

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN
EVİRİŞİMSEL SİNİR AĞLARI KULLANILARAK
SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ
Zehra KADİROĞLU

Anabilim Dalı: Elektrik ve Elektronik Mühendisliği
Programı: Elektrik ve Elektronik Teknolojileri

Tez Danışmanı: Doç. Dr. Erkan DENİZ

OCAK-2019

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN EVRİŞİMSEL SINIR
AĞLARI KULLANILARAK SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Zehra KADİROĞLU

162138102


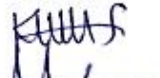
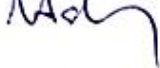
Tezin Enstitüye Verildiği Tarih : 29 Kasım 2018

Tezin Savunulduğu Tarih : 28 Aralık 2018

Tez Danışmanı : Doç. Dr. Erkan DENİZ

Diğer Jüri Üyeleri : Prof. Dr. Abdulkadir ŞENGÜR

Dr. Öğr. Üyesi Muzaffer ASLAN

ARALIK -2018

ÖNSÖZ

Bu tez çalışmasında, ilgisini ve desteğini hiçbir zaman benden esirgemeyen ve yapacağım diğer çalışmalarda da desteğini esirgemeyeceğini düşündüğüm değerli hocam ve tez danışmanım Doç. Dr. Erkan DENİZ'e, çalışmalarım süresince yardımlarıyla beni sürekli destekleyen, bilgi ve birikimlerini benimle paylaşan değerli hocam Prof. Dr. Abdulkadir ŞENGÜR'e teşekkürü bir borç bilirim.

Zehra KADIOĞLU
ELAZIĞ-2019

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	II
İÇİNDEKİLER	III
ÖZET	V
SUMMARY	VI
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ	VIII
SİMGELER VE KISALTMALAR	IX
1. GİRİŞ	1
1.1. Tezin Tanımı.....	4
1.2. Tezin Amacı.....	5
1.3. Tezin Organizasyonu	5
2. YAPAY SİNİR AĞLARI	7
2.1. Tek Katmanlı Algılayıcılar	9
2.2. Basit Algılayıcı Modeli (Perceptron).....	9
2.3. Çok Katmanlı Algılayıcı.....	10
2.4. Geri Yayılım Algoritması	10
3. DERİN ÖĞRENME	13
3.1. Derin Öğrenmenin Tarihçesi	13
3.2. Tanım.....	14
3.3. Transfer Öğrenme	15
3.4. Özellik Çıkarma.....	16
3.5. Evrimsel Sinir Ağları	16
3.5.1. ESA katmanları.....	18
3.5.1.1. Giriş Katmanı	18
3.5.1.2. Evrişim katmanı.....	18
3.5.1.3. Doğrultulmuş Doğrusal Birim Katmanı	19
3.5.1.4. Havuzlama Katmanı	20
3.5.1.5. Tam Bağlantılı Katman	20
3.5.1.6. DropOut Katmanı	21
3.5.1.7. Sınıflandırma Katmanı	21
3.6. AlexNet.....	22

3.7.	VGG16.....	23
4.	DÜŞÜK SEVİYELİ DOKU ÖZNETELİKLERİ.....	25
4.1.	Yerel İkili Örüntü (YİÖ).....	25
4.2.	Yönlü Gradyanlar Histogramı (YGH).....	26
4.3.	Ölçekten Bağımsız Özellik Dönüşümü (ÖBÖD)	27
4.4.	Gri Seviye Eş-Oluşum Matrisi (GSEM).....	27
4.5.	Destek Vektör Makinesi (DVM)	28
5.	HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN SINIFLANDIRILMASI	30
5.1.	Veri Tabanı	30
5.2.	Evrişimsel Sinir Ağlarına ait Deneysel Sonuçlar	32
5.3.	Düşük Seviyeli Doku Özneteliklerine ait Deneysel Sonuçlar	37
6.	SONUÇLAR.....	39
	KAYNAKLAR	40
	ÖZGEÇMİŞ	48

ÖZET

Meme kanseri, dünya çapında kadınlar arasında önde gelen kanser tiplerinden biridir. Her yıl birçok meme kanseri hastası geç tanı ve tedaviye bağlı olarak hayatını kaybetmektedir. Bu nedenle meme kanserinin erken teşhisi hayati önem arz etmektedir. X-ray mamografi en çok tercih edilen görüntüleme yöntemi olmasına rağmen kanser teşhisi için tek başına yeterli değildir. Bilgisayar destekli tespit ve teşhis (BDT) yöntemleri, tanı sürecinde radyoloğa yardımcı olmak, hastayı gereksiz ağrıdan kurtarmak amacıyla geliştirilmiş yöntemlerdir. Bu bağlamda literatürde birçok BDT yöntemi bulunmaktadır. Bu tez çalışmasında, görüntü tanımda yüksek performans gösteren derin öğrenme mimarilerinden evrişimsel sinir ağları hakkında detaylı bilgi verilmiş ve BrecaHis veri tabanından alınan histopatolojik meme kanseri görüntülerinin sınıflandırılmasında evrişimsel sinir ağları kullanılmıştır. Ayrıca doku tabanlı görüntü tanımda öncelikli olarak tercih edilen düşük seviyeli doku öznitelikleri ile de sınıflandırma gerçekleştirilmiştir. Evrişimsel sinir ağları özellik çıkarma ve transfer öğrenme aşamalarından oluşmaktadır. Özellik çıkarma, AlexNet ve Vgg16 modellerinin fc6 ve fc7 katmanlarında gerçekleştirilmiştir. Transfer öğrenme için önceden eğitilmiş AlexNet modeli kullanılmıştır. Düşük seviyeli doku öznitelik yöntemleri sırası ile Yerel İkili Örüntü (YİÖ), Yönlü Gradyanlar Histogramı (YGH), Ölçekten Bağımsız Özellik Dönüşümü (ÖBÖD) ve Gri Seviye Eş-Oluşum Matrisi(GSEM)'dir. Her iki çalışmada sınıflandırma aşamasında Destek Vektör Makineleri (DVM) yöntemi kullanılmıştır. Evrişimsel sinir ağlarında özellik çıkarma için en yüksek doğruluk değeri %93.78 ile AlexNet-fc7 ve Vgg16-fc7'nin birleştirilmiş derin özelliklerinden elde edilmiştir. Transfer öğrenme için %93.57 en yüksek doğruluk değeridir. Düşük seviyeli doku öznitelikleri yöntemlerinde en yüksek sonuç, YİÖ-ÖBÖD yöntemlerinin birleştirilmesi ile %75.48 olarak elde edilmiştir.

Anahtar Kelimeler: Meme Kanseri, Evrişimsel Sinir Ağları, Görüntü Sınıflandırma

SUMMARY

Classification of Histopathological Breast Cancer Images Using Convolutional Neural Networks

Breast cancer is one of the leading cancer types among women worldwide. Every year, many breast cancer patients die due to late diagnosis and treatment. Therefore, early diagnosis of breast cancer is of vital importance. Although X-ray mammography is the most preferred imaging modality, it is not sufficient for cancer diagnosis alone. Computer aided detection and diagnosis (CAD) methods are developed to assist the radiologist in the diagnosis process and to free the patient from unnecessary pain. In this context, there are many CAD methods in the literature. In this thesis, detailed information was given about convolutional neural networks from deep learning architectures, which are high performance in image recognition. In addition, classification was carried out with low-level texture features preferred primarily for texture based image recognition. Convolutional neural networks consist of feature extraction and transfer learning. Feature extraction was performed on the fc6 and fc7 layers of AlexNet and Vgg16 models. Pre-trained AlexNet model was used for Transfer learning. The low-level texture features methods are respectively Local Binary Pattern (LBP), Histogram of Oriented Gradients (HOG), Scale-Invariant Feature Transform (SIFT) and Grey Level Co-occurrence Matrix (GLCM). In both studies, Support Vector Machines (SVM) method was used in the classification stage. The highest accuracy value for feature extraction in convolutional neural networks was obtained from the combined properties of AlexNet-fc7 and Vgg16-fc7 with 93.78%. Transfer learning is the highest accuracy value of 93.57%. The highest results in low-level texture features methods were obtained as 75.48% by combining LBP-SIFT methods.

Keywords: Breast Cancer, Convolutional Neural Network, Image Classification

ŞEKİLLER LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1. McCulloch-Pitts nöron modeli.....	7
Şekil 2.2. Biyolojik Sinir Hücresinin Yapısı.....	8
Şekil 2.3. Yapay sinir hücresinin yapısı.....	8
Şekil 2.4. Girdi, çıktı ve gizli katmanlardan oluşmuş çok katmanlı bir yapay sinir ağı.....	8
Şekil 2.5. Tek katmanlı algılayıcı örneği.....	9
Şekil 2.6. Perceptron örneği.....	10
Şekil 2.7. Çok katmanlı algılayıcı örneği.....	10
Şekil 3.1. Makine öğrenmesi ve derin öğrenme yöntemlerinde görüntü sınıflandırma.....	15
Şekil 3.2. Evrişimsel sinir ağının katmanları.....	18
Şekil 3.3. Giriş matrisine uygulanan filtre ile oluşan öznitelikler.....	19
Şekil 3.4. ReLu fonksiyonunun matris üzerindeki etkisi.....	19
Şekil 3.5. Maksimum ve ortalama havuzlama uygulanmış bir matrisin çıktısı.....	20
Şekil 3.6. Evrişimsel Sinir Ağına DropOut Uygulanması.....	21
Şekil 3.7. Sınıflandırma işleminin iki olası sonucu.....	22
Şekil 3.8. AlexNet ağı.....	23
Şekil 3.9. VGG16 ağı.....	24
Şekil 4.1. 3×3'lük matrisin yerel ikili örüntü değerinin hesaplanması.....	26
Şekil 4.2. Bir görüntünün yönlü gradyanlar histogramının elde edilmesi.....	26
Şekil 4.3. ÖBÖD yönteminin adımları; (a) Ölçek alanı üretimi (b) DoG görüntü üretimi (c) Yerel maksimum ve minimum tespit (d) Gradyan hesaplama (e) Histogram hesabı ve 128 boyutlu vektörlerin üretimi.....	27
Şekil 4.4. Gri seviye eş-oluşum matrisinin oluşturulması.....	28
Şekil 4.5. Doğrusal olarak ayrılabilen ve ayrılamayan veri kümeleri.....	29
Şekil 5.1. Histopatolojik görüntülerin Transfer Öğrenme için eğitilmesi.....	32
Şekil 5.2. Histopatolojik meme kanseri görüntülerinden derin özellik çıkarma ve DVM sınıflandırması.....	33
Şekil 5.3. İnce ayarlı AlexNet modelinin eğitim süreci.....	34
Şekil 5.4. Histopatolojik meme kanseri görüntülerinin düşük seviyeli doku öznitelikleri ile sınıflandırılması.....	37

TABLolar LİSTESİ

	<u>Sayfa No</u>
Tablo 5.1. Büyütme faktörü ve tümör türüne göre görüntü dağılımı.....	31
Tablo 5.2. Büyütme faktörü ve histopatolojik alt tiplerine göre iyi huylu görüntü dağılımı	31
Tablo 5.3. Büyütme faktörü ve histopatolojik alt tiplerine göre kötü huylu görüntü dağılımı	31
Tablo 5.4. AlexNet-fc6 ve Vgg16-fc6 derin öznitelikler çıkarma sonuçları	34
Tablo 5.5. AlexNet-fc7 ve Vgg16-fc7 derin öznitelikler çıkarma sonuçları	35
Tablo 5.6. İnce ayarlı AlexNet ile elde edilen sınıflandırma doğruluğu	36
Tablo 5.7. Her büyütme seviyesi için elde edilen sonuçların karşılaştırılması.....	36
Tablo 5.8. Özellik Tanımlayıcıların Ortalama Doğruluk Değerleri	38
Tablo 5.9. Literatürdeki Çalışmanın Doğruluk Değerleri.....	38

SİMGELER VE KISALTMALAR

ζ_j	: Ağın ürettiği çıktı
B_j	: Beklenen çıktı
e_j	: Ağın hata değeri
w_i	: Ağırlıklar
x_i	: Girdiler
E	: Toplam hatanın karesinin ortalaması
b	: Bias Değeri
η	: Öğrenme katsayısı
ϕ	: Eşik Değeri
2-D	: İki Boyutlu
BDT	: Bilgisayar Destekli Tespit ve Teşhis
BT	: Bilgisayarlı Tomografi
DVM	: Destek Vektör Makinesi
ESA	: Evrişimsel Sinir Ağları
GPU	: Grafik İşleme Birimi
GSEM	: Gri Seviye Eş-oluşum Matrisi
ILSVRC	: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
MRG	: Manyetik Rezonans Görüntüleme
NLP	: Doğal Dil İşleme
ÖBÖD	: Ölçekten Bağımsız Özellik Dönüşümü
PYT	: Pozitron Yayıcı Tomografi
ReLU	: Doğrultulmuş Doğrusal Birim
RGB	: Red Green Blue
ROI	: İlgi Bölgesi
SOB	: Cerrahi (Açık) Biyopsi
YİÖ	: Yerel İkili Örüntü
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Meme kanseri, memenin farklı bölgelerinde ve hücrelerin kontrol dışı çoğalmaya başlamasıyla meydana gelmektedir. Çoğu meme kanseri süt bezlerinde başlar, bir kısmı da sütü meme başına taşıyan kanallardaki hücrelerde başlar [1]. Amerikan Kanser Topluluğunun tahminlerine göre 2018 yılında yaklaşık 2.550 erkek ve 266.120 kadına yeni invaziv (yayılma potansiyeli olan) meme kanseri vakası teşhisi konacaktır. Yaklaşık 480 erkek ve 40.920 kadının meme kanserinden ölmesi beklenmektedir [2]. Bununla birlikte kanserin erken teşhisi bu hastalığın başarılı bir şekilde tedavi edilme şansını büyük ölçüde arttırmakta ve hastaların uğradığı zihinsel ve fiziksel ağrıları azaltmaktadır. Bu yüzden kanserin erken dönemde tespiti ve tedavi edilmesi son derece önemlidir. Meme kanserinin erken tespiti için birçok yöntem bulunmaktadır. Bunlardan en yaygın olanları; görüntüleme yöntemleri (mamografi, ultrasonografi, manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT), pozitron yayıcı tomografi (PYT) vb.), fiziksel muayene ve biyopsidir [3]. BT, PYT, MRG gibi görüntüleme yöntemlerinin yüksek radyasyona maruz bırakma açısından ciddi dezavantajları vardır. Meme kanserinin ilk tespiti bu görüntüleme teknikleri kullanılarak gerçekleştirilmesine rağmen, meme dokularında saptanan anormalliğin kötü huylu olduğunun tespitinde tek başlarına yeterli değildirler. Bu nedenle, memedeki değişimin kötü huylu olduğu biyopsi ile doğrulanıncaya kadar hastalığın tedavisine başlanmaz [4]. Eğer kanser varsa anlamanın tek yolu biyopsi yaptırmaktır [5].

Biyopsi, görüntüleme yöntemlerinde tespit edilen şüpheli bölgenin kanserli olup olmadığını anlamak ve kesin olarak teşhis edebilmek için uygulanan bir işlemdir. Meme biyopsileri, meme dokusunun mikroskopik yapısının histolojik olarak değerlendirilmesini sağlar. Histopatoloji; hastalık belirtisi olan organ, doku veya hücrelerde çeşitli yöntemler kullanılarak yapılan histolojik incelemedir. Histopatoloji, normal hücreleri, iyi huylu ve kötü huylu hücreleri ayırmayı amaçlamaktadır. Histolojik olarak iyi huylu tümörler yavaş gelişirken, kötü huylu tümörler komşu hücreleri tahrip edebilir ve uzak bölgelere yayılabilirler. Çeşitli meme biyopsi yöntemleri vardır. Uygulanacak biyopsi yöntemi hastanın tercihine, bir diğer biyopsi yöntemiyle elde edilen sonuçların net olmamasına, şüpheli bölgenin büyüklüğüne ve memedeki değişime göre seçilir. En yaygın biyopsi yöntemi olan Cerrahi Açık Biyopsi (SOB) yönteminde, görüntüleme yöntemlerinin biriyle tespit edilip tel ile belirgin hale getirilen şüpheli parçanın bir kısmı ya da tamamı cerrahi

operasyonla çıkarılır [6]. Bu yöntem hastalığın tespiti açısından iğne biyopsiye göre daha az riskli ve daha güvenlidir. Bununla birlikte herhangi bir iğne biyopsisi yöntemiyle karşılaştırıldığında; maliyetli olması, daha fazla ağrı verici olması, yara iyileşmesi sırasında yaşanan olumsuz durumlar ve iyileşmenin uzun sürmesi gibi dezavantajlara sahiptir [7]. Meme biyopsilerinde patoloğlar, dokunun mikroskobik yapısını histolojik olarak değerlendirir ve görsel muayene ile son kanser teşhisi koyar. Bu aşamada patoloğun tecrübesi, dikkati, yorgunluk seviyesi vb. durumlar yanlış teşhis oranını arttırmaktadır. Bu yüzden biyopsi ile toplanan verilerin makine öğrenme algoritmalarıyla değerlendirilmesi kanserin doğru teşhisinde daha yüksek sonuç elde edilmesini sağlamaktadır [8].

Makine öğrenme algoritmaları daha doğru, hızlı ve güvenilir olmaları bakımından erken teşhis için karar vermede yaygın hale gelmiştir. Bununla birlikte makine öğrenme algoritmalarının görüntü verilerini ham haliyle işleme yetenekleri sınırlıdır. Çok büyük boyutlu görüntüleri işlemede yetersiz olmaları, kapasitelerinin düşük olması, görüntüye uygulandıklarında bazen elde edilmesi gereken sonucu vermemeleri, eğitim için kullanılacak özelliklerin elle belirlenmesi makine öğrenme algoritmalarının görüntü işlemedeki dezavantajlarından bazılarıdır [9]. Makine öğrenmesi algoritmalarının görüntü işlemedeki eksikliklerine çözüm olarak derin öğrenme algoritmaları ortaya çıkmıştır. Temsili öğrenme, bir makinenin ham verilerle beslenmesini ve tespit veya sınıflandırma için gereken temsilleri otomatik olarak veriden keşfetmesini sağlayan bir yöntem dizisidir. Derin öğrenme, ham girdiden başlayarak temsilleri her aşamada daha yüksek düzeyde bir temsile dönüştüren temsili öğrenme yöntemidir. Bu yöntem ile görüntüdeki özellikler daha iyi öğrenilir. Böylelikle daha iyi bir sınıflandırma olanağı sağlamaktadırlar [10].

Literatürde derin öğrenme algoritmaları kullanılarak meme kanserinin tespitine yönelik çalışmalar bulunmaktadır. Selvathi ve ark, denetimsiz derin öğrenme temelli bir teknikle mamografi görüntülerinden meme kanserinin saptanmasına yönelik bir sistem önermişlerdir. Denetimsiz derin öğrenme tekniklerinin kullanımı ile daha küçük kütlelerin yerlerinin daha doğru tespit edilmesini amaçlamışlardır. Yoğun mamografi görüntülerini sınıflandırmada %98,5'e varan bir doğruluk elde etmişlerdir [4]. Wang ve ark, mikro kalsifikasyonların tanısal doğruluğunu iyileştirmek için büyük veri kümelerindeki derin öğrenme algoritmasının performansını değerlendirmişlerdir. Meme lezyonlarının sınıflandırılması için, mikro kalsifikasyonların ve meme kitlelerinin ayrımı ve birleşimi şeklinde doğruluklarının değerlendirilmesi için bir sınıflandırma modeli oluşturmuşlardır. Derin öğrenme modeli ile mikro kalsifikasyonların ve meme kitlelerinin birleşiminden %89,7

doğruluk elde etmişlerdir [11]. Bayramoğlu ve ark, histopatolojik meme kanseri görüntülerini sınıflandırmak için iki farklı görevli evrimsel sinir ağları (ESA) kullanmışlardır. Tek görevli ESA'yı kötü huylu tümörleri tahmin etmek için, çok görevli ESA'yı da hem kötü huylu tümörleri hem de büyütme oranını eş zamanlı olarak tahmin etmek için kullanmışlardır [12]. Motlagh ve ark, makine öğrenmesi algoritmalarının tümör alt tiplerini doğru saptadığını kanıtlamak için önceden eğitilmiş derin sinir ağlarını (DNN) kullanmışlardır. Yaklaşımı test etmek için 6.402 doku mikro-dizi (TMA) eğitim numunesini kullanarak farklı kanser türlerini sınıflandırmışlardır. Önceden eğitilmiş ResNet-V1-50 modelini kullanarak meme, mesane, akciğer ve lenf dâhil olmak üzere dört kanser tipinde ortalama %99,8'inde doğruluk elde etmişlerdir. Daha sonra meme kanseri alt tiplerinin sınıflandırılması için ResNet-V1-152 modeli ile %98,7'lik bir doğrulukla iyi huylu ve kötü huylu meme kanserlerini sınıflandırmışlardır [13]. Bardou ve ark, histolojik meme kanserinin görüntülerini iyi huylu ve kötü huylu ve iyi huylu ve kötü huylu tümörlerin alt tipleri şeklinde sınıflandırmak için ESA'ların performanslarını karşılaştırmışlardır. En yüksek doğruluk değeri %98.33'dür [14]. Rakhlin ve ark, hematoksilen ve eozin lekeli histolojik meme kanseri görüntülerini sınıflandırılması için derin evrimsel sinir ağlarına dayanan hesaplama yaklaşımını geliştirmişlerdir. Birkaç derin sinir ağı mimarisini özellik çıkarma için ve gradyan artırma karar ağaçları sınıflandırma için kullanmışlardır. Sınıflandırma işleminin sonucunda %93,8'lik bir doğruluk elde etmişlerdir [15]. Araujo ve ark, ESA kullanarak hematoksilen ve eozin boyalı meme biyopsisi görüntülerinin sınıflandırılması için bir yöntem önermişlerdir. Görüntüleri dört sınıfa; normal dokuya, iyi huylu lezyona, in situ karsinomaya/non-invaziv karsinomaya (kansereleşme ihtimali yüksek ama yayılma ihtimali olmayan) ve invaziv karsinomaya (yayılma potansiyeli olan) ve iki sınıfa, karsinoma (kanserli) ve non-karsinomaya (kanserli olmayan) ayırmışlardır. ESA tarafından çıkarılan özellikleri bir DVM sınıflandırıcısını eğitmek için de kullanmışlardır. Dört sınıflı sınıflandırma için %77,8, iki sınıflı sınıflandırma için %83,3 oranında doğruluk elde etmişlerdir [16]. Liu ve ark, iki ayrı veri tabanındaki yapılandırılmış verilerin sınıflandırma performansını iyileştirmek amacıyla tamamen bağlı olan katmanların ilk evrim tabakasından önce yerleştirildiği bir ESA yapısı önermişlerdir. Sonuçlar, önerilen ESA yapısının her iki veri kümesi için saf çok katmanlı algılayıcılardan ve saf ESA'dan daha iyi bir sınıflandırma performansı sağlayabildiğini elde etmişlerdir. Önerilen ESA yapısı ile veri kümeleri için %99,28 doğruluk ve %98,71 doğruluk elde etmişlerdir [17]. Nazeri ve ark, mikroskop görüntülerinin meme dokusunu sınıflandırması sorununu derin öğrenme

tekniklerini kullanarak arařtırmıřlardır. Eđitim veri setindeki her bir resmin byklđ nedeniyle, birbirini izleyen iki evriřimsel sinir ađından oluřan yama tabanlı bir teknik nermiřlerdir. nerdikleri yntem ile %95 dođruluk elde etmiřlerdir [18]. Basavanhally ve ark, meme kanseri grntlerinde invaziv duktal karsinoma (IDC-yayılma potansiyeli olan kt huylu tmr) doku blgelerinin otomatik tespit ve grsel analizi iin derin đrenme yaklařımı sunmaktadırlar. Uyguladıkları yntemin F-lm ve dengeli dođruluk aısından (%71,80, %84,23) en iyi nicel sonular olduđunu gzlemlemiřlerdir [19]. Paydar ve ark, yaptıkları alıřma ile mamografi grntlerinden lezyon tespiti iin daha hızlı bir Blgesel Evriřimsel Sinir Ađları (R-CNN/Region Convolution Neural Networks) detektrnn performansını deđerlendirmiřlerdir [20]. Dubrovina ve ark, mamografi grntlerinde ayırt edici zellikleri otomatik olarak đrenmek iin ESA kullanmıřlardır. Piksel yntemli otomatik sınıf tahminini hızlandırmak iin, klasik tam bađlı katmanlar yerine evriřim katmanları kullanmıřlardır [21]. Han ve ark, yeniden tasarladıkları bir derin đrenme modelini kullanarak meme kanseri oklu sınıflandırma yntemi nermiřlerdir. Yapılandırılmıř derin đrenme modeli ile ortalama %93,2 dođruluk elde etmiřlerdir [22]. Xi ve ark, mamogram grntlerinde kalsifikasyonları ve kitleleri sınıflandırmak ve sınırlandırmak iin derin evriřimsel sinir ađlarını (DCNN) kullanmıřlardır. Deney sonucunda en iyi genel dođruluđu VggNet ile %92,53 olarak elde etmiřlerdir [23]. Ertosun ve ark, mamografi grntlerinde ktlelerin otomatik arama ve lokalizasyonu iin derin bir đrenme temelli grsel arama sistemi geliřtirmiřlerdir. Mamogramları, bir derin đrenme sınıflandırıcısı kullanarak bir ktle veya hi ktle iermeyen olarak sınıflandırmıřlardır ve daha sonra, derin bir đrenme ađına dayalı blgesel bir olasılıksal yaklařım kullanarak grnt iindeki ktleleri sınırlandırılmıřlardır. Kitle ieren grntlerin tanımlanmasında %85 dođruluk elde etmiřlerdir [24].

1.1. Tezin Tanımı

Derin đrenme algoritmaları, grnt tanıma iin kullanılan yntemlerin eksikliklerine zm olarak geliřtirilmiř yapılarıdır. Derin đrenme algoritmaları ham veriden zellikleri kendisi ıkarır ve bu řekilde đrenme iřlemine gerekleřtirir. Derin đrenme algoritmalarının katmanlarında zellik ıkarma iřlemi eřitli ařamalardan oluřur. nce dřk seviyeli zellikler ve daha sonra yksek seviyeli zellikler ıkarılır. Bu da grntnn daha iyi tanınması ve daha yksek bir oranda sınıflandırma olanađı sađlar. Derin đrenme

algoritmalarının temel yapıtaşı Evrişimsel Sinir Ağları (ESA) dır. ESA makine öğrenme algoritmalarının görüntü tanımadaki eksikliklerini gidererek problemin çözülmesini sağlamıştır. Bu ağ modelinde özellik çıkarımı Evrişim (Convulation), Doğrultulmuş Doğrusal Birim Katmanı (ReLU), Havuzlama (Pooling) katmanlarında gerçekleşirken; sınıflandırma işlemi de Tam Bağlı katman (Fully Connected) ve Sınıflandırma katmanında gerçekleşir.

Doku, görüntülerin temel bir özelliği olduğundan görüntü tanımadada önemli bir rol oynar. Bir görüntüyü tanımlamak için özelliklerinin bir özellik vektörü biçiminde olması gerekir. Bu da özellik çıkarma ile elde edilebilir. Düşük seviyeli doku öznitelikleri, özellik tanımlayıcılar ile görüntü için önemli özellikleri çıkararak doku analizini gerçekleştirirler. Özellik çıkarmak için birçok yöntem bulunmaktadır. Bunlardan bazıları, yerel ikili örüntü, yönlü gradyanlar histogramı, ölçekten bağımsız özellik dönüşümü, gri seviye eş-oluşum matrisidir.

1.2. Tezin Amacı

Bu tez çalışmasının amacı; evrişimsel sinir ağlarını incelemek ve önceden eğitilmiş farklı evrişimsel sinir ağlarını histopatolojik meme kanseri görüntülerinin sınıflandırılmasına uygun hale getirip kullanmaktır. Bu çalışmada, evrişimsel sinir ağları iki amaçla kullanılacaktır. Bu amaçlar; özellik çıkarma ve transfer öğrenmedir. Özellik çıkarma için önceden eğitilmiş AlexNet ve Vgg16 ağları kullanılacaktır. Transfer öğrenme için de önceden eğitilmiş AlexNet modeli kullanılacaktır. Histopatolojik meme kanseri görüntüleri aynı zamanda düşük seviyeli doku öznitelikleri kullanılarak da sınıflandırılacaktır. Düşük seviyeli doku özniteliklerinin ve ESA'nın performanslarının karşılaştırılması yapılacaktır. Bu bağlamda, BreakHis veri tabanı kullanılacaktır. Deneysel çalışma ile ilgili tüm analizler MATLAB programı kullanılarak yapılacaktır.

1.3. Tezin Organizasyonu


Bu tez çalışması giriş, yapay sinir ağları, derin öğrenme, histopatolojik meme kanseri görüntülerinin sınıflandırılması, düşük seviyeli doku öznitelikleri ve sonuç olmak üzere altı bölümden oluşmaktadır. İlk bölümde, meme kanseri ile ilgili tıbbi bilgiler ve dünya çapında meme kanserinin mevcut durumu ile ilgili istatistikler verilmiştir. Tespit yöntemleri ile ilgili

bilgiler ayrıntılı olarak açıklanmıştır. Derin öğrenme algoritmaları kullanılarak meme kanserinin tespiti ile ilgili literatür taraması yapılarak yöntemin üstünlüklerinden bahsedilmiştir. Ayrıca tezin tanımı, amacı ve organizasyonu açıklanmıştır. Bölüm 2’de derin öğrenmenin temelini oluşturan yapay sinir ağları anlatılmıştır. Bölüm 3’de derin öğrenmenin tarihçesi, derin öğrenme yöntemleri, derin öğrenme algoritmaları, sık kullanılan ağ yapıları anlatılmıştır. Bölüm 4’de düşük seviyeli doku öznelik yöntemlerinden bahsedilmiştir. Bölüm 5’de deneysel çalışmalarda izlenen adımlar ile ilgili detaylı bilgi verilmiştir. Kullanılan veri tabanından ve deneysel çalışmaların sonuçlarından bahsedilmiştir. Bölüm 6’da çalışmada elde edilen sonuçlar değerlendirilmiştir.




2. YAPAY SİNİR AĞLARI

Yapay sinir ağı, insanlardaki en temel işlev olan öğrenme işlemini otomatik olarak kendi kendine gerçekleştirebilen bilgisayar algoritmalarıdır. Beyinde öğrenme kimyasal olarak gerçekleşirken yapay sinir ağı da beyin bu özelliğini matematiksel olarak modelleyerek bir model oluşturan sınıflandırma algoritmalarıdır. Biyolojik sinir ağlarının çevreden gelen girdilere bağlı olarak davranışlar ve tepkiler öğrenebildikleri gibi yapay sinir ağlarının da aynıını yapması beklenir. Bu aşamada hangi öğrenme yöntemi seçilmişse (denetimli, denetimsiz) yapay sinir ağının çıktısı yöntemine göre elde edilir [25]. Yapay sinir ağları ile ilgili ilk olarak 1943 yılında nörofizyolog Warren McCulloch ve matematikçi Walter Pitts beyindeki nöronların nasıl çalıştığını açıklamak için elektrik devreleri kullanarak basit bir sinir ağı modellemiştir [26]. Şekil 2.1’de McCulloch-Pitts nöron modeli gösterilmiştir.



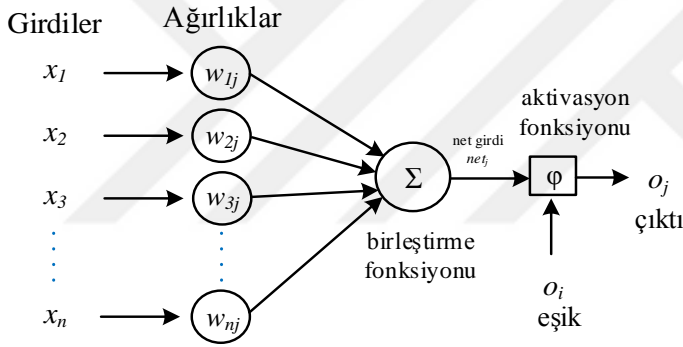
Şekil 2.1. McCulloch-Pitts nöron modeli [27]

Şekil 2.2’de biyolojik sinir hücresinin yapısı görülmektedir. Biyolojik sinir hücrelerinin çalışma prensibi; sinir uçlarına (dendrit) gelen bilgilerin hücre gövdesinde değerlendirildikten sonra akson boyunca ilerleyerek diğer hücrelerin dendritlerine gönderilmesidir. Yapay sinir ağları biyolojik sinir hücrelerinin çalışma prensibi ilham alınarak modellenmiştir. Yapay sinir hücrelerinde giriş katmanına gelen girdiler toplanır, belli bir eşik değerinin üzerinde ise çıktı üretir.



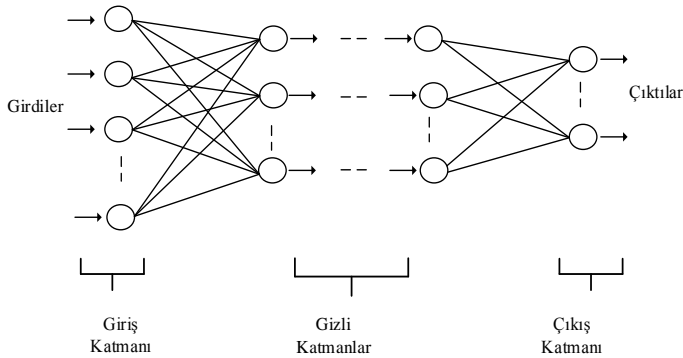
Şekil 2.2. Biyolojik Sinir Hücresinin Yapısı [28]

Yapay sinir ağları yapay sinir hücrelerinin yani matematiksel ifadeyle süreç elemanlarının birbirine bağlanmasından oluşur. Bir yapay sinir hücresi beş temel bileşenden oluşur. Bu bileşenler; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır. Şekil 2.3’de yapay sinir hücresinin bileşenlerini görülmektedir.



Şekil 2.3. Yapay sinir hücresinin yapısı [29]

Yapay sinir ağları, yapay sinir hücrelerinin 3 katman halinde birbirlerine bağlanmasıyla oluşur. Bu katmanlar: giriş katmanı, gizli katmanları ve çıkış katmanıdır. Şekil 2.4’de çok katmanlı yapay sinir ağının katmanlarına örnek verilmiştir.




Şekil 2.4. Girdi, çıktı ve gizli katmanlardan oluşmuş çok katmanlı bir yapay sinir ağı [30]

Yapay sinir ağlarının temel işlevi, verilen girdilere göre uygun çıktıyı üretebilmektir. Bunun için, girdi katmanına gelen veriler genellikle işleme tabi tutularak gizli katmana gönderilir. Girdi katmanının düğüm sayısı ağa verilen özelliklerin sayısı kadardır. Gizli katmana gelen veriler işlenerek çıktı katmanına gönderilir. Çıktı katmanında; gizli katmandan gelen bilgiler işlenir ve üretilmesi istenen çıktı üretilir. Çıktı katmanının düğüm sayısı ise ağdan yapmasını istediğimiz işlemin sonucuna bağlıdır. Yapay sinir ağlarının ilk modelleri; tek katmanlı algılayıcılar, basit algılayıcı (perceptron), ADALİNE/MADALİNE modelleridir.

2.1. Tek Katmanlı Algılayıcılar


Tek katmanlı yapay sinir ağları bir girdi ve bir çıktı katmanından oluşan en basit ağ modelidir. Tek katmanlı algılayıcının formülündeki eşik değeri, $\phi = 1$ olduğu için çıktı değeri hiçbir zaman sıfır(0) olmaz. Şekil 2.5’de iki girdi ve bir çıktıdan oluşan tek katmanlı algılayıcı modeline örnek verilmiştir.



Şekil 2.5. Tek katmanlı algılayıcı örneği [31]

2.2. Basit Algılayıcı Modeli (Perceptron)


1958 yılında Rosenblatt [32] tarafından geliştirilen basit algılayıcı (perceptron), tek bir yapay sinir hücresinden (katmandan) oluşan ileri beslemeli bir sinir ağıdır. Temel düzeyde bir biyolojik nöronun matematiksel temsilidir. Çalışma prensibi; birden fazla girdinin ($x_i; i = 1,2 \dots n$) yalnızca iki sonuç(ya sıfır ya da bir) üretmesine dayanmaktadır. Ağırlıkların istenen değere ulaşana kadar algoritmanın çalışmaya devam etmesi yapay sinir ağlarının eğitimi öğrenme özelliğinin göstergesidir. Şekil 2.6’da Perceptron örneği verilmiştir.



Şekil 2.6. Perceptron örneği [33]

2.3. Çok Katmanlı Algılayıcı

Basit algılayıcı modelin XOR probleminin çözümünde yetersiz olması bu problemin çözümüne yönelik yeni bir ağ modelinin araştırılmasını ve geliştirilmesini sağlamıştır. Çok katmanlı algılayıcı, 1969 yılında Minsky ve Papert tarafından geliştirilmiştir [34]. Basit algılayıcı model bir giriş ve bir çıkış katmanından oluşurken çok katmanlı algılayıcı modelinde giriş ve çıkış katmanları arasında bir veya daha fazla sayıda gizli katman bulunmaktadır. Şekil 2.7’de çok katmanlı algılayıcı örneği verilmiştir.



Şekil 2.7. Çok katmanlı algılayıcı örneği [31]

2.4. Geri Yayımlım Algoritması

1960 yılında Widrow ve Hoff, Adaline (Adaptive Linear) sinir ağı modelini geliştirmişlerdir [35]. Ağın öğrenme aşamasında ağırlıkların ayarlanması, en küçük ortalamaların karesi (LMS) algoritması kullanılarak gerçekleştirilmiştir. Bu öğrenme kuralı

delta kuralı olarak da bilinmektedir [31]. 1986 yılında Rumelhart, Hinton ve Williams Genelleştirilmiş Delta Kuralını geliştirmiştir [36]. Geri yayılım algoritmasına hatanın geri yayılımı veya genelleştirilmiş delta kuralı da denilmektedir [37]. Geri yayılım; çok katmanlı ileri beslemeli yapay sinir ağlarının öğrenme sürecindeki en önemli adımdır. Yapay sinir ağının verilen girişe karşılık olarak istenilen çıkışı elde edebilmesi için hatanın en aza indirgenmesi gerekir. Yapay sinir ağlarında öğrenme iki şekilde gerçekleştirilir. Bunlar ileriye doğru hesaplama ve geriye doğru hesaplama'dır. İleri doğru hesaplamada girdi değerleri işlenerek bunlara karşılık gelen çıktı değerleri hesaplanır. Her girdi için bir çıktı üretene kadar işlem devam eder. Geriye doğru hesaplamada ise, ağın ürettiği çıktı değerleri ile beklenen çıktı değerleri karşılaştırılır. Ağın ürettiği çıktı değerleri ile beklenen çıktı değerleri arasındaki farka hata denir. Geri yayılım algoritmasının temel amacı bu farkı yani hatayı azaltmaktır. Öğrenme sürecinin başlangıcında ağırlıklar rastgele belirlenir. Geriye hesaplamada hata önceki katmana geri yayılarak ağırlıklar güncellenir. Böylelikle hata azaltılmış olur. Bu iterasyonlar hata belli bir değerin altına düşene kadar devam eder.

Çok katmanlı ağ için geri yayılım hesabı aşağıdaki adımlardan oluşmaktadır [31]:

1.adım: İleri doğru hesaplama ile ara katmanlara gelen değerler Eşitlik 2.1'e göre hesaplanır.

$$NET_i = \sum_{i=1}^m w_i x_i + b \quad (2.1)$$

Burada, w ; ağırlıklar, x ; girdiler, b ; bias değeridir.

2.adım: Kullanılacak aktivasyon fonksiyonuna göre ara katmanın çıkış değeri Eşitlik 2.2' e göre hesaplanır. Aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanıldığını varsayarsak;

$$\zeta_{NET_i} = \frac{1}{1+e^{-(NET_i)}} \quad (2.2)$$

İlk 2 adım, girdi katmanından alınan değerlerden ara katmandaki çıktı değeri hesaplanırken ve ara katmanın yeni girdi değerinden çıktı değeri hesaplanırken tekrarlanır. Bu işlemler sonucunda yeni bir çıktı değeri elde edilir.

3.adım: Geri doğru hesaplama ile beklenen çıktı ile hesaplanan çıktı arasındaki fark değeri Eşitlik 2.3'e göre hesaplanır.

$$e_j = B_j - \zeta_j \quad (2.3)$$

e_j ;hata değeri, B_j ; beklenen çıktı, ζ_j ; ağın ürettiği çıktı. Toplam hata hesaplanırken hata karelerinin ortalaması Eşitlik 2.4'e göre alınır.

$$E = \frac{1}{2} \sum_j e_j^2 \quad (2.4)$$

4.adım: Elde edilen hata değeri geriye doğru dağıtılarak ağırlıkların güncellenmesi sağlanır. Hata fonksiyonunun türevi ağırlıklara göre hesaplanır. Bunun için sigmoid fonksiyonu gibi bir aktivasyon fonksiyonu kullanılır. Ağın ürettiği çıktının aktivasyon fonksiyonu cinsinden yazılması Eşitlik 2.5'e göre yapılır. Toplam hatanın herhangi bir ağırlığa göre türevi Eşitlik 2.6'da verildiği gibi zincir kuralına göre alınır. Ağırlığın yeni değeri Eşitlik 2.7'e göre hesaplanır. Burada η ; öğrenme katsayısıdır.

$$\zeta_j = f(a_j) = \sum_i x_i w_{ji} \quad (2.5)$$

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial \zeta_j} \cdot \frac{\partial \zeta_j}{\partial w_{ji}} \quad (2.6)$$

$$w_{ji} = w_{ji} - \eta \frac{\partial E}{\partial w_{ji}} \quad (2.7)$$

3. DERİN ÖĞRENME

3.1. Derin Öğrenmenin Tarihçesi

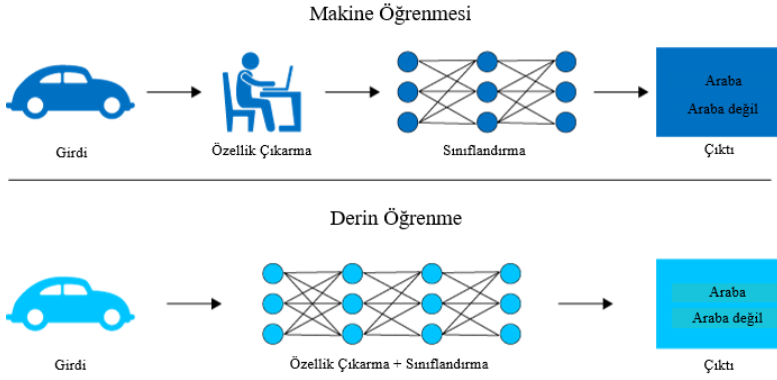
İlk derin ağ mimarisi 1965 yılında Ivakhnenko ve arkadaşları tarafından eğitilen çok katlı ağ modelidir [38]. Bu ağ yapısı için özellik seçim adımları başka bir katmanın eklenmesiyle daha fazla gelişme sağlanamadığından dolayı sürekli olarak daralan bir mimariye sahiptir. 1980’de Fukushima tarafından görsel örüntü tanıma için çoklu havuzlama ve evrişim katmanlarına sahip bir sinir ağı modeli tasarlanmıştır [39]. Neocognitron adlı ağ, “*öğretmen olmadan öğrenme*” ile kendini organize eden ve şekillerin pozisyonlarından etkilenmeden, geometrik benzerliğine dayanarak modellerini tanıma becerisine sahiptir. Derin öğrenme ağlarının eğitimi sırasında ayarlanması gereken çok sayıda parametre vardır. 1985 yılında Rumelhart ve arkadaşlarının sinir ağı eğitiminde hataları azaltmak için geri yayılım algoritmasını kullanması ile bu alandaki gelişmeler hız kazanmıştır [40]. LeCun ve arkadaşları 1989’da el yazısı posta kodunu tanıma için ve 1990’da el yazısı rakamları tanıma için geri yayılım algoritmasını ESA için kullanmışlardır [41,42]. Bu gelişmelere rağmen derin öğrenme algoritmalarının çalışması için çok sayıda veriye ve bu veriyi işleyebilecek kapasitede bilgisayarlara ihtiyaç bulunmaktadır. Bu alandaki bir diğer önemli gelişme ise bilgisayarların veri işlemede daha hızlı hale gelmeye başladığı ve grafik işleme birimlerinin (GPU) geliştirildiği yıllarda gerçekleşmiştir. GPU’ların resimleri daha hızlı işlemesi ile hesaplama hızı yaklaşık 10 yıllık bir sürede 1000 kat daha fazla artmıştır [43]. Derin ağların eğitimindeki bir diğer sorun, gradyan problemlerinden dolayı daha önceki katmanlara hiçbir öğrenme sinyalinin ulaşamaması ve özelliklerin öğrenilememesidir. Bu problemin çözümü için ağ, denetimsiz öğrenmeyi kullanarak önceden eğitilmiş katmanlar ile tasarlanmıştır [44]. Derin ağ mimarilerinde ağ eğitimi için çok sayıda etiketli veriye ihtiyaç olduğundan 2009 yılında Fei-Fei Li ve arkadaşları tarafından 14 milyondan fazla etiketli görüntü içeren ImageNet veri tabanı oluşturulmuştur [45]. Derin öğrenmenin dünya çapında yankı uyandırması 2012 yılında gerçekleşmiştir. Krizhevsky ve arkadaşları ImageNet Büyük ölçekli Görsel Tanıma Yarışmasında (ILSVRC) kullandıkları AlexNet ağı ile %26.2 olan top-5 test hata oranını %15.3’e kadar düşürmüşlerdir [46]. Bu ağ yapısında daha hızlı bir eğitim için GPU kullanılmış ve tam bağlı katmanlardaki ezberlemeyi (overfitting) azaltmak için, “dropout” olarak adlandırılan düzenleme yöntemi uygulanmıştır. Büyük ölçekli veri

setlerinde ezberleme, eğitim verilerindeki karmaşık uyumları önlemek için dropout kullanılarak azaltılabilir. Dropout yönteminde, her bir eğitim iterasyonunda her bir gizli katman ağdan rastgele bir şekilde 0,5 olasılıkla çıkarılır ve böylece bir gizli katman mevcut olan diğer gizli katmanlara bağlanmaz [47].

3.2. Tanım

Geleneksel makine öğrenmesi algoritmaları özellik çıkarma açısından bazı dezavantajlara sahiptirler. İlk olarak, yüksek boyutlu verilerle çalışırken, yani çok sayıda girdi ve çıktıya sahipken bu verileri işlemede kullanışlı değildirler. Bir diğer dezavantaj ise bilgisayara sonucu tahmin etmede ve daha iyi bir doğruluk elde etmede bakması gereken özelliklerin neler olduğunu anlatmaktır [48]. Bu nedenle, makine öğrenmesi modellerini veya algoritmalarını nesne tanıma, el yazısı tanıma, doğal dil işleme (NLP) vb. gibi karmaşık problemlere uygulamak çok zordur. Derin öğrenme; NLP, bilgisayarlı görme ve görüntü işleme alanındaki çeşitli problemleri çözmek için çok sayıda benzer fakat farklı derin sinir ağı mimarilerini kullanan bir makine öğrenmesi dalıdır [49]. Derin bir sinir ağının temel öğrenme yapısı; ağın her bir katmanının önceden eğitilmesi ve çıktının sonraki katmana giriş olarak verilmesine dayanır [50].

Derin öğrenmede derin sinir ağları sayesinde sınıflandırma için önemli olan özellikler otomatik olarak öğrenilir, buna karşın Makine Öğrenmesinde ise bu özellikler manuel olarak tanımlanmak zorundadırlar. Derin öğrenme algoritmaları, özellik hiyerarşileri olarak adlandırılan bir yöntemle çoklu katmanlarda görüntü özelliklerini keşfeder. Her katmandaki özellikler önceki katman gösterimlerinden hesaplanır ve özellikler aşamalı olarak düşük seviyeden yüksek seviyeye doğru öğrenilir [51]. Makine öğrenmesi algoritmaları kararlar veya tahminler yapmak için verilerden bilgi alırken, Derin Öğrenme algoritmaları öğrenmeyi aşamalı ve birikimli hale getirmek için katmanlardaki verilerle etkileşime girer [52]. Şekil 3.1’de makine öğrenmesi ve derin öğrenme için araç görüntüsü sınıflandırılırken uygulanan adımların karşılaştırılması gösterilmiştir.



Şekil 3.1. Makine öğrenmesi ve derin öğrenme yöntemlerinde görüntü sınıflandırma [53]

Derin öğrenme ile son yıllarda görüntü tabanlı nesne tanımada [46], konuşma tanımada [54], optik karakter tanımada [55], trafik işaretlerini tanımada [56] kayda değer sonuçlar elde edilmiştir. Facebook yapay zekâ araştırma ekibi (FAIR) derin öğrenmeyi kullanarak fotoğraftaki nesnelere algılamak için 3 aşamalı bir sistem tasarlamıştır. DeepMask [57] ile ilk aşamada nesne maskeleri oluşturulmuştur, SharpMask [58] ile bu maskeler daha hassas hale getirilmiş ve son olarak MultiPathNet [59] ile her maske tarafından tanımlanan nesnelere algılanmıştır. Literatürde dil işleme probleminde hem çoklu görev öğrenimi hem de yarı gözetimli öğrenme için kullanılan derin öğrenme ağları da mevcuttur [60].

Derin öğrenme algoritmaları iki amaçla kullanılabilir. Bu amaçlar; özellik çıkarma ve transfer öğrenmedir. Özellik çıkarma aşamasında, önceden eğitilmiş sinir ağ yapısı probleme uygun yeniden eğitilerek sınıflandırma işlemi gerçekleştirilir. Transfer öğrenmede ise önceden eğitilmiş ağın son üç katmanı kaldırılır ve probleme uygun bir çözüm bulmak için yeni katmanlar eklenir. Ağ tekrar eğitilir.

3.3. Transfer Öğrenme

Transfer Öğrenme (TÖ), bir alanda daha önce öğrenilen bilginin sınıflandırma ve özellik çıkarma amacıyla başka bir alana aktarılması olarak tanımlanır [61]. Hedef veri kümesinin sınırlı miktarda etiketli veriye sahip olması durumunda ezberlemenin üstesinden gelmek için etkili bir araçtır [62]. Makine öğrenme yöntemlerinin tersine, transfer öğrenme yöntemleri, mevcut alandaki farklı veri modellerinden oluşan tahmin modellemesini kolaylaştırmak için yardımcı alanlardaki verilerden toplanan bilgiyi kullanır [50]. Derin öğrenme modellerinde TÖ, daha büyük bir veri setinde daha önce eğitilmiş derin bir ESA modeli kullanılarak gerçekleştirilmektedir. Daha az sayıda eğitim görüntüsü içeren yeni bir veri kümesinde

önceden eğitilmiş ESA modelinin kullanılması ile veri kümesi daha önce eğitilmiş veri kümelerine göre daha fazla eğitilir. Bu işleme ince ayar (fine-tuning) denmektedir. Son zamanlarda birçok derin öğrenme uygulamasında TÖ kullanılmıştır. Çünkü önceden eğitilmiş bir ESA modelinin ince ayarının yapılması, rastgele başlatılmış ağırlıklar ile bir ESA modelinin eğitilmesinden genellikle çok daha hızlı ve kolaydır. Derin ESA'ları sıfırdan eğitmek, yüksek hesaplama gücü, geniş bellek kaynakları ve zaman gerektirir. Transfer öğrenmenin performansını değerlendirme yöntemi, önceden eğitilmiş ağırlıklı ağların hata oranlarını rastgele başlatılmış ağlarınkiler ile karşılaştırmaktır [63].

Genel olarak ESA modellerinde, başlangıç katmanlarında kenarlar, eğriler, köşeler ve renk bölgeleri gibi özellikler öğrenilir ve ESA modellerinin son katmanları soyut ve belirli özellikleri temsil eder [46]. Pratik uygulamalarda, önceden eğitilmiş ESA modelinin son üç katmanı, yani tam bağlı katman, softmax tabakası ve sınıflandırma çıktı katmanı kaldırılır ve kalan katmanlar yeni sınıflandırma görevine aktarılır.

3.4. Özellik Çıkarma

Derin özellik çıkarma, başka bir transfer öğrenme türü olarak görülebilir [61]. Önceden eğitilmiş bir ESA modelinin ince ayarını yapmak yerine, ESA modelinin aktivasyon katmanları temsili özellik vektörlerini çıkarmak için kullanılabilir. Önceki katmanların aktivasyonları, kenarlar gibi düşük seviyeli görüntü özelliklerine benzer gösterimler sağlarken, daha derin katmanlar, görüntü sınıflandırması için daha yüksek seviyeli özellikler sunar. Örneğin, ImageNet'de, birinci ve ikinci tam bağlı katmanların (fc6 ve fc7) aktivasyonları, görüntü tanıma görevleri için bir özellik temsili olarak yaygın şekilde kullanılır. Ortaya çıkan özellik vektörleri toplam 4096 öznitelik içerir.

3.5. Evrimsel Sinir Ağları


ESA, öğrenme yoluyla kendini optimize eden yapay sinir ağlarına benzemektedir. Klasik bir sinir ağındaki katman sayısı arttıkça oluşan hesaplama problemi, ESA yardımı ile çözülebilir. ESA, bu problemi işlem hızı yüksek, kapasiteleri artırılmış GPU sayesinde çözer. ESA hesaplama algoritması, aranan özellikleri temsil eden giriş verileri ve filtreler arasındaki bir dönüşüme dayanır. ESA ve YSA arasındaki temel fark, ESA'nın öncelikli olarak görüntü içinde örüntü tanıma alanında kullanılmasıdır. Bu, görüntüye özgü

özelliklerin mimariye kodlanmasını sağlayarak, ağın görüntü odaklı görevler için daha uygun hale getirilmesini sağlar. Ayrıca modeli kurmak için gerekli parametreleri daha da azaltır [64].

Yapay sinir ağlarından farklı olarak ESA'nın katmanları 3 boyutta sıralanmış nöronlara sahiptir. Bu boyutlar; genişlik, yükseklik ve derinliktir. ESA, iki boyutlu (2-D) bir evrişim katmanı kullanır ve bu nedenle görüntü gibi 2-D verilerinin işlenmesi için uygundur. Evrişimsel sinir ağları ile yapay sinir ağlarının arasındaki bir diğer fark ise; katmanlarda yapılan işlemlerdir. ESA' da, evrişim katmanları sayesinde öznitelik çıkarılır ve sayısı artırılır. Klasik Sinir Ağlarında da katmanlarda öznitelikler çıkarılır ve bu öznitelikler sonucunda sınıflandırma işlemi yapılır. ESA'da ise resmin üzerinde bir filtre yapay ve dikey hareket ettirilerek öznitelikler çıkarılır. Sonra bu özelliklerin boyutları azaltılır ki bu faydalı bir azalmadır. Bu sayede ağda daha az bir hesaplama işlemi yapılır.

Evrişimsel sinir ağlarının katmanları sırasıyla; giriş katmanı, evrişim katmanı, doğrultulmuş doğrusal birim katmanı, havuzlama katmanı, tam bağlantılı katman, dropout katmanı ve sınıflandırma katmanıdır. ESA, uçtan uca (end to end) öğrenme yapısıyla hem öznitelik çıkarma hem de sınıflandırma sağlar [65]. Evrişim, havuzlama ve doğrusal birim katmanları, ağı oluşturmak için sıralı bir şekilde yerleştirilir. Evrişim ve havuzlama işlemlerinin gerçekleştirilmesi, sınıflandırmanın gerçekleştirildiği üst düzey özellikleri art arda oluşturur. Sınıflandırma, ESA mimarisinin tam bağlantılı katmanında gerçekleştirilir. Eğitim aşamasında, ESA gerçekleştirilmek istenen işleme göre otomatik olarak filtrelerin değerlerini öğrenir. Örneğin, bir görüntü ham piksel değerleri ile girişe verilir. Sınıflandırma sırasında, bir ESA ilk katmanda kenarların varlığını veya yokluğunu öğrenir, daha sonra ikinci katmanda kenar pozisyonlarındaki küçük değişikliklere bakılmaksızın basit şekilleri tespit etmek için kenarları kullanır ve daha sonra yüksek katmanlardaki yüz gibi üst düzey şekilleri belirlemek için bu özellikleri kullanır. Son katman, bu yüksek seviyeli özellikleri kullanan bir sınıflandırıcıdır [66].

Şekil 3.2' de görüldüğü gibi ESA'ya verilen bir araba resmine katmanlarda belli işlemler uygulanarak özellik çıkarımı gerçekleştirilmiş ve en son sınıflandırma katmanında da uygulanan işlemlerin sonucunda sınıflandırma işlemi gerçekleşmiştir. İlk aşamada bilgisayarlı görme için geliştirilen ESA modellerinin, NLP ve daha birçok uygulama için etkili olduğu ve mükemmel sonuçlara ulaştığı görülmüştür [67].



Şekil 3.2. Evrişimsel sinir ağının katmanları [68]

3.5.1. ESA katmanları

3.5.1.1. Giriş Katmanı

Bu katman ESA'nın ilk katmanıdır. Görüntü ham piksel değerleri ile ağına verilmektedir. Görüntü boyutunun artması eğitim süresini arttırsa da ağın başarısı da artacaktır. Aynı şekilde görüntü boyutunun küçük seçilmesi eğitim süresini azaltır fakat ağın başarısı da düşük olur. ESA, giriş görüntüsünü kategorilere ayırır. Görüntüyü, bu kategoriler arasında sonucun en yüksek çıktığı sınıfa atar.

3.5.1.2. Evrişim katmanı

ESA adını bu katmandan alır. Bu katman ESA'nın temel yapı taşıdır. Evrişim katmanı, giriş görüntülerini bir dizi filtre işleminden geçirir. Bu filtrelerin her biri görüntüdeki belirli özellikleri etkinleştirir. İlk evrişim katmanı; kenarlar, çizgiler ve köşeler gibi düşük seviyeli özellikleri seçip çıkarır. Daha yüksek seviyeli evrişim katmanları daha yüksek seviyeli özellikleri seçip çıkarmaktadır [69]. Filtreler giriş boyunca dikey ve yatay olarak hareket eder ve her bölge için, resmin değerleri ve filtrenin değerleri birbiri ile çarpılır, sonuçlar toplanır ve çıkış matrisine yazılır. Bu filtreleme işlemine evrişim denir. Filtreler değişik boyutlarda olabilir. Evrişim işlemi sonucunda bir aktivasyon haritası oluşturulur. Boyutları $N \times N \times D$ olan bir giriş görüntüsüne, boyutları $k \times k \times D$ olan bir filtre uygulandığı zaman aktivasyon haritasının boyutları $(N - k + 1) \times (N - k + 1)$ olacaktır [69]. Şekil 3.3'de görüldüğü üzere 5×5 'lik bir giriş resmine 3×3 'lük bir filtre uygulanmış, çıkış olarak 3×3 'lük bir matris elde edilmiştir.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

4		

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0


4	3	

Şekil 3.3. Giriş matrisine uygulanan filtre ile oluşan öznelikler [70]

3.5.1.3. Doğrultulmuş Doğrusal Birim Katmanı

Bu katman evrişim katmanından sonra gelir. Bu katmanda bir aktivasyon fonksiyonu kullanıldığı için bu katmana aktivasyon katmanı da denilmektedir. ESA’ da aktivasyon fonksiyonu olarak çoğunlukla ReLu (doğrultulmuş doğrusal birim) kullanılır. Bunun sebebi ReLu’nun diğer aktivasyon fonksiyonlarına göre hem ileri besleme hem de geri yayılım için daha hızlı çıkış üretmesidir [71]. Evrişim işlemi uygulandıktan sonra oluşturulan aktivasyon haritasına ReLu fonksiyonu uygulandıktan sonra oluşturulan doğrultulmuş aktivasyon haritası Eşitlik 3.1’e göre hesaplanır [72]. Şekil 3.4’de görüldüğü gibi ReLu katmanının temel etkisi görüntüdeki negatif piksellerin sıfır (0) ile değiştirilmesidir.

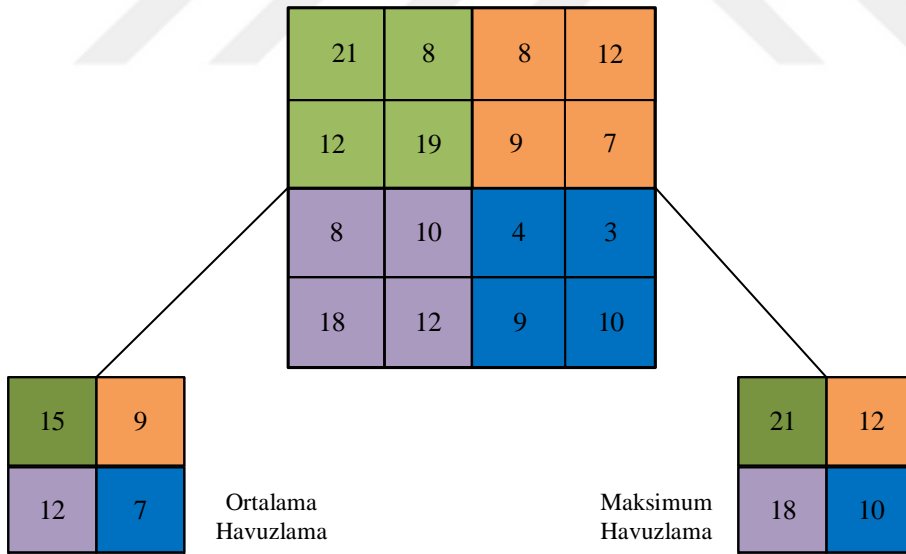
$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (3.1)$$



Şekil 3.4. ReLu fonksiyonunun matris üzerindeki etkisi [69]

3.5.1.4. Havuzlama Katmanı

Aktivasyon katmanından sonra havuzlama katmanı gelir. Bu katman alt örnekleme veya aşağı örnekleme katmanı olarak da adlandırılmaktadır. Bu katmana alt örnekleme veya aşağı örnekleme denilmesinin sebebi; giriş matrisi üzerinde bir filtre gezdirilerek resimden daha farklı boyutlarda ya da özelliklerdeki resimleri tanıyabilmesi ve bu sayede daha iyi bir tanıma işlemi yapılabilmesidir. Evrişim katmanında olduğu gibi bu katmanda da giriş görüntüsüne belli boyutlarda filtreler uygulanır. Şekil 3.5’de görüldüğü gibi 4×4’lük bir giriş matrisine 2×2’lik maksimum ve ortalama havuzlama filtresi uygulanmıştır. Maksimum havuzlamanın mantığı, giriş matrisi üzerinde dolaştırılan filtredeki her bir kare için en yüksek değeri çıkış matrisine yazmasıdır. Ortalama havuzlamanın mantığı ise her karenin ortalamasının alınıp çıkış matrisine yazılmasıdır. Böyle bir işlem sonucunda giriş matrisinin genişlik ve yükseklik boyutları azalsa da bu ESA için faydalı bir azalmadır. Maksimum, ortalama ve toplam gibi değişik havuzlama çeşitleri vardır fakat ESA’ da genel olarak maksimum havuzlama kullanılır.



Şekil 3.5. Maksimum ve ortalama havuzlama uygulanmış bir matrisin çıktısı [73]


3.5.1.5. Tam Bağlantılı Katman

Bu katman havuzlama katmanından sonra gelir. Bu katmana tam bağlantılı katman denilmesinin sebebi; kendinden önceki katmandaki tüm nöronlarla birbirine bağlıdır. Bu katmandan önceki katmanlarda özellik çıkarımı işlemi yapılırken bu katmanda artık bir

sınıflandırma işlemi yapılır. Evrişim ve havuzlama katmanlarında yapılan işlemlerden sonra elde edilen çıktı, giriş görüntüsünün yüksek seviyeli özelliklerini temsil eder. Tam bağlantılı katmanın amacı, giriş görüntüsünü eğitim veri kümesine dayalı olarak çeşitli sınıflara sınıflandırmak için bu özellikleri kullanmaktır [71].

3.5.1.6. DropOut Katmanı

Evrişimsel Sinir Ağları YSA'ya göre daha fazla katmana sahiptir. Bu katmanlarda daha çok veri ile işlemler yapılır. Bu da hesaplama yönünden daha fazla bir yük oluşturur. Bu ağlardaki büyük miktarda verileri işleme sırasında ağ bazen ezberleme yapabilir. Hesaplama yükünü azaltmak ve ağın ezberlemesini önlemek için eğitim sırasında rastgele bazı düğümler ağdan kaldırılır. Şekil 3.6'da görüldüğü üzere ESA' da nöronlar önceki katmanlarla birbirine tam bağliken dropout uygulandıktan sonra bazı düğümler rastgele kaldırılmıştır.



(a) Standart Evrişimsel Sinir Ağı


(b) Dropout uygulandıktan sonra

Şekil 3.6. Evrişimsel Sinir Ağına DropOut Uygulanması [74]

3.5.1.7. Sınıflandırma Katmanı

Bu katman ESA'nın son katmanıdır. Bu katmanda sınıflandırma işlemi yapılmaktadır. Bu katmandan önceki katmanlarda giriş görüntüsüne ait belli özellikler çıkarılır. Bu özellikler sayesinde yüksek bir doğruluk oranıyla bu katmanda sınıflandırma işlemi tamamlanır. Şekilde görüldüğü üzere sınıflandırma çıktı olasılıklarının değerinin toplamı birdir. Bunun sebebi; Softmax aktivasyon fonksiyonu kullanılmasıdır [75]. Softmax aktivasyon fonksiyonunun işlevi; bir sinir ağının çıkış değerlerini normalize ederek onları

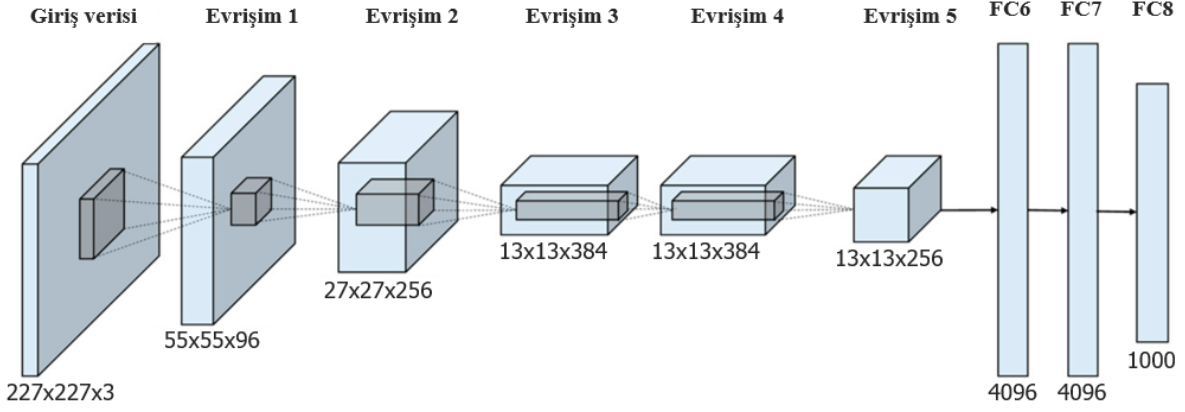
olasılık değerlerine dönüştürmektir. Şekil 3.7’de görüldüğü üzere girişe bir köpek resmi verilmiş olup yüksek bir doğruluk oranıyla sınıflandırma gerçekleştirilmiştir.



Şekil 3.7. Sınıflandırma işleminin iki olası sonucu [76]

3.6. AlexNet


AlexNet, ESA’ların popülerleşmesini sağlayan derin ağ modelidir ve ImageNet-2012 yarışmasının kazananıdır. ReLu, dropout katmanları, havuzlama katmanları ve eğitilebilir ağırlıkları içeren sekiz katmanı ile toplamda 25 katmandan oluşmaktadır. Eğitilebilir ağırlıkları içeren katmanlar; beş evrişim katmanı ve üç tam bağlı katmanlardır. ImageNet veri tabanındaki görüntüler farklı boyutlara sahip olduğundan dolayı herhangi bir şekilde ön işlem uygulanmadan ham RGB (Red Green Blue) değerlerinde 256×256 sabit boyuta yeniden boyutlandırılmıştır. Bu görüntülerden rastgele kırılmış 227×227 görüntü yamaları ile ağı eğitimi gerçekleştirilmiştir. İlk evrişim katmanında filtreler 11×11 boyutunda ve 4 piksellik bir adımla kayar. İkinci evrişim katmanında ilk evrişim katmanının çıktısı alınmıştır ve 5×5 boyutlu filtre kullanılmıştır. Bu katmandan sonraki evrişim katmanlarında 3×3 ’lük filtre kullanılmıştır. Tam bağlı katmanların her biri 4096 nörona sahiptir. Son katman, 1000 sınıflı etiketli veriler üzerinde çalışabilen softmax katmanıdır [46]. Şekil 3.8’de AlexNet ağı gösterilmiştir.



Şekil 3.8. AlexNet ağı [46]

3.7. VGG16

Simonyan ve arkadaşları ESA'daki derinliğin büyük ölçekli görüntü tanımda nasıl etki ettiğini araştırmak için ILSVRC-2014 yarışmasına VGG16 adında daha derin bir ağ modeli tasarlamışlardır [77]. VGG16 modeli, öğrenilebilir ağırlıklara sahip 16 katmanın ardından ReLu ve havuzlama katmanların olduğu toplam 41 katman içerir. Öğrenilebilen katmanları, 13 evrişim katmanı ve 3 tam bağlı katman oluşturur. VGG16 modeli, tüm evrişim katmanlarda sadece 1 piksellik adım kayma ve 3x3 filtre kullanır ve AlexNet'e benzer şekilde, maksimum havuzlama katmanları evrişim katmanlarını takip eder [46,77]. Maksimum havuzlama 2 adımlı 2x2 filtre ile gerçekleştirilir. Birinci ve ikinci tam bağlı katmanlardaki aktivasyonlar (fc6, fc7), özellik vektörlerini çıkarmak için kullanılır. fc6 ve fc7'den elde edilen sonuç vektörleri toplam 4096 özneliği içerir. Eğitim için 224x224 boyutunda RGB görüntüler kullanılmıştır. VGG16, AlexNet'ten daha iyi performans göstermesine ve daha basit bir mimari tasarıma sahip olmasına rağmen, daha fazla hesaplama gerektiren parametreye sahiptir. Şekil 3.9'da VGG16 ağı verilmiştir.




Şekil 3.9. VGG16 ağı [77]

4. DÜŞÜK SEVİYELİ DOKU ÖZNETELİKLERİ

Bir verideki ayırt edici özelliklerin çıkarılması, verinin doğru bir şekilde tanımlanması için oldukça önemlidir ve sınıflandırma algoritmasının başarısının artmasını sağlayacaktır. Özellik çıkarma işleminin amacı, sınıflandırma gibi karar verme sürecini kolaylaştırmak için ham görüntüyü indirgenmiş biçiminde temsil etmektir. Öznitelik vektörü, bir görüntünün veya gereksiz bilgileri atarak yararlı bilgileri ortaya çıkaran ve görüntüyü basitleştiren görüntü yamasının bir gösterimidir. Öznitelik vektörü özellik çıkarma işlemi sonucunda elde edilir. Bir görüntünün özelliklerini çıkarmanın çeşitli yolları vardır. Bu özellikler renk, doku veya şekle bağlı olarak çıkarılabilir. Doku tabanlı görüntü tanıma için birçok özellik tanımlayıcıları bulunmaktadır. Bu tez çalışmasında kullanılan yöntemler alt başlıklarda sırası ile verilmiştir.

4.1. Yerel İkili Örüntü (YİÖ)


İlk olarak Ojala ve arkadaşları [78] tarafından geliştirilen bu yöntem, 3×3 'lük bir pencerede, her pikseli komşusuyla karşılaştırarak bir görüntünün piksellerini etiketleyen ve sonucu bir ikili sayı olarak elde eden bir özellik çıkarma işlemidir. Komşu pikselleri eşikleme prensibine göre, merkez piksel değeri eşik değer olarak alınır. Bu değer komşu piksel değerleriyle karşılaştırılır. Eşik değerinden küçük piksel değerleri 0 olarak atanır. Büyük ve eşit piksel değerleri ise 1 olarak atanır. Böylece, her bir piksel için, bir ikili kod elde edilir. Tüm bu ikili kodları, sol üstten başlayarak saat yönünde hizalayarak sekiz bitlik bir ikili sayı elde edilir ve etiketleme için karşılık gelen ondalık değer kullanılır. Bu değer merkez pikselin yeni değeri olarak atanır. Şekil 4.1'de 3×3 'lük bir matrisin yerel ikili örüntü değerinin hesaplanmasına örnek verilmiştir.



Şekil 4.1. 3×3'lük matrisin yerel ikili örüntü değerinin hesaplanması [79]

4.2. Yönlü Gradyanlar Histogramı (YGH)

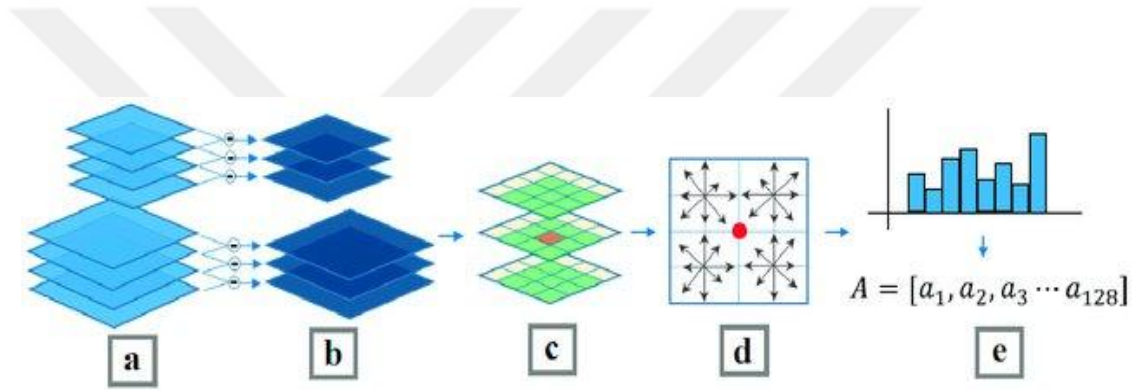
YGH, nesne tanıma amacıyla bilgisayarlı görme ve görüntü işlemede kullanılan etkili bir özellik tanımlayıcısıdır [80]. Bir giriş görüntüsünü dikdörtgen bölgelerin yoğun ızgarasına bölerek işlemine başlar. Her bir ilgi alanı için, gradyanların yönelimleri hesaplanır. Her bir pikselin gradyan büyüklüklerinin ağırlıklı oylarının birikmesine dayalı olarak her bölge için bir histogram oluşturulur. Genellikle, yerel histogram üretimi için, bir 8×8'lik pencere, dokuz hücreli ve 0-180 derece yönelim aralığı dikkate alınır. Ayrıca, dikdörtgen bölgeler bloklar halinde gruplanır ve tüm bölge histogramları normalleştirilir. Çakışma olduğundan, aynı bölge birkaç blokta farklı şekilde normalleştirilebilir. Şekil 4.2'de bir görüntünün yönlü gradyanlar histogramının elde edilmesi gösterilmiştir.



Şekil 4.2. Bir görüntünün yönlü gradyanlar histogramının elde edilmesi [79]

4.3. Ölçekten Bağımsız Özellik Dönüşümü (ÖBÖD)

Ölçekten Bağımsız Özellik Dönüşümü (ÖBÖD), 1999 yılında David Lowe [81] tarafından geliştirilen görüntü tabanlı eşleştirme ve nesne tanıma için bir özellik tanımlayıcısıdır. Bir görüntüdeki aydınlatma değişiklikleri, poz farklılıkları gibi gereksiz bilgiler sınıflandırma algoritmasının istenilen düzeyde çalışmasının önündeki en büyük engeldir. ÖBÖD yönteminde görüntü dönüşümlerinden, döndürmeden, ölçeklemeden ve aydınlatma değişikliklerinden bağımsız bir şekilde özellik dönüşümü yapılabilmektedir. ÖBÖD, görüntü eşleştirme, doku sınıflandırma ve nesne tanıma alanlarında iyi bir performans gösterdiği için öncelikli tercih edilen bir yöntemdir.



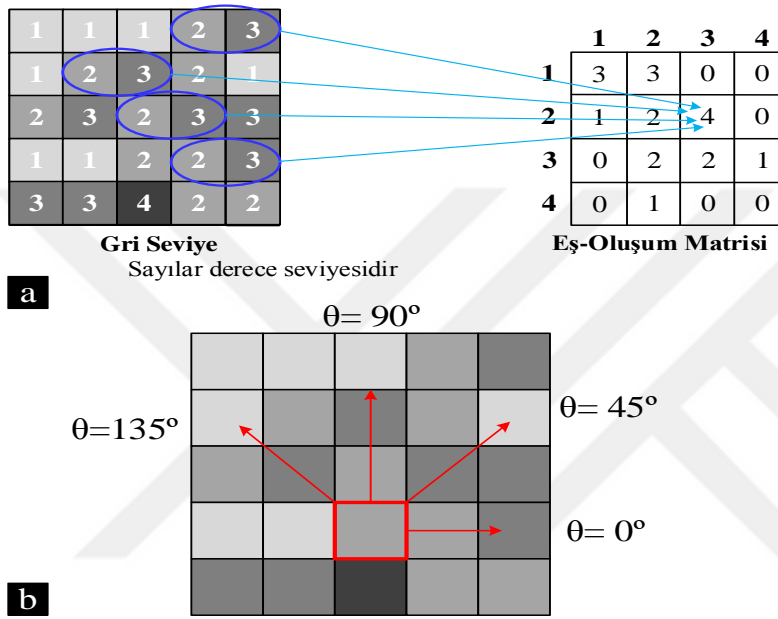
Şekil 4.3. ÖBÖD yönteminin adımları; (a) Ölçek alanı üretimi (b) DoG görüntü üretimi (c) Yerel maksimum ve minimum tespit (d) Gradyan hesaplama (e) Histogram hesabı ve 128 boyutlu vektörlerin üretimi [82]

Şekil 4.3’de ÖBÖD özellik çıkarma yönteminin adımları verilmiştir. ÖBÖD yönteminin iki temel amacı vardır. Bunlar; ölçeklemeye ve döndürmelere göre değişmeyen özelliklerin çıkarılmasıdır. Döndürme değişmezliği kilit noktaların etrafındaki piksellerin gradyan yönleri ve büyüklükleri kullanılarak sağlanır. Ölçek değişmezliği ise ölçek uzayı yaklaşımı kullanılarak sağlanır. Algoritmanın basamakları; Gaussian farkı (DoG) ile ölçek uzayı üretimi, kötü noktaların kaldırılması ile kilit nokta normalizasyonu, kilit nokta gradyanlarının yönlerinin belirlenmesi ve özellik vektörünün elde edilmesidir [83].

4.4. Gri Seviye Eş-Oluşum Matrisi (GSEM)

Eş-oluşum dağılımı olarak da adlandırılan bir eş-oluşum matrisi, bir görüntü üzerinde, verilen karşılıklı birlikte ortaya çıkan değerlerin dağılımı olarak tanımlanmaktadır. 1973

yılında Haralick ve arkadaşları [84] tarafından tanımlanan GSEM, gri ölçekli bir görüntüden oluşturulur. GSEM, gri tonlu m değerine sahip bir pikselin, n değeri ile birlikte, bitişik piksellere yatay, dikey veya çapraz olarak ne sıklıkta birlikte oluştuğunu hesaplar. GSEM hesaplandıktan sonra, görüntüdeki özellikleri temsil eden matristen doku özellikleri bulunabilir. Şekil 4.4’de gri renk bir matris için gri seviye eş oluşum matrisinin oluşturulmasına örnek verilmiştir.




Şekil 4.4. Gri seviye eş-oluşum matrisinin oluşturulması [79]

4.5. Destek Vektör Makinesi (DVM)

Sınıflandırma; daha önceden tanımlanmış ve etiketi belirlenmiş veri kümesine yeni gelen verinin sınıfının belirlenmesidir. İki farklı veri kümesini sınıflandırmak için veri kümeleri arasında bir sınır çizmek mümkündür. DVM, doğrusal ve doğrusal olmayan iki sınıflı veri kümelerinin sınıflandırılmasında sınıf üyelerini üye olmayanlardan ayıran sınırı oluşturan hiper düzlemi bulmaya çalışan sınıflandırma algoritmasıdır. 1995 yılında Vapnik ve Cortes tarafından [85] geliştiren DVM hem sınıflandırma hem de regresyon problemleri için kullanılan denetimli bir makine öğrenmesi algoritmasıdır. Doğrusal olarak ayrılabilen verilerde veriyi ayrılacak en yüksek marjli (veri ile doğru arasındaki mesafe) hiper düzlem seçilir. Matematiksel işlevli olan doğrusal olmayan çekirdeğin kullanılması doğrusal bir özellik uzayından gelen verileri doğrusal olmayan bir özellik alanına dönüştürür ve

böylelikle DVM doğrusal olmayan verilerde sınıflandırmayı gerçekleştirebilir. Şekil 4.5’de doğrusal olarak ayrılabilen ve ayrılamayan veri kümeleri görülmektedir.



Şekil 4.5. Doğrusal olarak ayrılabilen ve ayrılamayan veri kümeleri [79]

5. HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

5.1. Veri Tabanı

Bu çalışmada BreaKHis veri tabanı kullanılmıştır [86]. BreaKHis veri tabanı iyi huylu ve kötü huylu meme tümörlerinin mikroskopik biyopsi görüntülerini içerir. Görüntüler Ocak 2014'den Aralık 2014'e kadar bir klinik çalışma ile toplanmıştır. Örnekler, hematoksilin ve eozin (HE) ile boyanmış meme dokusu biyopsi parçalarından üretilmiştir. Örnekler, histolojik çalışma için hazırlanan ve P&D (önleme ve teşhis) Laboratuvarı patoloğları tarafından etiketlenmiş, SOB yöntemi ile toplanılmıştır. Veri tabanında 24'ü iyi huylu 58'i kötü huylu olmak üzere toplam 82 hastadan elde edilmiş 7909 histopatolojik meme kanseri görüntüleri bulunmaktadır. Örnekler toplanırken farklı büyütme oranları kullanılmıştır. Bu büyütme oranları 40X, 100X, 200X, 400X'dir. Veri seti beş kat (fold) olarak düzenlenmiştir. Görüntüler 700×460 piksel boyutlarında ve 3 kanallı görüntüler olup 2480'i iyi huylu örneklerdir ve 5429'u kötü huylu örneklerdir. Farklı büyütme oranlarındaki görüntülerin elde edilmesi şu şekilde gerçekleştirilir: patoloğ, tümörü ve ilgi bölgesini (ROI) tanımlar. Tüm ROI'yi kaplamak için, en düşük büyütme, yani, 40X'i kullanılarak birkaç görüntü yakalanır. Patoloğ tek bir tümör türüyle (vakaların çoğunda) görüntüleri seçer, ancak görüntülerin bazıları da, örneğin normal patolojideki geçiş dokusunu içerir. Daha sonra, büyütme oranı manüel olarak 100X'e yükseltilir ve başlangıçtaki ROI içinde benzer sayıda görüntü yakalanır. Bu işlem sırasıyla 200X ve 400X büyütme oranları için tekrarlanır. Her iki meme tümörü hücreleri mikroskop altında görünme şekline göre farklı tiplere ayrılabilir. Meme tümörlerinin çeşitli tipleri-alt tipleri farklı prognozlara (hastalığın süreci) ve tedavi sonuçlarına sahip olabilir. Veri seti şu anda dört farklı histopatolojik iyi huylu meme tümörü tipini içermektedir. Bunlar; adenosis (A), fibroadenom (F), fillodes tümör (PT) ve tübüler adenoma (TA)'dir. Benzer şekilde dört kötü huylu meme tümörü tipini içermektedir; ductal karsinom (DC), lobüler karsinom (LC), müsinöz karsinom (MC) ve papiller karsinom (PC). Tablo 5.1'de büyütme oranı ve tümör türüne göre görüntü dağılımı gösterilmektedir. Tablo 5.2 ve 5.3'de iyi huylu ve kötü huylu meme kanseri görüntülerinin histopatolojik alt tiplerine ve büyütme oranına göre dağılımı gösterilmektedir.

Tablo 5.1. Büyütme oranı ve tümör türüne göre görüntü dağılımı

Büyütme oranı	İyi huylu	Kötü huylu	Toplam
40X	625	1370	1995
100X	644	1437	2081
200X	623	1390	2013
400X	588	1232	1820
Toplam Görüntü	2480	5429	7909
Toplam Hasta	24	58	82

Tablo 5.2. Büyütme oranı ve histopatolojik alt tiplerine göre iyi huylu görüntü dağılımı


Büyütme oranı	A	F	TA	PT	Toplam
40X	114	253	109	149	598
100X	113	260	121	150	614
200X	111	264	108	140	594
400X	106	237	115	130	562
Toplam Görüntü	444	1014	453	569	2368
Toplam Hasta	4	10	3	7	24

Tablo 5.3. Büyütme oranı ve histopatolojik alt tiplerine göre kötü huylu görüntü dağılımı


Büyütme oranı	DC	LC	MC	PC	Toplam
40X	864	156	205	145	1370
100X	903	170	222	142	1437
200X	896	163	196	135	1390
400X	788	137	169	138	1232
Toplam Görüntü	3451	626	792	560	5429
Toplam Hasta	38	5	9	6	58

5.2. Evrimsel Sinir Ağlarına ait Deneysel Sonuçlar

Çalışmada, histopatolojik meme kanseri görüntülerinden meme kanseri tespiti için transfer öğrenme ve derin öznitelik çıkarma yöntemleri kullanılarak sınıflandırma performansları karşılaştırılmaktadır. Derin özellik çıkarımı ve transfer öğrenme için, iki popüler derin ESA mimarisi, yani AlexNet ve Vgg16 modelleri kullanılmıştır [46,77]. Üç farklı deneysel çalışma gerçekleştirilmiştir. İlk çalışmada, özellik çıkarma işlemi için AlexNet ve Vgg16 modellerinin fc6 katmanı kullanılmış, çıkarılan özellikler sınıflandırma için birleştirilmiştir. İkinci çalışmada, özellik çıkarmak ve elde edilen özellik vektörlerini birleştirmek için AlexNet ve Vgg16 modellerinin fc7 katmanları kullanılmıştır. Görüntülerin iyi huylu ve kötü huylu olarak sınıflandırılması için birinci ve ikinci deneysel çalışmalarda elde edilen özellik vektörleri daha sonra giriş görüntülerinin sınıf etiketini belirlemek için DVM sınıflandırıcı ile sınıflandırılmıştır. Üçüncü deneyde, önceden eğitilmiş AlexNet modeli meme kanseri görüntülerini sınıflandırmak için daha fazla ayarlanmıştır. BreaKHis veri seti rastgele % 70 eğitim ve % 30 test olarak ayrılmıştır. Özellik çıkarma işleminde veri seti kendi içinde ayrılmış şekliyle kullanılmıştır. Transfer öğrenmede ağı daha iyi ayarlanması ve daha çok veriye ihtiyaç duyulduğu için veri setindeki her fold tekrar birleştirilmiş ve %75 eğitim için %25 test için kullanılmıştır. Deneysel sonuçlar, ince ayarlı (fine-tuning) AlexNet 'in daha iyi performans gösterdiğini ve ilk deney sonuçlarının ikincisinden daha iyi olduğunu göstermektedir. Önerilen ESA'nın şeması ve mimarisi, şekil 5.1 ve 5.2'de sırasıyla verilmiştir. Her iki şekilde de görüldüğü gibi, önceden eğitilmiş ESA modellerinin girişi histopatolojik meme kanseri görüntüleri ile beslenmektedir.




Şekil 5.1. Histopatolojik görüntülerin Transfer Öğrenme için eğitilmesi [65]



Şekil 5.2. Histopatolojik meme kanseri görüntülerinden derin özellik çıkarma ve DVM sınıflandırması [65]

Deneyisel çalışma Intel Core i7-4810 CPU ve 32GB bellek ile yapılandırılmıştır. Öncelikli olarak tüm giriş görüntüleri AlexNet ve VGG16 modellerinin girişlerine uygun olarak sırasıyla 227×227 ve 224×224 boyutlarına yeniden boyutlandırılmıştır. Özellik çıkarma için fc6 ve fc7 katmanları kullanılmıştır. Çıkarılan özellikler daha sonra birleştirilmiştir. Homojen haritalama ile DVM sınıflandırıcısı ve L2-düzenli L2-kayıp çift çözücüsüne sahip LIBLINEAR Kütüphanesi, daha küçük miktarlarda eğitim verisine olan dayanıklılığından dolayı düşünülmüştür [87,88]. DVM parametresi C, $[10^{-4}-10^3]$ aralığında aranır. Önerilen yöntemin performansı, sınıflandırma doğruluğu kullanılarak değerlendirilmiştir. ESA modelinin ince ayarı için, küçük parça boyutu 10 olarak seçilmiştir ve başlangıç öğrenme oranı 0.0001 olarak belirlenmiştir. İlk öğrenme oranı, transfer edilen katmanlarda öğrenmeyi yavaşlatmak için yeterince küçük seçilmiştir. Maksimum devir sayısı 7'ye ayarlanmış ve ESA modeli momentumlu stokastik gradyan azalma ile eğitilmiştir. Eğitim işlemi yaklaşık 1100 iterasyonun sonunda sonlandırılmıştır. Şekil 5.3, ince ayarlı AlexNet modelinin eğitim sürecini göstermektedir. Sonuç, fold 3, 40X büyütme seviyesi için elde edilmiştir. Şekildeki ilk grafik, iterasyonlara karşı doğruluğun sapmasını gösterirken, ikinci grafik iterasyonlara karşı kayıp sapmasını gösterir.



Şekil 5.3. İnce ayarlı AlexNet modelinin eğitim süreci [65]

İlk deneyler, derin öznetelik çıkarımı ve DVM sınıflandırması ile gerçekleştirilmiştir. Elde edilen sonuçlar sırasıyla Tablo 5.4 ve 5.5’de tablo haline getirilmiştir. Tablo 5.4, AlexNet-fc6 ve Vgg16-fc6’dan gelen özelliklerin birleştirilmesiyle elde edilen sonuçları gösterirken, Tablo 5.5, AlexNet-fc7 ve Vgg16-fc7’nin birleştirilmiş derin özellikleriyle üretilen doğruluk değerlerini göstermektedir. Tablo 5.4 ve 5.5’in satırları; foldları, sütunları ise büyütme seviyelerini gösterir. Her fold için en yüksek değer koyu siyah ile gösterilmiştir.

Tablo 5.4. AlexNet-fc6 ve Vgg16-fc6 derin öznetelikler çıkarma sonuçları

	Doğruluk (%)			
	40X	100X	200X	400X
Fold 1	86.31	89.34	88.58	88.40
Fold 2	85.28	89.52	86.77	85.92
Fold 3	83.71	90.73	93.02	90.71
Fold 4	83.71	86.82	86.89	79.87
Fold 5	85.42	89.65	88.31	88.84

Tablo 5.4’de görüldüğü gibi, fold 1 için, en iyi sınıflandırma doğruluğu 100X büyütme seviyesindeki % 89.34’dır. 200X ve 400X büyütme faktörleri için doğruluk değerleri

sırasıyla % 88.58 ve % 88.40'dır. Fold 1 için en düşük doğruluk skoru 40X büyütme faktörü için elde edilmiştir. Fold 2 için, en yüksek doğruluk oranı 100X büyütme faktörü için % 89.52 olarak elde edilmiştir. Diğer büyütme seviyeleri için doğruluk değerleri sırasıyla % 85.28, % 86.77 ve % 85.92'dir ve 100X büyütme seviyesine yakın doğruluk değerleri üretmiştir.

40X büyütme seviyesi hariç, Fold 3 için elde edilen sonuçlar Fold 1, 2, 4 ve 5 için elde edilen sonuçlardan daha iyi bulunmuştur. 200X büyütme seviyesi için % 93.02 doğruluk değeri kaydedilmiştir. Fold 4 için % 86.89 ve % 86.82 doğruluk değerleri 200X ve 100X büyütme seviyeleri için elde edilmiştir. Son olarak, fold 5 için 100X büyütme seviyesi için % 89,65 doğruluk değeri kaydedilmiştir. Tablo 5.4 ile ilgili önemli bir sonuç; 100X büyütme seviyesi için elde edilen doğruluk değerlerinin diğer büyütme seviyelerinden daha iyi olmasıdır.

Tablo 5.5. AlexNet-fc7 ve Vgg16-fc7 derin öznetelikler çıkarma sonuçları

	Doğruluk (%)			
	40X	100X	200X	400X
Fold 1	85.10	89.34	87.77	87.94
Fold 2	86.39	88.23	86.10	84.48
Fold 3	83.41	91.18	93.78	90.71
Fold 4	82.71	87.25	85.86	79.87
Fold 5	85.29	89.16	88.05	87.03

Tablo 5.5, AlexNet-fc7 ve Vgg16-fc7'den çıkarılan özelliklerin birleştirilmesiyle elde edilen sonuçları temsil etmektedir. 100X büyütme seviyesinin sonuçları sırasıyla % 89.34, % 88.23, % 87.25 ve % 89.16'dır ve fold 1, 2, 4 ve 5 için en yüksek doğruluk değerleri elde edilerek daha iyi performans gösterdiğini belirtmek gerekir. Fold 3 için, en iyi doğruluk % 93.78; 200X büyütme seviyesi için üretildi. Ayrıca elde edilen tüm sonuçlar Tablo 5.4 ve 5.5'de verildiği zaman 40X ve 400X büyütme seviyeleri için herhangi bir en yüksek doğruluk değeri elde edilememiştir.

Tablo 5.6, ince ayarlı AlexNet modeli için elde edilen sınıflandırma sonuçlarını göstermektedir. İnce ayarlı AlexNet modelinin sonuçları (Tablo 5.6) diğer sonuçlar (Tablo 5.4 ve 5.5) ile karşılaştırıldığında daha iyi sonuçlar elde ettiği açıktır. Hemen hemen tüm elde edilen doğruluk değerleri % 90'ın üzerindedir. Fold 3 ve 40X büyütme faktörlerinde en

yüksek doğruluk değeri % 93,57 olarak bulunmuştur. Ayrıca fold 5 ve 200X büyütme faktöründe elde edilen % 93.24'lük bir doğruluk değeri daha vardır. Fold 2 ve 4, 400X büyütme faktörü için sırasıyla en yüksek doğruluk değerleri % 90.77 ve % 91.87 üretmiştir. Son olarak, fold 1, 40X büyütme faktörü için % 91.37 doğruluk değeri üretti.

Tablo 5.6. İnce ayarlı AlexNet ile elde edilen sınıflandırma doğruluğu

	Doğruluk (%)			
	40X	100X	200X	400X
Fold 1	91.37	91.35	88.87	90.77
Fold 2	89.76	90.58	90.66	90.77
Fold 3	93.57	92.50	92.64	90.77
Fold 4	90.16	87.31	91.45	91.87
Fold 5	89.96	91.15	93.24	92.31

Elde edilen sonuçlar için Tablo 5.7'de bir karşılaştırma daha yapılmıştır. Karşılaştırmalar, foldlar için hesaplanan ortalama doğruluk değerine ve standart sapmasına dayanılarak temsil edilmiştir. Tablo 5.7'nin sütunları büyütme seviyelerini göstermektedir. Tablo 5.7'de görüldüğü gibi, İnce Ayarlı AlexNet modeli ile tüm büyütme seviyeleri için en yüksek ortalama doğruluk değerleri elde edilmiştir ve en yüksek sonuç 200X büyütme seviyesinde % 91.37 ± 1.72 'dir. İkinci en iyi ortalama doğruluk değeri, AlexNet-fc6+Vgg16-fc6 özellik kümesi tarafından üretilmiştir. AlexNet-fc6+Vgg16-fc6 özellik kümesi için en yüksek sonuç 100X büyütme seviyesinde % 89.21 ± 1.44 olarak elde edilmiştir. En düşük ortalama doğruluk değerleri, AlexNet-fc7+ Vgg16-fc7 özellik seti ile elde edildi. AlexNet-fc7+Vgg16-fc7 çıkarılan özellikler için en yüksek sonuç 100X büyütme seviyesinde % 89.03 ± 1.46 'dir.

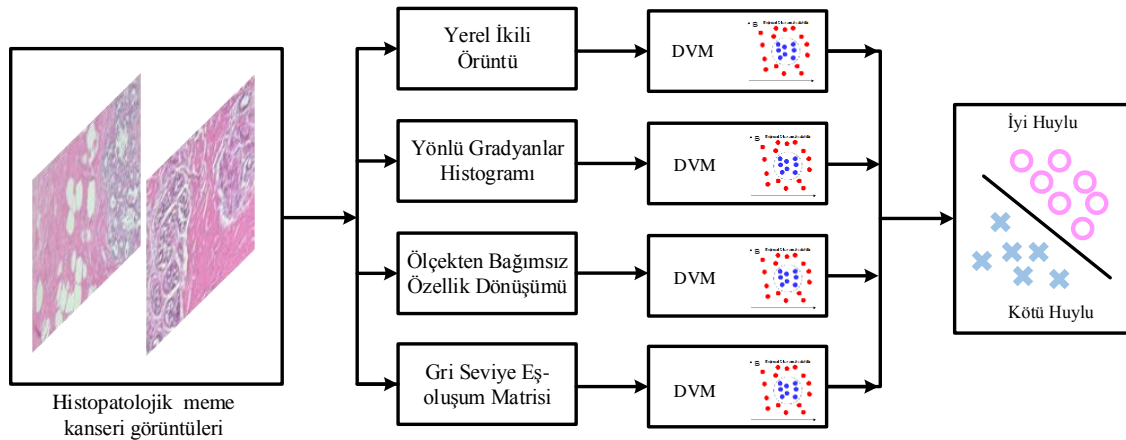
Tablo 5.7. Her büyütme seviyesi için elde edilen sonuçların karşılaştırılması

Yöntem	Doğruluk (%)			
	40X	100X	200X	400X
AlexNet-fc6+Vgg16-fc6	84.87±1.14	89.21±1.44	88.65±2.41	86.75±4.21
AlexNet-fc7+Vgg16-fc7	84.58±1.49	89.03±1.46	88.31±3.20	86.00±4.08
İnce ayarlı AlexNet	90.96±1.59	90.58±1.96	91.37±1.72	91.30±0.74

5.3. Düşük Seviyeli Doku Özniteliklerine ait Deneysel Sonuçlar

Çalışmada, meme kanserinin erken teşhisine yönelik bilgisayar destekli teşhis (BDT) sistemi önerilmiştir. Önerilen sistem özellik çıkarma ve sınıflandırma aşamalarından oluşmaktadır. Özellik çıkarım aşamasında düşük seviyeli doku öznitelikleri düşünülmüştür. Bunlar sırası ile Yerel İkili Örüntü (YİÖ), Yönlü Gradyanlar Histogramı (YGH), Ölçekten Bağımsız Özellik Dönüşümü (ÖBÖD) ve Gri Seviye Eş-Oluşum Matrisi'dir (GSEM). Sınıflandırıcı aşamasında da iyi bilinen Destek Vektör Makineler (DVM) yöntemi kullanılmıştır.

Deneysel çalışmalarda öncelikle veri tabanından elde edilen görüntüler yeniden boyutlandırılmıştır. Görüntü üzerinde dolaşan bir pencere ile görüntü yamaları oluşturulmuştur. Görüntü yamalarından özellik tanımlayıcılar ile öznitelik vektörü elde edilmiştir. Elde edilen öznitelik vektörlerinin birleştirilmesiyle öznitelik matrisi oluşturulmuştur. Öznitelik matrisini sınıflandırmak için DVM sınıflandırıcısı kullanılmıştır. Histopatolojik meme kanser görüntüleri, RGB bileşenlerinden oluşan renkli görüntüler olduğundan R, G ve B bileşenleri için ayrı ayrı hesaplamalar yapılmıştır. Özellik çıkarma aşamasında görüntüler YİÖ, YGH ve GSEM yöntemleri için 512×512 ; ÖBÖD yöntemi için 256×256 yeniden boyutlandırılmıştır. Pencere boyutu ise 128 olarak seçilmiştir. Şekil 5.4'de histopatolojik meme kanseri görüntülerinin düşük seviyeli doku öznitelikleri ile sınıflandırılması gösterilmiştir. Tablo 5.8'de düşük seviyeli özellik tanımlayıcılarının ortalama doğruluk değerleri verilmiştir. Tablo 5.9'da özellik çıkarma için aynı yöntemlerin kullanıldığı literatür çalışmasının sonuçları verilmiştir.



Şekil 5.4 Histopatolojik meme kanseri görüntülerinin düşük seviyeli doku öznitelikleri ile sınıflandırılması

Tablo 5.8. Özellik Tanımlayıcıların Ortalama Doğruluk Değerleri

YÖNTEM	Doğruluk (%)			
	40X	100X	200X	400X
YİÖ-YGH	69.86±0.43	71.61±1.90	74.60±2.76	71.33±3.76
ÖBÖD	72.14±2.52	72.09±1.33	73.85±5.94	67.20±5.00
GSEM	72.00±3.56	72.92±1.40	73.69±5.58	72.63±4.80
YİÖ-ÖBÖD	75.11±2.21	75.48±1.41	74.88±5.94	71.07±4.52
GSEM-ÖBÖD	68.96±2.69	70.68±1.85	65.81±4.51	68.12±3.97
GSEM-ÖBÖD-YİÖ	72.09±2.98	73.93±1.50	66.64±3.94	70.81±3.66

Tablo 5.8’de görüldüğü üzere, özellik çıkarma yöntemleri, 40X büyütme seviyesi için, 68 ile 75 değer aralığında değişmektedir. 40X, 100X, 200X’de en yüksek sonucu YİÖ-ÖBÖD yöntemi vermiştir. 100X büyütme seviyesi için, değerler 70 ile 75 aralığında değişmektedir. Değerler 200X büyütme seviyesi için 65 ile 74 ve 400X için 67 ile 72 aralığında değişmektedir. YİÖ-YGH, ÖBÖD ve GSEM yöntemleri 4 büyütme seviyesi içinde 200X’de en yüksek değerine ulaşmıştır. YİÖ-ÖBÖD, GSEM-ÖBÖD ve GSEM-ÖBÖD-YİÖ yöntemleri 100X’de en yüksek sonuca ulaşmıştır.

Tablo 5.9. Literatürdeki Çalışmanın Doğruluk Değerleri

YÖNTEM	Doğruluk (%)			
	40X	100X	200X	400X
YİÖ	74.20±5.00	73.20±3.50	71.30±4.00	73.10±5.70
GSEM	74.00±1.30	78.60±2.60	81.90±4.90	81.10±3.20

Tablo 5.9’da F. Spanhol ve arkadaşlarının [8] aynı veri seti (BreaKHis) için deneysel sonuçları gösterilmiştir. Verilen sonuçlar karşılaştırıldığında; özellik çıkarma yöntemlerinden olan YİÖ için 200X büyütme seviyesinde Tablo 5.8’deki değer 74.60 olarak elde edilirken, literatürdeki çalışmada (Tablo 5.9) bu sonuç 71.30 olarak kaydedilmiştir.

6. SONUÇLAR

Bu çalışmada son dönemlerde oldukça yaygın kullanılmaya başlanan derin öğrenme ve ESA hakkında bilgi verilmiştir. BrecaKHis veri tabanından alınan histopatolojik meme kanseri görüntülerinin sınıflandırılması için önceden eğitilmiş ESA modelleri mevcut probleme uygun yeniden eğitilerek ağın başarımlarını değerlendirmesi yapılmıştır. ESA özellik çıkarma ve transfer öğrenme aşamalarından oluşmaktadır. Önceden eğitilmiş AlexNet ve VGG16 modelleri özellik çıkarma işleminde kullanılmıştır. Transfer öğrenme için önceden eğitilmiş AlexNet modeli kullanılmıştır. Ağın başarımlarını DVM ile test edilmiştir. ESA için elde edilen sonuçlar sırası ile Tablo 5.4, 5.5, 5.6 ve 5.7’de verilmiştir. Sonuçlar incelendiğinde transfer öğrenme başarımlarının her iki özellik çıkarma sonuçlarından daha iyi olduğu gözlemlenmiştir. Deneysel çalışmalar ile ilgili tüm analizler MATLAB ’da yapılmıştır.

Histopatoloji meme kanseri görüntüleri daha sonra düşük seviyeli doku öznelikleri ile sınıflandırılmıştır. Özellik tanımlayıcı olarak yüksek performans gösteren YİÖ, YGH, ÖBÖD ve GSEM yöntemleri özellik çıkarma işleminde kullanılmıştır. Sınıflandırma DVM ile tamamlanmıştır. Yöntemlerin performanslarının karşılaştırılması Tablo 5.8’de verilmiştir. Sonuçlar değerlendirildiğinde YİÖ-ÖBÖD yöntemlerinin birleştirilmesinden elde edilen başarımların en yüksek sonucu veren değerlerdir. ESA ve düşük seviyeli doku özneliklerinden özellik çıkarmada, veri seti kendi içinde eğitim ve test için ayrıldığı haliyle kullanılmıştır. Transfer öğrenme için tüm veri seti yeniden eğitilmiştir. Sistemin başarımlarını test edilmiştir.

ESA ve düşük seviyeli doku özneliklerinin özellik çıkarma performansları karşılaştırıldığında ESA’nın görüntülerdeki özellikleri aşamalı olarak daha iyi öğrendiği için daha yüksek sonuçlara ulaştığı gözlemlenmiştir. Transfer öğrenme ve derin özellik çıkarma yöntemleri karşılaştırıldığında; transfer öğrenme probleme uygun olarak daha iyi ayarlandığından performans sonuçlarının da daha yüksek olduğu sonucuna varılmıştır.

KAYNAKLAR

- [1] American Cancer Society “About Breast Cancer.” Available: <https://www.cancer.org/content/dam/CRC/PDF/Public/8577.00.pdf>
- [2] American Cancer Society “Cancer Facts & Figures 2018.” Available: <https://www.cancer.org/content/dam/cancer-org/research/cancer-facts-and-statistics/annual-cancer-facts-and-figures/2018/cancer-facts-and-figures-2018.pdf>
- [3] **Dr. Filiz Yenicesu** “Meme Kanserinde Görüntüleme Yöntemleri” Available: [https://www.duzen.com.tr/workshop/2011/Meme_Kanserinde_Goruntuleme_Y%C3%B6ntemleri_\(Dr_Filiz_Yenicesu\).pdf](https://www.duzen.com.tr/workshop/2011/Meme_Kanserinde_Goruntuleme_Y%C3%B6ntemleri_(Dr_Filiz_Yenicesu).pdf)
- [4] **Selvathi, D., Poornila A. A.** “Breast Cancer Detection In Mammogram Images Using Deep Learning Technique” Middle East Journal of Scientific Research 25 (2), pp. 417-426, 2017.
- [5] **Wang, L.** “Early Diagnosis of Breast Cancer”, Sensors, vol.17-1572, pp.1-20, 2017.
- [6] American Cancer Society “Breast Biopsy” Available: <https://www.cancer.org/cancer/breast-cancer/screening-tests-and-early-detection/breast-biopsy.html>
- [7] **James, T.A., Mace, J.L., Virnig, B.A., Geller, B.M.** “Preoperative needle biopsy improves the quality of breast cancer surgery” Journal of the American College of Surgeons, 215(4), pp.562-568, 2012.
- [8] **Spanhol, F. A., Oliveira, L. S., Petitjean, C., Heutte, L.** “A Dataset for Breast Cancer Histopathological Image Classification”, IEEE Transactions on Biomedical Engineering, Vol. 63(7), pp. 1455-1462, 2016.
- [9] **Gurcan, M. N., Yener, B., Rajpoot, N., Boucheron, L., Can, A., Madabhushi, A.** “Histopathological image analysis: A review” IEEE Rev. Biomed. Eng., vol. 2, pp. 147-171, 2009.
- [10] **LeCun, Y., Bengio, Y., Hinton. G.** “Deep learning” Nature, 521, pp.436-444, May, 2015.

- [11] **Wang, J., Yang, X., Cai, H., Tan, W., Jin, C., Li, L.** “Discrimination of breast cancer with microcalcifications on mammography by deep learning” *Scientific reports*, 6, 27327, 2016.
- [12] **Bayramoglu, N., Kannala, J., Heikkilä, J.** “Deep learning for magnification independent breast cancer histopathology image classification” In *Pattern Recognition (ICPR), IEEE, 23rd International Conference on*, pp. 2440-2445, 2016.
- [13] **Motlagh, N. H., Jannesary, M., Aboulkheyr, H., Khosravi, P., Elemento, O., Totonchi, M., & Hajirasouliha, I.** “Breast Cancer Histopathological Image Classification: A Deep Learning Approach” *bioRxiv*, 242818, 2018.
- [14] **Bardou, D., Zhang, K., Ahmad, S. M.** “Classification of breast cancer based on histology images using convolutional neural networks” *IEEE Access*, vol. 6, pp. 24680-24693, 2018.
- [15] **Rakhlin, A., Shvets, A., Iglovikov, V., Kalinin, A.A.** “Deep Convolutional Neural Networks for Breast Cancer Histology Image Analysis” *arXiv preprint arXiv: 1802.00752*, 2018.
- [16] **Araújo, T., Aresta, G., Castro, E., Rouco, J., Aguiar, P., Eloy, C., Polónia, A., Campilho, A.** “Classification of breast cancer histology images using convolutional neural networks” *PloS one* 12(6), e0177544, 2017.
- [17] **Liu, K., Kang, G., Zhang, N., Hou, B.** “Breast Cancer Classification Based on Fully-Connected Layer First Convolutional Neural Networks” *IEEE Access*, 6, pp.23722-23732, 2018.
- [18] **Nazeri, K., Aminpour, A., Ebrahimi, M.** “Two-Stage Convolutional Neural Network for Breast Cancer Histology Image Classification” *arXiv preprint arXiv: 1803.04054*, 2018.
- [19] **Cruz-Roa, A., Basavanhally, A., González, F., Gilmore, H., Feldman, M., Ganesan, S., Shih, N., Tomaszewski, J., Madabhushi, A.** “Automatic detection of invasive ductal carcinoma in whole slide images with convolutional neural networks” In *Medical Imaging 2014: Digital Pathology (Vol. 9041, p. 904103)*. International Society for Optics and Photonics.
- [20] **Reiazi, R., Paydar, R., Ardakani, A. A., Etedadialiabadi, M.** “Mammography Lesion Detection Using Faster R-Cnn Detector” *Computer Science & Information Technology*, 111.

- [21] **Dubrovina, A., Kisilev, P., Ginsburg, B., Hashoul, S., Kimmel, R.** “Computational mammography using deep neural networks” *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 6(3), pp.243-247, 2018.
- [22] **Han, Z., Wei, B., Zheng, Y., Yin, Y., Li, K., Li, S.** “Breast cancer multi-classification from histopathological images with structured deep learning model” *Scientific reports*, 7(1), 4172, 2017.
- [23] **Xi, P., Shu, C., Goubran, R.** “Abnormality Detection in Mammography using Deep Convolutional Neural Networks” *arXiv preprint arXiv:1803.01906*, 2018.
- [24] **Ertosun, M. G., Rubin, D. L.** “Probabilistic visual search for masses within mammography images using deep learning” *IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, pp.1310-1315,2015.
- [25] **Deniz, E.,** “ANN-Based MPPT Algorithm for Solar PMSM Drive System Fed by Direct-Connected PV Array” *Neural Computing and Applications*, vol. 28, no. 10, pp. 3061-3072, 2017.
- [26] **McCulloch, W., Pitts, W.** “A Logical Calculus of the Ideas Immanent in Nervous Activity” *Bulletin of Mathematical Biophysics*, Vol. 5, pp. 115-133, 1943.
- [27] **Malica, T.** “Photonic reservoir computing using semiconductor ring lasers: Numerical Analysis” 2014.
- [28] “Yapay Sinir Ağları – Beyin Simülasyonu” Available: <http://teknosektor.com/2015/06/03/yapay-sinir-aglari-beyin-simulasyonu>
- [29] **Atalay, M., Çelik, E.** “Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları ” *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9.22, pp.155-172, 2017
- [30] Available: <http://www.tahmin.web.tr/model.html>
- [31] **Öztemel, E.** “Yapay Sinir Ağları” *Papatya Yayıncılık*, 2. Basım, İstanbul, 2006.
- [32] **Rosenblatt, F.** “The perceptron: a probabilistic model for information storage and organization in the brain” *Psychological Review*, 65, pp.386-408, 1958.
- [33] **Kabalıcı, E.** “Çok Katmanlı Algılayıcı (Multilayer Perceptron)” Available: <https://ekblc.files.wordpress.com/2013/09/mlp.pdf>
- [34] **Minsky, M., Papert, S.** “Perceptrons” *MIT Press*, Cambridge, Mass, 1969.
- [35] **Widrow, B., Hoff, M. E.** “Adaptive switching circuits” In *Proceedings WESCON*, pp. 96-104, 1960.

- [36] **Rumelhart, D., Hinton, G., Williams, R.** “Learning representations by back-propagating errors” *Nature*, 323, pp.533-536, 1986.
- [37] **Gurney, K.** “An introduction to neural networks” UCL Press, UK, 1996.
- [38] **Ivakhnenko, A. G., Lapa, V. G.** “Cybernetic predicting devices.” CCM Information Corporation, 1965.
- [39] **Fukushima, K.** “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position.” *Biol. Cybernetics*, vol. 36, no. 4, pp. 193-202, 1980.
- [40] **Rumelhart, D. E., Hinton, G. E., Williams, R. J.** “Learning internal representations by error propagation” No. ICS-8506, California Univ San Diego La Jolla Inst for Cognitive Science, 1985.
- [41] **LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., Jackel, L.D.** “Backpropagation applied to handwritten zip code recognition.” *Neural Computation*,” vol. 1, no. 4, pp. 541–551, 1989.
- [42] **LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W., Jackel, L.D.** “Handwritten digit recognition with a back-propagation network.” *Advances in Neural Information Processing Systems*, 2, pp.396- 404, Morgan Kaufman. 1990.
- [43] **Foote, K. D.** “A Brief History of Deep Learning” Available: <http://www.dataversity.net/brief-history-deep-learning>
- [44] **Dettmers, T.** “Deep Learning in a Nutshell: History and Training” Available: <https://devblogs.nvidia.com/deep-learning-nutshell-history-training>
- [45] **Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L.** “ImageNet: A Large-Scale Hierarchical Image Database.” *IEEE Computer Vision and Pattern Recognition (CVPR)*, pp. 248-255, 2009.
- [46] **Krizhevsky, A., Sutskever, I., Hinton, G. E.** “ImageNet Classification with Deep Convolutional Neural Networks” In *Proceedings of NIPS*, pp. 1106-1114, 2012.
- [47] **Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. R.** “Improving Neural Networks by Preventing Co-adaptation of Feature Detectors,” *Neural Evol. Comput.*, Jul. 2012.
- [48] **Bakshi, A.** “What is Deep Learning? Getting Started With Deep Learning?” Available: <https://www.edureka.co/blog/what-is-deep-learning>

- [49] **Mayo, M.** “7 Steps to Understanding Deep Learning” Available: <https://www.kdnuggets.com/2016/01/seven-steps-deep-learning.html>
- [50] **Lu, J., Behbood, V., Hao, P., Zuo, H., Xue, S., Zhang, G.** “Transfer learning using computational intelligence: A survey” *Knowledge-Based Systems*, vol. 80, pp. 14-23, 2015.
- [51] **Bayramoglu, N. and Heikkila J.** “Transfer Learning for Cell Nuclei Classification in Histopathology Images” In *ECCV Workshops (3)*, pp. 532-539, 2016.
- [52] **Ghosh, P.** “Machine Learning vs. Deep Learning” Available: <http://www.dataversity.net/machine-learning-vs-deep-learning>
- [53] **Gill, J. K.** “Automatic Log Analysis using Deep Learning and AI for Microservices” Available: <https://www.xenonstack.com/blog/data-science/log-analytics-deep-machine-learning-ai>
- [54] **Graves, A., Mohamed, A., Hinton, G.** “Speech recognition with deep recurrent neural networks” In *Proceedings of ICASSP 2013*.
- [55] **Koyun, A., Afşin, E.** “Derin Öğrenme ile İki Boyutlu Optik Karakter Tanıma” *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi* 10 / 1, pp.11-14, 2017.
- [56] **Ciresan, D. C., Meier, U., Masci, J., Schmidhuber, J.** “A committee of neural networks for traffic sign classification,” in *International Joint Conference on Neural Networks*, to appear, pp. 1918-1921, IEEE, 2011.
- [57] **Pinheiro, P. O., Collobert, R., Dollár, P.** “Learning to segment object candidates” In *NIPS*, 2015.
- [58] **Pinheiro, P. O., Lin, T.-Y., Collobert, R., Dollár, P.** “Learning to refine object segments” In *ECCV*, 2016.
- [59] **Zagoruyko, S., Lerer, A., Pinheiro, P. O., Lin, T.-Y., Dollár, P., Gross, S., Chintala, S.** “A multipath network for object detection” 2016.
- [60] **Collobert R., Weston, J.** “A unified architecture for natural language processing: Deep neural networks with multitask learning,” in *Proceedings of the 25th international conference on Machine learning - ICML '08*, vol. 20, no. 1, pp.160-167, Helsinki, Finland, 2008.

- [61] **Orenstein, E. C., Beijbom O.** “Transfer Learning and Deep Feature Extraction for Planktonic Image Data Sets.” 2017 IEEE Winter Conference on Applications of Computer Vision,(WACV), IEEE, pp.1082-1088, 2017.
- [62] **Yosinski, J., Clune, J., Bengio, Y., Lipson, H.** “How transferable are features in deep neural networks?” In: Advances in Neural Information Processing Systems. pp. 3320-3328,2014.
- [63] **Ciresan, D. C., Meier, U., Schmidhuber, J.** “Transfer learning for Latin and Chinese characters with deep neural networks.” In Proceedings of International Joint Conference on Neural Networks (IJCNN), 2012.
- [64] **O'shea, K., Nash, R.** “An introduction to convolutional neural networks” 2015.
- [65] **Deniz, E., Şengür, A., Kadiroğlu, Z., Guo, Y., Bajaj, V., Budak, Ü.** “Transfer learning based histopathologic image classification for breast cancer detection” Health information science and systems, 6(1), 18, 2018.
- [66] **Britz, D.** “Understanding Convolutional Neural Networks For Nlp.” Available: <http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp>
- [67] **Kim, Y.** “Convolutional neural networks for sentence classification” 2014.
- [68] Available: <https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>
- [69] **Hijazi, S., Kumar, R., Rowen, C.** “Using Convolutional Neural Networks for Image Recognition”, Cadence Design Systems Inc., 2015.
- [70] **Işık, G., Artuner, H.** “Radyo Sinyallerinin Derin Öğrenme Sinir Ağları ile Tanınması” In: Signal Processing and Communication Application Conference, pp.837-840,2016.
- [71] **Serengil, Ş. I.** “A Gentle Introduction to Convolutional Neural Networks” Available:<http://sefiks.com/2017/11/03/a-gentle-introduction-to-convolutional-neural-networks>
- [72] **İnik, Ö., Ülker, E.** “Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri”.GBAD, 6(1), pp.85-104,2017.
- [73] “Theories of Deep Learning” Available: <https://stats385.github.io/poolinglayers>
- [74] **Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., Salakhutdinov, R.** “Dropout: a simple way to prevent neural networks from overfitting.” Journal of machine learning research 15(1),pp.1929-1958, 2014.

- [75] Ujjwalkarn “An Intuitive Explanation of Convolutional Neural Networks” Available: <https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets>
- [76] **Moncada, S.** “Convolutional Neural Networks (Cnn): Softmax & Cross-Entropy” Available: <https://www.superdatascience.com/convolutional-neural-networks-cnn-softmax-cross-entropy>
- [77] **Simonyan, K., Zisserman, A.** “Very deep convolutional networks for large-scale image recognition.” Computing Research Repository (CoRR), 2014.
- [78] **Ojala, T., Pietikinen, M., Harwood, D.** “A comparative study of texture measures with classification based on featured distribution”, Pattern Recognition, vol. 29, no. 1, pp. 51-59, 1996.
- [79] **Kadiroğlu, Z., Şengür, A., Deniz, E.,** “Düşük Seviyeli Doku Öznitelikleri ile Histopatolojik Meme Kanseri Görüntülerinin Sınıflandırılması” International Engineering and Natural Sciences Conference (IENSC’18), Nov 2018.
- [80] **Dalal, N., Triggs, B.** “Histograms of oriented gradients for human detection” In: CVPR, pp. 886-893, 2005.
- [81] **Lowe, D. G.** “Object recognition from local scale-invariant features.” In: Computer vision, 1999. The proceedings of the seventh IEEE international conference on. IEEE, pp.1150-1157,1999.
- [82] **Kartal, H., Alganci, U., Sertel, E.** “Automated Orthorectification of VHR Satellite Images by SIFT-Based RPC Refinement.” ISPRS International Journal of Geo-Information, 7.6: 229, 2018.
- [83] **Cui, S., Jiang, H., Wang, Z., Shen, C.** “Application of neural network based on sift local feature extraction in medical image classification” In Proceedings of the 2017 2nd International Conference on Image, Vision and Computing (ICIVC), pp. 92-97, 2017.
- [84] **Haralick, R.M., Shanmugam, K., Dinstein, I.** “Textural Features for Image Classification”, IEEE Trans. on Systems, Man and Cybernetics, pp.610-621,1973.
- [85] **Cortes, C., Vapnik, V.** “Support Vector Network” Machine Learning, 20(3), pp.273-297, 1995.
- [86] “Laboratório Visão Robótica e Imagem” Available: <http://web.inf.ufpr.br/vri/breast-cancer-database>

- [87] **Hearst, M.A., Dumais, S.T., Osuna, E., Platt, J., Scholkopf, B.** “Support vector machines” IEEE Intelligent Systems and their Applications, Volume: 13, Issue: 4, pp.18-28, 1998.
- [88] **Vedaldi, A., Zisserman, Andrew.** “Efficient additive kernels via explicit feature maps” IEEE transactions on pattern analysis and machine intelligence 34.3, pp. 480-492, 2012.



ÖZGEÇMİŞ

Adı Soyadı: Zehra KADİROĞLU

Doğum Tarihi: 21.02.1993

E-mail: zehrakad@gmail.com

Telefon: 0535 571 46 14

Öğrenim Durumu:

Derece	Bölüm/Program	Üniversite	Yıl
Lisans	Elektrik-Elektronik Mühendisliği	Dicle Üniversitesi	2016
Yüksek lisans	Elektrik-Elektronik Mühendisliği	Fırat Üniversitesi	2019

YAYINLAR

- Şengür, A., Deniz, E., Kadiroğlu, Z., Akılotu, B. N., Tuncer, S. A., Yavuzkılıç, S., & Budak, Ü.** Derin Öznelikler ile Retinal Görüntülerde Optik Diskin Belirlenmesi. Signal Processing and Communications Applications Conference (SIU'18), pp. 1-4, May 2018.
- Deniz, E., Şengür, A., Kadiroğlu, Z., Guo, Y., Bajaj, V., Budak, Ü.** Transfer learning based histopathologic image classification for breast cancer detection. Health information science and systems, 6(1), 18, 2018.
- Kadiroğlu, Z., Şengür, A., Deniz, E.,** Düşük Seviyeli Doku Öznelikleri ile Histopatolojik Meme Kanseri Görüntülerinin Sınıflandırılması. International Engineering and Natural Sciences Conference (IENSC'18), Nov 2018.