

**(Araştırma Makalesi)****Bilek ve Ön Kol X-Ray Görüntüleri Kullanılarak DenseNet Tabanlı Yeni Bir Anomali Tespiti Yöntemi****Selahattin GÜÇLÜ\*<sup>1</sup>, Durmuş ÖZDEMİR<sup>2</sup>, Hamdi Melih SARAĞLU<sup>3</sup>**<sup>1</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kütahya,ORCID No : <https://orcid.org/0000-0001-5596-3005><sup>2</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya,ORCID No : <https://orcid.org/0000-0002-9543-4076><sup>3</sup> Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, KütahyaORCID No : <https://orcid.org/0000-0002-5075-9504>**Anahtar Kelimeler:**Derin Öğrenme,  
DenseNet,  
MURA Veri Seti

**Özet:** X-ray görüntülerdeki anomalilerin, bilgisayar destekli tespiti büyük öneme sahiptir ve görüntü tanımanın önemli dallarından biridir. Bu çalışma, kas iskelet radyografisi veri kümesinden bilek ve ön kol X-ray görüntüleri kullanılarak, paralel yapılar kullanılarak bir derin öğrenme modeli olan DenseNet'i geliştirmeyi amaçlamaktadır. Anomali tespiti için; AlexNet, DenseNet, Paralel DenseNet ve Önerilen Paralel DenseNet derin öğrenme modelleri kullanılarak, bilek ve ön kol kısmı için analiz sonuçları kıyaslanmıştır. Bilek kısmı için 1530 sağlıklı, 1523 anomali X-ray görüntüsü olmak üzere; ön kol kısmı için 1163 sağlıklı, 810 anomali X-ray görüntüsü derin öğrenme modellerinin eğitiminde kullanılmıştır. Bilek kısmı için istatistiksel analiz sonucunda, test doğruluk değeri en başarılı modelin %73,86 ile Önerilen Paralel DenseNet modeli, sonraki başarılı modelin %72,11 ile AlexNet olduğu görülmüştür. Ön kol kısmı için istatistiksel analiz sonucunda, test doğruluk değeri en başarılı modelin %74,07 ile Önerilen Paralel DenseNet modeli, %73,06 ile AlexNet ve Paralel DenseNet modeli olduğu görülmüştür. Kas iskelet bilek ve ön kol X-ray görüntüleri kullanılarak yapılan anomali tespitinde; DenseNet tabanlı geliştirilen Önerilen Paralel DenseNet modelinin, klasik DenseNet modele göre test doğruluk değeri açısından daha başarılı olduğu görülmüştür.

**(Research Article)****A New DenseNet Based Anomaly Detection Method Using Wrist and Forearm X-Ray Images****Keywords:**Deep Learning,  
DenseNet,  
MURA Data Set

**Abstract:** Computer-aided detection of anomalies in X-ray images is of great importance and is one of the important branches of image recognition. This study aims to develop DenseNet, a deep learning model using parallel structures, using wrist and forearm X-ray images from the Musculoskeletal Radiographs dataset. In this study compared for anomaly detection the performance of several deep learning models: AlexNet, DenseNet, Parallel DenseNet, and a Proposed Parallel DenseNet. The analysis focused on wrist and forearm data. On the wrist part, 1530 healthy and 1523 anomaly X-ray images; 1163 healthy and 810 anomaly X-ray images for the forearm part were used to train deep learning models. As a result of the statistical analysis for the wrist part, was seen that the most successful model with the test accuracy value was the Proposed Parallel DenseNet model with 73.86%, and the next successful model was AlexNet with 72.11%. As a result of the statistical analysis for the forearm part, the most successful test accuracy value was found to be the Proposed Parallel DenseNet model with 74.07%, AlexNet and Parallel DenseNet models with 73.06%. In anomaly detection using musculoskeletal wrist and forearm X-ray images, was observed that the DenseNet-based Proposed Parallel DenseNet model was more successful in terms of test accuracy than the classical DenseNet model.

## 1. GİRİŞ

Kemikler, insan vücudunun en önemli parçalarından biridir. İnsan vücudunda kişinin hareket etmesine yardımcı olur ve çeşitli yaşam işlevlerini yerine getirmesini sağlar. Ayrıca göğüs kafesi, kafatası ve diğer bölümleri ile insan vücudunun yumuşak kısımları için ilk savunma hattını oluşturur. Kemikler, bileşim açısından en yoğun doğal yapılar olmakla birlikte, yapı ve şekillerindeki herhangi bir değişiklik, insan işlevlerini doğal biçimlerinde yerine getirememesine neden olabilir [1]. Şiddetli düşmeler, araba kazaları veya sağlıklı kemikler üzerindeki uzun süreli yük taşıma baskıları gibi yüksek etkiler nedeniyle, her yaşta insan ortopedik travmanın yaygın bir şekli olan kırıklara karşı hassastır [2]. Bu nedenle, bu değişiklik anomali olarak adlandırılır. Bu anomalilerin ana nedenleri; doğrudan yaralanma, genetik faktörler, kas ve kemik yapısının bazı bölümlerinin enfeksiyonudur [1]. Kas iskelet sistemi röntgen görüntüleri anomali sınıflandırılması için çok önemlidir. Genellikle, bir hasta kaza geçirdiğinde veya bir kıraktan şüphelendiğinde, hasta acil servise gider ve burada acil servis doktoru kırıkları tespit etmek için ilk olarak bir röntgen çeker. Acil serviste röntgen görüntülerinin yanlış sınıflandırılma oranı, röntgeni sınıflandıran acil servis doktorunun deneyimli bir radyolog olmaması ve sürecin hızlı olması gibi çeşitli faktörler nedeniyle çok yüksektir ve istenmeden hatalara yol açmaktadır [3]. Bu nedenle, doktorun deneyimine bağlı olarak kırıklar, donanım, dejeneratif eklem hastalığı, lezyonlar ve subluksasyonlar dahil olmak üzere çeşitli anomaliler gözden kaçabilir [4]. X-ray görüntülerinin sınıflandırılmasında, otomatik bir sınıflandırıcının olması doktora çok yardımcı olabilir ve hata oranını azaltabilir [3]. X-ray görüntülerin bilgisayarla işlenmesi ve analizi; görüntü alma, görüntü oluşturma, görüntü analizi ve görüntü tabanlı görselleştirmeyi içerir. X-ray görüntü işleme, bilgisayarlı görmeyi, örüntü tanımayı, görüntü madenciliğini ve aynı zamanda çeşitli yönlerde makine öğrenimini içerecek şekilde büyümüştür. Derin öğrenme, görüntü sınıflandırmak için yaygın olarak kullanılan bir metodolojidir. [5]. Derin öğrenme, tıbbi görüntülerin sınıflandırılmasında genellikle eğitim için iyi açıklanmış veri kümeleri gerektirir; bu da araştırma kurumları ve hastaneler tarafından tıbbi veri kümelerinin oluşturulmasını büyük ölçüde yönlendirir [6].

İnsanlarda kas iskelet sistemi anomalilerinin tespiti için yapılan çalışmalar incelendiği zaman, veri kümeleri; hastaların X-ray görüntüleri olarak kullanılmış ve genelde derin öğrenme algoritmalarından faydalanılmıştır.

Urakawa ve arkadaşları, önceden eğitilmiş bir sınıflandırma modeli olan VGG16 kullanarak, kırılmış önden görünümü kalça radyografileri üzerinde transfer öğrenme tabanlı anomali sınıflandırması gerçekleştirmişlerdir [7]. Harini ve arkadaşları, MURA (Musculoskeletal Radiographs) veri setinde parmak, bilek ve omuz X-ray görüntüleri kullanılarak Inception V3, Xception, VGG-19, DenseNet ve MobileNet derin öğrenme yöntemlerini kullanarak sonuçları

kıyaslamışlardır [8]. Barhoom ve arkadaşları, MURA veri setinde bulunan tüm kısımlarda anomali tespiti için VGG-16 derin öğrenme yöntemini modifiye ederek sınıflandırma yapmıştır [9]. Nguyen ve arkadaşları, X-ray görüntülerinde anomali tespiti için YOLOV4 tabanlı bir derin öğrenme öğrenme yöntemi kullanmışlardır. Eğitim sırasında bazı veri büyütme tekniklerini kullanmalarının yanı sıra görüntü kontrastı algoritmalarının performansa etkisini de göstermişlerdir. Faster-RCNN tabanlı sınıflandırmanın daha iyi sonuçlar verdiği belirtilmiştir [10]. Alzubaidi ve arkadaşları, MURA veri setinde omuz X-ray görüntülerini kullanarak yeni bir transfer öğrenme modeli ile klasik derin öğrenme yöntemlerini kıyaslayarak, önerdikleri modelde daha iyi sonuçlar aldıklarını belirtmişlerdir [11]. Manoila ve arkadaşları, diz eklemi bölgesinin otomatik olarak tanımlanması için önceden ayarlanmış parametrelere sahip çeşitli derin öğrenme modelleri içeren esnek bir MRI analiz çerçevesi sunmuştur. Diz kemiği segmentasyonu için umut verici bir evrimsel sinir ağını (ESA) ve görüntü işlemeyi iyileştirmek üzere yeni bir ağırlıklı alt örnekleme yöntemini vurgulamaktadır [12]. Akgül ve arkadaşları, meme kanseri teşhisinde derin öğrenme modellerinde hibrit bağlantı kullanmışlar ve analiz sonuçlarını kıyaslamışlardır [13]. Akgül ve arkadaşları, COVID-19 teşhisinde derin öğrenme modellerini ve önerdikleri modeli kullanmışlar. Önerdikleri IsVoNet derin öğrenme modelinde başarı oranı yüksek sonuçlar elde etmişlerdir [14].

Yapılan literatür çalışmalarında, bir derin öğrenme yöntemi olan DenseNet modelinin insanlarda kas iskelet sistemi rahatsızlıklarını sınıflandırmada başarılı sonuçlar elde ettiği görülmüştür. Literatürde, paralel katmanlar kullanan derin öğrenme yöntemleri kullanılmasına rağmen, MURA veri kümesi gibi çok sayıda X-ray görüntüsü içeren veri kümelerinde paralel katman ve katman sayısındaki artışa ilişkin performans analizi eksik kalmaktadır. Bu çalışmada, paralel ve çok katmanlı mimarinin doğruluk performansını arttıracığı literatürden öngörülmüş ve DenseNet mimarisine uygulanarak test edilmiştir. Çalışmada klasik DenseNet derin öğrenme modelinin katmanlarını, blok olarak paralel bağlantıda ve AlexNet modeli ile kıyaslanarak test doğruluk değerlerinin performans analizi yapılmıştır. Bu çalışmada MURA veri seti X-ray görüntüleri kullanılarak, klasik DenseNet model ile geliştirilen Önerilen Paralel DenseNet (ÖPDN) modeli kıyaslanmıştır. ÖPDN modeli, kas iskelet sistemi anomali tespitini mümkün kılacak şekilde uygulanmasını önermektedir.

Bu çalışma aşağıdaki şekilde tasarlanıp organize edilmiştir: Bölüm 2’de kullanılan derin öğrenme modelleri ve teknik prosedürler hakkında bilgi verilmiştir. Önerilen modeller ve süreçleri Bölüm 3’te ele alınmıştır. Bölüm 4’te performans ölçümleri verilmiştir. Deneysel analiz ve sonuçlar Bölüm 5’te verilmiştir. Son olarak sonuç yorumları ve öneriler 6. Bölüm’de sunulmuştur.

## 2. METODOLOJİ

## 2.1. Derin öğrenme

Model mimarileri, sofistike yapılar veya sinir ağları gibi bir dizi doğrusal olmayan dönüşümden inşa edilen diğer yöntemleri kullanarak verilerdeki üst düzey soyutlamaları temsil etmeye çalışan algoritmalara dayanan bir makine öğrenme dalıdır [15]. Kullanılan algoritma birden fazla gizli katmana sahip bir sinir ağı olduğunda, derin öğrenme olarak adlandırılır [16]. Derin öğrenme, insan beyninden esinlenerek daha akıllı sistemler oluşturmak için yapılan araştırmalardan ortaya çıkmıştır. 1940'larda S. McCulloch ve Walter H. Pitts, beyindeki sinir hücrelerinin aktif ya da pasif olma durumunun bir eşik değere bağlı olduğunu ve bu hücrelerin birbirine bağlanarak bir devre oluşturabileceğini, böylece bu devre sayesinde kararlar alınabileceğini öne sürmüştür. Nöronlar belirli katsayılar ile girdileri çarparak ağırlıklı toplam alınır. Elde edilen sonuç, bir eşik değere karşılaştırılır; sonuç eşik değerin altında kalırsa iletim gerçekleşmez, ancak eşik değeri aşarsa nöron iletimi gerçekleştirir. Bu yapı, yapay sinir ağlarının temel çalışma prensibini ortaya koymaktadır. [17]. Çok katmanlı yapay sinir ağı mimarisi fikrinin ortaya çıkmasıyla, katman sayısı artırılarak derin sinir ağları olan ESA geliştirilmiştir. Bilgisayar teknolojisindeki ilerlemeler, yapay sinir ağlarının yeniden popüler hale gelmesine önemli ölçüde katkıda bulunmuştur [18].

Derin öğrenme; denetimli, denetimsiz, yarı denetimli veya takviyeli olarak gerçekleştirilebilir. Yapay sinir ağlarının yapısında birden fazla giriş, çıkış ve gizli katman bulunması nedeniyle bu öğrenme sürecine "derin" denir. Bu katmanlar aracılığıyla veri işlenerek bilgi elde edilir. Derin öğrenmede isabetli tahminler yapabilmek için geniş çaplı eğitim veri setlerine ihtiyaç vardır. Çok sayıda ve karmaşık işlem içerdiği için, makine öğrenmesinden farklı olarak, yüksek performanslı donanımlara sahip makinelerle daha verimli sonuçlar elde edilebilmektedir. Makine öğrenmesinden bir diğer farkı, derin öğrenmenin çıktısının sadece sınıflandırma veya sayısal değer olmak zorunda olmamasıdır. Çıkış katmanında sayısal bir değer üretmenin yanı sıra, metin, ses gibi çeşitli biçimlerde çıktılar da üretebilir. Derin öğrenme, pek çok farklı sektörde uygulanabilir. Derin öğrenmenin en yaygın kullanım alanlarına örnek olarak; ses sinyali sınıflandırma veya gürültü azaltma, görüntü

işleme ve sınıflandırma, sohbet botları, duygu analizi, hizmetlere yönelik otomatik öneriler sunma, sürücüsüz araçlar ve tıp alanında teşhis ve tedaviye yardımcı tahminlerde bulunma gibi birçok alanda faaliyet göstermektedir [19],[20].

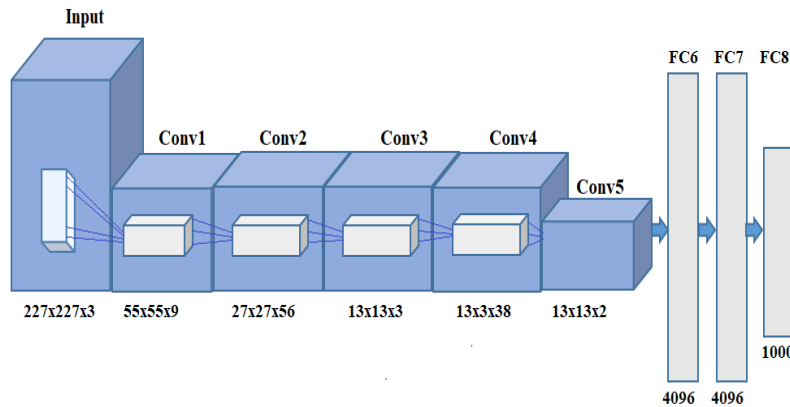
Günümüzde yaygın olarak kullanılan derin öğrenme mimarilerini: Derin OtoKodlayıcılar (Deep Auto-Encoders), Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNNs), Derin İnanç Ağları (Deep Belief Network), ESA, Üretken Çekişmeli Ağlar ve Hibrit Mimariler olarak sınıflandırabiliriz [21].

## 2.2. Modeller

Bir derin öğrenme metodu olan ESA, güçlü özellik çıkarma yeteneği nedeniyle sağlık alanında görüntü tanımadaki kullanılan algoritmaların başında gelir [22]. ESA'lar, giriş verilerinin hiyerarşik temsillerini öğrenebildikleri için özellikle görüntü tanıma görevleri için etkilidir [23]. Bu çalışmada, bilek ve önkol X-ray görüntülerini, ESA ile eğitmek için popüler olan DenseNet ve AlexNet derin öğrenme metodları kullanılmıştır.

### 2.2.1. AlexNet modeli

AlexNet modeli, transfer öğrenme uygulamalarında sıkça kullanılan bir modeldir ve Alex Krizhevsky ile ekibi tarafından 2012 yılında geliştirilmiştir [24]. ImageNet veri tabanı kullanılarak bir milyondan fazla görüntü ve 1000 farklı sınıf (örneğin, hayvanlar, bitkiler) üzerinde eğitilmiş bir derin öğrenme modelidir. Görüntülerin girdi boyutları  $227 \times 227 \times 3$  olarak belirtilmiştir. Toplamda 25 katmandan oluşan bu model, yaklaşık 60 milyon parametre içerir. Model, 5 konvolüsyonel katmanı, 7 ReLU aktivasyon fonksiyon katmanı, 3 havuzlama katmanı ve 3 tam bağlantılı katman kullanılarak oluşturulmuştur. AlexNet'ten transfer öğrenme yöntemleri kullanılarak, önceden öğrenilmiş parametreler sayesinde daha küçük veri kümeleri daha etkili bir şekilde sınıflandırılabilir [25]. AlexNet'in mimari yapısı Şekil 1'de gösterilmektedir.




Şekil 1. AlexNet derin öğrenme modelinin mimarisi [26]

## 2.2.2. DenseNet modeli

DenseNet, Huang ve çalışma arkadaşları tarafından ESA modellerinde ilk katmanlar ile sonraki katmanlar arasındaki kısa bağlantıların derinliği artırarak, daha doğru ve verimli sonuçlar elde edilebileceği öngörüsüyle geliştirilmiştir [27]. DenseNet modeli klasik ESA modelinde bulunan her katman ile bir sonraki katman arasında bir tane olmak üzere, birbirine tam bağlı katmanlardan oluşur. Normal bir  $N$  katmanlı ESA'da  $N$  adet bağlantı bulunurken, DenseNet modelinde ise her katman kendinden sonra gelen her katmana bağlı olduğundan dolayı  $N(N+1)/2$  bağlantıdan oluşur. Her katman için, önceki tüm katmanların özellik haritaları

girdi olarak kullanılır ve kendi özellik haritaları sonraki tüm katmanlara girdi olarak gönderilir [28]. Bu sayede DenseNet, gradyan problemiyle başa çıkmayı, özellik yayılımını güçlendirmeyi, özelliklerin yeniden kullanımını teşvik etmeyi ve parametre sayısını önemli ölçüde azaltmayı amaçlar [29]. DenseNet'in 121, 169, 201, 264 katmana sahip olan türleri vardır [30]. Şekil 2'de DenseNet modelinin mimarisi gösterilmiştir.

DenseNet türlerine göre mimariler farklılık gösterdiğinden bu farklılıklar, Tablo 1'de verilmiştir.

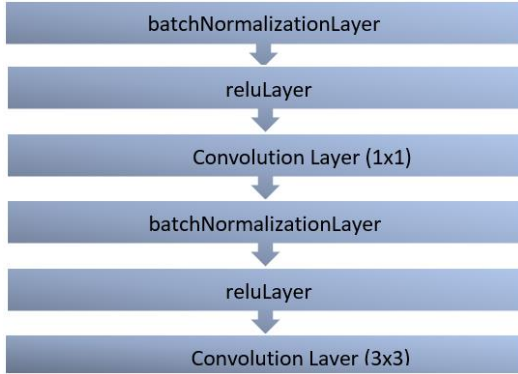


Şekil 2. DenseNet derin öğrenme modelinin mimarisi [31]

Tablo 1. DenseNet mimarileri. (Tabloda gösterilen her "konv" katmanı, sırasıyla BN (Batch Normalization)-ReLU-Konv (Konvolüsyon) dizisine karşılık gelir) [32]


Katmanlar	Çıkış Boyutu	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264				
Konvolüsyon	112x112	7x7 konv, adım(stride) 2							
Havuzlama	56x56	3x3 max havuzlama, adım(stride) 2							
Dense Blok-1	56x56	1x1 konv 3x3 konv	x6	1x1 konv 3x3 konv	x6	1x1 konv 3x3 konv	x6	1x1 konv 3x3 konv	x6
Geçiş Katmanı-1	56x56	1x1 konv							
	28x28	2x2 ortalama havuzlama, adım(stride) 2							
Dense Blok-2	28x28	1x1 konv 3x3 konv	x12	1x1 konv 3x3 konv	x12	1x1 konv 3x3 konv	x12	1x1 konv 3x3 konv	x12
Geçiş Katmanı -2	28x28	1x1 konv							
	14x14	2x2 ortalama havuzlama, adım(stride) 2							
Dense Blok-3	14x14	1x1 konv 3x3 konv	x24	1x1 konv 3x3 konv	x32	1x1 konv 3x3 konv	x48	1x1 konv 3x3 konv	x64
Geçiş Katmanı -3	14x14	1x1 konv							
	7x7	2x2 ortalama havuzlama, adım(stride) 2							
Dense Blok-4	7x7	1x1 konv 3x3 konv	x16	1x1 konv 3x3 konv	x32	1x1 konv 3x3 konv	x32	1x1 konv 3x3 konv	x48
Sınıflandırma Katmanı	1x1	7x7 global ortalama havuzlama							
		1000D Tam bağlantılı, softmax							

Şekil 3'te DenseNet blok açılımı gösterilmiştir. DenseNet'in bu yoğun bağlantılı yapısı, daha az parametre ile daha derin ağlar oluşturmayı mümkün kılmakta, böylece modelin genelleme kabiliyetini artırmakta ve öğrenme sürecini hızlandırmaktadır.



Şekil 3. DenseNet bloğu açılımı [33]

Şekil 4'te DenseNet geçiş katmanı açılımı gösterilmiştir. Geçiş katmanları, DenseNet'i verimli ve güçlü bir model haline getiren kritik bileşenlerdir. Bu katmanlar yoğun bloklar arasında dengeli ve kontrollü bir bilgi akışı sağlar.



Şekil 4. DenseNet geçiş katmanı açılımı [33]

Çalışmada MURA veri seti radyografi görüntülerinin analiz edilmesinde klasik DenseNet modeli olarak, DenseNet-264 kullanılmıştır.

### 3. ÖNERİLEN MODEL VE SÜREÇLER

DenseNet modelinin ana modülü olan Dense Blok modülünün görevi, giriş verisi olan görüntülerden özellik çıkarmaktır. Bununla birlikte, bu Dense blok modülde çeşitli işlevsel katmanların düzenlenmesi yeterince uygun olmadığı için optimize edilme alanı bulunmaktadır. CrodenseNet mimarisinde farklı paralel yapılar kullanılarak COVID-19 hastalığının teşhisinde daha iyi sonuçlar elde edilmiştir [34]. CIFAR 10 ve CIFAR 100 veri setini kullanarak Yin ve arkadaşları, klasik DenseNet model üzerinde paralel katmanlar kullanarak doğruluk düzeyi yüksek sonuçlar elde etmişlerdir [35]. Klasik DenseNet bloklarının sayısını azaltarak üç paralel blok kullanan Yin ve arkadaşlarının aksine, bu çalışmada dört paralel blok kullanılmıştır. Dolayısıyla bazı katmanları silerek, ekleyerek ve konvolüsyon katmanını ayarlayarak,

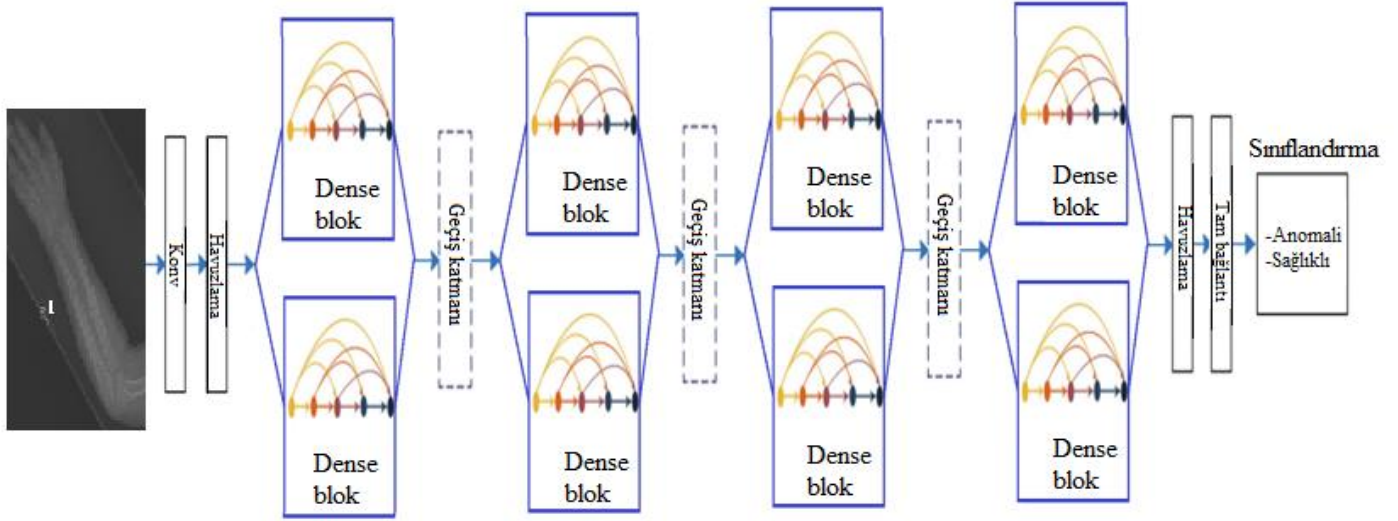
paralel bloklar eklenerek DenseNet derin öğrenme yöntemi geliştirilmiştir. Daha fazla konvolüsyon katmanı, boyut açısından daha büyük olan alıcı alanına üst üste bindirildiğinde, daha zengin özelliklerin çıkarılmasını ve daha yüksek hesaplama verimliliğini sağlayabilir. Yin ve arkadaşlarının aksine, geliştirilen DenseNet derin öğrenme modellerinde, daha büyük alanlardaki özellikleri yakalamak veya özellik çıkarmak için 1x1 yerine 3x3 konvolüsyon katmanı kullanılmıştır. 3x3 konvolüsyon katmanı her pikseli, kendisi ve komşularının etrafındaki 3x3'lük bir pencerede işler. Ayrıca, DenseNet özellikle giriş özelliklerini yoğun blok modülü üzerinden işler ve özellik çıkarmak için yalnızca tek bir konvolüsyon çekirdeği kullanılır, bu kaçınılmaz olarak nispeten tek bir yapıdadır ve resimdeki bilgiyi kaybetmek kolaydır [35]. Mevcut özelliklerden tam anlamıyla yararlanmak ve fazla parametre eklememek amacıyla, genişletilmiş konvolüsyon yöntemine dayalı yeni bir genişletilmiş konvolüsyon bloğu paralel olarak tasarlanmıştır. Ardından, çoklu yol Dense bloklar, farklı kanallardan çeşitli özellik haritalarını birleştirmek için bağlanır. Bu, kanalların özellik uyumunu modellemeye ve güçlü özellik çıkarma işlemini gerçekleştirmeye yardımcı olur.

Çalışmada, MURA veri seti radyografi görüntüleri kullanılarak bir derin öğrenme modeli olan DenseNet modelini geliştirmek amacıyla; önce klasik DenseNet mimarisine paralel şekilde Dense bloklar eklenerek "Paralel DenseNet" modeli geliştirilmiştir. DenseNet mimarisini paralelleştirerek sınıflandırmada daha iyi sonuçlar elde edildi [34],[35]. Geliştirilen bu Paralel DenseNet mimarisini optimize edilerek "Önerilen Paralel DenseNet" modeli geliştirilmiştir. Çalışmada kullanılan DenseNet modelleri eğitildikten sonra görüntü tanıma için kullanılır. Ayrıca, elde edilen sonuçlar test görüntülerinin etiketleriyle karşılaştırılarak bu görüntü tanımının doğruluğu elde edilir.

#### 3.1. Paralel DenseNet modeli

Paralel DenseNet modelinde, klasik DenseNet-264 modelinin katmanları ve tekrar sayıları bire bir kullanılmıştır. Geçiş katmanları Şekil 4'te gösterilen ile aynıdır. Paralel DenseNet derin öğrenme modelinin mimarisi Şekil 5'de gösterilmiştir.

Şekil 5'de görüldüğü gibi klasik DenseNet mimarisi temel alınarak, klasik Dense bloklara paralel bağlanan aynı katman ve özelliklerdeki Dense bloklar eklenmiştir. Dense blok sayıları artırılabilir ve azaltılabilir [35]. Çalışmamızda paralel bloklar klasik DenseNet ile aynı özelliklere sahip olan geçiş katmanları ile birbirine bağlanmıştır. Paralel bağlantı sonucu, yapı gereği Dense bloklar özellik haritaları birleştirilerek bağlandıktan sonra özellik çıkarma işlemi gerçekleştirilir. En son katmanda 'havuzlama' ve 'tam bağlantı' katmanları bağlanarak 'Anomali-Sağlıklı' sınıflandırması yapılır. Paralel blok sayısı 3 ile yapılan analizlerde %10 test doğruluk değerinde performans düşüşü yaşandığı için paralel Dense blok sayısı 4 olarak seçilmiştir.




Şekil 5. Paralel DenseNet derin öğrenme modelinin mimarisi

### 3.2. Önerilen Paralel DenseNet modeli

ÖPDN modelinde, yine klasik DenseNet-264 modelinin katmanları ve tekrar sayıları bire bir kullanıldı. Geçiş katmanları Şekil 4'te gösterilen ile aynıdır. Önerilen modelde; geliştirilmiş Dense bloklara, ayrıık Dense bloklar paralel bağlanarak Şekil 6'da gösterilen mimari oluşturulmuştur.

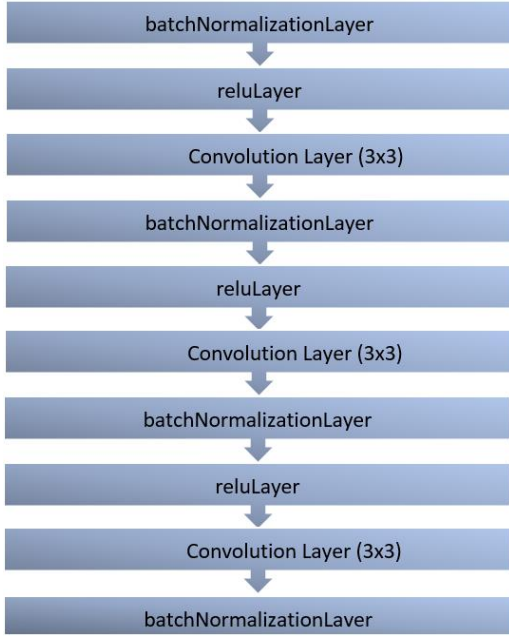
Klasik DenseNet mimarisi art arda eklenen katmanlardan oluşmaktadır. Paralel bloklar klasik DenseNet ile aynı

özelliklere sahip olan geçiş katmanları ile birbirine bağlandı. ÖPDN modelinde; birinci blokta bulunan birbirine paralel bağlı Geliştirilmiş Dense blok ve Ayrıık Dense blok 6 kez, ikinci blokta 12 kez, üçüncü blokta 64 kez ve dördüncü blokta 48 kez tekrarlanmıştır. ÖPDN mimarisinde Şekil 6'da görüldüğü gibi Dense bloklar, farklı kanallardan gelen özellik haritaları birleştirilir ve ardından özellik çıkarma işlemine yardımcı olur.



Şekil 6. ÖPDN derin öğrenme modelinin mimarisi

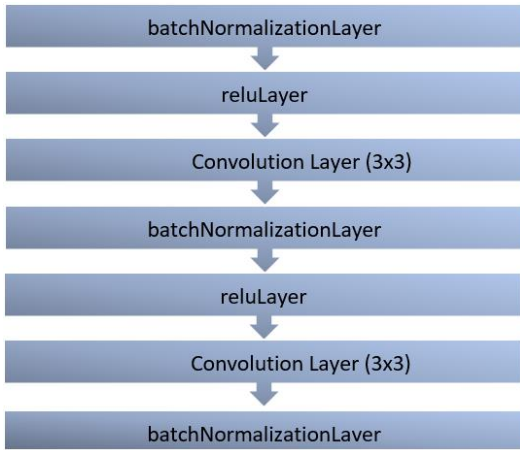
Geliştirilmiş DenseNet bloğu açılımı Şekil 7’de gösterilmiştir.



Şekil 7. Geliştirilmiş DenseNet bloğu açılımı

Şekil 7’de gösterildiği gibi Geliştirilmiş DenseNet bloğu açılımında, klasik DenseNet bloğundan (Şekil 3) farklı olarak, görüntüdeki bilgiyi kaybetmemek için konvolüsyon katmanları 1x1 yerine 3x3 olarak kullanılmıştır. Klasik DenseNet bloğundan farklı olarak sırasıyla Batch Normalization-ReLU-Konv (Convolution) katmanları eklenmiştir.

Ayrık DenseNet bloğu açılımı Şekil 8’de gösterilmiştir.



Şekil 8. Ayrık DenseNet bloğu açılımı

ÖPDN mimarisinde, Şekil 8’de gösterilen paralel olarak bağlanan Ayrık DenseNet bloğu açılımında; klasik DenseNet bloğundan farklı olarak (Şekil 3), görüntüdeki bilgiyi kaybetmemek için konvolüsyon katmanları 1x1 yerine 3x3 olarak kullanılmıştır. Klasik DenseNet bloğundan farklı olarak normalizasyon işlemi için de Batch Normalization katmanı eklenmiştir. Sınıflandırma katmanından önce klasik DenseNet mimarisinden farklı olarak Batch

Normalization-ReLU-Konv(Convolution) ve dropout katmanları kullanılarak ‘Anomali-Sağlıklı’ sınıflandırması yapılır.


### 3.3. Veri seti ve görüntü ön işleme

MURA veri seti, geniş bir zaman diliminde toplanan çok sayıda hastadan alınan X-ray görüntülerinden oluşan geniş bir veri kümesidir. Stanford Hastanesi'nin Resim Arşivi ve İletişim Sistemi'nden (PACS - Picture Archive and Communication System) HIPAA (Health Insurance Portability and Accountability Act - Sağlık Sigortası Taşınabilirlik ve Sorumluluk Yasası) uyumlu görüntülerden toplanmıştır [36]. Veri seti; önkol, dirsek, bilek, humerus, el, parmaklar ve omuz gibi yedi kemik türünden oluşturulmuştur. Bu veri kümesi, 40.561 röntgen görüntüsünün farklı anatomik pozisyonlarının çoklu görüntüsü ile toplam 14.863 kemik X-ray görüntüsünü içeren 12.173 hastadan toplanmıştır [37]. Tüm veri seti, sağlıklı veya anomali olarak radyologlar tarafından etiketlendi [38].

Anomali tespiti, bir çalışmanın sağlıklı ya da anormal olduğunu belirlemek için ikili bir sınıflandırma işidir. Bir X-ray görüntünün sağlıklı mı yoksa anomali mi olduğunu belirlemek kritik derecede önemlidir, dolayısıyla hastaların daha ileri tanısal testlerden geçme ihtiyacını, prosedürleri ve müdahaleleri ortadan kaldırabilir. Anomalinin nedenleri; dejeneratif eklem hastalıkları, donanım, kırıklar, lezyonlar ve subluksasyonlar gibi çeşitli anormallikler olarak sıralanır [39]. Şekil 9 ve 10’da MURA veri seti bilek ve ön kol kısımları için X-ray görüntüleri gösterilmiştir.



Şekil 9. MURA veri seti bilek kısmı (a) sağlıklı, (b) anomali veri kümesi örneği



Şekil 10. MURA veri seti ön kol kısmı (a) sağlıklı, (b) anomali veri kümesi örneği

512x512 piksel ile 97x512 piksel arasında değişen, MURA veri seti orijinal boyutları sabit değildir ve dosya uzantısı '.png'dir [40]. Derin öğrenmede, giriş veri kaybının az olması için ve aynı piksel değerinde olması amacı ile, değişken boyutlu tüm görüntüleri 320x320 piksel olacak şekilde yeniden boyutlandırıldı [41]. '.png' uzantılı görüntüler bu boyutlandırmadan sonra, Şekil 9 ve Şekil 10'da gösterildiği gibi fazla olan boşlukları veya kenarları kırılarak, görüntü merkeze alındı ve ortalandı. Yapılan bu işlem görüntüyü ilgi alanına veya odak noktasına daha yakın hale getirmek için kenarlardaki boş veya gereksiz alanları kaldırmak amacı ile yapılmıştır. MURA veri setindeki görüntüler, 8 ile 24 arasında değişen bit derinliğine sahiptir. Çalışmada tüm giriş görüntü verilerinin bit derinliği, eğitimin daha verimli olması için 8 olarak dönüştürülmüştür [42].

Giriş görüntü verileri çalışmada, rastgele olarak yatay ve dikey pozisyonda  $-30^0$  ile  $+30^0$  arasında döndürülerek ve yine her iki x-y ekseninde yansıtılarak çoğaltılmıştır [4]. Bunun yanında 0,9 ile 1,1 değerleri arasında giriş görüntü verileri ölçeklendirilerek giriş veri sayısı artırılmıştır [43].

Deneysel analizlerde kullanılması için kullanılan X-ray görüntü verilerinin sayısı Tablo 2'de gösterilmiştir.

**Tablo 2.** Çalışmada kullanılan MURA X-ray görüntü verilerinin sayısı

Çalışma	Kısım	Sağlıklı	Anomali
Bu çalışmada	Bilek	1530	1523
Karabağ ve diğ.[A18]	Bilek	2274	1423
Reddy and Cutsuridis [A19]	Bilek	143	169
Bu çalışmada	Ön kol	1163	810
Karabağ ve diğ.[A18]	Ön kol	659	351
Reddy and Cutsuridis [A19]	Ön kol	163	160

## 4. PERFORMANS ÖLÇÜMLERİ

MURA veri setinde sağlıklı-anomali tespiti için modellemelerin performansını; doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), özgüllük (specificity), F1-skor, Cohen'in kappa istatistiği ve 5 katlı çapraz doğrulama gibi klinik olarak önemli istatistiksel ölçütler kullanılarak değerlendirilmiştir. Bu ölçütler kısaca şu şekilde tanımlanır:

### 4.1. Doğruluk

Doğru yaptığımız tahminlerin sayısının bütün yaptığımız tahminlerin sayısına bölümünden bulunur. Formülü aşağıdaki gibidir.

$$\text{Doğruluk} = (DP + DN) / (DP + YP + YN + DN) \quad (1)$$

Burada; DP: model tarafından doğru tahmin edilen pozitif vakaların sayısı; DN: model tarafından doğru tahmin edilen negatif vakaların sayısı; YP: model tarafından yanlış tahmin edilen pozitif vakaların sayısı; YN: model tarafından yanlış tahmin edilen negatif vakaların sayısını ifade etmektedir.

### 4.2. Kesinlik

Pozitif olarak tahmin edilen örneklerin, kaçının doğru tahmin edildiğinin oranıdır. Formülü aşağıdaki gibidir.

$$\text{Kesinlik} = DP / (DP + YP) \quad (2)$$

### 4.3. Duyarlılık

Pozitif olarak tahmin edilmesi gereken örneklerin, kaçının doğru tahmin edildiğini oransal olarak ifade etmektedir. Formülü aşağıdaki gibidir.

$$\text{Duyarlılık} = DP / (DP + YN) \quad (3)$$

### 4.4. Özgüllük

Doğru tahmin edilen negatif gözlemlerin tüm gerçek negatif gözlemlere oranıdır.

$$\text{Özgüllük} = DN / (YP + DN) \quad (4)$$

### 4.5. F1-Skor

F1 skor; duyarlılık ve kesinlik değerlerini kullanarak tek bir sayıya indirger. F1 skoru, birden fazla modelin kesinlik ve doğruluk değerleri arasında en iyi modeli seçmek için kullanılır. Formülü aşağıdaki gibidir [44],[45].

$$\text{F1-Skor} = 2(\text{Kesinlik} \times \text{Duyarlılık}) / (\text{Kesinlik} + \text{Duyarlılık}) \quad (5)$$

### 4.6. Cohen'in kappa istatistiği

Sınıflama düzeyinde puanlama yapan iki puanlayıcı arasındaki uyum derecesini belirlemek için kullanılan bir ölçümdür. Cohen'in kappa istatistiği ( $\kappa$ ) için formül aşağıdaki gibidir [46]:

$$P_e = \frac{(TP+FP) \times (TP+FN) + (TN+FN) \times (TN+FP)}{(TP+TN+FP+FN)^2} \quad (6)$$

$$\kappa = (\text{Doğruluk} - P_e) / (1 - P_e) \quad (7)$$

### 4.7. K-katlı çapraz doğrulama

Verilerin k sayısı kadar rastgele bölünmesi ve her seferinde farklı bir veri kümesinin test verisi olarak kullanılması olarak tanımlanır. Bu sayede, tüm verilerin eğitim ve test verisi olarak kullanılması sağlanmış olur [47]. Aşırı öğrenme (overfitting) problemini önlemeye yardımcı olan bu yöntem, literatürde genelde  $k = 3, 5$  ve  $10$  değerleri için kullanılır [48]. Eğitim süresini kısaltmak ve literatürde de kullanıldığı için çalışmada  $k$  değeri  $5$  olarak seçilmiştir.



## 5. DENEYSEL ANALİZ VE SONUÇLAR

Deneysel ortam aşağıdaki gibi tanımlanmıştır. Bu deneydeki tüm ağ modelleri derin öğrenme çerçevesine dayanmaktadır ve her bir model deneyi, 12th Gen Intel(R) Core(TM) i7-12650H 2.30 GHz, Windows 11 Pro işletim sistemli, 16 GB bellekli ve NVIDIA GeForce RTX4060 Dizüstü Bilgisayar GPU'su bulunan bir bilgisayarda, MATLAB programı kullanılarak tamamlanmıştır.

Parametre ayarları aşağıdaki gibidir. Bu deneydeki ağlar aynı parametre ayarlarını kullanmaktadır. Veri setinde öğrenme oranı 0.001 olarak ayarlanmış, minibatch size değeri 128 ve epoch sayısı 250 olarak belirlenmiştir. Model Ağı tarafından üretilen çıktı değeri ile gerçek değer arasındaki hata miktarını en aza indirmek amacıyla ADAM (Adaptif Moment Tahmini) algoritması kullanılarak kategorik çapraz-entropi fonksiyonu ayarlandı. Bu şekilde, model tarafından üretilen çıktı değeri ile gerçek değer arasındaki farkı en düşük seviyeye indirerek, istenen hedefe ulaşılmaya çalışıldı. Tüm modellerde, veri giriş görüntüleri rastgele(randomized) %80 eğitim, %5 validation ve %15 test oranlarıyla eğitilmiştir.

MURA X-ray görüntü veri setinde bilek kısmı için 1530 sağlıklı, 1523 anomali görüntü kullanılmıştır. Bilek kısmı için AlexNet, DenseNet, Paralel DenseNet ve ÖPDN modelleri kullanılarak elde edilen, test verilerine ait dört derin öğrenme modelinin performansları Tablo 3'te gösterilmektedir.

**Tablo 3.** Bilek kısmı için derin öğrenme modellerinin karşılaştırmalı performansları

Model	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Keskinlik (%)	F1-Skor (%)	Kappa istatistiği	5-katlı çapraz doğrulama (%)	Eğitim süresi (dk)
AlexNet	72,11	80,98	67,23	57,64	67,35	0,4419	69,73	55
DenseNet	69,06	79,59	64,10	51,09	62,23	0,3808	67,22	176
Paralel DenseNet	69,93	88,24	63,53	45,85	60,34	0,3981	68,15	676
ÖPDN	73,86	81,50	69,23	61,57	70,15	0,4768	72,32	887

Tablo 3'e göre en yüksek doğruluk oranı (%73,86) ÖPDN modelinde, en düşük doğruluk oranları ise DenseNet (%69,06) ve Paralel DenseNet (%69,93) modellerinde görülmüştür. Öte yandan AlexNet modeli (%72,11), DenseNet ve Paralel DenseNet modellerinden daha başarılı sonuçlar vermekle birlikte, Önerilen Paralel DenseNet modelinden daha az doğruluk oranına sahiptir.

Karabağ ve arkadaşları AlexNet modeli kullanarak yaptıkları çalışmada bilek kısmı için %69,00 doğruluk oranı ile sınıflandırma yapmışlardır [47]. Yang ve arkadaşları yaptıkları çalışmada bilek kısmı için AlexNet modelini kullanarak %66,36 doğruluk oranı ile sınıflandırma yapmışlardır [49]. Bu değerler, bu çalışmada analiz sonucunda elde edilen %72,11 değerine yakın sonuçlardır. ÖPDN modelinde elde edilen 0,4768 Kappa istatistik değeri tüm modellere göre daha başarılıdır. 5-kat çapraz doğrulama yöntemiyle yapılan

analizlerde ÖPDN modeli, %72,32 doğruluk oranıyla diğer modellere göre üstünlük sağladı.

MURA X-ray veri setinde ön kol kısmı için 1163 sağlıklı, 810 anomali görüntü kullanılmıştır. Ön kol kısmı için AlexNet, DenseNet, Paralel DenseNet ve Önerilen Paralel DenseNet modelleri kullanılarak elde edilen, test verilerine ait dört derin öğrenme modelinin performansları Tablo 4'te gösterilmektedir.

**Tablo 4.** Ön kol kısmı için derin öğrenme modellerinin karşılaştırmalı performansları

Model	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Keskinlik (%)	F1-Skor (%)	Kappa istatistiği	5-katlı çapraz doğrulama (%)	Eğitim süresi (dk)
AlexNet	73,06	75,00	72,30	51,64	61,17	0,416	71,13	33
DenseNet	70,03	67,37	71,29	52,46	58,99	0,3595	67,22	111
Paralel DenseNet	73,06	73,86	72,73	53,28	61,90	0,419	71,05	430
ÖPDN	74,07	71,03	75,79	62,30	66,38	0,4543	72,56	608

Tablo 4'e göre en yüksek doğruluk oranı (%74,07) ÖPDN modelinde, en düşük doğruluk oranı ise DenseNet (%70,03) modelinde görülmüştür. Paralel DenseNet ve AlexNet modeli (%73,06) doğruluk oranları ile aynı değerlerde sonuç elde edilmiştir.

Karthik ve Kamath yaptıkları çalışmada ön kol kısmı için AlexNet modelini kullanarak %74,50 doğruluk oranı ile sınıflandırma yapmışlardır [50]. Yang ve arkadaşları AlexNet modeli kullanarak yaptıkları çalışmada ön kol kısmı için %73,62 doğruluk oranı ile sınıflandırma yapmışlardır [49]. Bu değerler, bu çalışmada analiz sonucunda elde edilen %73,06 değerine yakın sonuçlardır. ÖPDN modelinde elde edilen 0,4543 Kappa istatistik değeri tüm modellere göre daha başarılıdır. 5-kat çapraz doğrulama yöntemiyle yapılan analizlerde ÖPDN modeli, %72,56 doğruluk oranıyla diğer modellere göre üstünlük sağladı.

## 6. SONUÇ VE TARTIŞMA

Derin öğrenmede kullanılan ESA modelleri, MURA veri seti bilek ve ön kol kısmı X-ray görüntüleri kullanılarak sağlıklı ve anomali olarak sınıflandırıldı. Kas iskelet sistemi hastalığının erken teşhisi ile tedavi süresinin kısalması büyük önem taşımaktadır. Yapılan çalışmada klasik DenseNet modeli geliştirilmiş ve diğer modeller ile test sonuçları kıyaslanarak karşılaştırılmıştır. Elde edilen sonuçlara göre kas iskelet sistemi hastalığının teşhisi konusunda karar süreçlerine olumlu katkı sağlanması beklenmektedir. Önerilen yöntem ile test doğruluk oranı ve personel iş yükü gibi konularda önemli avantajlar sunmaktadır. Bilek kısmı için yapılan istatistiksel analiz sonucunda; en yüksek test doğruluk oranı (%73,86) ÖPDN modelinde, en düşük doğruluk oranları ise DenseNet (%69,06) ve Paralel DenseNet (%69,93) modellerinde görülmüştür. Öte yandan AlexNet modeli (%72,11), DenseNet ve Paralel DenseNet modellerinden daha başarılı sonuçlar elde edilmiştir. Ön kol kısmı için yapılan istatistiksel analiz sonucunda; en yüksek test

doğruluk oranı (%74,07) ÖPDN modelinde, en düşük doğruluk oranları ise DenseNet (%70,03), Paralel DenseNet (%73,06) ve AlexNet (%73,06) modellerinde görülmüştür. Bilek kısmı için Karabağ ve arkadaşlarının yaptığı çalışmadaki klasik DenseNet modeli accuracy değeri %69,50 olmak üzere, çalışmamızdaki ÖPDN modelinde test accuracy değeri %73,86'nın altında kalıyor [47]. Yine bilek kısmı için Harini ve arkadaşlarının yaptığı çalışmadaki klasik DenseNet modeli accuracy değeri %56,30 olmak üzere, çalışmamızdaki ÖPDN modelinde test accuracy değeri %73,86'nın altında kalıyor [51]. Ön kol kısmı için Kandel ve arkadaşlarının yaptığı çalışmadaki klasik DenseNet modeli test accuracy değeri %68,77 olmak üzere, çalışmamızdaki ÖPDN modelinde test accuracy değeri %74,07'nin altında kalıyor [52]. Kappa istatistik değeri ölçümleri ve 5 kat çapraz doğrulama doğruluk değerleri karşılaştırıldığında; ÖPDN modeli hem bilek hem de ön kol kısımları için klasik DenseNet modelinden daha başarılıdır. Dolayısıyla çalışmamızda, ÖPDN modelinde özellik çıkarma işleminin, klasik DenseNet modellere kıyasla daha iyi çalıştığı elde edilen sonuçlardan da görülmektedir. Klasik DenseNet yerine ÖPDN modelin kullanımını öneriyoruz. ÖPDN modelinin dezavantajı, eğitim süresinin diğer modellere göre daha uzun olmasıdır. ÖPDN modelinin test doğruluk oranlarında elde edilen başarılı sonuçların, farklı veri kümelerinde, kas iskelet sistemi rahatsızlığının erken teşhisinde ve bundan sonra yapılacak çalışmalarda, önerilen yöntemin hastanelerde kullanılan bilgisayar destekli yazılım sistemlerine entegre edilmesinde faydalı olacağı düşünülmektedir. Bununla birlikte gelecek çalışmalarda, radyologlar tarafından anomali olan bölgelere odaklanılarak elde edilen radyografi görüntüleri yönetsel ve teknik olarak geliştirilebilir.

## Etik Hususlar

### Etik kurallara uyum

Yazarlar olarak, insan gönüllüleri ve deneysel hayvan içeren çalışmalarda gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun çalıştıklarımızı deklare ederiz.

### Finansman

Yazarlar olarak, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almadık.

### Çıkar çatışması

Yazarlar olarak herhangi bir çıkar çatışması içinde bulunmadık.

## KAYNAKÇA

[1] Barhoom, A. M., Al-Hiealy, M. R. J., Abu-Naser, S. S. 2022. Bone abnormalities detection and classification using deep learning-VGG16

- algorithm. *Journal of Theoretical and Applied Information Technology*, 100(20), 6173-6184.
- [2] Lu, S., Wang, S., Wang, G. 2022. Automated universal fractures detection in X-ray images based on deep learning approach. *Multimedia Tools and Applications*, 81(30), 44487-44503.
- [3] Kandel, I., Castelli, M. 2021. Improving convolutional neural networks performance for image classification using test time augmentation: a case study using MURA dataset. *Health Information Science and Systems*, 9(1). doi:10.1007/s13755-021-00163-7
- [4] He, M., Wang, X., Zhao, Y. 2021. A calibrated deep learning ensemble for abnormality detection in musculoskeletal radiographs. *Scientific Reports*. 11. 10.1038/s41598-021-88578-w.
- [5] Suganyadevi, S., Seethalakshmi, V., Balasamy, K. 2022. A review on deep learning in medical image analysis. *International Journal of Multimedia Information Retrieval*, 11(1), 19-38.
- [6] Guo, X., Gichoya, J. W., Trivedi, H., Purkayastha, S., Banerjee, I. 2021. MedShift: identifying shift data for medical dataset curation. *arXiv preprint arXiv:2112.13885*.
- [7] Urakawa, T., Tanaka, Y., Goto, S., Matsuzawa, H., Watanabe, K., Endo, N. 2019. Detecting intertrochanteric hip fractures with orthopedist-level accuracy using a deep convolutional neural network. *Skeletal radiology*, 48, 239-244.
- [8] Harini, N., Ramji, B., Sriram, S., Sowmya, V., Soman, K. P. 2020. Musculoskeletal radiographs classification using deep learning. In *Deep Learning for data analytics* (pp. 79-98). Academic Press.
- [9] Barhoom, A. M., Al-Hiealy, M. R. J., Abu-Naser, S. S. 2022. Bone abnormalities detection and classification using deep learning-VGG16 algorithm. *Journal of Theoretical and Applied Information Technology*, 100(20), 6173-6184.
- [10] Nguyen, H. P., Hoang, T. P., Nguyen, H. H. 2021. A deep learning based fracture detection in arm bone X-ray images. In *2021 international conference on multimedia analysis and pattern recognition (MAPR)* (pp. 1-6). IEEE.
- [11] Alzubaidi, L., Salhi, A., A. Fadhel, M., Bai, J., Hollman, F., Italia, K., Gu, Y. 2024. Trustworthy deep learning framework for the detection of abnormalities in X-ray shoulder images. *Plos one*, 19(3), e0299545.
- [12] Manoila, C. P., Ciurea, A., Albu, F. 2022. SmartMRI framework for segmentation of mr images using multiple deep learning methods. In *2022 E-Health and Bioengineering Conference (EHB)* (pp. 01-04). IEEE.
- [13] Akgül, İ., Kaya, V., Karavaş, E., Aydın, S., Baran, A. 2024. A novel artificial intelligence-based hybrid system to improve breast cancer detection using DCE-MRI. *Bulletin of the Polish Academy of Sciences. Technical Sciences*, 72 (3), 1-11.
- [14] Akgül, İ., Kaya, V., Ünver, E., Karavaş, E., Baran, A., Tuncer, S., 2023. Covid-19 detection on x-ray images using a deep learning architecture. *Journal of Engineering Research*, vol.11, no.2B, 15-26.

- [15] Polamuri, D., Kumbhkar, M., Daniel, D. 2022. Introduction to deep learning.
- [16] Kandel, I.H.A. 2021. Deep learning techniques for medical image classification. NOVA Information Management School Universidade Nova de Lisboa Lisbon, Portugal.
- [17] McCulloch, W. S., Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity, The bulletin of mathematical biophysics 1943 5:4, vol. 5, no. 4, pp. 115–133, Dec. 1943, doi: 10.1007/BF02478259.
- [18] Nassa, V. K., Satpathy, S. K., Pathak, M. K., Takale, D. G., Rawat, S., Rana, S. 2023. A comparative analysis in using deep learning models which results in efficient image data augmentation. In 2023 4th International Conference on Computation, Automation and Knowledge Management (ICCAKM) (pp. 1-6). IEEE.
- [19] Lecun, Y., Bengio, Y., G. Hinton, G. 2015. Deep learning, Nature 2015 521:7553, vol. 521, no. 7553, pp. 436–444, doi: 10.1038/nature14539.
- [20] Alammar, Z., Alzubaidi, L., Zhang, J., Santamaria, J., Li Y. Gu, Y. 2022. A concise review on deep learning for musculoskeletal X-ray images, 2022 International Conference on Digital Image Computing: Techniques and Applications (DICTA), Sydney, Australia, pp. 1-8, doi: 10.1109/DICTA56598.2022.10034618.
- [21] Piccialli, F., Di Somma, V., Giampaolo, F., Cuomo, S., Fortino, G. 2021. A survey on deep learning in medicine: Why, how and when?. Information Fusion, 66, 111-137.
- [22] Liu, T., Zheng, H., Zheng, P., Bao, J., Wang, J., Liu, X., Yang, C. 2023. An expert knowledge-empowered CNN approach for welding radiographic image recognition. Advanced Engineering Informatics, 56, 101963.
- [23] Li, C., Li, X., Chen, M., Sun, X. 2023. Deep learning and image recognition. In 2023 IEEE 6th International Conference on Electronic Information and Communication Technology (ICEICT) (pp. 557-562). IEEE.
- [24] Ariff, N. A. M., Ismail, A. R. 2023. Study of adam and adamax optimizers on alexnet architecture for voice biometric authentication system. In 2023 17th International Conference on Ubiquitous Information Management and Communication (IMCOM) (pp. 1-4). IEEE.
- [25] Sarkar, A., Maniruzzaman, M., Alahe, M. A., Ahmad, M. 2023. An effective and novel approach for brain tumor classification using AlexNet CNN feature extractor and multiple eminent machine learning classifiers in MRIs. Journal of Sensors, 2023.
- [26] Zahan, N., Hasan, M. Z., Uddin, M. S., Hossain, S., Islam, S. F. 2022. A deep learning-based approach for mushroom diseases classification. In Application of Machine Learning in Agriculture (pp. 191-212). Academic Press.
- [27] Yan, F., Huang, X., Yao, Y., Lu, M., Li, M. 2019. Combining lstm and densenet for automatic annotation and classification of chest x-ray images. IEEE Access, 7, 74181-74189.
- [28] Dalvi, P. P., Edla, D. R., Purushothama, B. R. 2023. Diagnosis of coronavirus disease from chest x-ray images using DenseNet-169 architecture. SN Computer Science, 4(3), 214.
- [29] Shaik, S., Kirthiga, S. 2021. Automatic modulation classification using DenseNet. In 2021 5th International Conference on Computer, Communication and Signal Processing (ICCCSP) (pp. 301-305). IEEE.
- [30] Khoei, T. T., Kaabouch, N. 2022. Densely connected neural networks for detecting denial of service attacks on smart grid network. In 2022 IEEE 13th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON) (pp. 0207-0211). IEEE.
- [31] Zhou, T., Ye, X., Lu, H., Zheng, X., Qiu, S., Liu, Y. 2022. Dense convolutional network and its application in medical image analysis. BioMed Research International, 2022(1), 2384830.
- [32] Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. 2017. Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).
- [33] Podder, P., Alam, F. B., Mondal, M. R. H., Hasan, M. J., Rohan, A., Bharati, S. 2023. Rethinking densely connected convolutional networks for diagnosing infectious diseases. Computers, 12(5), 95.
- [34] Yang, J., Zhang, L., Tang, X. CrodenseNet: An efficient parallel cross DenseNet for COVID-19 infection detection, Biomedical Signal Processing and Control, 2022, doi:10.1016/j.bspc.2022.103775.
- [35] Yin, L., Hong, P., Zheng, G., Chen, H., Deng, W. 2022. A novel image recognition method based on DenseNet and DPRN. Appl. Sci. 12, 4232. <https://doi.org/10.3390/app12094232>
- [36] Goodarz, M. 2020. Automating abnormality detection in musculoskeletal radiographs through deep learning.
- [37] Mehta, R., Pareek, P., Jayaswal, R., Patil, S., Vyas, K. 2023. A bone fracture detection using ai-based techniques. Scalable Computing: Practice and Experience, 24(2), 161-171.
- [38] Arangarajan, P., Kumar, C. S., Shunmugakarpagam, N., Vijayabhasker, R., Gayathri, C. 2023. A improved training method for deep learning based anatomical classification of X-rays. In 2023 International Conference on System, Computation, Automation and Networking (ICSCAN) (pp. 1-6). IEEE.
- [39] Vojtech, J. 2022. Detecting abnormalities in x-ray images using neural networks. Bachelor's thesis. Czech Technical University in Prague, Faculty of Information Technology.
- [40] Kandel, I., Castelli, M., Popovič, A. 2021. Comparing stacking ensemble techniques to improve musculoskeletal fracture image classification. Journal of Imaging, 7(6), 100. doi:10.3390/jimaging706100
- [41] Siddiqui, A. 2020. neXt-Ray: Deep learning on bone X-rays.

- [42] Liao, L., Liu, W., Liu, S. 2023. Effect of bit depth on cloud segmentation of remote-sensing images. *Remote Sensing*, 15(10), 2548.
- [43] Karna, A., Jha, A., Dahal, A., Pandey, A., Jha, T. 2023. Chest X-Ray classification using DenseNet.
- [44] Jain, G., Mittal, D., Thakur, D., Mittal, M. K. 2020. A deep learning approach to detect Covid-19 coronavirus with X-Ray images. *Biocybernetics and biomedical engineering*, 40(4), 1391-1405.
- [45] El Asnaoui, K., Chawki, Y. 2021. Using X-ray images and deep learning for automated detection of coronavirus disease. *Journal of Biomolecular Structure and Dynamics*, 39(10), 3615-3626.
- [46] Normawati, D., D. Ismi, P. 2019. K-fold cross validation for selection of cardiovascular disease diagnosis features by applying rule-based datamining. *Signal and Image Processing Letters*, 1(2), 62-72.
- [47] Karabağ, C., Ter-Sarkisov, A., Alonso, E., Reyes-Aldasoro, C. C. 2020. Radiography classification: A comparison between eleven convolutional neural networks. In *2020 Fourth International Conference on Multimedia Computing, Networking and Applications (MCNA)* (pp. 119-125). IEEE.
- [48] Fushiki, T. 2011. Estimation of prediction error by using K-fold cross-validation. *Stat. Comput.*, 21, 137-146. doi: 10.1007/s11222-009-9153-8
- [49] Yang, F., Wei, G., Cao, H., Xing, M., Liu, S., Liu, J. 2020. Computer-assisted bone fractures detection based on depth feature. In *IOP Conference Series: Materials Science and Engineering* (Vol. 782, No. 2, p. 022114). IOP Publishing.
- [50] Karthik, K., Sowmya Kamath, S. 2023. MSDNet: A deep neural ensemble model for abnormality detection and classification of plain radiographs. *Journal of Ambient Intelligence and Humanized Computing*, 14(12), 16099-16113.
- [51] Harini, N., Ramji, B., Sriram, S., Sowmya, V., Soman, K. P. 2020. Musculoskeletal radiographs classification using deep learning. In *Deep learning for data analytics* (pp. 79-98). Academic Press.
- [52] Kandel, I., Castelli, M., Popovič, A. 2020. Musculoskeletal images classification for detection of fractures using transfer learning. *Journal of imaging*, 6(11), 127.