



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME YÖNTEMLERİ
KULLANARAK KALÇA DİSPLAZİSİNİN BELİRLENMESİ

Muhammed Cihad ÖZDEMİR

YÜKSEK LİSANS TEZİ

Elektrik- Elektronik Mühendisliği Anabilim Dalı

Haziran-2023
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Muhammed Cihad Özdemir tarafından hazırlanan “Derin Öğrenme Yöntemleri Kullanılarak Kalça Displazisinin Belirlenmesi” adlı tez çalışması .../.../2023 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik–Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr.Öğr.Üyesi Levent CİVCİK

.....

Danışman

Doc.Dr. Murat CEYLAN

.....

Üye

Dr.Öğr.Üyesi Saim ERVURAL

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Muhammed Cihad ÖZDEMİR
Tarih: 01.08.2023

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK KALÇA DİSPLAZİSİNİN BELİRLENMESİ

Muhammed Cihad ÖZDEMİR

Lisansüstü Eğitim Enstitüsü

Elektrik- Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Murat CEYLAN

2023, 66 Sayfa

Jüri

Doç. Dr. Murat CEYLAN

Dr.Ögr.Üyesi Levent CİVCİK

Dr.Ögr.Üyesi Saim ERVURAL

Gelişimsel kalça displazisi (GKD), doğum öncesi, doğum sırası ya da doğum sonrası çeşitli nedenlere bağlı olarak kalça eklemine normal gelişmemesi sonucu oluşan bir hastalıktır. Ülkemizde yapılan araştırmalarda, dislokasyon oranlarının 5-15:1000 gibi yüksek olduğunu görülmüştür. Gelişimsel kalça displazisinin (GKD) tespit etmek için kullanılan en önemli yöntem ise kalça ultrasonografisidir (US). Kalça US görüntüsünün elde edilme aşaması operatöre ve dış etkilere bağlı olduğu için değişkenlik göstermektedir. Bu değişkenlikte yanlış sınıflandırmalara yol açabilmektedir. Gerçekleştirilen tez çalışması ile bu değişkenliği ortadan kaldırmak ve hataları en aza indirmek için yapay zekâ tabanlı bir sistem geliştirilmiştir. Geliştirilen sistem 2 aşamalı bir derin öğrenme modelini kapsamaktadır.

İlk aşamada U-NET mimarisi ikinci aşamada da Maske ile bölge tabanlı evrişimsel sinir ağı mimarisi kullanılmaktadır. İlk olarak kalça US görüntüsü doğru alınıp alınmadığı yani analiz edilebilirliği kontrol edilmektedir. Belirlenmesi gereken 3 temel anatomik yapının (iskium, ilium, labrum) tespit edilip edilmediği kontrol edilir. Daha sonra iliak kemiğin temel çizgiye paralelliği kontrol edilmektedir. Eğer ilium temel çizgiye paralelse ve tüm anatomik yapılar tespit edilmişse, US görüntüsü analiz edilebilir olarak sınıflandırılmaktadır. Analiz edilebilir olarak sınıflandırılan bu US görüntüsü üzerinde alfa ve beta açıları hesaplanarak gelişimsel kalça displazisi sınıflandırılmaktadır. Tez çalışmasında geliştirilen sistemin, gelişimsel kalça displazisi tanısında operatörler arası değişkenliği ortadan kaldırarak, yapılacak teşhisin doğruluğunu arttıracığı ve böylelikle uzmanlara yardımcı olacağı düşünülmektedir.

Anahtar Kelimeler: Derin Öğrenme, Gelişimsel Kalça Displazisi, Evrişimsel Sinir Ağları, Maskeli Bölge Tabanlı Evrişimli Sinir Ağı , U-NET

ABSTRACT

MS THESIS

DETERMINING HIP DYSPLASIA USING DEEP LEARNING METHODS

Muhammed Cihad ÖZDEMİR

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Assoc. Prof. Murat CEYLAN

2023, 66 Pages

Jury

Assoc. Prof. Murat CEYLAN

Assist. Prof. Levent CİVCİK

Assist. Prof. Saim ERVURAL

Developmental hip dysplasia (DDH) is a disease in which the hip joint fails to develop normally due to various reasons before, during or after birth. In studies conducted in our country, it has been observed that dislocation rates are as high as 5-15:1000. The most important method used to detect developmental hip dysplasia (DDH) is hip ultrasonography (US). The stage of obtaining the hip US image varies because it depends on the operator and external influences. This variability may lead to misclassification. In this thesis, an artificial intelligence based system has been developed to eliminate this variability and minimise errors. The developed system includes a 2-stage deep learning model.

In the first stage, U-NET architecture is used and in the second stage, region-based convolutional neural network architecture with mask is used. Firstly, it is checked whether the hip US image is taken correctly, that is, whether it can be analysed. It is checked whether the 3 basic anatomical structures (ischium, ilium, labrum) that need to be determined are detected. Then, the parallelism of the iliac bone to the baseline is checked. If the ilium is parallel to the baseline and all anatomical structures are detected, the US image is classified as analysable. Alpha and beta angles are calculated on this US image classified as analysable and developmental hip dysplasia is classified. It is thought that the system developed in this thesis will increase the accuracy of the diagnosis to be made by eliminating inter-operator variability in the diagnosis of developmental hip dysplasia and thus will help the experts.

Keywords: Deep Learning, Developmental Dysplasia of the Hip, Convolutional Neural Networks, Masked Region Based Convolutional Neural Network, U-NET

ÖNSÖZ

Tez çalışmasının her aşamasında bilgi ve tecrübe paylaşımı yaparak bana yardımcı olan danışmanım Sayın Doç. Dr. Murat Ceylan'a ve manevi anlamda daima yanımda olan aileme teşekkürlerimi sunarım. Ayrıca, ultrason verilerinin analizi aşamasında desteğini esirgemeyen Selçuk Üniversitesi Tıp Fakültesi Ortopedi ve Travmatoloji ABD Öğretim Üyeleri Sayın Prof. Dr. Bahattin Kerem Aydın ve Dr.Öğr.Üyesi Sadettin Çiftçi'ye teşekkür ederim.

Muhammed Cihad ÖZDEMİR

KONYA-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
SİMGELER VE KISALTMALAR.....	viii
1. GİRİŞ.....	1
2 KAYNAK ARAŞTIRMASI.....	4
3. MATERYAL VE YÖNTEM	7
3.1. Gelişimsel Kalça Displazisinin Tespitinde Kullanılan Yöntemler	7
3.1.1. Ortoloni ve Barlow Testi.....	7
3.1.2.Radyolojik Değerlendirme	9
3.2. Kullanılan Veri.....	13
3.3. Önerilen Yaklaşım	14
3.4. Veri Arttırma	16
3.4.1. Geleneksel Veri Arttırma Yöntemleri.....	17
3.4.2.Tezde Kullanılan Ultrason Verilerinin Arttırılması	22
3.5. Kullanılan Derin Öğrenme Mimarileri.....	23
3.5.1. Evrişimsel Sinir Ağları.....	24
3.5.2. Aktivasyon Fonksiyonları	30
3.5.3. Segmentasyon	32
3.5.4. U-NET.....	33
3.5.5. Maskeli Bölge Tabanlı Evrişimli Sinir Ağı	37
3.5.6. Kalça Ultrason Görüntülerinin Analiz Edilebilirliği İçin Ağın Eğitilmesi	42
3.5.7. Kalça Ultrason Görüntülerinin Sınıflandırılması İçin Ağın Eğitilmesi	44
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	45
4.1. Yapay Zekâ Değerlendirme Metrikleri	45
4.2. U-NET Mimarisi Sonuçları.....	47
4.3. Maskeli Bölge Tabanlı Evrişimli Sinir Ağı Eğitim Sonuçları	47
4.4. Kalça Ultrason Görüntülerinin Analiz Edilebilirliğinin Tespiti.....	48
4.5. Gelişimsel Kalça Displazisi Tespiti İçin Alfa ve Beta Açılarının Hesaplanması	50
4.6. Gelişimsel Kaçla Displazisinin Sınıflandırılması	52
5. SONUÇLAR VE ÖNERİLER.....	54
5.1. Sonuçlar	54
5.2. Öneriler	56
KAYNAKLAR.....	58
EKLER	62

SİMGELER VE KISALTMALAR

Simgeler

- c : Katmanın Bias Vektörü
exp : Üstel Fonksiyonu
G : Evrişim Katmanındaki Çıkış
sum : Toplama İşlemi
U : Katmanın Geri Bağlantı Ağırlık Matrisi
V : Katmanın Bağlantı Ağırlık Matrisi
W : Ağırlık Matrisi
⊕ : Öğrenilebilir Birleştirme Operatörü

Kısaltmalar

- AKD: Ayrık Kosinüs Dönüşümü
BÖA : Bölgesel Öneri Ağı
BT : Beyin Tomografisi
ÇKA : Çoklu Katman Algılayıcısı
ÇÜA : Çekişmeli Üretici Ağlar
DAR : Derin Ağ Restorasyonu
DDB : Doğrusal Doğrultma Birimi
DVM: Destek Vektör Makineleri
ESA : Evrimsel Sinir Ağı
GKD: Gelişimsel Kalça Displazisi
HBEA: Daha Hızlı Bölge Tabanlı Sinir Ağı
HBT : Her Bir Bölge Teklifi
İBH : İlgili Bölge Hizalaması
KÜB : Kesişim Üzerine Birliktelik
LBOS: Çerçeve Kaybı
LCSC: Sınıflandırma Kaybı
LNACK: Maskeleyme Kaybı
MBT-ESN: Maskeli bölge tabanlı evrimsel sinir ağı
MRG: Manyetik Rezonans Görüntüleme
ÖPA : Özellik Piramidi Ağı
US : Ultrasonografi
YSA : Yapay Sinir Ağı

1. GİRİŞ


Gelişimsel kalça displazisi (GKD), doğum öncesi, doğum sırası ya da doğum sonrası çeşitli nedenlere bağlı olarak gelişebilen bir hastalıktır. GKD, asetabulumun yetersiz gelişimi (displazi), tam olmayan çıkık ve tam çıkığı içeren tüm şekillerini kapsar (William ve ark.,1999, Yorgancıgil ve ark.,2016). GKD, bebek büyüdükçe çeşitli faktörlerden etkilenecek kendiliğinden kötüleşebilir veya düzelebilir (Bilgen ve ark.,2005, Guner ve ark.,2013). Tedavi başarısında en önemli faktör, özellikle yenidoğan döneminde erken tanı konması ve en kısa sürede tedaviye başlanmasıdır (Kose ve ark., 2010, Ayanoglu, 2014).

GKD'nin yeni doğan bebeklerde değerlendirilmesi, dünya genelinde olduğu gibi ülkemizde de önemlidir. Doğumdan sonraki ilk altı ay süresince femur başı ossifikasyonu gerçekleşene kadar olan dönemde tanı için en güvenilir radyolojik yöntem ultrasonografi (USG) kullanılır. Radyolojik yöntem ile kalça US görüntüsü elde edilişi Şekil 1.1'de gösterilmektedir.



Şekil 1.1. Kalça US görüntüsü Elde Edilmesi (Avcılar Hospital,2022).

Ultrasonografi, doğru bir şekilde uygulandığında tanıda altın standart olarak kabul edilir. GKD tedavisinin amacı, stabil, normal hareket genişliğine, ağrısız ve radyolojik açıdan normal aralıklara sahip bir kalça eklemi elde etmektir (Ramsey ve ark., 1976, Şeker ve ark., 2010). Şekil 1.2'de kalça ultrason görüntüsü gösterilmektedir.



Şekil 1.2. Yenidoğan Kalça Ultrason Görüntüsü

GKD'nin erken dönemde kolay uygulanabilir ve düşük maliyetli yöntemlerle tedavi edilebilmesi önemlidir. Ancak tanının gecikmesi durumunda başarı şansları düşerken, komplikasyon riskleri ve tedavi maliyetleri artar. Gecikmiş veya tedavi edilmemiş GKD vakalarında ilerleyen yaşlarda ciddi sakatlıklar ortaya çıkarak işgücü kaybına ve yüksek maliyetli ameliyatlara neden olabilmektedir. Bu durum hem bireyin yaşam kalitesinde hem de ekonomik yetkinliğinde önemli kayıplara yol açabilmektedir. Bu nedenle, GKD'nin erken tanısı ve tedavisi büyük bir önem taşır.

GKD, yenidoğan döneminde en sık görülen ortopedik hastalıklardan biridir. Araştırmalar, GKD displazi (yüksek riskli durum) sıklığının yaklaşık olarak her 100 doğumda bir, GKD dislokasyon (tam çıkık) sıklığının ise her 1000 doğumda bir olduğunu göstermektedir (Barlow ve ark.,1962). Ülkemizde yapılan araştırmalarda, dislokasyon oranlarının 5-15:1000 gibi yüksek olduğunu öngörmektedir (Köse ve ark., 2013). GKD kız çocuklarında erkek çocuklara göre yaklaşık 6 kat daha sık görülür ve sol kalçada daha sık ortaya çıkar. Yaklaşık %20 oranında iki taraflı etkileyebilir (Kutlu ve ark., 2013).

Coğrafi konumlara göre farklılık göstermekle birlikte Akdeniz kuşağında ve Amerika yerlilerinde daha sık görüldüğü bildirilmektedir. Ülkemizde yaygın görülmesinin en önemli nedeninin olarak yeni doğanlara uygulanan gelenekleşmiş

kundaklama kültürü olduğu düşünülmektedir. Ayrıca, araştırmacılar doğum sırasında bebeğin baş aşağı pozisyonunda tutulmasının sakıncalı olduğunu söylemektedirler.

GKD'nin ortaya çıkmasında aile öyküsünün olumlu olması, bağ dokusu gevşekliği, doğum öncesi makat duruşu, makatta doğum geçmişi, çoğul gebelik veya oligohidramniyoz (az idrarla gebelik) gibi durumların etkili olabileceği belirtilmektedir (Ertürk ve Büyükdoğan, 2019). Tortikollis gibi eşlik eden anomalilerin varlığı da GKD riskini artırabilir. GKD'nin oluşma sıklığını arttıran bu risk faktörlerinin dikkate alınması ve erken tanı ile tedavi sürecinin başlatılması, büyük önem arz etmektedir.

GKD'nin erken tanısı ve yönlendirmesi sağlık personeli için oldukça önemlidir. Hasta yakınlarının sağlık çalışanları tarafından bilgilendirilmeleri, erken tedavi başarısı ve uzun süreli tedavi sırasında karşılaşılabilecekleri sorunların azaltılması açısından önemlidir. Bu nedenle, sağlık personelinin bilgilerinin güncellenmesi ve standartlaştırılması gerekmektedir.

Tez çalışması, ülkemizde çocuk ortopedisi alanında önemli bir yere sahip olan GKD'nin tanısında hekimlere yardımcı olmayı, ilgili tespitlerin hızlı bir şekilde yapılabilmesini ve insana bağlı hataların azaltılmasını hedeflemektedir.

2 KAYNAK ARAŞTIRMASI

Derin öğrenme ve nesne tanıma yöntemleri son yıllarda hızla artmaktadır. Gerçek zamanlı nesne algılama için Bölge Önerisi ağları ile Daha hızlı bölge tabanlı sinir ağı (HBEA) modelinin kullanıldığı çalışma nesne algılama sürecindeki iki aşamayı birleştirmeyi hedeflemektedir. İlk aşama, bölge önerisi ağı kullanarak olası nesne bölgelerini tahmin etmek ve bu bölgeleri daha fazla işleme tabi tutmak için kullanılır. İkinci aşama ise, önerilen bölgeleri sınıflandırmak ve sınırlayıcı kutuların koordinatlarını tahmin etmek için bir sınıflandırma ve regresyon ağı içermektedir (Girshick. ve ark., 2015).

Shelhamer ve arkadaşlarının 2015 yılında gerçekleştirdikleri çalışmada geleneksel görüntü bölütlemesi yöntemlerindeki tam bağlantılı katmanları evrişim tabanlı katmanlarla değiştirerek görüntü segmentasyonu gerçekleştirilmiştir. Bu sayede, giriş görüntüsünün her pikselinin bir sınıf etiketiyle eşleştirilmesi ve böylece piksel düzeyinde ayrıntılı bir segmentasyon haritasının elde edilmesinin mümkün olduğu gözlemlenmiştir.

Özellik Piramidi Ağı (ÖPA), Tsung-Yi Lin ve arkadaşları (2017) tarafından önerilen birçok ölçekli nesne algılama algoritmasıdır. ÖPA, nesne algılama yöntemlerinde geleneksel olarak kullanılan tek ölçekli yaklaşımın yerine, farklı özellik katmanlarında bağımsız olarak tahmin yaparak daha iyi sonuçlar elde etmeyi amaçlar. ÖPA 'nın temel amacı, özellik piramidi oluşturarak nesneleri farklı ölçeklerde algılamaktır. Bu sayede hem küçük hem de büyük nesnelerin doğru şekilde algılanması mümkün olur. ÖPA, alt özellik katmanlarından gelen yüksek çözünürlüklü özellik haritalarını üst özellik katmanlarına taşıyarak daha geniş bir içerik sağlar. Böylece nesne algılama performansı önemli ölçüde iyileştirilir.

Nesne algılama ve görüntü segmentasyonu görevlerini aynı anda sunan Maskeli bölge tabanlı evrişimli sinir ağı (MBT-ESN) modeli Girshick ve arkadaşları tarafından 2015 yılında tanıtılmıştır. MBT-ESN modeli HBEA ve görüntü segmentasyon ağı ve Tam Evrişimli Ağ (TEA) 'ın birleşimi olarak tanımlanmaktadır

U-NET, Ronneberger ve ark. tarafından 2015 yılında biyomedikal görüntü segmentasyonu için önerilen bir konvolüsyonel ağıdır. Bu yöntem, yüksek ayrıntı düzeyinde piksel bazlı segmentasyon görevlerinde etkili bir şekilde kullanılmaktadır. U-NET'in temel önerisi, simetrik bir kodlayıcı-kod çözücü yapısı kullanarak görüntü segmentasyonunu gerçekleştirmektir. Kodlayıcı kısmı, görüntünün özelliklerini çıkaran

evrişim tabanlı katmanlardan oluşurken, kod çözücü kısmı, segmentasyon sonuçlarını oluşturan ters evrişim ve evrişim katmanlarından oluşur. Bu mimari, ayrıntılı lokalizasyonu sağlamak için atlama bağlantıları kullanır.

Tıbbi Görüntü Analizinde Derin Öğrenme Üzerine Bir Araştırma adlı çalışma derin öğrenme tekniklerinin tıbbi görüntü analizi alanında kullanımına yönelik kapsamlı bir derleme sunmaktadır. Bu derleme, derin öğrenme yöntemlerinin tıbbi görüntülerin analizindeki başarılarını ve potansiyel uygulamalarını değerlendirmektedir. Çalışmada, farklı derin öğrenme mimarileri, veri setleri, öğrenme stratejileri ve performans metrikleri üzerinde durulmaktadır. Ayrıca, derin öğrenmenin tıbbi görüntü analizindeki avantajları, zorlukları ve gelecek vaatlerine de yer verilmektedir (Litjens ve ark., 2017).

Tıbbi görüntü analizinde derin öğrenme üzerine gerçekleştirilen bir diğer çalışmada derin öğrenme yöntemlerinin tıbbi görüntü analizi alanında nasıl kullanıldığı, sağlık sorunlarının teşhisinde ve tedavisinde nasıl bir rol oynadığı üzerinde durulmaktadır. Çalışma, derin öğrenme algoritmalarının medikal görüntü analizindeki başarılarını ve farklı görüntü modaliteleriyle ilişkili uygulamalarını ele almaktadır. Ayrıca, derin öğrenme tekniklerinin tıbbi görüntü analizindeki avantajları ve sınırlamaları da değerlendirilmektedir. (Suganyadevi ve ark., 2022)

Lee ve ark. (2021) Gelişimsel Kalça Displazisi (GKD) Taraması için Yeni Bir Derin Öğrenme Modeline Dayalı Bölütleme ve Anahtar Nokta Çoklu Tespit Yönteminin Doğruluğunun inceledikleri çalışmada, geliştirilen derin öğrenme modelinin ultrasonografi görüntülerinde GKD tespitiindeki etkinliğini değerlendirmek için gerçek hasta verilerini kullanmışlardır. Yapılan deneysel sonuçlar, bu yöntemin GKD taraması için yüksek doğruluk sağladığını göstermektedir.

Standart ön-arka pelvik radyografilerde sharp açısının otomatik olarak saptanmasıyla kalçanın gelişimsel displazisinin yardımcı tanısı adlı çalışma ile alfa ve beta açıları Maskeli bölge tabanlı evrişimli sinir ağı (MBT-ESN) ile otomatik olarak hesaplanmıştır (Li. ve ark., 2017).

2021 yılında Moharil ve ark. yaptığı maskeli bölge tabanlı evrişimli sinir ağı kullanarak proksimal femoral kırığı tespiti adlı çalışmada, MBT-ESN modelinin etkinliğini değerlendirmek için gerçek hasta verilerini kullanmıştır. Sonuçlar, önerilen yöntemin proksimal femoral kırıkların tespitinde yüksek doğruluk sağladığını ve potansiyel bir klinik araç olarak kullanılabileceğini göstermektedir.

Kalça displazisi taraması için 3 boyutlu ultrason görüntülerindeki önemli anatomik yapıları otomatik olarak belirlemeyi amaçlayan bir diğer çalışmada, El Hariri ve ark. (2021) U-NET derin öğrenme modelini kullanmışlardır.

Hodgson ve ark, 2019 yılında yeni doğan bebeklerde ultrason görüntülerindeki kalça kemiklerinin segmentasyonunda manuel oluşturulan ve derin öğrenmeyle öğrenilen özelliklerin karşılaştırmalı olarak değerlendirilmesini amaçlayan çalışmada, yeni doğan bebeklerdeki kalça kemiklerinin doğru bir şekilde segmentasyonunu gerçekleştirmek için hem manuel oluşturulan özelliklerin hem de derin öğrenmeyle öğrenilen özelliklerin etkinliğini karşılaştırmaktadır.



3. MATERYAL VE YÖNTEM

GKD tespitinde yapılan kalça muayenesinin, her yeni doğana rutin olarak uygulanması büyük önem taşımaktadır. Bu muayene, ülkemiz dahil dünyadaki pek çok ülkede GKD tespiti rutin tarama programının bir parçası olarak kabul edilmiştir.

GKD'nin erken teşhisinde, fizik muayene ve radyolojik değerlendirme yöntemleri kullanılmaktadır. Fiziksel muayene yöntemleri uzun bir süre boyunca ilk aşama olarak kullanılmış olsa da yenidoğan muayeneleri kesin tanıya ulaşmak için yeterli olmamaktadır (Tachdjian ve ark., 1982). Fiziksel muayene, yenidoğan, süt çocuğu ve yürüme çağındaki çocuklarda farklı bulgular arayarak gerçekleştirilmektedir (Köse ve ark. 2010).

GKD tespiti için yapılan fiziki muayenede yenidoğan döneminde yapılacak olan Ortolani ve Barlow testleri büyük önem arz etmektedir. Bu testler, deneyimli bir sağlık personeli tarafından uygulanmalıdır. Pozitif bir bulgu elde edilmesi durumunda, yani kalçada displazi belirlendiğinde, daha ileri radyolojik değerlendirme için ultrasonografi yöntemi tercih edilir (Güner, 2017).

3.1. Gelişimsel Kalça Displazisinin Tespitinde Kullanılan Yöntemler

GKD tespitinde kullanılan 2 temel yöntem vardır. Bunlar fiziki muayene ve radyolojik değerlendirmedir (Ertürk ve Büyükdoğan, 2019). Fiziki muayenede, Ortolani ve Barlow testleri uygulanmaktadır. Radyolojik değerlendirme ise kalça US görüntüsü, pelvis ön-arka grafi, artrografi, manyetik rezonans görüntüleme gibi tekniklerle gerçekleştirilmektedir. Bu yöntemler arasında, GKD'nin tanısında en güvenilir ve en yaygın kullanılan radyolojik yöntem ultrasonografidir (Güner, 2017).

3.1.1. Ortolani ve Barlow Testi

Ortolani testi, disloke olmuş bir kalçanın redükte edilmesini, Barlow testi ise kalçanın kısmi çıkık veya tam çıkık olmasını değerlendirmek amacıyla kullanılan testlerdir. Her iki kalça ayrı ayrı, aynı anda değil, tek tek değerlendirilmelidir. Ortolani ve Barlow testlerinin duyarlılığı, uygulayan hekimin tecrübesine bağlı olarak değişebilir ve yüksek özgünlüğe sahiptir. Ancak, yumuşak doku kontraktürü nedeniyle 3. aydan sonra Ortolani ve Barlow testlerinin pozitiflik oranı azalır.

İlk olarak Ortoloni testi uygulanmaktadır. Bebeğin ayak ucuna geçilir. Bir el kasığa yerleştirilir ve başparmak ile diğer parmaklar arasında pubis ile iskiyon kolları kavranarak pelvis sabitlenir. Diğer elin baş parmağı trokenter minora diğer dört parmak ise trokanter majör üzerine yerleştirilir. Bebeğin kalçası 90 derece fleksiyondayken abdüksiyona alınır. Kalça abdüksiyona giderken eğer kalça çıkıksa asetabulumun arkasında bulunan femur başı adduktor kasların gerilmesiyle kalça eklemi içine yerleşir. Bu yerleşme sırasında femur başının asetabulum arka dudağı üzerinde atlamasıyla bir çıtırtı hissi alınır. Bu hissin alınması kalçanın çıkık olduğu ve bu manevra sayesinde geçici olarak yerine yerleştiği anlamına gelir. (Ortoloni Pozitif). Bu test sırasında kalçayı hareket ettiren ele ait ve trokanter majör üzerinde bulunan parmaklar yardımıyla itme yapılarak femur başının yerleşmesine yardımcı olunur (Centel, 2023). Şekil 3.1’de ortoloni testinin görseli yer almaktadır.



Şekil 3.1. Ortoloni Testi (Centel, 2023).

Barlow testinde, kalça 90 derece fleksiyonda ve nötral rotasyonda tutulur. Testi yapan el, bebeğin fleksiyondaki dizini el ayasıyla kavrar. Başparmak trokenter minör üzerine yerleştirilirken diğer parmaklar trokenter majör üzerinde konumlanır. El ayasıyla dizden kalçaya doğru bir itme uygulanır. Bu sırada, eğer kalça çıkık değilse ancak instabil ise femur başı, asetabulumun arka dudağından atlayarak çıkar. Bu hareket sırasında sürtünme hissi (çıtılama) hissedilir. Bu durumda Barlow testi pozitif kabul edilir.

Kalçadaki instabiliteyi belirlemek için, kalça 5 ila 10 derece adduksiyona alınır ve trokenter minör üzerindeki başparmak yardımıyla femur başı dışa doğru itilir.

Bazen her iki kalçada da çıkık olabilir. Kalça abdüksiyonları kısıtlı olmasına rağmen simetrik ve Galeazzi bulgusu görülmez. Bu durumu atlamamak için Klisic testi kullanılabilir. Klisic testinde, işaret parmağı spina ilyaka anterior süperiorda, orta parmak ise trokenter majör üzerinde konumlandırılır. Parmak uçlarından çekilen hayali hat normalde göbekten geçer. Eğer bu hat göbeğin altından geçiyorsa, bu kalça çıkığı lehine bir bulgudur (Centel, 2023). Şekil 3.2’de Barlow testi gösterilmektedir.




Şekil 3.2. Barlow Testi (Centel, 2023).

3.1.2. Radyolojik Değerlendirme

GKD'nin tanı, tedavi ve sonrası izlemlerinde çeşitli görüntüleme yöntemleri kullanılmaktadır. Bunlar arasında ultrasonografi, pelvis ön-arka grafi, artrografi, manyetik rezonans görüntüleme (MRG) ve bilgisayarlı tomografi (BT) dir (Kawaguchi ve ark. 2000).

Yenidoğanların kalça yapısı kıkırdak ağırlıklı olduğundan, radyografiyle değerlendirme zorluğu yaşanmaktadır. Bu nedenle, GKD'nin erken tanısı için genellikle ultrasonografi tercih edilmektedir. Ultrasonografi, kalça eklemi ve ilişkili yapıların ayrıntılı bir şekilde incelenmesine olanak sağlayan güvenilir ve invaziv olmayan bir yöntemdir. Özellikle yenidoğanlarda ve 6 aylık çocuklarda GKD'nin tarama ve tanı sürecinde ilk tercih edilen yöntem olarak kabul edilmektedir. Kalça ultrasonografisinin değerlendirilmesinde Graf, Terjesen, Harcke yöntemleri kullanılmaktadır. Bu yöntemlerden en fazla kullanılan ve güvenilir olanı Graf yöntemidir (Cuhacı ve ark., 2009).

Şekil 3.3'te kalça eklemi ve periferik elemanları gösterilmektedir.



Şekil 3.3. Kalça Eklemi ve Çevre Elemanları (Tuncay, .2004)

Kalça US görüntüleme yönteminin avantajları hızlı şekilde kesin tanıya olanak vermesi ve X-ışını içermemesidir. En büyük dezavantajı ise uygulayıcıya bağlı bir yöntem olması nedeniyle uygun şekilde yapılmadığında yanlış teşhise veya tedavide gecikmeye yol açabilmektedir. Yenidoğanlarda ilk 4-6 hafta kalça gelişiminde fizyolojik gecikme olabilmektedir. Aynı zamanda ilk 4 haftadaki kız çocuklarında anneden geçen hormonların eklem laksitesini arttırması nedeniyle yanlış pozitif sonuçlar alınabilmektedir. Bu durum, gereksiz tedavilere yol açabileceği için US görüntüsü taramasının bu haftalardan önce yapılması önerilmemektedir.

Ortopedistler GKD tedavisinin yasal yükümlüsü olarak kalça US görüntüsüne hâkim olmak zorundadır. Bu konunun önemi nedeniyle Türk Ortopedi ve Travmatoloji Birliği Derneği (TOTBİD) “Türk Pediatrik Kalça Ultrasonografi Kursu-Graf Yöntemi” başlığı altında eğitim kursları düzenleyerek ortopedistleri teşvik etmektedir. GKD hastalarının takibinde kalça ultrasonografisi her seferinde farklı kişiler tarafından yapılması ve radyologların hiçbir hastanın klinik takibini yapamaması nedeniyle tedavi sürecinin olumsuz etkilendiği de gözlemlenmektedir (Ertürk ve ark., 2019)

Gelişimsel kalça displazisi (GKD) tespitinde, öncelikle yapılan ultrason görüntüsünde ilium, labrum ve ishium noktalarının üçünün birden net olarak görünmesi önemlidir. Bu noktaların açıkça görülebilmesi morfolojik tanımlamaların yapılabilmesi için gereklidir. Ultrason görüntülerinin karşılaştırılabilmesi ve farklı kişiler tarafından aynı düzlemde ölçümler yapılabilmesi için standart bir kesit kabul edilmiştir. Bu

standart kesit, koronal düzlemde elde edilir. Koronal düzlemdeki standart kesitte bulunması gereken üç önemli kriter vardır. İliak kemik cilde paralel olmalıdır. Bu doğru pozisyonlama ve görüntünün kalitesi açısından önemlidir.

İkinci olarak Labrum görülmelidir. Labrum, kalça eklemi çevresindeki kıkırdaklı yapıdır. Standart kesitte, labrumun net bir şekilde görülmesi gerekmektedir. Bu durum labrumun durumunu ve olası anormallikleri değerlendirmek için önemlidir.

Son olarak asetabulum içinde iliumun osifiye ucu görülmelidir. Asetabulum, kalça eklemine ait yuvarlak kısımdır. Standart kesitte, asetabulum içindeki iliumun osifiye (kemikleşmiş) ucu açıkça görülmelidir. Bu, kalça ekleminin olası anormalliklerini tespit etmek ve değerlendirmek için önemlidir.


Bu kriterlerin sağlanması, GKD'nin doğru bir şekilde tespit edilmesini ve morfolojik analizlerin yapılabilmesini sağlar. Standart kesitlerin uygun bir şekilde elde edilmesi, doğru tanı koyma ve tedavi planlaması için önemlidir.

Ultrasonografik görüntüde bu üç noktanın görülemediği istisna olan durumlar da vardır. Bunlar Tip III ve Tip IV olarak tanımlanan disloke kalçalardır. Çekilen grafilerde labrumun saptanması mutlak gereklidir. Labrumun tanımlanması için kullanılan anatomik özellikler şu şekilde sıralanabilir. Labrum, eklem kapsülünün altındadır ve asetabulum çatısının hiyalin kıkırdak bölümünün inferolateralindedir. Başın eklem kapsülünden ayrıldığı noktadadır.

Tez çalışmasında kalça ultrasonografisinin de en çok kullanılan yöntem olan Graf yöntemi üzerinde durulmuştur (Tuncay ,2004).

Graf yönteminde US görüntüsünün açısal değerlendirilmesi yapılır. Elde edilen koronal kalça görüntüsünde üç adet çizgi çizilir. İlk çizgi ilium kemiğinin lateral kenarına paralel olacak şekilde çizilir ve temel çizgi adı verilir. İkinci çizgi ilium ossifiye ucundan asetabulum inferior kemik kenarından geçen teğet çizgidir. İki çizgi arasındaki açı alfa açısı olarak adlandırılır ve kemik çatı ölçümüdür. Üçüncü çizgi labrumun merkezinden asetabulumda konkavitenin konveksiteye döndüğü noktaya çizilendir ve temel çizgi ile yaptığı açıya beta açısı denir. Beta açısı kıkırdak asetabulum (labrum) ölçümüdür.

Şekil 3.4'te alfa ve beta açılarının hesabı için çizilmesi gereken çizgiler gösterilmektedir.



Şekil 3.4. Temel çizgi (1), kemik çatı çizgisi (2), kıkırdak çatı çizgisi (3), alfa açısı ve beta açısının şematik çizilmesi (Tuncay, 2004)

Saptanan bu açılar yardımı ile kalçalar ultrasonografik olarak tiplendirilir. Tip I olarak tanımlanan grupta alfa açısı 60 derece ve daha fazladır. Bu kalçalar tamamen normal olup matür kalça olarak tanımlanır. Herhangi bir ek ultrasonografik veya radyografik takibe ve incelemeye gerek yoktur. Bu tip kalçalar sağlıklı olarak sınıflandırılmaktadır.

Tip 1 a olarak adlandırılan kalçalarda beta açısı 55 dereceden azdır ve labrum ince, uzundur. Tip 1 b olarak adlandırılan kalçalarda beta açısı 55 dereceden daha büyüktür ve labrum kısa ve geniştir. Her iki labrum şekli de normal matür kalçaların varyantlarıdır.

Tip 2 a, 2 a (+) ve 2 a (-), adlandırılan gruplarda kalça eklemi yerindedir. Asetabular kemik çatı yetersiz gelişmiştir. Kemik kenar yuvarlaktır, asetabular çatının kıkırdak bölümü daha büyüktür fakat femur başı tam olarak örtünmüştür. Fizyolojik immatür kalça olarak adlandırılırlar. 6 haftalık bir bebeğin alfa açısının ölçümü 55 dereceden küçükse, bu kalçanın kendiliğinden 3 ayı tamamladığında 60 dereceye gelmesi mümkün değildir. Bu nedenle Tip 2 a (-) olarak tanımlanır ve tedavi edilmesi gereklidir.

Bebek 6 haftalık olup da alfa açısı 55 dereceden büyük ise yüksek ihtimalle bebek 3 aylık olduğunda 60 dereceye ulaşmaktadır. Bu nedenle bu kalçalar Tip 2 a (+) olarak tanımlanır. 3 ayı tamamlayan bu bebeklerde kalça ultrasonografisinin tekrarlanması ve alfa açısının 60 dereceye ulaştığının saptanması gereklidir. Bebeğin yaşı üç aylık ve daha büyük olup, alfa açısı 50-59 derece arası olanlar bu gruba girerler. Bu kalçalar ise tedavi edilmeden 60 dereceye ulaşamazlar ve displazik kalça olarak nitelendirilirler. Bu nedenle 60 dereceye en kısa sürede ulaşacak şekilde tedavi edilmelidirler. Tip 2 c kritik

bölgedir. Alfa açıları 43-49 arasında olup, beta açıları 77'den küçüktür. Bu gruba giren kalçalar eğer tedavi edilmezlerse mutlaka çıkık gelişecek kalçalardır (Centel , 2023).

Çizelge 3.1. Graf yöntemine göre kalça US görüntüsünün ait derecelendirmeler (Centel T.023).


TİP	KEMİK ÇATI	KEMİK KÖŞE	ALFA AÇISI	BETA AÇISI
TİP 1 A	İYİ	KÖŞELİ/KÜNT	≥ 60	< 55
TİP 1 B	İYİ	KÖŞELİ/KÜNT	≥ 60	> 55
TİP 2 A	YETERLİ	YUVARLAK	50-59	
TİP 2 B	EKSİK	YUVARLAK	50-59	
TİP 2 C	İLERİ DERECEDE EKSİK	YUVARLAK VE DÜZLEŞMİŞ ARASI	43-49	< 55
TİP D	İLERİ DERECEDE EKSİK	YUVARLAK VE DÜZLEŞMİŞ ARASI	43-49	> 55
TİP 3 A ve B	KÖTÜ	DÜZLEŞMİŞ	< 43	
TİP 4	KÖTÜ	DÜZLEŞMİŞ	< 43	

3.2. Kullanılan Veri

Tez çalışmasında kullanılan yenidoğan kalçasına ait ultrason görüntüleri Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden 30.12.2020 tarih ve 2020/586 sayılı Etik Kurul onayı ile temin edilmiştir (İlgili etik kurul onayı Ekler bölümünde verilmiştir).

Veri setinde farklı çözünürlüklerden oluşan 540 adet görüntü yer almaktadır. Bu görüntülerde analiz edilemez ve analiz edilebilir ultrason görüntüleri bulunmaktadır.

Elde edilen US görüntüleri 700x600 ile 934x700 arasında değişen çözünürlük değerlerine sahiptir. Farklı çözünürlükler görüntülerin analizini etkilediğinden, tüm görüntüler 256x256 çözünürlüğe dönüştürülmüştür. Şekil 3.5'te etik onayı ile alınmış veri setinden bir örnek gösterilmektedir.




Şekil 3.5. Tezde kullanılan US görüntüsü

3.3. Önerilen Yaklaşım

Ultrason görüntülerinin analizi ve yorumlanması genellikle zorlu bir süreçtir. Bu süreçte, anatomik yapıların otomatik olarak tespit edilmesi ve insan müdahalesi olmadan gerekli açıların elde edilmesi için geniş bir görüntü verisine ihtiyaç duyulmaktadır. Bu zorluğu minimize etmek amacıyla gerçekleştirilen tez çalışmasında, daha az görüntü içeren veri setlerinde de başarılı sonuçlar veren U-NET algoritması kullanılmıştır. U-NET mimarisi, ultrason görüntülerinde tespit edilmesi gereken anatomik yapıları anlamsal segmentasyon yöntemiyle tanımlamaktadır. Ardından, tanımlanan anatomik yapılar Maske ile bölge tabanlı evrişimli sinir ağı algoritmasına girdi olarak verilerek sınırları ayrıştırılmakta ve analiz edilebilirlikleri kontrol edilmektedir. Gerçekleştirilen çalışmada, 2 aşamalı bir yapay zekâ sistemi başarıyla uygulanmaktadır.

Önerilen sistemin akış şeması Şekil 3.6'da gösterilmektedir.



Şekil 3.6. İki aşamalı kalça displazisi belirleme sistemi

Şekil 3.6'da gösterilen diyagramda, ilk adım farklı boyut ve çözünürlükteki US görüntülerini bakımından standart hale getirmektir. Bu standartlaştırma işlemi, görüntülerin çözünürlük ve boyut açısından aynı özelliklere sahip olmasını sağlar. Standartlaştırma sonrasında, tanımlanması gereken anatomik yapılar etiketlenir ve bir veri kümesi oluşturulur. Elde edilen veri kümesi, U-NET mimarisi kullanılarak eğitilir. Maske ile bölge tabanlı evrişimli sinir ağı mimarisi için veri kümesi, U-NET ağının çıktı görüntülerinin yeniden etiketlenmesiyle oluşturulur. MBT-ESA mimarisi ile veri kümesi eğitilir ve tespit edilmek istenen 3 temel anatomik yapının (iskium, iliak kemik, labrum) varlığı kontrol edilir. Eğer bu anatomik yapıların en az biri tespit edilememişse, program ekranında “US alın” uyarısı verilir. Eğer 3 temel anatomik yapı başarılı bir şekilde tespit edilmişse, bir sonraki adım olan iliak kemiğin temel çizgiye paralelliği kontrol edilir. Önce iliak kemiği paralel bir çizgi çizilir. Bu çizgi temel çizgisi olarak adlandırılır. Ardından, US görüntüsünün analiz edilebilir olduğundan emin olmak için temel çizgisi ile iliak kemik arasındaki paralellik kontrol edilir. Eğer bu paralellik

belirlenen eşik değerin altındaysa, ekranda "US alın" mesajı bir kez daha görüntülenir. Eğer belirlenen eşik değerinindeyse ekrana "Analiz Edilebilir US" yazısı yazdırılır.

Kalça US görüntüsü başarılı şekilde alındıktan sonra gelişimsel kalça displazisini sınıflandırmak için açı hesaplama aşamasına geçilir. Bu aşamada kıkırdak çizgi ve temel çizgi çizilerek alfa ve beta açıları hesaplanır. Açı değerlerine göre graf derecelendirmesi baz alınarak sınıflandırma yapılır ve açı değerleri ekranda gösterilir.

3.4. Veri Arttırma

Veri arttırma işlemi derin öğrenme modelleri için veri setinin çeşitliliğini önemli ölçüde arttırılmasını sağlayan bir yöntemdir.

Derin öğrenme modellerinin eğitim sonucunda genelleştirebilme özelliğinin yüksek olması gerekmektedir. Genelleştirebilirlik, eğitim verilerini doğru bir şekilde sınıflandırmanın ötesinde, yeni ve görülmemiş veri örneklerini de doğru bir şekilde sınıflandırabilme yeteneğini ifade eder. Başka bir deyişle, bir modelin genelleştirilebilirliği, eğitim veri setinde görmediği örnekleri doğru bir şekilde tahmin etme yeteneği anlamına gelmektedir.

Derin öğrenme modelinin genelleştirebilirliğinin artması için en önemli etken veri seti çeşitliliği ve örnek sayısının yüksek olmasıdır. Ancak bazı problemlerin çözümü için yeterli sayıda veri elde etmek mümkün olmamaktadır. Ayrıca veri setinde bulunan örneklerin farklı açıları veya renk ölçekleri gibi farklı olasılıklara sahip olması gerekmektedir. Eğer veri setindeki görseller birbirine benzer verilerden meydana gelmişse bu durum modelin aşırı uyumuna neden olmaktadır. Bir modelde aşırı uyum olması, test doğruluğu düşüken yüksek eğitim doğruluğuna ulaşması anlamına gelmektedir.

Derin öğrenme tabanlı veri arttırma yöntemleri çalışma mantığına göre 3'e ayrılır: özellik arttırmaya tabanlı veri arttırma, sinir ağı transferiyle veri arttırma ve Çekişmeli Üretici Ağlarla (ÇÜA) veri arttırmadır (Shorten ve Khoshgoftaar, 2019).


Çekişmeli Üretici Ağlarla veri arttırma bu yöntemlerin en yaygınıdır. ÇÜA, bir üretici ve bir ayırt edici olmak üzere iki bileşenden oluşur. Üreteç, rastgele gürültüden gerçekçi görüntüler üretmeye çalışırken, ayırt edici, gerçek görüntüler ile üreticinin ürettiği görüntüler arasında ayırım yapmaya çalışır (Goodfellow ve ark., 2014).

Veri artırma amacıyla ÇÜA kullanırken, üretcin eğitimi sırasında gerçek görüntüler kullanılırken, üretilen görüntüler ise ayırt edicinin eğitimi sırasında kullanılır. Bu süreçte, üretcin amacı, ayırt edicinin yanıltmasını sağlamak ve gerçek görüntülere benzeyen, ancak farklı örnekler üretmektir. Ayırt edicinin amacı ise gerçek görüntüleri doğru bir şekilde tanımak ve üretilen görüntüleri gerçekten ayırt etmektir.

Sinir ağı transferi ile veri arttırmada ise, genellikle bir model, büyük bir veri kümesi veya karmaşık bir görev için önceden eğitilmiş bir model olarak kullanılır. Ardından, hedef veri kümesine veya göreve özgü bir şekilde ayarlanır veya doğrudan kullanılır. Bu, modelin yeni veriye veya göreve daha iyi uyum sağlamasını sağlar (Yosinski ve ark., 2014).

Geleneksel veri artırma yöntemleri olarak, Dönüşüm, Kesme, Döndürme, Parlaklık ve Kontrast Ayarlama, Gürültü Ekleme, Renk Dönüşümleri örnek verilebilir.

Bu tez çalışmasında, 540 ultrason görüntüsünü içeren orijinal veri seti üzerinde geometrik dönüşümler, renk uzayı dönüşümleri gibi geleneksel veri artırma teknikleri uygulanmıştır. Şekil 3.7’de geleneksel ve derin öğrenme tabanlı veri arttırma yöntemleri gösterilmektedir.



Şekil 3.7. Veri arttırma yöntemleri

3.4.1. Geleneksel Veri Arttırma Yöntemleri

Geleneksel veri artırma, klasik yöntemlerle veri kümesinin çeşitliliğini ve hacmini arttırmaya yönelik teknikleri ifade eder. Geleneksel veri artırma teknikleri, veriye dönüşümler uygulayarak yeni eğitim örnekleri oluşturma veya mevcut veriyi

değiştirme esasına dayanır. Bu teknikler, eldeki sınırlı eğitim verisini daha çeşitli hale getirerek modelin daha genelleştirilebilir özellikleri öğrenmesini sağlar. Yaygın olarak kullanılan geleneksel veri artırma teknikleri; Dönüşüm, Kesme, Döndürme, Parlaklık ve Kontrast Ayarlama, Gürültü Ekleme, Renk Dönüşümleri olarak ifade edilebilir.

3.4.1.1. Karşıtlık (Kontrast) İyileştirme

Kontrast, bir görüntüdeki maksimum ve minimum piksel yoğunluğu arasındaki fark olarak açıklanabilir (Smith, 1997). Başka bir deyişle kontrast, bir görüntüdeki farklı pikseller veya bölgeler arasındaki parlaklık farkını ifade eden bir ölçüdür. Kontrast, görüntünün görsel netlik ve ayrıntı seviyesini belirler. Yüksek kontrastlı bir görüntüde, parlaklık değerleri farklı bölgeler arasında belirgin bir şekilde değişirken, düşük kontrastlı bir görüntüde bu fark daha az belirgindir veya neredeyse yoktur.


Görüntüdeki kontrast, piksellerin renk değerleri veya gri tonlamaları arasındaki farklılıklarla ilişkilidir. Yüksek kontrastlı bir görüntüde, parlak bölgeler daha açık renklere veya daha yüksek gri tonlarına sahipken, karanlık bölgeler daha koyu renklere veya daha düşük gri tonlarına sahiptir. Bu durum, görüntünün daha keskin ve belirgin görünmesini sağlar.

Kontrastın önemi, bir görüntünün ayrıntılarını vurgulayabilmesi ve nesnelerin veya özelliklerin daha iyi ayırt edilebilmesidir. Yüksek kontrastlı bir görüntüde, kenarlar ve konturlar daha belirgin hale gelir, nesneler daha iyi tanımlanabilir ve görsel anlamda daha fazla derinlik sağlanır. Bununla birlikte, düşük kontrastlı bir görüntüde, ayrıntılar daha az belirgin olabilir, nesneler ayrılamayabilir ve görsel detaylar kaybolabilir.

Kontrast iyileştirme de piksel yoğunluğu dağılımının dinamik aralığını ayarlayarak görüntü kontrastını geliştirme anlamına gelir. Kontrast iyileştirme, görüntünün daha belirgin hale gelmesini sağlayarak ayrıntıların daha iyi görülebilmesini ve görsel kalitenin artmasını amaçlar. Kontrast iyileştirme teknikleri, uygulandıkları veri alanına göre piksel-etki alanı ve dönüştürme-etki alanı kategorilerine ayrılabilir. Birincisi piksel yoğunluğu işlemine dayanırken, ikincisi ayırık kosinüs dönüşümü (AKD), dalgacık dönüşümü ve eğricik dönüşümü gibi dönüşümler kullanarak bir görüntüye dönüşüm alanında kontrast iyileştirme uygular. Genellikle piksel alanında uygulanan kontrast iyileştirme teknikleri daha düşük hesaplama maliyetinden dolayı

gerçek uygulamalarda daha yaygın olarak kullanılır. En yaygın kullanılan piksel alanına dayanan kontrast iyileştirme yöntemi ise histogram eşitlemedir (Gonzalez, ve ark., 2008).


Şekil 3.8’de, iki farklı kontrast örneği yer almaktadır. (a)’da kontrol grubuna ait orijinal görüntü, (b) 'de yüksek kontrastlı görüntü, (c)’de ise düşük kontrastlı görüntü gösterilmiştir. Burada tüm pikseller gri tonludur ve detaylar kaybedilmiştir.



Şekil 3.8. (a) Orijinal görüntü (b) Yüksek kontrastlı görüntü (c) Düşük kontrastlı Görüntü

3.4.1.2. Parlaklık Değişirme

Parlaklık, ışık kaynaklarından yayılan veya yansıyan ışığın göze ulaşma miktarını ifade eden bir ölçüdür. Genel olarak görüntünün açıklığını veya koyuluğunu ifade edilen parlaklık, görüntü matrisinde basit toplama veya çıkarma ile kolayca artırılabilir veya azaltılabilir. Şekil 3.9’da iki farklı parlaklık örneği yer almaktadır. (a)’da kontrol grubuna ait orijinal görüntü, (b) 'de yüksek parlaklığa sahip görüntü, (c)’de ise düşük parlaklığa sahip görüntü gösterilmiştir.



Şekil 3.9. (a) Kontrol grubuna ait orijinal görüntü (b) yüksek parlaklığa sahip görüntü ve (c) düşük parlaklığa sahip görüntüdür


3.4.1.3. Keskinlik (Netlik) Değiştirme

Netlik veya keskinlik, bir görüntünün ayrıntılarının belirginliğini veya tanımlanabilirliğini ifade eder. Keskinleştirme, bir görüntünün kenarlarında ve ayrıntılı bölgelerinde kontrastın artırılması yoluyla görüntünün netliğini iyileştirmeyi amaçlayan bir görüntü işleme tekniğidir. Keskinleştirmenin temel amacı, bir görüntüdeki ince ayrıntıları daha belirgin hale getirmektir.

Görüntülerdeki ayrıntılar, farklı parlaklık veya renk değerlerine sahip pikseller arasındaki geçişlerde ortaya çıkar. Netlik, bu geçişlerin belirginliği veya vurgusu ile ilişkilidir. Keskinleştirme işlemi, bu geçişleri daha belirgin hale getirerek ayrıntıları vurgular.

Keskinleştirme işlemi genellikle bir kenar tespiti algoritmasıyla gerçekleştirilir. Bu algoritmalar, görüntüdeki parlaklık veya renk değerlerindeki ani değişiklikleri tespit eder ve bu değişikliklerin olduğu bölgelerde kontrastı artırır. Böylece, kenarlar daha belirgin hale gelir ve ayrıntılar daha iyi tanımlanır.

Şekil 3.10'da orijinal görüntü ve keskinliğinin arttırıldığı şekli gösterilmektedir.



Şekil 3.10. (a) Orijinal görüntü (b) Keskinliğin arttırıldığı görüntü

Keskinlik iyileştirme literatürde 3 farklı yöntemle uygulanmaktadır. Bunlar; yüksek geçiren filtre, yüksek kuvvetlendirilmiş filtre, keskin olmayan çekirdektir (Obulesu ve Kishore, 2012).

Yüksek geçiren filtrede görüntüye yüksek geçiren bir filtre uygulanarak düşük frekanslı bileşenler azaltılır ve yüksek frekanslı bileşenler korunur. Bu sayede, görüntünün kenarları, ayrıntıları vurgulanır ve keskinlik artırılır.

Yüksek kuvvetlendirilmiş filtrede ise, görüntü önce bir alçak geçiren filtreden geçirilir ve ardından bu düzleştirilmiş görüntü bir kuvvetlendirme faktörüyle çarpılır. Elde edilen kuvvetlendirilmiş görüntü, orijinal görüntüden çıkarılarak kenarların ve ayrıntıların daha belirgin hale gelmesi sağlanır.

Keskin olmayan çekirdek yönteminde, görüntünün bir keskin olmayan veya düzleştirilmiş bir versiyonu oluşturulur. Bu düzleştirilmiş görüntü, orijinal görüntüden çıkarılarak kenarların ve ayrıntıların vurgulanması amaçlanır. Bu işlem, görüntünün keskinlik bilgisini artırır ve netlik algısını iyileştirir.


3.4.1.4 Döndürme ve Aynalama

Döndürme ve aynalama, görüntü verisini çeşitlendirmek ve veri arttırmak için kullanılan yaygın olarak kullanılır. Bu teknikler, geometrik dönüşümleri temel alır ve görüntülerin farklı açılardan veya yansıtılmış hallerinden yeni örnekler oluşturur.

Döndürme görüntüyü belirli bir açıda döndürmek anlamına gelir. Döndürme açısı genellikle derece cinsinden ifade edilir ve pozitif veya negatif değerler alabilir. Döndürme işlemi en çok, x ekseninde, y ekseninde veya $+45$ ile -45 ($+315$) derece olarak gerçekleştirilmektedir.

Aynalama, görüntüyü dikey veya yatay eksende yansıtmak anlamına gelir. Dikey aynalama, görüntüyü yatay eksende simetrik olarak yansıtırken, yatay aynalama görüntüyü dikey eksende simetrik olarak yansıtır. Bu işlem, görüntünün piksel değerleri yer değiştirilerek gerçekleştirilir. Aynalama, özellikle nesne tespiti veya görüntü sınıflandırma gibi görevlerde, nesnelerin farklı yönlere doğru hareket edebileceği senaryolarda kullanılarak veri çeşitliliğini artırır.

Şekil 3.11'de, bir görüntü döndürme örneği yer almaktadır. (a)'da orijinal görüntü, (b) 'de saat yönünde 45 derece döndürülmüş görüntü, (c)'de ise saat yönünün tersine 45 derece döndürülmüş görüntü gösterilmiştir.



Şekil 3.11. (a) Orijinal görüntü, (b) Saat yönünde 45 derece döndürülmüş görüntü ve (c) Saat yönünün tersinde 45 derece döndürülmüş görüntü

3.4.2. Tezde Kullanılan Ultrason Verilerinin Arttırılması


Tezde kullanılan 540 adet ultrason görüntüsüne aynalama, döndürme parlaklık ayarı ve kontrast ayarı ile veri arttırma işlemleri uygulanarak 840 adet veri elde edilmiştir.

İlk olarak farklı çözünürlüklerdeki ultrason verileri 256x256 piksel olacak şekilde standartlaştırılmıştır. Daha sonra 540 adet US görüntüsünden 200 adet görüntü seçilmiştir. Bu görüntülerin kontrastı ve parlaklık değerleri değiştirilerek farklı veri grupları elde edilmiştir.

US görüntüleri genellikle siyah ve beyaz renk uzayında olduğu için kontrast ve parlaklık düzeltmeleri, orijinal görüntülerden daha fazla tanımlayıcı bilginin çıkarılabileceği varsayılarak uygulanmıştır. Kontrast ayarı, görüntü yoğunluğu değerlerini yeniden eşleyerek daha fazla bilginin elde edilmesine yardımcı olmaktadır. İyi kontrastlı bir görüntü, siyah ve beyaz arasında keskin farklılıklara sahip olduğundan görüntü ile ilgili tanımlayıcı nitelikler sağlamaktadır. Piksel uzayında kontrast-parlaklık iyileştirme tekniği olan histogram eşitleme, kontrast ve parlaklık ayarı için gerçekleştirilmiştir. Aynı veri grubuna y eksenine göre aynalama işlemi de yapılmıştır.

Daha sonra 100 adet farklı US görüntüsü seçilip bu görüntülerin üzerinde kontrast ve parlaklık ayarlarına ek keskinlik ayarları eklenerek veriler farklılaştırılmıştır. Daha sonra elde edilen görüntüler 45 derece saat yönünde ve 45 derece saat yönünün tersinde döndürülmüştür.

Şekil 3.12’de uygulanan veri arttırma prosedürü yer almaktadır.



Şekil 3.12. Uygulanan veri arttırma prosedürü

Veri arttırma işlemleri sonucunda toplam 840 US görüntüsünden oluşan bir veri seti elde edilmiştir.

3.5. Kullanılan Derin Öğrenme Mimarileri

Makine öğrenmesi, deneyimden otomatik olarak öğrenme ve geliştirme yeteneği sağlayacak şekilde programlanmış algoritmaların bütünüdür. Bu algoritmalar, belirli bir sistemin girdileri ve çıktıları arasındaki matematiksel ilişkileri modeller. Makine öğrenmesi, veriye dayalı modeller oluşturarak bilgisayar sistemlerinin görevleri yerine getirmesini sağlamak için kullanılır. Bu modeller, veri analizi ve istatistiksel yöntemler kullanarak, belirli bir problemi çözmek veya öngörü yapmak için kullanılan matematiksel fonksiyonlardır.

Yaygın olarak kullanılan makine öğrenme algoritmalarına örnek olarak; Lineer Regresyon, Lojistik Regresyon, Karar Ağaçları, Destek Vektör Makineleri (SVM), K-En Yakın Komşu, Yapay Sinir Ağları (YSA) verilebilir.

Yapay sinir ağları, biyolojik sinir sistemlerinden ilham alarak oluşturulan matematiksel modellemelerdir ve makine öğrenimi alanında yaygın olarak kullanılırlar. Yapay sinir ağları, veriye dayalı problemleri çözmek, desenleri tanımak, sınıflandırma yapmak, tahminlerde bulunmak gibi birçok görevi yerine getirebilirler. Bu ağlar, birçok bağlantılı yapay sinir hücresinden (nöron) oluşur ve bu nöronlar, bilgi işleme ve iletişim için matematiksel işlemleri gerçekleştirirler.

Makine öğrenmesinin bir alt kümesi olan Derin Öğrenme ise, yapay sinir ağlarına dayanan ve büyük miktarda veriyi kullanarak karmaşık modellerin otomatik olarak öğrenilmesini sağlar. Bu yaklaşım, insan beyninin çalışma şeklini taklit ederek bilgisayar sistemlerinin öğrenme ve çıkarım yapma yeteneklerini artırmayı amaçlar. Derin öğrenme algoritmaları, birçok katmandan oluşan yapılara sahip derin sinir ağları kullanır. Bu ağlar, veri setlerindeki kompleks yapıları ve desenleri öğrenmek için büyük bir veri kümesi üzerinde eğitilir.

Derin öğrenme, özellik çıkarımı ve temsiliyet öğrenme gibi konuları ele alır. Önceki yöntemlere kıyasla, derin öğrenme daha yüksek düzeyde otomatik öğrenme sağlayarak, veriye daha karmaşık ve soyut özellikleri tanımlama yeteneği kazandırır. Bu yaklaşımın temelinde, sinir ağları arasında bağlantılar kurarak veriyi temsil eden yapay nöronlar yer alır. Bu nöronlar, girdi verisini işleyerek katmanlar arasında bilgi akışını sağlar ve son katmanda istenen çıktıyı üretir.

Derin öğrenme, birçok farklı alanda uygulanmaktadır. Görüntü tanıma, nesne algılama, metin sınıflandırma, doğal dil işleme gibi alanlarda derin öğrenme modelleri önemli gelişmeler sağlamıştır. Ayrıca, tıbbi teşhis, otonom araçlar, robotik ve finans gibi birçok alanda da kullanılmaktadır. Derin öğrenme, veriye dayalı problemleri çözmek ve karmaşık modelleri öğrenmek için güçlü bir araç olarak kabul edilmektedir (LeCun ve ark., 2015).

3.5.1. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (ESA), birden fazla evrişim katmanından oluşan ve bu katmanlarda lineer olmayan fonksiyonların bulunduğu yapılardır.

ESA genelde giriş katmanına evrişim uygulanmasına dayanan bir yapıya sahiptir. Bu yapı, geleneksel ileri beslemeli sinir ağına ek olarak kullanılır. Evrişimli sinir ağlarının temel amacı, veri üzerinde evrişim işlemi uygulayarak özellikleri algılamak ve bu özelliklerin kullanıldığı bir çıkış üretmektir.


Her evrişim katmanı, farklı filtreler veya çekirdekler kullanarak girdi üzerinde evrişim işlemi gerçekleştirir. Evrişim işlemi, filtrelerin giriş üzerinde hareket ettirilmesi ve her konumda bir nokta çarpım işlemi uygulanmasıdır. Bu işlem, girdi verileri üzerindeki farklı bölgelerdeki özellikleri algılamayı sağlar. Her evrişim katmanının

çıktısı, bir sonraki evrişim katmanına veya bir aktivasyon fonksiyonuna giriş olarak sunulur.

Çoklu evrişim katmanlarının kullanılmasıyla, ağ daha karmaşık ve soyut özellikleri öğrenebilir. Farklı filtrelerin kullanılması, ağın farklı özellikleri algılama yeteneğini artırır. Evrişim katmanlarından sonra genellikle bir aktivasyon fonksiyonu uygulanır, bu da çıktıların belirli bir aralığa sıkıştırılmasını ve ağın daha karmaşık özellikleri öğrenmesini sağlar.

Evrişimli sinir ağları ayrıca havuzlama katmanlarıyla da desteklenir. Havuzlama katmanları, evrişim katmanlarının çıktılarını özetlemek için kullanılır. Örneğin, maksimum havuzlama veya ortalama havuzlama gibi işlemlerle belli bir bölgedeki en büyük veya ortalama değerler alınarak boyut azaltma işlemi gerçekleştirilir. Bu, hesaplama maliyetini düşürür, ağın yer değiştirmesini ve ölçek değişikliklerine karşı daha dayanıklı olmasını sağlar (Rawat ve Wang, 2017).

Şekil 3.13'te, iki evrişimsel katman, iki maksimum havuzlama katmanı ve iki tam bağlı katmandan oluşan bir ESA örneği gösterilmiştir.



Şekil 3.13. İki evrişimsel katman, iki maksimum havuzlama katmanı ve iki tam bağlı katmandan oluşan bir ESA örneği

3.5.1.1. Evrişimsel Katman

Evrişimsel katmanlar, derin öğrenme modellerinde yaygın olarak kullanılan önemli bir bileşendir. Bu katmanlar, özellikle görüntü işleme ve desen tanıma gibi alanlarda etkin sonuçlar vermektedir.

Evrişimsel katmanlar, genellikle bir filtre (çekirdek) matrisi ve bir aktivasyon fonksiyonundan oluşur. Giriş verisine filtre matrisi, kayan bir pencere şeklinde uygulanır ve nokta çarpımı işlemiyle çıktı değeri elde edilir. Bu işlem, giriş verinin farklı bölgelerindeki özellikleri algılamayı sağlar.

Filtre matrisinin boyutu ve adım sayısı, evrişim işleminin özelliklerini belirler. Filtre boyutu, giriş verisi üzerinde uygulanacak pencerenin boyutudur. Örneğin, 3x3 boyutunda bir filtre matrisi, 3x3'lük bir pencere üzerinde uygulanır. Adım sayısı ise filtre matrisinin giriş veri üzerinde kayma miktarını belirler. Bu adımların büyüklüğü, çıktı boyutunu ve hesaplama maliyetini etkiler.

Evrişimsel katmanların ardından genellikle bir aktivasyon fonksiyonu uygulanır. Bu fonksiyon, çıktı değerlerini sıkıştırarak doğrusal olmama özelliği ekler ve modelin daha kompleks ilişkileri öğrenmesini sağlar. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında doğrusal doğrultma birimi (DDB), sigmoid ve tanh bulunur.

Evrişimsel katmanlar genellikle birbirini takip eden yapıda kullanılır. Bu sayede, model daha karmaşık ve soyut özellikleri öğrenebilir. Aynı zamanda, havuzlama katmanları da kullanılarak boyut azaltma ve özetleme işlemleri gerçekleştirilir. Havuzlama katmanları, evrişimsel katmanların çıktılarını küçültmek ve önemli özellikleri öne çıkarmak için kullanılır.

Evrişimsel katmanlar, veri üzerinde lokal özelliklerin algılanması ve modelin daha genel ve ince özellikleri öğrenmesi için etkili bir yöntemdir. Özellikle görüntü işleme problemlerinde yaygın olarak kullanılırlar. Örneğin, nesne tanıma, yüz tanıma, görüntü sınıflandırma gibi görsel verilerle çalışan uygulamalarda evrişimsel katmanlar önemli bir rol oynar.


Evrişimsel katmanlar, giriş verinin farklı özelliklerini algılamak için filtrelerin kullanılması sayesinde özellik çıkarımı yapar. İlk evrişimsel katmanda, basit düzeydeki özellikler (kenarlar, köşeler vb.) algılanırken, daha derin katmanlarda daha karmaşık ve soyut özellikler (yüzler, objeler vb.) tespit edilir. Bu, evrişimsel katmanların hiyerarşik bir şekilde çalıştığını ve verinin daha yüksek düzeyli temsillerini öğrendiğini gösterir.

Evrişimsel katmanlardan elde edilen özellik haritaları, genellikle daha sonraki tamamen bağlı katmanlara veya sınıflandırma katmanına giriş olarak kullanılır. Tamamen bağlı katmanlar, evrişimsel katmanlardan gelen özellikleri kullanarak veri üzerinde sınıflandırma veya tahminleme yapar.

Evrişimsel sinir ağları, verinin yerel bağlantılarından yararlanarak daha az parametreyle daha etkili öğrenme sağlayabilirler. Ayrıca, evrişim işlemi, veri boyutunu

azaltır ve özelliklerin özetlenmesini sağlar. Bu sayede, ağın hesaplama maliyeti düşer ve aşırı öğrenmeye karşı daha dirençli hale gelir. (Rawat, W. ve Wang, Z. 2017).

Şekil 3.14 'deki giriş görüntüsü matrisi siyah – beyaz bir görüntüyü göstermektedir.



Şekil 3.14. Evrişim katmanları ve görüntü matrisi üzerinde kayan bir pencere fonksiyonu


3.5.1.2. Havuzlama

Havuzlama katmanları, ağın öğrenme kapasitesini azaltmadan veri boyutunu azaltarak hesaplama maliyetini düşürürler. Bu sayede, ağın daha hızlı ve etkin bir şekilde çalışması sağlanır. Ayrıca, havuzlama katmanları aşırı öğrenmeye karşı da dirençli bir yapı oluşturur. Yerel bağlantıların korunması, evrişim katmanlarından gelen özelliklerin daha genel ve anlamlı bir şekilde özetlenmesini sağlar.

Havuzlama katmanlarının genellikle maksimum havuzlama veya ortalama havuzlama gibi yöntemlerle çalıştığı belirtilmelidir. Maksimum havuzlama, her bir bölgedeki en büyük değeri alarak özellikleri vurgular. Örneğin, 2x2 boyutundaki bir maksimum havuzlama işlemi uygulandığında, her 2x2'lük bölgedeki en büyük değer alınır ve çıktı matrisine yerleştirilir. Buna karşılık, ortalama havuzlama, her bir bölgedeki değerlerin ortalamasını alarak özellikleri özetler.

Havuzlama katmanları, genellikle evrişimsel sinir ağlarının ardından tamamen bağlı katmanlara giriş olarak kullanılır. Evrişimsel katmanlardan elde edilen özellik haritaları, havuzlama katmanlarından geçirilerek verinin boyutu ve karmaşıklığı azaltılır. Bu, sonraki tamamen bağlı katmanlarda daha etkili bir şekilde sınıflandırma veya tahminleme yapılmasını sağlar (Işık ve Artuner, 2016).

Şekil 3.15, bir görüntü matrisi üzerine 2x2 filtrelerle maksimum havuzlamanın uygulanmasını göstermektedir.



Şekil 3.15. Havuzlama katmanları ve bir matrise 2x2 filtrelerle maksimum havuzlamanın uygulanması

3.5.1.3. Tam Bağlı Katmanlar

Tam bağlı katmanlar, derin öğrenme modellerinde önemli bir rol oynar. Bu katmanlar, bir sinir ağındaki nöronların bir önceki katmandaki tüm nöronlarla bağlantıya sahip olduğu bir yapıya sahiptir. Tam bağlı katmanlar, giriş verilerini alır, bu verileri birbirleriyle bağlantılı ağırlıklarla çarparak çıktıları hesaplar ve sonuç olarak bir sınıflandırma, regresyon veya tahminleme yapar.

Tam bağlı katmanlar, önceki katmanlardan gelen özellikleri temsil eden vektörleri alır ve her bir nöronun çıktısını hesaplar. Bu hesaplama, giriş verisini ağırlıklarla çarparak gerçekleştirilir. Her bir nöron, çıktıyı hesaplamak için girdi verisine atanmış bir ağırlık vektörüne sahiptir. Bu ağırlıklar, ağırlık öğrenme sürecinde eğitilir ve giriş verilerinin özelliklerini temsil eden öğrenilmiş değerlerdir.

Hesaplama sürecinde, her bir nöronun çıktısı bir aktivasyon fonksiyonundan geçirilir. Bu fonksiyonlar genellikle DDB, sigmoid veya tanh gibi doğrusal olmayan fonksiyonlardır. Aktivasyon fonksiyonu, nöronun çıktısını sınırlar veya normalize eder ve ağırlık daha karmaşık ve genelleştirici desenleri öğrenmesine yardımcı olur.

Tam bağlı katmanlar, genellikle evrişimli sinir ağı veya tekrarlayan sinir ağı gibi diğer sinir ağı yapılarından sonra kullanılır. Evrişimli sinir ağı genellikle görsel verilerle çalışırken, tekrarlayan sinir ağı ise sinir ağı zaman serileri veya doğal dil işleme gibi sıralı verilerle çalışır. Tam bağlı katmanlar, bu yapıların çıktıları olarak daha yüksek seviyeli sınıflandırma veya tahminleme yapar.

Tam bağı katmanlar derin öğrenme modellerinde aşırı uyum riski taşır. Aşırı uyum, bir modelin eğitim verilerine çok fazla uyum sağlaması ve genelleme yapma yeteneğini kaybetmesi durumunu ifade eder. Tam bağı katmanlardaki çok sayıda öğrenilebilir parametre, modelin eğitim verilerine aşırı uyum sağlama eğilimini artırır.


Tam bağı katmanlar, yüksek boyutlu ve karmaşık veri uzaylarında çalışırken, veri setinin yapısı ve varyansı ile daha fazla etkileşime girerler. Bu durum, modelin eğitim verilerindeki gürültüye ve dalgalanmalara duyarlı hale gelmesine neden olabilir. Aşırı uyum, modelin eğitim verilerine aşırı hassas hale gelerek, yeni verilere genelleme yapma yeteneğini azaltabilir.

Aşırı uyumu engellemek için çeşitli yöntemler kullanılabilir. Bunlardan biri, modelin karmaşıklığını azaltmak için tam bağı katmanlardaki nöron sayısını ve katman sayısını kontrol etmektir. Daha az sayıda nöron veya katmanla daha sade bir model elde edilebilir. Ayrıca, düzenlileştirme teknikleri kullanılabilir, örneğin bırakma veya L1/L2 düzenlilestirmesi gibi yöntemlerle ağı aşırı uyum yapmasının önüne geçilebilir.

Aşırı uyumun kontrol edilmesi için veri setinin bölünmesi de önemlidir. Eğitim, doğrulama ve test veri setlerinin ayrılması ve modelin eğitim sürecinde doğrulama veri seti üzerinde değerlendirilmesi, modelin genelleme yapma yeteneğini daha iyi değerlendirmeye yardımcı olur.

Tam bağı katmanlar genellikle sınıflandırma problemlerinde Softmax fonksiyonunu varsayılan olarak kullanır. Softmax fonksiyonu, her bir çıktı sınıfının olasılığını temsil etmek için kullanılır. Bu fonksiyon, çıktı değerlerini $[0, 1]$ aralığına sıkıştırır ve toplam çıktıların toplamı 1 olacak şekilde normalize eder. Böylece, her bir sınıfın olasılığına karşılık gelen çıktı değerlerini elde ederiz. Ancak bazen tam bağı katmanlarda softmax fonksiyonu yerine Destek Vektör Makinesi (DVM) kullanılabilir. Destek vektör makinesi, sınıflandırma problemlerinde kullanılan bir öğrenme algoritmasıdır. DVM, verileri bir hiper düzlemlerle böler ve sınıflandırma yapmak için bu hiper düzlemi kullanır. Tam bağı katmanlardaki softmax fonksiyonu yerine DVM kullanılması, farklı bir sınıflandırma yaklaşımı sağlar ve farklı sonuçlar elde edilebilir. (Tang, 2013).

Bu tez çalışmasında, verilerin sınıflandırılması için softmax ve DDB fonksiyonları kullanılmıştır. Tam bağı katmanlarda, Şekil 3.16'da görüldüğü gibi, bir katmandaki her bir nöron başka bir katmandaki nörona bağlıdır.



Şekil 3.16. Tam bağlı katmanlar

3.5.2. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, yapay sinir ağlarında her bir sinir hücresinin çıktısını belirlemek için kullanılan matematiksel işlevlerdir. Bu fonksiyonlar, sinir hücresinin aktivasyon durumunu belirlemek için giriş değerleriyle birlikte kullanılır. Aktivasyon fonksiyonları, sinir ağındaki bağlantıları ve ağırlıkları temsil eden matris çarpımları ve toplamalarını doğrusal olmayan bir şekilde dönüştürerek ağı öğrenme yeteneğini artırır. (Nwankpa ve ark., 2018).

Sigmoid (lojistik fonksiyon), Tanh (Hiperbolik Tanjant fonksiyonu), Softmax ve Doğrusal Doğrultma Birimi (DDB) fonksiyonları literatürde en yaygın olarak kullanılan aktivasyon fonksiyonlarıdır.

Bu tez çalışmasında, DDB ve softmax aktivasyon fonksiyonları kullanılmıştır. DDB (Doğrultulmuş Doğrusal Ünite) fonksiyonu, giriş değeri pozitif ise giriş değerini korurken, giriş değeri negatif ise çıktı değeri olarak 0 değerini döndürür. DDB, hesaplamaları hızlandırma ve aşırı uyumu azaltma eğilimindedir.

DDB fonksiyonu Eşitlik 3.1.'de şu şekilde ifade edilmiştir;

$$f(x) = \max(0, x) = \begin{cases} x_i, & \text{if } x_i \geq 0 \\ 0, & \text{if } x_i < 0 \end{cases} \quad (3.1)$$

Eşitlik 3.1'de $f(x)$, doğrusal doğrultma birimi (DDB) fonksiyonunun çıktısı, giriş değeri x 'e dayanarak hesaplanır. Bir diğer ifade olan $\max(0, x)$ ifadesi, x ve 0 arasından maksimum değeri seçen bir fonksiyonu ifade eder.

DDB aktivasyon fonksiyonunun matematiksel ifadesidir. DDB, giriş değeri olan x 0'dan küçükse çıktıyı 0 yapar; x , 0'dan büyük veya eşitse çıktıyı x olarak bırakır. Bu şekilde, negatif giriş değerlerini sıfıra eşitlerken pozitif giriş değerlerini değiştirmeden aktarır. DDB, yapay sinir ağlarında sıkça kullanılan bir aktivasyon fonksiyonudur ve doğrusal olmayan özellikler ekleyerek ağın daha karmaşık örüntüleri öğrenmesine yardımcı olur.

Kaybolan gradyan problemi nedeniyle derin ağlarda Tanh ve Sigmoid'in kullanımı DDB kadar verimli değildir. Kaybolan gradyan problemi ile gradyan tabanlı öğrenme yöntemleri ve geri yayılım algoritması kullanılarak yapay sinir ağları eğitilirken karşılaşılır. Bazı durumlarda, gradyanların çok küçülüp sıfıra yaklaşması (kaybolması), ağırlıkların değerini değiştirmesini önler ve ağı eğitmeyi zorlaştırır (Hochreiter, 1998).

Kaybolan gradyan problemi, derin yapay sinir ağlarında karşılaşılan bir sorundur. Bu sorun, geri yayılım algoritmasıyla ağın eğitilmesi sırasında gradyan değerlerinin zamanla giderek küçülmesi veya sıfıra yaklaşması sonucunda ortaya çıkar. Bu durum, ağırlıkların güncellenmesini etkileyerek ağın eğitimini zorlaştırabilir.

Tanh ve sigmoid aktivasyon fonksiyonları, gradyanın 0'a yaklaşmasına neden olabilen doygunluk bölgesine sahiptir. Bu fonksiyonların türevleri, giriş değeri büyük veya küçük olduğunda yaklaşık olarak sıfır olur. Bu, gradyanların zamanla küçülmesine ve kaybolmasına yol açar. Bu nedenle, derin ağlarda Tanh ve sigmoid fonksiyonlarının kullanımı, gradyan tabanlı öğrenme yöntemleriyle eğitim sürecinde sorunlara yol açabilir.

DDB fonksiyonu ise negatif giriş değerleri için sıfır döndürerek kaybolan gradyan sorununu azaltır. DDB fonksiyonunun türevidirler, pozitif giriş değerleri için 1 döndürür ve bu sayede gradyan değerlerini daha iyi korur. Bu özelliği nedeniyle DDB, derin sinir ağlarında daha verimli bir şekilde kullanılabilir.

Matematiksel ifadesi Eşitlik 3.2'de verilmiştir.

$$DDB(x) = \max(0, x) \quad (3.2)$$

Verilerin sınıflandırılması için tez çalışmasında mimarilerin son katmanlarında softmax fonksiyonu kullanılmıştır. Softmax fonksiyonu 0 ile 1 arasında bir çıktı üretir.

Her deęer bir sınıfın olasılıęını temsil eder ve tüm olasılıkların toplamı 1'e eşittir. Softmax fonksiyonu Eşitlik 3.3'teki gibi ifade edilebilir;

$$\text{softmax}(x_i) = \exp(x_i) / \sum(\exp(x_j)) \quad (3.3)$$

Eşitlik 3.3'te x_i , softmax fonksiyonuna uygulanan giriş veri setindeki i. elemanını, x_j ise softmax fonksiyonuna uygulanan giriş veri setindeki j. elemanı temsil eder.

3.5.3. Segmentasyon

Segmentasyon, bir görüntü veya veri kümesinde benzer özelliklere sahip nesnelerin veya bölgelerin belirlenmesi işlemidir. Bu işlem, bir bütünü parçalara ayırarak her bir parçayı daha ayrıntılı bir şekilde analiz etmeyi sağlar. Segmentasyon, görüntü işleme ve bilgisayarlı görü gibi alanlarda yaygın olarak kullanılan bir tekniktir (Szeliski, R. 2010).

Segmentasyon yöntemleri genellikle piksel bazında veya bölge bazında gerçekleştirilir. Piksel bazında segmentasyona anlamsal segmentasyon, bölge bazında segmentasyon örnek segmentasyon örnek verilebilir. Bu tez çalışmasında anlamsal segmentasyon ve örnek segmentasyon kullanılmıştır.

Anlamsal segmentasyon, nesne örneklerini ayırt etmeden her pikseli sabit bir kategori kümesine sınıflandırmakla ilgilidir. Başka bir deyişle, anlamsal segmentasyon piksel düzeyinde benzer nesneleri tek bir sınıf olarak tanımlamak/sınıflandırmakla ilgilidir. Anlamsal segmentasyon, görüntüdeki nesneleri arka plandan ayırdığı için arka plan segmentasyonu olarak da bilinir. Şekil 3.18 (a) anlamsal bölütleme sonucunu göstermektedir.

Örnek segmentasyon, bir görüntüdeki tüm nesnelerin doğru bir şekilde algılanması ve aynı zamanda her bir örneğin doğru bir şekilde bölütlenmesi ile ilgilidir. Bu nedenle nesne tespiti, nesne lokalizasyonu ve nesne sınıflandırmasının bir kombinasyonudur. Başka bir deyişle, bu segmentasyon türü, benzer bir örnek olarak sınıflandırılan her nesne arasında net bir ayırım sağlayarak her nesnenin sınırlarını belirler. Şekil 3.18 (b) örnek segmentasyon sonucunu göstermektedir.



(a)


(b)

Şekil 18. (a) Anlamsal Segmentasyon (b) Örnek Segmentasyonu

3.5.4. U-NET

U-NET mimarisi bir evrişimli sinir ağı yaklaşımıdır. U-NET ilk olarak biyomedikal görüntüler üzerinde daha iyi bir bölütleme (segmentasyon) yapma önerisi ile 2015 yılında tartışılmıştır (Ronneberger, O. Ve ark., 2015).

Mimari U şeklinde olduğu için adı U-NET olarak isimlendirilmiştir. Ağ mimarisi Şekil 3.19'da gösterilmiştir.



Şekil 3.19. U-NET Mimarisi

U-NET mimarisi, nispeten küçük bir veri kümesiyle iyi sonuçlar elde etmek için tasarlanmıştır ve çevresel kontrast iyileştirme ve segmentasyon gibi görevler için etkili bir şekilde kullanılabilir.

U-NET'in temel yapısı, kodlayıcı (encoder) ve kod çözücü (decoder) olmak üzere iki kısımdan oluşur. Kodlayıcı kısmı U-NET modelinin giriş verisini daha düşük çözünürlükte bir özellik haritasına dönüştürmek için kullanılan bölümdür. Bu kısım, evrişim ve havuzlama işlemlerini içerir.

Kodlayıcı, giriş verisine evrişim katmanları uygulayarak özellik haritalarını çıkarır. Evrişim katmanları, filtreler kullanarak veriden lokal özelliklerin çıkarılmasını sağlar. Her evrişim katmanı, verinin daha yüksek düzeyli özelliklerini temsil eden daha geniş bir filtre boyutuna sahip olabilir. Bu şekilde, kodlayıcı, giriş verisindeki lokal özelliklerin hiyerarşik bir temsilini oluşturur.

Evrişim işleminden sonra, havuzlama katmanları kullanılarak özellik haritalarının boyutu küçültülür. Havuzlama işlemi, bir pencere üzerindeki maksimum veya ortalama değeri seçerek veya bu değerleri birleştirerek gerçekleştirilir. Havuzlama katmanları, verinin ölçek ve konum değişikliklerine karşı daha ince ayrıntıları kaybetmeden özeti almayı sağlar. Bu sayede, verinin daha küçük boyutlu bir temsiline geçilirken önemli özellikler korunmuş olur.

Kodlayıcı kısmında her bir evrişim katmanı ve havuzlama katmanı çoğaltılarak derinlik artırılabilir. Bu, kodlayıcının daha karmaşık ve daha yüksek seviyede özellikleri yakalayabilmesini sağlar. Derinlik arttıkça, kodlayıcının daha genel ve daha soyut özellikler elde etme yeteneği artar.

Kodlayıcı kısmı, giriş verisini daha düşük çözünürlükte bir özellik haritasına dönüştürdüğü için özet oluşturur. Bu özet, giriş verisinin önemli özelliklerini içerir ve daha sonra kod çözücü kısmında kullanılarak yüksek çözünürlüklü bir tahmin elde edilir.

Kodlayıcı kısmı, evrişim ve havuzlama işlemlerini kullanarak giriş verisinden düşük çözünürlüklü bir özellik haritası elde eder ve bu sayede modelin daha detaylı bir tahmin yapabilmesine olanak sağlar.

Kodlayıcı kısmın matematik ifadesi aşağıda verilmiştir.

$$f(\ell) = \text{DDB}(W(\ell) * f(\ell - 1) + b(\ell)) \quad (3.4)$$

$$f(0) = \text{input} \quad (3.5)$$

$$\ell = 1, 2, \dots, L \quad (3.6)$$

Burada $f(\ell)$ kodlayıcının ℓ 'inci çıktı özellik haritasını temsil eder. DDB aktivasyon fonksiyonunu temsil eder. $W(\ell)$, ℓ . katmanın bağlantı ağırlık matrisini, $b(\ell)$, ℓ . katmanın bias vektörünü ifade etmektedir.

Kod çözücü kısmı, U-NET modelinin girişin düşük çözünürlüklü özellik haritalarından yüksek çözünürlüklü bir tahmin oluşturmak için kullanılan bölümüdür. Bu bölüm, ters evrişim ve evrişim işlemlerini içerir.

Kod çözücü kısmı, aşamalı olarak çözünürlüğü artırırken, aynı zamanda özelliklerin yüksek düzeyli temsillerine erişmeyi sağlamak için skip bağlantıları kullanır. Skip bağlantıları, kodlayıcıdaki evrişim katmanlarının ilgili katmanlarına geçit yaparak daha düşük çözünürlüklü özellik haritalarını daha yüksek çözünürlüklü özellik haritalarıyla birleştirir. Bu, modelin hem düşük hem de yüksek düzeyli özelliklere erişebilmesini ve daha hassas segmentasyon sonuçları üretebilmesini sağlar.

Kod çözücü kısmının başlangıcında, en üst katmandan başlayarak ters evrişim işlemi uygulanır. Bu işlem, her adımda çözünürlüğü artırırken özellik haritalarının boyutunu da genişletir. Ters evrişim işlemi, genellikle piksel değerlerini tahmin etmek için kullanılan filtrelerin boyutunu artırarak gerçekleştirilir. Bu işlem, önceki evrişim katmanlarında yapılan özellik çıkarımını geri alır ve girişe benzer bir çıktı oluşturur.

Daha sonra, evrişim katmanları bu işlemin sonucuna uygulanır. Evrişim katmanları, girişten daha yüksek düzeyli özelliklerin çıkarılmasına yardımcı olur. Bu, segmentasyon sürecinde daha ayrıntılı ve hassas sonuçlar elde etmek için önemlidir.

Kod çözücü kısmın matematik ifadesi aşağıda verilmiştir.

$$g(\ell) = DDB(U(\ell) * g(\ell+1) \oplus V(\ell) * f(\ell) + c(\ell)) \quad (3.7)$$

$$g(L+1) = f(L) \quad (3.8)$$

$$\ell = L, L-1, \dots, \quad \ell \quad (3.9)$$

Burada $g(\ell)$ kod çözücünün ℓ 'inci çıktı özellik haritasını temsil eder. $h(l)$ skip bağlantısının ℓ 'inci çıktı özellik haritasını temsil eder. $V(\ell)$, katmanın bağlantı ağırlık matrisini, $U(\ell)$, katmanın geri bağlantı ağırlık matrisini temsil eder. $b(\ell)$ ve $c(\ell)$ evrişim katmanlarının biaslarını, $*$ evrişim işlemini, $\oplus$ ifadesi ise birleştirme operatörünü temsil eder. Bu operatör, özellik haritalarını birleştirmek için genellikle piksel düzeyinde toplama işleminde kullanılır.

Son olarak, kod çözücü kısmında bulunan skip bağlantıları, kodlayıcıdaki ilgili evrişim katmanlarından elde edilen özellik haritalarıyla birleştirilir. Bu birleştirme işlemi, düşük çözünürlüklü özelliklerin daha yüksek çözünürlüklü özelliklere eklenmesini sağlar. Bu sayede, model daha ayrıntılı segmentasyon sonuçları elde edebilir.

Bu bağlantılar sayesinde ağın gradyan akışı iyileştirilir. Geri yayılım sırasında, gradyanlar doğrudan skip bağlantıları üzerinden kodlayıcıya iletilir ve düşük seviyeli özelliklerin güncellenmesine katkıda bulunur. Bu, gradyanların daha iyi bir şekilde akmasını sağlayarak modelin daha hızlı ve daha istikrarlı bir şekilde öğrenmesine yardımcı olur.

Skip bağlantıları, U-NET modelinin özellikle segmentasyon gibi görevlerde başarılı olmasını sağlayan önemli bir özelliktir. Bu bağlantılar hem düşük hem de yüksek seviyeli özelliklerin birleştirilmesiyle daha ayrıntılı ve doğru sonuçlar elde etmeye yardımcı olur.

3.5.5. Maskeli Bölge Tabanlı Evrişimli Sinir Ağı

Maske ile bölge tabanlı evrişimli sinir ağı (MBT-ESA), daha hızlı bölge tabanlı sinir ağı (HBEA) modeli temelinde geliştirilen bir bölge-tabanlı evrişimsel sinir ağıdır. İşleyişini anlamak için HBEA modelini temel olarak ele almak gerekmektedir. HBEA modelinde, giriş resimlerinden özellik haritaları elde edilir. Bu özellik haritaları, resimdeki nesne özelliklerini temsil eden bilgileri içerir.

Maskeli bölge tabanlı evrişimli sinir ağı, HBEA'nın üzerine ek olarak nesne maskelerini tahmin etmek için bir maske çıktısı ekler. Bu şekilde, model aynı anda nesne tespiti ve nesne segmentasyonunu gerçekleştirebilir.

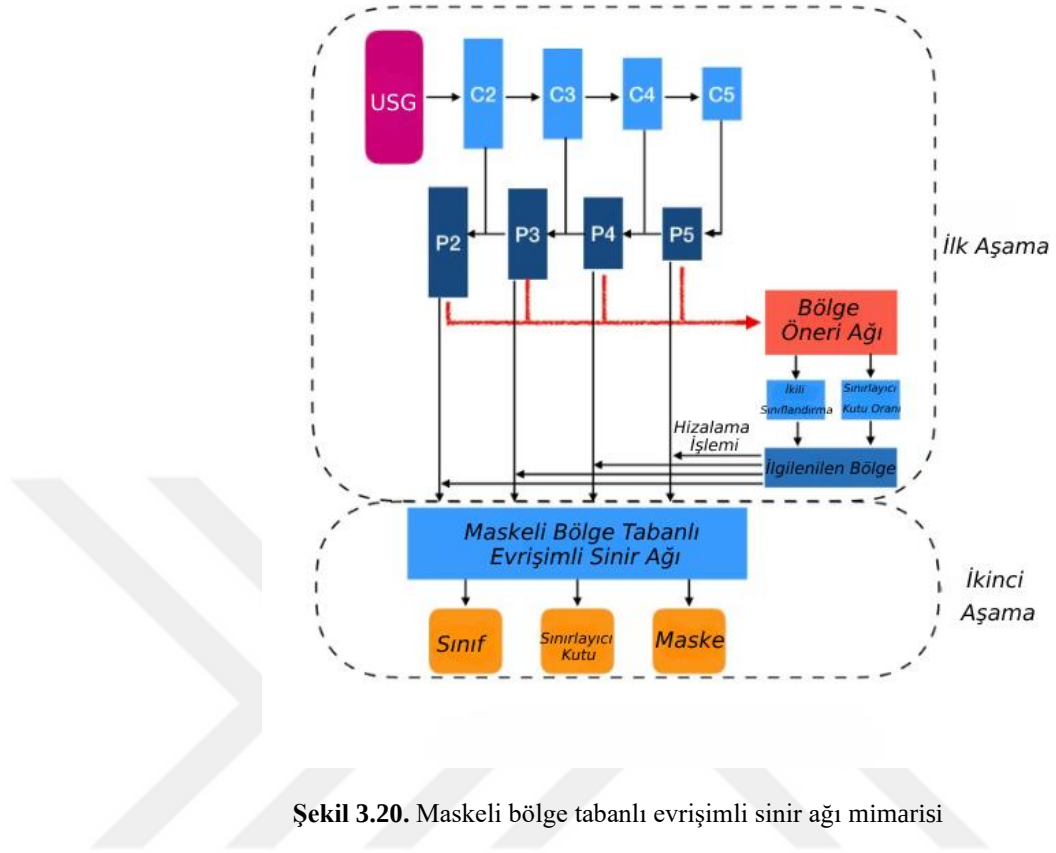
MBT-ESA mimarisinde, önceki adımlardan farklı olarak bölgesel öneri ağı (BÖA) kullanılır. BÖA, giriş resmi üzerindeki potansiyel nesne bölgelerini belirlemek için kullanılır. BÖA, özellik haritalarını analiz ederek bölge önerileri üretir. Bu bölge önerileri, olası nesne konumlarını içeren sınırlayıcı kutuları temsil eder.

Daha sonra, bölge önerileri havuzlama işlemine tabi tutulur. Havuzlama işlemi, bölge önerilerini daha küçük boyutlara indirger ve daha sonra nesne tespiti ve segmentasyonu için kullanılan tam bağlantılı çoklu katman algılayıcılara (ÇKA) giriş olarak sunulur. ÇKA aşamasında, sınıf tahmini ve sınırlayıcı kutu ofseti tahmini yapılmaktadır.

MBT-ESA mimarisinde özellik haritaları üzerinde piksel seviyesinde hizalama işlemi yapılır ve maske çıktıları üretilir. Maskeler, nesnelerin her pikseline ait segmentasyon bilgisini içerir. Bu segmentasyon bilgisi, nesnelerin kenarları ve iç bölgeleri gibi daha ayrıntılı özellikleri yakalamaya yardımcı olur.

MBT-ESA mimarisi, HBEA mimarisine kıyasla daha hızlı sonuçlar elde etmektedir (He. ve ark., 2017). Çünkü HBEA'da maskelerin tahmin edilmesi için ayrı bir aşama gerekmektedir, MBT-ESA'da maskeler doğrudan modelin bir parçası olarak tahmin edilir. Bu sayede nesne tespiti ve segmentasyonu aynı anda gerçekleştirilebilir.

Şekil 3.20’de Maskeli bölge tabanlı evrişimli sinir ağı mimarisi gösterilmektedir.



Şekil 3.20. Maskeli bölge tabanlı evrişimli sinir ağı mimarisi

MBT-ESA algoritmasında, örnek bölütleme (segmentasyon) özelliği kullanılarak nesnelerin yüzeyleri renklendirilerek maskeleme işlemi gerçekleştirilir. Bu işlem, aynı türden birden fazla nesnenin olduğu durumlarda bu nesnelerin farklı renklerle ayrılmasını sağlar.

MBT-ESA algoritmasındaki kayıplar(L), sınıflandırma kaybı (Lcsc), maskeleme kaybı (LNACK) ve çerçeve kaybı (Lbos) olmak üzere üç ana bileşenden oluşur. Bu kayıplar, algoritmanın eğitim aşamasında kullanılır ve modelin performansını optimize etmeye yöneliktir.

Eşitlik 3.10’a göre, algoritma kaybı (L) aşağıdaki şekilde ifade edilir:

$$L = L_{csc} + L_{NACK} + L_{bos}$$

(3.10)

Burada, Lcsc sınıflandırma kaybını, LNACK maskeleme kaybını ve Lbos çerçeve kaybını temsil eder.

Bu kayıplar, modelin tahminlerinin gerçek değerlerden ne kadar farklı olduğunu ölçer ve bu farkı azaltmaya çalışarak daha doğru tahminler elde etmeyi hedefler. Bu şekilde, MBT-ESA mimarisinde yüksek doğrulukla nesne tanıma ve bölütleme işlemlerini gerçekleştirebilir.

MBT-ESA mimarisi, omurga, bölgesel öneri ağı (BÖA), ilgili bölge hizalaması (İBH), sınıflandırma ve sınırlayıcı kutu ve maskeleme bölümlerinden oluşmaktadır.

3.5.5.1. Omurga

MBT-ESA mimarisinde, özellik çıkarımı için derin ağ restorasyonu (DAR) kullanılır. ÖPA (Özellik Piramid Ağı), aşağıdan yukarıya, yukarıdan aşağıya ve yanall bağlantı olmak üzere üç kanal içeren omurgaya eklenir. Bu üç kanal, özellik haritasının farklı düzeylerini temsil eder.

Aşağıdan yukarıya kanal, özellik haritasının boyutuna göre 5 aşamaya ayrılan DAR 'ı kullanır. Aşama 1'in konvolüsyon1'i kullanılmazken, aşama 2'nin son katmanından aşama 5'e kadar olan çıktılar sırasıyla C2, C3, C4, C5 olarak adlandırılır. Bu aşamaların çıktıları, orijinal görüntüye göre {4, 8, 16, 32} adımlara sahip özellik haritalarını temsil eder.

Yukarıdan aşağıya kanal, en üst katmandan başlayarak örnekleme yapar. Bu işlem, özellik haritalarının boyutunu küçültür ancak daha yüksek düzeydeki detayları korur.

Yanall bağlantı, aşağıdan yukarı kanaldan elde edilen yukarı örneklenmiş özellik haritalarıyla birleştirme yapmak için kullanılır. Yanall bağlantı, aşağıdan yukarı kanal tarafından oluşturulan aynı boyuttaki özellik haritalarının yukarı örnekleme sonuçlarıyla birleştirilir. Bu sayede, yüksek düzeydeki özelliklerin daha düşük düzeydeki özelliklerle birleştirilmesi sağlanır.

C2, C3, C4, C5'teki her katman, bir konvolüsyon 1×1 işlemine tabi tutulur ve çıkış kanalları 256'ye ayarlanır. Ardından, bu çıkış kanalları birleştirilerek yukarı örneklenmiş özellik haritasıyla birlikte çalıştırılır. Bu işlem, ÖPA'nın sonucu olan

özellik haritasını oluşturur, daha sonra bu özellik haritası MBT-ESA mimarisinin sınıflandırma, sınırlayıcı kutu ve maske tahmin ağlarına beslenir.

Bu şekilde, ÖPA ve yanal bağlantılar kullanılarak MBT-ESA, farklı ölçeklerdeki nesneleri doğru şekilde tespit etmek ve maskelemek için daha kapsamlı bir özellik temsili elde eder.

3.5.5.2.Bölge Öneri Ağı

Omurga ağından sonra, her özellik haritası BÖA'ya giriş olarak verilir. BÖA, iki ayrı yola ayrılmıştır.

İlk yol, her piksel konumunda bulunan bölge tekliflerini sınıflandırmak için çapaları kullanır. Bu yol, softmax aktivasyonu kullanarak pozitif ve negatif sınıflandırmalar elde etmek için çapaları işler. Bölgeler, potansiyel nesne bölgelerini temsil eder ve sınıflandırma sonucunda olumlu (içeren nesne) veya negatif (içermeyen nesne) olarak etiketlenir.

İkinci paralel yol, her aşamadaki bölge teklifleri için sınırlayıcı kutu regresyon referansını hesaplar. Bu regresyon işlemi, bölge tekliflerinin doğru sınırlayıcı kutularını tahmin etmeyi amaçlar. Bu sayede, bölge tekliflerinin daha iyi hizalanması ve nesne sınırlarının daha doğru tahmin edilmesi sağlanır.

Son teklif katmanı, pozitif çapaları ve karşılık gelen sınırlayıcı kutu regresyon ofsetlerini sentezleyerek teklifleri elde etmekten sorumludur. Bu katmanda, çok küçük veya sınır dışı teklifler filtrelenir ve sadece önemli ve potansiyel nesne bölgeleri seçilir.

BÖA'nın görevi, özellik haritaları üzerinde çalışarak ilgilenilen bölgeleri çıkarmaktır. Bu ilgilenilen bölgeler, daha sonra MBT-ESA mimarisinde sınıflandırma, sınırlayıcı kutu regresyonu ve maske tahmini için kullanılır. Omurga ağının özellik piramidinin (P2, P3, P4, P5) çıktılarından en uygun ölçeği seçerek, BÖA uygun bölge tekliflerini elde etmek için çalışır. Bu şekilde, önemli nesne bölgeleri MBT-ESA'nın sonraki adımlarında işlenecek şekilde belirlenir.

3.5.5.3.İlgili Bölge Hizalaması

Maskeli bölge tabanlı evrişimli sinir ağı, HBEA'da kullanılan ilgi bölge havuzu yerine ilgili bölge hizalaması (İBH) kullanarak daha hassas ve doğru bir özellik çıkarımı sağlar. İlgili bölge havuzu işleminde, bölge teklifleri genellikle tam sayı olmayan $\{x, y, w, h\}$ değerlerine sahiptir. Bu nedenle, İlgili bölge havuzu işleminde iki yuvarlama işlemi yapılır. İlk yuvarlama işlemi, bölge teklifinin tam sayı koordinatlara yuvarlanmasını sağlar. İkinci yuvarlama işlemi ise tam sayı sınır alanını $k \times k$ hücrelere böler ve her hücrenin sınırlarını tam sayıya yuvarlar.

Ancak, bu yuvarlama işlemleri sonucunda bölge teklifleri orijinal konumlarından sapmış olur. Bu durum, özellik haritasının hassasiyetini etkileyebilir. İBH, bu sorunu çözmek için yuvarlama işlemini iptal eder ve ondalık sayıları korur. İBH işlemi, her bir bölge teklifi için özellik haritasından özelliklerin örneklendiği noktaları hesaplar. Bu noktalar ondalık koordinatlara sahip olabilir. Daha sonra, çift doğrusal ara değer bulma yöntemi kullanılarak kayan nokta koordinatları hesaplanır. Bu yöntem, örnekleme işleminde hassaslık sağlamak için kullanılır.

İBH, daha hassas ve doğru bir özellik çıkarımı yapabilen bir yöntemdir. Orijinal ilgi bölge havuzlaması yönteminden farklı olarak, yuvarlama işlemlerini ortadan kaldırarak özelliklerin daha iyi hizalanmasını sağlar. Bu da MBT-ESA mimarisinin daha iyi bölgesel tahminler ve nesne maskeleme sonuçları elde etmesini sağlar.

3.5.5.4.Sınıflandırma ve Sınırlayıcı Kutu Regresyonu

MBT-ESA mimarisinde sınıflandırma ve sınırlayıcı kutu regresyonu için benzer yöntemler kullanılır. Her bir bölge teklifi (HBT), sınıflandırma için softmax aktivasyonunu kullanarak sınıflandırılır. Bu işlem, her HBT'nin hangi sınıfa ait olduğunu tahmin etmek için gerçekleştirilir.

Aynı zamanda, sınırlayıcı kutu regresyonu da yapılır. Her HBT için, sınırlayıcı kutu regresyon ofseti hesaplanır. Bu ofset, HBT'nin sınırlayıcı kutusunun orijinal görüntüdeki konumunu düzeltmek için kullanılır. Bu, BT'nin daha doğru bir şekilde hedef nesneyi çevrelemesini sağlar.

Çoklu olarak işaretlenmiş sınırlayıcı kutuları temizlemek için maksimum olmayan bastırma kullanılır. Maksimum olmayan bastırma, örtüşen veya yakın

sınırlayıcı kutuları birleştirerek yalnızca en güvenilir olanları korur. Bu sayede, aynı nesneye ait birden fazla sınırlayıcı kutunun elenmesi sağlanır ve sonuç olarak daha temiz ve daha doğru sınırlayıcı kutular elde edilir.

Bu adımlar, MBT-ESA mimarisinin her bir HBT için sınıflandırma ve sınırlayıcı kutu regresyonu yapmasını, ardından maksimum olmayan bastırma ile sonuçları temizlemesini sağlar. Bu sayede, nesnelerin sınıflandırılması ve sınırlayıcı kutularının doğru şekilde tahmin edilmesi sağlanır.

3.5.5.5.Maske

MBT-ESA mimarisi, HBEA mimarisine ek olarak segmentasyon maskesi oluşturur. Önceki adımlarda belirlenen bölge önerileri, bir havuzlama katmanı kullanılarak aynı boyuta dönüştürülür. Bu işlem, bölge önerilerinin farklı boyutlarda olabileceği durumlarda, her bir bölgeyi aynı şekle getirerek maskeleme işlemini kolaylaştırır.

Daha sonra, dönüştürülen bölgeler tamamen bağlı bir ağdan geçirilir. Bu ağ, bölge önerilerinin sınıf etiketlerini ve sınırlayıcı kutu ofsetlerini tahmin eder, yani nesnelerin hangi sınıfa ait olduğunu ve sınırlayıcı kutularının doğru konumunu belirler.

Bununla birlikte, MBT-ESA'nın özgün özelliği, segmentasyon maskelerinin oluşturulmasıdır. Bölge önerilerinden elde edilen dönüştürülmüş bölgeler, bir maskeleme ağına verilir. Maskeleme ağı, her bölge için maske oluşturmak üzere çalışır.


Maskeleme ağı, dönüştürülmüş bölgeyi piksel seviyesinde sınıflandırır ve her piksele ait bir olasılık değeri tahmin eder. Bu olasılıklar kullanılarak, her bölge için ayrı bir segmentasyon maskesi oluşturulur. Maske, bölge içindeki piksellerin nesneye ait olma olasılıklarına göre etiketlenir.

3.5.6. Kalça Ultrason Görüntülerinin Analiz Edilebilirliği İçin Ağın Eğitilmesi

Önerilen sistemin ilk aşamasında U-NET mimarisinin eğitimi bulunmaktadır. Bu aşamanın temel amacı US görüntüsünde belirlenmesi gereken noktaları (iskium, iliak kemik, labrum) tek bir nokta olarak segmente ederek verileri MBT-ESA mimarisine hazırlamaktır. Bu aşamada U-NET mimarisinin tercih edilmesinin sebebi mimarinin

semantik segmentasyona dayalı olmasıdır. Çünkü ilk etapta karmaşık bir ultrason görüntüsünün basitleştirilmesi ve sistemin sadece tespit edilmek istenen anatomik yapılara odaklanması hedeflenmektedir. Bu sayede MBT-ESA mimarisinin performansı artırılmıştır.

Veri artırma işlemi sonucunda oluşan 840 adet US görüntüsünde, tespit edilmek istenen anahtar yapılar Labelme programı kullanılarak belirlenmiş ve etiketleme işlemi gerçekleştirilmiştir. Şekil 3.21’de veri etiketleme işlemi gösterilmektedir.



Şekil 3.21. U-NET mimarisi için veri etiketleme

Veri etiketleme işlemi, görsel veriler üzerindeki nesneleri tanımlayarak veya sınıflandırarak, metin verilerindeki belirli öznitelikleri veya kategorileri belirleyerek veya diğer veri türlerindeki ilgili bilgileri atayarak gerçekleştirilir. Bir görüntü veri setinde, her görüntüde hangi nesnelerin bulunduğunu ve nesnelerin konumlarını belirlemek için bölge etiketlemesi yapılabilir.

U-NET ağında eğitmek için 840 US görüntüsünden oluşan veri seti hazır hale getirilmiştir. Eğitim, her 500 adımda bir kontrol edilmek üzere toplam 75000 adımdan oluşmaktadır. Öğrenme oranı 0.0001'e sabitlenmiştir ve yığın boyutu 16'dır. Eğitimin doğruluğunu değerlendirmek için kesişim üzerine birliktelik (KÜB) ve dice benzerlik katsayısı metrikleri kullanılmıştır.

3.5.7. Kalça Ultrason Görüntülerinin Sınıflandırılması İçin Ağın Eğitilmesi

U-NET mimarisi sonucunda üretilen çıktı görüntülerinde iskium, iliak kemik(ilium) ve labrum noktaları tek bir nokta olarak yorumlanmaktadır. Anatomik yapıları sınıflandırabilmek için U-NET mimarisi sonucunda oluşan görüntüler MBT-ESA mimarisine girdi olarak verilmiştir. U-NET mimarisi sonucunda semantik segmentasyonlar sınırları belirlenmiş anatomik yapıları bulunduran 840 adet görsel elde edilmiştir. Bu görsellerden 200 adet US görüntüsü seçilmiştir.

Bu görüntülerdeki anatomik yapıların sınırlarının belirlenmesi ve anlamlandırılması için Labelme programı kullanılarak etiketleme işlemi gerçekleştirilmiştir. Etiketleme işlemi Şekil 3.22’de gösterilmektedir.



Şekil 3.22. MBT-ESA mimarisi için veri etiketleme

Etiketleme işleminin ardından 200 adet US görüntüsünden oluşan yeni bir veri kümesi oluşturularak eğitime hazır hale getirilmiştir. MBT-ESA modeli örnek segmentasyonuna dayalı bir modeldir. Bu sayede, U-NET mimarisi tarafından tek bir bölge şeklinde oluşturulan anatomik yapıların sınırları birbirinden ayrılacaktır.

Eğitim, en iyi model seçimini doğrulamak için her 200 adımda bir doğrulama ile 16000 adımdan oluşur. Öğrenme oranı ve ağırlık azaltma 0,001 olarak ayarlanmıştır. Stokastik gradyan inişi, 10'luk bir parti boyutu ile kullanılmıştır. Eğitim, yazılımsal veri artırma yöntemi kullanılarak gerçekleştirilmiştir. Veri artırma işleminde aşağı kaydırma, rastgele ölçekleme, rastgele döndürme gibi özellikler kullanılmıştır.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Tez çalışmanızda, sağlıklı ve hasta kalça ultrason görüntülerini içeren bir veri seti kullanılmıştır. Bu veri seti, öncelikle U-NET mimarisiyle eğitilmiştir. U-NET mimarisi, görüntülerin semantik segmentasyonunu gerçekleştirerek belirli anatomik yapıları (iskium, iliak kemik, labrum) tek bir nokta olarak segmente etmektedir.

Daha sonra, U-NET mimarisiyle eğitilmiş ağın çıktılarından oluşan bir veri seti oluşturulmuştur. Oluşturulan yeni veri seti, MBT-ESA'ya girdi olarak kullanılmıştır. MBT-ESA mimarisi, sınıflandırma, sınırlayıcı kutu tahmini ve segmentasyon maskesi oluşturma işlemlerini gerçekleştirmektedir.

Sistem, iki aşamada eğitildikten sonra, kesişim üzerine birliktelik (KÜB) ve dice benzerlik katsayısı gibi metrikler ile değerlendirilmiştir.

Bu iki aşamalı eğitim sürecinde, sağlıklı ve hasta kalça ultrason görüntülerindeki anatomik yapıların tespiti ve segmentasyonunu gerçekleştirmeyi hedeflemektedir. U-NET mimarisi, görüntülerin basitleştirilmesi ve odaklanması gereken anatomik yapıların vurgulanması için kullanılmış, ardından MBT-ESA mimarisi daha detaylı bir nesne tespiti ve segmentasyonu sağlamıştır.

4.1. Yapay Zekâ Değerlendirme Metrikleri

Yapay zekâ değerlendirme metrikleri, yapay zekâ modellerinin performansını ve etkinliğini ölçmek için kullanılan çeşitli metriklerdir. Tez çalışmasında doğruluk, hassasiyet, f1 skoru, kesişim üzerine birliktelik (KÜB) ve dice benzerlik katsayısı gibi metrikler kullanılmıştır.


Doğruluk, Bir sınıflandırma modelinin doğru tahminlerin yüzdesini ölçer. Doğru tahminlerin toplam örneklere oranı olarak hesaplanır. Hassasiyet, Pozitif olarak tahmin edilen örneklerin içerisindeki gerçek pozitif örneklerin yüzdesini ifade eder. Gerçek pozitiflerin, pozitif olarak tahmin edilenlerle oranı olarak hesaplanır.

F1 skoru, hassasiyet ve duyarlılık metriklerinin harmonik ortalamasını temsil eder. Hassasiyet ve duyarlılık arasındaki dengeyi değerlendirir.

Kesişim üzerine birliktelik (KÜB) iki bölgenin (gerçek ve tahmin edilen) ne kadar örtüştüğünü ölçen bir değerlendirme metriğidir. Özellikle nesne tespit ve segmentasyon problemlerinde yaygın olarak kullanılır. İki bölge arasındaki örtüşme

alanının, birleşim alanına bölünmesiyle elde edilir. KÜB, genellikle 0 ila 1 arasında bir değer alır, 1'e ne kadar yakınsa, iki bölge o kadar iyi örtüşmektedir.


KÜB metriğine ait görsel Şekil 4.1'de gösterilmektedir.



Şekil 4.1. Kesişim Üzerine Birliktelik (Iwasa, ve ark.,2021)

Dice benzerlik katsayısı iki kümenin benzerliklerini ölçmek için kullanılan bir metriktir. Özellikle görüntü segmentasyonu ve medikal görüntü analizi gibi alanlarda yaygın olarak kullanılır. Gerçek ve tahmin edilen bölgelerin ortak alanının iki kümenin toplam alanına oranı olarak hesaplanır. Dice benzerlik katsayısı da 0 ila 1 arasında bir değer alır, 1'e ne kadar yakınsa, iki küme o kadar benzerdir.

Şekil 4.2'de Dice Benzerlik Katsayısı metriğine ait görsel gösterilmektedir.



Şekil 4.2. Dice Benzerlik Katsayısı Temsili Gösterimi (Al-Rahamneh, ve ark., 2021)

KÜB ve Dice benzerlik katsayısı, nesne tespiti ve segmentasyon gibi görevlerde modelin performansını değerlendirmek için kullanılan yaygın metriklerdir. Bu metrikler, gerçek ve tahmin edilen bölgelerin örtüşme derecesini ve benzerliğini niceliksel olarak ifade eder. Yüksek KÜB veya dice benzerlik katsayısı değerleri,

modelin daha doğru ve hassas tahminler yaptığını gösterirken, düşük değerler ise tahminlerin hedefe yakınsamadığını veya hatalı olduğunu gösterebilir.

4.2. U-NET Mimarisi Sonuçları


U-NET mimarisinde 840 adet kalça US görüntüsü kullanılmıştır. U-NET eğitimi tensorflow ortamında gerçekleştirilmiştir.

Eğitim sonucunda oluşan toplam hata 0.07, doğrulama hatası ise 0,12 olarak hesaplanmıştır.

Çizelge 4.1. U-NET ağ parametreleri ve sonuçları

Eğitim Mimarisi	Eğitim Süresi (dak.)	Eğitim Adımı	Doğruluk (%)	Ortalama KÜB	Veri Seti Boyutu
U-NET	185	75000	0.93	0.87	840

Eğitim sonucunda Şekil 4.3'te görülebileceği gibi ilium, iliak kemik ve labruma karşılık gelen alanlar üzerinde semantik segmentasyon gerçekleştirilmiştir.



Şekil 4.3. (a) US Görüntü (b) U-NET Mimarisinin sonucu

4.3. Maskeli Bölge Tabanlı Evrişimli Sinir Ağı Eğitim Sonuçları


U-NET mimarisi sonucunda oluşan çıktı görüntülerden elde edilen ve hazır hale getirilen 200 veri eğitimde kullanılmıştır. Eğitim tensorflow ortamında gerçekleştirilmiştir.

Eğitim sonucunda toplam hata 0.04, doğrulama hatası ise 0,10 olarak hesaplanmıştır.

Çizelge 4.2. MBT-ESA mimarisinin ağ parametreleri ve sonuçları

Eğitim Mimarisi	Eğitim Süresi (dak.)	Eğitim Adımı	Doğruluk (%)	Ortalama KÜB	Veri Seti Boyutu
MBT-ESA	840	16000	0.96	0.90	200

İkinci eğitim olan MBT-ESA mimarisinin temel amacı, U-NET ağı sonucunda oluşan görüntünün sınırlarını belirlemek ve tespit edilecek bölgeleri ayırt etmektir. MBT-ESA mimarisine girdi olarak verilen görüntü ve eğitim süreci sonucunda oluşan çıktı görüntüsü Şekil 4.4'te gösterilmiştir.



(a)
(b)

Şekil 4.4. (a) Giriş görüntüsü (b) MBT-ESA mimarisinden elde edilen çıkış görüntüsü



4.4. Kalça Ultrason Görüntülerinin Analiz Edilebilirliğinin Tespiti

Bir kalça US görüntüsünün analiz edilebilir olarak değerlendirilebilmesi için İlium (iliak kemik), labrum ve iskiüm (kalça kemiği) noktalarının üçünün birden net olarak görünmesi gerekmektedir. Bu yapılar her biri ayrı ayrı görüldükten sonra iliak kemiğin temel çizgiye paralellığı kontrol edilmektedir. Bu paralellik yazılımsal olarak belirlenen bir eşik değere göre belirlenmektedir. Eşik değerinin altında bir paralellik varsa kalça US görüntüsü analiz edilemez olarak değerlendirilecektir.

Tez çalışmasında önerilen yaklaşımın ilk aşaması olan U-NET mimarisi kalça US görüntülerini analiz ederek görüntünün analiz edilebilirliği kontrol etmektedir.

Sistem tespit edilmesi gereken anatomik yapıları ayrı ayrı kontrol ederek tespit edilip edilmediğini analiz etmektedir. Gerekli anatomik yapılardan biri dahi tespit edilmemişse veya iliak kemik temel çizgiye paralel değilse sistem kalça US görüntüsünü analiz edilemez olarak sınıflandıracaktır.

Kalça US görüntüsü analiz edilebilir olarak sınıflandırılmıyorsa ikinci aşama olan MBT-ESA aşamasına geçilmeden sistem, “tekrar US görüntüsü alın” uyarısı vermektedir. Bu sayede kullanıcı tekrar görüntüleme yaparak yanlış teşhis ihtimalini azaltacaktır. Şekil 4.5 de anatomik yapılardan iskiumun tespit edilmediği gözlemlenmektedir.



Şekil 4.5. Eksik anatomik yapıdan dolayı analiz edilemeyen US görüntüsü

Burada iliak kemiğin temel çizgiye paralelliği kontrol edilmeden önce anatomik yapıların tamamının tespit edilip edilmediği kontrol edilmektedir. İskium tespit edilmediği için iliak kemiğin temel çizgiye paralelliğinin kontrolüne gerek kalmadan kalça US görüntüsü analiz edilemez olarak sınıflandırılmıştır.

Tüm anatomik yapılar tek tek tespit edilmişse, iliak kemiğin temel çizgiye paralelliği kontrol edilmektedir. Eğer paralellik durumu tolerans değerleri arasında değilse analiz edilemez US olarak değerlendirilmektedir. Şekil 4.6’te iliak kemik temel çizgiye paralel olmadığı için analiz edilemez olarak sınıflandırılan kalça US görüntüsü gösterilmektedir.



Şekil 4.6. İliak kemik temel çizgiye paralel olmayan US görüntüsü

Tüm anatomik yapılar tespit edilmiş ve iliak kemik temel çizgiye paralel ise sistem kalça US görüntüsünü analiz edilebilir olarak sınıflandırılacaktır. Şekil 4.7’de analiz edilebilir US olarak sınıflandırılan kalça US görüntüsü gösterilmektedir.



Şekil 4.7. Analiz edilebilir olarak sınıflandırılan US görüntüsü

Sistem kalça US görüntüsünün analiz edilebilir olarak sınıflandırdıktan sonra ekranda analiz edilebilir US şeklinde uyarı verip ikinci aşama olan MBT-ESA aşamasına geçilerek gerekli alfa ve beta açıları tespit edilecektir.

4.5. Gelişimsel Kalça Displazisi Tespiti İçin Alfa ve Beta Açılarının Hesaplanması

Gelişimsel kalça displazisi sınıflandırması için alfa ve beta açılarının doğru şekilde hesaplanması çok büyük önem arz etmektedir. Hesaplama işleminde kullanılan

parametrelerin operatörlere bağlı olması hata olasılığını arttırmaktadır. Bu tez çalışmasında bu hesabın otomatik şekilde yapay zekâ tarafından yapılarak operatörler arasında farklılıkların ortadan kaldırılması hedeflenmektedir.

Kalça ultrason görüntüsünün analizinde alfa ve beta açıları, kalça morfolojisini değerlendirmek için kullanılan önemli ölçümlerdir. Alfa açısı, kalça eklemi üzerindeki kemik çatı ölçümünü ifade eder. Hesaplanması için, görüntü üzerindeki iliak kemik kısmının yan kenarına paralel bir temel çizgi çizilir. İkinci çizgi, iliumun osifiye (kemikleşmiş) ucundan asetabulumun (iskium) alt kenarından geçen teğet çizgi olarak çizilir. Alfa açısı, temel çizgi ile ikinci çizgi arasındaki açıdır. Alfa açısının normal aralığı genellikle 50 ila 60 derece arasında olmalıdır. Bu açı, kalça eklemi üzerindeki kemik çatısının doğru şekilde oluştuğunu gösterir.

Beta açısı ise, kalça eklemi üzerindeki kıkırdaklı asetabulumun (labrum) ölçümünü ifade eder. Hesaplanması için, labrumun merkezinden başlayarak asetabulumda konkavitenin konveksiteye döndüğü noktaya çizgi çizilir. Bu çizginin, temel çizgi ile yaptığı açı beta açısıdır. Beta açısının normal aralığı, genellikle 10 ila 40 derece arasındadır. Bu açı, kıkırdaklı asetabulumun doğru şekilde oluştuğunu gösterir.

Gerekli açıların hesaplanması için çizilecek doğrular büyük önem arz etmektedir. Bu doğrular için labrumun markezi, iskiumun konkavitenin konveksiteye döndüğü nokta ve iliumun osifiye ucu tespit edilmiştir.

Şekilde 4.8’de alfa ve beta açılarının hesabında kullanılan doğruların çizilişi gösterilmektedir. Yeşil renkte olan üçgen beta açısının hesabı için çizilmiştir. Kırmızı renkteki üçgen ise alfa açısının hesabı için çizilmiştir.



Şekil 4.8. Alfa ve Beta açılarının hesabı için çizilen üçgenler

Gerekli doğrular düzgün şekilde çizildikten sonra gerekli hesaplamaları yapılarak alfa ve beta açıları elde edilmiştir. Şekil 4.8 da alfa ve beta açılarının ölçüm sonuçları gösterilmiştir.



Şekil 4.9. Alfa ve Beta açılarının ölçüm sonuçları


4.6. Gelişimsel Kalça Displazisinin Sınıflandırılması

Gelişimsel kalça displazisinin sınıflandırılmasında öncelikli olarak kalça US görüntüsünün analiz edilebilir olması gerekmektedir. Bu ilk şart sağlandıktan sonra alfa ve beta açılarının doğru şekilde tespit edilmesi gerekmektedir. Alfa ve beta açılarının değerlendirilmesinde graf derecelendirme sistemi kullanılmıştır. Şekil 4.10 (a)'da analiz edilen kalça US görüntüsünde tüm anatomik yapılar tespit edilmiştir. İkinci kriter olan temel çizginin iliak kemiğe paralellik durumunun belirlenen tolerans aralığında olduğu gözlemlenmiştir. Bu iki şartın gerçekleşmesinden sonra alfa ve beta açıları hesaplanmıştır. Alfa açısı 47,12 derece, beta açısı da 12,2 derece ölçülmüştür. Kalça displazisinin sınıflandırılmasında graf derecelendirme sistemi kullanılmıştır. Bu derecelendirmeye göre sistem Şekil 4.10 (a) daki kalça US görüntüsünü TİP 2C, Şekil 4.10 (b) deki kalça US görüntüsünde TİP 2A olarak sınıflandırmıştır.

Tip 2C kalça tipi, kalça eklemi yüzeyinin normalden daha yassı olduğu anlamına gelir. Yassı kalça eklemi, kalça eklemine stabilitesini olumsuz yönde etkileyebilir ve çocukta kalça çıkığına yol açabilir. Tip 2C kalça tipi genellikle tedavi gerektiren bir durumdur ve tedavi genellikle kalçayı yerine oturtmak veya kalça eklemine daha fazla stabilite sağlamak için çeşitli yöntemleri içerebilir.

Tip 2A kalça tipi ise, kalça eklemi yüzeyinin normal olmadığı, yani normalden daha düz veya yuvarlak olabileceği anlamına gelir. Yüzeyin düz olması, kalça

ekleminin stabilitesini etkileyebilir ve çocukta kalça çıkığına yol açabilir. Ancak, bu tip genellikle tedavi gerektirmeyebilir veya konservatif tedavilerle düzelebilir.



Şekil 4.10. (a) TİP 2C olarak sınıflandırma sonuçları, (b) TİP 2A olarak sınıflandırma sonuçları

Şekil 4.11'de ise alfa ve beta açıları ölçümü sonucunda TİP 1A olarak sınıflandırılmış bir kalça US görüntüsü gösterilmektedir. GKD'nin TİP 1A olması, kalça eklemi açısından normal bir durumu ifade eder.



Şekil 4.11. TİP 1A olarak sınıflandırma sonuçları

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

US görüntüleme tekniği, gelişimsel kalça displazisinin tespiti için mükemmel sonuçlar sağlayan güvenli bir tanı aracıdır (Tom ve ark 2001) . Bununla birlikte, gözlemciler arası değişkenlik kalça US görüntülemesinin ölçümünde sorunlara neden olmaktadır. Gözlemcilerin gün boyunca çok sayıda tanı koymak zorunda kalması, hata yapma olasılığını artırır ve gözlemciler arası standardın kaybolmasına da yol açabilir.

Bu çalışmada, yeni doğan bebeklerin kalçalarının ultrason görüntülerinin yapay zekâ kullanılarak analizi için iki aşamalı bir yapay zekâ modeli önerilmektedir. Bu çalışmanın literatürdeki diğer çalışmalardan temel farkı, iki aşamalı bir yapay zekâ modelinin kullanılmasıdır. Literatürdeki çalışmalarda ya sadece U-NET algoritması ya da sadece Maske ile bölge tabanlı evrimsel sinir ağı gibi algoritmalar kullanılmıştır. Bunun da birtakım dezavantajları vardır. Örneğin, yapay zekâ algoritmalarını yeni doğan kalçasının ultrason görüntüleri üzerinde eğitmek zordur. Bunun nedeni, çok sayıda benzer yapı içermeleridir. Bu da bir yapay zekâ algoritmasının bu alanda yüksek derecede başarı elde etmesini zorlaştırmaktadır.

U-NET algoritması semantik örnek segmentasyonuna dayanmaktadır. Model segmentasyonu açısından Maske ile bölge tabanlı evrimsel sinir ağı gibi diğer iyi bilinen algoritmaların gerisinde kalmaktadır. Dolayısıyla U-NET algoritmasının tek başına kullanıldığı uygulamalarda nesnenin bir bütün olarak algılanmasında bir sorun yaşanmaz. Ancak bu nesnelerin ayrı ayrı tanınmasında bazı sorunlar yaşanabilir.

Maske ile bölge tabanlı evrimsel sinir ağı mimarisi örnek segmentasyonuna dayanmaktadır. Bu mimari, ultrason görüntüleri gibi karmaşık, benzer yapılar içeren görüntülerin eğitiminde bazı zorluklar yaşamaktadır. Bu nedenle eğitim sonrasında istenen doğruluğa ulaşmak zordur. Tespit edilecek anatomik yapıların sınırlarını kolaylıkla belirleyebilir ancak ultrason görüntüleri için ideal bir algoritma olmadığından ve görüntünün tamamını analiz ettiğinden sistemin benzer başka yapılar bularak yanlışla ihtimali vardır.

Çizelge 5.1: Kalça eklemine gelişimsel displazisinin analizine ilişkin literatür karşılaştırması

Yıl	Çalışma Adı	Yöntem	Veri Setindeki Görüntü Sayısı	Doğruluk
2019	Li, Q., Zhong, L., Huang	Maske-RCNN	11574	%76
2020	Park, HS, Jeon, K., Cho, YJ, Kim	CNN	5076	%90
2020	Si-Cheng Zhang, Jun Sun	RESNET-101	9081	%95
2021	Wook Lee ,Hee-Uk Ye,Kyung-Jae Lee	MBT-ESA	1243	%84
2021	Hareendranathan, A.R	MBT-ESA	214	%85
2021	Young Han Lee, MD	U-NET		%88
2022	B. Gong et al	TML-DERM	758	%85
2022	Abhilash Rakkunedeth Hareendranathan ,Myles Mabee ,Baljot S. Chahal	CNN	1548	%95
2023	Tez Çalışması	U-NET-MBT-ESA	840	%96

Bu çalışmada diğer çalışmalardan farklı olarak iki yapay zekâ algoritması, U-NET ve maske ile bölge tabanlı evrişimli sinir ağı birlikte kullanılmıştır. Bu sayede iki algoritmanın dezavantajları büyük ölçüde giderilmiştir.

İlk olarak U-NET mimarisi kullanılarak semantik segmentasyon gerçekleştirilmiş ve tespit edilecek anatomik yapılar tek bir bölge olarak segmente edilmiştir. Bu sayede nispeten karmaşık olan US görüntüsü basitleştirilerek MBT-ESA mimarisi için hazır hale getiriliyor. Bu noktada U-NET mimarisi az sayıda veri setiyle bile yüksek düzeyde başarı sağlıyor. Ayrıca kısa eğitim süresi ve hızlı çalışması gibi özellikleri de bu aşamada tercih edilme sebepleridir.

Daha sonra U-NET sonucunda semantik olarak segmente edilmiş görüntüler MBT-ESA mimarisine girdi olarak verilir. Bu aşamada MBT-ESA mimarisi sadece

tespit edilecek segmente edilmiş anatomik yapılara odaklanarak hızlı bir şekilde cevap vermekte ve yüksek doğrulukta örnek segmentasyonu gerçekleştirilmektedir. Bu sayede sistemin doğruluğunun önemli ölçüde arttığı gözlemlenmektedir.

2 aşamalı yapay zekâ sistemi toplam 840 kalça US görüntüsünü analiz etmiştir. Kalça US görüntüsünün analiz edilebilirliğini 0,96 doğrulukla; alfa ve beta açılarının hesaplanarak gelişimsel kalça displazisinin sınıflandırmasında da 0,85 doğrulukta belirlemiştir. Sistem gözlemciler arası değişkenliği ortadan kaldıracak şekilde tasarlanmıştır. Çalışmanın çeşitli kısıtlamaları vardır. İlk olarak, veri seti istenildiği kadar büyük değildir. İkincisi, doktorların analiz edilebileceğini düşündüğü birçok farklı US görüntüsünü yapay zekanın sonuçlarıyla karşılaştırmış ve bir standart belirlenmiştir. Bu standart, operatörler arasındaki değişkenliği ortadan kaldırmıştır. Sistemin doğruluğu, veri kümesinin dışından alınan US görüntüleriyle test edilmiş ve başarısı doğrulanmıştır.

Çizelge 5.1’de görüldüğü gibi 2 aşamalı yapay zekâ sistemi diğer çalışmalara göre daha düşük sayıda veri setinde daha iyi sonuç verdiği görülmektedir.

Gelişimsel kalça displazisinin erken teşhisi çok önemlidir. Tanı gecikirse, tedavi daha zor hale gelir. Önerilen sistem, gelişimsel kalça displazisinde gözlemciler arası değişkenliği azaltmayı amaçlamaktadır.

Tez çalışmasında gelişimsel kalça displazisinin tespiti için alınan kalça US görüntülerinin analiz edilebilirliğini belirlemek için iki aşamalı bir yapay zekâ modeli geliştirilmiştir. Sistemin performansı, gerçek zamanlı uygulamalar için de kullanılabileceğini göstermektedir.

5.2. Öneriler

Analiz edilmesi zor ve karmaşık görüntülerden oluşan kalça US veri seti önce U-NET mimarisi ile eğitilmiş daha sonra MBT-ESA mimarisi ile eğitilerek işlem tamamlanmıştır. Bu sayede yüksek doğruluk oranı sağlanmıştır. Sistem sadece U-NET mimarisi ile ya da sadece MBT-ESA mimarisi ile eğitildiğinde istenilen seviyede hassasiyet sağlanamamıştır. Tez çalışması ile bu tür karmaşık yapıların çözümünde iki farklı derin öğrenme mimarisinin birlikte kullanılmasının çözüm olabileceği gözlemlenmiştir. Ayrıca farklı diğer mimarilerde bu şekilde denenebilir ve doğruluk oranı arttırılabilir.

Bu çalışmada kullanılan kalça ultrason veri seti, analiz için yeterli olsa da daha fazla veri kullanılması sistem doğruluğunu artırabilir. Veri seti, farklı hastaların, farklı yaş gruplarının ve farklı etnik kökenlere sahip bireylerin görüntülerini içermelidir. Bunun için, daha geniş bir hasta grubunu kapsayan ve farklı merkezlerden elde edilen veri setleri kullanılabilir.

Önerilen sistemin klinik ortamlarda test edilmesi ve doğruluk oranının klinik çalışmalarla doğrulanması önemlidir. Bu sayede önerilen sistemin gerçek dünya koşullarında kullanılabilirliği ve güvenilirliği kanıtlanacaktır.



KAYNAKLAR

- Al-Rahamneh, Z., Khtoom, A., & Ryalat, M. (2021). Evaluation of Applying Surface Simplification Techniques in Medical Volume Data. *International Journal of Computer Applications*, 183, 7-11. doi:10.5120/ijca2021921423.
- Ayanoğlu, S. (2014). 6-18 Ay Arası Çocuklarda Gelişimsel Kalça Displazisi ve Tedavisi. *TOTBİD Dergisi*, 13, 403-411.
- Avcılar Hospital. (2022). Bebeklerde kalça ultrasonu. Erişim tarihi: [01 Temmuz 2023], <https://www.avcilarhospital.com.tr/saglik-rehberi/radyoloji/bebeklerde-kalca-ultrasonu/>
- Barlow, T. G. (1962). Early diagnosis and treatment of congenital dislocation of the hip. *J Bone Joint Surg Br*, 44(2), 292-301. <https://doi.org/10.1302/0301-620X.44B2.292>
- Breiman, L., Friedman, J., Olshen, R. ve Stone, C. (1984). *Classification and Regression Trees*. Chapman and Hall, Wadsworth, New York.
- Bilgen, S., Sarısözen, B. (2005). Gelişimsel Kalça Displazisi. *Güncel Pediatri*, 2, 18-21.
- Centel, T. (2023). "Doğumsal Kalça Çıkığı (DDH) Nedir?" [Online]. Erişim Tarihi: [Ziyaret Tarihi:24 Haziran 2023]. Web Adresi: <https://tuncaycentel.com/ddh/ddhTR7.htm>
- Çuhacı Çakır, B., Kibar, A., Çakır, H., Arhan, E., Cansu, A., & Yakut, H. (2009). 300 bebeğin gelişimsel kalça displazisi açısından ultrasonografi ile taranması. *Türkiye Çocuk Hastalıkları Dergisi*, 3(4), 5-9.
- El-Hariri, H., Hodgson, A. J., Mulpuri, K., & Garbi, R. (2021). Automatically Delineating Key Anatomy in 3-D Ultrasound Volumes for Hip Dysplasia Screening. *Ultrasound in Medicine & Biology*, 47(9), 2713-2722. DOI: 10.1016/j.ultrasmedbio.2021.05.011.
- Ertürk C, Büyükdoğan H (2019). Gelişimsel Kalça Displazisinde Etiyoloji ve Tanı (I). *İstanbul Kanuni Sultan Süleyman Tıp Dergisi*, 11(2), 61- 69. 10.5222/iksstd.2019.20982
- Ferguson, A.B. (1982). Treatment of congenital dislocation of the hip. In M.O. Tachdjian (Ed.), *Congenital Dislocation of the Hip* (pp. 283-293). New York, NY: Churchill Livingstone.
- Gonzalez, R.C., and Woods, R.E. (2008). *Digital Image Processing* (3rd ed.). Pearson Prentice Hall, Upper Saddle River.
- Guner, S. I., Guner, S., Peker, E., Ceylan, M. F., Guler, A., Turktas, U., et al. (2013). Are Consanguineous Marriage And Swaddling The Risk Factors of Developmental Dysplasia of The Hip? *J Membr Biol*, 246(2), 115-119.

- Güner, Ş. İ., Güner, S. (2017). Treatment Methods in The Patients With Developmental Dysplasia Of Hip. *Van Med J*, 24(3), 204-209.
- He, K., Gkioxari, G., Dollar, P., and Girshick, R. (2017). Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2961-2969.
- Hochreiter, S. (1998). The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02), 107-116.
- Işık, M. B., and Artuner, S. A. (2016). Pooling Layers in Convolutional Neural Networks: A Survey. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 7(1), 132-147.
- Iwasa, Y., Iwashita, T., Takeuchi, Y., Ichikawa, H., Mita, N., Uemura, S., Shimizu, M., Kuo, Y.-T., Wang, H.-P., & Hara, T. (2021). Automatic Segmentation of Pancreatic Tumors Using Deep Learning on a Video Image of Contrast-Enhanced Endoscopic Ultrasound. *Journal of Clinical Medicine*, 10(16), 3589. doi:10.3390/jcm10163589.
- Kawaguchi, A. T., Otsuka, N. Y., Delgado, E. D., Genant, H. K., & Lang, P. (2000). Magnetic resonance arthrography in children with developmental hip dysplasia. *Clinical Orthopaedics and Related Research*, (374), 235-246. doi:10.1097/00003086-200005000-00021. PMID: 10818983.
- Köse, N., Ömeroğlu, H., Dağlar, B. (2013). Gelişimsel Kalça Displazisi Ulusal Erken Tanı ve Tedavi Programı. TC. Sağlık Bakanlığı-TOTBİD Çocuk Ortopedisi Şubesi Ortak Çalışması.
- Köse, N., Ömeroğlu, H., Dağlar, B. (2010). Gelişimsel Kalça Displazisi Ulusal Erken Tanı ve Tedavi Programı, 2-19.
- Kutlu, A., Memik, R., Mutlu, M., Kutlu, R., Arslan, A. (1992). Congenital dislocation of the hip and its relation to swaddling used in Turkey. *J Pediatr Orthop*, 12, 598-602.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, 521, 436-444. <http://dx.doi.org/10.1038/nature14539>
- Lee, S. W., Ye, H. U., Lee, K. J., Jang, W. Y., Lee, J. H., Hwang, S. M., & Heo, Y. R. (2021). Accuracy of New Deep Learning Model-Based Segmentation and Key-Point Multi-Detection Method for Ultrasonographic Developmental Dysplasia of the Hip (DDH) Screening. *Diagnostics*, 11(7), 1174. doi:10.3390/diagnostics11071174

- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully Convolutional Networks for Semantic Segmentation. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, 3431-3440.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Li, Q., Zhong, L., Huang, H., Liu, H., Qin, Y., Wang, Y., ... Huang, Y. (2019). Auxiliary diagnosis of developmental dysplasia of the hip by automated detection of Sharp's angle on standardized anteroposterior pelvic radiographs. *Medicine*, 98(52), e18500. doi:10.1097/MD.00000000000018500
- Moharil, A., & Singh, S. (2021). Detection of Proximal Femoral Bone Fracture Using Mask R-CNN. In *International Conference on Intelligent Computing, Information and Control Systems* (pp. 239-253). Pune, India: Vishwakarma Institute Of Information Technology. doi:10.1007/978-981-15-8443-5_19
- Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
- Obulesu, M., and Kishore, V.V. (2012). A New Approach for Sharpness and Contrast Enhancement of an Image.
- Ramsey, P. L., Lasser, S., MacEwen, G. D. (1976). Congenital dislocation of the hip. Use of the Pavlik harness in the child during the first six months of life. *J Bone Joint Surg Am*, 58(7), 1000-1004
- Rawat, W., & Wang, Z. (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, 29(9), 2352-2449. doi:10.1162/neco_a_00990.
- Ren, S., He, K., Girshick, R., and Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-NET: Convolutional Networks for Biomedical Image Segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 234-241). Springer.
- Yorgancıgil, H., Aslan, A., Demirci, D., Atay, T. (2016). Gelişimsel Kalça Displazili Çocuklarda Tedavi Yaşının ve Cerrahi Yöntemin Klinik ve Radyolojik Sonuçlara Etkisi: Karşılaştırmalı Bir Çalışma. *Journal of Academic Research in Medicine*, 6, 177-182.

- Shorten, C., and Khoshgoftaar, T.M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6, 1-48.
- Suganyadevi, S., Seethalakshmi, V., & Balasamy, K. (2022). A review on deep learning in medical image analysis. *International journal of multimedia information retrieval*, 11(1), 19–38. <https://doi.org/10.1007/s13735-021-00218-1>
- Szeliski, R. (2010). *Computer vision: Algorithms and applications*. Springer Science & Business Media.
- Şeker, S., Tutanç, M., Okur, H. M. (2010). Gelişimsel Kalça Displazisinin Erken Tanısında Ultrasonografi Muayenesinin Önemi. *Tıp Araştırmaları Dergisi*, 8(1), 18-21.
- Tang, J. (2013). Support vector machines: models, theory, and applications. In *Machine Learning: Models, Technologies, and Applications* (pp. 439-459). Springer.
- Tuncay, I. C. (2004). Yenidoğan Kalça Ultrasonografisinin Değerlendirilmesi. *Baskent University Journal of Health*, 3(3-4), 99. Retrieved from [<https://dergi.totbid.org.tr/abstract.php?lang=en&id=77>]
- Tom, P.; Valle, M.; Rossi, U.; Brunenghi, GM Pediatric hip—ultrasound scan for developmental dysplasia of the hip: A review. *Euro. J. Ultrason*2001, 14, 45-55.
- Quader, N., Schaeffer, E. K., Hodgson, A. J., Abugharbieh, R., & Mulpuri, K. (2018). A Systematic Review and Meta-analysis on the Reproducibility of Ultrasound-based Metrics for Assessing Developmental Dysplasia of the Hip. *Journal of Pediatric Orthopaedics*, 38(6), e305-e311. DOI: 10.1097/BPO.0000000000001179.

EKLER

EK-1 Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden 30.12.2020 tarih ve 20201586 sayılı Etik Kurulu kararı

