



T.C. SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
BAKIRKÖY DR. SADİ KONUK SAĞLIK UYGULAMA VE ARAŞTIRMA MERKEZİ
RADYOLOJİ KLİNİĞİ

**Sakroiliak Eklemin inflamatuvar ve Dejeneratif Hastalıklarında Manyetik Rezonans
Radiomiks Analizi**

Dr. Melik Gazi BUZLUK

TIPTA UZMANLIK TEZİ

İSTANBUL 2024





T.C. SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
BAKIRKÖY DR. SADİ KONUK SAĞLIK UYGULAMA VE ARAŞTIRMA MERKEZİ
RADYOLOJİ KLİNİĞİ

**Sakroiliak Eklem'in inflamatuvar ve Dejeneratif Hastalıklarında Manyetik Rezonans
Radiomiks Analizi**

Dr. Melik Gazi BUZLUK

Tez Danışmanı:

Prof. Dr. Ercan İNCİ

TIPTA UZMANLIK TEZİ

İSTANBUL 2024



İÇİNDEKİLER

İÇİNDEKİLER.....	V
TEŞEKKÜR	VII
SİMGELER VE KISALTMALAR	VIII
TABLO LİSTESİ	IX
ŞEKİL LİSTESİ	X
ÖZET	11
ABSTRACT	12
GİRİŞ VE AMAÇ	13
1. AMAÇ.....	13
GENEL BİLGİLER.....	14
1. SAKROİLİAK EKLEM.....	14
2. SAKROİLİİT.....	14
3. ANKİLOZAN SPONDİLİT.....	15
3.1. Epidemiyoloji	15
3.2. Etiyoloji	15
3.3. Klinik Bulgular	15
3.4. Tanı ve Sınıflama	16
3.5. Klinik Kriterler	17
3.6. Laboratuvar Testleri	18
3.7. Görüntüleme bulguları	18
4. Sakroiliak Eklemde Dejeneratif Değişiklikler.....	22
5. Radiomiks.....	22
5.1. Görüntü Segmentasyonu	23
5.2. Tekstür Analizi	23
6. Makine Öğrenmesi.....	35
6.1. 1. Lojistik Regresyon (Logistic Regression)	36
6.2. 2. Destek Vektör Makineleri (SVM - Support Vector Machines).....	36
6.3. 3. Karar Ağaçları (Decision Trees)	36

6.4.	4. Rastgele Ormanlar (Random Forest)	37
6.5.	5. Naive Bayes.....	37
6.6.	6. K-En Yakın Komşu (KNN - k-Nearest Neighbors)	37
6.7.	7. Lineer Regresyon (Linear Regression).....	38
6.8.	8. Yapay Nöral Ağları (Artificial Neural Networks - ANN)	38
	Gereç ve Yöntemler	39
1.	Hasta Seçimi	39
2.	Görüntüleme protokolü	40
3.	Radiomics verilerinin hesaplanması	40
4.	Veri İşlenmesi ve Özellik Seçimi	41
	BULGULAR	42
1.	Hastaların Demografik Özellikleri	42
2.	Tekstür Analizinin İstatiksel Sonuçları.....	43
3.	Makine Öğrenmesi Sonuçları	49
3.1.	Ankilozan Spondilitli ve Kontrol Grubunun Makine Öğrenmesi Sonuçları	49
3.2.	Ankilozan Spondilit ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan Grubun Makine Öğrenmesi Sonuçları	51
3.3.	Kontrol Grubu ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan Grubun Makine Öğrenmesi Sonuçları	52
3.4.	Ankilozan Spondilit Grubu ile Diğer Grupların Karşılaştırılması	53
	VAKA ÖRNEKLERİ	55
1.	Vaka 1	55
2.	Vaka 2	56
3.	Vaka 3	57
	TARTIŞMA	58
	SONUÇ	61
	KAYNAKÇA	62

TEŞEKKÜR

Uzmanlık eğitimim boyunca bilgi ve tecrübelerinden her zaman faydalandığım, her konuda ilgisini, desteğini gördüğüm, mesleki gelişimime büyük katkıları olan, bilimin ışığında ilerlememiz için bize yol gösteren ve eğitim sorumlum ve tez danışmanım Prof. Dr. Ercan İnci'ye,

Uzmanlık eğitimim boyunca tecrübelerinden her zaman faydalandığım, eğitimime büyük katkıda bulunan Prof. Dr. Elif Hocaoglu'na saygı ve teşekkürlerimi sunarım

Kliniğimde birlikte çalışmaktan mutluluk duyduğum, bilgi ve tecrübelerini içtenlikle paylaşan, her konuda desteğini, ilgisini gördüğüm değerli hocalarım ve uzmanlarım Prof. Dr. Figen Palabıyık'a, Doç. Dr. Ayşegül Akdoğan Gemici'ye, Doç. Dr. Mustafa Orhan Nalbant'a Doç. Dr. Sema Aksoy'a, Uzm. Dr. Sinan Aygan'a, Dr. Orkun Civan'a Uzm. Dr. Fatma Çelik Yabul'a, Uzm. Dr. Derya Baş'a, ve Uzm. Dr. Süleyman Öncü'ye,

Girişimsel radyoloji ünitesinde birlikte çalıştığım, bilgi ve deneyimlerini içtenlikle paylaşan değerli hocalarım ve uzmanlarım Prof. Dr. Hatem Hakan Selçuk'a, Doç. Dr. Çağlayan Çakır'a, Uzm. Dr. Ömer Yıldız'a, Uzm. Dr. Fatih Kılınç'a,

Beraber çalıştığımız her andan mutluluk duyduğum, beraber emek harcadığımız ve bana her açıdan destek olan tüm asistan arkadaşlarıma,

Kliniğimizin tüm teknisyen, hemşire ve sağlık personeli çalışanlarına,

Bugünlere gelmemde emeği sonsuz ve her zaman yanımda olan sevgili anne ve babama,

Ve son olarak benden sevgisini desteğini hiçbir zaman esirgemeyen, düştüğümde ayağa kalkabilmemi sağlayan , varlığıyla beni hep mutlu eden bu satılar yazılırken daha doğmamış olan oğlumuzun annesi biricik eşim Dr. Tuğba Buzluk'a sonsuz teşekkür ederim

SİMGELER VE KISALTMALAR

BT	Bilgisayarlı Tomografi
SİE	Sakroiliak Eklem
MRG	Manyetik Rezonans Görüntüleme
NPD	Negatif Prediktif değer
PPD	Pozitif Prediktif Değer
ROC	Receiver operating characteristic
Sen.	Sensitivite
Spe.	Spesifite
ROI	Region of Interest
VOI	Volume of Interest
PCA	Principal Component Analysis
ASAS	The Assessment of SpondyloArthritis international Society
TE	Echo Time
TR	Repetition Time
NEX	Number of excitation

TABLO LİSTESİ

Tablo 1: The Assessment of SpondyloArthritis international Society (ASAS) Kriterleri.....	17
Tablo 2: Vakaların cinsiyet dağılımı.....	42
Tablo 3: Vakaların gruplara göre dağılım şeması.....	43
Tablo 4: Radiomiks parametrelerinin istatistiksel olarak karşılaştırılması.....	44
Tablo 5: Radiomiks parametrelerinden istatistiksel olarak anlamlı olanların önem sırası tablosu.....	49
Tablo 6: Ankilozan Spondilit ve Kontrol Grubu karşılaştırmasının makine öğrenmesi başarı metrikleri	50
Tablo 7: Ankilozan Spondilit ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan Grubu karşılaştırmasının makine öğrenmesi başarı metrikleri	51
Tablo 8: Ankilozan Spondilit ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan Grubu karşılaştırmasının makine öğrenmesi başarı metrikleri	52
Tablo 9: Ankilozan Spondilit Grubu ile Diğer Grupların Karşılaştırılmasının makine öğrenmesi başarı metrikleri	53

ŞEKİL LİSTESİ

Şekil 1 : Modifiye New York Kriterleri evrelemesi	20
Şekil 2: Histogram örnekleri.....	24
Şekil 3: GLCM Matrisinin Oluşturulması.....	25
Şekil 4: GLRLM Matrisinin Oluşturulması.....	27
Şekil 5: GLSZM Matrisinin Oluşturulması.....	30
Şekil 6: NGTDM Matrisinin Oluşturulması.....	34
Şekil 7: Akış Şeması	40
Şekil 8: Segmentasyon örneği.....	41
Şekil 9: Logistic Regression Modelinin test sonuçları.....	50
Şekil 10: KNN Modelinin test sonuçları.	52
Şekil 11: Logistic Regression Modelinin test sonuçları.....	53
Şekil 12: Neural Network Modelinin test sonuçları.....	54
Şekil 13: Vaka 1'in Makine Öğrenmesi Model Sınıfı.....	55
Şekil 14: Vaka 2'in Makine Öğrenmesi Model Sınıfı.....	56
Vaka 3: Vaka 3'in Makine Öğrenmesi Model Sınıfı.....	57

ÖZET

Amaç: Bu çalışmamızda sakroiliak eklem inflamatuar ve dejeneratif hastalıkların ayırımında makine öğrenmesi destekli radyomiks analizinin etkinliğinin araştırılması amaçlanmıştır.

Yöntem ve Gereçler : T.C. Sağlık Bakanlığı Sağlık Bilimleri Üniversitesi Bakırköy Dr. Sadi Konuk Eğitim ve Araştırma Hastanesi Radyoloji Kliniği'nde Ocak 2023 ve Haziran 2024 tarihleri arasında bel veya kalça ağrısı sebepli kontrastsız sakroiliak eklem MR görüntülemesi yapılan hastalar tarandı. Bu kriterlere uygun 95 hastadan 150 sakroiliak eklem için görüntüler elde edildi. 95 hasta ankilozan spondilit grubu, dejeneratif grup ve kontrol grubu olmak üzere 3 gruba ayrıldı. Bu görüntüler 3D Slicer programında segmente edildi ve segmente edilen alanlarda PyRadiomics kullanılarak radiomics verileri çıkarıldı. Toplam 93 radiomics verisinden istatistiksel çalışmalar yapılarak aralarında istatistiksel olarak anlamlı farklılık bulunan 14 özellik seçildi. Bu 14 özellik ile MatLab programında PCA işlevli ve işlevsiz 64 adet model oluşturuldu. Her bir grup diğer gruplarla ve her grup birlikte makine öğrenmesi kullanılarak karşılaştırıldı.

Bulgular: Ankilozan spondilit ve kontrol grubu karşılaştırmasında Logistic Regression bazlı makine öğrenmesi algoritması %96 doğruluk oranı ile en başarılı model oldu. Ankilozan Spondilit ve Dejeneratif grubu karşılaştırmasında KNN bazlı makine öğrenmesi algoritması %83 doğruluk oranı ile en başarılı model oldu. Dejeneratif Grup ile Kontrol Grubunun karşılaştırmasında Neural Network bazlı makine öğrenmesi algoritması %96 doğruluk oranı ile en başarılı model oldu. Ankilozan Spondilit ile diğer grupların karşılaştırmasında ise Neural Network bazlı makine öğrenmesi algoritması %93 doğruluk oranı ile en başarılı model idi.

Sonuç: Makine öğrenmesi destekli radiomics analizi sakroiliak eklem inflamatuar hastalıklarının dejeneratif hastalıklardan ayırımında yüksek doğruluk oranı ile etkinliğini göstermiştir.

Anahtar Kelimeler: Makine Öğrenmesi, Ankilozan spondilit, Manyetik Rezonans, Radiomics

ABSTRACT

Objective: This study aims to investigate the effectiveness of machine learning-assisted radiomics analysis in distinguishing inflammatory and degenerative diseases of the sacroiliac joint.

Materials and Methods: Patients who underwent non-contrast sacroiliac joint MRI due to back or hip pain at the Radiology Department of Bakırköy Dr. Sadi Konuk Training and Research Hospital, University of Health Sciences, Ministry of Health of the Republic of Turkey, between January 2023 and June 2024, were reviewed. Images were obtained from 150 sacroiliac joints of 95 patients meeting the criteria. The 95 patients were divided into three groups: ankylosing spondylitis group, degenerative group, and control group. The images were segmented using the 3D Slicer software, and radiomics data were extracted from the segmented areas using PyRadiomics. Out of 93 radiomics features, 14 statistically significant features were selected based on statistical analyses. Using these 14 features, 64 models were created in MATLAB with and without PCA functionality. Each group was compared with the others and collectively using machine learning algorithms.

Results: In the comparison between the ankylosing spondylitis group and the control group, the Logistic Regression-based machine learning algorithm achieved the highest accuracy, with a rate of 96%. In the comparison between the ankylosing spondylitis group and the degenerative group, the KNN-based machine learning algorithm achieved the highest accuracy, with a rate of 83%. In the comparison between the degenerative group and the control group, the Neural Network-based machine learning algorithm achieved the highest accuracy, with a rate of 96%. In the comparison of the ankylosing spondylitis group with the other groups collectively, the Neural Network-based machine learning algorithm achieved the highest accuracy, with a rate of 93%.

Conclusion: Machine learning-assisted radiomics analysis demonstrated high accuracy and effectiveness in distinguishing inflammatory diseases of the sacroiliac joint from degenerative diseases.

Keywords: Machine Learning, Ankylosing spondylitis, Magnetic Resonance, Radiomics

GİRİŞ VE AMAÇ

1. AMAÇ

The Assessment of SpondyloArthritis international Society (ASAS) kriterlerine göre sakroiliak eklemden kemik iliği ödemi tespit etmek ankilozan spondilitli hastalarda önemli tanı bulgularından biridir. Fakat kemik iliği ödemi her zaman ankilozan spondilit sebebi ile oluşmaz. Birçok farklı patoloji sakroiliak eklemden kemik iliği ödemi oluşturabilir. Bu yüzden ankilozan spondilit nedeni ile oluşmuş kemik iliği ödemi diğer sebeplerden ayırmak önemlidir. Bu ayrımı yapmak için görüntülerin deneyimli radyologlar tarafından hastanın klinik ve laboratuvar bulgularıda göz önünde bulundurularak değerlendirilmesi gerekir. Yapılan çalışmalarda sakroilite bağlı kemik iliği tespitinde radyologların görüşleri arasında önemli farklılıklar bulunmuştur. Hastalığın tanısında bu kadar önemli bir bulguda radyologlar arasında bir konsensus bulunmaması hastanın tanısında ve tedavisinde gecikmeye yol açabilir. Tedavisiz hastalarda kronik dönemde hareket kısıtlılığına kadar giden bulgular yüzünden erken tanı ve tedavi çok önemlidir.

Radiomiks tıbbi görüntülerden çeşitli algoritmalarla sayısal veriler çıkarılır. Bu veriler ışığında tıbbi görüntülerden insan gözünün tespit edemeyeceği detayların ortaya çıkarılması amaçlanır. Fakat bu verileri tek başına yorumlamak zordur. Yapay zeka bu noktada devreye girebilir. Bir tıbbi görüntüden elde edilen radiomiks verilerinin çeşitli makine öğrenmesi algoritmalarıyla bazı hastalıklar arasında ilişki kurulabilir. Örneği malign tümör dokularının sınırları genelde daha düzensiz olurken, benign tümörlerin sınırları genelde daha düzgün olur. İşte böyle dokulardan elde edilen radiomiks verileri ile yapay zeka kullanılarak çeşitli çıkarımlar yapılır. Bu sayede dokuların tıbbi görüntülerdeki insan gözünün ayırt edemediği özellikleri kullanılarak hastalıkların tanısı iyileştirilebilir. Ayrıca bu radiomiks verilerin tekrarlanabilir olması, subjektif olmaması sayesinde görüntüler ve tanımlar arasında görüş birliği sağlanabilir.

Bu çalışmamızda radiomics verilerini kullanarak çeşitli makine öğrenmesi algoritmalarının ankilozan spondilite bağlı kemik iliği ödemi normal ve diğer kemik iliği ödemiye yol açan hastalıkların ayırımıdaki etkinliğinin değerlendirilmesini amaçladık.

GENEL BİLGİLER

1. SAKROİLİAK EKLEM

Sakroiliak eklemler (SIE'ler), üst vücuda stabil ama sınırlı bir esneklikle destek sağlamak için özelleşmiş eklemlerdir(1). İki ayak üzerinde yürüyen canlılarda pelvis, omurga ve iki bacak gibi büyük kaldıraçların üzerinde etkili olduğu temel bir platform işlevi görür. Bu yapı, üst vücuttan alt ekstremitelere verimli bir şekilde ağırlık aktarımı sağlarken denge ve stabiliteyi korur.

Hem iyi gelişmiş lifli yapının sıklığı hem de SIE'min özel yapısı, hareket kabiliyetinin sınırlı olmasına neden olur. Sakral hareket, SIE'mi içerir ve ayrıca diskleri ve büyük olasılıkla üstteki lumbar eklemleri de doğrudan etkiler. SI eklemlerinin stabilitesi, eklem bağları, güçlü dış bağlar ve kaslarla çevrili, çapraz yönde yerleşmiş dalgalı eklem yüzleriyle sağlanır(2).

Eklem, iki bölmeden oluşur: aşağıda/önde (ventralde) yer alan C veya L şeklindeki kıkırdak kaplı bir kısım ve yukarıda/arkada (dorsalde) güçlü interosseöz bağlar içeren bağ dokulu bir kısım. Kıkırdaklı eklem yüzeyinin boyutu, şekli ve konturu bireyler arasında büyük ölçüde farklılık gösterir. Ancak erkeklerde SIE'leri tipik olarak sakral S1, S2 ve S3 segmentlerine karşılık gelecek şekilde oluşurken, kadınlarda tüm S3 segmentinin dahil olması nadirdir. Bu nedenle kadınlarda SIE'min yük taşıyan yüzeyi genellikle daha küçüktür ve eklem yüzeyinin konumu sıklıkla daha yataydır. Eklemdeki bağ dokulu kısma karşılık gelen interosseöz ve dorsal sakroiliak bağları, SIE'min en güçlü destekleyici bağlarıdır. Bu bağlar, kıkırdaklı eklemi arkadan çevreleyerek sakrum ile ilium arasındaki boşlukları kıkırdaklı eklemün üst/arka kısmında doldurur(3).

2. SAKROİLİİT

Sakroiliit, sakroiliak eklemünün genellik ile ağrı ile bulgu gösteren bir inflamasyondur. Bu inflamasyon, osteoartrit, hamilelik, spondiloartritler ve travma gibi durumların bir sonucu olarak meydana gelebilir. Sakroiliak ağrının prevalansına ilişkin raporlar büyük farklılıklar göstermektedir. Bazı çalışmalar, alt sırt ağrısı olanların %10 ila %25'inde sakroiliak ağrının bulunduğunu bildirmektedir(4). Kesin bir tanı konmuş olanlarda, ağrının sunumu çoğunlukla ipsilateral kalçada (%94) ve orta alt lomber bölgede (%74) olmaktadır. Daha önce de belirtildiği gibi, sunum farklılık gösterebilir. Vaka sayısının %50'sine kadar olanlarda ağrı alt ekstremitelere yayılabilir: %6'sında üst lomber bölgeye, %4'ünde kasığa ve %2'sinde alt karın bölgesine yayılma görülebilir(5).

3. ANKİLOZAN SPONDİLİT

Ankilozan spondilit (AS), bir tür SpA (Spondiloartrit) olup, esas olarak omurga eklemleri, sakroiliak eklemler (SIJ) ve bunlara bitişik yumuşak dokuları, örneğin tendonlar ve bağları etkileyen otoimmün bir hastalıktır. Daha ileri vakalarda, bu iltihaplanma fibrozis ve kalsifikasyona yol açarak esnekliğin kaybına ve omurganın kaynaşmasına neden olabilir; bu durum, omurganın "bambu" görünümünü alarak hareketsiz bir pozisyon oluşturmaya benzer. Başlıca klinik belirtiler arasında bel ağrısı ve ilerleyici omurga sertliği ile kalça, omuz, çevresel eklemler ve parmak/tırnak iltihaplanması yer alır. Ayrıca akut anterior üveit ve inflamatuvar bağırsak hastalığı (IBD) gibi ekstra-artiküler bulgular da görülebilir(6).

3.1. Epidemiyoloji

Ülkemizde yapılan araştırmalarda, spondiloartrit prevalansı yaklaşık %1, ankilozan spondilit prevalansı ise %0,5 civarında bulunmuştur. Bu oranlar, diğer ülkelerde gözlemlenen sıklıklarla uyumludur. Hastalığın erkeklerde kadınlara oranla 2-3 kat daha fazla görüldüğü bildirilmiştir(7).

3.2. Etiyoloji

Ankilozan spondilit (AS), genetik yatkınlık ve çevresel faktörler arasındaki karmaşık etkileşimler sonucu gelişen bir otoimmün hastalıktır. Genetik faktörlerin, ankilozan spondilit (AS) oluşumunda kritik bir rol oynadığı kabul edilmektedir. AS ile genetik arasındaki ilişki, hastalığın kalıtsal özelliklerinin 1961 yılında aile içinde ilk kez doğrulanmasından bu yana sürekli tartışılan bir konu olmuştur(8). En önemli genetik faktörlerden biri, majör histokompatibilite kompleksi (MHC) sınıf I aleli olan HLA-B27'dir(9). Çalışmalar, ankilozan spondilit (AS) hastalarının %90-95'inin HLA-B27 pozitif olduğunu göstermiştir. Buna karşılık, HLA-B27 pozitif bireylerin yalnızca %1-2'sinde AS gelişir. Ancak, birinci derece akrabasında AS bulunan bireylerde bu oran %15-20'ye yükselmektedir(10). Ayrıca ankilozan spondilit (AS), inflamatuvar bağırsak hastalığı (IBD), anterior üveit ve psoriasis gibi bir dizi otoimmün hastalıkla ilişkilidir. Bu durum, bu hastalıkların genetik bir temel ve bazı ortak immünolojik süreçleri paylaşabileceğini düşündürmektedir(11). Bazı mikrobiyal enfeksiyonlar da, konağın doğal bağışıklık sistemini tetikleyici bir faktör olarak işlev görür ve ankilozan spondilit (AS) gelişimine katkıda bulunabilir(12).

3.3. Klinik Bulgular

Spondiloartrit alt tipi ne olursa olsun, bu hastalık grubunun temel klinik özellikleri; sakroiliit ve aksiyel iskeletin diğer bölgelerindeki iltihaplanmaya bağlı olarak ortaya çıkan

inflamatuvar bel ağrısı, periferik artrit, entezit ve anterior üveittir(13). Ankilozan spondilitin karakteristik semptomları, omurga iltihabı, yapısal hasar veya her ikisinin birleşimi sonucu ortaya çıkan omurga sertliği ve omurga hareketliliğinin kaybıdır(14). Yapısal değişiklikler, genellikle osteorezorpsiyon yerine osteoproliferasyon nedeniyle oluşur. Sindesmofitler ve ankiloz, bu hastalığın en karakteristik özellikleridir ve genellikle aylar ile yıllar arasında konvansiyonel röntgenlerde görülebilir. Periferik artrit genellikle monoartiküler veya oligoartiküler olup, başlıca ancak yalnızca alt ekstremiteleri etkiler(15).

3.4. Tanı ve Sınıflama

Sakroiliit, özellikle ankiloza spondilitin erken evrelerinde bir belirleyici özelliktir. Hastalarda ankiloza spondilitin çok yüksek prevalansı nedeniyle sınıflandırma kriterlerinin geliştirilmesinde önemli bir araç haline gelmiştir. Sakroiliak eklemlerin radyografileri hastalığın erken evresinde normal görünebileceğinden, yapısal değişiklikler ancak yıllar sonra belirgin hale gelebilir. Bu, bu hastalığı taşıyan hasta grubunun büyük bir kısmı için önemlidir. Manyetik rezonans görüntüleme (MRG) yönteminin kullanıma girmesiyle, sakroiliak eklemlerin radyografilerinin iltihabın yapısal sonuçlarını (kıkırdak ve kemik hasarını) değil, iltihabı kendisini tespit ettiği açıkça görülmüştür. Buna göre, MRG tekniği, hastalığın erken evrelerinde, kronik değişiklikler tespit edilemediği zamanlarda, sakroiliak eklemlerdeki iltihabı tespit etmeye olanak sağlar. Sakroiliak eklemlerdeki kronik değişikliklerin radyografik olarak tespitindeki bu gecikme, ankilozan spondilitin tanı gecikmesine katkıda bulunabilir(16).

En son ASAS (Ankylosing Spondylitis Assessment Study) sınıflandırma kriterleri, hem erken hem de ileri evre vakalar için geliştirilmiştir ve erken tanı için önemli bir araç olarak manyetik rezonans görüntüleme (MRG) tekniğini (aktif iltihaplanma) içermektedir.

Bel ağrısının süresi >3 ay ve başlangıç yaşı <45 olan hastalarda;

Görüntülemelerde sakroiliit + ≥1 SpA Bulgusu		HLA+ B27 + ≥ 2 SpA Bulgusu	
SPA BULGUSU		GÖRÜNTÜLEMEDE SAKROİLEİT	
• İnflamatuvar bel ağrısı • Artrit • Entezit • Üveit • Daktilit • Psöriyazis • Chron / Kolit • Non- steroid ağrı kesicilere iyi yanıt • SpA için aile öyküsü • HLA -B27 pozitifliği • CRP yüksekliği		• MRG'de aktif inflamasyon • Modifiye New York Kriterlerine göre kesin radyografik sakroiliit	

Tablo 1: The Assessment of SpondyloArthritis international Society (ASAS) Kriterleri

3.5. Klinik Kriterler

İnflamatuvar bel ağrısı, spondiloartrit ve ankilozan spondilit tanısında, hem erken hem de geç evreler ile sınıflandırmada önemli bir klinik belirtidir. İnflamatuvar bel ağrısı (İBA), aksiyal omurga ve sakroiliak eklemlerde yoğunlaşan kronik bir ağrıdır ve belirli tanısal özellikleri sayesinde mekanik bel ağrısından ayrılır. İnflamatuvar durumlarla güçlü bir şekilde ilişkili olmasına rağmen, İBA tek başına tanı koydurucu değildir.

İnflamatuvar bel ağrısı (İBP), aksiyel omurga ve sakroiliak eklemler üzerinde yoğunlaşan kronik bir ağrı türüdür ve belirli tanısal özelliklerle mekanik bel ağrısından ayırt edilir. İnflamatuvar durumlarla güçlü bir şekilde bağlantılı olmasına rağmen, İBP tek başına kesin bir tanı koydurmaz.

IBP'yi diğer bel ağrısı nedenlerinden ayırt etmeye yardımcı olan birkaç temel özellik şunlardır(17): İnflamatuar bel ağrısı genellikle aksiyel omurgada, özellikle lomber bölgede lokalizedir. Ayrıca, hastalar bir yandan diğer yana geçiş gösteren kalça ağrısı da yaşayabilir. Hastanın özellikleri, özellikle yaş ve kronik ağrının varlığı, IBP'yi ayırt etmede önemli rol oynar. Ağrı genellikle 40 yaşından önce başlar ve 3 ay veya daha uzun süren kalıcı bir ağrıya neden olur. Ağrının zaman içindeki seyri, IBP tanısında önemli bir faktördür. Ağrı genellikle sinsi bir başlangıç gösterir ve uzun bir süre boyunca kademeli olarak kötüleşir. IBP'li hastalar genellikle sabah tutukluğu yaşarlar; bu tutukluk hareket veya egzersiz ile düzelir. Bu belirti, IBP'yi diğer bel ağrısı türlerinden ayırmada önemli bir rol oynar. Klasik olarak ankilozan spondilit ile ilişkilendirilse de, IBP psöriyatik artrit (PsA), enteropatik artropati, juvenil idiyopatik artrit (JIA) ve reaktif artrit gibi diğer seronegatif spondiloartropatilerde de görülebilir. Bazı durumlarda, IBP'nin nedeni belirlenemeyebilir; bu, belirgin tanısal özelliklerin eksikliği veya birden fazlasının bir kombinasyonu nedeniyle ortaya çıkabilir.

3.6. Laboratuvar Testleri

Spondiloartrit tanısında potansiyel olarak önemli olan iki temel laboratuvar göstergesi vardır: HLA-B27 ve C-reaktif protein (CRP)(18). HLA-B27, erken spondiloartrit tanısında önemli bir faktördür. HLA-B27 testinin performansı, popülasyonda HLA-B27 prevalansına bağlıdır ve bu oran ırklara göre farklılık gösterir. Beyaz ırka mensup hastalarda HLA-B27 alt tiplerinin ölçülmesine genellikle gerek yoktur; ancak Çinli hastalarda bazı alt tipler nedeniyle alt tip belirleme gerekli olabilir. Hastalığın aktivitesi ile inflamasyon göstergeleri arasındaki ilişki sınırlıdır. Bu hastalığa sahip hastaların yalnızca yarısında C-reaktif protein (CRP) seviyeleri yükselmiştir(19).

3.7. Görüntüleme bulguları

3.7.1. Radyografi

Radyografi, sakroiliit teşhisinde en yaygın kabul edilen görüntüleme yöntemidir çünkü nispeten ucuzdur, kolay erişilebilir ve pozitif bulgular sağladığında oldukça faydalıdır. Ancak, radyografi yalnızca kronik kemik değişikliklerini tespit edebilir ve bu değişikliklerin belirgin hale gelmesi genellikle birkaç yıl sürer, bu da tanıda gecikmeye neden olur(20).

Modifiye New York kriterlerine göre, sakroiliit beş derece üzerinden değerlendirilir: 0 (normal) ile 4 (ankiloz) arasında değişir. Derece 0, iyi tanımlanmış kenarlara sahip normal sakroiliak eklemleri ifade ederken, derece 1 şüpheli değişiklikleri, başlangıç sklerozu ve eklem aralığında yer yer incelmeyi gösterir. Derece 2, eklem kenarlarında belirginliğin

kaybolduđu, subkondral osteoporoz ve reaktif skleroz alanları gibi minimal anormalliklerle tanımlanır. Derece 3, hem sakral hem de iliak eklem kenarlarında (çoğunlukla iliak tarafta) subkondral skleroz, erozyonlar, eklem aralığında daralma, genişleme ve başlangıç ankilozu gibi kesin anormallikleri içerir. Derece 4 ise artık sklerozun zamanla azalma eğiliminde olduđu tam ankilozu ifade eder. Modifiye New York kriterlerine göre, sakroiliitin radyografik olarak teşhis edilebilmesi için, bilateral değışikliklerin derece 2 veya üzerinde ya da unilateral değışikliklerin derece 3 veya üzerinde olması gerekmektedir(21)





Şekil 1 : Modifiye New York Kriterleri evrelemesi A. Grade I B. Grade II C. Grade III D. Grade IV

3.7.2. Bilgisayarlı Tomografi

BT (Bilgisayarlı Tomografi), yapısal değişikliklerin tespitinde konvansiyonel radyografiye göre daha hassastır; bu nedenle, sakroiliak eklemlerin daha ayrıntılı bir şekilde değerlendirilmesine olanak tanır. Ayrıca, manyetik rezonans (MR) görüntülemenin aksine, BT, eklemin ligamentoöz bölümünde kemik proliferasyonunu iyi bir şekilde değerlendirmeye olanak tanır. Ancak BT'nin dezavantajları arasında radyasyon maruziyeti ve aktif inflamasyonun varlığını değerlendirememesi yer alır(22). Sakroiliitin BT bulguları,

radyografide görülen bulgulara benzer olup erozyonlar, skleroz ve hastalık ilerlerse ankilozu içerir.

3.7.3. Manyetik Rezonans Görüntüleme

MR görüntüleme, aksiyel spondiloartropati ile ilişkili sakroiliitin teşhisinde günümüzde temel araçlardan biri haline gelmiştir, çünkü akut inflamatuvar değişikliklerin değerlendirilmesine olanak tanır. Bu da MR görüntülemenin kıkırdaktaki başlangıç değişikliklerini ve subkondral kemik, ligamentler, sinovyum ve kapsüler bölgede akut inflamatuvar aktiviteyi gösterebileceği anlamına gelir. Bu bulgular arasında ilk ortaya çıkan ise kemik iliği ödemi(23). Aktif inflamatuvar lezyonlar (kemik iliği ödemi, sinovit, kapsülit ve entezit) STIR, yağ baskılı T2 ağırlıklı ve kontrastlı yağ baskılı T1 ağırlıklı görüntülerde görselleştirilebilir. Kemik iliği ödemi, yağ baskılı hızlı spin-eko T2 ağırlıklı veya STIR görüntülerde artmış sinyal yoğunluğu ve gadolinyum kontrastlı yağ baskılı hızlı spin-eko T1 ağırlıklı görüntülerde kontrast tutulumu ile kendini gösterir. Bu ödem, periartiküler olarak lokalize olur ve erozyon gibi yapısal değişikliklerle ilişkili olabilir. Sinovit, paramanyetik kontrast madde uygulandıktan sonra eklem sıvısından ayırt edilebilir ve eklem sinovyal kısmında kontrast tutulumu olarak kendini gösterir. Kapsülit, anterior ve posterior kapsülü etkileyebilir ve bazen kontrastlı yağ baskılı T1 ağırlıklı görüntülerde, STIR veya yağ baskılı T2 ağırlıklı görüntüleme kıyasla daha kolay tespit edilebilir. Son olarak, entezit, STIR ve yağ baskılı T2 ağırlıklı görüntülerde hiperintens sinyal olarak ve gadolinyum kontrastlı yağ baskılı T1 ağırlıklı görüntülerde kontrast tutulumu olarak, ligamentlerin ve tendonların kemiklere bağlandığı bölgelerde kendini gösterir(24).

Kronik veya yapısal lezyonlar genellikle T1 ağırlıklı görüntülerde iyi bir şekilde görülür ve subkondral skleroz, erozyonlar, periartiküler yağ birikintileri ve ankilozu içerir. Tüm sekanslarda, subkondral skleroz, genellikle sakroiliak eklem aralığından en az 5 mm uzanan düşük sinyal yoğunluğu bantları olarak kendini gösterir. Erozyonlar, kıkırdaklı bölgenin eklem kenarındaki kemik kusurlarıdır ve T1 ağırlıklı görüntülerde hipointens odaklar olarak görünür. Eğer aktifse, STIR görüntülerde hiperintens odaklar olarak gözlemlenirler ve genellikle daha iyi bir şekilde gradient echo T2 ağırlıklı veya yağ baskılı T1 ağırlıklı görüntülerde betimlenirler. Yağ birikintileri, yağ baskılı olmayan T1 ağırlıklı görüntülerde hiperintens olarak görünür ve muhtemelen önceki inflamasyon bölgelerini gösteren özgül olmayan bir bulgudur. Kemik köprüleri veya ankiloz, genellikle inflamasyon sürecinde oluşan ve birbirine bakan kemik tomurcuklarının kaynaşması sonucu meydana gelir ve eklem boşluğunun bulanık bir görünüme sahip olmasına neden olabilir(24). Yeni ASAS aksiyel

spondiloartropati kriterlerine göre, MR görüntülemesinde sakroiliitin tanımlanabilmesi için subkondral veya periartiküler kemik iliği ödeminin varlığı zorunludur. Eğer yalnızca bir lezyon varsa, bu lezyon en az iki kesitte bulunmalıdır; bir kesitte birden fazla lezyon varsa, o kesit tanı koymak için yeterlidir. Sinovit, kapsülit veya entezit varlığı, aktif sakroiliit tanısını koymak için yeterli olmasa da tanı ile uyumludur. Yağ birikintileri, skleroz, erozyonlar ve kemik ankilozu gibi yapısal lezyonlar, önceki inflamasyonu yansıtmaya olasılığı taşır, ancak bunlar pozitif bir MR görüntüleme incelemesi tanımını yapmak için yeterli değildir.

4. Sakroiliak Eklemde Dejeneratif Değişiklikler

Her yük binen eklemde olduğu gibi sakroiliak eklemde de dejeneratif değişiklikler izlenebilir. Yine bu eklemlerle benzer olarak dejeneratif değişiklikler eklem mesafesinde daralma, osteofitler, subchondral skleroz ve kistler gibi bulgular gösterebilir. Ayrıca dejenerasyona bağlı bu bulgular kemik iliği ödemi eşlik edebilir(25). Bilgisayarlı tomografi görüntülerinde yetişkinlerin %65.1 yaşla artan bir şekilde insidental olarak sakroiliak eklem dejenerasyonu bulguları tespit edilmiştir(26). Önemli bir diğer nokta SIE dejenerasyonu ile çevredeki yapılar, örneğin kalça veya omurga, arasındaki bağlantıdır. Tam olarak kesin mekanizması bilinmemekle birlikte omurga füzyonu veya kalça artrodezinden sonra SI eklemde dejenerasyonun arttığı bildirilmiştir(27).

5. Radiomiks

Radyomiks, genel olarak medikal görüntüleme alanlarında yoğun bir şekilde tartışılan bir konudur. Terim tam olarak tanımlanmamış olsa da, radyomiks genellikle, insan gözüyle tanımlanması veya nicelendirilmesi zor olan karmaşık desenler de dahil olmak üzere, tanısal görüntülerden nicel ve ideal olarak yeniden üretilebilir bilgiler çıkarmayı amaçlar(28).

Radyomiks, doku ve lezyon özelliklerini, örneğin şekil ve heterojeniteyi, ve seri görüntülemelerde bu özelliklerin zaman içindeki değişikliklerini (tedavi veya izlem sırasında) yakalamak için kullanılabilir. Onkoloji alanında, doku heterojenitesinin değerlendirilmesi özellikle önemlidir. Genomik analizler, tümör heterojenitesinin derecesinin, sağkalım için bir prognostik belirleyici olduğunu ve kanser kontrolü için bir engel oluşturduğunu göstermiştir(29).

Radyomik veriler, "madencilik yapılabilir" olarak tanımlanır; yani yeterince büyük veri setlerinde, daha önce bilinmeyen hastalık evrimi, ilerlemesi ve tedavi yanıtı belirteçleri ile desenlerini keşfetmek için kullanılabilirler.

5.1. Görüntü Segmentasyonu

Eğer tüm görüntüyü analiz etmek yerine belirli bir bölgeyle ilgileniyorsanız, ilgili bölü mü piksel veya voksel düzeyinde belirlemek için iki veya üç boyutlu olarak ayırmanız gerekmektedir.

Segmentasyon hem otomatik olarak gerçekleştirilebilir hem de yardım alarak veya manuel olarak yapılabilir. Radyologlar tarafından hala standart olarak kabul edilen manuel olarak kesit kesit yapılan işlemde, kullanıcıya bağlı hatalar ve farklılıklar da göz önünde bulundurulmalı.

5.2. Tekstür Analizi

Radyomiks tekstür özellikleri beş gruba ayrılır : lezyonun boyut ve şekline dayalı morfolojik özellikler, birinci derece istatistik olarak da adlandırılan histogram garifiğinde türetilen parametreler, ikinci derece istatistiksel hesaplarla elde edilen ve voksellerin birbiriyle komşuluk ilişkilerinin tanımlayıcıları, filtrelenmiş görüntülerden çıkarılan parametreler ve fraktal özellikler.

5.2.1. Morfolojik Özellikler

İncelenen ROI'nin iki veya üç boyutlu şeklinden kaynaklanan özelliklerdir. Bu morfolojik özellikler :

Hacim (V): Genel olarak voksellerin (VOI'nin) sayısı ve birim hacmi ile ilişkilidir.

Küresellik: İncelenen nesnenin mükemmel bir küreye olan uzaklığının tarifi olup “1” mükemmel küreyi ifade eder. Formülde A, nesnenin yüzey alanını temsil etmektedir.

$$SHAPE_{Sphericity} = \sqrt[3]{\pi} * \sqrt[2/3]{(6 * V)/A}$$

Kompaktlık: Nesnenin (VOI'nin) kompaktlığını gösterir.


$$SHAPE_{Compacity} = A^{3/2}/V$$

Bizim çalışmamızda kitlesel bir lezyon bulunmadığın her sakroiliak eklemden aynı boyutlarda ROI alınmıştır. Bu yüzden çalışmamızda morfolojik özelliklere yer verilmemiştir.

5.2.2. Birinci Sıra Özellikler: Histogram

Histogram belirli bir özelliğin frekans dağılımının grafik olarak gösterilmesidir. Piksel yoğunluklarının dağılımını inceleyerek doku homojenliği ve kontrastı hakkında bilgi verir.

Histogram grafiğinden en sık hesaplanan verileri; ortalama, varyans, enerji, entropi, basıklık ve çarpıklıktır. Ortalama değeri radyolojik görüntülerde gri seviyesini yani parlaklığını, standart sapma (varyans) görüntü kontrastını, enerji-entropi ise heterojeniteyi yansıtır. Çarpıklık, eğrinin ortalamaya göre simetrisi; basıklık ise dağılım genişliği hakkında bilgi verir.



Şekil 2: Histogram örnekleri


5.2.3. İkinci Sıra Özellikler

Histogram kabaca bir görüntüdeki grilerin seviyelerine göre ayrılıp, sıklıklarına göre sıralandığı bir grafiğdir. Lezyonun uzaysal konfigürasyonu ile ilgili bilgi edinilemez. İkinci sıra özellikler gri değerlerinin matrislere aktarılması üzerinden uzaysal ilişkilerini de gösterebilir.

5.2.4. Gri Skala Birlikte Oluşum Matrisi (GLCM)

GLCM, bir görüntüdeki gri ton seviyelerinin (piksel yoğunluklarının) birbirine olan göreceli konumlarını analiz eden bir matristir(30). Temel olarak, bir pikselin belirli bir mesafe ve yönde (örneğin yatay, dikey veya çapraz) başka bir pikselle olan ilişkisini değerlendirir. Belirli voksel çiftlerinin komşuluk frekansı ve uzaysal ilişkileri üzerinden matris oluşturulur. Matris oluşturulurken 2 boyutlu görüntülerde her pikselin 4 doğrultuda, 8 yönde; 3 boyutlu

görüntülerde her vokselin 13 doğrultuda, 26 yönde komşuluğu bulunur. GLCM matrisi her yön için ayrı ayrı hesaplanır. Her bir hücre, görüntüdeki iki pikselin belirli gri seviyelerine sahip olma durumunun sayısını temsil eder.



Şekil 3: GLCM Matrisinin Oluşturulması

GLCM matrisi üzerinden 13 yönde ortalama alınarak hesaplanacak bazı tekstür değişkenleri ise şunlardır;

Homojenite (GLCM_Homogeneity): Gri seviyelerinin benzerliğini, yani homojenitesini gösterir.

$$GLCM_{Homogeneity} = \sum_i \sum_j \frac{GLCM(i, j)}{1 + |i - j|}$$

Enerji (GLCM_Energy): Dokunun tekdüzeliği-düzensizlik dağılımını gösterir. Periyodik ya da sabit dağılan gri değerleri yüksek enerji değerleri ile ilişkilidir.

$$GLCM_{Energy} = \sum_i \sum_j GLCM(i, j)^2$$

Kontrast (GLCM_Contrast): GLCM matrisindeki gri seviye değerlerinin lokal varyansıdır. GLCM matrisinde i ve j'nin eşit olduğu köşegen üzerinde (i-j) farkı sıfır olduğundan kontrast yoktur. Fark arttıkça kontrast, formülden de anlaşılacağı gibi üstel olarak artar.

$$GLCM_{Contrast} = \sum_i \sum_j (i - j)^2 * GLCM(i, j)$$

Korelasyon (GLCM_Correlation): Gri değerlerinin doğrusal bağımlılığıdır. Yani bir piksel-vokselin komşuluğundakiler ile ilişkini gösterir.

$$GLCM_{Correlation} = \sum_i \sum_j (i - \mu_i) * (j - \mu_j) * GLCM(i, j) / \sigma_i * \sigma_j$$

Entropi (GLCM_Entropy_{log10}): Entropi yani gri skala değerlerinin rastgeleliğini gösterir. Tekdüzelikten uzaklaştıkça entropi değeri artar.


$$GLCM_{Entropy_{log10}} = - \sum_i \sum_j GLCM(i, j) * \log_{10}(GLCM(i, j) + \epsilon)$$

Benzerlik (GLCM_Dissimilarity): Kontrast temelli bir ölçü olup, farklı olarak ağırlıklar köşegenden uzaklaştıkça değil doğrusal olarak artar.

$$GLCM_{Dissimilarity} = \sum_i \sum_j |i - j| * GLCM(i, j)$$

5.2.5. Gri Seviye Koşu Uzunluğu Matrisi (GLRLM)

Gri Seviye Koşu Uzunluğu Matrisi (Grey-Level Run Length Matrix: GLRLM), GLRLM, bir görüntünün farklı yönlerdeki ardışık gri ton uzunluklarını sayarak bir matris oluşturur. Bu matris, görüntüdeki belirli bir gri seviyesinin, bir doğrultuda ardışık olarak tekrarlandığı piksel sayılarını ifade eder(31). GLCM'den farklı olarak, GLRLM, yalnızca piksel çiftleri yerine ardışık piksel gruplarını değerlendirir. (32).



Şekil 4: GLRLM Matrisinin Oluşturulması

Kısa Tekrar Vurgusu (GLRLM_SRE): Kısa tekrar dizilerinin dağılımının bir ölçüsüdür.

Homojen dokular genelde yüksek SRE değerine sahiptir.

$$GLRM_{SRE} = \frac{1}{N} \sum_j^{N_r} \frac{GLRM(i, j)}{i^2}$$

Uzun Tekrar Vurgusu (GLRLM_LRE): Uzun tekrarların dağılımının bir ölçüsüdür. Daha düzensiz veya heterojen dokular yüksek LRE değerine sahiptir.

$$GLRM_{LRE} = \frac{1}{N} \sum_j^{N_r} GLRM(i, j) * i^2$$

Düşük Gri Skala Değeri Tekrar Vurgusu (GLRLM_LGLRE): Dokuya düşük değere sahip gri sakala değerlerinin hakimiyetini gösteren bir metriktir. Kısa tekrar vurgusuna benzetmekle birlikte, kısa tekrarları değil, düşük gri seviyelerini vurgular.

$$GLRLM_{LGLRE} = \frac{1}{N} \sum_i^{N_g} \frac{GLRM(i, j)}{i^2}$$

Yüksek Gri Skala Değeri Tekrar Vurgusu (GLRLM_HGLRE): Dokudaki yüksek gri skala değerine sahip tekrarları vurgular. Uzun tekrar vurgusunun aslında gri skala karşılığıdır.

$$GLRLM_{HGLRE} = \frac{1}{N} \sum_i^{N_g} GLRM(i, j) * i^2$$

Düşük Gri Seviyelerinin Kısa Tekrar Vurgusu (GLRLM_SRLGE): GLRLM matrisindeki düşük gri seviyesi ve kısa tekrarları, yani matrisin sol üst köşesine denk gelen alanı vurgular. Düşük gri skala alanlardaki heterojenitenin bir ölçüsüdür.

$$GLRLM_{SRLGE} = \frac{1}{N} \sum_i^{N_g} \sum_j^{N_r} \frac{GLRLM(i, j)}{i^2 * j^2}$$

Yüksek Gri Seviyelerinin Kısa Tekrar Vurgusu (GLRLM_SRHGE): GLRLM matrisinin sol alt köşesine denk gelen, yüksek gri seviyelerinin kısa tekrarlarının bir göstergesidir. Yüksek gri skala alanlarındaki heterojenitenin ölçüsüdür.

$$GLRLM_{SRHGE} = \frac{1}{N} \sum_i^{N_g} \sum_j^{N_r} \frac{i^2 * GLRLM(i, j)}{j^2}$$

Düşük Gri Seviyelerinin Uzun Tekrar Vurgusu (GLRLM_LRLGE): Matrisin sağ üst kadranına denk gelir ve düşük gri skala alanlarındaki homojeniteyi gösterir.

$$GLRLM_{LRLGE} = \frac{1}{N} \sum_i^{N_g} \sum_j^{N_r} \frac{j^2 * GLRLM(i, j)}{i^2}$$

Yüksek Gri Seviyelerinin Uzun Tekrar Vurgusu (GLRLM_LRHGE): Matrisin sağ alt kadranına denk gelir ve yüksek gri skala alanlarının homojenitesini gösterir.

$$GLRLM_{LRHGE} = \frac{1}{N} \sum_i^{N_g} \sum_j^{N_r} i^2 * j^2 * GLRLM(i, j)$$

Gri Seviye Tekrarlarının Uyumsuzluğu (GLRLM_GLNU): Gri skala seviyelerine karşılık gelen tekrarların dağılımının bir ölçüsüdür. Tekrarlar farklı gri skala seviyelerinde benzer dağılıyorsa, değeri düşüktür.

$$GLRLM_{GLNU} = \frac{1}{N} \sum_i^{N_g} GLRLM(i, j)^2$$

Tekrar Uzunluklarının Uyumsuzluğu (GLRLM_RLNU): Bu özelliklik tekrar sayısının, yani matrisin tekrar sütunları, tekrar uzunluklarına dağılımını gösterir. Düşük olması tekrar uzunluklarının, tekrar sayılarınca homojen dağıldığını gösterir.

$$GLRLM_{RLNU} = \frac{1}{N} \sum_j^{N_r} GLRLM(i, j)^2$$


Tekrar Yüzdesi (GLRLM_{RP}): Aslında homojenitenin olasılığıdır. Bir ROI’de gerçekleşen tekrar sayısının (N_s), vokseldeki toplam olabilecek potansiyel tekrar sayısına (N_v) oranıdır. Potansiyel tekrar sayısı, gri seviyesi ve maksimum tekrar uzunluğu çarpımı ile hesaplanır.

$$GLRLM_{RP} = \frac{N_s}{N_v}$$

Gerçekleşen tekrar sayısı, daha düzenli ve homojen dokularda, potansiyel tekrar sayısına göre çok daha düşük beklenir.

5.2.6. Gri Skala Bölgesel Boyut Matrisi (GLSZM)

Gri Skala Bölgesel Boyut Matrisi (Grey-Level Size Zone Matrix), bir görüntüde aynı gri ton değerine sahip ve birbirine bitişik olan piksellerin oluşturduğu büyüklük bölgelerini değerlendirir. Bir büyüklük bölgesi (size zone), belirli bir gri ton seviyesine sahip ve mekansal olarak birbirine bağlı olan piksellerin sayısıdır. İlişkili voksel kavramı ise, bir voksele komşu olan aynı gri skala seviyesindeki vokseller olarak tanımlanır (33).



Şekil 5: GLSZM Matrisinin Oluşturulması

Küçük Bölge Vurgusu (GLSZM_{SZE}): Bu özellik aynı seviyedeki gri skaladan oluşan küçük bölgelerin bir ölçütüdür. Dokunun ince iç yapısıyla ilişkilidir.

$$GLSZM_{SZE} : \frac{1}{N_s} \sum_j^{N_z} \frac{GLSZM(i, j)}{j^2}$$

Büyük Bölge Vurgusu (GLSZM_LZE): Büyük bölgelerin dağılımıdır. Doku yapısının kabalığını gösterir.

$$GLSZM_{LZE} : \frac{1}{N_s} \sum_j^{N_z} j^2 * GLSZM(i, j)$$

Düşük Gri Skala Bölge Vurgusu (GLSZM_LGZE): Küçük bölge vurgusunun gri skaladaki karşılığıdır.

$$GLSZM_{LGZE} : \frac{1}{N_s} \sum_i^{N_g} \frac{GLSZM(i, j)}{i^2}$$

Yüksek Gri Skala Bölge Vurgusu (GLSZM_HGZE): Yüksek gri intensite bölgelerinin ölçüsüdür. Büyük bölge vurgusunun gri skala karşılığıdır.

$$GLSZM_{HGZE} : \frac{1}{N_s} \sum_i^{N_g} i^2 * GLSZM(i, j)$$

Düşük Gri Skala Küçük Bölge Vurgusu (GLSZM_SZLGE): Matrisin sol üst kadrana denk gelir ve görüntüye düşük gri değerli küçük bölgelerin hakimiyetini gösterir.

$$GLSZM_{SZLGE} : \frac{1}{N_s} \sum_i^{N_g} \sum_j^{N_z} \frac{GLSZM(i, j)}{i^2 * j^2}$$

Yüksek Gri Skala Küçük Bölge Vurgusu (GLSZM_SZHGE): Matrisin sol alt kadranına denk gelir ve görüntüye yüksek gri değerli küçük bölgelerin hakimiyetini gösterir.

$$GLSZM_{SZHGE} : \frac{1}{N_s} \sum_i^{N_g} \sum_j^{N_z} \frac{GLSZM(i, j) * i^2}{j^2}$$

Düşük Gri Skala Büyük Bölge Vurgusu (GLSZM_LZLGE): Matrisin sağ üst kadranına denk gelir ve görüntüye düşük gri değerli büyük bölgelerin hakimiyetini gösterir.

$$GLSZM_{LZLGE} : \frac{1}{N_s} \sum_i^{N_g} \sum_j^{N_z} \frac{GLSZM(i, j) * j^2}{i^2}$$

Yüksek Gri Skala Büyük Bölge Vurgusu (GLSZM_LZHGE): Matrisin sağ alt kadranına denk gelir ve görüntüye yüksek gri değerli küçük bölgelerin hakimiyetini gösterir.

$$GLSZM_{LZHGE} : \frac{1}{N_s} \sum_i^{N_g} \sum_j^{N_z} i^2 * j^2 * GLSZM(i, j)$$

Gri Skala Uyumsuzluğu (GLSZM_GLNU): Gri skala değerlerine göre bölge büyüklüklerinin dağılımının bir ölçüsüdür. Bölge sayısı, gri seviyelerine eşit dağılıyorsa değeri küçülür.

$$GLSZM_{GLNU} : \frac{1}{N_s} \sum_i^{N_g} GLSZM(i)^2$$

Bölge Boyutu Uyumsuzluğu (GLSZM_ZSNU): Gri skaladan bağımsız bölge boyutlarının dağılımının bir göstergesidir.

$$GLSZM_{ZSNU} : \frac{1}{N_s} \sum_j^{N_z} GLSZM(j)^2$$

Bölge Oranı (GLSZM_ZP): Gerçekleşen bölge sayısının (N_s), vokseldeki toplam olabilecek potansiyel bölge sayısına (N_v) oranıdır. Birbirine benzer bölgeler, gerçekleşen bölge sayısını azaltacağından, kesirin küçülmesi düzen-homojenite anlamına gelir.

$$GLSZM_{ZP} = \frac{N_s}{N_v}$$

5.2.7. Komşu Gri Skala Fark Matrisi (NGTDM)

Gri Skala Birlikte Oluşum Matrisi (GLCM)'ne bir alternatif olarak tanıtılmıştır. Bir pikselin gri ton değerini, komşularının ortalama gri ton değeriyle karşılaştırarak bir dizi matris oluşturur. Burada, her gri ton seviyesi için, o seviyeye sahip piksellerin çevresiyle olan farkı bir matrise kaydedilir. Bu farklar üzerinden bir görüntünün görsel özellikleri hakkında bilgi elde edilir. (34). Komşu Gri Skala Fark Matrisi (Neighbouring Gray Tone Difference Matrix), belli bir i gri seviyesindeki piksel/voksele δ uzaklığında (Chebyshev mesafesi) komşu piksel/vokselin gri seviye mutlak farklarının ortalamalarından oluşur. NGTDM matrisi özellikle gri skala değişikliklerinin ve lokal desenlerin bir ifadesidir.

NGTDM matrisinin oluşturulması Şekil 6'da şematize edilmiştir. Buna göre i gri skala seviyesini, ni ise bu i seviyesinden kaç adet olduğunu, pi toplam pikseller içinde ni 'nin olasılığını ve si ise bu gri skalaya karşılık gelen her bir hücrenin etrafındakiler ile farklarının karşılığı olan esas NGTDM değeridir.

1	2	2	3
1	2	3	3
4	2	4	1
4	1	2	3

(a) Grey levels

		n_i	p_i	s_i
i	1	0	0.00	0.000
	2	2	0.50	1.000
	3	1	0.25	0.625
	4	1	0.25	1.875

(b) Neighbourhood grey tone difference matrix

Şekil 6: NGTDM Matrisinin Oluşturulması

Bu matris hesaplandıktan sonra, matris üzerinden 3 tekstür özelliği tariflenmiştir.

Kabalık (Coarseness): Santraldeki gri değeri ile komşulukları arasındaki ortalama farkın bir ölçüsü olup spasyal değişim hızını gösterir. Komşuluklar arası fark ne kadar az ise, yani doku ne kadar homojen ise, payda küçüleceğinden değer artar (34).

$$NGTDM_{Coarseness} = \frac{1}{\sum_i^{N_g} p_i * s_i}$$

Kontrast (Contrast): Spasyal olarak komşuluklar arası gri skala seviyelerinin farkıdır. Ancak kontrast toplam gri skala seviyesine (yani dinamik aralığa) da bağlıdır. Her ikisi de yüksek olduğunda kontrast fazladır (34).

$$NGTDM_{Contrast} = \left(\frac{1}{N_{g,p}(N_{g,p} - 1)} \sum_{i_1}^{N_g} \sum_{i_2}^{N_g} p_{i_1} * p_{i_2} * (i_1 - i_2)^2 \right) \left(\frac{1}{N_{v,c}} \sum_i^{N_g} s_i \right)$$

Meşguliyet (Busyness): Komşu gri skalaları arasında büyük farklar olan dokular meşgul olarak tanımlanmıştır.

$$NGTDM_{Busyness} = \frac{\sum_i^{N_g} p_i * s_i}{\sum_{i_1}^{N_g} \sum_{i_2}^{N_g} |i_1 p_{i_1} - i_2 p_{i_2}|}$$

Karmaşıklık (Complexity): Düzensiz ve değişikliklerin hızlı olduğu dokular karmaşıktır (34).

$$NGTDM_{Complexity} = \frac{1}{N_{v,c}} \sum_{i_1}^{N_g} \sum_{i_2}^{N_g} |i_1 - i_2| \frac{p_{i_1} s_{i_1} + p_{i_2} s_{i_2}}{p_{i_1} + p_{i_2}}$$

6. Makine Öğrenmesi

Makine öğrenimi (ML), yapay zekâ alanında, verilerden öğrenebilen ve görülmemiş verilere genelleme yaparak görevleri yerine getirebilen istatistiksel algoritmaların geliştirilmesi ve incelenmesiyle ilgili bir çalışma alanıdır. Bu sayede, makine öğrenimi explicit (açık) talimatlar olmadan görevleri yerine getirebilir. Makine öğrenmesi örnek verilerden istatistiksel tahimler yapan bir algoritma oluşturarak yeni sonuçlar tahmin eder.

Makine öğrenmesi (ML) temel olarak üç ana türde sınıflandırılabilir: denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning). Her biri, farklı türdeki veri ve problem türlerine göre kullanılır.

Denetimli öğrenme, modelin, giriş verileri ve bu verilere karşılık gelen doğru çıktılar (etiketler) kullanılarak eğitildiği bir yöntemdir. Model, bu etiketli verilerle öğrenir ve ardından yeni, etiketlenmemiş veriler üzerinde tahmin yapabilir.

Denetimsiz öğrenme, modelin etiketlenmemiş verilerle çalıştığı ve verinin yapısını, örüntülerini veya gizli ilişkilerini öğrenmeye çalıştığı bir yaklaşımdır. Burada modelin neyi öğrenmesi gerektiği hakkında bir etiket veya doğru yanıt yoktur.

Pekiştirmeli öğrenme, bir sistem ile çevresi arasındaki etkileşim üzerinden öğrenmeyi hedefler. Sistem, çevreye yaptığı eylemler sonucu ödüller veya cezalar alır ve bu geri

bildirimlere göre en iyi stratejiyi öğrenir. Bu tür, özellikle zamanla bir dizi karar alması gereken durumlarda kullanılır.

Çalışmamızda radiomiks verileri denetimli öğrenme algoritmaları kullanılarak karşılaştırılmaya alınmıştır.

6.1. 1. Lojistik Regresyon (Logistic Regression)

Lojistik regresyon, genellikle ikili sınıflandırma problemlerinde (örneğin, evet/hayır) kullanılan bir algoritmadır. Giriş değişkenlerinin doğrusal kombinasyonunu alarak bir olasılık değeri üretir ve bu değeri sınıflara ayırır. **Sigmoid fonksiyonu** kullanarak çıktıyı 0 ile 1 arasında bir değere dönüştürür.

- **Kullanım Alanları:** Hastalık teşhisi (hasta/sağlıklı), müşteri memnuniyeti (memnun/şikayetli).
- **Avantajlar:** Hızlı, basit ve anlaşılır.
- **Dezavantajlar:** Sadece doğrusal ilişkilerde iyi performans gösterir.

6.2. 2. Destek Vektör Makineleri (SVM - Support Vector Machines)

SVM, iki sınıf arasındaki en iyi ayrımı yapan hiper düzlemi (veya sınırı) bulmaya çalışır. Bu sınır, sınıflar arasındaki marjı maksimize eder. SVM, doğrusal olmayan sınıflandırmalar için çekirdek (kernel) fonksiyonları kullanarak veriyi daha yüksek boyutlu bir uzaya dönüştürür.

- **Kullanım Alanları:** Yüz tanıma, metin sınıflandırma, biyolojik veri analizi.
- **Avantajlar:** Genellikle çok iyi genelleme performansı sağlar ve yüksek boyutlu veriyle de iyi çalışır.
- **Dezavantajlar:** Hesaplama açısından pahalı olabilir ve büyük veri kümelerinde yavaş çalışabilir.

6.3. 3. Karar Ağaçları (Decision Trees)

Karar ağaçları, veriyi sınıflandırmak için bir dizi "evet/hayır" sorusuyla ilerleyen ağaç şeklinde bir model oluşturur. Ağaç her düğümde, veri kümesini daha küçük parçalara bölen bir özelliği seçer. Bu seçim, genellikle entropi veya Gini indeks gibi ölçütlerle yapılır.

- **Kullanım Alanları:** Müşteri segmentasyonu, kredi skorlama, pazarlama.
- **Avantajlar:** Kolay anlaşılır ve yorumlanabilir, hızlı eğitim.

- **Dezavantajlar:** Ağaçlar kolayca aşırı uyum (overfitting) gösterebilir.

6.4. 4. Rastgele Ormanlar (Random Forest)

Rastgele ormanlar, çok sayıda karar ağacından oluşan bir ensemble (toplu) öğrenme yöntemidir. Her bir ağaç, eğitim verisinin rastgele bir alt kümesiyle eğitilir ve nihai sınıflandırma, tüm ağaçların oylama sonucu belirlenir. Bu, tek bir karar ağacının aşırı uyum yapma problemini azaltır.

- **Kullanım Alanları:** Finansal modelleme, biyomedikal veri analizi, görüntü sınıflandırma.
- **Avantajlar:** Yüksek doğruluk, aşırı uyumu engeller, genelleme yeteneği yüksektir.
- **Dezavantajlar:** Hesaplama açısından pahalı olabilir, modelin yorumlanması zor olabilir.

6.5. 5. Naive Bayes

Naive Bayes, Bayes teoremi temelinde çalışan ve her özelliğin diğerlerinden bağımsız olduğu varsayımına dayanan bir sınıflandırma algoritmasıdır. Bu "naive" (saf) varsayım, algoritmanın hesaplamalarını basitleştirir ve hızlı hale getirir.

- **Kullanım Alanları:** E-posta spam sınıflandırma, metin sınıflandırma, duygu analizi.
- **Avantajlar:** Basit, hızlı ve verimli, özellikle büyük veri setlerinde iyi çalışır.
- **Dezavantajlar:** Özellikler arasındaki bağımlılığı göz ardı eder, bu da bazı karmaşık veri setlerinde zayıf performans anlamına gelebilir.

6.6. 6. K-En Yakın Komşu (KNN - k-Nearest Neighbors)

KNN, sınıflandırma için basit ve sezgisel bir yöntemdir. Bir örnek verisinin sınıfı, onun en yakın k komşusunun çoğunluğuna göre belirlenir. Yani, veriyi sınıflandırırken, en yakın komşularının hangi sınıfta olduğuna bakılır.

- **Kullanım Alanları:** El yazısı tanıma, yüz tanıma, tıbbi teşhisler.
- **Avantajlar:** Basit, herhangi bir varsayım yapmadan çalışır, esnektir.
- **Dezavantajlar:** Hesaplama açısından pahalı olabilir, büyük veri setlerinde yavaş çalışabilir, özellik mühendisliği gerektirir.

6.7. 7. Lineer Regresyon (Linear Regression)

Lineer regresyon, bağımsız değişkenlerin doğrusal kombinasyonuna dayalı olarak sürekli bir bağımlı değişkeni tahmin eder. Amaç, hata terimini (gerçek ve tahmin edilen değer arasındaki fark) minimize eden doğrusal bir model oluşturmak.

- **Kullanım Alanları:** Ev fiyat tahmini, satış tahmini, ekonomik göstergeler.
- **Avantajlar:** Basit, hızlı ve yorumlanabilir.
- **Dezavantajlar:** Sadece doğrusal ilişkilerde iyi performans gösterir, çoklu doğrusal bağlantı problemi (multicollinearity) gibi sınırlamaları vardır.

6.8. 8. Yapay Nöral Ağları (Artificial Neural Networks - ANN)

Sinir ağları, biyolojik sinir ağlarından ilham alınarak geliştirilen bir modeldir. Giriş verileri, ağın katmanları boyunca işlenir ve her katman, çıktıyı dönüştürerek sonuca ulaşır. Derin öğrenme algoritmalarında yaygın olarak kullanılır.

- **Kullanım Alanları:** Görüntü işleme, konuşma tanıma, doğal dil işleme.
- **Avantajlar:** Karmaşık ve büyük veri setlerinde yüksek doğruluk, esnek.
- **Dezavantajlar:** Eğitim süresi uzun olabilir, çok fazla hesaplama gücü gerektirir, modelin yorumlanması zor olabilir.

Bu algoritmalar, farklı veri türlerine ve problemlerine göre uygun yöntemler olarak seçilebilir. Genelde her bir algoritmanın avantajları ve zorlukları, hangi tür veri ile çalışıldığına ve hedefin ne olduğuna bağlı olarak değişir.

Gereç ve Yöntemler

1. Hasta Seçimi


T.C. Sağlık Bakanlığı Sağlık Bilimleri Üniversitesi Bakırköy Dr. Sadi Konuk Eğitim ve Araştırma Hastanesi Radyoloji Kliniği'nde Ocak 2023 ve Haziran 2024 tarihleri arasında bel veya kalça ağrısı sebebiyle kontrastsız sakroiliak eklem MR görüntülemesi yapılan hastalar retrospektif olarak tarandı. Çalışmamız retrospektif bir vaka çalışmasıdır. 2024/154 protokol kodlu etik kurul onayı 02.08.24 tarihinde alınmıştır. P değeri <0.05 anlamlı olarak kabul edilmiştir.

Çalışmaya dahil etme kriterleri

- Sakroiliak MRG çekimi olması
- 18 yaşından büyük olgular
- 80 yaşın altındaki olgular
- Yeterli kalite ve çekim protokolünde MR görüntülemesi olan hastalar
- Sakroiliak eklemde inflamatuvar patolojileri açısından laboratuvar tetkiki yapılmış olgular
- Bilgilendirilmiş gönüllü onam formunu doldurmuş hastalar

Çalışmadan dışlama kriterleri

- 18 yaşından küçük olgular
- Kemik iliğini etkileyen kronik hastalığı olan olgular
- Daha önce geçirilmiş travma, operasyon veya sakroiliak eklemde fraktür öyküsü olan hastalar
- Manyetik duyarlılık artefaktlarına bağlı görüntü distorsiyonu/artefaktları içeren MR İncelemeler
- Görüntülemesi olan 450 hastadan 95'i bu kriterlere göre çalışmaya dahil edildi.



Şekil 7: Akış Şeması

2. Görüntüleme protokolü


Sakroiliak eklem inceleme kliniğimizde bulunan Siemens Magnetom Verio 3T (Almanya) cihazla sakroiliak eklemi tamamen içine alacak şekilde 20 cm'lik bir alan tarandı. Toplamda coronal ve aksiyel planlarda 2'şer adet olmak üzere 4 sekans elde edildi. T2 – TIRM sekanslar aksiyel ve coronal planlarda TE 80ms TR 2000ms sırasıyla 576x382 ve 424x300 matrix boyutu ile NEX değeri 2 olacak şekilde T1A sekanslar coronal planda yağ baskılı olarak TE 8ms TR 350ms 276x236 matrix boyutu ve NEX değeri 2 olacak şekilde, aksiyel planda yağ baskısız olarak TE 9ms TR 400ms, 576x382 matrix boyutu ve NEX değeri 2 olacak şekilde alındı.

3. Radiomics verilerinin hesaplanması

Çalışmaya dahil edilen hastaların sakroiliak eklem segmentasyonları 3D Slicer Programı(35) ile yapılmıştır. Segmentasyon işlemi aksiyel planda elde edilen yağ baskılı T2A sekanslarda yirmi üç ve beş yıllık deneyime sahip iki radyolog tarafından yapılmış olup segmentasyon korelasyonu Sorensen Dice benzerlik formülü ile karşılaştırılıp %75'den az benzeşen ölçümler tekrarlanmıştır.

Sakroiliak eklem 3 boyutlu olarak segmente olarak her sakroiliak eklemde yuvarlak şekilli 2 boyutlu 3921 pixel içeren ROI şeklinde standardize edilmiştir. ROI yerleştirme kriterleri; a) sakroiliak eklem ROI 'nin tam ortasında olacak, b)anormal bulgu olan kesimler olabildiğince ROI içerisinde olacak, c) anatomik komşulukta bulunun yapılar (vasküler, sinirler, kaslar)

mümkün olduğunda ROI'ye dahil edilmeyecek şekilde oluşturulmuştur. Kesin ROI boyutu bu kriterleri karşılayabilen mümkün olduğunca büyük boyutta olacak şekilde tüm incelemelerde aynı boyutta tutulmuştur. Anormal bulgu bulunmayan hastalarda ROI iki ve üçüncü kriteri karşılayacak şekilde sakroiliak eklemin üst ve alt kısımlarına koyulmuştur.



Şekil 8: Segmentasyon örneği

Radiomics verileri 3D Slicer eklenti kütüphanesinde bulunan PyRadiomics(36) eklentisi ile hesaplanmıştır. PyRadiomics radiomiks özelliklerini hesaplamak için kullanılan açık kaynak kodlu bir Python paketidir. Platform, hem 2D hem de 3D'de özellik çıkarımını destekler ve bir ROI için tekil değerler hesaplamak ('segment tabanlı') ya da özellik haritaları oluşturmak ('voxel tabanlı') için kullanılabilir. Her sakroiliak eklem için histogram, ikinci ve üçüncü sıra tekstür analizleri 3D Slicer için PyRadiomics eklentisi kullanılarak hesaplandı. Çalışmamızda tüm sakroiliak eklemlerde aynı ROI kullanıldığı ve tümör segmentasyonu gibi kitlesel bir lezyonun segmentasyonu yapılmadığı için morfolojik radiomiks verileri kullanılmadı. Morfolojik veriler seçili ROI'nin şekli ile ilgili bilgiler içerdiği ve çalışmamızdaki tüm ROI'ler aynı boyut ve şekilde olduğu için karşılaştırmaya dahil edilmedi.

4. Veri İşlenmesi ve Özellik Seçimi

Çalışmamızda her hasta için 94 adet radiomiks verisi elde edilmiştir. Makine öğrenmesi yöntemleri kullanılmadan önce bu verilerin işleme uygun hale getirilmesi gerekmektedir. 94 adet radiomiks verisinden bazıları yapılacak karşılaştırma için anlamsız olabilir ve makine öğrenmesi algoritmalarının performansını düşürebilir. Bu yüzden bu algoritmalarda kullanıcak verilerin önceden belirlenmesi için özellik seçimi (feature selection) yapılması gerekmektedir. Özellik seçimi, veri setindeki en önemli, anlamlı ve etkili özelliklerin (değişkenlerin) seçilmesi işlemidir. Bu sayede, gereksiz veya düşük bilgi taşıyan özellikler modele dahil edilmez ve model daha verimli çalışır. Özellik seçimi genellikle üç farklı yaklaşımla yapılır: filtre yöntemleri (filter methods), sarmal yöntemler (wrapper methods) ve gömülü yöntemler (embedded methods). Çalışmamızda özellik seçimi filtre yöntemi ile yapılmıştır.

Ayrıca bazı veri setlerinde her grubun eşit derecede temsil edilmemesinden kaynaklı sınıf dengesizliği problemi ortaya çıkabilir. Yani, bir sınıf (örneğin, negatif örnekler) çok fazla örneğe sahipken, diğer sınıf (örneğin, pozitif örnekler) çok daha az sayıda örneğe sahip olabilir. Makine öğrenmesi algoritmalarının bazıları az sayıda olan sınıfın özelliklerini görmezden gelemeye yatkın olabilir. Bu tür bir dengesizlik, modelin doğru ve adil bir şekilde eğitim almasını zorlaştırabilir ve modelin performansını olumsuz etkileyebilir. Çalışmamızda her sınıf için benzer sayılarda hasta sayısı bulunduğu için sınıf dengesizliği sorunu yoktur. Bu yüzden eğitim verilerinde herhangi oversampling yada undersampling işlemi yapılmamıştır.

BULGULAR

1. Hastaların Demografik Özellikleri

Çalışmaya dahil edilen 52 kadın 43 erkek toplam 95 hasta inflamatuvar hastalık ASAS kriterlerine göre 3 kategoriye ayrılmıştır. New York kriterlerini karşılayan 14 kadın 20 erkek hasta toplam 34 ankilozan spondilitli hasta, sakroiliak ekleminde herhangi bir bulgusu olmayan ve New York kriterlerini karşılamayan 12 erkek 18 kadın kontrol grubu ve sakroiliak ekleminde kemik iliği ödemi bulgusu olup New York kriterlerini karşılamayan 9 erkek 21 kadın dejeneratif grup hastası bulunmaktadır. Kontrol grubu yaş ortalaması 42.6, ankilozan spondilitli grubun yaş ortalaması 41.1, dejeneratif grubunun yaş ortalaması ise 44.8 bulunmuştur. Erkek vakaların yaş ortalaması 40 kadın vakaların yaş ortalaması 44.9 bulunmuş olup bu gruplar arasında yaş ortalamaları istatistiksel olarak anlamlı bir farklılık saptanmamıştır.

Vakaların cinsiyet ve hastalıklara göre dağılımı aşağıdaki şekilde verilmiştir.

Hastalık	Sayı	%
Ankilozan Spondilit	34	36.2%
Dejeneratif	30	31.9%
Kontrol Grubu	30	31.9%

Tablo 2: Vakaların cinsiyet dağılımı

Vakaların hastalıklara göre cinsiyet dağılımı aşağıdaki tabloda verilmiştir.

Hastalık	Cinsiyet	Sayı	%
Ankilozan Spondilit	Erkek	21	22.1%
	Kadın	14	14.7%
Dejeneratif	Erkek	9	9.5%
	Kadın	21	22.1%
Kontrol Grubu	Erkek	12	12.6%
	Kadın	18	18.9%

Tablo 3: Vakaların gruplara göre dağılım şeması

Çalışmamıza dahil edilen 95 hastanın kriterlere uygun 150 sakroiliak eklemin T2A aksiyel serilerde 3D Slicer programı üzerinden 3 boyutlu segmentasyon yapıldıktan sonra 3D Slicer programında PyRadiomics modülü kullanılarak 130’ar tekstür parametresi hesaplandı.

Çalışmamızda yaptığımız segmentasyon standart bir ROI kullanıldığı için tekstür parametrelerinde şekille ilgili olanlar çıkarıldıktan sonra her sakroiliak eklem için toplam 93 tane tekstür parametre kaldı.

Tekstür değişkenleri grupları ise şöyledir; morfolojik parametreler, intensite bazlı parametreler, histogram bazlı parametreler ve GLCM, GLRLM, GLSZM, NGTDM gibi ikinci sıra matris bazlı tekstür değişkenleridir.

2. Tekstür Analizinin İstatiksel Sonuçları

Çalışmamızda New York Kriterlerine göre toplam 3 grup hasta yer almaktadır. Bu hasta gruplarının tekstür bileşenlerden özellik seçimi yapmak için Kruskal Wallis One Way Anova testi ile yapılmıştır.

T2A görüntüler üzerinden yapılan tekstür analizinde elde edilen 93 değişkenden $p < 0.001$ anlamlı olarak kabul edilmiştir. Bu 93 veriden 14 tanesi gruplar arasında istatistiksel olarak anlamlı bulunmuştur. Tabloda bu veriler arasındaki ilişki verilmiştir.

Kruskal-Wallis Testi

	χ^2	df	p
10Percentile	6.6828	2	0.035
90Percentile	6.0271	2	0.049
Energy	0.8589	2	0.651
Entropy	7.5681	2	0.023
InterquartileRange	0.8695	2	0.647
Kurtosis*	24.3395	2	<.001
Maximum	5.1081	2	0.078
MeanAbsoluteDeviation	3.2267	2	0.199
Mean	1.9104	2	0.385
Median	0.6058	2	0.739
Minimum	2.2580	2	0.323
Range	5.1842	2	0.075
RobustMeanAbsoluteDeviation	0.9787	2	0.613
RootMeanSquared	2.9841	2	0.225
Skewness*	73.2259	2	<.001
TotalEnergy	1.7966	2	0.407
Uniformity	6.9319	2	0.031

Variance	6.1449	2	0.046
Autocorrelation	7.3944	2	0.025
ClusterProminence*	14.0778	2	<.001
ClusterShade	13.2871	2	0.001
ClusterTendency	10.3708	2	0.006
Contrast	4.9092	2	0.086
Correlation*	15.8526	2	<.001
DifferenceAverage	4.8958	2	0.086
DifferenceEntropy	5.0264	2	0.081
DifferenceVariance	4.8693	2	0.088
Id	4.9173	2	0.086
Idm	4.9000	2	0.086
Idmn	2.3247	2	0.313
Idn	3.7187	2	0.156
Imc1*	19.9458	2	<.001
Imc2*	13.8938	2	<.001
InverseVariance	4.8849	2	0.087
JointAverage	6.8359	2	0.033
JointEnergy	6.8811	2	0.032

JointEntropy	7.0224	2	0.030
MCC*	15.6772	2	<.001
MaximumProbability	6.7111	2	0.035
SumAverage	6.8359	2	0.033
SumEntropy	7.9212	2	0.019
SumSquares	8.9907	2	0.011
DependenceEntropy	0.6760	2	0.713
DependenceNonUniformity	9.5876	2	0.008
DependenceNonUniformityNormalized	2.8483	2	0.241
DependenceVariance*	20.6097	2	<.001
GrayLevelNonUniformity*	30.8345	2	<.001
GrayLevelVariance	7.9125	2	0.019
HighGrayLevelEmphasis	6.0889	2	0.048
LargeDependenceEmphasis*	33.1714	2	<.001
LargeDependenceHighGrayLevelEmphasis	12.9147	2	0.002
LargeDependenceLowGrayLevelEmphasis*	23.9605	2	<.001
LowGrayLevelEmphasis	5.4919	2	0.064
SmallDependenceEmphasis	20.8562	2	<.001
SmallDependenceHighGrayLevelEmphasis	11.2194	2	0.004


SmallDependenceLowGrayLevelEmphasis*	34.3667	2	<.001
GrayLevelNonUniformity *	23.1958	2	<.001
GrayLevelNonUniformityNormalized	7.9406	2	0.019
GrayLevelVariance	7.9716	2	0.019
HighGrayLevelRunEmphasis	5.8915	2	0.053
LongRunEmphasis	5.1713	2	0.075
LongRunHighGrayLevelEmphasis	3.9433	2	0.139
LongRunLowGrayLevelEmphasis	4.8477	2	0.089
LowGrayLevelRunEmphasis	5.2144	2	0.074
RunEntropy	8.1856	2	0.017
RunLengthNonUniformity	0.8355	2	0.659
RunLengthNonUniformityNormalized	1.7831	2	0.410
RunPercentage	4.0483	2	0.132
RunVariance	1.5498	2	0.461
ShortRunEmphasis	2.0179	2	0.365
ShortRunHighGrayLevelEmphasis	3.1274	2	0.209
ShortRunLowGrayLevelEmphasis	3.9020	2	0.142
GrayLevelNonUniformity	4.9543	2	0.084
GrayLevelNonUniformityNormalized	5.9792	2	0.050

GrayLevelVariance	9.7412	2	0.008
HighGrayLevelZoneEmphasis	0.0256	2	0.987
LargeAreaEmphasis	10.4500	2	0.005
LargeAreaHighGrayLevelEmphasis	11.4601	2	0.003
LargeAreaLowGrayLevelEmphasis	9.0245	2	0.011
LowGrayLevelZoneEmphasis	1.5624	2	0.458
SizeZoneNonUniformity	2.2244	2	0.329
SizeZoneNonUniformityNormalized	0.6599	2	0.719
SmallAreaEmphasis	5.3878	2	0.068
SmallAreaHighGrayLevelEmphasis	3.1854	2	0.203
SmallAreaLowGrayLevelEmphasis	5.7791	2	0.056
ZoneEntropy	1.4141	2	0.493
ZonePercentage	4.3971	2	0.111
ZoneVariance	8.2212	2	0.016
Busyness	0.3282	2	0.849
Coarseness	0.6760	2	0.713
Complexity	5.4320	2	0.066
Contrast	3.5163	2	0.172
Strength	5.3957	2	0.067

Tablo 4: Radiomiks parametrelerinin istatistiksel olarak karşılaştırılması

Daha sonra bu 14 veriden Z skoru algoritması üzerinde Jamovi(37) programında standardize edilerek makine öğrenmesi algoritmaları için kullanılabilir hale getirildi.

Radiomiks Özelliklerinin Önem Skorları



Tablo 5: Radiomiks parametrelerinden istatistiksel olarak anlamlı olanların önem sırası tablosu

3. Makine Öğrenmesi Sonuçları

Makine öğrenmesi için hasta karşılaştırma grupları 4'e ayrılmıştır. Bu gruplar ankilozan spondilitli hastalar ve bulgusu olmayanlar (kontrol grubu), ankilozan spondilit ve sakroiliak eklemdede dejeneratif değişiklikleri olan hastalar, dejeneratif değişiklikleri olan hastalar ve kontrol grubu, ve son olarak bu üç hasta grubunun bir arada karşılaştırıldığı gruplardır.


3.1. Ankilozan Spondilitli ve Kontrol Grubunun Makine Öğrenmesi Sonuçları

Ankilozan Spondilitli ve Kontrol Grubunun karşılaştırması T2A sekanslarda elde edilen istatistiksel olarak en anlamlı bulunan 14 özellik kullanılarak MatLab programı üzerinde PCA işlevli ve işlevsiz 35'er, toplam 70 model oluşturuldu. PCA işlevinin başarı metriklerine ekstra katkısı olmamıştır. Oluşturulan en başarılı 4 modelin sonuçları tabloda verilmiştir.

Model Tipi	Logistic Regression	SVM	Naive Bayes	Neural Network
Duyarlılık	1.00	0.933	0.866	0.866
Özgüllük	0.909	0.916	0.916	0.818
NPD	1.00	0.916	0.846	0.818
PPD	0.937	0.933	0.928	0.866
Doğruluk	0.963	0.925	0.888	0.846
F1 Skoru	0.967	0.933	0.896	0.866
MKK	0.927	0.842	0.768	0.684

Tablo 6: Ankilozan Spondilit ve Kontrol Grubu karşılaştırmasının makine öğrenmesi başarı metrikleri (NPD: Negatif Prediktif Değer, PPD: Pozitif Prediktif Değer, MKK; Matthew Korelasyon Katsayısı)

Logistic Regression modeli %100 duyarlılık %90 özgüllük ve %96 doğruluk doğruluk ile bu grupların karşılaştırmasında en başarılı makine öğrenmesi modeli olmuştur. SVM modelinde %93 duyarlılık %91 özgüllük ve %92 doğruluk, Naive Bayes modelinde %86 duyarlılık %91 özgüllük ve %88 doğruluk, SVM modelinde ise %86duyarlılık, %81 özgüllük oranı ve %84 doğruluk oranı elde edilmiştir.



Şekil 9: Logistic Regression Modelinin test sonuçları


3.2. Ankilozan Spondilit ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan Grubun Makine Öğrenmesi Sonuçları

Ankilozan Spondilit ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan hasta grubu karşılaştırması T2A sekanslarda elde edilen istatistiksel olarak en anlamlı bulunan 14 özellik kullanılarak MatLab programı üzerinde PCA işlevli ve işlevsiz 35'er, toplam 70 model oluşturuldu. Oluşturulan en başarılı 4 modelin sonuçları tabloda verilmiştir.

<i>Model Tipi</i>	<i>SVM</i>	<i>Neural Network</i>	<i>Logistic Regression</i>	<i>KNN</i>
<i>Duyarlılık</i>	0.777	0.722	0.818	0.888
<i>Özgüllük</i>	0.857	0.750	0.631	0.750
<i>NPD</i>	0.750	0.642	0.857	0.818
<i>PPD</i>	0.875	0.812	0.562	0.842
<i>Doğruluk</i>	0.812	0.733	0.700	0.833
<i>F1 Skoru</i>	0.823	0.764	0.666	0.864
<i>MKK</i>	0.600	0.463	0.434	0.649

Tablo 7: Ankilozan Spondilit ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan Grubu karşılaştırmasının makine öğrenmesi başarı metrikleri (*NPD: Negatif Prediktif Değer; PPD: Pozitif Prediktif Değer; MKK; Matthew Korelasyon Katsayısı*)

KNN modeli %88 duyarlılık %75 özgüllük ve %83 doğruluk doğruluk ile bu grupların karşılaştırmasında en başarılı makine öğrenmesi modeli olmuştur. Neural Network modelinde %72 duyarlılık %75 özgüllük ve %73 doğruluk, Logistic Regression modelinde %81 duyarlılık %63 özgüllük ve %70 doğruluk, SVM modelinde ise %77duyarlılık, %85 özgüllük oranı ve %81 doğruluk oranı elde edilmiştir.



Şekil 10: KNN Modelinin test sonuçları.

3.3. Kontrol Grubu ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan Grubun Makine Öğrenmesi Sonuçları


Kontrol Grubu ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan hasta grubu karşılaştırması T2A sekanslarda elde edilen istatistiksel olarak en anlamlı bulunan 14 özellik kullanılarak MatLab programı üzerinde PCA işlevli ve işlevsiz 35'er, toplam 70 model oluşturuldu. Oluşturulan en başarılı 4 modelin sonuçları tabloda verilmiştir.

Model Tipi	Neural Network	Naive Bayes	Logistic Regression	Decision Tree
Duyarlılık	0.937	0.882	0.875	0.823
Özgüllük	1.000	1.000	0.928	0.923
NPD	0.933	0.867	0.867	0.800
PPD	1.000	1.000	0.933	0.933
Doğruluk	0.966	0.933	0.900	0.866
F1 Skoru	0.967	0.937	0.903	0.875
MKK	0.935	0.878	0.801	0.740

Tablo 8: Ankilozan Spondilit ve Sakroiliak Ekleminde Dejeneratif Değişiklikleri Olan Grubu karşılaştırmasının makine öğrenmesi başarı metrikleri (NPD: Negatif Prediktif Dğer, PPD: Pozitif Prediktif Değer, MKK; Matthew Korelasyon Katsayısı)

Neural network modeli %93 duyarlılık, %100 özgüllük oranı ve %96 doğruluk ile bu grupların karşılaştırmasında en başarılı makine öğrenmesi modeli olmuştur. Naive Bayes

modelinde %88 duyarlılık %100 özgüllük ve %93 doğruluk, Logistic Regression modelinde %87 duyarlılık %92 özgüllük ve %90 doğruluk, Decision Tree modelinde ise %82 duyarlılık %92 özgüllük ve %87 doğruluk oranı elde edilmiştir.



Şekil 11: Logistic Regression Modelinin test sonuçları


3.4. Ankilozan Spondilit Grubu ile Diğer Grupların Karşılaştırılması

Ankilozan Spondilit Grubu ile Diğer Grupların Karşılaştırılması T2A sekanslarda elde edilen istatistiksel olarak en anlamlı bulunan 14 özellik kullanılarak MatLab programı üzerinde PCA işlevli ve işlevsiz 35'er, toplam 70 model oluşturuldu. Oluşturulan en başarılı 4 modelin sonuçları tabloda verilmiştir.

Model Tipi	Neural Network	Lineer	SVM	KNN
	Discirimant			
Duyarlılık	0.833	0.888	0.818	0.769
Özgüllük	1.000	0.904	0.947	1.000
NPD	0.900	0.950	0.900	0.850
PPD	1.000	0.800	0.900	1.000
Doğruluk	0.933	0.900	0.900	0.900
F1 Skoru	0.909	0.842	0.857	0.869
MKK	0.866	0.771	0.782	0.808

Tablo 9: Ankilozan Spondilit Grubu ile Diğer Grupların Karşılaştırılmasının makine öğrenmesi başarı metrikleri (NPD: Negatif Prediktif Dğer, PPD: Pozitif Prediktif Değer, MKK; Matthew Korelasyon Katsayısı)

Neural network modeli %83 duyarlılık, %100 özgüllük oranı ve %93 doğruluk ile bu grupların karşılaştırmasında en başarılı makine öğrenmesi modeli olmuştur. Lineer Discriminant modelinde %88 duyarlılık %90 özgüllük ve %90 doğruluk, SVM modelinde %81 duyarlılık %94 özgüllük ve %90 doğruluk, KNN modelinde ise %76 duyarlılık %100 özgüllük ve %90 doğruluk oranı elde edilmiştir.





Şekil 12: Neural Network Modelinin test sonuçları

VAKA ÖRNEKLERİ

1. Vaka 1


52 yaşındaki erkek hasta, hastanemizin romatoloji kliniğine uyandıktan sonra şiddetli başlayan gün için azalan bel ve kalça ağrısı nedeni ile başvuruyor. İnflamatuvar bel ağrısı tarifleyen hastadan hemogram, biyokimya, HLA B27 testleri isteniyor. Sakroiliak MR görüntülemesi yapılması içinse radyoloji kliniğimize başvuruyor. Laboratuvar tetkiklerinde HLA B27 pozitif bulunuyor. Hemogramında WBC değeri 13.000, biyokimya testlerinde ise CRP değeri 15 tespit ediliyor. Çekilen MR görüntülemesinde T2A aksiyel sekansı şekilde verilmiştir. Her iki sakroiliak ekleme komşu iliak ve sakral kemikte ileri derecede kemik iliği ödemi izlenmektedir. Hasta New York kriterleri ile birlikte değerlendirildiğinde Ankilozan Spondilit tanısı almıştır. Lezyonun radiomiks özellikleri geliştirilen makine öğrenmesi modeli ile birlikte değerlendirildiğinde, model lezyonu doğru olarak tespit edebilmiştir.



Şekil 13: Vaka1'in Makine Öğrenmesi Model Sınıfı

2. Vaka 2



37 yaşında kadın hasta hastanemizin beyin ve sinir cerrahisi kliniğine yürümekle artan bel ağrısı şikayeti ile başvuruyor. Hastadan hemogram, biyokimya, HLA B27 testleri isteniyor. Lomber ve Sakroiliak MR görüntülemesi yapılması içinse radyoloji kliniğimize başvuruyor. Yapılan laboratuvar testlerinde herhangi bir anomali tespit edilmiyor. Çekilen lomber MR'de disk hernisine rastlanmıyor. Sakroiliak eklem görüntülemesi aşağıda verilmiştir. Sol sakroiliak eklem orta kesim anteriorda ekleme komşu sakral yüzde küçük bir alanda kemik iliği ödemi tespit ediliyor. New York kriterlerini karşılamayan hastada bulgular ankilozan spondilit lehine değerlendirilmiyor. Ankilozan spondilite bağlı olmayan kemik iliği ödemi olarak kabul ediliyor. Lezyonun radiomiks özellikleri geliştirilen makine öğrenmesi modeli ile birlikte değerlendirildiğinde, model lezyonu doğru olarak tespit edebilmiştir.



Şekil 14: Vaka 2'in Makine Öğrenmesi Model Sınıfı

3. Vaka 3

29 yaşında erkek hasta hastanemizin romatoloji kliniğine sabahları otuz dakika süren bel ağrısı şikayeti ile başvuruyor. Hastadan hemogram, biyokimya, HLA B27 testleri isteniyor. Sakroiliak MR görüntülemesi yapılması içinse radyoloji kliniğimize başvuruyor. Hastanın laboratuvar ve radyolojik görüntülerinde herhangi bir anomaliye rastlanmıyor. Lezyonun radiomiks özellikleri geliştirilen makine öğrenmesi modeli ile birlikte değerlendirildiğinde, model vakayı doğru kategorize edebilmiştir.



Vaka 3: Vaka 3'in Makine Öğrenmesi Model Sınıfı

TARTIŞMA

Yapay zeka bilişim devrimindeki bir sonraki büyük dalga olarak övülmüş ve sağlık sektörü de dahil olmak üzere birçok endüstri için dönüştürücü bir teknoloji olarak gösterilmiştir(38). Tıp biliminin belki de teknoloji ile en alakalı bölümü olarak gösterebilecek radyolojinin de bu gelişmelerden kaçınması mümkün değildir. Özellikle yapay zekanın görüntü işlemedeki üstünlüğü, görüntülerde insan gözünün göremeyeceği özelliklerin çıkarılmasındaki başarı sayesinde radyoloji biliminde yeni ufuklar ortaya çıkarmaktadır. Radiomiks ve doku analizi gibi yöntemlerle görüntülerden büyük miktarlarda kantitatif ve objektif veri elde edilmiştir. Bu büyüklükte bir veri tabının ise radyologlar tarafından tek tek incelenmesi zaman ve maliyet açısından etkin değildir(39). Günümüzdeki modern bilgisayarlar milyarlarca veriyi saniyeler gibi kısa sürelerde işleyebilmektedir. Bu bilgisayarlar kullanılarak bu büyüklükte verilerin yapay zeka algoritmaları kullanılarak incelenmesi radyologların işini kolaylaştırabilir(40).

Radyoloji alanında yapay zekanın uygulama alanlarında kanser görüntülemeleri başı çekmektedir(41). Fakat günümüzde yapay zekanın uygulama alanları artan işlem gücüyle birlikte çoğalmaktadır. Bu alanlardan biride kas iskelet görüntülemesidir. Amerika Birleşik Devletleri'nde 2021 yılında yapılan MR görüntülemelerin %30'unu kas iskelet görüntüleme oluşturmaktadır(42).

Kas iskelet sistemi ile alakalı yapay zeka çalışmaları bir çok farklı alana odaklanmaktadır. Diz eklemi görüntülemesinde menisküs yaralanmaları, bağ yırtıkları, osteoartrit tanısı ve prognozunda, omurga ile alakalı çalışmalarda disk hernisi ve spondiloartrit tanısı, kemik kırıkları ve osteoporoz değerlendirmesi gibi pek çok alanda çeşitli araştırmalar yapılmaktadır.

Sakroiliak eklem patolojilerinde ise özellikle inflamatuvar artrit tanısı ve diğer hastalıklarından ayrımı ile alakalı çalışmalar önemli bir yer tutmaktadır. Bizim çalışmamızda da yapay zeka, makine öğrenmesi algoritmaları kullanılarak bu inflamatuvar hastalıkların diğer hastalıklarından ayrımındaki etkinliği ölçmeyi amaçladık. Çalışmamızda daha objektif veriler elde edebilmek için ASAS kriterlerini kullanarak ankilozan spondiliti inflamatuvar hastalık örneği olarak kullandık. Özellikle sakroiliak eklemdaki kemik iliği ödeminin ayrıcı tanısının yapılması hasta yönetimi açısından önemlidir.

Kepp ve arkadaşları tarafından yapılan 90 vakayı kapsayan araştırmada (43)umut verici sonuçlar ortaya konulmuştur. Bu çalışmada literatürdeki diğer çalışmalardan farklı olarak bizim çalışmamızda olduğu gibi ankilozan spondilitli, dejeneratif değişikliği bulunan ve

kontrol grubu olmak üzere 3 hasta grubu kullanılmıştır. Fakat bizim ve literatürdeki diğer çalışmalardan farklı olarak bu çalışma T2A ve T1A kontrastlı görüntüler kullanılarak yapılmış olup kontrastlı serilerdeki makine öğrenmesi başarı oranı daha yüksek bulunmuştur. Fakat kontrastlı görüntüler bizim kliniğimizde rutin protokolde yer almakta olup ASAS çalışma grubunda kontrastlı görüntülerle ilgili bir sekme yoktur(44). Bu yüzden biz rutin protokolde yer alan T2A görüntüler üzerinde makine öğrenmesi modelleri geliştirdik. Faleiros ve arkadaşları (45), algoritmalarını eğitmek için 56 hastaya ait koronal STIR görüntülerini kullanmış ve bu görüntüleri, subkondral kemik iliği ödeminin varlığına göre inflamatuvar sakroiliit için pozitif ya da negatif olarak etiketlemiştir. Çalışmada kullanılan veri setinin, pozitif vakaların oranı %43 iken, diğer çalışmalarda bu oran yaklaşık %25'tir. Çalışmalarında en etkili modelin, doğrulama setlerinde sırasıyla %80 doğruluk ve %66.7 spesifisite oranı elde eden bir Çok Katmanlı Algılayıcı (MLP) sınıflayıcı olduğu bulunmuştur. MLP, yapay zeka ve makine öğrenimi uygulamalarında sıklıkla kullanılan bir yöntemdir ve görüntü sınıflandırma görevlerinde etkili sonuçlar verme kapasitesine sahiptir

Ye L. ve arkadaşları da (46)aktif sakroiliit teşhisi için radyomiks ve klinik verileri entegre ederek bir nomogram oluşturmayı amaçlamıştır. Çalışmalarında Faleiros ve arkadaşlarının çalışmasındaki gibi hastaları subkondrol kemik iliği ödeme göre ikiye ayrılmış toplam 638 vaka kullanılmıştır. MR sekansı olarak STIR sekans kullanılmıştır. Makine öğrenmesi başarıları %70.9 duyarlılık ve %81.3 özgüllükle sonuçlanmıştır.

Triantafyllou ve arkadaşları (47) 354 tane sakroilaik eklem üzerinden yaptıkları çalışmalarda vakaları inflamatuvar ve inflamatuvar olmayan kemik iliği ödeme göre iki gruba ayırmıştır. XGBoost makine öğrenmesi modeli 0.71 AUC-ROC değeri sağlayarak en başarılı makine öğrenmesi algoritması olmuştur.

Çalışmamızda toplam 95 hastadan oluşan bir vaka grubu kullanılmıştır. Bu gruplar ankilozan spondilite bağlı kemik iliği ödemi, dejenerasyon bağlı kemik iliği ödemi ve bulgusu olmayan kontrol grubundan oluşmaktadır. 95 hastadan toplan 154 sakroiliak eklemlerle alakalı 93 tane radiomiks verisi toplanmış ve aralarında istatistiksel olarak anlamlı bulunan 14 tane veri makine öğrenmesi algoritmalarında kullanılmak üzere ayrılmıştır. Radiomiks verileri yağ baskılı T2A serilerden elde edilmiştir. Diğer çalışmalardan farklı olarak her grup, diğer iki grupla ayrı ayrı ve ankilozan spondilit ile diğer gruplar olmak üzere 4 karşılaştırma yapılmıştır. Kontrol grubu ve ankilozan spondilit grubunun karşılaştırılmasında Logistic Regression modeli %100 duyarlılık %90 özgüllük ve %96 doğruluk en başarılı model olmuştur. Ankilozan Spondilit ve Dejeneratif grubunun karşılaştırılmasında KNN modeli

%88 duyarlılık %75 özgüllük ve %83 doğruluk ile başarılı model olmuştur. Dejeneratif grup ile kontrol grubunun karşılaştırılmasında Neural network bazlı model %93 duyarlılık, %100 özgüllük oranı ve %96 doğruluk ile en başarılı model olmuştur. Ankilozan spondilit grubu ile diğer grupların karşılaştırmasında ise Neural network bazlı model %83 duyarlılık, %100 özgüllük oranı ve %93 doğruluk ile bu grupların karşılaştırmasında en başarılı makine öğrenmesi modeli olmuştur.

Çalışmamızda bazı limitasyonlarda bulunmaktadır. Yapay zeka modelleri ne kadar çok veriyle çalışırsa o kadar başarılı olma eğilimindedir. Bu yüzden 95 hasta ve 154 sakroiliak eklemden oluşan bir vaka grubu az sayılabilir. Fakat literatürdeki diğer çalışmalarda da Ye L ve arkadaşlarının çalışması hariç benzer sayılarda vaka kullanılmıştır. Retrospektif veri toplamanın, aşırı uyum sağlamaya yol açabilecek doğasıda bir limitasyon sayılabilir. Her hasta grubundan benzer oranlarda bulunması toplumdaki ankilozan spondilit prevalans ile bağdaşmamaktadır ve buda aşırı uyumun ortaya çıkmasına neden olabilir.

SONUÇ

Çalışmamız sakroiliak eklemin inflamatuvar hastalıklarının dejeneratif hastalıklarından ayrımında radiomiks verileri kullanılarak makine öğrenmesi algoritmalarının kullanımının hastalıkları yüksek doğruluk ve özgüllük oranları ile tahmin edebileceğini göstermiştir. Böyle bir radyomiks model, sağlam bir dış doğrulamanın ardından PACS (Görüntü Arşivleme ve İletişim Sistemi) modülüne entegre edilebilir. Bu, özellikle kas-iskelet görüntüleme konusunda uzmanlaşmamış radyologların teşhis kararlarını desteklemek için faydalı olabilir. Radyomiks verilerin analizi, hastalıkların daha doğru bir şekilde tanınmasına ve teşhis süreçlerinin iyileştirilmesine katkıda bulunabilir.



KAYNAKÇA

1. Vleeming A, Schuenke MD, Masi AT, Carreiro JE, Danneels L, Willard FH. The sacroiliac joint: an overview of its anatomy, function and potential clinical implications. *J Anat.* Aralık 2012;221(6):537-67.
2. Dietrichs E. Anatomy of the pelvic joints--a review. *Scand J Rheumatol Suppl.* 1991;88:4-6.
3. Egund N, Jurik AG. Anatomy and histology of the sacroiliac joints. *Semin Musculoskelet Radiol.* Temmuz 2014;18(3):332-9.
4. Buchanan BK, Varacallo M. Sacroiliitis. 2024.
5. Baronio M, Sadia H, Paolacci S, Prestamburgo D, Miotti D, Guardamagna VA, vd. Etiopathogenesis of sacroiliitis: implications for assessment and management. *Korean J Pain.* 01 Ekim 2020;33(4):294-304.
6. Zhu W, He X, Cheng K, Zhang L, Chen D, Wang X, vd. Ankylosing spondylitis: etiology, pathogenesis, and treatments. *Bone Res* [Internet]. 01 Aralık 2019 [a.yer 10 Kasım 2024];7(1):22. Erişim adresi: <https://pmc.ncbi.nlm.nih.gov/articles/PMC6804882/>
7. Türkiye Cumhuriyeti Sağlık Bakanlığı. TÜRKİYE KAS ve İSKELET SİSTEMİ HASTALIKLARI ÖNLEME ve KONTROL PROGRAMI 2015-2020.
8. de BLECOURT J, POLMAN A, de BLECOURT-MEINDERSMA. Hereditary factors in rheumatoid arthritis and ankylosing spondylitis. *Ann Rheum Dis.* Eylül 1961;20(3):215-20.
9. Reveille JD. An update on the contribution of the MHC to AS susceptibility. *Clin Rheumatol.* Haziran 2014;33(6):749-57.
10. Brown MA. Genetics of ankylosing spondylitis. *Curr Opin Rheumatol.* Mart 2010;22(2):126-32.
11. Rudwaleit M. Low T cell production of TNFalpha and IFNgamma in ankylosing spondylitis: its relation to HLA-B27 and influence of the TNF-308 gene polymorphism. *Ann Rheum Dis.* 01 Ocak 2001;60(1):36-42.
12. Sieper J, Braun J, Kingsley GH. Report on the Fourth International Workshop on Reactive Arthritis. *Arthritis Rheum.* Nisan 2000;43(4):720-34.
13. Martin TM, Smith JR, Rosenbaum JT. Anterior uveitis: current concepts of pathogenesis and interactions with the spondyloarthropathies. *Curr Opin Rheumatol.* Temmuz 2002;14(4):337-41.
14. Wanders A, Landewé R, Dougados M, Mielants H, van der Linden S, van der Heijde D. Association between radiographic damage of the spine and spinal mobility for individual patients with ankylosing spondylitis: can assessment of spinal mobility be a proxy for radiographic evaluation? *Ann Rheum Dis.* Temmuz 2005;64(7):988-94.
15. Dougados M, van der Linden S, Juhlin R, Huitfeldt B, Amor B, Calin A, vd. The European Spondylarthropathy Study Group preliminary criteria for the classification of spondylarthropathy. *Arthritis Rheum.* Ekim 1991;34(10):1218-27.
16. van der Linden S, van der Heijde D. Ankylosing spondylitis. Clinical features. *Rheum Dis Clin North Am.* Kasım 1998;24(4):663-76, vii.
17. Lassiter W, Bhutta BS, Allam AE. Inflammatory Back Pain. *StatPearls* [Internet]. 26 Şubat 2024 [a.yer 10 Kasım 2024]; Erişim adresi: <https://www.ncbi.nlm.nih.gov/books/NBK539753/>

18. Rudwaleit M, Van Der Heijde D, Khan MA, Braun J, Sieper J. How to diagnose axial spondyloarthritis early. *Ann Rheum Dis* [Internet]. Mayıs 2004 [a.yer 10 Kasım 2024];63(5):535-43. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/15082484/>
19. Relative value of erythrocyte sedimentation rate and C-reactive protein in assessment of disease activity in ankylosing spondylitis - PubMed [Internet]. [a.yer 10 Kasım 2024]. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/10229432/>
20. Imaging of the seronegative spondyloarthropathies - PubMed [Internet]. [a.yer 12 Kasım 2024]. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/11123073/>
21. Evaluation of diagnostic criteria for ankylosing spondylitis. A proposal for modification of the New York criteria - PubMed [Internet]. [a.yer 12 Kasım 2024]. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/6231933/>
22. Carrera GF, Foley WD, Kozin F, Ryan L, Lawson TL. CT of sacroiliitis. *AJR Am J Roentgenol* [Internet]. 1981 [a.yer 12 Kasım 2024];136(1):41-6. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/6779578/>
23. Early recognition of sacroiliitis by magnetic resonance imaging and single photon emission computed tomography - PubMed [Internet]. [a.yer 12 Kasım 2024]. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/7869315/>
24. Lambert RGW, Bakker PAC, Van Der Heijde D, Weber U, Rudwaleit M, Hermann KGA, vd. Defining active sacroiliitis on MRI for classification of axial spondyloarthritis: update by the ASAS MRI working group. *Ann Rheum Dis* [Internet]. 01 Kasım 2016 [a.yer 12 Kasım 2024];75(11):1958-63. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/26768408/>
25. Asada M, Tokunaga D, Arai Y, Oda R, Fujiwara H, Yamada K, vd. Degeneration of the Sacroiliac Joint in Hip Osteoarthritis Patients: A Three-Dimensional Image Analysis. *J Belg Soc Radiol* [Internet]. 23 Mayıs 2019 [a.yer 16 Aralık 2024];103(1):36. Erişim adresi: <https://pmc.ncbi.nlm.nih.gov/articles/PMC6534012/>
26. Bäcklund J, Clewett Dahl E, Skorpil M. Is CT indicated in diagnosing sacroiliac joint degeneration? *Clin Radiol*. 01 Ağustos 2017;72(8):693.e9-693.e13.
27. Longo UG, Loppini M, Berton A, Laverde L, Maffulli N, Denaro V. Degenerative changes of the sacroiliac joint after spinal fusion: an evidence-based systematic review. *Br Med Bull* [Internet]. 01 Aralık 2014 [a.yer 16 Aralık 2024];112(1):47-56. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/25355839/>
28. Gillies RJ, Kinahan PE, Hricak H. Radiomics: Images Are More than Pictures, They Are Data. *Radiology* [Internet]. 01 Şubat 2016 [a.yer 12 Kasım 2024];278(2):563-77. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/26579733/>
29. Yip SSF, Aerts HJWL. Applications and limitations of radiomics. *Phys Med Biol* [Internet]. 07 Haziran 2016 [a.yer 12 Kasım 2024];61(13):R150-66. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/27269645/>
30. Mall PK, Singh PK, Yadav D. GLCM based feature extraction and medical X-RAY image classification using machine learning techniques. 2019 IEEE Conference on Information and Communication Technology, CICT 2019. 01 Aralık 2019;
31. Öztürk Ş, Akdemir B. Application of Feature Extraction and Classification Methods for Histopathological Image using GLCM, LBP, LBGLCM, GLRLM and SFTA. *Procedia Comput Sci*. 01 Ocak 2018;132:40-6.
32. Galloway MM. Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*. 01 Haziran 1975;4(2):172-9.

33. Thibault G, Angulo J, Meyer F. Advanced statistical matrices for texture characterization: Application to cell classification. *IEEE Trans Biomed Eng.* Mart 2014;61(3):630-7.
34. Amadasun M, King R. Textural Features Corresponding to Textural Properties. *IEEE Trans Syst Man Cybern.* 1989;19(5):1264-74.
35. Fedorov A, Beichel R, Kalpathy-Cramer J, Finet J, Fillion-Robin JC, Pujol S, vd. 3D Slicer as an image computing platform for the Quantitative Imaging Network. *Magn Reson Imaging.* Kasım 2012;30(9):1323-41.
36. Van Griethuysen JJM, Fedorov A, Parmar C, Hosny A, Aucoin N, Narayan V, vd. Computational Radiomics System to Decode the Radiographic Phenotype. *Cancer Res [Internet].* 01 Kasım 2017 [a.yer 15 Aralık 2024];77(21):e104. Erişim adresi: <https://pmc.ncbi.nlm.nih.gov/articles/PMC5672828/>
37. The jamovi project (2024). jamovi (Version 2.5) [Computer Software]. Retrieved from <https://www.jamovi.org>.
38. Syed AB, Zoga AC. Artificial Intelligence in Radiology: Current Technology and Future Directions. *Semin Musculoskelet Radiol [Internet].* 2018 [a.yer 14 Aralık 2024];22(5):540-5. Erişim adresi: <http://www.thieme-connect.com/products/ejournals/html/10.1055/s-0038-1673383>
39. Giger ML. Machine Learning in Medical Imaging. *Journal of the American College of Radiology [Internet].* 01 Mart 2018 [a.yer 14 Aralık 2024];15(3):512-20. Erişim adresi: <http://www.jacr.org/article/S1546144017316733/fulltext>
40. Giger ML. Machine Learning in Medical Imaging. *Journal of the American College of Radiology.* 01 Mart 2018;15(3):512-20.
41. Koh DM, Papanikolaou N, Bick U, Illing R, Kahn CE, Kalpathi-Cramer J, vd. Artificial intelligence and machine learning in cancer imaging. *Communications Medicine [Internet].* 01 Aralık 2022 [a.yer 14 Aralık 2024];2(1):133. Erişim adresi: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9613681/>
42. Rapid Musculoskeletal MRI in 2021: Value and Optimized Use of Widely Accessible Techniques | Enhanced Reader.
43. Kepp FH, Huber FA, Wurnig MC, Mannil M, Kaniewska M, Guglielmi R, vd. Differentiation of inflammatory from degenerative changes in the sacroiliac joints by machine learning supported texture analysis. *Eur J Radiol [Internet].* 01 Temmuz 2021 [a.yer 14 Aralık 2024];140. Erişim adresi: <http://www.ejradiology.com/article/S0720048X21002369/fulltext>
44. Sieper J, Rudwaleit M, Baraliakos X, Brandt J, Braun J, Burgos-Vargas R, vd. The Assessment of SpondyloArthritis international Society (ASAS) handbook: a guide to assess spondyloarthritis. *Ann Rheum Dis.* 01 Haziran 2009;68(Suppl 2):ii1-44.
45. Faleiros MC, Nogueira-Barbosa MH, Dalto VF, Júnior JRF, Tenório APM, Luppino-Assad R, vd. Machine learning techniques for computer-aided classification of active inflammatory sacroiliitis in magnetic resonance imaging. *Advances in Rheumatology.* 07 Aralık 2020;60(1):25.
46. Ye L, Miao S, Xiao Q, Liu Y, Tang H, Li B, vd. A predictive clinical-radiomics nomogram for diagnosing of axial spondyloarthritis using MRI and clinical risk factors. *Rheumatology [Internet].* 11 Nisan 2022 [a.yer 14 Aralık 2024];61(4):1440-7. Erişim adresi: <https://dx.doi.org/10.1093/rheumatology/keab542>
47. Triantafyllou M, Klontzas ME, Koltsakis E, Papakosta V, Spanakis K, Karantanas AH. Radiomics for the Detection of Active Sacroiliitis Using MR Imaging. *Diagnostics 2023, Vol 13, Page 2587 [Internet].* 03 Ağustos 2023 [a.yer 14 Aralık 2024];13(15):2587. Erişim adresi: <https://www.mdpi.com/2075-4418/13/15/2587/htm>

