



SKOLYOZ TANISINDA DERİN ÖĞRENME MODELLERİ VE DEĞERLENDİRİLMESİ

DOÇ.DR MURAT SAYLIK

Ortopedi ve Travmatoloji Uzmanı



SKOLYOZ

Skolyoz, omurganın anormal şekilde eğilmesi sonucu gelişen, genellikle genç yaşlarda başlayan ve tedavi edilmediğinde ciddi sağlık sorunlarına yol açabilen bir hastalıktır. 10 ila 18 yaş arasındaki kişilerde etiyolojisi bilinmeyen ve 10° veya daha fazla omurga eğriliği olarak tanımlanır. Ergenlerde en sık görülen omurga bozukluğu olup, dünya çapında %0,5-5,2 oranında görülür. [1] Eğriye, az veya çok gövde dengesizliği ve asimetrik kaburga çıkıntısı veya "kaburga kamburu" eşlik eder. [2] Skolyoz genellikle sırtın bir deformitesi olarak ortaya çıkar, **daha nadiren radyografide şans eseri bulunur veya ağrı veya ilgisiz semptom şikayetiyle ilişkilidir.**



RADYOLOJİK YÖNTEM RİSK

Günümüzde, skolyoz tanısı çoğunlukla fiziksel muayene ve radyolojik görüntüleme yöntemleriyle konulmaktadır. Ancak X-ray gibi geleneksel radyolojik yöntemler, hastaların özellikle çocuklar ve gençler için yüksek dozda radyasyona maruz kalmalarına sebep olmakta ve bu da uzun vadede sağlık riskleri taşımaktadır. Skolyoz taraması için geleneksel tanı araçları, önemli sayıda uzman personel ve donanım gerektirir ve bu da erken tanı ve optimum tedavi için fırsatların kaçırılmasına yol açabilecek rahatsızlığa neden olur. Bu sebepten ötürü, **radyasyon içermeyen, non-invaziv yöntemlere olan ihtiyaç her geçen gün artmaktadır.**




LİTERATÜR ÇALIŞMA ÖRNEKLER

Deep learning-assisted screening and diagnosis of scoliosis: segmentation of bare-back images via an attention-enhanced convolutional neural network Derin Öğrenme Destekli skolyoz Taraması ve Tanısı: Dikkatle geliştirilmiş evrişimli sinir ağı aracılığıyla çıplak sırt görüntülerinin segmentasyonu

Skolyoz taramasının verimliliğini artırmak için derin öğrenmeye dayalı bir görüntü segmentasyon modeli geliştirdik [4]

A Survey of Methods and Technologies Used for Diagnosis of Scoliosis Skolyoz Tanısında Kullanılan Yöntem ve Teknolojilerin İncelenmesi



ÇALIŞMA HEDEF VE KAPSAM

Derin öğrenme modelleri, özellikle büyük veri setlerini işleme yetenekleri ve yüksek doğrulukları ile tıbbi görüntü analizi alanında çok başarılı sonuçlar çıkarmaktadır. Çalışma, **düşük maliyetli, kolay uygulanabilir ve radyasyon içermeyen** bu yöntemin toplum tabanlı skolyoz taramalarında kullanılabilirliğini önermektedir.

Skolyozun otomatik tespiti amacıyla çeşitli derin öğrenme modelleri kullanılmıştır. Verilen çıplak sırt görüntüleri üzerinde yapılan bu çalışma, düşük maliyetli, radyasyonsuz ve non-invaziv bir tarama yöntemi sunmayı amaçlamaktadır.



VERİ SETİ

Skolyoz hastalığının tanısına yönelik Kaggle alınmış ve ayrıca farklı hasta resimlerinin kullanıldığı bir veri seti kullanılarak yapılmıştır. Veri seti, "**skolyoz var**" ve "**skolyoz yok**" olarak etiketlenmiş iki ana sınıfa ayrılmış çıplak sırt (bare back) görüntülerinden oluşmaktadır.

Skolyoz Yok : 30 **Skolyoz Var** :60

Veri Seti	Oran(%)	Açıklama
Eğitim (Train)	%70	Modelin öğrenme süreci verisi
Doğrulama (Validation)	%15	Eğitim sırasında modelin performansını değerlendirme verisi
Test	%15	Eğitim tamamlandıktan sonra modelin genel başarı performansını ölçme verisi

Model ezberliyor mu (overfitting) yoksa gerçekten öğreniyor mu?

Hiperparametreler (örneğin: öğrenme oranı, epoch sayısı, dropout oranı vs.) doğru mu?

Modelin erken durdurulması (early stopping) gerekiyor mu?



VERİ HAZIRLAMA SÜRECİ

Google Drive üzerinde barındırılmış ve Google Colab ile işlenmiştir. Verinin büyüklüğü sınırlı olduğu için **veri artırımı (data augmentation)** yöntemleri uygulanarak modelin genelleme yeteneği artırılmıştır.

Kullanılan artırma teknikleri **arasında rastgele döndürme, renk değişimi, kaydırma ve rastgele kırpma** yer almaktadır.

Bu sayede **modelin aşırı öğrenme (overfitting)** riski azaltılmış ve daha sağlam bir eğitim süreci sağlanmıştır.



VERİ HAZIRLAMA SÜRECİ

- ❑ `transforms.RandomResizedCrop(224, scale=(0.8, 1.0))` Rastgele Kırpma , 224x224 boyutuna yeniden ölçeklenir ve orijinal görüntünün %80 ile %100'ü arasında değişir.
- ❑ `transforms.RandomRotation(degrees=15)` rastgele -15° ile +15° arasında döndürülür, görüntüdeki açısal varyasyonlara karşı modelin toleransını artırmak.
- ❑ `transforms.ColorJitter(brightness=0.3, contrast=0.3, saturation=0.3, hue=0.05)` Renk özelliklerinde rastgele değişiklik yapılır Parlaklık (brightness): $\pm\%30$ Kontrast (contrast): $\pm\%30$ Doygunluk (saturation): $\pm\%30$ Renk tonu (hue): $\pm\%5$ Işık koşulları ve renk varyasyonları altındaki dayanıklılığı artırmak
- ❑ `transforms.RandomAffine(degrees=0, translate=(0.05, 0.05))` Genişliğin ve yüksekliğin %5'i kadar sağa-sola veya yukarı-aşağı rastgele kaydırma yapılır. Konum farklılıklarına karşı dayanıklılık kazandırmak.
- ❑ `transforms.Normalize([0.485, 0.456, 0.406], [0.229, 0.224, 0.225])` Görüntüleri ImageNet ortalama ve standart sapmasına göre normalize eder. Modelin daha iyi genelleştirme yapması.



YAPAY ZEKA MODELLER

DenseNet121, "vanishing gradient" (eğimin kaybolması) probleminin üstesinden gelebilmekte. Her katman, kendinden önceki tüm katmanların çıktısını doğrudan giriş olarak alır. Bu özellik, **skolyoz gibi yapısal bozuklukların görüntü üzerinde küçük detaylarla belirlendiği durumlarda faydalı olmuş**, modelin detayları kaybetmeden derinlemesine öğrenmesini sağlamıştır.

ViT-B16: Transformer tabanlı görüntü analizi

EfficientNet-B0: Yüksek doğruluk ve verimlilik

ResNet50: Residual bloklar ile derin ağlar

ConvNeXt-Tiny: Modernleştirilmiş CNN yapısı




EĞİTİM AŞAMALARI

Her bir model, PyTorch framework'ü ile eğitilmiştir. Modellerin eğitimi için **Çapraz Entropi Kayıp Fonksiyonu** (cross-entropy loss function) kullanılmış, optimizasyon işlemi için ise **Adam Optimizasyon** algoritması tercih edilmiştir. Her bir model, GPU üzerinde eğitilmiş ve doğruluk (accuracy), kayıp (loss) ve ROC eğrisi (Receiver Operating Characteristic curve) gibi metriklerle izlenmiştir. Eğitim süreci boyunca, her modelin doğruluk oranı ve AUC değeri detaylı bir şekilde hesaplanmış ve sonuçlar karşılaştırılmıştır. Eğitim süreci **20 dönem (epoch) boyunca** devam etmiştir.




DEĞERLENDİRME METODLARI

Confusion Matrix



ROC Eğrisi



DEĞERLENDİRME METODLARI

Sınıf	Precision	Recall	F1-Score	Support
No	0.83	0.83	0.83	6
Yes	0.90	0.90	0.90	10
Accuracy			0.88	16
Macro Avg	0.87	0.87	0.87	16
Weighted Avg	0.88	0.88	0.88	16



MODEL TEST GÖRSELLERİ

Gerçek: Yes
Tahmin: Yes



Gerçek: No
Tahmin: No



Gerçek: Yes
Tahmin: Yes



Gerçek: Yes
Tahmin: Yes



Gerçek: Yes
Tahmin: Yes



Gerçek: No
Tahmin: No



Gerçek: Yes
Tahmin: Yes



Gerçek: Yes
Tahmin: Yes



Gerçek: Yes
Tahmin: Yes



ÇALIŞMANIN KATKISI

Gelecekte, bu modellerin **toplu taramalarda ya da klinik ön değerlendirme araçları olarak kullanılması potansiyel taşımaktadır.** Önerilen yöntemin klinik taramalarda kullanılabilir potansiyele sahip olduğunu göstermektedir. Çalışmanın elde ettiği yüksek doğruluk, AUC ve sınıflandırma skorları, skolyozun erken tanısı için düşük maliyetli, hızlı ve güvenli bir alternatif sunmaktadır. Derin öğrenme algoritmalarının kullanımı gereksiz sevkleri ve örneğin skolyoz tarama maliyetlerini azaltma potansiyeline sahiptir. [3]

Radyasyon riski içermemesi, özellikle çocuklar ve ergenlerde geniş ölçekli tarama programları için önemli bir avantaj sağlamaktadır.

