



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN KONVOLÜSYON AĞI İLE
DERMATOSKOPIK GÖRÜNTÜLERDE DERİ
LEZYONLARININ SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Emrah ÇEVİK

TOKAT

Eylül, 2021



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN KONVOLÜSYON AĞI İLE
DERMATOSKOPIK GÖRÜNTÜLERDE DERİ
LEZYONLARININ SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Emrah ÇEVİK

Danışman: Dr. Öğr. Üyesi Kenan ZENGİN

TOKAT

Eylül, 2021

Her hakkı saklıdır

Emrah EVİK tarafından hazırlanan “**Derin Konvolüsyon Ağı ile Dermatoskopik Görüntülerde Deri Lezyonlarının Sınıflandırılması**” adlı tez çalışmasının savunma sınavı 25/08/2021 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliğı ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Mekatronik Mühediliğı Anabilim dalında yüksek lisans tezi kabul edilmiştir.



TEZBEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdiği yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

EMRAH ÇEVİK

25/08/2021

ÖZET

Deri lezyonlarını görüntüleyebilmek için dermoskopi yöntemi kullanılmaktadır. Dermoskopi deri üzerindeki lezyonların daha iyi görüntülenebilmesini sağlamak için kullanılmakta olan yönteme verilen isimdir. Dermoskopi uygulaması esnasında dermatoskop adı verilen bir cihaz kullanılmaktadır. Bu cihaz deri katmanlarını belirli oranlarda büyütürken incelenebilmesine katkı sağlamaktadır. Bahsi geçen bu cihazın kullanımı oldukça önemlidir. Çünkü deri üzerindeki lezyonları çıplak gözle görüp; sahip olduğu yapıyı anlamlandırabilmek mümkün değildir.

Cilt hastalıklarının teşhisi oldukça önemlidir. Özellikle malign melanom adı verilen cilt kanseri türü yalnızca erken teşhis konulduğu takdirde tedavi edilebilmektedir. Bu nedenle uzman dermatologların bu noktada yerine getirmekte olduğu işlevi kolaylaştırmak adına hem deri lezyonlarının işlevsel bir biçimde sınıflandırılması hem de kullanılan tekniklerle elde edilmekte olan deri katman görüntülerinin etkili ve verimli olması gerekmektedir.

Bu çalışmanın amacı; yapay zekâ tekniği ile cilt lezyonlarını tasniflendirerek alanında uzman olan doktorun karar vermesine yardımcı olabilecek bir karar destek sistemi meydana getirmektir. Gerçekleştirilecek olan karar destek sistemi hem tanı koyma süresini azaltacak hem de doğru teşhis oranının artmasına imkân sağlayacaktır.

Geliştirilen uygulama sayesinde tıp çalışanlarının uygulamada baz alınan cilt hastalıklarının teşhisi için ihtiyaç duyduğu süre azaltılmış ve ayrıca doğruluk oranı yüksek tahminler sayesinde hastalık için daha erken zamanlarda önlem alınması mümkün olacaktır. Güvenilirlik düzeyi yüksek VGG-16 modelinin HAM10000 veri seti üzerinde eğitilmesi sonucu test doğruluk oranı %85,62 olarak elde edilmiştir.

Anahtar Kelimeler: Deri Lezyonları, Dermoskopi, Dermatoskop, Malign Melanom, Derin Konvolüsyon Ağı

ABSTRACT

Dermoscopy method is used to view skin lesions. Dermoscopy is the name given to the method used to provide better visualization of the lesions on the skin. During dermoscopy, a device called a dermatoscope is used. This device contributes to the examination of skin layers by enlarging them at certain rates. The use of this device is very important. Because you can see the lesions on the skin with the naked eye; It is not possible to make sense of its structure.

Diagnosis of skin diseases is very important. In particular, a type of skin cancer called malignant melanoma can only be cured if diagnosed early. For this reason, in order to facilitate the function performed by expert dermatologists at this point, both the functional classification of skin lesions and the skin layer images obtained by the techniques used should be effective and efficient.

The aim of this study; is to create a decision support system that can help the doctor who is an expert in the field to make a decision by classifying skin lesions with artificial intelligence technique. The decision support system to be implemented will both reduce the time of diagnosis and increase the rate of correct diagnosis.

Thanks to the developed application, the time needed by medical professionals to diagnose skin diseases based on the application has been reduced, and it will also be possible to take measures for the disease at earlier times thanks to the high-accuracy predictions. As a result of training the VGG-16 model with high reliability on the HAM10000 data set, the test accuracy rate was 85.62%.

Key Words: Skin Lesions, Dermoscopy, Dermatoscope, Malignant Melanoma, Deep Convolutional Network

ÖNSÖZ

Bu tez çalışmasında makine öğrenmesi tekniklerinden faydalanmak suretiyle deri lezyonlarına ait örnek verinin düzenlenmesi, VGG-16 derin öğrenme modeli ile eğitimin gerçekleştirilmesi ve devamında üretilen tahminler sayesinde cilt hastalıklarının teşhisi hususunda tıp çalışanlarına yardımcı olmak ve bu tür problemlerin aşılmasında derin öğrenme temelli yaklaşımların avantajlarının vurgulanması amaçlanmıştır.

Öncelikle tez konusu seçiminde ve ilerleyen aşamalarda bana yardımcı olan, engin bilgi ve tecrübeleriyle beni yönlendiren tez danışmanım Dr. Öğr. Üyesi Kenan Zengin'e ve bu zorlu süreçte en büyük destekçilerimden olan sevgili aileme teşekkürlerimi bir borç bilirim.

EMRAH ÇEVİK

25/08/2021

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	1
ABSTRACT.....	2
ÖNSÖZ	3
İÇİNDEKİLER	4
ŞEKİL LİSTESİ.....	6
TABLolar LİSTESİ.....	8
KISALTMALAR LİSTESİ	9
1. GİRİŞ	11
1.1. Araştırmanın Konusu.....	12
1.2. Araştırmanın Amacı.....	12
1.3. Araştırmanın Önemi	13
2. LİTERATÜR ÖZETLERİ ve KURAMSAL TEMELLER.....	14
2.1. Bilgisayar Destekli Teşhis Sistemi	14
2.1.1 Dermoskopide tıbbi teşhis yöntemleri	14
2.2. Yapay Sinir Ağı (Ann).....	21
2.2.1 Algılayıcı	22
2.2.2 Çok katmanlı algılayıcı yapısı	23
2.2.3 Aktivasyon fonksiyonları.....	24
2.2.4 Kayıp fonksiyonu.....	29
2.2.5 Eğitim süreci	31
2.2.6 Normalleştirme prosedürü	32
2.2.7 Optimizasyon algoritmaları	35
2.2.8 Derin öğrenme	38
2.3. Derin Öğrenme ve Evrişimli Sinir Ağları (Esa)	38

2.3.1. Derin öğrenme ve tarihçesi	38
2.3.2. Derin öğrenmenin güçlü yönleri	40
2.3.3. Derin öğrenmede etkili olan kavramlar	42
2.3.4. Evrişimsel sinir ağıları (cnn) ve ana bileşenleri.....	46
2.4. İlgili Araştırmalar	66
3. MATERYAL ve YÖNTEM	87
3.1. Uygulama Adımları	89
4. BULGULAR ve TARTIŞMA	106
5. SONUÇ ve ÖNERİLER	1080
KAYNAKLAR	112
EKLER.....	119
ÖZGEÇMİŞ	1190

ŞEKİL LİSTESİ

Şekil 2.1: Lokal Özelliklere Örnek	15
Şekil 2.2: Dermatoskopi görüntülerinde global özelliklere örnekler: (a) retiküler, (b) globüler, (c) kaldırım taşı, (d) homojen, (e) paralel ve (f) patlayan yıldız (Oliveira ve ark., 2016).	16
Şekil 2.3: Asimetri, Kenar Düzensizliği, Renk, Çap ve Evrimleşme (ABCD-E kuralı). 17	
Şekil 2.4: Puanların toplamı 7'dir. Bundan dolayı, bu lezyon melanomdur.	19
Şekil 2.5: Puanların toplamı 3'tür. Bundan dolayı, bu lezyon melanomdur.	19
Şekil 2.6: Puanların toplamı 1'dir. Bundan dolayı, bu lezyon Clark nevüstür.	20
Şekil 2.7: Lezyonda pozitif işaret varlığı örneği.....	21
Şekil 2.8. Biyolojik Sinir Ağı (Hollander, 2021).....	22
Şekil 2.9: Basit Bir Yapıya Sahip Olan Yapay Sinir Ağı (Mathematical Model, 2021)	23
Şekil 2.10: Tek Gizli Katmanla Çok Katmanlı Algılayıcı.....	24
Şekil 2.11: (a) Sigmoid fonksiyonu. (b) Sigmoid fonksiyonu gradyanı (Fundamentals of Deep Learning, 2017)	26
Şekil 2.12: (a) tanh fonksiyonu (b) tanh fonksiyonu gradyanı (Fundamentals of Deep Learning, 2017).....	27
Şekil 2.13: (a) Relu fonksiyonu. (b) Relu fonksiyonu gradyanı (Fundamentals of Deep Learning, 2017).....	28
Şekil 2.14: (a) Sızıntılı Relu fonksiyonu. (b) Sızıntılı Relu fonksiyonu gradyanı (Fundamentals of Deep Learning, 2017)	29
Şekil 2.15: Maliyet fonksiyonunun şekli (Cavaioni, 2018)	32
Şekil 2.16: Orijinal veriler (Cavaioni, 2018)	33
Şekil 2.17: İlk uygulamadan sonra normalleştirilen veri (Cavaioni, 2018).....	34
Şekil 2.18: Varyans normalleştirme (Cavaioni, 2018)	35
Şekil 2.19: Derin sinir ağlarını genel yapısı (Mira,1995)	39
Şekil 2.20: Derin Öğrenme ve Geleneksel Makine Öğrenmesi Yaklaşımının Karşılaştırılması	41
Şekil 2.21: Tek boyutlu evrişim işlemine ait şema. (a) Tek kanallı girdi; (b) Çok kanallı girdi (Jiao ve ark., 2020).	48

Şekil 2.22: c_i ve y_i değerlerinin giriş ve çıkış özniteliklerini temsil ettiği durumda doğrusal olmayan ReLU fonksiyonuna ait grafik (Jiao ve ark., 2020).....	50
Şekil 2.23. 32x32 boyutunda bir görüntüye uygulanan CNN mimarisinin genel yapısı (Aloysius ve Geetha, 2017)	53
Şekil 2.24: LeNet-5 mimarisinin genel yapısı (LeCun ve ark., 1998).....	54
Şekil 2.25: VGG mimarileri (a) VGG-16 (b) VGG-19 (Shaha ve Pawar, 2018)	58
Şekil 2.26: AlexNet mimarisi (Krizhevsky ve ark., 2012)	60
Şekil 2.27: ZFNet mimarisi (Zeiler ve Fergus, 2014).....	61
Şekil 2.28: Parçalama, dönüşüm ve birleştirme yapısını gösteren temel inception bloğu mimarisi (Khan ve ark., 2020).	63
Şekil 2.29. Büyüme oranı olarak $k = 4$ kullanan ve 5 Dense bloğu içeren bir DenseNet mimarisi (Huang ve ark., 2017)	65
Şekil 2.30: MobileNetV2 mimarisinin genel çalışma şeması (Toğaçar ve ark., 2021)..	66
Şekil 3.1: HAM10000 veri kümesindeki sınıflara ait örnek imajlar.....	668
Şekil 3.2: HAM10000 veri kümesindeki sınıflar.....	665
Şekil 3.3: Düzenlenmiş Ham 10000 Sınıfı Dağılımları.....	66
Şekil 3.4: Vücut kısımlarına dair yapılmış olan analiz grafiği	667
Şekil 3.5: Uygulama eksenindeki cinsiyet dağılım grafiği	668
Şekil 3.6: Veri setine ait imaj ve sınıf sayıları	669
Şekil 4.1: Test ve train verilere ait doğruluk ve kayıp fonksiyonları	667
Şekil 4.2: K-Fold Cross Validation.....	669

TABLÖLAR LİSTESİ

Tablo 2.1: 7 noktalı Kontrol Listesi yöntemi örneği	18
Tablo 3.1. Csv dosyasından veri seti ile ilgili bilgiler	93
Tablo 3.2. Veri setinde bulunan imaj ve sınıf sayıları	94
Tablo 3.3. VGG16 modeline ait özet bilgileri	962
Tablo 3.4. VGG16 modeline ait özet bilgileri (devamı).....	963
Tablo 3.5 Karışıklık Matrisi.....	968



KISALTMALAR LİSTESİ

Adam	: Adaptive Momentum
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
API	: Uygulama Programlama Arayüzü(Application Programming Interface)
CAD	: Bilgisayar Destekli Teşhis (Computer Aided automatic diagnoses)
CNMD	: Consensus Net Meeting on Dermoscopy
CNN	: Evrişimli Sinir Ağları (Convolutional Neural Network)
CNN	: Evrişimsel Sinir Ağları (Convolutional Neural Network)
DA	: Teşhis Başarımı (Diagnostic Accuracy) FCN : Tam Evrişimli Ağ (Fully Convolution Network)
DNN	: Dekonvolüsyonel Sinir Ağı (Deconvolutional Neural Network)
FCNN	: Tam Evrişimli Sinir Ağı (Fully Convolutional Neural Network)
FP	: Yanlış Pozitif (False Positive) FN : Yanlış Negatif (False Negative)
GPU	: Grafik İşlem Ünitesi (Graphical Processor Unit)
ILSVRC	: ImageNet Büyük Ölçekli Görüntü Tanıma Yarışması (ImageNet Large-Scale Visual Recognition Challenge)
ISIC	: Uluslararası Deri Görüntüleme İşbirliği (International Skin Imaging Collaboration)
LM	: Levenshtein Matrisi (Levenshtein Matrix)
MLP	: Çok Katmanlı Algılayıcı (Multi-Layer Perceptron)
MNN	: Çok Katmanlı Yapay Sinir Ağı (Multilayer Neural Networks)
N	: Doğru Negatif (True Negative)

NER	: Adlandırılmış Varlık Tanıma (Named Entity Recognition)
NLP	: Doğal Dil İşleme (Natural Language Processing)
NN	: Yapay Sinir Ağı (Neural Network)
OCR	: Optik Karakter Tanıma (Optical Character Recognition)
PC	: Kişisel Bilgisayar (Personal Computer)
PCA	: Temel Bileşen Dönüşümü (Principle Component Analysis)
PDE	: Kısmı Difransiyel Denklem (Partial Differential Equation)
ReLU	: Düzleştirilmiş Doğrusal Birim (Rectified Linear Units)
RMSprop	: Root Mean Square Prop
ROI	: İlgi Alanı (Region Of Interest)
SGD	: Olasılıksal Gradyan İnişi (Stochastic Gradient Descent)
SVM	: Destek Vektör Makineleri (Support Vector Machine)
TP	: Doğru Pozitif (True Positive)
VGG	: Görsel Geometri Grubu (Visual Geometry Group)

1. GİRİŞ

İnsan vücudunda mevcut olan en büyük organ deridir. İnsan vücudunun toplam ağırlığının yaklaşık olarak %16'sını deri oluşturmaktadır. Derinin üç katmanlı bir yapısı bulunmaktadır. Bunlar deri altı doku, orta deri ve üst deridir. (Sterry, 2006). Derinin üst bölümünde su geçirmeme özelliğine sahip olan ve bir bariyer görevi gören Epidermis katmanı mevcuttur. Derinin renk tabakasının oluşmasından sorumlu olan doku, epidermis katmanının alt kısmında bulunmaktadır ve pigment hücreleri bu katman içerisinde bulunmaktadır. Bahsi geçmekte olan bu katman; güneş ışınlarına maruz kalan derideki melanin üretimini arttırmaktadır. Bu sayede ultraviyole radyasyona karşı deri korunumu gerçekleşmiş olmaktadır (AAD, 2021). Derinin işlevlerinden en önemlisi; iç organların dışarıdan gelen tehlikelere karşı korunma sağlamasıdır. Vücudu, dış ortamdan korumakta olan bir bariyer olma özelliği göstermektedir (Gawkrödger ve Ardern-Jones, 2016). Bu özelliğinden dolayı; deri, vücudu, istenilmeyen güneş ışınlarından korumakta, vücut ısını kontrol etmekte ve belirli enfeksiyonların meydana gelmesine engel olmaktadır (Bhardwaj ve Bhatia, 2014).

Dermoskopi; deri lezyonlarının sahip oldukları özellikleri incelemek ve deri lezyonlarını teşhis etmek için kullanılmakta olan, invaziv özellik göstermeyen bir metottur. Dermoskopi; epilüminesans ve deri yüzey mikroskobu olarak da adlandırılmaktadır. Pigmente olan cilt kanserinin, özellikle de melanomun teşhis edilmesinde oldukça önemli bir destekleyici işlev görmektedir. Bundan dolayı, melanom deri kanserinin erken tanı ile teşhisinin gerçekleştirilmesi çok önemlidir. Dolayısıyla dermoskopi; dermatologların yaygın bir şekilde ve sıkça kullandıkları bir metottur. Deri yüzeyi; dermoskopi sayesinde gözle görülemeyen detayların bile derinlemesine analiz edilebilecek biçimde görüntülenmesini sağlamaktadır. Bahsi geçmekte olan bu cihaz ile malign lezyonlarının, benign lezyonlarından ayırt edilmesi oldukça kolaylaşmaktadır.

Dermoskopi işleminin gerçekleştirilmesi dermatoskop olarak adlandırılmakta olan ve elle manuel olarak kullanılan bir araç vasıtasıyla gerçekleştirilmektedir. Bu teknik, epidermiste bulunan dermoepidermal bileşkedeki ve üst dermisteki yüzey altında bulunmakta olan deri yapılarının görüntülenmesine imkân sağlamaktadır. Bu yapılar genel itibarıyla çıplak gözle görülememektedir. Dermoskopi görülmesi istenen bölgenin

10 kata kadar büyütülmesini sağlamaktadır. İşlem sırasında deri yüzeylerinin yansımaması için ise polarize olmayan bir ışıktan yardım alınmaktadır. Modern dermatoskoplarda ise klasik dermatoskoplarda bulunmakta olan sıvı besiyeri kullanılmamakta ve aynı zaman yeni teknolojiyle birlikte polarize olan ışık kaynağıyla da gözlem yapılması söz konusu olmaktadır. Yüzey yansımaları ne kadar çok ortadan kaldırılabiliirse, derinin derin katmanlarına ulaşım da o derece kolay olmaktadır (Vestergaard ve ark, 2008; Bowling, 2021).

1.1. Araştırmanın Konusu

Deri lezyonlarının dermoskopik görüntülerinin tasnifi, kötü huylu ya da iyi huylu melanositik tümörlü birbirinden ayrılması oldukça zorlu bir işlemi gerektirmektedir. Kötü huylu olan melanom, cilt kanserinin ölümcül düzeyi en yüksek olan biçimidir. Dünya üzerinde en hızlı gelişim göstermekte olan kanser türlerinden biri olarak dikkat çekmektedir. Bunu yanı sıra teşhisinin erken yapılması ve tedavinin hemen başlaması durumunda ilgili hastanın kolaylıkla iyileşmesi söz konusu olmaktadır.

Ölümcül olan bir hastalığın kolayca tedavi edilebilmesi için tanının erken konulması oldukça önemlidir ve hayati bir önem taşımaktadır. Bu bağlamda da dermoskopi, cilt kanserine yönelik rahatsızlıklara erken tanı konulabilmesi için oldukça önemli bir araç olma niteliği taşımaktadır. İnsanların öznelliğinin olması, yanlış yapabilmesi ve zayıf yargı mekanizmasına sahip olması sebebiyle, dermoskopi ile elde edilmekte olan görüntüyü otomatik olarak direkt tanıma algoritmasına gereksinim duyulmuştur. Bu çalışmada, deri kanserinin erken teşhis edilmesi için dermoskopik görüntüler ve derin öğrenme teknikleri kullanılarak bir model geliştirilmesi söz konusu olmuştur.

1.2. Araştırmanın Amacı

Melanoma; derinin yüzey kısmının pigment üretmekte olan hücrelerinde başlayan bir kanser türü olmakla birlikte oldukça da ölümcüldür. Cilt kanseri türleri arasında melanomanın görülme sıklığı %4'tür ancak ölüm oranı ise %75'tir. Alanında uzman olan dermatologlar hastalığın teşhisini gerçekleştirmek için dermatoloji görüntülerini kullansalar dahi teşhisin doğru konulabilmesi oranı %75 ila %84 oranında değişim göstermektedir.

Bu çalışmada amaç; yapay zekâ tekniği ile cilt lezyonlarını tasniflendirerek alanında uzman olan doktorun karar vermesine yardımcı olabilecek bir karar destek sistemi meydana getirmektir. Gerçekleştirilecek olan karar destek sistemi hem tanı koyma süresini azaltacak hem de doğru teşhis oranının artmasına imkân yaratacaktır.

1.3. Araştırmanın Önemi

Bu çalışma cilt kanseri hastalığının teşhisi sürecinde kullanılmakta olan yönteme yeni bir perspektiften yaklaşılarak özellik eklenebilmesine katkı sunmaktadır. Cilt kanseri çok tehlikeli ve ölümcül bir hastalıktır. Bunun yanı sıra ise erken konulan teşhis ile tedavisi oldukça kolay bir şekilde gerçekleştirilebilmektedir. Bu nedenle var olan sistemin geliştirilmesi ihtiyacı hissedilmiştir.

Yapay zekanın pozitif özelliklerinin ön plana çıkartılması ile doğru teşhis oranlarında artış yaşanması ön görülmektedir. Teşhisin hızı ve doğruluğu cilt kanseri için oldukça önemlidir. Bu nedenle yapılan bu çalışmanın teşhis koyma yöntemine katkıda bulunabilme potansiyeli ve içerisinde barındırmakta olduğu teknolojik ve modern perspektif de oldukça önem arz etmektedir.

2. LİTARATÜR ÖZETLERİ ve KURAMSAL TEMELLER

2.1. Bilgisayar Destekli Teşhis Sistemi

CAD, doğru bir şekilde klinik tanı yapılmasında ve dermatologlara yardımcı olma noktasında çok önemli bir role sahiptir. Uygulamada kullanılmakta olan CAD sistemi 4 ana basamaktan meydana gelmektedir. Bu basamaklar;

- 1) Tıbbi nitelik taşımakta olan görüntülerin azaltılması için ön işleme,
- 2) Lezyon kenarlarının belirlenmesine yönelik olan bölütleme,
- 3) Özellik çıkarımının yapılması ve seçilmesi,
- 4) Cilt kanseri tasniflendirilmesi.

Bahsi geçmekte olan bu basamaklar içinde, melanoma kenar belirleme, lezyon kenarına yönelik kesin bir çıkarım yapmaya ilişkin zor bir görev olarak belirtilebilmektedir.

2.1.1 Dermoskopide tıbbi teşhis yöntemleri

Dünyanın çeşitli bölgelerinden 2000 Dermoskopik Uzlaşma Toplantısı'na katılım gösteren uzman sıfatına sahip dermatologlar, lezyonun melanom ya da iyi huylu melanositik lezyon özelliği gösterip göstermediğini belirlemek için bir standart oluşturma yoluna gitmişlerdir. Bahsi geçmekte olan bu toplantı iki kademedен oluşmaktadır.

İlk kademede, melanositik lezyonların melanositik olmayan lezyonlardan ayırt edilebilmesi üzerinde durulmuştur. İkinci basamakta ise 4 farklı teşhis algoritmasının kullanımı söz konusu olmuştur. Bu teşhis algoritmaları melanositik lezyonun iyi huylu veya kötü huylu olmasının ya da şüpheli bir durumda bulunmasının tespiti üzerinde durmaktadır. Bahsi geçmekte olan dört teşhis algoritması; Patern analizi, ABCD-E kuralı, Yedi noktalı kontrol listesi ve Menzies yöntemi olarak adlandırılmaktadır.


Patern analizi

Dermatologların en yaygın şekilde kullandığı yöntem; patern analizi yöntemidir. Patern analizinde lezyonlarda bulunmakta olan paternler lokal ya da global olmak kaydıyla

aranmaktadır. Bunun yanı sıra lezyonun melanositik özeliği taşıyıp taşımadığı belirlenmektedir. Patern analizi, 1987 yılında Pehamberger ve arkadaşlarının birlikte ortaya koymuş oldukları bir yöntemdir.

Bu analiz yöntemi 2000 CNMD'si ile güncellenme işlemine tabi tutulmuştur. Lokal nitelik taşımakta olan özellikler, lezyonun çevresinde mevcut olan özelliklerin bireysel koleksiyonları biçiminde elde edilebilmektedir. Fakat, cilt lezyon bölgesinin tipik olarak büyük bir kısmını sarmakta olan pürüzlü patern bloğunda global özelliklere de rastlanmaktadır (Saez ve ark., 2014).


Lokal nitelik taşımakta olan özelliklerle ilişkili olarak, lezyon içerisinde malignite ya da malignite olmadığını göstermekte olan tipik/ atipik ya da normal/ düzensiz bir yapı şeklinde sunulmaktadır. Türlerin lezyon içerisinde yer alması (düzensiz olan çizgiler, atipik pigment ağları, düzensiz olan noktalar/globüller, regresyon yapıları, düzensiz olan lekeler ve beyazımsı mavi örtü) lezyonun kötü huylu olduğunun bir göstergesi olarak bilinmektedir. Bunun yanı sıra; tipik pigment ağları, düzenli olan noktalar/globüller, düzenli olan çizgiler ve düzenli olan lekeler, lezyonun yaygın olarak iyi huylu olduğu şeklinde bilgi vermektedir. Şekil 2.1.'de lokal kötü huyluluk özelliklerine belirli örnekler gösterilmektedir (Saez ve ark., 2014).



Şekil 2.1: Lokal Özelliklere Örnek

Global nitelik taşımakta olan özellikler; genellikle teşhis edilmesine imkan tanıyan dermatoskopik özelliklerle belirlenmektedir. Melanositik ve melanositik olmayan

dermoskopik özellikler; globüler, retiküler, parlayan yıldız, homojen renk, çok bileşen, paralel, karmaşık yapı, globüller ve noktalar, atipik pigment ağı yapıları, mavi beyaz örtü, asimetrik lekeler, yara izini andırmakta olan beyaz depigmentasyon, mavi bibere benzemekte olan granüller adı verilen terimlerin kullanılmasıyla etiketlenmiştir. Dermatoskopi izlenimlerinde global özelliklerin belli başlı örnekleri Şekil 2.2.'de gösterilmektedir.



Şekil 2.2: Dermatoskopi görüntülerinde global özelliklere örnekler: (a) retiküler, (b) globüler, (c) kaldırım taşı, (d) homojen, (e) paralel ve (f) patlayan yıldız (Oliveira ve ark., 2016).

ABCD-E kuralı

Melanomun erken bir şekilde belirlenebilmesi prosedürümü basitleştirme esnasında karşılaşılmakta olan ilk zorluğu ABCD kuralı ifade etmektedir. Bunun yanı sıra patern analizi yönteminden sonra oluşturulmuş olan ikinci bir yöntem biçimi olarak kabul

görmüştür. ABCD yöntemi; 1985'te Friedman ve diğerleri tarafından ortaya çıkarılmıştır (Friedman ve ark., 1985). Lezyonda;

- (A) Asimetri,
- (B) Kenar Düzensizliği,
- (C) Renk Değişikliği,
- (D) Çap,

Parametrelerinin kontrolüne dayanmaktadır.

2004'de Abbasi ve diğerleri tarafından lezyonun evrimleşmesi (E) ilave edilerek ABCD-E kuralı olarak genişletilmiştir. ABCD-E kuralının açıklaması kısaca aşağıda belirtilmiştir (Abbasi ve ark., 2004).

(A) Asimetri: mol, yarı yarıya olacak biçimde katlanması durumunda kenarların birleşmesi söz konusu olmamaktadır.

(B) Kenar Düzensizliği: Kenarlar düz bir durumda değildir. Düzensiz, girintili ya da oymalıdır.

(C) Renk Değişikliği: kırmızı, mavi ve kahverengi gibi renk çeşitliliği bulunmaktadır.

(D) Çap: mol, 6 mm'den geniş, yaklaşık olarak bir kalem silgisinin ucu kadardır.

(E) Evrimleşme: Lezyona ait olan yükseklik, şekil, boyut ya da renkte meydana gelebilecek olan bir değişikliğin ifade edilmesidir.



Şekil 2.3: Asimetri, Kenar Düzensizliği, Renk, Çap ve Evrimleşme (ABCD-E kuralı).


7 Noktalı kontrol listesi

Yedi noktalı kontrol listesi yönteminde adından da anlaşılacağı üzere 7 özellik bulunmaktadır. Bunların her birine 1 puan atfedilmektedir. Teşhis eğer cilt lezyonunda 3 puan alır ise, lezyonun daha çok melanom olması beklenmektedir. Bunun yanı sıra deri üzerine uzmanlaşmış bir doktora gidilmesi söz konusu olmaktadır. Bütün bu yedi özellik; minör ve majör standartlar olmak üzere iki farklı gruba ayrılmış durumdadır (Walter ve ark., 2013). Minör standartların değeri 1 puandır. Majör standartların değeri ise 2 puandır. Bahsi geçmekte olan bu iki grubun gösterimi Tablo 2.1.'de yapılmaktadır.


Tablo 2.1: 7 noktalı Kontrol Listesi yöntemi örneği

ÖZELLİK TÜRLERİ	STANDARTLAR	AĞIRLIKLAR
Minör Özellikler	Kaşıntı ya da değişmekte olan his	1 Puan
	İnflamasyon	
	Diğer lezyonlardan geniş (çap > 7mm)	
	Lezyonda kabuklanma/sızıntı	
Majör Özellikler	Düzensiz Pigmentasyon	2 Puan
	Lezyon boyutunda farklılık	
	Düzensiz kenar	


Yedi noktalı kontrol listesi melanom teşhis yöntemi, pigmente olmuş durumdaki lezyonun içinde sunulmakta olan her bir standart için puan eklemesi yapmaktadır. Bu durumun açıklayıcılığını arttırmak için örnek gösterimi yapılmaktadır.



Şekil 2.4: Puanların toplamı 7'dir. Bundan dolayı, bu lezyon melanomdur.



Şekil 2.5: Puanların toplamı 3'tür. Bundan dolayı, bu lezyon melanomdur.




Şekil 2.6: Puanların toplamı 1'dir. Bundan dolayı, bu lezyon Clark nevüstür.

Menzies yöntemi

Mezies yöntemi, analiz yapabilmek için pozitif ve negatif olmak kaydıyla mevcut olan iki sınıfın özelliklerini kullanmaktadır. Pozitif sınıfta kötü huylu tümörler için lezyonların, çoklu mavi/gri noktalar, genişletilmiş ağ, çoklu renk, yara izine benzemekte olan depigmentasyon, psödopod, mavi beyaz örtü, radyal akış, çoklu kahverengi noktalar gibi niteliklere bakılmaktadır. Negatif sınıfta ise iyi huylu olan tümörlerin tespit edilebilmesi adına lezyonların tek renk ya da simetrisine bakılmaktadır.

Dermatologların, teşhis esnasında kullanmış olduğu prosedüre uygun bir şekilde pozitif ve negatif özellikleri toplaması gerekmektedir. Örnek olarak, diğer bütün negatif özelliklerin olmaması gibi pozitif bir özelliğin varlığı, lezyonun melanom özellik gösterip göstermediğine karar vermek için yeterli görülmektedir (Dermoscopy Totutorial, 2021). Bu duruma örnek teşkil eden görsel şekil 2.7.'de gösterilmiştir.




Şekil 2.7: Lezyonda pozitif işaret varlığı örneği.

2.2. Yapay Sinir Ağı (Ann)

İnsan beyninin sinir içerikli yapısını bilgisayar ortamına benzetmek adına tasarlanmış bulunan yapay zekanın belirli bir bölümüdür. Yapay sinir ağları; metin, görüntü ve ses ile ilişkili verileri tanımak amacıyla oluşturulmuş insan beyninin taklidini yapan bir grup algoritma biçiminde tasarlanmıştır. İnsanın beyni; biyolojik bir sinir ağıdır. Bunun yanı sıra bilgisayar beyni ise yapay sinir ağıdır (Anderson ve McNeill, 1992). Yapay sinir ağlarında mevcut olan matematiksel kavramlar oluşturulurken biyolojik sinir ağlarından esinlenilmiştir. Sinir ağları ayrıca, girdi-çıkı üretimi yapıldığında eşzamanlı bir şekilde çalışmaktadır. Oysa ki insan beyni, istenilen vakitte girdi ve çıktı üretmek amacıyla tepki verebilmektedir (Amazon, 2021).

Biyolojik organizmaların öğrenebilme yetilerini taklit etmekte olan yapay sinir ağları; yaygın bir şekilde kullanılmakta olan makine öğrenme yöntemlerindendir. İnsanlarda bulunan sinir sistemi, nöronlar olarak adlandırılan hücrelerden meydana gelmektedir. Dendritler ve aksonlar; çoklu nöronları birbirine entegre eden bağlayıcılarıdır. Sinapslar ise aksonun sonun kısmında yer almaktadır. Görevi ise nöronlar arasındaki bağlantıyı sağlamaktır (Hollander, 2021). Şekil 2.8.'de biyolojik sinir ağının gösterimi yapılmıştır.




Şekil 2.8. Biyolojik Sinir Ağı (Hollander, 2021)

2.2.1 Algılayıcı

1958’de ilk yapay sinir ağı yapısını Rosenblatt meydana çıkarmıştır. Bahsi geçmekte olan bu ağı; perceptron adı verilmekte olan çok basit yapıya sahip bir ağıdır. İlk yapay sinir ağı, çoklu nitelik göstermekte olan ikili girdilerden meydana gelmektedir. Bunun sonucunda ise tekli ikili çıktı üretimi yaptığı bilinmektedir. Rosenblatt, ikili sınıflandırıcı için basit nitelikte olan bir model önerisinde bulunmuştur. Bu öneri, bahsi geçmekte olan bu ikili sınıflandırmaya dayanan model çıktısının daha yüksek ihtimaline güven duyulmasından dolayı söz konusu olmuştur.

Rosenblatt’ın geliştirmiş bulunduğu ilk modelin basit yapısı, lineer özellik taşımayan görevler için Çok Katlı Algılayıcılara fikir vermiş ve onlara ilham kaynağı olmuştur (Alradad, 2015; Vojt,2016). Algılayıcı ağında bulunmakta olan bir nöron, ağırlıklar baz alınarak yapılan girdi ve çıktıyla ilgili olan hesaplama yöntemini içerisinde barındırmaktadır. Bahsi geçen nöron, biyolojik organizmalarda bulunan sinaptik bağlantılarla aynı görevi yerine getirmektedir. Ağırlıklar; nörona giriş yapan her bir girdi biriminin ölçülmesi için kullanılmaktadır. Basit düzeydeki bir yapay sinir ağının gösterimi Şekil 2.9.’da gösterilmiştir.



Şekil 2.9: Basit Bir Yapıya Sahip Olan Yapay Sinir Ağı (Mathematical Model, 2021)

2.2.2 Çok katmanlı algılayıcı yapısı


Çok Katmanlı Algılayıcı, birbirine bağlı durumdaki çoklu nöron katmanlarını içermekte olan ileri beslemeli bir yapay sinir ağı sistemidir. Çok Katmanlı Algılayıcı; girdi katmanı, bir ya da daha çok gizli katman ve çıktı katmanından meydana gelmektedir. Bir katmanda mevcut olan her bir nöron, bir sonraki katmanda bulunmakta olan diğer bir nöronla ilişki halindedir. Bu durumda, gizli katmanda bulunmakta olan her bir nöron, yalnızca tek bir algılayıcının temsiliyi gerçekleştirmektedir. Yapay sinir ağı sistemi için Çok Katmanlı Algılayıcı tasarımı yapmanın arkasında yatmakta olan asıl motivasyon, ağın, lineer olmayan görevleri çözümleyebilmesine neden olmasıdır (Alradad, 2015; Vojt,2016).

Temel olan bir hesaplama elemanına genel olarak düğüm ve birim ismi atfedilmektedir. Bahsi geçmekte olan hesaplama elemanı başka düğümlerden girdi alımı gerçekleştirmektedir. Alımı gerçekleştirilmiş olan her bir girdinin kendine özgü ağırlığı (w) bulunmakta olup; sinaptik öğrenmeye yönelik bir model biçiminde ayarlaması yapılabilmektedir. Düğümler üzerinden girdilerin ağırlıklı toplamının bulunabilmesi için f fonksiyonunun hesaplanması yapılmaktadır:

$$y_i = (\sum_j w_{ij}x_j + b)$$

(2.1)

Bu sayede, çıktı; diğer mevcut olan düğümler için girdi rolü üstlenmektedir.



Şekil 2.10: Tek Gizli Katmanla Çok Katmanlı Algılayıcı

$\sum_j w_{ij}x_i$ birimin net girdisini ifade etmektedir. w_j i, j birimlerin ağırlığı, f ise ilgili birimin aktivasyon fonksiyonudur.

2.2.3 Aktivasyon fonksiyonları

Aktivasyon fonksiyonun adı; transfer fonksiyonu olarak da anılmaktadır. Aktivasyon fonksiyonu, ağda mevcut olan her bir katmanın çıkısına eklemelenen bir birimdir. Aslında herhangi bir nöronun aktive edilmesi durumu; aktivasyon fonksiyonun, aktive edilip edilmemesine karar vermesine bağlı bulunmaktadır.

$$A = \sum(\text{ağırlık} * \text{girdi}) + \text{yanlılık} \quad (2.2)$$

$$X = (A) \text{Aktivasyon} \quad (2.3)$$

Ağ içerisinde herhangi bir aktivasyon fonksiyonunun bulunmaması halinde, yanlılık ve ağırlık, denklem 2.2.'deki gibi lineer özellik taşıyan bir denkleme geçiş yapmaktadır. Karmaşık problemlerin çözüme kavuşturulmasında lineer denklemlerinin becerisi oldukça sınırlı durumdadır. Lineer özellik göstermeyen bir denkleme sahip olan aktivasyon fonksiyonu, görüntü tasnifleme ve görüntü bölütleme gibi daha karmaşık nitelikteki görevlerin öğrenilip gerçekleştirilmesine olanak tanımaktadır. Lineer özelliğe

sahip olmayan aktivasyon fonksiyonları diferansiyel denklemler aracılığıyla çözüme kavuşturulmaktadır. Bu durum, öğrenme optimizasyonu esnasında geriye yayılımın daha verimli bir duruma gelmesini sağlamaktadır (Walia, 2021).

Aktivasyon fonksiyonu türleri

Yapay sinir ağlarında her biri birbirinden farklı özellikleri içerisinde barındırmakta olan birçok aktivasyon fonksiyonu çeşidi bulunmaktadır. Bu fonksiyonlardan en yaygın şekilde kullanılanları;

- Sigmoid veya Lojistik,
- Tanh- Hiperbolik Tanjan,
- ReLU,
- Sızıntılı ReLU,

olmak üzere toplam dört tanedir. Aşağıda bu fonksiyonların incelemesi yapılmıştır.


Sigmoid veya lojistik

En yaygın biçimde kullanılmakta olan fonksiyon; sigmoid fonksiyondur. Lineer olmayan ve monotonik olarak artış göstermekte olan fonksiyonlardan biri olarak karşımıza çıkmaktadır. Her zaman çıktısı 0-1 aralığında olacağından dolayı özellikle sınıflandırma modellerinde kullanımına rastlanmaktadır. Bu durum Şekil 2.11-a'da gösterilmektedir. Sigmoid fonksiyonların tanımlaması denklem (2.4) ile yapılmaktadır.


$$f(a) = \frac{1}{1 + e^{-a}}$$

(2.4)

Sigmoid fonksiyonunda yaşanmakta olan en olası sorunlardan bir tanesi gardyanın her iki tarafta da başlangıca oldukça çok yatay vaziyette olması ve bundan dolayı öğrenme sürecinin hızının kesilmesidir. Bahsi geçmekte olan bu duruma gradyan kaçış noktası denilmektedir. Bu sorun Şekil 2.11-b'de gösterilmektedir. Gradyan kaçış noktası sorunundan uzaklaşmak adına ağırlık düzeyleri oldukça küçük olan değerlerle başlangıç yapmaktan kaçınılması gerekli görülmektedir (LeCun ve ark., 2012).



(a)




(b)

Şekil 2.11: (a) Sigmoid fonksiyonu. (b) Sigmoid fonksiyonu gradyanı (Fundamentals of Deep Learning, 2017)


Tanh - Hiperbolik tanjant

Çok yaygın bir şekilde kendisine kullanım alanı bulmuş olan aktivasyon türlerinden biri de tanh'dır. Sigmoide alternatif olma niteliği göstermekte olan bir fonksiyondur. Tanh'ın çıktısı sıfır merkezlidir. Bu durum şekil 2.12.-a'da gösterilmiştir. Sıfır merkezli olmasından kaynaklı olarak gizli olan birimlerde sigmoidin yerine her zaman tercih edilebilmektedir. Fakat, yine de gradyan kaçış noktası sorunu tanh fonksiyonunda da bulunmaktadır. Bu durum Şekil 2.12-b)'de gösterilmiştir. Tanh fonksiyonunun her zaman -1 ila 1 aralığında kalması gerekmektedir. Bahsi geçen bu aralığın (2.5) formülüyle tanımlaması yapılabilmektedir.

$$f(a) = \tanh(a) = \frac{2}{1 + e^{-2a}} - 1 \quad (2.5)$$



(a)



(b)

Şekil 2.12: (a) tanh fonksiyonu (b) tanh fonksiyonu gradyanı (Fundamentals of Deep Learning, 2017)


Relu

ReLU, son yıllarda oldukça popüler olmuştur ve yaygın bir şekilde kullanılmaktadır. Lineer olmayan bir özelliğe sahiptir. Denklem (2.6)'da tanımlanma ifadesi verilmektedir.

$$f(a) = \max(0, a)$$

(2.6)

x 'in sıfırdan az olması durumunda değerin sıfır olduğu, sıfırdan daha büyük olduğunda ise 1 eğimiyle lineer olduğu şekil 2.13'de gösterilmektedir. “Derin Evrişimsel Sinir Ağları” adlı eserde Krizhevsky ve diğerleri, imajnet tasniflendirilmesinde bir aktivasyon türü olan tanh üzerinden gerçekleşmekte olan yakınsama hususunun 6 kata daha fazla iyileşme göstermekte olduğunu belirtmektedirler (Krizhevsky ve ark., 2012).



(a)


(b)

Şekil 2.13: (a) Relu fonksiyonu. (b) Relu fonksiyonu gradyanı (Fundamentals of Deep Learning, 2017)


ReLU; tanh ve sigmoid fonksiyonlarının karşı karşıya kaldığı gradyan kaçış noktası sorununun çözülebilmesine yönelik ortaya çıkarılmış olan bir fonksiyondur. Fakat; ReLU fonksiyonunda da nöron ölümü sorunu meydana gelmektedir. Bahsi geçmekte olan bu sorun, belirli bazı nöronların ölmesine ve girdi ya da hata değişikliklerinde cevap vermemeye başlamasına neden olmaktadır. Bundan dolayı da sonuç itibariyle öğrenmenin engellenmesi söz konusu olmaktadır. ReLU fonksiyonun da gerçekleşmekte olan nöron ölümü sorunu, sızıntılı ReLU kullanımı ile çözüme kavuşturulmaya çalışılmaktadır.

Sızıntılı Relu

Sızıntılı ReLU; ReLU fonksiyonunun geliştirilmiş haldeki bir versiyonudur. x' in sıfırdan büyük olduğu durumlarda ReLU gradyanı 0'a eşittir. Bu durum Şekil 2.14'de gösterilmektedir. ReLU gradyanının 0 olması; o bölge bulunmakta olan birimin ölmesine sebep olmaktadır.



(a)



(b)

Şekil 2.14: (a) Sızıntılı Relu fonksiyonu. (b) Sızıntılı Relu fonksiyonu gradyanı (Fundamentals of Deep Learning, 2017)

Yatay çizgi alışverişinin arkasında yatmakta olan asıl amaç 0 gradyanının yok edilmesini sağlamaktır. Sızıntılı ReLU işleviyle ağ; belirlenmiş olan bölgedeki ölü birimle karşı karşıya kalmamış olacaktır.

2.2.4 Kayıp fonksiyonu

Makine öğrenimi hattının en önemli parçalarından birisi kayıp fonksiyonlarıdır. Öğrenme süresi zarfından elde edilmiş olan eğitim bulguları tahmin fonksiyonunun üretilmesi amacıyla kullanılmaktadır. Bahsi geçmekte olan fonksiyon, X girdilerini aldıktan sonra Y etiketleriyle eşleştirme çabasına girmektedir. Eğitim bulgularında önceden görmemiş olsa dahi ortaya çıkacak olan sonuç hakkında tahmin yürütmeye çalışmakta olan bir modeldir.

Modelin mümkün oldukça genelleştirilmiş durumda olması gerekmektedir. İşlemlerin belirli bir sıraya konulması tahmini bir şekilde çıktının hesaplanıp üretim yapabilecek kapasitede olması için amacıyla yapılmaktadır. Gerçek çıktıyla tahmini yapılmakta olan çıktıyı karşılaştırma süreci hata değeri olarak ifade edilmektedir. Hata değerini, gradyan inişi tarzındaki optimize etme stratejileri kullanarak olabildiğince en az seviyeye indirgenmeye çalışmak gerekmektedir. Bahsi geçmekte olan hata değerinin hesaplanabilmesi adına kullanılmakta olunan şeklin kayıp fonksiyonunu hesaplamak gerekmektedir.

Jaccard İndeksi olarak da adlandırılmakta olan IoU; tahmin edilmekte olan bölgeyle kesin referans bölgesi arasında mevcut olan benzerliği bulmak amacıyla kullanılan standartlaştırılmış bir ölçü olarak karşımıza çıkmaktadır. Aşağıda belirtilmekte olan denklem ile tanımlaması yapılmaktadır:

$$\frac{TP}{FP+TP+FN} \quad (2.7)$$

FP: Yanlış pozitif,

TP: Doğru Pozitif,

FN: Yanlış Negatif sayıları ifade etmek için kullanılmaktadır.

Rahman ve diğerleri, Sayım usulüne dayandırılmakta olan ölçümün yerine muhtemel nitelikteki değerlerin kullanımını gerçekleştirerek IoU puanını yaklaşık bir biçimde elde etmeyi önermiştir (van Beers ve Wiering, t.y.). Aşağıda gösterilmekte olan denklemde bahsi geçmekte olan bu önerinin açıklaması yapılmaktadır.

$$IoU = \frac{I(A)}{U(A)} \quad (2.8)$$

Burada gösterilmekte olan I(A):

$$I(A) = \sum_{Z \in Z} A_Z * B_Z \quad (2.9)$$

Ve yine burada gösterimi yapılan U(A):

$$U(A) = \sum_{Z \in Z} (A_Z + B_Z - A_Z * B_Z) \quad (2.10)$$

Bütün eğitim setlerinde bulunmakta olan her bir görüntünün büyük pikselleri Z şeklinde ifade edilmektedir. Ağın çıktı piksellerinin olasılık durumu ise A şeklinde gösterilmektedir. B ise Z setinin kesin olan referansını göstermektedir.

Sinir ağında mevcut olan eğitim sürecinin kılavuzu olma özelliği göstermekte olan fonksiyon; kayıp fonksiyonudur. Bölütleme probleminin çözülebilmesi adına genel

itibariyle Jaccard mesafesi ölçümü kullanılmaktadır. Jaccard mesafesinin tanımlaması aşağıdaki denklemde gösterilmektedir.

$$L_{IOU} = 1 - IoU = 1 - \frac{I(A)}{U(A)}$$

(2.11)

2.2.5 Eğitim süreci

Sinir ağı öğrenme süreci elde edilmiş olan gerçek çıktı değerleri ile arzu edilen çıktı değerleri arasında meydana gelen hatalara cevap olarak nöronların ağırlık durumlarını ve yanlılıklarını ayarlamaktadır. Yapay sinir ağı içerisinde yer alan eğitim veri seti, girdi olarak nitelendirilmekte olan verilere sahiptir. Bunun yanı sıra çıktılarla tasnif edilmektedir.

Sinir ağını eğitebilmek demek ileri ve geri yayılım biçiminde var olan iki temel adımın tekrar edilmesiyle bütün ağırlıkları bir standart içine almak demektir. İleri yayılım süreci; girdi niteliği taşımakta olan verilerle ağı besleme ve ilk olarak atılacak olan ileri adım için rastgele ağırlıkların seçimini yaparak çıktı etiketlerinin ihtimalini hesaplamayı ifade etmektedir. Geri yayılımda ise çıktı hatasının ölçümü yapılmaktadır. Bunun yanı sıra hata düşüşüne bakılarak ağırlıkların ayarlanması söz konusu olmaktadır. Epok olarak isimlendirilmiş olan ağı yardımıyla ağırlıkların güncellenmesi sağlanmaktadır. Daha sonra eğitim seti işlem adımına geçilmektedir. Bütün eğitim örnekleri çerçevesinde ağırlıkların ortama toplamının karesi alınmış hatalar en aza indirgenmeye çalışılmaktadır. En aza indirme işlemi tamamlanana kadar bütün eğitim örnekleri tekrar eden bir düzen içinde ağı giriş yapmaktadır.

Eğitim aşamasının sonucunda, eğitim neticesinde elde edilmiş olan verilerin hedef çıktı değerleri en az hata ile çoğaltılmak durumundadır. Toplamlarının karesi alınmış olan hata minimize edilmesi işlemine gradyan inişi denilmektedir. Bu bir hata azaltma yöntemi olarak karşımıza çıkmaktadır (Eberhart, 2014).


2.2.6 Normalleştirme prosedürü

Sinir ağı içerisinde yer almakta olan eğitimi hızlandırabilmek adına pek çok teknik kullanımı söz konusu olmaktadır:

Girdileri normalleştirme

Sinir ağındaki bayası en düşük seviyeye çekebilmek adına verilerin aynı değer aralıkları içerisinde yer alabilmesi dengesini sağlayabilmek amacıyla girdi verilerini tekrardan ölçeklendirme sürecine girdileri normalleştirme adı verilmektedir.

Ham girdileri kapsamı içerisine alan normalleştirme prosedürü verilerin eğitime uygun bir biçimde ayarlanması bakımından oldukça önemlidir. Verilerin normalleşme işlemi tamamlanmadığı sürece maliyet fonksiyon şekli tutarsızlık gösterme eğilimine sahip olmaktadır. (Bu durum Şekil 2.15-a'da gösterilmiştir.) Bundan dolayı, sinir ağlarının eğitimi olabildiğince yavaş kalabilmektedir. Bunun sebebi ise gradyan inişinin öğrenme düzeyi en düşük maliyete ulaşıncaya dek küçük adımlar atması durumunun söz konusu olmasıdır. Öte taraftan, normalleştirilmiş olan veriler ile maliyet fonksiyonunun biçimi tutarlı bir hal almaktadır. (Bu durum Şekil 2.15-b'de gösterilmiştir.) Bunun yanı sıra gradyan inişi, en aza indirgenen maliyeti bir araya getirebilmek adına öğrenme düzeyinde büyük adımlar atmaktadır (Jayalakshmi ve Santhakumaran, 2011). Girdilerin normalleştirilmesi süreci iki adımdan meydana gelmektedir (Cavaioni, 2018):



Şekil 2.15: Maliyet fonksiyonunun şekli (Cavaoni, 2018)

İlk olarak, eğitim girdilerinin her biri için ortalama çıkarılmaktadır (Denklem (2.12)). Bu işlem, eğitim girdilerinin sıfıra ortalanmasını sağlamaktadır. Bu durumun gösterimi Şekil 2.16’da ifade edilmiştir.

$$\mu = \frac{1}{m} \sum_{i=1}^m x^{(i)}$$


(2.12)

$$x = x - \mu$$


(2.13)

Denklemler üzerinde yer almakta olan x değeri eğitim seti içerisinde yer alan girdi verilerini ifade etmektedir. Denklem üzerinde yer almakta olan bir diğer değer m ise eğitim setindeki örnek sayısını belirtmektedir.

Eğitim seti içerisinde yer almakta olan girdilerin ortalaması ise yukarıda belirtilen denklemler üzerinde μ şeklinde ifade edilmektedir.



Şekil 2.16: Orijinal veriler (Cavaioni, 2018)




Şekil 2.17: İlk uygulamadan sonra normalleştirilen veri (Cavaioni, 2018)

İkinci olarak gerçekleştirilmekte olan sürece varyans normalleştirilmesi denilmektedir. Varyans çıktıların her birine bölünerek hesaplanmaktadır. Bu durum Denklem (2.11)'de gösterilmiştir. x_1 ve x_2 arasındaki verilerde yer almakta olan büyük farklılıklar Şekil 2.16'da gösterilmiştir. x_1 ve x_2 normalleştirildiğinde elde edilmiş olan verilerin varyansı Şekil 2.18'deki gibi oluşmaktadır.

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m x^{(i)2} \quad (2.14)$$

$$x / = \sigma^2 \quad (2.15)$$

σ^2 ;Denklem (2.14)' den elde edilmekte olan özelliklerin karesi alınmış vektörün ortalamasını ifade etmektedir. Normalleştirilmiş durumdaki girdilerin son neticesinin bir vektörü ise Denklem (2.15)'de ifade edilmektedir.



Şekil 2.18: Varyans normalleştirme (Cavaioni, 2018)

2.2.7 Optimizasyon algoritmaları

Maliyet fonksiyonun ayırt edilebilmesini sağlayarak oluşabilecek olan negatif eğimin takip edilip model parametrelerinde değişim meydana getirerek eğitim hatalarını azaltmak adına tasarlanmış olan ve sürekli tekrarlanan işleme optimizasyon algoritmaları adı verilmektedir. Toplam olarak hesaplanmış olan hatada ağırlık her bir biriminin vermiş olduğu katkıları tahmin edebilmek adına çalışan gradyan; maliyet fonksiyonu gradyanıdır (Niknafs, t.y.).

Ortaya çıkarılması planlanan en iyi çözüm için hazırlanmış olan gradyan arama yöntemlerinden biri geri yayılımdır.

Geri yayılım algoritması

Geri yayılım algoritması; ANN’de yer almakta olan ağırlık düzeyini hesaplayabilmek için ihtiyaç duyulan gradyanı hesaplama işinde en çok kullanılan tekniktir. Bu tekniğin ortaya çıkışı 1970’li yıllara dayanmaktadır. Rumelhart ve diğerlerinin geri yayılım algoritmasını geliştirmesiyle birlikte 1986 yılında bu yöntem popülerlik kazanmıştır (Nielsen, 2015).

Hedefe ulaşıncaya kadar eğitim örnekleri birçok adımdan geçirilmektedir. Bir demet görüntü; bir geri ya da ileri geçiş tekniğiyle Sinir Ağı’na girmektedir. Bu yöntemle verilmiş olan isim mini-yığıdır. Bahsi geçmekte olan geri yayılım algoritması, çoklu eğitimde tek bir yığını belirleyebilmek için tahmin yürütülen Yapay Sinir ağına meydana gelebilecek hata ya da hataları minimum seviyeye çekmek için bir gradyan

iniş yöntemi kullanılmaktadır. Kullanılmakta olan bu gradyan iniş tekniğine maliyet fonksiyonu adı verilmektedir (Nielsen, 2015).

Geri yayılım algoritması uygulamasında aşağıda belirtilmekte olan adımlar takip edilmektedir:

1. İleri besleme: Bu adımda, ağda bulunmakta olan her bir katman iki farklı hesaplama adımına denk düşmektedir:

a) z değerinin hesaplaması yapılmaktadır:

$$z^1 = w^1 a^{I-1} + b \quad (2.16)$$

b) z çıktısı için aktivasyon değeri hesaplaması yapılmaktadır.

$$a^1 = \sigma(z^1) \quad (2.17)$$

1, 2'den L'ye kadar olan katman sayılarının sıralanması ifade etmektedir. 1 katmanının sahip olduğu ağırlık; w^1 'dir. Önceki katman çıktısı ise a^{I-1} 'dir. a^1 ise mevcut durumdaki katmanın aktivasyon fonksiyonunun ifadesidir. b ise biası temsil etmektedir.

2. Çıktı Hatası δ^L : Bu hata ileri besleme işlem hatasını ifade etmektedir. Denklem (2.18)'de gösterildiği gibi hesaplaması yapılmaktadır.

$$\delta^L = \nabla_a C \odot \sigma'(z^L) \quad (2.18)$$

Son nöral yapı katmanı L ile ifade edilmektedir. $\nabla_a C$ ise a bakımından oluşan maliyet fonksiyonunun $\odot$ Hadamard ürününün ve gradyanının ifade edilmesinde kullanılmaktadır.

3. Geri yayılım hatası: δ^L çıktı hatasından başlamaktadır. Sonrasında girdiye doğru bir geri dönüş sergilemektedir. Tanımlaması Denklem (2.19)'da gösterilmiştir.

$$\delta^1 = ((w^{I+1})^T \delta^{I+1}) \odot \sigma'(z^1) \quad (2.19)$$

4. $\Delta w_{i,j}^1$ ve $\Delta b_{i,j}^1$ eğitilebilir potansiyele sahip olan parametrelerdir. Bu parametreler Denklem (2.20) ve Denklem (2.21)'de ifade edildiği gibi güncellenebilmektedir.

$$w^1 = w^1 - n \frac{\partial C}{\partial w^1}$$

(2.20)

$$b^1 = b^1 - n \frac{\partial C}{\partial b^1} \quad (2.21)$$

Eğitilebilmekte olan parametrelerin ne denli hızlı bir şekilde güncellenebildiğini kontrol altına almakta olan öğrenme oranı n ile ifade edilmektedir. $\frac{\partial C}{\partial w^1}$, w parametresi açısından bakıldığında söz konusu hatanın türevidir. $\frac{\partial C}{\partial b^1}$ ise b parametresi açısından hatanın türevini ifade etmektedir (Nielsen, 2015).

Öğrenme durumu için ihtiyaç duyulan iyileştirmenin maliyet fonksiyonundan daha iyi neticeler elde edebilmek adına kullanılmakta olan birçok yöntem vardır. Adam algoritması bu yönetime bir örnek teşkil etmektedir.

Adam algoritması

Adam algoritması; sinir ağlarında çok yaygın bir biçimde kullanılmakta olan bir optimizasyon algoritmasıdır. Bahsi geçmekte olan bu algoritma RMSprop ve izme algoritmalarının birleşiminden meydana gelmektedir ve klasik gradyan inişine göre daha hızlı bir şekilde yakınsama gerçekleştirilmesi söz konusu olmaktadır

NN alanında çokça kullanımı gerçekleştirilmekte olan bir algoritmadır. Bunun sebebi ise sahip olduğu asgari yakınsama hızıdır.

$$v_{dw} = \beta_1 v_{dw} + (1 - \beta_1) \frac{\partial L_{IoU}}{\partial w} \quad (2.22)$$

$$s_{dw} = \beta_1 s_{dw} + (1 - \beta_2) \left(\frac{\partial L_{IoU}}{\partial w} \right)^2 \quad (2.23)$$

$$v_{dw}^{corrected} = \frac{v_{dw}}{1 - (\beta_1)^t} \quad (2.24)$$

$$s_{dW}^{corrected} = \frac{s_{dW}}{1-\beta_1} t \quad (2.25)$$

$$W = W - \alpha \frac{v_{dW}^{corrected}}{\sqrt{s_{dW}^{corrected} + \varepsilon}} \quad (2.26)$$

v_{dW} ve s_{dW} ; geçmişteki gradyanların ve gradyanlarının karesinin geçmişinin üssel ağırlıklı ortamlarını ifade etmek amacıyla kullanılmaktadır. Ayar yapılması planlanan hiperparametreler β_1 ve β_2 olarak ifade edilmektedir. Mevcutta var olan kayıp gradyan ise $\frac{\partial L_{loss}}{\partial W}$ oranı ile gösterilmektedir. Son olarak ε , sıfıra bölünerek değiştirilebilen çok ılımlı bir değer olarak tanımlanmaktadır.

2.2.8 Derin öğrenme

ANN kavramını meydana getiren ve nöron olarak adlandırılmakta olan insan beyni hücrelerinin vermiş olduğu ilhamla birlikte algoritmalar ile ilgilenmekte olan makine öğreniminin bir özel alt alanı olarak tabir edilen öğrenme tarzı derin öğrenmeyi oluşturmaktadır.


Derin öğrenmedeki asıl avantaj; köşeler ya da kenarlar gibi temel özellik setlerinin yapışması sağlanarak basit olan ham madde verilerinden karmaşık yapıdaki kavramların oluşturulması durumunun söz konusu olmasıdır. Son dönemlerde derin öğrenme yöntemlerinin görüntü tasnifleme, belirli bir nesnenin tespitini sağlama ve bölütleme yapma gibi pek çok alanda uygulandığına şahit olunmaktadır (Serra ve ark., t.y.).

2.3. Derin Öğrenme ve Evrişimli Sinir Ağları (Esa)

2.3.1. Derin öğrenme ve tarihçesi

2006'da ilk defa Hinton ve diğerleri vesilesiyle çok katmana sahip olan yapay sinir ağlarının daha etkili ve verimli bir şekilde eğitilebileceği öne sürülmüştür. Ancak derin öğrenmeyi nitelendiren bu eğitim türünün geçmişi 1987 yılına dayanmaktadır. Nitekim 1987 yılı içerisinde Rina Dechter derin öğrenme terimini ilk defa kullanmıştır. Igor Aizenberg ve diğerleri 2000 yılında yapmış oldukları bir araştırmada derin öğrenme kavramına değinmiştir.

Burada bahsi geçmekte olan derin kelimesi ağda bulunmakta olan katman sayını ifade edebilmek için kullanılmaktadır. Katman sayısında artış yaşandıkça ağın yapısında da derinleşme meydana gelmektedir. Yapay sinir ağları genel olarak bir ya da iki adet katmandan oluşmaktadır. Derin olarak nitelendirilen ağlar ise yüzlerce katmandan meydana gelmektedir. Fakat derin öğrenme 1990 ve 2000 yılları arasında yaşanmakta olan ana darboğazı, verilerin yetersiz olması ve donanımsal yetersizlikten kaynaklı olarak beklenen parlamayı gösterememiştir. Bunun nedeni ise sinir ağ modelinin derinlik gösterdikçe işlem yükünün atması ve donanım bağlamında yetersizliklerin ortaya çıkmış olmasıdır. Bunun yanı sıra üzerinde değerlendirme yapılan ağın geriye doğru eğitilmesi esnasında katman miktarı artış göstermektedir. Bu artışa paralel olarak geri bildirim sinyallerinde de azalma meydana gelmektedir. Hatta geri bildirim sinyallerinin yok olup gittiğine şahit olunmaktadır. Verilerin yetersiz olması derin öğrenmenin en büyük sorunlarından biri olan aşırı uydurma durumunun ortaya çıkmasına neden olmaktadır.



Şekil 2.19: Derin sinir ağlarını genel yapısı (Mira,1995)

Derin öğrenmenin gelişimi

Derin öğrenme gelişiminin ilk basamağını internetin yaygın olarak kullanılmaya başlanması, makine öğrenmesinin gereksinim duymakta olduğu büyük veri setlerinin toplanması ve bahsi geçmekte olan bu setlerin dağıtımının mümkün olabilmesi durumunun ortaya çıkması hususları oluşturmaktadır.

2009-2010 yıllarında oldukça basit olan fakat aynı zamanda önemlilik arz eden birtakım algoritmaların keşfedilmesi söz konusu olmuştur. Böylelikle hata sinyallerinin geriye

doğru daha iyi bir şekilde iletilmesi mümkün hale gelmiştir. Bahsi geçmekte olan bu algoritmalar;

- Katmanlar için daha yoğun olan Relu, Softmax gibi aktivasyon fonksiyonları,
- Daha uygun bir halde olan ilk baştaki ağırlığı başlatma teknikleri,
- Optimizasyonu daha iyi bir şekilde sağlayacak olan RMSProp ve Adam gibi daha iyi eniyileme teknikleri,

2014- 2016 yılları arasında hata sinyalinin geriye doğru daha iyi yayılımını sağlamakta olan artık bağlantılar, yığın normalizasyonu ve derinlemesine evrişim gibi yöntemler popülerlik kazanmıştır. Böylelikle günümüzde sayısı yüzleri geçen katmanlardan meydana gelen ağların sil baştan eğitilebilir duruma gelmesi söz konusu olabilmektedir.


Sonuç itibariyle derin öğrenme günümüzde eğitim, sağlık, iletişim gibi sektörlerde örüntü tanıma, doğal dil işleme, konuşma tanıma ve benzeri birçok alanların içerisinde yaygın olarak kullanılmaktadır.

2.3.2. Derin öğrenmenin güçlü yönleri

Derin öğrenmede, bütün katmanların gösterimleri sıralı bir şekilde değil bütünleşik bir şekilde öğrenilmektedir. Derin öğrenmede mevcut olan her faktörün yalnızca tek bir geri bildirim sinyali tarafından kontrol edilebilmekte olduğu söylenebilmektedir. Bunun yanı sıra modelde yaşanmakta olan her değişim hedefe ulaşma durumuna hizmet etmektedir. Böylelikle sıkı olan modellerin üst üste sıralamak gerekliliği ortadan kalmaktadır. Ara katmanlarından herhangi birinden soyut bir biçimde öğrenim sağlayabilmenin mümkün olma durumu söz konusu olabilmektedir.

Derin öğrenmenin diğerlerinden farklı olmasını sağlamakta olan en önemli özelliklerden bir tanesi; klasik makine öğrenme yöntemlerinde elde edilmekte olan verinin kullanılmasından önce ön bir işleminden geçirilmesi ve elde edilen verinin model için anlamlı kılınması gerekliliğine önem verilmesidir. Bu durumu sağlayabilmek ve mevcut olan sorunun çözümünü kolaylaştırabilmek adına girdilerin daha fazla ayırt edici bir nitelikte olması imkanını sağlayan özneliliklerin çıkarılması gerekmektedir.

Derin öğrenmede, makine öğrenmesinde mevcut olan bu kritik basamak tam manasıyla otomatikleştirilmiş bir biçimde kendi içinde yapılmaktadır. Bu durum ortaya çıkan sorunların çözüme kavuşturulmasını kolaylaştırmaktadır. Aşağıda bulunan şekildeki görüntüde, mevcut olan girdilere yönelik tahmin yürütülmesinde derin öğrenme ile klasik makine öğrenmesinin bir arada kullanılması durumunda ne gibi bir yol izlendiği tarif edilmektedir.



Şekil 2.20: Derin Öğrenme ve Geleneksel Makine Öğrenmesi Yaklaşımının Karşılaştırılması

Geleneksel olan makine öğrenme yöntemlerin mevcut olan eğitim verilerinin artırılması her zaman başarı durumunu olumlu bir şekilde etkilemektedir. Derin öğrenmede ise içerisinde yer almakta olan eğitim verileri çeşitlenip arttıkça başarı oranı da mutlak suretle artmaktadır. Böylesi bir durumda derin öğrenme durumunun söz konusu olabilmesi için çok sayıda eğitim verisine gereksinim duyulmaktadır. Geleneksel olarak nitelendirilen makine öğrenmesinde başarılı düzeyde bir sonuç elde edebilmek için az sayıda eğitim verisi yeterlilik arz edebilmektedir.

Derin sinir ağı ile yapılmakta olan uygulamalarda genel olarak birbirinden farklılık göstermekte olan üç yöntemin uygulaması yapılmaktadır. İlk olarak ortadaki sorunun çözümlenebilmesi uygun bir derin ağ modeli oluşturulması sonucunda eğitim gerçekleştirilmesiyle mümkün olabilmektedir. İkinci olarak ise önceden eğitilmiş olan hazır haldeki bir ağ yapısının yeni verilerle eğitilebilmesi söz konusu olmaktadır. Son olarak da derin sinir ağı yapısından özneliksel çıkarım yapılması durumunda diğer makine öğrenme tekniklerinden faydalanılması hususundan bahsetmek mümkündür.

2.3.3. Derin öğrenmede etkili olan kavramlar

Zincirleme olarak eklenmekte olan katmanlar derin ağ yapısını meydana getirmektedir. Derin ağ yapısı girdi verilerini yapılmakta olan tahminler ışığında eşleştirmektedir. Daha sonra kayıp fonksiyonu aracılığıyla hedefler ve tahminler arasındaki kayıp değeri bulunmaktadır. Kayıp olan değer bulunmasıyla ağ tahminleriyle hedeflerin ne ölçüde eşleştiğine bakılmaktadır. Eniyileme algoritmasında kayıp değerlerin ağırlık ve sapma değerleri kullanılarak ilgili değerlerin güncellenmesi söz konusu olmaktadır.

Derin öğrenme uygulamalarında en sık kullanılan hiperparametreler aşağıdaki gibidir.

- Veri setinin boyutu
- Mini – Batch boyutu
- Öğrenme ve Momentum katsayısı
- Optimizasyon algoritması
- Eğitim tur (epoch) sayısı
- Ağırlık (weight) başlangıç değerlerinin belirlenmesi
- Aktivasyon fonksiyonu
- Seyreltme (dropout) değeri
- Katman sayısı ve nöron sayısı
- Evrişimli sinir ağı kernel boyutu
- Evrişimli sinir ağı pooling yöntemi

Ağırlık

Ağırlık parametresi W harfi ile gösterilmektedir. Bu gösterimin sebebi ise ağırlık kelimesinin İngilizce karşılığının “weight” olmasıdır. Sinir ağında eğitim sırasında daha önemli bir duruma sahip olduğu fikrine sahip olunan girdilere daha yüksek bir ağırlık değeri atfedilmektedir.

Sapma

Eğitilmekte olan parametrelerinden bir tanesi olan sapmanın gösterimi b harfi ile ifade edilmektedir. Bunun sebebi ise bu parametrenin İngilizce karşılığının “bias” olmasıdır. Ağırlığa ilave olarak uygulanmakta olan doğrusal bileşene sapma denilmektedir. Bahsi geçmekte olan bu değer; ağırlıklı ve katsayılı girişin aralığını temel manada değiştirmek adına eklenmektedir.

Aktivasyon fonksiyonu

Aktivasyon fonksiyonları tensörlere etki etmekte olan doğrusal nitelikte olmayan operasyonlardır. Buradaki amaç sapma ve ağırlık değerlerinin ayarlanabilmesi durumunun sağlanmasından kaynaklanmaktadır. Bu durumu nöronların tetikleyici unsuru olarak da düşünebilmek mümkündür.

YSA’da ve yapay zekada kullanılmakta olan diğer fonksiyonlar; ReLU fonksiyonu, Hiperbolik Tanjant Fonksiyonu ve Softmax Fonksiyonlarıdır.

- ReLU Fonksiyonu; düzeltilmekte olan doğrusal birim aktivasyonu fonksiyonudur. Bu fonksiyon ile Sigmoid fonksiyonunda yer almakta olan sorun aynıdır. Bahsi geçmekte olan bu sorun 0’dan küçük olan değerleri 0 olarak kabul etmektedir. ReLU fonksiyonunda yer almakta olan pozitif değerler değerine karşılık gelmektedir. Negatif olan değerlerin ise 0 olarak kabul edildiği görülmektedir. Bu bağlamda bahsi geçmekte olan bu durumun formülizasyonu aşağıda gösterilmektedir.

$$y = f(x) = \max(0, x), 0 \leq f(x)$$

(2.27)

- Hiperbolik Tanjant Fonksiyonu (Tanh); Sigmoid fonksiyonundaki $[-1$ ve $1]$ aralığını kapsamakta olan fonksiyona verilen isimdir. Bu fonksiyon içerisinde eşikleme $0,5$ 'te sağlanmamaktadır. Eşikleme durumu sağlanması 0 'da yapılmaktadır. Bundan dolayı 0 'dan küçük bulunan sayılar 0 olarak kabul edilmemektedir. Bundan dolayı -1 'e yaklaşmakta olan değerlerin alınması söz konusu olmaktadır. Bahsi geçmekte olan bu fonksiyonun denklemi aşağıdaki gibi formüle edilebilmektedir:

$$-1 \leq f(x) \leq 1 \quad (2.28)$$

ReLU fonksiyonu; Hiperbolik Tanjant ve Sigmoid fonksiyonlarını kullanmakta olan aktivasyon kodlarına göre YSA eğitimi esnasında çok daha hızlı çalışmaktadır. Bu nedenle ağıın öğrenmesi süresi zarfında sık bir biçimde kullanılmakta olan fonksiyondur. Ancak bu fonksiyon içerisinde de Sigmoid Fonksiyonda görüldüğü gibi aktivasyon kodunda bazı dezavantajlara rastlanılmaktadır. Bu dezavantajlılık durumu negatif olan değerlerin 0 olarak kabulünün sağlanmasından kaynaklanmaktadır. Bahsi geçmekte olan bu dezavantajlı durumun önüne geçilebilmesi adına sızdırmalı ReLU fonksiyonu kavramı ortaya çıkarılmıştır. Bahsi geçmekte olan bu fonksiyonun formüle edilmiş hali aşağıda gösterilmektedir.

$$y = f(x) = 1(x < 0)(ax) + 1(x \geq 0)(x) \quad (2.29)$$

Fonksiyonda gösterimi gerçekleştirilmekte olan a sabiti genel olarak küçük bir sayı şeklinde eklenmektedir. Bunun sonucunda 0 'a yakın olan bir değer elde edilmesi söz konusu olmaktadır. Bu değer daha sonra negatif ağırlık değeri ile çarpma işlemine tabi tutulmaktadır.

- Softmax Fonksiyonu; çoklu sınıflandırma işlemlerinde kullanılmak üzere en çok başvurulan fonksiyondur. Aynı zamanda, girdiler için bir sınıflandırma ihtimaline bağlı bulunan değerlerin üretilmesine katkı sunan bir fonksiyondur. Girdilerin gerçek olan sınıfa ait olan dağılımı ve aynı zamanda ait olma ihtimali olan kümenin dağılımını normalize etmektedir. Bunun yanı sıra iki farklı değer arasındaki çarpaz entropi değerinin minimuma indirgenebilmesi mantığıyla hareket edilerek çıktıların sunulması söz konusu olmaktadır

Bahsi geçmekte olan bu fonksiyonlara ilave olarak derin öğrenme için kullanılmakta olan birbirinden farklı niteliğe sahip aktivasyon kodları de mevcuttur.

Öğrenme katsayısı ve eniyileme algoritması

Öğrenme katsayısı; hata düzeltme katsayı biçiminde de ifade edilebilmektedir. YSA içeriğinde akson görevi görmekte olan taşıyıcı nitelikteki sinaptikler eğim düşümü algoritmalarında kullanılmakta olan bir katsayı olarak bilinmektedir. Bahsi geçmekte olan öğrenme katsayısı, eğim düşümüne uygun bir biçimde tanımlanmış olan algoritmaların birbirlerine yaklaşması durumunu ortaya çıkarmaktadır.

Öğrenme katsayısında büyüme meydana geldikçe sinaptiklerin daha sonraki katmana bilgiyi taşıyamayabilme durumu söz konusu olmaktadır. Bahsi geçmekte olan bu katsayıya oldukça küçük bir değer ataması yapıldığında öğrenme sürecinde uzamının meydana geldiği görülmektedir.

Öğrenme katsayılarının belirlenebilmesi için birtakım eniyileme algoritmaları kullanılmaktadır. Bu algoritmalar, öğrenme durumunun ne şekilde ve nasıl gerçekleşebileceğini belirlemektedir. Öğrenme katsayıları için sıklıkla kullanılmakta olan algoritmaları; Adamax, Adagrad, Adadelata, Nadam, Momentum ve RMSprop olarak belirtilebilmektedir.

Kayıp fonksiyonu

Ağ için hesaplanmakta olan doğruluk değeri için kayıp fonksiyonu kullanımı söz konusu olmaktadır. Kayıp fonksiyonu, üzerinde işlem yapılmakta olan ağın, gerçek değerlerinin tahmini sürecinde hata meydana gelir ise cezalandırma mekanizmasını devreye sokmaktadır. Sınıflandırmayla ilgili sorunlarda genel anlamda kategorik çapraz entropi fonksiyonu kullanımı gerçekleştirilebilmektedir.

Geri yayılım

Bir tek iterasyon ile elde edilmekte olan çıktılar için ilgili ağın hatasının hesaplanması söz konusu olmaktadır. Elde edilmiş olan hata değeri, maliyet fonksiyonun eğimiyle beraber ilgili ağın ağırlığıyla ilgili olabilmektedir. Bu nedenle güncellenme işleminin yapılabilmesi için mutlaka bahsi geçen ağ ağırlıklarının güncellenmesi gerekmektedir. Bundan dolayı geri beslemenin yapılması durumunun ortaya çıkması söz konusu

olmuştur. Daha sonraki iterasyonlar için de hatanın en aza indirgenmesi için ağırlıkların güncellenmesi gerekmektedir. Kayıp fonksiyonunun eğimi vasıtasıyla ağırlıkların güncellenmesi durumuna geri yayılım adı verilmektedir.

Yığın, epok ve tekrar sayısı

İlgili model tarafından işlenebilmesi için tek seferde alınmakta olan miktara yığın adı verilmektedir. Bütün girdi değerlerinin bir defada gönderilmesinin yerine girdi değerleri rastgele bir şekilde de seçilebilmektedir. Rastgele seçilmiş birbirine denk büyüklükteki aynı zamanda birbirlerinden bağımsız olan yığınlar bölünme işlemine tabi tutularak içlerinde bulundukları ağda eğitilmektedir. Her bir yığın kümesinin yeniden işlenmesi durumuna tekrar denilmektedir. Bütün girdi yığınlarının tek seferde işlenmesine verilen isim ise epoktur.

2.3.4. Evrişimsel sinir ağları (cnn) ve ana bileşenleri

Canlıların görme merkezlerinden yola çıkılarak geliştirilmiş olan ve oldukça yaygın bir şekilde kullanımı gerçekleştirilen derin öğrenme yaklaşımına evrişimsel sinir ağları denmektedir. İlk başta yalnızca nesne tanıma yönelik yapılmakta olan çalışmalarda kullanılan evrişimsel sinir ağı mimarileri; güncel olarak nesne takibi ve metin tespiti benzeri çalışmalarda da kullanılmaktadır (Aloysius ve Geetha, 2017).

Evrişimsel sinir ağlarının kısaltılmış hali CNN'dir. CNN mimarileri, öğrenme yoluyla kendiliğinden optimize olan nöronlardan oluşmaktadır. Bu husus bağlamından bakıldığında geleneksel yapay sinir ağlarıyla benzerlik göstermekte olduğu görülmektedir. CNN mimarilerinin klasik nitelikteki yapay sinir ağlarından en büyük farkı öncelikli bir şekilde görüntülerde yer almakta olan örüntüleri tanıma hususunda kullanılması durumunun söz konusu olmasıdır (O'Shea ve Nash, 2015).

Kullanım yerlerine göre CNN mimarileri birbirinden farklı yapılarda kurulabilmektedir. Buna rağmen genel olarak parçalar şeklinde gruplandırılmış havuzlama ve evrişim katmanlarından meydana gelmektedir. Bahsi geçmekte olan bu katmanların devamında ise standart geri yayımlı sinir ağlarında kendisine yer bulmakta olan bir ya da birden çok tam bağımlı katman yer almaktadır (Rawat ve Wang, 2017).

Evrişim (konvolüsyon) katmanı

Konvolüsyon katmanı, CNN mimarisinde yer bulmakta olan öznitelik çıkarım aşamasının merkezi nitelikteki bir adımı olarak ifade edilmektedir. Bahsi geçmekte olan bu katmanın 2 önemli avantajı bulunmaktadır.


İlk avantajı, aralıklı bağlantı özelliğine sahip olmasıdır. Evrişimsel filtrelerden her biri, önceki özniteliklerin yerel nitelikteki parçasına bağlı bulunmaktadır. Bu durum etkili bir biçimde parametre sayısını azaltabilme potansiyeline sahiptir. Böylesi bir durum eğitim hızında artış meydana getirmektedir.

Bahsi geçen avantajlardan ikincisi ise ağırlık paylaşım özelliğine sahiptir. Öznitelik haritası üzerinde gezilirken, filtrelerin her birinin ağırlığı değişmeden kalmaktadır. Bu durum parametre sayısını daha çok azalmaktadır. Genel manada evrişim katmalarından her birinde birden fazla filtre bulunmaktadır. Bu durum daha kapsamlı bir şekilde öznitelik temsillerinin öğrenilebilmesini amaçlanmaktadır. Matematiksel bir biçimde; $x \in \mathbb{R}^d$ d- boyutlu olan bir veri olarak gösterilmektedir. Denklem (2.32)'de j. öznitelik haritasının gösterimi paylaşılmaktadır:

$$c^j = x * w^j + b^j \quad (2.32)$$

Formülde yer almakta olan $j \in \mathbb{R}^h$ ifadesi; j. filtresini temsil etmektedir. Bunun yanı sıra x girdisinin kodlanması için kullanılmaktadır. c^j olarak gösterimi gerçekleştirilmekte olan j. öznitelik haritasını meydana getirmektedir.

Bahsi geçmekte olan öznitelik haritasının gösterimi, $c^j = [c_1^j, c_2^j, \dots, c_{d-h+1}^j]$ biçiminde olmaktadır. Formül içerisindeki sapma terimi; b^j ile gösterilmektedir. Buna ilave olarak, dolgu parametreleri ve atlama sayısı da elde edilen çıktının boyutunu, evrişim yoğunluğunu kontrol altında tutmaktadır (Jiao ve ark., 2020). Tek boyuta sahip olan evrişim katmanına ait sezgisel nitelikteki şema Şekil 2.21'de gösterilmektedir.



Şekil 2.21: Tek boyutlu evrişim işlemine ait şema. (a) Tek kanallı girdi; (b) Çok kanallı girdi (Jiao ve ark., 2020).

Havuzlama katmanı

Evrişimsel katmanların arasında bulunan bağlantı miktarlarını azaltan ve buna paralel olarak hesaplama maliyetlerini de düşüren CNN bileşenine havuzlama katmanı denmektedir (Gu ve ark., 2018).

Havuzlama katmanının temel olan rolü, anlamsal bir şekilde birbirine benzemekte olan öz nitelikleri tek bir öz nitelikte birleştirmek şeklinde ifade edilebilmektedir (LeCun ve ark., 2015). Havuzlama esnasında atlama sayısı genellikle birden büyük bir sayı olarak seçilmektedir. Bu nedenle evrişim sonrası meydana gelmekte olan temsillerin boyutsal olarak azalmaya maruz kaldığı görülmektedir. Benzer çalışmalarda atlama sayısı havuzlama filtresinin ölçütlerine eşit olacak şekilde seçilmektedir. Bundan kaynaklı olarak havuzlama bloklarında çakışma meydana gelme durumu söz konusu olmamaktadır (Sze ve ark., 2017).

Tam bağlı katman

Tam bağlı katmanlar; havuzlama ve evrişim katmanlarından meydana gelen blokların oluşumundan sonra öz nitelikleri daha ileri bir boyutta işleyebilmek adına kullanılmaktadır. Aşağıda verilmekte olunan matematiksel ifade tam bağlı katmanın denklemdir.

$$fc^1 = \sigma(w^l \cdot fc^{l-1} + b^1) \quad (2.33)$$

l . Sıradaki tam bağlı katmanın çıkışında bulunan öz nitelikler; formüldeki fc^l ifadesiyle temsil edilmektedir. Bunun yanı sıra w^l ifadesi bağlantı ağırlığını belirtmek amacıyla

kullanılmaktadır. Denklemden yer almakta olan sapma değeri ifadesinin gösterimi ise b' 'dir. $\sigma(.)$ ise doğrusal durumunda bulunmayan aktivasyon fonksiyonun gösterim biçimidir (Jiao ve ark., 2020).

Standartlaşmış olan bir derin sinir ağında tam bağlı katmanlar; ağıda yer almakta olan parametrelerin büyük bit bölümünü oluşturmaktadır. Örneğin AlexNet mimarisi 60 milyon parametreden meydana gelmektedir ve parametrelerinin tam olarak 58 milyonu tam bağlı katmanlarda yer almaktadır. Buna benzer bir durumlar VGGNet ağında da karşılaşmak mümkündür. Bahsi geçen bu katmanda yer almakta olan parametrelerden tam bağlı katmanlarda bulunanların sayısı 123 milyon tanedir (Basha ve ark., 2020).

CNN ağında kendisine yer bulmuş olan tam bağlı katman sayısı ve her katmanda mevcut halde bulunan nöron sayısı ortada bulunan soruna yönelik olarak değişiklik gösterse de ağıın son bölümünde yer almakta olan tam bağlı katmanın çıktı nöron miktarı genel olarak CNN ağındaki sınıf sayısına denktir (Yamashita ve ark., 2018). Basha ve diğerlerinin birlikte yürütmüş oldukları bir araştırmada tam bağlı katmanların içerisinde bulunmakta olan nöron miktarının sığ ya da derin sinir ağları üzerindeki etkileri üzerine bir çalışma gerçekleştirilmiştir.

Bu çalışma neticesinde daha yüksek düzey performans alımı sağlayabilmek için derin ağlarda mevcut olan tam bağlı katmanlarda daha az miktarda nörona gereksinim duyulmaktadır. Bunun tam tersi olarak sığ ağlarda ise daha fazla nöron gereksinimi söz konusudur. Bunun yanı sıra bu çalışmada ulaşılmakta olan bir diğer bilgi ise; geniş veri setlerinin derin veri setlerine nazaran daha fazla miktarda tam bağımlı katmana gereksinim duymakta olduğu yönündedir.


Aktivasyon katmanı

Gizli olan nöronlardaki aktivasyon fonksiyonunda değişim meydana getirmek; derin sinir ağlarının öğrenme kabiliyetini arttıran yöntemlerden bir tanesidir. Tarihsel perspektiften bakıldığında sigmoid fonksiyonunun yaygın bir biçimde yapay sinir ağları özelinde aktivasyon fonksiyonu olarak kullanımına rastlanılmaktadır. Fakat tanjant hiperbolik fonksiyonu ve sigmoid fonksiyonu gibi standart hale gelmiş olan aktivasyon fonksiyonları kullanıldığı takdirde büyük değer içinde yer almakta olan gradyanlar neredeyse 0 olmaktadır. Bundan dolayı Olasılıksal Gradyan İniş güncellemelerinin çok

küçük olduğu görülmektedir. Bu durumda ortaya çıkan problem; “kaybolan gradyan sorunu” ismiyle anılmaktadır.

Meydana çıkmakta olan bahsi geçen Gradyan problemini çözüme kavuşturabilmek amacıyla ReLU aktivasyon fonksiyonunun geliştirilmesi söz konusu olmuştur. ReLU adı verilen fonksiyonun gradyan değerleri pozitifte sabit kalmaktadır ve hiçbir şekilde kaybolmamaktadır (Ide ve Kurita, 2017). Bu özelliklerinden dolayı ReLU aktivasyon fonksiyonu hem kaybolan gradyan porblemini çözüme kavuşturmakta hem de derin sinir ağı öğrenim hızında artışa sebep olmaktadır (Jiao ve ark., 2020).

ReLU fonksiyonunun avantajları bunlarla sınırlı kalmamaktadır. Avantajlarından biri de hesaplama maliyetinin oldukça düşük düzeyde olmasıdır. ReLU fonksiyonu içeriğinde bölme işlemleri ve üssel hesaplama yöntemleri kullanılmamaktadır. Maliyetinin düşük olması da bu husustan kaynaklanmaktadır (Nwankpa ve ark., 2018). ReLU; güncel bir şekilde derin sinir ağlarında standartlaşmış bir aktivasyon fonksiyonu olarak yerini almış bulunmaktadır (Ide ve Kurita, 2017). Aşağıda gösterimi gerçekleştirilmekte olan grafik; ReLU aktivasyon fonksiyonuna aittir.



Şekil 2.22: c_i ve y_i değerlerinin giriş ve çıkış özniteliklerini temsil ettiği durumda doğrusal olmayan ReLU fonksiyonuna ait grafik (Jiao ve ark., 2020).

Optimizasyon algoritması

Evrişimsel sinir ağı kurma işleminden sonra kurulmuş olan bu ağda kabul edilebilir bir zaman diliminde en iyi parametrelerin elde edilmesi gerekmektedir. Bunun bir diğer ifade ediliş tarzı da ilgili ağı eğitmesidir. Eğitimin sağlanabilmesi için genel olarak

gradyan düşüş tekniklerinin kullanımına rastlanmaktadır. Eğitim aşamasında genellikle kullanımına rastlanmakta olan yaklaşımlar; BGD ve SGD'dir (Jiao ve ark., 2020).

BGD yönteminde yapılan her güncelleme sonrasında gradyanın alınabilmesi adına tüm eğitim verilerinin hesaplaması yapılmaktadır. Bundan dolayı dışbükey özellik göstermekte olan düzlemin iyi anlamda maksimum değerine veya dışbükey olmayan ortamın yine iyi anlamda maksimum değerine yaklaşabilmek mümkün olmaktadır. BGD algoritmasında yapılması planlanan bir güncelleme için bütün veri setlerinin öncelikle güncellenmesi gerekli görülmektedir. İçerisinde birçok prosedürü barındırması sebebiyle dünyada uygulamasına nadiren rastlanmaktadır. Fakat, SGD yaklaşımına bakıldığında yapılması planlanmakta olan her güncelleme için yalnızca tek bir örnekten faydalandığı görülmektedir. Dolayısıyla BGD yaklaşımına nazaran daha kısa bir sürede güncelleme işleminin tamamlanmasına katkı sağlamaktadır (Jiao ve ark., 2020). Nitekim optimizasyon algoritması olarak SGD yaklaşımının kullanılması BGD yaklaşımının kullanılmasına kıyasla daha avantajlıdır.

Dropout (seyreltme) katmanı

Seyreltme katmanı; ağda bulunmakta olan birtakım bağlantıları ya da birimleri belirli bir olasılık çerçevesinde herhangi bir sistematığe bağlı kalmadan rastgele olacak bir biçimde atlayarak ağdaki genelleştirme kabiliyetini arttırmaktadır. Sinir ağlarında doğrusal durumda bulunmayan bir ilişkiyi öğrenmeye çalışmakta olan çoklu bağlantılar, birtakım durumlarda ağ içerisinde ezber durumunun gelişmesine neden olabilmektedir (Hinton ve ark., 2021). Bu vesileyle birkaç küçük ağ mimarisi üretimi de söz konusu olabilmektedir. Bunun sebebi ise birtakım birimlerin ya da katmanların rasgele bir şekilde atlanabilmekte olmasından kaynaklanmaktadır. Üretilmiş olan küçük ağ mimarilerinden küçük ağırlık içermekte olan ağ tespit edilerek temsilci ağ olarak seçimi yapılmaktadır. Seçilmekte olan bu mimari daha sonrasında tüm sunulmakta olan ağların yaklaşımı şekilde kabul edilmektedir (Khan ve ark., 2020).

Seyreltme işlemine maruz kalmış olan nöronlar, ileri besleme durumunda katkı sağlayamamaktadır. Bunun yanı sıra geri yayılım durumuna da katılım gösterememektedir. Bundan dolayı her bir çalışmada farklı özelliklere sahip mimari örnekleri oluşabilmektedir. Oluşmakta olan tüm mimariler ağdaki ağırlığı paylaşmaktadır. Bu teknik; nöron grupları arasında bulunan bağımlılık problemini

azaltıcı etki göstermektedir. Bunun sebebi ise bir nöronun artık başka bir nöronun varlığına bağlı bir şekilde çalışmıyor olmasıdır. (Krizhevsky ve ark.,2012).

Sınıflandırma katmanı

Öznitelik çıkarımı yapıldıktan sonra elde edilen sonuçların alınması için sınıflandırma katmanı çıktı katmanı olarak kullanılmaktadır. Sınıflandırma katmanlarında en popüler ve yaygın şekilde kullanılmakta olan aktivasyon fonksiyonu Softmax fonksiyonudur (Jiao ve ark., 2020).

Geçmişten bugüne kadar derin öğrenme yöntemleri birçok çalışmada ve araştırmada kullanılmıştır ve en yüksek düzeyde performans sonuçları alınmıştır. (Krizhevsky ve ark., 2012; Simonyan ve Zisserman, 2014). Yapılmakta olan bu çalışmalarda kullanımı gerçekleştirilen sinir ağlarında sınıflandırıcı rol üstlenen aktivasyon fonksiyonu Softmax aktivasyon fonksiyonu olmuştur (Agarwal ve ark., 2018).


Yaygın olarak sınıflandırma katmanında Softmax aktivasyon fonksiyonunun kullanılmasının sebebi, bahsi geçen bu aktivasyon fonksiyonunun her bir sınıf adına ihtimalleri ayrı ayrı hesaplamasından kaynaklanmaktadır (Aloysius ve Geetha, 2017). SVM yöntemi de yaygın bir biçimde kullanımı gerçekleştirilmekte olan bir diğer yöntemdir (Cortes ve Vapnik, 1995). SVM, CNN özniteliklerin entegre olabilecek bir kapasiteye sahiptir. Bunun yanı sıra çeşitli sınıflandırma faaliyetlerinde kullanımı söz konusu olmaktadır (Gu ve ark., 2018).

Softmax aktivasyon fonksiyonunun ifade edilmekte olduğu matematiksel denklemin gösterimi Denklem 2.33’de verilmiştir.

$$p(z)_i = \frac{e^{z_i}}{\sum_{i=1}^{N_c} e^{z_i}} \quad (2.33)$$

Yukarıdaki denklemde yer alan $p(z)_i$ ifadesi; olasılık durumunu temsil etmektedir. Giriş vektörü olarak kullanılmakta olan standart üssel fonksiyon ise e^{z_i} ifadesi kullanılarak gösterilmektedir. Bunun yanı sıra formülde yer almakta olan z değeri i kategorisine aittir. Bu durumun matematiksel gösteri ise $i \in N_c$ biçiminde yapılmaktadır (Jiao ve ark., 2020).

Çalışmanın bu kısmında CNN mimarisinde yer almakta olan havuzlama, evrişim ve tam bağlı katmanlardan bahsedilmektedir. Bunun yanı sıra ağırlıkların güncellenmesi durumunda kullanılmakta olan optimizasyon yönteminden ve ilgili ağı son katmanında kendisine yer bulmakta olan sınıflandırma katmanından da söz edilmiştir. Verilmekte olan genel bilgiler ışığında; 32x32 ölçülerine sahip olan örnek görüntü girdisine uygulaması gerçekleştirilen CNN mimarisinin genel yapısı aşağıda gösterimi gerçekleştirilen şekil 2.23'te verilmiştir.



Şekil 2.23. 32x32 boyutunda bir görüntüye uygulanan CNN mimarisinin genel yapısı (Aloysius ve Geetha, 2017)

Evrişimsel sinir ağları mimarileri

LeNet-5 mimarisi

LeNet-5 mimarisi el yazısı basamaklarının sınıflandırılabilmesi adına Yann LeCun ve arkadaşları tarafından geliştirilmiştir (LeCun ve ark.,1998). LeNet-5 mimarisi görüntülerde oldukça az olacak şekilde ön işlemeye gereksinim duymaktadır. Bunun yanı sıra ham olan piksellerden doğrudan öğrenim gerçekleştirebilmektedir. LeNet-5 mimarisi birden fazla katmana sahiptir. Aynı zamanda LeNet-5 mimarisi geri yayılım algoritması kullanımıyla eğitilebilme potansiyelini içerisinde barındırmaktadır (Gu ve ark., 2018).


LeNet-5 mimarisi, eğitilebilir özelliğe sahip olmakta olan 7 adet katmandan meydana gelmiş bir CNN mimarisidir. LeNet-5 mimarisi;

- iki tane tam bağlı katman,
- iki tane havuzlama katmanı,

- iki adet evrişim katmanı,
- bir adet çıktı katmanından oluşmaktadır.

Tarihsel süreçte geçmiş zaman diliminde ABD’de bulunan birçok bankada kullanılmakta olan çeklerin üzerindeki el yazısı rakamlarının tanınmasında LeNet-5 mimarisinin kullanımı gerçekleştirilmiştir. Bu kullanım sonucu LeNet-5 mimarisinden oldukça memnun kalınmıştır. Bunun nedeni ise mükemmel bir düzeyde tanıma başarısı elde edilmiş olmasıdır (Wang ve Gong, 2019).

Bahsi geçen mimari de giriş görüntüsünün boyutu 32x32 olarak belirlenmiştir. Seçimi gerçekleştirilmiş olan bu görüntü boyutu, veri tabanında mevcut olan ve 28x28 boyutuna sahip bir alanda ortalanmış durumdaki maksimum 20x20 boyutuna sahip olan karakter boyutlarından son derece büyüktür. Rakam görüntülerinin tanınabilmesi çalışmasında kullanılmakta olan LeNet-5 mimarisi Şekil 2.24 kapsamında gösterilmektedir.



Şekil 2.24: LeNet-5 mimarisinin genel yapısı (LeCun ve ark., 1998)

Bu şekil çerçevesinde gösterilmiş olan LeNet-5 mimarisindeki mevcut evrişim katmanları sırasıyla C1 ve C3 olarak ifade edilmektedir. Havuzlama katmanları ise S2 ve S4 olarak yine sıralı bir şekilde gösterilmiştir. C5 ve F6 ise tam bağlı katmanları ifade etmektedir. 10 adet basamağı bulunan bir veri setini sınıflandırmak amacıyla kurulmuş bulunan LeNet-5 ağında yine toplamda basamaklara paralel olarak 10 sınıf bulunmaktadır. Bundan dolayı ilgili ağı çıkış kısmında 10 nörona sahip olan bir çıktı katmanı mevcuttur.

C1 olarak isimlendirilmiş olan katmanın 6 öznitelik haritası bulunmaktadır. Öznitelik haritasında mevcut olan her birimin, giriş görüntüsünde bulunan 5x5 boyutundaki komşuya bağlılığından söz edebilmek mümkündür. C1 katmanında bulunan eğitilebilir nitelikteki parametrelerin sayısı 156'dır. Aynı zamanda C1 katmanı 122.304 adet bağlantıyı içerisinde barındırmaktadır. S2 katmanı ise bir havuzlama katmanıdır. Bu katman dahilinde 14x14 boyutlarındaki 6 öznitelik haritası bulunmaktadır. Toplamda S2 katmanı 156 adet eğitilebilir nitelikteki parametreye sahiptir. Bunun yanı sıra ise 122.304 adet bağlantıyı içerisinde bulundurmaktadır.

Bundan sonra gelmekte olan C3 katmanı, evrişim katmanıdır. İçerisinde 16 öznitelik haritası mevcuttur. Bunu yanı sıra toplam 151.600 bağlantıyı içerisinde barındırmaktadır. İçerisinde 1.516 parametre mevcuttur. S4 havuzlama katmanının içerisinde 16 adet öznitelik haritası bulunmaktadır. Bunların boyutları ise 5x5'tir. Bahsi geçmekte olan S4 katmanında toplam 32 adet eğitilebilir özelliğine sahip parametre bulunmaktadır. S4 katmanı içerisinde 2000 bağlantı olduğu görülmektedir.

C5 katmanı bir evrişim katmanıdır. 120 adet öznitelik haritasına sahiptir. İçerisinde barındırmak olduğu her bir birim, S4 katmanı üzerinde yer almakta olan 16 öznitelik haritasının 5x5 komşularına bağlı durumdadır. Öznitelik haritasının C5 katmanındaki boyutu 1x1'dir. Bu durumdan kaynaklı olarak C5 ile S4 arasında tam bir bağlantı olduğu görülmektedir.

C5 katmanı yukarıda da belirtildiği üzere bir evrişim katmanıdır. Buna rağmen tam bağlı katman şeklinde etiketlenmiştir. Bunun sebebi LeNet-5 girdi görüntüleri büyütülüp diğer bütün faktörlerin sabit kalması sağlanırsa, öznitelik haritasının boyutu 1x1'den daha büyük olarak karşımıza çıkmaktadır. F6 bağlı katmanı ise C5 katmanına tam bağlı durumdadır. İçerisinde toplam 10.164 adet eğitilebilir parametre barındırmaktadır (LeCun ve ark., 1998).

VGG-16 mimarisi

Büyük bir ölçeğe sahip olan görüntülerin tanınması durumunda, CNN mimarilerindeki derinliğin arttırılmasına bağlı olarak gerçekleşen başarı değişimlerini gözleyebilmek adına geliştirilmiş bulunan mimariye; VGG mimarisi denilmektedir. Bahsi geçmekte olan bu mimari, her bir evrişim katmanını içerisinde 3x3 gibi küçük boyutlu filtrelerin

kullanıldığı ilk mimaridir. 9x9 ve 11x11 gibi büyük boyutlardaki filtrelerin kullanıldığı AlexNet ve LeNet mimarilerine nazaran VGG mimarisinin kullanmakta olduğu filtreler oldukça küçük kalmaktadır. VGG mimarisinin vermekte olduğu en büyük nitelikteki katkı; daha büyük boyutlardaki maske filtrelerinin yüksek düzeydeki hesaplama maliyetini düşürmek adına birbirlerini takip etmekte olan evrişim gruplarını kullanarak olmasından kaynaklanmaktadır (Rezende ve ark., 2019).

VGG-16 ise; VGG ailesinin bir üyesi durumunda olan ve toplamda 16 katmandan meydana gelen bir mimaridir. VVG-16 mimarisi; 2014 yılı içerisinde Andrew Zisserman ve Karen Simonyan tarafından sunulmuştur. Bahsi geçmekte olan bu mimarinin eğitim aşaması kapsamında 224x224 boyutundaki RGB görüntülerinin kullanımı söz konusu olmuştur (Simonyan ve Zisserman, 2014).

VGG-16 mimarisi kapsamında yer almakta olan ilk iki evrişim katmanının 64 öznitelik filtresi bulunmaktadır. Bahsi geçmekte olan bu filtreler 3x3 boyutundadır. Giriş görüntüsünün ilk iki erişim evrişim katmanına gönderiminin gerçekleştirilmesiyle ilgili görüntünün boyutu 224x224x64 şeklinde değişime tabi tutulmaktadır. Oluşmuş durumdaki çıkış görüntüsünün atlama sayısı daha sonra 2 olarak ayarlanmıştır. Bu ayarlama sonucunda maksimum havuzlama katmanına gönderimi sağlanmıştır. 3. ve 4. evrişim katmanlarının içerisinde yer almakta olan 124 öznitelik bulunmaktadır. Bunun yanı sıra ise 3x3 filtre boyutuna sahiplerdir. Bahsi geçmekte olan bu iki katmanı atlama miktarı 2 olan bir adet maksimum havuzlama katmanı izlemektedir. Sonuç itibarıyla meydana gelen görüntünün boyutu 56x56x128'dir.

5.,6. ve 7. katmanlar evrişim katmanlarıdır. Filtre boyutları ise 3x3'tür. Bahsi geçmekte olan her üç katmanın içerisinde de toplamda 256 adet öznitelik haritası kullanımına rastlanmaktadır. Bu katmanları da atlama sayısı iki olan bir maksimum havuzlama katmanı izlemektedir. 8. ve 13. Katmanlar arasında yer almakta olan diğer katmanlar evrişimsel katman setleri olarak adlandırılmaktadır. Bu katmanların 3x3 filtre boyutuna sahip oldukları bilinmektedir. Bahsi geçmekte olan her evrişimsel katman grubu içerisinde 512 adet filtre mevcuttur.

Bahsi geçmekte olan katmanları, atlama sayısı 1 olarak tespit edilmiş olan maksimum havuzlama katmanı izlemektedir. 14. ve 15. katmanlar, tam bağlı gizli katmanlardır. Bahsi geçmekte olan bu katmanlar 4096 birimden meydana gelmektedir. Son katman

ise 16. katman olarak ifade edilmekte olan sınıflandırma katmanıdır. Bahsi geçmekte olan bu katman toplamda 1000 birimden oluşmakta olan bir Softmax katmanıdır (Tammina, 2019). Gizli olan katmanlarda ise aktivasyon fonksiyonu olarak ReLU aktivasyon fonksiyonu kullanımı tercih edilmiştir (Masood ve ark., 2020).

VGG-19 mimarisi

Zisserman ve Simonyan; VGG-19 mimarisinin sunumu ortaya koymuş bulunmaktadır (Simonyan ve Zisserman, 2014). 2014 yılında gerçekleştirilmiş olan Imagenet yarışmasına VGG takımının katılmasının sebebinin altında VGG-16 ve VGG-19 mimarileri bulunmaktadır. VGG takımı bu yarışmada bahsi geçmekte olan bu mimarileriyle birincilik ve ikincilik ödülü alamaya hak kazanmışlardır (Carvalho ve ark., 2017).

VGG-16 mimarisi ile VGG-19 mimarisi benzer yapı özelliklerine sahiptirler. Ancak VGG-19 mimarisinin VGG-16 mimarisine göre 3 katman fazla olması durumu aralarındaki farkı belirlemektedir. VGG-19 mimarisinde yer almakta olan bu fazladan 3 katman, eğitim çalışmalarının daha etkili olmasını sağlamaktadır. Bu nedenle elde edilmekte olan görüntülerden daha detaylı nitelikleri içerisinde barındıran örüntülerin öğrenilebilmesi söz konusu olmaktadır (Reghunath ve ark., 2019).

VGG-19 mimarisi kolaylıkla uygulanabilir olması ve sade olması sebebiyle avantaj yaratmaktadır. Bu nedenle de oldukça popülerdir. VGG-19 mimarisi görüntü sınıflandırma işlemlerinde oldukça üst seviye bir performans sergilemektedir. VGG-19 mimarisi ile VGG-16 mimarisi aynı boyuttaki (224x224) görüntüleri girdi olarak ele alıp değerlendirilmesini yapmaktadır (Xia ve ark., 2019).

VGG-19 mimarisi beş adet evrimsel katmandan oluşan blokları izleyen 3 adet tam bağlı katmandan meydana gelmektedir. Bahsi geçmekte olan bu evrimsel katmanların kullanmakta olduğu filtreler 3x3 boyutundadır. Atlama adım sayıları ise 1'dir. Aynı zamanda evrimsel katmanlar sahip oldukları her bir aktivasyon haritasının kendisinden bir önceki katmanla aynı olan uzaysal boyutların devamlılığın garanti altına alınması adına dolgu değeri olarak 1'i kullanmaktadır. Bu mimari yapısında her bir evrim katmanının ardından ReLU aktivasyon fonksiyonu kullanımı gerçekleştirilmektedir.

AlexNet mimarisi


2012’de Krihevesky ve arkadaşları AlexNet mimarisini ortaya koymuşlardır. AlexNet mimarisi ilk derin CNN mimarisi; AlexNet mimarisi olarak ifade edilmektedir (Krizhevsky ve ark., 2012). AlexNet mimarisi CNN mimarisinin öğrenme kabiliyetinin artış göstermesine neden olmuştur. Bu durum farklı parametre optimizasyon stratejisi kullanılmasından ve derinlik arttırılması hususundan kaynaklanmaktadır. Bahsi geçmekte olan bu mimari; birbiriyle aynı doğrultuda olan NVIDIA GTX 580 GPU üzerinden eğitilmiştir (Khan ve ark., 2020).

Şekil 2.26’da AlexNet mimarisi gösterimi gerçekleştirilmiştir. AlexNet mimarisi, 3 tam bağlı katmadan ve 3 evrişim katmandan meydana gelmektedir. Evrişim katmanlarının ilkinde Yerel Tipik Normalizasyon olarak adlandırılan LRN kullanılmıştır. Bu LRN kullanımı ile evrişim ve havuzlamanın gerçekleştirilmesi söz konusu olmaktadır.

İlk olarak yer almakta olan evrişim katmanında 96 adet birbirinden farklı filtre kullanılmaktadır. Bu filtrelerin boyutu 11x11’dir. En yüksek düzeydeki havuzlama işlemleri sırasında 3x3 boyutlu filtre kullanılmaktadır. Bunun yanı sıra bu işlem sırasından kaydırma sayısı 2 olarak belirlenmektedir.

Aynı işlemler ikinci katmanda da yapılmaktadır. Burada mevcut olan filtrelerin boyutları 5x5 olarak belirlenmiştir. 3., 4. ve 5. katmanlarda kullanımı söz konusu olan filtrelerin boyutları 3x3 olarak belirlenmiştir. Bu katmanlarda yer almakta olan öznetelik haritası boyutları ise sırası itibariyle 384, 384 ve 296 olacak şekilde tercih edilmiştir.

Tam bağlı katmanlarda seyreltme söz konusu olmaktadır. Ancak sonda yer almakta olan katmanda Softmax aktivesyon fonksiyonu kullanımı gerçekleştirilmektedir. ImageNet veri seti tarafından eğitilmiş olan AlexNet mimarisinin görüntü giriş boyutu 224x224x3 şeklinde belirlenmiştir (Alom ve ark., 2018).



Şekil 2.26: AlexNet mimarisi (Krizhevsky ve ark., 2012)

ZFNet mimarisi


CNN mimarilerinin sahip olduğu öğrenme mekanizmasında, 2013 yılı öncesine kadar görüntü tanıma hususunda gerçekleşmekte olan iyileşme durumunun asıl nedeni tespit edilememiştir. CNN mimarilerindeki bu iyileşme durumuna neden olan durumun bilinmemesi karmaşık niteliğe sahip olan görüntülerde mevcut olan performans düzeyinin oldukça sınır seviyede tutulmasına neden olmuştur.

Rop Fergus ve Mathew Zeiler, 2013’de AlexNet mimarisi uzantısına sahip olan bir CNN mimarisi sayesinde ILSVRC 2013’ü kazanmıştır. Bahsi geçen bu mimari ZFNet ismiyle anılmaya başlanmıştır. ZFNet mimarisinde 11x11 boyutlarındaki filtrelerin yerine boyutları 7x7 olan filtrelerin kullanılması uygun görülmüştür. Bu durum mevcut ağırlığı çok büyük oranda azaltmaktadır. Ağırlık sayısını azaltmakta olan bu mimari, genel olarak tanıma hususundaki başarı düzeyinde de artışa neden olmuştur (Alom ve ark., 2018).

ZFNet mimarisi, temel anlamda bakıldığında çok katmana sahip olan bir dekonvolüsyonel sinir ağı olarak da değerlendirilebilmektedir. Bahsi geçmekte olan bu mimari ağda gerçekleşmekte olan performans durumunu nicel bir biçimde görselleştirebilmek amacı doğrultusunda ortaya çıkarılmıştır. Ağ aktivitesinin görselleştirilmesi talebinin ortaya çıkmasındaki amaç, nöron aktivitelere yorum katarak CNN performansını takip etmektir.

ZFNet aracılığıyla sunulmakta olan özneteliklerin görselleştirilmesi düşüncesinin sağlanması AlexNet üzerinde de yapılmıştır. AlexNet kapsamında DNN kullanımının

gerçekleştirilmesiyle, yalnızca birtakım nöronların aktive olduğu sonucuna varılmıştır. Var olan ağda yer almakta olan 1. ve 2. katman dahilindeki diğer nöronların pasif nöronlar olduğu tespit edilmiştir. Elde edilmiş olan bu bulgulara dayanılarak, Fergus ve Zeiler tarafından CNN topolojisi düzenlemesi yapılmıştır. Bu düzenleme esnasında parametre optimizasyonu gerçekleştirilmiştir. Bahsi geçmekte olan mimarideki ilk iki evrimsel katmanda maksimum sayıda özneteliğin bulundurulabilmesi adına hem kaydırma adım sayısı azaltılmış hem de filtre boyutu küçültülmüştür. Böylelikle CNN mimarisinde yer alan öğrenme kapasitesi yükseltilmiştir (Khan ve ark., 2020). Şekil 2.27.'de ZFNet mimarisinin gösterimi gerçekleştirilmiştir.



Şekil 2.27: ZFNet mimarisi (Zeiler ve Fergus, 2014)

GoogleNet (inception-V1) mimarisi

Daha az hesaplama maliyetiyle daha yüksek düzeyde tanıma başarı elde edebilmek amacıyla GoogleNet mimarisi ortaya çıkmıştır. GoogleNet mimarisi sayesinde CNN yapısı içeriğine inception olarak tabir edilen başlangıç bloklarının ilave edildiği görülmektedir. Bahsi geçmekte olan bu mimaride; dönüştürme, parçalama ve birleştirme teknikleri kullanılarak çok ölçekli evrimsel dönüşümler bir araya getirilmektedir. Başlangıç bloğunu meydana getiren mimari yapının gösterimi şekil 2.28'de gösterilmiştir.


Bu mimaride, Network in Network mimarisine benzemekte olan bir biçimde geleneksel nitelikteki evrişim katmanları ile küçük blokların değiştirilmesi söz konusu olmuştur. Bahsi geçen bu bloklar, birbirinden farklı ölçeklerde uzaysal nitelikteki bilgileri yakalayabilmek adına birbirinden farklı boyutlara sahip olan filtreleri içerisinde barındırmaktadır. Bu filtrelerin boyutları 5x5, 3x3, 1x1 olarak değişmektedir. Burada gerçekleştirilmesi planlanan amaç; birbirinden farklı çözünürlüklere sahip resimlerden öğrenme yapılırken karşılaşılmakta problemleri çözüme kavuşturmaktadır.

GoogleNet mimarisi büyük olan filtreler 1x1 boyutundaki Bootleneck evriřim filtresini dahil ederek yapılmakta olan işlemlerin düzenlenmesini sağlamaktadır. Bunun yanı sıra GoogleNet mimarisinde seyrek yapıdaki bağlantıların kullanımı söz konusu olmaktadır. Çıkışta yer almakta olan öznetelik haritaları ile girişte bulunan öznetelik haritaları birbirlerine bağılı durumda değildir. Bahsi geçmekte olan bu yapıdaki amaç, gereksiz olan bilgi problemlerini çözüme kavuşturmak ve alakasız olan öznetelik haritalarını sistem dışı tutarak maliyetin düşürölmesine katkı sağlamaktır. Tüm bunların yanı sıra GoogleNet mimarisinde tam bağılı katmanın yerine küresel ortalama havuzlama kullanılmaktadır. Bundan dolayı bağılılık yoğunluğunun azaltılması uygun görölmüştür (Khan ve ark., 2020).

GoogleNet mimarisi, 22 katmandan meydana gelmektedir. Daha önce kullanılmakta olan herhangi bir ağı nazaran daha büyük olduğı söylenebilmektedir. Fakat katman sayısı çok olsa da bu mimaride kullanılmakta olan parametre miktarı, VGG ve AlexNet ağılarıyla kıyaslandığından daha azdır. Bahsi geçmekte olan ağların parametre sayıları řu şekilde ifade edilebilmektedir (Alom ve ark., 2018).

- GoogleNet → 7 milyon parametre,
- VGG-19 → 138 milyon parametre,
- AlexNet → 60 milyon parametre.

GoogleNet mimarisinin en büyük dezavantajı; topolojisinin heterojen bir yapıda olmasıdır. Bu heterojenlik durumu topolojinin birimden birime farklılaştırılıp özelleştirilmesini gerekli kılmaktadır. GoogleNet mimarisine ait olan bir diğeri dezavantajı ise dahilinde bulunan temsil darboğaz filtresinin bir sonraki katman içerisinde yer alan öznetelik haritasını küçölmesi ve belirli dönemlerde önemli nitelikteki bilgilerin kaybolmasına neden olabilmektedir (Khan ve ark., 2020).



Şekil 2.28: Parçalama, dönüşüm ve birleştirme yapısını gösteren temel inception bloğu mimarisi (Khan ve ark., 2020).

DenseNet121 mimarisi

2017’de sunumu gerçekleştirilmiş olan ve ağ mimarisindeki katmanların arasında gerçekleşmekte olan bilgi akışını maksimum seviyeye çıkarmayı amaçlayan CNN mimarisi türüne DenseNet121 denilmektedir. Bu mimari içerisinde yer almakta olan tüm katmanlar eşleşme gösteren özellik haritası boyutları ile doğrudan olacak bir biçimde birbirine bağlanmaktadır. Bu durum katmanlar arasındaki bilgi akış hızında artış meydana gelmesine sebep olmaktadır (Huang ve ark., 2017).

Alternatif bir şekilde havuzlama katmanlarının ve Dense bloklarının dizilimiyle oluşturulmakta olan DenseNet121; verimli ve basit bir ağ mimarisi olma özelliğiyle ön plana çıkmaktadır. DenseNet121 mimarisinde, ileri besleme bağlantıları oluşturulmaktadır. Bu bağlantılar oluşturulurken aynı zamanda bir katmandan diğer tüm katmanlara bağlantı kurulmaktadır. Diğer mimari tarzlarında N adet katman bulunmaktadır. Ancak DenseNet121 mimarisinde $N(N+1)$ adet doğrudan bağlantının olduğu görülmektedir. Ağın verimlilik düzeyimi ve doğruluk oranını arttırmak adına bahsi geçmekte olan bu mimaride ilk ve son katmanlar arasında yer almakta olan daha kısa bir daha kısa durumdaki bir bağlantı kullanılması söz konusu olmaktadır.

Sonraki katmanlarda giriş değeri ilerleme sağladıkça, her katmanda bulunmakta olan özellik haritaları bir öncesi haritayla bütünleştirilmektedir. Bu özellikten dolayı başka bir katmanın özellik haritasına katmanlar tarafından ulaşım sağlanabilmektedir. Bunun yanı sıra DenseNet121 mimarisi gradyan kaybolma sorununu da azaltarak ilgili özelliğin tekrardan kullanılmasına sebep olmaktadır.

Bu mimari tipinde diğer CNN minari tiplerine nazaran daha az parametre kullanıldığı görülmektedir. Gereksiz olarak görülen hiçbir parametrenin uygulamaya eklenmesi söz konusu olmamaktadır. DenseNet121 mimarisinde düşük değere sahip olan ağırlıklar bulunmaktadır. Bundan dolayı CNN mimarileriyle kıyaslandığında daha küçük bir ağ mimarisine sahip olduğu görülmektedir (Yapıcı ve ark., 2019).


DenseNet121 mimarisi; büyüme oranı adında bir hiper parametre kullanmaktadır. Bu parametre ile her katmanın genel ağ durumuna ne denli katkı sunduğu belirlenmektedir. Ağın içinde bulunduğu genel durum bir kere tespit edilip kayıt altına alındıktan sonra ağın her bölgesinde tespit edilmiş olan bu duruma ulaşabilmek mümkün olmaktadır. Böylelikle başka CNN mimarileri gibi her katman için farklı bir katmanda kopyalama yapılmasına gerek olmamaktadır. Ağda kullanılmakta olan büyüme oranı parametresinin gösterimi k ile yapılır ise; DenseNet121 mimarisi diğer CNN mimarilerine nazaran daha dar katmanlar içerebilmektedir.

İmageNet veri tabanı kullanılarak yapılmakta olan çalışmalarda 4 Dense bloğu kullanılmıştır. Giriş görüntü boyutu ise 224×224 ölçülerinde tercih edilmiştir. Yürütülmekte olan çalışmalarda havuzlama katmanlarında ve evrişim katmanlarında atlama adım sayısı 2 iki olarak belirlenmiştir. Kullanılmakta olan katmanların boyutları ise şu şekilde tercih edilmiştir;

- Evrişim boyutu $\rightarrow 7 \times 7$,

- Havuzlama katmanı $\rightarrow 3 \times 3$.

Büyüme oranı değeri olarak $k = 4$ değerini kullanmakta olan ve 5 Dense bloğundan meydana gelmekte olan DenseNet mimarisinin gösterimi Şekil 2.29'da yapılmıştır.



Şekil 2.29. Büyüme oranı olarak $k = 4$ kullanan ve 5 Dense bloğu içeren bir DenseNet mimarisi (Huang ve ark., 2017)


MobileNetV2 mimarisi

Mobil aygıtlar için geliştirilmiş olan; ağ boyutunu küçülten ve ağ maliyetini düşüren evrimsel sinir ağı mimarisi; MobileNetV1'dir. MobileNetV1 mimarisi kapsamında mobil aygıtlarda görüntü sınıflandırma işlemleri olabildiğince kolay bir şekilde yapılabilmektedir. 2018'de MobileNetV2 mimarisi kullanıma sunulmuştur. Bu mimari tipi MobileNetV1'in geliştirilmiş halidir.

İlk olarak yüz özneteliklerini tanımak adına tasarlanmış olan MobileNetV2 mimarisi; Google'ın kurum içi veri seti içerisinde eğitilmiştir (Saxen ve ark., 2019). Bu mimari kullanılarak sınıflandırma, nesne tanıma ve segmentasyon işlemleri gerçekleştirilmektedir.

MobileNetV2 mimarisi, bir önceki sürümü olan MobileNetV1'e ek iki yeni farklı özellik kullanılarak geliştirilmiştir. Bahsi geçen bu özelliklerden ilki; katmanların kendi arasında doğrusal bir şekilde darboğazların oluşabilmesini sağlamaktır. Bu özelliklerinden ikincisi ise mimari yapısının içerisinde yer almakta olan darboğazların kendi arasında geçişini sağlayan kısa yolların geliştirilmesidir. Genel olarak MobileNetV2 mimarisini ifade etmekte olan şema Şekil 2.30.'da gösterilmektedir (Toğaçar ve ark., 2021).

Derin öğrenme algoritmalar içerisindeki ağın derinliğinde artış meydana geldikçe gradyan kaybolma problemi de artış göstermektedir. Ancak MobileNetV2 mimarisinde bulunan ters çevrilmiş vaziyetteki artık blok, gradyan problemini çözmek için BN'yi kullanmaktadır. Mimaride ReLU aktivasyon fonksiyonu kullanılmaktadır. Çıkış değeri ise 0 ile sonsuz aralığında değişim göstermektedir. MobileNetV2 mimarisinde ReLU aktivasyon fonksiyonunun düzenlenmiş hali olan ReLU6 aktivasyon fonksiyonunun kullanımı tercih edilmiştir (Zou ve ark., 2020).



Şekil 2.30: MobileNetV2 mimarisinin genel çalışma şeması (Toğaçar ve ark., 2021).

2.4. İlgili Araştırmalar

2019 yılında tez danışmanım Dr. Öğr. Üyesi Kenan Zengin ile ortaya koyduğumuz çalışmada, cilt lezyonu içeren dermoskopik görüntülerin sınıflandırılması problemini çözmek için konvolüsyonel (evrimsel) sinir ağı ile derin öğrenme temelli bir çözüm sunulmuştur ve bahsi geçen çalışma Avrupa Bilim ve Teknoloji Dergisi'nin 2019 yılı özel sayısında araştırma makalesi olarak yerini almıştır.

2021 yılında Jusman ve diğerleri tarafından gerçekleştirilmiş olan çalışmada cilt kanserinin ehemmiyetine değinilmektedir. Cilt kanserinin nedenleri ve oluşum aşamaları üzerinde durulmaktadır. Bu araştırma kapsamında özel bir niteliğe sahip evrimsel sinir ağı olan Çok katmanlı Perceptron kullanılmıştır. Bunun yanı sıra cilt kanserinin tasniflendirilmesi için VGG-16 kullanılmıştır. Kullanılmakta olan bu sistem HAM10000 veri seti ile eğitilmiştir. Bu çalışmada sonuç olarak birbirinden farklı sinir ağlarının sistematik bir şekilde karşılaştırma yapmada ve yapılan karşılaştırmaların

analizini sağlamada kullanılmasının yarar sağlayabilecek bir potansiyele sahip olduğu çıkarımı yapılmıştır.

2016 yılında Fidan ve diğerleri yapmış oldukları çalışma melanom ekseninde şekil almıştır. Öncelikle bir cilt kanseri olan melanoma sebep olan kaynaklar üzerinde durulmuştur. Bu çalışmada gerçekleştirilmesi planlanan amaç; atipik, normal ve melanom gibi cilt lezyonlarını yapay zeka yöntemleri ile tasniflendirmektir. Bu tasniflendirme ile alanında uzman dermatologların karar aşamasına yardımcı olmak hedeflenmiştir. Çalışma kapsamında PH2 veri seti kullanılmıştır. Kullanımı gerçekleştirilen bu veri seti ile deri lezyonlarının %100 doğru tasniflendirilmesi sağlanmıştır. Çalışmanın neticesinde araştırma kapsamında elde edilen veriler, karar destek sisteminin cilt lezyonu tanısı koyma aşamasında alanında uzman dermatologlara yardımcı olabilecek bir niteliğe sahip olduğunu göstermektedir.

2009 yılında Demir yapmış olduğu çalışmada dermatoskopi üzerinde yoğunlaşmıştır. Bu çalışmanın amacı; pigmentte durumdaki deri lezyonlarının dermatoskopik, klinik muaeyene ve histopatolojik inceleme teknikleri ile değerlendirilmeye tabi tutularak lezyonların tanı koyma aşamalarının spesifitesi ve sensitivitesinin araştırılmasıdır. Bu çalışma 2005-2006 yıllarında Fırat Üniversitesi Hastanesi'nin ilgili polikliniğinde gerçekleştirilmiştir. 22'si erkek 45'i kadın olmak üzere toplamda 67 hasta üzerinde inceleme yapılmıştır. Hastalarda mevcut olan pigmentte lezyonları histopatolojik, dermatolojik ve klinik olarak incelenmiştir. Daha sonra ilgili lezyonların tanıları birbirleriyle karşılaştırılmıştır. Bu çalışmanın istatistiksel analizleri SPSS 12.0 paket programı ile yapılmıştır. Yapılan çeşitli analizler sonucunda dermatoskopinin pigmentte deri lezyonlarına doğru tanı koyabilme hususlarında alanında uzman olan doktorlara yardım edebileceği kanısına varılmıştır.

1999 yılında Küçüker ve diğerleri birlikte yürütmüş oldukları çalışmada fareler üzerinde deri lezyonu oluşturmuşlardır. Bu işlem subkutan enjeksiyonla yapılmıştır. Bu çalışmanın amacı klebsielle suşlarıyla deneysel deri lezyonu oluşturmaktadır. Nitekim sonuç olarak; uygulaması yapılan fare modelinin, Klebsiella cinsi bakterilerin virulansını tespit etme konusunda uygun bir yöntem olarak kabul edilmesi sağlanmıştır.

2019 yılında Oğrum tarafından yürütülmüş olan çalışmada çocukluk döneminde meydana gelmekte olan deri lezyonlarının diğer hastalıklarla olan ilişkisi tespit

edilmeye çalışılmıştır. Bu çalışma 2014-2017 yılları arasında gerçekleştirilmiştir. Çocuk sağlığı ve hastalıkları kliniğinden dermatoloji kliniğine yapılmakta olan konsültasyon işlemlerinin hasta verileri retrospesifik bir biçimde taranmıştır. Yalnızca verilerinde eksiklik olmayan hastalar araştırmaya dahil edilmiştir. Yapılan değerlendirmede toplam 500 hastanın verisi kullanılmıştır. Bu hastalardan 274'ü erkek, 226'sı kadındır. Bu çalışmanın sonucunda jeneralize döküntüyle seyretmekte olan hastalıklar ve egzamaların tanısı ve tedavisinde bilgi düzeyi artışı tespit edilmiştir.

2015 yılında Özkaya ve diğerleri yapmış oldukları çalışmada dermoskop kullanımı üzerine yoğunlaşmışlardır. Bu çalışmanın amacı; deri lezyonlarının değerlendirilmesinde klinik ön tanı düzeyini arttırmaktır. Çalışma kapsamında yapılmakta olan analizler 116'sı kadın ve 68'i erkek olmak üzere 184 hasta kişi üzerinde gerçekleştirilmiştir. Bu hastalardan elde edilen 300 eksizyon materyalinin tanıları birbirleriyle karşılaştırılmıştır. Çalışma sonucunda dermoskopi melanostik lezyonlarda daha yüksek düzeyde başarı sağlanmakta olduğu tespit edilmiş olup; tanı koyma aşamasının çok kritik bir öneme sahip olduğu vurgusu yapılmıştır.

2017 yılında İnık ve Ülker tarafından yapılmış olan çalışmada derin öğrenme modelleri üzerinde durulmuştur. Çalışmanın amacı klasik makine öğrenme yöntemlerinin yerine daha modern yöntemlerin kullanımının yaygınlaştırılmasını sağlamaktır. Bu doğrultuda uygulaması kolay ve maliyeti düşük olan derin öğrenme modellerinin açıklaması yapılmıştır. Çalışmanın sonucunda AlexNet, GoogleNet, ZFNet gibi mimarilerin kullanımının yaygınlaştırılması gerektiği yönünde fikir beyanında bulunulmuştur.

2020 yılında Aalami tarafından yapılmış olan çalışmada derin öğrenme teknikleriyle görüntülerin analizinin gerçekleştirilmesi hususuna önem verilmiştir. Bu çalışmanın amacı; görüntü analizlerinde son teknolojilerin kullanımına yaygınlık kazandırmaktır. Bu bağlamda hangi derin öğrenme tekniğinin görüntü analizinde daha çok etkin olduğu yönünde bir veri elde etme çabasına girilmiştir. Nitekim elde edilen bulgular neticesinde varılan sonuç; görüntü analizinde kullanılmakta olan derin öğrenme tekniklerinden en iyisinin düşük maliyetli ve kolay kullanımlı olması gerektiği yönünde ifade edilmiştir.

2021 yılında Moradi ve Amiri tarafından yapılmış olan çalışmada, bir kanser türü olan melanom üzerinde yoğunlaşmıştır. Melanom, insan cilt kanserinin en ölümcül türüdür. Ancak erken evrede teşhis konulursa tedavi edilebilir. Son zamanlarda, bilgisayar

destekli tanı (CAD) sistemleri çok ilgi görmektedir. Segmentasyon, bir CAD sisteminin çok önemli bir adımıdır. Renk, şekil, boyut ve görünüm açısından yüksek benzerliklere sahip farklı cilt lezyonları türleri vardır. Mevcut çalışmaların çoğu ikili bir segmentasyona odaklanmaktadır. Çok çeşitli cilt lezyonları ve farklı lezyon türleri arasındaki yüksek benzerlikler nedeniyle, çok sınıflı segmentasyon hala zorlu bir iştir. Bu çalışmada dermoskopik görüntülerin çok sınıflı bölütlenmesi için ortak öğrenmeye dayalı bir yöntem önerilmektedir. Buradaki ana düşünce; daha bilgilendirici bir yapı oluşturmak için farklı özellik alanlarından gelen verileri birleştirmeye dayanmaktadır. Eğitim verileri iki farklı alandan alınmaktadır. Nihai segmentasyon, hem lezyonların topolojik bilgisine hem de öğrenilen verilere dayanan bir grafik kesme yöntemiyle gerçekleştirilmektedir. Üç lezyon sınıfını segmentlere ayırmak için ISIC 2107 veri setinde önerilen yöntem değerlendirilmeye tabi tutulmaktadır. Dermoskopik görüntülerin çok sınıflı segmentasyonu için mevcut olan tek yöntemle karşılaştırıldığında, özellikle zorlu cilt lezyonları elde etmek için olan yöntem ortaya çıkmaktadır. Ayrıca ikili segmentasyon ve lezyon teşhisi için önerilen yöntemin performansını değerlendirilmektedir ve sonuçları diğer son teknoloji yöntemlerle karşılaştırılmaktadır. Deneysel sonuçlar, önerilen yöntemin sınırlı miktarda eğitim verisi kullanarak bile klinik uygulamalar için daha güvenilir sonuçlar üretmedeki etkililiğini ve verimliliğini göstermektedir.

2021 yılında Masterton ve diğerleri tarafından yapılmakta olan çalışma kapsamında operasyon notları üzerinde durulmuştur. Operasyon notlarında genellikle eksiklikler vardır ve Royal College of Surgeons (RCS)'ün operasyon notlarına nelerin dahil edilmesi gerektiğini açıklayan açık yönlendirmesine rağmen hasta notlarında bulmak zordur. Prosedüre özgü proformalar, diğer uzmanlıklar tarafından kullanılmasına rağmen, Plastik cerrahlar tarafından nadiren kullanılmaktadır. Deri malignitelerinin insidansındaki endişe verici artışla birlikte, eksizyon için Plastik cerrahlara sevk edilen deri lezyonlarının sayısında bir artış olmuştur. Cilt lezyonu eksizyonu için güvenilir, tekrarlanabilir, doğru ve kolay erişilebilir çalışma notlarına duyulan ihtiyaç, bakım ve tedavi planlamasının sürekliliği için çok önemlidir. Bu çalışma, RCS tavsiyeleriyle ilgili olarak prosedüre özel bir proforma uygulanmadan önce ve sonra cilt lezyonu operasyon notlarının kalitesini karşılaştırmayı amaçlamıştır. Deri lezyonu prosedürüne özgü proforma uygulandıktan sonra, RCS tavsiyelerine ortalama uyum geriye dönük olarak

%87,5'ten ileriye dönük olarak %98,8'e doğru önemli ölçüde artış göstermiştir (p değeri 0.0414). Değerlendirilen 14 parametrenin 6'sında kılavuzlara uyum açısından önemli gelişmeler olduğu gösterilmiştir. Sonuç itibarıyla; deri lezyonu prosedürüne özgü bir proformanın geliştirilmesi ve uygulanması, bir plastik cerrahi departmanındaki operasyon notlarının kalitesinde, ihmalleri en aza indirme ve cerrahi hasta bakımının sürekliliğini iyileştirme potansiyeline sahip önemli bir gelişme göstermiştir.

2020 yılında Hasan ve diğerleri tarafından gerçekleştirilmiş olan araştırmada deri lezyonlarının otomatik segmentasyonu üzerinde durulmuştur. Deri lezyonlarının otomatik segmentasyonu, melanom tespiti için Bilgisayar Destekli Tanı (CAD) sistemlerinde çok önemli bir adım olarak kabul edilir. Öneme rağmen, cilt lezyonu segmentasyonu, renk, doku ve şekillerdeki değişkenlikleri ve ayırt edilemez sınırları nedeniyle çözülmemiş bir sorun olmaya devam etmektedir. Cilt lezyonu segmentasyonu ağı, makalede tartışılan diğer yöntemlerden daha iyi performans gösterir ve melanom tespitinde daha iyi performansa yol açabilecek iki farklı test veri setinde daha iyi segmentlere ayrılmış maskeler sağlayabilir. Kaynak kodu ve tahmini maskelerle birlikte eğitilmiş olarak ortaya çıkarılmış olan model herkese açık hale getirilmiştir.

2020 yılında Xie ve diğerleri tarafından yapılmış olan çalışmada deri lezyonu segmentasyonu üzerinde durulmuştur. Deri lezyonu segmentasyonu, dermoskopi görüntülerinin bilgisayar destekli teşhisinde önemli ancak zorlu bir görevdir. Evrişimli sinir ağlarına dayanan birçok bölütleme yöntemi, haritalar ağ katmanları boyunca işlenirken özellik haritalarının uzamsal boyutu azaldığından, genellikle doğru lezyon sınırlarını çıkarmakta başarısız olmaktadır. Kenar ayrıntılarını koruyabilen bir dikkat mekanizmasına sahip evrişimli bir sinir ağına dayalı dermoskopi görüntülerinde cilt lezyonu segmentasyonu önerilmektedir. Yüksek çözünürlüklü öznetelik bloklarıyla donatılmış önerilen ağ, öznetelik çıkarımı sırasında uzamsal ayrıntıları korur ve dikkat mekanizması, gürültüyü bastırırken temsili öznetelikleri geliştirir. Bu nedenle önerilen yaklaşım, yüksek performanslı cilt lezyonu segmentasyonu sağlamaktadır.

2019 yılında Chatterjee ve diğerleri tarafından yapılmış olan araştırmada, dermoskopik görüntülerden hem melanositik hem de epidermal lezyon kategorilerinin iyi huylu ve kötü huylu cilt hastalıklarının özellik çıkarımı ve ardından sınıflandırması için sistematik bir yaklaşım önerilmektedir. Bu amaçla melanom ve nevüs melanositik deri

lezyonu kategorisinin temsilcileri olarak kabul edilirken, epidermal lezyon kategorisine bazal hücreli karsinom (BCC) ve seboreik keratoz (SK'ler) dahildir. Mevcut çalışma, çapraz korelasyon tekniğini kullanarak uygun çekirdek yamaları ile benzer görsel etkiler temelinde cilt lezyonlarının göze çarpan bölgelerinden uzaysal ve spektral özelliklerin çıkarılmasını açıklamaktadır. Dermoskopik özelliklere bağlı olarak, çekirdek yamaları, bu çalışma için seçilen tüm cilt hastalığı kategorilerini içeren bir dizi dermoskopik görüntüden seçilmiştir. Malign ve iyi huylu melanositik ve epidermal cilt lezyonlarının alt sınıf sınıflandırmalarıyla birlikte ayrılması için çok etiketli bir topluluk çok sınıflı cilt lezyonu sınıflandırma stratejisi tanıtımı gerçekleştirilmiştir. Hassasiyetleri sırasıyla %98.76, %99.01, %98.87 ve %99.41 olan melanom, nevüs, BCC ve SK hastalık sınıflarının hem malign hem de iyi huylu lezyonlarını belirlemek mümkün olmuştur.

2020 yılında Valle ve diğerleri tarafından yapılmış olan çalışmada derin öğrenme yöntemleri üzerinde durulmuştur. Derin öğrenme, son iki yılda otomatik cilt lezyonu analizinde bir sıçramayı teşvik etmiştir. Ancak bu modellerin eğitilmesi pahalıdır ve parametrelendirilmesi zordur. Amaç: Deri lezyonu analizi için derin öğrenme modellerini tasarlamak ve değerlendirmek için metodolojik konuların araştırılmasıdır. Araştırmacıların karşılaştığı on seçenek incelenmektedir. Bu seçenekler; transfer öğrenimi kullanımı, model mimarisi, tren veri kümesi, görüntü çözünürlüğü, veri büyütme türü, girdi normalleştirme, segmentasyon kullanımı, eğitim süresi, Destek Vektör Makinelerinin ek kullanımı ve test verisi büyütme olarak sıralanabilmektedir. Sonuç itibarıyla otomatik cilt lezyonu analizine yönelik araştırmaların ilerletilmesi, daha geniş halka açık veri kümelerinin küratörlüğünü gerektirir. Modelleri tasarlamak için test setinden alınan ayrıcalıklı bilgilerin dolaylı kullanımı, aşırı iyimser sonuçlara yol açan incelikli, ancak sık sık yapılan bir metodolojik hatadır. Model toplulukları, pahalı tam faktöriyel ve kararsız sıralı tasarımlara uygun maliyetli bir alternatiftir.

2020 yılında Hawas ve diğerleri tarafından yapılmakta olan çalışmada otomatik cilt lezyonu üzerinde durulmuştur. Otomatik cilt lezyonu segmentasyonu, dermoskopik görüntülere dayalı tanıda en önemli aşamalardan biridir. Etkin denetimsiz kümeleme tabanlı bölümlmeyi garanti etmek için, karşılık gelen merkezleriyle ilk küme sayısını elde etmek için bir histogram tabanlı kümeleme tahmini (HBCE) algoritması kullanılabilir. Buna göre, mevcut çalışma, nötrozofik grafik kesme algoritması (OCE-NGC) için optimize edilmiş kümeleme tahmini olarak adlandırılan yeni bir cilt

lezyonu segmentasyon algoritmasını tanıtmıştır. İlk olarak, genetik algoritma (GA), optimize edilecek β olarak adlandırılan bir faktörün fonksiyonları olan optimal eşik değerlerini bularak HBCE prosedürünü optimize etmek için kullanılır. Bu optimizasyon işlemi, önerilen kümeleme işleminde daha fazla kullanım için ilk küme sayısının ve bunlara karşılık gelen merkez noktalarının optimal olarak belirlenmesini garanti etmektedir. Böylece, deri lezyonu dermoskopik görüntüleri daha sonra nötrozofik c-ortalamar (NCM) tarafından hesaplanan nötrozofik küme (NS) alanına eşlenir. NCM, optimize edilmiş HBCE tarafından elde edilen önceden belirlenmiş optimal küme sayısını kullanarak dermoskopik görüntülerdeki pikselleri gruplandırır. Son olarak, segmentasyon işlemi için NS alanında grafik kesme (GC) algoritmasının bir maliyet fonksiyonu tanımlanır. Deneysel sonuçlar, önerilen OCE-NGC yaklaşımının, yalnızca NCM'li geleneksel HBCE, NGC'li geleneksel HBCE ve tipik GC ile karşılaştırıldığında üstünlüğünü ortaya koymaktadır. Herkese açık bir veri setinde, önerilen yaklaşım sırasıyla %97,12 ve %86,28 ortalama doğruluk ve ortalama Jaccard (JAC) değerlerine ulaşım sağlanmıştır.

2021 yılında Li ve diğerlerinin birlikte yürütmüş oldukları çalışmalarda dermoskopik görüntülerde tıkanıklık hususuna değinmişlerdir. Dermoskopik görüntülerde kıl nedeniyle oluşan tıkanıklık, tanısal işlemi ve cilt lezyonu analizinin doğruluğunu etkilemektedir. Ayrıca dermis kılı farklı özelliklere sahiptir. Bunlar, saç segmentasyonu ve saç boşluğu iç boyamayı içeren dijital epilasyonu (DHR) zorlu bir görev haline getirir. Bu nedenle, geleneksel sabit kodlu eşik tabanlı epilasyon yöntemleri etkili değildir, bu da cilt lezyonunun önemli bilgilerini kaybeden aşırı çıkarma veya tüyleri etkili bir şekilde çıkaramayan eksik çıkarma ile sonuçlanır. Bu yazıda, U-Net ve serbest biçimli bir görüntü içi boyama mimarisine dayalı DHR'ye derin bir öğrenme yaklaşımı önerilmektedir. Saç segmentasyonunda, doğru saç maskeleri elde etmek için U-Net'i eğitmek adına iyi etiketlenmiş bir veri seti oluşturulmakta ve kullanılmaktadır. İç boyamada, herhangi bir saç boşluğunu boyamak için milyonlarca görüntü üzerinde eğitilmiş serbest biçimli bir görüntü içi boyama mimarisi (yani Geçitli evrişim ve SN-PatchGAN) kullanılmaktadır. Ayrıca, yapısal benzerlik (Intra-SSIM) adı verilen tek bir dermoskopik görüntüye dayalı epilasyonun etkisini analiz etmek için bir değerlendirme yöntemi önerilmektedir. DHR işlemi, Intra-SSIM'in ortalama değerinde bir değişiklik kalmayana kadar tekrarlanmaktadır. Sonuç itibarıyla ISIC 2018 veri seti kullanılarak

önerilen yöntemin performansının diğer son teknoloji yöntemlerden daha iyi olduğu gösterilmiştir.

2021 yılında Jin ve diğerleri birlikte yürütmüş oldukları bu çalışmada cilt lezyonlarının doğru teşhisi ve segmentasyonu üzerine analizler gerçekleştirmiştir. Cilt lezyonunun doğru teşhisi ve segmentasyonu, cilt kanserinin erken tespiti ve teşhisi için kritik öneme sahiptir. Son zamanlardaki çok görevli öğrenme yöntemleri, cilt lezyonu analizi için pahalı açıklamalar gerektirirken, tek görevli modeller potansiyel bilgiyi tam olarak kullanamamaktadır. Bu çalışmanın amacı, esnek bir mimari ile ihmal edilen bilgileri dermoskopi cilt lezyonlarının sınıflandırılması ve bölütlenmesinde kullanmaktır. Bu çalışmada, sınıflandırma ve segmentasyon performanslarını aynı anda artırmak için farklı görevlerden öğrenilen bilgileri aktarmak ve toplamak için kademeli bir bilgi yayma ağı (CKDNet) önerilmektedir. CKDNet, bir dizi kaba seviye segmentasyon, sınıflandırma ve ince seviye segmentasyon ağlarından oluşur. Sınıflandırma ve segmentasyon için iki yeni özellik dolaştırma modülü, Entangle-Cls ve Entangle-Seg tasarlanmaktadır. Entangle-Cls modülü, sınıflandırma ağının dikkatini hastalıkla ilgili görüntü bölgelerine yönlendirmek için ilk segmentasyondan yayılan özellikleri toplar. Entangle-Seg modülü, özellikle belirsiz sınırlarda ince seviyeli segmentasyondan faydalanmak için sınıflandırmadan öğrenilen kademeli bağlam bilgisini bütünleştirir. Dolaşıklık modülleri, bir görevden diğerine dağıtılabilen bilgiyi uyarlanabilir bir şekilde kontrol edebilir, bu da diğer çoklu görev yöntemlerine kıyasla farklı öğrenme görevleri için ampirik ağırlık seçimini önler. ISIC2017 ve ISIC2018 gibi zorlu veri setleri ile cilt lezyonu sınıflandırması ve segmentasyonu üzerinde en son teknolojiye sahip yöntemlerle kapsamlı değerlendirmeler ve karşılaştırmalar yapılmaktadır. CKDNet'in, herhangi bir topluluk yaklaşımı veya herhangi bir harici veri seti kullanmadan üstün performans gösterdiği görülmektedir. Her bir bileşenin ve kayıp fonksiyonlarının etkinliği, sınıf aktivasyon haritaları (CAM), t-SNE ve sınıflandırma ve segmentasyon sonuçları kullanılarak yorumlanabilir sonuçlarla gösterilir.

2021 yılında Koskiger ve diğerleri tarafından yapılmış olan araştırmada dermoskopik görüntülerin bilgisayar tabanlı teşhisi ele alınmıştır. Dermoskopi görüntülerinin bilgisayar destekli teşhisinde cilt lezyonlarının bölütlenmesi kritik fakat zor bir süreçtir. Birçok segmentasyon yöntemi, ön işleme adımlarının eksikliği veya doğru sırada olmayan çok az sayıda ön işleme adımı nedeniyle doğru lezyon sınırlarını

çıkaramamaktadır. Bu makale, Çok seviyeli ön işleme adımlarının önemini ve lezyon görüntülerinin SegCaps segmentasyonundan önceki uygun sırasını göstermektedir. Çalışma kapsamında, cilt lezyonu görüntülerinin segmentasyonundan önce dört ön işleme adımı planlanmış olup, ilk sırada renk tutarlılığını elde etmek için 2. derece gri kenar algoritması kullanılmıştır. Epilasyon işleminde ikinci işlem iki alt işlemden oluşur. Başlamak için saç piksel seviyesine uyarlanabilen Prewitt filtresi kullanılmaktadır. Aşağıdaki prosedür, anizotropik Hızlı Yürütme Metodu kullanılarak gerçekleştirilen Onarım İşlemidir. Üçüncü işlem, en iyi medyan değeri belirlemek için Sıralanmış Çeyrek Medyan Vektörünü (SQMV) kullanan İyileştirilmiş Anahtarlamalı İki Taraflı Filtre (ISBF) ile bir gürültü filtrelemedir ve son işlemde, kenar iyileştirmeyi gerçekleştirmek için Yönlendirilmiş Kenar İyileştirici algoritması kullanılmaktadır. Önerilen model, HAM10000 veri seti kullanılarak MatlabR2017b üzerinde test edilmiştir. Önerilen yöntemin çıktısı, ön işlemeli ve ön işlemesiz bölütleme efektlerinin yanı sıra giriş görüntülerinden önceden işlenmiş görüntülerin görsel görünümü karşılaştırılarak değerlendirilir. Sonuçlardan, ön işleme adımları doğru sırada kullanıldığında, ön işleme adımları olmadan segmentasyona kıyasla segmentasyon doğruluğunun çok yüksek olduğu sonucuna varılmıştır.

2021 yılında Abdelhalim ve diğerleri birlikte yürütmekte oldukları çalışmada manuel teşhis yöntemleri ile bilgisayar destekli teşhis yöntemleri arasındaki ilişki incelenmiştir. Son yıllarda otomatik cilt lezyonu tespit sistemlerinde derin öğrenme yöntemlerinin dikkate değer başarısına tanık olunsa da, uzmanların manuel olarak değerlendirilmesi ile bilgisayarların otomatik olarak değerlendirilmesi arasında hala bir boşluk bulunmaktadır. Böyle bir boşluğun arkasındaki neden, derin öğrenme modellerinin önemli miktarda veri gerektirmesi ve açıklamalı görüntülerin kullanılabilirliğinin genellikle sınırlı olmasıdır. Veri Artırma (DA), etiketli veri eksikliğini azaltmanın bir yoludur; bununla birlikte, artırılmış görüntüler özünde orijinal olanlara benzer bir dağılıma sahiptir ve bu da sınırlı performans artışına yol açmaktadır. Gerçek görüntü dağılımındaki veri eksikliğini gidermek için, Generative Adversarial Networks (GAN'ler) kullanarak gerçekçi ancak orijinallerinden tamamen farklı cilt lezyonu görüntülerini sentezlenebilmektedir. Bu yazıda, geleneksel GAN'lar aracılığıyla zorlu olan Evrişimsel Sinir Ağı tabanlı melanom tespiti için ince taneli 256×256 cilt lezyonu görüntüleri oluşturmak üzere GAN'ların Kendi Kendine İlerleyen Büyümesi

(SPGGAN'ler) önerilmektedir. Yüksek çözünürlüklü kararsız GAN eğitimi ve boyut, şekil ve konumdaki çeşitli cilt lezyonları nedeniyle zorluklar ortaya çıkarmaktadır. SPGGAN'da, tüm özellik konumlarından toplanan bilgiler kullanılarak ayrıntılar oluşturulabilir. Ayrıca, ayırıcı, görüntünün uzak kısımlarındaki son derece ayrıntılı özelliklerin birbiriyle tutarlı olup olmadığını izleyebilir. Bunun yanı sıra, 256×256 cilt lezyonu görüntüsü oluştururken stabiliteyi artırmak için SPGGAN'a (SPGGAN-TTUR) İki Zaman Ölçekli Güncelleme Kuralı (TTUR) uygulanır. SPGGAN-TTUR, HAM10000 veri kümesi kullanılarak veri oluşturma ve sınıflandırma görevlerinde değerlendirilir. Bu çalışmanın sonucunda, cilt lezyonu sınıflandırıcılarını eğitmek için önerilen GAN tabanlı DA yaklaşımımızın önemini doğrulamaktadır ve klasik ile artırılmamış ve artırılmış olana göre duyarlılıkta (hatırlama) istatistiksel olarak anlamlı gelişmelere (p değeri <0.05) yol açabileceğini göstermektedir. Genel olarak, tüm sınıflar söz konusu olduğunda, duyarlılık iyileştirmeleri, artırılmamış ve artırılmış (en iyi DA şemasıyla) muadillerine göre sırasıyla %5,6 ve %2,5 olmuştur. Spesifik olarak, melanom sınıfı durumunda, duyarlılık iyileştirmeleri %13,8 ve %8,6 olmuştur. Önerilen yaklaşımın, dermoskopik görüntülerde otomatik cilt lezyonu saptama duyarlılığını geliştirmek için klinik uygulamada benimsenebileceğine ve böylece dermatologların melanom tanısını iyileştirme çabalarını destekleyebileceğine inanılmaktadır.

2021 yılında Marosan ve diğerleri yapmış oldukları çalışmada kanser riski taşımakta olan cilt lezyonları üzerinde incelemelerde bulunmuşlardır. Ultrason kullanılarak kanserden şüphelenilen cilt lezyonlarının segmentasyonu, ayırıcı tanı ve tedavi planlamasına yardımcı olabilmektedir. Aktif kontur modelleri (ACM), manuel olarak seçildiğinde segmentasyon doğruluğunda değişikliklere neden olabilecek bir ilk tohum gerektirir. Tam otomatik cilt segmentasyonu, tipik olarak, yöntemlerin bir kombinasyonunu kullanarak katman katman segmentasyonu kullanmaktadır. Fakat bu tür segmentasyon kanserli lezyonlar üzerinde henüz uygulanmamıştır. Mevcut çalışmada, tam otomatik segmentasyon iki adımda gerçekleştirilmektedir. Bu adımlar; katman katman yöntemini kullanan otomatik tohumlama (AS) adımı ve ardından ACM kullanılarak gerçekleştirilmekte olan büyütme adımıdır. Yöntem, iki ultrason görüntüleme sisteminden ($N=60$) alınan nevüs, melanom ve bazal hücreli karsinom görüntülerinde test edilmiştir ve tüm lezyonlar başarılı bir şekilde yerleştirilmiştir. Tohumlama adımı için referans olarak manuel tohumlama (MS) kullanılmıştır. AS,

MS'nin temel gerçeğe dayalı optimal bir sınırlayıcı dikdörtgen kullandığında MS'nin doğruluğuna yaklaşmıştır (sırasıyla 72.3'e karşı 74.6'lık Sørensen-Dice katsayısı (SDC)). Aynı zamanda manuel tohumun değiştirilmesinin etkisi de araştırılmış; tohum yüksekliğinde ve genişliğinde 0,7'lik bir azalma, 54.6'lık bir ortalama SDC'ye neden olduğu görülmüştür. Sonuçlar, cilt lezyonu segmentasyonu için otomatik tohumlamanın sağlamlığını göstermektedir.

2020 yılında Mahbod ve diğerleri birlikte yapmış oldukları çalışmada Malign melanom üzerinde durmuşlardır. Malign melanom (MM), en ölümcül cilt kanseri türlerinden biridir. Dermatoskopik görüntülerin analiz edilmesi, MM ve diğer pigmente cilt lezyonlarının erken tespitinde önemli bir rol oynamaktadır. Farklı bilgisayar tabanlı yöntemler arasında, derin öğrenme tabanlı yaklaşımlar ve özellikle evrişimli sinir ağları, dermatoskopik cilt lezyonu görüntüleri için mükemmel sınıflandırma ve segmentasyon performansları göstermiştir. Bu modeller, herhangi bir el yapımı özellik gerektirmeden uçtan uca eğitilebilmektedir. Ancak, lezyon segmentasyon bilgisinin kullanılmasının sınıflandırma performansı üzerindeki etkisi açık bir soru olarak kalmıştır. Bu çalışmada, deri lezyonu bölütleme maskeleri kullanmanın dermatoskopik görüntü sınıflandırma performansı üzerindeki etkisi açıkça araştırılmıştır. Bunu yapmak için önce, herhangi bir segmentasyon maskesi kullanmadan referans model olarak bir temel sınıflandırıcı geliştirilmiştir. Daha sonra hem eğitim hem de test aşamalarında manuel veya otomatik olarak oluşturulan segmentasyon maskeleri farklı senaryolarda kullanılmıştır ve sınıflandırma performansları incelenmiştir. Farklı senaryolar, cilt lezyonu görüntülerini kırpma veya çevreleyen arka planı kaldırmak için veya segmentasyon maskelerini model eğitimi için ek bir giriş kanalı olarak kullanmak adına segmentasyon maskelerinden yararlanan yaklaşımları içermektedir. Sonun olarak bahsi geçmekte olan görüntü segmentasyonunu kullanmanın dermatoskopik cilt lezyonu sınıflandırmasının performansı üzerindeki etkileri sistematik olarak ortaya çıkarılmıştır.

2021 yılında Iqbal ve diğerleri tarafından yapılmış olan çalışmada derin öğrenme ve hastalık teşhisleri arasındaki ilişki üzerinden yola çıkılarak bir araştırma yapılmıştır. Tıpta analitik bir araç olarak derin öğrenme büyük ilgi görmüştür ve hastalık teşhisi için yeni yollar açmıştır. Son çalışmalar, deri lezyonlarının (yani melanomlar ve nevüs sınıfları) dermoskopik görüntülerle ikili sınıflandırması için derin öğrenme algoritmalarının etkinliğini doğrulamaktadır. Bununla birlikte, bu ikili sınıflandırma

yöntemleri, çok sınıflı sınıflandırmanın dikkate alınması gereken cilt kanseri taramasının genel klinik durumuna uygulanamamaktadır. Bu araştırmanın temel amacı, cilt lezyonlarının otomatik çok sınıflı sınıflandırması bağlamında gelişmiş bir derin öğrenme modeli geliştirmek, uygulamak ve kalibre etmektir. Önerilen Derin Evrişimli Sinir Ağı (DCNN) modeli, birkaç katman ve birden çok filtre boyutuyla, ancak etkinlik ve performansı artırmak için daha az filtre ve parametreyle dikkatlice tasarlanmıştır. Dermoskopik görüntüler, deneyler için International Skin Imaging Collaboration veri tabanlarından (ISIC-17, ISIC-18 ve ISIC-19) elde edilmiştir. Önerilen DCNN yaklaşımının deneysel sonuçları kesinlik, duyarlılık, özgüllük ve diğer metrikler açısından sunulmaktadır. Özellikle ISIC-17'de %94 kesinlik, %93 duyarlılık ve %91 özgüllük elde edilmektedir. Deneysel sonuçlarla, önerilen bu DCNN yaklaşımının, cilt lezyonlarının sınıflandırılması için ISIC-17'de alıcı işletim özellikleri (AUROC) altında 0,964 alan sergileyerek en gelişmiş algoritmalarından daha iyi performans gösterdiği ve dermatologlara yardımcı olmak için kullanılabileceği gösterilmiştir. Cilt lezyonlarının sınıflandırılmasında sonuç olarak, önerilen bu yaklaşım, cilt lezyonu sınıflandırma görevini otomatikleştirmek ve hızlandırmak için yeni ve uygulanabilir bir yol sağlarken, emekten, zamandan ve insan hayatından tasarruf sağlanmasına katkı sunmaktadır.

2020 yılında Jafry ve diğerleri birlikte yapmış oldukları çalışmada melanom için olan tedavi kılavuzları incelenmiştir. Melanom in situ ve invaziv melanom için tedavi kılavuzları mevcut olmasına rağmen, diğer melanositik deri lezyonları için kılavuzlar mevcut değildir. Patologlar (N = 187) bir anketi tamamlamış ve ardından 240 melanositik deri lezyonu için teşhis ve tedavi önerileri sunmuştur. Tedavi önerileri ile ilişkili hekim özellikleri çok değişkenli modelleme ile değerlendirilmiştir. Tedavi önerileri, melanom in situ (%73) ve invaziv melanom (%86) olarak yorumlanan vakaların çoğu için Ulusal Kapsamlı Kanser Ağı kılavuzlarıyla uyumlu olmuştur. Mevcut tedavi kılavuzları olmayan diğer lezyon tipleri için tedavi önerilerinin daha fazla değişken olduğu görülmüştür. Ulusal Kapsamlı Kanser Ağı kılavuzlarına uygun olmayan tedavi önerilerinin sağlanmasıyla ilişkili özellikler, düşük vaka yükleri (invaziv melanom), burs eğitimi veya kurul sertifikası eksikliği (melanom in situ) ve 10 yıldan fazla deneyim (invaziv melanom ve melanoma in situ) olarak ifade edilmiştir. Patologların tedavi önerileri, melanositik lezyonlar için önemli ölçüde farklılık gösterir ve lezyon tipleri için ulusal kılavuzlara göre daha düşük değişkenlik vardır. Sonuçlar,

tüm melanositik lezyon tipleri için tedavi kılavuzlarının standardizasyonuna ihtiyaç olduğunu göstermektedir.

2021 yılında Voss ve diğerleri birlikte yürütmüş oldukları çalışmada atopik dermatit üzerinde yoğunlaştığı görülmektedir. Atopik dermatit (AD), dünya çapında çocukların yaklaşık %20'sini ve yetişkinlerin %3'ünü etkileyen ve genellikle istenmeyen yan etkileri olan steroid ilaların topikal uygulamasıyla tedavi edilen ok faktörlü kronik inflamatuvar bir hastalıktır. Alternatif tedavilerin geliştirilmesi bu nedenle önemli bir hedeftir. Bu alışmada, bir AD fare modelinde yeni bir suda özünür selenyum içeren karbonhidrat türevi (4-anhidro-4-seleno-D-tatitol, SeTal) ile topikal tedavinin semptomlar ve inflamatuvar parametreler üzerindeki etkileri araştırılmıştır. Fareler, 1-3. günlerde sırt derilerine 2,4-dinitroklorobenzen (DNCB) uygulanarak duyarlı hale getirilmiştir. Ardından 14, 17, 20, 23, 26 ve 29. günlerde kulaklarına ve sırt derisine daha fazla tehdit uygulanmıştır. SeTal (1 ve %2) veya hidrokortizon (%1) 14-29. günlerden itibaren farelerin sırtlarına topikal olarak uygulanmıştır ve cilt şiddeti skorları ve kaşınma davranışı 30. günde belirlenmiştir. Farelere ötenazi uygulanmıştır ve kulakları ve sırt derileri çıkarılmıştır. İnflamatuvar parametreleri, ödemi, miyeloperoksidaz (MPO) aktivitesini ve AD ile ilişkili sitokinleri (tümör nekroz faktörü alfa (TNF- α), interlökinler (IL)-18 ve IL-33) ölçülmüştür. DNBCB tedavisi cilt lezyonlarına neden olmuştur ve sırt derisinde kaşınma davranışı, kulak ödemi, MPO aktivitesi (kulak ve sırt derisi) ve sitokin düzeyleri artmıştır. SeTal'in topikal uygulaması, inflamatuvar belirteleri (sitokin seviyeleri ve MPO aktivitesi), kutanöz şiddet skorlarını ve kaşınma davranışını iyileştirmiştir. SeTal'in etkinliği, analiz edilen parametrelerde tatmin edici düzeydedir ve hidrokortizondan benzer veya daha iyi sonuçlar göstermiştir. SeTal, AD'nin tedavisi ve kontrolü için terapötik açıdan avantajlı görünmektedir.

2021 yılında Shahsavari ve diğerleri yapmış oldukları çalışmada kanser türlerinden cilt kanseri üzerinde durulmuştur. Cilt kanseri dünya çapında en kötü huylu kanserlerden biridir. Erken teşhis, hastaların tedavisinde önemli bir rol oynamaktadır. Cilt kanseri tanısını kolaylaştırmak için cilt lezyonu görüntülerinin kalitesi büyük önem taşımaktadır. Deri lezyonu görüntülerini almak için en yaygın teknolojilerden biri dermoskopi cihazıdır. Ancak, tüm insanlar için erişilebilir değildir. Görüntüleri mobil cihazlar gibi diğer teknolojiler aracılığıyla yakalamak, kalitesiz olmasına rağmen her

yerde mevcuttur. Bu yazıda, düşük çözünürlüklü eşdeğerleri kullanarak süper çözünürlüklü cilt lezyonu görüntülerini yeniden oluşturmak için yeni bir Cascade Ensemble Süper Çözünürlüklü Üretken Düşman Ağı (CESR-GAN) yöntemi önerilmiştir. Spesifik olarak, mümkün olduğunca fazla ayrıntı elde etmek ve daha yüksek kaliteli görüntüler oluşturmak için yeni bir özellik tabanlı ölçüm kaybı işlevi tasarlanmıştır. CESR-GAN modelimiz ve diğer son teknoloji yöntemler arasındaki nicel ve nitel karşılaştırmalardan elde edilen deneysel sonuçlar, önerilen yöntemimizin sırasıyla ISIC ve PH2 veri kümelerinde karşılaştırılan yöntemlerden daha iyi performans gösterdiğini göstermektedir. CESR-GANs yöntemi, oldukça dikkate değer performanslara sahip cilt lezyonlarının süper çözünürlüklü cilt görüntülerini oluşturmak için kullanılabilir.

2020 yılında Ghaleejoogh ve diğerleri birlikte yürütmüş oldukları çalışmada malign melanom cilt kanseri üzerinde durulmuştur. Son yıllarda otomatik sistemler, cilt kanseri tanı oranını artırmada çok önemli bir rol oynamıştır. Bu makalenin temel amacı, sınıflandırma aşamasında sınıflandırıcıları birleştirmek için yeni bir yaklaşım getirerek bir cilt kanseri otomatik teşhis sisteminin performansını artırmaktır. Bu nedenle, deri lezyonu sınıflandırması için Meta Learning algoritmasına dayalı Stacking Ensemble Metodu önerilmiştir. Deri lezyonlarını melanom, displastik ve iyi huylu olarak sınıflandırmak için, heterojen sınıflandırıcıları birleştirmek için İstiflemeye Dayalı Yapı (SBS) ve İstiflemeye Dayalı Hiyerarşik Yapı (HSBS) olmak üzere iki yeni hibrit yaklaşım tanıtılmıştır. Deri lezyonları sınıflandırması için önerilen yöntemler, Beş Katlı Çapraz Doğrulama prosedürü ve seçilen özelliklerin farklı sayıları kullanılarak iki PH2 ve Ganster veri setinin dermoskopik görüntülerine dayalı olarak uygulanmış ve değerlendirilmiştir. Sonuçlar, SBS yaklaşımının, her iki veri seti için melanom dışı lezyonlardan melanom lezyonlarını teşhis etmede iyi bir performansa sahip olduğunu gösterdi. Ayrıca sonuçlar, SBS yaklaşımına ve aynı veri seti üzerindeki diğer çalışmalara kıyasla HSBS yönteminin cilt lezyonlarını iyi huylu, displastik ve melanom olarak sınıflandırmada çok daha iyi bir performans sunduğunu göstermiştir.

2017 yılında Wei ve diğerleri yapmış oldukları çalışmada arsenik maruziyeti, arsenik metilasyonu ve deri lezyonları ve hipertansiyon prevalansı arasındaki ilişkiler araştırılmaktadır. Sonuçlar, HS (hipertansiyon ve cilt lezyonları) grubunun ve S (cilt lezyonları) grubunun daha yüksek idrar konsantrasyonlarında iAs (inorganik arsenik),

MMA (monometilarsenik asit), DMA (dimetilsinöz asit) ve %MMA ve daha düşük SMI'ye sahip olduğunu göstermektedir. H (hipertansiyon) ve N (hem hipertansiyon hem de cilt lezyonları olmadan) gruplarıyla karşılaştırıldığında; H'ye neden olan sudaki arsenik içeriği, HS ve S'ye neden olandan daha düşük olabildiği görülmektedir. Ayrıca, olasılık oranları, iAs ve MMA, %iAs, %MMA ve PMI'nin daha yüksek idrar konsantrasyonlarının yalnızca hipertansiyon ve cilt prevalansını yükselttiğini göstermektedir. Bununla birlikte, daha yüksek %DMA ve SMI ve daha düşük %MMA, sadece deri lezyonlarına kıyasla hem hipertansiyon hem de deri lezyonlarının prevalansını artırır. Deri lezyonlarının hipertansiyon prevalansının daha yüksek olduğu sonucuna varılabilir. Hipertansiyon hastalarında deri lezyonları prevalansı daha yüksek olabilmektedir. Daha düşük %DMA ve SMI, daha yüksek %iAs, %MMA ve PMI sadece hipertansiyon ve deri lezyonlarının ve hem hipertansiyon hem de deri lezyonlarının prevalansını arttırmaktadır. Ayrıca, iAs ve MMA daha yüksek toksisiteye sahip olabilir ve sadece hipertansiyondan ziyade hem hipertansiyona hem de deri lezyonlarına yol açabilir.

2020 yılında Hajabdollahi ve diğerleri yapmış oldukları çalışmada cilt anormalliği üzerinde durulmaktadır. Cilt anormalliğinin otomatik analizi, tıp uzmanları için teşhis prosedürlerini kolaylaştırmanın ve yeteneklerini geliştirmenin etkili bir yoludur. Konvolüsyonel sinir ağları (CNN'ler) gibi cilt anormalliklerinin analizi için etkili ve doğru yöntemler tipik olarak karmaşıktır. Bu nedenle, bu tür karmaşık yapıların taşınabilir tıbbi cihazlarda uygulanması, güç ve kaynak sınırlamaları nedeniyle mümkün değildir. CNN'ler, cilt anormalliği görüntülerinden özellikleri otomatik olarak çıkarabilir. Ağın sadeliğine yol açabilecek özellik çıkarma yükünü azaltmak için uygun giriş renk kanalları seçilebilir. Bu yazıda, en bilgilendirici renk kanallarının seçimi ve ağın basitleştirilmesi yoluyla bu karmaşık yapıları basitleştirmek için bir budama çerçevesi önerilmiştir. Ayrıca, farklı ağların karmaşıklığını analiz etmek için farklı ağ yapılarının donanım gereksinimleri belirlenir. Hem dermoskopi hem de dermoskopi olmayan görüntülerin halka açık iki veri setinden görüntülerin bölütlenmesi için deneysel sonuçlar yapılmıştır. Simülasyon sonuçları, önerilen renk kanalı seçim yöntemini kullanarak, cilt anormalliklerinin segmentasyonu için basit ve verimli sinir ağı yapılarının uygulanabileceğini göstermektedir.

2020 yılında Chen ve diğerleri yapmış oldukları çalışmada atopik dermatit hastalığı üzerinden çeşitli analizler gerçekleştirilmiştir. Atopik dermatit (AD), derinin yaygın, tekrarlayan, inflamatuvar bir hastalıdır. T yardımcı tip 2 (Th2)-tarafı bağışıklık tepkileri ile ilişkilidir. AD tedavisi için mevcut ilaçların etkinliğine rağmen, güvenlikleri ve yan etkileri endişe yaratmaktadır. Mevcut çalışma, Nc/Nga farelerinde AD benzeri semptomların etkin bir şekilde giderilmesi için immünomodülatör etkileri olan çözünebilir poli-y-glutamat (y-PGA) mikro iğnelerinin (MN'ler) kullanımını açıklamaktadır. γ -PGA MN'ler, epidermise kolayca nüfuz edebilir ve immün yanıtları modüle etmek için dendritik hücrelerle etkileşime girmek üzere dendritik hücre açısından zengin dermise γ -PGA'yı serbest bırakabilir. Yüksek moleküler ağırlıklı (HMW, 1100 kDa) γ -PGA MN'lerin transdermal uygulaması, farelerde immünoglobulin (Ig) E ve IgG1 düzeylerini (Th2 ile ilişkili antikorlar) aşağı regüle ederek klinik dermatit skorlarını, epidermal kalınlığı ve mast hücre infiltrasyonunu önemli ölçüde azaltmıştır. Bununla birlikte, düşük moleküler ağırlıklı (200-400 kDa) γ -PGA MN'ler, AD benzeri cilt lezyonlarını HMW γ -PGA MN'lerden daha az etkili bir şekilde iyileştirilmiştir. Bu nedenle γ -PGA'nın MW'sinin immünomodülatör özelliklerini etkileyebileceğini gösterir. Özellikle, fare derisi, MN uygulamasından sonra 4 saat içinde bariyer işlevini hızla geri kazanmıştır. 8 haftalık tedavi süresi boyunca MN ile tedavi edilen farelerde kilo kaybı veya anormallik gözlenmemiştir. Bu sonuçlar, γ -PGA MN'lerin AD yönetimi için yenilikçi ve güvenilir bir terapötik stratejiyi temsil ettiğini göstermektedir.

2021 yılında Champeau ve diğerleri birlikte yürütmüş oldukları çalışmada topikal fotodinamik terapi üzerinde durmuşlardır. Topikal fotodinamik terapi (PDT), melanom dışı cilt kanserlerini tedavi etmek için yaygın olarak kullanılmaktadır. Bir ön ilaç (5-aminolevulinik asit (5-ALA) veya metil aminolevulinat (MAL)) içeren ve daha sonra ışığa duyarlılaştırıcı protoporfirin IX'a (PpIX) metabolize edilen bir kremin cilt lezyonlarına topikal olarak uygulanmasından oluşmaktadır. Oksijen ile birleştirilen PpIX uyarma dalga boyunda ışık ışıması, hücre ölümüne neden olan bir fotokimyasal reaksiyona yol açar. Bununla birlikte, bu geleneksel PDT tedavisi, ön ilacın penetrasyon derinliği sınırlı olduğundan ve derin yerleşimli lezyonlarda PpIX üretimini engellediğinden şu anda yüzeysel cilt lezyonları ile sınırlıdır. Bu sorunun üstesinden gelmek için, kare esnek bir yamaya dahil olan çözünen mikro iğneler (MN'ler)

geliştirilmiştir. Bu kullanımı kolay MN-yama, hyaluronik asit (HA) ile karıştırılmış 5-ALA'dan oluşmaktadır ve cilt uygulamasından sonra çözülme özelliğine sahiptir. Bu MN-yamasının in vivo etkinliğini değerlendirmek için, UV-B aydınlatmaları uygulanarak sıçanlar üzerinde bir cilt lezyonu modeli geliştirilmiştir. 40 UV-B aydınlatmasından sonra, histolojik ve farmakokinetik kontroller, sıçanların deri lezyonları sergilediği doğrulanmıştır. Sıçan derisi lezyon modeli doğrulandıktan sonra, MN'lerin deriye nüfuz ettiği ve sıçanların çoğunda bir saat içinde tamamen çözündüğü gösterilmiştir. Bir saat sonra, floresan görüntüleri MN-yamasının müteakip ve homojen bir PpIX seviyesi ürettiğini göstermiştir. Genel olarak, çözünen MN-yama ilginç özelliklere sahip yeni bir teknolojidir ve etkinliğini melanom dışı cilt kanserlerinin PDT'si için geleneksel tedavi ile karşılaştırmak için birkaç klinik öncesi araştırma yönlendirilmelidir.

2021 yılında Wakelin yapmış olduğu araştırmada iyi huylu cilt lezyonları üzerinde tespitler gerçekleştirmiştir. İyi huylu cilt lezyonları, dermatoloji konsültasyonunun en yaygın nedenlerinden biridir. Bebeklikten yaşamın sonlarına kadar herhangi bir yaşta doğuştan veya edinilmiş olabilirler ve köken aldıkları hücreye göre sınıflandırılabilirler. Çok sayıda histopatolojik antite mevcuttur, ancak en yaygın olanları iyi huylu melanositik nevüsler (benler), lentiginler, seboreik keratozlar, epidermoid kistler, cilt etiketleri, dermatofibromlar ve hemanjiyomları içermektedir. İyi huylu lezyonlar, şüpheli cilt kanseri kliniklerine sevk edilen hastalarda yaygındır ve malign muadillerinden sayıca fazladır. Dikkatli muayene ve bir dermoskop kullanımı çoğu durumda güvenli bir teşhise izin vererek gereksiz ameliyattan kaçınılabilir. Nadiren iyi huylu lezyonlar, iç maligniteye yatkınlık oluşturan genetik sendromlarla ilişkili olabilir.

2021 yılında Filali ve diğerleri yapmış oldukları araştırmada bir cilt kanseri türü olan melanom üzerinde yoğunlaşmışlardır. Tıbbi taramanın pahalı maliyeti nedeniyle, makroskopik görüntülerde melanomun otomatik bilgisayar destekli teşhisinin (CAD) geliştirilmesine ihtiyaç vardır. Bu sistemlerde ilk işlem adımı olarak cilt lezyonlarının segmentasyonu gerekir. Bu yazıda, grafik tabanlı bir cilt lezyonu bölütleme algoritması önerilmektedir. Çalışmaya yüzeysel bir lezyon ve arka plan şablonlarını belirlenerek başlanmıştır. Daha sonra, çeşitli özellikleri içeren hem lezyon hem de cilt ipuçlarına bölgesel benzerlikleri sıralayan bir grafikler geliştirilmiştir. Her özelliğin katkısı,

bölgesel ayırım gücüne göre kontrol edilir. Son olarak, iki sıralama işlemini birleştiren bir strateji kullanarak lezyon bölümlere ayrılmıştır. Üç zorlu veri tabanından seçilen hem melanom hem de iyi huylu lezyonlar üzerinde karşılaştırmalı bir değerlendirme yapılmıştır. Sıralama sürecimiz cilt bölgelerini baskılayabilmekte ve lezyonun tamamını etkili bir şekilde vurgulayabilmektedir. Birkaç metrik kullanan nicel değerlendirme, algoritmamızın son teknoloji on yöntemle karşılaştırıldığında sürekli olarak daha iyi segmentasyon performansı sağladığını göstermektedir. Yüksek performansı, CAD sistemlerinin bir parçası olarak pratik kullanıma uygun olduğunu göstermiştir.

2020 yılında Qin ve diğerleri tarafından yapılmış olan çalışmada bir cilt kanseri türü olan melanom üzerinde durulmuştur. Dermoskopi, melanom ve diğer cilt lezyonlarını taramak için önemli bir görüntüleme tekniğidir. Bununla birlikte, bilgisayar destekli tanı tekniklerine dayalı cilt lezyonu sınıflandırması, etiketli verilerin azlığı ve sınıf dengesiz veri kümesi nedeniyle zorlu bir iştir. Dermatologların daha doğru teşhis kararlarında yardımcı olması için cilt lezyonu sınıflandırmasına üretici hasım ağlarına (GAN) dayalı veri artırma tekniği uygulamak gereklidir. Bu makalede, cilt lezyonu sınıflandırma performansını iyileştirmek için GAN tabanlı veri artırma teknolojisini kullanma sürecinin tamamı oluşturulmuştur. Her şeyden önce, stil tabanlı GAN'ların temel mimarisine göre cilt lezyonu stil tabanlı GAN'lar önerilmektedir. Önerilen model, orijinal oluşturucudaki stil kontrolünün ve gürültü girdisinin yapısını değiştirmekte, yüksek kaliteli cilt lezyonu görüntülerini verimli bir şekilde sentezlemek için hem oluşturucuyu hem de ayırıcıyı ayarlamaktadır. Görüntü sınıflandırmasına gelince, sınıflandırıcı önceden eğitilmiş derin sinir ağı üzerinde transfer öğrenme yöntemi kullanılarak oluşturulmaktadır. Önerilen cilt lezyonu stili tabanlı GAN'lardan elde edilen sentetik görüntüler, sınıflandırıcının daha iyi sınıflandırma performansı için eğitilmesine yardımcı olmak için nihayet eğitim setine eklenir. Önerilen cilt lezyonu stiline dayalı GAN'lar, yüksek kaliteli cilt lezyonu görüntülerini verimli bir şekilde üretebilir ve bu da sınıflandırma modelinin performans iyileştirmesine yol açmaktadır. Bu çalışma, derin öğrenmeye dayalı tıbbi görüntü analizi için değerli bir referans sağlamaktadır.

2020 yılında Rodrigues ve diğerleri yapmış oldukları çalışmada melanom cilt kanseri üzerinde durulmuştur. Melanom cilt kanseri, dünyadaki en yaygın hastalıklardan biridir. Melanomu erken bir aşamada teşhis etmek önemlidir. Deri lezyonlarının tıbbi

muayenesi sırasında gözle muayene, lezyonlar arasında benzerlik olduğu için basit bir iş değildir. Ayrıca, tıbbi deneyim ve eğilim yanlış teşhislere neden olabilmektedir. Nesnelerin İnterneti (IoT) gibi teknolojiler, etkili sağlık sistemleri oluşturmaya yardımcı olmaktadır. Doktorlar, subjektif faktörlere hâlel getirmeksizin daha fazla kişiye teşhis konabileceği garantisi ile bunları her yerde kullanabilmektedirler. Transfer Öğrenme ve Derin Öğrenme, farklı hastalıkların klinik tanısında giderek daha önemli hale gelmektedir. Bu çalışma, doktorlara yaygın cilt lezyonlarının, tipik nevüslerin ve melanomun teşhisinde yardımcı olmak için bir IoT sisteminde Transfer Öğrenme ve Derin Öğrenmenin kullanımını önermektedir. Bu çalışma, kaynak çıkarıcı olarak Evrişimli Sinir Ağlarını (CNN'ler) kullanmaktadır. Kullanılan CNN modelleri şunlardır: Görsel Geometri Grubu (VGG), Başlangıç, Artık Ağlar (ResNet), Inception-ResNet, Extreme Inception (Xception), MobileNet, Yoğun Evrişim Ağı (DenseNet) ve Sinir Mimarisi Arama Ağı (NASNet). Yaralanmaların sınıflandırılması için Bayes, Support Vector Machines (SVM), Random Forest (RF), Perceptron Multilayer (MLP) ve K-Nearest Neighbors (KNN) sınıflandırıcıları kullanılmaktadır. Bu çalışmada iki veri seti kullanılmıştır: ilki Uluslararası Biyomedikal Görüntüleme Sempozyumu'nda (ISBI) Uluslararası Cilt Görüntüleme İşbirliği (ISIC) tarafından sağlanmıştır; ikincisi PH²'dir. ISBI-ISIC için, bu çalışma nevüsler ve melanomlar arasındaki lezyonları incelemiştir. PH²'de bu çalışma, yaygın nevüs, atipik nevüs ve melanom lezyonlarına dayalı tanıyı analiz etmektedir. DenseNet201 çıkarma modeli, KNN sınıflandırıcısı ile birlikte ISBI-ISIC veri seti için %96.805 ve PH² için %93,167 doğruluk elde etmektedir. Bu nedenle, IoT sistemine odaklanan bir yaklaşım, cilt lezyonlarının teşhisine yardımcı olan doktorlar için güvenilir ve etkilidir.

2021 yılında Bagheri ve diğerleri yapmış oldukları çalışmada cilt kanserinin tedavisi ve önlenmesi üzerinde durulmuştur. En sık görülen kanserlerden biri olan cilt kanserinin zamanında teşhis edilmesi, ölümü büyük ölçüde önleyebilmektedir. Otomatik cilt lezyonu segmentasyonu, otomatik cilt kanseri teşhis sisteminin önemli bir parçasıdır. Lezyonların renk, konum, boyut, şekil ve sınır kontrastındaki geniş çeşitlilik nedeniyle lezyon segmentasyonu hala zorlu bir problemdir. Bu çalışmada, iki aşamalı otomatik cilt lezyonu bölütleme yöntemi sunulmaktadır. İlk aşamada, algılama tabanlı bir segmentasyon yapısı olan Retina-Deeplab'ın, nesneleri aynı anda algılayan ve segmentlere ayıran Mask R-CNN ile birleştirilmesi önerilmiştir. Bu iki bölütleme

yönteminin sonuçlarını birleştirmek için iki jeodezik tabanlı ve grafik tabanlı kombinasyon yaklaşımı önerilmiştir. Önerilen yöntem, iyi bilinen üç cilt görüntüsü veri seti (ISBI 2017, DermQuest ve PH2) kullanılarak değerlendirilir. Önerilen iki aşamalı grafik tabanlı kombinasyon stratejisi sayesinde, genel lezyon segmentasyon yönteminin Jaccard değeri, ISBI 2017 lezyon segmentasyon mücadelesinin kazananından %3,54 daha yüksek olan %80,04'e ulaşmıştır. Önerilen Retina-Deeplab segmentasyon yöntemi, Mask R-CNN'den daha yüksek Jaccard değerinin yaklaşık %1'ine ulaşmıştır. Genel bölütleme yöntemi hem tüm görüntülerdeki lezyonların genel özelliklerini (birinci aşamada CNN tabanlı yöntemler kullanarak) hem de lezyonların görüntüye özgü özelliklerini (ikinci aşamada jeodezik tabanlı/grafik tabanlı kombinasyon yaklaşımlarını kullanarak) dikkate almaktadır. Önerilen iki aşamalı jeodezik tabanlı ve grafik tabanlı kombinasyon yaklaşımları, önceki kombinasyon stratejilerinden daha iyi performans göstermiştir. Deneyler, genel olarak önerilen lezyon segmentasyon yöntemlerinin, iyi bilinen veri kümelerinde diğer son teknoloji yöntemlerden daha iyi performans gösterdiği sonucuna ulaşılmıştır.

2020 yılında Al-masni ve diğerleri yapmış oldukları çalışmada tıbbi dermoskopi görüntüleri incelenmeye tabi tutulmuştur. Bu çalışmada, cilt lezyonu sınır segmentasyon aşamasını ve çoklu cilt lezyonları sınıflandırma aşamasını birleştiren entegre bir tanı çerçevesi önerilmektedir. İlk olarak, derin öğrenme tam çözünürlüklü evrişim ağı (FrCN) kullanarak tüm dermoskopi görüntülerinden cilt lezyonu sınırlarını segmentlere ayrılmıştır. Ardından, sınıflandırma için segmentlere ayrılmış cilt lezyonlarına bir evrişimli sinir ağı sınıflandırıcısı (yani, Inception-v3, ResNet-50, Inception-ResNet-v2 ve DenseNet-201) uygulanmıştır. İlk aşama, çeşitli cilt lezyonlarının belirgin özelliklerini çıkardığı için cilt lezyonu teşhisi için kritik bir ön koşul adımıdır. İyi kurulmuş sınıflandırma konvolüsyonel sinir ağları test edilerek umut verici bir sınıflandırıcı seçimi gerçekleştirilmiştir. Önerilen entegre derin öğrenme modeli, uygun dengeleme, segmentasyon ile üç bağımsız veri seti (yani, sırasıyla iki, üç ve yedi tip cilt lezyonu içeren Uluslararası Cilt Görüntüleme İşbirliği ((ISIC) 2016, 2017 ve 2018) kullanılarak değerlendirilmiştir. Entegre tanı sisteminde segmentlere ayrılmış lezyonlar, ISIC 2016 test veri setinin iyi huylu ve kötü huylu vakaları için F1 puanı açısından Inception-ResNet-v2'nin sınıflandırma performansını sırasıyla %2,72 ve %4,71 oranında iyileştirmektedir. Inception-v3, ResNet-50, Inception-ResNet-v2 ve DenseNet-

201 sınıflandırıcıları, ISIC 2016, 81.29'un iki sınıfı için %77.04, %79.95, %81.79 ve %81.27'lik genel ağırlıklı tahmin doğruluklarıyla yeteneklerini sergilemektedir. ISIC 2017'nin üç sınıfı için sırasıyla %, %81,57, %81,34 ve %73,44 ve yedi ISIC 2018 sınıfı için sırasıyla %88,05, %89,28, %87,74 ve %88,70, ResNet-50'nin üstün performansını göstermektedir. Önerilen entegre tanı ağları, cilt kanseri teşhisinde daha fazla gelişme için dermatologları desteklemek ve onlara yardımcı olmak için kullanılabilme potansiyelini içerisinde barındırmaktadır.

2021 yılında Belvedere ve diğerleri yapmış oldukları çalışmada cilt yara onarımı üzerinde durulmuştur. Cilt yara onarımı, terapötik zorluklar için önemli bir konuyu temsil etmektedir. Birçok molekül, doğru doku rejenerasyonunu indüklemek için topikal cihazların aktif prensipleri olarak yaygın olarak kullanılmaktadır. Bu moleküller arasında, glikozaminoglikanların bir karışımı olan mesoglikan ve laktoferrin son zamanlarda ilgi uyandırmıştır. Burada ilk kez, esas olarak yara iyileşmesinde rol oynayan hücre popülasyonlarını tedavi etmek için mesoglikan/laktoferrin kullanımı gerçekleştirilmiştir. İnsan keratinositlerinin, fibroblastlarının ve endotel hücrelerinin, ilişki ile tedavi edildiğinde daha hızlı göç ettiğini ve istila ettiği ortaya çıkarılmıştır. Ayrıca, mesoglikan/laktoferrinin keratinositlerin farklılaşma sürecini, fibroblastların miyofibroblastlara geçişini, endotel hücreleri için mezenkimal fenotip edinilmesini tetikleyebildiğini ve bu yolla kılcal damar benzeri yapı oluşturmaya başladığı bulunmuştur. Ek olarak, laktoferrinin iyi bilinen antimikrobiyal davranışının, bu formülasyon için çekici bir özellik sağlayarak *S. aureus* ve *P. aeruginosa* biyofilm oluşumunun inhibisyonunu teşvik ettiği kanıtlanmıştır. Son olarak, in vivo analizle, mesoglikan/laktoferrinin farelerin sırtında gerçekleştirilen cilt yaralarının kapanmasını desteklediği gözlemlenmiştir. Fare biyopsilerinin konfokal analizi ile lezyon çaplarının azalmasının yanı sıra, birlikteliğin kullanımının doğru doku rejenerasyonunun altında yatan hücre aktivasyonunu güçlü bir şekilde desteklediği belirtilmiştir. Bu sonuçlar, bu ilişkiyi içeren yeni bir topikal yamanın geliştirilmesini amaçlayan daha fazla araştırmayı teşvik etmektedir.

3. MATERYAL ve YÖNTEM

10015 adet görüntü verisini içeren “HAM10000” (Human Against Machine) veri seti üzerinde tasarlanan derin ağ modeli eğitilerek sonuçlar gözlemlenmiştir. Veri setinde bulunan lezyonlara ait sınıf bilgileri aşağıdaki gibidir.

Actinic Keratoses

Basal Cell Carcinoma

Benign Keratosis

Dermatofibroma

Malignant Melanoma


Melanocytic Nevi

Vascular Lesions

Cilt lezyonlarına ait sınıflar için örnek görseller Şekil 3.1’ de verilmiştir.

Veri setine ait “Melanocytic nevi” sınıfına ait imaj sayısının diğer sınıflardan bir hayli fazla olması, homojen yapıyı bozmaktadır. Ayrıca modelin eğitimi aşamasında çok fazla bu sınıf ile karşılaşması, gereğinden fazla ezberlemeye eğilimli olacaktır. Eğitim setimiz monoton ise, fazla uydurma riski yüksektir. Bu sebeple veri setinin düzenlenerek eğitime sokulması gerekecektir.

Ayrıca eğitim aşamasında görüntü verilerinin düzenlenmesi, bu veriler üzerinde çeşitli filtreler kullanılarak evrişim ve ortaklama işlemlerinin uygulanması ve eğitimin gerçekleştirilmesi donanımsal açıdan kabiliyetli sisteme ihtiyaç doğurmuştur. Bu aşamada Tokat Gaziosmanpaşa Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği Bölümü’ne ait donanımsal altyapıdan faydalanılmıştır.



Şekil 3.1: HAM10000 veri kümesindeki sınıflara ait örnek imajlar

Çalışmada Ham10000 imaj veri setinden yola çıkarak yukarıdaki yedi adet sınıfa ait doğruluk oranı yüksek tahminler amaçlanmaktadır. Uygulama için Phyton dili tercih edilmiş ve 3.7 sürümü üzerinde proje geliştirilmiştir. IDE ortamı olarak ise PhyCharm Community Edition üzerinde çalışılmıştır.

Yukarıda belirtilen HAM10000 veri setine ait imaj verileri VGG-16 mimarisi üzerinde eğitime tabi tutulmuştur. Eğitim aşamasından önce verileri test ve train olarak sınıflandırılması kapsamında K-Fold Cross Validation tekniğinden faydalanılmıştır.

3.1. Uygulama Adımları

Bu başlık altında uygulama esnasında kullanılmakta olan adımlar belirtilmekte olup; kullanılmış olan bu adımlara dair hususlara değinilmiştir.

Uygulamada kullanılan kütüphaneler aşağıdaki gibi projeye eklenmiştir.

```
import matplotlib.pyplot as plt
```

Matplotlib; veri görselleştirmesinde kullandığımız temel python kütüphanesidir. 2 ve 3 boyutlu çizimler yapmamızı sağlar.

```
import pandas as pd
```

Pandas, “ilişkisel” ve “etiketli” verilerle çalışmayı kolay ve sezgisel hale getirmek için tasarlanmış hızlı, esnek ve etkileyici veri yapıları sağlayan bir Python paketidir.

```
import os
```

Os modülü Python’da hazır olarak gelen , dosya ve dizinlerde kolaylıkla işlemler yapmamızı sağlayan bir modüldür.

```
from glob import glob
```

UNIX’in dosya arama altyapısı modern işletim sistemlerinin temelini oluşturuyor. Python dilinde bu arama özelliğini glob modülü sayesinde kullanabiliyoruz.

```
import numpy as np
```

NumPy (Numerical Python) bilimsel hesaplamaları hızlı bir şekilde yapmamızı sağlayan bir matematik kütüphanesidir. Numpy’ın temelini numpy dizileri oluşturur. Numpy dizileri python listelerine benzer fakat hız ve işlevsellik açısından python listelerinden daha kullanışlıdır.

```
from keras.models import *
```

Keras, neredeyse her tür derin öğrenme modelini tanımlamak ve eğitmek için uygun bir yol sağlayan Python için bir derin öğrenme kütüphanesidir. Keras, Tensorflow , Theano ve CNTK üzerinde çalışabilen Python ile yazılmış bir üst düzey sinir ağıları API'sidir.

```
from keras.optimizers import *
```

Bir sinir ağını eğitirken, ağırlıkları başlangıçta rastgele olarak başlatılır ve ardından ağırlıkların genel doğruluğunu artıracak şekilde her çağda güncellenir. Her dönemde, eğitim verilerinin çıktısı, hatayı hesaplamak için kayıp fonksiyonu yardımıyla gerçek verilerle karşılaştırılır ve ardından ağırlık buna göre güncellenir. Bu, esasen amacın kayıp fonksiyonunu optimize etmek ve ideal ağırlıklara ulaşmak olduğu bir optimizasyon problemidir. Optimizasyon için kullanılan yöntem, Optimizer olarak bilinir.

```
from keras.callbacks import ModelCheckpoint, LearningRateScheduler
```

ModelCheckpoint geri çağırısı, bir modeli veya ağırlıkları (bir denetim noktası dosyasında) belirli aralıklarla kaydetmek için model.fit () kullanarak eğitimle birlikte kullanılır, böylece model veya ağırlıklar daha sonra eğitime kaydedilen durumdan devam etmek için yüklenebilir.

Eğitim sırasında öğrenme oranının en basit ve belki de en çok kullanılan uyarlaması, zaman içinde öğrenme oranını düşüren tekniklerdir. Bunlar, eğitim prosedürünün başlangıcında daha büyük öğrenme oranı değerleri kullanıldığında büyük değişiklikler yapma ve eğitim prosedürünün ilerleyen kısımlarında ağırlıklara daha küçük bir oran ve dolayısıyla daha küçük eğitim güncellemeleri yapılacak şekilde öğrenme oranını düşürme avantajına sahiptir.

Bir sinir ağını eğitmenin zor yanlarından biri, uğraşmamız gereken çok sayıda hiperparametrenin olmasıdır. Örneğin

- Öğrenme oranı
- Adam optimizasyon algoritması için momentum veya hiperparametreler
- Katman sayısı
- Gizli birimlerin sayısı
- Mini parti boyutu
- Aktivasyon fonksiyonu

Bunlar arasında en önemli parametre öğrenme oranıdır. Öğrenme oranınız düşük olarak ayarlanmışsa, ağıntıdaki ağırlıklarda çok küçük güncellemeler yaptığınız için eğitim çok yavaş ilerleyecektir. Bununla birlikte, öğrenme oranınız çok yüksek ayarlanmışsa, kayıp fonksiyonunuzda istenmeyen farklı davranışlara neden olabilir.

Learning Rate Schedules, öğrenme oranını önceden tanımlanmış bir programa göre düşürerek eğitim sırasında öğrenme oranını ayarlamayı amaçlar. Popüler öğrenme oranı programları şunları içerir:

- Sabit öğrenme oranı
- Zamana dayalı bozulma
- Adım çürümesi
- Üstel bozulma

```
from sklearn.metrics import confusion_matrix
```

Bir karışıklık matrisi, gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde, bir sınıflandırma modelinin performansını tanımlamak için sıklıkla kullanılan bir tablodur.

```
import itertools
```

Tekrarlanan, yinelenen veriler için hızlı, belleği verimli kullanan fonksiyonlar sunan bir modüldür. Döngüleri kullanırken herşey sorunsuz ilerliyor gibi görünür, fakat veri büyüdükçe döngüye sokmak biraz zorlaşmaya başlar. Bu tür durumlar için python ile beraber gelen core modüllerden biri olan itertools bize yardımcı oluyor. Hızlı çalışan, bilgisayarın kaynaklarını verimli kullanan fonksiyonlar barındırıyor.

```
from keras.utils.np_utils import to_categorical
```

Keras, numpy dizilerinde eylemler gerçekleştirmek için işlevler sağlayan numpy yardımcı program kitaplığı sağlar. To_categorical () yöntemini kullanarak, bir numpy dizisi (veya) farklı kategorileri temsil eden tamsayılara sahip bir vektör, bir numpy

dizisine (veya) ikili değerleri olan ve içindeki kategori sayısına eşit sütunları olan bir matrise dönüştürülebilir.

```
from keras.layers import Dense, Dropout, Flatten, Conv2D, MaxPool2D
```

Dense layer: Düzenli olarak derinlemesine bağlı sinir ağı katmanıdır.

Dropout: Tam bağlı (Fully connected) katmanlarda belli eşik değerin altındaki düğümlerin seyreltilmesinin başarımı arttırdığı gözlenmiştir. Yani zayıf bilgilerin unutulması öğrenimi arttırdığı gözlenmiştir.

Yukarıda anlatılan kütüphaneler eklendikten sonra uygulamaya ait adımlar aşağıdaki gibidir.

Adım 1:

```
np.random.seed(123)
```

Python'da pseudo rastgele sayıları içindir. NumPy'nin rastgele işlemler için sözde rastgele sayılar üretmesini sağlayan temel bir girdi sağlar. Burada 123 tohum değeridir. NumPy rasgele çekirdek işlevleri, "sözde rasgele sayı üreticileri" algoritmalarına dayalı rasgele sayılar üretir.

Adım 2:

```
os.chdir('input')
```

Varsayılan çalışma klasörü olarak 'input' klasörü seçiliyor. Çünkü verisetimiz bu klasör içinde bulunuyor.

```
imageid_path = {os.path.splitext(os.path.basename(x))[0]: x  
for x in glob(r'*.*jpg')}
```

Temel çalışma klasörü altında bulunan tüm iç içe klasörler aranarak bulunan jpg dosyaları imageid_path isimli dizide saklanıyor.

Adım 3:

```
lesion_type = {  
    'nv': 'Melanocytic nevi',  
    'mel': 'dermatofibroma',  
    'bkl': 'Benign keratosis-like lesions ',  
    'bcc': 'Basal cell carcinoma',  
    'akiec': 'Actinic keratoses',  
    'vasc': 'Vascular lesions',  
    'df': 'Dermatofibroma'  
}
```

```
veriler = pd.read_csv('HAM10000_metadata.csv')
```

csv dosyasından veriseti ile ilgili bilgiler alınıyor.

	A	B	C	D	E	F	G
1	lesion_id	image_id	dx	dx_type	age	sex	localization
2	HAM_0000118	ISIC_0027419	bkl	histo	80	male	scalp
3	HAM_0000118	ISIC_0025030	bkl	histo	80	male	scalp
4	HAM_0002730	ISIC_0026769	bkl	histo	80	male	scalp
5	HAM_0002730	ISIC_0025661	bkl	histo	80	male	scalp
6	HAM_0001466	ISIC_0031633	bkl	histo	75	male	ear
7	HAM_0001466	ISIC_0027850	bkl	histo	75	male	ear
8	HAM_0002761	ISIC_0029176	bkl	histo	60	male	face
9	HAM_0002761	ISIC_0029068	bkl	histo	60	male	face
10	HAM_0005132	ISIC_0025837	bkl	histo	70	female	back
11	HAM_0005132	ISIC_0025209	bkl	histo	70	female	back
12	HAM_0001396	ISIC_0025276	bkl	histo	55	female	trunk
13	HAM_0004234	ISIC_0029396	bkl	histo	85	female	chest
14	HAM_0004234	ISIC_0025984	bkl	histo	85	female	chest
15	HAM_0001949	ISIC_0025767	bkl	histo	70	male	trunk
16	HAM_0001949	ISIC_0032417	bkl	histo	70	male	trunk
17	HAM_0007207	ISIC_0031326	bkl	histo	65	male	back
18	HAM_0001601	ISIC_0025915	bkl	histo	75	male	upper extremity
19	HAM_0001601	ISIC_0031029	bkl	histo	75	male	upper extremity
20	HAM_0007571	ISIC_0029836	bkl	histo	70	male	chest
21	HAM_0007571	ISIC_0032129	bkl	histo	70	male	chest
22	HAM_0006071	ISIC_0032343	bkl	histo	70	female	face

Tablo 3.1. Csv dosyasından veriseti ile ilgili bilgiler

Adım 4:

```
veriler['path'] = veriler['image_id'].map(imageid_path.get)
veriler['cell_type'] = veriler['dx'].map(lesion_type.get)
veriler['cell_type_idx'] = pd.Categorical(veriler['cell_type']).codes
```

Dizi içerisinde indisler güncelleniyor.

```
print(veriler.sample(3))
```

```
print(veriler.describe(exclude=[np.number]))
```

Burada örnek veri ekrana yazdırılıyor.


```
      lesion_id  image_id  ...  cell_type  cell_type_idx
9725  HAM_0004376  ISIC_0024843  ...  Actinic keratoses         0
6059  HAM_0003024  ISIC_0024768  ...  Melanocytic nevi         4
4540  HAM_0001659  ISIC_0026564  ...  Melanocytic nevi         4

[3 rows x 10 columns]
```

Tablo 3.2. Veri setinde bulunan imaj ve sınıf sayıları

Adım 5:

```
fig, ax1 = plt.subplots(1, 1, figsize=(10, 5))
```




Şekil 3.2: HAM10000 veri kümesindeki sınıflar

Görüldüğü üzere veri seti üzerindeki sınıfların dağılımında “Melanocytic nevi” sınıfına ait aşırı sayıda örnek bulunması veri setinin homojen yapısını bozmaktadır. DROP metodu kullanılarak bu sınıfa ait veriler tekrar düzenlenerek (bir kısmı atılarak: 5000 adet) eğitim için sınıfların dağılımı kabul edilebilir ölçüye getirilmiştir.

```
veriler = veriler.drop(veriler[veriler.cell_type_idx == 4].iloc[:5000].index)
fig, ax2 = plt.subplots(1, 1, figsize=(10, 5))

plt.show(veriler['cell_type'].value_counts().plot(kind='bar', ax=ax2))
```




Şekil 3.3. Düzenlenmiş Ham 10000 Sınıfı Dağılımları

Bu grafikte düzenlenmiş halde olan Ham 10000 veri seti sınıfı dağılımları gösterilmektedir. Bu grafik Şekil 3.3'te gösterimi gerçekleştirilmiş olan heterojen yapının DROP metoduyla düzenlemeye tabi tutulmuş versiyonudur.

Adım 6:

```
plt.show(veriler['localization'].value_counts().plot(kind='bar'))
```

Veri setine ait CSV dosyasında “image” kimlikleri ile birlikte age, localization, sex gibi lezyonlara ait konum, cinsiyet yaş gibi bilgiler de bulunmaktadır.




Şekil 3.4. Vücut kısımlarına dair yapılmış olan analiz grafiği

Yukarıdaki grafikte vücut bölümlerine dair yapılmış olan analizin sayısal verileri gösterilmektedir. Bu verilere bakıldığında en çok sırt bölgesinde yoğunluğun söz konusu olduğundan söz edilebilmektedir.

Adım 7:

```
plt.show(veriler['sex'].value_counts().plot(kind='bar'))
```



Şekil 3.5. Uygulama eksenindeki cinsiyet dağılım grafiği

Veri seti incelendiğinde erkek katılımcıların daha fazla olduğu görülmektedir. Ancak azımsanmayacak düzeyde kadın katılımcının varlığından söz edebilmek de mümkündür. Cinsiyeti bilinmeyen katılımcıların da veri setinde yer aldığı görülmektedir.

Uygulamanın eğitim ve test aşamalarında sadece “image” bilgilerinden faydalanılmıştır. CSV dosyası içerisinde bulunan location, sex, age gibi bilgiler eğitime dahil edilmemiştir. Burada amaç VGG16 mimarisinin evrişim ve ortaklama işlemleri ile sadece resimler baz alınarak, problemin çözümünde ne kadar yetenekli olduğunun gösterilmesidir.

Adım 8:

```
from PIL import Image
veriler['image'] = veriler['path'].map(lambda x: np.asarray(Image.open(x).resize((200,
150))))
```

Bu kısımda resimlerim boyutları 200x150 olarak ayarlanmakta. Resmin boyutu ne kadar büyük olursa işlemci üzerine düşecek yük o derecede artacaktır.

Adım 9:

```
y = veriler.cell_type_idx
print(y)
print(y.count())
print(veriler['image'].count())
```

Veriler dizisindeki imaj sayıları ve sınıf sayıları ekrana yazdırılmaktadır.

```
[3 rows x 10 columns]
```

	lesion_id	image_id	...	path	cell_type
count	10015	10015	...	10015	10015
unique	7470	10015	...	10015	7
top	HAM_0001863	ISIC_0029607	...	ISIC_0032370.jpg	Melanocytic nevi
freq	6	1	...	1	6705


```
[4 rows x 8 columns]
```

Şekil 3.6. Veri setine ait imaj ve sınıf sayıları

Adım 10:

Aşağıdaki kod ile veri seti çapraz doğrulama tekniği (RepeatedKFold) kullanılarak test ve eğitim veri setlerine ayrılmaktadır.

```
from sklearn.model_selection import RepeatedKFold
rkf = RepeatedKFold(n_splits=10, n_repeats=10, random_state=None)

print(rkf)
for train_index, test_index in rkf.split(veriler):
    print("Train:", train_index, "Validation:", test_index)
```

??

```

x_train_o, x_test_o = veriler.iloc[train_index], veriler.iloc[test_index]
y_train_o, y_test_o = y.iloc[train_index], y.iloc[test_index]

print("x_train_o:",x_train_o.shape)
x_train = np.asarray(x_train_o['image'].tolist())
x_test = np.asarray(x_test_o['image'].tolist())
print('xtrain:',x_train.shape)
x_train_mean = np.mean(x_train)
print('xtrain_mean:',x_train_mean.shape)
x_train_std = np.std(x_train) # std=standart sapma
print('xtrain_std:',x_train_std.shape)
x_test_mean = np.mean(x_test)
x_test_std = np.std(x_test)

x_train = (x_train - x_train_mean)/x_train_std
x_test = (x_test - x_test_mean)/x_test_std
y_train = to_categorical(y_train_o, num_classes = 7)
y_test = to_categorical(y_test_o, num_classes = 7)

```

Veri setini eğitim ve test set olarak ayırmamızın amacı, olası overfitting'den kaçınmak ve modelin daha önceden görmediği veri seti üzerinde nasıl performans gösterdiğini anlamaktır. Fakat modelimizin eğitim ve test aşamasında dağılımdan kaynaklı bazı hatalar söz konusu olabilmektedir. Bu hataları minimum seviyeye indirmek için K – Fold Cross Validation tekniği kullanılır. Eğitim veri setini rasgele k parçaya bölmektedir. k-1 parça eğitim için kullanılırken 1 parçada test seti için kullanılır ve k defa bu işlem tekrar etmektedir. Her aşamada elde edilen değerler toplanır; ortalaması alınır ve modelin performansının değerlendirilmesi gerçekleştirilir.

Adım 11:

Bir sinir ağını eğitirken, ağırlıkları başlangıçta rastgele olarak başlatılır ve ardından ağırlıkların genel doğruluğunu artıracak şekilde her çağda güncellenir. Her dönemde, eğitim verilerinin çıktısı, hatayı hesaplamak için kayıp fonksiyonu yardımıyla gerçek verilerle karşılaştırılır ve ardından ağırlık buna göre güncellenir. Bu, esasen amacın kayıp fonksiyonunu optimize etmek ve ideal ağırlıklara ulaşmak olduğu bir optimizasyon

problemidir. Optimizasyon için kullanılan yöntem, Optimizer olarak bilinir. Bu çalışmada aktivasyon fonksiyonu olarak “RELU”, kayıp fonksiyonu olarak “Binary Cross-Entropy”, iyileştirici (optimizer) olarak ise “ADAM” fonksiyonu parametre olarak kullanılmıştır.

Aşağıdaki kod ile VGG16 modeli tanımlanmaktadır. Keras kütüphanelerinde bu model bulunmaktadır ve dolayısıyla modelimizi kolayca import edip parametrelerini girebilmekteyiz.

```
num_classes = 7
from keras.applications.vgg16 import VGG16

model_vgg16_conv = VGG16(weights=None, include_top=True,
input_shape=(150,200,3))

model_vgg16_conv.summary()

x = Dense(num_classes, activation='softmax',
name='predictions')(model_vgg16_conv.layers[-2].output)

model = Model(input=model_vgg16_conv.input, output=x)

model.summary()
```

Model: "vgg16"

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	(None, 150, 200, 3)	0
block1_conv1 (Conv2D)	(None, 150, 200, 64)	1792
block1_conv2 (Conv2D)	(None, 150, 200, 64)	36928
block1_pool (MaxPooling2D)	(None, 75, 100, 64)	0
block2_conv1 (Conv2D)	(None, 75, 100, 128)	73856
block2_conv2 (Conv2D)	(None, 75, 100, 128)	147584
block2_pool (MaxPooling2D)	(None, 37, 50, 128)	0
block3_conv1 (Conv2D)	(None, 37, 50, 256)	295168
block3_conv2 (Conv2D)	(None, 37, 50, 256)	590080
block3_conv3 (Conv2D)	(None, 37, 50, 256)	590080
block3_pool (MaxPooling2D)	(None, 18, 25, 256)	0
block4_conv1 (Conv2D)	(None, 18, 25, 512)	1180160

Tablo 3.3. VGG16 modeline ait özet bilgileri

block4_conv1 (Conv2D)	(None, 18, 25, 512)	1180160
block4_conv2 (Conv2D)	(None, 18, 25, 512)	2359808
block4_conv3 (Conv2D)	(None, 18, 25, 512)	2359808
block4_pool (MaxPooling2D)	(None, 9, 12, 512)	0
block5_conv1 (Conv2D)	(None, 9, 12, 512)	2359808
block5_conv2 (Conv2D)	(None, 9, 12, 512)	2359808
block5_conv3 (Conv2D)	(None, 9, 12, 512)	2359808
block5_pool (MaxPooling2D)	(None, 4, 6, 512)	0
flatten (Flatten)	(None, 12288)	0
fc1 (Dense)	(None, 4096)	50335744
fc2 (Dense)	(None, 4096)	16781312
predictions (Dense)	(None, 1000)	4097000
=====		
Total params: 85,928,744		
Trainable params: 85,928,744		
Non-trainable params: 0		

Tablo 3.4. VGG16 modeline ait özet bilgileri (devamı)

```

model.compile(optimizer=Adam(lr=1e-4), loss='binary_crossentropy',
metrics=['accuracy'])
checkpointer = ModelCheckpoint(filepath='agirliklar.hdf5', monitor='loss', verbose=1,
save_best_only=True)
history = model.fit(x_train, y_train,
                    batch_size=32,
                    epochs=12,
                    verbose=1,
                    callbacks=[checkpointer],
                    validation_data=(x_test, y_test))
score = model.evaluate(x_test, y_test, verbose=1)

```

Adım 12:

Model çalıştırıldıktan sonra kayıp fonksiyonu ve test doğruluğu izlenebilmektedir.

```
print('Test loss:', score[0])
print('Test accuracy:', score[1])

fig, ax = plt.subplots(2, 1)
ax[0].plot(history.history['loss'], color='b', label="Training loss")
ax[0].plot(history.history['val_loss'], color='r', label="Validation loss", axes=ax[0])
legend = ax[0].legend(loc='best', shadow=True)
ax[1].plot(history.history['acc'], color='b', label="Training accuracy")
ax[1].plot(history.history['val_acc'], color='r', label="Validation accuracy")
legend = ax[1].legend(loc='best', shadow=True)
plt.show(block=True)
plt.interactive(False)
```

Epoch 1/12

```
128/8012 [.....] - ETA: 1:05:32 - loss: 0.3947 - acc: 0.8571
160/8012 [.....] - ETA: 1:04:03 - loss: 0.3754 - acc: 0.8661
192/8012 [.....] - ETA: 1:03:08 - loss: 0.3547 - acc: 0.8735
224/8012 [.....] - ETA: 1:02:13 - loss: 0.3435 - acc: 0.8763
256/8012 [.....] - ETA: 1:01:32 - loss: 0.3361 - acc: 0.8806
288/8012 [>.....] - ETA: 1:00:51 - loss: 0.3281 - acc: 0.8829
320/8012 [>.....] - ETA: 1:00:23 - loss: 0.3234 - acc: 0.8844
352/8012 [>.....] - ETA: 1:00:10 - loss: 0.3129 - acc: 0.8888
384/8012 [>.....] - ETA: 59:45 - loss: 0.3112 - acc: 0.8884
416/8012 [>.....] - ETA: 59:24 - loss: 0.3084 - acc: 0.8870
```

Adım 13:

Aşağıdaki kod ile karmaşıklık matrisi oluşturulmaktadır. Bir karışıklık matrisi, gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde, bir sınıflandırma modelinin performansını tanımlamak için sıklıkla kullanılan bir tablodur.

```
def plot_confusion_matrix(cm, classes, normalize=False, title='Confusion matrix',
                           cmap=plt.cm.Blues):
    plt.imshow(cm, interpolation='nearest', cmap=cmap)
    plt.title(title)
    plt.colorbar()
    tick_marks = np.arange(len(classes))
    plt.xticks(tick_marks, classes, rotation=45)
    plt.yticks(tick_marks, classes)
    if normalize: cm = cm.astype('float') / cm.sum(axis=1)[:, np.newaxis]
    thresh = cm.max() / 2.
    for i, j in itertools.product(range(cm.shape[0]), range(cm.shape[1])):
        plt.text(j, i, cm[i, j],
                 horizontalalignment="center",
                 color="white" if cm[i, j] > thresh else "black")
    plt.tight_layout()
    plt.ylabel('True label')
    plt.xlabel('Predicted label')

y_pred = model.predict(x_test)

y_pred_classes = np.argmax(y_pred, axis=1)

y_true = np.argmax(y_test, axis=1)

confusion_mtx = confusion_matrix(y_true, y_pred_classes)

plot_confusion_matrix(confusion_mtx, classes=range(7))

plt.show(block=True)
plt.interactive(False)
```

4. BULGULAR ve TARTIŞMA

Python programlama dili ile evrişimli sinir ağının eğitilmesi için farklı aşamalarda temel olarak aşağıdaki hazır kütüphanelerden faydalanılmıştır.

Tensorflow, Keras, Sklearn, Pandas, Numpy

K-Fold Cross validation tekniğini kullanarak verileri test ve train olarak ayırmamız, VGG-16 derin öğrenme mimarisinin bu tarz problemler için uygun olduğunu görmemizi sağlamıştır. Şayet Sklearn kütüphanesine ait train_test_split() fonksiyonunu kullanmış olsaydık, derin öğrenmenin başarısı daha da artacaktı, ancak kullandığımız modelin gerçek gücünü yansıtmayacaktı.


Uygulamaya ait implementasyonun Tensorflow (CPU) üzerinde 12 adet epoch parametresi ile çalıştırılması sonucu, aşağıdaki görüldüğü üzere %85,6 test başarısı elde edilmiştir.

```
64/501 [==>.....] - ETA: 43s
96/501 [====>.....] - ETA: 40s
128/501 [=====>.....] - ETA: 38s
160/501 [=====>.....] - ETA: 34s
192/501 [=====>.....] - ETA: 31s
224/501 [=====>.....] - ETA: 27s
256/501 [=====>.....] - ETA: 24s
288/501 [=====>.....] - ETA: 21s
320/501 [=====>.....] - ETA: 18s
352/501 [=====>.....] - ETA: 14s
384/501 [=====>.....] - ETA: 11s
416/501 [=====>.....] - ETA: 8s
448/501 [=====>....] - ETA: 5s
480/501 [=====>..] - ETA: 2s
501/501 [=====>] - 50s 100ms/step
Test loss: 0.42555698960603117
Test accuracy: 0.8562874371658067
Process finished with exit code 0
```

Eğitim ve test aşamalarında doğruluk ve kayıp fonksiyonlarına ait sonuç değerlerini Şekil 4.1 üzerinde incelemek mümkündür.


Eğitim aşamasında doğruluk oranının %86'dan başlayarak %95 lere kadar ilerlediği görülmektedir. Kayıp fonksiyonu ise %35 den başlayarak %15 lere kadar düşmektedir.

Test aşamasında doğruluk oranı %85 ile %88 arasında değişmektedir. Kayıp fonksiyonu ise %30 ile %40 arasında değişim göstermektedir.



Şekil 4.1: Test ve train verilere ait doğruluk ve kayıp fonksiyonları

Kullanılmakta olan kod ile karmaşıklık matrisi oluşturulmaktadır. Karmaşıklık matrisi, gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde, bir sınıflandırma modelinin performansını tanımlamak için sıklıkla kullanılan bir tablodur. Bu matrisin gösterimi Tablo 3.5.'de gösterilmektedir.




Tablo 3.5. Karışıklık Matrisi

Kullanımı söz konusu olmuş olan model mimarisi, aktivasyon fonksiyonları, kayıp fonksiyonları değiştirilerek ve yapay sinir ağında gizli katman sayısı artırılarak uygulamanın başarısının artırılması mümkün olacaktır.

Sınıflara ait tahmin başarılarının ağırlıklı ortalaması %85,62 olarak program çıktısında mevcuttur. Buradaki karışıklık matrisi ise ilk kata ait değerleri göstermektedir.

K-Fold Cross Validation tekniğine ait veri ayırma işlemi Şekil 4.2’de gösterilmiştir. Karışıklık matrisimiz ise buradaki iterasyon katmanlarından sadece birisine ait test verisinin sonuçlarını vermektedir.



Şekil 4.2: K-Fold Cross Validation

Görselde veri seti 10 parçaya bölünmüştür. Her turda, mavi boyalı alan test setine ayrılmışken diğer parçalar eğitim için ayrılmıştır. Her turun sonunda sınıflandırıcımızdan gelen performans puanları da E değişkenine kaydedilir. Bütün turlar bittiğinde E'nin aritmetik ortalaması modelimizin performansını gösterir. Karmaşıklık matrisi yedi adet sınıfımızı 0,1,2,3,4,5,6 şeklinde indisler ile simgeleyerek, bu sınıflar üzerindeki tahminleri ve tahmin sayılarına karşılık gelen doğru sınıf değerlerini göstermektedir. İndekslenmiş olan sınıf bilgileri aşağıdaki gibidir.

0: Melanocytic Nevi

1: Malignant Melanoma

2: Benign Keratosis

3: Basal Cell Carcinoma

4 : Actinic Keratoses

5: Vascular Lesions

6: Dermatofibroma

5. SONUÇ ve ÖNERİLER

İnsan vücudunun sahip olduğu deri; vücudun en büyük organıdır. Toplam vücut ağırlığının %16'sı deriden meydana gelmektedir. Deri üç katmanlı bir yapıya sahiptir. Bu nedenle oldukça karmaşık bir yapısı vardır. Bu karmaşık yapı içerisinde çeşitli sebeplerden dolayı birtakım hastalıklar meydana gelebilmektedir. Bu hastalıklardan en tehlikeli olanı ise melanom olarak adlandırılmış olan deri kanseridir.

Malign melanom hastalığına çok sık olarak rastlanmasa da deri hastalıklarının en ölümcül şeklidir. Ancak malign melanom erken teşhis edilirse tedavisi oldukça kolaydır. Bu hastalığa teşhis koyabilmek adına deri lezyonlarının görüntülemesinin oldukça başarılı bir şekilde gerçekleştirilmesi gerekmektedir. Bunun için kullanılan yöntemle verilen isim ise dermoskopidir.

Geliştirilen uygulama sayesinde tıp çalışanlarının uygulamada baz alınan cilt hastalıklarının teşhisi için ihtiyaç duyduğu süre azaltılmış ve ayrıca doğruluk oranı yüksek tahminler sayesinde hastalık için daha erken zamanlarda önlem alınması mümkün olmuştur.

Yapay sinir ağında mevcut olan aktivasyon fonksiyonlarında, evrişim süreçlerinde, kayıp fonksiyonlarında değişime gidilerek ve daha çok gizli katman kullanımı yapılarak yapılmış olan uygulamanın başarı düzeyinde artış gerçekleştirmek mümkündür. Cilt kanseri problemlerinin gözlemlenme sıklığı son zamanlarda artış göstermiştir. Ancak aynı doğrultuda erken teşhis koyabilmek için yapılan çalışmalarda da artış meydana gelmiştir. Daha önce yapılmış olan araştırmalara bakıldığında veri setlerinin kısıtlı olduğu ya da sınıf dağılımlarının dengeli bir durumda olmadığı tespit edilmiştir. Bu bilgiler doğrultusunda, yapılan bu çalışma çerçevesinde veri seti stabilize edilerek ve k-fold doğrulama yöntemi kullanılarak oldukça kapsamlı bir ayırım sağlamakta olan güvenilirlik düzeyi yüksek bir model geliştirilmiştir. Test aşamasında eğitilmiş olan modelin sınıf geçerliliğinin %85,62 oranında elde edildiği görülmektedir.

Çalışma sonucu elde edilen eğitilmiş modeli bir web ara yüz ile veya gömülü sistemlere entegre edilmek suretiyle kolaylıkla sahada kullanılması mümkündür. Ayrıca uygulamada kullanılan aktivasyon fonksiyonları, kayıp fonksiyonları, optimizasyon fonksiyonları gibi parametreler değiştirilmek suretiyle daha kabiliyetli ve kararlı

sonuçlar almak mümkün olacaktır. Daha sonra yapılacak çalışmalar için bu uygulama önemli bir temel oluşturacaktır. Verinin düzenlenmesi, sınıflandırılması ve eğitime sokulması aşamaları için önemli ipuçları içermektedir.

Dermoskopi işleminin yapılabilmesi için dermatoskop olarak adlandırılan bir cihaz kullanılmaktadır. Bu cihaz el yordamıyla kullanılmakta olan manuel bir aygıttır. Bu cihaz ile deri yapılarının görüntülenmesi sağlanmaktadır. Çünkü deri üzerindeki yapıları ve lezyonları çıplak gözle görmek mümkün değildir. Bu tez çalışması ile geliştirilen uygulamanın da bu yönetime paralel olarak değerlendirmeye alınması, tahmin sonuçlarının hızlı ve daha kararlı olmasını sağlayacaktır.

Yapılmakta olan teşhis çalışmalarında ortamda mevcut olan ışığın kullanılan dermatoskopa etki etmemesini sağlamak gerekmektedir. Dermatoskop ne kadar ortam ışığı alırsa deri lezyonlarının görüntülenmesi o kadar zor olmaktadır. Bu nedenle çeşitli geliştirme çalışmalarıyla dermatoskop içine girebilecek olan ışınların minimum seviyeye getirilebilmesi sağlanmaya çalışılmıştır. Tez çalışmasında ortaya sunulan derin öğrenme yönteminin daha da iyileştirilmesi ile her türlü dermatoskopik görüntüye ait imaj verisinin yorumlanması ve yüksek oranlarda tahminlerin sunulması mümkün olacaktır.

Uygulamaya ait eğitilmiş modelin ağırlıkları `agirlıklar.hdf5` isimli dosyaya kaydedilmiştir. Bu şekilde eğitilmiş model üzerinden her türlü lezyon görüntüsü test işlemine tabi tutulabilmektedir. Ayrıca bu test işlemi için yüksek donanımlı sistemlere ihtiyaç olmayacaktır. Geliştirilen uygulama bir mobil ara yüz ile kullanıma hazır hale getirilebilir. Bu mobil uygulama üzerinden telefon veya tablete ait kamera girdisi ile anlık tahmin yapılabilir. Bu şekilde hızlı ve kararlı sistemlerin artması, tıp alanında erken teşhisin önemi de göz önüne alındığında bilim ve sağlık açısından önem arz etmektedir.

Ayrıca bu tez çalışmasında olduğu gibi aşırı sayıda görüntü verisi içeren veri setlerinin uygun modeller kullanılarak eğitilmesi ve bu eğitime ait başarının artırılması sadece cilt kanseri için değil, dermatoskopik görüntü verileri içeren her türlü rahatsızlık için çözüm teşkil etmektedir. Bu çalışma ileride yapılabilecek daha kabiliyetli derin öğrenme uygulamaları için ileriye dönük temel bir adım teşkil etmektedir.

KAYNAKLAR

- “A Beginner’s Guide to Neural Networks and Deep Learning,” Skymind. [Online]. Available: <http://skymind.ai/wiki/neural-network>. Erişim Tarihi: 24.05.2021.
- “Amazon.com: Artificial Intelligence for Humans, Volume 3: Deep Learning and Neural Networks eBook: Jeff Heaton: Kindle Store.” [Online]. Available: <https://www.amazon.com/Artificial-Intelligence-Humans-Learning>. Erişim Tarihi: 24.05.2021.
- “Dermoscopy_tutorial - 7point check list.” [Online]. Available: <http://www.dermoscopy.org/consensus/2d.asp>.
- “Dermoscopy_tutorial - Menzies’ scoring method.” [Online]. Available: <http://www.dermoscopy.org/consensus/2c.asp>. Erişim Tarihi: 24.05.2021.
- “Fig. 2. Mathematical model of artificial neuron,” ResearchGate. [Online]. Available: https://www.researchgate.net/figure/Mathematical-model-of-artificial-neuron_fig1_320270458. Erişim Tarihi: 24.05. 2021.
- “Fundamentals of Deep Learning - Activation Functions and their use,” Analytics Vidhya.
- “Pattern analysis | DermNet NZ.” [Online]. Available: <https://www.dermnetnz.org/cme/dermoscopy-course/pattern-analysis/>. Erişim Tarihi: 23.05.2021.
- “The layers of your skin | American Academy of Dermatology.” [Online]. Available: <https://www.aad.org/public/kids/skin/the-layers-of-your-skin>. Erişim Tarihi: 23.05.2021
- “The Skin Cancer Detector That Could Save Your Life,” TipHero. [Online]. Available: <https://tiphero.com/the-skin-cancer-detector-that-could-save-your-life/>. Erişim Tarihi: 24.05.2021.

“What is dermoscopy?,” Dr Jonathan Bowling. [Online]. Available: <http://mydermatologist.co.uk/worried-about-a-mole/what-is-dermoscopy/>.

Erişim Tarihi: 23. 05.2021.

A. Krizhevsky, I. Sutskever, and G. E. Hinton (2012) “ImageNet Classification with Deep Convolutional Neural Networks,” in Advances in Neural Information Processing Systems F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, Eds. Curran Associates, Inc., pp. 1097–1105.

Abbasi N. R. et al. (2004). “Early Diagnosis of Cutaneous Melanoma: Revisiting the ABCD Criteria,” JAMA, vol. 292, no. 22, pp. 2771–2776.

Agarwal N, Balasubramanian VN, Jawahar C, (2018). Improving multiclass classification by deep networks using DAGSVM and Triplet Loss. Pattern Recognition Letters, 112, 184-90.

Alom MZ, Taha TM, Yakopcic C, Westberg S, Sidike P, Nasrin MS, Van Esesn BC, Awwal AAS, Asari VK, (2018). The history began from alexnet: A comprehensive survey on deep learning approaches. arXiv preprint arXiv:1803.01164.

Aloysius N, Geetha M. A. (2017). review on deep convolutional neural networks. International Conference on Communication and Signal Processing (ICCSP), 0588-92.

Alradad, M. (2015). “Robust classification with convolutional neural networks,” Thesis, University of Missouri--Columbia.

Anderson D. and G. McNeill (1992). “Artificial neural networks technology,” Kaman Sci. Corp., vol. 258, no. 6, pp. 1–83.

Basha SS, Dubey SR, Pulabaigari V, Mukherjee S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. Neurocomputing, 378, 112-9.

- Bhardwaj A. and D. J. Bhatia (2014). "An image segmentation method for early detection and analysis of melanoma," IOSR J. Dent. Med. Sci., vol. 13, no. 10, pp. 18–22.
- Carvalho T, De Rezende ER, Alves MT, Balieiro FK, Sovat RB. (2017). Exposing computer generated images by eye's region classification via transfer learning of VGG19 CNN. IEEE International Conference on Machine Learning and Applications (ICMLA), 866-70.
- Cavaioni, M. (2018). "DeepLearning series: Deep Neural Networks tuning and optimization," Medium.
- Cortes C, Vapnik V. (1995). Support-vector networks. Machine learning, 20, 3, 273-97.
- Eberhart, R. C. (2014). Neural Network PC Tools: A Practical Guide. Academic Press,
- Friedman R. J., D. S. Rigel, and A. W. Kopf (1985). "Early detection of malignant melanoma: The role of physician examination and self-examination of the skin," CA. Cancer J. Clin., vol. 35, no. 3, pp. 130–151.
- Gawkrodger D. and M. R. Ardern-Jones (2016). Dermatology: An Illustrated Colour Text. Elsevier Health Sciences.
- Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, Liu T, Wang X, Wang G, Cai J, (2018). Recent advances in convolutional neural networks. Pattern Recognition, 77, 354-77.
- Hinton GE, Srivastava N, Krizhevsky A, Sutskever I, Salakhutdinov RR, (2012). Improving neural networks by preventing co-adaptation of feature detectors. arXiv preprint arXiv:1207.0580.
- Holländer, B. (2021). "Natural vs Artificial Neural Networks," Becoming Human: Artificial Intelligence Magazine. [Online]. Available: <https://becominghuman.ai/natural-vs-artificial-neural-networks-9f3be2d45fdb>. Erişim Tarihi: 24.05.2021.

- Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. Proceedings of the IEEE conference on computer vision and pattern recognition, 4700-8.
- Ide H, Kurita T. (2017). Improvement of learning for CNN with ReLU activation by sparse regularization. International Joint Conference on Neural Networks (IJCNN), 2684-91.
- Jayalakshmi T. and Santhakumaran A. (2011). “Statistical Normalization and Back Propagation for Classification,” Int. J. Comput. Theory Eng., pp. 89–93.
- Jiao J, Zhao M, Lin J, Liang K, (2020). A comprehensive review on convolutional neural network in machine fault diagnosis. arXiv preprint arXiv:2002.07605.
- Khan A, Sohail A, Zahoor U, Qureshi AS, 2020. A survey of the recent architectures of deep convolutional neural networks. Artificial Intelligence Review, 53, 8, 5455-516.
- Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 1097-105.
- LeCun Y, Bottou L, Bengio Y, Haffner P, (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86, 11, 2278-324.
- LeCun Y. A., L. Bottou, G. B. Orr, and K.-R. Müller (2012). “Efficient BackProp,” in Neural Networks: Tricks of the Trade: Second Edition, G. Montavon, G. B. Orr, and K.-R. Müller, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 9–48.
- M. Niknafs, “Neural Network Optimization,” p. 7
- Masood S, Ahsan U, Munawwar F, Rizvi DR, Ahmed M, (2020). Scene Recognition from Image Using Convolutional Neural Network. Procedia Computer Science, 167, 1005-12

- Mira, J. (1995), Neural Computation Lecture Notes In Computer, International Workshop on Artificial Neural Networks Malaga- Torremolinos ,Spane June 1995, Proceeding, IWANN '95. Sprenger ISBN 3 1741 102 204 973 pp. 4-15.
- Nielsen, M. A. (2015). “Neural Networks and Deep Learning,”.
- Nwankpa C, Ijomah W, Gachagan A, Marshall S, (2018). Activation functions: Comparison of trends in practice and research for deep learning. arXiv preprint arXiv:1811.03378.
- Oliveira R., J. Papa, A. S. Pereira, and J. Tavares (2016). “Computational Methods for Pigmented Skin Lesion Classification in Images: Review and Future Trends,” Neural Comput. Appl.
- O'Shea, K., Nash, R. (2015). An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458.
- Rawat, W., & Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. Neural computation, 29(9), 2352-2449.
- Reghunath A, Nair SV. (2019). Shah J. Deep learning based Customized Model for Features Extraction. 2019 International Conference on Communication and Electronics Systems (ICCES), 1406-11.
- Rezende VC, Costa M, Santos A, de Oliveira RC. (2019). Image Processing with Convolutional Neural Networks for Classification of Plant Diseases. 2019 8th Brazilian Conference on Intelligent Systems (BRACIS), 705-10.
- Sáez A., B. Acha, and C. Serrano (2014). “Pattern Analysis in Dermoscopic Images,” in Computer Vision Techniques for the Diagnosis of Skin Cancer, J. Scharcanski and M. E. Celebi, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 23–48.
- Serra X., Castán J., and Escalera S., “Face recognition using Deep Learning,” p. 96.

- Shaha M, Pawar M. (2018). Transfer learning for image classification. 2018 Second International Conference on Electronics, Communication and Aerospace Technology (ICECA), 656-60.
- Simonyan K, Zisserman A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Sterry W. (2006). Thieme Clinical Companions Dermatology, 1 edition. Stuttgart ; New York: Thieme.
- Sze V, Chen Y.H., Yang T.J., Emer J.S. (2017). Efficient processing of deep neural networks: A tutorial and survey. Proceedings of the IEEE, 105, 12, 2295-329.
- Toğaçar, M., Cömert, Z., Ergen, B. (2021). Intelligent skin cancer detection applying autoencoder, MobileNetV2 and spiking neural networks. Chaos, Solitons & Fractals, 144, 110714.
- van Beers and. Wiering D. M. A., “Using Intersection over Union loss to improve Binary Image Segmentation,” p. 10.
- Vestergaard M. E., P. Macaskill, P. E. Holt, and S. W. Menzies (2008). “Dermoscopy compared with naked eye examination for the diagnosis of primary melanoma: a meta-analysis of studies performed in a clinical setting,” Br. J. Dermatol., vol. 159, no. 3, pp. 669–676.
- Vojt J. (2016). “Deep neural networks and their implementation,”.
- Walia A. S. (2021). “Activation functions and it’s types-Which is better?,” Towards Data Science. [Online]. Available: <https://towardsdatascience.com/activation-functions-and-its-types-which-is-better-a9a5310cc8f>. Erişim Tarihi: 24.05.2021.
- Walter F. M. et al. (2013). “Using the 7-point checklist as a diagnostic aid for pigmented skin lesions in general practice: a diagnostic validation study,” Br J Gen Pr., vol. 63, no. 610, pp. e345– e353.
- Wang, G., Gong, J. (2019). Facial expression recognition based on improved LeNet-5 CNN. 2019 Chinese Control And Decision Conference (CCDC), 5655-60.

- Xia Y, Cai M, Ni C, Wang C, Shiping E, Li H. (2019). A Switch State Recognition Method based on Improved VGG19 network. 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 1658-62.
- Yamashita, R., Nishio, M., Do, R.K.G., Togashi K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9, 4, 611-29
- Yapıcı, M.M., Tekerek, A., Topaloğlu, N. (2019). Performance comparison of convolutional neural network models on GPU. 2019 IEEE 13th International Conference on Application of Information and Communication Technologies (AICT), 1-4.
- Zeiler, M.D., Fergus, R. Visualizing and understanding convolutional networks. *European conference on computer vision*, 818-33.
- Zou, Y., Zhao, L., Qin, S., Pan, M., Li, Z. (2020). Ship target detection and identification based on SSD_MobilenetV2. 2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC), 1676-80.

EKLER

Ham10000 veri seti ve kullanım şartları:

Tschandl, Philipp, 2018, "HAM10000 veri seti, yaygın pigmentli cilt lezyonlarının çok kaynaklı dermatoskopik görüntülerinden oluşan geniş bir koleksiyon", <https://doi.org/10.7910/DVN/DBW86T>, Harvard Dataverse, V3, UNF:6:/APKSsDGVDhwPBWzsStU5A== [fileUNF]

Creative Commons Atıf- GayriTicari 4.0 Uluslararası Kamu Lisansı

Lisanslı Hakları kullanarak, bu Creative Commons Atıf-GayriTicari 4.0 Uluslararası Kamu Lisansının ("Kamu Lisansı") hüküm ve koşullarına bağlı kalmayı kabul edersiniz. Bu Kamu Lisansının bir sözleşme olarak yorumlanabileceği ölçüde, Bu hüküm ve koşulları kabul etmeniz karşılığında Size Lisanslı Haklar verilir ve Lisans Veren, Lisans Veren'in Lisanslı Materyali kullanıma sunmaktan elde ettiği faydalar karşılığında Size bu hakları verir.

K-Fold Cross Validation ile Test ve Train olarak verinin düzenlenmesi:

K-Fold Cross Validation tekniği ile veri setinin Python dili ile eğitim ve test olarak ayrıştırılması işlemi aşağıdaki gibidir. Görüldüğü gibi validation için ayrılan değerler veri seti üzerinden rastgele belirli bloklar şeklinde çekilmektedir.

```
<sklearn.model_selection._split.RepeatedKFold object at 0x0000023354136588>
Train: [ 0  1  2 ... 5012 5013 5014] Validation: [ 22  31  74  93
 177 179 183 215 216 229 231 245 262 263 289 305 318 322
 329 330 337 353 355 374 376 382 387 404 417 433 437 442
 456 457 463 467 469 472 473 477 487 490 495 498 499 503
 512 524 536 539 553 556 560 563 571 586 596 603 605 610
 612 633 636 654 655 661 662 664 673 674 677 687 722 724
 738 745 749 751 774 798 809 816 822 836 849 851 857 869
 895 903 907 911 912 953 956 966 978 983 990 991 1007 1022
1023 1034 1041 1043 1045 1048 1062 1069 1085 1095 1141 1148 1149 1162]
[6] TODO [6] Terminal [6] Python Console
```

ÖZGEÇMİŞ

