



**FATİH SULTAN MEHMET VAKIF ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

**BEYİN KAN DAMARLARININ DERİN ÖĞRENME
SİNİR AĞLARI KULLANILARAK ANALİZİ**

YÜKSEK LİSANS TEZİ

**TUĞÇE GÖKSU
(190221001)**

**Danışman
(Dr. Öğr. Üyesi Berna Kiraz)**

**Eş Danışman
(Dr. Öğr. Üyesi Musa Aydın)**

İSTANBUL, 2022

25/03/2022

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Bilgisayar Mühendisliği Anabilim Dalı'nda 190221001 numaralı Tuğçe GÖKSU'nun hazırladığı "Beyin Kan Damarlarının Derin Sinir Ağları Kullanılarak Analizi" konulu Yüksek Lisans tezi ile ilgili Tez Savunma Sınavı, 25/03/2022 Cuma günü saat 10:00'da yapılmış, sorulara alınan cevaplar sonunda adayın tezinin **Kabulüne OyBirliği** ile karar verilmiştir.

Düzeltilme verilmesi halinde:

Adı geçen öğrencinin Tez Savunma Sınavı .../.../20... tarihinde, saat ...:... da yapılacaktır.

Tez adı değişikliği yapılması halinde: Tez adının "Beyin Kan Damarlarının Derin Öğrenme Sinir Ağları Kullanılarak Analizi" şeklinde değiştirilmesi uygundur.

Jüri Üyesi	Karar
1. (Danışman) Dr. Öğr. Üyesi Berna KIRAZ	KABUL
2. Prof. Dr. A. Yılmaz ÇAMURCU	KABUL
3. Doç. Dr. Buket DOĞAN	KABUL
4. (İkinci Danışman) *Dr. Öğr. Üyesi Musa AYDIN <i>*2. Danışman varsa doldurulması gerekmektedir.</i>	

ETİK BİLDİRİM

Bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bağlı olduğum üniversite veya bir başka üniversitedeki başka bir çalışma olarak sunulmadığını beyan ederim.

Tuğçe Göksu

TEŐEKKÜR

Tezin fikir aŐamasından tamamlanmasına kadar geŐen sÜreŐte, deđerli fikirleri ile teze katkılarından, sađladıkları sonsuz destekten dolayı Sayın Dr. Öğr. Üyesi Berna KİRAZ ve Sayın Dr. Öğr. Üyesi Musa AYDIN'a teŐekkürlerimi sunuyorum. Tez sırasında zorlandıđım anlarda bana motivasyon kaynađı oldular. Hem araştırma hem de kariyerim konusundaki tavsiyeleri, ayrıca toplantılarda gösterdikleri tutum ve sabır benim için paha biçilemez derecede deđerlidir.

Tez savunma jüri üyeleri Sayın Prof. Dr. Yılmaz ÇAMURCU ve Sayın DoŐ. Dr. Buket DOĐAN'a ilgileri, zamanları, katkı sađlayıcı yorum ve önerinlerinden dolayı teŐekkür ediyorum.

Veri setinin oluŐturulmasında katkı sađlayan Sayın Esra Özkan, Sayın DoŐ. Dr. Atay Vural'a deđerli zamanlarını ayırdıkları ve veri setleri üzerindeki yorumları ile yönlendirmeler yaparak teze sađladıkları katkılardan dolayı teŐekkür ediyorum.

Tez süresince deđerli fikirleri ile araŐtırmama yön vermeme sađlayan, tezi geliŐtirici yorum ve önerilerde bulunan Sayın Prof. Dr. Alper Kiraz'a sađladıđı yoğun destekten dolayı teŐekkür ediyorum.

Son olarak, desteđini, inancını ve sevgisini hiç esirgemeyen aileme benim adıma yaptıkları tüm fedakarlıklar için teŐekkür etmek istiyorum. Ayrıca gösterdiđi sabır, anlayıŐ ve sevgisi ile tezi bitirmeme vesile olan eŐim Ömer Faruk Göksu'ya da teŐekkür ediyorum.

TuđŐe Göksu

İmza

BEYİN KAN DAMARLARININ DERİN ÖĞRENME SİNİR AĞLARI KULLANILARAK ANALİZİ

Tuğçe Göksu

ÖZET

Çok katmanlı ileri beslemeli bir yapay sinir ağı modeli olan evrişimsel sinir ağı (ing: Convolutional Neural Network - CNN) özellikle görüntüler üzerinden özellik çıkarılması ve analizlerinin yapılması aşamasında sıklıkla kullanılmaktadır. Yapılan bu tez çalışmasında, iki boyutlu olarak elde edilen gerçek beyin damar ağı görüntüleri kullanılarak, derin öğrenme sinir ağı tabanlı otomatik damar ağı bölütlemesi gerçekleştirilen bir sistem ortaya konulmuştur. Görüntülerdeki damar ağı bölütlemesi için üç farklı derin öğrenme sinir ağı mimarisi kullanılmıştır. Kullanılan derin öğrenme sinir ağı mimarileri sırası ile Otomatik kodlayıcı (AutoEncoder), U-Net ve ResNet+U-Net ağlarıdır. Otomatik bölütleme adımında kullanılan derin öğrenme sinir ağı mimarilerinin eğitimi için oluşturulan veri setinde, eğitim için 1806 adet test için ise 34 adet görüntü kullanılarak eğitim ve test işlemi tamamlanmıştır. Üç ağ mimarisinden elde edilen eğitilmiş ağ modeli ile yapılan test işleminde en yüksek doğruluk başarımlarını %97,31 ile ResNet+U-Net ağı vermiştir. Bölütleme işleminden sonra, vasküler analiz aşamasından önce, bölütlenmiş görüntüler üzerinde ikilileştirme (ing: binarization) işlemi uygulanarak, bölütlenmiş görüntülerdeki sadece beyin damar ağının belirginleştirilmesi sağlanmıştır. Tez çalışmasının bir sonraki aşamasında ise bölütlenmiş beyin damar ağı görüntüleri kullanılarak vasküler analiz işlemi gerçekleştirilmiştir. Yapılan vasküler analiz ile beyin damar ağının, vasküler alan fraksiyonu, dallanma noktası sayısı (ing: branching point), dal sayısı (ing: branch number) ve vasküler uzunluk (damar uzunluğu) metrikleri hesaplanmıştır. Elde edilen sonuçlar, tıbbi alanda kullanılan angio-tool ve fiji uygulamaları ile karşılaştırılmıştır. Doğruluk, birleşimlerin kesişimi (ing: Intersection Over Union-IoU), zar katsayısı (ing: dice

coefficient), kesinlik (ing: precision) ve duyarlılık (ing: recall) deęerlendirme kriterleri ile deęerlendirmeler yapılmıřtır. Tez alıřması kapsamında yazılan uygulama, var olan analiz uygulamaları (Angiotool ve Fiji makrosu) ile aynı veri seti kullanılarak test edilerek sonuları karřılařtırılmıřtır. Analiz sonuları, tez alıřmasında yapılan uygulamanın medikal alanda kullanılan dięer uygulamalara kıyasla deęerlendirme metriklerine gre daha iyi sonular verdiđini gstermektedir.

Anahtar Kelimeler: Grnt bltleme, Derin đrenme sinir ađları, Beyin kan damarları bltleme, medikal grnt analizi

ANALYZES OF BRAIN BLOOD VESSELS USING DEEP LEARNING NEURAL NETWORKS

Tuğçe Göksu

ABSTRACT

Convolutional Neural Network (CNN), which is a multi-layered feed-forward artificial neural network model, is frequently used especially during feature extraction and analysis on images. In this thesis study, a deeplearning neural network-based automatic vascular network segmentation system was introduced by using real brain vascular network images obtained in two dimensions. Three different deep learning neural network maritimes are used for vascular network segmentation in the images. The deep learning neural network architectures used are AutoEncoder, U-Net and ResNet+U-Net networks, respectively. In the data set created for the training of the deep learning neural network architectures used in the automatic segmentation step, the training and testing process was completed by using 1806 images for training and 34 images for testing. In the test process with the trained network model obtained from the three network architectures, the ResNet+U-Net network gave the highest performance accuracy value with 97,31%. After the segmentation process, before the vascular analysis step, the binaryzation process was applied on the segmented images, and only the cerebral vascular network in the segmented images was clarified. In the next stage of the thesis, vascular analysis was performed using segmented brain vascular network images. With the vascular analysis, the vascular area fraction, branching point number, branch number and vascular length metrics of the cerebral vascular network were calculated. The results obtained were compared with the angiotoool and fiji applications used in the medical field. Evaluations were made with the evaluation criteria of accuracy, Intersection Over Union-IoU, dice coefficient precision and recall. The application written within the scope of the thesis study was tested using the same data set with the existing

analysis applications (Angiotool and Fiji macro) and the results were compared. Analysis results show that the application made in the thesis study gives better results compared to other applications used in the medical field, according to evaluation metrics.

Key words: Image segmentation, Brain blood vessel segmentation, Deep learning neural networks, Medical image analyzes

ÖNSÖZ

Klinik karar vermede hastalara daha düşük hatalı teşhisler koyma, daha kaliteli bir bakım sağlamak ve en iyi tedaviyi önermek için yardımcı yazılımlar, sistemler geliştirilmesi önemlidir. Bu çalışmamızda klinik karar vermede destek sağlamak için beyin vaskülatürünün iki boyutlu görüntülerinin çeşitli analizleri yapılmıştır. İleride yapılacak olan üç boyutlu analizler için ve damarlarda meydana gelen çeşitli hastalıkların teşhisi ve analizi için yapılan ön çalışmalardır. Yapılan analizler daha önceki yapılmış çalışmalar ile grafikler aracılığıyla karşılaştırılmıştır. Grafikler arasındaki benzerlik ve farklılıklar ortaya konulmuş, sebepleri incelenmiştir.

İÇİNDEKİLER

ÖZET.....	v
ABSTRACT	vii
ÖNSÖZ.....	ix
KISALTMALAR	xiv
GİRİŞ	1
BİRİNCİ BÖLÜM.....	3
1. TEMEL KAVRAMLAR VE LİTERATÜR ÇALIŞMASI	3
1.1. DERİN ÖĞRENME	3
1.2. EVRİŞİMSEL SİNİR AĞLARI.....	8
1.2.1. Girdi Katmanı	9
1.2.2. Evrişim Katmanı	9
1.2.3. Dış Boşluk ve Bir adım değeri.....	10
1.2.4. Ortaklama Katmanı.....	11
1.2.5. Düzleştirme	12
1.2.6. Tam Bağlantılı Katman	13
1.2.7. Optimizasyon Yöntemleri.....	13
1.2.7.1. Adam Algoritması.....	14
1.2.8. Aktivasyon Fonksiyonları.....	14
1.2.8.1. Sigmoid Aktivasyon Fonksiyonu	15
1.2.8.2. Doğrultulmuş Linear Ünite	16
1.3. ESA İLE YAPILAN DAMAR BÖLÜTLEME ÇALIŞMALARI	16
1.4. DEĞERLENDİRME METRİKLERİ.....	18
1.4.1. Doğruluk	18
1.4.2. Duyarlılık	19
1.4.3. Kesinlik	19
1.4.4. F1 Skoru.....	19
1.4.5. Zar Katsayısı	20

1.4.6.	İKili Çapraz Entropi.....	20
1.4.7.	Kesişimlerin Birleşimi.....	20
İKİNCİ BÖLÜM		21
2. DENEYSEL ÇALIŞMALAR.....		21
2.1.	MODELLER	22
2.1.1.	Otomatik Kodlayıcı (AutoEncoder)	22
2.1.2.	U-Net.....	23
2.1.3.	ResNet+U-Net	24
2.1.	VERİ SETİ	25
2.2.	İKİLİLEŞTİRME	27
2.3.	VASKÜLER ANALİZLER	30
2.3.1.	Vasküler Alan Fraksiyonu	30
2.3.2.	Vasküler Dallanma Sayısı.....	31
2.3.3.	Vasküler Uç Nokta Sayısı	32
2.3.4.	Vasküler Uzunluk	32
ÜÇÜNCÜ BÖLÜM		33
3. BULGULAR VE TARTIŞMA		33
3.1.	VESSEINN VERİ SETİ SONUÇLARI	33
3.2.	KUVESSG + VESSEINN VERİ SETİ SONUÇLARI	38
3.3.	KUVESSR VERİ SETİ SONUÇLARI	42
SONUÇ VE GELECEK ÇALIŞMA		43
KAYNAKÇA		45
EKLER.....		49

ŞEKLİLLER TABLOSU

Şekil 2.1 Perceptron Modeli	4
Şekil 2.2 Geri Yayılım Algoritması Akış Diyagramı	5
Şekil 2.3 Evrişimsel Sinir Ağı Mimarisi	9
Şekil 2.4 Evrişim işlemi örnek gösterimi	10
Şekil 2.5 Dış boşluk örneği	11
Şekil 2.6 Ortaklama Örneği	12
Şekil 2.7 Düzleştirme Örneği (Flatten)	13
Şekil 2.8 Sigmoid aktivasyon fonksiyonu karakteristik grafiği	15
Şekil 2.9 ReLU aktivasyon fonksiyonu karakteristik grafiği	16
Şekil 2.10 Karmaşıklık Matrisi	18
Şekil 3.1 Genel Akış Diyagramı	21
Şekil 3.2 Otomatik kodlayıcı sinir ağının ağ mimarisi	23
Şekil 3.3 U-Net evrişimsel sinir ağının ağ mimarisi	24
Şekil 3.4 ResNet ve U-Net evrişimsel sinir ağlarının birlikte kullanılarak oluşturulduğu ağ mimarisi	25
Şekil 3.5 VesselNet veri setine ait görüntüler	26
Şekil 3.6 KUVESG veri seti örnek görüntüler	26
Şekil 3.7 KUVESR veri seti örnek görüntüler	27
Şekil 3.8 Fare beyin vasküler test verilerinin (a) orjinal girdi görüntüsü, (b) Li yöntemi ile eşiklenmiş görüntü, (c) Isodata yöntemi ile eşiklenmiş görüntü, (d) gerçek referans görüntü, (e) Minimum yöntemi ile eşiklenmiş görüntü, (f) Otsu yöntemi ile eşiklenmiş görüntü, (g) Mean yöntemi ile eşiklenmiş görüntü, (h) triangle yöntemi ile eşiklenmiş görüntü, (j) Yen yöntemi ile eşiklenmiş görüntü.	29
Şekil 3.9 (a) ve (b) Vasküler alan fraksiyonu için örnek görüntüler.....	30
Şekil 3.10 (a) Örnek vasküler görüntü, (b) Örnek vasküler görüntünün test görüntüsü.....	31
Şekil 3.11 Vasküler dallanma noktaları	31
Şekil 3.12 Vasküler uç noktalar	32
Şekil 3.13 Vasküler uzunluklar	33
Şekil 4.1 Damar segmentasyonu için üç CNN ağı ile elde edilen doğruluk değerinin epoch' a bağlı olarak yakınsama grafikleri.	35
Şekil 4.2 Yapay sinir ağlarının test hatalarının değişim grafiği.....	36
Şekil 4.3 Dört adet fare beyin vasküler test verilerinin (a) orijinal girdi görüntüler, (b)gerçek referans görüntüler, (c) U-Net ile bölütlenmiş görüntüler, (d) ResNet+U-Net ile bölütlenmiş görüntüler, (e) otokodlayıcı ile bölütlenmiş görüntüleri	37
Şekil 4.4 (a, b) Örnek gürültülü test görüntüleri	39
Şekil 4.5 Şekil 4.5 (a) Test-3 görüntüsü, (b) Test-6 görüntüsü, (c) Test-9 görüntüsü test , (d) Test-3 görüntüsünün referans görüntüsü, (e) Test-6 görüntüsünün referans görüntüsü, (f) Test-9 görüntüsünün referans görüntüsü	39
Şekil 4.6 Test görüntülerinin vasküler alan fraksiyonu grafiği	40
Şekil 4.7 (a) Örnek test görüntüsü , (b) Fiji makrosu ile eşiklenmiş görüntü, (c) Referans görüntü	40
Şekil 4.8 (a) Orijinal örnek görüntüler, (b) İkileştirilmiş ResNet+U-Net tahmin görüntüleri, (c) Fiji makrosu tarafından eşiklenmiş görüntüler	42

TABLO LİSTESİ

Tablo 3.1 Veri setleri özellikleri.....	26
Tablo 3.2 İkileştirme yöntemlerinin IoU değerleri	29
Tablo 4.1 Derin öğrenme sinir ağı modellerinin eğitim ve test verileri üzerinde elde edilen başarımlar	35
Tablo 4.2 Fiji makrosu ve ResNet+U-Net ağı KUVESG + VESSEINN veri seti üzerinde vasküler analizlerin ortalama hata değerleri	43
Tablo 4.3 Angiotool ile ResNet+U-Net ağı KUVESG + VESSEINN veri seti üzerinde vasküler analizlerin ortalama hata değerleri	43

KISALTMALAR

bkz.	Bakınız
DVM	Destek Vektör Makinesi
EDCNN	Kodlayıcı-Çözücü Evrişimsel Sinir Ağları
ESA / CNN	Evrişimsel Sinir Ağı / Convolutional Neurol Network
FP	Yanlış Pozitif / False Positive
FN	Yanlış Negatif / False Negative
GB	Giga Byte
GPU	Grafik Process Unit / Grafik işlemci birimi
KNN.	K En Yakın Komşu
Nnd	En Kısa Komşu Mesafesi / Nearest Neighbour Distance
ReLU	Doğrultulmuş Doğrusal Birim
Std	Standart sapma / Standard Deviation
TP	Doğru Pozitif / True Positive
TN	Doğru Negatif / True Negative
Vaf	Vasküler Alan Fraksiyonu

GİRİŞ

Tıbbi görüntüleme tekniklerinin artması ile tıbbi görüntü bölütleme tekniklerinin önemi artmıştır. Görüntü bölütleme; görüntüyü içerisinde farklı nitelikler barındıran anlamlı bölgelere ayırmak olarak tanımlanabilir [1]. Beynin vasküler yapısındaki değişimlerin izlenmesi, çözümlenmesi ve incelenmesi, beyinde oluşabilecek hasarların, hastalıkların ve beyin işlevlerinin gözlenebilmesine olanak tanımaktadır. Bu nedenle beyin mikrovasküler ağ yapısının eksiksiz bölütlenmesi, ilgili hekimin oluşabilecek hastalığın önceden teşhisi ve tedavisi hakkında fikir belirtmesine önemli katkı sağlamaktadır. Beyin damar ağı yapısının deneyimli hekimler tarafından manuel olarak bölütlenmesi ve analiz edilmesi zaman alan ve hata oranı yüksek işlemler dizisidir.

Derin öğrenme medikal alanda; görüntüleri sınıflandırma, bölütleme (ing: segmentation), nesne algılama vb. gibi analizlerde kullanılmaktadır. Derin öğrenme ve makine öğrenmesi yapay zekânın alt dallarıdır. Makine öğrenmesi ve derin öğrenmenin birbirinden farklılığı algoritmaların öğrenme stilidir. Derin öğrenme, öğrenme işleminin özellik ayıklama bölümünü otomatik hale getirir ve el ile yapılan insan müdahalesine ihtiyaç duyulmadan, büyük veri kümelerinin kullanılmasını sağlar. Klasik makine öğrenmesi ise öğrenmek için insan müdahalesine daha fazla ihtiyaç duyar.

Sağlık alanında yapılan yanlış teşhis ve tedaviler en modern ve donanımlı toplumlarda bile önemli bir problem olmaktadır. Alınan yanlış kararlar uzman hekimler, hastalar ve hasta yakınları için maddi ve manevi olarak çok ciddi sonuçlara yol açabilmektedir. Bu çalışmada beyin vasküler yapısının bölütlenmesi ve analizi için, derin öğrenme sinir ağı temelli bir karar destek sistemi oluşturularak, gereken uzman hekim ihtiyacının azaltılması ve daha kısa sürede çözüme ulaşılması hedeflenmiştir.

Bu tez çalışmasında beyin damarlarının bölütlenmesi için literatürde görüntü bölütlemeye sıklıkla kullanılan, U-Net, ResNet+U-Net ve Otomatik kodlayıcı derin öğrenme sinir ağı modelleri kullanılmıştır. Bu derin öğrenme sinir ağı modelleri ile laboratuvarında alınan görüntüler ve bu görüntülerin manuel olarak oluşturulan referans görüntüleri ile eğitilmiş ve bölütleme sonuçları karşılaştırılmıştır. Yapılan

karşılaştırmalar sonucunda en iyi bölütleme sonucu %97 başarı oranı ile ReNet+U-Net ağından elde edilmiştir. Bölütleme işleminden sonra, elde edilen bölütlenmiş görüntülere ikilileştirme (ing: binarization) uygulanmıştır. İkilileştirme yöntemlerinde birleşimlerin kesişimi (ing: Intersection over Union-IoU) değerlendirme metriğine göre %69 başarı sağlayan Otsu metodu kullanılmıştır. Elde edilen bölütlenmiş vasküler görüntüler üzerinde vasküler alan fraksiyonu, dallanma noktası sayısı, uç nokta sayısı, damar uzunluğu analizleri yapılarak sonuçlar sayısallaştırılmıştır. Yapılan vasküler analizler sağlık alanında kullanılan uygulamalar ile karşılaştırılmıştır.

Bu çalışmanın katkıları şu şekilde ifade edilebilir:

İlk olarak araştırma için alınan görüntülerin özgün olmasıdır. Tez çalışması süresince kendi aldığımız multifoton mikroskop görüntüleri ile literatüre orijinal beyin vasküler görüntüleri kazandırmıştır. Alınan görüntüler farklı araştırmalarda da kullanılabilir bir veri setidir.

Tezin ikinci katkısı, multifoton mikroskopundan alınan orijinal gürültülü görüntülerin manuel olarak temizlenerek literatüre gerçek referans görüntülerinin kazandırılmasıdır. Tez süresinde yapılan referans görüntüler oluşturulurken uzmanlardan alınan görüşler dikkate alınmıştır.

Üçüncü katkı, tez çalışmasında uzmanlara klinik karar vermede yardımcı olmak için sistemi otomatikleştiren yardımcı uygulama yazılımı yapılmıştır. Sistemin otomatik hale gelmesi uzmanlara gereken ihtiyacı azaltarak zamandan tasarruf sağlamanın yanı sıra daha düşük hatalı teşhisler koymak, hastalara daha kaliteli bakım sağlamak, en uygun tedaviyi önermede destek sağlamaktadır.

Bu tez çalışması beş ana bölüm olarak organize edilmiştir. Birinci bölüm, tez çalışmasına ait temel kavramlar ve amacı içermektedir. İkinci bölümde literatürde görüntü bölütlemeye yapılan çalışmalardan, derin öğrenme sinir ağlarının tarihçesinden ve ağların yapısındaki temel kavramlardan bahsedilmiştir. Üçüncü bölümde kullanılan ağlardan, veri setlerinden ve vasküler analizlerden bahsedilmiştir. Dördüncü bölümde elde edilen sonuçlar değerlendirilmiş ve var olan medikal araçlarla karşılaştırma sonuçları sunulmuştur. Beşinci bölümde çalışmanın sonucu özetlenerek gelecek çalışmalardan bahsedilmiştir.

BİRİNCİ BÖLÜM

1. TEMEL KAVRAMLAR VE LİTERATÜR ÇALIŞMASI

Yapay Sinir ağlarının tıbbi görüntüleme teknikleriyle elde edilen görüntüler üzerinde tahminler yapması, çeşitli sonuçlar üretmesi son yıllarda sıklıkla çalışılan konulardandır. Medikal görüntüler gerek ışının yansınması, saçılması gibi nedenlerle dijital kameralar ile çekilen görüntülere göre daha yüksek gürültü-sinyal oranına sahiptir. Bu oran çözünürlüğün kalitesini belirtir, düşük çözünürlük ise, farklı anatomik yapıları kontrast farkından ayırt etmeyi güçleştirir.

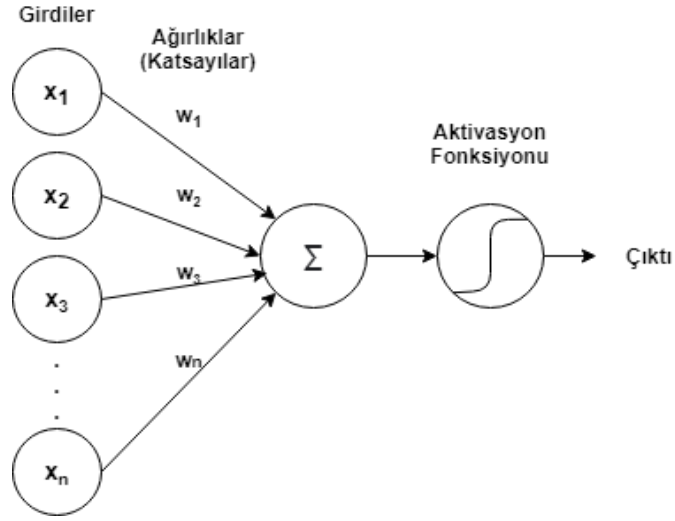
Yapılan bu tez çalışmasında derin yapay sinir ağları kullanılarak beyin vasküler görüntülerinde bölütleme (segmentasyon) işlemi gerçekleştirilmiştir. Kullanılan ağların performansları karşılaştırılmıştır. Elde edilen bölütlenmiş görüntüler üzerinde analizler gerçekleştirilmiş ve var olan uygulama ile karşılaştırılması yapılmıştır.

Bu bölümde, yapay zekanın alt bilim dalları olan makine öğrenmesi ve derin öğrenmeden bahsedilecektir ve ayrıca derin öğrenme sinir ağlarının mimarisinde var olan yapılar ve kavramlar anlatılacaktır.

1.1. DERİN ÖĞRENME

İnsan beyninden ilham alınarak daha zeki sistemler üretebilmek için yapılan çalışmalar neticesinde ortaya çıkmıştır. 1940'lı yıllarda S. McCulloch ve Walter H. Pitts beyindeki sinir hücrelerinin aktif veya pasif olmasının bir eşik değere bağlı olduğunu, beyindeki sinir hücrelerini birbirlerine bağlayarak bir devre kurulabilir ve bu devre ile kararlar alınabileceğinden bahsetmiştir. Nöronlar girdileri belirli katsayılar ile çarparak ağırlıklı toplam alınır. Sonuç eşik değeri ile kıyaslanır, eğer sonuç eşik değerin altında kaldıysa iletim olmaz, fakat eşik değeri geçerse nöron iletimi gerçekleştirir. Bu yapı başlıca yapay sinir ağlarının çalışma prensibini gösterir. Fakat günümüzdeki yapay sinir ağlarından farklı olarak katsayıların, ağırlıkların öğrenilemeyeceğini söylemişlerdir [2].

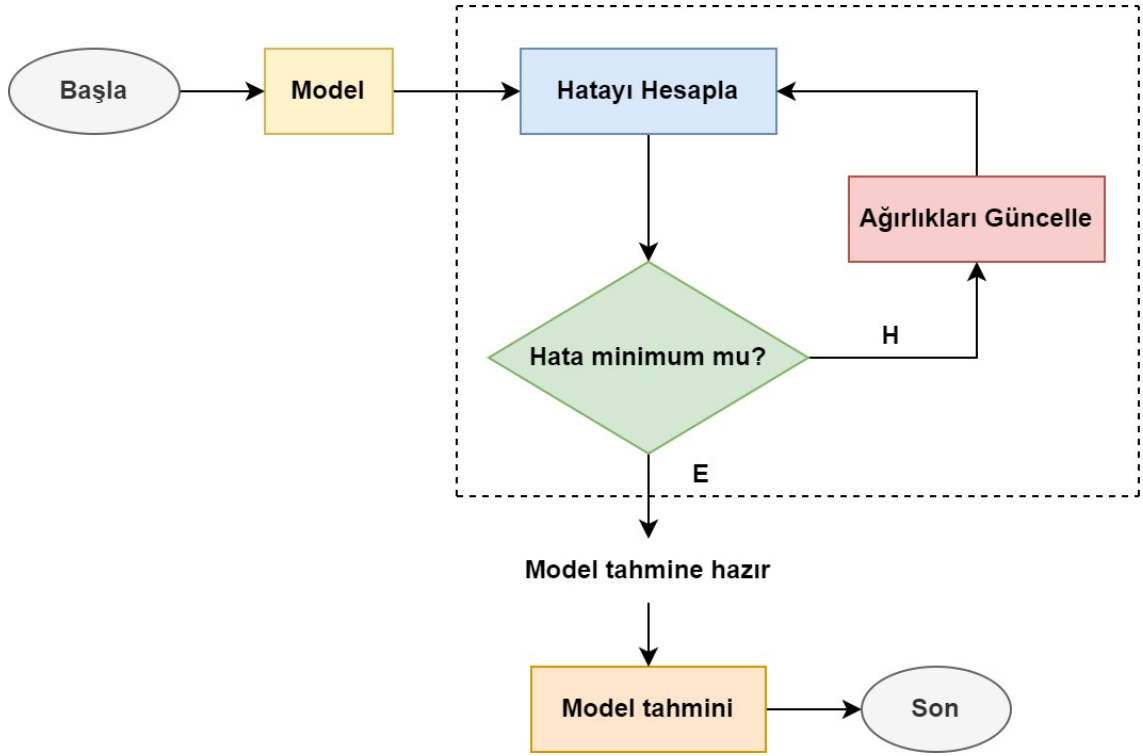
1957 yılında Frank Rosenblatt Perceptron öğrenme algoritması ile temel yapay sinir ağlarındaki ağırlıkların değiştirilebileceğini göstermiştir [3]. Perceptron yapısı (Şekil 2.1) tek katmanlı öğrenebilen ve çıkışta tek bir sonuç üretebilen bir yapay sinir ağıdır.



Şekil 2.1 Perceptron Modeli

Perceptron yapısı lineer denklemler için başarılı sonuçlar üretmekteydi fakat lineer olmayan problemleri çözme konusunda yeterli başarıyı sergileyememekteydi. Böylece insan beyin hücrelerini taklit ederek karar verebilen mekanizmalar oluşturma çalışmaları 1960'lı yılların sonlarında resmen durdu.

1986 senesinde G. Hinton, R. Williams ve D. Rumelhart tarafından yayımlanan paralel programlama çalışmalarını içeren eser, Çok Katmanlı Algılayıcılar (Multi Layer Perceptron) fikrinin ortaya çıkmasında önemli rol oynamıştır. Aynı sene Rumelhart ve McClelland tarafından geri yayılım kavramının ortaya atılmasıyla birlikte 17 sene sonra Derin Öğrenme canlanarak yeniden popüler olmuştur [4]. Geri yayılım (ing: backpropagation), ağırlık ileri yönlü yaptığı işlemler sonucunda elde ettiği tahmin ile referans değer arasındaki farkı (hata) azaltmak için kullanılan bir algoritmadır. Şekil 2.2'de gösterildiği üzere başlangıçta ağırlıklar herhangi bir değer ile başlatılır ve modelin çıktısı hesaplanır, eğer hata minimize değil ise ağırlıklar güncellenir ve model çıktısı yeniden hesaplanır. Hata minimum değere ulaşıncaya kadar işlem tekrarlanır ve son olarak model tahmini yapılır. Geri yayılım algoritması, gradyan iniş olarak isimlendirilen bir teknikle hata fonksiyonunun minimum değerini bulur.



Şekil 2.2 Geri Yayılım Algoritması Akış Diyagramı

Çok katmanlı yapay sinir ağ mimarisi fikrinin ortaya atılmasıyla katman sayısı çoğaltılarak Evrişimsel Sinir Ağı (ing: Convolutional Neural Network) geliştirilmiştir. Pan ve arkadaşları [5] evrişimsel sinir ağı modelinde gizli katmanlar kullanarak ve özellik sayısının sadece %2 kadarı kullanarak yaptıkları deneylerde, tüm özellikleri kullanan diğer modellerin benzerlik oranını (ing: recognition rate) iki kat daha hızlı bir sürede yakalamışlardır.

Yapay sinir ağlarının yeniden gündeme gelmesinde bilgisayar teknolojisindeki ilerlemelerin de önemli bir katkısı bulunmaktadır. 1990'lı yıllardan itibaren günlük yaşamda kullandığımız sistemlere yapay sinir ağı çalışmaları entegre edilmiştir.

Derin öğrenme yöntemleri, beyin hücrelerinin sınıflandırılması [6], doku sınıflandırılması, 3 boyutlu beyin yeniden yapılanması (ing: reconstruction) [7], organların bölütlenmesi, Alzheimer gibi hastalıkların teşhisi [8], tümör veya kanserli hücre tespiti [9] gibi medikal alanındaki problemlerin çözülmesi için kullanılmaktadır.

Shan ve Li [10] gözün arka bölümünde (fundus) gerçekleşen mikro anevrizmaları görüntülerden tespit etmek için otomatik kodlayıcı modelini sunmuşlardır. Softmax aktivasyon fonksiyonunu kullanarak görüntüdeki ayırt edici özelliklerin tasarladıkları iki katmanlı otomatik kodlayıcı ile bölütlenmesinde başarılı sonuç elde etmişlerdir. Softmax fonksiyonu, birden fazla sınıflı bir sınıflandırma problemlerinde kullanır. Aynı zamanda çoklu Sigmoid olarak da adlandırılan bu metot, çıktı olarak her sınıfa ait 0 ile 1 arasında olasılık değerleri döndürür. 10 kat çapraz doğrulama sonrasında model, sınıflandırma problemleri için sıklıkla kullanılan ROC eğrisi ile test edilmiştir. Bu test yönteminde eğrinin altında kalan arttıkça ağın doğru tahmin etme performansı artmaktadır. Eğrinin altında kalan alan AUC (ing: area under the curve) olarak adlandırılır. Yapılan çalışmada AUC test yöntemi ile yaklaşık %96,2'lik bir başarı elde edilmiştir.

Heba Mohsen ve ark. [11] beyin MRG görüntülerini normal ve 3 tip malignant beyin tümörü: glioblastoma, sarkom, metastatik bronkojenik karsinom tümörleri olarak sınıflandırmak için Derin Öğrenme Sinir Ağı, K-en yakın komşu (KNN), Doğrusal Ayırma Analizi (ing: Linear Discriminant Analysis-LDA) ve optimize edilmiş Destek Vektör Makinesi algoritmaları karşılaştırılmıştır. Sınıflandırıcı, ana bileşen analizi (Principal Component Analysis-PCA), güçlü dalgacık dönüşümü (ing: Discrete Wavelet Transform-DWT) ve güçlü özellik çıkarma aracı ile birleştirilmiştir. Derin öğrenme sinir ağı %96,97 sınıflandırma oranı ile diğer algoritmalara kıyasla en iyi performansı gösterdiği gözlenmiştir.

M.E. Çelebi ve ark. [12], dermoskopi görüntüleri üzerinde cilt lezyonlarının sınıflandırılmasına yönelik çalışma yapmışlardır. İlk olarak, otomatik sınır tespiti ile lezyonlu bölgeyi arka plan derisinden ayırmışlardır. Ardından lezyonun alanı, en-boy oranı, asimetriklik, yoğunluk, maksimum çap, eksantriklik, katılık gibi özelliklerine bakılarak şekil özelliklerini tanımlamışlardır. Renk, şekil ve doku için özellik çıkarımı (ing: feature extraction) yapmışlardır. 437 özellik arasından testler sonucu AUC değerlendirme metriğine göre en iyi sonucu veren 18 öznitelik kullanılmıştır. Son olarak Destek Vektör Makinesini (ing: Support Vector Machine) kullanarak dokuları kötü huylu ve iyi huylu melanom olarak ayırmak üzere ikili sınıflandırma yapmışlardır. 594

görüntü örneği yapılan çalışmada, %92,34'lük özgüllük (ing: specificity) ve %93,33'lük duyarlılık (ing: sensitivity) elde etmişlerdir.

Makine öğrenmesi [13] 1980'lerde ortaya çıkan yapay zekânın bir alt bilim dalıdır. Sisteme verilen veri kümesini matematiksel ve istatistiksel işlemlerden geçirerek, tahminde bulunmak veya sınıflandırmak için kullanılır. Makine öğrenmesi öğrenme yöntemlerine göre 3 gruba ayrılır; Gözetimli (ing: Supervised) Öğrenme, Gözetimsiz (ing: Unsupervised) Öğrenme, Takviyeli (ing: Reinforcement) öğrenme.

Gözetimli Öğrenme, ağa verilen işaretlenmiş (ing: labelled) veriler ile istenen çıktı verileri arasında eşleştirme yaparak öğrenen bir algoritmadır. Fakat girdi verileri işaretlenmemiş ise (ing: unlabelled) bu veriler ortak özellikler içeren kümelere bölünür. Bunu sağlayan yapıya ise Gözetimsiz öğrenme denir. Takviyeli öğrenme ise deneme yanılma ile öğrenen bir yöntemdir. Denemeler sonucu edinilen başarılar pekiştirilerek bir problem için en iyi tavsiyeyi sunmayı amaçlar.

Makine öğrenmesinin alt bilim dalı olan derin öğrenme [14], gözetimli, gözetimsiz, yarı gözetimli veya takviyeli olarak gerçekleştirilebilir. Buradaki yapay sinir ağlarının yapısında giriş, çıkış ve gizli katmanlar birden fazla olduğundan öğrenme süreci derin olarak adlandırılır. Bu katmanlar sayesinde veriyi işleyerek bilgiye ulaşılır. Derin öğrenmede doğru tahminler yapabilmek için büyük miktarda eğitim veri setine ihtiyaç duyulur. Çok sayıda ve karmaşık işlemler içerdiğinden makine öğrenmesinden farklı olarak üst düzey donanıma sahip makineler üzerinde verimli sonuçlar alınır. Makine öğrenmesinden bir diğer farkı ise derin öğrenmenin çıkışı sınıflandırma veya bir sayısal değer olmak zorunda değildir. Çıkış katmanında sayısal bir değer üretmesinin yanı sıra metin, ses gibi çok biçimli çıktılar üretebilir.

Derin öğrenme birçok farklı sektörde kullanılabilir. En yaygın kullanım alanlarına örnek vermek gerekirse; görüntü işleme-sınıflandırma, ses sinyali sınıflandırma veya gürültü azaltma, duygu analizi, sohbet botları, sürücüsüz araçlar, hizmetlere yönelik otomatik öneri sunma, tıp sektöründe teşhis ve tedaviye yardımcı tahminlerde bulunma gibi birçok örnek verilebilir.

Günümüzde yaygın olarak kullanılan derin öğrenme mimarileri: Derin Oto-Kodlayıcılar (ing: Deep Auto-Encoders), Derin İnanç Ağları (ing: Deep Belief

Network), Tekrarlayan Sinir Ağları (ing: Recurrent Neural Networks-RNNs), Evrişimsel Sinir Ağları (ing: Convolutional Neural Network-CNN).

Otomatik kodlayıcılar, girdi katmanındaki verileri çıktı katmanında yeniden oluşturan bir ağ modelidir. Girdi olarak verilen verinin sıkıştırılmış halinden en ayırt edici, en iyi özellikleri öğrenmeyi hedefler. Derin Oto-Kodlayıcılar ise her katmandaki çıktının önceki katmanın girişine bağlandığı birden fazla katmandan oluşan yapay sinir ağıdır.

Derin İnanç Ağları, küçük boyutlu denetimsiz sinir ağlarından oluşur. Bu mimaride katmanlar arasında bağlantılar bulunurken, katman içerisindeki birimler arasında bağlantı bulunmamaktadır.

Tekrarlayan Sinir Ağları, bir adet giriş katmanı, iki tane gizli katman ve bir çıkış katmanından oluşmaktadır. Diğer yöntemlerde katmanlar birbirlerinden bağımsız çalışmaktadır. Bu mimaride ise her çıkış, kendi girişi ve önceki girişe bağlı olarak hesaplanmaktadır.

Evrişimsel Sinir Ağları, çok katmanlı bir yapay sinir ağı türüdür. En popüler ve sıklıkla kullanılan bir derin öğrenme mimarisidir. Evrişimsel sinir ağı mimarileri görüntülerin analiz edilmesinde yüksek başarımlar sağladığı için yapılan tez çalışmasında bu mimariler kullanılmıştır. Bir sonraki bölümde detaylıca anlatılacaktır

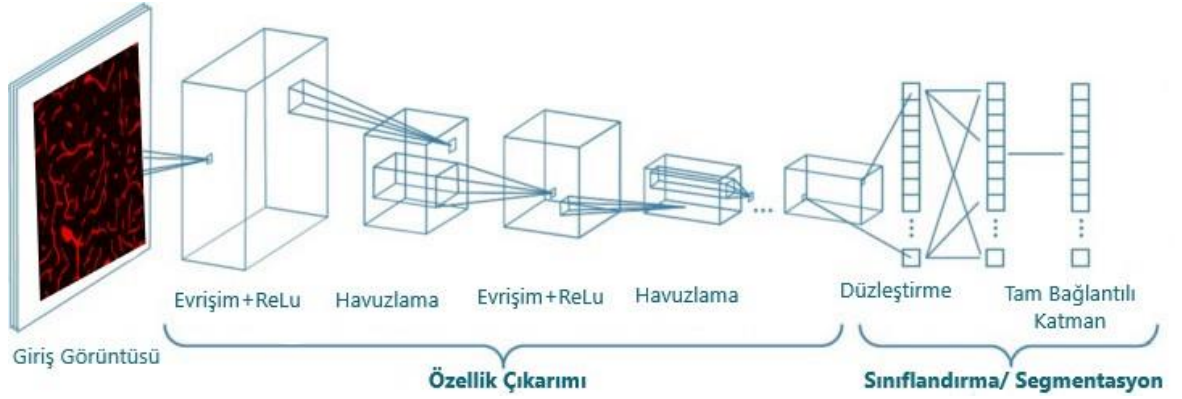
1.2. EVRİŞİMSEL SİNİR AĞLARI

Evrişimsel Sinir Ağları 1998 yılında LeCun ve ark. [12] tarafından, Hubel ve Wiesel'in [13] korteks nörobiyolojisinden ilham alarak tasarladıkları modeldir. LeCun tarafından sunulan LeNet modeli görüntülerdeki el yazısı ile yazılmış rakamları sınıflandırmaktaydı. Ardından Krizhevsky ve ark. [14] 2012 yılında AlexNet modelini tanıtarak Şekil 2.3'te verilen Evrişimsel Sinir Ağları (ESA) modelinin bilinirliğini artırmıştır. ESA günümüzde görüntü sınıflandırma, görüntü bölütlemesi, nesne tanıma, nesne konumlandırma (ing: localization) gibi birçok görüntü analiz işlemlerinde sıklıkla kullanılan bir modeldir.

ESA'da görüntülerin dijital karşılıkları olan matrisler üzerinde filtreleme işlemleri yaparak görüntünün ayırt edici özelliklerini çıkarmayı otomatik olarak gerçekleştirir. Evrişim ismini bu filtreleme işlemlerinden almaktadır. Özellik çıkarma

işleminin otomatik gerçekleşmesi klasik makine öğrenmesi algoritmaları ile arasındaki önemli bir farktır. Görüntülerin öznitelikleri elde edildikten sonraki aşama bu değerleri kullanarak görüntüleri sınıflandırma veya bölütleme adıdır.

Bir diğer taraftan, ESA modelinin performansı ile veri miktarı arasında doğrusal bir ilişki vardır. Hem eğitim hem de tahmin aşamalarında doğruluğu artırmak için büyük miktarda veriye ihtiyaç duyulmaktadır. Büyük miktarda veri ise daha fazla hesaplama gerektireceğinden, daha yüksek işlem gücüne sahip donanımlar gerekmektedir.



Şekil 2.3 Evrişimsel Sinir Ağı Mimarisi

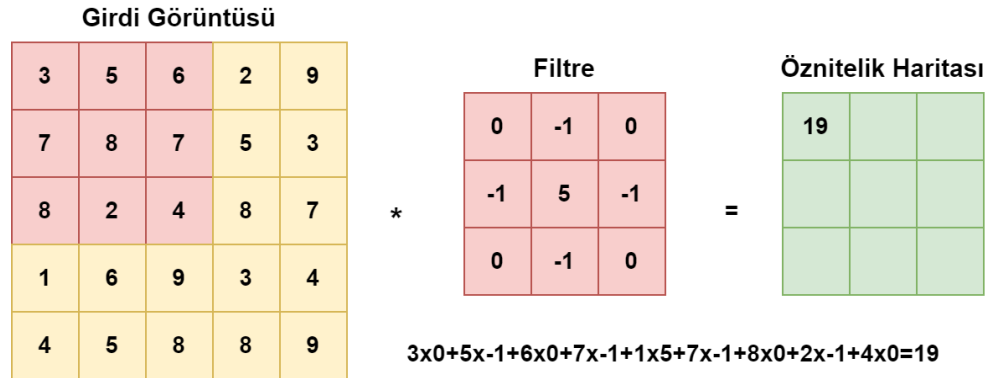
1.2.1. Girdi Katmanı

Sinir ağını beslemek için ağa verilen görüntüdür. Bu girdinin dijital olarak işlenebilmesi için bir görüntü matrisi olarak ifade edilir. Görüntünün boyutları, kaç kanallı olduğu gibi bilgiler girdinin tutulduğu matrisi değiştirir. Girdinin boyutunun büyük olması bellekte daha fazla yer kaplamasına ve hesaplama karmaşıklığının artmasına neden olur. Fakat girdi hakkında daha fazla özellik bilmek ağın yapacağı tahmini iyileştirir.

1.2.2. Evrişim Katmanı

Evrişim katmanı giriş katmanında verilen görüntüyü filtreler ile konvüle ederek ayırıcı özelliklerini çıkarmaktadır. Dolayısıyla bu katman ESA'ların en önemli katmanlarından birisidir.

Evrişim filtreleri görüntü boyutundan küçük matrislerden oluşur. Bu filtreler, giriş görüntüsünün hacmine eşit hacimde derinliğe sahiptir. H_i ve W_i 'nin oluşturulan filtrenin genişlik ve yükseklik piksel boyutları ve D_i 'nin görüntünün kanal sayısı olduğunu varsayarsak $D_i \times H_i \times W_i$ boyutlu filtre, tüm görüntü matrisini kapsayacak şekilde, görüntü matrisi üzerinde gezdirilir. Filtrenin içi çıkarılmak istenen özelliklere göre uygun değerler ile doludur. Şekil 2.4'te evrişim filtresi ile görüntü matrisi üzerinde evrişim işlemi gösterilmektedir. Girdi görüntüsünün pembe renkli bölümü olan 3×3 'lük filtre ile karşılık gelen değerlerin birebir çarpımının toplamı $(3 \times 0) + (5 \times -1) + (6 \times 0) + (7 \times -1) + (5 \times 8) + (7 \times -1) + (8 \times 0) + (2 \times -1) + (4 \times 0) = 19$ evrişim değerini verir. Her katmanda tekrar edilen evrişim işlemleri sonucunda iki boyutlu bir çıkış elde edilir. Bu katman sonucunda öznitelik haritası elde edilir. Evrişim katmanı sayısı kadar her biri farklı özelliği temsil eden öznitelik haritası oluşur,



Şekil 2.4 Evrişim işlemi örnek gösterimi

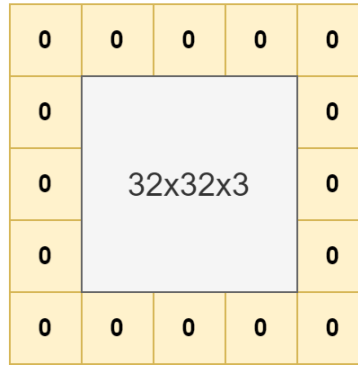
Evrişim işleminde kullanılan filtrenin (ing: kernel) içindeki değerlerin ve boyutunun seçimi girdi görüntüsünden çıkarılacak özellikleri ve hesaplama sürelerini etkiler. Uygulanan filtrelerin değerlerine ağırlıklar adı verilir ve bu ağırlıklar evrişim işlemi sonucu hesaplanan hata değerine göre güncellenirler. Güncellenen ağırlık değerleri ile yapılan evrişim sonucu yeni özellikleri ortaya çıkartır.

1.2.3. Dış Boşluk ve Bir adım değeri

Girdi görüntülerini kullanarak daha karmaşık özniteliklere ulaşmak istiyorsak bu filtreler karmaşıktırılabilir. Filtrenin matris üzerinde gezintisinde kaçır adım

kayacağı Adım değeri (ing: stride) ile belirlenir. Aralık değeri öznitelik haritasının çıktı boyutunu değiştirir. Adım değerinin büyük olması çıktı boyutunu küçültür.

Evrışimsel sinir ağının ilk katmanlarında mümkün olduğunda fazla bilgiyi korumamız gerekmektedir. Bu nedenle görüntünün boyutunun küçülmesini istenmediği durumlarda boyutu korumak için girdi görüntü matrisinin dışına değerler eklenir. Bu işleme dış boşluk (ing: padding) denir. Dış boşluğa eklenen yeni değerler sıfırlardan oluşabileceği gibi matrisin kenar değerlerinin aynı piksel değerleri ile doldurulabilir.




Şekil 2.5 Dış boşluk örneği

Örneğin, Şekil 2.5' de sarı çerçevenin içindeki alan $32 \times 32 \times 3$ boyutlu bir giriş görüntüsü olsun. Görüntü matrisin etrafına bir dış boşluk sayısı eklenirse matris boyutu $34 \times 34 \times 3$ olur. Oluşan yeni matrise $3 \times 3 \times 3$ ' lük bir filtre uyguladığımızda $32 \times 32 \times 3$ ' lük bir çıktı elde ederiz.

1.2.4. Ortaklama Katmanı

Girdi görüntüsünün boyutu büyüdükçe uygulamamız gereken filtrelerdeki hesaplamalar bizlere büyük işlem yükleri getirir. Ayrıca yapılan evrişim işlemlerinin birden fazla olduğunu göz önüne alırsak bu durum büyük sıkıntılar çıkarabilir. Bu sorunu çözmek için ortaklama (ing: pooling) bir diğer adıyla alt örnekleme (ing: subsampling) kullanılır. Ortaklama katmanı ESA'da girdi boyutunun ve özelliklerin boyutunun azaltılması için kullanılır. Özelliklerin yükseklik ve genişliği değişirken derinlik aynı kalır. Bu katman sayesinde bazı özellikler kaybolursa da ağıdaki parametreler ve hesaplama miktarı azaldığı için çalışma süresi kısalmıştır.

Ortaklama işleminin, maksimum ortaklama, ortalama ortaklama, minimum ortaklama ve toplam ortaklama gibi farklı türleri vardır. Maximum ortaklama, filtreyi uygulanan alandaki en büyük değeri alır, minimum ortaklama en küçük değeri alır, ortalama ortaklama değerlerin toplamını alır, toplam ortaklama ise değerlerin toplamını alır ve bu sayede öznitelik haritasının boyutu azaltılmış olur. Seçilen filtre boyutuna ve işlevine uygun olarak görüntüdeki denk gelen alandaki değerlere ortaklama işlemi uygulanır. Ardından evrişim katmanındaki gibi bu filtre adım değeri kadar kaydırılır ve işlemler tekrarlanır. Maximum ve minimum ortaklama işlemleri Şekil 2.6’da örnekle gösterilmiştir. Şekilde 2 x 2 boyutunda filtreler 2 adım değeri kadar kaydırılarak sırasıyla mor, turuncu, yeşil ve mavi renkli alanlara uygulanır. Maximum filtre için ilk alanda 39, 43, 56 ve 18 değerleri arasından en büyük piksel değeri olan 56 seçilerek ilk ortaklama işlemi yapılmıştır. Minimum ortaklama işleminde ise en küçük değer olan 18 alınmıştır. Bu filtrenin tüm matrise uygulanması ile 4 x 4’lük bir matrisin boyutu yarıya indirilir.

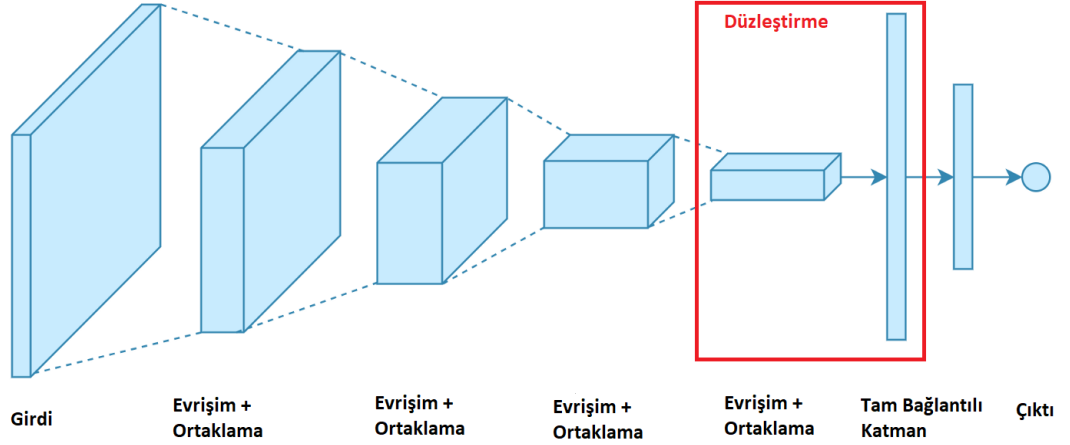


Şekil 2.6 Ortaklama Örneği

1.2.5. Düzleştirme

Düzleştirme adımı kadar yapılan işlemler Şekil 2.3’te gösterilen ESA modelinin özellik çıkarımı bölümünün işlemleridir. Bu katmanın görevi ise tam bağlantılı katmanın girişine verilecek verileri hazırlamaktır. Düzleştirme (ing: Flatten), evrişim ve

ortaklama katmanlarından gelen matrisleri Şekil 2.7’ de gösterilen şekilde tek boyutlu bir diziye yani vektöre dönüştürür.



Şekil 2.7 Düzleştirme Örneği (Flatten)

Örneğin, öznelik matrisi boyutunun $32 \times 32 \times 128$ olduğunu varsayalım. Bu 32×32 boyutunda 128 adet özellik anlamına gelmektedir. Bu matris tek boyutlu bir diziye çevrildiğinde $32 \times 32 \times 128$ işlemi sonucu 131.072×1 boyutunda bir vektör elde edilir. Elde edilen matris tam bağlantılı katmanın girişine verilir.

1.2.6. Tam Bağlantılı Katman

Tam bağlantılı katman (ing: Fully Connected Layer), yapay sinir ağlarında özellik çıkarıldıktan sonra elde edilen bu özelliklerin sınıflara ayrılması görevini üstlenir. Bu katmanda elde edilen özellikler ağırlıklandırılarak bir tahmin sonucu üretilmektedir. Bu katmana verilen vektörün giriş bilgisi ile çıkış arasında gizli katmanlar (ing: hidden layers) olabilir. Katmanlar arasındaki bağlantılar sayıca fazla olabilir ancak çıkış katmanında sınıf sayısı düğüm sayısına eşit olmalıdır.

1.2.7. Optimizasyon Yöntemleri

Yapay sinir ağlarında ağırlıklar her zaman hata değerini en aza düşürecek şekilde güncellenir. Ağırlıklar geri yayılım algoritması ile toplam hataya göre güncellenir. Hesaplanan ağırlıkların hataya olan etkisi çoğunlukla gradyan tabanlı algoritmalar ile hesaplanır. Optimizasyonu sağlamak için RMS-Prop (Root Mean Square Propagation) [15], Stokastik Gradyan Azaltma [16] ve Adam [17] algoritmaları

çoğunlukla kullanılan algoritmalarıdır. Bu algoritmaların uygulamaları farklı olsa da alt yapısında türev ve geri yayılım kullanılmaktadır.

Bu çalışmada, benzer veri kümelerinde daha önce kullanılan ve yüksek başarımlı sonuçları verdiği görülen Adam algoritması kullanılmıştır. Yapay sinir ağlarında ağırlıklar her zaman hata değerini en aza düşürecek şekilde güncellenir. Ağırlıklar geri yayılım algoritması ile toplam hataya göre güncellenir. Hesaplanan ağırlıkların hataya olan etkisi çoğunlukla gradyan tabanlı algoritmalar ile hesaplanır. Optimizasyonu sağlamak için RMS-Prop (Root Mean Square Propagation) [15], Stokastik Gradyan Azaltma [16] ve Adam [17] algoritmaları çoğunlukla kullanılan algoritmalarıdır. Bu algoritmaların uygulamaları farklı olsa da alt yapısında türev ve geri yayılım kullanılmaktadır.

Bu çalışmada, benzer veri kümelerinde daha önce kullanılan ve yüksek başarımlı sonuçları verdiği görülen Adam algoritması kullanılmıştır.

1.2.7.1. Adam Algoritması

Adam yani Adaptif Momentum Tahmini (ing: Adaptive Moment Estimation) [17], gradyanın karelerin ortalamasının karekökü ile normalize edilmiş haline momentum eklenmiş yöntemdir. Adam algoritmasında her parametre kendi öğrenme hızına sahiptir ve bu öğrenme oranı giderek azalmaktadır. Öğrenme oranının hızlı düşmesini engellemek amacıyla bu yöntemde momentum değişiklikleri önbellekte (ing: cache) tutulur. Momentum üstel hareketli ortalama (ing: exponential moving average) (değişken bir miktarın ortalama değerini korumak için kullanılan standart bir metot) ile güncellenerek hesaplanır.

1.2.8. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonu [18] yapay sinir ağlarında doğrusal olmayan özellikleri öğrenmeyi sağlar. Metin, ses, görüntü ve video gibi gerçek dünya verileri doğrusal olmayan karmaşık verilerdir. Eğer aktivasyon fonksiyonu kullanılmazsa ağın çıkışı basit bir lineer fonksiyondan oluşur, elde edilen fonksiyon tek katmanlı bir yapay sinir ağı gibi davranır. Bu şekilde tasarlanan modelde kısıtlı bir öğrenme oranına sahip olacak ve karmaşık problemlerde yetersiz kalacaktır. Bu sebeple doğrusal olmayan aktivasyon fonksiyonları kullanılarak yapay sinir ağlarının karmaşık verileri öğrenmesi sağlanır.


Geri yayılım algoritmasının hata / kayıp değerini azalttığından bahsetmiştik. Geri yayılımı sağlamak amacıyla aktivasyon fonksiyonunun türevlenebilir olması gerekmektedir. Aksi takdirde modeli iyileştiremeyiz. Türevlenmesi daha basit olan aktivasyon fonksiyonları hesaplama açısından daha kısa sürede yapılır, dolayısıyla performans açısından olumlu etkiler. Çoğunlukla kullanılan aktivasyon algoritmaları şunlardır; Sigmoid, hiperbolik tanjant, doğrultulmuş doğrusal birim (ing: Rectified Linear Unit – ReLU), sızdırılmış doğrultulmuş doğrusal birim (ing: Leaky–ReLU).

1.2.8.1. Sigmoid Aktivasyon Fonksiyonu

Yapay sinir ağlarında kullanılan aktivasyon fonksiyonları arasında en sık kullanılan fonksiyondur. Denklem 2.2’ de ifade edilen sigmoid fonksiyonu çıktı olarak [0,1] aralığında olasılıksal bir değer verir. Bunun anlamı çıktının karşılık geldiği sınıfa ait olma olasılığıdır. Genellikle ikili sınıflandırma problemlerinde yapay sinir ağının son katmanında kullanılır. Sürekli türevlenebilen bir fonksiyon olması sigmoid fonksiyonunun avantajıdır.

$$\sigma(x) = \frac{e^x}{1 + e^x} \quad (2.2)$$

Diğer yandan, Şekil 2.8’de karakteristiği görülen sigmoid fonksiyonunu incelersek uç noktalarda x değerlerinin değişimine y değerinin yeteri kadar tepki vermediği gözlenmektedir. Bu durum Kaybolan gradyan (ing: Vanishing Gradient) olarak adlandırılan; türevinin tur sayısı arttıkça sifira yakınsaması anlamına gelir. Gradyan kayboldukça öğrenme azalır ve 0 olursa ağ öğrenme gerçekleştiremez.




Şekil 2.8 Sigmoid aktivasyon fonksiyonu karakteristik grafiği

1.2.8.2. Doğrultulmuş Lineer Ünite

Doğrultulmuş Lineer Ünite (ing: Rectified Linear Unit – ReLU) fonksiyonu Denklem 2.3’ den görüleceği gibi negatif ekseninde 0 değerini almaktadır. Bu durumda ağa giren tüm nöronlar aktivasyon işlemine uğramamaktadır. Ağdaki bazı nöronların aktif olup bazılarının elimine edilmesi hesaplama yükünü azaltmaktadır. Bu da fonksiyonun hızlı çalışmasını sağlar. Sağladığı performans artışından ötürü özellikle çok katmanlı ağ yapılarında ara katmanlarda sıklıkla kullanılan bir metottür.

$$g(x) = \max(0, x) = \begin{cases} x & \text{eğer } x \geq 0 \\ 0 & \text{eğer } x < 0 \end{cases} \quad (2.3)$$

Ayrıca Şekil 2.9’da grafiği verilen ReLU fonksiyonunun türevi sıfıra yakınsama yapmadığı için Kaybolan gradyan sorunu olmadığını söyleyebiliriz. Fakat fonksiyonun türevinin negatif değerlerde sıfır sonucunu üretmesi Geri Yayılım (ing: Back Propagation) sırasında parametrelerin değerlerinin güncellememesi ve buna bağlı olarak öğrenme işleminin olamaması demektir. Bu soruna Dying ReLU denilmektedir. Bu problemin çözümü için ReLU’nun bazı versiyonları geliştirilmektedir.



Şekil 2.9 ReLU aktivasyon fonksiyonu karakteristik grafiği

1.3. ESA İLE YAPILAN DAMAR BÖLÜTLEME ÇALIŞMALARI

Makinelerin hesaplama yeteneğinin gelişmesi ile derin öğrenme sinir ağları, görüntülerin işlenmesi ve makine öğrenmesi alanlarında çok sayıda yarışmayı

kazanmıştır. Çeşitli derin öğrenme sinir ağları arasında, görüntü analizi için en başarılı model türü evrimsel sinir ağlarıdır (ESA/CNN).

Liskowski ve ark [9] derin evrimsel sinir ağını retina kan damarlarının bölütlenmesinde uygulayan ilk çalışmayı yayınlamışlardır. O zamandan beri, ESA'lar birçok damar bölütleme uygulamasında aktif olarak kullanılmaktadır.

Kalinovsky ve ark. [19], göğüs radyograflarında (X-Ray göğüs görüntüleri) akciğerlerin bölütlenmesini yapmak için derin öğrenme ve Kodlayıcı-Çözücü Evrimsel Sinir Ağlarını (ED-CNN) kullanmışlardır. Manuel olarak bölütlenmiş radyografi görüntüleriyle yapılan testler sonucu %96,2 doğruluk ve %97,4 en büyük zar katsayısı değerlerine ulaşmışlardır. Zar skoru, referans görüntü ile bölütlenmiş görüntü arasındaki örtüşen alanının 2 katının, her iki görüntüdeki toplam piksel sayısına bölünmesiyle hesaplanır. Yapılan çalışma sonucu, göğüs radyografilerinde otomatik akciğer bölütlemesi için ED-CNN ağlarının kullanılması umut verici sonuçlar vermiştir.

Hoorali ve ark. [20], şarbon hastalığının deride oluşturduğu yara görüntüsünün mikroskopik görüntüsünden otomatik bakteri bölütlemesi yapan ağ tasarlamışlardır. Şarbon hastalığı sığır, keçi, koyun gibi ot yiyen enfekte olmuş hayvanlardan çeşitli yollarla insana tehlikeli şarbon bakterilerinin geçmesi sonucu oluşur. Çalışmada doku örneklerini bölütlemek için U-Net mimarisindeki özellikleri daha iyi temsillerle çıkarmak için atlama bağlantılarındaki çok ölçekli özellikleri, başlangıç ve artık blokları birleştirerek IRUNet olarak adlandırdıkları bir model önermişlerdir. IRUNet, sonuçları incelendiğinde %92,8 kesinlik, %93 duyarlılık oranı ve %92,9 zar katsayısına ulaşır.

Phellan ve ark [21], derin öğrenme mimarisini kullanarak kontrastsız manyetik rezonans anjiyografi (TOF MRA) görüntülerinde beyin damarlarını otomatik olarak bölütlemişlerdir. İki boyutlu sagittal, koronal ve transversal düzlemlerden alınmış görüntüler manuel etiketlenerek ESA'yı eğitmek için kullanılmıştır. Çapraz doğrulamalar ve eğitim için kullanılan görüntü sayısına bağlı olarak 0,764 ila 0,786 arasında değişen bir ortalama Zar katsayısı ile damarları bölütleyebildiklerini ortaya koymuştur.

1.4. DEĞERLENDİRME METRİKLERİ

Bir modelin başarılı bir sonuç üretip üretmediğinin analizini yapmak için değerlendirme metrikleri kullanılmaktadır. Çıktıları tek bir metrik üzerinden değerlendirmek yerine birden fazla metrik ile destekleyerek, modelin başarımlarını doğrular. Bu tez çalışmasında kullanılan değerlendirme metrikleri bölüm 2.5.1 ve 2.5.7 numaralı alt başlıklarda verilmiştir ve detaylı olarak açıklanmıştır.

Tasarlanan modelin tahmin değerleri ile gerçek değerler arasındaki ilişkileri inceleyebilmek için Şekil 2.10'da gösterilen Karmaşıklık Matrisi (ing: Confussion Matrix) kullanılır.

		Tahmin edilen sonuçlar	
		Doğru Pozitif	Yanlış Negatif
Gerçek sonuçlar	Doğru Pozitif	Doğru Pozitif	Yanlış Negatif
	Yanlış Pozitif	Yanlış Pozitif	Doğru Negatif

Şekil 2.10 Karmaşıklık Matrisi

Yukarıdaki matriste pozitif ve negatif alanlar doğru yanlış temsil etmezler, ağın ayırmak istediği sınıfları temsil ederler. Doğru Pozitif (DP) ve Doğru Negatif (DN) ağın doğru tahmin yaptığı, Yanlış Pozitif (YP) ve Yanlış Negatif (YN) ağın yanlış tahmin ettiği adedi tutar. Örneğin; bir veri kümesindeki görüntülerde bisiklet mi yoksa motosiklet mi olduğunu tahmin etmeye çalışan bir model düşünelim. Karmaşıklık matrisine göre pozitifleri bisiklet, negatifleri motosiklet olarak ele alalım. DP ve YN bisiklet ve motosiklet için doğru tahmin edilen sayıları gösterir. YP ve YN ise bisiklet ve motosiklet için yapılan yanlış tahminleri tutmaktadır.

1.4.1. Doğruluk

Doğruluk [22], Denklem 2.4'te belirtildiği gibi, modelin doğru tahmin sayısının toplam sayıya oranı ile hesaplanır. Bu skor 0 ile 1 arasında sonuç üretir ve sonuç büyüdükçe modelin o kadar başarılı olduğu kabul edilir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (2.4)$$

1.4.2. Duyarlılık

Dengesiz dađılan deđiřkeler iin dikkate alınan bir deđerlendirme metriđidir. Denklem 2.5'te belirtildiđi gibi duyarlılık [23], pozitif olarak tahmin etmemiz gerekenlerin ne kadarını pozitif olarak tahmin ettiđimizin ölçütünü verir. Bařarım iin deđerinin yüksek olması gerekmektedir.

$$Duyarlilik(Recall) = \frac{DP}{DP + YN} \quad (2.5)$$

1.4.3. Kesinlik

Kesinlik [23], duyarlılık gibi dengesiz dađılan deđiřkenlerin deđerini ortaya ıkarmak iin kullanılan bir metriktir. Pozitif olarak tahmin ettiđimiz deđerlerin gerekte ka tanesinin pozitif olduđunu gösterir, Denklem 2.6'da kesinlik hesabına ait eřitlik verilmektedir. Bu metrik Yanlıř Pozitif tahminlerinin önemli olduđu durumlarda kullanılır. Örneđin, tümör ieren görüntü kümesi ele alınırrsa, kanserli doku sađlıklı olarak tahmin edilirse, bu durumda hayati riski bulunan bir tahmin yapılmıř olur. Bu gibi durumlarda kesinlik deđerinin model seiminde önemi büyüktür.

$$Kesinlik(Precision) = \frac{DP}{DP + YP} \quad (2.6)$$

1.4.4. F1 Skoru

F1 skoru [24], kesinlik ve duyarlılık deđerlerinin harmonik ortalamasını verir (Denklem 2.7). Harmonik ortalama sayesinde uç noktalar göz ardı edilmemektedir. Kesinlik ve duyarlılık gibi tek bir hata deđil tüm hata maliyetlerini ieren bir deđerlendirme metriđidir. Ayrıca eřit dađılmayan veri setlerinde de dođru deđerler vermektedir.

$$F1\ skoru = 2 * \frac{Kesinlik + Duyarlilik}{Kesinlik * Duyarlilik} \quad (2.7)$$

1.4.5. Zar Katsayısı

Zar katsayısı (ing: dice coefficient) [25], model tahmini ve gerçek referans alanın örtüşme alanının her iki görüntüdeki toplam piksel sayısına oranını veren bir metriktir (Denklem 2.8).

$$\text{Zar Katsayısı} = \frac{\text{Kesişen alan}}{\text{İki görüntüdeki toplam piksel sayısı}} \quad (2.8)$$

1.4.6. İkili Çapraz Entropi

İkili çapraz entropi [26], ikili sınıflandırma problemlerinde kullanılan bir kayıp fonksiyonudur. İkili sınıflandırma problemi, çıktısı yalnızca iki seçenekten oluşan problemlerdir. Bu fonksiyon, tahmin edilen olasılıkları, 0 veya 1 lerden oluşan gerçek çıktı değerleri ile karşılaştırır. Bu olasılıkların, beklenen değere olan uzaklıklarına göre bir skor hesaplanır. Bu gerçek değere ne kadar yakın veya uzak olduğu anlamına gelir.

$$\text{Kayıp} = -\frac{1}{N} \sum_{i=1}^N y_i * \log(p_i) + (1 - y_i) * \log(1 - p_i) \quad (2.9)$$

Denklem 2.9'da ifade edilen N çıktı büyüklüğünü, p_i bir sınıfa ait olma olasılığı, $(1-p_i)$ bir diğer sınıfa ait olma olasılığıdır. Veri hangi sınıfa aitse o kısım aktif olur, formülün diğer kısmı sıfırlanır. Bu şekilde çapraz entropi hesaplanır.

1.4.7. Kesişimlerin Birleşimi

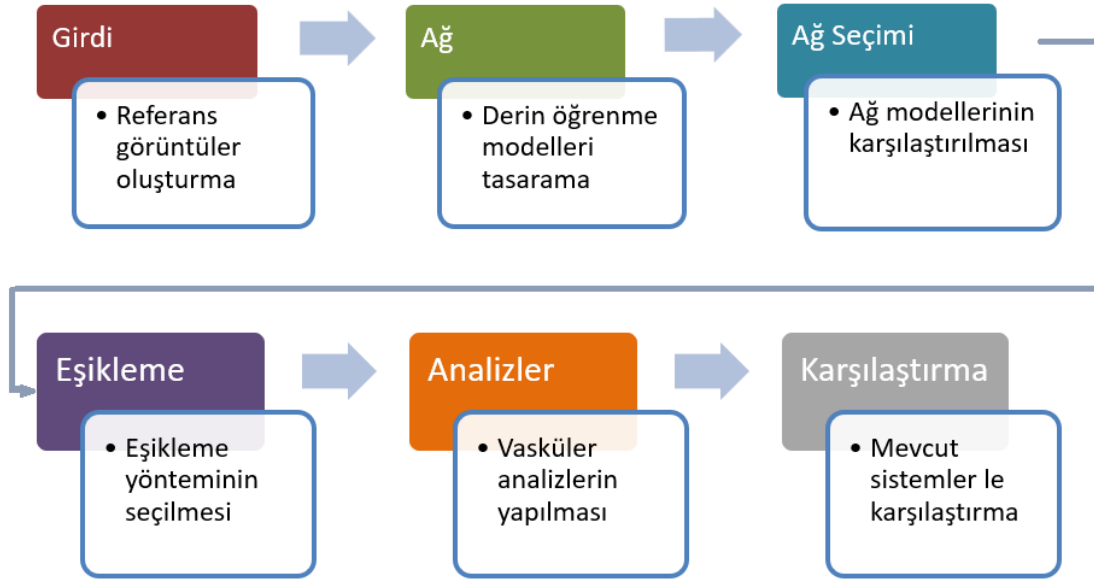
Kesişimlerin birleşimi (ing: Intersection Over Union- IoU) [26], gerçek referans değer ile modelin tahmin ettiği sonucun kesiştikleri alanın (ing: intersection) toplam birleşim (ing: union) alanına bölümü olarak hesaplanır (Denklem 2.10). Çakışma bölgesinin büyük olması IoU değerinin yüksek olması anlamına gelir.

$$\text{IoU} = \frac{\text{Kesişen alan}}{\text{İki alanın birleşimi}} \quad (2.10)$$

İKİNCİ BÖLÜM

2. DENEYSEL ÇALIŞMALAR

Tez çalışmasında kullanılan veri seti, Koç Üniversitesi Translasyonel Tıp Araştırma Enstitüsü laboratuvarındaki araştırmacılar tarafından, multifoton mikroskobu ile elde edilmiştir. Elde edilen veri seti için öncelikle manuel olarak referans görüntüler oluşturulmuştur. Üç farklı derin öğrenme algoritması (Otomatik kodlayıcı, U-Net, ResNet+U-Net) karşılaştırılarak en iyi bölütleme yöntemi seçilmiştir. Bölütlenmiş görüntüleri analiz edebilmek için ikilileştirme yöntemleri karşılaştırılarak en başarılı ikilileştirme yöntemi belirlenmiş ve son görüntüler üzerinde vasküler analizler yapılmıştır. Yapılan deneylerin sayısal sonuçları verilerek bu sonuçların değerlendirilmesi yapılmıştır. Ayrıca benzer uygulamalar ile karşılaştırılması sunulmaktadır (bkz. Şekil 3.1).



Şekil 3.1 Genel Akış Diyagramı

Bu bölümde kullanılan veri setleri ve çalışmada geliştirilen üç evrişimsel derin öğrenme sinir ağı olan; otomatik kodlayıcı, ResNet+U-Net ve U-Net modellerinin detayları açıklanmaktadır. Bu ağları kullanılarak beyin vasküler görüntülerin otomatik bölütlenmesi yapılmıştır. Bölütlenmiş vasküler görüntüler üzerinde ikilileştirme

metotları denenerek en iyi sonucu veren metot seçilmiştir. Son olarak elde edilen bölütlenmiş görüntüler üzerinde yapılan analiz sonuçları paylaşılmıştır.

2.1. MODELLER


Geliştirilen bütün modeller için ağlara girdi olarak 512×512 boyutunda medikal görüntüler verilmiştir. Bütün katmanlarda evrişim için kullanılan filtre boyutu 3×3 olarak belirlenmiştir. Bu değer transpozu alınmış evrişim katmanları için 2×2 ve son evrişim katmanlarında bölütleme haritasını elde etmek için 1×1 olarak değişmektedir. Evrişim katmanlarında aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Fakat son evrişim katmanlarında çıktıda tahmin edilen piksel değerinin 0 ile 1 arasında bir değer olmasını sağlamak amacıyla bu aktivasyon fonksiyonu Sigmoid olarak değiştirilmiştir. He normalizasyonu kullanılarak filtre matrisinin ağırlıkları hesaplanmıştır. Oluşturulan ağların ortak özellikleri şu şekilde belirlenmiştir: *{Optimizasyon algoritması (ing: optimizer): Adam, epoch: 50, kayıp fonksiyonu (ing: loss): ikili çapraz entropi (ing: binary cross entropy), değerlendirme metrikleri: doğruluk (ing: accuracy), f1-skoru (ing: f1-score), duyarlılık (ing: recall), kesinlik (ing: precision), öğrenme oranı (ing: learning rate) = 0.0001}*.

2.1.1. Otomatik Kodlayıcı (AutoEncoder)

İlk modelimizde Evrişimsel Sinir Ağı modellerinden otomatik kodlayıcı ve çözücü mimarisi kullanılmıştır. Bu model, çok boyutlu bilgileri önce sıkıştırıp boyutunu küçültmek sonra sıkıştırılmış veriyi yeniden yapılandırarak açmak/boyutunu artırmak için kullanılır. Otomatik kodlayıcı ve çözücü ağının hedef n boyutlu bir özellik vektörünü en az kayıp ile daha küçük bir boyutlu vektöre düşürmektir. Modelde çıkış katmanındaki düğüm sayısı, giriş katmanındaki düğüm sayısı ile eşit olmalıdır. Otomatik kodlayıcı modeli iki kısımdan oluşur: Kodlayıcı (ing: Encoder) ve Kod Çözücü (ing: Decoder). Kodlayıcı giriş ile gizli kat arasına denilmektedir. Gizli katmanın sonucu için giriş katmanındaki bilgilerin daha küçük boyutlara sahip bir uzaya iz düşürülmüş halidir. Kod çözücü ise gizli katman ile çıkış katmanı arasına denir. Kod çözücü, boyutu azaltılmış gizli katmanın boyutunu çoğaltır ardından yeniden yapılandırarak çıkış katmanının oluşumunu sağlar. Otomatik kodlayıcı modelini derin öğrenme modeli haline dönüştürmek için, modelin son tabakasına çözülen soruna uygun

olan bir öğrenme katmanını eklenmelidir. Otomatik kodlayıcı modeli ile oluşturulan derin öğrenme makinaları, görüntü bölütleme algoritmalarında kullanılmaktadır [27].

Tez kapsamında oluşturulan Şekil 3.2’de mimarisi verilen otomatik kodlayıcı modeli dokuz evrişim katmanından oluşmaktadır. İlk dört katman kodlayıcı bölümünde, son beş katman kod çözücü bölümünde bulunur. İlk adımda 16 özellik haritası ile oluşturulmuş ve kodlayıcının her katmanında özellik haritası sayısı iki katına çıkarılarak ilerletilmiştir. Son katmanı Batch normalizasyonu, 2×2 ’ lik maksimum ortaklama işlemi (adım değeri=2) ile aşağı örnekleme (ing: down sampling) ve aşırı öğrenmeyi (ing: overfitting) önlemek için 0.5 oranında iletim sönümü (ing: dropout) katmanları izlemiştir. Kod çözücü kısmında ise 128 özellik haritası ile oluşturulmuş ve 4 katmanda özellik sayısı yarıya indirilmiştir. Son katmanı Batch normalizasyonu ve yukarı örnekleme (ing: up sampling) katmanları izlemiştir.

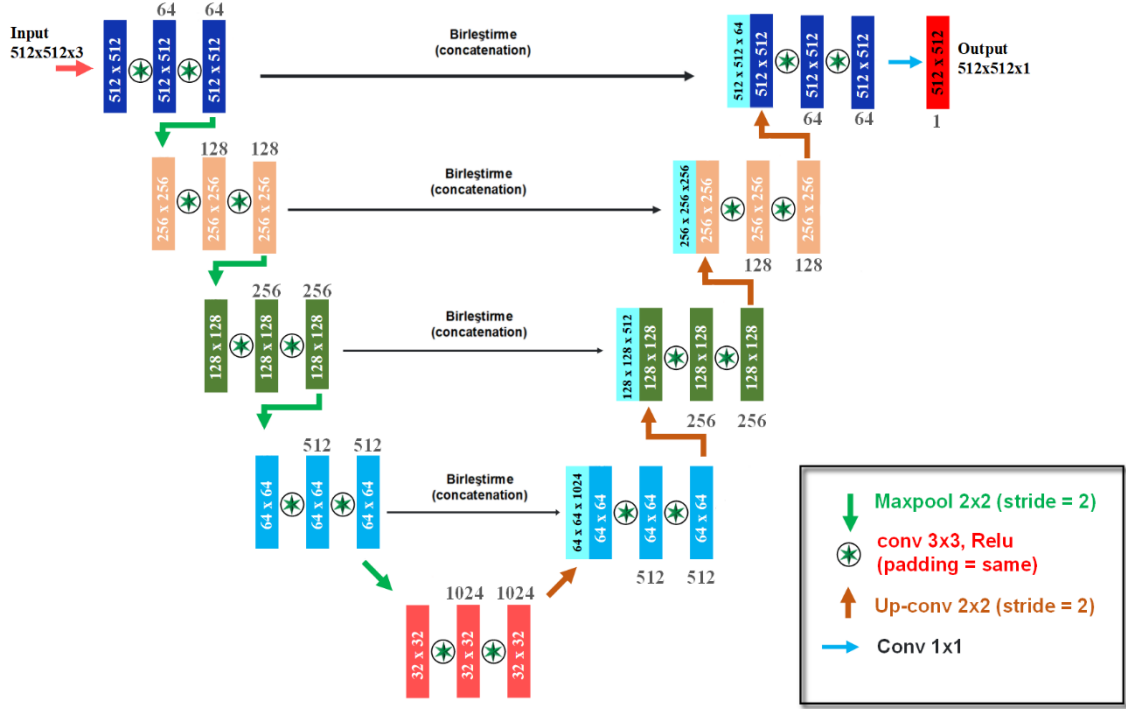


Şekil 3.2 Otomatik kodlayıcı sinir ağının ağ mimarisi

2.1.2. U-Net

İkinci model olarak medikal görüntülerin bölütlenmesinde yüksek bir başarı oranı sunan U-Net derin öğrenme sinir ağı mimarisi kullanılmıştır [28]. Şekil 3.3’ de mimarisi verilen model iki kısımdan oluşmaktadır: ilk kısım küçülme-daralma yolu, ikinci kısım büyüme-genişleme yoludur. Küçülme yolunda, 3×3 ’lük iki tane evrişimin tekrarlanarak katmanlar boyunca giriş bilgisinin boyutunun azaltılmasından oluşur. Giriş katından çıkarılan özellik sayısı 64’ tür ve bu rakam daralma yolunda her adımda iki katına çıkarılır. Küçülme kısmında 2×2 ’lik aşağı örnekleme ve maksimum ortaklama işlemi (adım değeri =2) yapılır. Kod çözücü-genişleme yolunun her adımında ise 2×2 ’lik yukarı örnekleme yapılır ve elde edilen özellik kanalları, aynı basamakta bulunan küçülme yolundaki özellik kanalları ile birleştirilir (ing: concatenation). Her

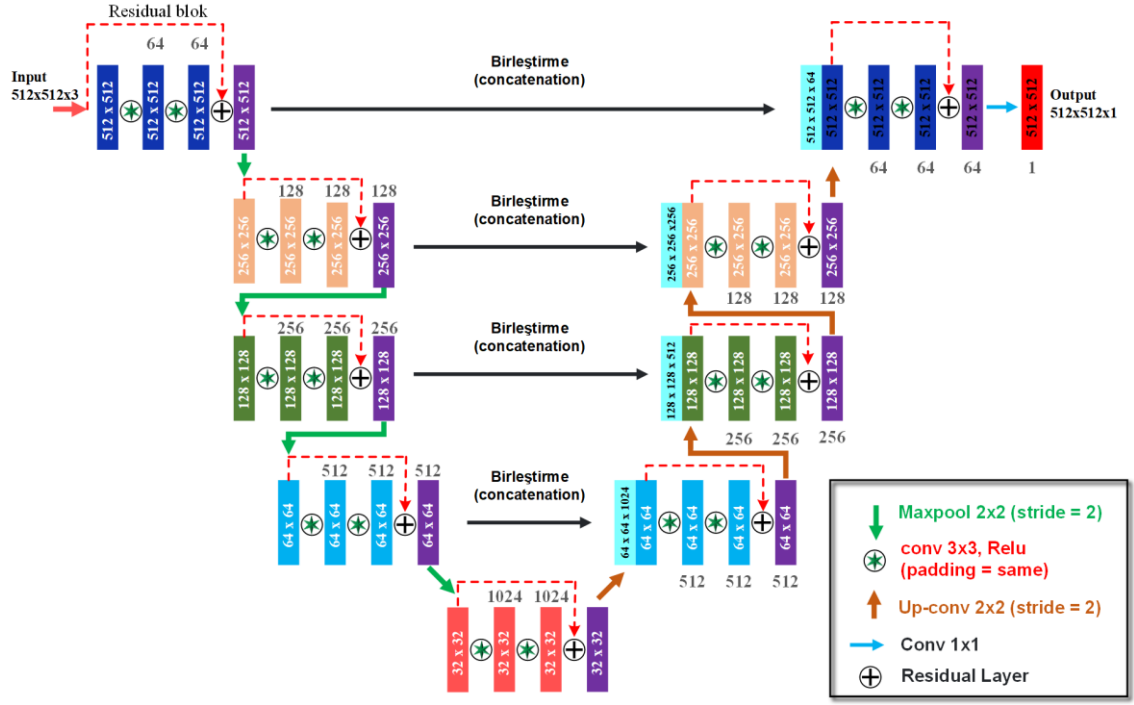
yukarı örnekle yapıldıktan sonra, özellik sayısı yarıya bölüldüğü için büyüme yolu ile küçülme yolunun simetrik olduğu söylenebilir.



Şekil 3.3 U-Net evrişimsel sinir ağının ağ mimarisi

2.1.3. ResNet+U-Net

ResNet+U-Net, ResNet ve U-Net evrişimsel sinir ağlarının beraber kullanılmasıyla oluşan ağ mimarisidir. Evrişimsel sinir ağlarında katman sayısının artmasıyla ağ derinleşir ve aşırı öğrenme gerçekleşir. Aşırı öğrenme (ing: overfitting) ağın parametrelerini ezberlemesi durumudur. Bu da test doğruluğunun düşmesine sebep olur ve eğitim hatasının düşmesi yerine artmasına yol açar. ResNet-Artık Ağ [29] modelinde artık blok olarak katmanlar bulunur. Bu katmanlar test doğruluğunun düşmesini engellemek amacıyla kullanılır. Artık bloklar, giriş verisinin bir atlama bağlantısı ile direk ağın çıkışına eklenmesinden elde edilen bloklardır. Bu bloklar sayesinde kaybolan gradyan sorununun olma ihtimali önlenmiş olur. Kaybolan gradyan sorunu bazı durumlarda eğimin kaybolacak kadar küçülmesinden kaynaklı ağırlık değerlerinin değiştirilmesini önemli bir şekilde engellemesi durumudur.



Şekil 3.4 ResNet ve U-Net evrişimsel sinir ağlarının birlikte kullanılarak oluşturulduğu ağ mimarisi

İkinci modeldeki U-Net ağ mimarisinin büyüme ve küçülme yolundaki her evrişim katmanından sonra, evrişim sonucu artık blok olarak adlandırılan bir önceki katmanın çıktısı ile birleştirilerek oluşturulur. Bu çalışma kapsamında ResNet ve U-Net ağlarının birleştirilmesi ile oluşturulan hibrit ağ mimarisine ait model Şekil 3.4' te gösterilmiştir


2.1. VERİ SETİ

Bu çalışmada, VESSEINN, KUVESG ve KUVESR olarak adlandırılan 3 farklı veri seti ile deneyler yapılmıştır. Her veri setindeki görüntü sayıları ve boyutları Tablo 3.1 de verilmiştir.

Tablo 3.1 Veri setleri özellikleri


Veri Seti	Görüntü Adedi	Boyut
VESSEINN	179	512 x 512
KUVESG	156	512 x 512
KUVESR	60	512 x 512

VESSEINN olarak adlandırılan birinci veri seti, hacimsel beyin damar görüntülerinden oluşmaktadır ve iki foton mikroskopisi kullanılarak alınmıştır [30]. Veri seti insan skuamöz hücreli karsinom tümörleri ve fare korteksi görüntüleri içeren toplamda 12 adet hacimsel yığından oluşmaktadır. Tez çalışmada 512×512 boyutlu fare korteks görüntülerinden 9 tane yığından toplam 179 adet görüntü ile çalışılmıştır. Bu görüntü setine ait görüntüler Şekil 3.5 'te gösterilmektedir. Veri seti tek kanallı olup piksel değerleri 0-255 arasında olan gri tonlamalı görüntülerdir.




Şekil 3.5 VesseINN veri setine ait görüntüler

İkinci veri seti olarak KUVESG olarak isimlendirdiğimiz multifoton mikroskopundan alınan fare korteks görüntüleridir. Bu veri seti 1024×1024 boyutlu 39 adet görüntüden oluşmaktadır. Her bir görüntü 4 eşit parçaya bölünerek 156 adet 512×512 boyutundan görüntüler elde edilmiştir. Bu veri setine ait birkaç örnek Şekil 3.6' de gösterilmektedir.



Şekil 3.6 KUVESG veri seti örnek görüntüler

Üçüncü veri seti olarak Şekil 3.7’de örnekleri sunulan KUVESSR veri seti kullanılmıştır. Bu veri setinde 60 adet 512 x 512 boyutlu görüntü bulunmaktadır. KUVESSR görüntüleri multifoton mikroskobundan alınmış fare korteks görüntüleridir.



Şekil 3.7 KUVESSR veri seti örnek görüntüler

Mevcut görüntü miktarı derin öğrenme yöntemlerinin eğitimi için yetersiz kalmaktadır. Bu nedenle veri çoğaltma işlemi yapılmıştır. Veriyi çoğaltmak amacıyla görüntülere çevirme ve döndürme işlemleri uygulanmıştır. Görüntüler dikey ve yatay eksende çevrilerek simetriği alınmıştır. Ayrıca görüntülerin piksel değerlerini bozmamak amacıyla görüntüler 90, 180, 270 derece döndürülmüştür. Yapılan çoğaltma işlemleri sonucunda eğitim için ağlara verilen görüntü miktarları altı katına çıkarılmıştır. Test bölümünde veri artış sayıları ile ilgili detaylı bilgi verilmiştir.

2.2. İKİLİLEŞTİRME

Ağ modellerinin son katmanında aktivasyon fonksiyonu olarak kullanılan sigmoid fonksiyonu sonucu [0-1] arasında üretilen değer gri tonlamalı bir görüntü çıktısını oluşturur. Bu görüntüler üzerinde analiz yapabilmek, iskeletini çıkabilmek için piksel değerlerini 0 ve 1’lerden oluşan ikili görüntülere çevirmemiz gerekmektedir. Bu işleme ikilileştirme (ing: binarization) denir. İkilileştirme için bir eşik değeri belirlenir, eşik değerinden daha yüksek piksel değerleri 1’e atanırken, daha düşük piksel değerleri 0’a atanır. Eşik değerini hesaplamak için birden fazla yöntem bulunmaktadır. Bunlar; Isodata, Li, Mean, Minimum, Otsu, Triangle ve Yen metotlarıdır. Bu metotlar arasında görüntüdeki vasküler alanları belirgin hale getirerek, gürültü seviyesindeki ufak noktaları silerek bir eşikleme yapılması daha iyi sonuç verdiğini göstermektedir. Isodata

eşikleme yönteminde [31];görüntüdeki piksel değerleri aralığında bir t değerinin belirlenmesi gerekmektedir, görüntüdeki gri değeri t ‘den küçük veya ona eşit olan tüm piksellerin ortalamasına m_L , gri değeri t ‘den büyük olan tüm piksellerin ortalamasına m_H diyelim. Isodata yöntemi bu iki değer in ortalaması olarak belirlenir ve Denklem 3.11’ de bu hesap görülmektedir.


$$t = \frac{m_L + m_H}{2} \quad (3.11)$$

1998 yılına kadar Isodata metodunda olduğu gibi bu eşiği bulmak için tüm olası eşikleri denemek ve ardından en küçük çapraz entropiye sahip olanı seçmek gerekiyordu. Li metodu [32] bu noktada çapraz entropinin eğimini kullanarak en uygun değer eşik değerini daha hızlı bulan yinelemeli bir yöntemdir. Ortalama (ing: mean) eşikleme yöntemi [33], gri tonlamalı görüntünün ortalama değerini eşik değeri olarak ayarlayan bir yöntemdir. Minimum yönteminde [34], girilen görüntünün histogramı hesaplanır ve histogram grafiğinde yalnızca iki maksimum değer kalana kadar düzleştirilir. İki maksimum değer arasındaki minimum değeri eşik değeri olarak alır. Otsu yöntemi [35] olası tüm eşik değerleri için (0-255) sınıf-ıçi varyans değerleri hesaplanır, bulunan varyans değerlerinden en küçük olan değeri ikilileştirme için eşik değeri olarak seçilir. Triangle (Üçgen) yöntemi [36], görüntünün histogramın tepe noktası ile histogramın en uzak ucu arasında bir çizgi oluşturur. Eşik değeri, çizgi ile histogram arasındaki maksimum uzaklık noktasıdır. Yen yöntemi [37], entropi ölçümlerine hesaplama açısından daha verimli bir alternatif olarak maksimum korelasyon kriterine dayalı eşik değeri üretir.

Tablo 3.2 İkileştirme yöntemlerinin IoU değerleri

Yöntemler	IoU
IsoData	0.6878
Li	0.6735
Mean	0.6550
Minimum	0.6875
Otsu	0.6878
Triangle	0.5459
Yen	0.5806

Çalışmanın sonraki bölümünde yapılacak analizler için kullanılacak eşikleme metodunun seçimi kesişimlerin birleşimi (IoU) değerlendirme metriği kullanılarak belirlenmiştir. ResNet+U-Net modelinin tahmin ettiği 34 adet test görüntüsünün referans değerleri ile kesişimlerinin birleşimi değerlendirme sonuçları Tablo 3.1’de verilmektedir. Tablo 3.2 incelendiğinde IsoData, Minimum ve Otsu metotlarının en iyi sonuçları verdiği görülmektedir. Sonraki bölümde en yüksek sonucu veren Otsu metodu kullanılarak ikilileştirilmiş görüntüler ile analizler yapılmasına karar verilmiştir.



Şekil 3.8 Fare beyin vasküler test verilerinin (a) orjnal girdi görüntüsü, (b) Li yöntemi ile eşiklenmiş görüntü, (c) Isodata yöntemi ile eşiklenmiş görüntü, (d) gerçek referans görüntü, (e) Minimum yöntemi ile eşiklenmiş görünüşü, (f) Otsu yöntemi ile eşiklenmiş görüntü, (g) Mean yöntemi ile eşiklenmiş görüntü, (h) triangle yöntemi ile eşiklenmiş görüntü, (j) Yen yöntemi ile eşiklenmiş görüntü


Şekil 3.8’de ikilileştirme yöntemlerinin örnek bir uygulaması verilmektedir. Burada kırmızı ile işaretlenmiş örnek bir test görüntüsü bulunmaktadır. Yeşil ile işaretlenmiş alan ise test görüntüsünün referans görüntüsü verilmiştir. Diğer alanlar test görüntüsünün farklı eşikleme yöntemleri ile eşiklenmiş halini vermektedir.

2.3. VASKÜLER ANALİZLER

Vasküler analizler, beyin damar görüntüleri üzerinde çeşitli anormal durumların (örneğin; inme, fonksiyon kaybı, tümör vs.) tespit edilmesinde önemli faktörler olarak kullanılmaktadır. Medikal alanda çalışan uzmanların vasküler görüntülerdeki damar yoğunluğu, damar uzunluğu gibi sayısal sonuçlara bakarak ilgili bölgede fonksiyon hasarı veya kayıp durumları gibi anormal durumlara yönelik yorumlar yapabilmesi açısından önemlidir.

2.3.1. Vasküler Alan Fraksiyonu


Vasküler alan fraksiyonu, ilgili alandaki damar yoğunluğunun belirlenmesini sağlayan bir faktördür. Vasküler alan fraksiyonunu (ing: vascular area fraction-vaf) hesaplariken, ikili tonlamadaki görüntüde değeri 1 olan piksellerinin sayısını, görüntüdeki tüm piksel sayısına oranlanarak hesaplanmıştır. Bu yöntemle görüntüdeki vasküler yoğunluğun yüzdesi bulunmuştur. Örneğin Şekil 3.9’da (a) görüntüsündeki vasküler alan fraksiyonu %21 iken, (b) görüntüsünün vasküler alan fraksiyonu %40’tır.



Şekil 3.9 (a) ve (b) Vasküler alan fraksiyonu için örnek görüntüler


2.3.2. Vasküler Dallanma Sayısı

Görüntülerdeki damarların dallanma sayısının (ing: branch number) hesabı için öncelikle görüntünün iskeletinin çıkarılması gerekmektedir. Görüntüyü damarların merkez çizgisi üzerinde yapısını değiştirmeden bir piksel genişliğinde eğimli çizgilere indirgeyerek görüntünün iskeleti elde edildi. Şekil 3.10’da örnek vasküler görüntü ve bu görüntüsünün iskeleti verilmiştir.



Şekil 3.10 (a) Örnek vasküler görüntü, (b) Örnek vasküler görüntünün test görüntüsü


İskelet görüntüleri üzerinde bölütlenmiş damar iskeletinde eğer pikselin 1 değerinde 2’den fazla komşusu varsa burası dallanma noktası olarak belirlenmiştir. Şekil 3.11’de dallanma noktaları sarı ile işaretlenmiştir.



Şekil 3.11 Vasküler dallanma noktaları

2.3.3. Vasküler Uç Nokta Sayısı


İskelet görüntüleri üzerinde damarların takibinde eğer pikselin 1 değerinde bir tane komşusu varsa orası uç nokta (ing: end point) olarak adlandırılır. Şekil 3.12’da vasküler uç noktalar mavi yıldız ile işaretlenmiştir.



Şekil 3.12 Vasküler uç noktalar

2.3.4. Vasküler Uzunluk

İskelet görüntüsü üzerindeki damarların dallanma noktalarından uç noktalarına olan mesafeler piksel sayısı ile belirlenmiştir. Her damarın ucuna bu uzunluk bilgisi yazılarak Şekil 3.13’te gösterilmiştir. Görüntüdeki damar sayısı bilindiği için, toplam damar uzunluğunun damar sayısına bölünmesiyle ortalama damar uzunluğu bulabilir.



Şekil 3.13 Vasküler uzunluklar

ÜÇÜNCÜ BÖLÜM

3. BULGULAR VE TARTIŞMA

Bu bölümde yapılan deneyler, deneylerin yapıldığı ortam ve deneylerin sayısal sonuçları verilerek bu sonuçların değerlendirilmesi yapılmıştır. Ayrıca damarlar üzerinde aynı testleri uygulayan uygulamalar ile karşılaştırılması sunulmaktadır.

Tez kapsamı boyunca yapılan deneyler 3 bölümden oluşmaktadır. İlk bölümde damar bölütlemesi için VESSEINN veri seti kullanılarak ağ mimarileri karşılaştırılmıştır. İkinci bölümde benzer iki veri seti olan VESSEINN ve KUVESSESSG birleştirilerek bölütleme işlemi yapılmış ve vasküler analizler tamamlanmıştır. Üçüncü kısımda farklı bir veri seti olan KUVESSESSR üzerindeki çalışmanın sonuçları verilmiştir.

Yapılan tez çalışmasında tasarlanan ağ modellerinin eğitilmesi ve test edilebilmesi için Google'ın sunmuş olduğu Google Colab Pro sanal servisi kullanılmıştır. Bu sanal servisin sunduğu donanım özellikleri; ekran kartı: Tesla T4 GPU -16 GB, bellek: 25 GB, depolama: 167 GB ve 24 saat bağlantı şeklindedir.

Programlama dili olarak Python 3.7 versiyonu kullanılmıştır. Derin öğrenme modellerinin geliştirilip test edilmesi için Tensorflow ve Keras kütüphanelerinin 2.7 versiyonları kullanılmıştır.

3.1. VESSEINN VERİ SETİ SONUÇLARI

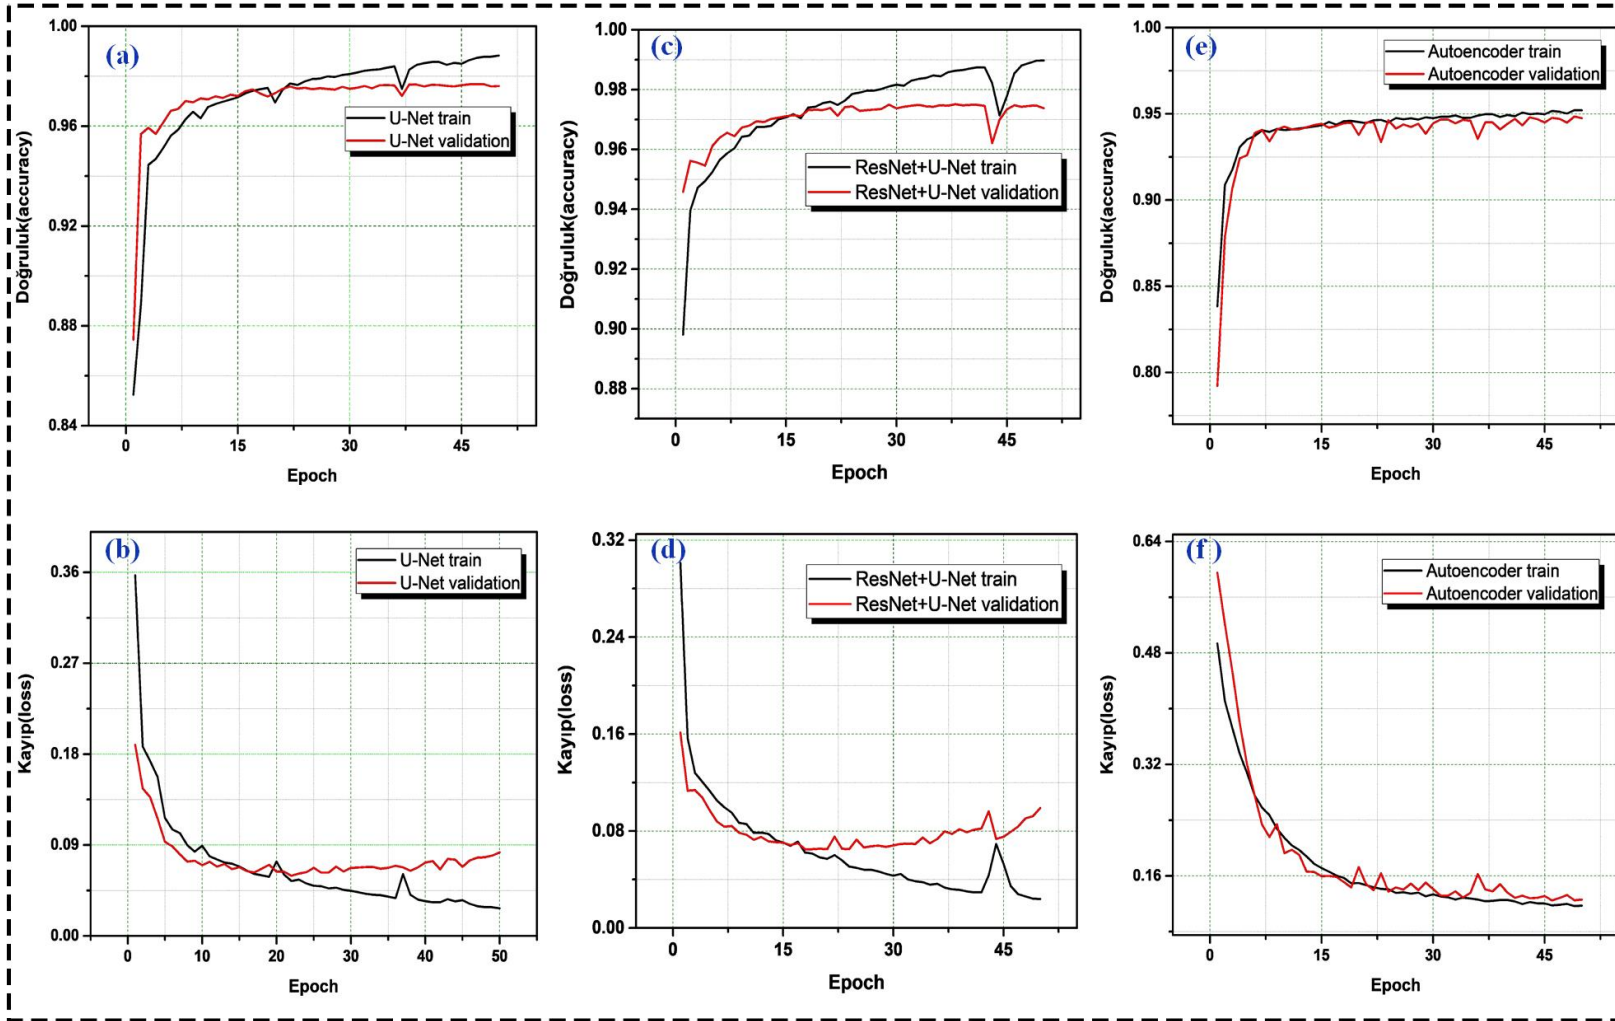
Yapılan tez çalışmasında kullanılan üç farklı derin öğrenme yöntemi ile VESSEINN veri setindeki görüntülerin otomatik olarak bölütlenmesi sağlanmıştır. Veri seti Racz ve arkadaşları tarafından yapılan [38] farklı sayıda veri içeren setler ve farklı ayırma oranları (50,60,70,80) ile ayrılarak yapılan testlerde eğitim oranının arttıkça modelin performansının arttığı gözlenmiştir. Bu çalışmaya dayanarak veri seti %80 eğitim %20 olacak şekilde rastgele ayrılmıştır. Ayrılan eğitim görüntüleri veri seti çoğaltma yöntemleri ile altı katına çıkarılarak 859 adet eğitim verisi elde edilmiştir. Bu set kullanılarak üç ağ modeli de eğitilmiştir. Ağları test etmek için veri seti 10 farklı rassal değişken ile eğitim ve test olarak ayrılarak eğitilip, test işleminin de 10 defa tekrar edilmesi sonucunda performans değerlendirme metriklerinin ortalama değerleri Tablo 4.1'de sunulmuştur. Kullanılan performans değerlendirme metriklerinin (f1-skoru

(ing: f1-score), doğruluk (ing: accuracy), duyarlılık (ing: recall), kesinlik (ing: precision) hem eğitim aşaması sonucu ortalama değerleri hem de test aşaması sonucu ortalama değerleri Tablo 4.1’ de sunulmuştur. Eğitim ve test aşaması için en başarılı sonuçları sunan modeller eğitim için U-Net ağı, test için ResNet+U-Net olmuştur.

Tablo 4.1 Derin öğrenme sinir ağları modellerinin eğitim ve test verileri üzerinde elde edilen başarımlar

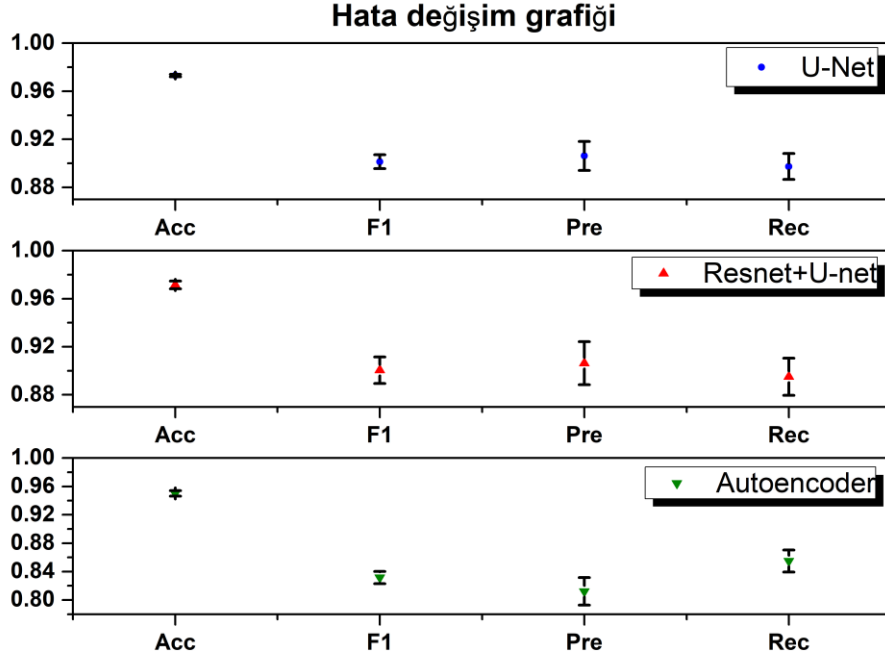
	Eğitim Verisi			Test Verisi		
	Otokodlayıcı	U-Net	ResNet+U-Net	Otokodlayıcı	U-Net	ResNet+U-Net
Doğruluk	0.9514	0.9884	0.9856	0.9501	0.9715	0.9731
f1-skoru	0.8283	0.9570	0.9454	0.8317	0.9005	0.9013
Kesinlik	0.8399	0.9596	0.9524	0.8122	0.9064	0.9065
Duyarlılık	0.8251	0.9550	0.9378	0.8548	0.8950	0.8973

Eğitim ve test aşamasında kullanılan değerlendirme metriklerine göre en düşük değerleri otomatik kodlayıcı ağı sunmaktadır. Bu durum otomatik kodlayıcı ağının özellik sayısının daha az olması ve yapısının daha az karmaşıklıkta olmasından kaynaklanmaktadır. Fakat model mimarisinde birleştirme adımları olmadığı için karşılaştırılan ağlar arasında en hızlı otomatik bölütleme yapan ağ mimarisidir. U-Net ve ResNet+U-Net ağları birbirlerine yakın sonuçlar göstermişlerdir. Bu iki ağ karşılaştırıldığında, eğitim sonuçlarına göre U-Net ağının performans metriklerinde az bir farkla da olsa daha iyi sonuçlar verdiği, fakat test sonuçlarına bakıldığında bu durumun tam tersi olduğu gözlenmektedir. Bunun sebebinin ResNet+U-Net ağının içerdiği atlama bağlantıları sayesinde olabileceği mümkün görülmüştür. Deneysel çalışmalar sonucunda eğitim ve doğrulama veri seti üzerindeki doğruluk ve kayıp değerlerinin epoch 'a (döngü) bağlı olarak yakınsama grafikleri, Şekil 4.1’ de görülmektedir. Şekil 4.1’deki grafikler incelendiğinde U-Net ve ResNet+U-Net modelleri 50 epoch 'da yakınsayarak benzer davranış sergiledikleri gözlemlenmiştir. Modellerin epoch sayısı artırıldığında performans parametrelerinin artışının durduğu gözlemlendiği için 50 epoch olarak çalıştırılmıştır. Bu Otokodlayıcı incelendiğinde 15 epoch 'da yakınsadığı görülsede daha düşük doğruluk değerlerine sahiptir. Aynı şekilde kayıp (ing: loss) grafiklerine bakıldığında eğitim kaybı grafiği U-Net ve ResNet+U-Net için daha az hata ile başlayarak sifira otokodlayıcıdan daha fazla yaklaşmışlardır, Kayıp fonksiyonlarının doğrulama (ing: validasyon) grafiğine bakıldığında 50 epoch sonucunda bütün ağların kayıp değerlerinin birbirlerine yakın değerler verdiği görülmektedir



Şekil 4.1 Damar segmentasyonu için üç CNN ağı ile elde edilen doğruluk değerinin epoch' a bağlı olarak yakınsama grafikleri

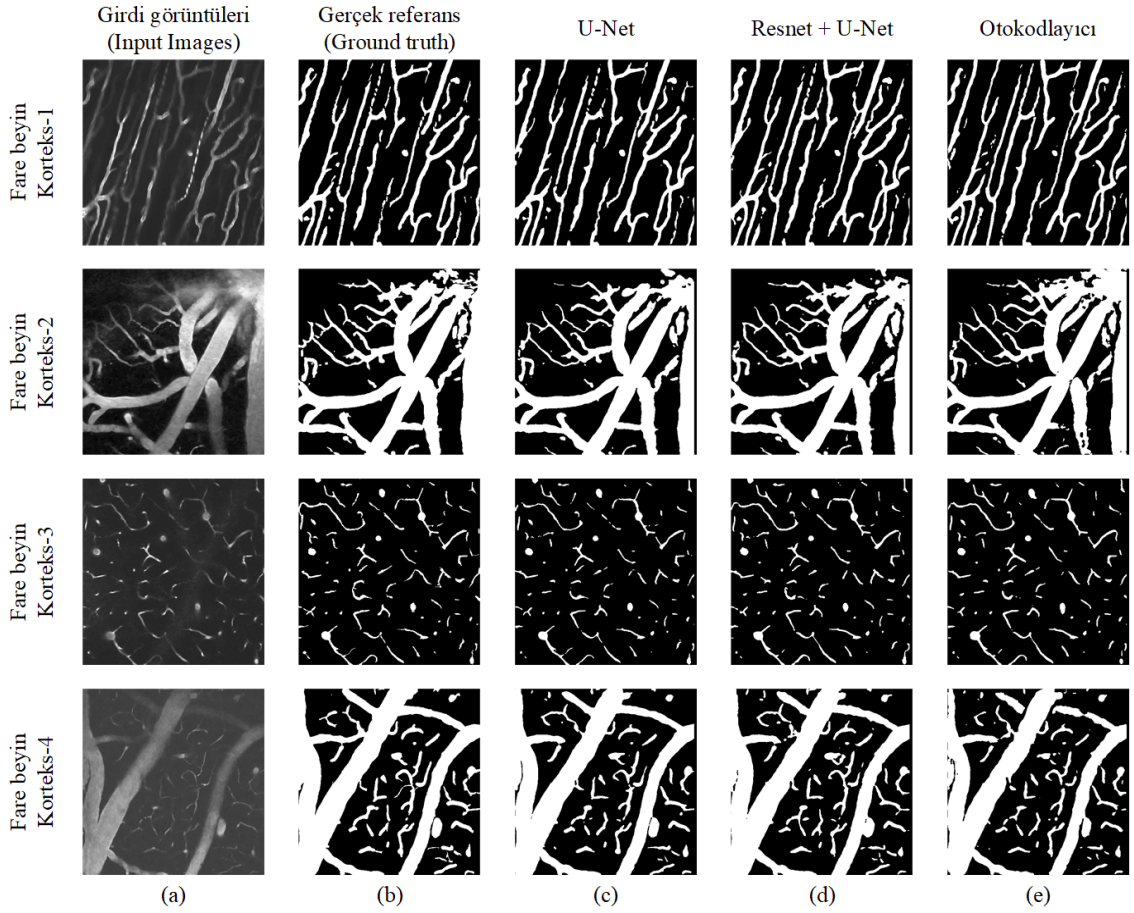
Şekil 4.2' de 10 defa rastgele ayrılma sonucu oluşan test görüntülerinin üç CNN ağının dört değerlendirme metriğine göre hata değişim grafikleri sunulmuştur. 10 defa çalıştırılması sonucu doğruluk değerlendirme metriğine göre standart sapmanın düşük olduğu görülmektedir.



Şekil 4.2 Yapay sinir ağlarının test hatalarının değişim grafiği

Şekil 4.3' de fare beyin vasküler test görüntülerinin gerçek referans görüntüleri ve tez kapsamında tasarlanan üç farklı ağ ile otomatik olarak bölütlenmiş görüntüleri sunulmaktadır. Şekil 4.3' de birinci sütunda orijinal girdi görüntüler, ikinci sütunda gerçek referans görüntüler (ing: ground truth), üçüncü sütunda U-Net sinir ağı ile bölütlenmiş görüntüler, dördüncü sütunda ResNet+U-Net ağı ile bölütlenmiş görüntüler, beşinci sütunda ise otomatik kodlayıcı ağı ile bölütlenmiş görüntüler yer almaktadır. Fare Beyin Korteks-2 görüntüsü incelendiğinde sağ üst köşedeki parlayan alanda otomatik kodlayıcı bölütleme işleminde yeterince başarılı olamamış ve damarları birleşik olarak bölütlemiştir, fakat U-Net ve ResNet+U-Net modelleri ile otomatik damar bölütlemeye referans değere daha yakın bir bölütleme sağlanmıştır. Aynı şekilde Fare Beyin Korteks-4 görüntüsü incelendiğinde görüntünün sol kenarında uzunlamasına

olan damarın otomatik kodlayıcı ile tahmininde eksiklikler mevcuttur, buna karşın diğer modellerin damarın içerisini referans görüntüdeki gibi doldurduğu görülmektedir. Her iki model için %97 oranında doğruluk değerine ulaşılmıştır. Bununla birlikte otomatik kodlayıcı ile elde edilen bölütlenmiş görüntülerde aynı başarıyı elde edilememiş ve doğruluk değeri %95'te kalmıştır.




Şekil 4.3 Dört adet fare beyin vasküler test verilerinin (a) orijinal girdi görüntüleri, (b) gerçek referans görüntüleri, (c) U-Net ile bölütlenmiş görüntüleri, (d) ResNet+U-Net ile bölütlenmiş görüntüleri, (e) otokodlayıcı ile bölütlenmiş görüntüleri

3.2. KUVESG + VESSEINN VERİ SETİ SONUÇLARI

Gerçekleştirilen analiz çalışmasında VESSEINN ve KUVESG veri kümelerindeki görüntüler benzer olduğundan iki veri seti birleştirilmiştir. VESSEINN veri kümesinden 179, KUVESG veri kümesinden 156 adet görüntü alınarak toplam 335 adet görüntü ile çalışılmıştır. Burada veriler %10 test, %90 eğitim verisi olarak rastgele (random state: 42) ayrılmıştır. 301 adet eğitim verisi eğitim için yetersiz olduğundan önceki bölümde bahsedilen veri çoğaltma yöntemleri ile 6 katına çıkarılarak 1806 adet veri elde edilmiştir. ResNet+U-Net mimarisi 512 x 512 boyutunda 1806 adet görüntü ile 50 epoch eğitilerek, test edilmiş ve %94,15 doğruluk, %83,42 zar katsayısı, %84,8 f1 skoru, %81,91 duyarlılık, %88 kesinlik test başarımları elde edilmiştir.


Ağın tahmin sonuçlarına Otsu ile ikilileştirme yapıldıktan sonra, Rust ve ark [39] tarafından Fiji aracı kullanılarak geliştirilen makro uygulaması çıktıları ile karşılaştırılmıştır. Karşılaştırma sonucu elde edilen değerler Tablo 4.2’de verilmiştir. İlk sütunda 34 adet test görüntüsü numaralandırılmıştır. Renklendirilmiş alanlarda; pembe alan Fiji ile yazılmış makronun orijinal test görüntüleri üzerinde ikilileştirme ile analiz değerlerini, ikinci toprak renkli alan tasarlanan ResNet+U-Net ağı ile bölütlenmiş görüntüler ile yapılan analiz değerlerini, üçüncü turuncu renkli alan ise test görüntülerinin gerçek referans görüntüleri üzerinde yapılan analizler sonucu referans değerlerini göstermektedir.

Görüntülerdeki gürültüler fazlaca yaygın olduğunda veya alınan beyin görüntü korteksin köşe kısmından alındığında damarlar net olarak görünmemektedir. Bu tip görüntüler için referans değer 0 olmalıdır. Tez çalışması kapsamında tasarlanan ResNet+U-Net ağı gürültüleri fazlaca yoğun olan görüntülerde piksel değerleri 0 olan görüntü tahmin etmektedir. Bu da damar bulunamadı anlamına gelmektedir. Ek A.1’de tabloda görüntülerin sayısal verileri verilmiştir. Bahsedilen gürültü oranı fazla örnek görüntülerden Test-5 ve Test-7 görüntüleri Şekil 4.4’te gösterilmiştir.

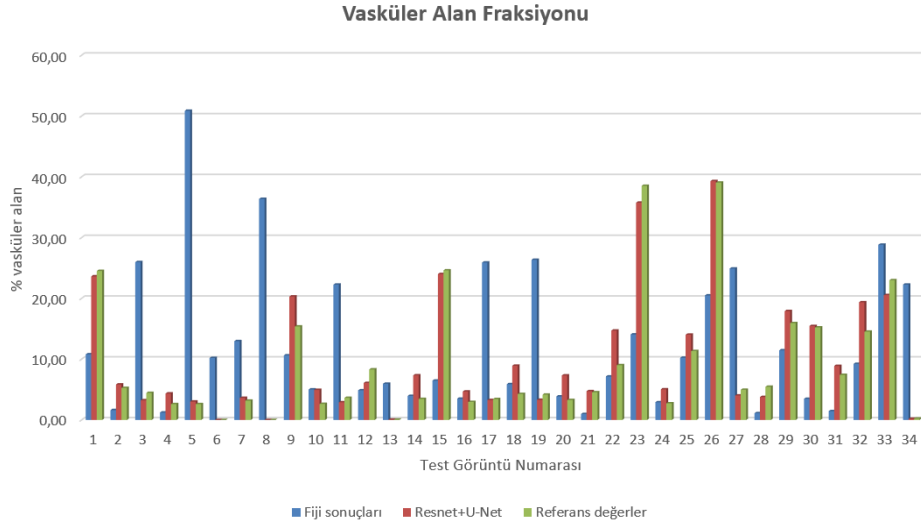


Şekil 4.4 (a, b) Örnek gürültülü test görüntüleri

Veri setindeki bazı test görüntülerinde birleşik tek bir damar bulunmaktadır. Damarlar arasındaki en yakın mesafenin hesaplanabilmesi için en az iki ayrı damar alanı bulunması gerekmektedir. Bu yüzden Angiotool uygulaması damarlar arasındaki en yakın mesafeyi hesaplayamamaktadır. Bahsedilen Test-3, Test-6 ve Test-9 numaralı görüntüler Şekil 4.5'te altında referans görüntüleri ile verilmiştir.




Şekil 4.5 (a) Test-3 görüntüsü, (b) Test-6 görüntüsü, (c) Test-9 görüntüsü test , (d) Test-3 görüntüsünün referans görüntüsü, (e) Test-6 görüntüsünün referans görüntüsü, (f) Test-9 görüntüsünün referans görüntüsü



Şekil 4.6 Test görüntülerinin vasküler alan fraksiyonu grafiği

Şekil 4.6'daki grafik incelendiğinde Fiji makrosu ile yapılan ikilileştirme işlemi sonucu bazı görüntülerde uç değerler verdiği görülmektedir. Test-5. ve Test-7. görüntülerin herhangi bir damarın belli olmadığı fazlaca gürültülü görüntülerdir.



Şekil 4.7 (a) Örnek test görüntüsü , (b) Fiji makrosu ile eşiklenmiş görüntü, (c) Referans görüntü

Fiji makrosunda görüntüdeki en düşük ve en yüksek piksel arasında otomatik eşikleme ile işlem yapıldığı için referans değerden oldukça uzak bir sonuç üretmektedir. Bu duruma örnek bir görüntü Şekil 4.7'de gösterilmektedir. Test-5. Ve Test-7. gibi uç değer veren gürültülü görüntüler hesaba katılmadığında yapılan analizlerin ortalama hata oranları Tablo 4.2' de verilmektedir. Bu tabloya göre ResNet+U-Net ağının ürettiği görüntüler ile yapılan testlerin daha başarılı sonuçlar ürettiği gözlenmektedir.

Tablo 4.2 Fiji makrosu ve ResNet+U-Net ağıının KUVESSEG + VESSEINN veri seti üzerinde vasküler analizlerin ortalama hata değerleri

Analizler	Ortalama Hata Oranı	
	Fiji makro	ResNet+U-Net
Vaf(%)	%73	%33
Dallanma noktası sayısı	%81	%47
Dal sayısı	%186	%29
Damar uzunluğu	%86	%10
Nnd	%42	%22
Nnd std	%44	%29

Aynı veri seti kullanılarak medikal alanda vasküler analizleri yapmak için sıklıkla kullanılan Angiotool [40] aracı ile karşılaştırma yapılmıştır. Angiotool uygulamasında analiz yapılmadan önce her test görüntüsüne uygun damar kalınlık oranını, görüntü eşikleme değerini ve boşluk doldurma miktarını el ile (ing: manuel) ayarlamak gerekmektedir. Aksi takdirde uygulamanın başta otomatik atadığı ilk parametre değerleri ile damar tayinini hatalı yapılmaktadır. Parametre değerleri ayarlandıktan sonra oluşan görüntü üzerinden analizler yapılmaktadır. Angiotool aracı ile yapılan analizler vasküler alan fraksiyonu, toplam vasküler uzunluk, dal sayısı, dallanma noktası/bağlantı noktası sayısı ve uç nokta sayısıdır. Analiz sonuçları Ek B.1’de tabloda verilmiştir. Bu sonuçlar incelendiğinde Angiotool uygulaması insan müdahalesi ile iyileştirildiğinde tez kapsamında geliştirilen insan müdahalesi gerektirmeyen tamamen otomatik çalışan uygulama ile yakın sonuçlar ürettiği gözlenmektedir. EK B.1’de bulunan tablodaki analiz sonuçları ile hata oranları hesaplanarak Tablo 4.3’ de gösterilmiştir. Referans görüntüleri ile hesaplanan hata oranları bize ResNet+U-Net ağı kullanarak tasarlanan uygulamanın Angiotool uygulamasına göre daha başarılı sonuçlar ürettiğini göstermektedir.


Tablo 4.3 Angiotool ile ResNet+U-Net ağıının KUVESSEG + VESSEINN veri seti üzerinde vasküler analizlerin ortalama hata değerleri

Analizler	Ortalama Hata Oranı	
	Angiotool	ResNet+U-Net
Vaf(%)	%63	%33
Dallanma noktası Sayısı	%72	%47
Dal sayısı	%50	%29
Uzunluk	%44	%10
Uç nokta sayısı	%69	%43

3.3. KUVESSR VERİ SETİ SONUÇLARI

KUVESSR veri seti ağımızın önceki veri setinden öğrenmiş olduğu gürültülerden farklı seviye ve frekansta gürültülere sahiptir. Dolayısı ile ağa KUVESSR görüntülerinden eklendiğinde eğitim doğruluğunun %80'e düştüğü ve diğer metriklerde de azalma gözlenmektedir. Ayrıca ağ test ettiğimizde gürültü seviyeleri yüksek tahminler üretmektedir.

Örneğin Şekil 4.8'de KUVESSR veri setinden birinci satırdaki orijinal görüntü KUVESSG ve VESSEINN veri setine benzer seviyede gürültüye sahip olduğu için ikinci sütunda bulunan tez çalışmasında kullanılan modelin tahmin sonucu üçüncü sütunda bulunan Fiji makrosuna göre iyi sonuç vermektedir. Fakat ikinci satırda bulunan orijinal görüntü ile model test edildiğinde ağın öğrendiğinden farklı seviyede gürültülere sahip olduğu için ikinci sütundaki tahmin Fiji makrosuna göre fazla gürültülü bir bölütleme yaptığı görülmektedir.



Şekil 4.8 (a) Orijinal örnek görüntüler, (b) İkileştirilmiş ResNet+U-Net tahmin görüntüleri, (c) Fiji makrosu tarafından eşiklenmiş görüntüler

SONUÇ VE GELECEK ÇALIŞMA

Otomatik bölütleme için ağ karşılaştırması ile en uygun ağın seçilmesi çalışmasında, fare beyin korteksindeki vasküler görüntülerin otomatik olarak bölütlenmesi için üç farklı evrimsel sinir ağı modelinin test görüntüleri üzerinde performanslarının karşılaştırılması amaçlanmıştır. Bu karşılaştırmalarda 4 farklı metrik (doğruluk, F1-skoru, kesinlik, duyarlılık) kullanılmıştır. Test sonuçları incelendiğinde en az başarıyı sağlayan ağın %95 test doğruluğu ile otokodlayıcı olduğu, U-Net ve ResNet+U-Net ağlarının %97 doğruluk ile birbirine yakın sonuçlar ürettiği gözlenmektedir [41].

Çalışmada elde edilen sonuçlar ile, beyin damar ağı yapısının otomatik bölütlenmesinde derin öğrenme sinir ağlarının kullanılması ile %97 doğruluk ve otomatik yapısıyla büyük bir performans artışının sağlandığı ve uzmana yardımcı olarak geliştirilmiş makine öğrenmesi tabanlı bir sistemin ortaya konulması sağlanmıştır. Buradan yola çıkarak bu çalışmanın, araştırmacıların tüm bir beynin mikrovasküler damar ağı yapısının üç boyutlu olarak görselleştirmesine olanak tanıyacak yapının oluşturulması için bir ön çalışma niteliğinde olduğu düşünülmektedir. Derin öğrenme sinir ağlarının karşılaştırılması sonucu en iyi otomatik damar ağı segmentasyonu sonuçlarını veren ResNet+U-Net ağ modelinin tahmin sonuçları tezin ileriki aşamalarındaki analizler için kullanılmıştır.

Derin öğrenme sinir ağından elde edilen tahmin sonuçlarından analiz yapılabilmesi için görüntülerin ikilileştirilmesi gerekmektedir. Burada eşikleme için en iyi yöntemi belirlemek amacıyla eşikleme algoritmaları test veri setini kullanarak test edilmiştir. İkileştirme yöntemlerinden literatürde en sık kullanılan Isodata, Li, Mean, Minimum, Otsu, Triangle ve Yen yöntemleri kullanılmıştır. Her yöntemin eşikleme sonuçları referans görüntüler ile kesişimlerin birleşimi değerlendirme metriğine göre değerlendirilmiştir. Bu değerlendirme metriğine göre %68 'lik bir başarı sağlayarak en iyi eşikleme sonucu Otsu yöntemi ile elde edilmiştir.

Eşiklenmiş görüntüler üzerinde, beyin damar ağı vasküler alan fraksiyonu, lokal bir damarın uzunluğu, dallanma sayısı, uç nokta sayısı ve en yakın komşu mesafesi analizleri yapılmıştır. Analizler sonucunda hata oranlarına bakarak, medikal alanda günümüzde tercih edilen Angiotool uygulaması ile yapılan analizlerin, ResNet+U-Net ağıının bölütlediği görüntüler ile yapılan analizlerden daha yüksek hata oranlarına sahip olduğunu gözlenmiştir. Angiotool manuel olarak görüntü üzerinde boşluk doldurma, damar çapını belirleme, ikilileştirme değerini seçme, küçük partikülleri yok etme gibi işlemler yapmaya izin vermesine rağmen gürültülü görüntülerde damar bölütlemesi yapmakta yetersiz kalmaktadır.

Yakın zamanda Fiji kullanılarak yapılan çalışmadaki [27] makro kullanılarak analiz testleri yapılmış ve ResNet+U-Net ağı ile karşılaştırılmıştır. Karşılaştırma sonucu Fiji makrosu referans görüntülerden çok uzak sonuçlar üreterek başarılı bir bölütleme yapamamıştır. Burada referans görüntüler ile arasındaki hata oranlarının çok yüksek çıkmasının sebebi; ikilileştirme işlemi için kullanılan basit yöntemin mikroskop görüntülerinin yaygın gürültüsünün giderilmesinde yetersiz kalmasıdır.

KAYNAKÇA

- [1] S. Devunooru, · Abeer Alsadoon, · P W C Chandana, and · Azam Beg, “Deep learning neural networks for medical image segmentation of brain tumours for diagnosis: a recent review and taxonomy,” *Journal of Ambient Intelligence and Humanized Computing* 2020 12:1, vol. 12, no. 1, pp. 455–483, May 2020, doi: 10.1007/S12652-020-01998-W.
- [2] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *The bulletin of mathematical biophysics* 1943 5:4, vol. 5, no. 4, pp. 115–133, Dec. 1943, doi: 10.1007/BF02478259.
- [3] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in the brain,” *Psychological Review*, vol. 65, no. 6, pp. 386–408, Nov. 1958, doi: 10.1037/H0042519.
- [4] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature* 1986 323:6088, vol. 323, no. 6088, pp. 533–536, 1986, doi: 10.1038/323533a0.
- [5] Z. Pan, A. G. Rust, and H. Bolouri, “Image redundancy reduction for neural network classification using Discrete Cosine Transforms,” *Proceedings of the International Joint Conference on Neural Networks*, vol. 3, pp. 149–154, 2000, doi: 10.1109/IJCNN.2000.861296.
- [6] T. Sadad *et al.*, “Brain tumor detection and multi-classification using advanced deep learning techniques,” *Microscopy Research and Technique*, vol. 84, no. 6, pp. 1296–1308, Jun. 2021, doi: 10.1002/JEMT.23688.
- [7] R. S. Cruz, L. Lebrat, P. Bourgeat, C. Fookes, J. Fripp, and O. Salvado, “DeepCSR: A 3D deep learning approach for cortical surface reconstruction,” *Proceedings - 2021 IEEE Winter Conference on Applications of Computer Vision, WACV 2021*, pp. 806–815, Jan. 2021, doi: 10.1109/WACV48630.2021.00085.
- [8] M. A. Ebrahimighahnavieh, S. Luo, and R. Chiong, “Deep learning to detect Alzheimer’s disease from neuroimaging: A systematic literature review,” *Computer Methods and Programs in Biomedicine*, vol. 187, p. 105242, Apr. 2020, doi: 10.1016/J.CMPB.2019.105242.

- [9] A. Hu and N. Razmjooy, "Brain tumor diagnosis based on metaheuristics and deep learning," *International Journal of Imaging Systems and Technology*, vol. 31, no. 2, pp. 657–669, Jun. 2021, doi: 10.1002/IMA.22495.
- [10] J. Shan and L. Li, "A Deep Learning Method for Microaneurysm Detection in Fundus Images," *undefined*, pp. 357–358, Aug. 2016, doi: 10.1109/CHASE.2016.12.
- [11] H. Mohsen, E.-S. A. El-Dahshan, E.-S. M. El-Horbaty, and A.-B. M. Salem, "Classification using deep learning neural networks for brain tumors," *Future Computing and Informatics Journal*, vol. 3, no. 1, pp. 68–71, Jun. 2018, doi: 10.1016/J.FCIJ.2017.12.001.
- [12] M. E. Celebi *et al.*, "A methodological approach to the classification of dermoscopy images," *Computerized medical imaging and graphics : the official journal of the Computerized Medical Imaging Society*, vol. 31, no. 6, p. 362, Sep. 2007, doi: 10.1016/J.COMPMEDIMAG.2007.01.003.
- [13] I. el Naqa and M. J. Murphy, "What Is Machine Learning?," *Machine Learning in Radiation Oncology*, pp. 3–11, 2015, doi: 10.1007/978-3-319-18305-3_1.
- [14] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature 2015 521:7553*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [15] G. Hinton, N. Srivastava, and K. Swersky, "Rmsprop: Divide the gradient by a running average of its recent magnitude," *Neural networks for machine learning, Coursera lecture 6e*, p. 13, 2012.
- [16] L. Bottou, "Large-Scale Machine Learning with Stochastic Gradient Descent," *Proceedings of COMPSTAT 2010 - 19th International Conference on Computational Statistics, Keynote, Invited and Contributed Papers*, pp. 177–186, 2010, doi: 10.1007/978-3-7908-2604-3_16.
- [17] D. P. Kingma and J. L. Ba, "Adam: A Method for Stochastic Optimization," *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, Dec. 2014, Accessed: Jan. 21, 2022. [Online]. Available: <https://arxiv.org/abs/1412.6980v9>
- [18] C. Enyinna Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, "Activation Functions: Comparison of trends in Practice and Research for Deep Learning," Nov. 2018, doi: 10.48550/arxiv.1811.03378.
- [19] A. Kalinovsky and V. Kovalev, "Lung Image Segmentation Using Deep Learning Methods and Convolutional Neural Networks," 2016.
- [20] F. Hoorali, H. Khosravi, and B. Moradi, "IRUNet for medical image segmentation," *Expert Systems with Applications*, vol. 191, p. 116399, Apr. 2022, doi: 10.1016/J.ESWA.2021.116399.

- [21] R. Phellan, A. Peixinho, A. Falcão, and N. D. Forkert, "Vascular Segmentation in TOF MRA Images of the Brain Using a Deep Convolutional Neural Network," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 10552 LNCS, pp. 39–46, 2017, doi: 10.1007/978-3-319-67534-3_5.
- [22] X. Zhu, Z. Cheng, S. Wang, X. Chen, and G. Lu, "Coronary angiography image segmentation based on PSPNet," *Computer Methods and Programs in Biomedicine*, vol. 200, p. 105897, Mar. 2021, doi: 10.1016/J.CMPB.2020.105897.
- [23] T. Ma *et al.*, "Ensembling low precision models for binary biomedical image segmentation," *Proceedings - 2021 IEEE Winter Conference on Applications of Computer Vision, WACV 2021*, pp. 325–334, Jan. 2021, doi: 10.1109/WACV48630.2021.00037.
- [24] N. K. Tomar *et al.*, "FANet: A Feedback Attention Network for Improved Biomedical Image Segmentation," *IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS*, vol. XX, p. 2021, Mar. 2021, Accessed: Mar. 02, 2022. [Online]. Available: <https://arxiv.org/abs/2103.17235v2>
- [25] L. R. Dice, "Measures of the Amount of Ecologic Association Between Species," *Ecology*, vol. 26, no. 3, pp. 297–302, Jul. 1945, doi: 10.2307/1932409.
- [26] F. van Beers, A. Lindström, E. Okafor, and M. A. Wiering, "Deep Neural Networks with Intersection over Union Loss for Binary Image Segmentation", doi: 10.5220/0007347504380445.
- [27] A. Myronenko, "3D MRI brain tumor segmentation using autoencoder regularization," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11384 LNCS, pp. 311–320, 2019, doi: 10.1007/978-3-030-11726-9_28.
- [28] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9351, pp. 234–241, 2015, doi: 10.1007/978-3-319-24574-4_28.
- [29] K. He, X. Zhang, S. Ren, and J. Sun, "Identity Mappings in Deep Residual Networks," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9908 LNCS, pp. 630–645, 2016, doi: 10.1007/978-3-319-46493-0_38.
- [30] P. Teikari, M. Santos, C. Poon, and K. Hynynen, "Deep Learning Convolutional Networks for Multiphoton Microscopy Vasculature Segmentation," Jun. 2016, Accessed: Jan. 21, 2022. [Online]. Available: <http://arxiv.org/abs/1606.02382>

- [31] T. W. Ridler and S. Calvard, "PICTURE THRESHOLDING USING AN ITERATIVE SELECTION METHOD.," *IEEE Transactions on Systems, Man and Cybernetics*, vol. SMC-8, no. 8, pp. 630–632, 1978, doi: 10.1109/TSMC.1978.4310039.
- [32] C. H. Li and C. K. Lee, "Minimum cross entropy thresholding," *Pattern Recognition*, vol. 26, no. 4, pp. 617–625, 1993, doi: 10.1016/0031-3203(93)90115-D.
- [33] C. A. Glasbey, "An Analysis of Histogram-Based Thresholding Algorithms," *undefined*, vol. 55, no. 6, pp. 532–537, Nov. 1993, doi: 10.1006/CGIP.1993.1040.
- [34] J. M. S. Prewitt and M. L. Mendelsohn, "THE ANALYSIS OF CELL IMAGES*," *Annals of the New York Academy of Sciences*, vol. 128, no. 3, pp. 1035–1053, Jan. 1966, doi: 10.1111/J.1749-6632.1965.TB11715.X.
- [35] N. Otsu, "THRESHOLD SELECTION METHOD FROM GRAY-LEVEL HISTOGRAMS.," *IEEE Trans Syst Man Cybern*, vol. SMC-9, no. 1, pp. 62–66, 1979, doi: 10.1109/TSMC.1979.4310076.
- [36] G. W. Zack, W. E. Rogers, and S. A. Latt, "Automatic measurement of sister chromatid exchange frequency.," *undefined*, vol. 25, no. 7, pp. 741–753, 1977, doi: 10.1177/25.7.70454.
- [37] J. C. Yen, F. J. Chang, and S. Chang, "A new criterion for automatic multilevel thresholding," *IEEE transactions on image processing : a publication of the IEEE Signal Processing Society*, vol. 4, no. 3, pp. 370–378, 1995, doi: 10.1109/83.366472.
- [38] A. Rácz, D. Bajusz, and K. Héberger, "Effect of Dataset Size and Train/Test Split Ratios in QSAR/QSPR Multiclass Classification," *Molecules 2021, Vol. 26, Page 1111*, vol. 26, no. 4, p. 1111, Feb. 2021, doi: 10.3390/MOLECULES26041111.
- [39] R. Rust *et al.*, "A Practical Guide to the Automated Analysis of Vascular Growth, Maturation and Injury in the Brain," *Frontiers in Neuroscience*, vol. 14, Mar. 2020, doi: 10.3389/FNINS.2020.00244.
- [40] E. Zudaire, L. Gambardella, C. Kurcz, and S. Vermeren, "A Computational Tool for Quantitative Analysis of Vascular Networks," *PLoS ONE*, vol. 6, no. 11, p. 27385, 2011, doi: 10.1371/journal.pone.0027385.
- [41] T. Koçak, M. Aydın and B. Kiraz, "Empirical Comparison of Deep Neural Networks for Brain Vessel Segmentation," 2021 6th International Conference on Computer Science and Engineering (UBMK), 2021, pp. 751-756, doi: 10.1109/UBMK52708.2021.9559015.

EKLER

EK A : Vasküler Analizlerin Fiji Makrosu ile Karşılaştırılması

Üç farklı görüntü veri seti için yapılan 4 adet analiz sonucu Ek A.1’ de tabloda görülmektedir. Analizlerin ilk sütununda “vaf (%)” ile yazılan sütun vasküler alan fraksiyonunu yüzde olarak göstermektedir. “Bağlantı sayısı”, dallanma noktası sayısını göstermektedir. “Uzunluk” görüntüdeki toplam damar uzunluğunu vermektedir. “nnd” ise damarlar arasındaki en kısa mesafeyi vermektedir. Görüntüde ikiden fazla damar olması durumunda bu uzaklıkların ortalaması alınmıştır ve analizlerin son sütununda ise “nnd std” alanında en yakın mesafelerin standart sapmaları gösterilmiştir.

Görüntülerdeki gürültüler fazlaca yaygın olduğunda veya alınan beyin görüntü korteksin köşe kısmından alındığında damarlar net olarak görünmemektedir. Bu tip görüntüler için referans değer 0 olmalıdır. Tez çalışması kapsamında tasarlanan ResNet+U-Net ağı gürültüleri fazlaca yoğun olan görüntülerde piksel değerleri 0 olan görüntü tahmin etmektedir. Bu da damar bulunamadı anlamına gelmektedir. Ek A.1’de tabloda bu tipteki görüntülerin sayısal verileri sarı ile işaretlenmiştir.

Ek A.1.’deki tabloda yeşil ile işaretlenmiş test görüntülerinde birleşik tek bir damar bulunmaktadır. Bu yüzden uygulama damarlar arasındaki en yakın mesafeyi hesaplayamadığı için ‘nnd’ sütununda ‘nan’ değerleri yazılmıştır.

Tablo A.1 Vasküler analizlerin Fiji makrosu ile karşılaştırmalı sayısal sonuçları

# Görüntü	vaf(%)	Fiji						Res-Net+U-Net						Referans görüntüler					
		# bağlantı noktası	# dal	uzunluk	nnd	nnd std	vaf(%)	# bağlantı noktası	# dal	uzunluk	nnd	nnd std	vaf(%)	# bağlantı noktası	# dal	uzunluk	nnd	nnd std	
0	10,80	41	128	1908,7	58,5	39,01	23,62	41	106	3250,24	63,48	54,67	24,51	31	76	3246,26	52,41	38,07	
1	1,62	9	120	936,13	44,08	20,19	5,84	18	130	3099,99	38,22	11,08	5,26	34	156	3437,88	40,21	12,32	
2	25,97	699	2356	17042,11	31,95	13,91	3,23	10	129	2163,00	37,15	13,97	4,45	29	149	2898,97	39,02	12,66	
3	1,22	60	214	1453,5	50,23	14,84	4,35	9	28	1593,02	113,60	53,15	2,60	9	19	1523,45	nan	nan	
4	50,86	1713	4310	21694,31	20,24	18,83	3,02	8	138	2040,92	37,01	11,07	2,61	8	132	2033,26	37,14	11,41	
5	10,2	277	1105	18695,94	20,24	18,83	0,00	0	0	nan	nan	nan	0,00	0	0	nan	nan	nan	
6	12,97	585	2700	14023,73	18,76	14,41	3,63	10	26	1201,89	102,50	43,95	3,18	3	7	1070,34	nan	nan	
7	36,37	579	1306	20031,84	18,76	14,41	0,00	0	0	nan	nan	nan	0,00	0	0	nan	nan	nan	
8	10,63	365	1109	8747,87	18,76	14,41	20,31	53	138	5431,89	72,63	33,50	15,37	66	136	5830,16	109,93	63,66	
9	5,01	261	1143	7303,6	26,64	16,08	4,94	10	25	1278,63	163,72	76,07	2,64	17	35	1709,21	nan	nan	
10	22,26	548	1704	21997,77	33,96	11,99	2,91	8	110	1812,72	43,55	12,31	3,63	17	123	2315,53	39,90	11,40	
11	4,87	82	354	2677,36	40,32	20,21	6,09	19	104	2264,43	41,71	21,96	8,31	11	71	2308,93	45,89	19,27	
12	5,95	276	1098	9498,19	14,76	7,57	0,05	3	9	38,73	199,98	0,00	0,05	0	4	75,46	118,80	62,09	
13	3,96	111	388	3523,07	46,37	21,4	7,33	46	130	5015,74	61,33	30,70	3,45	46	124	5228,95	64,27	28,37	
14	6,48	108	378	4547,29	28,04	13,56	24,00	65	164	7624,64	48,39	31,07	24,60	82	192	7826,52	54,63	38,50	
15	3,5	169	799	5368,82	31,1	14,76	4,68	7	25	1318,36	123,54	69,34	2,96	12	30	1685,95	365,39	0,00	
16	25,9	666	2213	25690,35	32,19	12,38	3,28	10	123	2122,71	37,96	12,40	3,44	19	131	2405,09	39,89	11,39	
17	5,88	163	507	5364,21	47,2	22,21	8,92	50	133	5387,68	65,98	32,34	4,28	58	140	5533,37	77,06	28,78	
18	26,35	785	2605	28757,04	29,78	13,86	3,32	12	140	2111,77	37,68	12,38	4,17	40	180	2841,54	38,47	12,13	
19	3,87	127	465	3550,5	45,5	16,96	7,32	53	141	5090,22	67,84	26,29	3,28	56	143	4999,31	60,07	34,73	
20	0,97	8	100	514,45	53,14	28,33	4,73	10	125	2596,75	34,73	12,58	4,56	34	177	2878,23	35,93	12,30	
21	7,14	186	588	4018,69	47,74	27,55	14,71	42	108	4028,03	57,50	17,72	9,00	32	72	4058,57	144,60	77,49	
22	14,06	167	522	5066,71	37,14	24,06	35,75	49	108	4993,33	71,51	33,41	38,52	29	70	4403,99	85,25	38,55	
23	2,91	86	350	2604,51	38,21	22,42	5,04	27	100	2905,11	48,85	20,62	2,73	33	83	3102,71	62,15	49,19	
24	10,24	145	474	5039,61	28,18	27,29	14,03	32	105	2037,97	45,02	26,69	11,34	12	35	1349,82	90,79	50,46	
25	20,48	156	475	5677,53	52,71	31	39,29	34	106	4974,93	46,27	24,03	39,05	26	82	4816,70	47,39	24,08	
26	24,91	1087	4278	40492,61	24,84	10,53	4,02	12	143	2458,79	36,44	8,16	4,96	40	190	2802,41	34,62	9,88	
27	1,11	19	54	592,32	49,2	26	3,78	21	50	1083,10	109,20	51,97	5,47	13	34	947,00	67,32	48,27	
28	11,45	303	1408	8582,33	31,05	25,64	17,92	19	49	2315,47	95,61	44,62	15,94	17	45	2106,42	70,00	20,17	
29	3,47	33	155	1379,9	49,7	18,63	15,45	30	113	3419,31	43,47	25,19	15,21	29	108	3224,93	46,67	20,37	
30	1,46	5	24	368,39	89,57	51,85	8,89	19	55	1511,18	60,49	32,35	7,42	6	24	1110,99	60,23	26,76	
31	9,22	297	956	8149,49	46,69	25,36	19,36	67	172	6032,99	57,12	35,06	14,53	69	142	6479,78	124,88	96,04	
32	28,82	216	500	8807,78	43,05	39,01	20,54	38	91	2529,15	71,15	40,48	22,98	6	23	2069,01	114,39	55,60	
33	22,27	571	2289	41035,98	14,85	8,71	0,19	0	4	125,81	74,00	41,64	0,23	0	4	292,12	119,22	68,53	

EK B : Vasküler Analizlerin AngoTool ile Karşılaştırılması

Üç farklı görüntü veri seti için yapılan 5 adet analiz sonucu Ek B.1’ de tabloda görülmektedir. Analizlerin ilk sütununda “vaf (%)” ile yazılan sütun vasküler alan fraksiyonunu yüzde olarak göstermektedir. “Dallanma noktası”, dallanma noktası sayısını göstermektedir. “Uzunluk” görüntüdeki toplam damar uzunluğunu vermektedir. “Dal” görüntüdeki damar adedini göstermektedir. “Uç nokta” damarların başlangıç, bitiş ve dallanma yaptıkları dalların bitiş noktalarının sayısını göstermektedir.

Görüntülerdeki gürültüler fazlaca yaygın olduğunda veya alınan beyin görüntü korteksin köşe kısmından alındığında damarlar net olarak görünmemektedir. Bu tip görüntüler için referans değer 0 olmalıdır. Tez çalışması kapsamında tasarlanan ResNet+U-Net ağı gürültüleri fazlaca yoğun olan görüntülerde piksel değerleri 0 olan görüntü tahmin etmektedir. Bu da damar bulunamadı anlamına gelmektedir. Ek A.1’de tabloda bu tipteki görüntülerin sayısal verileri sarı ile işaretlenmiştir.

Tablo B.1 Vasküler analizlerin AngioTool ile karşılaştırmalı sayısal sonuçları

# Görüntü	AngioTool						ResNet+U-Net						Referans					
	vaf(%)	# dallanma noktası	Uzunluk	# dal	# uç nokta	vaf(%)	# dallanma noktası	Uzunluk	# dal	# uç nokta	vaf(%)	# dallanma noktası	Uzunluk	# dal	# uç nokta			
0.PNG	27,24	96	4132,61	66	227	23,62	41	3250,24	106	87	24,51	31	3246,26	76	57			
1.PNG	3,50	7	1598,93	87	175	5,84	18	3099,99	130	209	5,26	34	3437,88	156	211			
2.PNG	2,78	3	976,63	76	149	3,23	10	2163,00	129	233	4,45	29	2898,97	149	212			
3.PNG	11,61	22	1271,14	23	68	4,35	9	1593,02	28	28	2,60	9	1523,45	19	10			
4.PNG	3,48	2	1244,51	85	161	3,02	8	2040,92	138	257	2,61	8	2033,26	132	238			
5.PNG	7,91	60	1740,29	53	164	0,00	0	nan	0	0	0,00	0	nan	0	0			
6.PNG	14,72	168	4090,63	55	266	3,63	10	1201,89	26	19	3,18	3	1070,34	7	5			
7.PNG	5,50	53	1690,30	89	225	0,00	0	nan	0	0	0,00	0	nan	0	0			
8.PNG	16,02	135	7157,53	35	174	20,31	53	5431,89	138	116	15,37	66	5830,16	136	74			
9.PNG	13,86	142	3217,03	26	188	4,94	10	1278,63	25	21	2,64	17	1709,21	35	21			
10.PNG	2,69	3	1019,50	50	98	2,91	8	1812,72	110	199	3,63	17	2315,53	123	192			
11.PNG	3,73	13	1633,64	50	113	6,09	19	2264,43	104	151	8,31	11	2308,93	71	109			
12.PNG	26,57	78	2058,74	32	138	0,05	3	38,73	9	8	0,05	0	75,46	4	8			
13.PNG	9,20	58	5095,60	34	120	7,33	46	5015,74	130	122	3,45	46	5228,95	124	111			
14.PNG	10,24	18	4313,89	41	100	24,00	65	7624,64	164	133	24,60	82	7826,52	192	134			
15.PNG	14,54	138	3428,81	31	201	4,68	7	1318,36	25	29	2,96	12	1685,95	30	29			
16.PNG	3,18	4	988,92	57	113	3,28	10	2122,71	123	221	3,44	19	2405,09	131	203			
17.PNG	10,99	65	5831,22	33	128	8,92	50	5387,68	133	120	4,28	58	5533,37	140	104			
18.PNG	3,03	2	1078,51	73	145	3,32	12	2111,77	140	246	4,17	40	2841,54	180	237			
19.PNG	9,25	64	5402,95	45	148	7,32	53	5090,22	141	125	3,28	56	4999,31	143	116			
20.PNG	2,73	5	1094,49	72	144	4,73	10	2596,75	125	224	4,56	34	2878,23	177	251			
21.PNG	11,21	64	3785,43	45	144	14,71	42	4028,03	108	92	9,00	32	4058,57	72	46			
22.PNG	21,09	100	4895,48	36	162	35,75	49	4993,33	108	68	38,52	29	4403,99	70	53			
23.PNG	7,44	43	3065,01	34	104	5,04	27	2905,11	100	120	2,73	33	3102,71	83	68			
24.PNG	16,94	110	4697,69	52	214	14,03	32	2037,97	105	115	11,34	12	1349,82	35	34			
25.PNG	22,17	94	5975,26	48	176	39,29	34	4974,93	106	111	39,05	26	4816,70	82	85			
26.PNG	3,15	1	856,41	67	129	4,02	12	2458,79	143	259	4,96	40	2802,41	190	256			
27.PNG	9,47	9	652,37	5	19	3,78	21	1083,10	50	36	5,47	13	947,00	34	29			
28.PNG	16,93	236	5317,61	38	299	17,92	19	2315,47	49	39	15,94	17	2106,42	45	39			
29.PNG	10,05	56	3333,97	61	175	15,45	30	3419,31	113	135	15,21	29	3224,93	108	130			
30.PNG	8,00	4	435,26	10	24	8,89	19	1511,18	55	53	7,42	6	1110,99	24	29			
31.PNG	14,74	133	7182,01	23	148	19,36	67	6032,99	172	142	14,53	69	6479,78	142	68			
32.PNG	6,27	26	2077,16	48	118	20,54	38	2529,15	91	67	22,98	6	2069,01	23	27			
33.PNG	16,03	111	2851,17	34	179	0,19	0	125,81	4	8	0,23	0	292,12	4	8			