

İletişim / Correspondence:

¹ Uzm. / MSc.

Binalı Yıldırım Üniversitesi
osman.demirel@saglik.gov.tr

² Dr. Öğr. Ü. / Assoc. Prof. Dr
Karabük Üniversitesi
esonuc@karabuk.edu.tr

Geliş Tarihi: 15.11.2021

Kabul Tarihi: 25.12.2021

Received Date: 15.11.2021

Accepted Date: 25.12.2021

Anahtar Kelimeler:

Evrişimsel sinir ağları; Tıbbi görüntüler için derin öğrenme, Tanner-Whitehouse; Greulich ve Pyle

Keywords:

Convolutional neural networks; Deep learning for medical images; Tanner-Whitehouse; Greulich and Pyle.

Yapay Zekâ Teknikleri Kullanılarak Kemik Yaşı Tespiti

Osman DEMİREL¹, Emrullah SONUÇ²

Özet

Radyografi görüntülerinden kemik yaşının belirlenmesi, çocukların gelişimlerinin takibinde ve adli tıpta önemli bir yer tutmaktadır. Kemik yaşı tayini genellikle Greulich ve Pyle yöntemi veya Tanner-Whitehouse yöntemi kullanılarak sol elin radyolojik muayenesi ile yapılmaktadır. Bu yöntemler gözlemsel eşleşmelere dayalı sonuçlar üretmektedir. Bu durum radyologların tespitleri arasında farklara neden olabilmektedir. Bu çalışmada amaç, hekimlerin yaş tespitinde kullanabilecekleri destekleyici bir yöntem sunarak daha başarılı tahmin yapmalarına olanak sağlamaktır. Çalışmada, kemik yaşını otomatik olarak değerlendirmek için karpal kemiklerin hesaplanmış alanları ve radiusun distal epifiz bölgesinin birlikte kullanıldığı bir yöntem önerilmiştir. 1-7 yaş arası erkek ve kız çocukların sol el grafiklerini içeren yerli bir veri seti kullanılmıştır. Karpal kemikler, Digital Imaging and Communications in Medicine, Tıpta Dijital Görüntüleme ve İletişim (DICOM) görüntü penceresi değişkenleri, kenar ve kontur tespit ediciler kullanılarak ayrıştırılmıştır. Ayrıştırılan karpal kemikler manuel olarak seçilerek alanlar hesaplanmıştır. Alanlar ve radiusun distal epifiz bölgesi, modellenen yapay sinir ağına verilerek %87 doğruluk ile eğitilmiştir. Modelin test verileri üzerindeki başarı oranı %85 olarak ölçülmüştür. Sonuç olarak önerilen yöntemin kemik yaşının belirlenmesinde etkili olduğu ortaya konulmuştur.

Bone Age Determination using Artificial Intelligence Techniques

Osman DEMİREL¹, Emrullah SONUÇ²

Abstract

Determination of bone age from radiography is important in pediatric development follow-up and forensic medicine. Bone age determination is usually made by radiological examination of the left hand using the Greulich and Pyle method or the Tanner-Whitehouse method. These methods produce results based on observational matches, which can cause differences in the determinations of radiologists. The aim of our study is to provide a supportive method that physicians can use in age determination, allowing them to make a more successful estimation. In this study, a method is proposed in which the calculated areas of carpal bones and the distal epiphyseal region of the radius are used together to assess bone age automatically. A native data set containing left hand graphics of boys and girls aged 1-7 was used. Carpal bones were decomposed using DICOM (Digital Imaging and Communications in Medicine) image window variables, edge and contour detectors. Areas were calculated by manually selecting the dissociated carpal bones. The areas and the distal epiphyseal region of the radius were given to the modelled artificial neural network and the network was trained with an accuracy of 87%. The success rate of the model on the test data was measured as 85%. As a result of the study, it was concluded that the proposed method is effective in determining bone age.

1. Giriş

Çocukların kemik yaşının değerlendirilmesi, büyüme sırasındaki iskelet bozukluklarının tedavisi için önemlidir (Cheung ve Luk, 2017). Yapısal büyüme gecikmesi, büyüme hormonu eksikliği, hipotiroidizm, yetersiz beslenme ve kronik hastalığı olan çocuklarda daha fazla görülmektedir (İzgi ve Kök, 2020; Martin ve diğerleri, 2011).

Herhangi bir suç işlendiğinde, şüphelinin bildirilen yaşının şüpheli olduğu ve kişisel belgelerinin geçersiz veya mevcut olmadığı durumlarda yaş tespiti önem kazanmaktadır (Schmeling, Olze, Reisinger, König ve Geserick, 2003).

Sağ elin baskın olarak kullanımı ve sol el kemiklerinin daha az deforme olması nedeniyle değerlendirmelerde sol el kemikleri tercih edilmektedir (Subramanian ve Viswanathan, 2021). Standart bir klinik prosedür olmamasına rağmen, çoğunlukla iki klinik yöntem kullanılmaktadır. En sık kullanılan yöntem Greulich ve Pyle (GP) yöntemidir. Ek olarak, Tanner Whitehouse (TW) yöntemi de bu amaçla kullanılmaktadır (Pinchi ve diğerleri, 2014).

Greulich ve Pyle Atlası, erkek ve kadın sol el röntgen filmlerinin yer aldığı standart referans görüntüler içerir. Kemik yaşı, sol el bileği görüntülerinin atlastaki farklı yaşlar için standart olan görüntüler ile karşılaştırılarak atlasta yer alan en yakın eşleşen referans görüntüleriyle tespit edilir (Manzoor Mughal, Hassan ve Ahmed, 2014).

Tanner Whitehouse (TW2) Method, Tanner'ın (1962-1981) yılları arasında Londra'da bakıma muhtaç çocuklar yurdunda 3000 kız ve erkek çocuk üzerinde her 6 ayda bir aldığı el bileği röntgen görüntülerini 12 yıl süreyle incelemesi sonucu oluşturulmuş bir kemik yaşı belirleme yöntemidir. Radius, ulna ve kısa kemikler kısaca RUS harfleri ile ifade edilir ve 13 kemikten oluşur. Bu yöntemde 13 kemik ve 7 karpal kemik 8 gelişim dönemine ayrılmıştır. Gelişim evrelerinin sayısal hesaplamalarda kullanımı için her bir kemiğin

olgunlaşmaya kadar geçen süreci puanlandırılmıştır. Bireyin kemik yaşı, puanların toplamıyla elde edilmektedir (Öztürk, Kiliçoğlu ve Saka, 2013).

Kullanılan yöntemler uzmanların gözlemsel değerlendirmelerinin farklılıklarına bağlı olarak aynı sonuçları üretememe gibi bir sorunu ortaya çıkarmaktadır (Van Rijn, Lequin, Robben, Hop ve Van Kuijk, 2001).

Alshamrani, Messina ve Offiah (2019) GP atlası kullanarak yapmış oldukları meta-analiz sonucunda, atlası ait standartların kesin sonuçlar üretmediği ve Asyalı erkek ve Afrikalı kadın popülasyonlarına uygulandığında, özellikle adli/yasal amaçlarla kronolojik yaşı belirlemeyi amaçlarken dikkatli kullanılması gerektiği, yanlış sonuçlar üretebileceği kanaatine varmışlardır.

Bilgisayar bilimlerinin gelişimiyle birlikte daha istikrarlı sonuçlar üreten yöntemler üzerine çalışmalar yapılmıştır. Booz ve diğerleri (2020) yaptıkları çalışmada kronolojik yaşın, yapay zeka yaş tahmini ile Kök-Ortalama-Kare Hatasını (RMSD) 0,56 yıl olarak hesaplanmıştır. Aynı zamanda kronolojik yaşın Greulich-Pyle atlas yaş tahminine göre RMSD' si 1,12 yıl olarak hesaplanmıştır. Kullanılan yapay zekâ sistemi ortalama okuma sürelerini %87 oranında azaltmıştır.

Literatürde bu konudaki çalışmalar kısıtlıdır. Ülkemizde ise veriye ulaşım zorluğu nedeniyle az sayıda çalışma mevcuttur. Hsieh, Jong, Chou ve Tiu (2007) çalışmalarında elin karpal kemiklerinin geometrik özelliklerinin analizine dayanan bilgisayarlı bir kemik yaşı tahmin sistemi geliştirmişlerdir. Kemik yaşını kategorize etmek için doğrusal, en yakın komşu, geri yayılım sinir ağı ve radyal temel işlevli sinir ağı olmak üzere dört sınıflandırıcı ile tespit yapmışlardır. Ding, Zhao, Zhang, Wang ve Zhang (2019) yaptıkları çalışmada X-ray görüntüsünde pediatrik el kemiği segmentasyonu için bir U-Net mimarisi tabanlı çok ölçekli evrimsel ağ önermişlerdir. Geliştirilen ağ, iki alt örnekleme ve yukarı örnekleme işlemiyle U-Net mimarisine dayanmaktadır ve çocuklarda

büyüme sırasında el kemik ölçęęi deęişikliklerine karşı koymak için farklı çekirdek boyutuna sahip çoklu filtreler uygulanmışlardır.

Koitka ve dięerleri (2020) çalışmalarında kemik yaşı tespitinde kemikleşme alanlarını tanımlayan bir dedektör ağı ve tespit edilen alanlardan yaşı tahmin eden cinsiyete ve bölgeye özgü regresyon ağlarının yer aldığı bir yöntem kullanmışlardır.

Su, Fu ve Hu (2021) çalışmalarında veri artırma yöntemi kullanarak cinsiyet etiketi ve kemik yaşı bilgilerini ayrı olarak ele alan, denetimli ve yarı denetimli eğitimler yaptıklarından bahsetmişlerdir.

Deshmukh ve Khaparde (2022) yaptıkları çalışmada elin orta falanks, üçüncü metakarpal, radius ve ulna gibi beş bölgesini kullanarak hızlı bölgeye dayalı evrişimsel Sinir Ağı (R-CNN) modelinin kullanıldığı bir yöntem geliştirmişlerdir.

Bu çalışmada, dięer çalışmalardan farklı olarak gri renk skalasına sahip tekil görüntüler yerine aynı görüntünün Hounsfield Units (HU) deęerleri üzerinden çoęaltılmış gri örnekler oluşturularak en uygun gri görüntü seçilerek elin karpal kemiklerinin kontur alanları hesaplatılmıştır. Çalışmada radius distal epifizyal alanlar, oluşturulan maske aracılığı ile DICOM pixel deęerleri korunarak belirlenmiştir. Son olarak oluşturulan yapay sinir ağı modeli kullanılarak kemik yaşı tespitinde yarı otomatik bir sistem geliştirilmiştir. Çalışmada Evrişimsel Sinir Ağlarının (Convolutional neural networks, CNN) ve Çok Katmanlı Algılayıcıların (Multilayer Perceptron, MLP) birleşiminden oluşan ağa radiusun epifizyal görüntüsü ve karpal kemiklerin hesaplanan alanları aktararak yaş tahmini yapılmıştır. Çalışmanın kısımları şu şekildedir: İkinci bölüm gereç ve yöntemler bölümü olup veri setinin tanıtımından ve kullanılan görüntü işleme tekniklerinden bahsedilmiştir. Evrişimsel sinir ağı ve çok katmanlı algılayıcı hakkında bilgiler yine bu bölümde yer almaktadır. Üçüncü bölümde modelden elde edilen deneysel sonuçlar sunulmuş ve yorumlanmıştır. Son bölümde ise genel bir tartışma yapılmış ve gelecekte

yapılabilecek çalışmalar için öneride bulunulmuştur.

2. Gereç ve Yöntemler

Çalışmada Google Colab derleyici ortamında python programlama dili kullanılarak kodlama yapılmıştır. Geliştirilen masaüstü uygulamayla manuel olarak DICOM görüntüsü farklı HU deęerlerine ait gri görüntülere Canny filitesi uygulanarak karpal kemikler kontur bazlı ayrıştırılıp alanları hesaplatılmış, radius bölgesi kesilerek DICOM olarak kaydedilmiştir.

2.1. Veri Seti


Karabük Üniversitesi Etik Kurul Kararı ve Samsun İl Sağlık Müdürlüğü Bilimsel Araştırma Deęerlendirme Komisyonu izni ile Samsun İl Sağlık Müdürlüğü Veri Merkezi tarafından 1-7 yaş kız ve erkek çocuklarına ait sol el radyografilerinin anonimleştirilmesi kurum tarafından yapılarak DICOM görüntü formatında elde edilmiştir.

Ağın eğitiminde aşırı öğrenme olmaması için genellikle büyük bir veri kümesi gerekir (Wang, Ge, Li ve Fang, 2017). Aşırı öğrenme modelin yalnızca eğitim örneğine uygulanabilir bir öğrenme gerçekleştirdiği ve genelleştirilemeyeceği anlamına gelir (Mutasa, Sun ve Ha, 2020).

Veriler DICOM görüntüleyici ile açılarak hasta hareketine baęlı olduęu düşünölen görüntü bozulmaları, görüntölenmek istenilen alana giren yabancı cisimler, dalgalı görüntüler, yetersiz pozlandırma kaynaklı olduęu düşünölen dokular arası farkın az olduęu görüntüler ve yanlış organ görüntüsü gibi görüntüler veri setinden çıkartılarak karpal kemik ve radius alanlarının optimum olanları seçilmiştir. Seçilen 82 radyografik görüntünün radius epifizyal bölgesine veri büyüme işlemi yapılmıştır. Modellerin yüksek eğitim performansına sahip olmasına rağmen, yeni verilerle karşılaştıldığında performansının düştüğü aşırı öğrenme durumunun oluşmaması için eğitim verilerinin miktarı, veri artırma, düzenleme ve bırakma gibi yöntemlerle tespit

edilmektedir (Mutasa ve diğerleri, 2020). Aşırı uymayı engellemek için, veriler DICOM piksel verileri açık kaynak kodlu bir sinir ağı kütüphanesi olan Keras'ın ImageDataGenerator kütüphanesi kullanılarak Resim-1'de görüldüğü gibi öteleme (yatay-dikey), rotasyon ve yatay çevirme yöntemleriyle 4100 görüntü sayısına çıkarılmıştır. Bu görüntüler disk üzerinde olmayıp piksel veri türünde oluşturulan dizide tutulmaktadır ve tekrarlı işlemlerde aynı görüntülerin üretimi için kitaplık parametreleri ayarlanmıştır.

Resim 1. Veri Büyütme Tek Radius Epifiz bölgesi



Veri seti, %64 eğitim, %16 doğrulama ve %20 test verisi olacak şekilde bölünmüştür.

2.2. Görüntü İşleme

2.2.1. Pencereleme

Bilgisayarlı tomografide piksel yoğunluğu Hounsfield birimi olarak ifade edilir. Bilgisayarlı tomografiyle ölçülen ölçeklendirilmiş soğurma birimleridir. Hounsfield birimi, adını ilk pratik CT tarayıcıyı geliştiren ve Allan Cormack ile birlikte 1979 Nobel Tıp Ödülü'nü kazanan Sir Godfrey Hounsfield'dan almıştır (Powsner, Palmer ve Powsner, 2013).

X ışınının dokudan geçerken soğurulması doku yoğunluğu ile orantılıdır. X ışını algılayıcıları, taranan dokulardan geçen fotonların zayıflama derecesini ölçer ve verileri bayt olarak saklayan görüntü işlemcisi, görüntülenen piksellerin orantılı olarak atanmış piksel parlaklığına sahip olması için bu değerleri dönüştürür (Hermena ve Young, 2021). İlgilenilen piksel için ortalama doğrusal zayıflama katsayısı μ olarak ifade edilmiş ve ölçek, suyun 0 HU ve havanın -1000 HU değerinde olacak şekilde tanımlanmıştır (Rehani ve diğerleri, 2015).

$$(HU_{doku}) = \frac{(doku \mu - su \mu)}{su \mu} \times 1000 \quad (1)$$

Formülde (1) her bir piksel için ortalama doğrusal zayıflama katsayısı μ olarak ifade edilmiş ve ölçek, suyun 0 HU ve havanın -1000 HU değerinde olacak şekilde tanımlanmıştır (Rehani ve diğerleri, 2015).

Görüntülerdeki HU değerleri 5000 birimlik bir ölçekte ifade edilse de insan gözü optimal koşullarda çok daha az sayıda gri değeri ayırt edebilir.

Pencere genişliği, görüntüye dahil edilen HU aralığını temsil eder. Tablo-1'de HU değerlerine karşılık gelen doku bilgisi verilmiştir. Pencere seviyesi ise görüntü parlaklığını belirler. Pencere seviyesinin yüksekliğine göre parlaklık seviyesi de o kadar yüksek olur. Yağ sudan daha az yoğun olduğundan ve HU değeri -30 ila -70 aralığında

olduğundan, görüntülerde yağ her zaman sudan daha koyu görünür (Cuong ve diğerleri, 2018).

Tablo 1. HU Doku Değer Aralıkları

HU	Doku
>1000	Kemik, kalsiyum, metal
100 ila 600	İyotlu BT kontrastı
30 ila 500	Noktasal kalsifikasyonlar
60 ila 100	Kafa içi kanama
35	Gri madde
25	Beyaz madde
20 ila 40	Kas, yumuşak doku
0	Su
-30 ila -70	Yağ
<-1000	Hava

Radyografik görüntüde Tablo-1'de yer alan 1000 HU değer ile kemik dokusu beyaz en düşük değere sahip hava ise -1000 HU değeriyle siyah olarak görünür.

Pencereleme, görüntünün tüm piksel değerlerinden sadece bir kısmının görüntülenmesine izin verir. Örneğin, bir görüntünün minimum piksel değeri 0 ve maksimum piksel değeri ise 200 olabilir. Görüntünün daha parlak kısımlarındaki kontrast farklılıkları geliştirmek istenirse, 100'den 200'e kadar bir pencere seçilebilir. Seçim sonrası, 0 ila 100 arasında değerlere sahip pikseller en karanlık yoğunlukta görüntülenir ve bu nedenle monitörde görünmeyecektir (Bushberg, Seibert, Leidholdt ve Boone, 2011).


DICOM görüntü formatında tek renkli görüntülerde piksel başına bir örnek bulunur ve görüntüde, depolanan renk bilgisi bulunmaz. Röntgen, bilgisayarlı tomografi (BT) ve manyetik rezonans (MR) görüntüleri gibi klinik radyolojik

görüntüler gri skalaya sahiptir. Renk bilgisi bulunan pozitron emisyon tomografisi (PET) ve tek foton emisyon tomografisi (SPECT) gibi nükleer tıp görüntüleri tipik olarak bir renk haritası veya renk paleti ile görüntülenir. DICOM dosyasında piksel verileri bölümü, piksellerin sayısal değerlerinin saklandığı bölümdür. Veri türüne göre piksel verileri, gereken minimum bayt sayısı kullanılarak depolanır (Larobina ve Murino, 2014). DICOM görüntüsünde bulunan piksel, eğim ve kesişim değerleri kullanılarak, HU değerleri hesaplanabilir (Elsayed, Mahar, Kholief ve Khater, 2015).

$$HU = \text{Piksel Değeri} \times \text{Eğim} + \text{Kesişim} \quad (2)$$

DICOM görüntüsünde saklanan veriler, içinde eğim ve kesişme değerlerinin yer aldığı denklem (2) kullanılarak Hounsfield birimlerine dönüştürülür. Çalışmada karpal kemiklerin istenilen ayırımı sağlanması için manuel olarak pencere genişliği ve merkezi Resim-2'de görüldüğü gibi değiştirilmiştir.

Resim 2. Farklı Pencere Değerleri




2.2.2. Kenar Belirleme

Kontur çıkarma iki adımlı bir süreçtir. Öncelikle kenar algılama ve ardından kenar gruplandırma yapılır (Gong ve diğerleri, 2018).

Kenar algılama, çok sayıda yaklaşımı olan bilgisayarlı görüdeki temel işlemlerden biridir. Marr ve Hildreth (1980) yaptıkları çalışmada, Gauss ve Laplace filtrelerinin sıralı olarak uygulanmasına dayalı LoG filtresini ilk kez kullanmışlardır.

Resim 3. Karpal Kemik Seçimi



Başka bir çalışmada, polinom fonksiyonlarını yerel görüntü yoğunluklarına uydurarak ve fonksiyonların yönlü türevinin sıfır geçişlerini bularak kenarlar belirlenmiştir (Haralick, 1984).

Canny yaptığı çalışmada bir optimizasyon işlemi ile kenarları belirlemiş ve Gauss düzleştirilmiş bir görüntünün gradyan büyüklüğünün maksimumu olarak optimal dedektörlü bir yaklaşım önerilmiştir (Canny, 1986).

Canny kenar tanımlayıcıda, istenen görüntü ayrıntılarının azaltılması için görüntü uygun bir Gauss filtresiyle düzeltilmeli, her pikselde gradyan büyüklüğü ve gradyan yönü belirlenmeli, bir pikseldeki gradyan büyüklüğü gradyan yönündeki iki komşusundakinden daha büyükse piksel bir kenar olarak işaretlenmelidir. Aksi takdirde, piksel arka plan olarak işaretlenmeli, histerezis eşikleme ile zayıf kenarlar kaldırılmalıdır (Jain, Kasturi ve Schunck 1995).

Bu çalışmada gerçek zamanlı farklı pencereleme seviyelerinde Canny kenar belirleme yöntemi kullanılmıştır.


2.2.3. Kontur Belirleme

Konturlar şekil analizinde ilgilenilen nesnenin boyutunu bulmada ve nesne algılamada kullanışlıdır. Kontur tespit ediciler yerel ve global operatörler olarak ikiye ayrılır. İlki temel olarak diferansiyel analize, istatistiksel yaklaşımlara, faz uyumluluğuna, sıra filtreleri ve bunların kombinasyonlarına dayanır. İkincisi ise kontur belirginliğinin hesaplanmasını, algısal gruplamayı, gevşeme etiketlemesini ve aktif konturları içerir (Paparı ve Petkov, 2011).

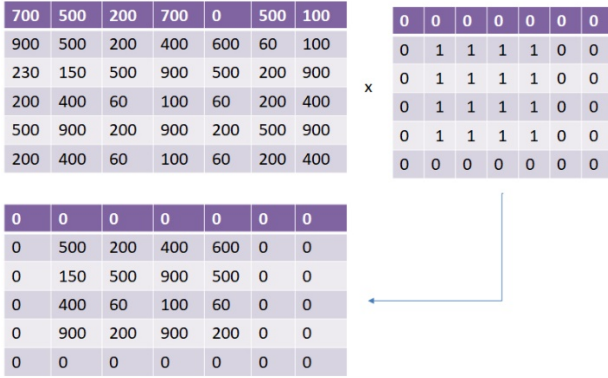
Temelde kenar izleme ve sınır izleme olarak iki tip kontur izleme tekniği bulunmaktadır. Her ikisi de basit, kapalı eğriler için aynı kontur elemanları dizisi ürettiğinden, iki yaklaşım arasındaki fark teknikten ziyade kavramsaldir (Rosenfeld, 1970). Kenar izlemede, kontur "kenarları" oluşturan bitişik piksel çiftlerinden oluşur ve izleme, nesnenin etrafında bir yönde döndürülerek (örneğin saat yönünün tersine) gerçekleştirilir (Codrea ve Nevalainen, 2005).

Çalışmamızda oluşan konturlar Resim-3'te gösterildiği gibi manuel olarak seçilmiş ve alan hesaplaması yapılarak 8 kemik için bir alan dizisi oluşturulmuştur. Henüz oluşmamış karpal kemiklerin alanları 0 kabul edilmiştir.

Resim 4. Radius bölgesi tayini



Resim 5. Görüntünün Maskelenmesi



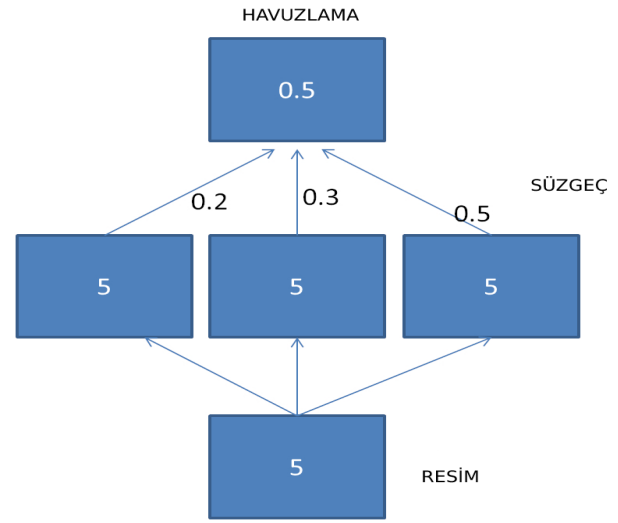
2.2.4 Radius kemiğinin seçimi.

Resim-4'te görüldüğü gibi görüntü üzerinden oluşturulan sınır kutusu manuel olarak radius kemiği epifizyal bölgeyi içerisine alacak şekilde konumlandırılmıştır. Seçili bölge Resim-5'de gösterildiği gibi görüntü maskesi oluşturularak kesme işlemi yapılmıştır. Görüntünün orijinal piksel değerleri korunarak bu işlem gerçekleştirilmiştir.

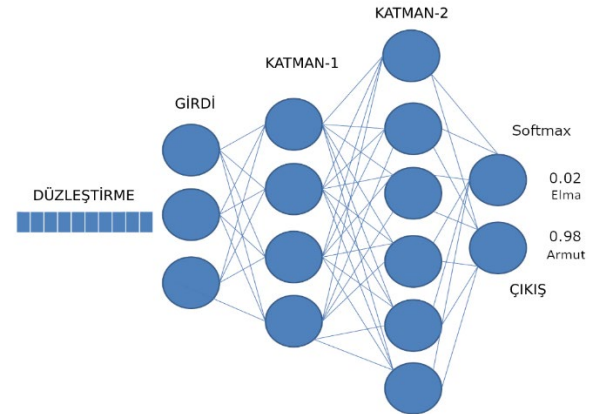
2.3 Evrişimsel Yapay Sinir Ağı

Normal bir sinir ağı, girdi verilerini tek bir vektör olarak alır ve bir dizi gizli katmandan geçer. Her gizli katman bir dizi nörondan oluşur, burada her nöron bir önceki katmandaki nöronlara bağlıdır. Çıkış katmanı olarak da adlandırılan son katman, bir görüntü sınıflandırma probleminde sınıf puanlarını içerir. Genel olarak, basit bir evrişimsel sinir ağının üç ana katmanı vardır. Bunlar evrişimsel katman, havuzlama katmanı ve tam bağlantılı katmandır (Sewak, Karim ve Pujari, 2018) (Ahmed ve Sonuç, 2021).

Resim 6. Havuzlama



Resim 7. Tam Bağlantılı Katman



Evrişimsel katmanın görevi, giriş görüntüsünden özellikleri çıkarmaktır. Bu katman, hesaplamaların büyük kısmının yapıldığı yerdir. Görüntünün üzerine filtreler uygulayarak yeni özelliklerin matrislerini oluşturur. 2-B Evrişimsel sürecin matematiksel formülü şu şekilde verilmektedir:

$$H(x, y) \rightarrow \quad (3)$$

$$= \sum_{n1=-\infty}^{n1=\infty} \sum_{n2=-\infty}^{\infty} F[n1, n2] x G[x - n1, y - n2]$$

Formülde (3), H çıktı, G girdi görüntüsünü temsil eden görüntü matrislerini, F çekirdek matrisini temsil eder. Formülde, x ve y indeksleri görüntü matrisleri, n1 ve n2 indeksleri ise çekirdek matrisleri için kullanılır.

Evrişimsel sinir ağında, evrişimsel katmanlar, çekirdek adı verilen küçük bir pencere ile kare benzeri bir şekilde bir giriş tensörünü filtreler. Çekirdek, bir evrişimsel işlemin filtreleyeceği verileri tam olarak tanımlayan ve aradığını bulduğunda güçlü bir yanıt üretecek olan yapıdır (Zafar, Tzanidou, Burton, Patel ve Araujo, 2018).

Havuzlama katman, genellikle özellik haritalarının görünüşünü azaltmak için kullanılır (Han, Zhong, Cao ve Zhang, 2017). Havuzlama, öğrenilebilir parametrelerin sayısını büyük ölçüde azaltır. Maksimum havuzlama, hareketli bir pencerede, o penceredeki maksimum değer çıktı olduğu iki boyutlu giriş alanı boyunca

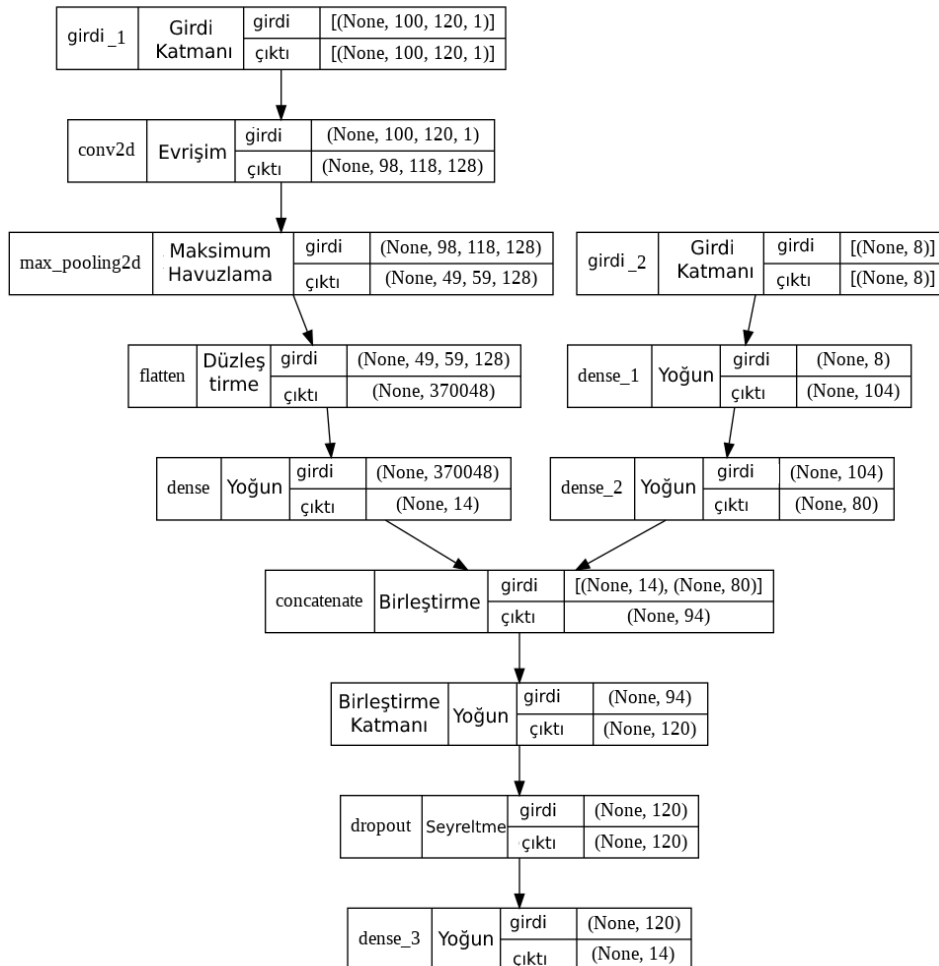
uygulanmasıdır. (Dias ve diğerleri, 2018). Modeldeki parametre sayısı Resim-6'da gösterildiği gibi azaltılmış olur.

Tam bağlantılı katman, bahsedilen katmanlar içerisinde öğrenmenin başladığı katmandır. Resim-7'de gösterildiği gibi düzleştirilen veriler aktivasyon fonksiyonlarının yardımıyla sınıflandırmaya katılırlar.

2.4. Çok Katmanlı Algılayıcı

Çok katmanlı algılayıcı (Multilayer Perceptron, MLP), en yaygın kullanılan yapay sinir ağlarından biridir. Çok katmanlı algılayıcının katmanları, yönlendirilmiş, döngüsel olmayan bir grafik oluşturur. Genel olarak, her katman bir sonraki katmana tam olarak bağlıdır; bir katmandaki her yapay nöronun çıktısı, bir sonraki katmandaki her yapay nöron için çıktıya doğru bir girdidir.

Resim 8. Uygulamalıya Ait Model



MLP'lerde üç veya daha fazla yapay nöron katmanı bulunur. Giriş katmanı, basit giriş nöronlarından oluşur. Giriş nöronları, yapay nöronların en az bir gizli katmanına bağlanır. Gizli katman, gizli değişkenleri temsil eder; bu katmanın girdi ve çıktıları eğitim verisinde gözlemlenemez. Son olarak, son gizli katman bir çıktı katmanına bağlanır (Hackeling, 2014).

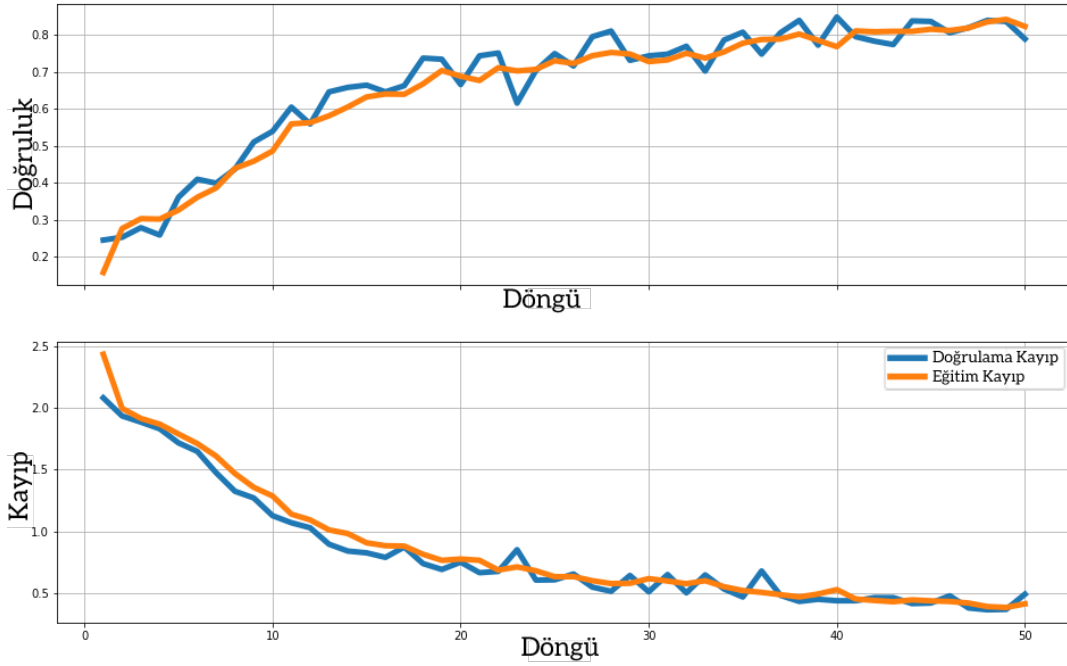
Çalışmada önerilen yapay sinir ağı Resim-8'de görülmektedir. Görüntüler 120x100 piksel ölçeğine getirilerek girdi_1 olarak, 8 karpal kemik alanı ise girdi_2 olarak verilmiştir. Evrişim ve havuzlama işlemi sonrasında sınıflandırma için veriler matris yapıdan tek boyutlu dizi yapısına geçirilerek düzleştirme yapılmıştır. Girdi olarak

verilen alan bilgisi aktivasyon fonksiyonları ile birleştirme katmanına iletilir ve burada düzleştirilen veriler ile birleştirme işlemi yapılır. Sonrasında aşırı eğitimi önlemek için seyreltme işlemine tabi tutulur. Seyreltilen veriler softmax fonksiyonuna iletilerek sınıf olasılıkları oluşturularak model eğitilmiştir.

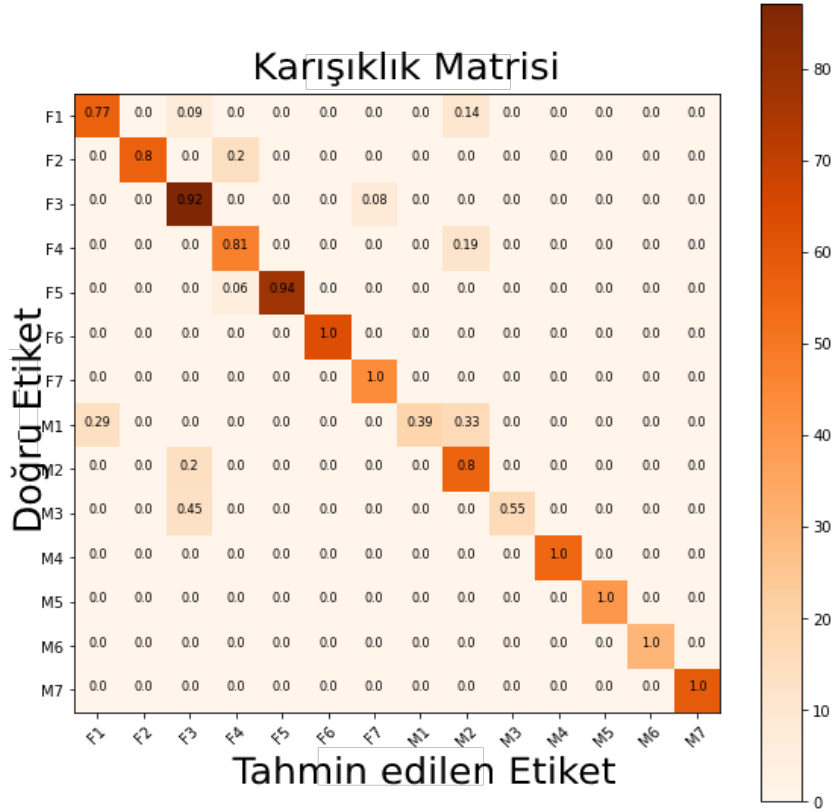
3. Bulgular

Ağ 50 döngü ile eğitilmiştir. Eğitim verileri ve doğrulama verilerinin doğruluk oranları genel olarak artış göstermiş, %87 seviyesi modelin doğruluğunun en yüksek olduğu seviye olmuştur. Eğitime ait 50 döngülük sürece ilişkin grafik Resim-9'da gösterilmiştir.

Resim 9. Modelin Eğitim Doğruluk Kayıp Grafiği



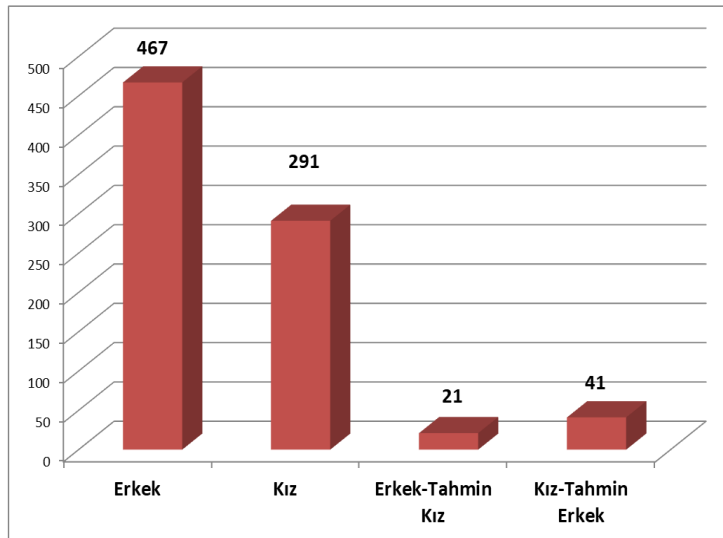
Resim 10. Karşılaştırma Matrisi (F-Kız, M-Erkek, 1M -1 Yaş Erkek)




Eğitilmiş modelin başarısı test edildiğinde modelin cinsiyet ve yaş tespit başarımı %85 olarak gerçekleşmiştir. Resim-10'da gösterilen karışıklık (hata) matrisinde modelin en düşük başarımı %39

ile 1 yaş erkek çocuklara ait el görüntülerinde olduğu gözlenmektedir. Eğitilen evrimsel sınırlı ağı, 5-7 yaş grubundaki kız ve erkek çocuklar için ortalama %99 ile en yüksek başarıyı göstermiştir.

Resim 11. Test Sonuçları Cinsiyet Dağılımı (Kişi Sayısı)



Resim 12. Test Cinsiyet Oransal Dağılım (%)

Modelin cinsiyete göre doğru tanıladığı erkek çocuk sayısının kız çocuk sayısından fazla olduğu, hatalı tanılamamanın en az erkek çocuklarda olduğu Resim-11'de yer alan test sonuçlarında görülmektedir. Modelin erkek çocuklarını tanılamadaki başarımı kız çocuklarına oranla daha yüksek olup Resim-12'de gösterildiği gibi %95,70 olarak elde edilmiştir.

4. Tartışma ve Sonuç

Veri setinin görüntü formatının DICOM olması görüntü üzerinde daha fazla kontrol imkânı sağlamaktadır. Genel olarak gri görüntü skalasına (0-255) sahip görüntüler tercih edilmekte ve araştırmalar bu görüntülerin bulunduğu veri setleri üzerinden yapılmaktadır. Aynı görüntünün farklı pencereleme seviyelerinde gri skalaya (0-255) çevrilen görüntülerin farklı sonuçlar üreteceği bir gerçektir. Çalışmada karpal kemiklerin DICOM verisinin farklı pencere seviyesinde görüntüleri işlenerek ayrıştırma yapılmıştır. Görüntüler, farklı X-ray tüp mesafesinden elde edildiğinden, görüntüsel boyut farklılıkları mevcuttur (Griffiths, Noakes ve Pocock, 1997). Görüntüleme tekniğini uygulayan kişiye bağlı olarak X-ray ışın şiddetinin görüntülemeye göre farklılık göstermesi aynı doku için farklı HU değerleri üretilmesine sebep olabilmektedir (Afifi, Abdelrazek, Deiab, Abd El-

Hafez ve El-Farrash, 2020). Bu faktörler göz ardı edilerek yapılan eğitimin başarımı %70 seviyelerinde kalmıştır. Sonrasında görüntülerde, her bir görüntünün en yüksek HU değeri üzerinden ve alan verilerinde en büyük ve en küçük alanı üzerinden normalleştirme yapılmıştır. Yapılan bu normalleştirme işlemi neticesinde eğitim başarımı %87'ye yükselmiştir.

Karpal kemiklerin özellikle 6-7 yaşlar arasında daha fazla gelişmesi, bu yaşlara ait görüntülerde kemiklerin üst üste gelerek örtüşmesine sebep olmuştur. Ayrıştırma işlemi çoğunlukla bu görüntülerde başarısız olmuştur. Model test sonuçları incelendiğinde ayrıştırmada yaşanan zorluklara rağmen 5-7 yaş arası erkek ve kız çocuklarda yüksek başarımler elde edilmiştir.

Çalışmada veri kaynağından çıkarılan farklı nitelikteki özellikler, evrimsel sinir ağı ve çok katmanlı algılayıcı ağdan oluşan yapay sinir ağı modelinde başarılı olarak eğitilmiştir.

Radyoloji kliniklerinde organ veya bölge etiketlenme işlemlerinin yapılması ve bu etiketli yapıyı saklayacak yeni formatların oluşturulması, ileride bu alanda yapılacak çalışmalar için önem arz etmektedir (Martín Noguero, Paulano-Godino, Martín-Valdivia, Menias ve Luna, 2019).

5. Teşekkür

Veri setini temin ettiğimiz Samsun İl Sağlık Müdürlüğü'ne yaptığı katkıdan ötürü yazarlar olarak teşekkür ederiz.

6. Kaynaklar

Affifi, M. B., Abdelrazek, A., Deiab, N. A., Abd El-Hafez, A. I. ve El-Farrash, A. H. (2020). The effects of CT x-ray tube voltage and current variations on the relative electron density (RED) and CT number conversion curves. *Journal of Radiation Research and Applied Sciences*, 13(1), 1-11. doi:10.1080/16878507.2019.1693176

Ahmed, S. R. A. ve Sonuç, E. (2021). Deepfake detection using rationale-augmented convolutional neural network. *Applied Nanoscience*. doi:10.1007/s13204-021-02072-3

Alshamrani, K., Messina, F. ve Offiah, A. C. (2019). Is the Greulich and Pyle atlas applicable to all ethnicities? A systematic review and meta-analysis. *European Radiology*, 29(6), 2910-2923. doi:10.1007/s00330-018-5792-5

Booz, C., Yel, I., Wichmann, J. L., Boettger, S., Al Kamali, A., Albrecht, M. H., ... Bodelle, B. (2020). Artificial intelligence in bone age assessment: Accuracy and efficiency of a novel fully automated algorithm compared to the Greulich-Pyle method. *European Radiology Experimental*, 4(1), 6. doi:10.1186/s41747-019-0139-9

Bushberg, J. T., Seibert, J. A., Leidholdt, E. M. ve Boone, J. M. (2011). *The Essential Physics of Medical Imaging*. Philadelphia, UNITED STATES: Wolters Kluwer. <http://ebookcentral.proquest.com/lib/ataturk-ebooks/detail.action?docID=2031899> adresinden erişildi.

Canny, J. (1986). A Computational Approach to Edge Detection. *A Computational Approach to Edge Detection*.

Cheung, J. P. Y. ve Luk, K. D.-K. (2017). Managing the Pediatric Spine: Growth Assessment. *Asian Spine Journal*, 11(5), 804-816. doi:10.4184/asj.2017.11.5.804

Codrea, M. C. ve Nevalainen, O. S. (2005). Note: An algorithm for contour-based region filling.

Computers & Graphics, 29(3), 441-450. doi:10.1016/j.cag.2005.03.005

Cuong, N. L. Q., Minh, N. H., Cuong, H. M., Quoc, P. N., Anh, N. H. V. ve Hieu, N. V. (2018). Porosity Estimation from High Resolution CT SCAN Images of Rock Samples by Using Housfield Unit. *Open Journal of Geology*, 8(10), 1019-1026. doi:10.4236/ojg.2018.810061

Deshmukh, S. ve Khaparde, A. (2022). Faster Region-Convolutional Neural network oriented feature learning with optimal trained Recurrent Neural Network for bone age assessment for pediatrics. *Biomedical Signal Processing and Control*, 71, 103016. doi:10.1016/j.bspc.2021.103016

Dias, C. A., Bueno, J. C. S., Borges, E. N., Botelho, S. S. C., Dimuro, G. P., Lucca, G., ... Drews Junior, P. L. J. (2018). Using the Choquet Integral in the Pooling Layer in Deep Learning Networks. G. A. Barreto ve R. Coelho (Ed.), *Fuzzy Information Processing içinde*, Communications in Computer and Information Science (ss. 144-154). Cham: Springer International Publishing. doi:10.1007/978-3-319-95312-0_13

Ding, L., Zhao, K., Zhang, X., Wang, X. ve Zhang, J. (2019). A Lightweight U-Net Architecture Multi-Scale Convolutional Network for Pediatric Hand Bone Segmentation in X-Ray Image. *IEEE Access*, 7, 68436-68445. *IEEE Access*, sunulmuş bildiri. doi:10.1109/ACCESS.2019.2918205

Elsayed, O., Mahar, K., Kholief, M. ve Khater, H. A. (2015). Automatic detection of the pulmonary nodules from CT images. 2015 SAI Intelligent Systems Conference (IntelliSys) içinde (ss. 742-746). 2015 SAI Intelligent Systems Conference (IntelliSys), sunulmuş bildiri. doi:10.1109/IntelliSys.2015.7361223

Gong, X.-Y., Su, H., Xu, D., Zhang, Z.-T., Shen, F. ve Yang, H.-B. (2018). An Overview of Contour Detection Approaches. *International Journal of Automation and Computing*, 15(6), 656-672. doi:10.1007/s11633-018-1117-z

Griffiths, M. R., Noakes, K. A. ve Pocock, N. A. (1997). Correcting the Magnification Error of Fan Beam Densitometers. *Journal of Bone and Mineral Research*, 12(1), 119-123. doi:10.1359/jbmr.1997.12.1.119

- Hackling, G. (2014). Mastering Machine Learning with scikit-learn. Olton Birmingham, UNITED KINGDOM: Packt Publishing, Limited. <http://ebookcentral.proquest.com/lib/ataturk-ebooks/detail.action?docID=1827594> adresinden erişildi.
- Han, X., Zhong, Y., Cao, L. ve Zhang, L. (2017). Pre-Trained AlexNet Architecture with Pyramid Pooling and Supervision for High Spatial Resolution Remote Sensing Image Scene Classification. *Remote Sensing*, 9(8), 848. doi:10.3390/rs9080848
- Haralick, R. M. (1984). Digital Step Edges from Zero Crossing of Second Directional Derivatives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-6(1), 58-68. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, sunulmuş bildiri. doi:10.1109/TPAMI.1984.4767475
- Hermena, S. ve Young, M. (2021). CT-scan Image Production Procedures-1. StatPearls [Internet]. StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK574548/> adresinden erişildi.
- Hsieh, C.-W., Jong, T.-L., Chou, Y.-H. ve Tiu, C.-M. (2007). Computerized geometric features of carpal bone for bone age estimation. *Chinese Medical Journal*, 120(9), 767-770.
- İzgi, M. S. ve Kök, H. (2020). Kemik Yaşı ve Maturasyon Tespiti. *Selcuk Dental Journal*. doi:10.15311/selcukdentj.477836
- Jain, R., Kasturi, R. ve Schunck, B. G. (1995). *Machine vision* (C. 5). McGraw-hill New York.
- Koitka, S., Kim, M. S., Qu, M., Fischer, A., Friedrich, C. M. ve Nensa, F. (2020). Mimicking the radiologists' workflow: Estimating pediatric hand bone age with stacked deep neural networks. *Medical Image Analysis*, 64, 101743. doi:10.1016/j.media.2020.101743
- Larobina, M. ve Murino, L. (2014). Medical Image File Formats. *Journal of Digital Imaging*, 27(2), 200-206. doi:10.1007/s10278-013-9657-9
- Manzoor Mughal, A., Hassan, N. ve Ahmed, A. (2014). Bone Age Assessment Methods: A Critical Review. *Pakistan Journal of Medical Sciences*, 30(1), 211-215. doi:10.12669/pjms.301.4295
- Marr, D. ve Hildreth, E. (1980). Theory of edge detection. *Proceedings of the Royal Society of London*, 187-217.
- Martin, D. D., Wit, J. M., Hochberg, Z., Sävendahl, L., Rijn, R. R. van, Fricke, O., ... Ranke, M. B. (2011). The Use of Bone Age in Clinical Practice – Part 1. *Hormone Research in Paediatrics*, 76(1), 1-9. doi:10.1159/000329372
- Martín Noguerol, T., Paulano-Godino, F., Martín-Valdivia, M. T., Menias, C. O. ve Luna, A. (2019). Strengths, Weaknesses, Opportunities, and Threats Analysis of Artificial Intelligence and Machine Learning Applications in Radiology. *Journal of the American College of Radiology*, Special Issue: Quality and Data Science, 16(9, Part B), 1239-1247. doi:10.1016/j.jacr.2019.05.047
- Mutasa, S., Sun, S. ve Ha, R. (2020). Understanding artificial intelligence based radiology studies: What is overfitting? *Clinical Imaging*, 65, 96-99. doi:10.1016/j.clinimag.2020.04.025
- Öztürk, Y., Kiliçoğlu, H. ve Saka, N. (2013). İskeletsel 3. Sınıf Vakalarda Kemik Olgunluğunun Tanner-Whitehouse (Tw2-Rus) Yöntemi İle Belirlenmesi-The Assesment Of The Skeletal Maturity In Skeletal Class 3 Cases According To Tanner-Whitehouse (Tw2-Rus) Method. *Journal of Istanbul University Faculty of Dentistry*, 27(1), 65-70.
- Papari, G. ve Petkov, N. (2011). Edge and line oriented contour detection: State of the art. *Image and Vision Computing*, 29(2), 79-103. doi:10.1016/j.imavis.2010.08.009
- Pinchi, V., De Luca, F., Ricciardi, F., Focardi, M., Piredda, V., Mazzeo, E. ve Norelli, G.-A. (2014). Skeletal age estimation for forensic purposes: A comparison of GP, TW2 and TW3 methods on an Italian sample. *Forensic Science International*, 238, 83-90. doi:10.1016/j.forsciint.2014.02.030
- Powsner, R. A., Palmer, M. R. ve Powsner, E. R. (2013). *Essentials of Nuclear Medicine Physics and Instrumentation*. Somerset, UNITED STATES: John Wiley & Sons, Incorporated. <http://ebookcentral.proquest.com/lib/ataturk-ebooks/detail.action?docID=1127124> adresinden erişildi.
- Rehani, M. M., Gupta, R., Bartling, S., Sharp, G. C., Pauwels, R., Berris, T. ve Boone, J. M. (2015). ICRP Publication 129: Radiological Protection in Cone

Beam Computed Tomography (CBCT). *Annals of the ICRP*, 44(1), 7-127. doi:10.1177/0146645315575485

Rosenfeld, A. (1970). Connectivity in Digital Pictures. *Journal of the ACM (JACM)*, 17(1), 146-160. doi:10.1145/321556.321570

Schmeling, A., Olze, A., Reisinger, W., König, M. ve Geserick, G. (2003). Statistical analysis and verification of forensic age estimation of living persons in the Institute of Legal Medicine of the Berlin University Hospital Charité. *Legal Medicine, Selected papers from the 5th International Symposium on Advances in Legal Medicine (ISALM) 2002*, 5, S367-S371. doi:10.1016/S1344-6223(02)00134-7

Sewak, M., Karim, R. ve Pujari, P. (2018). *Practical Convolutional Neural Networks: Implement Advanced Deep Learning Models Using Python*. Birmingham, UNITED KINGDOM: Packt Publishing, Limited. <http://ebookcentral.proquest.com/lib/ataturk-ebooks/detail.action?docID=5314627> adresinden erişildi.

Su, L., Fu, X. ve Hu, Q. (2021). Generative adversarial network based data augmentation and gender-last training strategy with application to bone age assessment. *Computer Methods and Programs in Biomedicine*, 212, 106456. doi:10.1016/j.cmpb.2021.106456

Subramanian, S. ve Viswanathan, V. K. (2021). Bone Age. *StatPearls [Internet]*. StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK537051/> adresinden erişildi.

van Rijn, R. R., Lequin, M. H., Robben, S. G. F., Hop, W. C. J. ve van Kuijk, C. (2001). Is the Greulich and Pyle atlas still valid for Dutch Caucasian children today? *Pediatric Radiology*, 31(10), 748-752. doi:10.1007/s002470100531

Wang, L., Ge, L., Li, R. ve Fang, Y. (2017). Three-stream CNNs for action recognition. *Pattern Recognition Letters*, 92, 33-40. doi:10.1016/j.patrec.2017.04.004

Zafar, I., Tzanidou, G., Burton, R., Patel, N. ve Araujo, L. (2018). *Hands-On Convolutional Neural Networks with TensorFlow: Solve Computer Vision Problems with Modeling in TensorFlow and Python*. Birmingham, UNITED KINGDOM: Packt

Publishing, Limited. <http://ebookcentral.proquest.com/lib/ataturk-ebooks/detail.action?docID=5504396> adresinden erişildi.