



Detection and classification of shoulder implants from X-ray images: YOLO and pre-trained convolution neural network based approach

Abdulkadir Karacı*

Department of Computer Engineering, Kastamonu University, Kastamonu, 37200, Turkey

Highlights:

- Automatic detection of shoulder implant manufacturer
- A new cascade deep learning method not used in previous studies
- Improving classification accuracy by focusing on the implant's head area with YOLO

Keywords:

- Shoulder implant
- Deep learning
- Convolutional neural networks
- Object detection
- YOLO

Article Info:

Research Article
Received: 28.02.2021
Accepted: 30.05.2021

DOI:

10.17341/gazimmfd.888202

Correspondence:

Author: Abdulkadir Karacı
e-mail:
akaraci@kastamonu.edu.tr
phone: +90 366 280 2918

Graphical/Tabular Abstract

Shoulder implants may need to be replaced several months or years after insertion. In this case, it is important to determine the manufacturer or model of the implant. In some cases, the implant manufacturer and model may not be known to patients or their physicians due to uncertainty in medical records. Today, the task of identifying an implant manufacturer or model in such situations relies on meticulous examination and visual comparison of X-ray images taken from the implant by medical professionals. But this identification task is often time-consuming, error-prone and difficult for both radiologists and orthopedic surgeons. In this study, it is aimed to automatically detect the implant manufacturer using deep learning methods. For this purpose, pre-trained CNN architectures and cascade models consisting of feeding these architectures with the YOLO algorithm have been proposed.

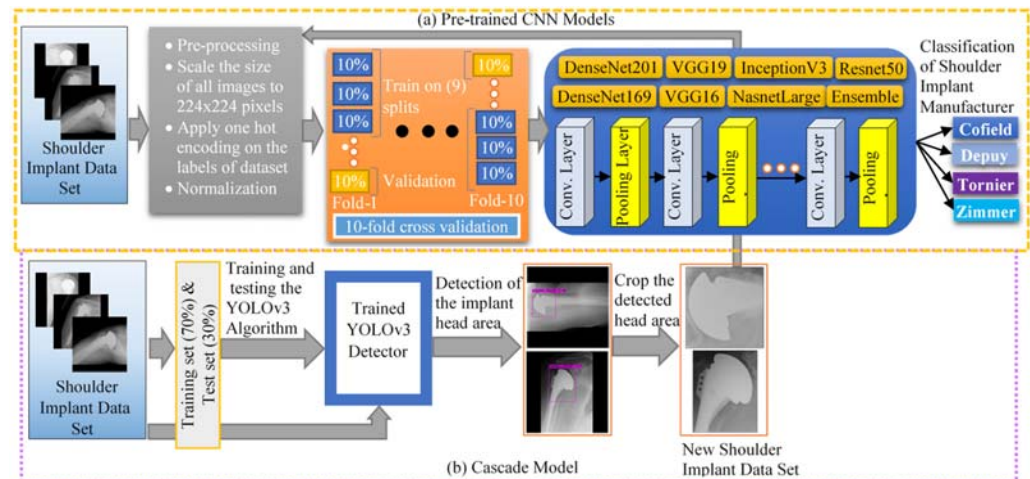


Figure A. System Architecture

Purpose: The aim of this study is to develop a deep learning-based automated detection system to help physicians detect the implant manufacturer from X-ray images.

Theory and Methods:

Pre-trained CNN architectures (DenseNet201, DenseNet169, InceptionV3, NasNetLarge, VGG16, VGG19, Resnet50) and cascade models have been created in which these architectures are fed by the YOLOv3 detection algorithm. The task of the YOLOv3 in cascade models is to detect the head region of the shoulder implants and give this region as an introduction to CNN architectures.

Results:

The highest classification performance was achieved in the cascade DenseNet201 model with an accuracy rate of 84.76%.

Conclusion:

In this study, a new cascade deep learning model, which was not used in previous studies, is proposed to classify the shoulder implant. The classification accuracy obtained is higher than a study using a similar data set in the literature. Furthermore, the classification accuracy of Yolo supported cascade models is higher than individual CNN models. That is, focusing on the head area of the implant with the YOLOV3 detection algorithm has increased classification accuracy. This method will inspire further studies in this.



X-ışını görüntülerinden omuz implantlarının tespiti ve sınıflandırılması: YOLO ve önceden eğitilmiş evrişimsel sinir ağı tabanlı bir yaklaşım

Abdulkadir Karacı*^{ID}

Kastamonu Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 37200, Kuzeykent, Kastamonu, Türkiye

Ö N E Ç İ K A N L A R

- Omuz implantı üreticisini otomatik tespit etme
- Önceki çalışmalarda kullanılmayan yeni bir kademeli derin öğrenme yöntemi
- YOLO ile implantın baş bölgesine odaklanarak sınıflandırma doğruluğunu artırma

Makale Bilgileri

Araştırma Makalesi

Geliş: 28.02.2021

Kabul: 30.05.2021

DOI:

10.17341/gazimmfd.888202

Anahtar Kelimeler:

Omuz implantı,
derin öğrenme,
evrişimsel sinir ağları,
nesne tespiti,
YOLO

ÖZ

Omuz implantları yerleştirildikten belirli bir süre sonra değiştirilmelidir. Ancak bu değişim sırasında implant üreticisini veya modelini belirlemek tıbbi uzmanlar için genellikle hataya açık ve zor bir işlemdir. Bu çalışmanın amacı 597 adet omuz implantı X-ışını görüntülerinden 4 farklı implant üreticisini tespit etmektir. Bu amaçla hem önceden eğitilmiş ESA mimarileri (DenseNet201, DenseNet169, InceptionV3, NasNetLarge, VGG16, VGG19 ve Resnet50) hem de bu mimarilerin YOLOv3 tespit algoritmasıyla beslendiği kademeli modeller oluşturulmuş ve bu modellerin sınıflandırma performansları karşılaştırılmıştır. Kademeli modellerdeki YOLOv3 tespit algoritmasının görevi omuz implantlarının baş bölgesini tespit ederek bu bölgeyi ESA mimarilerine giriş olarak vermektir. Bunun yanı sıra geleneksel makine öğrenmesi yöntemleri topluluk öğrenme yöntemi ile birleştirilerek veri seti üzerindeki performansları ortaya konulmuştur. En yüksek sınıflandırma performansı %84,76 doğruluk oranıyla kademeli DenseNet201 modelinde elde edilmiştir. Bu oran literatürde benzer veri setini kullanan başka bir çalışmaya göre daha yüksektir. Topluluk modellerin sınıflandırma doğruluğu ise önemli ölçüde ESA modellerinden daha düşüktür. Ayrıca YOLO destekli kademeli modellerin sınıflandırma doğruluğu bireysel ESA modellerinden daha yüksektir. Yani, YOLOv3 tespit algoritması ile implantın baş bölgesine odaklanmak sınıflandırma doğruluğunu artırmıştır. Bu yöntem bu alanda yapılacak sonraki çalışmalara ilham verecektir.

Detection and classification of shoulder implants from X-ray images: YOLO and pre-trained convolution neural network based approach

H I G H L I G H T S

- Automatic detection of shoulder implant manufacturer
- A new cascade deep learning method not used in previous studies
- Improving classification accuracy by focusing on the implant's head area with YOLO

Article Info

Research Article

Received: 28.02.2021

Accepted: 30.05.2021

DOI:

10.17341/gazimmfd.888202

Keywords:

Shoulder implant,
deep learning,
convolutional neural
networks,
object detection,
YOLO

ABSTRACT

Shoulder implants must be replaced after a certain period of time. But determining the manufacturer or model of the implant during this change is often a mistake-prone and difficult process for medical experts. The aim of this study is to identify 4 different implant manufacturers from 597 shoulder implant X-ray images. For this purpose, both pre-trained CNN architectures (DenseNet201, DenseNet169, InceptionV3, NasNetLarge, VGG16, VGG19 and Resnet50) and cascade models that feed these architectures with YOLOv3 detection algorithm were created and the classification performances of these models were compared. The task of the YOLOv3 detection algorithm in cascade models is to detect the head area of the shoulder implants and give this area as an input to CNN architectures. In addition, traditional machine learning methods were combined with the ensemble learning method and their performance on the data set was revealed. The highest classification performance was achieved in the cascade DenseNet201 model with an accuracy rate of 84.76%. This rate is higher in the literature than in a different study using similar dataset. Classification accuracy of ensemble models is substantially lower than CNN models. Also, the classification accuracy of YOLO supported cascade models is higher than individual CNN models. That is, focusing on the head of the implant with the YOLOv3 detection algorithm has increased the classification accuracy. This method will inspire future studies in this field.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : akaraci@kastamonu.edu.tr / Tel: +90 366 280 2918

1. GİRİŞ (INTRODUCTION)

Total Omuz Artroplastisi (TSA), omuz topunun ve soket ekleminin bir implant ile değiştirildiği, hasarlı omuz eklemlerinin tedavisinde uygulanan yaygın bir ortopedik prosedürdür [1-3]. TSA ameliyatı geçirmenin yaygın nedenleri, kritik omuz yaralanmaları veya şiddetli eklem iltihabıdır. Prosedür ağrıyı azaltır ve hastanın omuzundaki hareketi geri yükler. İmplant üreten farklı üreticiler vardır [2]. Ayrıca, implantın yerleştirildikten birkaç ay veya yıl sonra değiştirilmesi gerekebilir. Bu durumda implant üreticisini ya da modelini belirlemek önemlidir. Bazı vakalarda, implant üreticisi ve modeli hastalar veya doktorları tarafından tıbbi kayıtlardaki belirsizlik nedeniyle bilinmeyebilir. Günümüzde, bu gibi durumlarda bir implant üreticisini ya da modelini belirleme görevi, tıbbi uzmanların implanttan alınan X-ışını görüntülerini titiz bir şekilde incelemelerine ve görsel karşılaştırmalarına dayanmaktadır. X-ışını görüntüleri, implantların belirgin özelliklerini iyi bir şekilde göstermesine rağmen, tanımlama görevi hem radyologlar hem de ortopedi cerrahları için genellikle zaman alıcı, hataya açık ve zordur. Bu monoton bir görevdir ve her yeni hasta için zaman ve çaba gerektirir [2, 4-6]. İmplant tasarımının ameliyat öncesi belirlenememesi, ameliyat süresinin artmasına, daha karmaşık ameliyatlara, artmış kan kaybına, artmış kemik kaybına, iyileşme süresinin artmasına ve genel olarak artan sağlık bakım maliyetlerine yol açabilir [6]. Bunun yanı sıra implantların %10'unun ameliyat öncesi tanımlanamadığı ve %2'sinin ise ameliyat sırasında tespit edilemediği bildirilmektedir [7, 8]. Bu problemin çözümü için X-ışını görüntüleri üzerinde derin öğrenme temelli Evrişimsel Sinir Ağı (ESA) mimarileri kullanılabilir.

Derin öğrenmede (DÖ) her şey verilerle başlar. Biyomedikal veriler büyük ama aynı zamanda son derece heterojen olabilir. Derin öğrenme yöntemlerinin biyomedikal verilere uygulanmasının merkezinde, özellikle değişken boyutlu yapılandırılmış veriler olmak üzere farklı veri türlerini işleyebilen yöntemlerin geliştirilmesi yer alır [9]. Son zamanlarda DÖ modelleri tıbbi görüntü sınıflandırma da dâhil olmak üzere birçok alanda [10-12] başarılı bir şekilde uygulanmış [13-15] ve makine öğrenme yöntemlerinin yerini almaya başlamıştır [16]. Ancak, X-ışını görüntülerinden omuz implantlarının saptanması iyi bir şekilde çalışılmış ya da incelenmiş bir problem değildir [2].

İmplant modelini veya üreticisini makine öğrenmesi yöntemleri ile sınıflandıran çalışmalar çok azdır. Omuz implantını sınıflandıran iki çalışma göze çarpmaktadır. Urban vd. [2], 4 farklı implant üreticisini 597 adet omuz implantı X-ışını görüntüsünü kullanarak sınıflandırmışlardır. Sınıflandırma işleminde, önceden eğitilmiş 6 farklı ESA mimarisi (VGG16, VGG19, ResNet-50, ResNet-152, NasNet ve DenseNet-201) ve geleneksel makine öğrenmesi yöntemlerini kullanmışlardır. En yüksek sınıflandırma doğruluğunu 10-kat çapraz doğrulama ile NasNet ESA mimarisinde elde etmişlerdir. Yi vd. [4], 5 farklı omuz implant modelini 482 X-ışını görüntüsü üzerinde

sınıflandırmışlardır. Sınıflandırma işleminde ResNet önceden eğitilmiş ESA modelini kullanmışlardır. Bu çalışmanın en büyük sınırlılığı 5 farklı implant modelini tek bir ESA modeli ile sınıflandırmak yerine her bir implant için ayrı bir ESA modeli geliştirerek ikili sınıflandırma yapmalarıdır. Omuz implantı dışında kalça ve diz implantlarını da derin öğrenme ile sınıflandıran çalışmalar da vardır. Yi vd. [8], iki farklı diz implantı modelini 274 X-ışını görüntüsü üzerinde ResNet ESA mimarisi ile sınıflandırmışlardır. Ghose ve ark. [17], 6 farklı ortopedik diz implantı modelini 878 X-ışını görüntüsü üzerinden 8 farklı önceden eğitilmiş ESA mimarisi kullanarak sınıflandırmışlardır. En yüksek sınıflandırma doğruluğunu MobileNetV2 mimarisinden elde etmişlerdir. Borjali ve ark. [6], ise 3 farklı total kalça protezi implantını sınıflandırmışlardır. Sınıflandırma işlemini 252 kalça protezi X-ışını görüntüleri üzerinde DenseNet-201 önceden eğitilmiş ESA ile gerçekleştirmişlerdir.

Bu çalışmadaki amaç X-ışını görüntülerinden omuz implantlarını YOLOV3 (You Only Look Once) nesne tespit algoritması ve önceden eğitilmiş son teknoloji ESA mimarilerini (DenseNet201, DenseNet169, InceptionV3, NasNetLarge, VGG16, VGG19, Resnet50) birleştirerek kademeli modeller vasıtasıyla üreticiye göre sınıflandırmak ve bu mimarilerin sınıflandırma performanslarını karşılaştırmaktır. Çalışmanın ana katkıları aşağıdaki gibidir:

- Omuz implantını sınıflandırmak için önceki çalışmalarda kullanılmayan yeni bir kademeli derin öğrenme modeli önerilmektedir.
- Literatürde benzer veri setini kullanarak sınıflandırma yapan çalışmadan [2] daha yüksek sınıflandırma doğruluğu elde edilmektedir.
- YOLOV3 tespit algoritması ile implantın baş bölgesine odaklanmanın sınıflandırma doğruluğunu artırdığı ortaya konulmaktadır.
- 7 farklı ESA modeli hem YOLOV3 algoritması çıkışı hem de ham X-ışını görüntüleri ile beslenerek sonuçlar karşılaştırmalı olarak sunulmaktadır. Ayrıca geleneksel makine öğrenmesi yöntemleri topluluk öğrenme yöntemi ile birleştirilerek sonuçlar karşılaştırılmaktadır.

2. MATERYAL VE METODLAR (MATERIAL AND METHODS)

Bu bölümde YOLOv3 ile implantların baş bölgesinin tespit edilmesi, YOLOv3 modelinin önceden eğitilmiş ESA modelleri ile birleştirilerek kademeli modellerin oluşturulması, modellerin eğitilmesi ve parametreleri, kullanılan omuz implantı X-ışını görüntüsü veri seti ve modellerin değerlendirilmesinde kullanılan performans metrikleri açıklanmaktadır.

2.1. Veri Seti (DataSet)

Bu çalışmada kullanılan veri seti Urban vd.'nin [2] çalışmalarında kullandığı omuz implantı X-ışını

görüntülerinden elde edilmiştir. Urban vd. [2], bu veri setindeki görüntülerin bazılarını Washington Üniversitesi'nin omuz web sitesinden, diğerlerini ise bireysel cerrahlardan ve üreticilerden elde etmişlerdir. Veri seti farklı hastalardan alınan dört üreticinin 16 farklı modeline ait 597 omuz implantı X-ışını görüntülerinden oluşmaktadır. Bu görüntülerin 83'ü Cofield, 294'ü Depuy, 71'i Tornier, ve 149'u ise Zimmer üreticisi tarafından üretilen implantlardır. Veri setindeki bazı örnek X-ışını görüntüleri Şekil 1'de gösterilmektedir. Bunun yanı sıra, veri setinin bazı dezavantajları vardır: (i) X-ışını görüntüleri düşük ve değişken görüntü çözünürlüğüne sahiptir. Birçoğu 250x250 piksel çözünürlüğündedir. (ii) Görüntülerin en boy oranları farklılık göstermektedir. (iii) Düşük görüntü kontrastı vardır ve üreticiye göre sınıflar dengeli dağılmamıştır. Tüm bu dezavantajlar modellerin sınıflandırma performansını büyük ölçüde etkilemektedir.

2.2. Önerilen Modeller (Proposed Models)

X-ışını görüntülerinden omuz implantı üreticisini sınıflandırmak için iki farklı yöntem önerilmiştir. Bu yöntemler Şekil 2'de sunulmuştur. Birinci yöntemde DenseNet201, DenseNet-169 [18], Inception V3 [19], NasnetLarge [20], VGG-16, VGG-19 [21], Resnet50 [22] önceden eğitilmiş ESA modelleri YOLOv3 tespit algoritması ile beslenerek kademeli modeller oluşturulmuştur. Birinci aşamada, YOLOv3 tespit algoritması implantların baş bölgesini tespit etmek amacıyla önceden etiketlenmiş X-ışını görüntüleriyle eğitilmiştir. İkinci aşamada, eğitilmiş YOLO algoritmasına X-ışını görüntüleri giriş olarak verilerek implantların baş bölgesi tespit edilmiştir. Üçüncü aşamada ise tespit edilen baş bölgesi kırılarak önceden eğitilmiş ESA modellerine giriş olarak verilmiş, böylece eğitim ve test işlemleri gerçekleştirilmiştir. İkinci yöntemde ise birinci yöntemde kullanılan önceden eğitilmiş ESA mimarileri, veri setindeki ham X-ışını görüntüleri ile eğitilmiş ve test edilmiştir. Bunun yanı sıra geleneksel makine öğrenmesi yöntemlerinin veri


seti üzerindeki sınıflandırma performansı da test edilmiştir. Bunun için DenseNet201 mimarisinin "avg_pool" isimli havuzlama katmanının (çıkış katmanından önceki katman) çıkış verisi elde edilmiştir. Bu katmandan elde edilen öznitelikler, Rastgele Orman (RF), Aşırı Gradyan Artırma, K-En Yakın Komşu ve Çok Katmanlı Algılayıcı yöntemlerinin oylama yöntemi ile birleştirilmesinden oluşan topluluk sınıflandırıcıya giriş olarak verilerek sınıflandırma işlemi gerçekleştirilmiştir. Tüm yöntemlerin sınıflandırma performansları karşılaştırmalı olarak sonuçlar ve tartışmalar bölümünde sunulmuştur. Böylece farklı ESA modellerinin, kademeli modellerin ve geleneksel makine öğrenmesi modellerinin implant veri seti üzerindeki sınıflandırma performansları ortaya konulmuştur.

2.3. Modellerin Eğitilmesi (Training of Models)

YOLO ve ESA modelleri Python programlama dilinde Tensorflow ve Keras Kütüphanesi kullanılarak oluşturulmuştur. ESA temelli modellerin grafik işlemci birimi (GİB) kullanılmadan eğitilmesi çok zor ve uzun bir süreçtir. Bu nedenle modellerin eğitim ve test işlemi için Google Research'ün bir ürünü olan Google Colab üzerinde T4 ve P100 GİB'ler kullanılarak gerçekleştirilmiştir. Aşağıdaki başlıklarda YOLO ve ESA modellerinin eğitilmesi ve bu süreçte kullanılan model parametreleri ayrıntılı olarak sunulmaktadır.

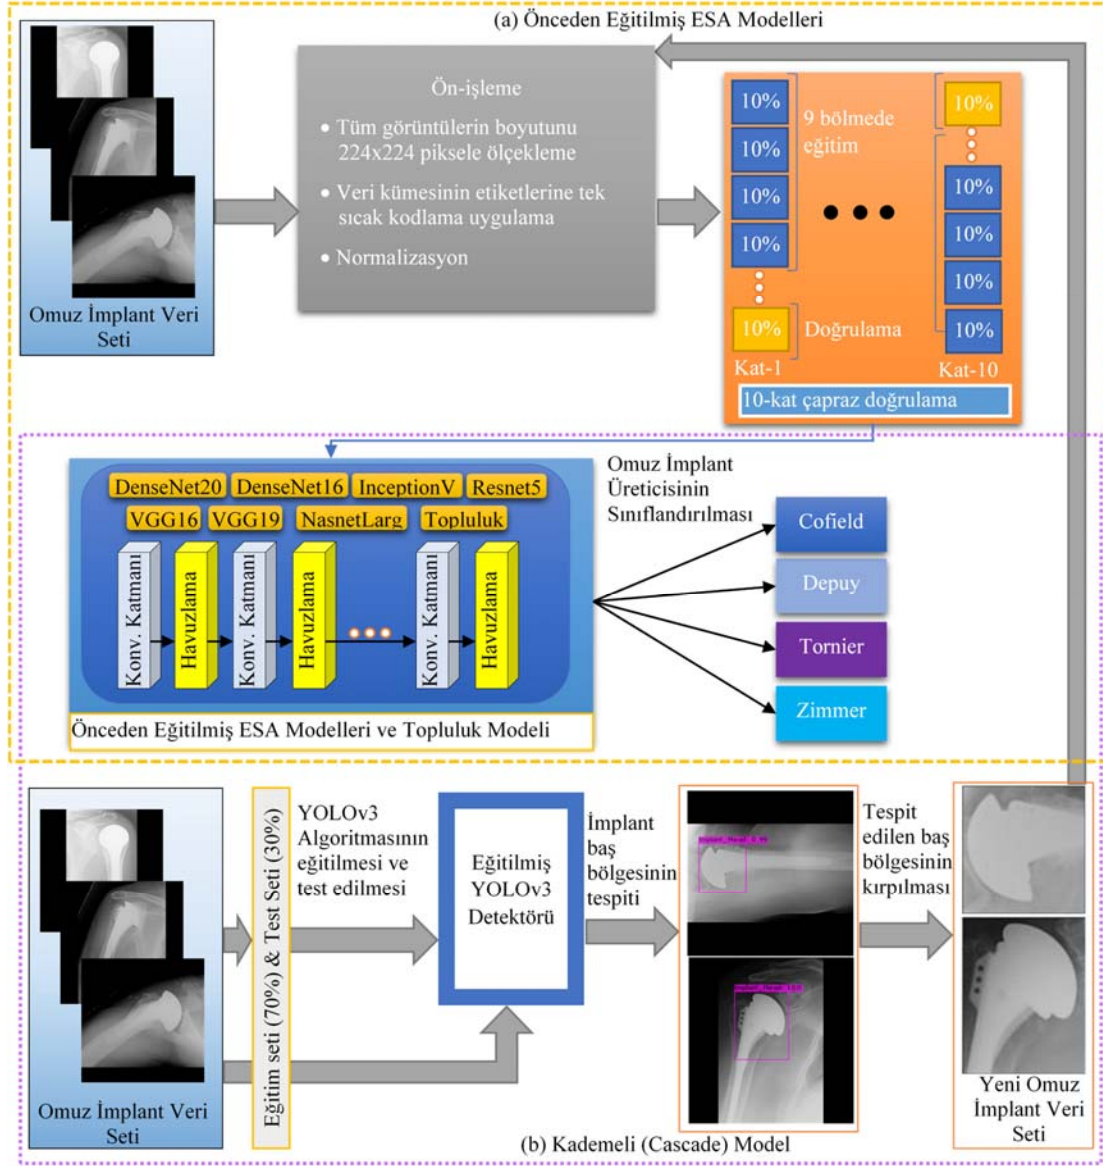
2.3.1. YOLOv3 tespit algoritmasının eğitilmesi ve implant baş bölgesinin otomatik kırılması (Training of YOLOv3 detection algorithm and automatic cropping of implant head area)

YOLO, ESA temelli nesne tespit algoritmasıdır. Bu algoritma nesne algılamayı, görüntü piksellerinden sınırlayıcı kutu koordinatlarına ve sınıf olasılıklarına kadar tek bir regresyon problemi olarak yeniden çerçevlendirmektedir [23]. Bu çalışmada implantın baş bölgesini tespit etmek için YOLOv3 versiyonu kullanılmıştır. YOLOv3, diğer algılama yöntemlerinden



Şekil 1. Veri setindeki dört farklı üreticiye ait örnek omuz implantı X-ışını görüntüleri. Soldan sağa: Cofield, Depuy, Tornier, Zimmer

(Sample shoulder implant X-ray images from four different manufacturers in the dataset. Left to right: Cofield, Depuy, Tornier, Zimmer)



Şekil 2. Önerilen yöntemlerin mimarisi: (a) Önceden eğitilmiş ESA modelleri (b) Kademeli modeller
(Architecture of proposed methods: (a) pre-trained CNN models (b) cascade models)

önemli ölçüde daha hızlı çalışır. Özellik çıkarma için DarkNet-53 ESA mimarisini kullanır. DarkNet-53, 3×3 ve 1×1 konvolüsyonel katmanları kullanır ve 53 katmana sahiptir [24].

YOLOv3 modelinin implant baş bölgesini tespit edebilmesi için eğitilmesi gerekmektedir. Bu eğitim işlemi için implant X-ışını görüntüleri üzerinde baş bölgesi etiketlenmelidir. Bunun için açık kaynak kodlu LabelImg (<https://github.com/tzutalin/labelImg>) grafik görüntü açıklama aracı kullanılmıştır. Bu araç vasıtasıyla her görüntü için bir metin dosyası oluşturulmuş. Bu dosyaya, etiketlenen X-ışını görüntülerinin Şekil 3'de gösterilen yükseklik (iY), genişlik (iG) ve implant baş bölgesinin konum bilgisini veren (X_0, Y_0, X_1, Y_1) koordinatları kaydedilmiştir. Bunun yanı sıra, oluşturulan veri setini, YOLOv3 mimarisine uygun

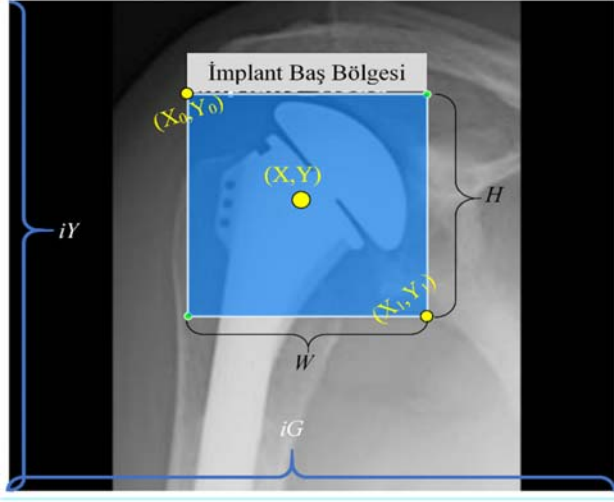
hale getirmek için normalizasyon işlemi yapılmıştır. Böylece görüntü içerisindeki etiketli implant baş bölgesinin, merkez nokta koordinatları (X, Y) , yükseklik (H) ve genişlik (W) bilgileri Eş. 1 ve Eş. 2'deki [25] gibi elde edilmiştir.

$$X = \frac{X_1 + X_0}{2} x \frac{1}{iG}, \quad Y = \frac{Y_1 + Y_0}{2} x \frac{1}{iY} \quad (1)$$

$$W = (X_1 - X_0) x \frac{1}{iG}, \quad H = (Y_1 - Y_0) x \frac{1}{iY} \quad (2)$$

Ön işlemler tamamlandıktan sonra veri seti, %70 eğitim ve %30 test olmak üzere rastgele ikiye ayrılarak YOLOv3 algoritmasının eğitim ve test işlemi gerçekleştirilmiştir. Model performansının değerlendirilmesinde Birlik üzerinde Kesişme (IoU) ve ortalama hassasiyet (mAP) metrikleri kullanılmıştır. IoU nesne algılamada model başarısını ortaya

koymak için önemli bir metriktir. Hedef sınırlayıcı kutu ile tahmin edilen çıktı arasındaki benzerlik oranını hesaplar [26]. Tahmin edilen değer ile hedef referans değeri arasında kalan bölgenin tüm bölgeye bölümü ile Eş. 3'deki gibi hesaplanır [25, 26].



Şekil 3. İmplant X-ışını görüntülerinin baş bölgesinin etiketlenmesi (Labeling of the head area of Implant X-ray images)

$$IoU = \frac{\text{Hedef ve tahmin edilen sınırlayıcı kutu alanlarının kesişimi}}{\text{Hedef ve tahmin edilen sınırlayıcı kutu alanlarının birleşimi}} \quad (3)$$

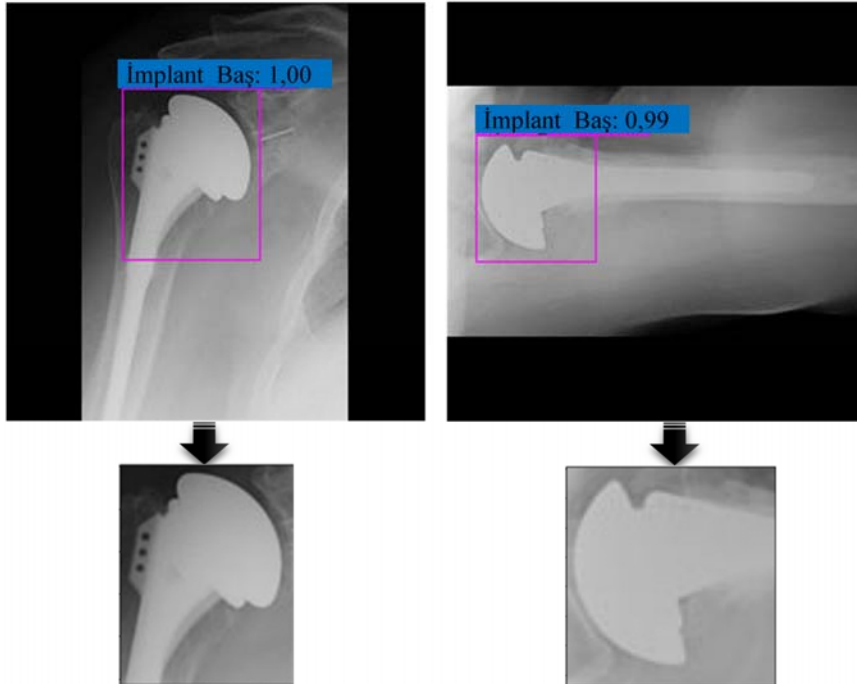
mAP ise kesinlik, duyarlılık, F1-skoru ve IoU gibi değerlerin tek bir noktadan değerlendirilmesini sağlar. Eş. 4'deki gibi hesaplanmaktadır [25].

$$mAP = \int_0^1 P(R)dR \quad (4)$$

mAP değeri hesaplanırken belirli bir IoU eşik değerinin üstündeki sınırlayıcı kutular ile işlem yapılır. Eşik değeri 0,50 olarak alındığında test verileri için mAP değeri %99,99 ve ortalama IoU değeri ise %81,40 olarak hesaplanmıştır. Bu performans değerlerine göre implantların baş bölgesinin yüksek doğrulukla tespit edildiği söylenebilir. Bu nedenle, bu performans metrikleri için elde edilen ağırlıklar kaydedilmiştir. Sonrasında veri setindeki X-ışını görüntülerinin hepsi, eğitilmiş YOLOv3 algoritmasına giriş olarak verilmiş ve implant baş bölgesi otomatik tespit edilmiştir. Tespit edilen implant baş bölgesi OpenCv ile kırılarak ESA mimarilerine giriş olarak verilmiş ve kademeli modeller oluşturulmuştur. Şekil 4'te implant baş bölgesi tespit edilen ve baş bölgesi kırılan X-ışını görüntüleri gösterilmektedir.

2.3.2. ESA modellerinin eğitilmesi (Training CNN models)

ESA modellerinin eğitiminde öncelikle X-ışını görüntüleri 224x224x3 boyutuna getirilmiştir. Sonrasında her giriş verisi 255'e bölünerek normalizasyon işlemi gerçekleştirilmiştir. Ayrıca çıkış sınıf etiketleri üzerinde tek sıcak kodlama (one hot encoding) işlemi uygulanmıştır. Eğitim ve test işleminde 10-kat çapraz doğrulama yöntemi kullanılmıştır. Hem kademeli modellerin hem de bireysel olarak kullanılan önceden eğitilmiş ESA modellerinin bazı eğitim parametreleri Tablo 1'de gösterilmektedir. Bu parametrelerden en önemli olanı optimizasyon algoritmasıdır. Bu algoritma öğrenme algoritması ve milyonlarca hatta milyarlarca parametrenin nasıl



Şekil 4. İmplant baş bölgesi tespit edilen ve kırılan örnek görüntüler (Sample images in which the implant head area is detected and cropped)

güncellendiğini tanımlar [27]. Modelleri eğitirken optimizasyon algoritmalarını seçmek zordur [28]. Bu nedenle Adam, Adadelta, Sgd, Rmsprop, Adamax ve Nadam optimizasyon algoritmaları denenmiş ve her bir ESA modeline göre en iyi sınıflandırma performansını veren algoritmalar tabloda sunulmuştur. Öğrenme performansını etkileyen diğer önemli bir parametre öğrenme oranıdır (learning rate). Öğrenme oranı için büyük değerler seçilirse, tahminin yerel çözümler arasında dolaşması diğer bir deyişle osilasyon yaşaması mümkündür. Küçük değerler seçilirse öğrenme zamanı artmaktadır [29]. ESA modelleri eğitilirken farklı öğrenme oranı değerleri denenerek en iyi sınıflandırma performansı elde edilmeye çalışılmıştır. Temel Model Eğitilebilir (Base Model Trainable) parametresi ise evrişim ve havuzlama katmanlarıyla ilgilidir. Bu parametre “False” ise bu katmanlar dondurulmakta, eğitim işlemi gerçekleştirilmemekte ve “imagenet” ağırlıkları olduğu gibi kullanılmaktadır. DenseNet201, DenseNet169 ve Inception V-3 ESA modellerinde bu parametre değeri “True” olarak ayarlanırken diğerlerinde “False” olarak ayarlanmıştır. Ayrıca yitim fonksiyonu olarak tüm modellerde kategorik çapraz entropi (categorical cross entropy) kullanılmıştır. Bunun yanı sıra, eğitim işlemi, DenseNet-169 ve Inception V-3 ESA modellerinde 70 epok’da tamamlanırken diğerlerinde 50 epok’da tamamlanmıştır.

Modellerin eğitimindeki diğer bir önemli parametre aktivasyon fonksiyonudur. ESA modellerindeki son katman çıkış katmanıdır ve aktivasyon fonksiyonu Softmax’dır. Bu katmandaki nöron sayısı dört olarak ayarlanmıştır. Çıkış

katmanı dışındaki katmanlarda aktivasyon fonksiyonu olarak Doğrultulmuş lineer birim (rectified linear unit-RELU) kullanılmıştır. Relu ve Softmax aktivasyon fonksiyonları sırasıyla Eş. 5 ve 6’daki gibi tanımlanmaktadır. Eş. 5’deki x_j ; son katmandaki j’ninci çıktıyı ifade etmektedir [30, 31].

$$\text{softmax}(x_i) = \frac{\exp(x_i)}{\sum_k \exp(x_k)} \quad (5)$$

$$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases} \quad (6)$$


En yüksek sınıflandırma performansına sahip kademeli DenseNet201 modelinin kat-2 adımına ait eğitim kaybı ve doğruluk eğrileri Şekil 5’de gösterilmektedir. Diğer modellere ait eğriler de hesaplanmış ancak çalışmanın okunurluğunu artırmak için çalışmaya eklenmemiştir. Şekil 5’de de görüldüğü gibi model hızlı ve kararlı bir eğitim süreci göstermiştir. 10 epok’a yakın bir seviyede yitim değeri sıfıra yaklaşmış sonrasında ufak bir pik yapıp tekrar 20 epok’da sıfıra yakın bir seviyede devam etmiştir. Benzer bir durum doğruluk eğrisinde de izlenmektedir.

2.3.4. Performans metrikleri (Performance metrics)

Modeller, kesinlik (K), duyarlılık (D), F1-puanı (F1) ve doğruluk metriklerine göre değerlendirilmiştir. Bu metriklerin matematiksel ifadeleri aşağıda verilmektedir. Bu eşitliklerde; DP: Doğru Pozitif, DN: Doğru negatif, YP: Yanlış Pozitif, YN: Yanlış Negatif dir.

Tablo 1. ESA modellerinin parametreleri (Parameters of CNN models)

ESA Modelleri	Optimizasyon Algoritması	Öğrenme Oranı	Temel Model Eğitilebilir	Epok	Aktivasyon Fonksiyonu	Yitim Fonksiyonu
DenseNet201	SGD	0,1	Doğru	50		
DenseNet169	SGD	0,1	Doğru	70		
Inception V-3	SGD	0,1	Doğru	70		
NasNetLarge	Adamax	0,001	Yanlış	50	Relu Softmax	Kategorik Çapraz Entropi
VGG-16	Adam	0,001	Yanlış	50		
VGG-19	Adam	0,01	Yanlış	50		
Resnet50	Adam	0,01	Yanlış	50		
Topluluk	RMSprop	0,0001	-	-	-	



Şekil 5. Kademeli DenseNet201 modelinin Fold-2 adımı için elde edilen eğitim kaybı ve doğruluk eğrileri (Training loss and accuracy curves obtained for the Fold-2 step of the cascade DenseNet201 model)

- **Kesinlik:** Bu parametre tahmin edilen pozitiflerdeki doğru pozitiflerin oranını ölçer. Bu nedenle DP ve YP değerlerine bağlıdır. Eş. 7'deki gibi hesaplanmaktadır [32].

$$K = DP / (DP + YP) \quad (7)$$

- **Duyarlılık:** Duyarlılık, model tarafından doğru bir şekilde sınıflandırılan gerçek pozitiflerin oranıdır [33]. Duyarlılık tüm pozitif örnekler için Eş. 8'deki gibi hesaplanmaktadır.

$$D = DP / (DP + YN) \quad (8)$$

- **F1-Puanı:** F1 puanı, modelin kesinlik ve duyarlılık parametrelerini birleştirerek modelin tümüne ait doğruluk değerini veren bir ölçüdür. Hassaslık ve duyarlılık değerlerinin harmonik ortalaması olarak Eş. 9'daki gibi hesaplanmaktadır [25].

$$F1 = 2x(KxD) / (K+D) \quad (9)$$

- **Doğruluk:** Eş. 10'daki gibi hesaplanmaktadır [31].

$$Doğruluk = (DP+DN) / (DP+DN+YP+YN) \quad (10)$$

2.4. Yoğun Bağlantılı Sinir Ağları (Densely Connected Neural Network)

Çalışma kapsamında en iyi sınıflandırma performansı yoğun bağlantılı sinir ağı olan DenseNet201 modelinde elde edildiğinden dolayı bu modelin mimarisinin sunulması önemlidir. Yoğun bağlantılı sinir ağları, katmanlar arası geçişlerde görüntü özelliğindeki kayıpları en aza indirmek amacıyla Huang vd. [18] tarafından geliştirilmiştir. Genel ağ mimarisi Şekil 6'da gösterilmektedir. Ağdaki katmanlar arasında maksimum bilgi akışını sağlamak için, tüm katmanlar (eşleşen özellik haritası boyutlarıyla) ileri beslemeli olarak doğrudan birbirine bağlanmıştır. Böylece

her katman önceki tüm katmanlardan ek girdileri alarak kendi özellik haritalarını sonraki tüm katmanlara aktarmıştır. Bu durum Eş. 11'deki gibi ifade edilmektedir. Burada $[X_0, X_1, \dots, X_{l-1}]$; 0, ..., l-1 katmanlarında üretilen özellik haritalarının birleştirilmesini ifade eder.


$$X_l = H_l[X_0, X_1, \dots, X_{l-1}] \quad (11)$$

H_l ise bu özellik haritalarını birleştiren bir bileşke fonksiyondur ve üç ardışık işlemin (YN-Relu-Konv.) birleşimi şeklinde tanımlanır. Bu ardışık işlemler sırasıyla, yığın normalizasyonu (YN), RELU [6] ve 3×3 konvolüsyon şeklindedir.

3. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Bu bölümde DenseNet201, DenseNet-169, InceptionV3, NasnetLarge, VGG-16, VGG-19, Resnet50 ve Topluluk mimarilerinin bireysel ve kademeli modellerdeki omuz implant üreticisini sınıflandırma performansları ayrıntılı olarak sunulmaktadır. Modeller hakkında genel bir değerlendirme yapmak amacıyla tüm modeller için üst üste binen (overlapped) karmaşıklık matrisi (KM) oluşturulmuş ve bu matris kullanılarak modelin genelini temsil eden performans metrikleri (D, K, F1-puanı ve doğruluk) hesaplanmıştır. Model performanslarının karşılaştırılmasında üst üste binen KM'den hesaplanan metriklerin kullanılması genel performansların ortaya konulması açısından önemlidir. Üst üste binen KM, her katta elde edilen KM'lerin toplanması ile oluşturulmaktadır [34].

Modellerin sınıflandırma performansları Tablo 2'de sunulmaktadır. Kademeli DenseNet201 modeli %84,76 ortalama sınıflandırma doğruluğu ile en yüksek sınıflandırma performansına sahiptir. Bu model, Cofield üreticisini %77,10 (D=0,7710), Depuy üreticisini %93,20 (D=0,9320), Tornier üreticisini %73,24 (D=0,7324) ve



Şekil 6. Yoğun bağlantılı sinir ağlarının genel mimarisi [18] (General architecture of densely connected neural networks [18])

Tablo 2. Kademeli ve bireysel modellerin D, K, F1-puanı ve doğruluk değerleri
(R, P, F1-score and acc values of cascade and individual models)

Modeller	İmplant Üreticisi	Performans Sonuçları (%)				Bireysel Modeller			
		D	K	F1	Doğruluk	D	K	F1	Doğruluk
<i>DenseNet201</i>	Cofield	77,10	81,01	79,01		66,27	79,71	72,37	
	Depuy	93,20	88,10	90,58		89,80	79,52	84,35	
	Tornier	73,24	81,25	77,04		59,15	72,41	65,12	
	Zimmer	77,85	81,12	79,45		65,10	70,29	67,60	
	<i>Ortalama</i>	<i>80,35</i>	<i>82,87</i>	<i>81,52</i>	<i>84,76</i>	<i>70,08</i>	<i>75,48</i>	<i>72,36</i>	<i>76,73</i>
<i>DenseNet169</i>	Cofield	73,49	73,49	73,49		63,86	85,48	73,10	
	Depuy	90,82	86,13	88,41		87,07	79,01	82,85	
	Tornier	71,83	82,26	76,69		59,15	62,69	60,87	
	Zimmer	73,15	76,76	74,91		65,77	68,06	66,89	
	<i>Ortalama</i>	<i>77,32</i>	<i>79,66</i>	<i>78,38</i>	<i>81,74</i>	<i>68,96</i>	<i>73,81</i>	<i>70,93</i>	<i>75,23</i>
<i>InceptionV3</i>	Cofield	77,11	72,73	74,85		65,06	69,23	67,08	
	Depuy	92,52	83,69	87,88		87,07	76,42	81,40	
	Tornier	66,20	74,60	70,15		56,34	72,73	63,49	
	Zimmer	65,10	80,17	71,85		55,70	64,34	59,71	
	<i>Ortalama</i>	<i>75,23</i>	<i>77,80</i>	<i>76,18</i>	<i>80,42</i>	<i>66,04</i>	<i>70,68</i>	<i>67,92</i>	<i>72,54</i>
<i>Topluluk</i>	Cofield	59,04	77,78	67,12		20,48	26,15	22,97	
	Depuy	93,54	76,39	84,10		86,73	53,24	65,98	
	Tornier	47,89	87,18	61,82		2,82	33,33	5,19	
	Zimmer	67,79	74,81	71,13		13,42	42,55	20,41	
	<i>Ortalama</i>	<i>67,07</i>	<i>79,04</i>	<i>71,04</i>	<i>76,88</i>	<i>30,86</i>	<i>38,82</i>	<i>28,64</i>	<i>49,27</i>
<i>NasnetLarge</i>	Cofield	57,83	75,00	65,31		36,14	54,55	43,48	
	Depuy	86,39	78,40	82,20		86,05	68,56	76,32	
	Tornier	52,11	72,55	60,66		39,44	59,57	47,46	
	Zimmer	69,80	65,82	67,75		48,32	57,14	52,36	
	<i>Ortalama</i>	<i>66,53</i>	<i>72,94</i>	<i>68,98</i>	<i>74,21</i>	<i>52,49</i>	<i>59,96</i>	<i>54,91</i>	<i>64,14</i>
<i>VGG16</i>	Cofield	51,81	69,35	59,31		50,60	46,67	48,55	
	Depuy	80,95	73,01	76,77		63,95	64,16	64,05	
	Tornier	45,07	50,79	47,76		15,49	33,33	21,15	
	Zimmer	54,36	55,48	54,92		43,62	35,91	39,39	
	<i>Ortalama</i>	<i>58,05</i>	<i>62,16</i>	<i>59,69</i>	<i>66,00</i>	<i>43,42</i>	<i>45,02</i>	<i>43,29</i>	<i>51,25</i>
<i>VGG19</i>	Cofield	60,24	60,98	60,61		43,37	40,91	42,11	
	Depuy	71,43	75,27	73,30		42,52	60,10	49,80	
	Tornier	49,30	37,23	42,42		38,03	19,42	25,71	
	Zimmer	45,64	47,89	46,74		38,26	35,19	36,66	
	<i>Ortalama</i>	<i>56,65</i>	<i>55,34</i>	<i>55,77</i>	<i>60,82</i>	<i>40,55</i>	<i>38,91</i>	<i>38,57</i>	<i>40,99</i>
<i>Resnet50</i>	Cofield	25,30	41,18	31,34		31,33	37,14	33,99	
	Depuy	90,14	52,89	66,67		59,18	53,37	56,13	
	Tornier	4,22	21,43	7,05		14,08	15,38	14,71	
	Zimmer	7,38	35,48	12,22		31,54	34,56	32,98	
	<i>Ortalama</i>	<i>31,76</i>	<i>37,75</i>	<i>29,32</i>	<i>50,24</i>	<i>34,03</i>	<i>35,11</i>	<i>34,45</i>	<i>43,02</i>

Zimmer üreticisini %77,85 (D=0,7785) oranında doğru sınıflandırmaktadır. En yüksek doğru sınıflandırma oranı Depuy üreticisine aittir. Bunun sebebi Depuy üreticisine ait implant X-ışını görüntü sayısının yaklaşık 3 kat daha fazla olmasıdır. Diğer üreticilerde de yine implant X-ışını görüntü sayısına göre sınıflandırma performansı artmaktadır. Kademeli DenseNet201 modelinin üst üste binen KM'si Şekil 7'de gösterilmektedir. Model, Cofield için 64 doğru 19 yanlış, Depuy için 274 doğru 20 yanlış, Tornier için 52 doğru 19 yanlış ve Zimmer için 116 doğru 33 yanlış sınıflandırma yapmaktadır.

Bunun yanı sıra YOLO ile beslenmeyen bireysel model performanslarına bakıldığında yine en yüksek sınıflandırma performansı %76,73 doğruluk değeri ile DenseNet201 modeline aittir. Ancak bu modelin sınıflandırma doğruluğu YOLO ile beslenen kademeli DenseNet201 modeline göre bir hayli düşüktür. Aynı durum diğer modellerde de söz konusudur. Yani ESA modellerinin YOLO ile beslenerek kademeli modeller oluşturulması sınıflandırma performansını kayda değer bir ölçüde artırmıştır. Hem kademeli hem de bireysel modellerde en iyi ikinci sınıflandırma performansı DenseNet169 modellerine aittir.

Bu modellerin sınıflandırma doğruluğu sırasıyla %81,74 ve %72,29 şeklindedir. DenseNet modelleri bu veri seti üzerinde diğer modellere göre daha iyi bir sınıflandırma performansı göstermiştir.

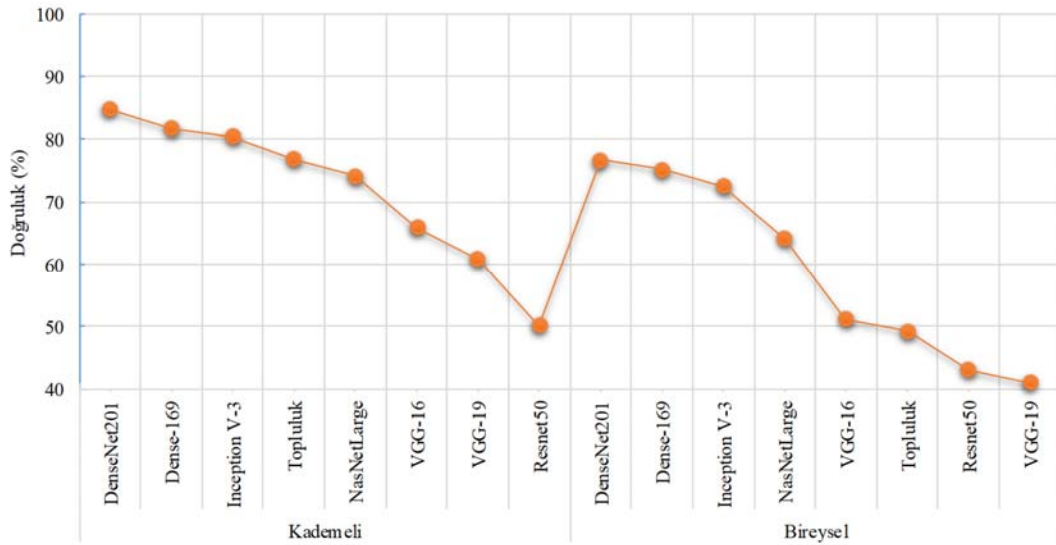
		Tahmin Değerleri			
		Cofield	Depuy	Tornier	Zimmer
Gerçek Değerler	Cofield	64	8	1	10
	Depuy	5	274	4	11
	Tornier	2	11	52	6
	Zimmer	8	18	7	116

Şekil 7. Kademeli DenseNet201 modelinin üst üste binen karmaşıklık matrisi
(Overlapped complexity matrix of the cascade DenseNet201 model)

Kademeli ve bireysel modellerin sınıflandırma doğruluk değerleri karşılaştırmalı olarak Şekil 8'de gösterilmektedir. Modellerin sınıflandırma performansları kademeli modeller için büyükten küçüğe doğru DenseNet201 (doğruluk=0,8476), DenseNet169 (doğruluk=0,8174), InceptionV3 (doğruluk=0,8042), Topluluk (doğruluk=0,7688), NasnetLarge (doğruluk=0,7421), VGG16 (doğruluk=0,6600), VGG19 (doğruluk=0,6082) ve

Resnet50 (doğruluk=0,5024) şeklinde sıralanabilir. Bireysel modeller için ise DenseNet201 (doğruluk=0,7673), DenseNet169 (doğruluk=0,7523), InceptionV3 (doğruluk=0,7254), NasnetLarge (doğruluk=0,6414), VGG19 (doğruluk=0,5125), Topluluk (doğruluk=0,4927), Resnet50 (doğruluk=0,4302) ve VGG19 (doğruluk=0,4099) şeklindedir. Resnet50 ve VGG19 modelleri hem kademeli hem de bireysel modeller içinde en kötü sınıflandırma performansına sahiptir. Bunun yanı sıra, Topluluk modeli kademeli yapıda orta düzey bir sınıflandırma performansı gösterirken bireysel yapıda çok daha düşük bir sınıflandırma performansı göstermektedir. Topluluk modelinin YOLO ile beslenmesi sınıflandırma performansını diğer modellere kıyasla dikkate değer bir oranda artırmaktadır.

Daha öncede vurgulandığı üzere omuz implantı X-ışını resimleri üzerinde derin öğrenme uygulayarak sınıflandırma yapan çalışmalar çok azdır. Ancak yine de önceden eğitilmiş ESA modellerini kullanarak sınıflandırma yapan birkaç çalışma vardır. Bu çalışmanın sonuçlarını diğer çalışmalarla karşılaştırmak önem arz etmektedir. Bu çalışmada, Urban vd. [2] tarafından kullanılan veri seti kullanılmıştır. Urban ve ark., önceden eğitilmiş 6 farklı ESA modeli ile sınıflandırma yapmışlar ve en yüksek 0,80 sınıflandırma doğruluğu elde etmişlerdir. Ancak bu çalışmada YOLO tespit algoritmasıyla beslenen kademeli modellerden üç tanesi Urban ve ark.'nın çalışmasında elde edilen sınıflandırma doğruluğundan daha yüksek bir doğruluk elde etmiştir. Bu sonuç, önceden eğitilmiş ESA mimarilerinin YOLO ile beslenerek kademeli modeller haline getirilmesinin sınıflandırma performansını artırdığını doğrulamaktadır. Diğer bir çalışmada Yi vd. [4], ResNet önceden eğitilmiş ESA mimarisini kullanılarak beş farklı omuz implantını sınıflandırmışlardır. Elde ettikleri sınıflandırma doğruluğu 5 farklı model için 0,90, 0,94, 0,95, 0,98 ve 1'dir. Yi ve ark., bu çalışmadan daha yüksek sınıflandırma doğruluğu elde etmişlerdir. Ancak, beş farklı omuz implantını 5 çıkışlı bir tane ESA modeli ile



Şekil 8. Kademeli ve bireysel modellerin doğruluk değerlerine göre karşılaştırılması
(Comparison of cascade and individual models according to accuracy values)

sınıflandırmak yerine her bir implant için ikili sınıflandırma (Doğru-Yanlış) yapan 5 farklı ESA modeli geliştirmişlerdir. Bu da sınıflandırma performansının daha yüksek olmasını açıklamaktadır. Çünkü ikili sınıflandırmada model sadece bir üreticiye ait implant ile eğitilmekte ve verilen X-ışını görüntüsünün ilgili implant üreticisine ait olup olmadığının cevabını vermektedir. Bunun yanı sıra kullandıkları veri seti bu çalışmadan farklıdır. Bu sebeplerden dolayı çalışmalarını sınıflandırma performansı açısından doğrudan karşılaştırmak çok doğru olmayacaktır. Yapılan literatür taramasına göre bu iki çalışma dışında omuz implantı ile ilgili sınıflandırma yapan başka çalışma bulunmamaktadır. Ancak kalça ve diz implantlarını derin öğrenme ile sınıflandıran birkaç çalışma vardır. Yi ve ark. [8], iki farklı diz implantını ResNet ESA mimarisi ile yüksek doğruluk oranıyla sınıflandırmışlardır. Burada yine ikili sınıflandırıcı kullanılmıştır. Ghose vd. [17], 6 farklı ortopedik diz implantını 0,96 doğruluk değerinde sınıflandırmışlardır. Sınıflandırma işleminde 8 farklı önceden eğitilmiş ESA mimarisi kullanmışlar ve en yüksek sınıflandırmayı MobileNetV2 mimarisinde elde etmişlerdir. Borjali vd. [6], 3 farklı total kalça protezi implantını DenseNet-201 önceden eğitilmiş ESA mimarisi ile 1 doğruluk değeri ile sınıflandırmışlardır.

Omuz implantı ve diğer implantlar üzerinde yapılan önceki çalışmaların hepsi önceden eğitilmiş ESA mimarilerini doğrudan kullanmışlardır. Ancak çalışmamızda, ESA mimarilerinin doğrudan kullanılmasının yanı sıra YOLO ile birleştirilerek kademeli model olarak kullanılması ve sınıflandırma performansını artırdığının ortaya konulması gelecekte bu alanda yapılacak çalışmalara yön gösterici olacaktır. Çalışmamızın en büyük sınırlılığı veri seti ile ilgilidir. Daha önce de vurgulandığı üzere X-ışını görüntülerinin düşük ve değişken çözünürlükte olması, en boy oranlarının farklı ve düşük görüntü kontrastı olması ve üreticiye göre dengeli dağılması model performanslarını önemli ölçüde olumsuz etkilemiştir. Çalışmada önerilen kademeli modeller bu olumsuz özelliklerin olmadığı daha kaliteli bir veri seti üzerinde daha yüksek sınıflandırma performansı ortaya koyabilir.

4. SONUÇLAR (CONCLUSIONS)

Bu çalışmada önceden eğitilmiş 7 farklı ESA mimarisi ve bu ESA mimarilerinin YOLO ile beslendiği kademeli modeller vasıtasıyla X-ışını görüntülerinden dört farklı omuz implantı üreticisi tespit edilmiştir. Çalışmada en yüksek sınıflandırma performansı %84,76 doğruluk oranıyla YOLO ile beslenen DenseNet201 ESA kademeli modelinde elde edilmiştir. Bu sınıflandırma doğruluğu benzer veri setini kullanan diğer bir çalışmadan [2] daha yüksektir. Bunun yanı sıra, kademeli modellerin sınıflandırma performanslarının bireysel ESA mimarilerinden daha yüksek olduğu açıkça ortaya konulmuştur. Kademeli modeller implant X-ışını görüntülerine bir bütün olarak odaklanmak yerine YOLO ile tespit edilen ayırt edici kısımlarına odaklanmaktadır. Bu da sınıflandırma performansını artırmaktadır. Bu çalışmada önerilen kademeli model implant ile ilgili yapılacak gelecek

çalışmalar için ilham verici olabilir. Ayrıca, geleneksel makine öğrenmesi modellerini oylama yöntemiyle birleştiren topluluk modeli ise ESA mimarilerinin birçoğuna göre daha düşük sınıflandırma performansı ortaya koymuştur. Derin öğrenme yöntemlerini kullanarak implant üreticisini tespit etmek hem radyologlara hem de ortopedi cerrahlarına kararlarında yardımcı olabilir.

Gelecek çalışmalarda omuz implantları üzerine yeni veri setlerine ulaşılabılırsa daha geniş bir veri seti üzerinde YOLO, R-CNN ve Fast R-CNN gibi tespit algoritmaları ve mümkün olan bütün ESA mimarileri ile kademeli modeller oluşturulacak ve sınıflandırma performansları ortaya konulacaktır. Ayrıca otomatik kodlayıcı (autoencoder) derin öğrenme yöntemi ile X-ışını görüntüleri yeniden oluşturularak farklı katmanlardaki özellikler kullanılarak kademeli ESA modelleri eğitilecektir.

KAYNAKLAR (REFERENCES)

1. Biron, D.R., Sinha, I., Kleiner, J.E., et al., A Novel machine learning model developed to assist in patient selection for outpatient total shoulder arthroplasty, *The Journal of the American Academy of Orthopaedic Surgeons*, 28 (13), 580-585, 2020.
2. Urban, G., Porhemmat, S., Stark, M., Feeley, B., Okada, K., Baldi, P., Classifying shoulder implants in X-ray images using deep learning, *Computational and Structural Biotechnology Journal*, 18, 967-972, 2020.
3. McFarland, E.G., Sanguanjit, P., Tasaki, A., Keyurapan, E., Fishman, E.K., Fayad, L.M., The reverse shoulder prosthesis: A review of imaging features and complications, *Skeletal Radiology*, 35, 488-496, 2006.
4. Yi, P.H., Kim, T.K., Wei, J., et al., Automated detection and classification of shoulder arthroplasty models using deep learning, *Skeletal Radiology*, 49 (10), 1623-1632, 2020.
5. Malathy, C., Sharma, U., Naidu, C.M., Pratheebha, U.U., A new approach for recognition of implant in knee by template matching, *Indian Journal of Science and Technology*, 9 (37), 1-5, 2016.
6. Borjali, A., Chen, A.F., Muratoglu, O.K., Morid, M.A., Varadarajan, K.M., Detecting total hip replacement prosthesis design on plain radiographs using deep convolutional neural network, *Journal of Orthopaedic Research*, 38, 1465-1471, 2020.
7. Wilson, N.A., Jehn, M., York, S., Davis, C.M., Revision total hip and knee arthroplasty implant identification: Implications for use of unique device identification 2012 AAHKS member survey results, *Journal of Arthroplasty*, 29 (2), 251-255, 2014.
8. Yi, P.H., Wei, J., Kim, T.K., et al., Automated detection & classification of knee arthroplasty using deep learning, *Knee*, 27 (2), 535-542, 2020.
9. Baldi, P., Deep learning in biomedical data science, *Annual Review of Biomedical Data Science*, 1 (1), 181-205, 2018.
10. Shen, D., Wu, G., Suk, H.-I., Deep learning in medical image analysis, *Annu. Rev. Biomed. Eng.*, 19 (1), 221-248, 2017.

11. Maier, A., Syben, C., Lasser, T., Riess, C., A gentle introduction to deep learning in medical image processing, *Z. Med. Phys.*, 29 (2), 86-101, 2019.
12. Özdoğan, H., Üncü, Y.A., Şekerci, M., Kaplan, A., Estimations of level density parameters by using artificial neural network for phenomenological level density models, *Appl. Radiat. Isot.*, 169, 109583, 2021.
13. Özdoğan, H., Ali Üncü, Y., Karaman, O., Şekerci, M., Kaplan, A., Estimations of giant dipole resonance parameters using artificial neural network, *Appl. Radiat. Isot.*, 169, 109581, 2021.
14. Lundervold, A.S., Lundervold, A., An overview of deep learning in medical imaging focusing on MRI, *Z. Med. Phys.*, 29 (2), 102-127, 2019.
15. Danişman, T., Üncü, Y.A., Karaçaylı, D., et al., Predicting the location of the uterine cervical os from 2D images with CNN, *J. Eng. Sci. Des.*, 8 (5), 52-57, 2020.
16. Yıldız O., Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 2241-2260, 2019.
17. Ghose, S. , Datta, S. , Batta, V. , Malathy, C., Gayathri, M., Artificial Intelligence based identification of Total Knee Arthroplasty Implants, 2020 3rd International Conference on Intelligent Sustainable Systems (ICISS), Thoothukudi-India, 302-307, 3-5 December, 2020.
18. Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q., Densely connected convolutional networks, *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, Honolulu-USA*, 2261-2269, 21-26 July, 2017.
19. Szegedy, C., Liu, W., Jia, Y., et al., Going deeper with convolutions, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston-USA, 1-9, 7-12 June, 2015.
20. Zoph, B., Vasudevan, V., Shlens, J., Le, Q. V., Learning transferable architectures for scalable image recognition, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Salt Lake-USA*, 8697-8710, 18-23 June, 2018.
21. Simonyan, K., Zisserman, A., Very deep convolutional networks for large-scale image recognition, 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, San Diego-USA, 1-14, 7-9 May, 2015.
22. He, K., Zhang, X., Ren, S., Sun, J., Deep residual learning for image recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas-USA, 770-778, 27-30 June, 2016.
23. Redmon, J., Divvala, S., Girshick, R., Farhadi, A., You Only Look Once: Unified, Real-Time Object Detection, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas-USA, 779-788, 27-30 June, 2016.
24. Redmon, J., Farhadi, A., YOLOv3: An incremental improvement, *arXiv preprint arXiv:1804.02767*, 2018.
25. Aktaş A., Doğan B., Demir Ö., Tactile paving surface detection with deep learning methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (3), 1685-1700, 2020.
26. Loey, M., Manogaran, G., Taha, M.H.N., Khalifa, N.E.M., Fighting against COVID-19: A novel deep learning model based on YOLO-v2 with ResNet-50 for medical face mask detection, *Sustainable Cities and Society*, 65, 1-8, 2021.
27. An, W., Wang, H., Sun, Q., Xu, J., Dai, Q., Zhang, L., A PID controller approach for stochastic optimization of deep networks, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Salt Lake-USA*, 8522-8531, 18-23 June, 2018.
28. Maas, A.L., Qi, P., Xie, Z., et al., Building DNN acoustic models for large vocabulary speech recognition, *Computer Speech and Language*, 41, 195-213, 2017.
29. Karaci, A., Yaprak, H., Ozkaraca, O., Demir, I., Simsek, O.: 'Estimating the properties of ground-waste-brick mortars using DNN and ANN, *CMES - Computer Modeling in Engineering and Sciences*, 118 (1), 207-228, 2019.
30. Mahmud, T., Rahman, M.A., Fattah, S.A., CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization, *Computers in Biology and Medicine*, 122, 2020.
31. Ari A., Hanbay D., Tumor detection in MR images of regional convolutional neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3), 1395-1408, 2018.
32. Ahamad, M.M., Aktar, S., Rashed-Al-Mahfuz, M., et al., A machine learning model to identify early stage symptoms of SARS-Cov-2 infected patients, *Expert Systems with Applications*, 160, 2020.
33. Altman, D.G., Bland, J.M., Statistics Notes: Diagnostic tests 1: sensitivity and specificity, *BMJ*, 308 (6943), 1552-1552, 1994.
34. Ozturk, T., Talo, M., Yildirim, E.A., Baloglu, U.B., Yildirim, O., Rajendra Acharya, U., Automated detection of COVID-19 cases using deep neural networks with X-ray images, *Computers in Biology and Medicine*, 121, 2020.