (147).

Pesteie ve ark. tarafından 2015 yılında perkütan spinal iğne enjeksiyonlarında optimal omur seviyesini otomatik olarak saptamak için ultrason görüntüleri ile eğitilmiş yapay sinir ağlarından faydalanılmıştır. Spinal ultrason görüntüleri bölgedeki oryantasyon korelasyon imzalarıyla eşleştirmek, farklı omurga desenleri için ayırt edici özellikleri tespit etmek için Hadamard katsayıları kullanılmıştır. Hem epidural hem de faset eklem için hedef düzlemine ait olan veya olmayan diye sınıflandırmak için yapay bir sinir ağı eğitilmiştir. Sonuçlar % 95 en yüksek doğruluk, % 96 maksimum duyarlılık, % 97 maksimum özgüllük ve % 97 maksimum hassasiyet gösterilmiştir(148, 149).

Hetherington ve ark. tarafından 2017 yılında hastanın en iyi lomber ponksiyon noktası için omur seviyesini otomatik olarak tespit eden önceden eğitilmiş bir CNN ve sonlu durumlu bir transdüser uygulayan gerçek zamanlı bir tarayıcı sistemi (SLIDE) bildirilmiştir. CNN, hastanın omur taraması-sakrum, omur arası boşluklar ve omurlar arasındaki üç bölgeyi tanıyabilmiş ve aynı zamanda her birine olasılıklar atayabilmiştir. Bu deneyde elde edilen doğruluk % 90.8 olarak bulunmuş ve lomber vertebra seviyelerini başarıyla tanımlayan bir makine öğrenme sistemi sunulmuştur(149).

Xue ve ark. tarafından 2017 yılında Kalça OA tanısında bir VGG 16-katmanlı CNN kullanılmıştır. 400'den fazla kalça röntgeni görüntüsü ilk önce normal olarak sınıflandırılmış ve 20 yıldan fazla deneyime sahip iki doktor tarafından etiketlenmiştir ve bu, MÖ aracını karşılaştırmak için çalışmanın temeli olarak kabul edilmiştir. CNN daha sonra yaklaşık 45 görüntü ile eğitilmiş ve parametreler beş

çapraz doğrulama işleminden sonra optimize edilmiş ve % 87,5 en iyi doğruluk elde edilmiştir. Test setinde özgüllük % 90.7 ve duyarlılık % 95 bulunmuştur. Test setinin otomatik sınıflandırması, ilk uzman değerlendirici ve testin sırasıyla 3, 10 ve 15 yıllık klinik deneyime sahip son üç değerlendiricisi arasında bir Teşhis Anlaşma Oranı (DAR) değerlendirilmiştir. CNN ve ilk uzman puanlayıcılar arasındaki DAR % 92.8 bulunmuştur. İlk uzmanlar ve daha deneyimli uzmanlar arasındaki DAR % 96,4 idi. CNN ve daha az deneyimli doktor arasındaki DAR'ın, CNN ve daha deneyimli doktor arasındakilerden daha düşük olduğu (sırasıyla% 74.7 ve% 92.8) gösterilmiştir. Bu çalışmanın sonuçlarında, derin öğrenmenin akıllı tıbbi görüntü tanı pratiği alanında umut verici bir potansiyele sahip olduğu gösterilmiştir.(150).

Giordano ve ark. tarafından 2016 yılında Tanner ve Whitehouse (TW2) klinik yönteminin değiştirilmiş versiyonuna göre iskelet kemiğinin otomatik olarak değerlendirilmesi için bir araç sunulmuştur. Araç, görüntü işleme teknikleriyle epifizyal/ metafizyal ROI'leri işleyerek ve gizli Markov modelleri ile TW2 aşama için her ROI'yi atayarak 0-6 yaş aralığında kesin bir kemik yaşı değerlendirmesi sağlayabilmiştir. Sistem, bir set üzerinde değerlendirilmiş ve 360 X-ışınının (erkekler için 180 ve kadınlar için 180), kemik yaşı değerlendirmesinde yüksek başarı oranına ulaşması (insan hatası ile karşılaştırılabilir ortalama hata oranı 0.41 ± 0.33 yıl) ve diğer etkili yöntemlerden daha iyi performans gösterilmiştir.(151).

Liu ve ark. tarafından 2018 yılında çok sınıflı bir sınıflandırma sınıflandırması için CNN tabanlı bir yaklaşımın çok yakın bir ilerlemesi rapor edilmiştir. SegNet teknolojisi, evrimsel kodlayıcı-kod çözücü ağına ve semantik segmentasyon problemlerinde yüksek doğruluk ve verimlilik sağlayabilen bir 3D simpleks deforme edilebilir modele dayandırılmıştır. Bu, kemik ve kırıkta segmentasyonu ve etiketleme için serbestçe temin edilebilen diz görüntü veri setine uygulanmıştır. Bildirilen performans doğruluğu femoral kırıkta etiketleme için % 75.3 ve patellar kırıkta etiketleme için % 78.1 bulunmuştur(152).

Adankon ve ark. tarafından 2012 yılında DVM'nin bir varyantı, En Küçük Kareler DVM (LS-SVM) optik sayısallaştırıcılar ile elde edilen 3B gövde

görüntülerinden skolyoz eğrisi tipleri arasında ayırım yapmayı amaçlamıştır. Görüntüler alındıktan sonra, 3D arka görüntüler yatay dilimlere bölünmüş ve her dilim dilimler halinde ayrıştırılmıştır. Torasik ve lomber geometrik tanımlayıcılar çıkarılmış. 165 örnek için, yaklaşık % 95'lik ortalama bir başarı oranı verilmiştir. Sistemin en düşük performansı, genellikle kafaları karışan torasik ana eğriye karşı çift ana eğrinin tespiti sırasında üretilmiştir. Benzer bir çalışma Ramirez ve ark.2008 yılında farklı MÖ teknikleri uygulayarak skolyozdaki eğri değişikliklerini tespit etmeye çalışılmıştır. DVM, DT ve bir lojistik regresyon sınıflandırıcısı. DVM 141 omurga grafisinde% 86 doğrulukla en iyi sonuç bulunmuştur(153, 154).

Yu ve ark. tarafından 2015 yılında DVM'nin uygulandığı diğer bir problem, iğne giriş yeri lokalizasyonu. En iyi sınıflandırma özelliklerini çıkarmak için ultrason omurga görüntülerine şablon eşleştirme ve orta hat algılama yöntemleri uygulandı. 1000'den fazla görüntü analiz edilmiş ve eğitim setinde% 95 ve test setinde% 92'lik doğruluk oranları elde edilmiştir. Aynı DVM daha sonra yaklaşık 50 video görüntüsünde iğnenin sokulması için kesişen bölgeyi tespit etmek için kullanılmış ve 46 kişiden 45'inde başarılı olmuştur(155).

2015 yılında Rio De Janeiro kominikasyon bilgi teknolojisini kullanarak ortopedi hastalarında antikoagülan terapisinin profesyonel sağlık bakımının optimizasyonu için bir prototip geliştirmiştir. Sonuçları 3 faza ayırmıştır. 1. Faz bilgilerin toplanması, 2. Faz Eclipse® programı kullanarak hızlı bir dizayn yapılması, son fazda ise Java® 7 and PostgreSQL® 9.3 programları kullanarak antikoagülan kullanımında sağlık yönetim sistemi olarak adlandırılan bir prototip oluşturmuştur(156).

Liu ve ark. tarafından 2014 yılında esas olarak üç parçadan oluşan yüzey yerleştirme teknikleri kullanılarak, segmente edilmiş asetabulumun doğruluğunu arttırmak için yeni bir yöntem bulunmuştur. (1) bir optimizasyon yüzeyi elde etmek için bir yüzey yinelemeli işlem tasarlama; (2) elipsoid bağlantı parçasını iki fazlı kuadrik yüzey bağlantı parçasına değiştirmek; (3), uygun kuadrik yüzeyin kenar noktalarını yakalamak için normal bir eşleme yöntemi ve bir optimizasyon bölgesi

yöntemi getirmek amaçlanmıştır. Ayrıca, bu yazıda 40 hastanın (79 kalça eklemi ile birlikte) tomografi veri setleri gösterilmiştir. Test sonuçları şunu göstermektedir; İlk olarak kuadrik yüzey montaj yönteminin ortalama hatası 2,3 mm dir. İkincisi otomatik olarak tanınan konturların doğruluk oranı% 89.4'ten büyüktür. Son olarak kesit konturlarının hata oranı, ciddi malformasyona sahip olmayan asetabulumlar için % 10'dan az ve ağır malformasyona sahip asetabulumlar için % 30'dan az olduğu tespit edilmiştir(157).

Tartışma kısmında makine öğrenme yöntemlerinin ortopedi uygulanma alanında kullanımından bahsedilmiştir. Fakat bu yöntemin sağlık sektörünün birçok alanında da kullanıldığını unutmamak gerekir. Meme kanseri teşhisinde, EKG sinyallerinde aritmi tespitinde, felçli insanların EEG sınıflandırılmasında, KOAH seviyelerinin belirlenmesinde ve daha birçok alanda kullanılmaktadır.

6. SONUÇ VE ÖNERİLER

Ölüme etki eden özellikler içinde kreatinin (revizyon için de önemli bir parametre) ve kronik hastalık varlığı modellerin genelde en fazla ağırlık verdiği parametreler olmuştur. Bu sebeple kalça kırığı sebebiyle parsiyel protez uygulanacak hastalarda bu 2 parametre yakın takip edilmeli ve tedavileri için yoğun mesai harcanmalıdır. Gerekli konsültasyonların ivedi bir şekilde yapılıp, değiştirilebilir ve tedavi edilebilir bu faktörlerin ameliyat öncesi ve sonrası düzeltilmesi gerekmektedir. Ayrıca protez uygulanırken intraoperatif olarak dikkat edilmesi gereken parametreler bacak uzunluk farkı, protez tipi(sementli) ve trokanterik tespit olarak belirlenmiştir. Parsiyel protez uygulanırken özellikle bacak uzunluk farkının olmamasına dikkat edilmelidir. Gerekirse protez deneme aparatı ile intraoperatif röntgen çekilmelidir.

Hastanede kalım süresine ve maliyete etki eden en önemli parametre ise başvuru tarihi ile ameliyat olduğu tarih arasındaki süre (ortalama 4.02 gün) olarak belirlenmiştir. Sonuç olarak bu hastalar ameliyata mümkün olan en kısa sürede ameliyata hazır hale getirilmeli ve en uygun zamanda opere edilmelidirler.

Kullandığımız modellerin bazı kısıtlılıkları olmuştur. Çünkü hasta sayımızın sınırlı olması ve parametrelerin yetersiz olması bunlardan birkaçıdır. Bu modellerin daha başarılı olması için, birincisi; daha fazla veri elde edilmesi, ikincisi; hastanemiz otomasyonların alt yapısına uygun uygulamaların geliştirilmesi ve bu işlemlerin otomatize edilmesi olarak sayılabilir.

Bilgisayar biliminin ortaya çıkması ve gelişmesi ile makine öğrenmesi popüler hale gelmiş ve yapay zekanın ana alt dallarından biri olmuştur. Makine öğrenmesi pratik hayatta birçok alanda kullanılmış ve kullanılmaya devam etmektedir. Makine öğrenmesinin avantajlarından biri kod yazılımı olmadan veri seti kullanarak ilginç algoritmalar ortaya çıkarmasıdır. Bilinen özellikler üzerinden bilinmeyen verileri keşfedebilmeye odaklanır. Pazarlama, otomotiv, eğlence ve sağlık sektörü gibi pek çok alanda kullanılmaktadır. Ve her geçen gün bu alanların sayısı artmaktadır.

Günümüzde, gelişen teknoloji ile birlikte elde tutulan veri miktarı artmış, saklanan ham veriyi bilgiye dönüştürmek geçmişe göre daha da önem kazanmıştır. Sağlık alanında bu veriler hasta sağlığının idamesi için kullanılmakta ve gelecek hastalar için yol göstermektedir. Kalça kırıklarının sıkça rastlandığı ülkemizde özellikle de yaşlılarda uygulanan tedavi protokollerine göre prognoz tahmini yapmak oldukça önemlidir. Zira özelliklerde kalça kırıklı yaşlı hastalarda uygulanan parsiyel protezin prognoza olumsuz etkisinin olduğu bilinmektedir. Bunun önüne geçmek ve hastaların perioperatif daha iyi yaşam almasını sağlamak amacıyla sadece tahmin analizi değil aynı zamanda prognoza ait faktörlerin açıklanabilirliği de önemlidir. Özellikle de değiştirilebilir faktörlerin sonuç üzerindeki etkilerini önleyerek hastalara daha kaliteli ve uzun ömür sağlanabilir. Aksi takdirde hastaların kalitesiz yaşamlarının hem kendilere ve ailelerine hem de ülkelerine maddi ve manevi yönden önemli ölçüde zarar vereceği kanaatindeyiz.

Devletlerin öncelikli amacı, vatandaşlarının yaşam kalitesini ve yaşam süresini artırmaktır(63). Bu nedenle vatandaşlarının daha uzun yaşamlarını sağlamak için çeşitli veri analizi yaparak yaşam üzerindeki etkenlerin ne olduğunu ve gelecekteki prognozunun nasıl belirlendiğini tespit etmek ülkelerin büyük bir sorumluluğudur. Maalesef ülkemizde ciddi bir eksiklik olarak gördüğümüz bir çalışma konusu üzerinde tez yazarak hem ortopedi alanın bu konudaki farkındalığı artırmak hem de bu alandaki çalışmaların sayısını artırma çabası içerisinde olmayı amaçladık. Makine öğrenme yöntemlerinin ve yapay zeka tekniklerinin ülkemizin sağlık alanında gelişmesine önemli katkıda bulunacağını düşünmekteyiz.

7. KAYNAKLAR

1. Kononenko I. Machine learning for medical diagnosis: history, state of the art and perspective. *Artificial Intelligence in medicine*. 2001;23(1):89-109.
2. Wang R, Pan W, Jin L, Li Y, Geng Y, Gao C, et al. Artificial intelligence in reproductive medicine. *Reproduction*. 2019;1(aop).
3. Miller DD, Brown EW. Artificial intelligence in medical practice: the question to the answer? *The American journal of medicine*. 2018;131(2):129-33.
4. Cummings SR, Nevitt MC, Browner WS, Stone K, Fox KM, Ensrud KE, et al. Risk factors for hip fracture in white women. *New England journal of medicine*. 1995;332(12):767-74.
5. Johnell O, Gullberg B, Kanis JA, Allander E, Elffors L, Dequeker J, et al. Risk factors for hip fracture in European women: the MEDOS study. *Journal of Bone and Mineral Research*. 1995;10(11):1802-15.
6. Kanis J, Johnell O, Gullberg B, Allander E, Elffors L, Ranstam J, et al. Risk factors for hip fracture in men from southern Europe: the MEDOS study. *Osteoporosis International*. 1999;9(1):45-54.
7. Hippisley-Cox J, Coupland C. Derivation and validation of updated QFracture algorithm to predict risk of osteoporotic fracture in primary care in the United Kingdom: prospective open cohort study. *Bmj*. 2012;344:e3427.
8. Deo RC. Machine learning in medicine. *Circulation*. 2015;132(20):1920-30.
9. Deng L. *IEEE/ACM Transactions on Audio, Speech and Language Processing (TASLP) Volume 22 Issue 12*. 2014.
10. Taigman Y, Yang M, Ranzato MA, Wolf L, editors. Deepface: Closing the gap to human-level performance in face verification. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 2014.
11. Silver D, Huang A, Maddison CJ, Guez A, Sifre L, Van Den Driessche G, et al. Mastering the game of Go with deep neural networks and tree search. *nature*. 2016;529(7587):484.

12. Strayer DL, Cooper JM, Turrill J, Coleman JR, Hopman RJ. The smartphone and the driver's cognitive workload: A comparison of Apple, Google, and Microsoft's intelligent personal assistants. *Canadian Journal of Experimental Psychology/Revue canadienne de psychologie expérimentale*. 2017;71(2):93.
13. Katrakazas C, Quddus M, Chen W-H, Deka L. Real-time motion planning methods for autonomous on-road driving: State-of-the-art and future research directions. *Transportation Research Part C: Emerging Technologies*. 2015;60:416-42.
14. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542(7639):115.
15. Wang S, Summers RM. Machine learning and radiology. *Medical image analysis*. 2012;16(5):933-51.
16. Andreu-Perez J, Poon CC, Merrifield RD, Wong ST, Yang G-Z. Big data for health. *IEEE journal of biomedical and health informatics*. 2015;19(4):1193-208.
17. Obermeyer Z, Emanuel EJ. Predicting the future—big data, machine learning, and clinical medicine. *The New England journal of medicine*. 2016;375(13):1216.
18. Patel VL, Shortliffe EH, Stefanelli M, Szolovits P, Berthold MR, Bellazzi R, et al. coming of age of artificial intelligence in. 2008.
19. Lee CS, Nagy PG, Weaver SJ, Newman-Toker DE. Cognitive and system factors contributing to diagnostic errors in radiology. *American Journal of Roentgenology*. 2013;201(3):611-7.
20. Neill DB. Using artificial intelligence to improve hospital inpatient care. *IEEE Intelligent Systems*. 2013;28(2):92-5.
21. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJ. Artificial intelligence in radiology. *Nature Reviews Cancer*. 2018;18(8):500.
22. Johnson KW, Soto JT, Glicksberg BS, Shameer K, Miotto R, Ali M, et al. Artificial intelligence in cardiology. *Journal of the American College of Cardiology*. 2018;71(23):2668-79.

23. Tang A, Tam R, Cadrin-Chênevert A, Guest W, Chong J, Barfett J, et al. Canadian Association of Radiologists white paper on artificial intelligence in radiology. *Canadian Association of Radiologists Journal*. 2018;69(2):120-35.
24. Johnston MD. *The spiritual logic of Ramon Llull*. 1987.
25. Bonner A. *Doctor Illuminatus: A Ramon Llull Reader*. 1994.
26. Nilsson NJ. *The quest for artificial intelligence*: Cambridge University Press; 2009.
27. Leibniz GW, von Leibniz GWF. *Leibniz: New essays on human understanding*: Cambridge University Press; 1996.
28. Bayes T. XLIII. A letter from the late Reverend Mr. Thomas Bayes, FRS to John Canton, MA and FR S. *Philosophical Transactions of the Royal Society of London*. 1763(53):269-71.
29. Dale AI. *A history of inverse probability: From Thomas Bayes to Karl Pearson*: Springer Science & Business Media; 2012.
30. MacHale D. *The life and work of George Boole: a prelude to the digital age*: Cork University Press; 2014.
31. Tesla N. *My inventions: the autobiography of Nikola Tesla: the Philovox*; 2007.
32. O'Neill J. *Prodigal genius: the life of Nikola Tesla*: Book Tree; 2007.
33. de Posada FG. *Leonardo Torres Quevedo*: Fundación Banco Exterior; 1992.
34. Klíma I, Klíma I. *Karel Čapek: life and work*: Catbird Press; 2002.
35. Popa I. *Robot's Apperance*: Vilnius Academy of Arts.
36. Landahl H, McCulloch WS, Pitts W. A statistical consequence of the logical calculus of nervous nets. *Bulletin of Mathematical Biology*. 1943;5(4):135-7.
37. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*. 1943;5(4):115-33.
38. Turing AM. Can a machine think. *The world of mathematics*. 1956;4:2099-123.
39. Marvin M, Seymour P. *Perceptrons*. MIT Press; 1969.
40. Keskenler MF, Keskenler EF. Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. *Takvim-i Vekayi*. 2017;5(2):8-18.

41. McCarthy J. Two puzzles involving knowledge. *Formalizing Common Sense*, Ablex. 1989.
42. McCarthy J, Hayes PJ. Some philosophical problems from the standpoint of artificial intelligence. *Readings in artificial intelligence*: Elsevier; 1981. p. 431-50.
43. McCarthy J, Minsky ML, Rochester N, Shannon CE. A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*. 2006;27(4):12-.
44. McCarthy J, Sato M, Hayashi T, Igarashi S. On the model theory of knowledge. STANFORD UNIV CA DEPT OF COMPUTER SCIENCE, 1978.
45. Rumelhart David E, Hinton Geoffrey E, Williams Ronald J. Learning representmions by back-propagating error~. *Nature*. 1986;323(6):088.
46. Schaeffer J, Plaat A. Kasparov versus deep blue: The rematch. *ICGA Journal*. 1997;20(2):95-101.
47. Haffner P, Bottou L, Howard PG, Simard P, Bengio Y, Le Cun Y, editors. Browsing through high quality document images with DjVu. *Proceedings IEEE International Forum on Research and Technology Advances in Digital Libraries-ADL'98-*; 1998: IEEE.
48. Goodfellow I, Bengio Y, Courville A. *Deep learning*: MIT press; 2016.
49. Granter SR, Beck AH, Papke Jr DJ. AlphaGo, deep learning, and the future of the human microscopist. *Archives of pathology & laboratory medicine*. 2017;141(5):619-21.
50. Silver D, Schrittwieser J, Simonyan K, Antonoglou I, Huang A, Guez A, et al. Mastering the game of go without human knowledge. *Nature*. 2017;550(7676):354.
51. Tomar D, Agarwal S. A survey on Data Mining approaches for Healthcare. *International Journal of Bio-Science and Bio-Technology*. 2013;5(5):241-66.
52. Koh HC, Tan G. Data mining applications in healthcare. *Journal of healthcare information management*. 2011;19(2):65.

53. Frank E, Hall M, Holmes G, Kirkby R, Pfahringer B, Witten IH, et al. Weka-a machine learning workbench for data mining. Data mining and knowledge discovery handbook: Springer; 2009. p. 1269-77.
54. Shalev-Shwartz S, Ben-David S. Understanding machine learning: From theory to algorithms: Cambridge university press; 2014.
55. Kukar M, Kononenko I, Silvester T. Machine learning in prognosis of the femoral neck fracture recovery. Artificial intelligence in medicine. 1996;8(5):431-51.
56. Kassahun Y, Yu B, Tibebu AT, Stoyanov D, Giannarou S, Metzen JH, et al. Surgical robotics beyond enhanced dexterity instrumentation: a survey of machine learning techniques and their role in intelligent and autonomous surgical actions. International journal of computer assisted radiology and surgery. 2016;11(4):553-68.
57. Chapelle O, Scholkopf B, Zien A. Semi-supervised learning (chappelle, o. et al., eds.; 2006)[book reviews]. IEEE Transactions on Neural Networks. 2009;20(3):542-.
58. Zhu XJ. Semi-supervised learning literature survey. University of Wisconsin-Madison Department of Computer Sciences, 2005.
59. Sutton RS, Barto AG. Introduction to reinforcement learning: MIT press Cambridge; 1998.
60. Kaelbling LP, Littman ML, Moore AW. Reinforcement learning: A survey. Journal of artificial intelligence research. 1996;4:237-85.
61. Ahmad P, Qamar S, Rizvi SQA. Techniques of data mining in healthcare: a review. International Journal of Computer Applications. 2015;120(15).
62. Landgrebe TC, Paclik P, Duin RP, editors. Precision-recall operating characteristic (P-ROC) curves in imprecise environments. null; 2006: IEEE.
63. KARTAL E, Programı E, BALABAN ME. SINIFLANDIRMAYA DAYALI MAKİNE ÖĞRENMESİ TEKNİKLERİ VE KARDİYOLOJİK RİSK DEĞERLENDİRMESİNE İLİŞKİN BİR UYGULAMA.
64. Bradley AP. The use of the area under the ROC curve in the evaluation of machine learning algorithms. Pattern recognition. 1997;30(7):1145-59.

65. Lavecchia A. Machine-learning approaches in drug discovery: methods and applications. *Drug discovery today*. 2015;20(3):318-31.
66. Bottou L. Stochastic gradient descent tricks. *Neural networks: Tricks of the trade*: Springer; 2012. p. 421-36.
67. Platt J. Sequential minimal optimization: A fast algorithm for training support vector machines. 1998.
68. Nielsen TD, Jensen FV. *Bayesian networks and decision graphs*: Springer Science & Business Media; 2009.
69. Marcus G. Deep learning: A critical appraisal. arXiv preprint arXiv:180100631. 2018.
70. Ravi D, Wong C, Deligianni F, Berthelot M, Andreu-Perez J, Lo B, et al. Deep learning for health informatics. *IEEE journal of biomedical and health informatics*. 2016;21(1):4-21.
71. Guo Y, Liu Y, Oerlemans A, Lao S, Wu S, Lew MS. Deep learning for visual understanding: A review. *Neurocomputing*. 2016;187:27-48.
72. Suzuki K. Overview of deep learning in medical imaging. *Radiological physics and technology*. 2017;10(3):257-73.
73. Garner SR, editor *Weka: The waikato environment for knowledge analysis*. Proceedings of the New Zealand computer science research students conference; 1995.
74. Suthar B, Patel H, Goswami A. A survey: classification of imputation methods in data mining. *International Journal of Emerging Technology and Advanced Engineering*. 2012;2(1):309-12.
75. Somasundaram R, Nedunchezian R. Evaluation of three simple imputation methods for enhancing preprocessing of data with missing values. *International Journal of Computer Applications*. 2011;21(10):14-9.
76. Guo Sa, DiPietro LA. Factors affecting wound healing. *Journal of dental research*. 2010;89(3):219-29.
77. Kamide K. *Cellulose and cellulose derivatives*: Elsevier; 2005.
78. Stryker LS, Abdel MP, Morrey ME, Morrow MM, Kor DJ, Morrey BF. Elevated postoperative blood glucose and preoperative hemoglobin A1C are

associated with increased wound complications following total joint arthroplasty. JBJS. 2013;95(9):808-14.

79. Kremers HM, Lewallen LW, Mabry TM, Berry DJ, Berbari EF, Osmon DR. Diabetes mellitus, hyperglycemia, hemoglobin A1C and the risk of prosthetic joint infections in total hip and knee arthroplasty. The Journal of arthroplasty. 2015;30(3):439-43.

80. Shemesh O, Golbetz H, KRiss JP, Myers BD. Limitations of creatinine as a filtration marker in glomerulopathic patients. Kidney international. 1985;28(5):830-8.

81. Hawkins RC. Age and gender as risk factors for hyponatremia and hypernatremia. Clinica chimica acta. 2003;337(1-2):169-72.

82. Viera AJ, Wouk N. Potassium Disorders: Hypokalemia and Hyperkalemia. American family physician. 2015;92(6).

83. Kiernan F. XXIX. The anatomy and physiology of the liver. Philosophical transactions of the Royal Society of London. 1833(123):711-70.

84. Hyder MA, Hasan M, Mohieldein AH. Comparative levels of ALT, AST, ALP and GGT in liver associated diseases. European journal of experimental biology. 2013;3(2):280-4.

85. Van Der Deure WM, Uitterlinden AG, Hofman A, Rivadeneira F, Pols HA, Peeters RP, et al. Effects of serum TSH and FT4 levels and the TSHR-Asp727Glu polymorphism on bone: the Rotterdam Study. Clinical endocrinology. 2008;68(2):175-81.

86. Dorr LD, Faugere M-C, Mackel AM, Gruen TA, Bognar B, Malluche HH. Structural and cellular assessment of bone quality of proximal femur. Bone. 1993;14(3):231-42.

87. Nash W, Harris A. The Dorr type and cortical thickness index of the proximal femur for predicting peri-operative complications during hemiarthroplasty. Journal of orthopaedic Surgery. 2014;22(1):92-5.

88. FLOERKEMEIER T, WELTIN J, BUDDE S, HURSCHLER C, WINDHAGEN H, VON LEWINSKI G, et al. A short stem with metaphyseal anchorage reveals a more physiological strain pattern compared to a standard stem-an

experimental study in cadavaric bone. *Acta of Bioengineering & Biomechanics*. 2019;21(2).

89. Kutzner KP, Freitag T, Donner S, Kovacevic MP, Bieger R. Outcome of extensive varus and valgus stem alignment in short-stem THA: clinical and radiological analysis using EBRA-FCA. *Archives of orthopaedic and trauma surgery*. 2017;137(3):431-9.

90. Flecher X, Ollivier M, Argenson J. Lower limb length and offset in total hip arthroplasty. *Orthopaedics & Traumatology: Surgery & Research*. 2016;102(1):S9-S20.

91. Williamson JA, Reckling FW. Limb length discrepancy and related problems following total hip joint replacement. *Clinical orthopaedics and related research*. 1978(134):135-8.

92. Woolson ST, Hartford JM, Sawyer A. Results of a method of leg-length equalization for patients undergoing primary total hip replacement. *The Journal of arthroplasty*. 1999;14(2):159-64.

93. AKTUĞLU K, ÖZKAYIN N. Kalça Eklemi Çevresi Yaralanmaları Acilleri. *Türkiye Klinikleri Orthopaedics and Traumatology-Special Topics*. 2010;3(3):29-32.

94. Heckman JD, McQueen MM, Ricci WM, Tornetta P, McKee MD. *Rockwood and Green's fractures in adults*: Wolters Kluwer Health; 2015.

95. Court-Brown CM, Caesar B. Epidemiology of adult fractures: a review. *Injury*. 2006;37(8):691-7.

96. Sharma S, Sharma P, Tyler LN. Transfusion of blood and blood products: indications and complications. *American family physician*. 2011;83(6).

97. Jameson SS, Jensen CD, Elson DW, Johnson A, Nachtsheim C, Rangan A, et al. Cemented versus cementless hemiarthroplasty for intracapsular neck of femur fracture—a comparison of 60,848 matched patients using national data. *Injury*. 2013;44(6):730-4.

98. Dorr LD, Glousman R, Hoy ALS, Vanis R, Chandler R. Treatment of femoral neck fractures with total hip replacement versus cemented and noncemented hemiarthroplasty. *The Journal of arthroplasty*. 1986;1(1):21-8.

99. Yli-Kyyny T, Ojanperä J, Venesmaa P, Kettunen J, Miettinen H, Salo J, et al. Perioperative complications after cemented or uncemented hemiarthroplasty in hip fracture patients. *Scandinavian Journal of Surgery*. 2013;102(2):124-8.
100. Moran CG, Wenn RT, Sikand M, Taylor AM. Early mortality after hip fracture: is delay before surgery important? *JBJS*. 2005;87(3):483-9.
101. Hayashi H, Dikkes P, Soriano SG. Repeated administration of ketamine may lead to neuronal degeneration in the developing rat brain. *Pediatric Anesthesia*. 2002;12(9):770-4.
102. Kofke WA, Garman RH, Stiller RL, Rose ME, Garman R. Opioid neurotoxicity: fentanyl dose-response effects in rats. *Anesthesia & Analgesia*. 1996;83(6):1298-306.
103. Ward CG, Loepke AW. Anesthetics and sedatives: toxic or protective for the developing brain? *Pharmacological research*. 2012;65(3):271-4.
104. Cabitza F, Locoro A, Banfi G. Machine learning in orthopedics: a literature review. *Frontiers in bioengineering and biotechnology*. 2018;6.
105. Karhade AV, Thio Q, Ogink P, Kim J, Lozano-Calderon S, Raskin K, et al. Development of Machine Learning Algorithms for Prediction of 5-Year Spinal Chordoma Survival. *World neurosurgery*. 2018;119:e842-e7.
106. Han I, Kim JH, Park H, Kim H-S, Seo SW. Deep learning approach for survival prediction for patients with synovial sarcoma. *Tumor Biology*. 2018;40(9):1010428318799264.
107. Olczak J, Fahlberg N, Maki A, Razavian AS, Jilert A, Stark A, et al. Artificial intelligence for analyzing orthopedic trauma radiographs: deep learning algorithms—are they on par with humans for diagnosing fractures? *Acta orthopaedica*. 2017;88(6):581-6.
108. Karhade AV, Schwab JH, Bedair HS. Development of Machine Learning Algorithms for Prediction of Sustained Postoperative Opioid Prescriptions after Total Hip Arthroplasty. *The Journal of Arthroplasty*. 2019.
109. Karnuta JM, Navarro SM, Haeberle HS, Helm JM, Kamath AF, Schaffer JL, et al. Predicting Inpatient Payments Prior to Lower Extremity Arthroplasty using Deep Learning: Which Model Architecture Is Best? *The Journal of arthroplasty*. 2019.

110. Navarro SM, Wang EY, Haeberle HS, Mont MA, Krebs VE, Patterson BM, et al. Machine learning and primary total knee arthroplasty: patient forecasting for a patient-specific payment model. *The Journal of arthroplasty*. 2018;33(12):3617-23.
111. Ramkumar PN, Navarro SM, Haeberle HS, Karnuta JM, Mont MA, Iannotti JP, et al. Development and validation of a machine learning algorithm after primary total hip arthroplasty: applications to length of stay and payment models. *The Journal of arthroplasty*. 2019;34(4):632-7.
112. Ramkumar PN, Haeberle HS, Ramanathan D, Cantrell WA, Navarro SM, Mont MA, et al. Remote Patient Monitoring Using Mobile Health for Total Knee Arthroplasty: Validation of a Wearable and Machine Learning–Based Surveillance Platform. *The Journal of arthroplasty*. 2019.
113. Bini SA, Shah RF, Bendich I, Patterson JT, Hwang KM, Zaid MB. Machine Learning Algorithms Can Use Wearable Sensor Data to Accurately Predict Six-Week Patient-Reported Outcome Scores Following Joint Replacement in a Prospective Trial. *The Journal of arthroplasty*. 2019;34(10):2242-7.
114. Shah AA, Karhade AV, Bono CM, Harris MB, Nelson SB, Schwab JH. Development of a machine learning algorithm for prediction of failure of nonoperative management in spinal epidural abscess. *The Spine Journal*. 2019.
115. Karhade AV, Ogink PT, Thio QC, Broekman ML, Cha TD, Hershman SH, et al. Machine learning for prediction of sustained opioid prescription after anterior cervical discectomy and fusion. *The Spine Journal*. 2019;19(6):976-83.
116. Karhade AV, Ogink PT, Thio QC, Cha TD, Gormley WB, Hershman SH, et al. Development of Machine Learning Algorithms for Prediction of Prolonged Opioid Prescription after Surgery for Lumbar Disc Herniation. *The Spine Journal*. 2019.
117. Karhade AV, Ahmed AK, Pennington Z, Chara A, Schilling A, Thio QC, et al. External Validation of the SORG 90-day and One-Year Machine Learning Algorithms for Survival in Spinal Metastatic Disease. *The Spine Journal*. 2019.
118. Ashinsky BG, Bouhrara M, Coletta CE, Lehallier B, Urish KL, Lin PC, et al. Predicting early symptomatic osteoarthritis in the human knee using machine

learning classification of magnetic resonance images from the osteoarthritis initiative. *Journal of Orthopaedic Research*. 2017;35(10):2243-50.

119. Ashinsky BG, Coletta CE, Bouhrara M, Lukas VA, Boyle JM, Reiter DA, et al. Machine learning classification of OARSI-scored human articular cartilage using magnetic resonance imaging. *Osteoarthritis and cartilage*. 2015;23(10):1704-12.

120. Pritzker KP, Gay S, Jimenez S, Ostergaard K, Pelletier J-P, Revell P, et al. Osteoarthritis cartilage histopathology: grading and staging. *Osteoarthritis and cartilage*. 2006;14(1):13-29.

121. Matic A, Savić SP, Ristić B, Stevanović VB, Devedžić G. Infrared assessment of knee instability in ACL deficient patients. *International orthopaedics*. 2016;40(2):385-91.

122. Phinyomark A, Osis ST, Hettinga BA, Kobsar D, Ferber R. Gender differences in gait kinematics for patients with knee osteoarthritis. *BMC musculoskeletal disorders*. 2016;17(1):157.

123. Thong W, Parent S, Wu J, Aubin C-E, Labelle H, Kadoury S. Three-dimensional morphology study of surgical adolescent idiopathic scoliosis patient from encoded geometric models. *European Spine Journal*. 2016;25(10):3104-13.

124. Jamaludin A, Lootus M, Kadir T, Zisserman A, Urban J, Battié MC, et al. ISSLS PRIZE IN BIOENGINEERING SCIENCE 2017: Automation of reading of radiological features from magnetic resonance images (MRIs) of the lumbar spine without human intervention is comparable with an expert radiologist. *European Spine Journal*. 2017;26(5):1374-83.

125. Kotti M, Duffell LD, Faisal AA, McGregor AH. Detecting knee osteoarthritis and its discriminating parameters using random forests. *Medical engineering & physics*. 2017;43:19-29.

126. Madelin G, Poidevin F, Makrymallis A, Regatte RR. Classification of sodium MRI data of cartilage using machine learning. *Magnetic resonance in medicine*. 2015;74(5):1435-48.

127. Mirzaalian H, Wels M, Heimann T, Kelm BM, Suehling M, editors. Fast and robust 3D vertebra segmentation using statistical shape models. 2013 35th annual international conference of the IEEE engineering in medicine and biology society (EMBC); 2013: IEEE.

128. Bellamy N, Buchanan WW, Goldsmith CH, Campbell J, Stitt LW. Validation study of WOMAC: a health status instrument for measuring clinically important patient relevant outcomes to antirheumatic drug therapy in patients with osteoarthritis of the hip or knee. *The Journal of rheumatology*. 1988;15(12):1833-40.
129. Dolatabadi E, Taati B, Mihailidis A. An automated classification of pathological gait using unobtrusive sensing technology. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2017;25(12):2336-46.
130. Pedoia V, Haefeli J, Morioka K, Teng HL, Nardo L, Souza RB, et al. MRI and biomechanics multidimensional data analysis reveals R2-R1 ρ as an early predictor of cartilage lesion progression in knee osteoarthritis. *Journal of Magnetic Resonance Imaging*. 2018;47(1):78-90.
131. Nagarajan MB, Coan P, Huber MB, Diemoz PC, Glaser C, Wismüller A. Computer-aided diagnosis for phase-contrast X-ray computed tomography: quantitative characterization of human patellar cartilage with high-dimensional geometric features. *Journal of digital imaging*. 2014;27(1):98-107.
132. Zhang K, Lu W, Marziliano P. Automatic knee cartilage segmentation from multi-contrast MR images using support vector machine classification with spatial dependencies. *Magnetic resonance imaging*. 2013;31(10):1731-43.
133. Štajduhar I, Mamula M, Miletić D, Ünal G. Semi-automated detection of anterior cruciate ligament injury from MRI. *Computer methods and programs in biomedicine*. 2017;140:151-64.
134. Oktay AB, Albayrak NB, Akgul YS. Computer aided diagnosis of degenerative intervertebral disc diseases from lumbar MR images. *Computerized Medical Imaging and Graphics*. 2014;38(7):613-9.
135. Silver AE, Lungren MP, Johnson ME, O'Driscoll SW, An K-N, Hughes RE. Using support vector machines to optimally classify rotator cuff strength data and quantify post-operative strength in rotator cuff tear patients. *Journal of biomechanics*. 2006;39(5):973-9.
136. Zarychta P. Features extraction in anterior and posterior cruciate ligaments analysis. *Computerized Medical Imaging and Graphics*. 2015;46:108-20.

137. Dam EB, Lillholm M, Marques J, Nielsen M. Automatic segmentation of high-and low-field knee MRIs using knee image quantification with data from the osteoarthritis initiative. *Journal of Medical imaging*. 2015;2(2):024001.
138. Atkinson EJ, Therneau TM, Melton III LJ, Camp JJ, Achenbach SJ, Amin S, et al. Assessing fracture risk using gradient boosting machine (GBM) models. *Journal of Bone and Mineral Research*. 2012;27(6):1397-404.
139. Kruse C, Eiken P, Vestergaard P. Machine learning principles can improve hip fracture prediction. *Calcified tissue international*. 2017;100(4):348-60.
140. Cunha P, Moura DC, López MAG, Guerra C, Pinto D, Ramos I. Impact of ensemble learning in the assessment of skeletal maturity. *Journal of medical systems*. 2014;38(9):87.
141. Kellgren J, Lawrence J. Radiological assessment of osteo-arthrosis. *Annals of the rheumatic diseases*. 1957;16(4):494.
142. Marques J, Genant HK, Lillholm M, Dam EB. Diagnosis of osteoarthritis and prognosis of tibial cartilage loss by quantification of tibia trabecular bone from MRI. *Magnetic resonance in medicine*. 2013;70(2):568-75.
143. Marques J, Granlund R, Lillholm M, Pettersen PC, Dam EB. Automatic analysis of trabecular bone structure from knee MRI. *Computers in biology and medicine*. 2012;42(7):735-42.
144. Lee SI, Huang A, Mortazavi B, Li C, Hoffman HA, Garst J, et al. Quantitative assessment of hand motor function in cervical spinal disorder patients using target tracking tests. *Journal of Rehabilitation Research & Development*. 2016;53(6).
145. Kadoury S, Mandel W, Roy-Beaudry M, Nault M-L, Parent S. 3-D morphology prediction of progressive spinal deformities from probabilistic modeling of discriminant manifolds. *IEEE transactions on medical imaging*. 2017;36(5):1194-204.
146. Forsberg D, Sjöblom E, Sunshine JL. Detection and labeling of vertebrae in MR images using deep learning with clinical annotations as training data. *Journal of digital imaging*. 2017;30(4):406-12.

147. Al-Helo S, Alomari RS, Ghosh S, Chaudhary V, Dhillon G, Moh'd B A-Z, et al. Compression fracture diagnosis in lumbar: a clinical CAD system. *International journal of computer assisted radiology and surgery*. 2013;8(3):461-9.
148. Pesteie M, Abolmaesumi P, Ashab HA-D, Lessoway VA, Massey S, Gunka V, et al. Real-time ultrasound image classification for spine anesthesia using local directional Hadamard features. *International journal of computer assisted radiology and surgery*. 2015;10(6):901-12.
149. Hetherington J, Lessoway V, Gunka V, Abolmaesumi P, Rohling R. SLIDE: automatic spine level identification system using a deep convolutional neural network. *International journal of computer assisted radiology and surgery*. 2017;12(7):1189-98.
150. Xue Y, Zhang R, Deng Y, Chen K, Jiang T. A preliminary examination of the diagnostic value of deep learning in hip osteoarthritis. *PloS one*. 2017;12(6):e0178992.
151. Giordano D, Kavasidis I, Spampinato C. Modeling skeletal bone development with hidden Markov models. *Computer methods and programs in biomedicine*. 2016;124:138-47.
152. Li Y, Liang W, Zhang Y, An H, Tan J, editors. Automatic lumbar vertebrae detection based on feature fusion deep learning for partial occluded C-arm X-ray images. 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 2016: IEEE.
153. Adankon MM, Dansereau J, Labelle H, Cheriet F. Non invasive classification system of scoliosis curve types using least-squares support vector machines. *Artificial intelligence in medicine*. 2012;56(2):99-107.
154. Ramirez L, Durdle N, Raso V. A machine learning approach to assess changes in scoliosis. *Stud Health Technol Informat*. 2008;140:254.
155. Yu S, Tan KK, Sng BL, Li S, Sia ATH. Lumbar ultrasound image feature extraction and classification with support vector machine. *Ultrasound in medicine & biology*. 2015;41(10):2677-89.
156. Azevedo DMd. Terapia anticoagulante em unidade de internação ortopédica: a proposta de um software para a promoção da segurança do paciente. 2015.

157. Liu H, Zhao J, Dai N, Qian H, Tang Y. Improve accuracy for automatic acetabulum segmentation in CT images. *Bio-medical materials and engineering*. 2014;24(6):3159-77.

