

T.C. İZMİR KATİP ÇELEBİ ÜNİVERSİTESİ TIP FAKÜLTESİ

ATATÜRK EĞİTİM VE ARAŞTIRMA HASTANESİ

ACİL TIP ANABİLİM DALI

**YAZILIMSAL ALGORİTMA KULLANARAK SKAFOİD
KIRIKLARININ OTOMATİK TESPİTİ**

UZMANLIK TEZİ

DR EMRE ÖZKAYA

TEZ DANIŞMANI

DOÇ. DR. FATİH ESAD TOPAL

DOÇ. DR. ZEYNEP KARAKAYA

İZMİR-2020

T.C. İZMİR KATİP ÇELEBİ ÜNİVERSİTESİ TIP FAKÜLTESİ

ATATÜRK EĞİTİM VE ARAŞTIRMA HASTANESİ

ACİL TIP ANABİLİM DALI

**YAZILIMSAL ALGORİTMA KULLANARAK SKAFOİD
KIRIKLARININ OTOMATİK TESPİTİ**

UZMANLIK TEZİ

DR EMRE ÖZKAYA

TEZ DANIŞMANI

DOÇ. DR. FATİH ESAD TOPAL

DOÇ. DR. ZEYNEP KARAKAYA

İZMİR-2020

TEŞEKKÜR

Yetişmemde ve tez hazırlanması sürecine katkılarından dolayı sayın Anabilim Dalı Başkanı ve tez hocam **Doç. Dr. Fatih Esad TOPAL**'a,

Hocalarım **Dr. Öğr. Üyesi Umut PAYZA**'a ve **Doç Dr. Zeynep KARAKAYA**'ya,

Tezimde çok emeği olan **Dr. Öğr. Üyesi Merve GÜRSOY BULUT** ve **Doç. Dr. Tuğrul BULUT** hocalarıma,

Tüm eğitim ve çalışma hayatım boyunca yanımda olan aileme,

Her zaman yanımda olan ve tezimi tamamlamamda büyük emeği olan hayat ortağım **Yasemin ÖZKAYA**'ya,

Bu süreçte aramıza katılan oğlum **Ali Aras ÖZKAYA**'ya,

Acil tıp eğitimim süresince üzerimde emeği geçen tüm öğretim üyelerine,

Acil servis doktoru olmanın zorluğunu, keyfini, heyecanını ve ayrıcalığını birlikte paylaştığım tüm doktor arkadaşlarıma ve tüm acil tıp çalışanlarına teşekkürlerimi sunarım.

Dr. Emre ÖZKAYA

İÇİNDEKİLER

SİMGELER ve KISALTMALAR	v
ŞEKİLLER TABLOSU.....	vi
TABLolar.....	vii
1-GİRİŞ	1
2-GENEL BİLGİLER	3
2.1 El Bileği Anatomisi.....	3
2.2 Skafoid Anatomisi.....	4
2.2.1 Kemiksel Anatomi.....	4
2.2.2 Ligamantöz Anatomi.....	5
2.2.3 Skafoid Kanlanması	8
2.3 Skafoid Kırıklarının Biyomekaniği.....	9
2.4 Skafoid Kırıklarının Tanısı ve Sınıflaması.....	10
2.4.1 Skafoid Kırıkları Tanısı.....	10
2.4.2 Skafoid Kırıkların Sınıflaması	12
2.5 Yapay Zekâ	16
2.6. Makine Öğrenmesi	16
2.6.1. Danışmanlı Öğrenme.....	17
2.6.2. Danışmansız Öğrenme	17
2.6.3. Pekiştirmeli Öğrenme.....	17
2.7. Yapay Sinir Ağları	17
2.7.1. Yapay Sinir Ağlarının Genel Özellikleri.....	18
2.7.2. Yapay Sinir Ağlarının Kullanım Alanları	19
2.7.3. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	19
2.7.3.1. Biyolojik sinir hücresi	19
2.7.3.2. Yapay Sinir Hücreleri.....	20
2.7.4. Yapay Sinir Ağlarının Sınıflandırılması	22
2.7.4.1. İleri Beslemeli Yapay Sinir Ağları.....	24
2.7.4.2. Geri Beslemeli Yapay Sinir Ağları	24
2.8. Derin Öğrenme	25
2.8.1. Derin öğrenime giriş.....	25
2.8.2. Derin öğrenmenin tarihi	26
2.8.3. Derin Sinir Ağı (Deep Neural Network).....	28
2.8.4. Derin Öğrenme.....	28
2.8.4.1. Vanishing Gradient (kaybolma gradyanı).....	29
2.8.4.2. Overfitting (Aşırı Uygunluk)	29

2.8.4.3. Computational load (Hesaplama yükü).....	30
2.8.5. Konvolüsyonel Sinir Ağları (Convolution Neural Network- ConvNet-CNN)	30
2.8.5.1. Konvolüsyon (Evrışim) Katmanı	31
2.8.5.2. Pooling Layer (Havuzlama Katmanı)	32
2.8.5.3. Fully Connected Layer (Tam Bağlı Katman).....	32
2.8.5.4. Hiper-Parametreler	33
3-GEREÇ YÖNTEM	36
3.1. Hasta dahil edilmesi	36
3.2. Veriler.....	36
3.3.Eğitim ve Validasyon	38
3.4.Ölçek	38
3.5.Verilerin Analiz Edilmesi.....	39
4-BULGULAR.....	40
5-TARTIŞMA	41
6-SONUÇ	44
7-ÖZET	45
SUMMARY	47
KAYNAKLAR.....	49
EKLER	56
Ek-1.1 Etik Kurul Onayı	56

SİMGELER VE KISALTMALAR

BT	:Bilgisayarlı Tomografi
CNN	:Konvolüsyonel Sinir Ağları
CSI	:Kimyasal Kaydırma Tekniği (Chemical Shift İmaging)
DNN	:Derin Sinir Ağları
GPU	:Grafik İşlem Birimi
MRG	:Manyetik Rezonans Görüntüleme
NPD	:Negatif Prediktif Değer
PA	:Posteroanterior
ROI	:Region of Interest
PPD	:Pozitif Prediktif Değer
YSA	:Yapay Sinir Ağları

ŞEKİLLER TABLOSU

Şekil 1 Karpal kemiklerin birbirleriyle ilişkileri	4
Şekil 2 El bileği dış bağları	6
Şekil 3 Skafoide yapışan ve stabiliteden sorumlu bağlar	8
Şekil 4 Skafoid kanlanması sağlayan 2 ana arter ve anjiografik görünümü	9
Şekil 5 MAYO Kırık Yerleşimi	13
Şekil 6 Skafoid kırıklarında Russe sınıflaması	14
Şekil 7 Skafoid kırıklarının Herbert ve Fisher sınıflaması.....	15
Şekil 8 Makine öğrenme teknikleri	16
Şekil 9 Biyolojik sinir hücresi	20
Şekil 10 Yapay sinir hücresinin yapısı	21
Şekil 11 Yapay sinir ağları katmanları	22
Şekil 12 Yapay sinir ağı mimarileri	23
Şekil 13 Yapay sinir ağı modelleri	24
Şekil 14 Yapay zekâ ile derin öğrenme arasındaki ilişki	25
Şekil 15 Derin sinir ağı.....	28
Şekil 16 Konvolüsyonel sinir ağı mimarisi	31
Şekil 17 Konvolüsyon katmanı süreci.....	32
Şekil 18 Skafoid bölgesini içeren dikdörtgen bir alanın seçimi.....	37
Şekil 19 Hem kırık hem de sağlıklı skafoid görüntüler içeren son veri kümesinden örnek görüntüler.	37

TABLULAR

Tablo 1 Klinik testlerin skafooid kırığı teşhisindeki doğruluk oranları	10
Tablo 2 Radyografik görüntüler	12
Tablo 3 Skafooid Kırık Sınıflamaları.....	14
Tablo 4 Skafooid kırıklarının tanısında CNN'nin tanısal doğruluğu.....	40



1-GİRİŞ

Skafoid kırıklar tüm karpal kemik kırıkları arasında en sık görülen kırıklardır (1). Üst extremite kırıkları içinde distal radius kırıklarından sonra ikinci sırada gelmektedir (2). Skafoid kırıkları %30'dan fazla oranda ilk etapta atlanan, tanısı geciken kırıklardır (3).

Skafoid kırıklarının teşhisi esas olarak radyografilerde yapılır, ancak bileğin karmaşık anatomik yapısından dolayı skafoid kemiğin radyografilerde değerlendirilmesinde zorluklar görülebilir. Bu durum özellikle acil servislerde bu kırıkların gözden kaçmasına neden olabilir. 6 hafta sonra teşhis edilen olgularda psödoartroz gelişme riskinin daha yüksek olduğu bildirilmektedir (4). Skafoid psödoartroz engelli ağrıya ve el fonksiyonunda azalmaya neden olur (5). Bu nedenle, bu kırıklar için erken tanı çok önemlidir.

Tanı ve tedavideki gecikmeler kırık prognozunu olumsuz yönde etkilemektedir. Skafoidin bu kaynamamaya yatkınlığının nedenleri arasında tanı gecikmesi, kemiğin %80 kadarının eklem yüzü olmasına bağlı zayıf vasküler desteği, kırık hattındaki yüksek gerilim kuvvetleri, eklem sıvısının iyileşme faktörlerini seyreltici etkisi sayılabilir.

Akut skafoid kırıklarının tanısını koymak güçtür. Nondeplase skafoid kırıkları masum lezyonlar değildir. Uzun süreli alçı yapılmalı veya erken osteosentez yapılmalıdır. Bazı çalışmalara göre skafoid kırığı şüphesi olan hastaların gerçek kırık prevalansı %5-10 civarındadır (6). Kırık şüphesi olan hastaların gereksiz yere alçı ile fazla tedavi edilmesinden de kaçınılmalıdır. Yapılan bir çalışmada %76-100 arasında değişen oranlarda gereksiz yere fazla alçı yapıldığı ve bu nedenle iş gücü kaybı ve gereksiz sağlık harcamaları olduğu tespit edilmiştir (7).

Skafoid kırığı komplikasyonlara açık bir kırıktır. Avasküler nekroz, %13-50 arasında değişen oranlarda en sık görülen komplikasyondur. Diğer komplikasyonlar nonunion, malunion, karpal instabilite ve radiokarpal artrozdur. Bu nedenle erken tanısı ve tedavisi hastalığın prognozu açısından kritik öneme sahiptir (8).

Bilgisayarlı tomografi (BT) erken tanı için kullanılabilir, ancak bu ek maliyetlere ve radyasyona maruz kalmaya yol açar. Ayrıca, BT'ye erişim her zaman mevcut değildir. Radyografiler acil servis doktorları veya acil servislerdeki deneyimli olmayan ortopedik cerrahlar tarafından değerlendirildiğinden, skafoid kırıklarının yanlış teşhisi nadir değildir. Bu nedenle, kırıkların erken ve doğru teşhisi için yeni ve kolay erişilebilir yöntemler geliştirmek son derece önemlidir.

Derin öğrenme yapay sinir ağlarının eğitimine dayanan bir makine öğrenme yaklaşımıdır. Görüntü analizi için genellikle bir dizi görüntü filtresi öğrenen evrişimli sinir ağı katmanları kullanılır ve bu da görüntü verilerinin daha verimli analizine yol açar. Bu sinir ağlarına Konvolüsyonel Sinir Ağları (CNN) denir. CNN'ler rastgele başlatılan filtre ağırlıklarından başlayarak eğitilebilir veya alternatif olarak hedef görüntü kümesi ve sorun için önceden ayarlanmış bir ağdan ağırlıklar ayarlanır. İkinci yaklaşıma transfer öğrenme denir ve çok daha az görüntü verisi gerektirir ve klinik problemlere ve veri setlerine başarıyla uygulanmıştır. Son yıllarda, çok sınırlı bir çalışmada, CNN kullanımı ile derin öğrenmenin kemik kırıklarının teşhisinde kullanılabileceği gösterilmiştir. (9) Derin sinir ağı klinisyenler tarafından kırık tespitini geliştirir (10). Bununla birlikte, bilginiz dahilinde, literatürde skafoid kırıklarının tanısında derin öğrenmenin doğruluğunu araştıran bir çalışma bulunmamaktadır. Bu çalışmanın amacı, anteroposterior (AP) el bilek radyografilerinde skafoid kırıklarının saptanmasında CNN kullanımı ile derin öğrenme algoritmasının doğruluğunu saptamaktır.

2-GENEL BİLGİLER

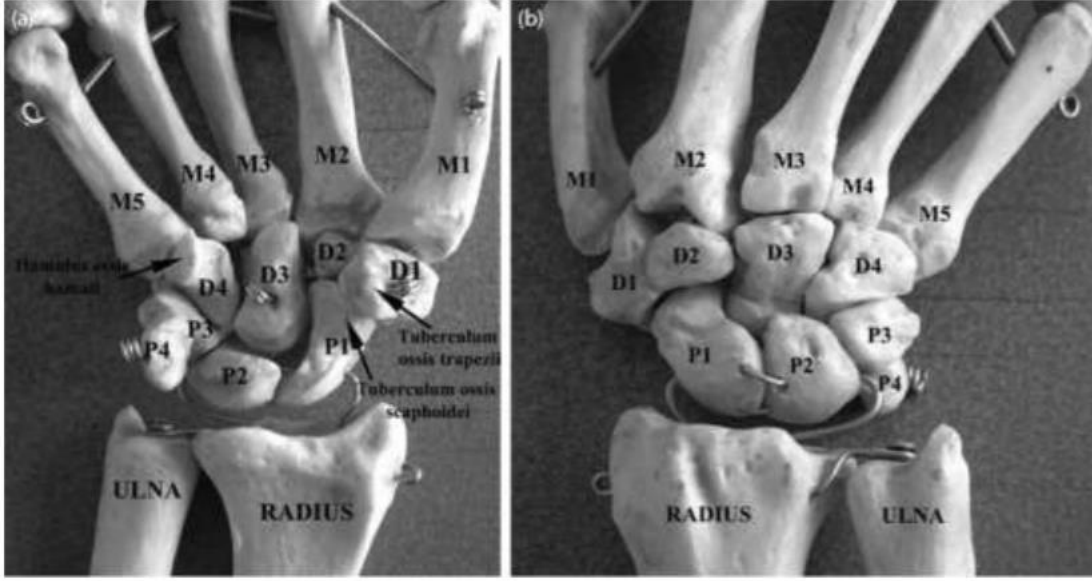
2.1 El Bileği Anatomisi

El bileği elin proksimal bölümü olup; el ve önkol bileşkesini oluşturur. El bileği, proksimalde ve distalde dörder adet olmak üzere, iki sıra üzerine dizilmiş sekiz adet karpal kemikten oluşur. Volar (ön) tarafta konkav, dorsal (arka) tarafta transvers yönde konveks, bir yüzey oluşturarak sıralanan bu küçük kemikler el bileğine esneklik kazandırır. Hem karpal kemikler hem de proksimal ve distal sıra kemikleri birbirleri üzerinde kayma hareketi yaparlar.

Proksimal sırada anatomik pozisyonda dıştan içe doğru os scaphoideum, os lunatum, os triquetrum ve os pisiforme bulunurken, distal sırada ise os trapezium, os trapezoideum, os capitatum ve os hamatum bulunur. Os pisiforme hariç, hepsinin genellikle altı yüzü vardır. Bu kemiklerin volar ve dorsal yüzlerine bağlar tutunduğu için pürtüklüdür. Os scaphoideum ve os lunatum dışındakilerinin dorsal yüzleri volar yüzlerine oranla daha geniştir. Proksimal ve distal yüzleri komşu kemiklerle eklem yaptığı için buralarda eklem yüzü bulunur. Genellikle proksimal yüzleri konveks, distal yüzleri konkavdır (11).

Bu kemikler doğumda henüz kemikleşmemiştir ve kırık yapıdadırlar. Os capitatum, ilk bir yıl içinde kemikleşmeye başlarken, diğerleri kemikleşme sürecini 12. yaşa kadar belli dönemlerde tamamlamış olurlar (12).

En çok kırılan karpal kemik os scaphoideum'dur. Uygun bir şekilde tedavi edilmediğinde psödoartroz gelişebilir. Sonrasında ise ağrı, kalıcı güçsüzlük ve osteoartrit gelişerek fonksiyon kaybına neden olabilir. Os scaphoideum'un kan damarları kemiğin proksimal ve distal bölümünden girer. Fakat bazen kan damarları kemiğin distal bölümünde toplanmış olabilir ki bu durum, kırık sonrasında kemiğin proksimal bölümünün avasküler nekrozu ile sonuçlanır (13).



Şekil 1 Karpal kemiklerin birbirleriyle ilişkileri (14) (a) Palmar taraftan, (b) dorsal taraftan görüntü. P: Proksimal sıra kemikleri; P1: Os scaphoideum; P2: Os lunatum; P3: Os triquetrum; P4: Os pisiforme; D: Distal sıra kemikleri; D1: Os trapezium; D2: Os trapezoideum; D3: Os capitatum; D4: Os hamatum; M1-M5: Metakarpal kemikler

2.2 Skafoid Anatomisi

2.2.1 Kemiksel Anatomi

Skafoid bileğin proksimal sırasındaki en büyük kemiktir. Skafoidin yaklaşık %80'i kırıkdayak yüzey ile kaplıdır. En dar yeri 6 mm enindedir. Skafoid ismini, Yunanca kayık, sandal anlamına gelen “scaphe” kelimesinden almıştır. Bu ismin verilmesinin nedeni gemi pruvası gibi kemik, proksimalde genişlerken distalde daralmaktadır (15).

Skafoidin kendine özgü anatomisi, karpal kemik kırıklarının gecikmiş olarak kaynamasına veya kaynamamasına zemin hazırlar. Distal radius ve kalan yedi karpal kemiğin dördüyle eklem yapması nedeniyle skafoid tüm karpal hareketlerde özellikle de volar fleksiyonda hareket etmektedir. Kırık, çıkık veya yarı çıkık yoluyla eklem yüzeyindeki herhangi bir değişiklik veya ligament rüptürü sebebiyle stabilitesindeki bir değişiklik, bütün karpal bölgeyi etkileyen ciddi sekonder değişikliklere neden olur (16).

Beş kemikle (radius, lunat, kapitat, trapezium ve trapezoid) eklem yapar. Proksimalde radius ile eklemleşen dış bükey şekilli eklem yüzüne, ulnarda lunat ile eklemleşen yarımay şekilli ve capitat ile eklemleşen iç bükey şekilli eklem yüzüne, distalde de trapezyum ve trapezoid ile eklemleşen bir adet eklem yüzüne sahiptir. Skafoidin karmaşık üç boyutlu bir geometrisi ve oblik yönelimi vardır. Skafoid el bileği uzun ve yatay eksenine 45 °lik açı ile

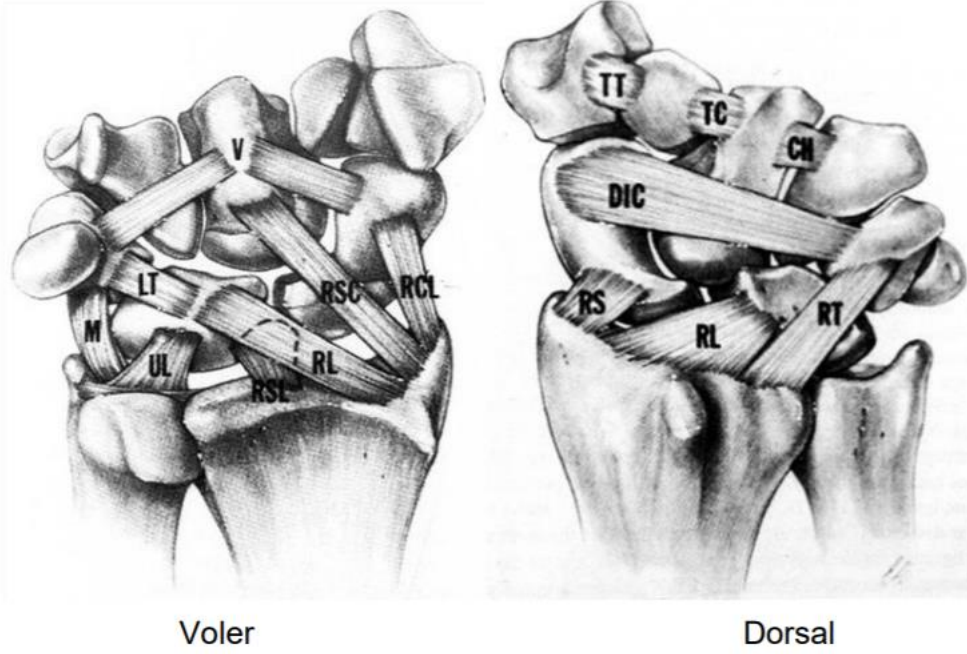
yerleşmiştir. Skafoid distal ucu proksimale göre pronasyona, flexiona ve ulnara açılanmıştır (17).

2.2.2 Ligamantöz Anatomi

El bileğinin dış bağları; radiokarpal, midkarpal ve her iki eklemide geçen kapsüler bağlardır. İç bağları ise başlangıç ve yapışma yerleri karpal kemikler üzerinde olan kapsül içi bağlardır (18).

El bileğinin iç bağları; proksimal karpal sırayı birleştiren skafolunat, lunotriquetral ve distal karpal sırayı birleştiren trapeziotrapezoidal, trapeziocapitat, kapitoamat bağlardır (16). Dış bağları ise; palmar yüzde radial tarafta radioskafocapitat bağ, radioskafolunat bağ, uzun ve kısa radiolunat bağ, ulnar tarafta ulnolunat ve lunotriquetral bağlardır.

Dorsal yüzde dorsal radiokarpal ve dorsal interkarpal bağlar mevcuttur. Dorsal dış bağlar; dorsal retinakulum eksiz edilip ekstensör tendonlar ekarte edildiğinde görülebilirler. Dorsal bağlar klinik olarak skafoidin stabilitesinden ve karpal hareketler sırasında skafoidin diziliminin korunmasından sorumludur (19). Ayrıca radyal tarafta radius stiloidinden skafoidin bel bölgesine uzanan radyal kollateral bağ ve ulnar tarafta ulna stiloidinden pisiform kemiğe uzanan ulnar kollateral bağ da vardır.



Şekil 2 El bileği dış bağları Voler: (RSC; radioskafocapitat, RSL; radioskafolunat, RL; radiolunat, RCL; radioskafoid, UL; ulnolunat, LT; lunotriquetral) Dorsal: (DIC; dorsal interkarpal, RT; radiotriquetral, RL; radiolunat, RS; radioskafoid) (20)

Dorsal radiokarpal bağ (dorsal radiotriquetral bağ); distal radius üzerinde bulunan lister tüberkülünden başlar ve distale triquetruma doğru uzanır. Dört ayrı varyasyonuna rastlanmıştır. Direk olarak skafoide yapışmaz; derin dalları lunatuma yüzeysel dalları ise triquetruma yapışır.

Dorsal interkarpal bağ; triquetrumdan başlar, skafoidin dorsal yükseltisine, trapeziuma, trapezoideuma yapışır. Dorsal interkarpal bağın derin dalları skafolunat ve lunotriquetral interosseöz bağların liflerine katılır ve onları güçlendirir (18,19).

Dorsal radiokarpal bağ ile birlikte dorsal stabiliteyi sağlar (19).

Radioskafokapitat bağ; geniş kapsüler bir bağdır. Radiusun palmar dudağından birçok noktadan başlar; skafoidin bel bölgesinin lateral palmar yüzüne ve distal kutbun proksimal yüzüne ve kapitatumun beline yapışır. Ulnokapitat bağ ile birleşerek arkuat bağı (deltoid bağı) oluşturur. Radioskafokapitat bağın gücü 100-150 newton olarak ölçülmüştür (18,19).

Radioskafolunat bağ (Testut bağı) bilek stabilitesinde çok az rol alır. Uzun ve kısa radiolunat bağlar arasında yer alır. Bu bağın histolojik değerlendirmelerinde organize kollajen demetlerinin olmadığı ortaya koyulmuştur. Bu nedenle gerçek bir bağ olmadığı söylenmektedir. Bu bağın asıl önemi; içinde vasküler ve nöral yapılar taşımaktır. Gücü 40 Newton olarak hesaplanmıştır (19).

Uzun radiolunat bađ; radiusun palmar dudađından bařlar, skafoidin proksimal kutbu üzerinden geerek lunatumun palmarına yapıřır. Radioskafokapitat ve uzun radiolunat bađlar arasındaki bořluđa Poirier aralıđı adı verilir. Bu alan perilunat ıkıkların oluřabileceđi zayıf nokta oluřturur (21).


Kısa radiolunat bađ lunat fossanın yanından radius dudađından bařlar ve lunatumun palmarına yapıřır. Bu bađın lifleri uzun radiolunat bađ, palmar lunotrikuetral bađ ve ulnolunat bađın lifleri ile kaynařır. Kısa radiolunat bađ lunatum kemiđinin en önemli stabilizatörüdür. Hiperekstansiyon zorlamalarında ıkıkđı önlemektedir (21).

Skafoide yapıřan interosseöz bađların kemik üzerinde ligamentöz yapıřma yerleri mevcuttur. (řekil 3)

Skafolunat interosseöz bađ; palmar, dorsal ve proksimal fibrokartilajinöz membran olmak üzere 3 bölümden oluřur. Bađın dorsal kısmı dorsalde skafoid ve lunat kemikleri birleřtiren kısa ve kalın liflerden oluřmuřtur. Skafolunat stabilitedeki rolü ok önemlidir. Volardeki kısmı ise nispeten daha zayıftır ve stabilitede rolü daha azdır (21).

Skafotrapezial bađ skafoidin distal kutbunun lateral yüzüne yapıřır. Skafoidin stabilitesi önemli oranda onu lunatum ve distalde trapezyum ve trapezeideuma bađlayan kısa i bađlarla iliřkilidir.

Skafokapitat bađ distal kutbun palmar ve lateral nonartikular yüzüne yapıřır. Kısa bir bađdır (22).




Şekil 3 Skafoide yapışan ve stabiliteden sorumlu bağlar (21)

2.2.3 Skafoid Kanlanması

Skafoidin beslenmesi palmar ve dorsalden olmak üzere 2 adet arteriyel sistem ile sağlanır. Bunlar radial arterin palmar süperficial dalı ve radial arterin dorsal karpal dalıdır. (Şekil 4) Dorsal dal distalden girerek kemiğin proksimal %70-80'ini besler. Palmar dallar ise dorsal dallar gibi distalden girer ancak tuberositas da dahil olmak üzere distal %20-30'luk kısmını besler. Bu nedenle proksimal parçanın kanlanması voler girişimlerde daha az zarar görmektedir (23).

Bu iki arteriyel sistem arasında intraosseöz bir bağlantı yoktur. Skafoidin proksimal kutbu en az kanlanmaya sahip alandır. Bu bölge radioskafolunat ligamanının derin liflerinin yapışma yeri hariç tamamen hyalin kıkırdak ile kaplıdır (24). Bu yüzden bel ve proksimal bölge kırıklarında proksimal parçanın beslenmesi olumsuz etkilenmekle birlikte, kaynamama ve avasküler nekroz oranı artmaktadır. Bu iki sistemin arasında interosseöz arterin dalları

sayesinde ekstraosseöz bir anastomoz mevcuttur.



Şekil 4 Skafoid kanlanması sağlayan 2 ana arter ve anjiografik görünümü (23)

2.3 Skafoid Kırıklarının Biyomekaniği

El bileğinin ekstansiyon hareketi yaklaşık olarak 85°dir. Aktif yapılan 60° el bileği ekstansiyon hareketinde skafoid kapitatum ile yaklaşık olarak aynı miktarda ekstansiyona gelir. Rainbow ve arkadaşlarının (25) yaptıkları çalışmada, 90° el bilek ekstansiyonu esnasında skafoid kemiğin kapitatuma göre bu harekete katılımı %74 olarak bulunmuştur. Bu da palmar taraftaki kuvvetli karpal bağların engellenmesine bağlanmıştır.

Dorsifleksiyonun 95-100° olduğu anda aşırı yüklenme ile skafoid kemik palmar yönde zorlanır, fakat proksimal kutbu bağlar tarafından güçlü bir şekilde stabilize edildiği için kapsüler yapılar tarafından desteklenmeyen distal kutba yük biner ve eğilme momentine karşı koyamayan bel bölgesinde kırık oluşur. Bu mekanizmanın klinik karşılığı açık el bileği üzerine düşmektir. El bileği nötral veya hafif derecede fleksiyondayken yumruk atan kişide, yük sadece ikinci metakarp ile iletildiğinde, aksiyel yüklenmenin de skafoid kırığına yol açabildiği gösterilmiştir(26).

Bükücü, makaslayıcı ve translasyonel güçlerin etkisi altındaki skafoide tespit uygulanmalı aksi halde kırık parçalar kayma eğiliminde olur. Distal parça fleksiyona giderken, proksimal parça sağlam skafolunat interosseöz bağ sayesinde, lunat kemik ile beraber

ekstansiyona gelir. Bu durum dorsal interkalar segment instabilitesi (DISI) olarak bilinir. Distal parçanın fleksiyona gitmesinde trapezium- skafoid makaslama stresi, eklem kompresif gücü ve kapitolunat rotasyon rol alır. Sonuç olarak skafoid kırık hattının volerinde kapanma dorsalinde açılma olur ve “hörgüç” deformitesi olarak adlandırılır(27).

2.4 Skafoid Kırıklarının Tanısı ve Sınıflaması

2.4.1 Skafoid Kırıkları Tanısı

Skafoid kırıklarında x-ray ile kırık görülemeyebilir. Bu nedenle fizik muayene özenle yapılmalıdır. Lokasizyonu, ağrının şiddetinden çok daha önemlidir. Ağrı çoğunlukla enfiye çukurunda, skafoidin distal çıkıntısında ya da dorsalde proksimal kutup üzerindedir (28). (Tablo 1) Baş parmağın düz traksiyonu ve el bileğinin özellikle fleksiyon ve radyal deviyasyon hareketinin sonlandığı sınırdaki ağrı olabilir. Diğer klinik bulgular; ekimoz, ödem nedeniyle enfiye çukuru konkavitesinde azalma ve krepitasyondur. Fizik muayenenin duyarlılığı yüksektir ancak özgüllüğü %74–80 aralığındadır. El bileğinde radyoulnar eklem ve dirsek mutlaka muayene edilmelidir (29).

Tablo 1 Klinik testlerin skafoid kırığı teşhisindeki doğruluk oranları (30,31)

Klinik test	Spesivite(%)	Sensitivite(%)
Enfiye çukuru hassasiyeti	40	90
Efüzyon (ultrasonda)	91	50
Skafoid tüberkül hassasiyeti	57	87
Skafoid kompresyon testi	92	94
Kombine	74	100

El bileği ağrısı ve enfiye çukurundaki hassasiyet aksi ispat edilinceye kadar alçı ile tespit edilmeli ve skafoid kırığı olarak değerlendirilmelidir. Radyografiler posteroanterior (PA), lateral, 45 derece pronasyonda oblik, 45 derece supinasyonda oblik ve ulnar deviyasyonda PA olarak alınmalıdır (32). (Tablo 2) İlk çekilen grafilerde %10-20 oranında kırık görülemeyebilir (33). Bu durumda 10-15 gün sonra grafi tekrar edilmelidir. Tekrardan yapılan fizik muayenede kırıktan şüphe edilirse ve x-ray grafilerde kırık hala görülüyorsa daha spesifik bir görüntüleme yöntemi düşünülmelidir.

Bilgisayarlı tomografi (BT) sagittal, ince kesitler alındığında tanı koydurur. Bilgisayarlı tomografi ile düzgün sagittal kesitler elde edebilmesi için çekimler uygun pozisyonda olmalıdır. Skafoid longitudinal aksı düzgün bir şekilde görüntülenebilmesi için hastanın pron pozisyonda masada uzanırken el baş üstü seviyede, pronasyonda ve nötral fleksiyonda çekimi yapılmalıdır

Manyetik rezonans görüntüleme (MRG) kırık hattını belirlemede yardımcıdır. Ancak daha da önemlisi nonspesifik el bileği ağrılarının ayırıcı tanısında ve skafoid kırığına eşlik eden yaralanmalarda daha değerlidir. Kemik sintigrafisi, metalik implantı olan ve kalp pili bulunan hastalarda MRG yapılamadığı zaman kullanılabilir. Özgüllüğü %100, özgünlüğü %92-98 oranındadır. Pozitif sintigrafiye rağmen radyografilerde negatif olma durumu ise %25-35 dir (34).

Henriksen, planar kemik sintigrafisi ile radyografilerin birleştirilmesinin görüntülerin yorumlanmasında belirgin katkısı olduğunu bunun tanı güvenilirliği ve gözlemciler arası farklılık azalmasını getirdiğini belirtmiştir (34).

Özgüllük ve özgünlük açısından karşılaştırıldığında; MRG %98, %99, kemik sintigrafisi %96, %89, BT ise %94, %96 oranında tanıya yardımcıdır (35).

Manyetik rezonans görüntüleme kullanımında yanlış pozitif sonuçlar olabilir. Bu bölgedeki kemik ödemi, bağ yaralanmaları bu duruma neden olabilir. MRG özellikle sporcularda kırığın dışlanması için kullanılır.

Skafoidin proksimal bölge kırıklarında canlılığı değerlendirmenin üç yöntemi vardır. Bu yöntemler; MRG, ameliyat esnasında turnike açılıp parçadan kanamanın gözle kontrolü, artroskopik kanama kontrolüdür.

Skafoid kırıklarının tedavisinde en önemli sorunlardan birisinin, tedavi yöntemi fark etmeksizin kırığın kaynamasının değerlendirilmesi olduğu açıktır. İster alçı ile konservatif tedavi ister perkutan tespit ya da açık yerleştirme ve trikortikal kemik grefti yapılmış olsun, standart grafilerle bazen durum anlaşılamayabilir. Böyle bir durumda altı haftalık aralıklarla rontgen çekilmesi, 2.-3. ayda hala şüphe varsa BT ile değerlendirme yapılması önerilir. Smith ve ark (36), tanı için BT'nin de proksimal kısım avasküler nekrozunda kullanılabileceğini göstermiş ve bu alandaki radyodens (sklerotik) görünümün histolojik olarak da avasküler nekrozla ilişkili olduğunu bildirmişlerdir.

Tablo 2 Radyografik görüntüler (32)

Nötral PA	<ul style="list-style-type: none">○ Yanıltıcıdır.○ Fakat el bileği ağrısı ile gelen tüm hastalarda rutin istenir.
Ulnar-deviyasyonda PA	<ul style="list-style-type: none">○ Özellikle proksimal pol kırıklarında yararlıdır.
45° oblik PA (semipronasyonda)	<ul style="list-style-type: none">○ Sulkusu içeren kırıkları en iyi gösterir.○ Aynı zamanda bel kırıkları ve bazı sulkal ve proksimal pol kırıklarının deplasman miktarını en iyi gösterir.
45° oblik AP (semisüpinasyonda)	<ul style="list-style-type: none">○ Proksimal pol kırıklarına spesifiktir.○ Aynı zamanda dorsal avulsiyon tipi kırıklarda gösterir.○ Skafoidin fleksiyon deformitesini (hörgüç) en iyi gösterir.
Lateral	<ul style="list-style-type: none">○ Kırığı göstermede zayıftır, karpal kollapsı göstermede yararlıdır.

2.4.2 Skafoid Kırıkların Sınıflaması

Skafoid kırıklarının yüksek oranda (%70) bel, %10–20'si distal kutup, %5'i tüberkül ve %5'i proksimal kutupta meydana gelir. Skafoid kırıkları, kırık yerleşimi, stabilite, kırık planı ve osteonekrozun varlığına göre sınıflandırılmıştır.

Otto Russe (37), skafoid kırıklarını şekline göre, horizontal oblik, vertikal oblik ve transvers olarak üçe ayırmış (Şekil 6) ve oblik kırıkların stabil olmadıklarını 1960 yılında vurgulamıştır.


Herbert ve Fisher (38), 1984 yılında skafoid kırıklarının cerrahi tedavisinde kullanılması amacıyla geliştirdikleri kompresyon vidasını tanımlarken, aynı zamanda röntgen görüntülerine dayanarak da bir sınıflama tanımlamışlardır. Bu sınıflamada akut kırıklar, Tip A akut stabil kırık, Tip B stabil olmayan akut kırık olarak ayrılmıştır. Tip C kırıklar altı hafta alçıyla immobilizasyondan sonra kaynamada gecikme gösterirlerken, Tip D kırıklar ise belirgin kaynamamadır. Alçı tespiti ile tedavi edilebilecek tek sınıf Tip A kırıklardır. Tip B, C ve D ise cerrahi olarak tedavi edilmelidir.

Bu sınıflamaların distal kutbu içermediğini düşünen Prosser ve arkadaşları, 1988 yılında sadece distal kutup kırıklarına yönelik bir sınıflama tanımlamışlardır. Bu sınıflamada; Tip 1,

tüberositasın avulsiyon kırığı veya fissürü; Tip 2, distal kutbun ekleme uzanan kırığı (a, radyal taraf; b, ulnar taraf; c, her ikisi birden) ve Tip 3, distal eklem yüzünün kapitatuma bakan tarafında osteokondral parça mevcut.

Compson, 1998 yılında direkt grafi ile bu sınıflamaları yapmanın zorluğunu vurgulamış ve Tip 1, cerrahi bel (transvers); Tip 2, dorsal sulkus (oblik) ve Tip 3, proksimal kutup kırıkları şeklinde yeni bir sınıflama tanımlamıştır.


Fakat, 1999 yılında Desai ve arkadaşları bu sınıflamaların hiçbirinin kırık kaynamasını tahmin etmek için prognostik olarak kullanılamayacağını göstermişlerdir.



Şekil 5 MAYO Kırık Yerleşimi; (1) Distal eklem yüzü (2) Distal tüberkül (3) Distal 1/3 (4) Orta 1/3 (5) Proksimal 1/3 (39)


Tablo 3 Skafoid Kırık Sınıflamaları

Kırık yerleşimi	Russe	Herbert	Prosser	Mayo klinik
Tüberkül kırığı		Tip A (stabil) A1 Tüberkül A2 inkomplet	Tip 1 tüberkül kırığı Tip 2 Distal intraartiküler Tip 3 Osteokondral kırık	Distal(%5) (100 kaynar)
Bel kırığı	Horizontal oblik Transvers Vertikal oblik (%5)	Tip B (Unstabil) B1 Oblig distal 1/3 B2 Deplase kırık B4 Kırıklı çıkık Tip C Kaynama gecikmesi Tip D D1 Fibröz kaynamama D2 Sklerotik kaynamama D3 DISI		Orta (%65) (%80 kaynar)
Proksimal pol		Tip B3 Proksimal 1/3 Tip D4 Avasküler nekroz		Proksimal(%30) (%64 kaynar)




Şekil 6 Skafoid kırıklarında Russe sınıflaması (VO, vertikal oblik; T, transvers; HO, horizontal oblik) (37)

Tip A: Stabil Akut Kırıklar



Tip B: Anstabil Akut Kırıklar



Tip C: Kaynama gecikmesi



Tip D: Kaynamama



Şekil 7 Skafoid kırıklarının Herbert ve Fisher sınıflaması (38)

2.5 Yapay Zekâ


Yapay zekâ 1956 yılında Stanford üniversitesinde ortaya çıkmıştır. İnsan beyninden ve öğrenme özelliklerinden rol model alınarak geliştirilmiştir. İnsanların fikir yürütme, bilgiyi öğrenme planlama, algı ve nesnelere işleme yeteneklerini gösterebilen sayısal bir zekâ oluşturulmak amaçlanmıştır. Günümüzde birçok alanda yapay zekâ kullanılmaktadır. Gelecekte günlük hayatımıza kadar gireceği öngörülmektedir.

2.6. Makine Öğrenmesi

Yapay zekanın bir alt dalıdır. Verilerin kalıplarını otomatik olarak algılayan ve daha sonra belirsiz koşullar altında gelecek verileri analiz eden ve bu verilerden anlamlı tahminler veya kararlar çıkarabilen modelleme ve algoritmalarından oluşmaktadır. Makine öğrenmesi, “veri”den “model”i belirleyen bir tekniktir. Burada, veriler belgeler, ses, görüntüler vb. anlamına gelmekte olup model ise makine öğreniminin son ürününü oluşturmaktadır.

Makine öğrenmesi tekniği, verileri analiz ederek ve modeli kendi başına oluşturan bir tekniktir. Buna “öğrenme tekniği” denir. Çünkü süreç model bulma problemini çözmek için verilerle eğitime benzerdir. Bu nedenle, Makine Öğreniminin modelleme sürecinde kullandığı verilere “eğitim” verileri denilmektedir.

Çeşitli alanlardaki sorunları çözmek için pek çok farklı Makine Öğrenme tekniği geliştirilmiştir. Bu Makine Öğrenme teknikleri, eğitim yöntemine bağlı olarak üç tipe ayrılabilir. Şekil 8’de bu teknikler görülmektedir.



Şekil 8 Makine öğrenme teknikleri

2.6.1. Danışmanlı Öğrenme

Danışmanlı öğrenme insanın bir şeyleri öğrenme sürecine benzerdir. Öğrenme süreci etiketli veriler üzerinden gerçekleştirilmektedir. Danışmanlı öğrenmede, her bir eğitim veri seti girdi ve doğru çıktı çiftlerinden oluşmalıdır. Doğru çıktı, modelin verilen girdi için üretmesi gereken şeydir. Danışmanlı öğrenmede öğrenme, bir modelin aynı girdi için doğru çıktı ile modelin çıktısı arasındaki farkı azaltmak için yapılan bir revizyon dizisidir. Bir model mükemmel şekilde eğitilirse, eğitim verisinden gelen girdiye karşılık gelen doğru bir çıktı üretmektedir.

2.6.2. Danışmansız Öğrenme

Danışmansız öğrenmede veri etiketleri olmayan girdi verilerini içermektedir. Doğru çıktıları bilinmemektedir. Danışmansız öğrenme genellikle verilerin özelliklerini araştırmak ve veriyi ön işleme koymak için kullanılmaktadır. Bu öğrenme yöntemiyle, sınıfları bilinmeyen verilerinin gruplandırılması veya kümelenmesi yapılmaktadır.

2.6.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme ön bilgi yerine gözlem ve seçim üzerine kurulu bir öğrenme şeklidir. Neden sonuç ilişkisinin nasıl kurulduğu bilgisi, yapay zekaya verilmez. Sistemin amacı yapay zekayı bir sonuca koşullandırmaktır. Bu sonuç her zaman en yüksek ödül değerindedir. Bu ödülün daha az, daha farklı bir ödül olması ya da hiçbir ödülün olmaması durumu yapay zekâ için bir ceza olarak görülmektedir.

2.7. Yapay Sinir Ağları

Yapay sinir ağları (YSA), yapay zekâ tekniklerinden birisi olup; insan beyninin yeteneklerini yardım almaksızın gerçekleştirilmesini amaçlayan bilgisayar sistemleridir. Bu sistemler programlanırken geleneksel yöntemler genellikle yeterli olmamaktadır.

Esasında yapay sinir ağları; insan ve hayvandaki biyolojik sinir ağından esinlenilmiştir. Örneğin biyolojik sinir sisteminde nöronlar, tek başına depolama görevini yapamazlar. Bu yüzden sinyalleri birinden diğerine ileterek beyne ulaştırırlar. Yani bilgisayarın depolama

işlemi için kullandığı bellek, biyolojik sistemdeki beyni taklit etmektedir. Amaçlar aynıdır fakat kullanılan mekanizma farklılık göstermektedir.

Kısaca; YSA programlanması zor olan olaylar için geliştirilmiş, veri işleme ile ilgilenen bilgisayar kaynaklı bir bilim dalı olduğu kabul edilmektedir (40).

2.7.1. Yapay Sinir Ağlarının Genel Özellikleri

YSA'nın özellikleri kullanılan algoritmalar ve modellere göre farklılık göstermektedir. Genel olarak aşağıdaki gibi sıralanabilmektedir.

Uyarlanabilirlik (Adaptasyon)

Yapay sinir ağında bilgi, ağın bağlantılarındaki aralıklarda saklanmaktadır. Aralıkların daima en iyi, en verimli değeri hesaplanmaktadır. Bu değer her durum için aynı bir değer değildir. Yapay sinir ağı oluşabilecek ters durumlara karşı kendisini yeniden yapılandırabilme özelliğine sahiptir.

Paralellik (Doğrusal Olmama)

Yapay sinir ağlarında işlemler doğrusal değildir. Bunun yerine paralellik mevcuttur. Yapay sinir ağlarında bazı bağlantıların ya da hücrelerin zarar görmesi veya etkisiz hale gelmesi doğru bilgi üretimine çok fazla etki etmemektedir.

Hata Toleransı

Yapay sinir ağlarında bilgi, ağın tamamına yayılmış durumdadır. Yani dağınık bir hafıza vardır. Bilgi belirli bir bölümde değil ağın tamamında depo edilmektedir. Bu da oluşabilecek bir hatanın bütün ağı etkilemesini engellemektedir. Hataya gösterilen tolerans, geleneksel metotlara göre çok daha fazladır.

Dereceli Bozukluk

Yapay sinir ağları hatalara karşı toleranslı oldukları için sistemin bozulması da dereceli olmaktadır (41). Hata olması durumunda klasik sistemlerde olduğu gibi tamamen çalışamaz duruma geçmemekte, sağlam olan birimler işleme devam etmektedir.

Öğrenme- Örneklemeye- Genelleme

Yapay sinir ağları makine öğrenmesi gerçekleştirilmektedir (42). Bu öğrenme işini gerçekleştirmek için örneklerden yararlanmaktadır. Kendisine öğretilen örneklerden kullanarak, olay hakkında genelleme yapabilecek yeteneğe sahip olmaktadırlar (Diğer bir adı adaptif öğrenme).

Örnekler gerçekleşmiş olaylardır. Yapay sinir ağları (YSA), daha önce gerçekleşmiş bir veriden öğrendikleri ve kendisine verilen yeni veri arasındaki benzerlikleri araştırıp, doğru bilgiye ulaşmaktadır. Bilgiye ulaştıktan sonra, bu sefer de genelleme yoluyla birbirine benzettiği örneklerin veya verilerin farklılıklarından yola çıkarak yeni bilgiler üretebilmektedir. Yine şekilleri birbirleriyle ilişkilendirip, sınıflandırıp sonrasında karşılıklarına çıkabilecek eksik şekilleri de tamamlayabilmektedirler.

Nümerik Bilgi ile Çalışma

Yapay sinir ağlarının çalışabilmeleri için bilgilerin sayısal olmaları gerekmektedir. Sayısal olmayan bilgiler önce sayısal ifadelerle dönüştürüldükten sonra ağına tanıtılmaktadır (41).

Gerçek Zamanlı Çalışma (Donanım ve Hız)

Yapay sinir ağları, paralel bir çalışma düzenindedir. Bu, aynı anda birçok işlem yapabilmelerini sağlamaktadır. Gerçek zamanlı çalışmaları ve birim zamanda çok daha fazla veriyi işleyebilmektedirler (41).

2.7.2. Yapay Sinir Ağlarının Kullanım Alanları


Yapay Sinir Ağları, insan beyninden esinlenerek hazırlanan hesaplamalı modellerdir. Yapay Sinir Ağları sürekli öğrenerek bilgi edinmektedirler. İnsanlarda olduğu gibi, edinilen bilgiler YSA içerisinde tasarlanan yapay nöronlarda depolanmakta ve gerekli görevi yerine getirmek için kullanılmaktadır.

2.7.3. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

2.7.3.1. Biyolojik sinir hücresi

Yeni bir şeyler öğrendiğimizde, beynimiz bu bilgiyi depolamaktadır. Bilgisayar ise bilgiyi depolamak için bellek kullanmaktadır. Her ikisi de bilgi depolar ancak mekanizmaları farklıdır. Beyin nöronların tümünü kullanırken, bilgisayar bilgi hafızasında belirtilen yerlere

depolama işlemini gerçekleştirmektedir. Nöronun kendisinde depolama kapasitesi yoktur; sinyalleri bir nörondan diğerine iletmektedir. Beyin, bu nöronların ağını oluşturmakta ve nöronların birleşmesi farklı bilgileri oluşturmaktadır. Nöronlar; dentritler, çekirdek, hücre gövdesi, akson ve sinapslardan oluşmaktadır. Şekil 9’da biyolojik sinir hücresi yer almaktadır.

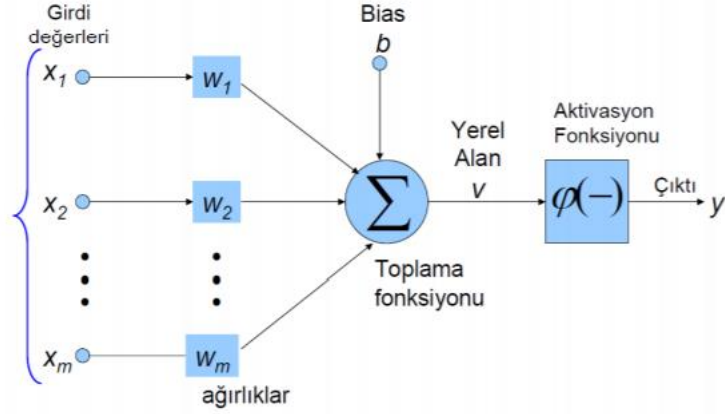


Şekil 9 Biyolojik sinir hücresi (43)

Nöronlar, sinir sistemi içindeki bilgileri diğer sinir hücrelerine, kas veya salgı hücrelerine ileten hücrelerdir. Nöronun bir hücre gövdesi, bir akson ve dendritleri vardır. Hücre gövdesi çekirdeği ve sitoplazmayı içermektedir. Akson hücre gövdesinden uzanmakta ve sıklıkla sinir terminallerinde bitmeden önce birçok küçük dallara ayrılmaktadır. Dendritler, nöron hücre gövdesinden uzanmakta ve diğer nöronlardan sinyali almaktadır. Sinapslar, bir nöronun diğeriyle iletişim kurduğu temas noktalarıdır. Dendritler, diğer nöronlardan aksonların uçları tarafından oluşturulan sinapslarla kaplı durumda bulunmaktadır (44).

2.7.3.2. Yapay Sinir Hücreleri

Yapay sinir ağları biyolojik sinir sisteminden etkilenilerek oluşturulmuştur. Biyolojik sistemin sinir hücreleri gibi, yapay sinir ağlarının da kendi yapay sinir hücreleri bulunmaktadır. Yapay sinir hücreleri de elemanlara sahiptir. Beş temel elemanı vardır. Bunlar: girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve hücrenin çıktısıdır. Şekil 10’da bir yapay sinir hücresinin yapısı gösterilmektedir.



Şekil 10 Yapay sinir hücresinin yapısı

Girdi Değerleri: Girdiler hücreye gelen bilgilerdir. Bu bilgiler dış dünyadan, başka bir hücreden ve hücrenin kendisinden gelebilmektedir. Girdiler giriş konumundadırlar. Görevleri bilgiyi iletmekle sınırlıdır, matematiksel işlem yapamazlar. Gelen bilgiler ağırlık öğrenmesi istenen örnekler tarafından belirlenmektedirler (45). Yapay sinir ağlarının algılayıcıları olarak nitelendirilebilirler (46).

Ağırlıklar: Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini göstermektedirler (40). Her girdinin ağırlık değeri aynı olmak zorunda değildir. Ağırlık değerleri matematiksel anlamda artı değerler veya eksi değerler alabilmekle beraber sabit de kalabilmektedir. Bir girdinin pozitif ya da negatif değere sahip olması, bilginin hücre içinde aynı oranda önemli olması anlamına gelmez. Bilginin ağırlık değeri sıfırken, bunun yapay sinir hücresi için önemi çok yüksek olabilir.

Eşik Değeri: Öğretilecek ağırlık ezberlemesini önlemek için kullanılan değerdir (47).

Toplama Fonksiyonu: Hücreye giren net girdiyi hesaplamak için toplama fonksiyonu kullanılmaktadır. Her hücre için farklı toplama fonksiyonu kullanılabilir. Birlikte en yaygın kullanılan fonksiyon formülünde her girdi değeri kendi ağırlığıyla çarpılmakta ve tüm girdiler için bulunan değerler toplanmaktadır (41).

$$NET = \sum_i^n G_i A_i$$

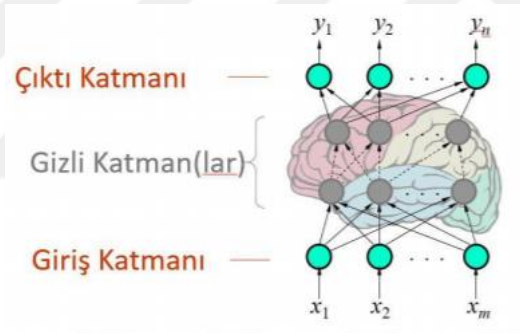
G: Girdileri; A: Ağırlıkları; n: Hücreye gelen toplam girdi sayısını göstermektedir.

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu, toplama fonksiyonunun ulaştığı net girdi bilgisini işleyerek hücrenin üreteceği çıktıyı belirlemektedir. Tıpkı toplama fonksiyonu gibi her hücre için farklı bir aktivasyon formülü kullanılabilir.

Çıktı: Aktivasyon fonksiyon tarafından belirlenen değerlerdir. Girdiler birden fazla olsa bile, hücrenin sadece bir adet çıktısı olabilir. Hücrenin ürettiği çıktı daha sonrasında dış ortama bırakılmaktadır. Diğer hücreler veya çıktıyı üreten hücrenin kendisi de bu çıktı bilgisini, girdi olarak tekrar hücre içine alabilmektedir.

2.7.4. Yapay Sinir Ağlarının Sınıflandırılması

Beyin, çok sayıda nöronların bir ağı olduğundan, sinir ağı beynin nöronlarına karşılık gelen elemanlar olan düğümlerin bağlantılarıyla oluşturulmuştur. Şekil 11’de gösterildiği gibi katmanlı bir yapıya sahiptir.



Şekil 11 Yapay sinir ağları katmanları

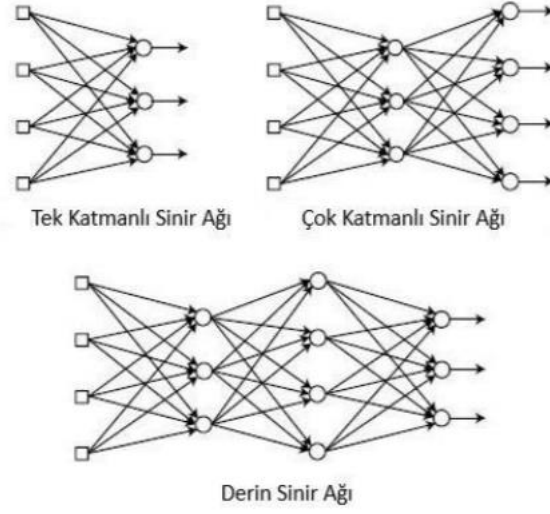
Yapay bir sinir ağının üç ana katmanı vardır:

Giriş Katmanı: Dış dünyadan gelen bilgilerin alındığı ve gizli katmanlara iletiildiği katmandır. Ağlar genel olarak birden fazla giriş katmanına sahiptir.

Gizli Katman(lar): Giriş katmanından alınan bilgilerin çeşitli işlemlerle değerlendirildiği ve çıkış katmanına iletiildiği katmandır. Ağın yapısına bağlı olarak, birden çok gizli katman olabilir.

Çıktı Katmanı: Gizli katmanlardan alınan bilgileri dış ortama veren katmandır. Çıktı katmanı beyindeki diğer sinir ağlarının da girdileri olan çıktı sinyallerini üretmektedir.


Düğümlemlerin nasıl bağlandığına bağılı olarak çeşitli sinir ağıları oluşturulabilir. Bu sinir ağılarından en yaygın kullanılanları aşağıda şekil 12’de gösterilmiştir.



Şekil 12 Yapay sinir ağı mimarileri (48)

Şekil 12’de görüldüğü üzere, ağılar tek katmanlı ve çok katmanlı olmak üzere (derin sinir ağı çok katmanlı bir yapıya sahiptir) birbirinden ayrılmaktadır.

Yapay sinir ağıları, sinirler ya da düğümler adı verilen işlem birimlerinin bir kombinasyonudur. Yapay sinir ağı modelleri, sinirler arasındaki bağıntıların yönüne veya ağıdaki akış yönüne göre ayrılabilir. Bu modellerden en yaygın kullanılanlar Şekil 13’te gösterilmiştir.



Şekil 13 Yapay sinir ağı modelleri (46)

Bu ağlar yapılarına göre ileri beslemeli ve geri beslemeli olarak sınıflandırılabilir.

2.7.4.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağı, basit tasarımıdır. İleri beslemeli ağlarda, bilgi giriş ve çıkış arasındaki gizli düğümler yardımıyla yalnızca tek bir yöne hareket etmektedir. Ağ üzerinde herhangi bir döngünün varlığından söz edilemez.

2.7.4.2. Geri Beslemeli Yapay Sinir Ağları

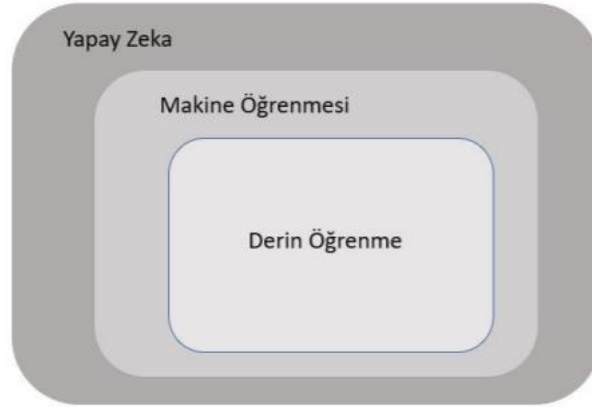
Geri beslemeli ağlarda yapay sinir hücresinin ürettiği çıktı, hücrenin kendisine veya diğer hücrelere tekrar girdi olarak girebilir. Bu işlem için gizli katmanlar kullanılmaktadır. İleri beslemeli ağlardan farkı döngüsel bir düzen olmasıdır. Bilgi tek taraflı hareket etmemektedir. Bu sayede ağ daha etkin ve öğrenme kabiliyeti daha yüksek bir hale gelmektedir.

2.8. Derin Öğrenme

2.8.1. Derin öğrenime giriş

İnsan beyni öğrenme, problemi tespit etme ve çözme gibi bilişsel işlemlere sahiptir. Yapay zekâ insanın bu işlevlerini makineyi kullanarak taklit eden bir alandır. Makine öğrenme yöntemleriyle insan, hataları en aza indirmek ve mükemmel doğruya ulaşmayı hedefleyen bir araç üretmek istemiş bunun için de yapay zekâyı geliştirmiştir. Özellikle bir amaç için programlanmadan tahminde bulunup, karar verme veya çözüm bulma gibi eylemleri uygulayabilmek, aynı zamanda kendine verilen görevi yerine getirmek için matematiksel veriler üretmek üzere makine öğrenimine yönelmiştir. Bu verilere "eğitim verileri" denir. İnsan yapay zekâ üretimine makine öğreniminden başlamıştır.

Göreve özgü programlamama olmadan, algoritmaların öğrenme verilerini temsil etmeye çalıştığı makine öğrenmesine ise derin öğrenme denir.



Şekil 14 Yapay zekâ ile derin öğrenme arasındaki ilişki

Derin Öğrenme, derin sinir ağını kullanan bir Makine Öğrenme tekniğidir.

Derin sinir ağları (DNN) ve tekrarlayan sinir ağları sayesinde oluşturan yapay zekalar; görüntü işleme, konuşma tanımlama, sosyal ağ filtreleme, tıbbi görüntü analizleri, ilaç tasarımları, masa oyunları gibi alanlarda insan uzmanlara yakın hatta bazı durumlarda daha iyi sonuçlar üretmeyi başarmıştır (49,50).

2.8.2. Derin öğrenmenin tarihi

Derin Öğrenme terimi, Rina Dechter tarafından 1986'da makine öğrenme topluluğuna tanıtılmış ve 2000 yılında Igor Aizenberg ve meslektaşları tarafından yapay sinir ağlarıyla buluşturulmuştur. 1965 yılında Alexey Ivakhnenko ve Lapa tarafından denetimli derin beslemeli çok katmanlı algılayıcılar için ilk genel, çalışma öğrenme algoritması yayınlanmıştır (51). Diğer derin öğrenme çalışma mimarileri, özellikle bilgisayar vizyonu için inşa edilenler, 1980 yılında Kunihiko Fukushima tarafından tanıtılan Neocognitron ile başlamıştır (52).

1989'da Yann LeCun ve ark. 1970'ten beri otomatik farklılaşmanın ters modu olan standart posta yarma algoritmasını, postadaki el yazısı ZIP kodlarını tanımak amacıyla derin bir sinir ağına uygulamıştır (53-56).

1991 yılına kadar, bu tür sistemler izole edilmiş 2 boyutlu elle yazılmış basamakları tanımak için kullanılırken, 3 boyutlu nesnelere tanımak, 2 boyutlu görüntüleri el yapımı 3 boyutlu nesne modeliyle eşleştirmek suretiyle yapılmıştır. Weng ve diğerleri bir insan beyninin monolitik bir 3B nesne modeli kullanmadığını öneri sürerek 1992 yılında, dağınık haldeki sahnelerde 3 boyutlu nesne tanımlamayı gerçekleştirecek olan Cresception'ı yayınlamışlardır. Doğrudan doğal görüntüleri kullandığından, Cresceptron doğal 3D dünyalar için genel amaçlı görsel öğrenmenin başlangıcına vesile olmuştur.

Cresceptron, Neocognitron'a benzer katmanlar dizisidir. Fakat Neocognitron, özellikleri birleştirmek için bir insan programcısına ihtiyaç duysa da Cresceptron, her bir özelliğin, bir konvüsyon çekirdeği tarafından temsil edildiği, her katmanda, denetimsiz bir şekilde çok sayıda özellik öğrenmiştir. Cresceptron, öğrenilen her nesneyi dağınık haldeki bir sahnedeki ağ üzerinden geriye doğru analiz yoluyla bölümlendirmiştir. Günümüzde genellikle derin sinir ağları tarafından benimsenen Max Pooling ilk kez Cresceptron'da pozisyon çözünürlüğünü daha iyi genellemek için kademeli olarak (2x2)'ye 1 kadarlık bir faktörle azaltmak için kullanılmıştır (57-59).

1994 yılında, André de Carvalho, Mike Fairhurst ve David Bisset ile birlikte, 3 katmanlı bir kendi kendini düzenleyen özellikli sinir ağı modülünden oluşan, ağırlıksız bir sinir ağı olarak da bilinen çok katmanlı bir boolean sinir ağının (SOFT) deneysel sonuçlarını yayınlamıştır ve ardından bağımsız olarak eğitilmiş çok katmanlı bir sınıflandırma sinir ağı modülü (GSN) takip etmiştir. Özellik çıkarma modülündeki her katman, önceki katmana göre artan bir karmaşıklıkta özellikler çıkarmıştır (60).

1995 yılında Brendan Frey, Peter Dayan ve Hinton ile birlikte geliştirilen uyandırma-uyku algoritmasını kullanarak, tamamen birbirine bağlı altı katman ve birkaç yüz gizli ünite içeren bir ağ kurmanın (iki günden fazla) mümkün olduğunu göstermiştir (61).

Hesaplama maliyeti ve beynin biyolojik ağlarını nasıl bağladığının anlaşılması sebebiyle, Gabor filtreleri ve destek vektör makineleri gibi göreve özel el yapımı özellikler kullanan daha basit modeller 1990'lar 2000'lerin popüler seçimleri olmuştur. Çoğu konuşma tanıma araştırmacısı, sinirsel ağlardan uzaklaşarak, üretken modellemeyi sürdürmüştür. Bir istisna 1990'ların sonlarında SRI International'dadır. ABD hükümetinin NSA ve DARPA tarafından finanse edilen SRI, konuşma ve konuşmacı tanıma konusunda derin sinir ağları üzerinde çalışır. Heck'in konuşmacı tanıma ekibi, 1998 Ulusal Standartlar Enstitüsü ve Teknoloji Konuşmacı Tanıma değerlendirmesinde konuşma işleminde derin sinir ağları ile ilk önemli başarıya imza atmıştır. SRI, konuşmacı tanımada derin sinir ağları ile başarı yaşamasına rağmen, konuşma tanımda benzer bir başarı göstermemiştir (62). Konuşma tanımanın birçok yönü, Hochreiter ve Schmidhuber tarafından 1997'de yayınlanan tekrarlayan bir sinir ağı olan uzun kısa süreli bellek, LSTM adı verilen derin bir öğrenme yöntemi ile ele alınmıştır. LSTM tekrarlanan sinir ağları, kaybolan gradyan probleminden kaçınır ve konuşma için önemli olan binlerce ayrı zaman aşaması olan olayların anılarını gerektiren "Çok Derin Öğrenme" görevlerini öğrenebilmiştir.

2003 yılında, LSTM, belirli görevlerde geleneksel konuşma tanıyıcılarla rekabet etmeye başlamıştır (63).

Donanımdaki gelişmeler, ilginin yenilenmesini sağlamıştır. 2009'da Nvidia, derin öğrenimin sinir ağları Nvidia grafik işlem birimleriyle (GPU'lar) eğitilmiştir. Özellikle, GPU'lar makine öğrenmesine katılan matris/vektör matematiği için çok uygundur (64,65). GPU'lar, çalışma algoritmalarını, büyüklük sırasına göre hızlandırarak haftalardan günlere kadar çalışma sürelerini azaltmaktadır. Verimli işlem için özel donanım ve algoritma optimizasyonları kullanılabilir (48,66).

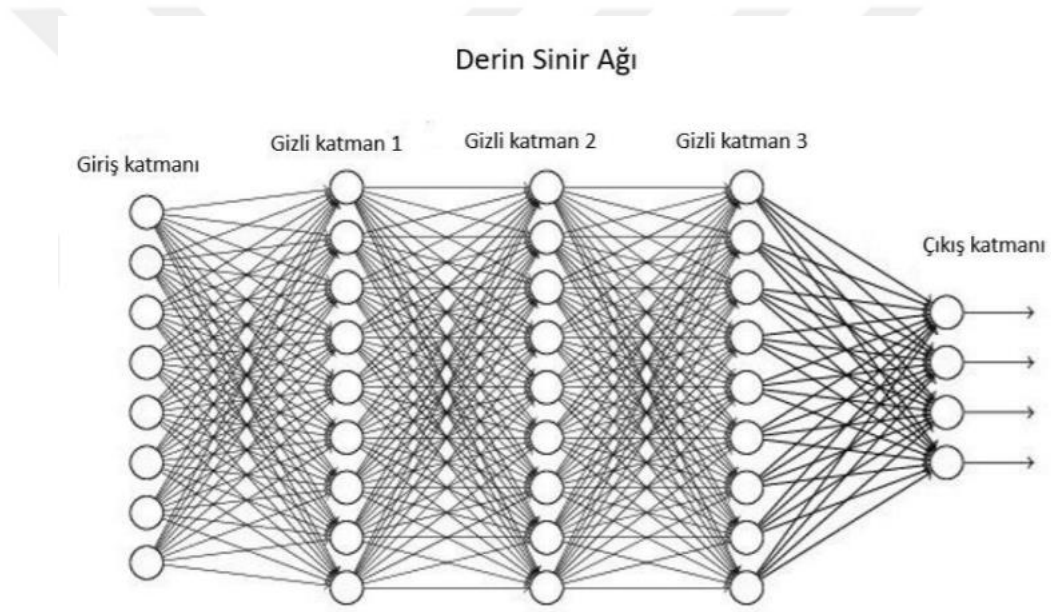
2012 yılında, Dahl liderliğindeki bir ekip, bir ilacın biyomoleküler hedefini tahmin etmek için çok görevli derin sinir ağlarını kullanarak "Merck Moleküler Aktivite Mücadelesi"ni kazanmıştır (67).

2014 yılında, Hochreiter grubu çevre kimyasallarının besinlerde, ev ürünlerinde ve ilaçlarda hedef dışı ve toksik etkilerini tespit etmek için derin öğrenme kullanmış ve NIH, FDA

ve NCATS'ın "Tox21 Veri Mücadelesi" ni kazanmıştır. Görüntü veya nesne tanımadaki önemli etkiler 2011'den 2012'ye kadar hissedilmiştir. Birçok farklı kategorideki yarışma derin öğrenme ile kazanılmıştır.

2.8.3. Derin Sinir Ağı (Deep Neural Network)

Derin sinir ağı (DNN), giriş ve çıkış katmanları arasında çoklu katmanlara sahip yapay bir sinir ağıdır (68). Derin sinir ağı, girdiyi çıktıya dönüştürmek için doğru matematiksel etkileşimin doğrusal mı yoksa doğrusal olmayan bir ilişki mi olduğunu bulur. Ağ, her çıktının olasılığını hesaplayan katmanlar arasında hareket eder.



Şekil 15 Derin sinir ağı (48)

2.8.4. Derin Öğrenme

Derin öğrenme, özellikleri ve görevleri doğrudan veriden öğrenen bir makine öğrenme tekniğidir. Ardışık her katman, önceki katmandaki çıktıyı girdi olarak kullanır (69). Denetlenen ve/veya denetlenmeyen davranışları öğrenir. Farklı soyutlama seviyelerine karşılık gelen çoklu temsil seviyelerini öğrenir ve seviyeler bir kavram hiyerarşisi oluşturur (70).

Derin öğrenmede, her seviye girdi verilerini biraz daha soyut ve bileşik bir gösterime dönüştürmeyi öğrenir. Bir görüntü tanıma uygulamasında, ham girdi bir piksel matrisi olabilir; birinci temsil katmanı pikselleri soyutlayabilir ve kenarları kodlayabilir; ikinci katman kenar

düzenlemelerini oluşturabilir ve kodlayabilir; üçüncü katman bir burnu ve gözleri kodlayabilir; dördüncü katman, görüntünün bir yüz içerdiğini kabul edebilir. Daha da önemlisi, derinlemesine bir öğrenme süreci hangi özellikleri hangi seviyeye kendi başına getirebileceğini öğrenebilir (71).

Daha derin katmanlara sahip olan sinir ağının düşük performans vermesinin nedeni, ağına uygun şekilde eğitilmemesidir. Geri yayılım algoritması, derin sinir ağının eğitim sürecinde şu üç ana güçlükle karşılaşır:

- Vanishing gradient (kaybolma gradyanı)
- Overfitting (Aşırı uygunluk, Ezberleme)
- Computational load (Hesaplama yükü)

2.8.4.1. Vanishing Gradient (kaybolma gradyanı)

Bu gradyan, geri yayılım algoritmasının deltasına benzer bir kavram olarak düşünülebilir. Kaybolma gradyanı, geri-yayılım algoritması ile öğrenme sürecinde, çıkış hatası uzaktaki düğümlere erişmenin başarısız olması olasılığı yüksek olduğunda ortaya çıkar. Geri yayılma algoritması, sinir ağını, çıktı hatasını geriye doğru gizli katmanlara yayarak eğitir. Ancak hatalar ilk katmana kadar nadiren geri geldiğinden, girdi katmanına yakın gizli katmanlar tam anlamıyla eğitilmiş olamazlar.

2.8.4.2. Overfitting (Aşırı Uygunluk)

Makine Öğrenmesinin başarısı, genelleme sürecinin ne kadar iyi uygulandığına büyük ölçüde bağlıdır. Eğitim verileri ile gerçek giriş verileri arasındaki farklılıklardan dolayı performans düşüşünü önlemek için, yeterli miktarda tarafsız eğitim verisine ihtiyacımız vardır.

Veri noktalarına bir göz attığımızda bazı aykırı veriler diğer grubun alanına girer ve sınırı bozar. Makine öğrenmesinin bu sorunu ayırt etmesinin bir yolu yoktur. Eğitim verileri mükemmel değildir ve çeşitli miktarda gürültü içerebilir. Eğitim verilerinin her ögesinin doğru olduğuna ve modelin tamına uyduğuna inanıyorsanız, geliştirilebilirliği daha düşük bir model elde edersiniz. Buna aşırı uygunluk denir.

Aşırı uyumsuzluk, Makine öğreniminin performans seviyesini önemli ölçüde etkiler. Derin sinir ağının özellikle fazladan overfitting'e (aşırı uygunluk) karşı savunmasız olmasının

nedeni, modelin karmaşıklıkça daha fazla gizli katman ve dolayısıyla daha fazla ağırlık içermesindedir. Karmaşık bir model overfitting'e karşı daha dayanıksızdır. Daha yüksek performans için katmanları derinleştirilmesi, sinir ağını makine öğrenimi güçlükleriyle yüzleşmeye zorlar.

Eğitim verilerini (training data) iki gruba ayırırız. Bir grup eğitim için diğer grup doğrulama için kullanılır. Genellikle eğitim setinin (training set) doğrulama kümesine (validation set) oranı 8:2'dir. Model eğitim seti kullanılarak eğitilir. Doğrulama seti kullanarak modelin performansı değerlendirilir.

Farklı doğrulama işlemleri de vardır. Çapraz doğrulama, doğrulama işleminin ufak bir varyasyonudur. Eğitim verilerini eğitim ve doğrulama için gruplara ayırır, ancak veri kümelerini değiştirmeye devam eder. Başlangıçta bölünmüş kümeleri koruyarak yerine çapraz doğrulama, verilerin bölünmesini yineler. Çapraz doğrulama, doğrulama veri kümesinin rast geleliğini korurken, modelin aşırı uygunluğunu daha iyi tespit edebilir.

2.8.4.3. Computational load (Hesaplama yükü)

Eğitimi tamamlamak için geçen süre hesaplama yüküdür. Ağırlıkların sayısı, gizli katmanların sayısı ile ilgili olarak artar, bu nedenle daha fazla eğitim verisi gerektirir. Bu daha fazla hesaplama yapılması gerektirir. Yapay sinir ağı ne kadar çok hesaplama yaparsa, eğitim o kadar uzun sürer. Bu problem sinir ağının pratik gelişiminde bir sorundur. Derin bir sinir ağının eğitilmesi bir ay gibi bir zaman gerekiyorsa bu durumda faydalı bir araştırma çalışması pek mümkün olmayabilir. Bu sorun, GPU gibi yüksek performanslı donanımın ve toplu normalleştirme gibi algoritmaların geliştirilmesiyle büyük ölçüde giderilmiştir.

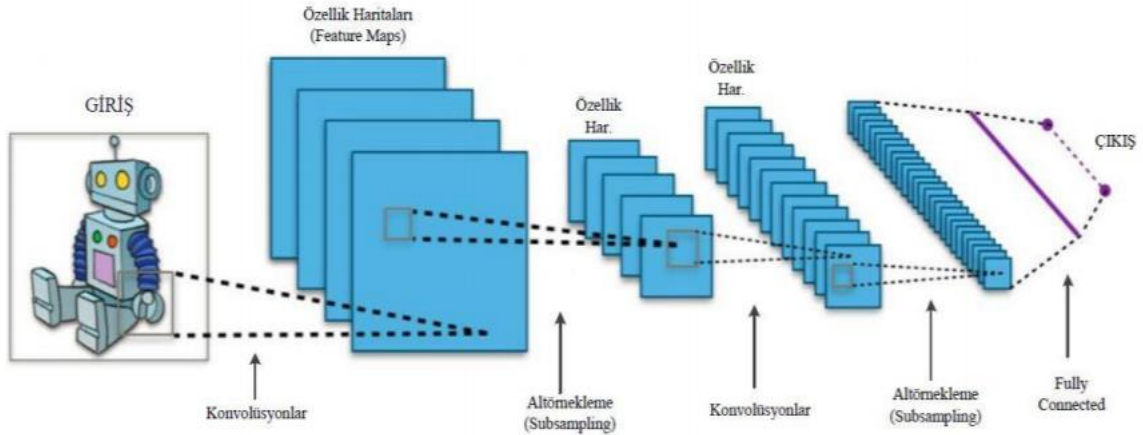
2.8.5. Konvolüsyonel Sinir Ağları (Convolution Neural Network- ConvNet-CNN)

Konvolüsyonel Sinir Ağları (CNN) çok katmanlı algılayıcıların özel bir türüdür. Maymun görsel korteksindeki mikrobiyolojik sinyal işleme mekanizmasının modellenmesinden ilham almıştır. Beynin görsel korteksinin görüntüleri nasıl işlediğini ve tanıdığını taklit eden derin bir ağıdır (56).

CNN algoritmalarıyla nesne tanıma, sınıflandırma, takip etme, doğal dil işleme, biyomedikal, tahmin problemleri gibi birçok farklı alanlarda uygulanmaktadır. Özellikle

görüntü işleme alanında MNIST veri seti üzerinde çalışan Çişeran ve arkadaşlarının yaptığı çalışmada CNN ile hata oranını %2'lere kadar düşürmüşlerdir (67).

2012 yılından beri dramatik bir şekilde yeniden canlandırılan konvolüsyonel sinir ağı, GPU'ların gelişmesiyle birlikte yaygın olarak kullanılmaya başlanmıştır. Şekil 16'da konvolüsyon sinir ağının yapısının görseli verilmiştir.

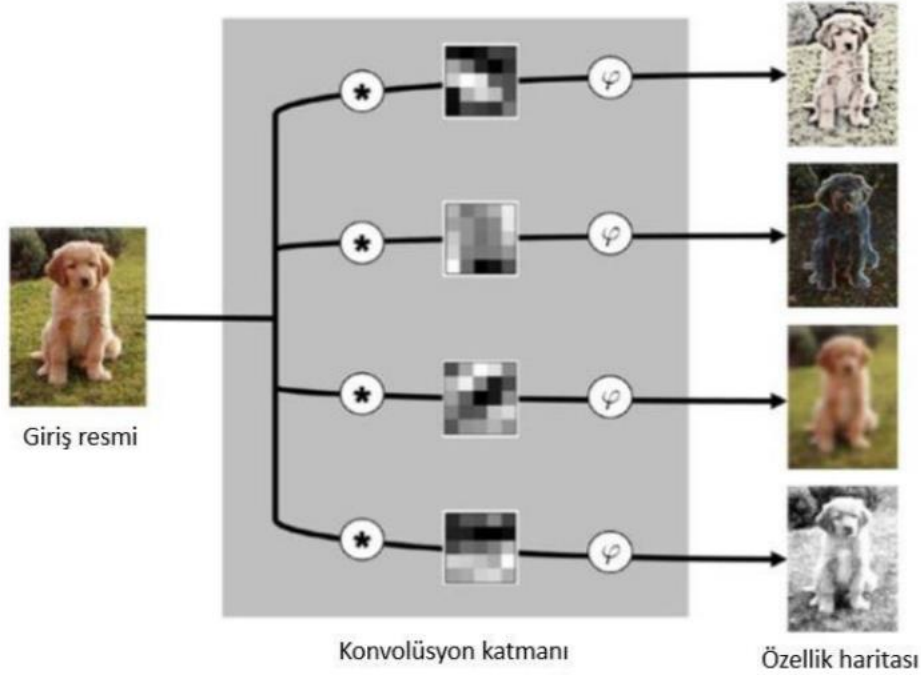


Şekil 16 Konvolüsyonel sinir ağı mimarisi

2.8.5.1. Konvolüsyon (Evrışim) Katmanı

Evrışim katmanı, özellik haritaları adı verilen yeni görüntüler oluşturur. Özellik haritası, orijinal görüntünün benzersiz özelliklerini vurgular. Evrışim katmanı, diğer sinir ağı katmanlarına kıyasla çok farklı çalışır. Bu katman bağlantı ağırlıklarını kullanmaz. Bunun yerine, görüntüleri dönüştüren filtreler içerir. Bu filtrelere evrışim filtreleri denir. Görüntünün evrışim filtreleri yoluyla girilmesi işlemi, özellik haritasını verir

Şekil 17, daire içine alınmış * işaretinin evrışim işlemi ifade ettiği ve ϕ işaretinin etkinleştirme işlevi olduğu, evrışim katmanı işlemi göstermektedir. Bu operatörler arasındaki gri renkli kare simgeler, evrışim filtrelerini göstermektedir. Evrışim katmanı evrışim filtreleriyle aynı sayıda özellik haritası oluşturur. Bu nedenle, örneğin, evrışim katmanı dört filtre içeriyorsa, dört özellik haritası oluşturur.



Şekil 17 Konvolüsyon katmanı süreci (27)

2.8.5.2. Pooling Layer (Havuzlama Katmanı)

Havuzlama katmanı, görüntünün belirli bir alanındaki birbirine komşu pikselleri tek bir temsilci değerde birleştirerek görüntünün boyutunu küçültülmesini sağlar. Havuz katmanında yürütülecek işlemler için görüntüdeki havuz piksellerinin (pooling pixels) nasıl seçileceği ve temsilci değerinin (representative value) nasıl ayarlanacağı önceden belirlenmelidir. Komşu pikseller genellikle kare matristen seçilir ve birleştirilen piksellerin sayısı probleme göre farklılık göstermektedir.

Sonuç olarak matematiksel anlamda havuzlama işlemi bir tür evrişim (konvolüyon) işlemidir. Evrişim katmanından farkı, evrişim filtresinin sabit olması ve evrişim bölgelerinin üst üste binmemesidir. Ek olarak, havuzlama işlemi görüntünün boyutunu düşürdüğü için, hesaplama yükünü hafifletmek ve aşırı uyumluluğu önlemek için oldukça faydalıdır.

2.8.5.3. Fully Connected Layer (Tam Bağlı Katman)

Konvolüsyon ve pooling katmanlarının arkasından gelen katmandır. Bu katman konvolüsyon sinir ağlarının son ve en önemli katmanıdır. Tam bağlı katmanlardan önceki konvolüsyon katmanları, girdideki (input) kenarlar, lekeler, şekiller vb. gibi girdi hakkındaki

ilgili bilgileri tutar. Her bir konvolüsyon katmanı yerel özelliklerden birini temsil eden birkaç filtre içerir. Tam bağlı katmanda tüm bu konvolüsyon katmanlarından gelen bileşik ve toplanmış bilgileri tutar. Önceki katmanlar tarafından ayıklanan özelliklere göre sınıflandırma yapar. Sonuç olarak tam bağlı katman, modelin tahmin etmeye çalıştığı sınıflandırma etiketlerinin her biri için bir olasılık (0-1 arasında bir sayı) veren bir aktivasyon fonksiyonu içeren geleneksel bir yapay sinir ağıdır.

2.8.5.4. Hiper-Parametreler

Makine öğrenme algoritmalarının birçoğu modelin parametrelerini optimize etmeden önce ayarlanması gereken birtakım değişkenleri (hiper-parametreleri) içerir. Hiper parametrelerin değerlerinin ayarlanması bir model seçim aşaması olarak görülebilir. Genellikle hiper-parametreler modeli tasarlayan kişi tarafından belirlenir, bazen de arama algoritmaları veya bazı hiper öğrenenler (hyper-learner) yardımıyla model seçimi ve optimizasyonu yapılır (71).

Yapay sinir ağlarında ağın yapısını ve ağın nasıl eğitileceğini belirleyen iki hiper-parametre grubu bulunmaktadır. Bunlar model hiper parametreler ve iyileştirici(optimizer) hiper parametrelerdir. Model hiper parametreler arasında en çok kullanılan aktivasyon fonksiyonları ve seyreltme katmanı (dropout layer) hiper parametreleridir. Mini-batch boyutu, öğrenme hızı (learning rate) ve epoch (eğitim tur sayısı) ise iyileştirici (optimizer) hiper-parametreler arasında yaygın kullanılanlardır (49, 72).

Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, bir nöronun ağırlıklarının toplamını hesaplayarak ve bias ekleyerek aktive edilip edilmemesine karar verir. Aktivasyon fonksiyonunun amacı, bir nöron çıkışına doğrusal olmayan (non-linear) bir özellik kazandırmaktır. Aktivasyon fonksiyonu olmayan bir yapay sinir ağı, sınırlı limite sahip olan ve iyi performans göstermeyen bir lineer regresyon modeli olacaktır

Seyreltme (Dropout) Katmanı

Çok sayıda parametreye sahip derin sinir ağları çok güçlü makine öğrenme sistemleridir. Ancak, aşırı uygunluk (overfitting) bu tür ağlarda ciddi bir sorundur. Seyreltme katmanı, bu sorunu gidermek için kullanılır. Bu, aşırı uyumluluğu önemli ölçüde azaltır ve diğer düzenleme yöntemlerine kıyasla önemli iyileştirmeler sağlar. Çok katmanlı derin sinir

ağlarında belli eşik değerin altındaki düğümlerin seyreltilmesinin performansı iyileştirdiğini gösterilmiştir. Özetle zayıf bilgilerin seyreltilmesi öğrenmede başarıyı arttırdığı gözlenmiştir (73,74).

Mini-Batch boyutu

Yapay sinir ağlarında bütün veriler için aynı anda işlem yapmak gerek bellek açısından gerekse zaman açısından son derece maliyetli ve zordur. Öğrenme işleminin her tekrarında yapılan geriyayılım (backpropagation) ve ağ üstünde geriye yönelik gradyan (gradient descent) hesaplama işlemleri kullanılarak nöronun ağırlık değerleri yenilenir/hesaplanır. Yapılan hesaplama işleminde (gradyan) veriler ne kadar fazlaysa işlem süresi de o kadar uzun olur. Bu süreyi azaltmak ve ağın performansını artırmak için veriler küçük gruplara ayrılıp öğrenme işlemi bu gruplar üzerinden devam eder.

Girdileri parçalayarak küçük gruplar haline getiren işleme mini-batch adı verilir. Mini-batch işlemi tasarlanan modelin aynı anda kaç veriyi işleyeceğini bulmamızı sağlar. Model önce mini-batch üzerinde ileri besleme ve hata değeri hesaplama işlemi yapar. Sonrasında geriyayılım ve gradyan hesaplamayla yeni ağırlık değerlerini hesaplar (72,73).

Genel olarak mini-batch boyutları hepsi aynı olup %1-%5 arasında ideal olarak seçilmektedir. %1'den küçük seçilirse gürültü çok fazla olmakta, %5'ten fazla seçilirse modelin eğitim değerleri düşmektedir.

Öğrenme Hızı (Learning Rate)

Geri yayılım işlemi derin öğrenmede ağırlık değerlerinin güncellenmesini sağlar. Bu işlem yapılırken önce geriye doğru türev alınarak fark bulunur. Sonrasında bulunan fark değeri learning rate parametresiyle çarpılır ve elde edilen değer ağırlık değerinden çıkarılır, yeni ağırlık değeri elde edilmiş olur. İşlem yapılırken kullanılan learning rate değeri sabit bir değer olabileceği gibi 0.1 ile 0.000001 arasında artan veya azalan bir değer olabilir. Öğrenim hızı için seçilen değerin çok büyük ya da çok küçük olmasının model üzerinde, eğitim verisinden çok etkilenme veya öğrenme süresinin çok uzun olması gibi sonuçları olabilir. Bu yüzden önce büyük değerler kullanılıp eğitim hızı artırılır sonrasında hata değerine yaklaştıkça kullanılan değerler küçültülerek öğrenme işlemi yavaşlatılır.

Eđitim Tur (Epoch) Sayısı

Model üzerinde eđitme iřlemi yapılırken bütn veriler aynı anda eđitime katılamaz bu yüzden veriler küçük gruplara ayrılır. Her bir para sırasıyla eđitilir, test edilir, test sonucu başarı durumuna göre geri yayılım (backpropagation) iřlemiyle yeni ađırlık deđerleri hesaplanır. Bütn paraları bu iřlemlerden geirmekteki ama model için en uygun ađırlık deđerini bulmaktır. Bu sreteki her bir eđitim basamađına "epoch" adı verilir (72,73).

Epoch'ların başarı oranı ilk bařlarda dřk olup sonradan artıř gsterir. Bunun nedeni problemi zmek için gereken ađırlık deđerinin adım adım hesaplanmasıdır. Bir noktadan sonra modelin đrenimi olduka yavařlar bu noktada genellikle đrenme iřlemi durdurulur. Btn bu đrenme sreci gnler hatta aylar srecek bir zamanı kapsayabilir.



3-GEREÇ YÖNTEM

Bu retrospektif çalışma için İzmir Kâtip Çelebi Üniversitesi Girişimsel Olmayan Etik Kurul onayı alınmıştır. Çalışmanın retrospektif doğası nedeniyle hastalardan bilgilendirilmiş onam alınması gerekli olmamıştır.

3.1. Hasta dahil edilmesi

Son 6 yılda İzmir Kâtip Çelebi Üniversitesi Atatürk Eğitim ve Araştırma Hastanesi'nde çekilen el bileği BT tetkiklerinin raporları "skafoïd kırığı" anahtar kelimesi kullanılarak taranmıştır. Tarama sonucunda skafoïd kırık (kırık grubu) tanısı almış 192 hasta ve skafoïd kırığı olmayan 198 normal hasta (normal grup) çalışmaya dahil edilmiştir. Tüm hastaların el bilek ön-arka (AP) standart radyografileri de mevcuttu. Tüm radyografiler, skafoïd kırığı varlığı veya yokluğu açısından 10 yıllık deneyime sahip bir radyolog ve ortopedik cerrah tarafından değerlendirildi. Daha sonra kırığın varlığı veya yokluğu BT ile doğrulandı. Kırığın varlığına veya yokluğuna karar 2 uzmanın ortak görüşü ile verildi.


3.2. Veriler

Skafoïd kemiği içeren region of interest (ROI) seçimine yardımcı olacak bir program, OpenCV 3.0 library for image processing ve Tkinter library for Graphical User arayüz elemanları kullanılarak Python 3'te yazılmıştır. Program, uzman radyoloğun skafoïd bölgeyi dikdörtgen bir alan şeklinde işaretlemesine yardımcı olmaktadır. Programın seçim ve detay pencereleri Şekil 18'de gösterilmiştir.



Şekil 18 Skafoid bölgesini içeren dikdörtgen bir alanın seçimine yardımcı olmak için, her radyogram fare imlecinin çevresindeki görüntü alanının yakınlaştırılmış bir versiyonunu gösteren bir ayrıntı penceresi ile birlikte görüntülenir. Radyolog, daha sonra bir kenarlıkla genişletilen, kırılan ve 196 x 196 piksel nihai veri kümesi görüntü boyutuna ölçeklendirilen skafoid çevresinde sıkı bir dikdörtgen alanı işaretler.

Radyolog 390 görüntünün tümünü işaretledikten sonra, her görüntü skafoid kemik görüntü içinde ortalanmış olarak (2xROI genişlik) boyutuna (2xROI genişlik) kırılır. Bu kırılan görüntüler daha sonra gerektiği şekilde ölçeklendirilerek 196 x 196 piksel boyutuna getirilir. ROI boyutu kabaca skafoid boyutlarıyla orantılı olduğundan, bu şema daha küçük ROI'leri uzatarak ve daha geniş ROI'leri sıkarak denekler arasındaki anatomik boyut farklılıklarını azaltmamıza yardımcı olur. Örnek görüntüler Şekil 19'da gösterilmiştir.



Şekil 19 Kesilmiş alanın ortasında ortalanmış hem kırık hem de sağlıklı skafoid görüntüler içeren son veri kümesinden örnek görüntüler.

Kırpılan görüntülerin bu veri kümesi daha sonra eğitim (training), doğrulama (validation) ve test setlerine aşağıdaki gibi bölündü.

Kırık skafoitleri içeren 50 görüntü ve sağlıklı skafoitleri içeren 50 görüntü rastgele seçildi ve bunlar test setine yerleştirildi. Test setindeki bu 100 görüntü bir kenara bırakılmakta olup eğitim prosedüründe herhangi bir rol oynamamaktadır. Aslında bu görüntüler, yeni hasta verileri üzerinde eğitilmiş ağın beklenen performansını değerlendirmek için sonunda sadece bir kez kullanıldı.

Kalan 290 görüntü eğitim ve doğrulama setlerini oluşturdu. Bunların %70'i sinir ağını eğitmek için ve %30'u doğrulama amacıyla kullanıldı. Eğitim seti sinir ağının ağırlıklarını ayarlamak için kullanıldı. Doğrulama seti, eğitim kalitesini ve alternatif sinir ağı mimarileri ile eğitim dönemi sayısı ve öğrenme hızı gibi hiperparametreler arasındaki seçimi değerlendirmek için tekrar tekrar kullanıldı.

3.3.Eğitim ve Validasyon

Hazırlanan veri kümesi, transfer learning ile sinir ağlarını eğitmek için kullanıldı. Bir sinir ağını rastgele başlatılan ağırlıklardan eğitmenin aksine, transfer learning skafoit sınıflandırma amaçları için ImageNet veri kümesinde önceden belirlenmiş bir ağın yeniden düzenlenmesini sağlamaktadır.

Bu amaçla, önceden hazırlanmış bir ResNet50 ağı indirmek ve en üst katmanları iki sınıf sınıflandırması gerçekleştiren bir katman kümesi ile değiştirmek için fast.ai kitaplığını ve PyTorch çerçevesi kullanılmıştır. Bu yeni katmanlar önce eğitim setini kullanarak eğitildi ve sonra tüm evrimsel katman setinin eğitimine başlandı. Prosedür Nvidia GTX 1050 Ti grafik kartı kullanılarak yaklaşık bir gün sürdü. Bu dönemde birden çok ağ anlık görüntüsü kaydedildi ve doğrulama veri kümesinde en iyi performans gösteren ağlardan biri seçildi ve bu, doğrulama kümesinde %90 doğru sınıflandırma elde etti.

3.4.Ölçek

Validasyon seti eğitim çalışmaları sırasında birçok kez kullanıldığından ve antrenman turlarının sayısının belirlenmesinde kullanıldığından, validasyon setinde elde edilen doğruluk ağın yeni hasta verileri üzerindeki gerçek yaşam performansını temsil etmez. En başta test

amaçlı olarak 100 resimlik ayrı bir set ayrıldığından, bu veriler ağın gerçek performansını ölçmek için kullanıldı.

3.5.Verilerin Analiz Edilmesi

Tüm veriler SPSS sürüm 20.0 yazılımı kullanılarak analiz edildi. CNN sonuçları referans standart olarak kabul edilen BT sonuçları ile karşılaştırıldı. Skafoid kırıklarının normal skafoidden ayırmada duyarlılık, özgüllük, pozitif prediktif değer (PPD), negatif prediktif değer (NPD) ve doğruluk istatistiksel olarak analiz edildi. Tanısal performans, duyarlılık, özgüllük, PPD, NPD ve doğruluk değerleri şu şekilde değerlendirildi: duyarlılık, gerçek pozitif muayene sayısının, gerçek pozitif artı yanlış negatif incelemelerin sayısına bölünmesiyle hesaplandı.

Özgüllük, gerçek negatif inceleme sayısının, gerçek negatif artı yanlış pozitif inceleme sayısına bölünmesiyle hesaplanmıştır. PPD, gerçek pozitif inceleme sayısının tüm gerçek ve yanlış pozitif inceleme sayısına bölünmesiyle hesaplanmıştır. NPD, gerçek negatif inceleme sayısının tüm gerçek ve yanlış negatif inceleme sayısına bölünmesiyle hesaplanmıştır. Doğruluk gerçek pozitif ve gerçek negatif inceleme sayısının tüm incelemelerin sayısına bölünmesiyle elde olunmuştur.

4-BULGULAR

Yaş ortalaması 42 (24-70 yıl) olan toplam 390 hasta çalışmaya dahil edildi.

Skafoid kırıklarının belirlenmesinde BT sonuçları referans olarak kabul edildiğinde CNN sonuçlarında 12 yanlış negatif, 4 yanlış pozitif, 46 gerçek negatif ve 38 gerçek pozitif sonuç belirlendi. Bu sonuçlara göre, derin öğrenme CNN modelinin skafoid kırığının belirlenmesinde %76 duyarlılık, %92 özgüllük, %90,4 PPD, %79,3 NPD ve %84 doğruluğa sahip olduğu hesaplandı. (Tablo 4).

Tablo 4 Skafoid kırıklarının tanısında CNN'nin tanısal doğruluğu

CNN	Radyolojik Bulgular			İstatiksel Bulgular
	Kırık	Normal	Toplam	%
Kırık	38	4	42	
Normal	12	46	58	
Toplam	50	50	100	
Sensitivite				%76
Spesifisite				%92
PPV				%90,4
NPV				%79,3
Doğruluk				%84

CNN: Konvolüsyon Sinir Ağı, BT: Bilgisayarlı tomografi, PPD: Pozitif prediktif değer, NPD: Negatif prediktif değer

5-TARTIŞMA

Skafoid kırıklarının ilk değeriendirilmesi genellikle acil servislerde yapılır. Skafoid kırıkları %30'dan fazla oranda ilk etapta atlanan, tanısı geciken kırıklardır (3). Bu yaralanmalar hayatı tehdit etmese de uygun tedaviye mümkün olduğunca erken başlayabilmek için erken tanı oldukça önemlidir. Tanı için ilk tercih edilen görüntüleme yöntemi basit, ucuz ve kolay ulaşılabilir bir görüntüleme yöntemi olan direkt radyografilerdir. Bu nedenle bu grafilerin mümkün olduğunca doğru değeriendirilmesi ve yorumlanması oldukça önemlidir. Ancak klinik olarak skafoid kırığından şüphelenilen durumlarda direkt radyografi ile gerçek kırıkların rapor edilme oranı %12 ile %57 arasında değişmektedir (78,85). Bu geniş aralık direkt grafilerin acil serviste ilk değeriendirilmesindeki kaliteyle ilişkili olabilir. Çünkü bu grafilerde skafoid kırığını kaçırmamanın veya gerçekte mevcut olmayan bir kırığı görmeyenin oldukça mümkün olduğu bilinmektedir (78). Bu nedenle BT gibi daha pahalı ya da daha fazla radyasyon maruziyetine neden olan görüntüleme yöntemlerine başvurmadan önce sadece direkt radyografi ile skafoid kırıklarında tanı koyulabilirliği arttıracak derin öğrenme CNN gibi yöntemler acil servislerde oldukça faydalı olabilir.

Bu çalışma; normal grafilerin skafoid kırıklarından ayırt edilmesinde derin öğrenme CNN modelinin kabul edilebilir bir performansa sahip olduğunu göstermiştir. Biz derin öğrenme CNN modelinin skafoid kırığının belirlenmesinde %76 duyarlılık, %92 özgüllük, %90,4 PPV, %79,3 NPV ve %84 doğrulukta olduğunu bulduk.

Skafoid kırıklarında direkt radyografilerin prevalansı ile etkinliğinin orantılı olmadığını bu kırıklarda grafilerin kesin tanıya ulaşmayı garanti etmediğini hatta hastaların sadece %66'sının sadece direkt radyografi kullanılarak teşhis edildiği belirtilmiştir (91). İnce skafoid kırıklar 1-2 hafta sonra düz filmde daha belirgin olma eğilimi gösterirken, 6 haftadan fazla radyografik olarak gizli kalabileceği belirtilmiştir (91). Tespit edilemeyen şüpheli olgularda %76-100 arasında değişen oranlarda gereksiz yere fazla alçı yapıldığı ve bu nedenle iş gücü kaybı ve gereksiz sağlık harcamaları olduğu tespit edilmiştir (7). Direkt radyografilerin tercih edilen ilk değeriendirme yöntemi olmasına rağmen ilk röntgende skafoid kırıklarının %16'sının kaçırıldığı rapor edilmiştir (88). Skafoid kırığı şüphesi olan hastaların gerçek kırık prevalansı %5-10 civarındadır (6). Ayrıca birçok çalışma, skafoid kırıklarının tanısında direkt radyografilerin %60-70 oranında duyarlılığa sahip olduğunu, bu oranın ancak kesitsel

görüntüleme yöntemlerinin kullanılması ile 95%'lere kadar çıkabildiğini beyan etmiştir (81,84,92).

Bu çalışmada; derin öğrenme CNN modeli ile 50 skafoid kırığının 38'ine (%76) doğru tanı konuldu. Bu oran literatürdeki çoğu çalışma ile aynı ya da daha iyiydi (81,84,92). Ancak derin öğrenme CNN modeli'nin gelişmeye açık olan potansiyeli göz ardı edilmemelidir. Yeni skafoid kırıkları eklendikçe derin öğrenme CNN modeli'nin tanısal performansı daha da artacaktır. Bu nedenle gelecekte el cerrahlarından bile daha iyi performans gösterebileceğini düşünüyoruz. Çünkü makine potansiyel olarak, herhangi bir el cerrahının yaşamı boyunca görebileceğinden çok daha fazla grafi görebilir ve bu grafi ile sistem otomatik olarak eğitilebilir. Bu da CNN'e düşük maliyetle geniş bir öğrenme imkânı sağlar.

Çalışmamızda derin öğrenme CNN modellemesi ile direkt radyografilerin yorumlanması sonucu yanlış negatiflik oranı %14 olarak bulundu.

Bilindiği üzere atlanmış skafoid kırıkları kaynamamaya ve kısa bir sürede gelişen kalıcı el bilek ağrısına neden olarak el bileğinde fonksiyonel kayba neden olabilir (89). Distale proksimal kan akışı nedeniyle, gözden kaçırılmış bel skafoid kırığı proksimal kemiğe kan akışını bozarak avasküler nekroz ile uzun süreli morbiditeye neden olarak bilekte erken başlangıçlı osteoartrit, kronik ağrı ve fonksiyon kaybına neden olabilir (81). Bu durum yaygın ve önemli bir dava nedenidir (82,83,86). Ring et al. (2015) skafoid kırıkları ile ilgili 99 dava olgusunu incelemiş ve bu davaların %77'sinin tanıdaki hatalarla ilişkili olduğunu bulmuştur (86). Harrison et al. (2015) 85 kapalı skafoid kırık vakasını incelemiş ve dava nedenlerinin %57'sinin atlanmış kırıklar olduğunu rapor etmiştir (82). CSI teknikleri bu kırıklarının tanısındaki gecikmeleri önleyebilir (90). Ancak CSI tekniklerinin daha yüksek maliyeti nedeniyle, tekrarlayan hasta ziyaretlerinde bile, direkt radyografiler çoğu acil servis ve polikliniklerde hala ilk tercih edilen görüntüleme yöntemidir (77,88,90). Son literatür değişken olarak BT ve MRG'nin klinik olarak şüphelenilen skafoid kırığı olan ancak normal düz radyografileri olan hastalarda tercih araştırması olarak kullanılabilirliğini ileri sürmektedir. İzotop kemik taraması oldukça hassastır, ancak daha düşük bir özgüllüğe sahiptir, bu nedenle yüksek yanlış pozitif oranına yol açar (90). Bu nedenle direkt radyografilerin tanıdaki önemi günümüzde hala devam etmektedir. Derin öğrenme CNN modelinin muhtemel potansiyeli de düşünüldüğünde hem basit hem de ucuz bir yöntem olan bu modelin geliştirilmesi ve özellikle acil servislerde yaygınlaşması ile medikolegal açıdan yaşanabilecek bu tür problemlerin bir kısmının önüne geçilebilir.

Her ne kadar eğitim datası arttıkça bu sistemin duyarlılığı artacak gibi görünse de gizli skafoid kırıklarında tanı yine de bir problem olarak devam edecek gibi görünmektedir. Çünkü bu çalışmada atlanmış olan 12 yanlış negatif (%14) grafi incelendiğinde 5'inin radyografik olarak belirgin kırık olduğu 7'sinin ise radyografik olarak tamamen normal olan gizli kırıklar olduğu görüldü. Bu 7 kırık klinik şüphe üzerine BT çekilerek skafoid kırığı tanısı almıştı. Bu modelleme ile gizli skafoid kırıklarının hiçbirisine tanı koyulamadı. Ancak biz bu durumun derin öğrenme CNN modelinin bir başarısızlığı olarak yorumlanmaması gerektiğini düşünüyoruz. Çünkü gizli kırıklar; optimal radyografik görüntüler elde edilse ve bu grafi deneyimli bir uzman tarafından değerlendirilse bile tanı alamayabilmektedir (75). Bu nedenle direkt radyografide herhangi bir bulgusu olmayan bu kırıkların CNN ile doğru tanı alması beklenen bir durum değildir.

Bu çalışmanın çeşitli kısıtlılıkları var bunlardan ilki de retrospektif olması. Bir diğer kısıtlılık ise scaphoid kırıklarının tanısının yalnızca AP el bilek radyografilerine dayanılarak konulmasıydı. Genellikle scaphoid kırıklarının tanısı AP, oblique, lateral ve angled AP grafi içeren skafoid seri grafi ile yapılmaktadır. Böylece tek bir projeksiyonda görünmeyen kırık diğer projeksiyonlarda görülebilir. Ancak çalışmamızda CNN'in tanılma performansını belirlemek için daha basit olması nedeniyle yalnızca AP grafi değerlendirildi. Aslında diğer projeksiyonlar ve BT görüntülerine dayanan değerlendirmeler CNN'in tanılma performansını arttırabilir. Bir diğer kısıtlılık ise çalışmanın örneklem boyutunun görece düşük olmasıydı.

Sonuç olarak bu çalışma derin öğrenme algoritmasının el cerrahisi alanında da kullanılabilme potansiyelini gösterdiği için önemlidir. Yapay zekâ el bilek AP grafiğinde skafoid kırıklarını doğru bir şekilde tanıyabilir. Bu sistem aynı anda birden çok merkezde çalıştırılabileceğinden dolayı ek veriler sayesinde sistemin eğitimi hızlı bir şekilde tamamlanabilir ve mevcut duyarlılığı arttırılabilir. Skafoid kırıklarının tanısı için geliştirilen yapay zekâ temelli bu otomatik tanı sistemi sayesinde el bilek grafi doğru bir şekilde yorumlanabilir ve sonuçları nerdeyse anında raporlanabilir. Bu durum gelecek için oldukça umut vericidir. Ancak yapay zekanın güvenilirliği ve klinik uygulanabilirliğiyle ilgili olarak daha fazla çalışmalara ihtiyaç vardır. Rutin klinik pratikte kullanılabilmesi için gelecekte yapılacak geniş serili çalışmalar ile bu sonuçların desteklenmesi gerekmektedir.

6-SONUÇ

İzmir Katip Çelebi Üniversitesi Atatürk Eğitim Araştırma Hastanesi'ne başvurup skafoid kırığı tespit edilen hastaların kırıklarının derin öğrenme yöntemi kullanılarak tespitinin doğruluğunu saptamak amacıyla yaptığımız çalışmada elde ettiğimiz verilere ışığında;

1. Yaş ortalaması 42 olduğu ve 390 hastayla çalışmanın yapıldığı,
2. Literatürde acil servis başvurularında skafoid kırıklarının %12-57 oranında tespit edildiği ve atlanan skafoid kırığının fazla olduğu,
3. Direkt grafilerde değerlendirme esnasında kırık olmayan görüntülerinde kırık olarak değerlendirilerek gereksiz yere alçı/atel uygulandığı,
4. Direkt grafilerle skafoid kırığının düşünülmesi üzerine yapılan kesitsel incelemelerle %95'e kadar skafoid kırığının tespit edilebildiği fakat bu durumda da hem radyasyon maruziyetinin fazla olduğu hem de ekonomik yükün fazla olduğu,
5. Bunun yanında derin öğrenme CNN modeliyle direkt grafi üzerinden tanı koymada doğruluk oranının %84 olduğu,
6. Derin öğrenme CNN modelinin potansiyeli düşünüldüğünde hem basit hem de ucuz bir yöntem olan bu modelin geliştirilmesi ve özellikle acil servislerde yaygınlaşması ile tanı koymada ve malpraktis davalarında önemli rol oynayabileceği,
7. Derin öğrenme CNN modelinin skafoid kırığı tespitinde kullanılabilir olduğu,
8. Kapsamlı çalışmalarla daha net sonuçlara varılabileceği,
9. Elde edilen verilerle hem literatüre hem de morbiditenin azaltılarak ülke ekonomisine katkı sağlanabileceği düşünüldü.

KISITLILIKLAR

Bu çalışmanın çeşitli kısıtlılıkları var. Retrospektif olması bunlardan biriyken en önemlisi de scaphoid kırıklarının tanısının yalnızca AP el bilek radyografilerine dayanılarak konulması. Skafoid kırıklarının tanısı AP, oblique, lateral ve angled AP grafileri ile koyulmakta. Böylece tek bir görünümde görülemeyen kırık diğer görünümde görülebilir. Ancak çalışmamızda CNN'in tanısız performansını belirlemek için daha basit olması nedeniyle yalnızca AP grafiler değerlendirildi. Diğer görünüm ve BT görüntülerine dayanan değerlendirmeler ile CNN'in tanısız performansı arttırılabilir. Bir diğer kısıtlılık ise çalışmanın örneklem boyutunun görece düşük olmasıydı.

7-ÖZET

Giriş ve Amaç: Skafoid kırıklar tüm karpal kemik kırıkları arasında en sık görülen kırıklardır. Skafoid kırıkları %30'dan fazla oranda ilk etapta atlanan, tanısı geciken kırıklardır. Skafoid kırıklarının teşhisi esas olarak radyografilerde yapılır. Bilgisayarlı tomografi (BT) erken tanı için kullanılabilir, ancak bu ek maliyetlere ve radyasyona maruz kalmaya yol açar. Derin öğrenme yapay sinir ağlarının eğitime dayanan bir makine öğrenme yöntemidir. Görüntü analizi için genellikle bir dizi görüntü filtresi öğrenen evrişimli sinir ağı katmanları kullanılır. Bu sinir ağlarına Konvolüsyonel Sinir Ağları (CNN) denir. CNN kullanımı ile derin öğrenmenin kemik kırıklarının teşhisinde kullanılabileceği gösterilmiştir. Bu çalışmanın amacı, anteroposterior (AP) el bilek radyografilerinde skafoid kırıklarının saptanmasında CNN kullanımı ile derin öğrenme algoritmasının doğruluğunu saptamaktır.

Materyal ve Metod: Son 6 yılda çekilen el bileği BT tetkiklerinin raporları “skafoid kırığı” anahtar kelimesi kullanılarak tarandı ve sonucunda skafoid kırığı (kırık grubu) tanısı almış 192 hasta ve skafoid kırığı olmayan 198 normal hasta (normal grup) çalışmaya dahil edildi. Kırığın varlığına veya yokluğuna karar 2 uzmanın ortak görüşü ile verildi. Skafoid kemiği içeren region of interest (ROI) seçimine yardımcı olacak bir program, OpenCV 3.0 library for image processing ve Tkinter library for Graphical User arayüz elemanları kullanılarak Python 3'te yazıldı. Kırık skafoidleri içeren 50 görüntü ve sağlıklı skafoidleri içeren 50 görüntü rastgele seçildi ve bunlar test setine yerleştirildi. Kalan 290 görüntü eğitim ve doğrulama setlerini oluşturdu. Bunların %70'i sinir ağını eğitmek için ve %30'u doğrulama amacıyla kullanıldı. Tüm veriler SPSS sürüm 20.0 yazılımı kullanılarak analiz edildi. CNN sonuçları referans standart olarak kabul edilen BT sonuçları ile karşılaştırıldı. Skafoid kırıklarını normal skafoidden ayırmada duyarlılık, özgüllük, pozitif prediktif değer (PPD), negatif prediktif değer (NPD) ve doğruluk istatistiksel olarak analiz edildi.

Bulgular: Yaş ortalaması 42 (24-70 yıl) olan toplam 390 hasta çalışmaya dahil edildi. Skafoid kırıklarının belirlenmesinde BT sonuçları referans olarak kabul edildiğinde CNN sonuçlarında 12 yanlış negatif, 4 yanlış pozitif, 46 gerçek negatif ve 38 gerçek pozitif sonuç belirlendi. Bu sonuçlara göre, derin öğrenme CNN modelinin skafoid kırığının belirlenmesinde %76 duyarlılık, %92 özgüllük, %90,4 PPD, %79,3 NPD ve %84 doğruluğa sahip olduğu hesaplandı.

Tartışma ve Sonuç: Skafoid kırıklarının ilk değerlendirilmesi genellikle acil servislerde yapılır. Skafoid kırıkları %30'dan fazla oranda ilk etapta atlanan, tanısı geciken

kırıklardır. Tanı için ilk tercih edilen görüntüleme yöntemi basit, ucuz ve kolay ulaşılabilir bir görüntüleme yöntemi olan direkt radyografilerdir. Çalışmamızda CNN ile direkt grafilerde skafoid kırıklarının doğruluğu %84 olarak tespit edilmiştir. Sadece direkt radyografi ile skafoid kırıklarında tanı koyulabilirliği arttırabilecek derin öğrenme CNN gibi yöntemler acil servislerde oldukça faydalı olabilir. Bu konuda daha kesin sonuçlara varmak için daha kapsamlı çalışmalara ihtiyaç duyulmaktadır.

Anahtar Kelimeler: acil servis, skafoid, kırık, derin öğrenme, yapay zeka, radyografi.



SUMMARY

EVALUATION OF AN ARTIFICIAL INTELLIGENCE SYSTEM FOR DIAGNOSING SCAPHOID FRACTURE ON DIRECT RADIOGRAPHY

Aim: Scaphoid fractures are the most common fractures among all carpal bone fractures. Scaphoid fractures are more than 30% in the first place and the diagnosis is delayed. Diagnosis of scaphoid fractures is made mainly on radiographs. Computed tomography (CT) can be used for early diagnosis, but this leads to additional costs and radiation exposure. Deep learning is a machine learning method based on the training of artificial neural networks. Convolutional neural network layers that often learn a range of image filters are used for image analysis. These neural networks are called Convolutional Neural Networks (CNN). It has been shown that deep learning can be used in the diagnosis of bone fractures with the use of CNN. The aim of this study is to determine the accuracy of deep learning algorithm with the use of CNN in the detection of scaphoid fractures in anteroposterior (AP) wrist radiographs.

Material and Method: Reports of wrist CT examinations taken in the last 6 years were scanned using the keyword “scaphoid fracture” and as a result, 192 patients with scaphoid fracture (fracture group) and 198 normal patients (normal group) without scaphoid fractures were included in the study. The decision on the presence or absence of the fracture was made with the common opinion of 2 experts. A program to help select the region of interest (ROI) containing scaphoid bone was written in Python 3 using the OpenCV 3.0 library for image processing and the Tkinter library for Graphical User interface elements. 50 images containing broken scaphoids and 50 images containing healthy scaphoids were randomly selected and placed in the test set. The remaining 290 images created training and verification sets. 70% of them were used to train the neural network and 30% were used for verification. All data were analyzed using SPSS version 20.0 software. CNN results were compared with CT results, which are considered as reference standards. Sensitivity, specificity, positive predictive value (PPD), negative predictive value (NPD) and accuracy were statistically analyzed to distinguish scaphoid fractures from normal scaphoid.

Results: A total of 390 patients with an average age of 42 (24-70 years) were included in the study. When CT results were accepted as the reference in determining scaphoid fractures, 12 false negative, 4 false positive, 46 true negative and 38 true positive results were determined in CNN results. According to these results, it was calculated that the deep learning CNN model

has 76% sensitivity, 92% specificity, 90.4% PPD, 79.3% NPD and 84% accuracy in determining the scaphoid fracture.

Discussion and Conclusion: The first evaluation of scaphoid fractures is generally performed in emergency departments. Scaphoid fractures are more than 30% in the first place and the diagnosis is delayed. The first preferred imaging method for diagnosis is direct radiographs, a simple, inexpensive and easily accessible imaging method. In our study, the accuracy of scaphoid fractures in direct radiographs with CNN was found to be 84%. Only methods such as deep learning CNN that can increase the diagnosis of scaphoid fractures by direct radiography can be very useful in emergency departments. More comprehensive studies are needed to reach more precise results in this regard.

Keywords: emergency services, scaphoid, fracture, deep learning, artificial intelligence, radiography.

KAYNAKLAR

1. Gaebler C, McQueen MM. Carpus kırıkları ve çıkıkları. In: Bucholz RW, Heckman JD, Court-Brown CM, Tornetta P, editörler. Yetişkinlerde kırıklar. 3. baskı Philadelphia: Lippincott Williams ve Wilkins; 2009. s. 782- 828.
2. Bucholz RW, Heckman JD, Court-Brown C. El bileği kırık ve çıkıkları. Şaylı U. Rockwood ve Green Erişkin Kırıkları. 6.Baskı, Ankara: Ayrıntı Basımevi, 2011:858.
3. Mark D Miller, stephen R. Thompson Jennifer A. Hart Review Of Orthopaedics 6th Edition Güneş tıp kitapevi 2014:603.
4. Trumble TE, Salas P, Barthel T, Robert KQ 3. Skafoid kaynamamaların yönetimi. J Am Acad Orthop Surg 2003; 11: 380-91.
5. Schuind F, Mounghondo F, El Kazzi W. Karpal skafoid noniyonların tedavisinde prognostik faktörler. Eur J Orthop Surg Traumatol. 2017; 27: 3-9.
6. Zhong-Gang Yin MD, Jian-Bing Zhang MD, Shi-Lian Kan MD, XiaoGang Wang MD. Diagnosing Suspected Scaphoid Fractures Clin Orthop Relat Res (2010) 468:723734.
7. Schuind F, Haentjens P, Van Innis F, Vander Maren C, Garcia-Elias M, Sennwald G. Prognostic factors in the treatment of carpal scaphoid nonunions. J Hand Surg Am 1999;24:761-76.
8. Adams JE, Steinmann SP. Acute scaphoid fractures. Orthop Clin North Am 2007;38:229-35.
9. Olczak J, Fahlberg N, Maki A, Razavian AS, Jilert A, Stark A, Sköldenberg O, Gordon M. Acta Orthop 2017; 88: 581-586.)
10. (Lindsey R, Daluiski A , Chopra S, Lachapelle A, Mozer M, Sicular S, Hanel D, Gardner M, Gupta A, Hotchkiss R, Potter H.Proc Natl Acad Sci US A. 2018; 115: 11591- 11596.)
11. Arıncı K, Elhan A. Anatomi. 1. Cilt. 4. Baskı. Ankara: Güneş Kitabevi; 2006.
12. Snell RS. Clinical anatomy by regions. 8th ed. Baltimore: Lippincott Williams & Wilkins; 2001. p. 480-87.
13. Standring S, Gray's anatomy: The anatomical basis of clinical practice. 39th ed. Edinburg: Churchill Livingstone; 2004.
14. Şen T, Kömürcü M. El bileği eklemının ve karpal tünelin anatomisi. TOTBİD Dergisi 2011;10(1):18-24
15. Gray, Henry F.R.S. Grays Anatomy. London, Constable and Robinson Ltd. 2002, s 103-104, 177-

16. Canale ST, Beaty J. Campbell's operative orthopaedics. Volume 4 Chapter 66: Wrist Disorders.. 11th ed 2008:961
17. R. Srinivas Reddy, J. Compson; Examination of the wrist surface anatomy of the carpal bones Current Orthopaedics (2005) 19, 171 179
18. Bonzentka D. Scapholunate instability. UPOJ 1999:Vol12;27-32
19. Patterson R, Morimoto H. Scaphoid anatomy and Mechanics: Update and review. Operative Techniques in Orthopaedics 2003;Vol13(1):2-10.
20. <http://surugue.com/oo/text/wrist-ligaments-Biomechanics.html>
21. Green DP, Pederson WC, Hotchkiss RN, Wolfe SW. Greens Operative Hand Surgery, Fifth edition, Philadelphia: Elsevier Churchill Livingstone, 2005:742
22. Bucholz RW, Heckman JD, Court-Brown C. El bileği kırık ve çıkıkları. Şaylı U. Rockwood ve Green Erişkin Kırıkları. 6.Baskı, Ankara:Ayrıntı Basımevi, 2011:866
23. Gelberman RH, Menon J. The vascularity of the scaphoid bone, J Hand Surg Am.1980 Sep;5(5):508-13.
24. Green DP, Pederson WC, Hotchkiss RN, Wolfe SW. Greens Operative Hand Surgery, eighth edition, Philadelphia: Elsevier Churchill Livingstone, 2008:Chapter 14,17
25. Rainbow MJ, Kamal RN, Leventhal E, Akelman E, Moore DC, Wolfe SW, Crisco JJ. In vivo kinematics of the scaphoid, lunate, capitate, and third metacarpal in extreme wrist flexion and extension. J Hand Surg Am 2013;38(2):278–88.
26. Horii E, Nakamura R, Watanabe K, Tsunoda K. Scaphoid fracture as a “puncher’s fracture”. J Orthop Trauma 1994;8(2):107–10.
27. Gaebler C. Fractures and dislocations of the carpus. In: Bucholz RW, Heckman JD, Court-Brown CM, editors. Rockwood and Green’s fractures in adults. 6th ed. Philadelphia, Pa: Lippincott Williams & Wilkins; 2006. p.857–908.
28. Freeland P. Scaphoid tubercle tenderness: a better indicator of scaphoid fractures? Arch Emerg Med 1989;6-1:46-50.
29. Grover R. Clinical assessment of scaphoid injuries and the detection of fractures. J Hand Surg Br 1996;21(3):341–3.
30. Munk B, Bolvig L, Kroner K, Christiansen T, Borris L, Boe S. Ultrasound for diagnosis of scaphoid fractures. J Hand Surg Br 2000;25-4:369
31. Chen SC. The scaphoid compression test. J Hand Surg Br 1989;323.

32. J. P. Compson The anatomy of acute scaphoid fractures J Bone Joint Surg [Br] 1998;80-B:218-24.
33. Haisman JM, Rohde RS, Weiland AJ; American Academy of Orthopaedic Surgeons. Acute fractures of the scaphoid. J Bone Joint Surg [Am] 2006;88:2750-8.
34. Henriksen OM, LonsdaleMN, JensenTD, WeikopKL, Holm O, Duus B, et al. Two-dimensional fusion imaging of planar bone scintigraphy and radiographs in patients with clinical scaphoid fracture: an imaging study. Acta Radiol 2009;50:71-7.
35. Ring D, Lozano-Calderon S. Imaging for suspected scaphoid fracture. J Hand Surg [Am] 2008;33:954-7
36. Smith ML, Bain GI, Chabrel N, Turner P, Carter C, Field J. Using computed tomography to assist with diagnosis of avascular necrosis complicating chronic scaphoid nonunion. J Hand Surg [Am] 2009;34:1037
37. Russe O. Fracture of the carpal navicular. Diagnosis, non-operative treatment and operative treatment. J Bone Joint Surg Am 1960;42-A:759-68.
38. Herbert TJ, Fisher WE. Management of the fractured scaphoid using a new bone screw. J Bone Joint Surg Br 1984;66(1):114-23.
39. Cooney WP, Dobyns JH, Linscheid RL. Fractures of the scaphoid: a rational approach to management. Clin Orthop 1980-149:90-7
40. Öztemel E (2003). Yapay sinir ağları. Papatya Yayıncılık, İstanbul.
41. Sarı M (2016). Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Sakarya
42. Karahan M (2011). İstatistiksel tahmin yöntemleri: yapay sinir ağları metodu ile ürün talep tahmini uygulaması, Doktora Tezi, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Konya.
43. Karpathy A (2018). Stanford University CS231n: Convolutional neural networks for Visual Recognition. Available from: <http://cs231n.stanford.edu/syllabus.html>. [Accessed 3 April 2019].
44. Alpaydın E (2011). Yapay Öğrenme, Boğaziçi Üniversitesi Yayınevi, İstanbul.
45. Yazıcı ÜH (2010). Yapay sinir ağları ile banka müşterisi bekleme süresi tahmini, Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Erzurum.

46. Ballı MT (2014). Yapay sinir ağları ile talep tahmini ve gıda sektöründe uygulanması, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul.
47. Dülger E (2016). Ekonomide öncü göstergeler ile büyüme tahmini uygulaması, Yüksek Lisans Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Ankara.
48. Kim P (2017). Matlab deep learning. In *With Machine Learning, Neural Networks and Artificial Intelligence*. Apress, New York, ABD.
49. Cireşan DC, Meier U, Schmidhuber J (2012). Multi-column deep neural networks for image classification. 2012 IEEE Conference on Computer Vision and Pattern Recognition, 3642-3649.
50. LeCun Y, Y, Hinton G (2015). Deep learning. *Nature* 521(7553): 436.
51. Ivakhnenko AG, Lapa VG (1965). *Cybernetic predicting devices*. CCM Information Corporation, New York, United States.
52. Fukushima K (1980). Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics* 36(4): 193-202.
53. Linnainmaa S (1970). The Representation of the cumulative rounding error of an algorithm as a Taylor expansion of the local rounding errors. Master's Thesis (in Finnish), University of Helsinki, Finland.
54. Griewank A (2012). Who invented the reverse mode of differentiation. *Documenta Mathematica, Extra Volume ISMP*: 389-400.
55. Werbos P (1974). Beyond regression: new tools for prediction and analysis in the behavioral sciences, PhD dissertation, Harvard University, ABD.
56. Werbos PJ (1982). Applications of advances in nonlinear sensitivity analysis. In: Drenick RF, Kozin F (eds) *System Modeling and Optimization*. Lecture Notes in Control and Information Sciences, vol 38. Springer, Berlin, Heidelberg, 762-770.
57. Weng J, Ahuja N, Huang TS (1992). Cresceptron: a self-organizing neural network which grows adaptively. In *IJCNN International Joint Conference on Neural Networks* 1:576-581.
58. Weng JJ, Ahuja N, Huang TS (1993). Learning recognition and segmentation of 3-d objects from 2-d images. *4th International Conference on Computer Vision* :121- 128.
59. Weng JJ, Ahuja N, Huang TS (1997). Learning recognition and segmentation using the cresceptron. *International Journal of Computer Vision* 25(2): 109-143.

60. De Carvalho A, Fairhurst MC, Bisset DL (1994). An Integrated boolean neural network for pattern classification. *Pattern Recognition Letters* 15(8): 807-813.
61. Hinton GE, Dayan P, Frey BJ, Neal RM (1995). The Wake-sleep algorithm for unsupervised neural networks. *Science* 268(5214): 1158-1161.
62. Heck LP, Konig Y, Sönmez MK, Weintraub M (2000). Robustness to telephone handset distortion in speaker recognition by discriminative feature design. *Speech Communication* 31(2-3): 181-192.
63. Hochreiter S, Schmidhuber J (1997). Long short-term memory. *Neural Computation* 9(8): 1735-1780.
64. Bengio Y (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning* 2(1): 1-127.
65. Oh KS, Jung K (2004). GPU implementation of neural networks. *Pattern Recognition* 37(6): 1311-1314.
66. Chellapilla K, Puri S, Simard P (2006). High performance convolutional neural networks for document processing. In *Tenth International Workshop on Frontiers in Handwriting Recognition*, Universite de Rennes, France.
67. Cireşan DC, Meier U, Gambardella LM, Schmidhuber J (2010). Deep, big, simple neural nets for handwritten digit recognition. *Neural Computation* 22(12): 3207- 3220.
68. Raina R, Madhavan A, Ng AY (2009). Large-scale deep unsupervised learning using graphics processors. In *Proceedings of the 26th Annual International Conference on Machine Learning*, Montreal, Quebec, Canada, 14-18 June 2009, 873-880.
69. Krizhevsky A, Sutskever I, Hinton GE (2012). Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*: 1097-1105.
70. Deng L, Yu D (2014). *Deep learning: methods and applications*. *Foundations and Trends in Signal Processing* 7(3-4):197-387.
71. Hubel DH, Wiesel TN (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology* 195(1): 215-243.
72. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research* 15(1): 1929-1958
73. Bengio Y (2012). Practical recommendations for gradient-based training of deep architectures. In *Neural Networks: Tricks of the trade* : 437-478.

74. Goodfellow I, Bengio Y, Courville A (2016). Deep learning. MIT press, Cambridge, United Kingdom.
75. Amrami KK, Frick MA, Matsumoto JM. Imaging for acute and chronic scaphoid fractures. *Hand Clin.* 2019, 35: 241-57.
76. Angermann P, Lohmann M. Injuries to the hand and wrist. A study of 50,272 injuries. *J Hand Surg Br.* 1993, 18: 642-4.
77. Bethel J. Scaphoid fracture: Diagnosis and management. *Emerg Nurse.* 2009, 17: 24-9.
78. Carpenter CR, Pines JM, Schuur JD et al. Adult scaphoid fracture. *Acad Emerg Med.* 2014, 21: 101-21.
79. Cheng CT, Ho TY, Lee TY et al. Application of a deep learning algorithm for detection and visualization of hip fractures on plain pelvic radiographs. *Eur Radiol.* 2019, 29: 5469-77.
80. Chung SW, Han SS, Lee JW et al. Automated detection and classification of the proximal humerus fracture by using deep learning algorithm. *Acta Orthop.* 2018, 89: 468-3.
81. De Zwart AD, Beeres FJ, Ring D et al. MRI as a reference standard for suspected scaphoid fractures. *Br J Radiol.* 2012, 85: 1098-101.
82. Harrison W, Newton AW, Cheung G. The litigation cost of negligent scaphoid fracture management. *Eur J Emerg Med.* 2015, 22: 142-3.
83. Jamjoom BA, Davis TRC. Why scaphoid fractures are missed. A review of 52 medical negligence cases. *Injury.* 2019, 50: 1306-8.
84. Platon A, Poletti PA, Van Aaken J et al. Occult fractures of the scaphoid: The role of ultrasonography in the emergency department. *Skeletal Radiol.* 2011, 40: 869-75.
85. Rhemrev SJ, Beeres FJP, van Leerdam RH et al. Clinical prediction rule for suspected scaphoid fractures: A prospective cohort study. *Injury.* 2010, 41: 1026-30.
86. Ring J, Talbot C, Price J, et al. Wrist and scaphoid fractures: A 17 year review of NHSLA litigation data. *Injury.* 2015, 46: 682-6.
87. Sabbagh MD, Morsy M, Moran SL. Diagnosis and management of acute scaphoid fractures. *Hand Clin.* 2019, 35: 259-69.
88. Smith M, Bain GI, Turner PC et al. Review of imaging of scaphoid fractures. *Aust N Z J Surg.* 2010, 80: 82-90.
89. Shetty S, Sidharthan S, Jacob J, et al. Clinical scaphoid fracture: Is it time to abolish this phrase? *Ann R Coll Surg Engl.* 2011, 93: 146-8.

90. Tibrewal S, Jayakumar P, Vaidya S et al. Role of MRI in the diagnosis and management of patients with clinical scaphoid fracture. *Int Orthop*. 2012, 36: 107-10.
91. Wijetunga AR, Tsang VH, Giuffre B. The utility of cross-sectional imaging in the management of suspected scaphoid fractures. *J Med Radiat Sci*. 2019, 66: 30-7.
92. Yin ZG, Zhang JB, Gong KT. Cost-effectiveness of diagnostic strategies for suspected scaphoid fractures. *J Orthop Trauma*. 2015, 29: e245-52.



EKLER

Ek-1.1 Etik Kurul Onayı

T.C.
İZMİR KÂTİP ÇELEBİ ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu Karar Formu

Sayın Doç. Dr. Fatih Esat TOPAL

Karar No: 440
Tarih : 19.12.2018

KARAR

Bilgisayar destekli sistem ile direk grafide skafoid kırıklarının tanısı adlı araştırma başvuru dosyanız kurulumuzda gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiştir. İnceleme sonucunda çalışmanın başvuru dosyasında belirtilen merkezlerde gerçekleştirilmesinde **etik ve bilimsel açıdan sakınca bulunmadığına** toplantıya katılan etik kurul üyelerinin **oy birliği** ile karar verilmiştir.

Doç. Dr. Orhan GÖKALP

Başkan

Doç. Dr. Serdar BAYATA
Başkan Yardımcısı

Prof. Dr. Yasemin TOKEM
Üye

T. KATILMADI
Prof. Dr. Belde Kasap DEMİR
Üye

İLİŞKİLİ T. KATILMADI
Doç. Dr. Özgür TOSUN
Üye

Doç. Dr. Aşlı BAYSAL
Üye

T. KATILMADI
Uzm. Dr. Ayşenur ATAY
Üye

T. KATILMADI
Dr. Mehmet ERTAN
Üye

Uzm. Dr. Doğu Barış KILIÇCIOĞLU
Raportör Üye

Dr. Öğr. Üyesi Gülşay OYUR ÇELİK
ÜYE

KARSI OY _____ :

