



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
UYGULAMALI MATEMATİK VE HESAPLAMALI BİLİMLER
ANABİLİM DALI

**Tıbbi Görüntülerde Skolyoz Sınıflandırması: Transfer
Öğrenme Destekli DVM Yaklaşımı**

Yüksek Lisans Tezi
Fatımanur Gültekin

Nisan 2025



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
UYGULAMALI MATEMATİK VE HESAPLAMALI BİLİMLER
ANABİLİM DALI

**Tıbbi Görüntülerde Skolyoz Sınıflandırması: Transfer
Öğrenme Destekli DVM Yaklaşımı**

Yüksek Lisans Tezi

Fatımanur Gültekin

Danışman

Doç. Dr. Betül Hiçdurmaz

Nisan 2025

TEZ JÜRİSİ ONAYI

Fatımanur Gültekin tarafından hazırlanan Tıbbi Görüntülerde Skolyoz Sınıflandırması: Transfer Öğrenme Destekli DVM Yaklaşımı " başlıklı bu Yüksek Lisans Tezi, Uygulamalı Matematik ve Hesaplamalı Bilimler Anabilim Dalı'nda hazırlanmış ve jürimiz tarafından kabul edilmiştir.

JÜRİ ÜYELERİ

İMZA

Tez Danışmanı:

Doç. Dr. Betül Hiçdurmaz
İstanbul Medeniyet Üniversitesi

Üyeler:

Prof. Dr. Özgür Yıldırım
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Nurullah Çalık
İstanbul Medeniyet Üniversitesi

Tez Savunma Tarihi: 21/ 04 / 2025

BEYANLAR

Yazım ve Kaynak Gösterme Kılavuzu Beyanı

Danışmanlığımda yazılan bu tezin APA yazım ve kaynak gösterme kılavuzunda belirtilen kurallara uygun olarak yapılandırıldığı ve bu kılavuzun metin içi kaynak gösterme standartlarının bu tezde tutarlı olarak uygulandığı tarafımdan incelenerek teyit edilmiştir.

İmza

Doç. Dr. Betül Hiçdurmaz

Etik İlkeler Sadakat Beyanı

Hazırladığım bu tezin tamamen kendi çalışmam olduğunu, akademik ve etik kuralları gözeterek çalıştığımı ve her alıntıya kaynak gösterdiğimi beyan ederim.

İmza

Fatımanur Gültekin

ÖZET

Tıbbi Görüntülerde Skolyoz Sınıflandırması: Transfer Öğrenme Destekli DVM Yaklaşımı

Gültekin, Fatımanur

Yüksek Lisans Tezi, Uygulamalı Matematik ve Hesaplamalı Bilimler ABD

Danışman: Doç. Dr. Betül Hiçdurmaz

Nisan, 2025

Bu çalışmada, omurganın önden ve arkadan çekilmiş röntgen görüntülerinden skolyozun otomatik olarak sınıflandırılmasına yönelik üç farklı makine öğrenmesi yaklaşımı değerlendirilmiştir. Bunlardan ilki, DenseNet201 derin öğrenme mimarisi ile doğrudan sınıflandırma; ikincisi transfer öğrenme ile çıkarılan derin özniteliklerin Destek Vektör Makinesi (DVM) ile sınıflandırıldığı hibrit yapı; üçüncüsü de sadece DVM'dir.

Model performansını artırmak için IMADJUST (Image Intensity Adjustment - Yoğunluk Aralığını Yeniden Ölçeklendirme) görüntü ön işleme yöntemi kullanılmıştır. DVM uygulamalarında, literatürde yeni olan Logaritmik Çekirdek Fonksiyonu (Logarithmic Kernel Function - LKF) da dahil olmak üzere farklı çekirdek fonksiyonları (Doğrusal, RBF, ANOVA, vb.) kullanılmış ve hiper parametre optimizasyonu yapılmıştır. Yöntemler doğruluk, F1 skoru, duyarlılık, kesinlik, eğitim süresi gibi performans ölçütleri üzerinden karşılaştırılmıştır.

DeneySEL sonuçların yorumlanması için boyut küçültme yöntemleri kullanılarak (t-SNE, UMAP) örneklerin orijinal vektörleri ve derin öğrenme ile elde edilen özellik vektörleri görsellenmiştir. Derin öğrenme ile elde edilen vektörlerde nonlinear yapının kaybolduğu, sınıfların basit şekilde ayrılabilir kadar farklı konumda gruplandığı görülmektedir.

Sonuçlar, transfer öğrenmenin ham verilerle %100 doğruluk sağladığını göstermiştir. Hibrit modeller, DVM'ye göre daha yüksek doğruluk, transfer öğrenmeye göre ise çok daha kısa işlem süresi sunmuştur. Özellikle ANOVA, LKF ve Doğrusal çekirdeklerle çalışan hibrit modellerin %97-100 doğruluk aralığında ve 2-5 saniye arasında sınıflandırma gerçekleştirdiği gözlenmiştir. Bu bulgular, hibrit yaklaşımın doğruluk, hız ve genelleme performansı açısından skolyoz sınıflandırması için etkili bir çözüm sunduğunu göstermektedir.

Anahtar Kelimeler: Skolyoz, Transfer Öğrenme, Destek Vektör Makinesi, DenseNet-201, Imadjust.

ABSTRACT

Scoliosis Classification in Medical Images: Transfer Learning Aided SVM Approach

Gültekin, Fatımanur

Master's Thesis, Applied Mathematics and Computational Sciences Department

Supervisor: Assoc. Dr. Betül Hiçdurmaz

April, 2025

In this study, three different machine learning approaches were evaluated for the automatic classification of scoliosis from anterior and posterior spinal X-ray images. The first approach involves direct classification using the DenseNet201 deep learning architecture; the second is a hybrid model where deep features extracted via transfer learning are classified using a Support Vector Machine (SVM); and the third approach uses only the SVM for classification.

To enhance model performance, the IMADJUST (Image Intensity Adjustment – Rescaling of Intensity Range) image preprocessing technique was applied. In the SVM-based models, various kernel functions—including the Logarithmic Kernel Function (LKF), which is relatively new in the literature, as well as Linear, RBF, and ANOVA kernels—were utilized, and hyperparameter optimization was performed. The methods were compared based on several performance metrics such as accuracy, F1-score, recall, precision, and training time.

For interpreting the experimental results, dimensionality reduction techniques (t-SNE and UMAP) were used to visualize both the original feature vectors and the deep feature vectors obtained through deep learning. The results showed that non-linear structures disappeared in the deep feature vectors, and the classes were grouped in distinctly separable positions.

The findings revealed that transfer learning achieved 100% accuracy when applied to raw data. Hybrid models outperformed pure SVM in terms of accuracy and were significantly faster than transfer learning. Notably, hybrid models using ANOVA, LKF, and Linear kernels achieved classification accuracies between 97% and 100% within 2 to 5 seconds. These results demonstrate that the hybrid approach offers an effective solution for scoliosis classification in terms of accuracy, speed, and generalization capability.

Keywords: Scoliosis, Transfer Learning, Support Vector Machine, DenseNet-201, Imadjust.

TEŞEKKÜR

Yardımları ve desteği için kardeşim Hatice Gültekin'e, akademik olarak ilerlemem için beni sürekli motive eden arkadaşlarım Dr.Saliha Aydın'a, Cansu Doğan Şafak'a, Selin Nalçakan'a ve kardeşim Muhammedcan Gültekin'e, bu tez çalışması dahil bir ömür boyu destekleri için sevgili annem Müge Gültekin ve babam Hasan Gültekin'e teşekkür ediyorum.

Eğitimim boyunca bilgi ve tecrübelerini benimle paylaşan, karşılaştığım sorunlarda çözüme ulaşmama yardım eden, sabrını ve hoşgörüsünü hiç eksik etmeyen, öğrencisi olmaktan daima onur duyduğum saygıdeğer danışmanım Doç. Dr. Betül Hiçdurmaz'a teşekkür ediyorum.

İÇİNDEKİLER

ÖZET	iv
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ.....	ix
KISALTMALAR.....	x
1. GİRİŞ.....	1
2. SKOLYOZ VE MEDİKAL GÖRÜNTÜLEME	4
3. MATERYAL VE YÖNTEM	6
3.1. VERİ SETİ	6
3.2. YÖNTEM	6
3.2.1. Görüntü Ön İşleme-Kontrast Artırma	7
3.2.2. Konvolüsyonel Sinir Ağları (CNN)	7
3.2.3. Transfer Öğrenme	9
3.2.4. Destek Vektör Makineleri ve Çekirdek Yöntemleri	10
3.2.5. Hibrit Makine Öğrenmesi	13
3.2.6. Performans Ölçütleri	14
4. DENEY SONUÇLARI – BULGULAR	15
4.1. TRANSFER ÖĞRENME SONUÇLARI	15
4.2. DVM SONUÇLARI.....	16
4.3. HİBRİT MODEL SONUÇLARI	21
5. SONUÇ VE TARTIŞMA	26
KAYNAKÇA.....	28
EKLER	31
Ek 1- MATLAB KODLARI.....	31
Ek 2- PYTHON KODLARI	32

TABLÖLAR DİZİNİ

Tablo 1. <i>Geleneksel Çekirdekler Tablosu</i>	12
Tablo 2. <i>Yeni Çekirdekler Tablosu</i>	13
Tablo 3. <i>DenseNet-201 Modeli ile Transfer Öğrenme Eğitim Sonuçları</i>	15
Tablo 4. <i>DenseNet-201 Modeli ile Transfer Öğrenme Test Sonuçları</i>	15
Tablo 5. <i>Ham Verilerle DVM Model Eğitim Sonuçları ve Destek Vektör Sayısı</i>	17
Tablo 6. <i>Ham Verilerle DVM Model Test Sonuçları</i>	17
Tablo 7. <i>Imadjust Uygulanmış Verilerle DVM Model Eğitim Sonuçları ve Destek Vektör Sayısı</i>	20
Tablo 8. <i>Imadjust Uygulanmış Verilerle DVM Model Test Sonuçları</i>	20
Tablo 9. <i>Ham Verilerle Hibrit Model Eğitim Sonuçları ve Destek Vektör Sayısı</i>	22
Tablo 10. <i>Ham Verilerle Hibrit Model Test Sonuçları</i>	23
Tablo 11. <i>Imadjust Uygulanmış Verilerle Hibrit Model Eğitim Sonuçları</i>	25
Tablo 12. <i>Imadjust Uygulanmış Verilerle Hibrit Model Test Sonuçları</i>	25

ŞEKİLLER DİZİNİ

Şekil 1. Skolyoz bulunmayan bir bireyin X-ray görüntüsü.....	4
Şekil 2. Skolyoz bulunmayan bir bireyin X-ray görüntüsü.....	4
Şekil 3. Cobb Açısının Hesaplanması, Kumar, Gupta ve Abraham (2024) çalışmasından alınmıştır.....	5
Şekil 4. Orijinal (solda) ve IMADJUST uygulanmış (sağda) skolyoz X-ray görüntüsü	7
Şekil 5. CNN Katmanları (MathWorks, t.y.)	8
Şekil 6. t-SNE ile Ham Görüntü Vektörlerinin Görsellenmesi	16
Şekil 7. UMAP ile Ham Görüntü Vektörlerinin Görsellenmesi	16
Şekil 8. t-SNE ile Imadjust Uygulanmış Görüntü Vektörlerinin Görsellenmesi	18
Şekil 9. UMAP ile Imadjust Uygulanmış Görüntü Vektörlerinin Görsellenmesi.....	19
Şekil 10. t-SNE ile Ham Veri için Çıkarılan Öznitelik Vektörlerinin Görsellenmesi	21
Şekil 11. Umap ile Ham Veri için Çıkarılan Öznitelik Vektörlerinin Görsellenmesi.....	22
Şekil 12. t-SNE ile İşlenmiş Veri için Öznitelik Vektörlerinin Görsellenmesi.....	24
Şekil 13. UMAP ile İşlenmiş Veri için Öznitelik Vektörlerinin Görsellenmesi	24
Şekil 14. IMADJUST kodu	31

KISALTMALAR

CNN: Konvolüsyonel Sinir Ağ
DVM: Destek Vektör Makinesi
GP: Gerçek Pozitif
GN: Gerçek Negatif
YP: Yanlış Pozitif
YN: Yanlış Negatif
Adam: Adaptive Momentum Estimation/ Uyarlanabilir Momentum Tahmini
RBF: Radial Basis Function/Radyal Tabanlı Fonksiyon
YSA: Yapay Sinir Ağları
LKF: Logarithmic Kernel Function/Logaritmik Çekirdek Fonksiyonu
IMADJUST: Image Intensity Adjustment/Yoğunluk Aralığını Yeniden Ölçeklendirme
TPE: Tree-structured Parzen Estimator
t-SNE: t-Distributed Stochastic Neighbor Embedding/t-dağılımlı Stokastik Komşuluk Yerleştirme
UMAP: Uniform Manifold Approximation and Projection/Uniform Manifold Yaklaştırması ve Yansıtması

1. GİRİŞ

Tıbbi görüntüleme alanında yapay zekâ destekli yaklaşımlar hem doğru tanı sürecini hızlandırmakta hem de sağlık hizmetlerinin kalitesini artırmaktadır. Skolyoz, erken teşhis edilmediğinde ilerleyebilen ve bireyin yaşam kalitesini doğrudan etkileyen bir omurga deformitesidir. Geleneksel tanı yöntemleri çoğunlukla Cobb açısı gibi ölçümlere dayanmakta ve bu ölçümler manuel olarak yapıldığında zaman alıcı olmasının yanı sıra gözlemciye bağlı hatalara da açık olmaktadır. Bu durum, skolyoz teşhisinde otomatik ve güvenilir sistemlerin geliştirilmesini önemli bir ihtiyaç hâline getirmektedir.

Bu tez çalışmasının temel amacı, skolyozun normal ve skolyozlu omurga X-ray görüntüleri üzerinden otomatik olarak sınıflandırılmasını sağlayan bir model geliştirmektir. Bu doğrultuda, görüntülerin kalitesini artırmak ve yapay zekâ modellerinin öğrenmesini kolaylaştırmak amacıyla ön işleme yöntemi olarak Imadjust yöntemi de uygulanarak, ham görüntü kümesine uygulanan model sonuçları ile karşılaştırılmıştır.

Görüntüler ön işlemeden geçirildikten sonra, transfer öğrenme tabanlı bir derin öğrenme modeli olan DenseNet201 kullanılarak hem doğrudan sınıflandırma yapılmış hem de modelden öznetelik çıkarımı gerçekleştirilmiştir. Elde edilen derin özellikler, daha sonra farklı çekirdek fonksiyonlarına sahip optimize edilmiş Destek Vektör Makineleri (DVM) ile sınıflandırılmıştır. Böylece hem derin öğrenme temelli transfer öğrenme ile sınıflandırma hem de transfer öğrenme ile çıkarılan özelliklerin klasik makine öğrenmesi ile sınıflandırıldığı hibrit bir yaklaşım değerlendirilmiştir. Bu modellerin yanında doğrudan DVM modeli ile de doğrudan sınıflandırma yapılmıştır. Bu modelde, literatürde daha önce uygulanmamış LKF çekirdeği farklı çekirdekler ile karşılaştırmalı incelenmiştir.

Bu çalışmada, özellikle etiketli medikal veri sayısının sınırlı olduğu durumlarda uygulanabilecek etkili ve enerji tasarruflu algoritmaların araştırılması hedeflenmiştir. Uygulanan yöntemler sayesinde hem hesaplama maliyetleri düşük tutulmuş hem de sınıflandırma başarımı artırılmıştır. Bu kapsamda elde edilen bulguların, klinik karar destek sistemlerine entegre edilebilecek yapay zekâ tabanlı çözümlere katkı sunması beklenmektedir.

Literatürde, derin öğrenme tabanlı özellik çıkarımı sonrasında DVM gibi klasik sınıflayıcıların uygulanması sıkça tercih edilen hibrit yaklaşımlar arasında yer almaktadır. Ancak bu çalışmada, yalnızca tek bir DVM modeli yerine; birden fazla çekirdek fonksiyonu (Doğrusal, RBF, Laplace, Sigmoid, LKF, Polinom ve ANOVA) ayrı ayrı denenmiş ve elde edilen doğruluk sonuçları karşılaştırmalı olarak analiz edilmiştir. Böylece, farklı çekirdek fonksiyonlarına göre gösterdiği sınıflandırma performansı ortaya konulmuştur. Bu yapı hem transfer öğrenmenin temsil gücünü hem de çekirdek temelli sınırlayıcıların ayırt ediciliğini test etmeyi mümkün kılmakta, çalışmaya deneysel açıdan zenginlik katmaktadır.

Literatürde skolyozun tanısında yalnızca sınıflandırma temelli yaklaşımlar değil, Cobb açısının doğrudan ölçümüne odaklanan derin öğrenme modelleri de yer almaktadır. Bu bağlamda, Maeda vd. (2023) tarafından gerçekleştirilen bir çalışmada, adölesan idiyopatik skolyoz tanısı almış 1021 hastaya ait tam omurga X-ray görüntüsü kullanılarak, CNN tabanlı bir sistemle hem omurların otomatik olarak tespiti hem de Cobb açısının hesaplanması gerçekleştirilmiştir. Çalışmada, transfer öğrenme yöntemi kullanılarak önceden eğitilmiş ResNet34 mimarisi ile omurga bölgesi tespiti yapılmış; ardından vertebral köşe noktaları

belirlenerek Cobb açısı otomatik olarak hesaplanmıştır. Maeda ve arkadaşlarının bu çalışması, transfer öğrenme ile desteklenen derin öğrenme modellerinin Cobb açısının objektif ve tutarlı şekilde hesaplanmasında yüksek başarı sağlayabileceğini ortaya koymaktadır.

Başka bir çalışmada, Xie vd. (2025), ön-arka ve yan X-ray görüntüleri üzerinde çalışarak omurganın hizalanma parametrelerini otomatik olarak ölçebilen bir model geliştirmiştir. ResNet34 mimarisi ile U-Net yapısını birleştirdikleri bu çalışmada, vertebra köşe noktaları tespit edilerek Cobb açısı geometrik olarak vektörler aracılığıyla hesaplanmıştır. Bu örnek çalışmalarda veri sayısı binin üzerindedir. Bu veri kümeleri açık veri değildir. Dolayısıyla bu tip araştırma geliştirmelerde araştırmacıların önüne çıkan bir engel veri bulma sorunudur. Bu tezde az veri ile nasıl daha etkili bir model oluşturabiliriz sorusuna cevap aranacaktır.

Bizim verileri aldığımız çalışma Fraiwan ve arkadaşlarına (2022) aittir. Bu çalışmada, X-ray görüntülerine manuel ölçümlere gerek kalmadan skolyoz ve spondilolistezisi sınıflandıracak derin öğrenme tabanlı transfer öğrenme yöntemleri uygulanmıştır. Veri setinde önden ve arkadan çekilmiş radyograflardan oluşan 338 X-ray görüntüsü vardır. Bu görüntüler 3 kategoriye ayrılmıştır; skolyoz (188), spondilolistezis (79) ve normal (71). VGG16, DenseNet201 ve InceptionV3 dahil olmak üzere, ağırlıkları ImageNet'ten başlatılan yedi önceden eğitilmiş CNN mimarisi değerlendirilmiştir. Bu çalışma, veri artırma gibi daha fazla iyileştirme sağlayabilecek topluluk tekniklerini veya imadjust gibi ön işleme yöntemlerini incelememektedir ancak transfer öğrenmenin omurga deformitelerini yüksek doğrulukla etkili bir şekilde tespit edebileceğini göstermektedir. Bulgular, transfer öğrenmesinin tıbbi görüntülemeye uygulanabilirliğini desteklemekte ve mevcut tezde karşılaştırmalı analiz için kullanılmaktadır. Bu tezde farklı olarak DVM modeli yardımı ile sınıflandırma süresi daha kısa süren algoritmalar ile bu çalışmaya benzer başarı skorlarına ulaşılabilmiştir.

Quy Thanh Lu ve Triet Minh Nguyen (2024)'in çalışmasında tıbbi muayene sürecinde zaman kaybı ve karmaşıklığı önlemek amacıyla, omurga hastalıklarının sınıflandırılması için X-ray (röntgen) görüntüleri üzerinde transfer öğrenme ve ince ayarlama (fine tuning) teknikleri kullanılmıştır. Omurga hastalıklarına ait X-ray görüntülerinden oluşan veri seti, Fraiwan ve arkadaşlarının çalışmalarında kullandıkları ve açık kaynak olarak paylaştıkları veri setidir. Modelin temelinde, parametre verimliliği ve derinlik açısından öne çıkan Xception mimarisi yer almakta olup, bu mimariye ek olarak dropout ve yoğun (dense) katmanlar eklenmiş ve model farklı görevler için optimize edilmiştir. Çalışma, transfer öğrenmenin gücünü, fine-tuning ile hedef göreve özgü ayarlamalarla birleştirerek, sınırlı veriyle dahi yüksek doğrulukta sonuçlar elde edilebileceğini ortaya koymaktadır.

Yahara vd. (2022), adölesan idiopatik skolyoz hastalarında skolyoz eğriliğinin ilerleyip ilerlemeyeceğini tahmin etmek amacıyla derin öğrenme tabanlı bir yöntem geliştirmiştir. Çalışmada, önceden ImageNet üzerinde eğitilmiş Xception modeli kullanılarak transfer öğrenme ve fine-tuning uygulanmış, model yalnızca frontal X-ray görüntüleriyle eğitilmiştir. Aynı görüntüler üzerinden tahmin yapan beş omurga cerrahının ortalama doğruluğu ise %47 olarak raporlanmıştır.

Shrestha vd. (2021), skolyozun erken evre tespiti için klasik makine öğrenmesi algoritmalarını karşılaştırarak, destek vektör makinesinin (SVM) doğrusal regresyona kıyasla daha yüksek doğruluk ve daha düşük işlem süresi sunduğunu göstermiştir (%85,67 doğruluk, 15.4 sn). Bu tez ile aynı veriseti kullanılmış ancak farklı çekirdekler ya da transfer öğrenmeden faydalanılmadığı için başarı skorları düşük kalmıştır.

Skolyoz teşhisinde makine öğrenme yöntemlerinin karşılaştırmalı analizini yapan Mahesh ve ark. (2022), X-ray görüntülerinde C-eğrisi ve S-eğrisi skolyoz tiplerinin sınıflandırılmasını incelemiştir. Çalışmada iki temel yaklaşım test edilmiştir: (1) Derin öğrenme tabanlı CNN modeli (%90+ doğruluk) ve (2) Geleneksel DVM yöntemi (%45-60 doğruluk). Bu sonuçlar, tıbbi görüntü sınıflandırmada derin öğrenme tabanlı özellik çıkarımının kritik rolüne işaret etmektedir


Agarap (2019), Evrişimli Sinir Ağları (CNN) ile Destek Vektör Makinelerini (DVM) birleştirerek CNN-DVM adı verilen hibrit bir sınıflandırıcı geliştirmiştir. Bu modelde CNN, özellik çıkarıcı olarak kullanılırken, sınıflandırma adımı DVM tarafından gerçekleştirilmiştir. MNIST ve Fashion-MNIST veri setleri üzerinde gerçekleştirilen deneylerde, CNN-DVM hibrit modelinin standart CNN modelleriyle karşılaştırılabilir sonuçlar verdiği gözlenmiştir. MNIST veri setinde CNN modeli %99.04 doğruluk elde ederken, CNN-DVM modeli %98,91 doğruluk elde etmiştir. Benzer şekilde, Fashion-MNIST veri setinde CNN modeli %90,72 doğruluk sağlarken, CNN-DVM modeli %90,60 doğruluk elde etmiştir. Elde edilen bu sonuçlar, derin öğrenme yöntemleriyle çıkarılan özelliklerin DVM ile sınıflandırılmasının geleneksel CNN modelleriyle rekabetçi sonuçlar üretebileceğini ortaya koymuştur (Agarap, 2019).

Ismael ve Şengür'ün (2021) çalışmasında, COVID-19 hastalığının tespitine yönelik olarak göğüs röntgeni (X-ray) görüntüleri üzerinden üç farklı derin öğrenme yaklaşımı uygulanmıştır: (1) öznitelik çıkarımı için önceden eğitilmiş CNN modelleriyle derin özellik elde etme ve DVM ile sınıflandırma, (2) önceden eğitilmiş modellerin yeniden eğitilmesi (fine-tuning) ve (3) baştan sona (end-to-end) yeni bir CNN modelinin eğitimi. DVM sınıflandırıcısında dört farklı çekirdek fonksiyonu (Doğrusal, Polinom, Kübik, RBF) test edilmiştir. En yüksek doğruluk oranı %94,7 ile ResNet50 modelinden çıkarılan derin özelliklerin Lineer çekirdek fonksiyonlu DVM ile sınıflandırılması sonucunda elde edilmiştir. Bouslihim ve arkadaşları (2023), tıbbi görüntü sınıflandırmasında EfficientNet mimarisi ile destek vektör makinelerini (SVM) birleştiren hibrit bir model önermiştir. Üstündağ (2022) tarafından yapılan bir çalışmada, göğüs röntgenlerinden COVID-19 sınıflandırması gerçekleştirilmiş ve transfer öğrenme kapsamında DenseNet, ResNet ve InceptionV3 gibi mimariler kullanılarak öznitelik çıkarımı yapılmıştır. Elde edilen bu derin öznitelikler, DVM algoritmasının farklı çekirdek fonksiyonları ile sınıflandırılmıştır. Bu sonuçlar, transfer öğrenme tabanlı derin özelliklerin klasik makine öğrenmesi algoritmalarıyla (özellikle çekirdek tabanlı DVM) birleştirilmesinin, DVM'de çekirdek fonksiyonlarının potansiyelinin önemine işaret etmektedir.

Literatürde, transfer öğrenme ile skolyoz teşhisine yönelik doğrudan sınıflandırma yöntemleri başarıyla uygulanmış; ayrıca destek vektör makineleri (DVM) gibi klasik sınıflayıcıların da medikal görüntü sınıflandırmalarında etkili olduğu birçok çalışma ile gösterilmiştir. Ancak bu iki yöntemin birlikte kullanıldığı hibrit yapıların, özellikle skolyoz X-ray verileri üzerinde sistematik biçimde incelendiği kapsamlı bir çalışmaya rastlanmamıştır. Bu tezde sunulan skolyoz teşhisine yönelik kapsamlı ve hibrit yaklaşımlar, literatürdeki önemli bir boşluğu doldurmakta ve klinik karar destek sistemlerine yönelik yeni bir perspektif sunmaktadır.

2. SKOLYOZ VE MEDİKAL GÖRÜNTÜLEME

Skolyoz, omurganın içerisindeki omurların dönmesi ile omurganın normal dikey hattından sağa ya da sola saparak eğilmesi olarak tanımlanır (Janicki ve Alman, 2007). Skolyoz omurganın herhangi bir bölümünde ortaya çıkabilse de en sık torasik (sırt) ve lomber (bel) bölgelerinde görülür. Bu durumda omurga, yan tarafa doğru eğilerek torasik veya lomber bölgede bir "C" şeklini oluşturur. Daha nadir durumlarda ise omurga iki ayrı eğrilik geliştirerek "S" şekli alabilir (Janicki ve Alman, 2007). Skolyoz etiyolojik olarak primer(birincil) ve sekonder(ikincil) skolyoz olarak ikiye ayrılabilir. Primer skolyozun en yaygın örneği idiyopatik (nedeni bilinmeyen) skolyozdur (Kim vd., 2010). Vakaların %80'ini idiyopatik skolyoz oluşturur (Türkiye Fiziksel Tıp ve Rehabilitasyon Derneği, 2013). İdiopatik skolyoz da kendi içinde yaş gruplarına göre üçe ayrılır, vakaların %85'ini 10-18 yaş grubunu kapsayan Adölesan İdiyopatik Skolyoz oluşturur (Karpel vd., 2021). Skolyozun erken teşhisi, özellikle çocukluk ve ergenlik dönemlerinde büyük önem taşır. Büyümenin hızlı olduğu bu evrelerde skolyoz eğriliği kısa sürede belirgin şekilde artabilir. Erken dönemde tespit edilen skolyoz vakalarında, konservatif (cerrahi olmayan) yöntemlerle eğriliğin ilerlemesini kontrol altına almak daha kolaydır (Lee vd., 2022). Örneğin, korse tedavisi veya fizik tedavi uygulamaları, hastalığın erken aşamalarında daha etkili sonuçlar verebilir. Bu nedenle erken teşhis hem hastalığın ilerlemesini engellemek




Şekil 1. Skolyoz bulunmayan bir bireyin X-ray görüntüsü



Şekil 2. Skolyoz bulunmayan bir bireyin X-ray görüntüsü

hem de tedaviye daha erken başlamak açısından kritik bir rol oynar (Türkiye Fiziksel Tıp ve Rehabilitasyon Derneği, 2013).

Skolyoz taraması genellikle fiziksel muayene ile başlar, ancak kesin tanı BT, MRG veya X-ray ile konulur (Janicki ve Alman, 2007). Skolyoz tanısında en sık kullanılan yöntem röntgen (X-ray) görüntülemesidir. Posterior-anterior grafide (arkadan-önden çekilen röntgen) Cobb açısı hesaplanır ve bu açı, skolyoz teşhisinde altın standart olarak kabul edilir (Türkiye Fiziksel Tıp ve Rehabilitasyon Derneği, 2013). Cobb açısı, eğriliğin başladığı ve sonlandığı vertebralar (omurlar) arasındaki sapma açısını ifade eder. Üst ve alt uç vertebraların plaklarına çizilen paralel çizgilere çekilen dikey çizgiler arasındaki açı Cobb açısını oluşturur. Bu açıya göre 10°'nin üzerindeki koronal eğrilikler "skolyoz" olarak sınıflandırılır (Lee vd., 2022).



Şekil 3. Cobb Açısının Hesaplanması, Kumar, Gupta ve Abraham (2024) çalışmasından alınmıştır.

Geleneksel görüntüleme yöntemleri, doktorların radyografları görsel olarak incelemesi ve belirli ölçümleri manuel olarak yapması nedeniyle zaman alıcı ve hata yapmaya açık bir süreçtir. Bu eksiklikler, son yıllarda özellikle görüntüleme verilerinin otomatik işlenmesini ve karar destek sistemlerinin geliştirilmesini sağlayan yapay zekâ uygulamalarına olan ilgiyi artırmıştır. X-ray görüntülerinden otomatik ölçüm yapan bu sistemler, teşhis sürecini hızlandırırken doğruluğu artırmayı amaçlar (Lee ve ark., 2022).

Bu doğrultuda, Chen vd. (2021) tarafından gerçekleştirilen kapsamlı literatür taraması, bu eğilimin güncel bir yansımasıdır. Yazarlar, makine öğrenmesi ve derin öğrenme modellerinin skolyozun yalnızca tanısında değil; aynı zamanda tarama, tedavi planlaması, cerrahi karar desteği, ameliyat içi yönlendirme, komplikasyon öngörüsü ve uzun vadeli prognoz tahmini gibi çok sayıda klinik süreçte etkin biçimde kullanılabildiğini belirtmiştir. Özellikle Cobb açısının otomatik ölçümünde CNN tabanlı modellerin yüksek doğruluk sunduğu rapor edilmiştir. Söz konusu yapay zekâ tabanlı sistemler, skolyozun üç boyutlu yapısal özelliklerini dikkate alarak standardize ve tekrarlanabilir değerlendirme sunmayı mümkün kılmaktadır.

Buna ek olarak Goldman vd. (2024) tarafından gerçekleştirilen ve adölesan idiopatik skolyoz (AIS) üzerine odaklanan kapsamlı bir literatür taramasında, skolyoz teşhis ve yönetimi için geliştirilen toplam 40 yapay zekâ temelli uygulama incelenmiş; en yaygın kullanım alanlarının otomatik görüntü analizi (%62,5) ve eğrilik ilerlemesi tahmini (%37,5) olduğu saptanmıştır. Kullanılan yöntemlerin başında Konvolüsyonel Sinir Ağları (CNN) (%55) yer almakta; bunun yanında Karar Ağaçları ve Rastgele Ormanlar (%15), Yapay Sinir Ağları (ANN) (%15) gibi farklı makine öğrenmesi algoritmalarının da skolyoz görüntüleri üzerinde başarıyla uygulandığı görülmektedir. Bu bağlamda, skolyoz teşhisinde hem hızlı hem de tekrarlanabilir sonuçlar sunabilecek yapay zekâ destekli yaklaşımlara olan ihtiyaç daha da belirgin hale gelmektedir. Bu bulgular, X-ray görüntülerine dayalı olarak skolyozun doğrudan sınıflandırılmasını hedefleyen bu tez çalışmasının gerekçesini desteklemekte ve literatürdeki boşluklara katkı sunmayı amaçlamaktadır.

3. MATERİYAL VE YÖNTEM

3.1. Veri Seti

Bu çalışmada kullanılan X-ray görüntüleri, Fraiwan vd. (2022) tarafından yayımlanan ve Mendeley Data platformunda erişime sunulan “A dataset of scoliosis, spondylolisthesis, and normal vertebrae X-ray images” adlı veri setinden alınmıştır. Veri setindeki omurga röntgen görüntüleri, Ürdün'ün İrbid kentindeki King Abdullah Üniversitesi Hastanesi (KAUH), Ürdün Bilim ve Teknoloji Üniversitesi'nde yerel olarak toplanmış ve tanı, KAUH'taki iki ortopedi uzmanı tarafından konulmuştur.

Veri seti skolyoz teşhisi konulan bireyler, spondilolistez teşhisi konulan bireyler ve normal(sağlıklı) bireyler olmak üzere toplamda 338 bireyin (240 kadın, 98 erkek, yaş aralığı: 9 ay- 79 yıl, ortalama $\pm$ SS: $24.9 \pm 18,58$ yıl) X-ray verilerinden oluşmaktadır. Ancak bu çalışmada, yalnızca skolyoz ve normal kategorilerindeki veriler kullanılmış olup, toplamda 71 normal (40 kadın, 31 erkek, yaş aralığı 9 ay- 56 yıl, ortalama $\pm$ SS: $19.41 \pm 11,19$ yıl) ve 188 skolyoz (151 kadın, 37 erkek, yaş aralığı 5- 35 yıl, ortalama $\pm$ SS: $14.73 \pm 3,36$ yıl) birey değerlendirilmiştir. Bu seçimin nedeni, analiz kapsamını ikili sınıflandırma (normal ve skolyoz) ile sınırlamaktır. Veri platformunda, derin öğrenme modellerine uygun olarak yeniden boyutlandırılmış $[224 \times 224 \times 3]$, $[227 \times 227 \times 3]$, $[256 \times 256 \times 3]$, $[299 \times 299 \times 3]$ ve $[331 \times 331 \times 3]$ boyutlarında görüntü seçenekleri de bulunmaktadır. Bu çalışmada, derin öğrenme modelleri için yaygın olarak kullanılan 224×224 boyutunda ve 3 kanallı (RGB) görüntüler tercih edilmiştir.

Bu şekilde seçilen toplam 259 X-ray görüntüsü Python programlama dili kullanılarak rasgele şekilde %70 train ve %30 test oranlarında ayrılmıştır. İşlemler sonucunda train kümesinde 180, test kümesinde 79 görüntü yer almıştır. Görüntü işleme adımlarında aynı örneklerin seçilmesini sağlamak ve sonuçların yeniden üretilebilirliğini korumak amacıyla test-train ayrımı sürecinin başında sabit bir rastgele tohum (seed) değeri belirlenmiştir. Bu sayede veriler her seferinde aynı şekilde bölünmekte ve işlenebilmektedir.

3.2. Yöntem

Bu çalışmada skolyoz teşhisini gerçekleştirmek amacıyla, görüntü ön işleme ile desteklenmiş sınıflandırma yöntemleri uygulanmıştır. İlk aşamada, ham X-ray görüntülerinin yanı sıra imadjust yöntemi kullanılarak görüntülerin kontrastı artırılarak yeni bir veri seti oluşturulmuştur. Görüntü ön işleme adımları MATLAB programı aracılığıyla gerçekleştirilmiş, elde edilen görüntüler derin öğrenme modellerine uygun olacak şekilde hazırlanmıştır.

Ön işleme süreci sonrasında, veriler üç farklı model yapısıyla değerlendirilmiştir. İlk yöntemde, transfer öğrenme tabanlı bir derin öğrenme modeli oluşturularak DenseNet201 mimarisi kullanılmış, ikinci yöntemde ise, DenseNet201+DVM hibrit bir yapı kullanılmış; DenseNet201 ile özellik çıkarımı gerçekleştirilmiş ve elde edilen özellik vektörleri, farklı çekirdek fonksiyonları ile yapılandırılmış DVM kullanılarak sınıflandırılmıştır. Üçüncü yöntemde ise doğrudan farklı çekirdek fonksiyonları ile DVM kullanılmıştır.

Literatürde hibrit yaklaşımlar, genellikle önce derin öğrenme modelleriyle özellik çıkarımı yapılması ve ardından geleneksel bir sınıflayıcıyla bu özelliklerin değerlendirilmesi şeklinde


tanımlanmaktadır. Bu yapı, transfer öğrenmenin güçlü temsil kapasitesi ile geleneksel yöntemlerin esnekliğini bir araya getirerek etkili bir sınıflandırma imkânı sunmaktadır. Özellikle tıbbi veri setlerinin genellikle sınırlı olması, bu yöntemi hem hesaplama açısından verimli hem de yüksek doğruluk potansiyeli olan bir çözüm haline getirmektedir.

Görüntü ön işleme adımları MATLAB ortamında gerçekleştirilmiştir. Transfer öğrenme ile öznitelik çıkarımı, ardından Destek Vektör Makineleri (DVM) ile sınıflandırma işlemleri ve tüm derin öğrenme modellerinin eğitimi ile test süreçleri Google Colab platformunda, L4 GPU donanım hızlandırıcısı kullanılarak Python diliyle uygulanmıştır. Bu sayede hem işlem süresi azaltılmış hem de yüksek hesaplama kapasitesi sağlanmıştır.

3.2.1. Görüntü Ön İşleme-Kontrast Artırma

Çalışmada kullanılan skolyoz veri seti, kontrast ve çözünürlük bakımından çeşitlilik göstermektedir. Skolyozun teşhisinde omurgadaki eğriliklerin net bir şekilde belirlenmesi, özellikle kenar yapılarının doğru analizine bağlıdır. Bu nedenle, X-ray görüntülerine kontrast artırma teknikleri uygulanmıştır.

Bu bağlamda Imadjust yöntemi tercih edilmiştir. Imadjust, tüm görüntü üzerinde piksel yoğunluklarını yeniden ölçeklendirerek global kontrastı artıran bir yöntemdir. MATLAB ortamında sıkça kullanılan bu fonksiyon, görüntüdeki düşük ve yüksek yoğunluk değerlerini yeniden haritalayarak detayların vurgulanmasını sağlar. Bu yöntemle özellikle yumuşak dokuların görünürlüğü artırılırken tanısal içeriğin korunması da sağlanmaktadır (Abdallah ve Ben Yousef, 2015).



Şekil 4. Orijinal (solda) ve IMADJUST uygulanmış (sağda) skolyoz X-ray görüntüsü


3.2.2. Konvolüsyonel Sinir Ağları (CNN)

Derin öğrenme modelleri arasında, özellikle görsel verilerle çalışan uygulamalarda en etkili yaklaşımlardan biri CNN'dir. CNN, hayvanların görsel korteksindeki nöronların organizasyon yapısından esinlenerek geliştirilmiştir. Görsel kortekste, her nöron sınırlı bir görsel alandan gelen uyarana tepki verir ve bu alıcı alanlar birbirleriyle kısmen örtüşerek tüm görsel alanı kapsayacak biçimde organize olur. Benzer şekilde, CNN mimarileri de görüntü üzerindeki sınırlı bölgeleri tarayarak yerel özellikleri yakalar ve bu yerel bilgileri üst katmanlarda daha karmaşık temsillere dönüştürür. Geleneksel sinir ağlarında olduğu gibi

görüntüyü vektörleştirerek işlemek, komşu pikseller arasındaki mekânsal yapıyı yok ettiği için, bu tür verilerde performans düşer. CNN'ler, bu yapısal bilgiyi koruyarak işlem yapabilmeleri sayesinde özellikle görüntü verilerine özgü olarak tasarlanmıştır (Hu, 2021).

CNN mimarileri görüntüleri çok katmanlı yapılarla analiz ederek, her katmanda daha soyut ve daha anlamlı özellikler çıkarır. CNN'ler giriş katmanı, çıkış katmanı ve aradaki çok sayıda gizli katmandan oluşan bir yapıdadır. Her katman, verinin özelliklerini daha iyi temsil edecek şekilde dönüştürme görevini üstlenir (LeCun, Bengio & Hinton, 2015).

Tipik bir CNN mimarisi; evrişim, aktivasyon (çoğunlukla ReLu) ve havuzlama (pooling) katmanlarının ardışık diziliminden oluşur. Bu katmanlar sayesinde bu ağlar, görüntülerdeki kenar, doku ve şekil gibi temel özellikleri ayıklayarak; her katmanda yapıları daha iyi temsil edecek şekilde dönüştürür (LeCun, Bengio ve Hinton, 2015).



Şekil 5. CNN Katmanları (MathWorks, t.y.)

Bu yapı hem sınıflandırma doğruluğunu artırır hem de modelin karmaşık örüntüleri öğrenmesini sağlar. İlk katmanlar, görüntüdeki kenar gibi temel özellikleri tanırken; daha ileri katmanlar, bu bilgileri birleştirerek daha karmaşık yapıları, örneğin nesne parçalarını ya da belirli bir hastalık belirtisini tanıyabilir (LeCun, Bengio ve Hinton, 2015; He, 2020).

Aktivasyon katmanları, sinir ağına giriş ve çıkışlar arasında yalnızca düz (lineer) ilişkiler yerine, karmaşık ve eğrisel ilişkileri de öğrenme yeteneği kazandırır. En yaygın kullanılan ReLU (Rectified Linear Unit), negatif değerleri sıfıra çeker ve öğrenme sürecini hızlandırır. Bu sayede model, sadece doğrusal ilişkileri değil, daha karmaşık örüntüleri de öğrenebilir.

CNN'in sonunda yer alan tam bağlı katman genellikle sınıflandırıcı olarak görev yapar. Örneğin, bir skolyoz teşhis modelinde bu katman, görüntüyü “normal” veya “skolyoz” olarak sınıflandırabilir (Kumar vd., 2024). Tüm bu öğrenme süreci, geri yayılım algoritması ile uçtan uca gerçekleştirilir. Böylece model, verinin hangi özelliklerine dikkat etmesi gerektiğini kendisi öğrenir (LeCun, Bengio ve Hinton, 2015).

CNN gibi derin öğrenme modelleri genellikle büyük veri kümeleri ile sıfırdan eğitilir. Ancak tıbbi görüntülerde, örneğin skolyoz teşhisi gibi, etiketlenmiş veri sınırlıdır. Bu durum, CNN'lerin sıfırdan eğitilmesini zorlaştırmakta ve genelleme yetisini olumsuz etkileyebilmektedir. Bu nedenle, önceden eğitilmiş bir CNN modelini, elimizdeki daha küçük veri kümesine uyarlamak gerekir. Bu yaklaşım transfer öğrenme olarak adlandırılır.

Transfer öğrenmede, genellikle geniş ve genel veri kümeleri (örneğin ImageNet) üzerinde önceden eğitilmiş CNN mimarileri kullanılarak, bu modeller medikal görüntüler gibi daha küçük ve özel veri kümelerine yeniden uyarlanır. Böylece, sınırlı veri ile bile yüksek doğruluk elde edilebilmekte ve modelin öğrenme süreci hızlanmaktadır (Yamashita vd., 2018; Litjens vd., 2017). Bu çalışmada da transfer öğrenme yaklaşımı benimsenmiş ve DenseNet201 mimarisi, skolyoz tespiti için özel olarak uyarlanmıştır.

3.2.3. Transfer Öğrenme

Derin öğrenme modelleri, yüksek başarı oranlarıyla dikkat çekmesine rağmen, çok fazla ve etiketlenmiş veriye ihtiyaç duyar. Ancak bazı alanlarda bu kadar veriyi toplamak hem maliyetlidir hem de zaman alıcıdır. Bu gibi durumlarda, önceden eğitilmiş bir modelden faydalanarak yeni bir probleme daha az veriyle çözüm üretmeye yarayan transfer öğrenme devreye girer. Transfer Öğrenme, önceden büyük ve çeşitli veri setlerinde (ImageNet gibi) eğitilmiş modellerin, farklı ancak benzer görevler için yeniden kullanılması esasına dayanır. Transfer öğrenme sayesinde, eğitim ve test verilerinin tamamen aynı özellikte olması gerekmez ve bu da model geliştirme sürecini kolaylaştırır. Özellikle derin öğrenme tabanlı transfer öğrenme, kaynak alandaki bilgileri kullanarak hedef alandaki modelin performansını artırmayı amaçlar. Bu yaklaşımla hem eğitim süresi kısılır hem de az veriye rağmen tatmin edici sonuçlar elde edilebilir. Gerçek hayattaki uygulamalarda ise bu yöntemler çoğu zaman bir arada kullanılarak daha güçlü sonuçlar elde edilir (Tan vd., 2018).

Tıbbi görüntülerin sınıflandırılmasında transfer öğrenme, sınırlı veriyle yüksek doğruluk elde etme imkânı sunduğu için son yıllarda sıkça tercih edilmektedir. Bu çalışmada kullanılan DenseNet201 mimarisi, derinliği artırırken aynı zamanda modelin verimli ve etkili öğrenmesini sağlayan özgün bir yapıya sahiptir. Her katmanın çıktısını sonraki tüm katmanlarla paylaşması, bilgi kaybını önlemekte ve özelliklerin tekrar kullanımını mümkün kılmaktadır. Özellikle sınırlı veri içeren tıbbi görüntülerde bu özellik, detaylı ve ayırt edici bilgi çıkarımı açısından büyük avantaj sağlar. DenseNet201'in 201 katmanlı yapısı, skolyoz gibi yapısal omurga bozukluklarını daha iyi tanımlamak için gerekli derinliği sunarken, transfer öğrenme ile yeniden eğitildiğinde yüksek doğruluk oranlarına ulaşmaktadır. Literatürde yapılan çalışmalarda da DenseNet201 modeli skolyoz, spondilolistezis ve normal sınıfların ayırımında %96'nın üzerinde doğruluk göstermiştir (Fraivan vd., 2022).

DenseNet mimarisi, her katmanı bir önceki tüm katmanların çıktılarıyla besleyerek özellik tekrarını azaltmakta ve öğrenmeyi derinleştirmektedir. Bu yapısı sayesinde, sınırlı veri ile bile zengin özellik çıkarımı yapılabilir. Bu çalışmada DenseNet201, son katmanları yeniden eğitmek üzere yapılandırılmış, geri kalan katmanlar ise dondurulmuştur. Özellikle ağın son 10 katmanı açık bırakılarak fine-tuning yapılmıştır. Bu sayede model, hem önceden öğrenilmiş genel görsel bilgileri korumakta hem de skolyoz ve normal görüntüler arasındaki ayırt edici desenleri öğrenmektedir.

Modelin eğitimi sırasında, veri dengesizliği problemi göz önünde bulundurularak sınıf ağırlıkları kullanılmıştır (Normal: 1.0, Scol: 0.7). Ayrıca, eğitim verilerine uygulanan veri artırma (data augmentation) teknikleri, döndürme, yakınlaştırma, yatay çevirme vb. modelin genelleme yeteneğini artırmak için kullanılmıştır. Modelin giriş boyutu 224×224 piksel olarak belirlenmiştir.

Modelin optimizasyonunda Adam algoritması kullanılmış, öğrenme oranı $1e-4$ olarak ayarlanmıştır. Kayıp fonksiyonu olarak binary crossentropy kullanılmış, başarı ölçütü olarak doğruluk değerlendirilmiştir. Aşırı öğrenmenin önüne geçmek amacıyla early stopping mekanizması uygulanmıştır.

Modelin doğrulama süreci, 5 katlı çapraz doğrulama (5-Fold cross-validation) yöntemiyle gerçekleştirilmiştir. Her bir kat için eğitim ve doğrulama doğrulukları ayrı ayrı hesaplanmış, ardından ortalama ve standart sapma değeri raporlanmıştır. Son olarak, tüm eğitim verisiyle yeniden eğitilen model test verisi üzerinde değerlendirilmiş ve doğruluk, F1- Skoru ve karışıklık matrisi gibi performans ölçütleri elde edilmiştir.

3.2.4. Destek Vektör Makineleri ve Çekirdek Yöntemleri

Destek Vektör Makineleri (DVM), Cortes ve Vapnik (1995) tarafından geliştirilmiş, özellikle iki sınıflı sınıflandırma problemleri için yüksek genelleme yeteneği sunan güçlü denetimli öğrenme algoritmalarıdır. Bu yöntemin temelinde, giriş vektörlerinin doğrusal olmayan bir dönüşümle daha yüksek boyutlu bir özellik uzayına aktarılması ve bu uzayda verileri en iyi ayıran karar yüzeyinin (hiperdüzlemin) belirlenmesi yer alır. Amaç, sınıflar arasında maksimum ayrımı sağlayacak şekilde, destek vektörleri (karar yüzeyine en yakın örnekler) arasındaki uzaklığı maksimize etmektir. DVM, yalnızca bu destek vektörlerini dikkate aldığı için yüksek boyutlu ortamlarda dahi aşırı öğrenmeyi önleyebilir. Gerçek dünya verilerinin genellikle doğrusal ayrılabilir olmaması nedeniyle, model yumuşak marjin yaklaşımıyla genişletilmiş ve böylece sınıflandırma hatalarına belirli bir esneklik tanınarak daha uygulanabilir bir yapı elde edilmiştir (Cortes ve Vapnik, 1995).

Bu tez çalışmasında skolyoz tespiti, sınıflandırma problemini bir optimizasyon problemine dönüştüren denetimli bir yöntem olan Destek Vektör Makineleri (DVM) ile ele alınmıştır. Dolayısıyla destek vektör makinelerinin (DVM) temel yapısını ve ardındaki matematiksel yaklaşımı anlamak, modelin işleyişine dair net bir bakış açısı sunmaktadır.

Eğitim verilerimiz, giriş vektörleri $x_i \in \mathbb{R}^d$ ve etiketleri $y_i \in \{-1, +1\}$ olmak üzere $i = 1, 2, \dots, N$ şeklindedir. İlk olarak verilerin doğrusal olarak ayrılabilir olduğu varsayılır ve bu durumda ayırıcı H hiper düzleminin denklemi şu şekilde tanımlanır:

$$w^T x_i + b = 0$$

Burada; w ağırlık vektörüdür ve b sapma (bias) terimidir. H'ye eşit uzaklıkta olan paralel iki hiper düzlem vardır. Bu düzlemlerin denklemleri de şu şekildedir:

$$w^T \cdot x^+ + b = 1, \quad w^T \cdot x^- + b = -1$$

x^+ ile y etiketi +1 olan x örnekleri, x^- ile de y etiketi -1 olan x örnekleri ifade edilmektedir. Bu iki durumu tek bir eşitsizlikle yazarsak:

$$y_i(w^T x_i + b) \geq 1, \forall i.$$

Bu iki sınıf sınırı arasındaki mesafe yani marjin aşağıdaki gibi hesaplanır:

$$\gamma = \frac{1}{\|w\|}$$

Amaç, bu marjini maksimize etmektir. Bu da $\|w\|$ 'nin yani ağırlık vektörünün normunun minimize edilmesiyle sağlanır. Bu durumda çözülmesi gereken optimizasyon problemi şudur:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \text{ öyle ki } y_i(w^T x_i + b) \geq 1, \forall i$$

Bu klasik sert marjin problemidir. Yani, hiçbir sınıflandırma hatasına izin verilmeyen, sadece doğrusal olarak tam ayrılabilen veriler için geçerlidir. Ancak gerçek dünyadaki birçok veri kümesinde bu şart sağlanamayabilir. Verilerin tam olarak ayrılamadığı durumlarda, bazı örneklerin karar sınırına yakın veya yanlış tarafta olmasına tolerans gösterebilmek için yumuşak marjin yaklaşımı geliştirilmiştir ve bu yöntem, modelin genelleme kabiliyetini artırır. Bunun için gevşeklik değişkenleri $\xi_i \geq 0$ tanımlanır. Bu değişkenler, sınıflandırma sınırlarının ihlâl edilmesine izin verir. Bu durumda sınıflandırma eşitsizliği şu şekilde güncellenir:

$$y_i(w^T x_i + b) \geq 1 - \xi_i, \quad \text{tüm } i = 1, 2, \dots, N.$$

Ayrıca, modelin karmaşıklığı ile hata toleransı arasındaki dengeyi kurmak için C adında bir ceza parametresi tanımlanır. Modelin hatalara ne kadar tolerans göstereceğini belirleyen bu parametre, bu tezde hiper parametre optimizasyon süreciyle ayarlanmıştır. Bu durumda çözülmesi gereken optimizasyon problemi aşağıdaki gibi olur:

$$\min_{w, b, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad \text{öyle ki } y_i(w^T x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0.$$

Gerçek dünya verilerinin çoğu doğrusal olarak ayrılamaz. Bu nedenle, verilerin doğrusal olarak ayrılabilmesi için daha yüksek boyutlu bir özellik uzayına aktarılması gerekir. Bu işlem doğrudan yapılmak yerine, çekirdek fonksiyonları kullanılarak dolaylı yoldan gerçekleştirilir. Bu teknik, DVM'nin karmaşık veri yapılarıyla başa çıkabilmesini sağlar. Bu dönüşüm şu şekilde tanımlanır:

$$\phi: R^d \rightarrow R^n, \quad x \mapsto \phi(x) = [\phi_1(x), \phi_2(x), \dots, \phi_n(x)]^T.$$

Bu dönüşümle birlikte yumuşak marjin optimizasyon problemi şu hale gelir:

$$\min_{w, b, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad \text{öyle ki } y_i(w^T \phi(x_i) + b) \geq 1 - \xi_i, \quad \xi_i \geq 0.$$

Doğrudan çözüm yerine, genellikle daha verimli olan ikili (dual) form kullanılır. İkili problem, Lagrange çarpanlarıyla ifade edilir ve çekirdek fonksiyonu yardımıyla iç çarpım yerine geçer:

$$\max_{\alpha} \left(\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \right) \quad \text{öyle ki } \sum_{i=1}^N \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C.$$

Burada $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ çekirdek fonksiyonunu temsil eder.

İkili formdaki optimizasyon probleminde yer alan $\alpha_i \neq 0$, yalnızca destek vektörleri için sıfırdan farklı olan Lagrange çarpanlarını temsil eder. Bu çarpanlar, modelin hem sınıf etiketlerini ($y_i \in \{-1, +1\}$) hem de ceza parametresi C ile belirlenen hata toleransı sınırlarını sağlamasını garanti eder. Burada kullanılan $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ çekirdek fonksiyonu, verileri iç çarpım yoluyla yüksek boyutlu bir uzaya aktaran dönüşüm fonksiyonudur.

Doğrusal çekirdekler doğrudan iç çarpımı hesaplarken; Polinom, RBF ve diğer çekirdek türleri, doğrusal olmayan ayrımları mümkün kılar. Modelin doğru çalışması için Lagrange çarpanları aşağıdaki iki kısıtı sağlamalıdır: (1) sınıf etiketleri ile ağırlıkların dengeli olması $\sum_{i=1}^N \alpha_i y_i = 0$ ve (2) her bir çarpanın belirli sınırlar içinde olması $0 \leq \alpha_i \leq C$.

Modelin tahmin yaparken kullandığı karar fonksiyonu ise şu şekildedir:

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i K(x_i, x) + b \right)$$

Bu ifade sayesinde yeni gelen bir örneğin normal mi yoksa skolyoz mu olduğuna karar verilir. Burada destek vektör makinelerinin temel matematiksel yapısı adım adım açıklanıp

hem doğrusal hem de doğrusal olmayan durumlar için modelin işleyişine dair kuramsal altyapı sunulmuştur. Bundan sonraki kısımda, farklı çekirdek fonksiyonlarının bu yapı üzerindeki etkileri ele alınacaktır.

Çekirdek fonksiyonları sayesinde veriler, iç çarpımlar aracılığıyla yüksek boyutlu özellik uzaylarına aktarılır ve bu uzayda doğrusal karar yüzeyleri elde edilir. Pratikte en çok tercih edilen çekirdek fonksiyonları arasında Polinom, RBF ve Sigmoid çekirdekler yer almaktadır. Çekirdek seçimi veri yapısına göre değişkenlik gösterir; genellikle doğrusal çekirdek ile başlanıp diğer çekirdeklerle karşılaştırma yapılması önerilmektedir (Ben-Hur ve Weston, 2010).

Literatürdeki çalışmalarda DVM performansının çekirdek fonksiyonu seçimine ne kadar duyarlı olduğu gösterilmiştir. Bu çalışmada literatürde sıklıkla tercih edilen RBF, Polinom, Doğrusal ve Sigmoid çekirdekler (Wirasati, Rustam, Aurelia, Hartini ve Saragih, 2021; Ismael ve Şengür, 2021; Khan ve Mehmood, 2022)) ve daha az incelenmiş olan ANOVA ve Laplace çekirdek fonksiyonları (Ngu, Yeo, Thien ve Nandong, 2024) yanında literatürde yeni tanıtılmış bir çekirdek olan LKF de bu tez çalışmasında kullanılmıştır. LKF özellikle sınırlı örnekleme içeren veri setlerinde yüksek genelleme yeteneği ve düşük standart sapma sağlaması açısından dikkat çekmektedir (Hiçdurmaz, Çalık ve Üstebay, 2024).

Literatürde kullanılan çekirdek fonksiyonları genel olarak iki grupta sınıflandırılabilir: Nokta çarpımı temelli fonksiyonlar (örneğin doğrusal, sigmoid veya polinom çekirdekler) ve uzaklık temelli radyal tabanlı fonksiyonlar. İlk grup fonksiyonlar genellikle $K(x, y) = K(x \cdot y)$ biçiminde tanımlanırken, ikinci grup fonksiyonlar ise $K(x, y) = K(\|x - y\|)$ şeklinde ifade edilir. Radyal tabanlı fonksiyonlar, yalnızca giriş verisi ile referans noktalar arasındaki mesafeye bağlı olarak değer üreten fonksiyonlardır.

Kullanılan çekirdek fonksiyonları ve bu fonksiyonların temel matematiksel biçimleri aşağıda verilmiştir. Her fonksiyonun sınıflandırma doğruluğuna etkisi, deneysel sonuçlar bölümünde karşılaştırmalı olarak analiz edilmiştir.

Tablo 1. Geleneksel Çekirdekler Tablosu

İsim	Çekirdek Fonksiyonları
Lineer çekirdek	$K(P_i, P_j) = P_i \cdot P_j$
Polinom çekirdek	$K(P_i, P_j) = (P_i \cdot P_j + 1)^P, P \in \mathbb{Z}^+$
Gauss çekirdek (RBF)	$K(P_i, P_j) = \exp(-\gamma \ P_i - P_j\ ^2), (\gamma > 0)$
Sigmoid Çekirdek	$K(P_i, P_j) = \tanh(\eta P_i P_j + v), \eta > 0, v < 0$
Laplace Çekirdeği	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\), \gamma > 0$

Tablo 2. Yeni Çekirdekler Tablosu

İsim	Çekirdek Fonksiyonları
ANOVA	$K(x_i, x_j) = \sum_{k=1}^d \left(\exp \left(-\gamma (x_{ik} - x_{jk})^2 \right) \right)^r$
Logaritmik çekirdek (LKF)	$K(x_i, x_j) = \log \left(\frac{\ x_i - x_j\ ^2 + e \cdot \lambda}{\ x_i - x_j\ ^2 + \lambda} \right)$

Tüm çekirdek fonksiyonu karşılaştırmalarında performansta artışa neden olduğu için LKF'nin bir versiyonu olan;

$$K(x_i, x_j) = \log \left(\frac{\|x_i - x_j\| + e \cdot \lambda}{\|x_i - x_j\| + \lambda} \right)$$

fonksiyonu kullanılmıştır. Modelin hata toleransı ve marjin genişliği üzerinde etkili olan C parametresi gibi hiper parametrelerin dikkatli seçilmesi de önemlidir (Ben-Hur & Weston, 2010). Bu tez çalışmasında modelin performansını artırmak amacıyla hiperparametre optimizasyonu gerçekleştirilmiş; bu süreçte HalvingGridSearch algoritması kullanılmıştır. Her model için ' C ': [0.1, 1, 10, 100] ve her çekirdeğe özgü gamma, d gibi parametrelerinin en uygun kombinasyonları optimizasyon ile belirlenmiş, adaletli olacak şekilde bir karşılaştırma yapılmıştır. Polinom çekirdeği için her defasında derece için 2,3,4 denenmiş, en iyi sonucu veren polinomun derecesi yöntem sütununda belirtilmiştir. En iyi sonucu veren polinom çekirdeğinin sonuçlarına tabloda yer verilmiştir.

3.2.5. Hibrit Makine Öğrenmesi

Hibrit Öğrenme, klasik makine öğrenmesi algoritmaları ile derin öğrenme gibi gelişmiş yapay zekâ tekniklerinin güçlü bir birleşimini temsil eder ve karmaşık görevleri dikkate değer bir verimlilik ve doğrulukla ele alma kapasitesini bize sunar. Bu modeller karmaşık senaryoları daha verimli bir şekilde ele alıp hesaplama yükünü azaltırlar ve sağlıktan finansa çok sayıda sektörde kullanılmaktadırlar (Polymer,2024).

Hibrit Öğrenme geleneksel makine öğrenmesi algoritmaları ve gelişmiş derin öğrenme tekniklerinin güçlü yönlerinden faydalanarak model performansını ve yorumlanabilirliğini artırmayı hedefler. Makine öğrenmesi algoritmaları, yapılandırılmış verileri işleme konusunda yetkindir ve açık bir yorumlanabilirlik sunar, öte yandan derin öğrenme, karmaşık örüntüleri öğrenme ve otomatik özellik çıkarma yeteneği sayesinde, görüntü ve veri gibi verileri işleme noktasında üstündür. Bu yöntemlerin amacı; model performansını artırmak, kaynak kullanımını optimize etmek ve çeşitli veri türlerine uyum sağlamaktır (Bengani, 2024).

Literatürde hibrit yaklaşımın kullanıldığı çalışmalarda, genellikle derin öğrenme ile öznelik çıkarımı yapılmakta ve bu öznelikler geleneksel makine öğrenmesi algoritmalarıyla sınıflandırılmaktadır (Alshagathrh vd., 2024).

Bu çalışmada, transfer öğrenme yöntemi kullanılarak önceden eğitilmiş bir derin sinir ağı olan DenseNet201 modeli ile X-ray görüntülerinden özellik çıkarımı gerçekleştirilmiştir. DenseNet201 modelinden çıkarılan bu özellik vektörleri, geleneksel bir makine öğrenme algoritması olan DVM’de farklı çekirdekler kullanılarak sınıflandırılmıştır. Böyle bir hibrit yapı, CNN’in güçlü özellik öğrenme kabiliyetini DVM’nin etkili sınıflandırma yeteneğiyle birleştirerek sistem performansını artırmayı amaçlamaktadır. Ayrıca farklı çekirdek fonksiyonlarının gösterdiği sınıflandırma performansı ortaya konulmuştur. Sonuçların karşılaştırılması için test doğruluk oranı, F1-Skoru, kesinlik, duyarlılık, eğitim süresi ve destek vektör sayısı gibi performans ölçütleri kullanılmıştır.

3.2.6. Performans Ölçütleri

Bu çalışmada hem veri ön işleme kombinasyonlarının hem de transfer öğrenme ve birleştirilmiş yaklaşımların etkinliğini değerlendirmek için aşağıdaki metrikler kullanılmıştır:

1) Kesinlik (Precision)

Modelin pozitif olarak tahmin ettiği örneklerden gerçekte pozitif olanların oranıdır. Yanlış pozitiflerin fazla olduğu durumlarda düşük olur. Pozitif tahminlerin ne kadar güvenilir olduğunu gösterir.

$$Kesinlik = \frac{TP}{TP + FP}$$

2) Duyarlılık (Recall)

Gerçek pozitif örneklerin ne kadarını doğru tahmin ettiğini gösterir. Pozitif sınıfın atlanmaması önemli olduğunda (örneğin hastalık tespiti) kritik bir metriktir.

$$Duyarlılık = \frac{TP}{TP + FN}$$

3) F1-Skoru (F-1 Score)

F1-Score, kesinlik (Precision) ve duyarlılık (Recall) metriklerinin harmonik ortalamasıdır. Dengeli bir performans ölçütü sağlar. Kesinlik ve Duyarlılık arasında denge sağlar, özellikle veri seti dengesiz olduğunda önemlidir. Kesinlik ve Duyarlılık’tan ayrı bir anlam taşımaz, ancak bunların dengelenmiş bir ölçüsüdür.

$$F1 = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık}$$

4) Doğruluk (Accuracy)

Modelin toplam doğru tahmin oranını ifade eder. Tüm doğru tahminlerin (doğru pozitif ve doğru negatif) toplam tahmin sayısına oranıdır. Genel model performansını hızlı bir şekilde değerlendirir. Dengeli olmayan veri setlerinde yanıltıcı olabilir. Örneğin, skolyoz kategorisi baskınsa, model sadece skolyozu tahmin ederek yüksek doğruluk sağlayabilir.

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

5) Karışıklık Matrisi (Confusion Matrix)
Modelin doğru ve yanlış tahminlerini görselleştiren bir tablodur.

$$\begin{bmatrix} TP & FN \\ FP & TN \end{bmatrix}$$

4. DENEY SONUÇLARI – BULGULAR

4.1. Transfer Öğrenme Sonuçları

Bu çalışmada ilk olarak, ön işleme uygulanmış X-ray görüntüleri doğrudan transfer öğrenme yöntemiyle sınıflandırılmıştır. DenseNet201 mimarisi, önceden eğitilmiş ağırlıklarla kullanılmış ve son 10 katman açık bırakılarak modelin medikal görüntülere uyum sağlaması amaçlanmıştır. Eğitim süreci 5 katlı çapraz doğrulama (5-fold cross-validation) yöntemiyle gerçekleştirilmiştir. Detaylı test sonuçları Tablo 3 ve Tablo 4’te sunulmuştur.

Tablo 3. DenseNet-201 Modeli ile Transfer Öğrenme Eğitim Sonuçları

Görüntü Ön İşleme Yöntemi	Eğitim Doğruluğu	Eğitim Doğruluğu Standart Sapması	Hesaplama Süresi
Ham Veri	0.9722	0.0176	241.500 sn
Imadjust	0.9889	0.0136	241.824 sn

Tablo 4. DenseNet-201 Modeli ile Transfer Öğrenme Test Sonuçları


Görüntü Ön İşleme Yöntemi	Test Doğruluğu	Test Kesinlik	Test Duyarlılık	Test F1-Skoru
Ham Veri	1.0000	1.0000	1.0000	1.0000
Imadjust	0.9873	0.9828	1.0000	0.9913

Transfer öğrenme yöntemi ile ham verilerle elde edilen sınıflandırma sonuçları doğrultusunda oluşturulan karışıklık matrisleri incelendiğinde hem skolyoz hem de normal sınıfların doğru şekilde sınıflandırıldığı görülmektedir. Imadjust ön işleme tekniği uygulanmış verilerde bir normal görüntünün yanlış şekilde skolyoz olarak sınıflandırıldığı görülmüştür. Tablo 3 ve Tablo 4 incelendiğinde her iki veri seti ile de yüksek sınıflandırma


doğruluğu görülmektedir. Imadjust ön işleme tekniği test doğruluğunu çok düşük düzeyde azaltmıştır.

4.2. DVM Sonuçları

Ham veri görüntülerin t-SNE ile ve UMAP ile görsellenmesi bize görüntü vektörleri arasında lineer olmayan bir ilişki bulunduğunu göstermektedir:



Şekil 6. t-SNE ile Ham Görüntü Vektörlerinin Görsellenmesi



Şekil 7. UMAP ile Ham Görüntü Vektörlerinin Görsellenmesi

Doğrudan DVM modeline görüntü vektörlerini vermenin sınıflandırma problemi açısından çok kolay olmadığı görülmektedir. Şekil 6 ve Şekil 7 verinin nonlinear bir yapıya sahip olduğunu göstermektedir. Bu da çekirdek fonksiyonlarının seçimini önemli kılmaktadır.


Tablo 5. *Ham Verilerle DVM Model Eğitim Sonuçları ve Destek Vektör Sayısı*

Çekirdek Türleri	Eğitim Doğruluğu	Eğitim Doğruluk Standart Sapması	Destek Vektör Sayısı	Hesaplama Süresi
RBF	0.9542	0.0287	113	12.4037
Doğrusal	0.9503	0.0262	69	5.3027
LKF	0.9467	0.0369	145	2.2879
Poly (n=3)	0.9352	0.0333	106	54.2246
Laplace	0.9085	0.0249	45	2.1568
Anova	0.9085	0.0249	45	601.0283
Sigmoid	0.9085	0.0249	45	5.1181


Tablo 6. *Ham Verilerle DVM Model Test Sonuçları*

Çekirdek Türleri	Test Doğruluğu	Test Kesinlik	Test Duyarlılık	Test F1 Skoru
LKF	0.9367	0.9362	0.9367	0.9362
Doğrusal	0.9241	0.9636	0.9298	0.9464
RBF	0.9241	0.9180	0.9825	0.9492
Poly (n=3)	0.8987	0.9298	0.9298	0.9298
Laplace	0.8101	0.8750	0.8596	0.8673
Anova	0.8101	0.8750	0.8596	0.8673
Sigmoid	0.8101	0.8750	0.8596	0.8673

79 test görüntüsünde, ANOVA, Sigmoid, Laplace çekirdekleri 15, Polinom çekirdeği 8 tane, RBF ve Doğrusal çekirdekleri 6 tane, LKF çekirdeği 5 tane görüntüyü yanlış sınıflandırmıştır. LKF, RBF ve Doğrusal çekirdekler, diğer çekirdek türlerine göre daha yüksek test doğruluğu ve F1-skoru sunarak veri setinde daha iyi genelleme başarısı göstermiştir. Çekirdek türüne bağlı olarak eğitim süresi değişkenlik göstermiş; Polinom çekirdeği en uzun eğitim süresine sahip olurken, LKF çekirdeği kısa sürede yüksek doğruluk elde ederek verimlilik avantajı sunmuştur. Imadjust ön işleme tekniği uygulanmış görüntü vektörlerinin görsellenmesi Şekil 8 ve Şekil 9’da sunulmuştur.



Şekil 8. t-SNE ile Imadjust Uygulanmış Görüntü Vektörlerinin Görsellenmesi



Şekil 9. UMAP ile Imadjust Uygulanmış Görüntü Vektörlerinin Görsellenmesi

Dense-Net201 modelinden çıkarılan öznetelik vektörlerinin geri yayılım esnasında lineer olmayan özelliklerinin törpülediği veri setinin etiketlerine göre gruplandığında lineere yakın bir sınırla kolayca ayrılabilceği görülmektedir. Bu da çekirdek fonksiyonların performanslarının birbirine benzer olmasına sebep olmaktadır. Imadjust Uygulanmış Verilerle DVM Model Eğitim ve Test Sonuçları Tablo 6 ve Tablo 7’de verilmiştir.

Tablo 7. *Imadjust Uygulanmış Verilerle DVM Model Eğitim Sonuçları ve Destek Vektör Sayısı*

Çekirdek Türleri	Eğitim Doğruluğu	Eğitim Doğruluk Standart Sapması	Destek Vektör Sayısı	Hesaplama Süresi
Poly (n=3)	0.9657	0.0076	113	52.9978
Doğrusal	0.9581	0.0254	68	4.7162
LKF	0.9544	0.0309	143	2.3851
RBF	0.9544	0.0254	126	11.7403
Laplace	0.9505	0.0255	88	2.2369
Anova	0.9505	0.0255	88	555.7580
Sigmoid	0.9505	0.0255	88	7.6242


Tablo 8. *Imadjust Uygulanmış Verilerle DVM Model Test Sonuçları*

Çekirdek Türleri	Test Doğruluğu	Test Kesinlik	Test Duyarlılık	Test F1 Skoru
LKF	0.9103	0.9016	0.9821	0.9402
Poly (n=2)	0.9103	0.9298	0.9464	0.9381
RBF	0.8974	0.8871	0.9821	0.9322
Doğrusal	0.8846	0.9434	0.8929	0.9174
Laplace	0.8846	0.9434	0.8929	0.9174
Anova	0.8846	0.9434	0.8929	0.9174
Sigmoid	0.8846	0.9434	0.8929	0.9174


79 test görüntüsünden Doğrusal, Sigmoid, Laplace ve ANOVA çekirdekleri 9, RBF çekirdeği 8, Polinom ve LKF çekirdekleri 7 görüntüyü yanlış sınıflandırmıştır. İmadjust uygulanmış verilerde, LKF ve Polinom (n=2) çekirdekleri %91,03 test doğruluğu ile en iyi performansı sergilemiştir. Buna karşılık, Doğrusal, Laplace, ANOVA ve Sigmoid çekirdeklerinde test doğruluğu %88,46'ya düşmüş ve bu çekirdeklerde sınıflandırma başarısı sınırlı kalmıştır. Özellikle LKF çekirdeği kısa eğitim süresi (~2,39 saniye) ile hem verimlilik hem de doğruluk açısından avantaj sağlamıştır. ANOVA çekirdeği ise aşırı uzun eğitim süresine (yaklaşık 555 saniye) rağmen düşük test doğruluğu ile dikkat çekmiştir.

4.3. Hibrit Model Sonuçları

Hibrit yaklaşımda, DenseNet-201 modeli yalnızca derin öznitelik çıkarımı amacıyla kullanılmış ve bu öznitelikler, farklı çekirdek fonksiyonlarıyla yapılandırılmış Destek Vektör Makineleri (DVM) ile sınıflandırılmıştır. Ham veri seti için DenseNet-201 modelinden çıkarılan öznitelik vektörlerinin görsellenmesi Şekil 10 ve Şekil 11'de verilmiştir.



Şekil 10. t-SNE ile Ham Veri için Çıkarılan Öznitelik Vektörlerinin Görsellenmesi



Şekil 11. Umap ile Ham Veri için Çıkarılan Öznitelik Vektörlerinin Görsellenmesi

Ham veriden çıkarılan öznitelik vektörlerinin t-SNE ve UMAP görselleri ikili bir yapı oluşturmaktadır. Çekirdek fonksiyonlarının farklılığı buradaki gibi lineere yakın bir sınır ile ayrılabilen sınıflandırma problemlerinde hesaplama süresidir.

Tablo 9. Ham Verilerle Hibrit Model Eğitim Sonuçları ve Destek Vektör Sayısı


Çekirdek Türleri	Eğitim Doğruluğu	Eğitim Doğruluk Standart Sapması	Destek Vektör Sayısı	Hesaplama Süresi
LKF	0.9962	0.0077	143	1.0075
Doğrusal	0.9955	0.0091	65	0.3848
Poly (n=2)	0.9955	0.0091	103	3.7523
Laplace	0.9955	0.0091	39	0.8948
Anova	0.9955	0.0091	39	21.0434
Sigmoid	0.9955	0.0091	39	0.5129
RBF	0.9955	0.0091	139	2.3575

Tablo 10. *Ham Verilerle Hibrit Model Test Sonuçları*


Çekirdek	Test	Test	Test	Test F1
Türleri	Doğruluğu	Kesinlik	Duyarlılık	Skoru
Anova	1.0000	1.0000	1.0000	1.0000
Sigmoid	1.0000	1.0000	1.0000	1.0000
LKF	0.9722	1.0000	0.9565	0.9778
Poly (n=4)	0.9444	1.0000	0.9130	0.9545
Doğrusal	0.9444	1.0000	0.9130	0.9545
Laplace	0.9444	0.9519	0.9444	0.9452
RBF	0.9444	1.0000	0.9130	0.9545

79 test görüntüsünden Doğrusal, Polinom ve RBF çekirdekleri 2, LKF çekirdeği 1 görüntüyü yanlış sınıflandırmıştır. Sigmoid, Laplace ve ANOVA çekirdekleri tüm görüntüleri doğru sınıflandırmıştır. Ham veri ile oluşturulan hibrit model sonuçlarına göre, Anova, Sigmoid ve Laplace çekirdekleri %100 test doğruluğu ve F1-skoru elde ederek tüm test görüntülerini doğru şekilde sınıflandırmıştır. Bu sonuçlar, hibrit modelin skolyoz verileri üzerinde son derece yüksek güvenilirlikle çalışabildiğini göstermektedir. LKF ve Doğrusal çekirdekler de yüksek doğruluk oranları ve düşük eğitim süreleri ile başarılı bir performans sergilemiştir. Saf DVM yaklaşımlarında daha sınırlı başarı gösteren ANOVA çekirdeğinin hibrit model içinde %100 doğruluğa ulaşması, transfer öğrenme ile çıkarılan özniteliklerin çekirdek performansını önemli ölçüde iyileştirdiğini ortaya koymuştur.

Imadjust ile işlenmiş veri için çıkarılan öznitelik vektörlerinin t-SNE ve UMAP görsellenmesi Şekil 12 ve Şekil 13'te verilmiştir.



Şekil 12. t-SNE ile İşlenmiş Veri için Öznitelik Vektörlerinin Görsellenmesi



Şekil 13. UMAP ile İşlenmiş Veri için Öznitelik Vektörlerinin Görsellenmesi

Imadjust uygulanmış verilerden çıkarılan öznitelik vektörlerinin t-SNE ve UMAP görsellerinde sınıflar arasında ham veride olduğu gibi yine belirgin bir ayrışma gözlemlenmekle birlikte, ham veriye kıyasla sınıf içi dağınıklığın arttığı ve sınıflar arası sınırların daha yumuşadığı görülmektedir. Bu durum, Imadjust işleminin verinin kontrastını artırarak bazı yapısal bilgileri değiştirmiş olabileceğini göstermektedir.

Tablo 11. *Imadjust Uygulanmış Verilerle Hibrit Model Eğitim Sonuçları*

Çekirdek Türleri	Eğitim Doğruluğu	Eğitim Doğruluk Standart Sapması	Destek Vektör Sayısı	Hesaplama Süresi
Anova	0.9955	0.0091	39	20.6475
LKF	0.9925	0.0092	107	0.7139
Doğrusal	0.9889	0.0136	56	2.6261
Poly (n=3)	0.9833	0.0136	83	3.3259
Laplace	0.9833	0.0136	42	0.8701
Sigmoid	0.9833	0.0136	42	0.5111
RBF	0.9667	0.0208	122	0.7681

Tablo 12. *Imadjust Uygulanmış Verilerle Hibrit Model Test Sonuçları*

Çekirdek Türleri	Test Doğruluğu	Test Kesinlik	Test Duyarlılık	Test F1 Skoru
LKF	0.9872	0.9825	1.0000	0.9912
Doğrusal	0.9872	0.9825	1.0000	0.9912
Poly (n=2)	0.9872	0.9825	1.0000	0.9912
Laplace	0.9872	0.9825	1.0000	0.9912
Anova	0.9872	0.9825	1.0000	0.9912
Sigmoid	0.9872	0.9825	1.0000	0.9912
RBF	0.9744	0.9655	1.0000	0.9825

79 test görüntüsünden, Doğrusal, Polinom, LKF, Sigmoid, Laplace ve ANOVA çekirdekleri 1, RBF çekirdeği 2 tane görüntüyü yanlış sınıflandırmıştır. Imadjust uygulanmış verilerle oluşturulan hibrit model, tüm çekirdek türlerinde %100 duyarlılık ve %98,72 test doğruluğu sağlayarak pozitif sınıfın eksiksiz şekilde tanımlandığını göstermiştir. RBF dışındaki tüm çekirdek fonksiyonlarında F1skoru %99,12 olarak hesaplanmış, bu da kesinlik ve duyarlılık dengesi açısından başarılı bir yapı ortaya koymuştur. Özellikle yalnızca 1-2 görüntünün

yanlış sınıflandırılması, modelin düşük hata oranı ve yüksek genelleme başarısını desteklemektedir. T-SEN ve UMAP görsellerinde sınıf ayrımının Imadjust verilerde biraz daha zayıfladığı görülse de hibrit model yapısı bu farkı telafi ederek etkili sınıflandırma sağlamıştır.

5. SONUÇ VE TARTIŞMA

Bu tez çalışmasında X-ray görüntülerinin skolyoz ya da normal olarak otomatik sınıflandırılmasına yönelik üç farklı yaklaşım karşılaştırılmıştır. Birinci yaklaşımda, DenseNet201 mimarisi transfer öğrenme yöntemiyle yeniden yapılandırılarak doğrudan sınıflandırma için kullanılmış; ikinci yaklaşımda yalnızca DVM ile sınıflandırma yapılmış, üçüncü yaklaşımda ise transfer öğrenme ile çıkarılan derin öznitelikler, DVM algoritmasıyla sınıflandırılmış ve böylece hibrit bir yapı oluşturulmuştur. Görüntü ön işleme yöntemi olarak görüntülerin kontrastını artırmak için Imadjust yöntemi kullanılmıştır ve bu yöntemin modellerin sonuçlarına etkisi gözlemlenmiştir.

DenseNet201 modeli ile transfer öğrenme yaklaşımı, ham verilerde %100 doğruluk elde ederek üstün performans göstermiştir. Imadjust ön işlemeli görüntülerde ise %98,73 doğruluk elde edilmiştir, her iki veri setinde de test duyarlılığı %100'dür.

Doğrudan DVM ile sınıflandırma yapmak, Umap ve t-SNE görsellemelerinden de anlaşıldığı gibi veri setimiz doğrusal olmayan bir yapıya sahip olduğu için kolay değildir ve diğer yöntemlerle karşılaştırıldığında performansı düşük kalmıştır. Imadjust işlemi, eğitim doğruluklarını artırmasına rağmen test aşamasında kullanılan çekirdeğe göre genel doğruluğun hafif şekilde azalmasına neden olmuştur. Özellikle LKF, Doğrusal ve RBF çekirdeklerinde, ham veri kullanımının test doğruluğu (%93,67 ve %92,41) ve F1-skoru açısından diğer çekirdeklerden daha iyi performans sergilemiştir. Sonuçlar, ham veri kullanımının DVM modellerinde daha iyi genelleme performansı sağladığını ortaya koymuştur.

Transfer öğrenme yöntemi özellikle ham veri ile çalışıldığında %100 doğruluk sağlamıştır. Ancak bu yüksek doğruluk oranı, yaklaşık 241 saniyelik uzun bir eğitim süresi ile elde edilmiştir. Buna karşılık, DVM çok daha kısa sürelerde, yaklaşık 2–3 saniyelik eğitim süresi ile tamamlanmış; ancak test doğrulukları %93–94 seviyelerinde kalmıştır. Bu sonuçlar, transfer öğrenmenin doğruluk açısından üstün, ancak hesaplama süresi açısından dezavantajlı; DVM yöntemlerinin ise hız açısından avantajlı ancak doğruluk bakımından sınırlı performans sunduğunu göstermektedir.

Her iki yöntemin avantajlı olduğu durumları birleştirmek için kullanılan hibrit modelde ise, DenseNet201 modelinden çıkarılan derin öznitelikler; Doğrusal, RBF, Laplace, Sigmoid, LKF, Polinom ve ANOVA olmak üzere yedi farklı SVM çekirdek fonksiyonu ile sınıflandırılmıştır. Ham veriden çıkarılan öznitelik vektörlerinin Umap projeksiyonları incelendiğinde, verilerin ikili bir yapı oluşturarak belirgin bir şekilde ayrıldığı gözlemlenmiştir. Bu durum, sınıflar arasında net bir sınır oluştuğunu ve sınıflandırmanın daha kolay gerçekleştirilebileceğini göstermektedir. Imadjust uygulanmış verilerde ise benzer şekilde lineere yakın bir ayrım gözlenmekle birlikte, ham veriye kıyasla sınıfların ayrışmasının daha az belirgin olduğu dikkati çekmiştir. Hibrit model sonuçları bu gözlemleri desteklemektedir. Ham veri kullanılarak oluşturulan hibrit modellerde, ANOVA ve Sigmoid

çekirdekleri ile %100 test doğruluğu ve F1-skoru ve LKF ile %97,22 test doğruluğu ve %97,78 F1-skoru elde edilmiştir. Imadjust verilerinde ise LKF, Doğrusal ve Polinom çekirdeklerinde %%98,72 test doğruluğuna ve %99,12 F1-skoruna ulaşılmıştır.

Çekirdek fonksiyonlarının etkisi, verilerin ayırım yapısı ile doğrudan ilişkilidir. Lineere yakın bir ayırımın söz konusu olduğu durumlarda, doğrusal çekirdekler veya düşük karmaşıklığa sahip çekirdekler (örneğin Doğrusal, LKF) hem daha kısa hesaplama süreleri sunmakta hem de yüksek doğruluk sağlamaktadır. Ham verilerle çalışıldığında hem öznelitekt vektörlerinin ayrışması daha net olmakta, hem de hibrit modeller daha yüksek performans göstermektedir.

Sonuç olarak hibrit model, yaklaşık 2–5 saniyelik bir sürede tamamlanarak transfer öğrenmeye kıyasla çok daha kısa sürede çalışmış, aynı zamanda DVM yöntemine göre daha yüksek doğruluk sağlamıştır. Hibrit model; doğruluk, hesaplama süresi ve genelleme yeteneği açısından transfer öğrenme ve DVM yöntemlerine göre daha dengeli ve üstün bir performans sergilemiştir. Bu sonuçlar, skolyoz gibi medikal görüntü sınıflandırmalarında hibrit modelin etkili ve uygulanabilir bir çözüm sunduğunu göstermektedir.

Bu çalışmada elde edilen sonuçlar ışığında, ilerleyen dönemlerde birkaç farklı araştırma yönü önerilebilir. Öncelikle, hibrit modelin başarısını daha büyük ve dengesiz veri setlerinde test etmek, modelin genelleme kapasitesini daha geniş ölçekte değerlendirmek açısından önemli olacaktır. Ayrıca, transfer öğrenme aşamasında kullanılan öznelitekt çıkarım katmanlarının optimize edilerek daha kompakt vektör boyutları oluşturulması, hesaplama süresini daha da azaltabilir ve aşırı öğrenme riskini azaltabilir. İleride, farklı derin öğrenme mimarilerinden çıkarılan öznelitektlerin DVM gibi geleneksel yöntemlerle birleştirilerek daha gelişmiş hibrit modellerin geliştirilmesi de skolyoz gibi medikal görüntü sınıflandırma problemleri için umut verici bir yaklaşım sunmaktadır.

KAYNAKÇA

- Abdallah, Y. M. Y., & Ben Yousef, R. M. (2015). Augmentation of X-rays images using pixel intensity values adjustments. *International Journal of Science and Research (IJSR)*, 4(2), 2425–2429.
https://www.academia.edu/11358915/Augmentation_of_X_rays_Images_using_Pixel_Intensity_Values_Adjustments
- Agarap, A. F. (2019). *An Architecture Combining Convolutional Neural Network (CNN) and Support Vector Machine (SVM) for Image Classification* (No. arXiv:1712.03541). arXiv.
<https://doi.org/10.48550/arXiv.1712.03541>
- Alshagathrh, F., Alzubaidi, M., Gecik, S., Alswat, K., Aldhebaib, A., Alahmadi, B., Alkubeyyer, M., Alosaimi, A., Alsadoon, A., Alkhamash, M., Schneider, J., & Househ, M. (2024). Hybrid Deep Learning and Machine Learning for Detecting Hepatocyte Ballooning in Liver Ultrasound Images. *Diagnostics*, 14(23), Article 23. <https://doi.org/10.3390/diagnostics14232646>
- Bengani, V. (2024). *Hybrid Learning Systems: Integrating Traditional Machine Learning with Deep learning Techniques*.
<https://doi.org/10.13140/RG.2.2.34709.54248/1>
- Ben-Hur, A., & Weston, J. (2010). A user's guide to support vector machines. *Methods in Molecular Biology (Clifton, N.J.)*, 609, 223-239.
https://doi.org/10.1007/978-1-60327-241-4_13
- Bouslihim, I., Cherif, W., & Kissi, M. (2023). Application of a hybrid EfficientNet-SVM model to medical image classification. *2023 14th International Conference on Intelligent Systems: Theories and Applications (SITA)*, 1-6.
<https://doi.org/10.1109/SITA60746.2023.10373755>
- Chen, K., Zhai, X., Sun, K., Wang, H., Yang, C., & Li, M. (2021). A narrative review of machine learning as promising revolution in clinical practice of scoliosis. *Annals of Translational Medicine*, 9(1), 67.
<https://doi.org/10.21037/atm-20-5495>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
<https://doi.org/10.1007/BF00994018>
- Fraiwan, M., Audat, Z., Fraiwan, L., & Manasreh, T. (2022). Using deep transfer learning to detect scoliosis and spondylolisthesis from X-ray images. *PLoS ONE*, 17(5), e0267851.
<https://doi.org/10.1371/journal.pone.0267851>
- Fraiwan, M., Audat, Z., & Manasreh, T. (2022). *A dataset of scoliosis, spondylolisthesis, and normal vertebrae X-ray images*. 1. <https://doi.org/10.17632/xkt857dsxk.1>
- Goldman, S. N., Hui, A. T., Choi, S., Mbamalu, E. K., Tirabady, P., Eleswarapu, A. S., Gomez, J. A., Alvandi, L. M., & Fornari, E. D. (2024). Applications of artificial intelligence for adolescent idiopathic scoliosis: Mapping the evidence. *Review of Spine Deformity*, 12(6), 1545–1570.
<https://doi.org/10.1007/s43390-024-00940-w>

- He, Z. (2020). Deep Learning in Image Classification: A Survey Report. *2020 2nd International Conference on Information Technology and Computer Application (ITCA)*, 174-177.
<https://doi.org/10.1109/ITCA52113.2020.00043>
- Hicdurmaz, B., Calik, N., & Ustebay, S. (2024). Gauss-like Logarithmic Kernel Function to improve the performance of kernel machines on the small datasets. *Pattern Recognition Letters*, 179, 178-184.
<https://doi.org/10.1016/j.patrec.2024.01.014>
- Hu, X. (2021). *Deep learning for medical image analysis* (Yayınlanmamış doktora tezi). Technische Universität München.
<https://mediatum.ub.tum.de/doc/1608918/2lw3a4uj2fsi9t3m4pb9eqxqf.Hu-Xiaobin.pdf>
- Ismael, A. M., & Şengür, A. (2021). Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Systems with Applications*, 164, 114054.
<https://doi.org/10.1016/j.eswa.2020.114054>
- Janicki, J. A., & Alman, B. (2007). Scoliosis: Review of diagnosis and treatment. *Paediatrics & Child Health*, 12(9), 771-776.
<https://doi.org/10.1093/pch/12.9.771>
- Karpiel, I., Ziębiński, A., Kluszczyński, M., & Feige, D. (2021). A survey of methods and technologies used for diagnosis of scoliosis. *Sensors*, 21(24), 8410.
<https://doi.org/10.3390/s21248410>
- Khan, R., & Mehmood, T. (2022). Classification of Thoracic Diseases Based on Chest X-ray Images Using Kernel Support Vector Machine. *Mathematical Problems in Engineering*, 2022(1), 9457730.
<https://doi.org/10.1155/2022/9457730>
- Kim, H., Kim, H. S., Moon, E. S., Yoon, C.-S., Chung, T.-S., Song, H.-T., Suh, J.-S., Lee, Y. H., & Kim, S. (2010). Scoliosis imaging: What radiologists should know. *Radiographics: A Review Publication of the Radiological Society of North America, Inc*, 30(7), 1823-1842.
<https://doi.org/10.1148/rg.307105061>
- Kumar, R., Gupta, M., & Abraham, A. (2024). A Critical Analysis on Vertebra Identification and Cobb Angle Estimation Using Deep Learning for Scoliosis Detection. *IEEE Access*, 12, 11170-11184.
<https://doi.org/10.1109/ACCESS.2024.3353794>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
<https://doi.org/10.1038/nature14539>
- Lee, G. B., Priefer, D. T., & Priefer, R. (2022). Scoliosis: Causes and Treatments. *Adolescents*, 2(2), Article 2.
<https://doi.org/10.3390/adolescents2020018>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
<https://doi.org/10.1016/j.media.2017.07.005>
- Lu, Q. T., & Nguyen, T. M. (2024). An Approach to Classifying X-Ray Images of Scoliosis and Spondylolisthesis Based on Fine-Tuned Xception Model. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 15(2), Article 2. <https://doi.org/10.14569/IJACSA.2024.0150262>
- Maeda, Y., Nagura, T., Nakamura, M., & Watanabe, K. (2023). Automatic measurement of the Cobb angle for adolescent idiopathic scoliosis using convolutional neural network. *Scientific Reports*, 13(1), 14576.

- <https://doi.org/10.1038/s41598-023-41821-y>
MathWorks. (t.y.). *Convolutional neural network (CNN)*. MathWorks.
<https://www.mathworks.com/discovery/convolutional-neural-network.html>
- Ngu, J., Sieng, Ir. Ts. D. Y., Thien, T., & Nandong, J. (2024). A comprehensive overview of the applications of kernel functions and data-driven models in regression and classification tasks in the context of software sensors. *Applied Soft Computing*, 164, 111975.
<https://doi.org/10.1016/j.asoc.2024.111975>
- R, M. T., Shrestha, P., Singh, A., Sarraf, I., & Garg, R. (2022). Identification and Classification of Scoliosis Using CNN And SVM Algorithms. *International Journal of Information Technology, Research and Applications (IJITRA)*, 1(2), 23-32. <https://doi.org/10.5281/zenodo.7014436>
- Shrestha, P., Singh, A., Garg, R., Sarraf, I., Mahesh, T. R., & Sindhu Madhuri, G. (2021). Early Stage Detection of Scoliosis Using Machine Learning Algorithms. *2021 International Conference on Forensics, Analytics, Big Data, Security (FABS)*, 1, 1-4.
<https://doi.org/10.1109/FABS52071.2021.9702699>
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018). *A Survey on Deep Transfer Learning* (No. arXiv:1808.01974). arXiv.
<https://doi.org/10.48550/arXiv.1808.01974>
- T.C. Sağlık Bakanlığı, Sağlık Hizmetleri Genel Müdürlüğü. (2018). *Türkiye adölesan idiyoPATİK skolyoz prevelans araştırması sonuç raporu* (1. baskı). T.C. Sağlık Bakanlığı Sağlık Hizmetleri Genel Müdürlüğü.
<https://www.tftr.org.tr/uploads/skolyoz.pdf>
- Üstündağ, E. (2022). *Evrişimli sinir ağları, transfer öğrenme ve destek vektör makineleri kullanarak akciğer röntgen görüntülerinden COVID-19 sınıflandırması* (Yayınlanmamış yüksek lisans tezi). Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü.
- Yahara, Y., Tamura, M., Seki, S., Kondo, Y., Makino, H., Watanabe, K., Kamei, K., Futakawa, H., & Kawaguchi, Y. (2022). A deep convolutional neural network to predict the curve progression of adolescent idiopathic scoliosis: A pilot study. *BMC Musculoskeletal Disorders*, 23(1), 610.
<https://doi.org/10.1186/s12891-022-05565-6>
- Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*, 9(4), 611–629.
<https://doi.org/10.1007/s13244-018-0639-9>
- What is Hybrid Machine Learning?* (t.y.). Polymer. Geliş tarihi 28 Nisan 2025, gönderen <https://www.polymersearch.com/glossary/hybrid-machine-learning>
- Wirasati, I., Rustam, Z., Aurelia, J. E., Hartini, S., & Saragih, G. S. (2021). Comparison some of kernel functions with support vector machines classifier for thalassemia dataset. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 10(2), Article 2.
<https://doi.org/10.11591/ijai.v10.i2.pp430-437>
- Xie, K., Zhu, S., Lin, J., Li, Y., Huang, J., Lei, W., & Yan, Y. (2025). A deep learning model for radiological measurement of adolescent idiopathic scoliosis using biplanar radiographs. *Journal of Orthopaedic Surgery and Research*, 20(1), 236.
<https://doi.org/10.1186/s13018-025-05620-7>

Ekler

Ek 1- Matlab Kodları

```
% Görüntü yolu
inputPath = 'C:\Users\fatmanur\Desktop\SplitDataSet\test\Scol\N53, Lt LAIS, F,
18 Yrs.jpg';

% Görüntüyü yükle
I = imread(inputPath);

% Görüntüyü yükle
I = imread(inputPath);

% Görüntünün boyutlarını kontrol et (renkli mi, gri mi?)
if size(I, 3) == 3
    % Görüntü renkliyse gri tonlamaya dönüştür
    I = rgb2gray(I);
    disp('Görüntü renkliydi, gri tonlamaya dönüştürüldü. ');
end

% imadjust uygula (Kontrast artırma)
J = imadjust(I);

% Görüntüleri yan yana birleştir
comparison = cat(2, I, J);

% Görüntüyü ekranda göster
figure;
imshow(comparison);
title('Sol: Orijinal Görüntü, Sağ: imadjust Uygulanmış Görüntü');

% Görüntüyü masaüstüne kaydet
outputPath = fullfile(getenv('USERPROFILE'), 'Desktop',
'imshow_comparison.jpg');
imwrite(comparison, outputPath);

disp(['Karşılaştırmalı görüntü başarıyla masaüstüne kaydedildi: ',
outputPath]);
```

Şekil 14. IMADJUST kodu

EK 2- Python Kodları

<https://github.com/ffatmanurggultekin/scoliosis-detection>