

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



PHYTON ÜZERİNDEN DERİN ÖĞRENME
ALGORİTMALARI KULLANILARAK DERİ
GÖRÜNTÜSÜNDEN CİLT HASTALIKLARININ TESPİT
EDİLMESİ

YÜKSEK LİSANS TEZİ

KAAN ONUR KOÇ

BOLU, KASIM - 2019

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



PYTHON ÜZERİNDEN DERİN ÖĞRENME
ALGORİTMALARI KULLANILARAK DERİ
GÖRÜNTÜSÜNDEN CİLT HASTALIKLARININ TESPİT
EDİLMESİ

YÜKSEK LİSANS TEZİ

KAAN ONUR KOÇ

BOLU, KASIM - 2019

KABUL VE ONAY SAYFASI

Kaan Onur KOÇ tarafından hazırlanan “PHYTON üzerinden derin öğrenme algoritmaları kullanılarak deri görüntüsünden cilt hastalıklarının tespit edilmesi” adlı tez çalışması **Elektrik Elektronik Mühendisliği Anabilim Dalı'nda** 27.11.2019 tarihinde savunularak **Bolu Abant İzzet Baysal Üniversitesi Fen Bilimleri Enstitüsü** Yüksek Lisans Tezi olarak kabul edilmiştir.

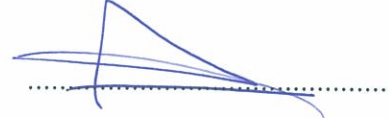
Jüri Üyeleri

Danışman
Prof. Dr. Kemal POLAT
Bolu Abant İzzet Baysal Üniversitesi

Üye
Dr. Öğr. Üyesi Rıfki Terzioğlu
Bolu Abant İzzet Baysal Üniversitesi

Üye
Dr. Öğr. Üyesi Murat PEKER
Ömer Halis Demir Üniversitesi

İmza



Prof. Dr. Ömer ÖZYURT 

Fen Bilimleri Enstitüsü Müdürü



Aileme..

ETİK BEYAN

Abant İzzet Baysal Üniversitesi, Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Kaan Onur KOÇ



ÖZET

**PYTHON ÜZERİNDEN DERİN ÖĞRENME ALGORİTMALARI
KULLANILARAK DERİ GÖRÜNTÜSÜNDEN CİLT HASTALIKLARININ
TESPİT EDİLMESİ
YÜKSEK LİSANS TEZİ
KAAN ONUR KOÇ
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: PROF. DR. KEMAL POLAT)**

BOLU, KASIM - 2019

Dünya çapında veri depolama, işleme ve anlamlandırma çalışmaları sektör fark etmeksizin hayati önem taşımaya başladı. Bu durum görselliğe dayalı yeni teknolojik düzeninde önemli bir parçası haline gelmiştir.

Görüntü işleme çalışmaları gelişen donanım ve artan internet hızı ile birlikte kompleks, detaylı ve daha modernize yapıların oluşmasına zemin hazırlamıştır. Fotoğraf ve video görüntülerinde kalitenin artması görsel dünyadan farklı birçok alanda tespit yapabilmemize olanak tanımaktadır. Siber güvenlik, finans, istatistik, savunma sanayi ve sağlık gibi birçok kapsamlı alanda görseller toplanıp işlenerek belirlenen amaçlar doğrultusunda teşhis, tespit ve çıkarım yapılabilmektedir.

Bunun günümüzdeki en etkili ve hızlı yolu ise büyük veri kümeleri için kullanılan derin öğrenme yöntemleridir. Çoklu miktardaki verileri paralel işleme yöntemi ile test edip, sınıflandırıp kendi kendine öğrenen ve yetebilen platformalar oluşturulmaktadır.

Sağlık sektörü de uzun yıllardır makine öğrenesi vb. yöntemlerle alanında uzman kişilere alternatif yöntemler geliştirilmeye çalışılmaktadır. Bu kapsamda önemli ölçüde başarılı çalışmalar yapılmıştır. Özellikle görüntüler üzerinde yapılan çalışmalar kendini fazlaca göstermektedir bunlardan bir tanesi de cilt kanseri teşhisi için değerlendirilen deri görüntüleridir. Cilt kanseri dünya çapında nüfusa oranla ciddi rakamlarda görülmektedir. Erken teşhis yüzdesi yüksek bir hastalığın tedavisinde önemli rol oynamaktadır. Çalışma deri kanserine erken teşhis için başarılı ve kolay bir alternatifi temsil etmektedir. Görüntü işleme yöntemleri bu kapsamda oldukça etkili olmaktadır. Fakat artan görüntü boyutlarının yanı sıra artan veri miktarı ve kendi kendine öğrenebilen yapıların varlığı ile derin öğrenme yöntemleri daha fazla ön plana çıkmaktadır.

Bu yapıları oluştururken kullanılan en yaygın yöntemlerden birisi Evrişsel Sinir Ağı- ESA (CNN- Convolutional Neural Network) dir. Bu yapı, incelenmek istenen verilerin sınıflandırılması için kullanılan en etkili yöntemlerden birisidir.

Yapılan çalışmada ESA yapısı kullanılıp farklı katmanlarla deri lezyonlarının teşhisi yapılmıştır.

ANAHTAR KELİMELELER: Derin Öğrenme, Cilt Kanseri, Evrişsel Sinir Ağı, Yapay Sinir Ağları, Görüntü İşleme

ABSTRACT

DETECTION OF SKIN DISEASES FROM SKIN IMAGE BY USING DEEP LEARNING ALGORITHMS IN PYTHON

MSC THESIS

KAAN ONUR KOÇ

**BOLU ABANT IZZET BAYSAL UNIVERSITY GRADUATE SCHOOL OF
NATURAL AND APPLIED SCIENCES
DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
(SUPERVISOR: PROF.DR. KEMAL POLAT)**

BOLU, NOVEMBER 2019

Worldwide data storage, processing, and interpretation work are becoming vital regardless of the industry. This has become an important part of the new technological scheme based on visuality.

With the developing hardware and the increasing speed of the internet, image processing works prepared the basis for the formation of complex, detailed and modernized structures. Increasing the quality of photographic and video images allows us to make a determination in many different areas from the visual world. In many fields such as cybersecurity, finance, statistics, defense industry, and health, visuals can be collected and processed for diagnosis, determination, and inference.

The most effective and fastest way to do this is by using deep learning methods for large data sets. Tests classify and self-learning platforms are created by parallel processing method.

The health sector has been teaching machine learning and so on for many years. alternative methods to the experts in the field are tried to be developed. In this context, significant successful studies have been conducted. In particular, studies on the images show a lot of them, one of which is the skin images evaluated for the diagnosis of skin cancer. Skin cancer is seen in serious numbers compared to the worldwide population. Early detection plays an important role in the treatment of a high percentage of the disease. The study represents a successful and easy alternative to early detection of skin cancer. Image processing methods are very effective in this context. However, in addition to the increasing image sizes, the increasing amount of data and the presence of self-learning structures, deeper learning methods become more prominent.

One of the most common methods of constructing these structures is the Convolutional Neural Network (ESA). This structure is one of the most effective methods used to classify the data to be examined.

In this study, the skin lesions were diagnosed with different layers using the ESA structure.

KEYWORDS: Deep Learning, Skin Cancer, Convolutional Neural Network, Artificial Neural Networks, Image Processing.

İÇİNDEKİLER

Sayfa

ÖZET	V
ABSTRACT	VI
İÇİNDEKİLER	Vii
ŞEKİL LİSTESİ	viii
ÇİZELGE LİSTESİ	ix
KISALTMA VE SEMBOLLER LİSTESİ	X
TEŞEKKÜR	XI
1. GİRİŞ	1
1.1 Giriş ve Amaç	1
1.2 Python Yapısı	3
1.3 Tensor Flow Yapısı	5
1.4 Çalışmanın İçeriği	5
2. İLGİLİ ÇALIŞMALAR	7
3. MATERYAL VE YÖNTEM	10
3.1 Veri Kümesi	10
3.2 Yöntem	12
3.3 Derin ve Evrişimsel Sinir Ağları	13
3.4 2 Boyutlu Evrişim	14
3.4.1 Piksel Ekleme	14
3.4.2 Kaydırma Adımı	15
3.4.3 Ortaklama	16
3.4.4 Yığın Normalizasyon	16
3.4.5 Bırakma	17
3.5 Yapay Sinir Ağı	18
4. ÖNERİLEN MODELLER	20
4.1 Evrişimsel Sinir Ağı Yapısı Modeli – 1	20
4.2 Evrişimsel Sinir Ağı Yapısı Modeli – 2	21
4.3 Veri Çoğaltma (Data Augmentation)	22
4.4 Ağın Eğitimi	25
4.5 Sınıflayıcı Performans Ölçütleri	25
5. BULGULAR VE TARTIŞMA	28
6. SONUÇ VE ÖNERİLER	36
7. KAYNAKLAR	37
8. ÖZGEÇMİŞ	40

ŞEKİL LİSTESİ

Sayfa

Şekil 3.1. Yöntem 1 evrişimsel ağ akış diyagramı.....	12
Şekil 3.2. Yöntem 2 evrişimsel ağ akış diyagramı.....	13
Şekil 3.3. Örnek 2 boyutlu evrişim işlemi.....	14
Şekil 3.4. Piksel ekleme işlemi sonrası 2B evrişim işlemi.....	15
Şekil 3.5. En büyük değer ortaklama.....	16
Şekil 3.6. Bırakma yapısı (Nitish Srivastava, 2014).....	17
Şekil 3.7. Temel sinir hücre modeli (cs231n.stanford.edu).....	19
Şekil 4.1. Önerilen ağ yapısı modeli-1.....	20
Şekil 4.2. Önerilen ağ yapısı modeli-2.....	21
Şekil 4.3. Veri kümesi örneği: akiec (Tschandl, Philipp, 2018).....	23
Şekil 4.4. Veri kümesi örneği: bcc (Tschandl, Philipp, 2018).....	23
Şekil 4.5. Veri kümesi örneği: bkl (Tschandl, Philipp, 2018).....	23
Şekil 4.6. Veri kümesi örneği: df (Tschandl, Philipp, 2018).....	23
Şekil 4.7. Veri kümesi örneği: mel (Tschandl, Philipp, 2018).....	24
Şekil 4.8. Veri kümesi örneği: nv (Tschandl, Philipp, 2018).....	24
Şekil 4.9. Veri kümesi örneği: vasc (Tschandl, Philipp, 2018).....	24
Şekil 5.1. Birinci ağa ait kayıp değer ve başarımlar grafiği.....	30
Şekil 5.2. İkinci ağa ait kayıp değer ve başarımlar grafiği. (akiec).....	30
Şekil 5.3. Birinci ağa ait kayıp değer ve başarımlar grafiği. (bcc).....	31
Şekil 5.4. Birinci ağa ait kayıp değer ve başarımlar grafiği. (bkl).....	31
Şekil 5.5. Birinci ağa ait kayıp değer ve başarımlar grafiği. (df).....	32
Şekil 5.6. Birinci ağa ait kayıp değer ve başarımlar grafiği. (mel).....	32
Şekil 5.7. Birinci ağa ait kayıp değer ve başarımlar grafiği. (nv).....	33
Şekil 5.8. Birinci ağa ait kayıp değer ve başarımlar grafiği. (vasc).....	33
Şekil 5.9. Birinci ağın test veri kümesi karmaşıklık matrisi.....	34
Şekil 5.10. Birinci ağın her bir sınıfın tespitinde elde ettiği hata oranları.....	35

ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1. TIOBE 2019 programlama dilleri derecelendirme listesi	4
Çizelge 3.1. Eğitimde kullanılan veri kümelerinde yer alan görüntü sayıları.	11
Çizelge 4.1. Çoğaltma sonrası veri sayısı.....	22
Çizelge 4.2. Karmaşıklık Matrisi	26
Çizelge 5.1. Birinci ağıın her bir sınıfa ait performans göstergeleri.....	28
Çizelge 5.2. İkinci ağıın her bir sınıfa ait performans göstergeleri.....	29
Çizelge 5.3. İkinci Ağıın Literatür ile Karşılaştırması 1 Vs All).....	36



KISALTMA VE SEMBOLLER LİSTESİ

AKIEC	: Actinic keratoses and intraepithelial carcinoma
BCC	: Basal cell carcinoma
BKL	: Benign keratosis
BV	: Büyük Veri (Big Data – BD)
ConvNet	: Evrişimsel Sinir Ağı (Convolutional Neural Network)
DF	: Dermatofibroma
DVM	: Destek Vektör Makinesi (Support Vector Machine – SVM)
ESA	: Evrişimsel Sinir Ağı (Convolutional Neural Network – CNN)
FCN	: Tamamen Evrişimsel Ağ (Fully Convolutional Network)
GİÜ	: Grafik İşleme Ünitesi (Graphics Processing Unit – GPU)
GN	: Gerçek Pozitif (True Negative- TN)
GP	: Gerçek Pozitif (True Positive- TP)
KM	: Karmaşıklık Matrisi (Confusion Matrix- CM)
MEL	: Melanoma
NV	: Melanocytic nevi
SD	: Sınıflandırma Doğruluğu (Classification Accuracy- CA)
VASC	: Vascular lesions
YN	: Yanlış Negatif (False Negative - FN)
YP	: Yanlış Pozitif (False Positive - FP)
YSA	: Yapay Sinir Ağları (Artificial Neural Network - ANN)
2B	: İki Boyut (two Dimension – 2D)

TEŐEKKÜR

Lisans üstü eğitimin boyunca;

Eđitime bařladıđım ilk günden bu yana gerek akademik gerek hayat tecrübesi anlamında birikimlerini ve bilgisini benimle paylaşıp birçok konuda bana destek olan değerli hocam Prof. Dr. Kemal POLAT'a,

Sadece akademik alanda deđil hayatın her kademesinde bana sürekli destek olan zor zamanlarımda sabır gösterip her daim inançları ile güç veren aileme

Teőekkür ederim.



1. GİRİŞ

1.1 Giriş ve Amaç

Dijitalleşen dünyanın getirdiği gereksinimlerden olan yaygınlaşan internet kullanımı ile birlikte hayatımıza dâhil olan veri akışı Büyük Veri - BV (Big Data -BD) kavramını ortaya çıkardı. Büyük miktardaki veri kümeleri dijital ortamlarda oluşturulup depolanacak hale getirilmiştir.

Derin öğrenme altyapısı, özellikle büyük miktardaki verileri işleme, tıbbi görüntü analizi, veri madenciliği ve bunun gibi çeşitli alanlarda önemli ilerlemeler kat edilmesine olanak tanımıştır.

Bahsi geçen konudaki araştırmaların patlamasına neden olan etken ise CNN yapısının kullanım yaygınlığının artmasına dayanmaktadır. Elde edilen sonuçlarla gelecekte profesyonel anlamda birçok meslek grubunun performansına rakip olacak bulgular oluşturmuştur.

Derin öğrenmenin en büyük yararı, ciddi miktarlarda denetimsiz verinin analizi ve öğrenilmesidir. Bu olay, anlamlandırılması düşünülen veri kümelerinin analizi için süreci hızlandıran önemli bir yapıdadır.

Bu yapılar, tasarlanmış kademeli hiyerarşik bir öğrenme süreci boyunca algoritmalar ile veri sunumları olarak üst düzey ve karmaşık soyutlamalar çıkartmaktadır.

Karmaşık soyutlamalar; bu kompleks yapıları daha basite indirilmiş halde ki veriler halinde planlanan bir seviyede öğrenilir ve aynı zamanda sistemi performanslı kılmaktadır.

Performanslı sistemler ise Big Data kavramı ile görüntü işleme adı altında farklı birçok sektöre öncülük edecek başarılar elde etmektedir. Sadece teşhis koyarken

bile her yıl global anlamda milyarlarca dolar harcanan sađlık sekt6r6 de bu alandaki 7alıřmaların odak noktalarından birisi haline gelmiřtir.

Uzun yıllar boyunca dermoskopik alandaki benzer metodolojilerin kullanımı k6resel anlamda ekonomik ve halk sađlıđı problemini besleyerek b6y6tm6řt6r. Geride bıraktıđımız 30 yıla bakıldıđında deri kanserindeki vakaların ciddi miktarda arttıđı g6r6lmektedir (American Cancer Society 2018) bu olduk7a can sıkıcı bir durum ayrıca muhasebeleřtirilmesi gereken bir konudur 76nk6 deri lezyonları d6nya 7apında rastlanan en yaygın hastalıklar arasında g6sterilmektedir. (D.R Bickers vd, 2016)

Deri lezyonları d6nyanın farklı yerlerinde; yař aralıđı, etnik k6ken farketmeksizin 6lkelerde pop6lasyon bazında insanların %30 ila %70'inde g6r6lmektedir.

Bu herhangi bir zamanda en az her 3 kiřiden 1'inin cilt rahatsızlıđına yakalanabileceđini g6stermektedir. 6te yandan iřin can sıkan bařka bir boyutu ise yapılan milyonlarca dolar kamu harcaması ile sekt6rde para denklemi kısmında meydana gelmiřtir.

Harcanan bu paraların b6y6k bir kısmı ise alanında uzman bir dermatolođun hasta 6zerinden belirli bir b6lgede elde ettiđi ufak kanıtların analizi 6zerine yapılmaktadır.

Tanı konusunda yapılan bu adımlardan herhangi birinin belirli iyileřtirmeler ile deđiřtirilmesi sekt6re yapılan harcamalarda ciddi anlamda d6ř6ř yařanması anlamına gelmiřtir.

Bu durum konuya olan ilginin artmasıyla birlikte eđitilmiş bir dermatolođa lezyon tanısı vb konularda rakip olacak sistemlerin geliřmesinin en b6y6k sebeplerinden birisi olarak g6sterilebilmektedir.

Haliyle derin 6đrenme y6ntemleri deri lezyon g6r6nt6leri ile k6resel 7apta bir probleme ıřık tutmak i7in ger7ekten etkili bir y6ntemdir. Ciddi miktardaki verileri geliřmiř Grafik iřleme 6nitesi – GI6 (Graphics Processing Unit – GPU) yardımı ile kısa s6re i7erisinde analiz edip, sınıflandırıp, arttırılmış bařarı oranları ile tanımlamaktadır.

Problem elde edilen görüntülerin miktar ve kalitesine bağılı kalmaksızın başarılı sonuçlar elde edilebilmesine dayanmaktadır. Bunun yanında deri lezyon sınıfının çeşitliliği de önemli bir parametre oluşturuyor yani kanserli, kötü huylu ya da sağlıklı görüntüleri analiz ederken ne kadar farklı hastalık türü tespit edilirse probleme yapılacak katkıda o kadar fazla olacaktır.

İşlenecek veri kümesindeki görüntü sayısının fazla olması yapılan çalışmasının yetkinliğine pozitif bir etki yapsa da tasarlanan sistemin hızını için dezavantaj oluşturabilmektedir. Bunun için büyük boyutlara sahip GIÜ ve bellek gerekmektedir.

Gonzales RC (2018) Bu çalışma klasik makine öğrenmesi metodları dışında derin öğrenme alanında, CNN yapısını kullanarak çok sayıda dermoskopik görüntüden kanserli olanları tespit etmek için etkili bir yöntem ortaya koymaya çalışmaktadır.

TensorFlow üzerinde geliştirilen bu çalışma kısa süre içerisinde veri kümesini segmente edip, sınıflandırıp, tanımlarını koyma amacı ile yapılmıştır.

1.2 Python Yapısı

Mühendislik ve bilimin birçok dalında kullanılan programlama dillerinin arasında Python kullanımı avantajlı ve doğru bir tercih olarak görülmektedir. Çalışmanın amacı ve detaylarına girmeden önce Python programlama dilinin geçmişine, tarihine ve avantajlarına değinilecektir.

Python'un en iyi web uygulamaları geliştirmede yada yapay zeka çalışmalarında fazla tercih edilme nedenlerine göz atarken dikkat edilmesi gereken şey Python'un ne olduğudur?

1990'da C programlama dilinde bir e-posta uygulaması yazmaya çalışan Guido van Rossum, e-posta uygulamasında henüz giriş yapma ve şifreleri yönetmek için mevcut sistemler bulunmadığından dolayı bir oturum açma programı hazırlarken birtakım zorluklarla karşılaştı. Bu giriş programını C'de çok fazla yazacağını ve elverişsiz olacağını düşünen van Rossum Python fikrini ortaya koymuştur.

Pratikte ilk olarak 1991 yılında tanıtılan Python (Belkin Malkoç, 2012) programlama dillerinin popülaritesini değerlendirip inceleyen TIOBE platformuna göre 2019'da dahil olmak üzere son yıllarda en sevilen diller arasında yer aldı. Tablo 1.1 de listelenmiştir. Platform bu sonuca ulaşmak için programlama dilinde çalışmalar yapan mühendis sayılarını, arama motorlarındaki arama sıklıklarını ve hakkındaki verilen dersler gibi indekslerden yararlanılmıştır.

Çizelge 1.1. Tiobre 2019 programlama dilleri derecelendirme listesi

Ekim 2019	Programlama Dili	Derecelendirme
1	Java	%16.884
2	C	%16.180
3	Phyton	%9.089
4	C++	%6.229
5	C#	%3.860
6	Visual Basic .NET	%3.745
7	Java Script	%2.076
8	SQL	%1.935

Yorumlanmış bir dil olarak Python donanım belleğini verimli kullanır, hata ayıklaması kolaydır ve geliştiricilerin birkaç adımda karmaşık görevleri gerçekleştirmelerine ve kodları hızlıca düzenlemelerine olanak tanımaktadır.

Python'ın da aralarında olduğu çoğu modern programlama dili nesne yönelimli olarak kabul edilir. Nesne yönelimli programlama dillerinin arkasındaki mantalite, programın kendi içinde iletişim kuran bağımsız nesnelere bölünmesiyle açıklanmaktadır. Bu hemen hemen mini programlar koleksiyonuna benziyor. Nesnelere, yazılım geliştiricilerinin daha iyi dizayn edilmiş kodlar yazmasına yardımcı olmaktadır; bu durum yazılımın oluşturulması, bakımı ve hata ayıklaması için daha kolay ve daha hızlıdır.

Python dinamik bir programlama dilidir. Bu, geliştiricilerin değişken türlerini beyan etmek zorunda olmadıkları anlamına gelir. Python, çalışma zamanında

(program başlatıldığında), ancak derleme sırasında (kaynak kod makine koduna dönüştürüldüğünde) türleri ve hataları doğrular. Bu, daha az kod, daha hızlı gelişme ve daha fazla esneklik sağlamaktadır.

1.3 TensorFlow Yapısı

Makine öğrenmesi yöntemleri oldukça karmaşık yapıda olabilmektedir. Eskiden kullanılan yöntemler göz önüne alındığında kullanım kolaylığı açısından Google'ın Tensor Flow vb. platformları sayesinde sürecin önceye nazaran ne kadar zorlayıcı olduğu ortaya konulmuştur.

Google imzalı bir platform olan TensorFlow, büyük ölçekli verilerin işlenmesi, sayısal hesaplamalar ve makine öğrenmesi yöntemleri için kullanılan pratik açık kaynak bir kütüphanedir. (Tensorflow.org, 2015)

TensorFlow bir dizi makine öğrenmesi ve derin öğrenme algoritmalarını bir araya getirerek ortak bir çatı altında kullanabilmeye olanak tanımaktadır.

TensorFlow; el yazısı tanıma, sınıflandırma, görüntü tanıma, sözcük yerleştirme, tekrarlayan sinir ağları, doğal dil işleme, karmaşık denklemler çözme, yapay sinir ağları tasarlama, eğitime ve tahminde bulunma v.b. aktiviteler için çok tercih edilen bir platform haline gelmiştir.

1.4 Çalışmanın İçeriği

Bu çalışma klasik makine öğrenmesi metodları dışında derin öğrenme alanında, CNN yapısını kullanarak çok sayıda dermoskopik görüntüden kanserli olanları tespit etmek için etkili bir yöntem ortaya koymaya çalışmaktadır.

TensorFlow üzerinde geliştirilen bu çalışma kısa süre içerisinde veri kümesini segmente edip, sınıflandırıp, tanımlarını koyma amacı ile yapılmıştır.

İki farklı ağ yapısı önerilmiş olup devam eden kısımlarda ağ yapılarının başarımlarına ve elde edilen bulgulara değinilmiştir. Çalışmada literatürde daha önce

konu ile ilgili yapılmış araştırma, tez, kaynaklara ilgili çalışmalar başlığı altında yer verilmiştir.

Materyal ve yöntem kısmında tez çalışmasında kullanılan veri kümesi hakkında bilgilendirme yapılmıştır devamında önerilen ağ yapıları hakkında alkış şemaları ile birlikte bilgi verilip CNN yapısının nasıl çalıştığı kısmına adım adım yer verilmiştir.

Önerilen modeller kısmında tasarlanan iki farklı ağ yapısının detaylarına yer verilmiştir. Tasarlanmış ağ yapıları örnek görsellerle desteklenmiş olup başarı kriterleri için değerlendirilen sınıflayıcı performans ölçütleri, ağı eğitimi, veri çoğaltma işlemleri ile ilgili bilgiler ortaya konulmuştur.

Devamında bulgular ve tartışma başlığı altında önerilen iki yöntemin listelenmiş başarı kriterleri grafiklerine yer verilmiş olup literatürdeki çalışmaların sonuçları ile karşılaştırılmıştır.

Sonuç ve öneriler kısmında tasarlanan yapıların literatüre kattığı kullanım kolaylığı ve önerilen katmanlı yapıların avantajları ortaya konulmuştur.

2. İLGİLİ ÇALIŞMALAR

Jain V vd. (2007), Sermanet. P vd. (2014) Görüntü işlemede CNN yapısı farklı veri tabanlarını kullanarak trafik, siber güvenlik, biyolojik görüntü işleme, finans vb sektörlerde geniş kullanım alanları sunmaktadır. Yalnızca görüntü üzerinde özellik çıkarımı ve sınıflandırmanın yanı sıra görseller üzerindeki farklı nesnelere konumlarının tespiti ve ayrımı da oldukça başarılı sonuçlar vermeye başlamıştır.

Shelhamer E. vd. (2017) Çalışmada Evrişimli Sinir Ağlarının kullanım çeşitliliği ve semantik bölütleme, FCN (Fully Convolutional Network) yapısının kullanım avantajlarına değinilmiştir. FCN ve semantik bölütleme ile nesne tanımlarının yanı sıra görselde yer alan farklı nesnelere konumları da tespit edilebilmektedir.

CNN yapısı altında bir özelleşmiş model olarak nitelendirilebilecek yapı ağı sokulacak verinin giriş ve çıkış ebatlarının aynı olması ve ayrıştırılması planlanan sınıf sayısı kadar kanal sayısına sahip bir matris ile gerçekleştirilebilmektedir.

Alper Arık vd, (2017) yaptığı çalışmada deri lezyonuna ait bir takım renkli görüntülerden cilt kanseri melanoma teşhisi yapılmıştır. Önerilen bu yöntemde görüntü işleme sürecinde genelde yaygın kullanılan ön işleme yöntemleri atlanarak direkt olarak sınıflandırma yapmanın da doğru veriler ortaya koyabileceği gerçekleştirilmiştir.

Zhen Ma vd , (2017) deri lezyonu tespiti için ortaya koydukları çalışmada bir veri tabanı için tasarlanan yapının başka bir veri tabanı üzerinde de aynı sonuçların alınamayabileceğini göstermiştir. Etkili melanoma teşhisi hedefiyle farklı bir saptama amacı güden ekip birbirinden farklı 3 veri tabanı için çeşitli görüntüleme durumlarını elde etmiş ve objektif temel oluşturulmuştur. Elde edilen veriler ortaya konan sonuçların birleştirilmesi ile daha sağlıklı teşhis yapıldığını göstermektedir.

Ortaya konan bu kompleks mimarinin eğitimli bir dermatoloğa rakip olabilecek sonuçlar elde edebileceği belirtilmiştir.

Muhammed A.Al-masni vd, (2018) deri lezyonu üzerinde yaptıkları çalışmada melanomanın erken teşhisi üzerine yoğunlaşmışlar. Çalışmada klasik kullanımların dışında tam çözünürlüklü evrişimli ağ (FrCN) kullanılmıştır. Yapı mevcut data kümesindeki lezyon görüntülerinin aynı standartta, boyutta ve sınırlarda olmaması ve otomatik segmentasyonu zora sokan problemler sonucu denenmiştir.

Yöntem görüntü bazında her bir pikselin segmentasyonunda ciddi performans iyileşmesine neden olmuştur. Elde edilen veriler FrCN metodunun klasik yöntemlere göre daha performanslı olduğunu ortaya koymuştur.

Harangi, B (2018) yaptığı çalışmada veri setlerindeki çeşitliliklerdeki eksiklerden dolayı farklı CNN algoritmalarının birleştirilmesi ile deri kanserinin sınıflandırılması üzerine çalışmıştır. Kullanıma göre özelleştirilebilen sistem sayesinde hastalar akıllı telefonlar ile tespit yapabilmektedir. Ek CNN algoritmaları kullanılarak genişletilebilen sistem sürekli yenilenebildiği için başarısı artmaktadır. Oluşturulan sistem amaca uygun adapte edildiği takdirde sistemin yüksek riskli hastalıkları tespiti kolaylaşmaktadır.

Gonzales RC (2018) yayınlanan çalışmasında derin ve Evrişimsel Sinir Ağlarının (ESA) klasik makine öğrenmesi yöntemlerine ne gibi avantajlar sağladığını ele almıştır. Evrişimsel Sinir Ağlarının büyük bir veri kümesinde özellik çıkarımı ve eğimi ve sınıflandırılması ortaya konmuştur. Ayrıca Evrişimsel Sinir Ağlarının sektörde ki kullanım alanının çeşitliliğine değinilmiştir.

Amirezza Ahmod vd, (2019) tarafından yapılan çalışma deri lezyonuna ait görüntülerin ön işleme, yapay sinir ağlarının tasarlanıp hibrit bir yapı haline getirilmesi, Destek Vektör Makinesi - DVM (SVM - Support Vector Machine) sınıflayıcısını eğiterek sonuçları toplamasını kapsıyor. ISIC 2016 ve ISIC 2017 verileri ile birlikte eğitim için 2187 görüntü kullanılmış. Farklı piksel boyutlarındaki görseller derlenerek standart hale getirilmiş. (227x227 ve 224x224 piksel) Yaklaşım ile birlikte birden fazla ağ yapısı birleştirilerek hibrit bir yapı oluşturulmuştur.

Bahsi geçen kompleks yapı çekirdekte farklı temeldeki mimariler ile oluşturulmuş ağların bir bütünü olarak herhangi katman ya da fazladan eğitim gerektirmeden daha elverişli sonuçlar vermektedir.

Detayda kompleks modelleme 18 farklı mimarinin birleşmesi ile elde edilmiş olup bu yapı ayrı ayrı her modelin sonucunun ortalaması alınarak farklı tek bir modele göre daha iyi sonuç verdiğini ortaya koymaktadır. Bunun temel nedeni ise hibrit yapıyı oluşturan farklı ağların (ResNet-101, ResNet18 ve AlexNet vb) birbirlerini tamamlayıcı etkiler oluşturduğu şeklinde yorumlanmıştır.

Semantik bölütleme ie ConvNet (Convolutional Neural Network) tabanlı segmentasyon yöntemleri oldukça başarılı sonuçlar veriyor. Temelde nesne konum tanımlamasında sınıflandırma esnasında kullanılan pencerenin merkez pikseli nesnelerin sınırlarını tayin edip eğitimde kullanılmaktadır.

Yöntem; CNN yapısını kullanarak pencere içinde görüntünün merkezindeki pikselin karar mekanizmasında kullanılıp kategorizasyon için sınıflandırılıp eğitilmesinde kullanılması şekilde özetlenebilir.

3. MATERİYAL VE YÖNTEM

3.1 Veri Kümesi

Bu tez kapsamında HAM10000 (Tschandl, Philipp, 2018) veri kümesi kullanılmıştır. Farklı popülasyonda pigmentli lezyonlar içerir. Bu veri kümesi toplamda 10015 adet görüntüden oluşmaktadır. Görüntü boyutları ağ girişini küçültmek ve ağ parametre sayısını azaltmak için 150x200 piksel boyutuna ölçeklenmiştir. Bu veri kümesinde yer alan teşhis sınıfları;

1. Actinic keratoses and intraepithelial carcinoma - akiec
2. Basal cell carcinoma - bcc
3. Benign keratosis - bkl
4. Dermatofibroma - df
5. Melanoma -mel
6. Melanocytic nevi – nv
7. Vascular lesions – vasc

olarak verilmiştir. Veri kümesinde yer alan her bir görüntü için hangi sınıfa ait olduğu bilgisi de veri kümesi ile birlikte sağlanmıştır.

Eğitimlerde kullanmak üzere veri kümesi eğitim, doğrulama ve test olmak üzere sırasıyla %75, %5 ve %20 oranlarına tüm veri kümesinden elde edilmiştir. Her bir kümenin kaç adet veri içerdiğini belirten veriler Tablo 4.1’de listelenmiştir.


Çizelge 3.2. Eğitimde kullanılan veri kümelerinde yer alan görüntü sayıları.

Teşhis Sınıfı	Eğitim	Doğrulama	Test
1	243	17	67
2	386	25	103
3	814	59	225
4	79	9	27
5	844	52	217
6	5034	328	1343
7	111	10	21
Toplam	7511	500	2003

Tabloda da görüleceği üzere veri kümesinde yer alan verilerin çoğu altıncı sınıfa aittir ve sınıflar arası eşit bir dağılım bulunmamaktadır. Bu eğitim aşamasında 6. sınıfın daha çok öğrenilmesine ve ağırlıklı olarak bu bilgileri öğrenerek bu sınıf ağırlıklı öğrenmesine yol açacaktır. Bu problemin üstesinden gelebilmek için Eğitim kümesinde yer alan görüntü sayıları veri çoğaltma yöntemi kullanılarak artırılmıştır. (Test kısmında yer alan görüntü sayıları veri çoğaltma yapılmamış görüntü sayılarıdır.) Sonuç olarak elde edilen eğitim kümesi 10015 adet görüntü içermektedir. Veri kümesinde yer alan görüntülerden bazı örnekler Şekil 4 dizisinde verilmiştir.

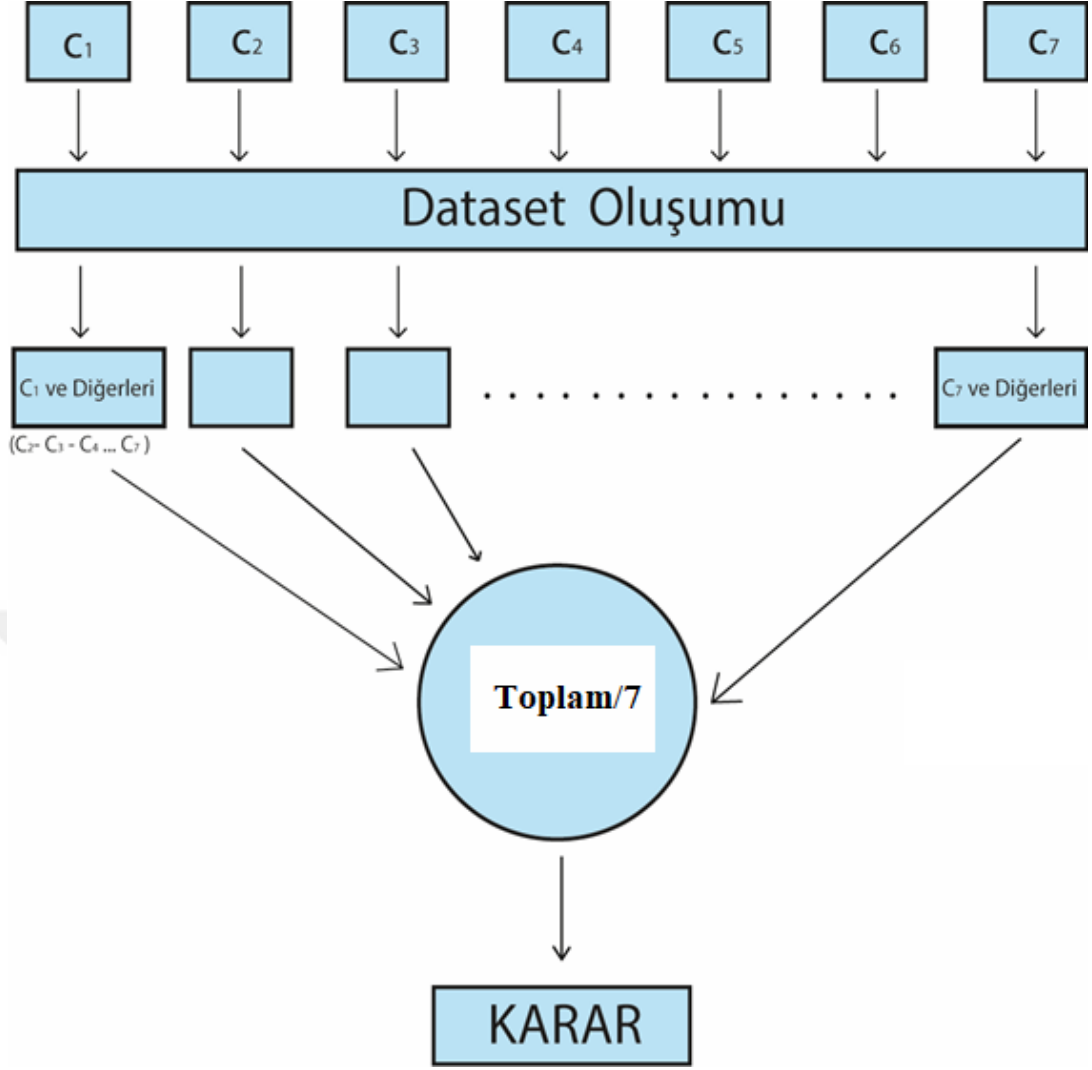
3.2 Yöntem

Birinci yöntem, evrişimsel ağ yapısı kullanılarak veri kümesinde yer alan görüntülerin çok sınıflı olarak sınıflandırılması için tasarlanmıştır. Bu yöntemde, giriş görüntüsü 0-1 arasına normalize edilmekte ardından tasarlanan CNN ağına giriş olarak uygulanmaktadır. CNN ağı çıkışında ise görüntünün hangi sınıfa ait olduğu bilgisi elde edilmektedir. Birinci yöntemin akış diyagramı Şekil 3.1’de verilmiştir.



Şekil 3.1. Yöntem 1 evrişimsel ağ akış diyagramı

İkinci yöntemde ise evrişimsel ağ yapısı bir sınıfın diğer tüm sınıflara karşı eğitilmesi ile elde edilmiştir. Olası tüm sınıflar için yeni ağ eğitimleri yapılmıştır. Toplamda yedi sınıf için yedi farklı ağ elde edilmiştir. Bu ağın girişi için de giriş görüntüsü 0-1 aralığına ölçeklenmiştir. İkinci yönteme ait akış diyagramı Şekil 3.2’de verilmiştir.



Şekil 3.2. Yöntem 2 evrişimsel ağ akış diyagramı

3.3 Derin ve Evrişimsel Sinir Ağları

Görüntü işleme uygulamalarında derin evrişimsel sinir ağlarının kullanılmaya başlanması ile birlikte birçok görüntü işleme problemimde yüksek başarıma sahip sonuçlar elde edilmeye başlanmıştır. (Gonzales RC 2018) Bu ağlar temel olarak evrişim ve sinir ağı olmak üzere iki farklı yapı içermektedir. Evrişimsel yapılar görüntü işleme tekniklerinin yeteneklerinin ağlar tarafından taklit edilmesini sağlarken, sinir ağları ise görüntülerden elde edilen bu verilerin anlamlandırılması için kullanılmaktadır. Sonraki alt bölümlerde bu yapılara değinilmiştir.

3.4 İki Boyutlu Evrişim

İki boyutlu (2B) evrişim, kolonlar ve sütunlardan oluşan bir şablon kullanılarak hesaplanmaktadır. Bu şablon, iki boyutlu görüntü üzerinde kaydırılarak bütün görüntü taranır. Her kayma adımı için görüntü ve şablon eleman elemana çarpılmakta ve bu değerler toplanarak elde edilen sonuç ilgili noktaya denk gelen piksele yazılarak yeni bir görüntü oluşturulmaktadır. Böylece görüntüde yer alan farklı frekanslara sahip bilgiler filtrenmektedir. Bu işleme örnek olarak Şekil 3.1’de bir giriş görüntüsüne uygulanan 3x3 şablon (çekirdek) ve çıkışta elde edilen sonuç gösterilmiştir.

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

Giriş Görüntüsü (5x5)

*

-1	-2	-1
0	0	0
1	2	1

3x3 Şablon
(Çekirdek)

=

0	2	3
-1	-1	0
1	0	-3

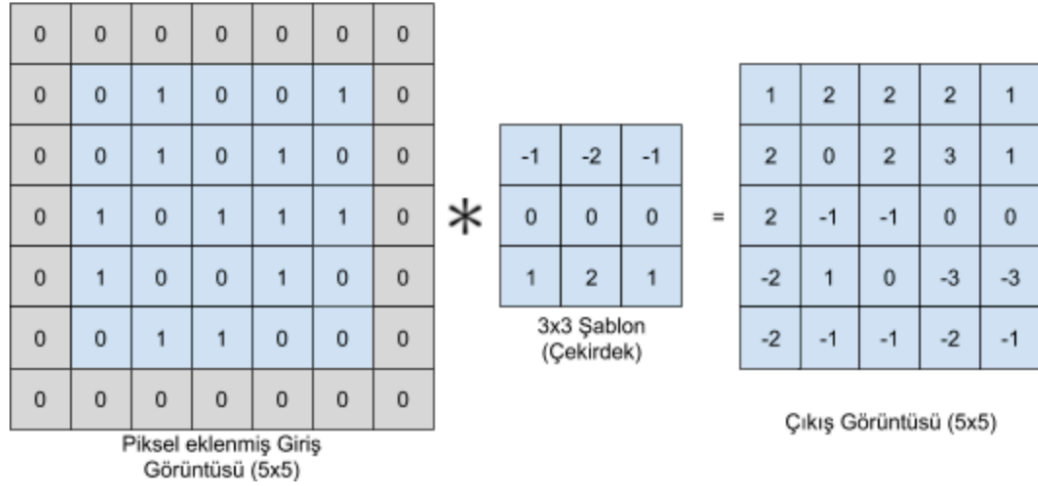
Çıkış Görüntüsü
(3x3)

Şekil 3.3. Örnek 2 boyutlu evrişim işlemi

Geleneksel görüntü işlemede, 2B evrişim kullanılarak kenar bulma, yumuşatma vb. gibi birçok ön işlem gerçekleştirilmektedir. Görüntü işlemenin temel işlemlerinden olduğundan derin ağlarda da öznitelik çıkarımı için kullanılmaktadır. 2B evrişim sonucunda elde edilen çıkış görüntüsünün boyutunu değiştirmek ve veriyi azaltmak gibi işlemler için kullanılabilen yöntemler alt bölümlerde incelenmiştir.

3.4.1 Piksel Ekleme

2B evrişim örneğinden görüldüğü üzere geçerli bir evrişim yapıldığı zaman giriş görüntüsü ile çıkış görüntüsü farklı boyutlara sahip olmaktadır. Çıkış görüntüsünün boyutunun değişmesi istenmediği zaman piksel ekleme işlemi uygulanarak çıkış görüntüsünün boyutu ayarlanabilmektedir. Şekil 3.2’de gösterilen örnek ile her kenara birer piksel eklendiği zaman elde edilen çıkış görüntüsü giriş görüntüsü ile aynı boyutta olmaktadır.



Şekil 3.4. Piksel ekleme işlemi sonrası 2B evrişim işlemi

Giriş görüntü boyutu $N \times N$, şablon boyutu ise $M \times M$ olması durumunda çıkış görüntü boyutu denklem (3.4.1.1) de görülmektedir.

$$(N + 2P - M + 1) * (N + 2P - M + 1) \quad (3.4.1.1)$$

ile hesaplanmaktadır. Burada P piksel ekleme değeridir. Eklenen piksel değerleri sıfır olabileceği gibi bir piksel komşuluktaki piksel değerinin kullanılması veya eklenen piksel kadar komşuluktaki piksellerin farklı biçimlerde birleştirilerek kullanılması mümkündür.

3.4.2 Kaydırma Adımı

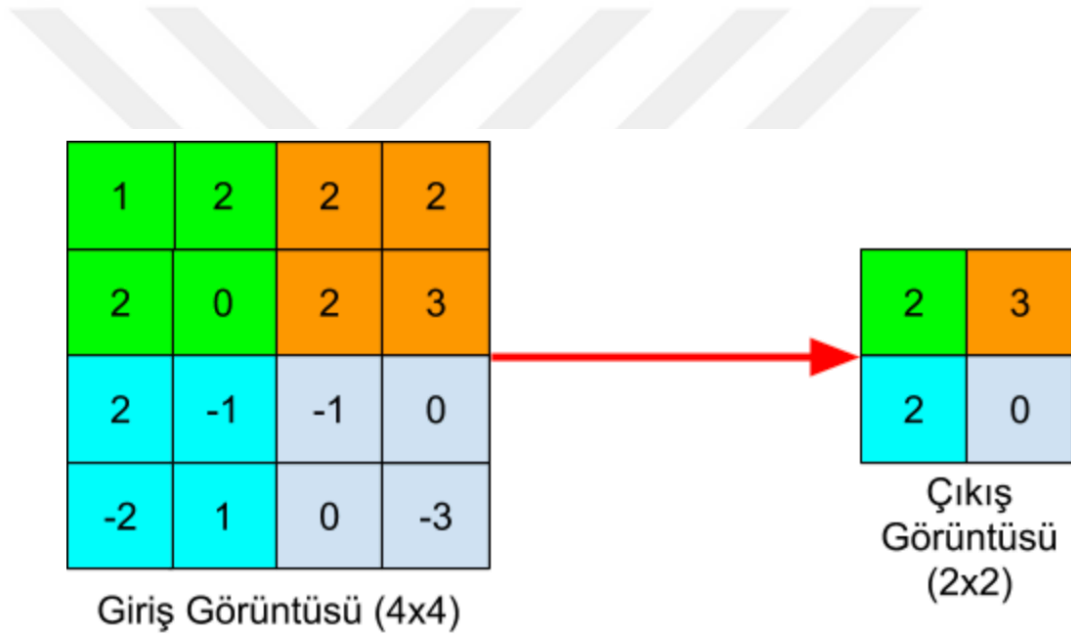
2B evrişim işleminde kullanılan bir diğer kontrol parametresi ise kaydırma adımdır. Bu değer ile evrişim için kullanılan birer piksel kaydırmalarının adım sayısı değiştirilmektedir. Böylece elde edilecek olan çıkış görüntü boyutu değişecektir. Kaydırma adımı da çıkış görüntü boyutunu hesaplamak için kullanılacak denklem (3.4.1.1) de görünmektedir.

$$\left(\frac{(N+2P-M)}{S} + 1 \right) * \left(\frac{(N+2P-M)}{S} + 1 \right) \quad (3.4.1.2)$$

formülü kullanılır. Burada S kaydırma adım sayısını ifade etmektedir.

3.4.3 Ortaklama

Ortaklama işlemi genellikle görüntü boyutlarının düşürülmesi için kullanılmaktadır. Giriş görüntüsünün kanal sayısı sabit olmak üzere genişlik ve yükseklik değerleri azaltılır. Belirlenen bir pencere içerisinde yer alan görüntü değerleri arasından en büyük, en küçük veya ortalama değer alınması gibi farklı yaklaşımlar kullanılabilir. Fakat literatürde en yaygın kullanıma sahip olan en büyük değer alınmasıdır. Bu işlemin amacı ağırlık geri kalanında oluşturulacak ağırlık katsayılarını azaltarak hesaplama yükünü azaltmaktır. Bu işlem içinde kaydırma adımı değeri kullanılabilir. Şekil 3.3'te 2x2 lik pencere boyutunda ve 2x2'lik kaydırma adımı kullanılarak yapılmış bir ortaklama işlemi gösterilmiştir.



Şekil 3.5. En büyük değer ortaklama

3.4.4 Yığın Normalizasyon


Yapılan çalışmada katmanlar arasında kullanılan toplu normalleştirme eğitim hızını artırarak her eğitim için daha yüksek öğrenme oranları ortaya koymaktadır. (Ioffe ve Szegedy 2015) Yığın normalleştirme bir sinir ağındaki verileri herhangi bir katmanı ekseninde 0'a ortalayacak şekilde işleme tabi tutarak 0-1 arasında değerler elde edilebilmesini sağlamaktadır.

Katmanlı bir sinir ağında normalde verilerin başlangıç ve bitişte ayrı ayrı normalize edilmesi gerekiyor. Fakat sistem katmanlar arasında geçiş yaparken veri düzen ve dağılımı değişebiliyor bu durumun önüne geçmek bahsi geçen yapı için katmanlar arasında normalizasyon işlemi yapılmaktadır.

3.4.5 Bırakma

Bırakma (Dropout) katmanı sinir ağındaki birimlerin bağlantıları koparmak ve unutmak anlamına gelen bir eylemdir. Rastgele seçilen belli nöronların birbirleri arasındaki bağın eğitim sırasında koparılmasıyla gerçekleştirilir.

Eğitim aşamasında nöronlar arasındaki düğümlerin koparılması ile o sinir ağına gelen ve giden bağlantılar elemine edilmiş olur. Bırakmaya ihtiyaç duyulma sebebi ise sinir ağı yapısının aşırı öğrenmesidir. (over-fitting) Sinir ağı eğitimi sırasında verilerin aşırı uyuşması ile birbirleri arasında karşılıklı bir bağlılık gelişir böylelikle sistem yanıltıcı sonuçlar verir bu bağlılığı kesmek için ise rastgele nöronlar arasındaki bağ kopartılarak sistem aşırı öğrenmeden çıkartılır.



Şekil 3.6. Bırakma yapısı (Nitish Srivastava, 2014)

Genellikle bir ağıın tam bağlı katmanında kullanılan yapı belirlenen bir eşik değerinden sonra katmanlar arasındaki bağlantıyı kopartarak bir sonraki katmanda öncekine ait bilgileri kısmi alıp birbirleri üzerindeki ağırlık değişiminden etkilenme

olayını minimuma indirmiş olmaktadır. Bu nedenle bırakma yapısı kullanımı daha stabil yapılar oluşturmaktadır (Nitish Srivastava, 2014)

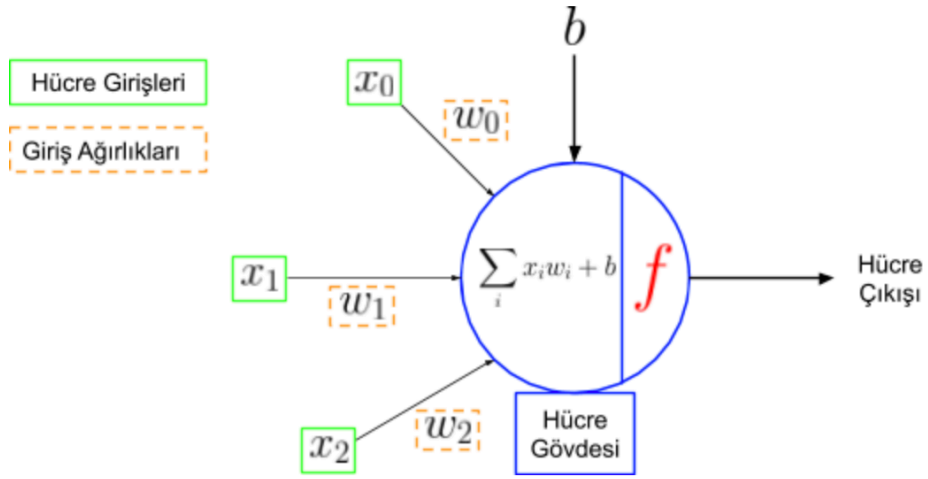
3.5 Yapay Sinir Ağı

Canlıların sinir sistemi, bir önceki bir sonrakini tetikleyecek şekilde çalışan bir yapı şeklinde oluşmuştur. Bu ağın her bir biriminin temelinde nöronlar bulunur. Sinir sisteminin bu temel yapıları, kendilerine bir önceki nörondan gelen verileri bir sonrakine iletmekle görevlidir. Veri iletimi, nöron bünyesinde ve dışarısında bulunan iyonların yer değiştirmesi ile gerçekleşir.

Değişim, akson boyunca bir elektriksel potansiyeli oluşturmaktadır bu söz konusu elektriksel aktivite nöron boyunca ileterek bir sonraki hücreye veri akışı sağlanır. (Morris, 1996).

Yapay sinir hücresi, biyolojik sinir hücrelerinin karar verme mekanizması modellenerek ortaya çıkmıştır. Bir yapay bir sinir hücresi girişler, gövde ve çıkışlar olmak üzere üç temel kısımdan oluşur. Girişler, bilginin w ağırlık katsayıları ile çarpılarak hücre gövdesine aktarılmasını sağlar. Bu ağırlıklandırılmış girişler hücre gövdesinde toplanarak f aktivasyon fonksiyonu ile lineer olmayan bir forma sokulur. Bunun amacı sinir hücresinin lineer olmayan veri tiplerinde de başarılı temsil yeteneği kazanmasını sağlamıştır. Son olarak bu fonksiyon sonucu elde edilen değer hücrenin

çıkış katmanına gönderilir. Temel bir yapay sinir ağ hücresi Şekil 3.4'te gösterilmiştir.



Şekil 3.7. Temel sinir hücre modeli (cs231n.stanford.edu)


Burada b dengeleme (offset) değeri, x_0 , x_1 , x_2 giriş değerlerini, w_0 , w_1 , w_2 ağırlık katsayılarını ifade etmektedir. Sinir hücrelerinin birbirine bağlanması ile oluşturulan yapılar yapay sinir ağları olarak adlandırılmıştır.

4. ÖNERİLEN MODELLER

Bu tez kapsamında, deri lezyonu sınıflandırma problemi için çok katmanlı evrişimsel bir yapılar kullanılarak çıkartılan öznelikler, tam bağlı yapay sinir ağı katmanlarına gönderilmektedir. Tam bağlı katmanlardan elde edilen sınıflandırma sonucunda, giriş görüntüsünde yer alan deri lezyonunun ait olduğu sınıf belirlenmektedir. Bu kapsamda deri lezyonu sınıflandırma problemi için iki farklı yapıya sahip çok katmanlı evrişimsel sinir ağı önerilmiştir. Alt bölümlerde bu yapılar incelenmiştir.

4.1 Evrişimsel Sinir Ağı Yapısı Modeli - 1

İlk ağ yapısı dört farklı evrişimsel katman ve bu katmanların çıkışına eklenmiş tam bağlı katmanlardan oluşmaktadır. Bu ağ yapısı toplamda 1,243,463 adet parametre içermektedir ve ağın görselleştirilmiş yapısı Şekil 4.1’de verilmiştir.

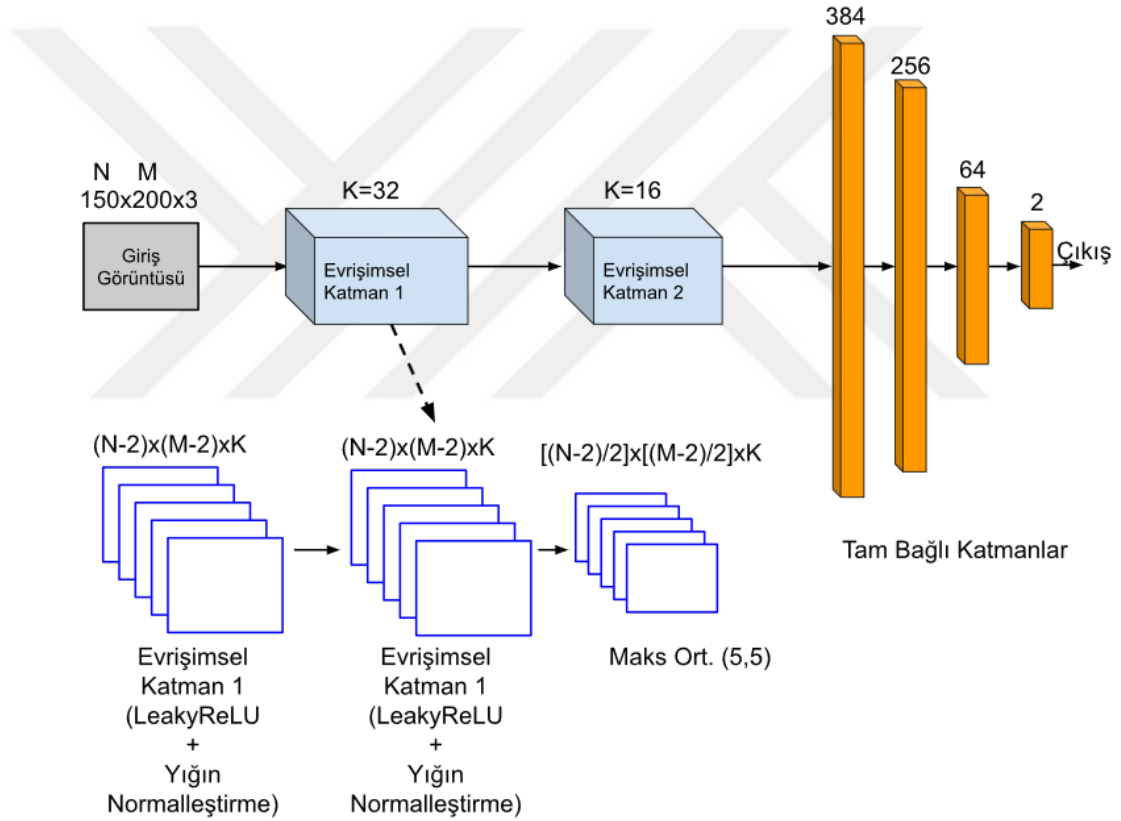


Şekil 4.8. Önerilen ağ yapısı modeli-1

4.2 Evrişimsel Sinir Ağı Yapısı Modeli – 2

Şekilde verilen ağ yapısı kullanılarak her bir sınıf için bir sınıfa karşılık diğer bütün sınıflardan oluşan bir veri kümesi kullanılarak eğitim yapılmıştır. Her sınıf için ağın çıkışında ikili (10-doğru, 01-yanlış) sınıflandırma yapılmıştır. Bu şekilde yedi sınıf için yedi farklı eğitim gerçekleştirilmiştir. Her ağın çıkışında ilgili sınıfa ait bir giriş görüntüsü verilip verilmediği anlaşılabilir. Her ağın çıkışında ilgili sınıfa ait bir giriş görüntüsü verilip verilmediği anlaşılabilir.

Bu ağ yapısı toplamda 153090 adet parametre içermektedir ve ağın görselleştirilmiş yapısı Şekil 4.2’de verilmiştir.



Şekil 4.9. Önerilen ağ yapısı modeli-2

4.3 Veri ođaltma (Data Augmentation)

Büyük miktardaki verilerin işlenmesinden başarılı sonuçlar elde etmek için sınır ađları çok iyi şekilde eğitilmesi gerekmektedir. (Goodfellow, I vd. 2016) Eğitim için kullanılan görüntü sayıları yetersiz veya dengesiz dağılıma sahip olabilmektedir. Eğitimde kullanılan yetersiz verilerin sayısını arttırmak için veri kümesinde çođaltma işlemi yapılmaktadır.

Veri çođaltma işlemi eğitim kümesine ek veriler oluşturmak için kullanılır. Orjinal görüntü üzerinde döndürme, ölçekleme, öteleme, gürültü ekleme gibi farklı yaklaşımlar veya bu yaklaşımların kombinasyonel olarak uygulanması ile gerçekleştirilmektedir (Howard AG 2013). Veri çođaltma işlemi uygulanan eğitim kümesi Tablo XX’de yer alan görüntü sayısına sahip olmaktadır. Kullanılan veri kümesine ait örnek görüntüler Şekil 4.3’den itibaren gösterilmiştir.

Çizelge 4.3. Çođaltma sonrası veri sayısı

Sınıf	Çođaltma Sonrası Veri Sayısı
Akiec - Actinic keratoses.	4860
Bcc - Basal cell carcinoma	5018
Bkl - Benign keratosis	4884
Df – Dermatofibroma	4977
Mel – Melanona	4220
Nv – Normal	5034
Vasc - Vascular lesions	4995
Toplam	33988




Şekil 4.10. Veri kümesi örneği: akiec (Tschandl, Philipp, 2018)




Şekil 4.11. Veri kümesi örneği: bcc (Tschandl, Philipp, 2018)




Şekil 4.12. Veri kümesi örneği: bkl (Tschandl, Philipp, 2018)




Şekil 4.13. Veri kümesi örneği: df (Tschandl, Philipp, 2018)



Şekil 4.14. Veri kümesi örneği: mel (Tschandl, Philipp, 2018)



Şekil 4.15. Veri kümesi örneği: nv (Tschandl, Philipp, 2018)



Şekil 4.16. Veri kümesi örneği: vasc (Tschandl, Philipp, 2018)

4.4 Ağın Eğitimi

Eğitim için belirtilen eğitim kümesi kullanılmıştır. Eğitim için 32 görüntülük gruplar halinde bütün eğitim veri kümesi kullanılarak bir çevrim tamamlanmaktadır. Eğitim için toplamda 15 çevrim yapılmıştır. Her bir çevrim sonunda doğrulama kümesi kullanılarak doğrulama sonucu elde edilmektedir. Bu değer ağın daha önce görmediği veriler üzerinde nasıl bir sonuca ulaşabildiğini belirtmektedir. Eğitim için Nadam (Nesterov Adam) eniyileme algoritması kullanılmıştır. Eğitim katsayısı 0.0001 olarak seçilmiştir. Önerilen ağ çıkışında kategorilendirilmiş çapraz entropi kullanılarak kayıp (loss) değeri hesaplanmıştır.

4.5 Sınıflayıcı Performans Ölçütleri

Veri kümesi kullanılarak tamamlanan eğitimin ardından sonuçları değerlendirmek için Karmaşıklık Matrisi - KM (Confusion Matrix - CM), Sınıflandırma Doğruluğu - SD (Classification Accuracy - CA), Kesinlik (Precision), Hatırlama (Recall) ve F1 Skoru (F-measure) kriterleri göz önüne alınmıştır.

Etkili ve fonksiyonel olarak kullanılan karmaşıklık matrisi veri kümesinde kullanılan sınıfların her biri için doğru ve yanlış tahmin sayısını görmemize yaramaktadır.

Karmaşıklık matrisini yorumlarken 4 farklı başlık kullanılır;

- Gerçek Pozitif - GP (True Positive - TP)
- Yanlış Pozitif – YP (False Positive - FP)
- Gerçek Negatif – GN (True Negative - TN)
- Yanlış Negatif – YN (False Negative - FN)

Çizelge 4.4. Karmaşıklık matrisi

	Pozitif	Negatif
Pozitif	TP	FN
Negatif	FP	TN

Gerçek Pozitif: Olumlu tahmin ve doğru sonuç

Gerçek Negatif: Olumsuz tahmin ve doğru sonuç

Yanlış Pozitif: Olumlu tahmin ve yanlış sonuç

Yanlış Negatif: Olumsuz tahmin ve yanlış sonuç

Sınıflandırma doğruluğu veri kümesinde doğru tahmin edilen sınıfların tüm veri kümesine bölünmesi ile elde edilen hesaplamadır. Denklem 4.1 ile hesaplanır.

$$\text{Sınıflandırma Doğruluğu} = \frac{TP+TN}{(TP+TN+FN+FP)} \quad (4.1)$$

Kesinlik (Precision) pozitif değerler içinde yapılan tahminin başarı durumunu ortaya koymak için kullanılan bir diğer başarı kriteri olarak kullanılıyor. Değerlerin olabildiğince yüksek olması çalışmanın başarısını gösteriyor. Denklem 4.2 ile hesaplanır.

$$\text{Hassasiyet} = \frac{TP}{(TP+FN)} \quad (4.2)$$

Hatırlama (Recall) yapılan tahminin pozitif durumdaki başarı kriterini göstermek için kullanılıyor. Kesinlikte olduğu gibi aynı şekilde değerlerin olabildiğince yüksek olması çalışmanın başarısını gösteriyor. Denklem 4.3 ile hesaplanır.

$$\text{Hatırlama} = \frac{TP}{(TP+FP)} \quad (4.3)$$

F1 Skoru (F-measure) kesinlik ve hatırlamayı aynı anda ölçüp karşılaştırma işlemleri için kullanılmaktadır. Yöntemde harmonik ortalama kullanılmaktadır. Denklem 4.4 ile hesaplanır.

$$F1 \text{ Skoru} = \frac{2 * \text{Hatırlama} * \text{Hassasiyet}}{(\text{Hatırlama} + \text{Hassasiyet})} \quad (4.4)$$

Belirtilen kriterlerden F1-skoru ve daha önce verilen başarımların değeri performansın en iyi göstergeleridir. Başarım, veri kümesi içinde doğru tespit edilen sınıf yüzdesini vermektedir ve en çok kullanılan performans göstergesidir. Fakat, başarımların değeri yanlış pozitif ve yanlış negatif değerlerini göz önünde bulundurmaz. F1-skoru ise kesinlik ve hatırlamanın ağırlıklı ortalamasının hesaplanması ile elde edildiği için daha dengeli bir performans göstergesidir. Bu ölçek ile yanlış alarm ve doğru bir şekilde sınıflandırılan verilerin oranı daha dengeli bir şekilde elde edilmiş olur.

5. BULGULAR VE TARTIŞMA

Eğitilen ağlar ve çıkışlarından elde edilen sınıflandırma sonuçlarının anlamları şekilde gösterilmiştir. İki sınıf içeren veri kümesinin eğitimi çok sınıflı veri kümesine göre daha kolaydır. Daha önceden kullanılan geniş ağ yapısına ihtiyaç kalmamaktadır. Her bir sınıf için eğitilen ağ yapılarından elde edilen test başarımları Çizelge 5.1 ve Çizelge 5.2’de görebilirsiniz.

Çizelge 5.1 ilk ağa ait kesinlik (precision), hatırlama (recall) ve F1-skoru değerleri verilmiştir.

Çizelge 5.5. Birinci ağın her bir sınıfa ait performans göstergeleri

Sınıf	Hassasiyet %	Hatırlama %	F1-Skoru
Akiec - Actinic keratoses	0.58	0.21	0.31
Bcc - Basal cell carcinoma	0.64	0.59	0.62
Bkl - Benign keratosis	0.48	0.61	0.54
Df - Dermatofibroma	0.39	0.41	0.40
Mel - Melanona	0.51	0.42	0.46
Nv - Normal	0.89	0.91	0.90
Vasc - Vascular lesions	1.00	0.48	0.65

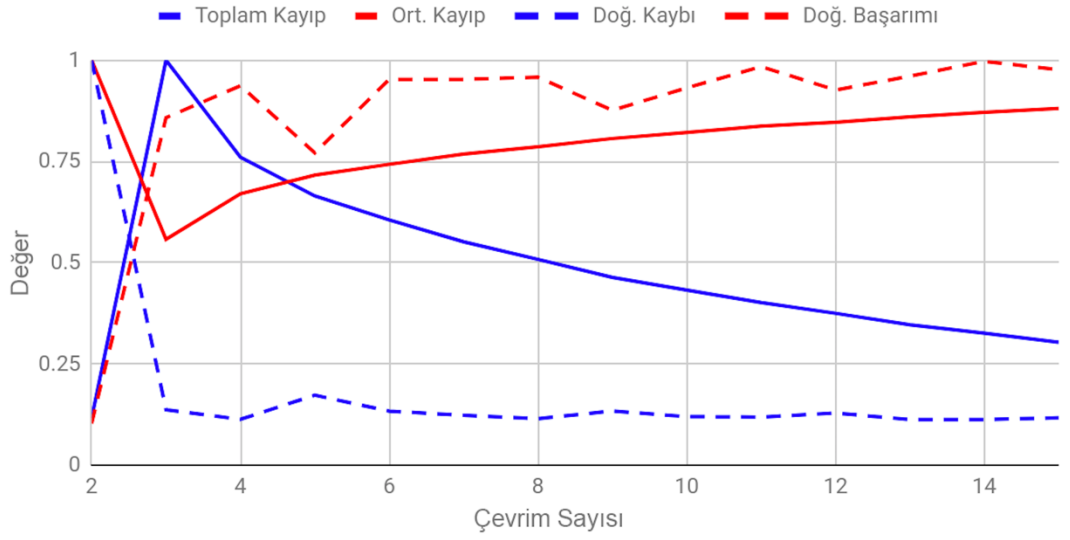
Çizelge 5.6. İkinci ağın her bir sınıfa ait performans göstergeleri

Sınıf	Başarı Oranları %
Akiec - Actinic keratoses.	%96.9
Bcc - Basal cell carcinoma	%95
Bkl - Benign keratosis	%89.7
Df – Dermatofibroma	%98.9
Mel – Melanona	%87.7
Nv – Normal	%82.9
Vasc - Vascular lesions	%99.2
Ortalama	%92.9


Çalışmada önerilen iki evrışimsel ağ kıyaslandığında; ilk ağ yapısı toplamda 7 adet sınıfı her birini kendi içinde ayırıp sınıflandırması sonucunda %77 oranında başarı elde etmiştir.

İkinci ağ yapısında ise her bir sınıf sırasıyla diğer sınıflar bir olarak değerlendirildiğinde daha yüksek başarı oranları görülmektedir. Bahsi geçen 7 adet sınıfın başarı oranlarını toplatıp ortalaması alındığında önerilen ikinci ağın %92.9 başarı oranı ortaya koyulmuştur.


Önerilen birinci ve ikinci ağların eğitiminde elde edilen kayıp değer ve başarıım grafikleri sırasıyla Şekil 5.1 ve devamında verilmiştir



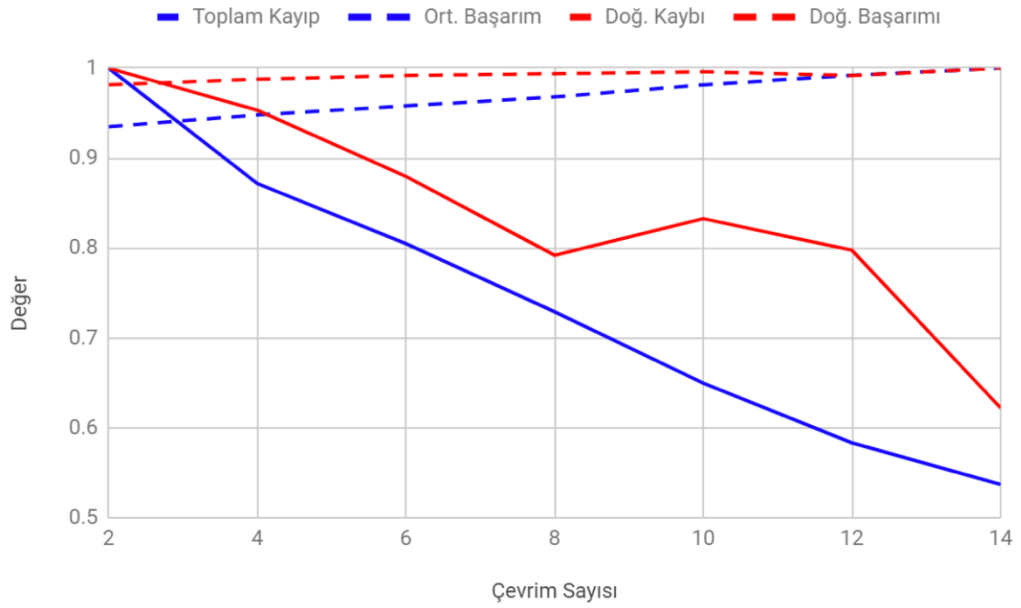
Şekil 5.17. Birinci ağı ait kayıp değer ve başarımları grafiği.




Şekil 5.18. İkinci ağı ait kayıp değer ve başarımları grafiği. (akiec)




Şekil 5.19. Birinci ağa ait kayıp değer ve başarımları grafiği. (bcc)



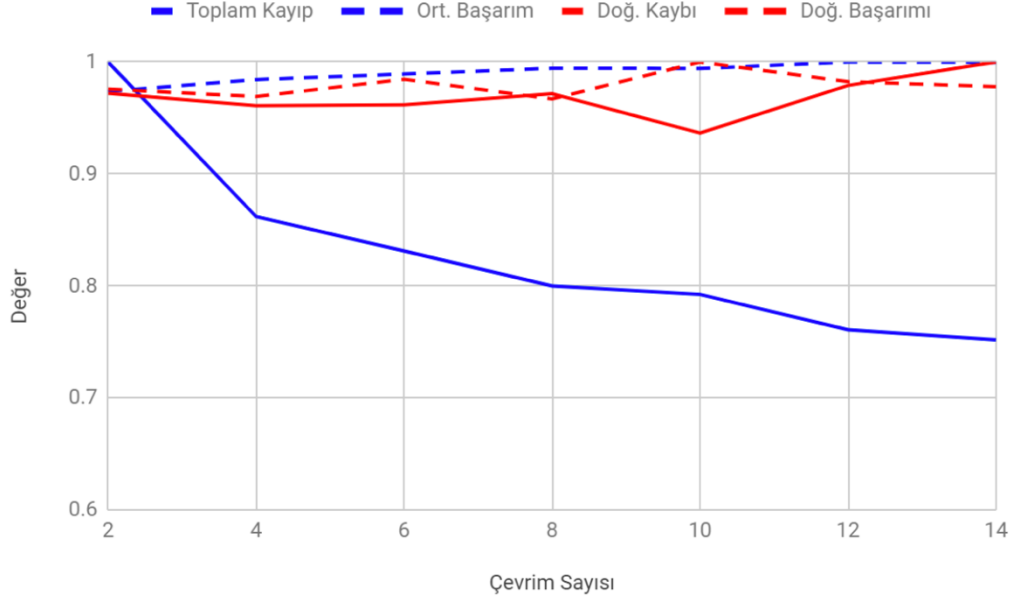
Şekil 5.20. Birinci ağa ait kayıp değer ve başarımları grafiği. (bkl)



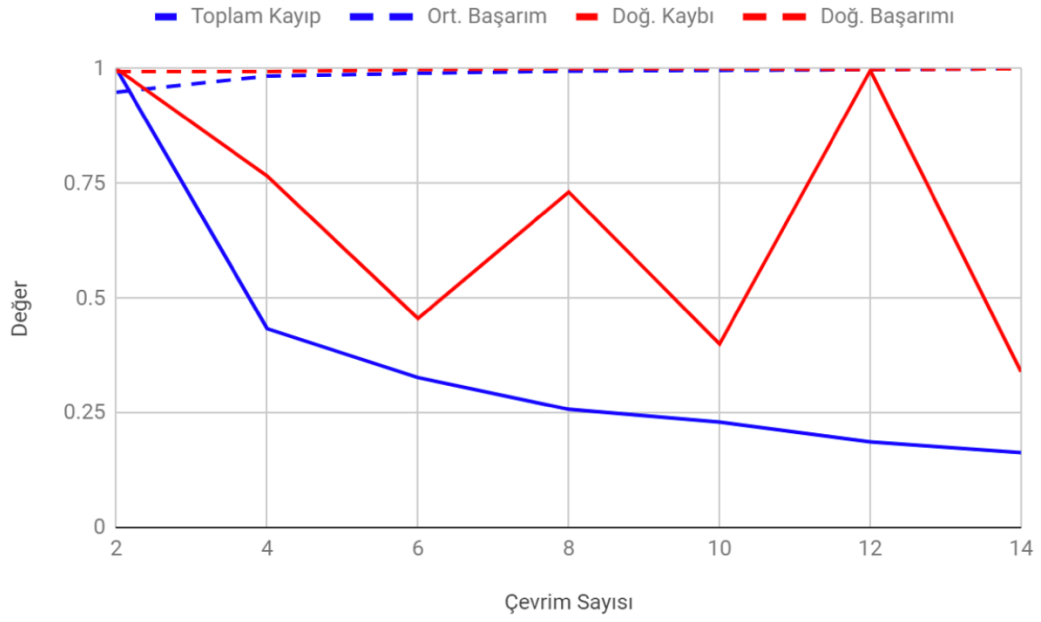
Şekil 5.21. Birinci ağa ait kayıp değer ve başarımlar grafiği. (df)



Şekil 5.22. Birinci ağa ait kayıp değer ve başarımlar grafiği. (mel)




Şekil 5.23. Birinci ağa ait kayıp değer ve başarımları grafiği. (nv)



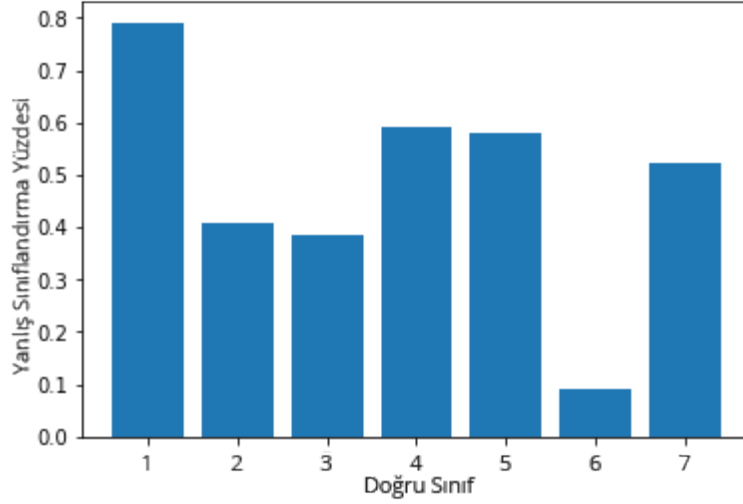
Şekil 5.24. Birinci ağa ait kayıp değer ve başarımları grafiği. (vasc)

Bu şekillerden görüleceği üzere oluşturulan ağların eğitiminde oluşan eğitim ve doğrulama başarımları uyumlu olarak ilerlemektedir. Bu grafiklerden ağın eğitilebildiği görülmektedir. Birinci ağın test başarımlı %77'dir. İkinci ağın test başarımlı ise ortalamada %92.9'dur. Test veri kümesi üzerinde eğitilen birinci ağdan elde edilen karmaşıklık matrisi - KM (confusion matrix- CM) Şekil 5.9'da verilmiştir.



Şekil 5.25. Birinci ağın test veri kümesi karmaşıklık matrisi

Bu karmaşıklık matrislerinden de anlaşılacağı üzere az sayıda veriye sahip olan sınıfların başarımları daha düşüktür. Her bir sınıfa ait başarımların incelenebilmesi için Şekil 5.10'de verilmiştir.



Şekil 5.260. Birinci ağın her bir sınıfın tespitinde elde ettiği hata oranları.

Buradan görüldüğü üzere, her iki ağ yapısı da ortalamanın üzerinde bir başarı ile deri lezyonlarının tahmin edilmesini sağlamaktadır.

Önerilen ağlardan ikinci ağ literatürdeki benzer çalışmalar göz önüne alınarak değerlendirildiğinde literatüre katkı yapacak bir değerde başarı ortaya koymuştur. Karşılaştırmaya ilişkin değerler Çizelge 5.3’de görülmektedir.

Çizelge 5.3. İkinci ağın literatür ile karşılaştırması (1 Vs All)

İlgili Çalışma	Başarı
Aleksey Nozdryn-Plotnick (vd. 2018)	%88.5
Nils Gessert (vd. 2018)	%85.6
Iaxin Zhuang (vd. 2018)	%84.5
Mohammed K. Amro (vd. 2018)	%81.2
Yeong Chan Lee	%78.5
Kaan Onur Koç	%92.9

6. Sonuç ve Öneriler

Big data kavramının oluşması derin öğrenme algoritmalarını klasik makine öğrenmesi yöntemlerine nazaran daha tercih edilebilir kılsa da mimarinin başarılı tasarlanması her zaman zor bir problem olarak karşımıza çıkmaktadır. Çalışılmak istenen veri kümelerinin büyük olması tasarlanacak mimari yapının da çok iyi optimize edilmiş olmasını gerektirmektedir. Aksi halde elde edilen başarının düşük olmasının yanı sıra çalışma süresinin verimliliği oldukça düşük olacaktır bu da sonuç verilerini elde edeceğimiz sürenin günler alabileceği kısır algoritmalar oluşturabilir.

Derin öğrenme yapılarının bir diğer avantajı güncel bir yapı olmasından dolayı gelişen teknolojinin desteğini de alması. Örneğin bulut üzerinden sağlanan servisler ile yüksek donanımlı bir bilgisayara sahip olmadan işlemleri online olarak çalışan TensorFlow, Google Colab v.b. platformlar ile yapılabiliyor olması. Görüntü işlemede yüksek boyutlu GPU'lara gereksinim olduğu düşünülünce maliyet anlamında da etkili bir çözüm ortaya koymaktadır.

CNN yapısı baz alınarak katmanlı olarak tasarlanan mimari çoklu model içeren bir yapı oluşturup karşılaştırılabilir başarı oranları ortaya konulmuştur. 10015 adet görselden oluşan veri kümesini 7 kategoride sınıflandırma yapabilmekte ve teşhisi konusunda Tekil bazda geliştirilen mimarilerin sınıflandırma başarıları düşük iken hazırlanan çalışmada çoklu katmanlı yapıların başarı oranının yüksek olmasına dikkat çekilmiştir.

Önerilen ağlardan ilkinde de giriş görüntüsünden 7 farklı sınıf için ait olduğu sınıfın olasılık değeri hesaplanmaya çalışılmıştır. Ama sınıflandırma için 7 farklı sınıf olunca karmaşık bir yapı ortaya çıkmaktadır. Bu sebepten ötürü 1vsAll yöntemi ikinci yöntem olarak denenmiştir. 1VsAll un avantajı her sınıf için doğru yanlış bazında bir sınıflandırma yapılmasıdır. Dolayısıyla karmaşıklığın azalmasına neden olmuştur. Böylece çoklu sınıflandırmadaki doğruluk oran değerleri her sınıf ayrı ayrı değerlendirildiğinde artmıştır. Ortalama başarıım %77'den %92,9'a çıkmıştır.

Çalışma deri hastalıklarının teşhisinde uzman dermatologlara ciddi anlamda destek olacak öncül bir metod olarak kullanılabilir.

7. Kaynaklar

- Bickers D R, Lim H W, Margolis D, Weinstock M A, Goodman C, Faulkner E, Gould C, Gemmen E, and Dall T, "The burden of skin diseases: 2004: A joint project of the american academy of dermatology association and the society for investigative dermatology," Journal of the American Academy of Dermatology, vol. 55, no. 3, pp. 490–500, 2006.
- V. Jain, J. F. Murray, F. Roth, S. Turaga, V. Zhigulin, K. Briggman, M. Helmstaedter, W. Denk, and H. S. Seung. Supervised learning of image restoration with convolutional networks. In ICCV'07.
- Belkin Malkoç Temel Bilimler ve Mühendislik Eğitiminde Programlama Dili Olarak Python 2012 Akademik Bilişim'12 - XIV. Akademik Bilişim Konferansı Bildirileri
- Howard, A.G. "Some Improvements on Deep Convolutional Neural Network Based Image Classification", CoRR, abs/1312.5402, (2013).
- P. Sermanet, D. Eigen, X. Zhang, M. Mathieu, R. Fergus, and Y. LeCun, "OverFeat: Integrated recognition, localization and detection using convolutional networks," in ICLR, 2014. 1
- Srivastava, Nitish, et al. "Dropout: a simple way to prevent neural networks from overfitting", JMLR 2014
- Sergey Ioffe, Christian Szegedy " Batch Normalization: Accelerating Deep Network Training b y Reducing Internal Covariate Shift " (2015)
- Tensorflow, An end-to-end open source machine learning platform, <https://www.tensorflow.org/>, (9.10.2019)
- Goodfellow, I., Bengio, Y. and Courville, A. "Deep Learning, The MIT Press" (2016).
- Alper Arık, Mesut Gölcük, Elif Mine Karşılıgil Deep Learning Based Skin cancer Diagnosis 2017 25th Signal Processing and Communications Applications Conference (SIU)

- E. Shelhamer, J. Long, and T. Darrell, "Fully convolutional networks for semantic segmentation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 4, pp. 640–651, 2017.
- Ma Z, Tavares JM(2017) "Effective Features to Classify Skin Lesions in Dermoscopic images" *Expert Systems With Applications* 84 92-101
- Mohammed A. Al-masni, Mugahed A. Al-antari, Mun-Taek Choi, Seung-Moo Hana, Tae-Seong Kima (2018) "Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks" *Computer Methods and Programs in Biomedicine* 162 221–231
- Aleksey Nozdryn-Plotnicki, Jordan Yap, and William Yolland "Ensembling Convolutional Neural Networks for Skin Cancer Classification" (2018)
- Nils Gessert, Thilo Sentkerac, Frederic Madestaac, Rudiger Schmitz ad, Helge Kniepag, Ivo Baltruschataef, Rene Werner ac and Alexander Schlaeferb "Skin Lesion Diagnosis using Ensembles, Unscaled Multi-Crop Evaluation and Loss Weighting" (2018)
- Jiaxin Zhuang, Weipeng Li, Siyamalan Manivannan, Roy Wang, JianGuo Zhang, Jihan Liu, Jiahui Pan, Gongfa Jiang, Ziyu Yin "Skin Lesion Analysis Towards Melanoma Detection Using Deep Neural Network Ensemble" (2018)
- Mohammed K. Amro, Baljit Singh, and Avez Rizvi "Skin Lesion Classification and Segmentation for Imbalanced Classes using Deep Learning" (2018)
- Yeong Chan Lee, Sang-Hyuk Jung, and Hong-Hee Won "WonDerM: Skin Lesion Classification with Fine-tuned Neural Networks" (2018)
- Tschandl, Philipp, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions" (2018)
- Balazs Harangi Skin lesion classification with ensembles of deep convolutional neural networks *Journal of Biomedical Informatics* Volume 86, October 2018, Pages 25-32
- Gonzalez, R. C. (2018). Deep Convolutional Neural Networks [Lecture Notes]. *IEEE Signal Processing Magazine*, 35(6), 79–87. doi:10.1109/msp.2018.2842646
- American Cancer Society, Cancer facts & figures 2018 <https://www.cancer.org/> ,
Ağustos 2019

Mahbod A, Schaefer G, Ellinger I, Ecker R, Pitiot A, Wang C, (2019) “Fusing fine-tuned deep features for skin lesion classification” Computerized Medical Imaging and Graphics 71 19-29

Stanford University, CS231n: Convolutional Neural Networks for Visual Recognition, <http://cs231n.stanford.edu/> , (11.11.2019)



8. Özgeçmiş

Adı Soyadı : Kaan Onur KOÇ

Doğum Yeri ve Tarihi : 10/01/1991

Lisans Üniversitesi : Fırat Üniversitesi
Mühendislik Fakültesi
Elektrik Elektronik Mühendisliği

Bolu Abant İzzet Baysal Üniversitesi
Mühendislik Mimarlık Fakültesi
Elektrik – Elektronik Mühendisliği

Elektronik posta : kaanonurkoc@gmail.com

İletişim Adresi : Yalı Mah. 23 Nisan Cad. 68/3 Aliğa İzmir

Yayın Listesi :

Bildiri

Koc K O ve Polat K (2017) “MATLAB GUI design for heart rate monitoring using smart phone camera”, Medical Technologies National Congress (TIPTEKNO 2017), 12 Ekim 2017, Trabzon.