T.C.
Atatürk Üniversitesi Tıp Fakültesi
Ortopedi ve Travmatoloji Anabilim Dalı

PROKSİMAL JUNCTİONAL KİFOZ GELİŞİM NEDENLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMİYLE TESPİTİ

Dr. Salih KAYA

UZMANLIK TEZİ

Danışmanlar
Doç. Dr. Sinan YILAR
Uzm. Dr. Kemal ZENCİRLİ

ERZURUM-2020

İÇİNDEKİLER

TABLOLAR DİZİNİ ……... iv

ŞEKİLLER DİZİNİ ……..... v

SİMGELER VE KISALTMALAR DİZİNİ …….. vi

TEŞEKKÜR ……... viii

ÖZET ……..x

ABSTRACT …….....xi

1.GİRİŞ VE AMAÇ ……..... 1

2.GENEL BİLGİLER ……... 4

2.1. Yapay Zeka (Artificel Intelligence) ……. 4

2.2. Tarihçe ……. 5

2.3. Günümüzde Yapay Zeka ……. 6

2.4. Sağlık Uygulamalarında Yapay Zeka ……. 7

2.5. Makine Öğrenmesi (Machine Learning) ……. 7

2.5.1. Denetimli Öğrenme (Supervised Learning) …… 8

2.5.2. Denetimsiz Öğrenme (Unsupervised Learning) …….. 8

2.5.3. Destekli Öğrenme (Reinforcement Learning) ……. 8

2.6. Derin Öğrenme (Deep Learning) ……. 8

2.7. Makine Öğrenme Yöntemleri …….. 9

2.7.1. Sınıflandırma ……... 9

2.7.2. Regresyon ……... 9

2.7.3. Lineer Regresyon (Linear Regression) ……... 9

2.7.4. Naive Bayes (Naive Bayesian) ……..10

2.7.5. Destek Vektör Makineleri (Support Vector Machine) …….. 11

2.7.6. Karar Ağacı (Desicion Tree) ……. 11

2.7.7. Yapay Sinir Ağları (Artificiel Neural Networks) ……. 12

2.8. Weka Bilgisayar Programı ……. 15

2.8.1. Weka Sınıflandırma Yöntemlerinin Yorumlanması ……. 16

2.9. Proksimal Junctional Kifoz (Proximal Junctional Kyphosis) ……....22
2.10. Proksimal Junctional Yetmezliği (Proksimal Junctional Failure)…… 22
2.11. PJK, PJF Risk Faktörleri……... 23
2.12. PJK'nin Sınıflaması…….. 25
3.GEREÇ VE YÖNTEMLER …….. 28
3.1. Kullanılan Parametreler …… 28
3.1.1. UIV, LIV ve Füzyon seviyesi …….. 28
3.1.2. Proksimal Junctional Açısı …….. 28
3.1.3. Torasik Kifoz (Thoracic Kyphosis) ……. 30
3.1.4. Lomber Lordoz (Lumbar Lordosis) ……. 31
3.1.5. Sagital Vertikal Aks (Sagittal Vertical Axis) ……... 31
3.1.6. Sakral Slop (Sacral Slope) ……..... 32
3.1.7. Pelvik Tilt (Pelvic Tilt) …… 33
3.1.8. Pelvik İnsidans (Pelvic Incidens) ……. 33
3.1.9. Global Sagital Dizilim (Global Sagittal Alignment) ……... 34
3.2. Cerrahi Teknik …….. 37
4.BULGULAR ……. 40
4.1. Ön İşlem (Preprocess) Sekmesi Sonuçları …… 40
4.2. Naive Bayes Sonuçları …….. 44
4.3. Destek Vektör Makineleri ……. 45
4.4. Karar Ağacı ……... 47
4.5. Yapay Sinir Ağları …… 49
5.TARTIŞMA …….. 50
5.1. Makine Öğrenmesi Algoritmalarının Sonuçlarının Yorumlanması …. 50
5.2. Hasta Bağımlı Risk Faktörlerinin Yorumlanması …… 53
5.2.1. Yaş ……... 53
5.2.2. Cinsiyet …… 53
5.2.3. Vücut Kitle Endeksi ……. 54
5.2.4. Ek Hastalık Varlığı …….. 54

5.2.5. Sigara Kullanımı …….. 55
5.3. Radyografik Risk Faktörlerinin Yorumlanması ……... 56
5.4. Cerrahi Nedenli Risk Faktörlerinin Yorumlanması ……. 56
5.4.1. Posterior Elemanların Diseksiyonu ……. 56
5.4.2. İmplant Özellikleri …….. 57
5.4.3. UIV, LIV Seçimi ve Entrüman Seviyesi ……. 58
5.4.4. Sakropelvik Füzyon …… 59
5.4.5. Deformitenin Aşırı Düzeltilmesi ……. 60
5.5. Diğer …… 61
6.SONUÇ VE ÖNERİLER ……. 65
7.KAYNAKLAR ……. 67

TABLOLAR DİZİNİ

Tablo 1. Veri setimizin niteliklerini gösteren arff dosya yapısı……..16

Tablo 2. Weka özet tablosu…….....17

Tablo 3. Örnek konfüzyon matrisi……..18

Tablo 4. ROC eğrisinin çizilmesi……20

Tablo 5. Tablo 4'ün devamı……21

Tablo 6. Tablo 5'in devamı…….21

Tablo 7. Yagi ve ark. nın PJK sınıflama ve derecelendirme şeması……...26

Tablo 8. Hart-Uluslararası omurga çalışma grubu PJK şiddet skalası……27

Tablo 9. PJK'ye etki eden parametreler……..40

Tablo 10. PJK'ye etki eden parametreler ön işlem sekmesi kullanılarak en yakın ilişkili olanlar sıralanmıştır…….41

Tablo 11. Postoperatif PJA'nın PJK gelişimiyle ilişkisini gösteren grafikte özellikle beş derece üzerindeki değerlerde PJK oranı artmaktadır……42

Tablo 12. PJK gelişiminde yaş parametresinin etkisi. Özellikle 11-17 ile 31-37 yaş aralığında PJK oranları yüksekti…….43

Tablo 13. Preoperatif PJA ile PJK gelişimi arasındaki ilişki. Üç derece üzerindeki üç hastanın tamamında PJK gelişti……..43

Tablo 14. SVA ameliyat öncesi ve ameliyat sonrası farkının PJK gelişimi üzerindeki etkisi. 8 derece üzerindeki değerlerin tamamında PJK gelişti……44

Tablo 15. PJK gelişimi üzerinde etki eden parametrelerin naive bayes algoritma sonucu…….44

Tablo 16. Destek vektör makinelerinden SMO (Sequencial Minimal Optimization) algoritması kullanılarak PJK üzerine etki eden parametreler belirlendi…….45

Tablo 17. SMO algoritmasında PJK var parametresine olumlu ve olumsuz etki eden parametrelerin gösterilmesi…….46

Tablo 18. Tablo 17'nin devamı……...46

Tablo 19. J48 karar ağacı algoritması sonuçları…….47

Tablo 20. J48 karar ağacı algoritma sonuçlarının görselleştirilmesi……..48

Tablo 21. YSA algoritması sonuçları…….49

Tablo 22. PJK gelişimi tahmini için makine öğrenmesi algoritmalarının sonuçları..50

ŞEKİLLER DİZİNİ

Şekil 1. Lineer regresyon modeli……..9

Şekil 2. Naive bayes modeli ve örnek çözüm…….....11

Şekil 3. Destek vektör makineleri modeli……...11

Şekil 4. Karar ağacı modellemesi……...12

Şekil 5. Biyolojik sinir hücresi anatomisi……...12

Şekil 6. Çok katmanlı ileri beslemeli yapay sinir ağı……13

Şekil 7. Örneklem……...19

Şekil 8. AUC grafiğinin çizilmesi……..21

Şekil 9. Proksimal junctional açısı…….22

Şekil 10. PJK gelişen bir hastamızın PJA ölçümü…….29

Şekil 11. Üst torakal bölge görüntülemesi yetersiz olan bir hastamızda "en uygun çizgi" yönteminin kullanılması……...30

Şekil 12. Torakal kifoz açısı ölçümü……..30

Şekil 13. Lomber lordoz açısı ölçümü…….....31

Şekil 14. Sagital vertikal aks……...32

Şekil 15. Sakral slop……...32

Şekil 16. Pelvik tilt……..33

Şekil 17. Pelvik insidans…….33

Şekil 18. Bir hastamızın preoperatif sagital Cobb açıları ölçümü……..35

Şekil 19. Bir hastamızın SVA ölçümü……36

Şekil 20. Bir hastamızın SS ve PT ölçümü…….36

Şekil 21. Ponte osteotomisi…….37

Şekil 22. Kifoskolyozlu bir hastanın pre-postop tam boy ön-arka ve yan grafileri…38

Şekil 23. T12 kama vertebranın PVKR sonrası kafes kullanılan bir hastamız……...39

Şekil 24. PT ve LL'nin küçük olduğu sagital omurga dizilimlerinde baş için yerçekimi çizgisi omurga önünden hizalanmaktadır……..52

Şekil 25. Sakrum ve iliak kanat füzyonu yapılmış bir hastamızın tam boy ön-arka ve yan grafileri……59

SİMGELER VE KISALTMALAR DİZİNİ

MÖ : Makine Öğrenmesi

YZ : Yapay Zeka

DÖ : Derin Öğrenme

PJK : Proksimal Junctional Kifoz

NB : Naive Bayes

DVM : Destek Vektör Makineleri

KA : Karar Ağacı

YSA : Yapay Sinir Ağları

GUA : Gözlemciler Arası Uzlaşma

UŞ : Uzlaşma Şansı

MAE : Mean Absolute Error

RMSE : Root Mean Absolute Error

ROC : Receiver Operating Characteristic

AUC : Area Under Curve

PJA : Proksimal Junctional Açısı

PVKR :Posterior Vertebral Kolon Rezeksiyonu

UIV : Upper Instrumented Vertebra

LIV : Lower Instrumented Vertebra

PJF : Proksimal Junctional Failure

LL : Lomber Lordoz

TK : Torakal Kifoz

SS : Sakral Slop

VKE : Vücut Kitle Endeksi

SVA : Sagital Vertikal Aks

PT : Pelvik Tilt

Pİ : Pelvik İnsidans

GSD : Global Sagital Dizilim

SMO : Sequencial Minimal Optimization

SP : Spinopelvik Parametreler

HRQOL : Health Related Quality of Life

TEŞEKKÜR

Ortopedi ve Travmatoloji asistanlığımın ilk gününden uzman olarak ayrıldığım son güne kadar bana bir abi yakınlığıyla davranan ve omurga cerrahisi konusunda bilgilerimi borçlu olduğum tez hocam Sn. Doç. Dr. Sinan YILAR'a,

Bölüm başkanımız olarak her sorunda bir baba şefkatiyle yaklaşan, sorunları çözme ve yol gösterme konusunda sabrını benden esirgemeyen Sn. Prof. Dr. Orhan KARSAN'a,

Pediatrik ortopedi ve hayat tecrübelerinden istifade ettiğim, eğitim sürecimdeki sabrıyla beni kendine hayran bırakan Sn. Prof. Dr. Naci EZİRMİK'e,

Hizmet bölgemizde tanınmış ve deneyimli bir cerrah olan, rekonstrüktif cerrahi konusunda bize ilham veren Sn. Prof. Dr. Ömer Selim YILDIRIM'a,

Pelvis travması konusundaki yaklaşımlarını ve cerrahi pratiğini örnek aldığım Sn. Doç. Dr. Ali AYDIN'a,

Spor cerrahisi alanında bana çok değerli bilgiler ve yetenekler kazandıran, teorik eğitim programlara bizleri teşvik eden Sn. Dr. Öğr. Üyesi Mehmet KÖSE'ye,

Ortopedik tümör cerrahisinin bölümümüzdeki temsilcisi olarak bu konuda bilgilerime çok katkısı olmuş Sn. Dr. Öğr. Üyesi Kudsi TUNCER'e,

Asistanlık dönemimde de birlikte çalıştığım ve iş disiplini konusundaki tutumunu takdir ettiğim Sn. Dr. Öğr. Üyesi M. Çağatay ENGİN'e,

Bölümümüze yeni yaklaşımlar katacağını düşündüğüm Sn. Dr. Öğr. Üyesi A. Emre PAKSOY'a,

Hem asistanlık süresince birlikte çalışırken hem de tez yazım aşamasında bilgi ve deneyimlerini bana aktarmasından büyük keyif aldığım değerli abim Uzm. Dr. Kemal ZENCİRLİ'ye

Birlikte bu yola çıktığım değerli mesai arkadaşlarım; Dr. M. Ali DURSUN, Dr. Recep TAŞKIN, Dr. Gürkan İDEN ve diğer asistan arkadaşlarımla birlikte yardımcı sağlık personeline,

Asistanlık dönemimin yükünü benimle paylaşan hayat arkadaşım, kader ortağım ve kızım Bilge Gökçe'nin annesi değerli eşim Naime SEYHAN KAYA'ya teşekkür ederim.

Dr. Salih KAYA

Erzurum, 2020

ÖZET

Proksimal Junctional Kifoz Gelişim Nedenlerinin Makine Öğrenmesi Yöntemiyle Tespiti

Amaç: Omurga deformitesi nedeniyle operasyon yapılan hastaların ameliyat sonrası dönemde proksimal junctional kifoz (PJK) gelişimine etki eden parametreleri makine öğrenmesi (MÖ) yöntemleriyle tespit etmek.

Gereç ve Yöntemler: 2015-2019 yılları arasında kliniğimizde omurga deformitesi nedeniyle posterior enstrümantasyon ve füzyon uygulanmış 167 hastanın kayıtları tarandı. Çalışma kriterlerine uyan 67 hasta incelendi. Hastaların; yaş, cinsiyet, kan grubu, vücut kitle endeksi, sigara kullanımı, aile öyküsü, ek hastalık durumu, aylık gelir miktarı, takip süresi, operasyon öncesi ve sonrası torakal kifoz (TK), lomber lordoz (LL), sagital vertikal aks (SVA) değerleri, füzyon seviyesi, alt ve üst enstrüman seviyeleri, rod kalınlığı, pelvik insidans (Pİ) değerleri, global sagital dizilim (GSD) değerleri, Ponte osteotomisi ve posterior vertebral kolon rezeksiyonu (PVKR) yapılan hastalar kaydedildi. Operasyon öncesi, erken operasyon sonrası ve son takiplerdeki proksimal junctional açıları (PJA) ölçülerek PJK olanlar belirlendi. Daha sonra bu veriler değerlendirilerek MÖ yöntemleri olan naive bayes (NB), destek vektör makineleri (DVM), karar ağacı (KA) ve yapay sinir ağı (YSA) modelleriyle kifoz gelişimi için en ilişkili parametreler belirlendi.

Veri seti Weka 3.8.4 programıyla çalışıldı. MÖ algoritmalarını karşılaştırmak için, doğruluk, F-measure, ROC (Receiver Operating Characteristic) ve MAE (Mean Absolute Error) oranları değerlendirildi. MÖ yöntemlerinden doğruluğu en yüksek KA J48 modeli oldu.

Sonuç: MÖ algoritmalarının PJK gelişimi üzerinde en çok ilişkili bulduğu parametre ameliyat sonrası erken dönemde ölçülen PJA oldu. PJK gelişimi üzerinde etkili diğer parametreler SVA farkı ve TK Cobb açı farkı oldu. PJK gelişimine ters yönde etki eden parametre, pelvik tilt (PT) idi.

Erken takiplerde PJA göz önünde bulundurularak PJK gelişimi açısından bir fikir elde edilebilir. PJK gelişimini engellemek için aşırı düzeltmelerden kaçınılmalıdır. Antevert pelvislerin PJK için koruyucu olduğu bilinmelidir ve ameliyat öncesi planlamada spinopelvik parametrelere (SP) dikkat edilmelidir.

Anahtar Kelimeler: Proksimal Junctional Kifoz, Skolyoz, Kifoz, Yapay Zeka, Makine Öğrenmesi

ABSTRACT

Determining Reasons of Proximal Junctional Kyphosis by Using Machine Learning Algorithms

Aim: To determine the reasons of proximal junctional kyphosis (PJK) by using machine learning (ML) for operated kyphosis deformity patients.

Material and Methods: Between 2015 and 2019, we looked 167 patient records performed posterior instrumentation and fusion for spinal deformity in our center. 67 patients who met the study criteria were examined. Age, gender, blood group, body mass index, smoke, family history, comorbidity, monthly income, follow time, preoperative and postoperative thoracal kyphosis (TK), lumbar lordosis (LL), sagittal vertical axis (SVA) values, fusion levels, lower and upper instrumented levels, rod diameters, pelvic incidens (PI), global spinal alignment (GSA) values, patients who underwent Ponte osteotomy and posterior vertebral column resection (PVCR) were recorded. We recorded proximal junctional angles (PJA) for preoperative, early postoperative and last follows. After we determined PJK patients and found the most related parameters for PJK by using naive bayes (NB), support vector machines (SVM), desicion trees (DT) and artificial neural networks (ANN) as machine learning algorihtms.

We used Weka 3.8.4 program for our data set. We looked accuracy, F-measure, ROC (Receiver Operating Characteristic) and MAE (Mean Absolte Error) rates for compare ML algortihms. Among the ML methods, DT J48 model was the most accurate.

Conclusions: The most relevant parameter for the development of PJK by the ML algorithms was the PJA measured in the early postoperative period. Other parameters affecting the development of PJK were SVA difference and TK Cobb angle difference. The parameter that adversely affected the development of PJK was pelvic tilt.

An idea can be obtained in terms of the development of PJK by considering PJA in early follow-up. Excessive corrections should be avoided to prevent the development of PJK. We think that the anteverted pelvis is protective for the PJK and attention should be paid to spinopelvic parameters in preoperative planning.

Keywords: Proximal Junctional Kyphosis, Scoliosis, Kyphosis, Artificial Intelligence, Machine Learning

1.GİRİŞ VE AMAÇ

Spinal deformiteler her yaş grubunda görülebilen, hastaların genel sağlığı üzerinde zayıflatıcı etkisi bulunan bir hastalık grubudur. Adölesan idiyopatik skolyoz ve Scheuermann kifozu genç erişkinleri etkileyen spinal deformitelerdendir. Erişkin dönemde görülen spinal deformitelerin en sık sebepleri ise iyatrojenik düz bel sendromu ve dejeneratif skolyozdur[1].

Spinal deformitelerin tedavisi çoğunlukla cerrahi yöntemlerle yapılmaktadır. Ameliyat esnasında ve sonrasında görülebilecek komplikasyonların yönetimi sağlık sistemleri üzerindeki iş yükünü kontrol edebilmek açısından önemlidir.

Küresel olarak, sağlık sistemleri artan hastalık yükü, çok sayıda ek hastalık, özürlülük, yaşlanma, sağlık hizmetlerine daha fazla talep, daha yüksek toplumsal beklentiler ve artan sağlık harcamaları gibi birçok zorlukla karşı karşıyadır. Bir başka zorluk ise sağlık sistemlerindeki verimsizliktir[2, 3].

Sağlık sistemlerinin temel dönüşümü, bu zorlukların üstesinden gelmek için 2030 yılına kadar evrensel sağlık dönüşümünü (Universal Health Coverage) başarmak durumundadır. Makine öğrenimi (MÖ), yapay zekanın (YZ) en somut halidir ve dijital teknolojideki en yeni büyüme alanıdır. Bu yeni teknoloji daha fazlasını başaracak potansiyele sahip olup ayrıca bu tür bir dönüşüm için katalizör olabilir[4].

YZ; minimum insan müdahalesiyle zeki davranışlar gösteren bilgisayar programlarının genel adıdır. Felsefe, matematik ve bilgisayar bilimini temel alan, zekanın özelliklerini taklit eden sistemler geliştirmeyi amaçlayan geniş bir alandır.

YZ tipik olarak insan zekası ile ilişkili görevler gerçekleştirmek için bilgisayar algoritmalarının geliştirilmesini içerir[5]. YZ'nin tıptaki genel amacı, verilerden ilgili bilgileri ortaya çıkarmak için bilgisayar algoritmalarını kullanmak ve klinik karar vermede yardımcı olmaktır[6]. YZ teknolojilerinin sağlık alanında; tanı koymada yardımcı olmak, tedavi seçimini belirlemek, risk tahminleri yapmak, hastalığı sınıflandırmak, tıbbi hataları azaltmak ve verimliliği arttırmak gibi amaçları vardır[7]. Bunu yaparken hekimlerin iş yükünü hafifletecek olup hükümetlerin sağlık

harcamalarını ve kaynaklarını doğru kanallara aktarmasına yardımcı olacaktır. Her ne kadar YZ gelişimi klinisyene olan ihtiyacı azaltacak gibi düşünülse de klinisyen-YZ birlikteliği daha verimili sonuçlar vermektedir[8]. YZ'nin MÖ ve derin öğrenme (DÖ) gibi alt dalları vardır.

MÖ, YZ'nin alt grubu olup temelde istatistik algoritmalar oluşturan bilgisayar programları aracılığıyla veriler arasında bağlantı kurup tahminlerde bulunur. Geniş veri setleri kullanan bu programlar tıp alanında kullanılmaya elverişlidir.

DÖ, gözlemcili veya gözlemcisiz olarak geniş ham bilgi kaynaklarını kullanarak ihtiyaca uygun tespit ve sınıflamalar oluşturabilir[9].

Bugün birçok alanda kullanım imkanı olan YZ ve MÖ, sağlık bilimlerinde uygulanabilirlik ve verim açısından oldukça başarılı olabilmektedir[10]. MÖ yöntemleri kullanılarak, önleyici sağlık hizmetlerinden tedavi edici tıbba, geniş bir veri ağını kontrol edip yorumlamalar yaparak amaç odaklı sağlık politikaları geliştirilebilir. Bu yenilikler hükümetlerin sağlık hizmetlerindeki kaynaklarının doğru kullanımına yardımcı olacaktır.

YZ ve MÖ yöntemleri hayatın her alanında olduğu gibi sağlık alanında da giderek ilgi toplamaktadır. Endüstri 5.0; insan müdahalesinin olmadığı, YZ sistemlerinin kontrolü ele aldığı, tamamen kişiselleştirilmiş ürünlere dikkat çekiyor. Tıp alanında önemli etkileri olacak bu değişimin kişiselleştirilmiş ürünler düşünülünce Ortopedi ve Travmatoloji alanında etkileri oldukça önemli olacaktır[11].

Geniş bir hasta popülasyonu ve gider bütçesi olan Ortopedi ve Travmatoloji uygulamaları açısından MÖ yöntemleri popülerliğini her geçen gün artırmaktadır. İskelet sistemi radyografilerinin doğru yorumlanması, cerrahi eğitimin hastaya zarar vermeden daha etkin gerçekleştirilebilmesi, doğru tedavi ve doktor-hasta işbirliği, robot yardımlı ortopedik cerrahinin daha iyi uygulanabilmesi, hastanede yatış süresinin ve takiplerin azaltılması ve problem çözmenin hızlanması açısından YZ uygulamaları ortopedi alanında işleri oldukça kolaylaştırabiliyor.[12, 13].

Spinal cerrahilerden sonra gelişen önemli komplikasyonlardan biri proksimal junctional kifozdur (PJK). Yaklaşık %20 ile %40 oranında görülen bu komplikasyon nedeniyle hasta memnuniyeti azalmakta ve bazen reviyon cerrahiler gerekmektedir.

Bu nedenle tezimizde spinal cerrahilerden sonra bir komplikasyon olarak görülen PJK'nin nedenlerini MÖ yöntemlerini kullanarak tespit etmeye çalıştık[14].

Terimlerin literatürde kullanılan İngilizce karşılıklarını yanlarında belirttik. Bazı terimlerin kısaltmalarını literatürde sıklıkla kullanılan şekliyle İngilizce olarak kullandık. Şekillerin çizimi bize aittir.

2.GENEL BİLGİLER

2.1. Yapay Zeka (Artificel Intelligence)

YZ modern bilim kurgunun bir ürünü olarak algılansa da yüzyıla yakın bir geçmişi vardır. Bu terim ilk olarak 1955'te John McCarthy isimli Amerikalı bilgisayar ve bilişsel bilimci tarafından Darmouth Kolej Konferası'nda kullanılmıştır[15]. YZ'yi "Zeki makineler yapma bilim ve mühendisliği" olarak tanımlamıştır. Takip eden yıllarda bilgisayarlar oldukça karmaşık matematik problemleri çözmeye başlamıştır. YZ sonraları gözden düşse de 80'lerde veri madenciliği ve tıbbi araştırmalarla yeniden yıldızı parlamıştır.

YZ popüler kültürün önemli bir parçası olmakla birlikte özellikle büyük veri akışlarının kontrolü ve amaç odaklı kullanımı açısından günlük pratikte sıklıkla kullanılıp her geçen gün gelişmektedir. Düşünen hatta insanlığı yok eden robotlar şimdilik bilim kurgu filmlerinin fantastik öğeleri olmakla birlikte yüz tanıma, dil tanıma, oyunlar için YZ, ses yardım asistanları ve sürücüsüz otomobiller gibi birçok teknolojik öğeyle günlük yaşantımızda yer edinmiştir.

YZ ve özellikle alt tipi olan DÖ algoritmalarının faydaları, tüm sektörlerde belirgin şekilde geliştirilmiş bilgi işlem gücü ve bulut depolama ile etiketlenmiş büyük verilerin kullanımı ile sağlanabilmiştir[16]. Tıp alanında YZ uygulamaları; klinisyenlerin, ağırlıklı olarak doğru görüntü yorumlaması yoluyla karar verme süreçlerindeki hızını artırıyor, sağlık sistemlerinde iş gücünün doğru kullanılmasını teşvik ediyor, tıbbi hataları azaltıyor ve hastalar için kendi verilerini işleyerek sağlıklarını iyileştiriyor.

YZ uygulamaları tıbbın bütün alanlarında kullanılabilecek bir potansiyele sahiptir[17]. Uzmanlık alanlarından hemen her çeşit klinisyen ve yardımcı sağlık personeli YZ ve özellikle alt dalı olan DÖ teknolojisini gelecekte kullanacaktır. Bu sayede medikal görüntüler, patoloji slaytları, retinal görüntüler, cilt lezyonları, elektrokardiyogramlar ve vital bulgular değerlendirilebilecektir.

Tıbbi araştırmaları düşünecek olursak, geniş hasta popülasyonları ve bunlara ait devasa biyomedikal verilerin tespit, sınıflama ve yorumlanmasında bir karmaşıklık söz

konusudur. Klasik istatistik programlarıyla yorumlanması zor olan verilerin hekimler tarafından kolay bir şekilde sınıflanması, hastalık teşhis ve tedavisinde hızlı davranılması için YZ yöntemlerinin tıbbi araştırmalarda kullanılması adeta bir zorunluluk haline gelmiştir[6].

2.2. Tarihçe

YZ ve robot neredeyse aynı terimler gibi düşünülmektedir. Robot, Çek dilinde "Robota" kelimesinden köken alır. Karel Capek'in 1921 tarihli oyunu "R.U.R" dan (Rostrum's Universal Robots) esinlenilerek literatüre kazandırılmıştır.

Oysaki ismi YZ olmasa da insansı eşyalar yapma merakı bir hayli eskiye dayanmaktadır. İlk insansı otomatlar üçüncü yüzyılda Çin'de mühendis Yan Shi tarafından imparator Mu of Zhou'ya taktim edilmiştir[18]. Bu makineler insansı görünümlü olup deri, ahşap ve yapay organlar içermektedir.

Onikinci yüzyıl Müslüman bilgin ve mucit El Cezeri, otomatik zil çalabilen makineler üretmiştir.

Onüçüncü yüzyıl filozofu Ramon Llull kavram kombinasyonlarından bahsetmiş mantıksal çıkarımlar yaparak YZ'nin kavramsallaştırılmasını öngörmüştür.

Rönesans döneminde Leonardo Da Vinci, insan anatomisi üzerine önemli çalışmalar yapmış ve insansı makineler tasarlamıştır. Da Vinci'nin ünlü eskiz kitabı 1950'lerde keşfedilmiş olup içerisinde oturup kalkabilen, kafasını ve çenesini hareket ettirebilen ve kollarını sallayabilen, pulley ve kablo sistemleriyle çalışan şövalye tasarımları içermektedir. Bu çizimler daha sonraları robot mühendisliği için Amerikan Ulusal Havacılık ve Uzay Dairesi (NASA) tarafından ilham kaynağı olarak kullanılmıştır.

Yine 18. yüzyılda da Fransız mucit Jacques de Vaucanson tarafından repertuvarında 12 beste bulunan, flüt çalan otomat icat edilmiştir.

1948'de William Gray Water ünlü buluşu "Machine Speculatrix" ile ilk elektronik otonom robotu icat etmiştir. Bunu yapmasındaki amacı beyin fonksiyonlarının nasıl işlediğini anlayabilmekti. Çok küçük sinir hücre topluluklarının dahi çok karmaşık davranışlar üretebileceğini keşfetti.

İkinci dünya savaşının ünlü enigma çözücüsü ve bilgisayar biliminin kurucularından kabul edilen Alan Turing "Makine düşünebilir mi?" diye sorarak modern anlamda bu ilginç alanın önünü açmıştır[19].

1955'de YZ terimi ilk olarak John McCharty tarafından kullanılmıştır. John McCarthy bilgisayar bilimine katkılarından dolayı 1971'de Turing ödülüne layık görülmüştür. Daha sonraları YZ konusu gözden düşse de 80'li yıllarda popülerliğini yeniden kazanmıştır. Çok hızlı bir gelişme kaydeden bilgisayar ve programlama bilimlerine paralel olarak baş döndüren serüvenine kaldığı yerden daha da hızlı olarak devam etmiştir. Öyle ki 1997 mayısında dünya satranç şampiyonu Gary Gasparov Google şirketi tarafından yazılan "Big Blue" programı tarafından yenilmiştir[20].

Bugünlerde YZ karmaşık problemleri çözmesi için kullanılan bir mühendislik ve bilgisayar dalıdır. Bilgisayar, programlama ve elektronikteki gelişmeler neticesinde belki bir gün insandan daha zeki programlar ve zeki insansı otomatlar üretilebilecektir.

2.3. Günümüzde Yapay Zeka

Google şirketinin "Deep Mind" projesinin "Deep Q-learning" yazılımı, atari oyunlarında müdahalesiz bir şekilde başarıyla kendi başına iyi skorlar elde etmiştir[21]. Örneğin daha önce tenisin ve top oyunlarının ne olduğunu bilmediği halde eğitim ve hatalar sonucunda yeteneklerini maksimum seviyeye çıkarıp tenis oyununda gerçek oyunculara karşı iyi skorlar elde etmeyi başarmıştır.

Google "Alpha Go" yazılımı 2016 mayısında go gibi çok karmaşık bir oyunda yetenekli Koreli go oyuncusunu alt etmeyi başararak herkesi şok etmiştir[22].

Google "Beyin", You Tube videolarından elde ettiği 10 milyon görüntü içinden kedi içerenleri ayırt ederek gelecek çalışmalar için ortamı hazırlamıştır. Takip eden çalışmalarda, beş yıl içerisinde DÖ tabanlı görüntü tanımlayıcıların insan doğruluğunu aşacak bir seviyeye ulaşması bekleniyor [23, 24].

DÖ'nün sağlık alanındaki kullanımı ilgi çekici olabilmektedir. Örneğin, Amerika Birleşik Devletleri merkezli "Food and Drug Administration" (FDA) ilaç şirketlerine ilaç toksisitelerini on yıllar süren hayvan çalışmaları olmaksızın beliryebileceği YZ uygulamalarına onay veriyor[25]. Hatta teşvik ediyor. Bu konuda ilaç toksisiteleri

açısından yapılan klinik öncesi hayvan deneylerinin YZ kullanılarak pas geçilebileceği konusunda umut vaat eden çalışmalar var[26].

Kanser tanılarında önemli olan patoloji örneklerinin incelenmesi amacıyla dijitalleştirilmiş patoloji örneklerini çalışan ticari YZ programları hızla artıyor. Benzer algoritmaları kullanan başka bir program radyolojik görüntüleri büyük bir doğrulukla yorumluyor[27, 28].

2.4. Sağlık Uygulamalarında Yapay Zeka

YZ teknolojileri kullanılarak sağlık alanında tanı konulmasına yardımcı olmak, tedavi seçimi yapmak, risk tahminleri yapmak, hastalığı sınıflamak, tıbbi hataları azaltmak ve verimliliği arttırmak gibi birçok işlevi yapmak mümkün olmaktadır[7, 16].

Sağlık verileri çok değişik kaynaklardan elde edilen veriler olup; toplanması, kaydedilmesi ve tekrar kullanılabilmesi gibi konularda sıkıntılar oluşabilmektedir. Kişisel sağlık verileri; demografik bilgileri, sağlık hizmetlerini sunan kişilerin notlarını, görüntüleri, laboratuvar sonuçlarını, genetik test verilerini ve tıbbi cihazlardan veya giyilebilir sensörlerden (Holter vs.) kayıtları içerebilir. Ancak bu kaynakların standartlaşması konusundaki sorunlar küresel ölçekte verilerin kullanılabilirliği üzerinde olumsuz etkiler oluşturmaktadır. İnternet ve teknolojik platformların gelişmesiyle birlikte bulut tabanlı sistem kapasitelerinin artışı, verilere ulaşım ve dağıtım açısından kolaylıklar oluşturmaktadır.

Sağlık alanında YZ uygulamaları açısından en uygun kullanım triaj ve görüntüleme araçları olabilir. Örneğin YZ, yoğun hasta sirkülasyonu olan acil servis bölümlerine başvuran hastaların radyolojik görüntülerini değerlendirerek hangilerinin bir uzman radyolog tarafından ileri inceleme yapılması gerektiğine karar verebilir[27]. Bu gibi örnekler iş gücü yükünü azaltıp kaynakların daha doğru kullanılmasına yardım edecektir.

2.5. Makine Öğrenmesi (Machine Learning)

Makine öğrenmesi (MÖ), YZ'nin bir alt disiplinidir. Bilgisayar programlarının önceki örnekler üzerinden bağlantı kurup tahminlerde bulunması esastır. MÖ basitçe istatistiksel modellerin bilgisayarları kullanarak verilere uygulanmasıdır. Makine

öğrenimi, tıpta tipik olarak kullanılanlardan daha geniş istatistiksel veri setlerini kullanır. DÖ gibi daha yeni teknikler temel veriler hakkında daha az varsayımı olan modellere dayanır ve bu nedenle daha karmaşık verileri işleyebilir.

2.5.1. Denetimli Öğrenme (Supervised Learning)

İnsan tarafından eğitilen bilgisayar programları girdi ve çıktılar arasındaki ilişkileri öğrenir. Öğrenme bir kez gerçekleşince veriler gelecekteki örnekleri tahmin etmek için kullanılabilir. Bu yöntem sağlık hizmetlerinde ve diğer alanlarda kullanılan en etkili ve köklü yöntemdir.

2.5.2. Denetimsiz Öğrenme (Unsupervised Learning)

Veriler üzerinde bilgisi olan dış bir kaynağın müdahalesi olmadan verilerdeki ilişkilendirmeleri öğrenen bilgisayar programlarıdır.

2.5.3. Destekli Öğrenme (Reinforcement Learning)

Önceden belirlenen bir ödülü en üst düzeye çıkarma yeteneklerine dayanarak eylemleri öğrenen bilgisayar programlarıdır. Bu yaklaşım davranış psikolojisinden etkilenmiş ve mükemmel bilgi gerektiren, birçok olası seçenek bulunan ve gerçek dünyada olmadığı için maliyeti olmayan oyun programlarında önemli bir başarı ile uygulanmıştır.

2.6. Derin Öğrenme (Deep Learning)

DÖ yöntemleri, bir makinenin büyük miktarlarda ham veri ile beslenmesine ve algılama veya sınıflandırma için gerekli cevapları keşfetmesine izin verir. DÖ yöntemleri verilerin ayrımı için önemli olan yönlerini güçlendiren çoklu katmanlara dayanır. Bu sayede alakasız yolaklar baskılanırken en mantıklı yolaklar desteklenir. DÖ denetimli veya denetimsiz olarak iki gruba ayrılır. DÖ yöntemleri, MÖ'deki son temel ilerlemelerin çoğundan sorumludur[29].

DÖ sistemleri yüksek kaliteli dijital verilerinin bol olduğu ve tahmin görevlerini otomatikleştirmenin çok faydalı olduğu ekonomik sahalarda yoğun bir şekilde uygulanmıştır[29].

2.7. Makine Öğrenme Yöntemleri

Denetimli öğrenme yöntemleri; Sınıflandırma (classification), regresyon (regression), kümeleme (clustering) ve ilişkilendirme (assosiation) olmak üzere 4 başlık altında incelenebilir.

2.7.1. Sınıflandırma

Sağlık alanında kullanımı sıktır. Verileri belirlenen hedefe göre ayırır. Örneğin sagital Cobb açılarına göre hastaları "kifoz" ya da "kifoz değil" diye ayırabilir. Sınıflandırma için lojistik regresyon (logistic regression), destek vektör makinesi (DVM), naive bayes (NB), karar ağacı (KA) ve yapay sinir ağları (YSA) kullanılır.

2.7.2. Regresyon

İki ya da daha fazla değişken arasındaki ilişkiyi belirlemek amacıyla uygulanan araştırma yöntemidir. Lineer (doğrusal) ve non-lineer (doğrusal olmayan) olarak iki gruba ayrılır. Regresyon modellerinde yapılan tahminlerin doğruluğunu tespit etmek için "Mean Absolute Error" (MAE) ve hataların karesinin alınıp toplam değerin 0 çıkmasını engelleyen "Root Mean Squared Error" (RMSE) yöntemleri kullanılır.

2.7.3. Lineer Regresyon (Linear Regression)

Regresyon Fransızca kökenli bir kelime olup gerileme anlamındadır. Veri setlerinde yapılan şey de tam olarak budur. Gerçek hayatta çok farklı özellikleri olan verilerin "y = a x + b" formülüyle bilinen basit bir doğruya indirgenmesi işlemidir. Görece basitliği ve iyi bilinen özelliklerinden dolayı sınıflama ve tahmin amacıyla sıklıkla kullanılır (Şekil 1).



Şekil 1. Lineer regresyon modeli

En temel regresyon modeli olan lineer regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi sınıflayıp tahmin eder. Örneğin kifoz deformitesi nedeniyle opere edilecek hastaların füzyon seviyelerini belirlemek için hastaların kifoz açısının ve tepe vertebrasının tahmini füzyon seviyesi kararına etkisini modelleyebilir.

2.7.4. Naive Bayes (Naive Bayesian)

NB istatistiksel bir sınıflama sistemidir. Olasılık hesaplamaları kullanan Bayes teoremine dayanır. Bu teorem belirli bir B durumu için var olan A durumuna kıyasen P olasılığını hesaplar. Basitçe "Mevcut bir B durumu için, B durumunun A durumundan kaynaklanma olasılığı nedir?" sorusu olarak düşünülebilir.

P (A/B)=P(B/A) X P(A) / P(B) şeklinde formüle edilir.

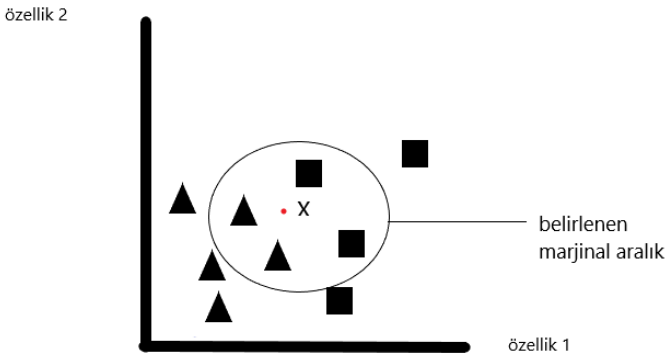
Şekil 2'de modellendiği gibi üçgenler ve kareler olarak 2 grubumuz olsun. Bunları temsil eden "Özellik 1" (x) ve "Özellik 2" (y) eksenlerimiz üzerinde belirlenen parametrelerimiz olsun. Oluşturduğumuz bu grafikte rastgele bir "X" noktası belirleyelim. Daha sonra bu noktanın etrafında bir sınır belirleyelim ve seçtiğimiz "X" noktasının bu sınırlar içerisinde üçgen gelme olasılığını hesaplayalım.

$$P(\text{ÜÇGEN}/X) = \frac{P(X/\text{ÜÇGEN}) \times P(\text{ÜÇGEN})}{P(X)}$$

$$= \frac{2/5 \times 5/9}{4/9}$$

$$= 1/2\ (\%50)$$

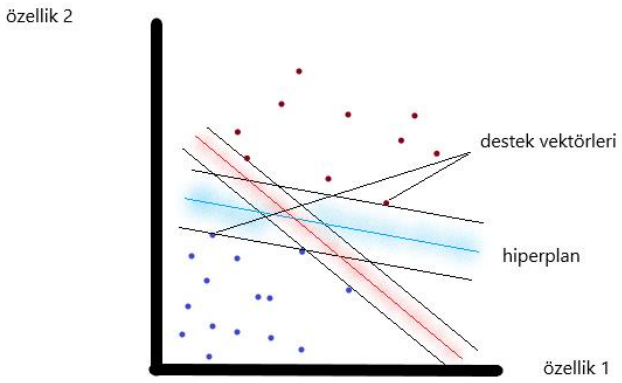
Belirlenen sınırlar içerisinde "X" noktasının üçgen olma olasılığı %50'dir.



Şekil 2. Naive bayes modeli ve örnek çözüm

2.7.5. Destek Vektör Makineleri (Support Vector Machine)

DVM temel olarak iki gruba ait verileri birbirinden en uygun şekilde ayırmak için kullanılır. Ancak grupları ayıran sonsuz sayıda düzlem olabilir. İki grup arasında en büyük alanı yakalayan düzlemler (destek vektörleri) seçilir ve hiper düzlem belirlenir (Şekil 3).



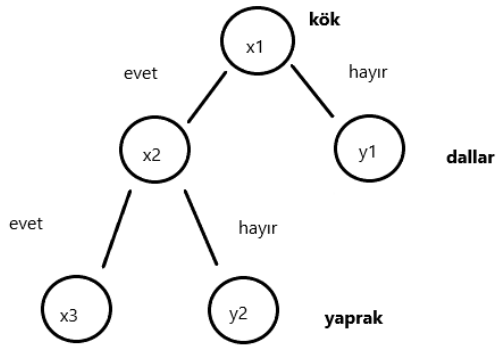
Şekil 3. Destek vektör makineleri modeli

Şekil 3'deki DVM şemasında daha dar olan kırmızı aralık iyi bir gruplama sağlamaz. Bunun için en geniş aralık olan mavi hiper planı seçilir.

2.7.6. Karar Ağacı (Desicion Tree)

KA kökü tepede olan ters bir ağaç gibi düşünülebilir. En tepede olan değişken karar basamaklarında ağırlığı en fazla olan değişkendir. Bütün basamaklar doğal bir

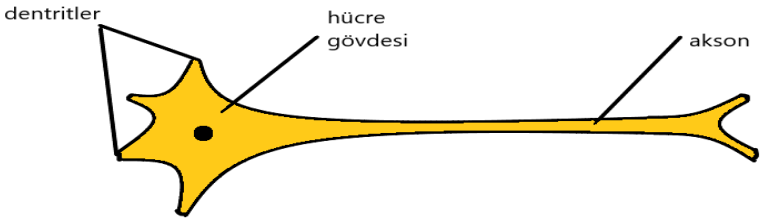
ağaç dallanması oluşturacak şekilde en kısa ağacı modellemek üzere belirlenir. Ağaç, kökten itibaren bir gövdeden iki ya da daha fazla dallara ayrılır. Bu durum daha fazla bölünemeyen bir yaprak (düğüm) elde edilene kadar devam eder (Şekil 4). Tıbbi tanı ve tedavi algoritmalarında görselleştirilmiş olarak sıklıkla kullanılır.



Şekil 4. Karar ağacı modellemesi

2.7.7. Yapay Sinir Ağları (Artificiel Neural Networks)

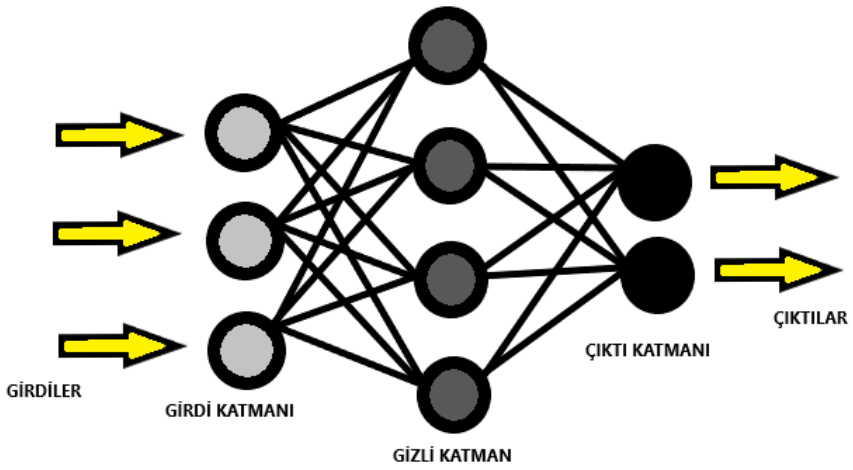
YSA en yaygın kullanılan makine öğrenme algoritmalarından biridir. Biyolojik sinir hücrelerinin bilgisayar programlarıyla taklit edilmesidir. Biyolojik sinir hücreleri olan nöronlar reseptörlerden veya diğer sinir hücrelerinden gelen sinyalleri alan dentritlerden, sinyali değerlendirip iletimine karar veren hücre gövdesinden ve diğer hücrelere bu sinyali aktaran aksonlardan oluşurlar (Şekil 5).



Şekil 5. Biyolojik sinir hücresi anatomisi

Nöronlar bilgi aktarım sürecinde “Ya hep ya hiç” prensibiyle çalışırlar. Yani alınan sinyal ya sönümlenir ya da diğer hücrelere aktarılır. Bu, sinyalin eşik değeri (treshold) aşıp aşmaması nedeniyledir.

Perceptronlar en temel, tek katmanlı YSA modelleridir. Araya gizli katmanlar (hidden layer) eklenince çok katmanlı (multilayer) YSA elde edilir (Şekil 6). Bu ağlar sinir katmanlarından oluşmaktadır. Girdi, çıktı ve değişen sayıda gizli katmanları bulunan bu yapıda her nöron arasında bağlantılar bulunuyor. Her bağlantının sayısal bir ağırlığı olan bu yapıda, yazılım bağlantı ağırlıklarını değiştirerek doğru sonuca ulaşıyor.



Şekil 6. Çok katmanlı ileri beslemeli yapay sinir ağı

YSA’lar doğası gereği tıptaki en ünlü YZ uygulamalarıdır[30]. YSA biyolojik sinir ağlarından ilham alınarak tasarlanmıştır. Önceki veriler üzerinden öğrenme becerisi, doğrusal olmayan verileri analiz edebilme yeteneği, kesin olmayan bilgilerin üstesinden gelebilme gibi özellikleri nedeniyle YSA tıbbi uygulamalarda popülerleşmiştir.

McCullogh ve Pitts 1943’de YSA’ları keşfettiler[31]. Daha sonraları psikolog olan Frank Rosenblatt, 1958’de perceptronu geliştirdi[32]. Birçok perceptron çeşidi

tanıtılmasına rağmen en ünlüsü “İleri beslemeli çok katmanlı perceptron” (Forward feedback multilayer perceptron) du.

1976’da YZ teknolojisi cerrahi alanda başarılı bir şekilde ilk kez Gunn tarafından kullanıldı. Gunn, bilgisayar analizleri kullanarak akut batın vakalarını tespit etmeye çalıştı[33]. Bir başka YSA algoritması karın ağrısıyla başvuran hastalarda apandisit tanısında kullanıldı[34].

PAPNET servikal kanser taramasında kullanılan ticari bir YSA algoritmasıdır. Sitolojik ve histolojik spesimenlerin diagnozunda sitologlara yardım etmektedir[35].

Baxt, klinikte YSA'ların potansiyelini kullanan ilk araştırmacılardan biriydi. Akut miyokard enfarktüsünü doğru teşhis eden bir YSA algoritması geliştirdi[36, 37].

YSA klinik tanı, radyolojik görüntüleme, histopatolojik analiz ve yoğun bakımda veri yorumlanmasında kullanılıyor. Stamey ve ark. prostat kanserinde benign-malign ayrımı yapan YSA yapısındaki bir algoritma olan “Prost Asure Index” i geliştirdiler[38]. Geliştirdikleri model %90 diyagnoztik doğruluk, %81 duyarlılık ve %92 özgüllüğe sahipti.

Radyolojik görüntülerin yorumlanması konusunda da YZ oldukça iyidir. YSA, akciğer grafileri üzerinden intersitisyel akciğer hastalıklarının ayırıcı tanısını yapabilir[39], kemik yaşı tayini için radyografileri YZ tarayabilir ve uzman bir adli tabip kadar doğru kararlar verebilir[27, 40], kalça kırıklarını, vertebral kompresyon kırıklarını uzman bir radyolog gibi tanıyabilir[41, 42], tedavi edilebilir retinal hastalıkların teşhisi için optik koherens tomografilerini yorumlayabilir[43] ve kardiyak görüntüleri kullanarak damar tıkanıklığını değerlendirebilir[44].

Ortopedi sahasında 256 bin el-el bileği ve ayak bileği filminin YSA algoritmaları kullanılarak bölge tespiti, kırık tanısı ve lateralite sınıflaması yapılan bir çalışmada YSA’nın kıdemli ortopedi uzmanlarıyla benzer sınıflama becerisi gösterdiği ortaya konulmuştur[12].

Yakın zamanlı bir başka çalışmada, şu anda Hindistan'daki hastanelerde kullanılan bir YSA’nın dört farklı akciğer grafisi patogonomik bulgusunun yorumlanması açısından dört uzman radyolog kadar doğru karar verdiği ortaya konulmuştur[45].

Göğüs röntgeni üzerinde kanserli pulmoner nodüller tespiti amaçlı geçmişe dönük yapılan 34.000'den fazla hastanın değerlendirildiği bir çalışmada YSA, 18 radyoloğun 17'sinden daha doğru sonuçlara ulaşmıştır[46].

Acil servis yoğunluğu düşünülünce kırık tanısının atlanması kaçınılmaz olabilmektedir. El bileği kırıklarının tespiti için yapılan başka bir YSA çalışmasında doğru tahmin oranı %90'lara ulaşan algoritmalar bu konuda umut vaat ediyor[40].

Son zamanlarda yapılan bir başka dikkat çekici çalışmada, destekleyici öğrenme yöntemiyle kullanılan bir algoritma sayesinde sepsisli yoğun bakım hastalarında iki intravenöz vazopresör kullanımını önerecek büyük veri setleri kullanılmış ve YZ tarafından seçilen tedavinin insan seçiminden daha etkili olduğu ortaya konulmuştur[47].

2.8. Weka Bilgisayar Programı

Weka (Waikato environment for knowledge analysis) 3.8.4 Yeni Zellanda Waikato Üniversitesi tarafından oluşturulmuş java tabanlı açık kaynak kodu kullanan ücretsiz, MÖ algoritmaları ve YSA modelleri içeren bir bilgisayar programıdır. Weka programında "arff " (attribute relationship file format) dosya yapısı kullanılmaktadır (Tablo 1).

Tablo 1. Veri setimizin niteliklerini gösteren arff dosya yapısı

```
@relation sayfa1

@attribute CINSIYET { E,K }
@attribute TANI { KIFOSKOLYOZ,SCHEUERMANN,KONJENITAL,IDIYOPATIK,POZISYONEL }
@attribute YAS real
@attribute KAN_GRUBU { 0RH+,ARH+,BRH+,ABRH+,ARH-,0RH-,BRH- }
@attribute TAKIP_SURESI real
@attribute ROD_CAP { INCE,KALIN }
@attribute BOY real
@attribute KILO real
@attribute VKI real
@attribute SIGARA { YOK,VAR }
@attribute EK_HASTALIK { YOK,VAR }
@attribute AILE_OYKUSU { YOK,VAR }
@attribute AYLIK_GELIR real
@attribute FOKAL_AGRI { YOK,VAR }
@attribute SRS_22 real
@attribute PREOP_COBB real
@attribute POSTOP_COBB real
@attribute COBB_FARKI real
@attribute PREOP_SVA real
@attribute POSTOP_SVA real
@attribute SVA_FARKI real
@attribute PREO_LL real
@attribute POSTOP_LL real
@attribute LL_FARKI real
@attribute UIV { T2,T3,T1,T11,T4 }
@attribute LIV { L3,L2,L4,ILIAK,T12,L1 }
@attribute FUZYON_SEV real
@attribute PREOP_PJA real
@attribute POSTOP_PJA real
@attribute SON_PJA real
@attribute PT real
@attribute SS real
@attribute PI real
@attribute GSA real
@attribute KIFEKTOMI { YOK,VAR }
@attribute PONTE { VAR,YOK }
@attribute PJK { YOK,VAR }
```

2.8.1. Weka Sınıflandırma Yöntemlerinin Yorumlanması

Weka programında kullanılan algoritmaların öğrenme ve test etme basamakları vardır. Bunu yapmak için "Cross validation 10 folds" veri setini 10'a bölüp biri üzerinde öğrenim diğer dokuzu üzerinde test eder. "Percentage split %66 ise veri setini üçe bölüp biriyle öğrenirken diğerlerini test eder.

Weka sınıflandırma modelleri kullanılarak bir özet tablosu (summary) görüntülenir. Özet tablosu; konfüzyon matrisi (confusion matrix), doğru sınıflandırılmış örnekler (correctly classified instances) ve sınıflandırma doğruluk detayları (detailed accuracy by class) olmak üzere 3 bölümden oluşur (Tablo 2).

Tablo 2. Weka özet tablosu

```
=== Summary ===

Correctly Classified Instances          20               90.9091 %
Kappa statistic                          0.614
Mean absolute error                      0.1184
Root mean squared error                  0.2386
Relative absolute error                 30.4167 %
Root relative squared error             59.1884 %
Total Number of Instances               22

=== Detailed Accuracy By Class ===

                 TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                 0,947    0,333    0,947      0,947    0,947      0,614    0,947     0,992     YOK
                 0,667    0,053    0,667      0,667    0,667      0,614    0,947     0,833     VAR
Weighted Avg.    0,909    0,295    0,909      0,909    0,909      0,614    0,947     0,970

=== Confusion Matrix ===

  a  b   <-- classified as
 18  1 |  a = YOK
  1  2 |  b = VAR
```

Doğru sınıflandırılmış örnekler; modellemede doğru şekilde sınıflandırılmış örneklerin sayısını ve yüzdesini verir.

Kappa istatistik (kappa statistic); gözlemciler arasındaki uyuşma veya uyuşmamayı tanımlar. Ortopedi polikliniğine başvurmuş 19 hastayı iş göremezlik açısından bağımsız değerlendiren 2 ortopedist olduğunu düşünelim. Her iki ortopedist aynı 10 hastanın iş görür olduğunu ve aynı 2 hastanın iş göremez olduğunu raporlasın. Ortopedist 1, ortopedist 2'nin iş görür raporu verdiği 4 hastaya iş göremez raporu versin. Ortopedist 2, ortopedist 1'in iş görür raporu verdiği 3 hastaya iş göremez raporu versin. Sonuç olarak ortopedist 1, 13 hastaya iş görür 6 hastaya iş göremez raporu vermiş olur. Ortopedist 2 ise 14 hastaya iş görür, 5 hastaya iş göremez raporu vermiş olur. Bu durum için aşağıdaki gibi bir konfüzyon matrisi oluşturalım (Şekil 8).

Tablo 3. Örnek konfüzyon matrisi

		Ortopedist 1		
		İş görür	**İş göremez**	**TOPLAM**
Ortopedist 2	**İş görür**	10	4	14
	İş göremez	3	2	5
	TOPLAM	13	6	19

Gözlemciler arası uzlaşma oranı (GUA); (10+2) / 19 = 0,63 olarak bulunur (kırmızı halka). Uzlaşma şansı (UŞ) ise (13/19 x 14/19) + (6/19 x 5/19) = 0,58 olarak bulunur.

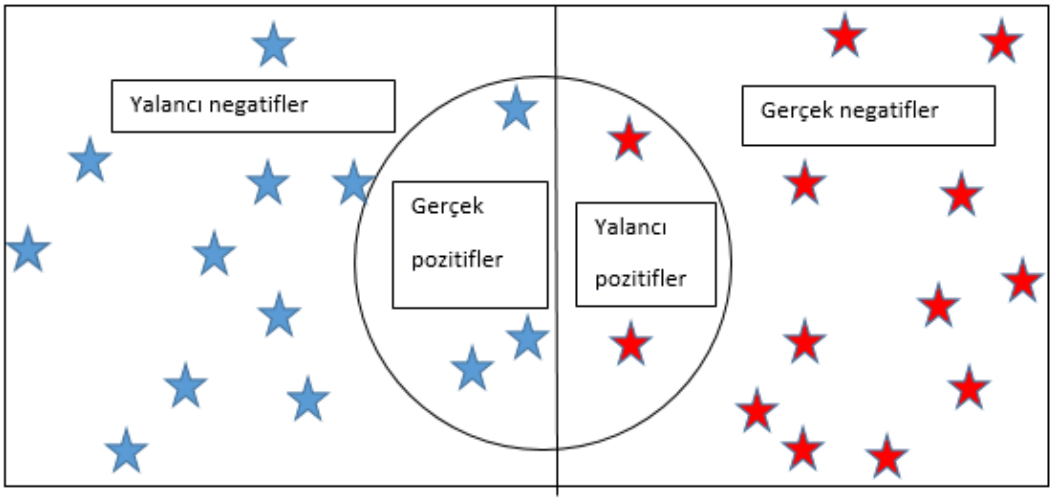
Kohen kappa değeri, (GUA – UŞ) / (1 – UŞ) formülüyle bulunur. Değer 1 olursa tam bir uzlaşma söz konusuyken değer 0 olunca hiç uzlaşma yok olarak yorumlanır. Bizim örneğimizde değerleri yerine koyarsak 0,12 buluruz.

Mean Absolute Error (MAE); tahmin edilen değerler ile gerçek değerlerin arasındaki hata ortalamasıdır. Eksi değerler elde edilmesi durumu söz konusu olup toplamda 0 değeri bulunabilir. Bu modellemenin hatasız olduğunu gösterir ki bu gerçekçi değildir. Bunu önlemek için **Root Mean Squared Error (RMSE)** hesaplanır. Bu yöntemde hataların kareleri alınarak eksi değerlerin oluşması engellenir.

Gerçek Pozitif Oranı (True Pozitive Rate (TP Rate)); gerçek pozitif örneklerin, gerçek pozitif ve yalancı negatif örneklerin toplamına oranıdır. Yani testin duyarlılığıdır (sensitivite).

Yalancı Pozitif Oranı (False Pozitive Rate (FP Rate)); yalancı pozitif örneklerin, yalancı pozitif ve gerçek negatif örneklere oranıdır. Yani testin özgüllüğüdür (spesifite).

Aşağıdaki mavi ve kırmızı yıldızlardan oluşan örneklemdeki halka, mavi yıldızları tahmin eden testi temsil ediyor. Halkanın sol yarısı gerçek mavi yıldızları yani gerçek pozitifleri sağ yarısı kırmızı yıldızları yani yalancı pozitifleri belirtiyor (Şekil 7). Bu örneklemde TP rate 3/(3+10)=0,23 ve FP Rate 2/(2+11)=0,15 olarak bulunur.



Şekil 7. Örneklem

Precision; gerçek pozitiflerin, gerçek pozitif ve yalancı pozitiflerin toplamına oranıdır. testin pozitif prediktif değeridir. Testin gerçek pozitifleri yakalama gücüdür. Şekil 7'de precision değeri 3/(3+2)=0,6 olarak bulunur.

Recall; gerçek pozitiflerin, gerçek pozitif ve yalancı negatiflerin toplamına oranıdır. Gerçek pozitif oranıyla aynıdır, testin duyarlılığını gösterir.

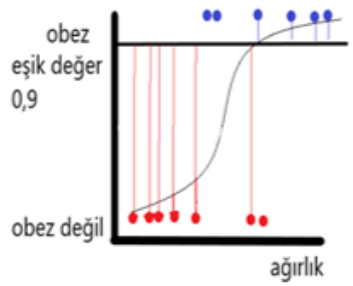
F- Measure (F Ölçüsü); precision ve recall değerlerinin harmonik ortalamasıdır. Makine öğrenme algoritmalarının yorumlanmasında önemlidir.

F-Measure = 2 X Precision X Recall / (Precision + Recall) şeklinde formüle edilir. Şekil 7'deki örneklemin F ölçüsü 2 x 0,6 x 0,23 / (0,6 + 0,23) = 0,32'dir.

ROC (Receiver Operating Characteristic); bir testin doğru pozitif (y ekseni) ve yanlış pozitif (x ekseni) oranlarını belirleyen eşik değerlerini (treshold) grafikler. Örneğin aşağıdaki grafikte ağırlıklarına göre obez ya da obez değil diye sınıflanan deney farelerinin olduğu bir grafiği yorumlayalım. Grafiğe lojistik regresyon eğrisi çizelim ve ilk eşik değerimizi 0,2 yapalım. Gerçek pozitif ve yalancı pozitif oranımızı bulmak için bir konfüzyon matris yapalım (Tablo 4). Daha sonra eşik değerimizi sırasıyla 0,5 ve 0,9 yapalım sonra konfüzyon matrislerini elde edelim (Tablo 5 ve 6). Bu yöntemle elde ettiğimiz doğru pozitif ve yanlış pozitif oranlarını grafikte işaretleyelim. Bu noktaları çoğaltıp birleştirdiğimizde ROC eğrisi elde etmiş oluruz (Şekil 8).

AUC (Area Under Curve); ROC eğrisinin altında kalan alanı ifade eder (Şekil 8).

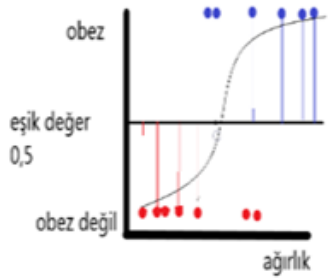
Tablo 4. ROC eğrisinin çizilmesi



1		Gerçekte olan	
		Obez	Obez değil
Tahmin edilen	Obez	4	6
	Obez değil	2	1

Gerçek pozitif oranı = 4/6 = 0.66 ve yalancı pozitif oranı = 6/7 = 0.85

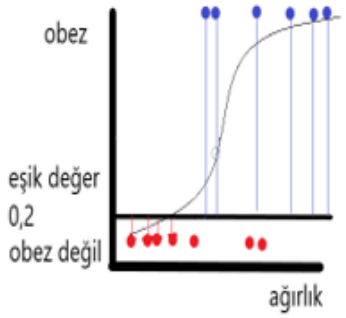
Tablo 5. Tablo 4'ün devamı



2		Gerçekte olan	
		Obez	Obez değil
Tahmin edilen	Obez	4	5
	Obez değil	2	2

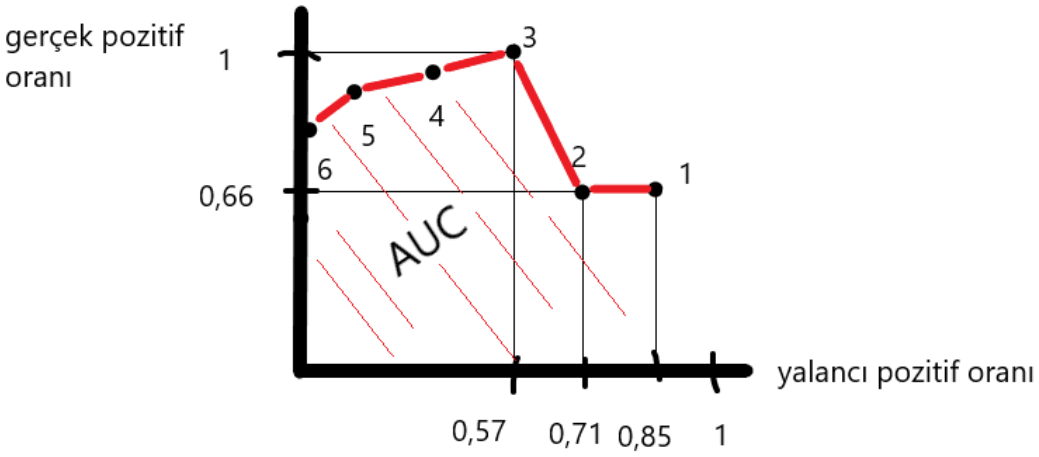
Gerçek pozitif oranı = 4/6 = 0.66 ve yalancı pozitif oranı = 5/7 = 0.71

Tablo 6. Tablo 5'in devamı



3		Gerçekte olan	
		Obez	Obez değil
Tahmin edilen	Obez	6	4
	Obez değil	0	3

Gerçek pozitif oranı = 6/6 = 1 ve yalancı pozitif oranı = 4/7 = 0.57

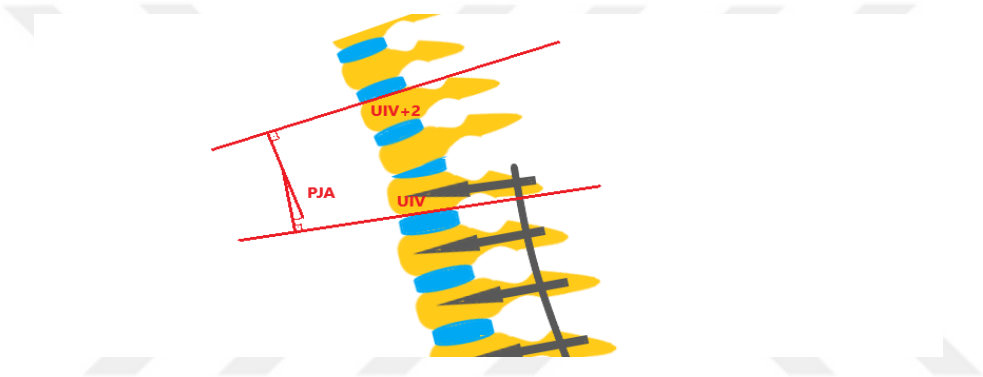


Şekil 8. AUC grafiğinin çizilmesi

2.9. Proksimal Junctional Kifoz (Proximal Junctional Kyphosis)

Proksimal junctional kifoz (PJK) yetişkin omurga deformite cerrahisinden sonra görülen yaygın bir komplikasyondur. Proksimal junctional açısının (PJA) 10 derece veya üzerinde olması ile cerrahi öncesi ölçümlerden en az 10 derecelik artışı olmak üzere iki kriterle tanımlanır.

PJA, en üst enstrümente vertebranın (Upper Instrumented Vertebra (UIV)) alt end platosu ile üstündeki ikinci vertebranın (UIV+2) üst end platosu araındaki açıdır (Şekil 9).



Şekil 9. Proksimal junctional açısı

PJK; cerrahi, radyografik ve hasta ilişkili olmak üzere çoklu risklerden kaynaklanmaktadır. PJK tanılı hastalar, asemptomatik, artan ağrı şikayeti, deformitenin tekrarlanması, fonksiyonel eksiklik ve en ciddi vakalarda nörolojik defisitle başvurabilmektedirler. Hastalığın başvurma şikayetleri çok farklı olduğu için hastalığı doğru tanımlayan yeni sınıflama şemalarına ihtiyaç duyulmaktadır.

2.10. Proksimal Junctional Yetmezliği (Proksimal Junctional Failure)

Proksimal junctional failure (PFJ), PJK'nin en şiddetli formudur. Yazarlar PJF'yi her türlü semptomatik olan ve revizyon cerrahisi gerektiren PJK olarak tanımlamaktadırlar.

Hart, Hostin ve ark. na göre PJF; UIV veya UIV+1 de vertebra kırığı, posterior osseoligamentöz kompleksin bozulması ve UIV seviyesinde enstrümanın çıkması durumlarından herhangi birinin eşlik ettiği PJK olarak tanımlarlar[48, 49].

Revizyon cerrahisinin PJF fenomenini tanımlamada oldukça önemli olduğu eski çalışmalara [50, 51] nazaran son çalışmalar PJK risk faktörlerini uygun bir şekilde tanımlama ve optimal PJK yönetimi üzerine vurgu yapmaktadırlar[48, 49, 52, 53].

PFJ gelişimi özellikle postoperatif erken süreçlerde gözlenen bir fenomendir. Yagi ve ark. nın çalışmasında ortalama 10 ayda revizyon yaptıklarını rapor etmişlerdir[51]. Benzer şekilde Houstin ve ark. PJF tanısının ortalama 3 ayda konulduğunu bildirmişlerdir[49]. Watanabe ve ark. çalışmalarında benzer sonuçlar elde etmişlerdir [54].

Bu çalışmalar ışığında diyebiliriz ki PJK ilerleyici bir seyir izlemektedir ve PJA postoperatif dönemde ciddi bir artış kaydetmektedir. Yine de PJF fenomeninin iyice anlaşılabilmesi için daha çok çalışmaya ihtiyaç duyulmaktadır.

2.11. PJK, PJF Risk Faktörleri

Erişkin vertebra deformitesi oldukça yüksek sıklığı olan yaygın bir bozukluktur. Yaşlı nüfusun artışı nedeniyle bu sıklığın önümüzdeki yıllarda daha da artması beklenmektedir. Omurga deformite cerrahisinde nörolojik olanlar dahil %10'dan %45'e varan çeşitli komplikasyon oranlarından söz edilmektedir[55]. Özellikle yaşlı, düşkün ve ek hastalıkları olanlarda bu komplikasyonlar daha yıkıcı olmaktadır[56]. Omurga cerrahisinin birçok komplikasyonu olmasına rağmen literatürde en önemli ilgi alanları proksimal geçiş bölgesinde gelişen kifoz üzerinedir.

PJK ilk kez Glattes ve ark. tarafından 81 erişkin hastanın retrospektif değerlendirilmesinde tanımlanmıştır[57]. PJK insidansı birçok kaynakta kabaca %20-%40 arasında bildirilmiştir[57, 58].

PJK etiyolojisi cerrahi kaynaklı, radyografik ve hasta ilişkili risk faktörleri olmak üzere multifaktöriyeldir. Cerrahi risk faktörleri genellikle insizyonel yaklaşımla ilgilidir. Örneğin kombine anterior-posterior yaklaşımda posterior dokuların ileri derecede zarar görmesi bir risk olarak karşımıza çıkmaktadır[58-61].

Yapısal sertlik; tüm seviyelerde pedikül vidası kullanımı, uzun füzyon seviyeleri, kalın veya az kontur verilmiş rodlar, sakroiliak fiksasyon ve UIV ve en alt enstrümente vertebra (lower instrumented vertebra (LIV)) seçimi olarak karşımıza çıkıyor [62-64].

Sakroiliak fiksasyon yapısal sertliği artırarak PJK gelişimine neden olabilmektedir[50, 58, 65].

UIV seçimi biyomekanik farklılıklara neden olacağı için PJK gelişiminde önemlidir[57]. Bridwell ve ark. nın yapmış olduğu çalışmada füzyonun görece alt seviyelerde bırakılması artmış PJK sıklığıyla ilişkili bulunmuştur[66].

Deformite düzeltilme oranının fazla olması, artmış PJK gelişimiyle ilişkilendirilmiştir[50-52, 67]. Son çalışmalarda daha büyük sagital vertikal aks (SVA) düzeltmesinin de PJK gelişimine katkıda bulunabileceği belirtilmiştirdir[50, 68, 69].

Benzer şekilde postoperatif artmış lomber lordoz (LL) PJK gelişiminde bir risk faktörü olarak tanımlandı[52, 67].

Preoperatif sagital dizilim bozukluğu olan yüksek SVA ve büyük torasik kifoz (TK) PJK gelişiminde rol oynayan başka risk faktörleridir[49, 52, 69].

Büyük preoperatif TK, düşük sakral slop (SS), yüksek pelvik insidans (Pİ) ve pelvik retroversiyonun da PJK gelişiminde risk faktörü olduğu belirlenmiştir[65, 67, 69].

Ameliyat öncesi proksimal junctional açısı (PJA) 5 derece ve üzerinde olduğunda PJK [70-72] ve PJF [48] gelişim riskinin arttığı gösterilmiştir.

Yaş, cinsiyet, vücut kitle endeksi (VKE), sigara kullanımı, eşlik eden kronik hastalık varlığı ve geçirilmiş vertebra operasyonu gibi hastaya özgü risk faktörleri de belirlenmiştir. İleri yaş artmış revizyon gerekliliğiyle birlikte PJK ve PJF gelişimine neden olduğu gösterilmiştir[57, 66, 68]. VKE'nin PJK veya PJF gelişimi üzerindeki etkisi açık değildir[66]. Yine büyük oranda, UIV seviyesinde görülen kırıklar osteoporozun PJK gelişimi üzerindeki etkisini göstermektedir[63, 67]. Watanabe ve ark. nın yaptığı bir çalışmada osteopeni ve ek hastalık varlığının proksimal vertebral kırık ve çıkıklarda rol oynadığı gösterilmiştir[54].

2.12. PJK'nin Sınıflaması

PJK tanısı asemptomatik hastalardan nörolojik defisiti olan ileri derecedeki hastalara geniş bir spektrumda konulabilir. Bu nedenledir ki PJK tanısını ve spesifik tiplerini tanımlayacak daha iyi girişimlere ihtiyaç duyulmaktadır.

Bugüne kadar PJK üzerine iki ayrı sınıflama tanımlanmıştır. İlki 2012 yılında Yagi ve ark. tarafından önerildi[50]. O zamandan beri spondilolistesizi de içerecek şekilde revize edildi. Sınıflama klinisyene basitçe PJK tipini ve derecesini tanımlayabilmesini sağlamaktadır. PJK tipleri; ligament yetmezliği (Tip 1), kemik yetmezliği (Tip 2) ve implant-kemik ara yüz yetmezliği (Tip 3) olarak üçe ayrılıyor. Derecesi ise; A= PJA 10-14 derece, B=15-19 derece ve C= 20 dereceden büyük olarak belirleniyor. Spondilolistesiz varlığında S, yokluğunda N olarak etiketleniyor[51]. Yagi ve ark. nın serisinde en çok tip 2N ve tip 2S'de görüldüğü not edilmiştir (Tablo 7).

Tablo 7. Yagi ve ark. [50, 51] tarafından tanımlanan PJK sınıflama ve derecelendirme şeması

Sınıflama	Tanımlama
Tip	
1	Disk veya ligament yetmezliği
2	Kemik yetmezliği
3	İmplant-kemik ara yüz yetmezliği
Seviye	
A	PJA artışı 10-19 derece
B	PJA artışı 20-29 derece
C	PJA artışı 30 dereceden fazla
Spondilolistezis	
N	UIV üzerinde gözlenen spondilolistezis var
S	UIV üzerinde spondilolistezis yok

Yagi'nin sınıflama şeması tanımlayıcı açıdan değerli olsa da hastalığın doğal seyri hakkında pek fikir vermemektedir[63].

Hart, Lau ve ark. nın önerdiği PJK şiddetini ölçen skalada 6 özellik değerlendirilmektedir. Bunlar; nörolojik defisit, fokal ağrı, implant problemleri, kifoz değişimi/posterior ligament kompleksi bütünlüğü, kırık bölgesi ve UIV

seviyesidir[48, 63]. Bu özellikler puanlanarak toplam hastalık şiddet skoru belirlenmektedir (Tablo 8).

Tablo 8. Hart-Uluslararası omurga çalışma grubu PJK şiddet skalası

Karakteristik	Şiddet Skoru
Nörolojik Defisit	
Yok	0
Radiküler Pain	2
Miyelopati/Motor Defisit	4
Fokal Ağrı	
Yok	0
VAS Skoru 4 Veya Düşük	1
VAS Skoru 5 Veya Büyük	3
Enstrüman Sorunları	
Yok	0
Kısmi Fiksasyon Kaybı	1
Çıkıntı	1
Tam Fiksasyon Kaybı	2
Kifoz Değişimi/PLK Bütünlüğü	
0-10 Derece	0
10-20 Derece	1
20 Dereceden Büyük	2
PLK Yetmezliği	2
UIV/UIV+1 Vertebra Kırığı	
Yok	0
Kompresyon Kırığı	1
Burst/Chance Kırığı	2
UIV Seviyesi	
Torakolomber Junctional	0
Toraks Üstü	1

PLK; Posterior ligament kompleksi

3.GEREÇ VE YÖNTEMLER

2015-2019 yılları arasında kliniğimize omurga deformitesi nedeniyle posterior enstrümantasyon ve füzyon cerrahisi uygulanmış 167 hastanın kayıtları tarandı. Hasta bilgileri Microsoft Excel dosyasına kaydedildi. Ölen hastalar, ulaşılamayan hastalar, eksik verisi olan hastalar, radyografileri eksik veya değerlendirilemeyen hastalar, 10 yaş altı ve 65 yaş üstü hastalar, revizyon, tümör ve enfeksiyon nedenli cerrahi tedavi uygulanmış hastalar elendi.

Radyografik veriler tam boy (90 cm), ayakta lateral görünteleri üzerinden standart pozisyonda (diz ve kalça ekstansiyonda, kollar 90 derece öne fleksiyondayken bir destek üzerinde) ölçüldü. Hastaların preoperatif, erken postoperatif ve son takiplerindeki PJA değerleri, UIV, LIV ve füzyon seviyesi, preoperatif ve postoperatif TK, LL ve sagital vertikal aks (SVA) ölçümleri ile, SS, pelvik tilt (PT), pelvik insidans ve global sagital dizilim (GSD) verileri, rod kalınlığı, posterior vertebral kolon rezeksiyounu (PVKR) ve ponte osteotomisi bilgileri kaydedildi. Hastalarda PJK gelişimine etki eden faktörleri belirlemek için Weka 3.8.4 bilgisayar programı aracılığıyla makine öğrenmesi algoritmaları kullanılarak tahminler değerlendirildi. Etik kurulu onayı alındı (Tarih: 01.10.2020 Sayı: B.30.2.ATA.0.01.00/448).

3.1. Kullanılan Parametreler

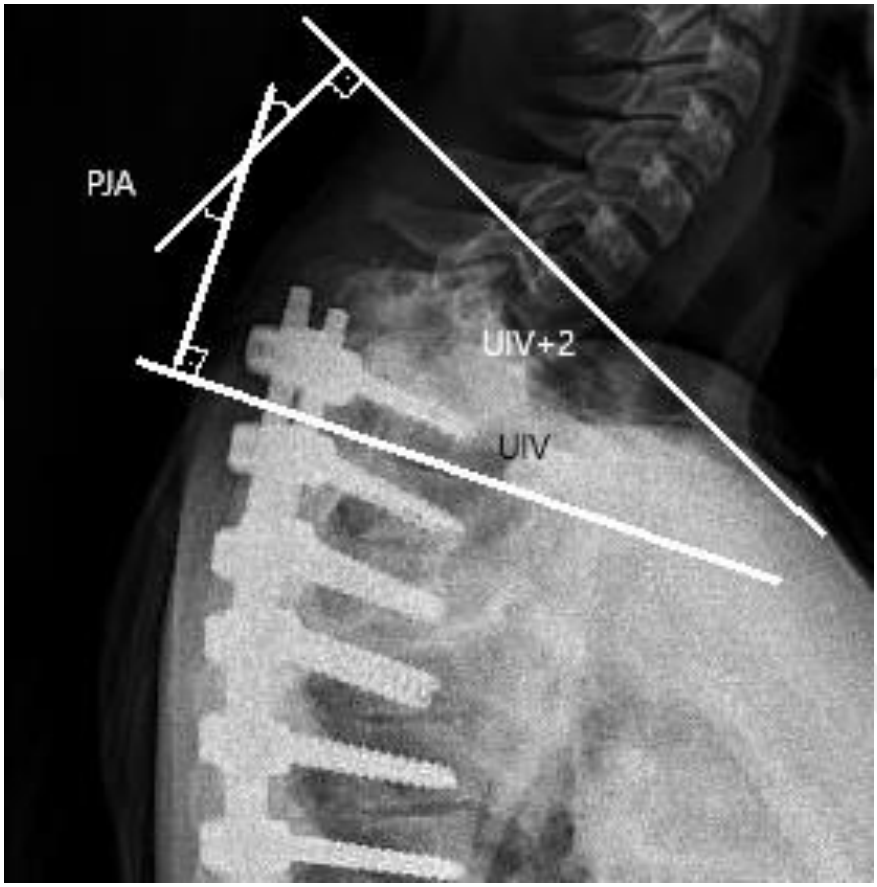
3.1.1. UIV, LIV ve Füzyon Seviyesi

UIV, proksimalde enstrüman uygulanan en son vertebradır. LIV ise en distal enstrüman uygulanan vertebradır. Füzyon seviyesi ise UIV ve LIV dahil aradaki tüm seviyelerin toplamıdır.

3.1.2. Proksimal Junctional Açısı

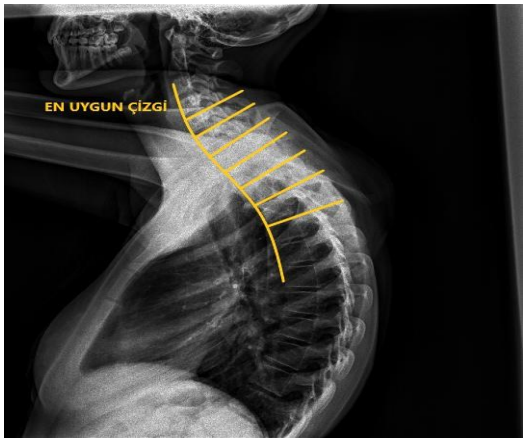
PJA, UIV alt end pleyti ile UIV+2 üst vertebranın üst end pleyti arasındaki sagital Cobb açısıdır (Şekil 10). Hastalarımızın operasyon öncesi, operasyon sonrası erken dönemde ve son takiplerindeki PJA değerleri hastanemizin PACS (picture archiving and communication systems) uygulaması kullanılarak tek bir gözlemci tarafından ölçülüp kaydedildi. Ortalama preop, erken postop ve son PJA değerleri sırasıyla 0,6

(0-28), 3 (0-32) ve 8,6 (0-58) olarak bulundu. Bu ölçümler sonucunda toplam 18 hastaya PJK tanısı konuldu.



Şekil 10. PJK gelişen bir hastamızın PJA ölçümü

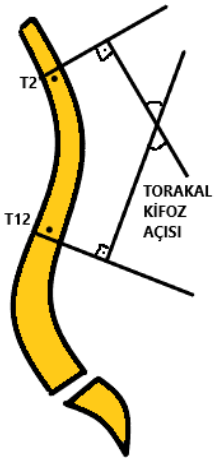
Bazı lateral radyografilerde üst torasik vertebraları gözlemleme zorluğu olabilmektedir. Bunu aşmak için yeni bir yöntem olan "En Uygun Çizgi (Best Fit Line)" yöntemi kullanılmıştır. Bu yöntem, gözlemlenemeyen omurga bölümünün üstündeki ve altındaki vertebra gövdelerinin anteriorlarını birleştiren bir çizgi çizilerek uygulanır. Görüntülenemeyen vertebraların olası eğimini bulabilmek için bu çizgiye dik çizgiler çekilir ve açı ölçümü yapılabilir (Şekil 11).



Şekil 11. Üst torakal bölge görüntülemesi yetersiz olan bir hastamızda “en uygun çizgi” yönteminin kullanılması

3.1.3. Torasik Kifoz (Thoracic Kyphosis)

Genel olarak TK açısı, T1-T12 vertebralar arasından ölçülür[73, 74]. Ancak görüntü süperpozisyonları nedeniyle proksimal seviye T2-T4 seçilerek ölçülülebilir[73, 75, 76]. Biz ölçümlerimizi T2 vertebra üst end pleyti ile T12 vertebra alt end pleytine paralel çizilen doğruların arasındaki açıdan yaptık (Şekil 12).

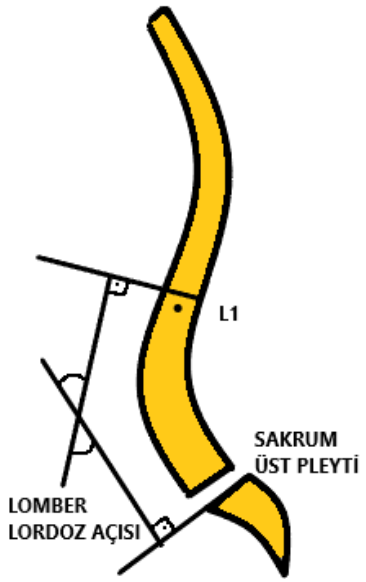


Şekil 12. Torakal kifoz açısı ölçümü

TK'nin normal değeri 20-50 derece arasındadır[73]. Bu açı hastalarımızda operasyon öncesi ve sonrası ölçülerek kaydedilmiştir. TK farkı parametreler arasında çalışılmıştır.

3.1.4. Lomber Lordoz (Lumbar Lordosis)

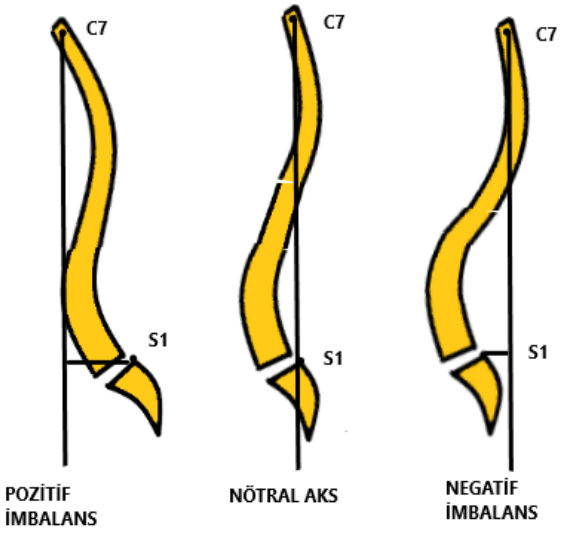
LL açısı, L1 vertebra üst end pleyti ile sakrum üst end pleytine paralel çizilen doğruların arasındaki açıdır (Şekil 13). Normal değeri 40-70 derece arasındadır. Operasyon öncesi ve sonrası LL değerleri ile LL farkı parametre olarak kullanılmıştır.



Şekil 13. Lomber lordoz açısı ölçümü

3.1.5. Sagital Vertikal Aks (Sagittal Vertical Axis)

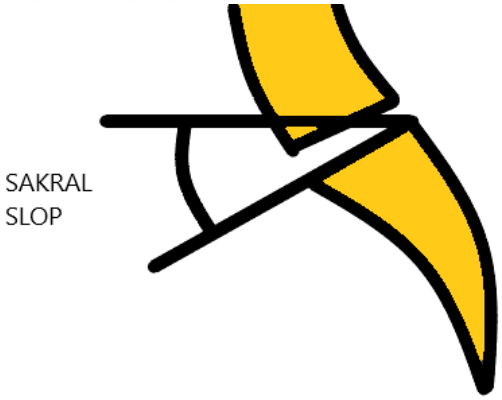
SVA, yedinci servikal vertebra gövde orta noktasından çizilen yere dik çizgi ile sakrum posterior köşesi arasındaki uzaklıktır (Şekil 14). Sakrum üst arka köşesine +2 ile -2 cm uzaklıkta bulunması normal kabul edilirken daha önde olması pozitif imbalans, daha arkada olması negatif imbalans olarak adlandırılır. Operasyon öncesi ve sonrası değerler ile SVA farkı kaydedilmiştir.



Şekil 14. Sagital vertikal aks

3.1.6. Sakral Slop (Sacral Slope)

SS, sakral üst end pleytinin horizontal çizgiyle yaptığı açıdır (Şekil 15). Sakrumun sagital plandaki oryantasyonunu gösterir.



Şekil 15. Sakral slop

3.1.7. Pelvik Tilt (Pelvic Tilt)

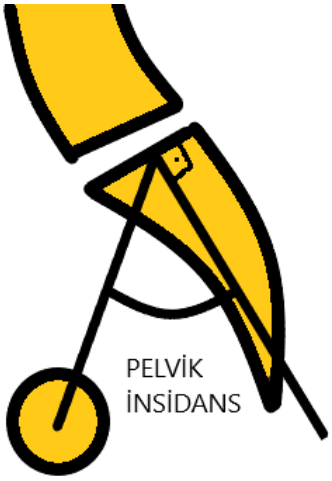
PT, femur başı orta noktasını sakrum üst end pleytinin orta noktasıyla birleştiren çizginin vertikal çizgiyle yaptığı açıdır (Şekil 16).



Şekil 16. Pelvik tilt

3.1.8. Pelvik İnsidans (Pelvic Incidens)

Pelvik insidans (Pİ) femur başı orta noktasından sakrum üst end pleytinin orta noktasına çizilen doğru ile yine sakrum üst end pleytinin orta noktasına dik çizilen doğru arasındaki açıdır (Şekil 17). PI, SS ve PT'nin matematiksel toplamıdır[77].

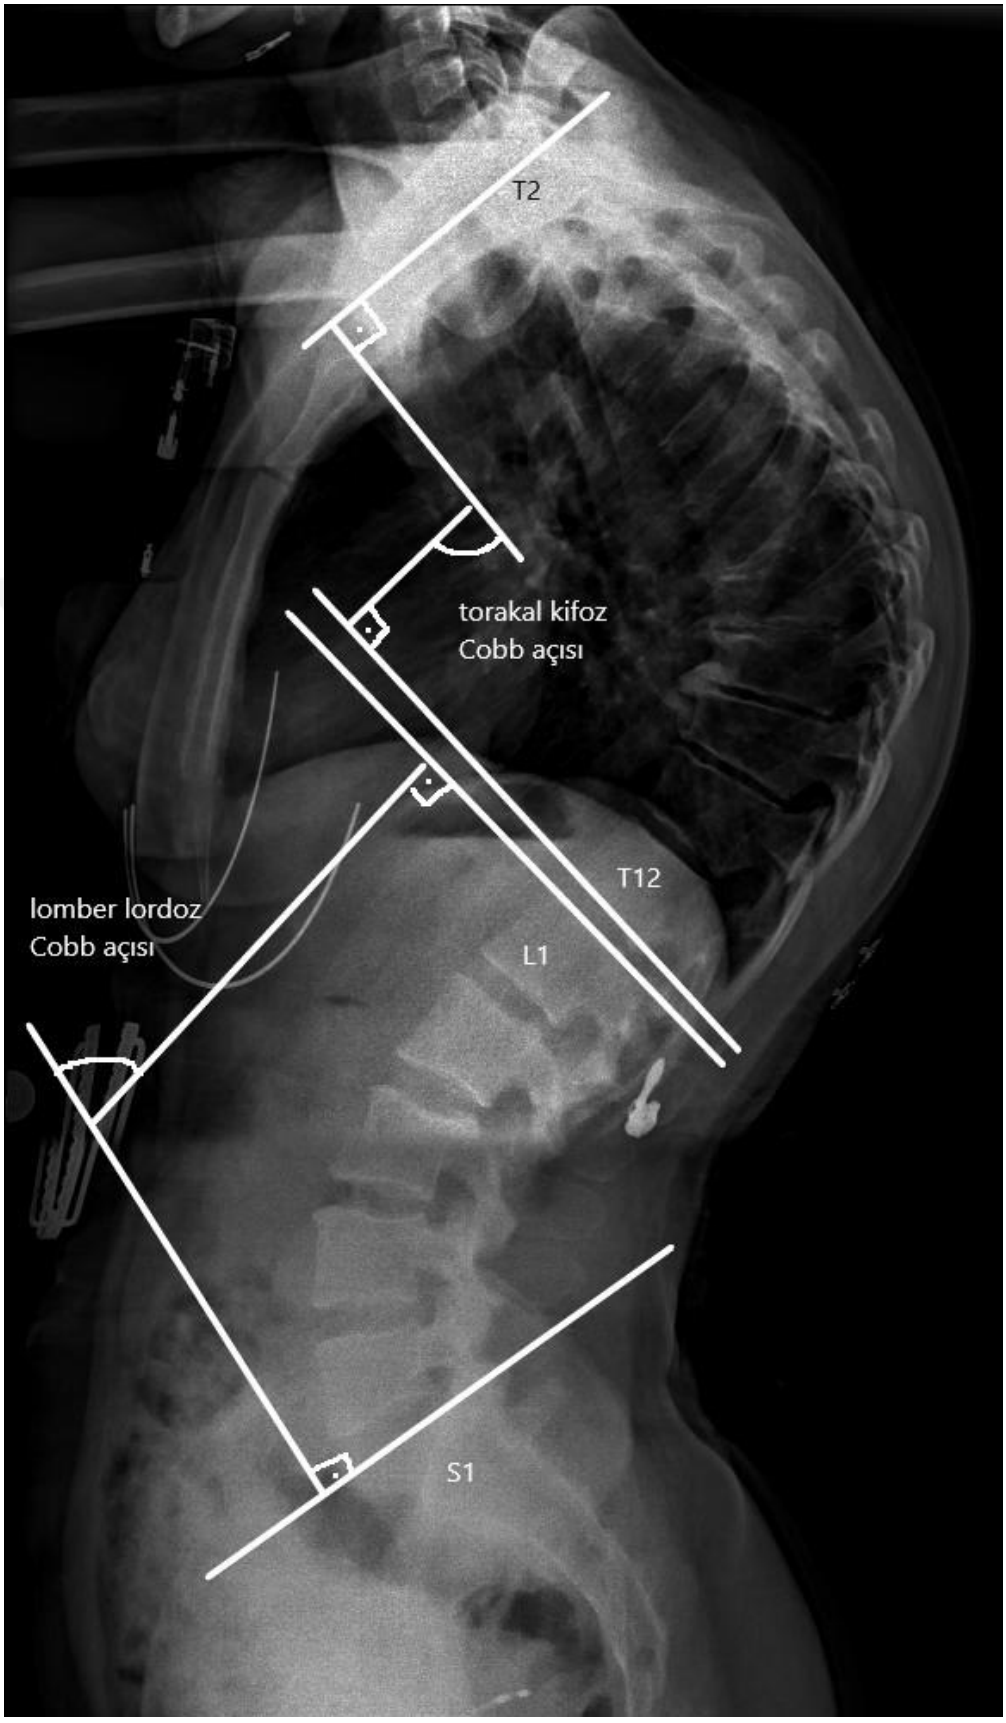


Şekil 17. Pelvik insidans

Dubousset, 1984 yılında “Pelvik vertebra” tanımı yapmıştır ve omurganın pelvis ile olan ilişkisine, spinopelvik dengeye dikkatleri çekmiştir[78]. 1985’de During ve ark. “Pelvisakral açı” yı tanımlamışlardır[79]. Legaye ve ark. Duval- Beaupe’re yöntemi olarak bilinen metodla Pİ açısını tanımlamışlardır[80].

3.1.9. Global Sagital Dizilim (Global Sagittal Alignment)

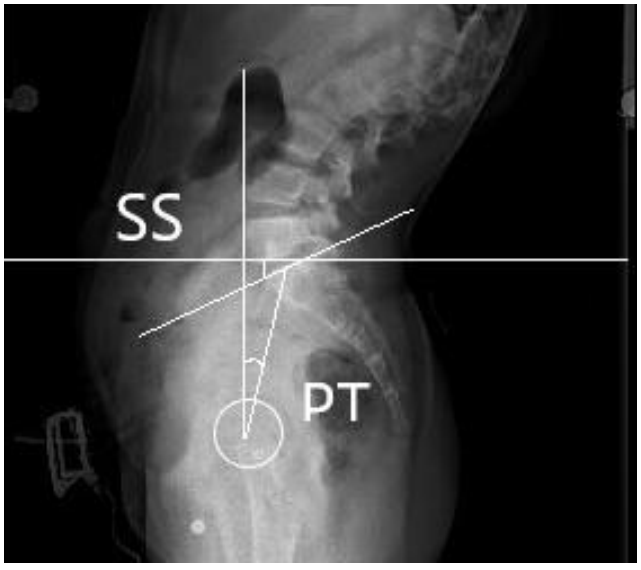
GSD ilk olarak Rose ve ark. tarafından tanımlanmıştır[81]. TK, LL ve PI toplamıdır. Vialle ve ark. nın yaptığı çalışmada TK ve LL düzeltme işlemlerinin PI baz alınarak yapılması gerektiğini savunmuştur[82]. Bu düzeltme işlemleri osteotomileri, kafesleri ve benzeri işlemleri içermektedir. Omurga deformitesi restorasyonunda bu toplam değer hedeflenerek işlem yapılmalıdır. Yagi ve ark. çalışmasında GSD’nin 45 dereceden az olduğu hastalarda PJK gelişim riskinin azaldığı ispatlanmıştır[50]. Rose ve ark. 45 derece altındaki değerlerin sagital omurga dizilimi için önemli olduğunu belirtmiştir[81]. Aynı çalışmada denklemdeki LL değerinin negatif olması gerektiği belirtilmiştir.



Şekil 18. Bir hastamızın preoperatif sagital Cobb açıları ölçümü



Şekil 19. Bir hastamızın sagital vertikal aks ölçümü

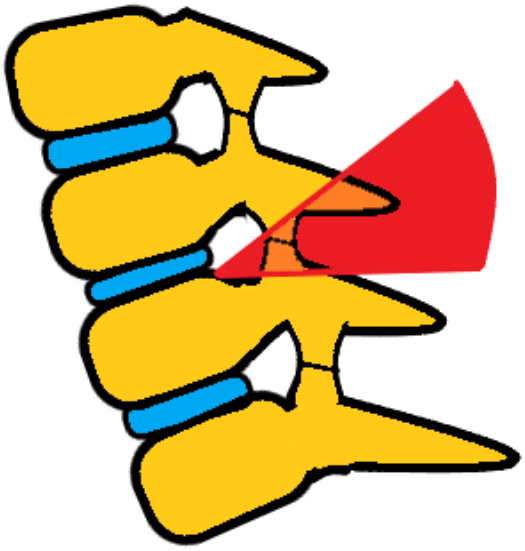


Şekil 20. Bir hastamızın sakral slop ve pelvik tilt ölçümü

3.2. Cerrahi Teknik

Hastaların tamamı genel anestezi altında yüzüstü pozisyonda steril şartlarda posterior yaklaşım ile aynı tecrübeli cerrah tarafından opere edilmiştir. Cilt, cilt altı ve fasya geçilmiştir. Vertebra laminaları ve faset eklemler görülecek şekilde paraspinal kaslar iki taraflı açılmıştır. Tüm seviyelerde faset eklemlere artrodez uygulanmıştır. Önceden belirlenmiş vertebralara uygun ölçüde vidalar gönderilmiş C kollu floroskopi yardımıyla vidaların konumu teyit edildikten sonra şekillendirilmiş rodlar yerleştirilip enstrümantasyon tamamlanmıştır. Uç noktalardaki posterior yumuşak dokulara özellikle hassasiyet gösterilmiştir. Tüm dokular usülüne uygun dikilerek kapatılmıştır.

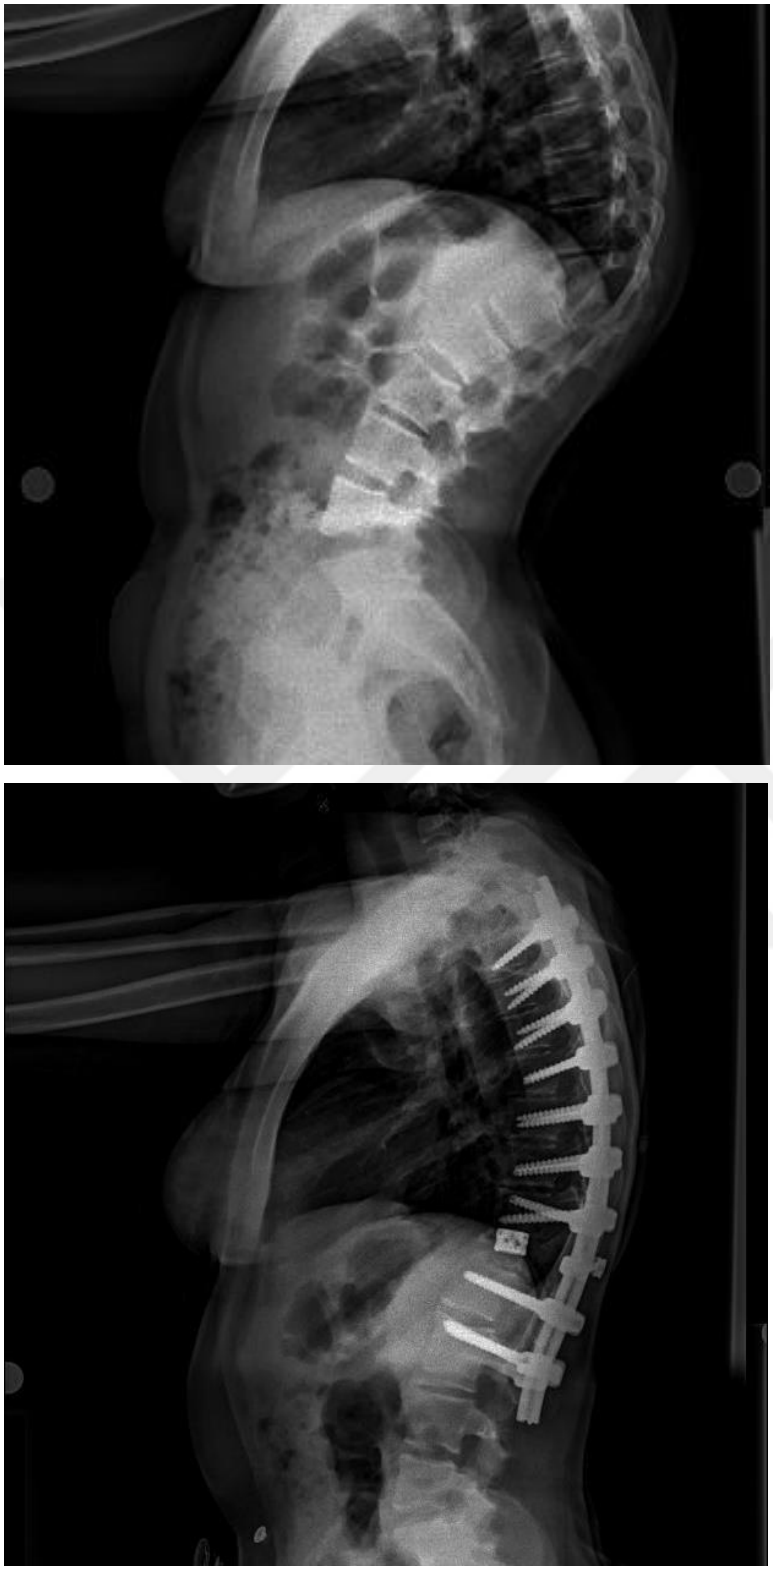
Uygun sagital dizilim sağlayabilmek için 7 (%10) hastamıza PVKR ve 33 (%50) hastamıza ponte osteotomisi yaptık.



Şekil 21**.** Ponte osteotomisi; omurganın arka kolonunun tam kalınlıkta, yandan yana, segmental rezeksiyonudur ve posterior kolonu kısaltarak kifoz açısının düzeltilmesine izin vermek için tasarlanmıştır[83].



Şekil 22. Kifoskolyozlu bir hastanın pre-postop tam boy ön-arka ve yan grafileri



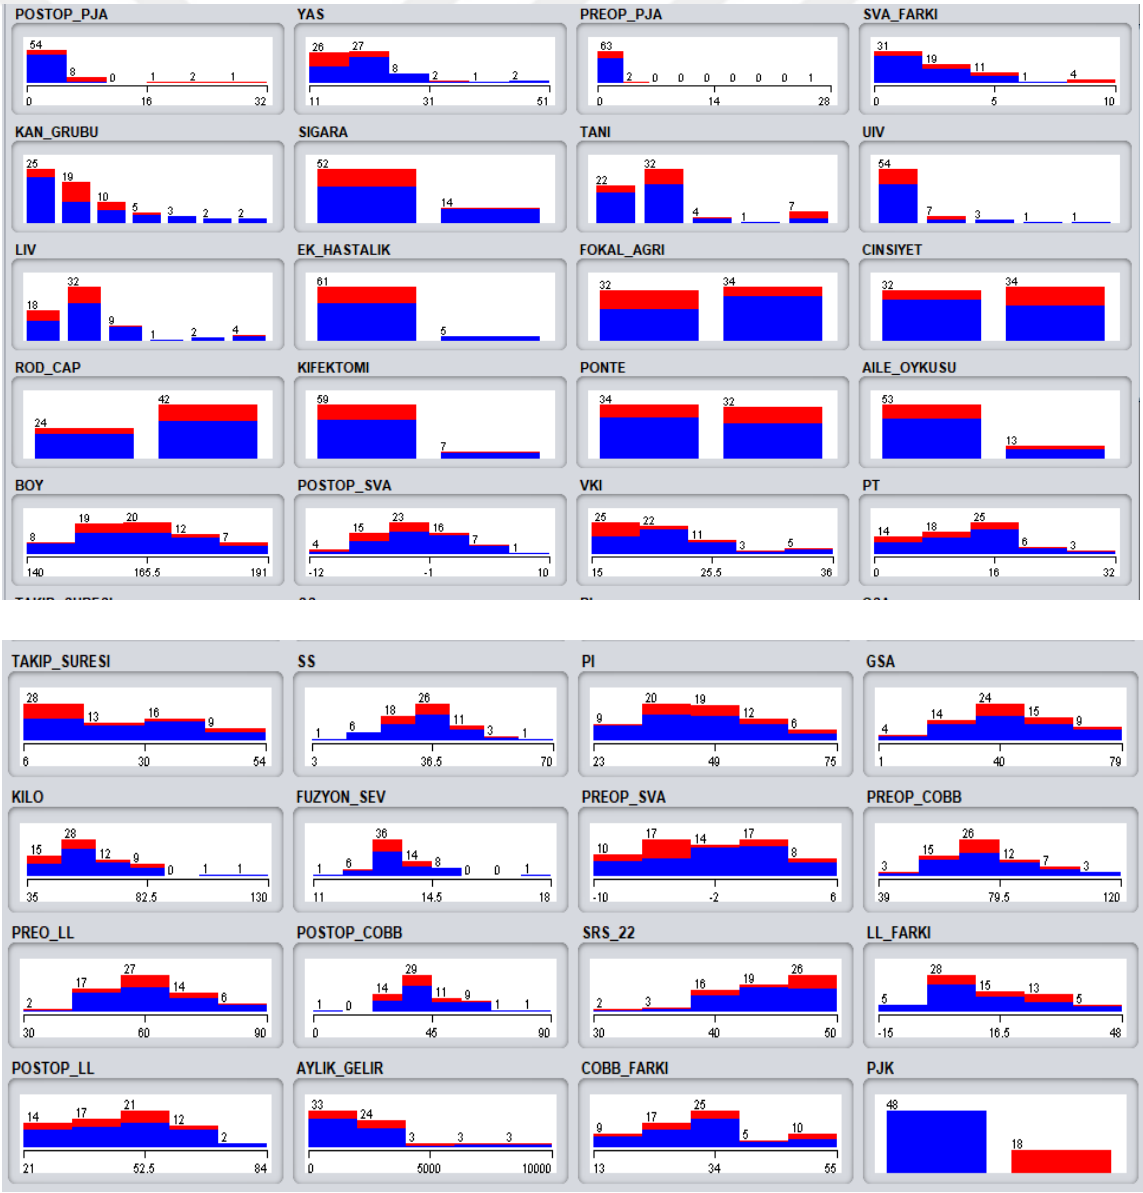
Şekil 23. T12 kama vertebranın PVKR sonrası kafes kullanılan bir hastamız

4.BULGULAR

4.1. Ön İşlem (Preprocess) Sekmesi Sonuçları

PJK'ye etki eden parametreler Weka ön işlem sekmesinde görüntülendi. Her bölüm, üzerinde belirtilen parametreyi temsil etmektedir, içlerindeki grafikler isimsel değerleri ayrı birer kolon halinde, sayısal değerleri ise birleşik olarak göstermektedir. Mavi boyalı alanlar o grup içerisindeki PJK olmayan hastaları, kırmızı boyalı olanlar ise PJK olan hastaları temsil etmektedir (Tablo9).

Tablo 9. PJK'ye etki eden parametreler (mavi; PJK yok, kırmızı; PJK var)

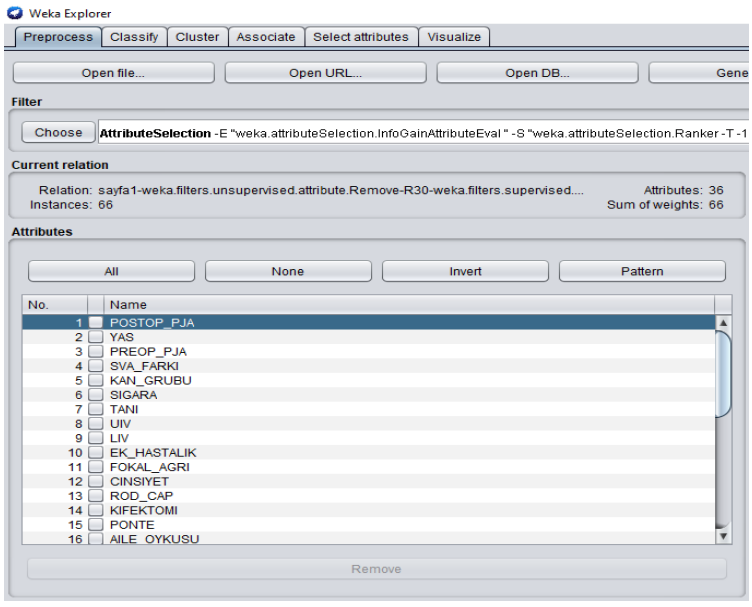


66 hastamızın 34'ü kadın 32'si erkekti. Hastalarımızın yaş ortalaması 20.5'ti (11-51). Hastalarımızın 32'si Scheuermann kifozu, 22'si kifoskolyoz, 7'si pozisyonel kifoz, 4'ü konjenital kifoz ve 1'i idiyopatik kifozdu. Ortalama takip süresi 25.2 aydı (6-54 ay). Kan grubu dağılımı toplum ortalamasıyla benzer olarak en çok 0 Rh+ (25), en az 0 Rh- (2) olarak bulundu. Ortalama VKE 21.8 di (15-36). 14 hasta sigara kullanıyordu. 5 hastanın ek sistemik hastalık öyküsü vardı. 13 hastanın ailesinde omurga deformitesi öyküsü vardı. Ortalama aylık gelir 2728 Türk Lirası'ydı (0-10.000 TL). 34 hastada fokal ağrı şikayeti vardı. SRS-22r anket ortalaması 4.4'tü (3-5).

66 hastamızın 18'inde PJK gelişti (%27.2). Hiçbirinde PJF gelişmemiş olup revizyon gereken hasta yoktu. PJK gelişen 18 hastanın 12'si kadın, 6'sı erkekti. PJK gelişen 10 (%56) hasta Yagi ve ark. tarif ettiği sınıflandırma yöntemine göre Tip 1AN, 8 (%44) hasta Tip 1BN'ydi.

Weka ön işleminde test edilen parametreyle en yakın ilişkili parametreleri sıralayan bir özellik bulunmaktadır (Tablo 10). Veri setimize bu işlemi uygulayınca birinci en yakın ilişkili parametre postoperatif erken PJA değeri (POSTOP_PJA) bulundu. Özellikle bu açı 8-10 derece arasındayken PJK oranının yükseldiği görülebilmektedir (Tablo 10).

Tablo 10. PJK'ye etki eden parametreler ön işlem sekmesi kullanılarak en yakın ilişkili olanlar sıralanmıştır.

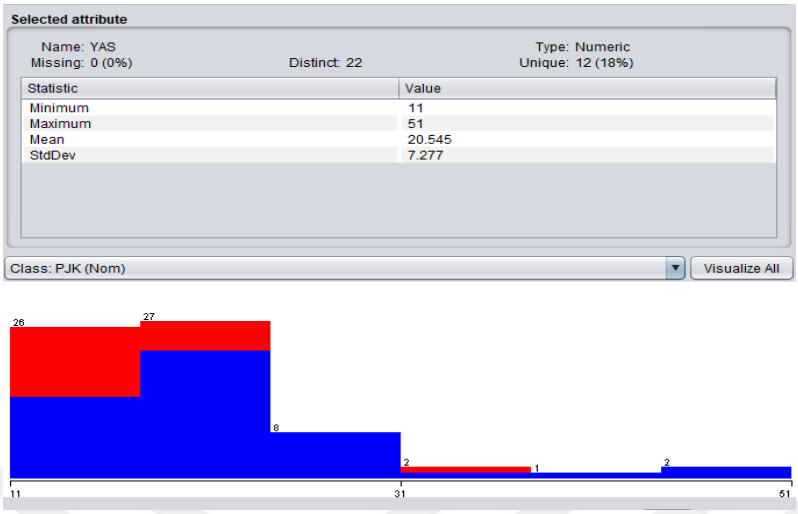


Tablo 11. Postoperatif PJA'nın PJK gelişimiyle ilişkisini gösteren grafikte özellikle 5 derece üzerindeki değerlerde PJK oranı artmaktadır (mavi; PJK yok, kırmızı; PJK var).

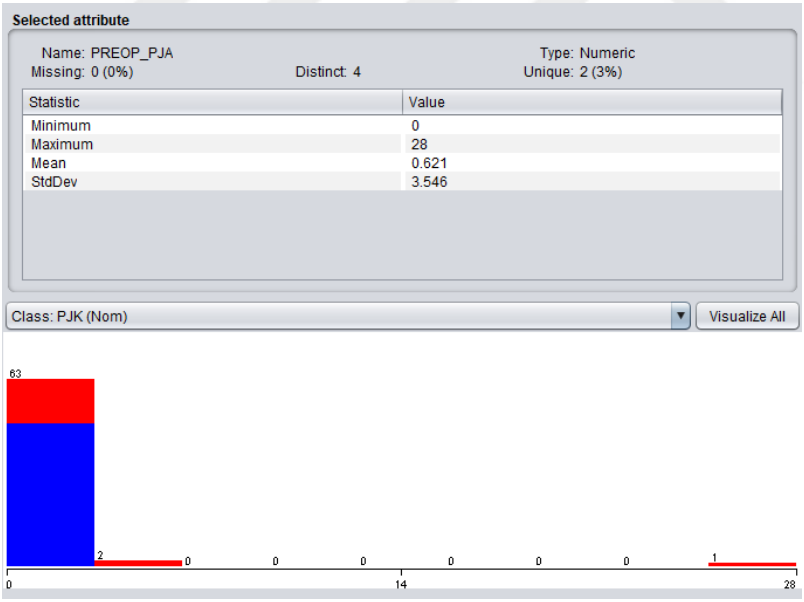


İkinci sırayı alan yaş parametresinde (YAS) özellikle 11-17 yaş aralığında PJK gelişimi oranlarında artış görüldü. Üçüncü sırayı alan preoperatif PJA değerlerinde (PREOP_PJA) özellikle 3 derece üzerinde PJK gelişim oranında artış görülmektedir (Tablo 12).

Tablo 12. PJK gelişiminde yaş parametresinin etkisi. Özellikle 11-17 ile 31-37 yaş aralığında PJK oranları yüksekti (Mavi; PJK yok, kırmızı; PJK var).



Tablo 13. Preoperatif PJA ile PJK gelişimi arasındaki ilişki. Üç derece üzerindeki üç hastanın tamamında PJK gelişti (mavi; PJK yok, kırmızı; PJK var).



Dördüncü sıradaki SVA farkı (SVA_FARKI) incelendiğinde 8cm'den fazla farkın olduğu 4 hastanın tamamında PJK geliştiği görüldü (Tablo 13).

Tablo 14. SVA ameliyat öncesi ve ameliyat sonrası farkının PJK gelişimi üzerindeki etkisi. 8 derece üzerindeki değerlerin tamamında PJK gelişti.



4.2. Naive Bayes Sonuçları

Tablo 15. PJK gelişimi üzerinde etki eden parametrelerin NB algoritma sonucu

```
=== Summary ===

Correctly Classified Instances          20               90.9091 %
Kappa statistic                          0.614
Mean absolute error                      0.1381
Root mean squared error                  0.2814
Relative absolute error                 35.4766 %
Root relative squared error             69.8083 %
Total Number of Instances               22

=== Detailed Accuracy By Class ===

               TP Rate   FP Rate   Precision   Recall  F-Measure  MCC      ROC Area  PRC Area  Class
               0,947     0,333     0,947     0,947     0,947      0,614    0,895     0,982     YOK
               0,667     0,053     0,667     0,667     0,667      0,614    0,895     0,778     VAR
Weighted Avg.  0,909     0,295     0,909     0,909     0,909      0,614    0,895     0,954

=== Confusion Matrix ===

  a  b   <-- classified as
 18  1 |  a = YOK
  1  2 |  b = VAR
```

Değerler 0-1 aralığında normalize edildikten sonra çalışıldı. Öğrenme-test oranını belirlemek için percentage split %66 seçildi. Doğruluk oranı %90.9 bulundu. Ortalama precision 0.90, recall 0.90, F-measure 0.90 ve ROC 0.89 bulundu.

4.3. Destek Vektör Makineleri

Tablo 16. Destek vektör makinelerinden SMO (Sequencial Minimal Optimization) algoritması kullanılarak PJK üzerine etki eden parametreler belirlendi.

```
=== Summary ===

Correctly Classified Instances          52               78.7879 %
Kappa statistic                          0.4031
Mean absolute error                      0.2121
Root mean squared error                  0.4606
Relative absolute error                 52.9586 %
Root relative squared error            103.2509 %
Total Number of Instances               66

=== Detailed Accuracy By Class ===

                 TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                 0,917    0,556    0,815      0,917    0,863      0,417    0,681     0,808     YOK
                 0,444    0,083    0,667      0,444    0,533      0,417    0,681     0,448     VAR
Weighted Avg.    0,788    0,427    0,774      0,788    0,773      0,417    0,681     0,709

=== Confusion Matrix ===

  a  b   <-- classified as
 44  4 |  a = YOK
 10  8 |  b = VAR
```

Değerler normalize edilerek SMO algoritması uygulandı. Öğrenme-test oranını belirlemek için cross validation 10 folds uygulandı. Doğruluk oranı %78.7 bulundu. Ortalama precision 0.77, recall 0.78, F-measure 0,77 ve ROC 0.68 bulundu.

Tablo 17. SMO algoritmasında PJK var parametresine olumlu ve olumsuz etki eden parametrelerin gösterilmesi

```
        2.159  * (normalized) POSTOP_PJA
+      -0.4892 * (normalized) YAS
+       0.2985 * (normalized) PREOP_PJA
+       1.6939 * (normalized) SVA_FARKI
+      -0.2285 * (normalized) KAN_GRUBU=0RH+
+       0.4526 * (normalized) KAN_GRUBU=ARH+
+       0.3706 * (normalized) KAN_GRUBU=BRH+
+      -0.186  * (normalized) KAN_GRUBU=ABRH+
+      -0.1948 * (normalized) KAN_GRUBU=ARH-
+      -0.2138 * (normalized) KAN_GRUBU=0RH-
+      -0.6007 * (normalized) SIGARA=VAR
+      -0.051  * (normalized) TANI=KIFOSKOLYOZ
+       0.2713 * (normalized) TANI=SCHEUERMANN
+      -0.3323 * (normalized) TANI=KONJENITAL
+      -0.0133 * (normalized) TANI=IDIYOPATIK
+       0.1252 * (normalized) TANI=POZISYONEL
+       0.145  * (normalized) UIV=T2
+       0.1385 * (normalized) UIV=T3
+      -0.2835 * (normalized) UIV=T1
+       0.2103 * (normalized) LIV=L3
+       0.3816 * (normalized) LIV=L2
+      -0.6418 * (normalized) LIV=L4
+      -0.0133 * (normalized) LIV=ILIAK
+       0.0632 * (normalized) LIV=L1
+      -0.1728 * (normalized) EK_HASTALIK=VAR
+      -0.5658 * (normalized) FOKAL_AGRI=VAR
```

Tablo 18. Tablo 17'nin devamı

```
+       0.3265 * (normalized) CINSIYET=K
+      -0.2592 * (normalized) ROD_CAP=KALIN
+      -0.2049 * (normalized) KIFEKTOMI=VAR
+      -0.0856 * (normalized) PONTE=YOK
+      -0.6207 * (normalized) AILE_OYKUSU=VAR
+       0.4191 * (normalized) BOY
+      -0.2083 * (normalized) POSTOP_SVA
+      -0.1922 * (normalized) VKI
+      -0.7034 * (normalized) PT
+       0.0432 * (normalized) TAKIP_SURESI
+       0.2273 * (normalized) SS
+      -0.14   * (normalized) PI
+      -0.0928 * (normalized) GSA
+       0.0142 * (normalized) KILO
+      -0.1311 * (normalized) FUZYON_SEV
+      -0.3992 * (normalized) PREOP_SVA
+      -0.1107 * (normalized) PREOP_COBB
+      -0.4863 * (normalized) PREO_LL
+      -0.3639 * (normalized) POSTOP_COBB
+      -0.1742 * (normalized) SRS_22
+       0.0573 * (normalized) LL_FARKI
+      -0.5205 * (normalized) POSTOP_LL
+       0.2215 * (normalized) AYLIK_GELIR
+       0.5664 * (normalized) COBB_FARKI
-       0.4076
```

PJK ile pozitif korelasyon gösteren ilk üç değer sırasıyla; ameliyat sonrası PJA açısı (POSTOP_PJA; 2.159), ameliyat sonrası SVA değişimi (SVA_FARKI; 1.6939) ve ameliyat sonrası TK Cobb açı farkıydı (COBB_FARKI; 0.5664).

PJK ile olumsuz yönde korelasyon gösteren ilk sıradaki değer; ameliyat öncesi PT (PT; -0.7034) oldu.

4.4. Karar Ağacı

J48 algoritması kullanıldı. KA'daki yönlendirici değerleri görebilmek için normalizasyon uygulanmadı. Öğrenme-test oranını belirlemek için percentage split %66 uygulandı.

Tablo 19. J48 karar ağacı algoritması sonuçları

```
=== Summary ===

Correctly Classified Instances          20               90.9091 %
Kappa statistic                          0.6986
Mean absolute error                      0.1647
Root mean squared error                  0.2758
Relative absolute error                 42.2973 %
Root relative squared error             68.4119 %
Total Number of Instances               22

=== Detailed Accuracy By Class ===

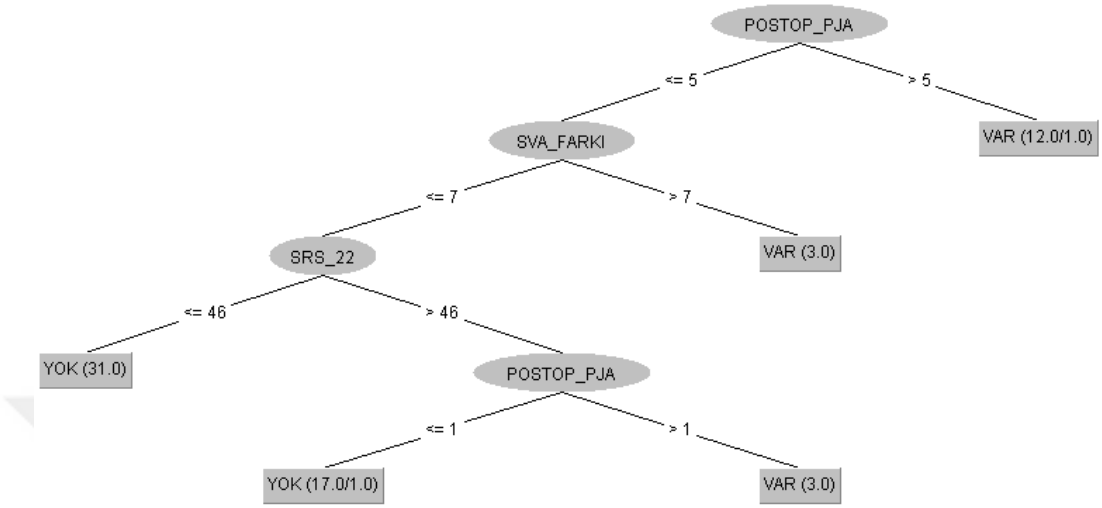
                 TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                 0,895    0,000    1,000      0,895    0,944      0,733    0,947     0,986     YOK
                 1,000    0,105    0,600      1,000    0,750      0,733    0,947     0,600     VAR
Weighted Avg.    0,909    0,014    0,945      0,909    0,918      0,733    0,947     0,933

=== Confusion Matrix ===

  a  b   <-- classified as
 17  2 |  a = YOK
  0  3 |  b = VAR
```

J48 karar ağacı algoritmasında doğruluk oranı %90.9 bulundu. Ortalama precision 0.94, recall 0.90, F-measure 0.91 ve ROC 0.94 bulundu.

Tablo 20. J48 karar ağacı algoritma sonuçlarının görselleştirilmesi



KA'nın en tepesinde ameliyat sonrası erken PJA vardı (POSTOP_PJA). Bu açı beş dereceden büyükken PJK gelişimi vardı. beş derece ve daha küçük değerlerde ameliyat sonrası SVA farkına (SVA_FARKI) bakılması gerektiği bulundu. Bu fark yedi cm'den büyükken PJK gelişimi vardı. Yedi cm ve daha altındaki değerlerde SRS-22 (SRS_22) anket sonuçlarına bakılması gerektiği bulundu. 4.6 ve altındaki skorlarda PJK yoktu. 4.6 üzerindeki skorlarda ise ameliyat sonrası erken PJA değerine (POSTOP_PJA) yeniden bakılması gerektiği görüldü. Bu aşamada PJA bir derece üzerinde PJK varken bir derece ve altında PJK gelişimi yoktu.

4.5. Yapay Sinir Ağları

Tablo 21. YSA algoritması sonuçları

```
=== Summary ===

Correctly Classified Instances          16               72.7273 %
Kappa statistic                          0.3714
Mean absolute error                      0.2573
Root mean squared error                  0.466
Relative absolute error                 66.0899 %
Root relative squared error            115.6121 %
Total Number of Instances               22

=== Detailed Accuracy By Class ===

                 TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                 0,684    0,000    1,000      0,684    0,813      0,478    0,947     0,992     YOK
                 1,000    0,316    0,333      1,000    0,500      0,478    0,947     0,833     VAR
Weighted Avg.    0,727    0,043    0,909      0,727    0,770      0,478    0,947     0,970

=== Confusion Matrix ===

  a  b   <-- classified as
 13  6 |  a = YOK
  0  3 |  b = VAR
```

Değerler normalize edilip multilayer perceptron algoritması kullanıldı. Öğrenme-test oranını belirlemek için percentage split %66 uygulandı. Doğruluk oranı %72.7 bulundu. Ortalama precision 0.90, recall 0.72, F-measure 0.77 ve ROC 0.94 bulundu.

5.TARTIŞMA

5.1. Makine Öğrenmesi Algoritmalarının Sonuçlarının Yorumlanması

MÖ algoritmalarımızın sonuçlarını karşılaştırdığımızda KA J48 algoritmasının veri setimizi en yüksek doğruluk oranıyla sınıflandırdığını gördük (Tablo 22).

Tablo 22. PJK gelişimi tahmini için MÖ algoritmalarının sonuçları

	NB	DVM (SMO)	**KA J48**	YSA
Doğruluk (%)	90.9	78.7	**90.9**	72.7
F-measure	0.90	0.90	**0.91**	0.77
ROC	0.89	0.77	**0.94**	0.94
MAE	0.13	0.21	**0.16**	0.25

KA'nın en tepesinde ameliyat sonrası erken dönem PJA vardı. Bu konuyla ilgili literatürü taradığımızda PJK tanısının büyük bir bölümünün postoperatif birinci yılda konulduğuna dair çalışmalarla karşılaştık.

Yagi , Kim ve ark. nın çalışmalarında PJK tanısı konulan hastaların ameliyat sonrası PJA'larının yarı değerlerinin ilk üç ay içerisinde arttığı gösterilmiştir[50, 58].

KA'nın ikinci satırına SVA farkı yerleşti. Yedi cm üzerindeki değişimlerde PJK gelişimi açısından direkt risk faktörü olarak tanımlandı. Literatürde sagital dizilimin ameliyat öncesi planlamada önemli olduğuna dair uyarılar sıklıkla mevcuttu.

Schwab ve ark. 2009'da spinal deformiteyi tanımlamak için tek başına SVA'nın yetersiz kaldığını söylediler. Sagital deformiteyi tam anlamıyla tanımlayabilmek için spinopelvik parametrelerin (SP) de değerlendirilmesi gerektiğini buldular. HRQOL

(health related quality of life) skorlarının değerlendirildiği çalışmalarında PT, PI, LL ve SVA'nın ameliyat kararında önemli olduğunu gösterdiler[84].

Yagi ve ark. nın çalışmalarında SVA değişimlerinin PJK gelişim riskini önemli derecede artırdığı gösterilmiştir[50, 65].

Lafage ve ark. nın 2013 yılında yaptığı bir çalışmada PT ve SVA'nın postop sagital dengeyi düzenlemede çok önemli olduğu gösterildi[85].

Kim ve ark. nın 2014'de yaptığı bir çalışmada omurga enstrümantasyonu uygulanan hastalardaki SVA değişikliklerinin yüksek revizyon oranlarıyla yakın ilişkili olduğu gösterilmiştir[68].

Radovanovic ve ark. nın 2017 tarihli çalışmasında lomber spondilolistezisli hastalarda ağrı anketleri açısından en önemli parametrenin SVA olduğu bulundu[86].

Ancak, Im ve ark. nın 2020 tarihli LL aşırı düzeltmesinin PJK gelişimine etkisini araştırdıkları çalışmada, LL ve SVA değişiminin PJK gelişimine neden olmadığı bildirilmiştir[87].

Biz SVA değişiminin yüksek olduğu hastalarda PJK gelişim riskinin arttığını bulduk. Bu nedenle sagital spinal denge restorasyonunda aşırı düzeltmelerden kaçınılması gerektiğini ve tam düzeltme yerine optimal düzeltme gerektiğini düşünüyoruz.

KA'ya göre SRS-22r anketleri PJK gelişimiyle ters orantılıydı. Yani PJK gelişimi üzerinde anlamlı etkisi yoktu. Literatürde SRS-22r vb. anketlerin PJK gelişimiyle anlamlı ilişkisinin olmadığını gösteren bolca yayın bulunmaktadır[50, 57-59, 65, 88, 89].

DVM algoritmalarından SMO, NB'den sonra doğruluk oranında üçüncü sırayı aldı. PJK gelişimiyle olumlu yönde birliktelik gösteren ilk üç değer sırasıyla postoperatif erken PJA, SVA farkı ve TK Cobb farkıydı. Ters yönde etki eden en önemli parametre PT'ydi.

Postoperatif erken PJA ve SVA farkının PJK gelişimi üzerindeki etkisi KA'da olduğu gibi en anlamlı parametreydi. Ek olarak SMO'da TK Cobb farkı da PJK

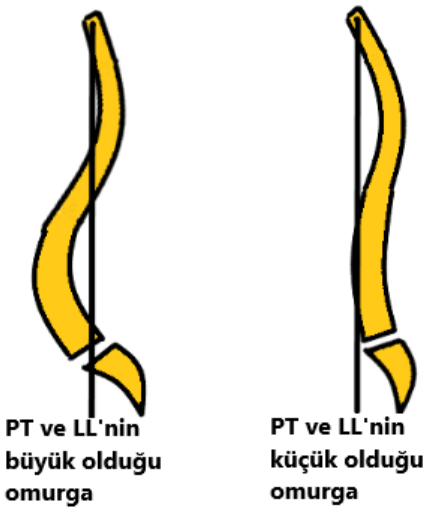
gelişimiyle yakın ilişkili görünüyordu. Bununla ilgili literatür tarandığında benzer sonuçların bulunduğu görüldü.

Kim ve ark. nın 2005 tarihli bir çalışmasında hiperkifozlu hastalara uygulanan posterior enstrümantasyon sonrası PJK gelişim riskinin yükseldiğini gösterdiler[88].

Kim ve ark. larının 2007 yılında yaptığı başka bir çalışmada TK Cobb farkının PJK riskini artırdığı gösterildi[89].

Yine 2012 yılındaki başka bir çalışmada postoperatif hipo ve hiperkifoz durumlarının PJK riskini artırdığı gösterildi[59].

PJK gelişimiyle ters yönde ilişkili değer olarak bulunan PT SPP'lerdendir ve ilişkili literatürde ameliyat planlamasında üzerinde bolca vurgu yapılmıştır. Düşük PT düşük LL ile birliktedir ve lomber bölgede daha düz bir omurgayı temsil eder. Bu durum literatürde arka bel ağrısının ve spondilolistezis gibi daha ileri omurga hastalıklarıyla ilişkilendirilmiştir. PT artışı pelvisi antevert bir hale getirirken baş için yerçekimi çizgisini omurga arkasına alır (Şekil 24). Bu durum entrümanın üst komşu bölgelerinden fleksiyona gelme durumuna engel olarak PJK gelişim riskini azaltıyor olabilir. İlişkili literatürde pelvik retroversiyonun PJK gelişimiyle ilişkili olduğunu gösteren yayınlar vardır[67, 69].



Şekil 24. PT ve LL'nin küçük olduğu sagital omurga dizilimlerinde baş için yerçekimi çizgisi omurga önünden hizalanmaktadır

Lafage ve ark. nın 2013 tarihli sanal omurga dizilimi modelleme çalışmasında düşük PT ile PJK ilişkisini bulmuşlardır[85].

5.2. Hasta Bağımlı Risk Faktörlerinin Yorumlanması

5.2.1. Yaş

PJK gelişimi için risk faktörlerinden bir diğer önemli parametre yaştır.

Kim ve ark. nın 2012 yılında yaptığı bir çalışmada ileri yaşın hasta bağımlı etkenlerden en önemlisi olduğu bildirilmiştir[59]. Yine farklı çalışmalarda da yaşın PJK gelişimi açısından önemli bir risk faktörü olduğu bulunmuştur[58, 90]. Ancak Yagi ve ark. nın bir çalışmasında yaş ile PJK gelişimi arasında anlamlı bir ilişki olmadığı rapor edilmiştir[50].

Lee ve ark. nın 2014 tarihli çalışmasında yüksek yaşın PJK gelişimi için bir risk faktörü olduğu bildirilmiştir[91].

Kim ve ark. nın 2014 yılında yaptığı bir çalışmada yüksek yaş ile revizyon gerektiren PJK vakaları arasında anlamlı bir ilişki olduğu gösterilmiştir[68].

Vedantam ve ark. nın asemptomatik gönüllüler üzerinde yaptığı bir çalışmada artan yaş ile SVA pozitif imbalansının ilişkisini göstermiştir. Asemptomatik ergenlerin, asemptomatik yetişkinlere göre daha büyük negatif sagital omurga diziliminde durma eğilimini rapor etmişlerdir[92].

Bizim çalışmamıza ileri yaş hastalar dahil edilmemiş olup yaş bağımlı bir ilişki bulunamamıştır.

5.2.2. Cinsiyet

PJK gelişimiyle cinsiyet arasında ilişki kuran yayınlar vardır.

Kim ve ark. 2007 tarihli bir çalışmada kadın cinsiyetin PJK gelişim riskiyle ilişkisini raporlanmışlardır[89].

Cinsiyetin PJK riskini artırmadığı yönündeki yayınlar daha fazladır[50, 68, 93].

Kadın cinsiyetin bir risk faktörü olarak değerlendirilmesinin nedeni adölesan idiyopatik skolyozun kadınlarda daha fazla görülüyor olması olabilir. Yine ileri yaş kadınlarda postmenapozal osteoporozun PJK riskini artırması nedeniyle bir bağlantı kurulabilir.

Bizim çalışmamızda cinsiyetle PJK gelişim riski arasında anlamlı bir ilişki bulunamadı. Bu konuda daha büyük hasta grupları üzerinde yapılacak çalışmalara ihtiyaç olduğunu düşünüyoruz.

5.2.3. Vücut Kitle Endeksi

Kim ve ark. nın 2013 tarihli bir çalışmasında VKE'nin PJK gelişimi üzerinde oldukça prediktif bir parametre olduğunu gösterilmiştir[90].

Bridwell ve ark. nın 2013 yılındaki bir çalışmasında obezitenin PJK riskini artırdığı bulunmuştur[66].

Wang ve ark. nın 2016 tarihli çalışmasında PJK gelişim riskiyle obezitenin bağlantılı olduğu gösterilmiştir[94].

Park ve ark. nın 2017 yılında yaptıkları bir çalışmada VKE yüksekliğinin PJK gelişimi için bağımsız bir risk faktörü olduğu raporlanmıştır[95].

Ancak Kim ve ark. nın 2014 yılında yaptıkları çalışmada VKE'nin PJK gelişimi ile ilişkili olmadığını raporlanmıştır[68].

Bizim hasta grubumuzda ortalama VKE düşük olup, PJK gelişim riskiyle ilişkili bulunmamıştır.

5.2.4. Ek Hastalık Varlığı

Özellikle yaşlı popülasyonda görülen kardiyovasküler sistem hastalıkları, Tip 2 diabet ve romatolojik hastalıkların PJK gelişimi üzerindeki etkileri net değildir. Ancak özellikle bayan hastalarda görülen postmenapozal osteoporozun PJK gelişimi için bir risk faktörü olduğunu bildiren yayınlar vardır.

Yagi ve ark. nın 2012 tarihli çalışmasında düşük kemik dansitesinin PJK gelişimi için bir risk faktörü olduğu bildirilmiştir[50].

Cho ve ark. nın 2014 yılında yaptığı sistematik derleme çalışmasında kemik mineral dansitesinin PJK gelişimi için bir risk faktörü olduğunu bulmuştur[96].

Hyun ve ark. nın 2016 tarihli çalışmasında osteoporozun PJK'ya neden olduğu gösterilmiştir[97].

Liu ve ark. nın 2016'da yaptığı bir çalışmada kemik mineral dansitesinin düşüklüğünün PJK gelişimi için risk faktörü olduğu yayınlanmıştır[93].

Wang ve ark. nın 2016 yılında yayınlanan bir çalışmasında osteoporozun PJK gelişimi için bir risk faktörü olduğu bulunmuştur[94].

Do Keun Kim ve ark. nın 2017 yılında yaptığı bir çalışmada kemik mineral dansitesinin PJK ile güçlü korelasyon gösterdiği raporlanmıştır[98].

Park ve ark. nın 2017 tarihli çalışmasında osteoporozun PJK gelişimi için bir risk faktörü olduğu bildirilmiştir[95].

Bridwell ve ark. nın 2013 tarihli çalışmasında spinal füzyon uygulanan hastalarda komorbidite varlığının PJK gelişim riskini artırdığı raporlanmıştır[66].

Arima ve ark. nın 2018 yılında yaptığı çalışmada revizyon gerektiren PJF hastalarının öyküsünde nörolojik komorbidite olması anlamlı bulunmuştur[99].

Bizim çalışma grubumuzun büyük bir çoğunluğu adölesan dönem hastalar olduğu için kemik mineral dansite ölçümü yapılmamıştır. Hastalara sistemik ek hastalıklar soruldu ve not edildi. Bu ek hastalıkların PJK gelişimiyle ilişkisi bulunamadı.

5.2.5. Sigara Kullanımı

Sigaranın kemik kaynama süreçlerini belirgin olarak etkilediği bilinmektedir. Spinal füzyon uygulanan hastalarda özellikle psödoartroz riskini artırdığı ayrıca raporlanmıştır[100].

Ancak sigara kullanımının PJK gelişim riskini artırmadığını savunan yayınlar vardır. Kim ve ark. nın iki ayrı çalışmasında sigara kullanımının PJK gelişimi için bir risk faktörü olmadığı bildirilmiştir[68, 90].

Bizim çalışmamızda sigara kullanımın PJK gelişim riskiyle anlamlı bir ilişkisinin olmadığını bulduk.

5.3. Radyografik Risk Faktörlerinin Yorumlanması

PJK gelişimi açısından risk faktörü olarak literatürde birçok radyografik parametre üzerinde durulmuştur. Özellikle TK, SVA ve SPP bunlardan bazılarıdır.

Kim ve ark. nın 2005 yılında yaptığı çalışmada ameliyat öncesi büyük TK'nin PJK gelişim riskini artırdığı gösterilmiştir[88]. Düzeltme büyüklüğü arttıkça yapı sertliğini artırdığı söylenebilir.

Park ve ark. nın 2017 tarihli çalışmasında ameliyat öncesi yüksek SVA değerlerinin PJK gelişim riskini artırdığı bildirilmiştir[95].

Çalışmamızda ameliyat öncesi PT değerinin düşük olmasının PJK'ye karşı koruyucu olduğunu bulduk. Bu retrovert pelvislerin PJK gelişim riskini azalttığı yönünde yorumlanabilir ve ameliyat öncesi planlamada bu parametreye dikkat edilmelidir.

5.4. Cerrahi Nedenli Risk Faktörlerinin Yorumlanması

PJK gelişimi etiyolojisinde cerrahi yaklaşım önemlidir. Özellikle posterior yaklaşımlarda posterior elemanların zarar görmesi nedeniyle PJK gelişim riski artmaktadır.

Kim ve ark. nın bir çalışmasında anterior ve posterior kombine yaklaşımlar bir risk faktörü olarak tanımlanmıştır[58].

Yagi ve ark. nın bir çalışmasında spinal enstrümantasyon girişimlerinde posterior yaklaşım bir risk faktörü olarak bulunmuştur[50].

5.4.1. Posterior Elemanların Diseksiyonu

Cammarata ve ark. nın 2014 yılında yaptığı biyomekanik bir çalışmada posterior elemanlarının farklı şekilde diseksiyon prosedürleri, UIV seviyesindeki implant çeşidi, sagital rod eğimi, proksimal bölgedeki geçiş rodunun kalınlığı gibi değişkenler PJK gelişimi açısından değerlendirilmiştir. Proksimal posterior yapıların iyi korunmasının, proksimal bölgede geçiş rodu ve transvers proçes kancası kullanımının, global sagital rod eğimini azaltmanın; PJA, TK, proksimal fleksiyon güç ve momentini azalttığı gösterilmiştir[62].

Uluslararası omurga çalışma grubunun 2016 yılında yayınlanan bir makalesinde minimal invazif yaklaşımların PJK oranını değiştirmediği bildirilmiştir[101].

Posterior vertebral bağlar, faset eklemler ve paraspinal kasların dik bir omurga üzerindeki etkisi yadsınamaz. Cerrahi nedenli posterior elemanların hasarı PJK gelişimi açısından güçlü bir risk faktörü olarak görünmektedir. Bu nedenle özellikle UIV seviyesindeki faset eklemlerin korunmasını, posterior bağ ve paraspinal kasların nazik diseksiyonunu öneriyoruz.

5.4.2. İmplant Özellikleri

Omurga deformite cerrahisinde kullanılan implantların çeşidi, implantın yapıldığı malzeme, rod ve vida çapı ile rodun konturu gibi bazı özellikler enstrüman sertliğiyle yakından ilişkilidir. Enstrüman sertliğinin PJK gelişimi üzerindeki etkisi ise açıktır.

PJK gelişim riskinin pedikül vidalarının büyük oranda kullanıldığı yapılarda önemli derecede arttığı ancak klinik önemi üzerinde etkisinin açık olmadığı yapılan çalışmalarda gösterilmiştir[88, 102]. Sadece vida kullanılan vakalarda sert bir omurga yapısının oluştuğu ve posterior proksimal bölgeden fleksiyon açlığının giderilerek PJK geliştiği düşünülebilir. Olası bir çözüm olarak; UIV seviyesinde kanca veya sublaminar metalik tel kullanımı yapının sertliğini önemli ölçüde azaltarak ve geçiş bölgesindeki posterior gergin yapıları koruyarak PJK gelişim riski azaltılabilir[102, 103].

Wang ve ark. nın 2010 tarihli bir çalışmasında UIV'de pedikül vida kullanımının artmış PJK riskiyle ilişkili olduğu gösterilmiştir[60].

Liu ve ark. 2016 tarihli çalışmalarında UIV'de pedikül vida kullanımının PJK riskini artırdığını raporlamıştır[93].

Lonner ve ark. nın 2017 yılında yaptığı çalışmada azaltılmış rod kontürünün PJK gelişim riskini artırdığı bulunmuştur[104].

Han ve ark. nın 2017 yılında yayınlanan çalışmasında krom-kobalt ve titanyum alaşımdan yapılmış rodların PJK gelişimi üzerindeki etkisi araştırılmış ve krom-kobalt rodların implant kırılmasına karşı koruyucu olmasına rağmen PJK gelişimine zemin hazırladığı bildirilmiştir[105].

Bizim hastalarımızda sadece vida fiksasyonu kullanılmış olup buna rağmen PJK oranımız (%27.2) literatürdeki PJK oranlarıyla benzerdir [50, 57, 70, 106].

Hastalarımızın 42'sinde (%63) 6mm çapında kalın rod kullanılmış olup PJK gelişimiyle belirgin bir ilişkisi saptanmamıştır.

5.4.3. UIV, LIV Seçimi ve Entrüman Seviyesi

UIV ve LIV seçiminin PJK gelişimi üzerindeki etkisini tartışan yayınlar vardır.

Denis ve ark. nın 2009 tarihli çalışmasında uygun UIV ve LIV seçiminin PJK riskini azaltabileceğini göstermişlerdir[70].

Bridwell ve ark. nın 2013 yılındaki çalışmasında kısa entrüman seviyeleri ve düşük LIV seviyelerinin PJK riskini artırdırdığı gösterilmiştir[66].

Cho ve ark. nın 2014 yılında yaptığı sistematik derleme çalışmasında ikinci lomber vertebra distalinde UIV seçiminin PJK'yle ilişkili bir risk faktörü olduğunu bildirmişlerdir[96].

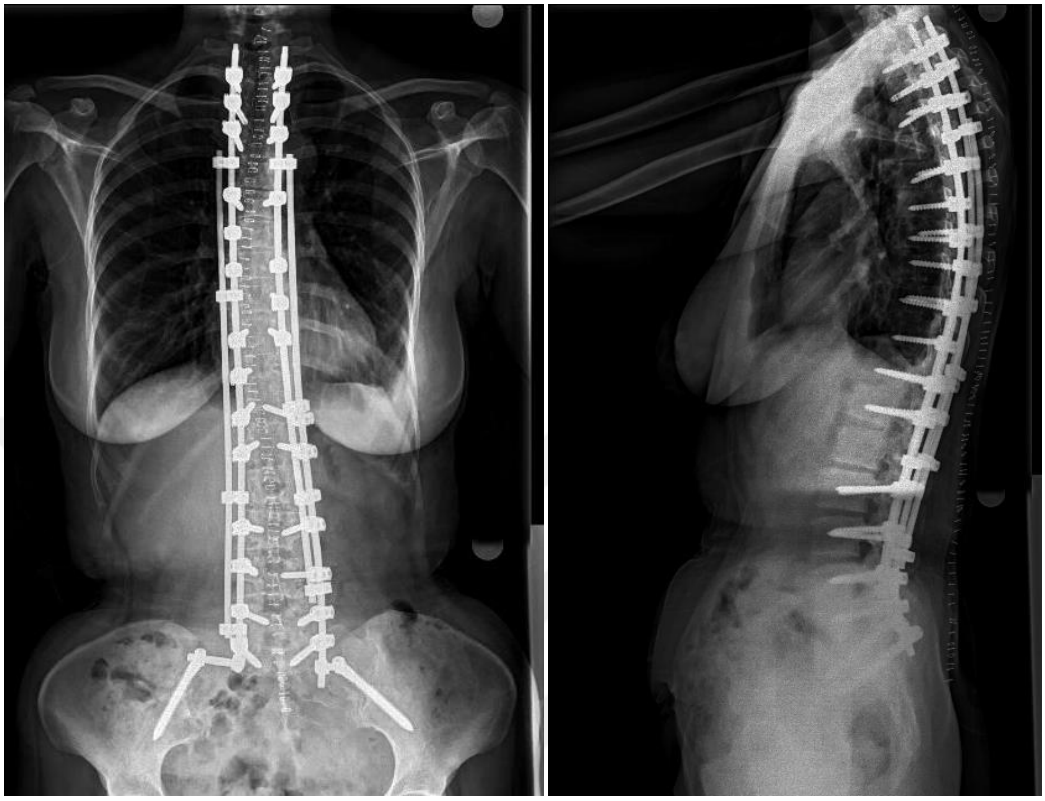
Wang ve ark. nın 2016 tarihli dejeneratif lomber skolyoz hastaları üzerinde yapmış olduğu çalışmada torakolomber seviyesinde seçilen UIV'nin PJK gelişim riskini artırdığı rapor edilmiştir[94].

Lonner ve ark. 2017 yılında yaptıkları çalışmasında PJK gelişimi açısından UIV seviyesinin önenmine dikkat çekilmiştir[104].

Lee ve ark. nın lomber dejeneratif kifoz hastaları üzerinde yapmış olduğu bir çalışmada ikinci lomber vertebranın altında kalmış UIV seviyeleriyle PJK gelişim riskinin arttığı gösterilmiştir[91].

Buell ve ark. nın yakın tarihli bir çalışmada distal torasik yerleşimli UIV seçiminin PJK riskini artırdığı raporlanmıştır[107].

5.4.4. Sakropelvik Füzyon



Şekil 25. Sakrum ve iliak kanat füzyonu yapılmış bir hastamızın tam boy ön-arka ve yan grafileri

Sakrum ve ililak kanat enstrümantasyonu implantı daha alt seviyelere taşımakla beraber daha sert bir yapı oluşturur. Bu durum literatürde sıklıkla PJK gelişimiyle ilişkilendirilmiştir.

Kim ve ark. nın 2012 yılında yaptığı çalışmada sakrum füzyonun PJK gelişim riskini artırdığını bildirmişlerdir[59].

Yagi ve ark nın 2011 ve 2012 tarihli iki ayrı çalışmasında da benzer olarak sakrum füzyonunun PJK gelişimi için bir risk faktörü olduğu raporlanmıştır[50, 65].

Bridwell ve ark. nın 2013 tarihli çalışmasında sakrum füzyonun revizyon gerektiren PJK riskini artırdığını bildirmişlerdir[66].

Maruo ve ark. nın aynı tarihli çalışmasında tamamına sakrum füzyonu uygulanmış hastaların iki yıllık takiplerinde PJK gelişim oranının %41 olduğunu yayınlamışlardır[67].

Park ve ark. nın 2017 yılında yayınlanan çalışmasında sakrum füzyonlu hastalarda PJK riskinin arttığı gösterilmiştir[95].

Bizim hastalarımızdan yalnızca birine sakropelvik füzyon yapılmış olup PJK gelişimi izlenmemiştir.

5.4.5. Deformitenin Aşırı Düzeltilmesi

Omurga deformitesinde amaç tam düzeltme yerine optimal düzeltme olmalıdır. Aşırı düzeltmeler sert bir yapı oluşturarak PJK ve PJF riskini artırabilir. Literatürde bu konu çokça çalışılmış olup aşırı düzeltmenin PJK ve PJF riskini artırdığı bildirilmiştir.

Kim ve ark. nın 2007 tarihli çalışmasında ameliyat sonrası TK farkının PJK gelişim riskini artırdığı raporlanmıştır[89].

Yagi ve ark. nın 2011 ve 2012 yılındaki çalışmalarında GSD ve SVA değişimlerinin PJK riskini önemli ölçüde artırdığı yayınlanmıştır[50, 65].

Yagi ve ark. nın 2014'deki çalışmasında aşırı SVA değişimlerinin ve aşırı düzeltmelerin PJK gelişim riskini artırdığı raporlanmıştır[51].

Kim ve ark. nın 2012 yılında yaptığı çalışmada ameliyat sonrası hipokifoz ve hiperkifoz durumlarının PJK riskini artırdığı gösterilmiştir[59].

Maruo ve ark. nın 2013 tarihli çalışmasında optimal sagital dizilim başarımının PJK gelişim riskine karşı koruyucu olduğu yayınlanmıştır[67].

Yine Kim ve ark. nın 2014 yılındaki çalışmasında büyük SVA değişimlerinin PJK revizyon oranlarını artırdığı raporlanmıştır[68].

Cho ve ark. nın 2014 tarihli çalışmasında uygunsuz GSD restorasyonunun PJK gelişim riskini artırdığı gösterilmiştir[96].

Liu ve ark. nın 2016 tarihli çalışmasında SVA farkının beş cm üzerinde olan hastalarda PJK gelişim riskinin arttığı bildirilmiştir[93].

Hyun ve ark. nın 2016'daki çalışmasında SVA'nın aşırı düzeltildiği hastalarda PJK gelişim riskinin arttığı gösterilmiştir[97].

Lonner ve ark. nın 2017'de yayınlanan bir çalışmasında ameliyat öncesi yüksek TK ve ameliyat sonrası yüksek değerlerde kifoz kaybının PJK gelişim riskini artırdığı gösterilmiştir[104].

Bu yayınlarla ters bir bulguya sahip olan Kim ve ark. nın 2008 yılındaki çalışmasında SVA değişikliklerinin PJK gelişimiyle ilişkisi bulunamamıştır[58].

Biz çalışmamızda ameliyat öncesi ve ameliyat sonrası SVA ve TK farkının PJK gelişimiyle yakından ilişkili olduğunu bulduk.

5.5. Diğer

Wang ve ark. nın 2010 yılında yaptıkları çalışmada otojen kemik greftinin PJK gelişim riskini artırdığı raporlanmıştır[60]. Bizim hastalarımızın tamamında otojen kemik grefti kullanılmıştır.

Park ve ark. nın 2017 tarihli bir çalışmasında PJK ve PJF risk faktörleri ayrı ayrı ele alınmış, PJK'nın ortalama 17 ayda, PJF'nin ortalama üç ayda geliştiği raporlanmıştır. Yine PJK için VKE'nin yüksekliği bağımsız bir risk faktörü olarak belirlenmiştir. PJF risk faktörleri olarak; yüksek yaş, osteoporoz, torakolomber bölgedeki UIV seviyeleri ve preoperatif yüksek SVA değerleri olarak sıralanmıştır[95].

PJK'dan korunmak için kesin bir yöntem tanımlanmamış olmasına rağmen Lau ve ark. nın çalışmasında bazı öneriler vardır. Bunlar; beş dereceden büyük Cobb açısına sahip segmental kifoz seviyelerinin enstrümantasyona dahil edilmesi, implant sertliğini azaltmak, kompozit materyal seçimi, daha az implant kullanmak, daha distalden yapılan osteotomileri tercih etmek, UIV seviyesinde yumuşak dokulara zarar vermemek için daha dikkatli olmak, optimal spinal dengeyi sağlamak, geçiş rodları kullanmak ve ameliyat sonrası sagital dizilimi optimize etmek olarak sıralanmıştır[63].

YZ teknolojisinin tüm imkan ve vaatlerine rağmen zorlu engeller ve tuzaklar halen varlığını sürdürüyor. Sadece öğretileni bilmesi, YZ ve MÖ yöntemlerinin öngördüğü tedavi algoritmalarının doğruluğu, insani duyguların olmaması, uygun bir denetimci

gerekliliği ve yaratıcı düşüncenin olmayışı YZ uygulamalarındaki kısıtlamalardan bazılarıdır[13]. Daha vahim bir senaryoda, YZ hastaya zarar verecek yanlış tanı ve tedavi önerilerinde bulunabilir.

Bunun son örneklerinden birisi IBM şirketinin Watson kanser algoritmasıydı. "Watson for oncology" olarak da bilinen algoritma dünya çapında yüzlerce sağlık merkezinde onkologlardan gelen gerçek olmayan hasta örnekleri kısıtlı verilerle kanser hastaları için tedavi önerilerinde kullanılmaktaydı. Ancak bir takım hastada kontrendike olmasına rağmen bevacizumab tedavisi gibi hatalı önerilerde bulundu[26]. Bu örnekte olduğu gibi, tek bir doktorun yapacağı hatanın bir hasta üzerinde zararı olacağı buna karşın bu tür algoritmaların yapacağı hatalar sonucunda birçok hastanın zarar görebileceği bilinmelidir.

İnsani olarak en büyük korkumuz YZ'nin bizden zeki olup hayatlarımız üzerindeki kontrolü ele alması olabilir. Ancak sınırlarını kendimizin çizdiği, etik çerçeve oluşturabileceğimiz bir alanda bu korku yersizdir.

Sadece başlangıç eğitimi için değil, YZ algoritmalarının gelişimi ve değerli sonuçlar üretmesi için de sürekli bir veri akışı gereklidir. Geniş çaplı YZ çalışmaları için verilerin birden fazla kuruluş hatta birden fazla ülke arasında paylaşılması önem arz etmektedir. Uluslararası ölçeği de düşünecek olursak verilerin kolayca anlaşılabilip uygulanması için anonimleştirme ve yeniden kimliklendirme gerekebilir.

Mevcut sağlık ortamı veri paylaşımını pek teşvik etmektededir. Ancak toplu sonuç üzerinden ücretlendirme modelli sağlık reformlarıyla değişebilir. Bu modeller sağlık uygulayıcılarını bilgi akışı ve paylaşımı için daha fazla teşvik edecektir[7].

Verilerin ve YZ algoritmalarının şeffaflığı büyük endişe konusudur. Şeffaflık birden fazla düzeyde geçerlidir. İlk olarak, denetimli öğrenme durumu tahminlerin doğruluğu ağırlıklı olarak ek açıklama girişlerinin doğruluğuna dayanır. Dolayısıyla zayıf etiketlenmiş veriler zayıf sonuçlara sebep olacaktır. Bunun için verilerin şeffaflığı özellikle denetimli öğrenme gibi insan dahlinin bulunduğu algoritmalarda önem kazanmaktadır. YZ teknolojisinde şeffaflığın öneminin bir başka nedeni algoritmik olarak, ırk, cinsiyet ve diğer ayırıcı özelliklere karşı yanlı sonuçlara eğilimli olmasıdır[108].

Sağlık hizmetindeki doktorlar ve diğer sağlık personeli hasta güvenliğini sağlamak için şeffaflığa önem vermelidirler[109].

YZ sistemleri karmaşık tahmin edilemez öğrenme süreçleri ve insan-makine etkileşimi gibi durumlardan ötürü güvenlik sorunlarıyla karşı karşıya kalabilir. Bu durumda hesap verilebilirlik önemli bir konu olarak karşımıza çıkmaktadır. Örneğin YZ algoritmasının önerdiği bir tedavi sonucu hasta zarar görürse sorumlusu kim olacaktır? YZ teknolojilerinin yaygınlaşması durumu hekimler üzerindeki sorumluluk duygusunun zayıflamasına neden olabilir.

Diğer alanlar düşünülürse sağlık verilerinin oldukça heterojen olduğu bilinmektedir[110]. Bu sebeple karmaşıklığı azaltmak için verilerin standart hale getirilmesi YZ uygulamaları açısından oldukça önemlidir. Bu nedenle verilerin standart hale getirilmesi veriyi farklı araç ve yöntemler kullanılınca dahi anlaşılabilir genel bir formata dönüştürmeyi tanımlar.

Tüm sağlık görevlilerinin tıpta YZ uygulama süreçlerine aktif olarak dahil olmaları gerekmektedir. YZ konusunda elde edilecek faydaların ve sınırların farkındalığı sağlanmalıdır. Tıp fakültesi müfredatları, sağlık verileri, bilgisayar bilimleri ve istatistik konusunda güncellenmelidir.

YZ uygulamaları verimliliği artırmak ve sonuçları iyileştirmek için ümit vaat edici olsalar da unutulmamalıdır ki tıpkı yaratıcısı olan insanlar gibi kusursuz değildirler. Bu uygulamaları, sınırlarını göz önünde tutarak eleştirel bir yaklaşımla değerlendirmek ve uygulamak gerekir[109].

Sürücüsüz araçlar üzerinde yapılan bir çalışmada görüldü ki YZ'nin tam özerkliği araçların güvenli kullanımını engelleyeceği için asla kabul edilemez[111]. İnsan sağlığı gibi daha hassas ve zarar toleransının az olduğu bir konuda daha temkinli olunması gerektiği açıktır.

YZ tarafından sağlık işgücünün toptan yer değiştirmesi korkusu vardır. Ancak YZ dönüşümünün fırsatlarını ve maliyetini göz önünde bulundursak ve YZ uygulamalarını sağlık sistemlerine parça parça uygularsak bu korku garanti altına alınabilir[112].

6.SONUÇ VE ÖNERİLER

PJK gelişimine neyin neden olduğu yıllardır yanıtlanmaya çalışılan bir sorudur. Bu sorunun olası yanıtı olabilecek çeşitli parametreleri MÖ yöntemleri kullanarak değerlendirdik. Bu yönüyle çalışmamız bu alanda yapılan ilk çalışmadır. Operasyon sonrası PJA, literatürün de sıklıkla üzerinde durduğu bir PJK risk faktörü olup uyarıcı görevi görmektedir. Erken PJA artışlarında PJK gelişimini engelleyecek tedavileri belirlemek için çalışmalara ihtiyaç vardır. Özellikle operasyon esnasında erken açı artışının önüne geçmek için posterior yumuşak dokulara oldukça özen gösterilmelidir.

PJK gelişimini önlemek için ameliyat öncesi planlamada SVA iyi değerlendirilmeli ve tam düzeltme yerine optimal düzeltme tercih edilmelidir. Aşırı SVA farkının PJK gelişimiyle yakın ilişkili olduğu göz önünde bulundurulmalıdır. Bu nedenle aşırı SVA değişimlerinden uzak durulmalıdır.

Ameliyat sonrası SRS-22r gibi anketlerin PJK gelişimiyle ilişkisinin yetersiz olduğu bilinmeli ve PJK gelişimi açısından hastanın ağrısız ve yaşam kalitesinin iyi oluşuna aldanılmamalıdır. Bu anketlerin özellikle PJK geliştikten sonra revizyona gidecek hastaları ayırmakta kullanılabilecek gereçler olduğu bilinmelidir. Bu yönüyle hasta ağrısız olsa bile rutin kontrollerinde tam boy omurga grafileri istenmeli ve olası bir PJK vakası atlanmamalıdır.

TK Cobb açısının ameliyat öncesi değerlendirmede önemli olduğu bilinmeli ve aşırı düzeltmelerden kaçınılmalıdır. Yine PJK gelişimini engellemek için tam düzeltme yerine optimal düzeltme düşünülmelidir.

SP'lerin sagital omurga dizilimi üzerinde etkisinin önemli olduğu açıktır. Bu nedenle omurga deformite düzeltmesi yapılacak her hastanın SP'leri kaydedilmeli ve düzeltme planlamasında kullanılmalıdır. Çalışmamızda bulduğumuz PT ile PJK ters ilişkisinin, antevert pelvislerde yerçekimi çizgisinin omurga arkasından seyri nedeniyle baş için fleksiyona kayma meylini azalttığı ve PJK gelişimini önlediğini düşünmekteyiz.

PJK gelişim nedeni olarak bir veya birkaç parametrenin üzerinde yoğunlaşmak anlamsız olabilir. Hasta özelinde gelişen şartlar sonucu parametrelerin PJK gelişimi

üzerindeki etkisi önemli ya da önemsiz olabilmektedir. PJK multifaktöryel bir etiyolojiye sahip olup en sık etiyolojik parametreyi belirleyebilmek için çok merkezli homojen hasta grupları üzerinde daha fazla çalışmaya ihtiyaç vardır.

Çalışma grubumuz az hasta içermesine rağmen yaş, cinsiyet, tanı gibi özellikler açısından homojendi ve daha önemlisi MÖ algoritmaları literatürle benzer tahminlerde bulundu. MÖ, daha büyük hasta grupları üzerinde şüphesiz daha etkili çalışacaktır. Ortopedi kliniğinin yoğun mesailerini düşünecek olursak MÖ algoritmaları ortopedistlere hastaların tanı, tedavi ve prognozunda büyük yardımlar sağlayabilir.

Çok merkezli daha büyük hasta gruplarını içeren açık erişimli YSA algoritmaları sayesinde hastaların tanı ve tedavi süreçlerinde işgücünün doğru kullanımı sayesinde maliyet-etkinliğin çok daha iyi olduğu bir sağlık sistemi inşa edilebilir.

7.KAYNAKLAR

1. Diebo, B.G., et al., *Adult spinal deformity.* The Lancet, 2019. **394**(10193): p. 160-172.
2. Atun, R., *Transitioning health systems for multimorbidity.* The Lancet, 2015. **386**(9995): p. 721-722.
3. Kocher, R. and N.R. Sahni, *Rethinking health care labor.* N Engl J Med, 2011. **365**(15): p. 1370-1372.
4. Badawi, O., et al., *Making big data useful for health care: a summary of the inaugural mit critical data conference.* JMIR medical informatics, 2014. **2**(2): p. e22.
5. Goodfellow, I., Y. Bengio, and A. Courville, *Deep learning*. 2016: MIT press.
6. Murdoch, T.B. and A.S. Detsky, *The inevitable application of big data to health care.* Jama, 2013. **309**(13): p. 1351-1352.
7. Jiang, F., et al., *Artificial intelligence in healthcare: past, present and future.* Stroke and vascular neurology, 2017. **2**(4): p. 230-243.
8. Wang, D., et al., *Deep learning for identifying metastatic breast cancer.* arXiv preprint arXiv:1606.05718, 2016.
9. Panch, T., P. Szolovits, and R. Atun, *Artificial intelligence, machine learning and health systems.* Journal of global health, 2018. **8**(2).
10. Theofilatos, K., et al., *Predicting protein complexes from weighted protein-protein interaction graphs with a novel unsupervised methodology: Evolutionary enhanced Markov clustering.* Artif Intell Med, 2015. **63**(3): p. 181-9.
11. Haleem, A. and M. Javaid, *Industry 5.0 and its applications in orthopaedics.* J Clin Orthop Trauma, 2019. **10**(4): p. 807-808.
12. Olczak, J., et al., *Artificial intelligence for analyzing orthopedic trauma radiographs.* Acta Orthop, 2017. **88**(6): p. 581-586.
13. Haleem, A., et al., *Artificial Intelligence (AI) applications in orthopaedics: an innovative technology to embrace.* Journal of Clinical Orthopaedics & Trauma, 2020. **11**: p. S80-S81.
14. Kim, H.J. and S. Iyer, *Proximal Junctional Kyphosis.* J Am Acad Orthop Surg, 2016. **24**(5): p. 318-26.
15. McCarthy, J., et al., *A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955.* AI magazine, 2006. **27**(4): p. 12-12.
16. Topol, E.J., *High-performance medicine: the convergence of human and artificial intelligence.* Nat Med, 2019. **25**(1): p. 44-56.
17. Ramesh, A.N., et al., *Artificial intelligence in medicine.* Ann R Coll Surg Engl, 2004. **86**(5): p. 334-8.
18. Needham, J., D. Kuhn, and T.-h. Tsien, *Science and Civilisation in China: Vol. 4, Physics and Physical Technology; Pt. 2, Mechanical Engineering*. 1965: Cambridge University Press.
19. Turing, A., *Can a machine think? in, newman, jr the world of mathematics. vol. iv*. 1956, New York: Simon and Schuster, Inc.
20. Hamet, P. and J. Tremblay, *Artificial intelligence in medicine.* Metabolism, 2017. **69S**: p. S36-S40.
21. Mnih, V., et al., *Human-level control through deep reinforcement learning.* Nature, 2015. **518**(7540): p. 529-533.
22. Silver, D., et al., *Mastering the game of Go with deep neural networks and tree search.* Nature, 2016. **529**(7587): p. 484-489.

23. Russakovsky, O., et al., *Imagenet large scale visual recognition challenge.* International journal of computer vision, 2015. **115**(3): p. 211-252.
24. Hu, J., L. Shen, and G. Sun. *Squeeze-and-excitation networks*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
25. Aliper, A., et al., *Deep Learning Applications for Predicting Pharmacological Properties of Drugs and Drug Repurposing Using Transcriptomic Data.* Molecular Pharmaceutics, 2016. **13**(7): p. 2524-2530.
26. Luechtefeld, T., et al., *Machine learning of toxicological big data enables read-across structure activity relationships (RASAR) outperforming animal test reproducibility.* Toxicological Sciences, 2018. **165**(1): p. 198-212.
27. Tang, A., et al., *Canadian Association of Radiologists white paper on artificial intelligence in radiology.* Canadian Association of Radiologists Journal, 2018. **69**(2): p. 120-135.
28. Bera, K., et al., *Artificial intelligence in digital pathology—new tools for diagnosis and precision oncology.* Nature reviews Clinical oncology, 2019. **16**(11): p. 703-715.
29. LeCun, Y., Y. Bengio, and G. Hinton, *Deep learning.* Nature, 2015. **521**(7553): p. 436-444.
30. Steimann, F., *On the use and usefulness of fuzzy sets in medical AI.* Artificial intelligence in medicine, 2001. **21**(1-3): p. 131-137.
31. McCulloch, W.S. and W. Pitts, *A logical calculus of the ideas immanent in nervous activity. 1943.* Bull Math Biol, 1990. **52**(1-2): p. 99-115; discussion 73-97.
32. Rosenblatt, F., *The perceptron: a probabilistic model for information storage and organization in the brain.* Psychol Rev, 1958. **65**(6): p. 386-408.
33. Gunn, A., *The diagnosis of acute abdominal pain with computer analysis.* Journal of the Royal College of Surgeons of Edinburgh, 1976. **21**(3): p. 170.
34. Pesonen, E., et al., *Diagnosis of acute appendicitis in two databases. Evaluation of different neighborhoods with an LVQ neural network.* Methods of information in medicine, 1998. **37**(01): p. 59-63.
35. Boon, M.E., L. Kok, and J. Under, *Neural network processing can provide means to catch errors that slip through human screening of Pap smears.* Diagnostic cytopathology, 1993. **9**(4): p. 411-416.
36. Baxt, W.G., *Use of an artificial neural network for data analysis in clinical decision-making: the diagnosis of acute coronary occlusion.* Neural computation, 1990. **2**(4): p. 480-489.
37. Baxt, W.G. and J. Skora, *Prospective validation of artificial neural network trained to identify acute myocardial infarction.* The Lancet, 1996. **347**(8993): p. 12-15.
38. Stamey, T., et al., *Effectiveness of ProstAsure in detecting prostate cancer (PCa) and benign prostatic hyperplasia (BPH) in men age 50 and older.* J Urol, 1996. **155**(Suppl): p. 436A.
39. Ashizawa, K., et al., *Artificial neural networks in chest radiography: application to the differential diagnosis of interstitial lung disease.* Academic radiology, 1999. **6**(1): p. 2-9.
40. Lindsey, R., et al., *Deep neural network improves fracture detection by clinicians.* Proceedings of the National Academy of Sciences, 2018. **115**(45): p. 11591-11596.
41. Gale, W., et al., *Detecting hip fractures with radiologist-level performance using deep neural networks.* arXiv preprint arXiv:1711.06504, 2017.
42. Bar, A., et al. *Compression fractures detection on CT*. in *Medical Imaging 2017: Computer-Aided Diagnosis*. 2017. International Society for Optics and Photonics.
43. De Fauw, J., et al., *Clinically applicable deep learning for diagnosis and referral in retinal disease.* Nature medicine, 2018. **24**(9): p. 1342-1350.

44. Slomka, P.J., et al., *Cardiac imaging: working towards fully-automated machine analysis & interpretation.* Expert review of medical devices, 2017. **14**(3): p. 197-212.
45. Singh, R., et al., *Deep learning in chest radiography: detection of findings and presence of change.* PloS one, 2018. **13**(10): p. e0204155.
46. Nam, J.G., et al., *Development and validation of deep learning–based automatic detection algorithm for malignant pulmonary nodules on chest radiographs.* Radiology, 2019. **290**(1): p. 218-228.
47. Komorowski, M., et al., *The artificial intelligence clinician learns optimal treatment strategies for sepsis in intensive care.* Nature medicine, 2018. **24**(11): p. 1716-1720.
48. Hart, R., et al., *Identification of decision criteria for revision surgery among patients with proximal junctional failure after surgical treatment of spinal deformity.* Spine, 2013. **38**(19): p. E1223-E1227.
49. Hostin, R., et al., *Incidence, mode, and location of acute proximal junctional failures after surgical treatment of adult spinal deformity.* Spine, 2013. **38**(12): p. 1008-1015.
50. Yagi, M., A.B. King, and O. Boachie-Adjei, *Incidence, risk factors, and natural course of proximal junctional kyphosis: surgical outcomes review of adult idiopathic scoliosis. Minimum 5 years of follow-up.* Spine, 2012. **37**(17): p. 1479-1489.
51. Yagi, M., et al., *Characterization and surgical outcomes of proximal junctional failure in surgically treated patients with adult spinal deformity.* Spine, 2014. **39**(10): p. E607-E614.
52. Annis, P., et al., *Predictive factors for acute proximal junctional failure after adult deformity surgery with upper instrumented vertebrae in the thoracolumbar spine.* Evidence-based spine-care journal, 2014. **5**(02): p. 160-162.
53. Smith, M.W., et al., *Early proximal junctional failure in patients with preoperative sagittal imbalance.* Evidence-based spine-care journal, 2013. **4**(02): p. 163-164.
54. Watanabe, K., et al., *Proximal junctional vertebral fracture in adults after spinal deformity surgery using pedicle screw constructs: analysis of morphological features.* Spine, 2010. **35**(2): p. 138-145.
55. Kim, H.J., et al., *Perioperative Neurologic Complications in Adult Spinal Deformity Surgery: Incidence and Risk Factors in 564 Patients.* Spine, 2017. **42**(6): p. 420-427.
56. Yagi, M., et al., *Impact of Frailty and Comorbidities on Surgical Outcomes and Complications in Adult Spinal Disorders.* Spine, 2018. **43**(18): p. 1259-1267.
57. Glattes, R.C., et al., *Proximal junctional kyphosis in adult spinal deformity following long instrumented posterior spinal fusion: incidence, outcomes, and risk factor analysis.* Spine, 2005. **30**(14): p. 1643-1649.
58. Kim, Y.J., et al., *Proximal junctional kyphosis in adult spinal deformity after segmental posterior spinal instrumentation and fusion: minimum five-year follow-up.* Spine, 2008. **33**(20): p. 2179-2184.
59. Kim, H.J., et al., *Combined anterior-posterior surgery is the most important risk factor for developing proximal junctional kyphosis in idiopathic scoliosis.* Clinical Orthopaedics and Related Research®, 2012. **470**(6): p. 1633-1639.
60. Wang, J., et al., *Risk factor analysis of proximal junctional kyphosis after posterior fusion in patients with idiopathic scoliosis.* Injury, 2010. **41**(4): p. 415-420.
61. Rhee, J.M., et al., *Sagittal plane analysis of adolescent idiopathic scoliosis: the effect of anterior versus posterior instrumentation.* Spine, 2002. **27**(21): p. 2350-2356.
62. Cammarata, M., et al., *Biomechanical risk factors for proximal junctional kyphosis: a detailed numerical analysis of surgical instrumentation variables.* Spine, 2014. **39**(8): p. E500-E507.

63. Lau, D., et al., *Proximal junctional kyphosis and failure after spinal deformity surgery: a systematic review of the literature as a background to classification development.* Spine, 2014. **39**(25): p. 2093-2102.
64. Thawrani, D.P., et al., *Transverse process hooks at upper instrumented vertebra provide more gradual motion transition than pedicle screws.* Spine, 2014. **39**(14): p. E826-E832.
65. Yagi, M., K.B. Akilah, and O. Boachie-Adjei, *Incidence, risk factors and classification of proximal junctional kyphosis: surgical outcomes review of adult idiopathic scoliosis.* Spine (Phila Pa 1976), 2011. **36**(1): p. E60-8.
66. Bridwell, K.H., et al., *Proximal junctional kyphosis in primary adult deformity surgery: evaluation of 20 degrees as a critical angle.* Neurosurgery, 2013. **72**(6): p. 899-906.
67. Maruo, K., et al., *Predictive factors for proximal junctional kyphosis in long fusions to the sacrum in adult spinal deformity.* Spine, 2013. **38**(23): p. E1469-E1476.
68. Kim, H.J., et al., *Patients with proximal junctional kyphosis requiring revision surgery have higher postoperative lumbar lordosis and larger sagittal balance corrections.* Spine, 2014. **39**(9): p. E576-E580.
69. Mendoza-Lattes, S., et al., *Proximal junctional kyphosis in adult reconstructive spine surgery results from incomplete restoration of the lumbar lordosis relative to the magnitude of the thoracic kyphosis.* The Iowa orthopaedic journal, 2011. **31**: p. 199.
70. Denis, F., E.C. Sun, and R.B. Winter, *Incidence and risk factors for proximal and distal junctional kyphosis following surgical treatment for Scheuermann kyphosis: minimum five-year follow-up.* Spine, 2009. **34**(20): p. E729-E734.
71. Hollenbeck, S.M., et al., *The prevalence of increased proximal junctional flexion following posterior instrumentation and arthrodesis for adolescent idiopathic scoliosis.* Spine, 2008. **33**(15): p. 1675-1681.
72. Lee, G.A., et al., *Proximal kyphosis after posterior spinal fusion in patients with idiopathic scoliosis.* Spine, 1999. **24**(8): p. 795-799.
73. Fon, G.T., M.J. Pitt, and A.C. Thies Jr, *Thoracic kyphosis: range in normal subjects.* American Journal of Roentgenology, 1980. **134**(5): p. 979-983.
74. Kado, D.M., et al., *Comparing a supine radiologic versus standing clinical measurement of kyphosis in older women: the Fracture Intervention Trial.* Spine, 2006. **31**(4): p. 463.
75. De Smet, A.A., et al., *Spinal compression fractures in osteoporotic women: patterns and relationship to hyperkyphosis.* Radiology, 1988. **166**(2): p. 497-500.
76. Singer, K., T. Jones, and P. Breidahl, *A comparison of radiographic and computer-assisted measurements of thoracic and thoracolumbar sagittal curvature.* Skeletal radiology, 1990. **19**(1): p. 21-26.
77. Le Huec, J.C., et al., *Pelvic parameters: origin and significance.* European spine journal : official publication of the European Spine Society, the European Spinal Deformity Society, and the European Section of the Cervical Spine Research Society, 2011. **20 Suppl 5**(Suppl 5): p. 564-571.
78. Dubousset, J., *Le bassin «os intercalaire».* Monographie du GES, 1984: p. 15-22.
79. During, J., et al., *Toward standards for posture. Postural characteristics of the lower back system in normal and pathologic conditions.* Spine, 1985. **10**(1): p. 83-87.
80. Legaye, J., et al., *Pelvic incidence: a fundamental pelvic parameter for three-dimensional regulation of spinal sagittal curves.* European Spine Journal, 1998. **7**(2): p. 99-103.
81. Rose, P.S., et al., *Role of Pelvic Incidence, Thoracic Kyphosis, and Patient Factors on Sagittal Plane Correction Following Pedicle Subtraction Osteotomy.* Spine, 2009. **34**(8): p. 785-791.

82. Vialle, R., et al., *Radiographic Analysis of the Sagittal Alignment and Balance of the Spine in Asymptomatic Subjects.* JBJS, 2005. **87**(2): p. 260-267.
83. Koller, H., et al., *Cervical Spine Surgery: Standard and Advanced Techniques: Cervical Spine Research Society-Europe Instructional Surgical Atlas*. 2019: Springer.
84. Schwab, F., et al., *Sagittal plane considerations and the pelvis in the adult patient.* Spine, 2009. **34**(17): p. 1828-1833.
85. Lafage, R., et al., *Virtual modeling of postoperative alignment after adult spinal deformity surgery helps predict associations between compensatory spinopelvic alignment changes, overcorrection, and proximal junctional kyphosis.* Spine, 2017. **42**(19): p. E1119-E1125.
86. Radovanovic, I., et al., *Influence of postoperative sagittal balance and spinopelvic parameters on the outcome of patients surgically treated for degenerative lumbar spondylolisthesis.* Journal of Neurosurgery: Spine, 2017. **26**(4): p. 448-453.
87. Im, S.-K., et al., *Proximal Junctional Kyphosis in Degenerative Sagittal Deformity after Under-and Overcorrection of Lumbar Lordosis: Does Overcorrection of Lumbar Lordosis Instigate PJK?* Spine, 2020. **45**(15): p. E933-E942.
88. Kim, Y.J., et al., *Proximal junctional kyphosis in adolescent idiopathic scoliosis following segmental posterior spinal instrumentation and fusion: minimum 5-year follow-up.* Spine, 2005. **30**(18): p. 2045-2050.
89. Kim, Y.J., et al., *Proximal junctional kyphosis in adolescent idiopathic scoliosis after 3 different types of posterior segmental spinal instrumentation and fusions: incidence and risk factor analysis of 410 cases.* Spine, 2007. **32**(24): p. 2731-2738.
90. Kim, H.J., et al., *Proximal junctional kyphosis results in inferior SRS pain subscores in adult deformity patients.* Spine, 2013. **38**(11): p. 896-901.
91. Lee, J.-H., et al., *Analysis of the incidence and risk factors for the progression of proximal junctional kyphosis following surgical treatment for lumbar degenerative kyphosis: minimum 2-year follow-up.* British journal of neurosurgery, 2014. **28**(2): p. 252-258.
92. Vedantam, R., et al., *Comparison of standing sagittal spinal alignment in asymptomatic adolescents and adults.* Spine, 1998. **23**(2): p. 211-215.
93. Liu, F.-Y., et al., *Incidence and risk factors for proximal junctional kyphosis: a meta-analysis.* European Spine Journal, 2016. **25**(8): p. 2376-2383.
94. Wang, H., et al., *Incidence and risk factors for the progression of proximal junctional kyphosis in degenerative lumbar scoliosis following long instrumented posterior spinal fusion.* Medicine, 2016. **95**(32).
95. Park, S.-J., et al., *Different risk factors of proximal junctional kyphosis and proximal junctional failure following long instrumented fusion to the sacrum for adult spinal deformity: survivorship analysis of 160 patients.* Neurosurgery, 2017. **80**(2): p. 279-286.
96. Cho, S.K., J.I. Shin, and Y.J. Kim, *Proximal junctional kyphosis following adult spinal deformity surgery.* European Spine Journal, 2014. **23**(12): p. 2726-2736.
97. Hyun, S.-J., Y.J. Kim, and S.-C. Rhim, *Patients with proximal junctional kyphosis after stopping at thoracolumbar junction have lower muscularity, fatty degeneration at the thoracolumbar area.* The Spine Journal, 2016. **16**(9): p. 1095-1101.
98. Do Keun Kim, J.Y.K. and S.C.R. Do Yeon Kim, *Risk factors of proximal junctional kyphosis after multilevel fusion surgery: more than 2 years follow-up data.* Journal of Korean Neurosurgical Society, 2017. **60**(2): p. 174.
99. Arima, H., et al., *Neurologic comorbidities predict proximal junctional failure in adult spinal deformity.* Spine deformity, 2018. **6**(5): p. 576-586.

100. Berman, D., et al., *The effect of smoking on spinal fusion.* International journal of spine surgery, 2017. **11**(4).
101. *Does minimally invasive percutaneous posterior instrumentation reduce risk of proximal junctional kyphosis in adult spinal deformity surgery? A propensity-matched cohort analysis.* Neurosurgery, 2016. **78**(1): p. 101-108.
102. Helgeson, M.D., et al., *Evaluation of proximal junctional kyphosis in adolescent idiopathic scoliosis following pedicle screw, hook, or hybrid instrumentation.* Spine, 2010. **35**(2): p. 177-181.
103. Hassanzadeh, H., et al., *Type of anchor at the proximal fusion level has a significant effect on the incidence of proximal junctional kyphosis and outcome in adults after long posterior spinal fusion.* Spine Deformity, 2013. **1**(4): p. 299-305.
104. Lonner, B.S., et al., *Risk factors of proximal junctional kyphosis in adolescent idiopathic scoliosis—the pelvis and other considerations.* Spine deformity, 2017. **5**(3): p. 181-188.
105. Han, S., et al., *Rod stiffness as a risk factor of proximal junctional kyphosis after adult spinal deformity surgery: comparative study between cobalt chrome multiple-rod constructs and titanium alloy two-rod constructs.* The Spine Journal, 2017. **17**(7): p. 962-968.
106. Kim, H.J., et al., *Proximal junctional kyphosis as a distinct form of adjacent segment pathology after spinal deformity surgery: a systematic review.* Spine, 2012. **37**: p. S144-S164.
107. Buell, T.J., et al., *Alignment risk factors for proximal junctional kyphosis and the effect of lower thoracic junctional tethers for adult spinal deformity.* World neurosurgery, 2019. **121**: p. e96-e103.
108. Char, D.S., N.H. Shah, and D. Magnus, *Implementing machine learning in health care—addressing ethical challenges.* The New England journal of medicine, 2018. **378**(11): p. 981.
109. He, J., et al., *The practical implementation of artificial intelligence technologies in medicine.* Nat Med, 2019. **25**(1): p. 30-36.
110. Kruse, C.S., et al., *Challenges and opportunities of big data in health care: a systematic review.* JMIR medical informatics, 2016. **4**(4): p. e38.
111. Shladaver, S.E., *The truth about "self-driving" cars.* Scientific American, 2016. **314**(6): p. 52-57.
112. Panch, T., P. Szolovits, and R. Atun, *Artificial intelligence, machine learning and health systems.* J Glob Health, 2018. **8**(2): p. 020303.