



**X-RAY GÖRÜNTÜLERİNDE OMUZ
ARTROPLASTİSİ İMPLANTLARININ
SINIFLANDIRILMASINDA YENİ BİR DERİN
ÖĞRENME YAKLAŞIMI**

Shamriz NAHZAT

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Mete YAĞANOĞLU

2023

(Her Hakkı Saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

X-RAY GÖRÜNTÜLERİNDE OMUZ ARTROPLASTİSİ
IMPLANTLARININ SINIFLANDIRILMASINDA YENİ BİR DERİN
ÖĞRENME YAKLAŞIMI

(A Novel Deep Learning Approach to Classifying Shoulder Arthroplasty Implants in
X-Ray Images)

YÜKSEK LİSANS TEZİ

Shamriz NAHZAT

Danışman: Doç. Dr. Mete YAĞANOĞLU

Erzurum
2023



FEN BİLİMLERİ ENSTİTÜSÜ

Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü
TEZ KABUL VE ONAY TUTANAĞI

**X-RAY GÖRÜNTÜLERİNDE OMUZ ARTROPLASTİSİ İMPLANTLARININ
SINIFLANDIRILMASINDA YENİ BİR DERİN ÖĞRENME YAKLAŞIMI**

Doç. Dr. Mete YAĞANOĞLU danışmanlığında, Shamriz NAHZAT tarafından hazırlanan bu çalışma, 15/08/2023 tarihinde aşağıdaki jüri tarafından BİLGİSAYAR MÜHENDİSLİĞİ Anabilim Dalı BİLGİSAYAR MÜHENDİSLİĞİ Bilim Dalı'nda Yüksek Lisans tezi olarak **oybirliği / oy çokluğu (3/0)** ile kabul edilmiştir.

Jüri Başkanı:	Doç. Dr. Mehmet BAYÇIN <i>Erzurum Teknik Üniversitesi</i>	Aslı Islak İmzalıdır
Danışman:	Doç. Dr. Mete YAĞANOĞLU <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır
Jüri Üyesi:	Doç. Dr. Ferhat BOZKURT <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır

Enstitü Yönetim Kurulunun
....../....../..... tarih ve
sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof.Dr. Saltuk Buğrahan CEYHUN

Enstitü Müdürü

Aslı Islak İmzalıdır

**FEN BİLİMLERİ ENSTİTÜSÜ**

Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ REKTÖRLÜĞÜ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisans Tezi olarak *Doç. Dr. Mete YAĞANOĞLU* danışmanlığında sunulan “X-Ray Görüntülerinde Omuz Artroplastisi Implantlarının Sınıflandırılmasında Yeni Bir Derin Öğrenme Yaklaşımı” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	5	30
Kuramsal Temeller	24	30
Materyal ve Metot	4	35
Araştırma Bulguları ve Tartışma	2	20
Sonuçlar ve Öneriler	0	20
Tezin Geneli	14	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Sunulan bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ettiğimizi beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Shamriz NAHZAT	Doç. Dr. Mete YAĞANOĞLU
23.8.2023	23.8.2023
İmza: Aslı Islak İmzalıdır	İmza: Aslı Islak İmzalıdır

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun .../.../... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun .../.../... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

İlk olarak, bu tezi tamamlamama yardımcı olan en merhametli ve Rahim Allah'a derin şükranlarımı sunmak istiyorum.

Ayrıca, tezin başından beri yanımda olan, her adımda yol gösteren ve beni cesaretlendiren değerli hocam ve tez danışmanım Sayın Doç. Dr. Mete YAĞANOĞLU'na içtenlikle teşekkürlerimi sunmak istiyorum. Sabrı, desteği ve yol göstericiliği sayesinde bu tezi başarıyla tamamladım.

Tez çalışmamda beni yönlendiren, fikir alışverişlerinde bulunduğum ve moral desteği veren eşime, anne-babama, tüm aileme, arkadaşlarıma ve sevdiklerime de teşekkürlerimi sunarım.

Son olarak, bu tez çalışmasını tamamlamama yardımcı olan herkese minnettarım. Bu tez çalışmasını kendime, aileme ve danışmanıma ithaf ediyorum.

Shamriz NAHZAT

ÖZET

YÜKSEK LİSANS TEZİ

X-RAY GÖRÜNTÜLERİNDE OMUZ ARTROPLASTİSİ İMPLANTLARININ SINIFLANDIRILMASINDA YENİ BİR DERİN ÖĞRENME YAKLAŞIMI

Shamriz NAHZAT

Danışman: Doç. Dr. Mete YAĞANOĞLU

Amaç: Bu tezin amacı, bir röntgen (X-ray) görüntüsüne dayalı olarak omuz artroplastisi implantlarının üreticisini belirleyebilecek bir model geliştirmektir.

Cerrahların implant üreticisini X-ray görüntüleriyle doğru bir şekilde belirlemesi genellikle zordur ve insan hatası içerebilir. Bu nedenle implant üreticisinin doğru ve güvenilir bir şekilde tanımlanması için akıllı bir sistem kullanılması etkili olacaktır.

Materyal-Metot: Bu tezde kullanılan veri kümesi, toplamda 597 adet farklı boyutlarda JPEG formatındaki görüntülerden oluşmaktadır ve dört farklı omuz implantı üreticisine aittir. Bu veri kümesine, halka açık olan UCI Machine Learning Repository websitesinden erişilebilmektedir. Nispeten küçük veri kümesi ve dengesiz sınıf dağılımı gibi kısıtlamaları aşmak için, çeşitli veri artırma teknikleri uygulanmıştır. Mevcut görüntüleri çeşitlendirmek ve zenginleştirmek için veri artırma teknikleri kullanılarak modelin daha genelleyici ve daha sağlam bir şekilde eğitilmesi hedeflenmiştir.

Bu çalışmada, yeni bir Evrişimli Sinir Ağı (CNN) modeli tasarlanmış ve beş önceden eğitilmiş model olan MobileNetV2, DenseNet121, DenseNet201, InceptionV3 ve ResNet50 transfer öğrenimi kullanılarak X-ray görüntülerinden karmaşık desenler ve özellikler yakalanmıştır. Bu sayede omuz implantı üreticilerinin sınıflandırılması mümkün hale gelmiştir.

Bulgular: Bu tezde yapılan çalışma, X-ray görüntüleri kullanarak omuz implantı üreticilerini sınıflandırmak için derin öğrenme tekniklerinin önemli bir potansiyel taşıdığını göstermektedir. Veri artırma teknikleri sayesinde küçük ve dengesiz veri kümeleri üzerinde bile etkili sonuçlar elde edilebilir. Önceden eğitilmiş modellerin transfer öğrenimi ile karmaşık görüntü desenleri başarılı bir şekilde öğrenilebilir ve omuz implantı üreticilerinin doğru bir şekilde sınıflandırılması sağlanabilir. Bu çalışma, tıbbi görüntü analizinde derin öğrenme tekniklerinin kullanımının değerini vurgulamakta ve gelecekteki tıbbi uygulamalarda potansiyel bir etkisi olabileceğini göstermektedir.

Sonuç: Tasarlanan Evrişimli Sinir Ağı (CNN) modeli, MobileNetV2, DenseNet121, DenseNet201, InceptionV3 ve ResNet50 gibi beş önceden eğitilmiş modelin transfer öğrenimi ile omuz implantlarını sınıflandırmada yüksek doğruluk elde etti. En başarılı model olan DenseNet121, X-ray görüntülerinden üreticiyi %98 doğrulukla doğru bir şekilde tanımlama yeteneğini sergiledi.

Anahtar Kelimeler: Omuz Artroplastisi, Evrişimli Sinir Ağı, X-ray Görüntüleri, Çoklu Sınıf Sınıflandırma, Transfer Öğrenimi.

2023, 68 sayfa

ABSTRACT

MASTER DEGREE THESIS

A NOVEL DEEP LEARNING APPROACH TO CLASSIFYING SHOULDER ARTHROPLASTY IMPLANTS IN X-RAY IMAGES

Shamriz NHZAT

Supervisor: Assoc. Dr. Mete YAĞANOĞLU

Aim: The aim of this thesis is to create a model that can identify the manufacturer of shoulder arthroplasty implants based on an X-ray image. It is often difficult for surgeons to accurately determine the implant manufacturer using X-ray images and may involve human error. Therefore, using an intelligent system to identify the implant manufacturer accurately and reliably would be effective.

Materials and Methods: The dataset used in this thesis consists of a total of 597 JPEG format images of different sizes, belonging to four different shoulder implant manufacturers. This dataset can be accessed from the publicly available UCI Machine Learning Repository website. To overcome the limitations of a relatively small dataset and imbalanced class distribution, various data augmentation techniques were applied. The aim was to diversify and enrich the existing images using data augmentation techniques to train the model in a more generalized and robust manner.

In this study, a new Convolutional Neural Network (CNN) model was designed, and five pre-trained models, namely MobileNetV2, DenseNet121, DenseNet201, InceptionV3, and ResNet50, were used for transfer learning to capture complex patterns and features from X-ray images. This enabled the classification of shoulder implant manufacturers.

Finding: This study demonstrates the significant potential of deep learning techniques in classifying shoulder implant manufacturers using X-ray images. Even with small and imbalanced datasets, effective results can be achieved with data augmentation techniques. Through transfer learning with pre-trained models, complex image patterns can be successfully learned, leading to accurate classification of shoulder implant manufacturers. This study highlights the value of using deep learning techniques in medical image analysis and showcases the potential impact it could have in future medical applications.

Results: The designed Convolutional Neural Network (CNN) model, along with the transfer learning of five pre-trained models (MobileNetV2, DenseNet121, DenseNet201, InceptionV3, and ResNet50), achieved high accuracy in classifying shoulder implants. The best-performing model, DenseNet121, achieved an accuracy of 98%, showcasing the model's ability to accurately identify the manufacturer from X-ray images.

Keywords: Shoulder Arthroplasty, Convolutional Neural Network, X-ray Images, Multi-Class Classification, Transfer Learning

2023, 68 pages

İÇİNDEKİLER

TEZ KABUL VE ONAY TUTANAĞI	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ.....	ix
KISALTMALAR VE SİMGELER DİZİNİ.....	x
GİRİŞ.....	1
Araştırmanın Amacı	2
Araştırmanın Hedefleri	2
Tezin sınırlamaları ve zorlukları.....	3
KURAMSAL TEMELLER VE İLGİLİ ARAŞTIRMALAR	5
Derin Öğrenme ve Sinir Ağları	5
Evrişimli Sinir Ağları (CNN)	6
İLGİLİ ARAŞTIRMALAR.....	7
MATERYAL ve YÖNTEM	11
Veri Seti.....	11
Veri Ön İşleme	12
Veri Artırma	13
Veri Bölme	15
Sınıflandırma İçin Kullanılan Derin Öğrenme Yöntemleri ve Algoritmalar	17
Özel CNN Modeli.....	17
Transfer Öğreniminde Kullanılan Önceden Eğitilmiş Modeller	19
Çapraz doğrulama (Cross-validation).....	30
Kullanılan Programlama Dili ve İlgili Kütüphaneler	30
TensorFlow:.....	30

Keras:.....	31
NumPy:.....	31
Pandas:.....	31
Matplotlib ve Seaborn:	31
Scikit-learn:	31
Imgaug:.....	31
ARAŞTIRMA BULGULARI ve TARTIŞMA	32
Veri Arttırma Olmadan Modellerin Değerlendirilmesi	33
Özel CNN modelinin Değerlendirilmesi	33
Transfer Öğreniminde Kullanılan Önceden Eğitilmiş Modellerin Değerlendirilmesi	36
Veri Arttırma ile Modellerin Değerlendirilmesi.....	41
Veri Arttırma ve Dengesiz Veri Kümesini Çözme Etkisi	48
SONUÇ VE ÖNERİLER	51
KAYNAKLAR.....	53

TABLÖLAR DİZİNİ

Tablo 1. X-ray görüntü sınıflandırması üzerine farklı araştırma çalışmalarının özeti.....	10
Tablo 2. Farklı Sınıflara Ait Orijinal ve Artırılmış Veri Sayıları.	15
Tablo 3. Transfer Öğrenme ile Önceden Eğitilmiş Modellerin Özellikleri.	29
Tablo 4. Veri Artırma Kullanılmadan Özel CNN Modeli Hiper parametreleri.....	34
Tablo 5. Veri Artırma Kullanılmadan Özel CNN Modelinin Performans Sonuçları.	35
Tablo 6. Önceden Eğitilmiş Modeller Hiper parametreleri (Veri Artırma olmadan).....	36
Tablo 7. MobileNetV2 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).	39
Tablo 8. DenseNet121 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).....	39
Tablo 9. DenseNet201 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).....	39
Tablo 10. InceptionV3 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).....	40
Tablo 11. ResNet50 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).....	40
Tablo 12. Veri Artırma Kullanılarak Özel CNN Modelinin Performans Sonuçları.	45
Tablo 13. Veri Artırma Kullanılarak MobileNetV2 Modelinin Performans Sonuçları.	46
Tablo 14. Veri Artırma Kullanılarak DenseNet121 Modelinin Performans Sonuçları.	46
Tablo 15. Veri Artırma Kullanılarak DenseNet201 Modelinin Performans Sonuçları.	47
Tablo 16. Veri Artırma Kullanılarak InceptionV3 Modelinin Performans Sonuçları.	47
Tablo 17. Veri Artırma Kullanılarak ResNet50 Modelinin Performans Sonuçları.	47
Tablo 18. Aynı veri seti kullanılarak yürütülen çalışmalarının sonuçlarının bu çalışma ile karşılaştırılması.....	50

ŞEKİLLER DİZİNİ

Şekil 1. Yapay Sinir Ağının Yapısı (Zafari, et al. 2013).....	5
Şekil 2. Temel bir evrişimli sinir ağı modeli.....	7
Şekil 3. Tez çalışma şeması aşamaları.	11
Şekil 4. Veri kümesindeki dört tip omuz implantı örneği.	12
Şekil 5. Omuz implantları röntgen görüntüleri veri kümesinin dağılımı.	12
Şekil 6. Veri artırmadan sonra X-ray görüntüleri.....	14
Şekil 7. Veri artırmadan sonra omuz implantları röntgen görüntüleri veri kümesinin dağılımı.	14
Şekil 8. Veri artırma kullanmadan verilerin eğitim, doğrulama ve test kümelerine ayrılması.	15
Şekil 9. Veri artırmayı kullanarak verilerin eğitim, doğrulama ve test kümelerine ayrılması.	16
Şekil 10. Özel CNN tabanlı model.....	18
Şekil 11. MobileNetv2'nin mimarisi (Seidaliyeva et al., 2020).	20
Şekil 12. DenseNet modelinin yapısı.	22
Şekil 13. Inception-V3 blokları (Szegedy, et al., 2015).....	25
Şekil 14. InceptionV3 modelinin yapısı (Dong et al., 2020).....	26
Şekil 15. ResNet50 modelinin yapısı.	28
Şekil 16. K-Katlamalı Çapraz Doğrulama'nın görsel anlatımı.....	30
Şekil 17. Özel CNN Modelinin Eğitim ve doğrulama doğruluğu ve kayıp eğrisi.	34
Şekil 18. Veri artırma olmadan özel CNN modeli karışıklık matrisi.....	35
Şekil 19. MobileNetV2 ve DenseNet121 Karışıklık matrisi.....	37
Şekil 20. DenseNet201 ve InceptionV3 Karışıklık matrisi.	38
Şekil 21. Veri Artırma Kullanılarak Özel CNN modeli ve MobileNetV2 Karışıklık matrisleri.	42
Şekil 22. Veri Artırma Kullanılarak DenseNet121 ve DenseNet201 Karışıklık matrisleri.	43
Şekil 23. Veri Artırma Kullanılarak InceptionV3 ve ResNet50 Karışıklık matrisleri.	44
Şekil 24. Veri artırma kullanılarak Özel CNN Modelinin Eğitim ve doğrulama doğruluğu ve kayıp eğrileri.....	45
Şekil 25. Veri artırma kullanarak ve kullanmadan sınıflandırma tekniklerinin doğruluk karşılaştırması.....	49

KISALTMALAR VE SİMGELER DİZİNİ

CNN:	Convolutional Neural Network (Evrışimli Sinir Ağı)
JPEG:	Joint Photographic Experts Group (Ortak Fotografik Uzmanlar Grubu)
UCI:	University of California, Irvine (California Üniversitesi, Irvine)
ML:	Machine Learning (Makine Öğrenimi)
DL:	Deep Learning (Derin Öğrenme)
TSA:	Total shoulder arthroplasty (Toplam omuz artroplastisi)
RTSA:	Reverse total shoulder arthroplasty (Ters topyekûn omuz artroplastisi)
DCNN:	Deep Convolutional Neural Network (Derin Evrışimli Sinir Ağı)



GİRİŞ

Omuz protezi ameliyatı olarak bilinen omuz artroplastisi, popüler ve karmaşık bir ortopedik ameliyattır. Bu işlem, omuz ekleminin bir implant ile değiştirilmesini içerir. Ölü veya yaralı bir omuz eklemine değiştirmek için yapay bir implant kullanılabilir (Surgery, 2013). Piyasada, her biri diğerlerinden farklı yapılarda çeşitli implantlar geliştirebilen birçok yapay implant üreticisi bulunmaktadır.

Farklı protez modellerinin onarımı ve çıkarılması, farklı prosedürler ve bazı durumlarda farklı ekipman gerektirir (Bates et al., 2020). Bir hastanın omuz implantı aksesuarlarıyla ilgili sorunlar yaşadığını veya hastanın omuz eklemine bir kazada yaralandığını ve eklemine değiştirmesi gerektiğini varsayalım. Bu gibi durumlarda implant üreticisi hem hasta hem de klinisyen tarafından bilinmeyebilir. Bu nedenle ameliyat başlamadan önce üreticiyi doğru bir şekilde belirlemek çok önemlidir.

Ayrıca bazı durumlarda hastalar, omuz protezinin implantı edildikten yıllar sonra onarılmasını veya değiştirilmesini gerektirebilir. Bununla birlikte, hastalar ve birinci basamak doktorları için protezin tam üreticisini ve modelini belirlemek zor olabilir. Bu, özellikle ameliyat farklı bir ülkede yapıldığında ve hastanın artık tıbbi kayıtlara erişimi olmadığında geçerlidir. Tıbbi kayıtlardaki veya görüntülerdeki belirsizlik de protezin tanımlanmasını zorlaştırabilir.

Şu anda tıp uzmanları, görsel incelemeye ve X-ray görüntülerinin karşılaştırılmasına dayalı olarak tanımlama gerçekleştirmektedir.

Cerrahların X-ray görüntüleri ile implant üreticisini doğru bir şekilde tanımlaması genellikle zordur ve insan hatası içerebilir. Bu nedenle, akıllı bir sistem kullanmak, implant üreticisinin doğru ve güvenilir bir şekilde tanımlanması için etkili olacaktır.

Omuz implantı üreticilerini belirlemek için X-ray görüntülerine dayalı bir modelin geliştirilmesi, yalnızca insan hatasını azaltmakla kalmayacak, aynı zamanda doğru ve güvenilir tanımlama sağlayarak omuz protezi ameliyatı geçiren hastalar için bakım kalitesini ve sonuçları iyileştirecektir.

Bu tez çalışmasında, X-ray görüntülerine dayalı olarak omuz implantlarının üreticisini doğru bir şekilde tanımlayabilen bir model geliştirmeyi amaçlamaktadır. Önerilen model, tıp

uzmanları tarafından yapılan görsel inceleme ve X-ray görüntülerine dayalı olarak implant üreticilerinin belirlenmesine olan bağımlılığı azaltacaktır.

Yapay zekâ (AI) algoritmalarının, makine öğreniminin ve özellikle derin öğrenme yöntemlerinin farklı tıbbi ve biyolojik uygulamalarda kullanımı, bilgisayar işlemcilerinin kapasitesi arttıkça hızla artıyor. Bu algoritmalar, tıbbi resimleri analiz etmek için otomatik ve yarı otomatik sistemlerden insan genomu bilgilerini işlemek için büyük veri işleme algoritmalarına kadar çeşitli disiplinlerde kullanılmaktadır (Bohr A., & Memarzadeh K., 2020).

Yapay zekâ, makine öğrenimi ve derin öğrenmenin X-ray da dahil olmak üzere tıbbi görüntülerin teşhisinde ve sınıflandırılmasında kullanılması, bu teknolojinin tıp alanında en yaygın kullanılan uygulamalarından biridir (Bohr A., & Memarzadeh K., 2020). Tıbbi görüntülerin karmaşıklığı ve içlerindeki bilgi bolluğu nedeniyle, bu teknolojinin kullanımı görüntülerin yüksek doğrulukta ve daha hızlı algılanıp düzeltilmesini sağlar.

Araştırmanın Amacı

Bu tezin amacı, X-ray resimlerinde omuz artroplastisi implantlarını güvenilir bir şekilde sınıflandırmak için bir model oluşturmak üzere en son derin öğrenme tekniklerini kullanmaktır. Amaç, daha iyi hasta bakımına, tedavi planlamasına ve klinik karar vermeye olanak sağlayacak omuz implantlarının üreticisini belirlemenin etkinliğini ve doğruluğunu artırmaktır.

Araştırmanın Hedefleri

Mevcut Literatürün İncelenmesi: Omuz artroplastisi, implant sınıflandırması ve bu alanda yapay zekâ, makine öğrenimi ve derin öğrenme uygulamasına ilişkin mevcut literatürün gözden geçirilmesi.

Ön İşleme ve Veri artırma: Röntgen görüntülerinin kalitesini ve tutarlılığını artırmak için ön işleme tekniklerinin uygulanması. Veri kümesi boyutunu artırmak ve fazla uydurma riskini azaltmak için döndürme, öteleme, çevirme ve yakınlaştırma gibi Veri artırma tekniklerini uygulamak.

Özel CNN Modellerinin Geliştirilmesi: X-ray görüntülerinde omuz artroplastisi implantlarını sınıflandırmak için özel olarak uyarlanmış yeni Evrişimli Sinir Ağı (CNN) mimarileri tasarlamak ve geliştirmek. Modellerin performansını optimize etmek için CNN katmanlarının varyasyonları, havuzlama ve aktivasyon işlevleri dahil olmak üzere farklı ağ mimarileriyle denemeler yapmak.

Transfer öğrenimi ile önceden eğitilmiş CNN modellerini kullanması: MobileNetV2, DenseNet121, DenseNet201, ResNet50 ve InceptionV3 gibi önceden eğitilmiş modellerden yararlanarak transfer öğrenme tekniklerinden yararlanma. Omuz implantı veri setinde önceden eğitilmiş modellerde ince ayar yapılması, bunların belirli sınıflandırma görevine uyarlanması. Önceden eğitilmiş bilgiden yararlanma ile modelin veri kümesine uyarlanmasına izin verme arasındaki en uygun dengeyi bulmak için katmanları dondurmak ve çözmek için farklı stratejiler keşfetmek.

Model Eğitimi ve Değerlendirme: Veri setini eğitim, doğrulama ve test setlerine bölmek ve uygun kayıp fonksiyonları, optimize ediciler ve öğrenme oranı programları kullanarak geliştirilen CNN modellerini ve önceden eğitilmiş modelleri eğitmek. Eğitim sürecini izleme ve modellerin doğrulama setindeki performansını değerlendirme, gerektiğinde hiper parametrelerde ince ayar yapmak. Son olarak, sınıflandırma etkinliğini ölçmek için modellerin doğruluğunu, kesinliğini, hatırlamasını ve bağımsız test setindeki F1 puanını değerlendirmek.

Performans Karşılaştırması ve Analizi: Özel CNN modellerinin performansının ve transfer öğrenme yaklaşımlarından elde edilenlerin karşılaştırılması. Modellerin doğruluğunun (accuracy), duyarlılığının (sensitivity), F1 skorunun değerlendirilmesi ve omuz artroplastisi implantlarının sınıflandırılmasında etkinliklerinin belirlenmesi.

Bu amaç ve hedeflere ulaşarak, bu tez tıbbi görüntü analizi alanını, özellikle derin öğrenme teknikleri kullanarak omuz artroplastisi implantlarının sınıflandırılmasında ilerlemeye çalışmaktadır. Odak noktası, gelişmiş hasta bakımına katkıda bulunabilecek ve sağlık profesyonellerinin bilinçli tedavi kararları vermesine yardımcı olabilecek doğru ve sağlam modeller geliştirmektir.

Tezin sınırlamaları ve zorlukları

Gerçekleştirilen bu tez çalışmasının kısıtları maddeler halinde aşağıda verilmiştir:

1. Sınırlı sayıda implant görüntüsü: Bu tezin temel sınırlamalarından biri, eğitim ve değerlendirme için mevcut olan az sayıda omuz implantı X-ray görüntüsüdür. Veri setinde yaklaşık 597 görüntü bulunması, farklı tipte omuz implantlarının tamamını ve bu implantlardaki varyasyonları ve karmaşıklıkları tam olarak temsil etmeyebilir. Bu durum, geliştirilen sınıflandırma modellerinin genelleştirilebilirliğini ve sağlamlığını etkileyebilir.

2. Dengesiz veri kümesi: Bir diğer sınırlama, veri kümesi içindeki sınıf dengesizliğidir. Eğer belirli omuz implantı sınıfları yeterince temsil edilmemişse, çoğunluk sınıflarını destekleyen önyargılı modellere yol açabilir. Bu durum, özellikle azınlık sınıfları için sınıflandırma sisteminin doğruluğunu ve güvenilirliğini etkileyebilir.
3. Düşük kalite ve tutarsız görüntü özellikleri: Omuz implantı X-ray görüntüleri, boyut ve çözünürlük açısından farklı düzeylerde kalite ve tutarsızlık sahiptir. Bazı görüntülerin düşük çözünürlüğe veya düşük kaliteye sahip olması, özellik çıkarma ve doğru sınıflandırma için zorluklar yaratabilir.

Bu sınırlamaların farkında olmak ve bunlarla başa çıkmak için uygun stratejiler geliştirmek önemlidir. Daha fazla omuz implantı görüntüsüne erişim sağlamak veya veri artırma tekniklerini kullanmak, sınırlı sayıdaki görüntü sorununu aşmada yardımcı olabilir. Dengesiz veri kümesiyle başa çıkmak için sınıf dengeleme yöntemleri kullanılabilir.

Bu sınırlamalara rağmen, omuz implantı üreticilerini X-ray görüntülerine dayalı olarak sınıflandırmak için geliştirilen derin öğrenme yaklaşımı, sağlık alanında önemli bir adım olabilir. Bu çalışma, sınırlamaları ve zorlukları göz önünde bulundurarak, omuz implantı üreticilerini sınıflandırmak için daha güvenilir ve objektif bir yöntem sunmayı hedeflemektedir.


KURAMSAL TEMELLER VE İLGİLİ ARAŞTIRMALAR

Bu bölümde, tezin altında yatan teorik ve kavramsal çerçeveyi tanımlıyor ve ilgili araştırmaları gözden geçiriyoruz.

Derin Öğrenme ve Sinir Ağları

Derin öğrenme, verilerden karmaşık kalıpları ve temsilleri öğrenmek için çok katmanlı yapay sinir ağlarını eğitmeye odaklanan bir makine öğrenimi dalıdır. Derin öğrenme, bilgisayar görüşü, doğal dil işleme ve tıbbi görüntü analizi dahil olmak üzere çok çeşitli alanlarda büyük ilgi ve başarı elde etmiştir. İnsan beyninin sinir ağlarının yapısını ve ilhamını kullanan derin öğrenme algoritmaları, çok büyük miktarda veriyi işleyebilir ve daha önce sıradan makine öğrenimi algoritmalarının keşfetmesi zor olan özellikleri ve kalıpları otomatik olarak algılayabilir (Joseph, 2022).

Derin öğrenme yöntemlerinin, birbirine bağlı nöron katmanlarından oluşan bir sinir ağı bulunur. Her nöron girdi alır, ağırlıklar ve aktivasyon fonksiyonları ile hesaplamalar yapar ve çıktılar üretir. Nöronlar arasındaki bağlantıları temsil eden ağırlıklar, her bağlantının gücünü ve etkisini etkiler (Aggarwal, 2018). Şekil 1’de, sinir ağının yapısını göstermektedir.



Şekil 1. Yapay Sinir Ağının Yapısı (Zafari, et al. 2013).

Şekilde görülen x değerleri girdiler, w değerleri ise ağırlıklardır. Bias (b) değeri, öğrenmeyi geliştirmek için kullanılır. Ağırlıklı girdi alındığı zaman, yapay nöron üç işlem gerçekleştirir:

1. Alınan ağırlıklı girdilerin toplamı:

$$\sum_{i=1}^N w_i x_i = w \cdot x \quad (1)$$

2. Bias 'ın eklenmesi:

$$\sum_{i=1}^N w_i x_i = w \cdot x + b \quad (2)$$

3. Doğrusal olmayan aktivasyon fonksiyonunun uygulanması:

$$\alpha(\sum_{i=1}^N w_i x_i + b) = \alpha(w \cdot x + b) \quad (3)$$

Bu şekilde, yapay nöron bir çıktı (biyolojik bir nöronun aksonunu temsil eden) üretir ve bu daha sonra bağlı diğer yapay nöronlara iletilir (Zafari, et al. 2013).


Evrişimli Sinir Ağları (CNN)

Evrişimli Sinir Ağları (CNN'ler), özellikle görsel verilerin analiz edilmesi için özel olarak tasarlanmış bir sinir ağı türüdür (Jmour et al., 2018). Bu ağlar, bilgisayarla görme alanında önemli bir etki yaratmış ve tıbbi görüntü analizinin ilerlemesinde de önemli bir rol oynamıştır. CNN'ler, hiyerarşik temsilleri çıkarma ve yerel kalıpları yakalama konusunda mükemmel performans sergiler, bu nedenle görüntü sınıflandırma, nesne algılama ve segmentasyon gibi görevler için ideal hale gelirler (Sakib et al., 2018).

Tipik olarak, CNN'lerin mimarisi, evrişimli katmanlar, havuzlama katmanları ve tamamen bağlı katmanları içeren birden çok katmandan oluşur. Evrişimli katmanlar, giriş görüntülerine evrişimli işlemler uygulayarak, yerel kalıpları ve özellikleri yakalayarak öznitelik çıkarımını gerçekleştirir. Bu sayede, görüntülerdeki önemli özellikler belirlenir ve vurgulanır. Havuzlama katmanları, öznitelik haritalarını alt örnekleyerek uzamsal boyutu azaltır ve çeviri değişmezliğini sağlar. Bu, ağın küçük yer değişikliklerine karşı duyarlılığını azaltır ve daha genelleştirilmiş özniteliklerin çıkarılmasını sağlar. Son olarak, ağın sonundaki tamamen bağlı katmanlar, çıkarılan özniteliklere dayanarak sınıflandırma yapar (Jmour et al., 2018).

CNN'lerin bu mimarisi, özellikle tıp alanında önemli bir rol oynamıştır. Hastalık tanısı, tedavi planlaması ve hastaların takibi gibi birçok önemli görev, CNN'ler sayesinde daha hızlı

ve daha hassas bir şekilde gerçekleştirilebilmektedir. Bu nedenle, CNN'lerin tıbbi görüntü analizindeki başarısı, ilerlemelerin devam etmesine katkıda bulunmaktadır (Sakib et al., 2018). Şekil 2.'de temel evrişimli sinir ağı modelini göstermektedir.



Şekil 2. Temel bir evrişimli sinir ağı modeli.

İLGİLİ ARAŞTIRMALAR

Bu bölüm, omuz implant üreticilerinin ve diğer implantların sınıflandırılmasına ilişkin bir dizi yayın ve çalışmayı incelemektedir. Bu araştırmalar, yapay zekâ ve görüntü analizi tekniklerinin omuz implantları üzerindeki etkinliğini ve ayrıca çeşitli üreticileri uygun şekilde belirlemek için kullanılan metodolojileri araştırıyor. Ayrıca bu araştırmaların bulguları ve elde edilen başarı oranları anlatılmaktadır.

Çalışmalarında, Sivari ve ark. (2022), omuz implant üreticilerini sınıflandırmak amacıyla hibrit bir makine öğrenimi sistemi sunmuşlardır. Yaklaşımları, derin öğrenme ve makine öğrenimi algoritmalarını birleştirmeyi içermektedir. Kullanılan makine öğrenimi algoritmaları arasında AdaBoost, Bernoulli Naive Bayes, Karar Ağacı, Gaussian Naive Bayes, K-En Yakın Komşu, Lineer Ayrımcı Analiz, Lojistik Regresyon, Lineer Destek Vektör Makinesi, Çok Katmanlı Algılayıcı ve Rastgele Orman bulunmaktadır. Kullanılan derin öğrenme algoritması ise DenseNet201'dir. DenseNet201 + LR algoritması, omuz implant üretici sınıflarını %95,07 doğruluk oranıyla tahmin ederken, DenseNet201 ağı %73,33 doğruluk oranı sağlamıştır (Sivari et al., 2022).

Sultan ve ark. (2021) omuz implantlarının tanımlanması için yoğun artık topluluk ağı (Dense Residual Ensemble-Network- DRE-Net) olan ve iki CNN modelinden (değiştirilmiş ResNet ve DenseNet) ve sığ bir birleştirme ağından (Shallow Concatenation Network- SCN)

oluşan derin öğrenmeye dayalı bir çerçeve sunmuştur. Bu çalışmada, aşırı uyumu (overfitting) önlemek için bir rotasyonel değişmez büyütme (Rotational Invariant Augmentation- RIA) kullandılar ve omuz implantlarının X-ray görüntülerinin 10 kat çapraz doğrulaması üzerinde deneyler yapıldı. Deneysel sonuçlar, DRE-Net'in sırasıyla %85,92, %84.69, %85.33 ve %84.11'lik bir doğruluk, F1 puanı, kesinlik ve geri çağırma elde ettiğini gösterdi (Sultan et al., 2021).

Yılmaz (2021), omuz implantı sınıflandırması için çok kanallı CNN modelini önerdi. Önerilen çok kanallı CNN modeline üç kanallı bir evrişim katmanı (Convolutional Layer) dahil edilmiştir. Model, görüntüler ön işleme tabi tutulduktan sonra genel evrişim katmanı ile başlar. Bu katman iki ayrı evrişim katmanını besler ve toplamda üç kanal olarak tasarlanmıştır. Bu katmanlarda üç evrişim katmanı, iki havuzlama katmanı (Pooling Layer), bir ReLU lineer birim ve bir tam bağlantılı katman (Fully Connected Layer) bulunur. Model toplam 12,447,924 parametreye sahiptir. Modellerini yaklaşık 45,000 saniye ve 500 iterasyonda eğitmişlerdir ve önerilen model %97,2 doğruluk göstermiştir. (Yılmaz, 2021).

Kentsel ve ark. (2020), omuz implantı üreticilerini sınıflandırmak için X-ray görüntülerini kullanmıştır. Araştırma, makine öğrenme yöntemlerinin yanı sıra VGG-16, VGG-19, ResNet-50, ResNet-152, DenseNet, NASNet ve özel bir CNN dahil olmak üzere yedi derin öğrenme modelini içermektedir. Modelleri eğitmek için 10 kat çapraz doğrulama kullandılar. Kullanılan yaklaşımlar arasında veri artırma olmadan, ImageNet üzerinde ön eğitim içeren NASNet derin öğrenme mimarisi, %80,4 ile en yüksek doğruluk oranına sahiptir. Veri artırma uygulandığında, DenseNet-201 mimarisi %78,9 ile en yüksek doğruluk oranına ulaşmıştır (Kentsel et al., 2020).

Urban ve ark. tarafından 2020 yılında gerçekleştirilen öncü bir çalışmada, Cofield, Depuy, Tornier ve Zimmer olmak üzere dört üretici sınıfını içeren 597 X-ray görüntüsünden oluşan bir veri seti oluşturularak omuz implant üreticilerini sınıflandırmak amaçlanmıştır. Önerilen sınıflandırma yönteminde altı farklı evrişimli sinir ağı (VGG-16, VGG-19, ResNet-50, ResNet-152, DenseNet, NASNet) ve dört farklı makine öğrenimi sınıflayıcısı (Lojistik Regresyon, Rastgele Ormanlar, Gradient Boost, ve K-En Yakın Komşu) kullanılmıştır. Sınıflandırma işlemi sırasında, evrişimli sinir ağları kullanılarak %74 ile %80 arasında doğruluk değerleri elde edilirken, diğer sınıflayıcılarla %51 ile %56 arasında doğruluk değerleri elde edilmiştir. Bu, omuz implant üreticilerini sınıflandırmak amacıyla yapılan ilk çalışmadır (Urban et al., 2020).

Yi ve ark. (2020) yılında otomatik olarak omuz artroplastisi modellerini algılamak ve sınıflandırmak için derin öğrenme yaklaşımları kullanmışlardır. Çalışmalarında, artroplasti implantlarının varlığını ikili olarak sınıflandırmak için bir transfer öğrenme tekniği ve ince ayarlı (fine-tuned) ResNet-18 modelini kullanmışlardır. Aynı yaklaşımı TSA ve RTSA'yı tanımlamak için de kullanmışlardır. Ayrıca, beş TSA modelini ikili olarak sınıflandırmak için ince ayarlı (fine-tuned) ResNet-152 tabanlı beş model kullanmışlardır (Yi et al., 2020).

Stark (2018), X-ray görüntülerinde omuz implantlarının otomatik olarak algılanması ve bölünmesi üzerine çalışmıştır. Çalışmasında, yazar, X-ray görüntülerinde implantların yerini ve omuz implantı olup olmadığını bulmak ve belirlemek için Hough çemberinin saptanmasına dayalı, %77 hassasiyet ve %64 F-ölçüsü gösteren bir model tanıtmıştır (Stark, 2018).

Karnuta ve ark. (2020), 9 farklı diz implantı modelinin sınıflandırılması için önceden eğitilmiş CNN modelini kullanmış, çalışmalarında ilk olarak her bir görüntü, implanta odaklanmak için kırılarak ön işleme tabi tutulmuş ve gri tonlamaya dönüştürülerek yeniden boyutlandırılmıştır. InceptionV3 modelini 1000 epoch ile eğittikten sonra, genel olarak, implant şirketinin belirlenmesinde %99 doğruluk ve implant tipinin belirlenmesinde %99 doğruluk elde edilmiştir (Karnuta et al., 2020).

Yi ve ark. (2019), diz implantlarını üç veri setinde sınıflandırmak için derin bir öğrenme sistemi kullanmışlardır. Yazarlar, görüntü sayısını artırmak için veri artırma (data augmentation) yöntemini kullandılar ve sınıflandırma ikili bir şekilde (implantın varlığı) yapılmıştı. Çalışmalarında ResNet-18 DCNN, diz radyografilerinde hem TDA'yı tespit etme hem de TDA ile UKA'yı (tek bölmeli diz artroplastisi) ayırt etme görevleri için %100'lük optimum duyarlılık ve özgüllükle 1'lik AUC değerleri elde etmiştir (Yi et al., 2019).

Kim ve ark. (2020), dört tip implantın sınıflandırılması için SqueezeNet, GoogLeNet, ResNet-18, MobileNet-v2 ve ResNet-50 gibi önceden eğitilmiş beş derin öğrenme modeli kullanmışlardır. Çalışmalarında, dört milyondan az parametreye sahip küçük ağlar olan SqueezeNet ve MobileNet-v2 sırasıyla %96 ve %97 doğruluk elde edilmiştir (Kim et al., 2020).

Sukegawa ve ark. (2020), 11 diş implantını sınıflandırmak için derin sinir ağları kullanmışlardır. Çalışmalarında implant sınıflandırması için beş CNN modeli kullanmışlardır. İnce ayarlı (fine-tuned) VGG16 modeli, %93,5 doğruluk oranı ile beş model arasında en yüksek doğruluk oranına sahiptir (Sukegawa et al., 2020).


Lindsey ve ark. (2018), radyografilerdeki kırıkları tanımlamak ve konumlandırmak için derin bir sinir ağı tasarlamışlardır. Geliştirilen sistem, klinisyenlerin duyarlılığını %80,8'den %91,5'e yükselterek, kırık tespitinde önemli bir artış sağlamıştır. Çalışmalarında, derin öğrenme modelinin radyografilerdeki bilek kırıklarını tespit etmek için deneyimli ortopedi cerrahlarınıninkine benzer bir tanısal doğrulukla eğitilebileceğini göstermektedir (Lindsey et al., 2018).

Tablo 1. X-ray görüntü sınıflandırması üzerine farklı araştırma çalışmalarının özeti.

Araştırma Çalışmaları	Problem Türü	Sınıf Sayısı	Yöntemler	Elde Edilen Sonuçlar Doğruluk (%)
Sivari et al., (2022)	Omuz implantları	4	Hibrit makine öğrenimi algoritmaları; 5 kat çapraz doğrulama	DenseNet201 + LR: 95,07
Sultan et al., (2021)	Omuz implantları	4	Yoğun artık topluluk ağı (DRE-Net): Değiştirilmiş ResNet ve DenseNet'in kombinasyonu; 10 kat çapraz doğrulama	85,92
Yılmaz, (2021)	Omuz implantları	4	Çok kanallı CNN modeli, 5 kat çapraz doğrulama	97,20
Urban et al., (2020)	Omuz implantları	4	Yedi farklı derin öğrenme modeli (VGG-16, VGG-19, ResNet-50, ResNet-152, DenseNet, NASNet, özel bir CNN), dört farklı makine öğrenimi sınıflayıcısı (Lojistik Regresyon, Rastgele Ormanlar, Gradient Boost, K-En Yakın Komşu)	DL algoritmaları: 74–80, ML algoritmaları: 51–56
Yi et al., (2020)	Omuz implantları	2	Transfer öğrenme ve ince ayarlı ResNet-18 modeli	97,00
Stark, (2018)	Omuz implantları	4	Hough Dönüşümü	77 hassasiyet
Karnuta et al., (2020)	Diz implantları	9	Önceden eğitilmiş InceptionV3 modeli	99,00
Yi et al., (2019)	Diz implantları	2	ResNet-18 DCNN modeli	100
Kim et al., (2020)	Diş implantları	4	Önceden eğitilmiş CNN modeli (SqueezeNet ve MobileNet-v2)	97,00
Sukegawa et al., 2020)	Diş implantları	11	İnce ayarlı (fine-tuned) VGG16 modeli	93,50
Lindsey et al., (2018)	Kırıklar	2	Derin sinir ağı	91,50

MATERYAL ve YÖNTEM

Derin öğrenme yaklaşımları kullanılarak X-ray görüntülerinde omuz artroplasti implantlarını sınıflandırmak için modeller oluşturmak üzere araştırmada kullanılan malzeme ve yöntemler bu bölümde açıklanmaktadır. Tez çalışma şeması aşamaları Şekil 3'te gösterilmektedir.




Şekil 3. Tez çalışma şeması aşamaları.


Veri Seti

Bu tezde kullanılacak veri seti dört kategoriden oluşan çok sınıflı bir sınıflandırma problemidir. Veri seti omuz implantının dört üreticisinden çeşitli boyutlarda JPEG formatında 597 görüntülerden oluşmaktadır ve halka açık olan UCI makine öğrenmesi deposu web sitesinden erişilebilmektedir (“Shoulder Implant Manufacture Classification,” 2020).

Veri setinde Cofield 83, Depuy 294, Tornier 71 ve Zimmer 149 görsele sahiptir. Her görüntünün ait olduğu kategoriyi gösteren bir adı vardır (“Shoulder Implant Manufacture Classification,” 2020). Bu veri seti, ilgili araştırma bölümünde bahsedilen tüm makaleler tarafından kullanılmıştır. Görüntüler çeşitlidir ve düşük görüntü çözünürlüğüne sahiptir. Şekil 4'te, veri kümesindeki dört tip omuz implantına ilişkin örnekler gösterilmektedir ve Şekil 5'te Omuz implantları röntgen görüntüleri veri kümesinin dağılımını gösterilmektedir.



Şekil 4. Veri kümesindeki dört tip omuz implantı örneği.



Şekil 5. Omuz implantları röntgen görüntüleri veri kümesinin dağılımı.

Veri Ön İşleme

Makine öğrenimi ve derin öğrenmede en kritik ve gerekli aşamalardan biri veri hazırlamadır. Bu teknik, bir veri kümesinde makine öğrenimi ve derin öğrenme algoritmaları kullanılırken güvenilir, doğru ve başarılı tahmin sonuçları için gereklidir.


Ön işleme yöntemlerinden biri de görüntüyü standart hale getirmektir. İlk başta, tüm resimleri aynı boyuta sığdırmak için fotoğrafları 256×256 olarak yeniden ölçeklendirilmiştir. Piksel değerleri 0-255 arasında tamsayılarla RGB görüntülerde sunulduğundan, modellerin eğitim hızını artırmak için piksel değerleri 0 ile 1 arasında değiştirilmiştir.

Veri Artırma


Derin öğrenme modellerinin başarısı genellikle önemli miktarda eğitim verisinin mevcudiyetine bağlıdır (Johnson, 2019). Bununla birlikte, X-ray görüntülerinde omuz artroplastisi implantlarının sınıflandırılması bağlamında, veri seti yalnızca 597 görüntüden oluşmaktadır ve bu, her bir sınıfı sınıflandırmak için yüksek doğrulukta bir model yetiştirmek için yetersizdir. Ayrıca, veri kümesi, her sınıfta değişen sayıda örnek ile dengesizdir. Bu zorluğun üstesinden gelmek ve dengeli temsili sağlamak için veri artırma teknikleri kullanılır (Smith, 2018). Görüntü büyütme, mevcut görüntülere döndürme, öteleme, çevirme ve yakınlaştırma gibi çeşitli dönüşümler uygulayarak yeni örnekler oluşturmayı içerir. Sonuç olarak bu tezde altı artırma tekniği kullanılmış, bu teknikler, mevcut görüntülere döndürme, öteleme, ölçekleme, çevirme, kırpma ve yakınlaştırma gibi dönüşümler uygulayarak yeni örnekler oluşturmayı amaçlamıştır. her sınıfın görüntü sayısı 600 örneğe ulaşana kadar artırılarak derin öğrenme modellerinin eğitimi için tüm sınıfların eşit sayıda görüntüye sahip olması sağlanmıştır.

Ek olarak, omuz implantlarının X-ray görüntüleri çok hassas olduğundan, uygun veri artırma tekniklerini ve ilgili parametrelerini dikkatli bir şekilde seçmek çok önemlidir. Bu çalışmada, çeşitli güçlendirme teknikleri ve parametrelerinin titiz bir şekilde test edilmesi ve değerlendirilmesi yoluyla, veri setini geliştirmek için uygun seçenekler belirlenmiştir. Doğru artırma tekniklerinin ve parametre değerlerinin seçimi, aşırı uydurmanın önlenmesinde ve modelin genelleme kabiliyetinin geliştirilmesinde önemli bir rol oynar (Doe, 2021).

Bu tez çalışması, farklı veri artırma tekniklerini deneyerek, bunların veri dağılımı üzerindeki etkilerini anlayarak ve en uygun veri artırma düzeyini belirleyerek, orijinal görüntünün orijinallliğini ve tıbbi önemini korurken veri setinin faydasını en üst düzeye çıkarmayı amaçlamaktadır. Veri kümesini büyütme, sınırlı sayıda görüntünün ve veri kümesinin dengesizliğinin ortaya çıkardığı zorluğu etkili bir şekilde ele alarak derin öğrenme modellerinin sağlam özellikleri öğrenmesini ve daha iyi sınıflandırma performansı elde etmesini sağlar. Şekil 6, veri artırma işleminden sonra X-ray görüntülerini göstermektedir. Şekil 7, veri artırma yapıldıktan sonra omuz implantları röntgen görüntüleri veri kümesinin dağılımını göstermektedir ve bu Şekilde gördüğümüz gibi, veri kümesindeki görüntü sayısı nispeten dengeli bir dağılım sergilemektedir. Tablo 2.de, her bir sınıf için orijinal veri sayıları ile veri artırma sonrası elde edilen veri sayıları görülmektedir.



Şekil 6. Veri artırmadan sonra X-ray görüntüleri.



Şekil 7. Veri artırmadan sonra omuz implantları röntgen görüntüleri veri kümesinin dağılımı.

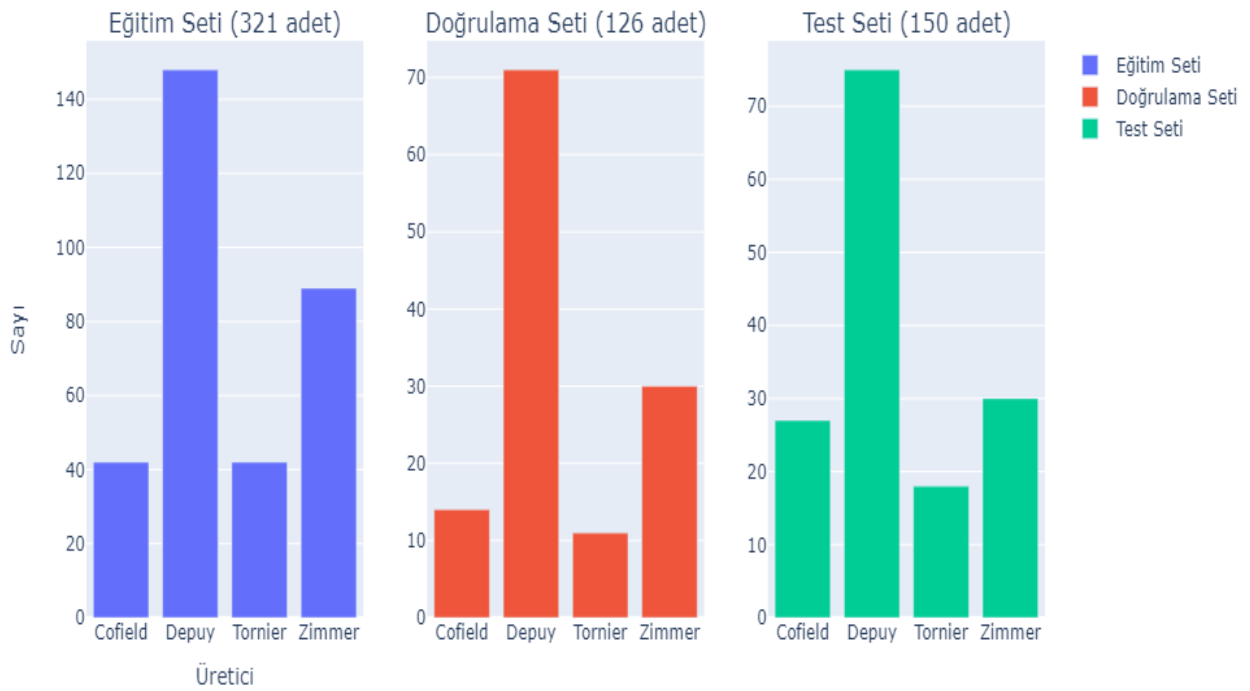
Tablo 2. Farklı Sınıflara Ait Orijinal ve Artırılmış Veri Sayıları.

Sınıf	Orijinal Veri	Artırılmış Veri
Cofield	83	683
Depuy	294	894
Tornier	71	671
Zimmer	149	749
Toplam	597	2997


Veri Bölme

Veri kümesini önceden işledikten sonra, omuz implantı X-raylarının tüm görüntülerini birleştirip karıştırıldı ve ardından omuz implantı sınıflandırması için modelleri iki farklı senaryoda eğitilmiş ve değerlendirilmiştir.

İlk senaryoda, oluşturulan modellerin performansını değerlendirmek için, eğitim seti için %53,8 (321 görüntü), doğrulama seti için %21,1 (126 görüntü) ve test seti için %25 (150 görüntü) kullanarak veri artırma olmadan yürütülmüştür. Ayrıca çapraz doğrulama yapmak için bu senaryoda, eğitim ve doğrulama kümeleri birleştirilmiş ve çapraz doğrulama için verilerin %75'i kullanılmıştır. Her sınıfın dağılımı da dahil olmak üzere eğitim, doğrulama ve test setine tahsis edilen veri seti Şekil 8'de gösterilmektedir.

**Şekil 8.** Veri artırma kullanmadan verilerin eğitim, doğrulama ve test kümelerine ayrılması.

İkinci senaryo için, veri setini genişletmek amacıyla veri büyütme tekniklerini dahil edilmiştir. Bu, test için aynı sayıda 150 görüntünün (%5) kullanılmasını içerirken, veri seti artırılırken eğitim seti için %75 (2277 görüntü) ve doğrulama seti için %20, 570 artırılmış görüntü kullanılmıştır. Ayrıca çapraz doğrulama yapmak için bu senaryoda, eğitim ve doğrulama kümeleri birleştirilmiştir. Her sınıfın dağılımı da dahil olmak üzere eğitim, doğrulama ve test setine tahsis edilen veri seti Şekil 9'da gösterilmektedir.



Şekil 9. Veri artırmayı kullanarak verilerin eğitim, doğrulama ve test kümelerine ayrılması.

Her iki senaryoyu da kullanarak, modellerin sınıflandırma performansının kapsamlı bir değerlendirmesini yapılabilir. İki senaryonun sonuçlarını karşılaştırmak, veri artırmanın modellerin doğruluğu ve görünmeyen verileri genelleştirme yeteneği üzerindeki etkisini anlamamızı sağlar.

Değerlendirme boyunca, her iki senaryo için de aynı sayıda test görüntüsü kullanarak tutarlılığı korumak çok önemlidir. Bu, omuz implantı üreticilerinin sınıflandırılmasında modellerin etkinliğinin belirlenmesinde değerlendirmenin adil, tarafsız ve güvenilir kalmasını sağlar.

Sınıflandırma İçin Kullanılan Derin Öğrenme Yöntemleri ve Algoritmalar

Derin öğrenme, son yıllarda görüntü sınıflandırma üzerinde önemli bir etkiye sahip olmuştur. Derin öğrenme modelleri, karmaşık sorunlarla başa çıkmada tipik makine öğrenimi modellerinden daha iyi performans göstererek olağanüstü doğruluk sergiledi. Evrişimli Sinir Ağları (CNN'ler), evrişimli filtreler kullanarak hem düşük hem de yüksek boyutlu bilgileri tanıyabilen karmaşık bir sinir ağı yapısı olarak gelişmiştir (Krizhevsky et al., 2012).

CNN'ler, görüntülerden görsel özellikleri otomatik olarak çıkarma yeteneğine sahiptir, bu da onları görüntü sınıflandırma uygulamalarında son derece yararlı kılar. Bu özellik, tıbbi görüntüleri kullanarak çok çeşitli hastalıkları tanımlamada önemli bir umut vaat ettikleri tıp da dahil olmak üzere çeşitli alanlarda yaygın kabul görmelerine yol açmıştır. Derin öğrenmenin otomatik özellik çıkarımı ve CNN'lerin uyarlanabilirliğinin birleşimi, zor görüntü sınıflandırma sorunlarının üstesinden gelmek için yeni yollar açmıştır ve bilgisayarla görme alanını önemli ölçüde geliştirmiştir (Simonyan & Zisserman, 2014).

Bu çalışmada, X-ray görüntülerinde omuz artroplastisi implant üreticisini sınıflandırmak için çeşitli derin öğrenme modelleri araştırılmıştır. Bu modeller, özel bir CNN modeli, MobileNetV2, DenseNet121, DenseNet201, InceptionV3 ve ResNet50 içerir.

Bu modeller, tıbbi görüntülerdeki karmaşık özellikleri yakalama yetenekleriyle bilinir ve çeşitli tıbbi görüntü analizi görevlerinde yaygın olarak kullanılır.


Özel CNN Modeli

Bu tez çalışmasında, Omuz implantı sınıflandırma için özel bir Evrişimli Sinir Ağı (CNN) modeli Geliştirilmiştir. Model mimarisi, evrişimli katmanlar, havuzlama katmanları (Pooling layers), toplu normelleştirme (Batch normalization), bırakma katmanları (Dropout layers) ve tamamen bağlı katmanlar (Fully connected layers) dahil olmak üzere birden çok katmandan oluşur. Spesifik olarak bu model, özelliklerin çıkarılmasından sorumlu olan beş evrişim bloğundan oluşur; CNN modeli, giriş X-ray görüntülerinden ilgili özellikleri çıkarmak ve farklı omuz implantı sınıflarıyla ilişkili karmaşık kalıpları öğrenmek için tasarlanmıştır.

Giriş bloğu olan ilk evrişim bloğunda Conv2D, sonraki evrişim bloklarında ise SeparableConv2D (Ayrılabilir evrişimler) kullanılır. Her evrişim bloğu, iki kat evrişim ve ardından bir 2×2 Max-Pooling filtresi içerir. Tüm bu evrişim bloklarında 3×3 filtre kullanılmış olup nöron sayısı sırasıyla 16, 32, 64, 128 ve 256'dır.

Özel CNN modeli, geleneksel Conv2D katmanlarına kıyasla daha az parametreye sahip bir tür evrişimli katman olan ikinci evrişim bloğundan SeparableConv2D katmanlarını kullanır. SeparableConv2D iki ardışık işlemten oluşur: derinlemesine evrişim (depthwise convolution) ve noktasal evrişim (pointwise convolution). Derinlemesine evrişim, her bir giriş kanalı için ayrı bir filtre uygularken, noktasal evrişim, derinlemesine evrişimin çıktılarını birleştirmek için 1x1'lik bir evrişim gerçekleştirir (Chollet, 2017).

SeparableConv2D katmanlarının kullanılmasının ana avantajı, parametre sayısını ve hesaplama karmaşıklığını azaltma yeteneğidir. Bu, daha küçük veri kümeleri gibi durumlarda daha verimli bir model elde etmeyi sağlar. CNN tabanlı modelin eğitilebilir parametresi 8,762,340'tır. Şekil 10'da geliştirilen, CNN tabanlı modeli göstermektedir.



Şekil 10. Özel CNN tabanlı model.

Özel CNN modeli birkaç temel bileşen içerir:

A. Evrişimli Katmanlar: Her evrişimli blok, her birini bir ReLU aktivasyon fonksiyonu tarafından takip edilen iki Evrişimli Katman içerir. Bu blok, giriş görüntülerinden ilgili özelliklerin çıkarılmasına yardımcı olur.

B. MaxPooling Katmanları: Her evrişim bloğundan sonra, özellik haritalarını alt örneklemek, uzamsal boyutları azaltmak ve en önemli bilgileri korumak için havuz boyutu (2x2) olan bir MaxPooling2D katmanı eklenir.

C. Toplu Normalleştirme (Batch Normalization): Aktivasyonları normalleştirmek ve eğitim sürecini iyileştirmek için ikinci Conv2D katmanından sonra toplu normalleştirme uygulanır.

D. Bırakma Katmanları (Dropout Layers): Eğitim sırasında nöronların bir kısmını rastgele bırakarak fazla uydurmayı önlemek için her MaxPooling katmanından sonra bırakma katmanları eklenir.

E. Düzleştirin (Flatten) ve Tamamen Bağlı Katmanlar (Fully connected Layers): Özellik haritaları düzleştirilir ve tamamen bağlı Dense katmanlara (Dense Layer) bağlanır. İlk Dense katman, 'relu' aktivasyon fonksiyonuna sahip 512 birime sahiptir ve ardından fazla uydurmayı daha da azaltmak için bir bırakma katmanı gelir. İkinci Dense katman, 'relu' aktivasyon fonksiyonuna ve dropout katmanına sahip 256 birime sahiptir, üçüncü Dense katman, 'relu' aktivasyon fonksiyonuna ve bırakma katmanına sahip 128 birime sahiptir ve tamamen bağlı katmanın son Dense katmanı, ile 64 birim, 'relu' fonksiyonuna ve bırakma katmana sahiptir.

F. Çıktı Katmanı: Nihai Dense katman, sınıflar üzerindeki olasılık dağılımını hesaplamak için bir 'softmax' aktivasyon fonksiyonu ile birlikte, omuz artroplastisi implantlarının dört sınıfını temsil eden 4 birimden oluşur.


Transfer Öğreniminde Kullanılan Önceden Eğitilmiş Modeller

Bu çalışmada, transfer öğrenme için beş önceden eğitilmiş model kullanılmıştır. MobileNetV2, DenseNet121, DenseNet201, InceptionV3 ve ResNet50. Transfer öğrenme, bu modellerin ilk olarak ImageNet veri kümesinde eğitilerek öğrenilen bilgileri kullanma ve bu modelleri omuz artroplastisi implantlarını X-ray görüntülerinde üreticilere göre sınıflandırılmasını özel görevimize uyarlamayı içerir. Transfer öğrenme süreci, bu modellerin büyük ve çeşitli bir veri kümesinde öğrendiği zengin özellikleri sınırlı veri miktarıyla kullanmamıza yardımcı olur.

MobileNetV2:

MobileNetV2, Sandler et al. (2018) tarafından tanıtılan hafif ve verimli bir derin öğrenme modelidir. Mobil ve gömülü görüntüleme uygulamaları için tasarlanmıştır ve sınırlı hesaplama kaynaklarına sahip cihazlar için idealdir. MobileNetV2, parametre ve işlem sayısını azaltmak için derinlikli ayrıştırma (depthwise separable) konvolüsyonlarını kullanırken iyi bir

doğruluk seviyesini korur. MobileNetV2 ağı mimarisi, bottleneck residual blokları olarak adlandırılan 19 orijinal temel bloktan oluşur. Mimaride birden çok derinlikli ayrıştırma konvolüsyon katmanı bulunur ve bu katmanlar, toplu normalleştirme ve ReLU aktivasyon fonksiyonları ile takip edilir. Sınıflandırma için global ortalama havuzlama ve tam bağlı katman kullanılır. Şekil 11, MobileNetV2'nin yapısını göstermektedir.



Şekil 11. MobileNetV2'nin mimarisi (Seidaliyeva et al., 2020).

MobileNetV2 Nasıl Çalışır:

1. Derinlik Tabanlı Ayrıştırma (Depthwise Separable Convolutions): MobileNetV2, derinlik tabanlı ayrıştırmayı kullanır. Bu, iki ayrı evrişim işleminden oluşur: derinlik tabanlı evrişim ve nokta tabanlı evrişim (pointwise convolution). Derinlik tabanlı evrişimde, girişin her kanalı, ilgili çekirdek ile bağımsız olarak evrişimlenir, bu da hesaplama maliyetini azaltır. Nokta tabanlı evrişim daha sonra derinlik tabanlı evrişimin çıktı kanallarını son çıktıya birleştiren 1x1 evrişim uygular. Bu teknik, parametre ve işlem sayısını önemli ölçüde azaltır ve daha verimli bir model elde edilmesini sağlar.
2. Tersine Çevrilmiş Kalıntılar (Inverted Residuals) ve Doğrusal Darboğazlar (Linear Bottlenecks): MobileNetV2, verimliliğini korurken modelin ifade yeteneğini artırmak için "tersine çevrilmiş kalıntılar" kavramını tanıtır. Tersine çevrilmiş kalıntılar, daha az filtre (genişletme faktörü olarak adlandırılır) içeren darboğaz katmanından sonra çıktı boyutunu istenen hale getiren nokta tabanlı evrişimi içerir. Bu doğrusal darboğaz yaklaşımı, modelin daha karmaşık özellikleri yakalamasına olanak tanıırken hesaplama yükünü düşük tutar.

3. Tersine Çevrilmiş Kalıntılar ile Kısa Yollar (Shortcut Connections): MobileNetV2'de, her tersine çevrilmiş kalıntı bloğu, eğitim sırasında kaybolan gradyan sorununu azaltmak için bir kısa yol bağlantısı (atlamalı bağlantı) içerir. Bu kısa yol bağlantıları, modelin girişe uygulanan artık fonksiyonları öğrenmesine olanak sağlar, eğitim sürecini kolaylaştırır ve modelin daha etkili bir şekilde öğrenmesini sağlar.
4. Birden Fazla Genişlik Katlayıcı (Width Multiplier): MobileNetV2, modelin genişliğini ayarlamak için birden fazla genişlik katlayıcı kullanma esnekliği sağlar. Genişlik katlayıcı, her katmandaki filtre sayısını ölçeklendirerek model boyutu ve doğruluğu arasında denge kurmayı sağlar. Daha küçük bir genişlik katlayıcı, parametre ve hesaplamayı azaltır, böylece daha kompakt ve hızlı bir model elde edilirken, daha büyük bir katlayıcı, modelin kapasitesini ve doğruluğunu artırır.

DenseNet121:


DenseNet121, Huang et al. (2017) tarafından önerilen güçlü bir derin öğrenme mimarisidir. Her katmanın, tüm önceki katmanlardan özellik haritaları almasıyla dense bağlantıya sahiptir. Bu dense bağlantı, özellikleri tekrar kullanmayı teşvik eder ve eğitim sırasında daha iyi gradyan yayılımını sağlar. Ayrıca, bu mimaride her katman, tüm sonraki katmanlarla bağlantılıdır, bu da parametre sayısında önemli bir azalmaya neden olur. DenseNet121, bellek ve hesaplama kaynaklarının verimli kullanımı ile tanınır. DenseNet121, çeşitli bilgisayarlı görü görevlerinde mükemmel performans sergilemiştir (Huang et al., 2017).

DenseNet121 Nasıl Çalışır:

1. Dense Bağlantılar: DenseNet121, diğer CNN mimarilerinden farklı olarak dense bağlantılara sahiptir. Her katman, kendisinden önceki tüm katmanların çıktılarını alır. Bu, her katmanın girişi, önceki tüm katmanların çıktılarına katılır, bu nedenle katmanlar arasında daha fazla bağlantı vardır. Bu dense bağlantılar, ağına daha fazla parametreye ve özelliklere sahip olmasını sağlar, bu da daha iyi öğrenme ve daha etkili bir şekilde özelliklerin kullanılması anlamına gelir.
2. Evrişimli Katmanlar: DenseNet121, giriş görüntüsünden temel özellikleri çıkarmak için bir dizi evrişimli katman içerir. Bu evrişimli katmanlar, görüntülerdeki çeşitli özellikleri algılamak için filtreleri kullanır ve bu özellikleri temsil eden özellik haritalarını oluşturur.

3. Dense Bloklar: DenseNet121, dense bloklar adı verilen birimler içerir. Dense bloklar, birden fazla evrişimli katmanın ardışık olarak bir araya gelmesiyle oluşur. Her dense blok, dense bağlantılar sayesinde önceki bloklardan aldığı özellik haritalarını kullanır. Bu, ağı her katmanının daha önce öğrendiği özellikleri kullanmasını ve daha kapsamlı bir bilgi birikimi sağlamasını sağlar.
4. Geçiş Katmanları: Dense bloklar arasında geçiş katmanları bulunur. Geçiş katmanları, özellik haritalarının boyutunu küçültmek ve hesaplama yükünü azaltmak için kullanılır. Bu katmanlar, 1x1 boyutunda evrişimli katmanlar ve ortalama havuzlama (average pooling) kullanarak boyut azaltma işlemini gerçekleştirir.
5. Tam Bağlı Katmanlar (Fully Connected Layers): Son dense bloğun ardından tam bağlı katmanlar eklenir. Bu katmanlar, ağı öğrendiği özellikleri sınıflara dönüştürmek için kullanılır ve sınıflandırma yapar.
6. Softmax Aktivasyonu: Çıkış katmanı genellikle softmax aktivasyon fonksiyonunu kullanarak sınıf olasılıkları üretir. Bu, önceki katmandan elde edilen ham skorları sınıf olasılıklarına dönüştürür ve giriş görüntüsünün her sınıfa ait olma olasılığını gösterir.

Dense bağlantılar ve dense bloklar, DenseNet121'in derin ağlarda aşırı uyum sorununu azaltmasına ve daha az parametreyle daha iyi performans elde etmesine yardımcı olan anahtar özelliklerdir. DenseNet121, özellikle sınırlı veriyle çalışırken iyi sonuçlar veren ve geniş bir yelpazede bilgisayar görüşü görevlerinde kullanılan güçlü bir derin öğrenme modelidir. Şekil 12, DenseNet modelinin yapısını göstermektedir.



Şekil 12. DenseNet modelinin yapısı.

DenseNet201:

DenseNet201, Gao Huang ve arkadaşları tarafından 2017 yılında tanıtılan derin öğrenme modelidir. DenseNet121 ile aynı dense bağlantı desenini korur, ancak daha fazla konvolüsyonel katman içerir. DenseNet mimarisinin bir uzantısı olan DenseNet201, çeşitli bilgisayarlı görme görevlerinde yüksek performansıyla bilinir. DenseNet201, dense bağlantı (dense connectivity) kullanır, bu sayede her katman önceki tüm katmanların özellik haritalarını alır. Dense bağlantı, özellikleri tekrar kullanımını (feature reuse) teşvik eder ve eğitim sırasında gradyan akışını (gradient flow) arttırarak modelin daha verimli ve etkili olmasını sağlar (Huang et al.,2017).

DenseNet201 Nasıl Çalışır:

1. **Dense Bloklar (Dense Blocks):** DenseNet201'in temel yapı birimi dense bloktur. Her dense blok, dense bağlantı içeren birden fazla katmandan oluşur. Dense blokta, her katman tüm önceki katmanların özellik haritalarını girdi olarak alır. Bu dense bağlantı, girdi görüntülerinden zengin ve çeşitli özellik temsillerinin elde edilmesine yardımcı olur.
2. **Darboğaz (Bottleneck) Katmanlar:** DenseNet201, hesaplama karmaşıklığını azaltmak için her dense bloğa Bottleneck katmanları ekler. Bottleneck katmanları, 1x1 evrişim filtrelerinden oluşur ve 3x3 evrişim filtrelerini uygulamadan önce kanal sayısını azaltır. Kanal sayısının azaltılması, parametre sayısını ve hesaplama maliyetini düşürmeye yardımcı olur, bu da modeli daha verimli hale getirir.
3. **Geçiş (Transition) Katmanları:** Her dense bloğun ardından DenseNet201, özellik haritalarını örnekleme yaparak küçültmek için geçiş katmanları ekler. Geçiş katmanları, 1x1 evrişim filtreleri ve ortalama havuzlamayı birleştirir. Bu katmanlar, özellik haritalarının mekansal boyutunu küçültür, bu da hesaplama yükünü azaltır ve modelin daha yüksek düzeyde özellikleri yakalamasına olanak tanır.
4. **Evrensel Ortalama Havuzlama (Global Average Pooling):** Ağın sonunda, DenseNet201 evrensel ortalama havuzlamayı kullanarak tüm görüntüyü temsil eden sabit uzunluklu bir vektör elde eder. Evrensel ortalama havuzlama, her özellik haritasının ortalama değerini hesaplayarak tüm görüntü için bir global özellik temsili elde eder.

5. Tam Bağlantılı Katman (Fully Connected Layer): Son olarak, DenseNet201 sınıflandırma için softmax aktivasyon işlevi ile tam bağlantılı bir katman içerir. Tam bağlantılı katman, çıkarılan özellikleri çıkış sınıflarına eşler ve sınıf olasılıklarını hesaplar.

DenseNet201'in dense bağlantısı ve Bottleneck katmanları, girdi görüntülerinden karmaşık desenleri ve özellikleri verimli bir şekilde öğrenmesini sağlar. Dense bağlantı, farklı katmanlardan gelen özellik haritalarının birleştirilmesini sağlayarak özellik tekrar kullanımını teşvik eder ve gradyanların kaybolma riskini azaltır. Bottleneck katmanları, modeli büyük veri kümesi tanıma görevlerinde kullanılması için popüler kılan parametre sayısını yönetme yeteneği sayesinde etkileyici performans gösterir.

Dolayısıyla, DenseNet201'in mimarisi, çeşitli bilgisayarlı görme uygulamaları, görüntü sınıflandırma, nesne algılama ve anlamsal bölütleme gibi karmaşık ve zorlu görsel tanıma görevlerinde güçlü bir derin öğrenme modeli olmasını sağlar.

InceptionV3:


InceptionV3, 2015 yılında Christian Szegedy ve ekibi tarafından geliştirilen derin öğrenme modelidir. Giriş görüntülerinden karmaşık desenleri ve özellikleri yakalamak için tasarlanmıştır. InceptionV3, karmaşık yapısıyla bilinir ve çoklu filtreleri kullanarak paralel olarak farklı ölçeklerdeki ve karmaşıklıkta desenleri yakalamak için inception modüllerini kullanır (Szegedy et al., 2015).

InceptionV3'ün Çalışma Prensipleri:


1. Inception Modülleri: InceptionV3, inception modülleri üzerine kuruludur ve bu modeller modelin temel yapı taşlarıdır. Her inception modülü, 1x1, 3x3 ve 5x5 filtreleri de içeren çoklu konvolüsyon filtreleri içerir. Bu filtreler aynı girişe paralel olarak uygulanır ve farklı ölçeklerdeki desenleri yakalarlar. Paralel filtrelerin çıktıları birleştirilir ve bir sonraki katmana iletilir, bu sayede modelin zengin ve çeşitli özellik temsilleri öğrenmesine olanak tanır, Şekil 13, InceptionV3'ün blokları göstermektedir.
2. Boyut Azaltma: Birden çok paralel filtreye sahip olmanın hesaplama maliyetini yönetmek için InceptionV3, boyut azaltma için 1x1 konvolüsyonları içerir. Bu 1x1 konvolüsyonlar, özellik haritalarındaki kanal sayısını azaltmaya yardımcı olur ve modeli hesaplama açısından daha verimli hale getirir.

3. Maksimum Havuzlama ve Ortalama Havuzlama: InceptionV3, örnekleme için hem maksimum havuzlama hem de ortalama havuzlama katmanları kullanır. Maksimum havuzlama, girişin bir bölgesinden maksimum değeri seçerken, ortalama havuzlama ortalama değeri hesaplar. Bu havuzlama işlemleri, özellik haritalarının mekansal boyutunu azaltmaya yardımcı olur, daha yüksek seviyeli özellikleri yakalar ve aşırı uyumlanmayı azaltır.
4. Yardımcı Sınıflandırıcılar: InceptionV3, belirli ara katmanlarda yardımcı sınıflandırıcılar içerir. Bu yardımcı sınıflandırıcılar, ara özellik haritalarında bilgi dolu öğrenmeyi teşvik etmek için kullanılır. Bu, kaybolan gradyan sorununu hafifletmeye yardımcı olur ve eğitim sırasında ekstra denetim sağlayarak daha iyi genelleme sağlar.
5. Tam Bağlantılı Katman: Modelin sonuna doğru, InceptionV3 genellikle sınıflandırma için tam bağlantılı katmanlar içerir. Son tam bağlantılı katman, öğrenilen özellikleri çıktı sınıflarına eşler ve sınıf olasılıklarını hesaplamak için softmax aktivasyonunu kullanır.

InceptionV3'ün mimarisi, karmaşık hiyerarşik özellik temsilleri öğrenmesine izin verir ve bu nedenle görüntü sınıflandırma ve nesne tespiti gibi çeşitli bilgisayar görüşü görevleri için uygun bir seçimdir. Inception modüllerinin ve boyut azaltmanın, hesaplama verimliliğini ifade gücüyle dengeler ve derin öğrenme uygulamalarında yaygın olarak tercih edilmesine neden olur. Şekil 14, InceptionV3'ün yapısını göstermektedir.



Şekil 13. Inception-V3 blokları (Szegedy, et al., 2015).



Şekil 14. InceptionV3 modelinin yapısı (Dong et al., 2020).

ResNet50:

ResNet50, 50 katmanlı Kalıntılı Ağ (Residual Network) olarak da bilinen, derin evrişimli sinir ağı mimarisidir ve Kaiming He ve arkadaşları tarafından 2015 yılında önerilmiştir. ResNet ailesinin bir türevidir ve bilgisayar görüşü alanında devrim yaratarak 2016 ImageNet yarışmasını kazanmıştır.


ResNet50'nin temel fikri, kalıntı bloklarının (skip bağlantıları veya kısayol bağlantıları olarak da bilinir) tanıtılmasıdır. Bu bloklar, ağı doğrudan istenen altta yatan eşlemeyi (mapping) öğrenmek yerine kalıntı (fark) öğrenmesine izin verir. Başka bir deyişle, ResNet50, giriş ve çıkış arasındaki kalıntıyı öğrenir ve ağı eğitim sürecini optimize etmeyi kolaylaştırır.

ResNet50 Nasıl çalışır:

1. Evrişimli Katman (Convolutional Layer): Giriş görüntüsü, ilk evrişimli katmandan geçirilir. Bu katmanda, 7x7 boyutunda ve 64 filtreli evrişimler ve adım büyüklüğü (stride) 2 kullanılır. Bu katman, giriş görüntüsünden temel özellikleri çıkarmaya yardımcı olur.
2. Batch Normalizasyon ve ReLU Aktivasyonu: Her evrişimli katmandan sonra, batch normalizasyon uygulanır ve ardından ReLU aktivasyon fonksiyonu kullanılır. Batch normalizasyon, önceki katmanın çıktılarını normalleştirerek eğitimi stabil hale getirir ve hızlandırır. ReLU, ağı karmaşık desenleri ve ilişkileri öğrenmesini sağlayan doğrusal olmayanlık ekler.

3. En Büyük Havuzlama (Max Pooling): 3x3 boyutunda filtre ve adım büyüklüğü 2 ile en büyük havuzlama uygulanarak özellik haritasının mekansal boyutları küçültülür. Bu, hesaplama ve aşırı uyum riskini azaltmaya yardımcı olur.
4. Kalıntı Blokları: ResNet50, dört set kalıntı bloğu içerir ve her biri birden çok evrişimli katman içerir. Kalıntı blokları, kısayol bağlantıları kullanarak bir önceki katmanın çıktısını doğrudan geçerli katmanın çıktısına ekler. Bu, ağın kalıntı eşlemeyi öğrenmesine olanak tanır ve derin ağ mimarilerinin vanishing veya exploding gradients sorunları olmadan etkili bir şekilde eğitilmesine yardımcı olur. Kalıntı blokları, ResNet50'nin 50 veya daha fazla katmana sahip ağları etkin bir şekilde eğitmesini sağlar.
5. Genel Ortalama Havuzlama (Global Average Pooling): Evrişimli katmanların sonunda, genel ortalama havuzlama uygulanarak özellik haritaları 2D matrise dönüştürülür. Genel ortalama havuzlama, her özellik haritasındaki tüm değerlerin ortalamasını alarak mekansal boyutları her bir özellik haritası için bir değere indirir. Bu, parametre sayısını azaltmaya ve aşırı uyumdan kaçınmaya yardımcı olur.
6. Tam Bağlı Katmanlar (Fully Connected Layers): Son olarak, bir veya daha fazla tam bağlı (dense) katmanlar sınıflandırma için eklenir. Bu katmanlar, evrişimli katmanlar tarafından öğrenilen özellikleri alır ve belirli bir görev için tahminler yapar, örneğin görüntü sınıflandırması.
7. Softmax Aktivasyonu: Çıkış katmanı genellikle softmax aktivasyon fonksiyonunu kullanarak sınıf olasılıkları üretir. Bu, önceki katmandan elde edilen ham skorları sınıf olasılıklarına dönüştürür ve giriş görüntüsünün her sınıfa ait olma olasılığını gösterir.

Kalıntı blokları, batch normalizasyon ve kısayol bağlantıları gibi özellikler, ResNet50'yi derin ağların etkili bir şekilde eğitilmesini sağlayan ve bilgisayar görüşü alanında büyük başarılar elde eden bir mimari yapar. ResNet50, görüntü sınıflandırması, nesne tespiti ve görüntü bölütleme gibi çeşitli bilgisayar görüşü görevlerinde çok başarılı olmuştur ve araştırmada ve pratik uygulamalarda yaygın olarak kullanılmaya devam etmektedir. Şekil 15, ResNet50'nin yapısını göstermektedir.



Şekil 15. ResNet50 modelinin yapısı.

Transfer Öğrenme Yaklaşımı:

Transfer öğrenme yaklaşımında, her bir önceden eğitilmiş model (MobileNetV2, DenseNet121, DenseNet201, InceptionV3 ve ResNet50), omuz artroplastisi implant üreticisi sınıflandırma görevi için temel model olarak hizmet etmiştir. Transfer öğrenme için aşağıdaki adımları uygulamıştır:

Temel Model Çıkarımı (Base Model Extraction): Önceden eğitilmiş temel modeli, sınıflandırma başlığı olmadan (`include_top=False`) yüklenmiştir. Bu adım, büyük ölçekli ImageNet veri kümesindeki eğitimden öğrenilen bilgileri özellik çıkarımı için kullanmamızı sağlamıştır. Temel modeller, milyonlarca çeşitli görüntüde önceden eğitildiği için zengin ve hiyerarşik özellik temsilleri öğrenmişlerdir.

Özel Sınıflandırma Başlığı (Custom Classification Head): Temel modelin üzerine, omuz implantı tanıma özel sınıflandırma başlığı eklemiştir. Özel sınıflandırma başlığı, özellik haritalarının mekansal boyutunu azaltmak için global ortalama havuzlama ve ardından ReLU aktivasyonu ve dropout düzenlemesi ile üç dense katman içerir. Dense katmanlardaki nöron sayısı ve dropout oranı, deney aşamasında ayarlanan hiper parametrelerdir.

Dondurma Katmanları (Freezing Layers): Değerli önceden eğitilmiş bilgiyi korumak ve sınırlı veri kümesinde aşırı uyum riskini önlemek için her temel modelde belli bir sayıda katmanı dondurmıştır. Dondurulan katmanlar, ince ayar süreci boyunca eğitilemez ve önceden eğitilmiş modelin özellik çıkarma yeteneklerini korur.

Tablo 3. Transfer Öğrenme ile Önceden Eğitilmiş Modellerin Özellikleri.

Önceden Eğitilmiş Model	Temel Model Katmanları	Eklenen Ek Katmanlar	Dondurulan Katman Sayısı
MobileNetV2	154	GlobalAveragePooling2D, Dense (512, activation='relu'), Dropout (0.3), Dense (256, activation='relu'), Dropout (0.2), Dense (4, activation='softmax')	100
DenseNet121	427	GlobalAveragePooling2D, Dense (256, activation='relu', kernel_regularizer=regularizers.l2(0.001)), Dropout(0.2), Dense(4, activation='softmax')	180
DenseNet201	604	GlobalAveragePooling2D, Dense (256, activation='relu', kernel_regularizer=regularizers.l2(0.001)), Dropout (0.3), Dense (128, activation='relu'), Dropout (0.2), Dense (4, activation='softmax')	200
InceptionV3	311	GlobalAveragePooling2D, Dense (512, activation='relu', kernel_regularizer=regularizers.l2(0.001)), Dropout (0.3), Dense (256, activation='relu'), Dropout (0.2), Dense (4, activation='softmax')	100
ResNet50	175	GlobalAveragePooling2D, Dense (512, activation='relu', kernel_regularizer=regularizers.l2(0.001)), Dropout(0.2), Dense (256, activation='relu'), Dropout (0.1), Dense (4, activation='softmax')	80

Tablo 3'te, Transfer Öğrenmenin kullanıldığı modellerin özellikleri verilmiştir. Tablo 3, her modelin temel mimarisi, eklenen özel katmanlar ve dondurulan katman sayısını içermektedir. Bu özellikler, omuz artroplasti implantı üreticisinin X-ray görüntülerini sınıflandırmak için kullanılan modellerin yapısal farklarını ve transfer öğrenmenin adaptasyon sürecini göstermektedir.


Transfer öğrenme sayesinde, önceden eğitilmiş modellerin güçlü özellik çıkarma yeteneklerini kullanarak omuz implantı sınıflandırma için bu modelleri ince ayarlanmıştır. Bu yaklaşım, nispeten küçük bir veri kümesiyle daha iyi genelleştirme ve yüksek doğruluk elde etmemize yardımcı olmuştur.

Çapraz doğrulama (Cross-validation)

Çapraz doğrulama, makine öğreniminde modelin verinin birden çok alt kümesi üzerinde performansını değerlendirmek için kullanılan yaygın bir tekniktir (Lyashenko, 2023). Bu çalışmada, omuz protezi implantlarını X-ray görüntülerinde sınıflandırmak için önceden eğitilmiş modellerin Transfer Öğrenimi ve özel CNN modelinin etkinliğini değerlendirmek için 5 katlı çapraz doğrulama kullanılmıştır.

Çapraz doğrulamanın temel amacı, modelin farklı veri alt kümeleri üzerinde test edilerek performansının daha güvenilir bir tahminini elde etmektir. Bu, değerlendirmedeki önyargı ve değişkenliği azaltmaya yardımcı olur ve modelin genelleme yeteneğine daha güvenilir bir tahmin sağlar.

5 katlı çapraz doğrulama işlemi, eğitim veri kümesini beş eşit büyüklükte alt kümeye bölmeyi içerir. Her katta, modelin eğitimi için dört alt küme kullanılırken, geriye kalan alt küme doğrulama için kullanılır. Bu işlem beş kez tekrarlanır ve her katta bir kez doğrulama kümesi olarak hizmet eder. Böylece, model farklı veri örnekleri üzerinde eğitilir ve değerlendirilir, bu da farklı veri dağılımlarındaki performansı hakkında bilgi edinmemizi sağlar. Şekil 16'da K-Katlamalı Çapraz Doğrulama'nın görsel anlatımı göstermektedir.



Şekil 16. K-Katlamalı Çapraz Doğrulama'nın görsel anlatımı.

Kullanılan Programlama Dili ve İlgili Kütüphaneler

Bu tez çalışmasında kullanılan programlama dili Python'dur. Python, makine öğrenimi ve derin öğrenme gibi alanlarda yaygın olarak kullanılan yüksek seviyeli bir programlama dilidir.

Bu tez çalışmasında aşağıdaki Python kütüphaneleri kullanılmıştır:

TensorFlow: TensorFlow, derin öğrenme modelleri geliştirmek ve eğitmek için yaygın olarak bilinen açık kaynaklı bir makine öğrenimi aracı setidir (Abadi et al., 2015).

Keras: Keras, TensorFlow üzerine inşa edilmiş yüksek seviyeli bir derin öğrenme API'sidir. Model oluşturmaya, eğitmeyi ve değerlendirmeyi daha kolay hale getiren kullanıcı dostu bir arayüze sahiptir (Chollet, 2017).

NumPy: NumPy, sayısal hesaplamalar için Python modülüdür. Yüksek performanslı dizi ve matris hesaplamaları sağlar (Harris et al., 2020).

Pandas: Pandas, Python veri işleme ve analiz aracıdır. Veri temizleme, filtreleme, birleştirme ve analiz gibi işlemleri kolaylaştırır (McKinney, 2010).

Matplotlib ve Seaborn: Matplotlib ve Seaborn, veriyi görselleştirmek için kullanılan Python kütüphaneleridir. Veriyi anlamak için çeşitli grafik ve tablolar oluşturmaya olanak tanır (Hunter, 2007) (Waskom, 2021).

Scikit-learn: Makine öğrenimi yöntemleri ve araçları içeren bir Python kütüphanesidir. Model eğitimi, doğrulama ve hiperparametre ayarlama gibi önemli makine öğrenimi işlemlerini hızlandırır (Pedregosa et al., 2011).

Imgaug: Veri artırma için güçlü bir Python kütüphanesidir ve veri kümesinin çeşitliliğini artırmak için geniş bir görüntü dönüşüm yelpazesi sunar ("Imgaug 0.4.0 Documentation).

Bu kütüphaneler, derin öğrenme modelleri oluşturmak, verileri işlemek, veri artırma tekniklerini uygulamak ve sonuçları analiz etmek için kullanılmıştır.

ARAŞTIRMA BULGULARI ve TARTIŞMA

Araştırma Bulguları ve Tartışma bölümü, bu tez çalışmasında gerçekleştirilen deneylerden elde edilen sonuçları sunmaktadır ve bu bulguların derinlemesine analizini ve yorumunu sağlar. Bu bölümde, omuz artroplastisi implantı üreticisi sınıflandırması için kullanılan farklı derin öğrenme modellerinin performansı, veri artırmanın etkisi ve transfer öğrenmenin etkinliği tartışılacaktır.

Bu çalışmada deneysel çalışmalar, aşağıdaki özelliklere sahip bir iş istasyonunda gerçekleştirildi: Intel(R) Xeon(R) Gold 5218 CPU @ 2.30GHz, NVIDIA® Quadro RTX™ 4000 8GB Ekran Kartı ve 128 GB RAM bellek.

Bu çalışmada, derin öğrenme modellerimizi eğitmek için veri artırma ve veri artırma olmadan iki farklı deney seti gerçekleştirilmiştir. Veri artırma, mevcut görüntülere çeşitli dönüşümler uygulayarak eğitim veri kümesinin çeşitliliğini yapay olarak artıran bir tekniktir. Veri artırmanın amacı, modellerin veri içindeki daha geniş bir varyasyon ve deseni görmesiyle genelleme ve sağlamlığını artırmaktır.

İlk deney seti için, modelleri veri artırma yapılmamış orijinal veri kümesiyle eğitilmiştir. Orijinal veri kümesi, omuz artroplastisi implantlarının X-ray görüntülerinden oluşuyordu ve modeller implantların üreticisini sınıflandırmak için eğitilmiştir. Eğitim sırasında, modeller orijinal görüntülerden doğrudan özellikler ve desenler çıkarmayı öğrendi ve herhangi bir ek veri değişikliği yapılmamıştır.

İkinci deney seti için, veri kümesine veri artırma uygulanmıştır. Veri artırma için imgaug kütüphanesinden yararlanılmıştır; bu kütüphane, görüntülerin örneğin kaydırma, döndürme, yansıtma, ölçeklendirme, eğme ve kırpma gibi çeşitli dönüşümlerle zenginleştirilmesini sağlar. Bu dönüşümleri uygulayarak, eğitim veri kümesinin boyutunu yapay olarak artırılmıştır ve görüntülerde çeşitlilik sağlanmıştır.

Veri artırma ile ve olmadan yapılan deneylerin amacı, modellerin farklı eğitim koşullarında performansını karşılaştırmaktır. Veri artırmanın, modellerin görmemiş verilere genelleme yeteneğini ve sınıflandırma doğruluğunu artırıp artırmayacağı değerlendirilmiştir. Ayrıca, veri artırma ile eğitilen modellerin, X-ray görüntülerindeki açı, aydınlatma koşulları ve yönlendirmeler gibi farklılıkları daha iyi yönetebileceğini belirlemeyi amaçlanmıştır.

Veri ayırma bölümünde belirtildiği gibi, bu çalışmada derin öğrenme modellerini her iki senaryoda da değerlendirmek için aynı sayıda test kümesi kullanıldı. Test kümesi, 150 adet omuz implantı görüntüsünden oluşmaktadır.

Veri Arttırma Olmadan Modellerin Değerlendirilmesi

Bu durumda, veri artırma olmadan derin öğrenme modellerini eğitilmiştir ve değerlendirilmiştir. Test süreci için ayrılmış olan 150 omuz implantı görüntüsü, eğitim ve doğrulama sırasında kullanılmamıştır ve yalnızca modellerin performansını değerlendirmek için kullanılmıştır. Modeller, bu orijinal test veri kümesi üzerinde sınıflandırma gerçekleştirdi ve her bir görüntüyü uygun üretici sınıfına etiketledi. Bu şekilde modellerin gerçek dünya verileri üzerindeki performansı değerlendirilmiş oldu.

Özel CNN modelinin Değerlendirilmesi

Özel CNN modeli, veri artırma kullanılmadan 10 katlı çapraz doğrulama yaklaşımıyla eğitilmiştir. Veri kümesi, omuz implantlarının 477 görüntüsünden oluşuyordu ve çapraz doğrulama için 10 alt kümeye bölünmüştür. Her katmanda, model 9 alt kümede eğitildi ve kalan alt kümede doğrulama işlemi yapılmıştır.

Eğitim sırasında, model Adam optimize edici, seyrek kategorik çapraz-entropi (sparse categorical cross-entropy) kayıp fonksiyonu ve doğruluk metriğiyle derlenmiştir. Model, her katmanda 50 epoch boyunca 16'lık bir grup boyutunda eğitilmiştir.

Aşırı uyumu (overfitting) önlemek ve eğitim verimliliğini artırmak için iki geri çağrı (callback) uygulanmıştır. İlk geri çağrı, doğrulama doğruluğuna dayanarak öğrenme hızını (learning rate) dinamik olarak ayarlayan bir öğrenme hızı azaltma geri çağrısıydı. İkinci geri çağrı, 12 epoch sonra doğrulama kaybında bir iyileşme olmazsa eğitimi durduran bir erken durdurma geri çağrısıydı.


Her katmandaki eğitimden sonra, model doğrulama verilerindeki doğruluğu ve kaybı elde etmek için değerlendirilmiştir. Her katmandaki doğruluk ve kayıp değerleri kaydedilmiştir ve tüm katmanlar arasında ortalama doğruluk ve kayıp hesaplanmıştır.

Tablo 4.te Veri Arttırma Kullanılmadan Özel CNN Modeli Hiper parametreleri göstermektedir.


Şekil 17, eğitim doğruluğu, doğrulama doğruluğu, eğitim kaybı ve doğrulama kaybı eğrilerini 50 epoch boyunca Göstermektedir. Modelin öğrenme süreci ve potansiyel aşırı uyum veya uygunlaşma eğilimleri hakkında bilgi sağlanmıştır.

Tablo 4. Veri Artırma Kullanılmadan Özel CNN Modeli Hiper parametreleri

Hiper parametre	Değer
Optimizer	Adam
Loss Function	Sparse Categorical Cross-Entropy
Evaluation Metric	Accuracy
Epochs	50
Batch Size	16
Learning Rate Reduction	Factor=0.3, Min LR=0.00001, Patience=3
Early Stopping	Patience=12




a. Eğitim doğruluğu, doğrulama doğruluğu eğrileri.



b. Eğitim kaybı, doğrulama kaybı eğrileri.

Şekil 17. Özel CNN Modelinin Eğitim ve doğrulama doğruluğu ve kayıp eğrisi.

Özel CNN modeli, 150 adet test görüntüsü üzerinde değerlendirilmiştir ve bu görüntüler 10 katlı çapraz doğrulama sürecine dahil edilmemiştir. Modelin performansı, Şekil 18'de gösterilen karışıklık matrisi kullanılarak değerlendirilmiştir.



Şekil 18. Veri artırma olmadan özel CNN modeli karışıklık matrisi.

Tablo 5, veri artırma kullanılmadan Özel CNN modelinin 150 adet test verisi üzerindeki performans değerlendirmesi sonuçlarını göstermektedir.

Tablo 5. Veri Artırma Kullanılmadan Özel CNN Modelinin Performans Sonuçları.

Genel Doğruluk (%): 75,33	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	76,00	65,00	70,00
Depuy	81,08	89,04	84,81
Tornier	50,00	50,00	50,00
Zimmer	73,17	65,85	69,39
Makro Ortalama	70,06	67,47	71,05

Transfer Öğreniminde Kullanılan Önceden Eğitilmiş Modellerin Değerlendirilmesi

Önceki bölümde bahsedildiği gibi, bu çalışmada, MobileNetV2, DenseNet121, DenseNet201, InceptionV3 ve ResNet50 gibi beş önceden eğitilmiş model kullanarak transfer öğrenmesi kullanılmıştır. Bu modeller, başlangıçta ImageNet veri kümesinde eğitilmiş ve daha sonra omuz artroplasti implant üreticilerini X-ray görüntülerinde sınıflandırmak için özelleştirilmiştir. Bu yaklaşım, omuz implantlarının sınırlı boyutlu veri kümesi nedeniyle önemlidir.

Her bir önceden eğitilmiş model için sağlam bir değerlendirme yapmak için 5 katlı çapraz doğrulama yöntemini kullanılmıştır.

5 katlı çapraz doğrulama veri seti, 477 X-ray görüntüsü içermektedir ve test seti için 150 adet röntgen görüntüsü kullanılmıştır.

Her katlamada, veri kümesi 5 alt kümeye ayrılmıştır ve model, 4 alt küme üzerinde eğitilirken kalan alt kümeye göre doğrulama yapılmıştır. Bu süreç beş kez tekrarlandı ve her alt küme bir kez doğrulama kümesi olarak kullanılmıştır.

Eğitim sürecinde, modeller Adam optimize edici ve seyrek kategorik çapraz entropi (sparse categorical cross-entropy) kayıp fonksiyonu ile derlenmiştir, doğruluk metriği olarak kullanılmıştır. Modeller, her katmanda 35 epoch boyunca 8'lik bir grup boyutunda eğitilmiştir.


Eğitim verimliliğini artırmak ve aşırı uydurmayı önlemek için iki geri çağrı (callbacks) kullanılmıştır: bir öğrenme oranı düşürme geri çağrısı ve bir erken durdurma geri çağrısı.

Tablo 6. Önceden Eğitilmiş Modeller Hiper parametreleri (Veri Artırma olmadan).



Hiper parametre	Değer
Optimizer	Adam
Loss Function	Sparse Categorical Cross-Entropy
Evaluation Metric	Accuracy
Epochs	35
Batch Size	8
Learning Rate Reduction	Factor=0.3, Min LR=0.0000001, Patience=3
Early Stopping	Patience=6

Tablo 6.da Veri Artırma Kullanılmadan Tüm Önceden Eğitilmiş Modeller Hiper parametreleri göstermektedir.

Önceden Eğitilmiş modellerin performansı, Şekil 19'da ve Şekil 20'de gösterilen Karışıklık matrisi kullanılarak değerlendirilmiştir.



Şekil 19. MobileNetV2 ve DenseNet121 Karışıklık matrisi.



Şekil 20. DenseNet201 ve InceptionV3 Karışıklık matrisi.

Her bir önceden eğitilmiş model için 150 görüntüden oluşan test setinde performans değerlendirme sonuçları aşağıda özetlenmiştir:

Tablo 7. MobileNetV2 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).

Genel Doğruluk (%): 72,00	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	71,05	74,07	72,53
Depuy	87,50	76,00	81,33
Tornier	66,67	66,67	66,67
Zimmer	48,78	63,33	55,07
Makro Ortalama	68,49	70,02	68,90

MobileNetV2 modeli, Ortalama genel doğruluk oranı olarak %72,00 başarı elde etmiştir. Tüm sınıflarda dengeli bir performans sergilemiştir.

Tablo 8. DenseNet121 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).

Genel Doğruluk (%): 83,33	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	85,71	88,89	87,28
Depuy	91,07	84,00	87,47
Tornier	73,68	77,78	75,68
Zimmer	71,19	80,00	75,38
Makro Ortalama	80,41	82,67	82,67

Tablo 8.de DenseNet121 modelinin, veri artırma kullanılmadan performans değerlendirmesi sonuçları yer almaktadır. Modelin her bir sınıf için doğruluk, kesinlik, duyarlılık ve F1 skoru değerleri gösterilmiştir.

Bu sonuçlara göre, modelin Cofield ve Depuy sınıflarında yüksek kesinlik, duyarlılık ve F1 skoru elde ettiği görülmektedir.

Tablo 9. DenseNet201 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).

Genel Doğruluk (%): 80,00	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	83,00	70,37	76,19
Depuy	85,82	88,00	86,90
Tornier	87,50	77,78	82,35
Zimmer	62,16	70,00	65,85
Makro Ortalama	79,62	76,54	77,82

Yukarıda verilen tabloda, DenseNet201 modelinin performans değerlendirmesi yer almaktadır.

Performans değerlendirmesi sonuçlarına göre, Depuy sınıfında en yüksek kesinlik (%85,82) ve duyarlılık (%88,00) değerleri elde edilmiştir. Tornier sınıfı için de yüksek bir kesinlik (%87,50) değeri görülmektedir. Ancak, Cofield ve Zimmer sınıfları için diğer ölçütlerde daha düşük performans değerleri bulunmaktadır.

Genel olarak, DenseNet201 modeli %80,00 doğruluk, %79,62 kesinlik, %76,54 duyarlılık ve %77,82 F1 skoru ile bu görevde ortalama bir performans sergilemektedir.

Tablo 10. InceptionV3 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).

Genel Doğruluk (%): 70,67	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	57,14	74,07	64,52
Depuy	94,64	76,00	84,44
Tornier	66,67	44,44	53,33
Zimmer	48,84	70,00	57,53
Makro Ortalama	66,83	66,13	64,96

InceptionV3 modelinin performans değerlendirmesine göre, genel doğruluk oranı %70,67 olarak hesaplanmıştır. Modelin en yüksek kesinlik değeri %94,64 ile Depuy sınıfında elde edilmiştir. Ancak, Tornier sınıfında düşük bir duyarlılık oranı (%44,44) ve F1 skoru (%53,33) gözlenmiştir. Bu durum, modelin Tornier sınıfını diğer sınıflara göre daha zor ayırt ettiğini göstermektedir.

Tablo 11. ResNet50 Modelinin Performans Sonuçları (Veri Artırma Kullanılmadan).

Genel Doğruluk (%): 58,00	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	78,79	40,74	53,78
Depuy	62,03	88,00	72,73
Tornier	0,00	0,00	0,00
Zimmer	34,48	36,67	35,56
Makro Ortalama	43,83	41,35	40,52

ResNet50 modelinin performans değerlendirmesine göre, genel doğruluk oranı %58,00 olarak hesaplanmıştır. Modelin en yüksek duyarlılık değeri %88,00 ile Depuy sınıfında elde edilmiştir. Ancak, Tornier sınıfında duyarlılık ve F1 skoru sıfır olarak belirlenmiştir, yani bu sınıfı doğru bir şekilde tanımlayamamıştır. Ayrıca, tüm sınıfların makro ortalaması düşüktür, bu da modelin genel olarak düşük performansa sahip olduğunu göstermektedir.

ResNet50 modeli diğer modellere göre daha düşük performans sergilemektedir ve Tornier sınıfında ciddi bir başarısızlık yaşamaktadır.

Veri artırma kullanılmadan değerlendirilen modeller arasında, DenseNet121 en iyi performansı göstermiştir ve en yüksek genel doğruluğa (%83,33) sahip olmuştur. Aynı zamanda çoğu sınıfta dengeli sonuçlar gösterilmiştir. Cofield ve Depuy implantları için güçlü kesinlik ve duyarlılık değerlerine sahipti ve Tornier ile Zimmer implantları için de makul bir performans sergiledi.

Öte yandan, ResNet50 modeli en düşük genel doğruluğa (%58,00) sahiptir ve Cofield, Tornier ve Zimmer implantlarını sınıflandırmada zorlandı, bu nedenle bu sınıflar için düşük kesinlik, duyarlılık ve F1 skorlarına ulaşmıştır.

Veri artırma kullanılmadan modellerin performansı bazı kısıtlamalar gösterilmektedir, özellikle daha az örnek içeren sınıflar için (örneğin ResNet50 modelinde Tornier implantları). Sınırlı bir veri kümesiyle, modeller altında yatan desenleri etkili bir şekilde öğrenemeyebilir ve bu da aşırı uyum veya optimize edilmemiş performansa yol açabilmiştir. Veri artırma, her sınıf için daha çeşitli örnekler sağlayarak bu zorluğu aşmada yardımcı olabilir ve böylece modellerin daha güçlü ve genelleştirilebilir özellikler öğrenmesine katkı sağlanmıştır.



Sonuç olarak, veri artırma kullanılmadan yapılan değerlendirmelerde DenseNet121'in en iyi performansı gösterdiği görülmüştür. Ancak, veri artırma kullanılması modellerin performansını ve genelleme yeteneğini daha da artırabilir. Veri kümesinin çeşitliliği ve boyutunun artırılması, sınırlı bir veri kümesinin ortaya koyduğu kısıtlamaların üstesinden gelmeye ve omuz implantı üreticilerini X-ray görüntülerinde sınıflandırma modellerinin doğruluğunu ve sağlamlığını artırmaya yardımcı olabilir.

Veri Artırma ile Modellerin Değerlendirilmesi



Bu çalışmada, veri artırma yöntemiyle derin öğrenme modellerinin değerlendirmesini gerçekleştirmiştir. Tüm modeller, adil ve tutarlı bir karşılaştırma için aynı hiper parametreler ve ayarlar kullanılarak eğitilmiştir.

Her modeli veri artırma ile eğittikten sonra, performanslarını 150 görüntüden oluşan test setinde değerlendirilmiştir.



Modellerin tüm değerlendirme sonuçları, Şekil 22, 23 ve 24'te gösterilen karışıklık matrisine göre hesaplanmıştır.



Şekil 21. Veri Artırma Kullanılarak Özel CNN modeli ve MobileNetV2 Karışıklık matrisleri.



Şekil 22. Veri Artırma Kullanılarak DenseNet121 ve DenseNet201 Karışıklık matrisleri.





Şekil 23. Veri Artırma Kullanılarak InceptionV3 ve ResNet50 Karışıklık matrisleri.

Veri artırma kullanılarak her bir modelin performans değerlendirme sonuçları aşağıda özetlenmiştir:

Tablo 12. Veri Artırma Kullanılarak Özel CNN Modelinin Performans Sonuçları.

Genel Doğruluk (%): 91,33	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	96,15	84,62	90,00
Depuy	85,25	100	92,08
Tornier	100	86,11	92,59
Zimmer	96,00	85,71	90,62
Makro Ortalama	94,35	89,11	91,32



Şekil 24. Veri artırma kullanılarak Özel CNN Modelinin Eğitim ve doğrulama doğruluğu ve kaybı eğrileri.

Tablo 12'deki sonuçlara göre, veri artırma kullanılarak özel CNN modeli yüksek doğruluk (%91,33) ve dengeli performans elde etmiştir. Cofield, Depuy, Tornier ve Zimmer sınıflarında yüksek kesinlik, duyarlılık ve F1 skorları elde edilmiştir. Şekil 21'de, modelin eğitim doğruluğu, doğrulama doğruluğu, eğitim kaybı ve doğrulama kaybı eğrileri 50 epoch boyunca gösterilmektedir. Bu eğriler, modelin eğitim sürecinde iyi bir şekilde performans gösterdiğini ve aşırı uyumdan kaçındığını göstermektedir.

Tablo 13. Veri Artırma Kullanılarak MobileNetV2 Modelinin Performans Sonuçları.

Genel Doğruluk (%): 95,33	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	100	92,31	96,00
Depuy	97,78	95,00	96,37
Tornier	100	94,44	97,14
Zimmer	82,14	100	90,24
Makro Ortalama	94,98	95,44	94,94

Tablo 13'teki sonuçlara göre, veri artırma kullanılarak MobileNetV2 modeli yüksek performans göstermiştir. Modelin genel doğruluk oranı %95,33 olarak oldukça yüksektir. Cofield, Depuy ve Tornier sınıflarında yüksek kesinlik, duyarlılık ve F1 skorları elde edilmiştir, bu da bu sınıfların iyi bir şekilde sınıflandırıldığını göstermektedir. Zimmer sınıfında duyarlılık oranı %100 olarak yüksek bulunmuş ancak kesinlik ve F1 skoru değerleri diğer sınıflara göre daha düşüktür. Makro ortalama, tüm sınıfların performansını dengeli bir şekilde değerlendiren bir ölçüdür.

Tablo 14. Veri Artırma Kullanılarak DenseNet121 Modelinin Performans Sonuçları.

Genel Doğruluk (%): 98,00	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	100	92,31	96,00
Depuy	100	100	100
Tornier	97,06	100	98,51
Zimmer	93,33	96,43	94,86
Makro Ortalama	97,59	97,19	97,34

DenseNet121 modeli, veri artırma kullanılarak elde edilen yüksek performansıyla dikkat çekmektedir. Genel doğruluk oranı %98,00 olarak oldukça yüksek ve güvenilirdir. Sınıflar arasında dengeli bir performans sergilemektedir. Cofield, Depuy, Tornier ve Zimmer sınıflarında yüksek kesinlik, duyarlılık ve F1 skorları elde edilmiştir.

Makro ortalama F1 skoru da oldukça yüksektir, bu da modelin tüm sınıfların performansını dengeli bir şekilde iyileştirdiğini göstermektedir.

Tablo 15. Veri Artırma Kullanılarak DenseNet201 Modelinin Performans Sonuçları.

Genel Doğruluk (%): 97,33	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	100	88,46	93,98
Depuy	97,96	100	98,97
Tornier	95,00	100	97,44
Zimmer	96,00	96,43	96,22
Makro Ortalama	97,24	96,22	96,65

DenseNet201 modeli, veri artırma kullanılarak eğitilmiş ve elde ettiği sonuçlar oldukça yüksek performans göstermektedir. Genel doğruluk oranı %97,33 olarak oldukça yüksek ve güvenilirlerdir. Cofield, Depuy, Tornier ve Zimmer sınıflarında yüksek kesinlik, duyarlılık ve F1 skorları elde edilmiştir.

Tablo 16. Veri Artırma Kullanılarak InceptionV3 Modelinin Performans Sonuçları.

Genel Doğruluk (%): 94,67	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	100	88,46	93,98
Depuy	95,24	98,33	96,76
Tornier	100	88,89	94,12
Zimmer	85,00	100	91,89
Makro Ortalama	95,05	93,92	94,19

Tablo 16'daki sonuçlara göre InceptionV3 modelinde genel doğruluk oranı %94,67 olup Cofield, Depuy, Tornier ve Zimmer sınıflarında yüksek kesinlik, duyarlılık ve F1 skorları elde edilmiştir. Ancak, Cofield sınıfında duyarlılık değeri diğer sınıflara göre biraz daha düşüktür.

Tablo 17. Veri Artırma Kullanılarak ResNet50 Modelinin Performans Sonuçları.

Genel Doğruluk (%): 90,00	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
Cofield	92,31	92,31	92,31
Depuy	87,04	96,67	91,63
Tornier	100	80,56	89,23
Zimmer	85,71	85,71	85,71
Makro Ortalama	91,27	88,81	89,72

ResNet50 modeli veri artırma kullanılarak eğitilmiş ve omuz implantlarının sınıflandırmasında %90,00 genel doğruluk ile kabul edilebilir bir performans göstermiştir. Ancak, diğer modellere göre bazı sınıflarda daha düşük kesinlik ve duyarlılık değerlerine sahiptir.


Veri Artırma ve Dengesiz Veri Kümesini Çözme Etkisi

Veri artırma, tüm modellerin performansını önemli ölçüde iyileştirmiştir. Ek artırılmış örnekler oluşturarak, modeller aynı verinin daha çeşitli varyasyonlarına maruz kalmış ve daha iyi genelleme yeteneği ve sağlamlılık elde etmiştir. Bu, modellerin sınırlı veri kümesinden daha temsilci özellikler ve desenler öğrenmesine katkıda bulunmuş ve doğruluk ve performanslarını artırmıştır.

Ayrıca, veri artırma, dengesiz veri kümesi sorununu ele almadaki kritik bir rol oynamıştır. Az temsil edilen sınıflar için sentetik veri üreterek, modeller bu sınıfları daha iyi öğrenmeye ve doğru bir şekilde sınıflandırmaya daha hazırlıklı hale gelmiştir. Bu, özellikle Tornier ve Zimmer gibi daha az örnek içeren sınıflar için daha dengeli Kesinlik ve Duyarlılık değerleri elde edilmesine yol açmıştır.

Sonuç olarak, veri artırma, sınırlı ve dengesiz veri kümeleri ile uğraşırken derin öğrenme modellerinin performansını artırmak için güçlü bir teknik olarak kanıtlamıştır. Veri artırma ile değerlendirilen modeller arasında, 98,00% ile en yüksek genel doğruluk elde ederek tüm sınıflar için dengeli performans sergileyen en iyi performans gösteren model olarak DenseNet121 ortaya çıkmıştır. DenseNet201 modeli de yüksek performans göstermiş ve ikinci en iyi performans gösteren model olarak sıralanmıştır.

Bu sonuçlar, omuz implantları sınıflandırmasında derin öğrenme modellerinin etkili bir çözüm olduğunu göstermektedir. Ayrıca, veri artırma kullanılarak eğitilen modellerin, diğer çalışmalardan daha iyi performans sergilediği gözlemlenmiştir. Veri artırma, sınıflandırma modellerinin performansını artırarak, özellikle dengesiz veri kümelerinde daha iyi sonuçlar alınmasını sağlamıştır.



Şekil 25. Veri artırma kullanarak ve kullanmadan sınıflandırma tekniklerinin doğruluk karşılaştırması.

Karşılaştırmalı olarak, araştırma çalışmaları ve bu çalışmada kullanılan modellerin sonuçlarına göre, omuz implantları sınıflandırması için önceden eğitilmiş CNN modellerinin Transfer öğrenimi oldukça başarılı sonuçlar vermektedir. Bu modeller, omuz implantları sınıflandırmasında yüksek doğruluk elde etmiştir.

Tablo 18'deki çalışmaların sonuçlarını bu çalışma ile karşılaştırdığımızda, Sivari ve ark. (2022) tarafından önerilen yöntem %95,07 doğruluk oranı test doğruluğunu elde etmiştir. Aynı şekilde, Yılmaz (2021) tarafından önerilen yöntem de %97,20 doğruluk oranı, 5 çapraz doğrulama ile doğruluğu elde etmiştir.

Urban ve ark. (2020) çalışmasında DL algoritmaları için %74-80 aralığında, ML algoritmaları için ise %51-56 aralığında doğruluk değerleri bildirilmiştir. Diğer bir çalışma olan Yi ve ark. (2020), 2 sınıflı bir veri seti üzerinde %97,00 doğruluk elde etmiştir. Stark (2018) ise Hough Dönüşümü yöntemi ile %77,00 hassasiyet sağlamıştır.

Bu çalışmada ise, veri artırma tekniklerini ile farklı derin öğrenme modelleri kullanılarak elde edilen sonuçlar sunulmaktadır. Özel olarak, Custom CNN Model %91,33 doğruluk, MobileNetV2 Model %95,33 doğruluk, DenseNet121 Model %98,00 doğruluk, DenseNet201 Model %97,33 doğruluk, InceptionV3 Model %94,67 doğruluk ve ResNet50 Model %90 doğruluk oranları ile sonuçlanmıştır. Ayrıca, bu çalışma özellikle DenseNet121 modeli ile %98,00 yüksek doğruluk oranı elde etmiştir.

Ayrıca bu çalışma gibi, Yılmaz, Urban ve Yi gibi diğer çalışmaların veri artırma tekniklerini farklı sayıda artırılmış veri ve farklı artırma tekniklerini kullandığını da belirtmek gerektirmektedir.

Tablo 18. Aynı veri seti kullanılarak yürütülen çalışmalarının sonuçlarının bu çalışma ile karşılaştırılması.

Araştırma Çalışmaları	Veri seti	Yöntemler	Elde Edilen Sonuçlar Doğruluk (%)
Sivari et al., (2022)	4 sınıf-597 veri seti	Hibrit makine öğrenimi algoritmaları; 5 kat çapraz doğrulama	DenseNet201 + LR: 95,07
Sultan et al., (2021)	4 sınıf-597 veri seti	Yoğun artık topluluk ağı (DRE-Net): Değiştirilmiş ResNet ve DenseNet'in kombinasyonu; 10 kat çapraz doğrulama	85,92
Yılmaz, (2021)	4 sınıf-597 veri seti	Çok kanallı CNN modeli, 5 kat çapraz doğrulama	97,20
Urban et al., (2020)	4 sınıf-597 veri seti	Yedi farklı derin öğrenme modeli (VGG-16, VGG-19, ResNet-50, ResNet-152, DenseNet, NASNet, özel bir CNN), dört farklı makine öğrenimi sınıflayıcısı (Lojistik Regresyon, Rastgele Ormanlar, Gradient Boost, K-En Yakın Komşu)	DL algoritmaları: 74–80, ML algoritmaları: 51–56
Yi et al., (2020)	2 sınıf-597 veri seti	Transfer öğrenme ve ince ayarlı ResNet-18 modeli	97,00
Stark, (2018)	4 sınıf-597 veri seti	Hough Dönüşümü	77,00 hassasiyet
Bu Çalışma	4 sınıf-597 veri seti	Custom CNN Model	91,33
		MobileNetV2 Model	95,33
		DenseNet121 Model	98,00
		DenseNet201 Model	97,33
		InceptionV3 Model	94,67
		ResNet50 Model	90,00

Sonuç olarak, Sivari et al., (2022), Yılmaz, (2021) ve diğer çalışmaların sonuçları ile karşılaştırıldığında, bu çalışma farklı derin öğrenme modelleri kullanarak, omuz implantları sınıflandırmasında yüksek başarı elde etmiştir. Bu modeller, tıbbi görüntülerin sınıflandırılması için etkili bir yaklaşım sunmaktadır ve veri artırma ile daha da iyileştirilebilirler. Bu çalışma, X-ray görüntü sınıflandırması alanındaki önemli katkıları vurgulamaktadır.

SONUÇ VE ÖNERİLER

Bu çalışmada, temel amacımız X-ray görüntüleri kullanarak omuz implantı üreticilerini sınıflandırmak olan zorlu bir görevi ele almaktadır. Doğru ve etkili implant sınıflandırması için derin öğrenme modelleri geliştirilmiştir ve değerlendirilmiştir, özellikle sınıf dengesizliği ve veri kıtlığı sorunlarına odaklanmıştır. Bu tez çalışması ve deneyleri boyunca, tıbbi görüntü analiz alanında önemli adımlar atmıştır ve derin öğrenme tekniklerinin tıbbi teşhis ve tedavi planlamasını iyileştirmede potansiyelini gösterilmiştir.

Veri setimiz, Cofield, Depuy, Tornier ve Zimmer olmak üzere dört farklı tipte omuz implantı içeren 597 X-ray görüntüsünden oluşmuştur. Ancak, belirli implant sınıflarının diğerlerine göre önemli ölçüde daha az örneğe sahip olması ve düşük veri sayısı sorunuyla karşılaşmıştır. Bu zorluğu ele almak ve modellerin performansını artırmak için veri artırma tekniklerinden yararlanmıştır. Farklı dönüşümleri uygulayarak veri setini yapay olarak genişleterek sınıf dengesizliğini etkili bir şekilde azaltmıştır ve modellerin daha çeşitli ve güçlü özellikler öğrenmesine olanak sağlanmıştır.

Deney aşamasında, MobileNetV2, DenseNet121, DenseNet201, InceptionV3 ve ResNet50 gibi önceden eğitilmiş CNN mimarileri yanı sıra özel bir CNN modeli kullanarak birden fazla derin öğrenme modeli eğitmiştir.

Modellerden elde edilen sonuçlar oldukça umut vericiydi. Önceden eğitilmiş CNN modelleriyle yapılan transfer öğrenimi, bazı önceki araştırma çalışmalarında kullanılan geleneksel görüntü işleme yöntemlerinden daha yüksek doğruluk sağlanmıştır. Özellikle DenseNet121 modeli, omuz implantı sınıflandırmasında %98'lik en yüksek doğruluk oranını elde ederek derin sinir ağlarının tıbbi görüntü sınıflandırma görevlerindeki gücünü vurgulamıştır.

Ayrıca, DenseNet201 modeliyle yapılan transfer öğrenimi %97,33'lük yüksek bir doğruluk göstermişti ve transfer öğreniminin tıbbi görüntü analizindeki etkinliğini doğrulamıştı. Özel olarak bu çalışma için geliştirilen CNN modeli, daha az eğitim parametresi ile %91,33'lük bir doğrulukla rekabetçi bir performans gösterilmiştir.

Veri artırmanın etkisi, tüm mimarilerde modellerin performansını artırmada net bir şekilde görülmektedir. Doğru veri artırma yöntemlerinin seçimi ve etkili parametrelerinin belirlenmesi, model doğruluğunda önemli iyileştirmelere katkıda bulunmaktadır. Sınıf

dengesizliđi sorununu gidermek için her sınıf için yaklaşık 600 yapay görüntü oluşturarak veri artırma, modellerin genel doğruluđuna önemli katkı sağlanmıştır.

Ayrıca, farklı önceden eğitilmiş CNN mimarilerinin incelenmesi, transfer öğreniminin tıbbi görüntü analizindeki önemini vurgulamıştır. Büyük ölçekli görüntü veri kümesinden öğrenilen bilginin, sınırlı veri bulunan tıbbi alanlarda kullanılabilirliđi, omuz implantı sınıflandırmasında yüksek doğruluk ve verimlilik elde etmeyi sağlanmıştır.

Gelecekteki araştırmalar için birkaç yol önerilmektedir. İlk olarak, omuz implantları üreticilerini temsil eden daha farklı ve çeşitli örnekler içeren veri kümesini genişletmek ve daha da artırmak, modellerin performansını ve genelleme yeteneklerini artırabilir.

Ayrıca, bu sınıflandırma modellerini daha büyük tıbbi görüntü veri kümelerinde test etmek ve farklı tıbbi uygulamalarda performanslarını değerlendirmek, genelleme potansiyellerini ve gerçek dünya uygulanabilirliklerini değerlendirmede yararlı olacaktır.

Sonuç olarak, çalışmamız tıbbi görüntü analizinde, özellikle X-ray görüntüleri kullanarak omuz implantı üreticilerini sınıflandırmada derin öğrenme tekniklerinin önemli potansiyelini göstermektedir. Sonuçlar, önceden eğitilmiş CNN modelleriyle transfer öğreniminin etkinliđini ve veri artırmanın sınıf dengesizliđi ve düşük veri sayısını ele almadaki olumlu etkisini vurgulamaktadır.

KAYNAKLAR

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Zheng, X. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. arXiv preprint arXiv:1603.04467.
- Aggarwal, C. C. (2018). Neural networks and deep learning. Springer eBooks. <https://doi.org/10.1007/978-3-319-94463-0>
- Bates, T., Fergason, J. R., & Pierrie, S. N. (2020). Technological advances in prosthesis design and rehabilitation following upper extremity limb loss. *Current Reviews in Musculoskeletal Medicine*, 13(4), 485–493. <https://doi.org/10.1007/s12178-020-09656-6>
- Bohr, A., & Memarzadeh, K. (2020). The Rise of Artificial Intelligence in Healthcare Applications. *Artificial Intelligence in Healthcare*. Crossref, 25–60.
- Chollet, F. (2017). Deep Learning with Python. Retrieved from <http://cds.cern.ch/record/2301910>
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1251-1258.
- Doe, A. (2021). Challenges of Small Datasets in Deep Learning for Medical Imaging. *Proceedings of the International Conference on Artificial Intelligence in Medicine*, 55-67.
- Dong, N., Li, Z., Wu, C., & Chang, J. (2020). Inception v3 based cervical cell classification combined with artificially extracted features. *Applied Soft Computing*, 93, 106311. <https://doi.org/10.1016/j.asoc.2020.106311>
- Harris, C. B., Millman, K. J., Van Der Walt, S., Gommers, R., Virtanen, P., Cournapeau, D., . . . Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/cvpr.2016.90>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2016). Densely connected convolutional networks. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1608.06993>
- Johnson, R. (2019). Addressing Class Imbalance in Medical Image Datasets with Data Augmentation. *Medical Image Computing and Computer-Assisted Intervention*, 78(2), 214-226.
- Joseph. (2022, August 16). Machine Learning vs. Deep Learning: What's the Difference? - reason.town. Retrieved from <https://reason.town/machine-learning-vs-deep-learning-2/>
- Jmour, N., Zayen, S., & Abdelkrim, A. (2018). Convolutional neural networks for image classification. <https://doi.org/10.1109/aset.2018.8379889>
- Karnuta, J. M., Luu, B. C., Roth, A. L., Haeberle, H. S., Chen, A. F., Iorio, R., ... & Ramkumar, P. N. (2020). Artificial Intelligence to Identify Arthroplasty Implants From Radiographs

- of the Knee. *The Journal of Arthroplasty*, 36(3), 935–940. <https://doi.org/10.1016/j.arth.2020.10.021>
- Kim, J. E., Nam, N. E., Shim, J. S., Jung, Y. H., Cho, B. H., & Hwang, J. J. (2020). Transfer Learning via Deep Neural Networks for Implant Fixture System Classification Using Periapical Radiographs. *Journal of Clinical Medicine*, 9(4), 1117. <https://doi.org/10.3390/jcm9041117>
- Kim, T. K., Nam, N. E., & Kim, J. E. (2020). Machine Learning and Deep Learning in Medical Imaging: Intelligent Imaging. *Clinical Neuroradiology*, 1–12. <https://doi.org/10.1007/s00062-020-01001-0>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1 (NIPS'12)* (pp. 1097-1105). Curran Associates Inc., Red Hook, NY, USA.
- Lindsey, R., Daluiski, A., Chopra, S., Lachapelle, A., Mozer, M., Sicular, S., ... & Potter, H. (2018). Deep neural network improves fracture detection by clinicians. *Proceedings of the National Academy of Sciences*, 115(45), 11591–11596. <https://doi.org/10.1073/pnas.1806905115>
- Sakib, S., Ahmed, N., Kabir, A. I., & Ahmed, H. (2018). An Overview of Convolutional Neural Network: Its Architecture and Applications. *Preprints.org*. <https://doi.org/10.20944/preprints201811.0546.v1>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1801.04381>
- Seidaliyeva, U., Akhmetov, D., Ilipbayeva, L., & Matson, E. T. (2020). Real-Time and Accurate Drone Detection in a Video with a Static Background. *Sensors*, 20(14), 3856. <https://doi.org/10.3390/s20143856>
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv:1409.1556*.
- Sivari, E., Güzel, M. S., Bostanci, E., & Mishra, A. (2022). A Novel Hybrid Machine Learning Based System to Classify Shoulder Implant Manufacturers. *Healthcare*, 10(3), 580. <https://doi.org/10.3390/healthcare10030580>
- Smith, J. (2018). Deep Learning in Medical Image Analysis. *Journal of Medical Imaging*, 25(3), 123-135.
- Stark, M. B. C. G. (2018). Automatic detection and segmentation of shoulder implants in x-ray images. *ScholarWorks*. <https://scholarworks.calstate.edu/concern/theses/79407z98n>
- Sultan, H., Owais, M., Park, C., Mahmood, T., Haider, A., & Park, K. R. (2021). Artificial Intelligence-Based Recognition of Different Types of Shoulder Implants in X-ray Scans Based on Dense Residual Ensemble-Network for Personalized Medicine. *Journal of Personalized Medicine*, 11(6), 482. <https://doi.org/10.3390/jpm11060482>
- Sukegawa, S., Yoshii, K., Hara, T., Yamashita, K., Nakano, K., Yamamoto, N., Nagatsuka, H., & Furuki, Y. (2020). Deep Neural Networks for Dental Implant System Classification. *Biomolecules*, 10(7), 984. <https://doi.org/10.3390/biom10070984>

- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2015). Rethinking the inception architecture for computer vision. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1512.00567>
- Tao, Z., XinYu, Y., Lu, H., Zheng, X., Qiu, S., & Liu, Y. (2022). Dense convolutional network and its application in medical image analysis. *BioMed Research International*, 2022, 1–22. <https://doi.org/10.1155/2022/2384830>
- Urban, G., Porhemmat, S., Stark, M., Feeley, B., Okada, K., & Baldi, P. (2020). Classifying shoulder implants in X-ray images using deep learning. *Computational and Structural Biotechnology Journal*, 18, 967–972. <https://doi.org/10.1016/j.csbj.2020.04.005>
- Waskom, M. (2021). seaborn: statistical data visualization. *Journal of Open Source Software*, 6(60), 3021. <https://doi.org/10.21105/joss.03021>
- Yi, P. H., Kim, T. K., Wei, J., Li, X., Hager, G. D., Sair, H. I., & Fritz, J. (2020). Automated detection and classification of shoulder arthroplasty models using deep learning. *Skeletal Radiology*, 49(10), 1623–1632. <https://doi.org/10.1007/s00256-020-03463-3>
- Yi, P. H., Wei, J., Kim, T. K., Sair, H. I., Hui, F. K., Hager, G. D., Fritz, J., & Oni, J. K. (2020). Automated detection & classification of knee arthroplasty using deep learning. *The Knee*, 27(2), 535–542. <https://doi.org/10.1016/j.knee.2019.11.020>
- Yilmaz, A. (2021). Shoulder Implant Manufacturer Detection by Using Deep Learning: Proposed Channel Selection Layer. *Coatings*, 11(3), 346. <https://doi.org/10.3390/coatings11030346>
- Zafari, A., Kianmehr, M. H., & Abdolazadeh, R. (2013). Modeling the effect of extrusion parameters on density of biomass pellet using artificial neural network. *International Journal Of Recycling of Organic Waste in Agriculture*, 2(1). <https://doi:10.1186/2251-7715-2-9>
- Zhang, H., & Dana, K. (2021). Multi-task learning of disease progression and classification from medical images. *Nature Communications*, 12(1), 3406. <https://doi.org/10.1038/s41467-021-23719-3>

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Shamriz NAHZAT
Doğum tarihi:	
Doğum Yeri:	
Uyruğu:	
Adres:	
Tel:	
E-mail:	
Eğitim	
Lise:	Saidal Naseeri Lisesi
Lisans:	Kabil Politeknik Üniversitesi
Yüksek lisans:	Atatürk Üniversitesi
Doktora:	
Yabancı Dil Bilgisi	
İngilizce:	İleri seviye
Türkçe:	İleri seviye
Üye Olunan Mesleki Kuruluşlar	
Tezden Üretilmiş Yayınlar	