

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**CİLT LEZYONLARININ DERMATOSKOP GÖRÜNTÜLERİ ÜZERİNDEN
DERİN ÖĞRENMEYE DAYALI YÖNTEMLE TESPİTİ VE
SINIFLANDIRILMASI**

Yusuf YETGİN

**FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

OCAK 2023

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**CİLT LEZYONLARININ DERMATOSKOP GÖRÜNTÜLERİ ÜZERİNDEN
DERİN ÖĞRENMEYE DAYALI YÖNTEMLE TESPİTİ VE
SINIFLANDIRILMASI**

Yusuf YETGİN

**FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

OCAK 2023

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**CİLT LEZYONLARININ DERMATOSKOP GÖRÜNTÜLERİ ÜZERİNDEN
DERİN ÖĞRENMEYE DAYALI YÖNTEMLE TESPİTİ VE
SINIFLANDIRILMASI**

Yusuf YETGİN
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

OCAK 2023

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

CİLT LEZYONLARININ DERMATOSKOP GÖRÜNTÜLERİ ÜZERİNDEN
DERİN ÖĞRENMEYE DAYALI YÖNTEMLE TESPİTİ VE
SINIFLANDIRILMASI

Yusuf YETGİN
BIYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 20/01/2023 tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Doç. Dr. Evgin GÖÇERİ
Doç. Dr. Hüseyin Özgür KAZANCI
Dr. Öğr. Üyesi Turgay BATBAT

ÖZET

CİLT LEZYONLARININ DERMATOSKOP GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENMEYE DAYALI YÖNTEMLE TESPİTİ VE SINIFLANDIRILMASI

Yusuf YETGİN

Yüksek Lisans Tezi, Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Evgin GÖÇERİ

OCAK 2023; 40 sayfa

Cilt hastalıklarının dünya nüfusunun yaklaşık üçte birini etkileyen en yaygın dördüncü hastalık olduğu bilinmektedir. Cilt hastalıklarında genellikle belirtiler, deri üzerindeki normal deri rengi ve deseninden farklı görülen ve lezyon olarak adlandırılan bölgelerdir. Cilt hastalıkları erken evrede teşhis edildiğinde tedavi edilebilen hastalıklardır. Bu nedenle, hastanın hayatını koruyabilmek için erken ve doğru teşhis kritik role sahiptir. Günümüzde, cilt hastalıklarının teşhis edilmesi işlemi, dermatoloğun deriyi eli ile incelemesi ve görebildiklerine göre karar vermesine dayalı olarak yapılmaktadır. Cilt hastalıklarının bu şekilde teşhis edilmesi dermatologların deneyimlerine göre değişiklik gösterebilmektedir. Otomatik yöntemler erken teşhis ve müdahalelerin yapılmasını sağlamaktadır. Literatürde otomatik yöntemler önerilmekte ve bilgisayar destekli teşhis sistemlerinde artan bir şekilde derin öğrenmeye dayalı yöntemler kullanılmaktadır. Bu nedenle, bu tez çalışması kapsamında da derin sinir ağ mimarisine dayalı olarak cilt lezyonlarının sınıflandırılması üzerinde durulmuş, dermatoskop görüntüsünden yüksek doğruluk ile lezyonların yedi sınıfa otomatik olarak sınıflandırılmasını sağlayan, evrimsel derin sinir ağ mimarisi ve kapsül ağı birlikte kullanıldığı bir yöntem önerilmiştir. Sonuçların değerlendirilmesi için doğruluk, hassaslık, özgüllük, F1-skor ve Mathew ilişkilendirme katsayısı olmak üzere beş farklı değerlendirme ölçütü kullanılmış ve sırasıyla %88.10, %89.18, %98.11, %87.25, %86.20 değerleri elde edilmiştir. Ulaşılan bu bulgular cilt lezyonlarının otomatik olarak sınıflandırılmasında önerilen bütünleşik ağ mimarisinin başarılı olduğunu göstermiştir.

ANAHTAR KELİMELE: Cilt hastalığı, derin öğrenme, kapsül ağ, sınıflandırma

JÜRİ: Doç. Dr. Evgin GÖÇERİ

Doç. Dr. Hüseyin ÖZGÜR KAZANCI

Dr. Öğr. Üyesi Turgay BATBAT

ABSTRACT

DETECTION AND CLASSIFICATION OF SKIN LESIONS BASED ON DEEP LEARNING FROM DERMATOSCOP IMAGES

Yusuf YETGİN

MSc Thesis in Biomedical Engineering

Supervisor: Assoc. Prof. Dr. Evgin GÖÇERİ

January 2023; 40 pages

It is known that skin diseases are the fourth common disorder that affects approximately one third of the world's population. In skin diseases, the symptoms are the areas on the skin that are different from the normal skin color and pattern and are called lesions. Skin diseases are diseases that can be treated when diagnosed at an early stage. Therefore, early and accurate diagnosis has a critical role in preserving the patient's life. Today, the process of diagnosing skin diseases is based on the dermatologist's visual examination of the skin and making a decision based on what the dermatologist can see. Diagnosis of skin diseases in this way may vary according to the experience of dermatologists. Automated methods enable early diagnosis and interventions. In the literature, automatic methods are suggested and deep learning-based methods are increasingly used in computer aided diagnostic systems. Therefore, within the scope of this thesis, the classification of skin lesions based on deep neural network architecture has been emphasized, and a method that uses convolutional deep neural network architecture and capsule network together, which provides automatic classification of lesions into seven classes with high accuracy from the dermatoscope image, has been proposed. Five different evaluation criteria, namely, specificity, sensitivity, accuracy, F1-score and Mathew correlation coefficient, were used to evaluate the results, and values of 88.10%, 89.18%, 98.11%, 87.25%, and 86.20% were obtained, respectively. These findings showed that the proposed integrated network architecture was successful in automatic classification of skin lesions.

KEYWORDS: Capsule network, classification, deep learning, dermatological diseases

COMMITTEE: Assoc. Prof. Dr. Evgin GÖÇERİ

Assoc. Prof. Dr. Hüseyin ÖZGÜR KAZANCI

Asst. Prof. Dr. Üyesi Turgay BATBAT

ÖNSÖZ

Bu tez çalışmasının oluşmasında ve çalışmaların her aşamasında yardımcı olan ve bana emeği geçen danışman hocam Doç. Dr. Evgin GÖÇERİ ve diğer tüm hocalarıma çok teşekkür ederim.

Yüksek lisansımı tamamlama konusundaki teşvik ve hoşgörülerinden dolayı Antalya Eğitim ve Araştırma Hastanesi Başhekimi Sayın Prof. Dr. Halil Yalçın YÜKSEL'e, Teknik Hizmetler Müdür Yardımcısı Bülent KAYA'ya ve Biyomedikal Cihaz Takip Birimi'ndeki tüm ekip arkadaşlarıma çok teşekkür ederim.

Tez çalışmam sürecinde bana motivasyon sağlayan ve manevi desteklerini esirgemeyen arkadaşlarım Ömer Burak İSTANBULLU ve Hazan Yasin İLHAN'a çok teşekkür ederim.

Ayrıca, bugüne kadar her zaman bana maddi manevi destek olan kıymetli annem, babam, kardeşim ile değerli eşim ve kızıma çok teşekkür ederim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
ÖNSÖZ.....	iii
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR	vi
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. KAYNAK TARAMASI	4
2.1. Evrişimsel Derin Ağ Mimarileri ile Cilt Lezyonu Sınıflandırma Yöntemleri	4
2.2. Kapsül Ağ Mimarileri ile Cilt Lezyonu Sınıflandırma Yöntemleri	6
3. MATERYAL VE METOT	8
3.1. Derin Öğrenme	9
3.2. Cilt Lezyonu Tespitinde Yaygın Kullanılan Evrişimsel Derin Ağ Mimarileri ...	12
3.2.1. AlexNet mimarisi.....	12
3.2.2. GoogleNet mimarisi.....	13
3.2.3. VGGNet mimarisi.....	14
3.2.4. ResNet mimarisi	15
3.2.5. InceptionNet mimarisi	16
3.2.6. DenseNet mimarisi	16
3.3. Kapsül Ağ Mimarisi ve Özellikleri	16
3.4. Önerilen Lezyon Tespit ve Sınıflandırma Metodu.....	21
3.4.1. Veri setlerinin oluşturulması.....	22
3.4.2. Ağ modelinin oluşturulması	22
3.4.3. Yazılım sisteminin geliştirilmesi	24
3.4.4. Ağın eğitimi ve test edilmesi	25
3.4.5. Sayısal ölçütlerden sonuçların elde edilmesi	26
4. BULGULAR.....	28
5. TARTIŞMA	30
6. SONUÇLAR	34
7. KAYNAKLAR	36

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Cilt Lezyonlarının Dermatoskop Görüntüleri Üzerinden Derin Öğrenmeye Dayalı Yöntemle Tespiti ve Sınıflandırılması” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

20/01/2023

Yusuf YETGİN

SİMGELER VE KISALTMALAR

Simgeler

W	: Ağırlık matrisi
u	: Alt düzeydeki kapsül çıkış vektörü
u_i	: Alt düzeydeki kapsül giriş vektörü
c_{ij}	: Bağlantı katsayısı
W_{ij}	: Dönüşüm matrisi
S	: Filtre adım büyüklüğü
F	: Filtre boyutu
B	: Girdi verisi boyutu
a	: Kapsüller arasındaki uyumu ifade eden değer
b_{ij}	: Kapsüllerin benzerliklerini ifade eden değer
L	: Kayıp değer
$.$	: Ondalık ayırıcı
P	: Piksel ekleme miktarı
k	: Sınıf sayısı
$\hat{u}_{i j}$	: Tahmin vektörü
$\hat{u}$	: Tahminleme vektörü
v	: Tahminleme vektörünün üst seviyedeki olası kapsül vektörü
Σ	: Toplam sembolü
v_j	: Üst düzeydeki kapsül çıkış vektörü
s_j	: Üst düzeydeki kapsül giriş vektörü
$\exp$	: Üstel fonksiyon

Kısaltmalar

AKIEC	: Actinic Keratosis and Intraepithelial Carcinoma
-------	---

BCC	: Basal Cell Carcinoma
BKL	: Benign Keratosis Lesion
DF	: Dermatofibroma
MKK	: Mathew Korelasyon Katsayısı
MN	: Melanocytic Nevi
MEL	: Melanoma
ReLU	: Rectified Linear Unit
VASC	: Vascular Lesion



ŞEKİLLER DİZİNİ

Şekil 1.1. Cilt kanseri görüntü örnekleri.....	1
Şekil 3.1. Bu çalışma kapsamında ele alınan hastalıklara ait HAM10000 veri tabanından alınmış görüntü örnekleri.....	9
Şekil 3.2. Bir evrişimsel derin sinir ağ mimarisinde bulunan katmanlar	10
Şekil 3.3. Çekirdeğin girdi verileri üzerinde kaydırılması ile alıcı bölgelerin (<i>receptive fields</i>) oluşturulmasını sağlayan evrişim işlemi	11
Şekil 3.4. Havuzlama yöntemleri.....	12
Şekil 3.5. AlexNet mimarisi	13
Şekil 3.6. Boyutu küçültülmüş bir inception modülü	13
Şekil 3.7. GoogleNet mimarisi	14
Şekil 3.8. VGG16 ağ mimarisi.....	14
Şekil 3.9. Artık bağlantı yapısı	15
Şekil 3.10. ResNet18 ağ mimarisi	15
Şekil 3.11. InceptionV3 mimarisi	16
Şekil 3.12. DenseNet mimarisi	16
Şekil 3.13. Kapsül giriş çıkışı	19
Şekil 3.14. Dinamik yönlendirme algoritması	20
Şekil 3.15. Kapsül ağ mimarisi	21
Şekil 3.16. Çalışmalarda uygulanan adımları gösteren akış şeması	22
Şekil 3.17. VGG16 ve kapsül ağın kullanıldığı mimari.....	23
Şekil 3.18. Önerilen ağ mimarisi	24

ÇİZELGELER DİZİNİ


Çizelge 4.1. Uygulanan ağ mimarilerinden elde edilen sonuçlar ile hesaplanan performans değerleri	28
Çizelge 4.2. Mimarilerin eğitim ve test edilme süreleri.....	29



1. GİRİŞ

Cilt hastalıkları çevresel faktörler, depresyon, güneş ışınlarına maruz kalma, yaşlanma veya genetik özellikler gibi çeşitli nedenlerden dolayı oluşan, her yaş ve cinsiyetteki kişilerde görülebilen hastalıklardır. En yaygın dördüncü hastalık olan deri hastalığı, dünya nüfusunun yaklaşık üçte birini etkilemektedir (Flohr ve Hay 2021). Güncel bir çalışma, cilt hastalığı olan pek çok kişinin bir dermatoloğa gitmediğini bu nedenle bu hastalıkların aslında belirtilenlerden çok daha yaygın olduğunu göstermiştir (Tizek vd. 2019).

Cilt hastalıklarında genellikle belirtiler, deri üzerindeki normal deri rengi ve deseninden farklı görülen ve lezyon olarak adlandırılan bölgelerdir. Bu lezyonlar cilt hastalıklarından dolayı oluşabileceği gibi, başka bir hastalığın önemli bir belirtisi de olabilmektedir. Akne, hemanjiyom, egzema, roza (rosacea) ve cilt kanseri en çok bilinen cilt hastalığı türleridir. Cilt lezyonlarını gösteren çeşitli örnek görseller Şekil 1.1’de sunulmuştur.



Şekil 1.1. Cilt kanseri görüntü örnekleri (Ngesthi vd. 2021)

Yaşam kalitesini önemli ölçüde etkileyen cilt hastalıkları, sosyal ilişkilerin bozulmasına sebep olabilen, özgüven eksikliği, utanma, kaygı bozukluğu ve depresyon gibi psikolojik sorunlara da yol açmaktadır (Zink vd. 2017; Leisner vd. 2019; Mento vd. 2020; Schuster vd. 2020; Al-Otaibi vd. 2020). Hatta, hastalarda intihar etme düşüncesinin yüksek oranda olduğu, akne hastaları ile ilgili 2015 yılında yayımlanan bir araştırma çalışması intihar vakalarının oluşunu göstermiştir (Tan ve Bhate, 2015). Litvanya’da yapılan güncel bir çalışmada, belirtisi yüzünde oluşmuş olan hastalarda intihar etme düşüncesine sahip olanların oranının %9.8 olduğu belirtilmektedir.

(Lukaviciute vd. 2020). Benzer şekilde, Kanada’da yapılan bir başka çalışmada, Quebec’deki psoriasis hastalarının intihar etme girişimlerinden dolayı hastanede kalanların oranının %1.82, intihar ederek ölenlerin oranının da %3.34 olduğunu göstermiştir (Laverde-Saad vd. 2020).

Cilt hastalıkları erken evrede teşhis edildiğinde tedavi edilebilen hastalıklardır. Bu nedenle, hastanın hayatını koruyabilmek için erken ve doğru teşhis kritik role sahiptir. Günümüzde, cilt hastalıklarının teşhis edilmesi işlemi, dermatoloğun deriyi eli ile incelemesi ve görebildiklerine göre karar vermesi ile başlamaktadır. Cilt hastalıklarının bu şekilde teşhis edilmesi dermatologların deneyimlerine göre de değişiklik gösterebilmektedir. Bu nedenle, farklı dermatologlar aynı hasta için farklı ön tanımlarda bulunabilmektedir. Ayrıca, bir dermatolog o andaki yoğunluk, yorgunluk veya aydınlatmanın etkisi ile, aynı hasta için farklı zamanlarda farklı teşhislerde bulunabilmektedir. Bununla birlikte, kişide bulaşıcı başka bir hastalığın olması veya cilt hastalığının impetigo hastalığı gibi bulaşıcı bir özellik taşıması, geleneksel yöntemle teşhis edilmesini daha da zorlaştırmaktadır. Çünkü, hastalığın yayılma riskini önlemek için lezyon olan bölgelerin uzaktan incelenmesi gerekmektedir (Assiri vd. 2013; Reusken vd. 2013; Zielecki vd. 2013; Forton vd. 2015; Hopkinson vd. 2015; Two vd. 2015). Ayrıca, geleneksel yöntem ile teşhis uzun sürmekte, ağrı ve enfeksiyonlara da neden olabilmektedir. Bunların yanı sıra, özellikle kırsal kesimde, gelişmekte olan ülkelerde ve Çin gibi kalabalık ülkelerde yeterli dermatolog bulunmamaktadır. Bunlara ek olarak, hastanın fiziksel bir engelinin olması, yaşlılık, iklim koşulları ve mesafe gibi çeşitli faktörler nedeniyle, dermatoloğa gitmek her zaman mümkün olamamakta, muayene ücretleri de maliyetli olabilmektedir (Feng vd. 2018; Arnold vd. 2019).

Otomatik yöntemler erken teşhis ve müdahalelerin yapılmasını sağlamaktadır. Bu nedenle, literatürde otomatik yöntemler önerilmekte olup, bilgisayar destekli teşhis sistemlerinde artan bir şekilde derin öğrenmeye dayalı yöntemler kullanılmaktadır (Puttagunta ve Ravi 2021). Cilt lezyonlarının tespiti ve sınıflandırılması ile ilgili olarak yapılmış olan çalışmalar incelendiğinde, kullanılan derin sinir ağ mimarilerinin genellikle GoogleNet (Szegedy vd. 2015), AlexNet (Krizhevsky vd. 2017), VGGNet (Simonyan ve Zisserman 2014), InceptionNet (Szegedy vd. 2016) ve ResNet (He vd. 2016) olduğu gözlenmiştir. Bu mimarilerde ardışık evrişim işlemlerinin gerçekleştirildiği evrişim katmanları, havuzlama ve tam bağlantılı katmanlar bulunmakta, görüntülerin sınıflandırılması ilk katmanlardaki evrişim işlemleri ile çıkarılan özniteliklerin sonraki katmanlarda kullanılması ile sağlanmaktadır.

Evrişimsel sinir ağları desen tanıma ve sınıflandırma işlemleri için tercih edilen ağ yapıları olmasına rağmen problemlerli mimarilerdir. Çünkü bu mimarilerde kullanılan havuzlama katmanından dolayı, görüntüdeki nesnelerin birbirine göre açısını, konumunu tanımlamak mümkün olmamaktadır. Havuzlama katmanında görüntülerin boyutları düşürülmekte ve dolayısı ile görüntülerdeki bazı önemli öznitelikler kaybolmaktadır. Bu sorunun çözümü için, özelleşmiş evrişimsel sinir ağı mimarisi olarak bilinen kapsül ağ mimarisi (Sabour vd. 2017) önerilmiştir.

Kapsül ağ mimarisinde bilgiler evrişimsel sinir ağ mimarilerinde olduğu gibi skaler değerler olarak değil, vektör düzeyinde depolanmaktadır. Bu depolama özelliği kullanılan kapsüller ile sağlanmaktadır. Kapsül, somutlaştırma parametrelerini kodlayarak öznitelikler arasındaki ilişkiyi gösteren bir vektörü temsil eden bir grup

nörondur. Ağ mimarisindeki bu kapsül vektörler görüntülerdeki önemli bilgileri temsil etmektedir. Mimaride bulunan birincil ve ikincil kapsül katmanları arasında kapsül vektörler dinamik yönlendirme algoritması ile yönlendirilerek görüntülerin sınıflandırılması sağlanmaktadır.

Bölüm 2’de sunulmuş olan literatürdeki çalışmalar, dermatoskop görüntülerinin sınıflandırılmasında kapsül ağının kullanılması durumunda evrimsel ağlara göre daha yüksek performans elde edildiğini göstermiştir. Fakat literatürde önerilmiş olan ağ mimarileri lezyonların iki sınıfa ayrıştırılmasında kabul edilebilir sonuçlar verse de dezavantajları ve farklı sınıftan cilt lezyonlarının birbirlerine benzerlikleri nedeniyle, lezyonların daha fazla sınıfa sınıflandırılmasında yeterli olamamaktadır. Bu nedenle, yeni bir ağ yapısının geliştirilip uygulanmasına ihtiyaç duyulmaktadır.

Bu tez çalışmasında dermatoskop görüntüsünden yüksek doğruluk ile lezyonların yedi sınıfa otomatik olarak sınıflandırılmasını sağlayan, evrimsel derin sinir ağ mimarisi ve kapsül ağın birlikte kullanıldığı bir yöntem önerilmiştir. Sonuçların değerlendirilmesi için doğruluk, hassaslık, özgüllük, F1-skor ve Mathew ilişkilendirme katsayısı olmak üzere beş farklı değerlendirme ölçütü kullanılmış ve sırasıyla %88.10, %89.18, %98.11, %87.25, %86.20 değerleri elde edilmiştir. Ulaşılan bu bulgular cilt lezyonlarının otomatik olarak sınıflandırılmasında önerilen bütünleşik ağ mimarisinin başarılı olduğunu göstermiştir.

Bu tez çalışması kapsamında önerilen yöntemin kullanılması sayesinde, dermatologlara hastalıklar ile ilgili olarak karar verme süreçlerinde destek sağlanmış olunacaktır.

Tez çalışmasının birinci bölümünde cilt hastalıkları ve önemi, bu hastalıkların teşhisi, otomatik olarak lezyonların tespit edilmesi ve sınıflandırılması için kullanılan yaklaşımlar hakkındaki bilgilere değinilmiştir. İkinci bölümde cilt lezyonlarının derin öğrenmeye dayalı olarak sınıflandırılması ile ilgili literatürde yapılmış olan çalışmalar sunulmuştur. Üçüncü bölümde bu tez çalışması kapsamında kullanılan materyal, cilt lezyonu tespitinde literatürde yaygın kullanılan evrimsel derin ağ mimarileri ve kapsül ağ mimarisinin özellikleri hakkında bilgi verildikten sonra önerilen yöntem açıklanmıştır. Üçüncü bölümde ayrıca çalışmalarımızda elde edilen verilerin değerlendirilmesi için kullanılan değerlendirme ölçütleri açıklanmıştır. Dördüncü bölümde, uygulamalarımızdan ulaşılan bulgular sunulmuştur. Beşinci bölümde çalışmalarımızda kullanılan ağ mimarileri hakkında tartışmalara yer verilmiş ve son bölümde de ulaşılan sonuçlar açıklanmıştır.

2. KAYNAK TARAMASI

Bu bölümde, literatürde cilt lezyonlarının otomatik olarak sınıflandırılması için kullanılmış olan derin öğrenmeye dayalı yöntemler sunulmuştur. Literatürde çoğunlukla evrişimsel derin ağ mimarileri kullanılmakla birlikte az sayıda da olsa kapsül ağ mimarilerinin de kullanıldığı gözlenmiştir.

Bölüm 2.1’de evrişimsel derin sinir ağ mimarileri ile önerilen yöntemlere yer verilmiş, Bölüm 2.2’de ise kapsül ağ mimarileri ile önerilen yöntemlere yer verilmiştir.

2.1. Evrişimsel Derin Ağ Mimarileri ile Cilt Lezyonu Sınıflandırma Yöntemleri

Cilt lezyonlarının tespiti ve sınıflandırılması ile ilgili olarak yapılmış olan çalışmalarda çeşitli özelliklere sahip evrişimsel derin sinir ağ mimarileri kullanılmıştır.

Örneğin, güncel bir çalışmada cilt lezyonlarını sınıflandırmak için derin sinir ağ yapısı olarak VGGNet19 ve ResNet50 kullanılmış ve sonuçlar karşılaştırılmıştır (Xie vd. 2019). Bu çalışmada, farklı büyütmelemlerle elde edilen nicel sonuçlar, ResNet50 ağ yapısı kullanılarak gerçekleştirilen lezyon sınıflandırmanın doğruluk ve duyarlılık değerlerinin VGGNet19 ağ yapısı ile gerçekleştirilen sınıflandırmadan daha iyi olduğunu göstermiştir.

ResNet101 ağ yapısı kullanılarak yapılan bir sınıflandırma çalışmasında da cilt lezyonları kötü huylu ve iyi huylu olarak iki sınıfta sınıflandırılmış ve çeşitli oranlardaki gürültü değerlerinin sınıflandırma sonuçlarına etkisi incelenmiştir (Xue vd. 2019). Yapılan çalışmalar ile, görüntülerdeki gürültü oranı arttıkça sınıflandırma sonuçlarının düşük çıktığı gösterilmiştir.

Cilt lezyonlarının melanoma olup olmadığını belirlemek için yapılan bir çalışmada derin ağ mimarisi olarak GoogleNet kullanılmış ve başarılı bir şekilde sınıflandırmanın sağlanabildiği gösterilmiştir (Hirano vd. 2020).

Lezyonları melanoma ve melanocytic nevi olmak üzere iki sınıfa sınıflandırılması için yapılan bir çalışmada da GoogleNet ve AlexNet mimarileri birlikte kullanılmış, bu iki lezyon türünün tespit edilmesinde kullanılan birleşik ağ mimari yapısının başarılı olduğu gösterilmiştir (Sallam vd. 2020).

Ölümcül olan kötü huylu melanoma lezyonlarının otomatik olarak tespit edilmesi için geliştirilen bir yöntemde AlexNet ile VGG16 ağ mimarileri birlikte kullanılmıştır (Gulati ve Bogal 2019). Bu iki ağ yapısını ayrı ayrı kullanmak yerine birleştirilmesi durumunda daha iyi sonuç verdiği gösterilmiştir.

Bir başka çalışmada ise melanoma lezyonlarının tespiti için ResNet mimarisi 7, 10, 25, 40 ve 50 olmak üzere farklı sayıdaki katmanlar ile oluşturulmuş ve en iyi performansın 50 katmanlı ResNet mimarisi ile elde edildiği gösterilmiştir (Budhiman vd. 2019).

İyi huylu nevi lezyonları ile kötü huylu melanoma lezyonlarının ayrıştırılması için yapılan bir sınıflandırma çalışmasında da InceptionV3 kullanılmıştır (Ridell ve Spett 2017).

Lezyonların kötü huylu ve iyi huylu olarak sınıflandırılması için uygulandığı bir çalışmada da VGG16 ile ResNet50 mimarisi karşılaştırılmış ve ResNet50 ile elde edilen sonuçların VGG16 mimarisi ile elde edilen sonuçlara göre daha iyi olduğu gösterilmiştir (Bechelli ve Delhommelle 2022).

Lezyonların iyi huylu ve kötü huylu olarak sınıflandırılması ile ilgili bir başka çalışmada da InceptionV3, ResNet ve VGG19 mimarileri uygulanıp sonuçları karşılaştırılmış ve bu ikili sınıflandırma için en iyi mimarinin InceptionV3 olduğu belirtilmiştir (Mijwil 2021).

DenseNet121 ve DenseNet264 mimarileri de lezyonların sınıflandırılmasında kullanılmış (Munaf vd. 2021; Zare ve Pourkazemi 2021; Stofa vd. 2022), yoğun evrişim katmanlarının olduğu ve derinliğin artırıldığı ağ mimarileri ile lezyonların başarılı bir şekilde sınıflandırıldığı gösterilmiştir.

Farklı bir çalışmada ise VGG16 mimarisine ResNet mimarisindeki gibi artık bağlantı yapıları eklenerek oluşturulan evrişimsel ağ modeli lezyonların sınıflandırılması için uygulanmış, sadece VGG16 mimarisinin uygulanması ile ulaşılan sonuçlara göre daha başarılı bir performans elde edilmiştir (Yan vd. 2022).

Cilt lezyonlarının BCC hastalığına ait olup olmadığına karar verilmesi için lezyonların otomatik olarak sınıflandırılması ile ilgili yapılan güncel bir çalışmada ise evrişimsel katmanlardan oluşan derin ağ mimarisinde, görüntülerden elde edilen renk ve desen özellikleri de kullanılmıştır (Serrano vd. 2022). Renk bilgisine dayalı özelliklerin elde edilmesi için renk uzayı dönüşümü uygulanırken, desen özelliklerinin elde edilmesi için gri seviye eş dönüşüm matrisi uygulanmıştır. Sınıflandırma sonuçları eklenen özelliklerin kullanımı ile sınıflandırmanın daha iyi bir performans ile sağlandığını göstermiştir.

Genel ortalama havuzlama ve toplu normalizasyon işlemlerinin eklenerek VGG16 mimari yapısının cilt lezyonlarının sınıflandırılmasında performansı yakın zamandaki bir başka çalışmada değerlendirilmiş ve mimarinin lezyonları sınıflandırmadaki becerisinin arttığı gözlenmiştir (Tabrizchi vd. 2022).

Lezyonların melanoma olup olmadığının tespiti için gerçekleştirilen bir çalışmada omurga olarak VGG16, VGG19, GoogleNet ve ResNet50 mimarileri ayrı ayrı uygulanmış ve diğerlerine göre GoogleNet ile melanoma tespitinin daha başarılı bir şekilde sağlandığı belirtilmiştir (Aljohani ve Turki 2022).

Lezyonların melanoma olup olmadığına otomatik olarak karar verilmesi için gerçekleştirilen bir sınıflandırma çalışmasında da histogram eşitleme ve zıtlık iyileştirme adımlarından oluşan bir ön işleme aşaması uygulanmış ve omurga olarak AlexNet ağ yapısı kullanılmıştır (Govindaswamy ve Mallappa 2022). İyileştirilmiş görüntülerin ağ mimarisinde kullanılması sayesinde başarılı sınıflandırma sonuçlarının elde edilebildiği gözlenmiştir.

Literatürdeki çalışmalarda elde edilen sonuçlar farklı performans ölçütleri ile sunulmuş, farklı sayıda eğitim ve test görüntü verileri kullanılmıştır. Ayrıca çalışmalarda çoğunlukla lezyonların melanoma olup olmadığının tespiti üzerinde

durulup görüntüler iki sınıfa sınıflandırılmıştır. Bazı çalışmalarda da cilt lezyonları kötü huylu ve iyi huylu olmasına göre iki sınıfa sınıflandırılmıştır.

2.2. Kapsül Ağ Mimarileri ile Cilt Lezyonu Sınıflandırma Yöntemleri

Literatürde dermatoskop görüntülerinden cilt lezyonlarının sınıflandırılması için kapsül ağların önerildiği sadece birkaç tane çalışma bulunmaktadır (Pal vd. 2018; Boaro vd. 2020; Cruz vd. 2020; Pérez ve Ventura, 2021; Tiwari 2021). Bunlardan çalışmaların birisinde orijinal kapsül ağ modeli uygulanmış ve başarılı sonuçlara ulaşıldığı gösterilmiştir (Cruz vd. 2020).

Bir başka çalışmada lezyonların melanoma olup olmadığının belirlenmesi için iki sınıfa sınıflandırılmasında orijinal kapsül ağ mimarisindeki ilk evrişim katmanı yerine bir evrişimsel blok katmanı kullanılmıştır (Pérez ve Ventura, 2021). Kullanılan kapsül ağ mimarisinin diğer evrişimsel ağ mimarilerinden daha başarılı sonuçlar verdiği gösterilmiştir.

Psoriasis teşhisi için gerçekleştirilen bir sınıflandırma çalışmasında da kapsül ağ ile yapılan sınıflandırmanın ResNet50 mimarisi ile yapılan sınıflandırmadan daha iyi sonuçlara ulaşıldığı gösterilmiştir (Pal vd. 2018).

Bir başka çalışmada kötü huylu melanoma lezyonları ile iyi huylu nevi lezyonlarının sınıflandırılması için uygulanmış ikili sınıflandırma yönteminde orijinal kapsül ağ mimarisi kullanılmış ve evrişimsel bir derin sinir ağ mimarisinden daha başarılı olduğu gösterilmiştir (Tiwari 2021).

Diğer bir çalışmada ise VGG16 mimarisi ile kapsül ağ mimarisi birlikte kullanılmıştır (Boaro vd. 2020). Bu yöntemde VGG16 mimarisi ile daha fazla öznetelik çıkarımı sağlanabilmektedir. Fakat öznetelik çıkarımının daha etkili hale getirilmesi ile ağın performansının daha da iyileştirilmesi mümkündür. Ayrıca, bu çalışmada sadece melanoma tespitinin yapılması amaçlanmış ve görüntülerden lezyonların melanoma olup olmadığının belirlenmesi için iki sınıflı sınıflandırma yapılmıştır. Ağ mimarisinin performansı daha fazla sayıdaki sınıflandırma için değerlendirilmemiştir.

Literatürdeki kapsül ağ mimarisi ile yapılmış olan çalışmalarda genel olarak az sayıda görüntü kullanılmıştır. Ayrıca, yapılan çalışmalarda sadece bir veya birkaç tip cilt kanserinin sınıflandırılması üzerinde durulmuş, diğer cilt kanseri türlerinin sınıflandırılması için ağ mimarilerinin performansları araştırılmamıştır. Genellikle melanoma hastalığı ele alınmış, lezyonların melanoma olup olmadığını tespit etmek için iki sınıfa sınıflandırılması yapılmıştır. Bununla birlikte, cilt lezyonlarının iyi huylu ve kötü huylu olarak iki sınıfa sınıflandırıldığı çalışma da yapılmıştır.

Bu tez çalışmasında literatürdeki VGG16 mimarisi ile kapsül ağın birlikte kullanılması ile oluşturulan ağ mimarisi, görüntüleri iki sınıfa sınıflandırmak yerine 7 sınıfa sınıflandırılması için uygulanmıştır. Ağ mimarisi eğitilip test edilmiş ve elde edilen bulgulara göre daha başarılı sonuçların sağlanabileceği bir mimari oluşturulmuştur.

Bu tez çalışması kapsamında uygulanan ağ mimarisi ile kullandığımız veri setleri üzerinden 7 çeşit cilt lezyonunun sınıflandırılması için yapılmış bir çalışmaya literatürde rastlanılmamıştır.




3. MATERYAL VE METOT


Gerçekleştirilen tez çalışmasında 7 cilt hastalığı üzerinde durulmuş olup, materyal olarak bu hastalıkları gösteren dermatoskop görüntüleri kullanılmıştır. Kullanılan dermatoskop görüntü verileri açık erişimli olan HAM10000 veri tabanından (Tschandl vd. 2018) sağlanmıştır.

Bu veri tabanında her hastalık için görüntü verilerinin sayıları eşit değildir. Bu tez çalışması kapsamında ele alınan cilt hastalıkları için veri sayıları şöyledir:

- 1) Actinic Keratosis and Intraepithelial Carcinoma (AKIEC): 327 görüntü
- 2) Vascular Lesion (VASC): 142 görüntü
- 3) Melanocytic Nevi (MN): 6705 görüntü
- 4) Dermatofibroma (DF): 115 görüntü
- 5) Basal Cell Carcinoma (BCC): 514 görüntü
- 6) Melanoma (MEL): 1113 görüntü
- 7) Benign Keratosis Lesion (BKL): 1099 görüntü

Şekil 3.1’de bu cilt hastalıklarını gösteren HAM10000 veri tabanından alınmış olan görüntülerden örnekler sunulmuş olup, aynı sınıftaki lezyonların çeşitliliği ve farklı sınıftaki lezyonların benzerlikleri de görüntülerde gözlenebilmektedir.





Şekil 3.1. Bu çalışma kapsamında ele alınan hastalıklara ait HAM10000 veri tabanından alınmış görüntü örnekleri: **a)** MEL; **b)** AKIEC; **c)** DF; **d)** BCC; **e)** BKL; **f)** MN; **g)** VASC

Bu çalışmada, dermatoskop görüntülerinden cilt hastalıklarının tespiti ve sınıflandırılması derin öğrenmeye dayalı olarak ve kapsül ağ yapısı kullanılarak gerçekleştirilmiştir. Bu nedenle, öncelikle derin öğrenme yaklaşımı Bölüm 3.1’de anlatılmış ve cilt lezyonlarının tespiti için yaygın olarak kullanılan evrimsel derin ağ mimarileri Bölüm 3.2’de tanıtılmıştır. Çalışmamızda omurga olarak kullanılan kapsül ağ yapısı ve özellikleri Bölüm 3.3’de açıklanmış olup, bu tez çalışması kapsamında önerilen metot ve gerçekleştirilen adımlar Bölüm 3.4’de sunulmuştur.

3.1. Derin Öğrenme


Derin öğrenme yaklaşımı, biyolojik beyindeki sinir ağlarında öğrenmenin nasıl gerçekleştiği dikkate alınarak geliştirilmiştir. Bir yapay sinir ağında, ağırlıklı sinapslar ile birbirlerine bağlanmış katmanlar ve nöronlar bulunmaktadır (Patrick vd. 2022). Ağırlıklar, bu yapay sinir ağı tarafından öğrenmenin gerçekleşmesini sağlayacak şekilde bir geri yayılım (*back propagation*) algoritması ile ayarlanmaktadır (LeCun vd. 2012; Nielsen 2015). Bir sinir ağı, eğitim verilerinden bir dizi çıktıyı öğrenmek için eğitilir. Eğitim sürecinde optimizasyon amaç fonksiyonunun en büyük veya en küçük değeri hesaplanarak sağlanır. En küçük değerin hesaplanması için yararlanılan fonksiyon “kayıp fonksiyonu” olarak adlandırılır (Goodfellow vd. 2017). Kayıp fonksiyonu, skaler bir değerle modelin tüm özelliklerini ve dolayısıyla modelin performansını temsil eder (Reed ve Marks II 1999). Kayıp fonksiyonunun değerini en aza indirmek için, sinir ağının ağırlık değerleri her devirden (*epoch*) sonra bir iyileştirici (*optimizer*) ile hesaplanır ve güncellenir.

Derin öğrenmeye dayalı algoritmalar içinde çok çeşitli sınıflandırma modelleri kullanılmaktadır. Bu modellerden en yaygın kullanılan evrimsel sinir ağ modelleridir. Bu ağ mimarilerinin tercih edilmesinin temel nedeni, evrim işlemleri sayesinde

herhangi bir ön bilgiye ihtiyaç duymadan, verilerden özniteliklerin çıkarılmasını otomatik olarak öğrenebilmesidir.

İlk evrişimsel sinir ağ mimarisi, 2012 yılında gerçekleştirilen ImageNet yarışmasında açıklanan AlexNet mimarisidir. Bu mimarinin görüntüleri sınıflandırmadaki başarısı evrişimsel sinir ağlarına olan ilgiyi artırmış, bu ağ mimarisinden eklenen katmanların özelliklerine, bulunduğu yerlere ve sayılarına bağlı olarak değişik modeller oluşturulmuştur. Mimariye eklenen katmanların özellikleri ve sayıları uygulamaya ve kullanılacak verilere göre bağlı olarak farklılaşmaktadır. Bu farklılıklar ile oluşturulmuş bir evrişimsel ağ modeli olan VGGNet 2014 yılında, daha iyi bir model olarak geliştirilen ResNet ise 2016 yılındaki ImageNet yarışmasında birinci olmuştur.

Bir evrişimsel sinir ağı temel olarak Şekil 3.2'de gösterildiği gibi 3 temel katmandan oluşmaktadır.




Şekil 3.2. Bir evrişimsel derin sinir ağ mimarisinde bulunan katmanlar

En genel anlamı ile bu ağ mimaride; ardışık evrişim katmanları ile köşe, desen ve kenar gibi düşük seviyeli öznitelikler çıkarılmakta ve daha sonra, bu öznitelikler daha yüksek seviyeli özniteliklerin oluşturulması için daha derin katmanlarda birleştirilmektedir.

Ağ mimarisindeki her bir katmanın işlevi şöyle açıklanabilir:

- Evrişim katmanı (*Convolutional Layer*): Çoğunlukla paralel olarak birkaç evrişim işlemi gerçekleştirmekte olup, öznitelikleri belirlemek için kullanılmaktadır.
- Havuzlama katmanı (*Pooling Layer*): Havuzlama, doğrusal olmayan alt örnekleme (sub-sampling) bir biçimdir.
- Tam bağlantılı katman (*Fully Connected Layer*): Düzleştirme (*flattening*) ile tek boyutlu dizi haline dönüştürülen havuzlama katmanının çıktısı bu katmanda kullanılır. Her dizideki her değer, belirli bir özelliğin bir etikete ait olma olasılığına karşılık gelir.

Evrişim işlemi, alıcı (*receptive*) alanları biçimlendirmek için, girdi olarak kullanılan görüntü verileri üzerinde filtreleme bir çekirdek (*kernel*) fonksiyonunun kaydırılması ile gerçekleştirilmektedir. Şekil 3.3'de, 3x3'lük bir çekirdek fonksiyonun giriş verileri üzerinde kaydırılması ile sağlanan evrişim işlemi gösterilmiştir.



Şekil 3.3. Çekirdeğin girdi verileri üzerinde kaydırılması ile alıcı bölgelerin (*receptive fields*) oluşturulmasını sağlayan evrişim işlemi

Evrişim katmanlarında görüntü üzerinde bir “filtre” (süzgeç) uygulanarak görüntüdeki düşük düzeyli ve daha sonra da yüksek düzeyli öznitelikler belirlenir. Düşük düzeyli öznitelikler, noktalar ve çizgiler gibi görüntüdeki küçük ayrıntılar olup, görüntüde bulunan nesneleri, daha büyük ve karmaşık şekilleri algılamak üzere bu düşük düzeyli özniteliklerden yüksek düzeyli öznitelikler oluşturulmaktadır.

Süzgeç çoğunlukla, öznitelik haritasının oluşturulması amacıyla bir girdi verisi dizisi ile çarpılan çok boyutlu piksel değerlerinin dizisini ifade eder. Evrişim işlemi, görüntünün her bir uzaysal konumunda filtrenin tepkisini gösteren, özellik veya aktivasyon haritası olarak bilinen görüntünün iki boyutlu bir temsiliyi oluşturur.

Filtreler giriş görüntüsünün boyutuna uymadığında piksel ekleme (*padding*) işlemi uygulanmaktadır. Filtrenin giriş görüntüsü üzerinde hareket etmesi, adım kaydırma olarak adlandırılmaktadır. Filtrenin giriş görüntüsü üzerinde hareket ettiği piksel sayısı ise adım büyüklüğü (*stride*) olarak adlandırılmaktadır.


Evrişim işlemi uygulandıktan sonra oluşan çıktının boyutu şu denklem ile elde edilmektedir:

$$\text{Çıktı boyutu} = \frac{B - F + 2P}{S} + 1 \quad (3.1)$$

Denklem (3.1)'de, S filtrenin adım büyüklüğünü, B girdi verisinin boyutunu, F filtre boyutunu ve P piksel ekleme miktarını (*padding*) göstermektedir.

Bir özellik haritası oluşturulduktan sonra bu özellik haritasındaki her bir değer, evrişim katmanından sonra yerleştirilen ve hangi nöronun aktif edileceğine karar veren bir aktivasyon fonksiyonundan geçirilmektedir. Genellikle bu aktivasyon fonksiyonu düzleştirilmiş doğrusal birim olarak ifade edilen *ReLU*'dir. Aktivasyon fonksiyonundan elde edilen çıktılar, havuzlama katmanına iletilmektedir. Havuzlama katmanının

kullanılmasının nedeni, temsilin uzaysal boyutunu küçültmek, bu sayede ağ modelinde kullanılan parametre sayısını azaltmaktır. Şekil 3.4'te gösterildiği gibi, farklı havuzlama yöntemleri mevcut olup, en yaygın olarak kullanılanı maksimum havuzlama yöntemidir. Bu havuzlama yönteminde, öznitelik haritasında filtrenin kapladığı her bölgeden en çok dikkat çeken değer (maksimum olan) üretilmektedir. Başka bir deyişle, en aktif olan özellikler kullanılmakta, diğer piksel bilgileri kullanılmamaktadır. Ortalama havuzlama yönteminde, öznitelik haritasında filtrenin kapladığı her bölgedeki değerlerin ortalaması üretilmektedir. Genel ortalama ve genel maksimum havuzlama yöntemlerinde ise, filtrenin kapladığı bölge dikkate alınmaksızın, öznitelik haritasındaki tüm değerlerin ortalaması ve maksimum değerleri üretilmektedir. Havuzlama katmanında yer alan öznitelik haritaları, düzleştirme (*flattening*) işlemi uygulanarak ile tek boyutlu dizi değerlerine dönüştürülmektedir.



Şekil 3.4. Havuzlama yöntemleri


Mimaride en sonda bulunan *softmax* fonksiyonu, ikiden fazla sınıflandırma yapılması gereken durumlarda tercih edilen, girdi verisinin bir sınıfa dahil olma olasılığını 1 ile 0 aralığında değerler üreterek belirlenmesini sağlamaktadır.

3.2. Cilt Lezyonu Tespitinde Yaygın Kullanılan Evrişimsel Derin Ağ Mimarileri

Literatürde cilt lezyonlarının tespiti için AlexNet, GoogleNet, VGGNet, ResNet, InceptionNet ve DenseNet genellikle tercih edilen mimariler olmuştur. Bu nedenle, bu bölümde bu ağ mimarileri açıklanmıştır.

3.2.1. AlexNet mimarisi


AlexNet mimarisinde 5 tane evrişimli katman, 3 tane maksimum havuzlama katmanı, 3 tane tam bağlı katman ve sınıflandırma için softmax katmanı bulunmaktadır. Evrişim ve tam bağlı katmanlardan sonra aktivasyon için ReLU fonksiyonu kullanılmaktadır. Şekil 3.5'te AlexNet mimari yapısı gösterilmektedir.



Şekil 3.5. AlexNet mimarisi (Krizhevsky vd. 2017)


3.2.2. GoogleNet mimarisi

22 ağırlık katmanı içeren bu mimaride ezberleme olasılığını azaltmak için paralel olarak birbirine bağlı katmanlar kullanmıştır. 3 adet çok katmanlı algılayıcı yapısı ile evrimsel ağ ve ortalama havuzlama (*average pooling*) işlemlerinden oluşmaktadır. Havuzlama katmanları ile birlikte toplam 27 katmandan oluşmaktadır. 9 adet *inception* modülü bulundurmakta olup, Şekil 3.6’da boyutu küçültülmüş bir *inception* modülü sunulmuştur. 5x5 ve 3x3 evrişim işlemlerinden önce fazladan 1x1 evrişim işlemi eklenerek giriş kanal sayısı sınırlandırılmaktadır. 1x1 evrişim işlemi maksimum havuzlama katmanından sonra eklenmektedir.



Şekil 3.6. Boyutu küçültülmüş bir *inception* modülü (Szegedy vd. 2015)


Şekil 3.7’de 22 katmanlı ve 9 tane *inception* modülü içeren GoogleNet mimarisi gösterilmektedir.



Şekil 3.7. GoogleNet mimarisi (Szegedy vd. 2015)

3.2.3. VGGNet mimarisi

İlk başta 13 tane evrişimsel katmanı olan VGG16 mimarisi geliştirilmiş olup, daha sonra 3 tane daha evrişimsel katmanın eklenmesi ile VGG19 mimarisi geliştirilmiş ve sınıflandırma çalışmalarında kullanılmıştır. VGG16 mimarisinde 16 ağırlık katmanı (13 tanesi evrişimsel katman, 3 tanesi tam bağlı katman) olup, ReLU ve *Softmax* katmanlarıyla birlikte toplamda 41 katmandan oluşmaktadır. Bu mimarinin özelliği, ikili ya da üçlü evrişimsel katmanlarının ardından havuzlama katmanlarının kullanılmasıdır. VGG16 mimarisinin derinliğinin artırılması ile oluşturulmuş bir ağ modelidir. Şekil 3.8'de VGG16 mimari yapısı yer almaktadır.




Şekil 3.8. VGG16 ağ mimarisi (Simonyan ve Zisserman 2014)

Ağ mimarisinde kullanılan evrişim filtre boyutları 3x3 olup derinlikleri değişmektedir. Filtre kaydırma adım büyüklüğü 1 piksel olup, dolgu (*padding*) değeri çıktının boyutlarını değiştirmeyecek şekilde 1 ve 0 olarak ayarlanmıştır. Toplam 5 defa

maksimum havuzlama (*maximum pooling*) uygulanmaktadır. Maksimum havuzlama için filtre boyutu 2x2 olup, kaydırma adım büyüklüğü 2 olarak alınmaktadır. Evrişim katmanlarını tam bağlı katmanlar izlemekte ve ilk iki tam bağlı katmanın her birinde 4096 adet nöron yer almaktadır.

3.2.4. ResNet mimarisi


ResNet ağ mimarisinde toplu normalizasyonlar (*batch normalizations*) ve artık bağlantı (*residual connection*) yapısı kullanılmaktadır. Şekil 3.9’da gösterildiği gibi, artık bağlantılar bir ağ katman çıktısını daha derin olan bir katmana iletmektedir. Artık bağlantı yapısında 3x3 boyutunda filtre kullanıp, adım büyüklüğü 2 alınarak evrişim işlemlerinin uygulandığı 2 adet evrişim katmanı bulunmaktadır.



Şekil 3.9. Artık bağlantı yapısı

Artık bağlantıların kullanılmasının sebebi, daha iyi sonuçların elde edilebilmesi için mimarilerin derinliklerinin artırılması nedeniyle oluşan kaybolan gradyan (*vanishing gradient*) problemini ortadan kaldırmaktır. Artık bağlantılar kullanıldığında, ağın derinliği artmış olsa da gradyan kaybı önlenebilmektedir.


Bu tez çalışmasında 18 ağırlık katmanı bulunan ResNet18 mimarisi kullanılmış olup Şekil 3.10’da bu mimari yapısı gösterilmiştir. Bu mimarideki derinliğin artırılması ile ResNet34, ResNet50, ResNet101 gibi modeller elde edilmiştir.



Şekil 3.10. ResNet18 ağ mimarisi

3.2.5. InceptionNet mimarisi


Bu ağ mimarisi, her birisinde farklı boyutlardaki evrişim ve havuzlama katmanları bulunan, farklı *inception* modüllerinden oluşmaktadır. InceptionV3 versiyonunda, InceptionV1 ve InceptionV2 olarak adlandırılan önceki iki versiyonundan farklı olarak, mimarinin daha düzenli olmasını sağlamak için eklenmiş olan grup normalizasyon katmanı ve tam bağlı katman bulunmaktadır. Şekil 3.11’de InceptionV3 yapısı gösterilmiştir.



Şekil 3.11. InceptionV3 ağ yapısı (Szegedy vd. 2016)

3.2.6. DenseNet mimarisi

Yoğun bloklardan (dense block) oluşan bu ağ yapısında bir katman diğer katmana ileri beslemeli olarak bağlanmıştır. Özniteliklerin tekrar kullanılmasını ve yayılımını sağlamak için oluşturulan bu ağ modelinde, Şekil 3.12’de gösterildiği gibi, 3 geçiş katmanı ve 4 yoğun blok içeren mimaride toplam 121 katman bulunmaktadır.



Şekil 3.12. DenseNet mimarisi

3.3. Kapsül Ağ Mimarisi ve Özellikleri

Kapsül ağlarda, evrişimsel sinir ağlarındaki nöronlar yerine kapsüller kullanılmakta ve dinamik yönlendirme yapılmaktadır. Bir kapsül, görüntünün belirli bir

bölgesindeki bir nesnenin algılanmasını öğrenmiş olan bir grup nörondan oluşmaktadır. Bir kapsülün çıktısı bir vektör olup, uzunluğu görüntüde bulunan nesnenin varlığını temsil etmektedir. Bu vektörün yönelimi görüntüdeki nesnenin konumu, boyutu, dönüşü veya ölçeği hakkında bilgi verir.

Orijinal kapsül ağ mimarisinde (Sabour vd. 2017) ilk katman, evrışimsel sinir ağ mimarilerindeki gibi, görüntülere adım büyüklüğü (*stride*) 1 alınarak 9x9 boyutlu bir filtre ile evrışim işleminin uygulandığı ve ReLU aktivasyon fonksiyonunun kullanıldığı bir evrışim katmanıdır. Bu katmanda kenar ve renk gibi temel özniteliklerin çıkarımı yapılmaktadır. Oluşturulan öznitelik haritasındaki değerler, bu katmandan sonra gelen öncül veya birincil (*primary*) kapsül katmanı olarak adlandırılan katmana aktarılır.

Birincil kapsül katmanında önceki katmandan gelen öznitelik haritasındaki değerler, kapsül boyutlarına uygun olacak şekilde tekrar boyutlandırılıp (*re-shaping*) vektörel gösterimi (*vector representation*) sağlanır. Bu katmandaki her kapsül (bir grup nöron) bu vektörler ile beslenir. Başka bir deyişle, bu katman öznitelik haritalarındaki değerlerin vektörel gösterimini temsil eden kapsüllerden oluşur. Kısaca, birincil kapsül katmanı önceki katmandan gelen nöronların çıktılarından, çıktısı (görüntüdeki bir özelliği temsil eden) bir vektör olan kapsülleri üretir. Bir kapsül vektörünün normu, kapsül tarafından temsil edilen nesne parçasının veya nesnenin girdi olarak kullanılan görüntüde var olma olasılığına karşılık gelir. Bu nedenle, bir kapsülün her boyutu görüntüdeki bir nesne veya nesne parçasının konum, desen, yön ve renk gibi bir özelliği olarak ifade edilebilir. Bu özelliklerin bir kapsülde bulunması, o özellik nöronlarının aktif olmasını sağlar.

Vektörel gösterim sağlandıktan sonra birincil kapsül katmanında da evrışim işlemi uygulanmaktadır. 32 kapsülden oluşan bu katmanda, adım büyüklük değeri 2 alınıp 9x9'luk bir filtre ile evrışim işlemi uygulanmaktadır. Evrışim katmanından farklı olarak bu katmanda evrışim işleminin çıktıları, kapsül düzeyinde aktivasyonu sağlayan, doğrusal olmayan bir fonksiyon olan ezme (*squash*) fonksiyonuna aktarılmaktadır.

Birincil kapsül katmanından sonra, daha karmaşık özniteliklerin çıkarıldığı ClassCaps olarak da adlandırılan ikincil (*secondary*) kapsül katmanı bulunmaktadır. İkincil kapsül katmanındaki her sınıf için bir kapsül bulunur. Birincil kapsül katmanının çıktıları dinamik yönlendirme algoritması ile bu katmana aktarılır.

Dinamik yönlendirme algoritması alt seviyedeki (birincil katmandaki) bir kapsülün çıktısını üst seviyedeki (ikincil katmandaki) en uygun kapsüle yönlendirerek, bu kapsüller arasındaki iletişimi sağlar. Alt seviyedeki her kapsülün üst seviyedeki her kapsüle yönlendirilmesi olasılığı vardır. Bu algoritma ile hesaplanan, birleştirme veya bağlantı katsayısı olarak adlandırılan ağırlık değeri bu olasılığı ifade eder. Dinamik yönlendirme algoritması alt seviyedeki her kapsül ile üst seviyedeki olası kapsüller arasında bu bağlantı katsayıları ile ilişkilendirme (bağlantı) sağlar. Bu bağlantı katsayılarının toplamı 1'dir. Dinamik yönlendirme işleminde bu bağlantı katsayı değerleri yinelemeli (*iterative*) olarak iyileştirilir. Başka bir ifade ile, dinamik yönlendirme mekanizması, bir kapsülün çıkışı ile bir sonraki kapsül katmanının girişi arasındaki optimal bağlantıyı güçlendirir. Bu sayede, alt katmandaki kapsüllerin üst katmandaki belirli bir kapsüle odaklanıp diğerlerini görmezden gelmesi sağlanarak katmanlar arasında kapsüller yönlendirilmiş olur.

Dinamik yönlendirme algoritmasının işleyişi şöyle gerçekleşir:

Alt seviyedeki her kapsülün çıktısı bir u vektörüdür. Alt seviyedeki her kapsülün üst seviyedeki bağlantı kurulacağı olası her bir kapsül için bir tahminleme vektörü $\hat{u}$ hesaplanır. Bunun için kapsüllerin çıktıları, alt ve üst seviyedeki kapsüller arasındaki bağlantıları içeren bir ağırlık matrisi W ile çarpılır. Bu matris bir nesnenin parçası ile daha önemli olan parçası arasındaki uzaysal ilişkiyi kodlayan bir doğrusal dönüşüm matrisidir. Bu çarpım ile tahminleme vektörü şu formül kullanılarak hesaplanır;

$$\hat{u} = W.u \quad (3.2)$$

Tahminleme vektörünün üst seviyedeki olası bir kapsül vektörü olan v ile skaler çarpımının (*dot product* veya *inner product*) sonucu tek bir sayı değeri olup,

$$a = v.\hat{u} \quad (3.3)$$

ile ifade edilir. Eğer bu a değeri büyükse, alt seviyedeki o kapsül ile üst seviyedeki o kapsül arasında bulunan bağıntı, bağlantı katsayısının artırılması ile güçlendirilir, üst seviyedeki diğer kapsüller ile olan bağıntısı ise bağlantı katsayısının azaltılması ile zayıflatılır. Her kapsülün çıktısı ezme aktivasyon fonksiyonuna gönderilir. Bu sayede, alt ve üst kapsüller arasındaki bağlantı katsayıları dinamik yönlendirme algoritması ile yinelemeli olarak güncellenir. Bağlantı katsayılarının hesaplanması, kapsüller arasındaki uyumu, yani üretilen a değerlerini kullanan ve bunları olasılıklara dönüştüren *softmax* fonksiyonu ile sağlanır.

Yinelemeli olarak bu yönlendirme işleminin nasıl gerçekleştiğini açıklamak için; alt düzeydeki i 'ninci kapsüle u_i , üst düzeydeki j 'ninci kapsüle v_j diyelim. Alt düzeydeki u_i kapsül vektörlerine *affine* dönüşüm matrisi W_{ij} şu denklem ile uygulanır:

$$\hat{u}_{i|j} = W_{ij}u_i \quad (3.4)$$

Bu çarpım ile tahmin vektörü olan $\hat{u}_{i|j}$ elde edilir. Bu tahmin vektörü ile, i 'ninci kapsülün j 'ninci kapsülü ne kadar aktif edebileceğini bağlantı katsayısı olan c_{ij} 'ler belirler. Bu nedenle, c_{ij} değerleri ile bu tahmin vektörleri çarpılıp toplamaları hesaplanır. Bu adım şöyle yazılır ve ağırlıklı toplam olan s_j değerini verir:

$$s_j = \sum_i c_{ij}\hat{u}_{i|j} \quad (3.5)$$

Bir j kapsülü için ağırlıklı toplam girdiyi ifade eden bu s_j değerlerinden aynı kapsülün çıktısı olan v_j 'ler elde edilir. Bu işlem şu denklem ile yazılan ezme aktivasyon fonksiyonu kullanılarak gerçekleştirilir:

$$v_j = \frac{\|s_j\|^2}{1+\|s_j\|^2} \frac{s_j}{\|s_j\|} \quad (3.6)$$

Ezme fonksiyonu, kapsül çıktıları vektör olduğundan yön bilgisinin değişmemesi için, çıktı vektörünün normunu 0 ile 1 arasında olmaya zorlarken vektörün yönünün korunmasını sağlamaktadır. Çıktı vektörü olan, her v_j vektörünün yönü ve büyüklüğü (*magnitude*) vardır. Bu büyüklük değeri kapsül tarafından kodlanan özelliğin

var olma olasılığını ifade eder. Vektörün yönü ise nesnenin konum ve eğim gibi bazı karakteristik özelliklerini ifade eder. Ezme fonksiyonu ile, kısa vektörler neredeyse sıfır norma, uzun vektörler ise bir norma indirgenir. Kapsül düzeyinde aktivasyon sağlayan ezme fonksiyonu, kapsül uzunluğunun 1'in altında olmasını garanti eder ve dolayısı ile farklı kapsüllerin kolayca sınıflandırılmasını sağlar.

Kapsül çıkış vektörü olan v_j ile tahmin vektörü olan $\hat{u}_{ij}$ skaler olarak çarpılarak kapsüllerin benzerliklerini ifade eden b_{ij} değerleri şöyle hesaplanır:

$$b_{ij} \leftarrow \hat{u}_{ij} v_j \quad (3.7)$$

Algoritmanın başlangıcında sıfır olan bu b_{ij} değerleri, alt düzey kapsül olan u_i 'nin üst düzey kapsül v_j 'ye yönlendirilip yönlendirilmeyeceğine karar veren bir ön olasılık (*prior probability*) değeridir. Başka bir deyişle, bağlantı katsayısı olan c_{ij} için ön olasılık değeridir. Bulunan b_{ij} değerleri kullanılarak bağlantı katsayısı olan c_{ij} 'lerin yeni değerleri *softmax* fonksiyonu ile şöyle hesaplanır:


$$c_{ij} = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})} \quad (3.8)$$

Denklem (3.8)'de k terimi sınıf sayısına karşılık gelmektedir.

Algoritmanın başlangıcında alt düzey kapsülün çıkışı üst düzeydeki tüm kapsüllere yönlendirilmekte, daha sonra s_j , v_j , ve c_{ij} değerleri yukarıdaki denklemler ile hesaplanıp b_{ij} elde edilmektedir. Bu b_{ij} değerlerinin daha doğru olması için (çoğunlukla 3 yinleme olmak üzere) aşağıdaki denklem ile yinelemeli (*iterative*) olarak değeri güncellenir:

$$b_{ij} = b_{ij} + \hat{u}_{ij} v_j \quad (3.9)$$

Eğer alt düzey kapsül kullanılarak bulunan tahminler üst düzey kapsülün çıktısına benzer ise aradaki bağlantı katsayısının değeri artar. Kapsül giriş ve çıkışı şekilsel olarak Şekil 3.13'de gösterilmiştir.



Şekil 3.13. Kapsül giriş çıkışı

Yukarıda açıklanan dinamik yönlendirme mekanizmasına ait algoritma Şekil 3.14’de yer almaktadır.

Algoritma Yönlendirme ($\hat{u}_{i|j}, l, t$)

Adım 1: katman l ’deki her kapsül i ve katman $(l+1)$ ’deki her kapsül j olmak üzere: $b_{ij} \leftarrow 0$

Adım 2: **for** t iterasyon **do**

Adım 3: katman l ’deki her kapsül i : $c_i \leftarrow \text{softmax}(b_i)$

Adım 4: katman $(l+1)$ ’deki her kapsül j : $s_j \leftarrow \sum_i c_{ij} \hat{u}_{i|j}$

Adım 5: katman $(l+1)$ ’deki her kapsül j : $v_j \leftarrow \text{squash}(s_j)$

Adım 6: katman l ’deki her kapsül i ve katman $(l+1)$ ’deki her kapsül j :
 $b_{ij} \leftarrow b_{ij} + \hat{u}_{i|j} v_j$

return v_j

Şekil 3.14. Dinamik yönlendirme algoritması

Dolayısı ile, bir kapsül ağı, ardışık kapsüller arasındaki bağlantı katsayılarını ayarlayarak ağın eğitimi süresince öznelilikleri, nesne parçaları ve bütün nesneler arasındaki uzamsal ilişkileri öğrenmektedir. Eğitim sürecinde ezberlemenin önlenmesi için dinamik yönlendirme üç defa yinelenir.

Kapsül ağ mimarisinde ikincil kapsül katmanına kadar olan kısım kodlayıcı (*encoder*) gibi işlev görürken, bu kapsül katmanından sonraki tam bağlantılı katmanların olduğu kısım kod-çözücü (*decoder*) gibi işlev görür. Çünkü tam bağlantılı katmanların kullanılmasının amacı yeniden oluşturma (*reconstruction*) olup, ikincil kapsül katmanından gelen temsili vektörler kullanılarak girdi olarak kullanılan görüntünün tekrar oluşturulmaya çalışılmasıdır. Tam bağlantılı katmanın çıktısı her sınıf için olasılık değerine sahip olan, sınıf sayısı kadar kapsülden oluşmaktadır.

Ağın eğitimi boyunca oluşan hatanın (kaybın) hesaplanıp öğrenme süresince gerekli geri bildirimin sağlanması için kayıp fonksiyon (*loss function*) kullanılarak hata hesaplaması yapılır. Bu hata hesaplaması marjın kaybı (*margin loss*) ve yeniden oluşturma kaybı (*reconstruction loss*) kullanılarak sağlanır. Marjın kayıp değerinin elde edilmesinde şu denklem ile bulunan her sınıfın marjın kayıp değeri kullanılır:

$$L_c = T_c \max(0, m^+ - \|v_c\|)^2 + \lambda(1-T_c) \max(0, \|v_c\| - m^-)^2 \quad (3.10)$$

Denklem (3.10)’da, c sınıfı için marjın kaybı L_c ile gösterilmiştir. Sabit bir değer olan T_c ise, eğer örnek c sınıfına ait ise 1, değil ise 0 değerini alır. λ , m^+ ve m^- sabit değerleri ise sırasıyla 0.5, 0.9 ve 0.1’dir. Marjın kaybının hesaplanması;


$$L_{margin} = \sum_c^N L_c \quad (3.11)$$

kullanılarak, her sınıf marjin kayıp değerinin toplanması ile sağlanır. Marjin kaybı olarak hesaplanan değere yeniden oluşturma kaybı (*reconstruction loss*) da hesaplanıp eklenir ve hata, şu toplam fonksiyon hata olarak hesaplanır;

$$L_{loss} = L_{margin} + \alpha L_{yenilolusturma} \quad (3.12)$$

Denklem (3.12)'deki α değeri bir sabit sayı olup orijinal kapsül ağ modelinde olduğu gibi genellikle 0.0005 olarak kullanılmakta ve yeniden oluşturma hata değerinin toplam fonksiyona katkısının en az olması sağlanmaktadır. Denklem (3.12)'deki $L_{yenilolusturma}$ (ortalama kare hatası) terimi, kapsül ağının çıktısı kullanılarak giriş verilerinin ne kadar iyi yeniden yapılandırıldığını gösteren bir terimdir. Bu terimin hesaplanmasında sadece girdi sınıfına karşılık gelen kapsül çıktısı kullanılır ve diğer sınıflardan gelen kapsül çıktıları kullanılmaz. Dolayısı ile, bir kapsül ağ mimarisinde kaybın hesaplanması, girdi olarak kullanılan görüntü ile kod çözücünden elde edilen çıktı arasındaki uzaklık (Öklid uzaklığı) en aza indirgenerek sağlanmaktadır.


Yukarıda açıklanmış olan katmanların bulunduğu kapsül ağ yapısı Şekil 3.15'de sunulmuştur.



Şekil 3.15. Kapsül ağ mimarisi

3.4. Önerilen Lezyon Tespit ve Sınıflandırma Metodu

Bu çalışmada 7 çeşit cilt lezyonunun tespiti ve sınıflandırılması için bütünleşik bir ağ modelinin kullanıldığı etkili bir metot geliştirilmiştir. Önerilen bu metot ardışık adımlardan oluşmakta olup, uygulanan adımları içeren bir akış şeması Şekil 3.16'da sunulmuştur. Akış şemasında belirtilen her bir adım ile ilgili açıklamalar aşağıda yer almaktadır.




Şekil 3.16. Çalışmalarda uygulanan adımları gösteren akış şeması

3.4.1. Veri setlerinin oluşturulması

Çalışmalarımızda HAM10000 veri tabanından alınan dermatoskop görüntüleri kullanılmıştır. Açık erişimli olan bu veri tabanındaki görüntü sayılarının dağılımı farklılık göstermektedir. Tasarlanan ağ modelinden elde edilen sınıflandırma sonuçlarının tarafsız olması için bu çalışmada her hastalık kategorisinden eşit sayıda görüntü kullanılmıştır. En az veri sayısı 115 görüntü ile DF sınıfında olduğundan, diğer hastalık gruplarının her birisinden 115 görüntü verisi alınarak veri setleri oluşturulmuş ve toplam 805 görüntü kullanılmıştır.

3.4.2. Ağ modelinin oluşturulması

Önerilen ağ modeli hem bir evrimsel ağ mimarisi olan ResNet mimarisinin avantajına hem de kapsül ağ mimarisinin avantajına sahip, bütünleşik bir modeldir. Bu model, Şekil 3.17’de sunulan ve Bölüm 2’de açıklanmış olan (Boaro vd. 2020) hibrit mimariden ilham alınarak geliştirilmiştir.




Şekil 3.17. VGG16 ve kapsül ağı kullanıldığı mimari (Boaro vd. 2020)

Bu tez çalışması kapsamında önerilen ağ mimarisinin Şekil 3.17’deki mimariye göre performans artışını sağlayacak önemli farklılıkları vardır. Bu farklılıklar şöyle listelenebilir:

- 1) Şekil 3.17’deki VGG16 mimarisi yerine, önerilen modelde içerdiği artık bağlantılar ve daha fazla evrişim katmanı sayesinde, öznetelik çıkarma ve sınıflandırmada VGG16 mimarisine göre daha başarılı olduğu bilinen ResNet18 mimarisi kullanılmıştır.
- 2) Şekil 3.17’deki ağ modeli sadece tek bir cilt hastalığı (melanoma) için lezyon tespiti yapabilmekte, dolayısı ile görüntülerdeki lezyonların melanoma olup olmadığına bağlı olarak sonuç vermekte, yani ikili sınıflandırma (*binary classification*) yapabilmektedir. Önerdiğimiz ağ modeli ise 7 farklı cilt hastalığı için lezyonların tespit edilmesi ve sınıflandırılmasını sağlayacak şekilde geliştirilmiş olup, çok sınıflı sınıflandırma sağlamaktadır.
- 3) Şekil 3.17’deki ağ modelinde kapsül ağlara görüntüler bütün olarak verilmemiş, bir maske kullanılarak lezyon kısımları görüntülerden çıkarılmış ve lezyon görüntüleri girdi olarak kullanılmıştır. Gerçekleştirdiğimiz çalışmamızda ise lezyonların görüntülerden çıkarılması işlemi uygulanmayıp görüntüler bütün olarak kullanılmıştır. Bunun nedeni ise, Şekil 3.1’de sunulan örneklerden de görülebileceği gibi, farklı hastalık gruplarındaki lezyonlar benzerlik gösterebilmesi, sadece lezyonun üzerindeki desen ve renk gibi özneteliklere dayalı olarak yapılan sınıflandırmaların hatalara sebep olabilmesidir. Lezyonların hangi sınıfa ait olduğunun belirlenmesinde sadece lezyon üzerindeki öznetelikler değil, aynı zamanda deri renginin ve lezyon ile deri arasında kalan bölgelerdeki dokulara ait öznetelikler de etkilidir. Bu nedenle, dermatologlar görsel incelemeler ile lezyonların hangi sınıfa ait olduğunu belirlerken sadece lezyonun üzerindeki özellikleri değil, görüntünün tamamına bakarak karar vermektedirler. Geliştirdiğimiz yöntemde yüksek performans ile sınıflandırma sonuçlarının elde edilmesini sağlamak için, oluşturulan ağ modeli dermatologların bu yaklaşımlarının bir benzetimi olarak tasarlanmış olup, evrişimsel ağ katmanları ile özneteliklerin elde edilmesinde görüntüler bütün olarak kullanılmıştır. Bu sayede sadece lezyona ait öznetelikler değil, deriye ait

özniteliklerin ve lezyon kenar bilgilerinin de ağ modeli tarafından öğrenilmesi sağlanmıştır.

Önerilen ağ modelinin mimarisi Şekil 3.18’de sunulmuştur.



Şekil 3.18. Önerilen ağ mimarisi

Şekil 3.18’de görüldüğü gibi, oluşturulan ağ modelinde 224x224x3 boyutundaki dermoskop görüntüleri ilk olarak ResNet18 mimarisinde girdi olarak kullanılmaktadır.

ResNet18 mimarisinden elde edilen ağırlık değerleri, kapsül ağ mimarisinin ilk katmanı olan evrişim katmanına aktarılmaktadır. Böylece orijinal kapsül mimarisinden farklı olarak, kapsül ağların rastgele ağırlık değerleri ile başlatılması yerine, önerdiğimiz ağ modelinde daha iyi ağırlık değerleri ile başlatılması sağlanmaktadır.

Evrşim katmanından elde edilen ağırlık değerleri birincil kapsül katmanına aktarılmaktadır. Bu katmanda her bir kapsülün boyutu 16x16 olan 32 adet kapsül bulunmaktadır. Bu katmanın çıktıları dinamik yönlendirme algoritması ile ikincil kapsül katmanına aktarılmaktadır. Bu katmandan sağlanan çıktılar ise, mimarinin kod çözümleyici kısmı olarak adlandırılan, tam bağlantılı ve toplam kayıp fonksiyon katmanlarına aktarılmaktadır. Son katman olan kayıp hesaplama katmanında marjin ve yeniden oluşturma kaybı (hatası) hesaplanmakta, en küçük hata değerine ulaşıldığında ağın eğitimi sonlandırılıp hesaplanan olasılık değerlerine göre sınıflandırma yapılmaktadır.

3.4.3. Yazılım sisteminin geliştirilmesi

Bu çalışmada gerçekleştirilen yazılım sisteminin geliştirilmesinde Python 3.6.5 programlama dili, Keras ve CUDA 10 kullanılmış, Windows 10 işletim sisteminin bulunduğu Intel i7-10700F işlemcili, 32 GB RAM ve NVIDIA GTX2070 grafiksel işlemci birimi içeren bilgisayar kullanılmıştır.

Bu çalışmada ayrıca Bölüm 2’de açıklanmış olan, cilt lezyonlarının sınıflandırılması için kullanılan kapsül ağlar için de kodlamalar yapılmış, kendi veri setlerimiz ile o ağ yapılarının da eğitilmesi ve test edilmesi gerçekleştirilmiştir. Bunun nedeni ise, önerilen bütünleşik ağ modeline ait sayısal sonuçların daha önce kullanılan kapsül ağ modellerine ait sayısal sonuçlar ile adil bir şekilde karşılaştırılmasıdır. Çünkü Bölüm 2’de belirttiğimiz kapsül ağlar ile ilgili kaynaklarda verilen sayısal sonuçlar, ya

sadece bir veya birkaç cilt hastalığı için ağı eğitilip test edilmesi ile elde edilmiş, ya da farklı görüntü türleri veya farklı cihazlarla elde edilmiş görüntüler (farklı gürültü tipi ve özelliğe sahip görüntüler) kullanılarak eğitilip test edilmiştir. Bu nedenle, bu çalışmamızda elde edilen çoklu sınıflandırma sonuçlarının kaynaklardaki yayınlarda sunulan sınıflandırma sonuçları ile karşılaştırılması adil olmayacaktır.

3.4.4. Ağı eğitimi ve test edilmesi

Oluşturulan ağı modelinin eğitimi için her hastalık grubundan eşit sayıda veri içeren veri setlerindeki görüntülerin %80'i (644 görüntü) kullanılmıştır. Geri kalan %20'si (161 görüntü) ise ağı modelinin test edilmesi için kullanılmıştır.

Bu çalışmada ayrıca, ResNet18 ağı mimarisinin kullanımında transfer öğrenme (bilgi transferi) tekniğinin avantajından da yararlanılmıştır. Transfer öğrenme tekniği, ağı eğitilmesi için, donanım veya veri yetersizliği durumunda bir derin öğrenme modelinin oluşturulması için en etkili ve hızlı yoldur. Klasik makine öğrenmesine dayalı yöntemler her işlevi sıfırdan öğrenme yoluyla yaparken, transfer öğrenmeye dayalı yaklaşımlar önceki işlevlerden öğrendikleri bilgiyi yeni gerçekleştirilecek işlevi öğrenme amacına aktarırlar. Eğer sahip olunan veri miktarı az ise bu veriye göre oluşturulan özel ağı yapısı, önce genel bir işlev gerçekleştirilmesi amacıyla oluşturulmuş büyük veri seti kullanılarak eğitilip sonra var olan veri ile eğitilebilir. Transfer öğrenme yaklaşımında transfer edilen unsur, parametrelerin başlangıç değerleridir. Ağırlıkları rastgele değerler ile başlatmak yerine daha önceden eğitilen bir ağı mimarisinin kullanılması ile başlatılması; ağı yapısının öğrenmede iyi bir başlangıç yapmasını ve daha başarılı sonuçlar vermesini sağlamaktadır. Verinin kıt olduğu çalışmalarda, transfer öğrenimi, bir ağı aşırı öğrenmeden korunmasını sağlamak amacı ile de kullanılan bir yaklaşımdır.

Bu nedenle, bu tez çalışmasında ResNet18 ağı mimarisi büyük bir veri seti olan ImageNet (Russakovsky vd. 2015) (1000 sınıf ve 1 milyon resim) ile önceden eğitilerek temel özniteliklerin bu ağı mimarisi tarafından önceden öğrenilmesi sağlanmıştır. Önerilen bütünleşik ağı modelinde bu ResNet18 mimarisi ile, önceden öğrenilmiş özniteliklerin (*pre-trained features*) kullanımı sayesinde, eğitim aşamasının daha hızlı olması sağlanmaktadır. Oluşturduğumuz veri setleri ile ResNet18 mimarisi tekrar eğitilmektedir.

Üç evrişim katmanından oluşan ResNet18 mimarisindeki evrişim işlemleri için çalışmalarımızda 7x7 komşuluğundaki piksel değerleri ile hesaplamaların yapıldığı kare şeklinde bir çekirdek fonksiyon kullanılmış, adım büyüklüğü (*stride*) 2 olarak belirlenmiş ve aktivasyon ise *ReLU* ile sağlanmıştır. Bu mimariden elde edilen sonuçlar tekrar 224x224x3 olarak boyutlandırılıp kapsül ağıdaki evrişim katmanına aktarılmış ve ResNet18 ağı mimarisi dondurularak kapsül ağı mimarisinin eğitimi sağlanmıştır.

Kapsül ağı mimarisinde, 256 kanal içeren ilk evrişim katmanındaki evrişim işlemleri için adım büyüklüğü 1 alınmış, 9x9 boyutlu çekirdek ve *ReLU* aktivasyon fonksiyonu kullanılmıştır. Bu katmandan sonra gelen birincil kapsül katmanı 32 kapsülden oluşmuş olup, her kapsülde 8 evrişim birimi bulundurulmuş ve bu birimlerdeki evrişim işlemi adım büyüklüğü 2 alınarak 9x9 boyutlu bir çekirdek fonksiyon ile sağlanmıştır.

Bu aşamada ayrıca, Bölüm 2’de açıklanmış olan, cilt lezyonlarının sınıflandırılması amacıyla kaynaklarda kullanılmış olan diğer ağ modelleri de karşılaştırmaların adil olarak yapılması için, kendi veri setlerimiz ile eğitilmiş ve test edilmiştir. Bununla birlikte adil karşılaştırma yapabilmek için her ağ modelinde optimizasyon Adam ile sağlanmış, öğrenme oranı 0.0001, yığın sayısı (*batch size*) 30 ve *epoch* sayısı 120 olarak alınmıştır.

3.4.5. Sayısal ölçütlerden sonuçların elde edilmesi

Bu çalışmada uygulamış olduğumuz tüm ağ mimarilerinin performansları sayısal değerlendirme ölçütleri kullanılarak değerlendirilmiştir. Değerlendirme ölçütleri veri sınıflandırma çalışmalarında yaygın olarak kullanılan doğruluk (*accuracy*), hassaslık (*sensitivity*) ve özgüllük (*specificity*) ölçütü olup, şu terimler kullanılarak elde edilmektedir:

- $T_{Pozitif}$ (True Positive): Gerçek Pozitif durumuna karşılık gelen bu sembol, pozitif olan örneklerin ağ mimarisi tarafından da yine pozitif olarak tahmin edilmesi anlamına gelir.
- $T_{Negatif}$ (True Negative): Gerçek Negatif durumuna karşılık gelen bu sembol, negatif olan örneklerin ağ mimarisi tarafından da yine negatif olarak tahmin edilmesi anlamına gelir.
- $F_{Pozitif}$ (False Positive): Yanlış Pozitif durumuna karşılık gelen bu sembol, negatif olan örneklerin ağ mimarisi tarafından pozitif olarak tahmin edilmesi anlamına gelir.
- $F_{Negatif}$ (False Negative): Yanlış Negatif durumuna karşılık gelen bu sembol, pozitif olan örneklerin ağ mimarisi tarafından negatif olarak tahmin edilmesi anlamına gelir.

Doğruluk ölçütü, ağ mimarisinin sınıflandırma işlemini ne kadar doğrulukta yaptığını gösterir. Bu nedenle, mimarinin doğru olarak tahmin ettiği tüm değerlerin ($T_{Pozitif}$ ve $T_{Negatif}$) tüm tahmin değerlerinin toplamına ($F_{Pozitif}$, $T_{Pozitif}$, $F_{Negatif}$, $T_{Negatif}$) oranıdır.

Hassaslık ölçütü, ağ mimarisinin aslında pozitif olan örneklerden ne kadarını doğru olarak tahmin ettiğini gösterir. Bu nedenle, ağ tarafından doğru tahmin edilen pozitif örneklerin ($T_{Pozitif}$), aslında pozitif sınıftan olan toplam değerlere ($F_{Negatif}$ ve $T_{Pozitif}$) oranıdır.

Özgüllük ölçütü, ağ mimarisinin aslında negatif olan örneklerden ne kadarını doğru olarak tahmin ettiğini gösterir. Bu nedenle, ağ tarafından doğru tahmin edilen negatif örneklerin ($T_{Negatif}$), aslında negatif sınıftan olan toplam değerlere ($T_{Negatif}$ ve $F_{Pozitif}$) oranıdır.

Bu nedenle, doğruluk, hassaslık ve özgüllük değerleri matematiksel olarak aşağıdaki formüller ile hesaplanmaktadır:

$$Doğruluk = \frac{T_{Pozitif} + T_{Negatif}}{T_{Pozitif} + F_{Pozitif} + T_{Negatif} + F_{Negatif}} \quad (3.13)$$

$$Hassaslık = \frac{T_{Pozitif}}{T_{Pozitif} + F_{Negatif}} \quad (3.14)$$

$$Özgüllük = \frac{T_{Negatif}}{T_{Negatif} + F_{Pozitif}} \quad (3.15)$$

Bunların yanı sıra gerçekleştirilen çalışmada F1-skor ve Mathew Korelasyon Katsayısı (MKK) değerleri de aşağıdaki formüller ile hesaplanıp sonuçları incelenmiştir.

$$F1-Skor = \frac{2 \times T_{Pozitif}}{2 \times T_{Pozitif} + F_{Pozitif} + F_{Negatif}} \quad (3.16)$$

$$MKK = \frac{T_{Pozitif} \times T_{Negatif} - F_{Pozitif} \times F_{Negatif}}{\sqrt{(T_{Pozitif} + F_{Pozitif})(T_{Pozitif} + F_{Negatif})(T_{Negatif} + F_{Pozitif})(T_{Negatif} + F_{Negatif})}} \quad (3.17)$$

4. BULGULAR

Bu bölümde, dermatoskop görüntülerinden cilt lezyonlarının otomatik olarak sınıflandırılması için önerilen, ResNet18 ile kapsül ağı birleştirilmesi ile oluşan ağ mimarisinden elde edilen bulgular sunulmaktadır.

Bu bölümde ayrıca çalışmalarımızda uyguladığımız diğer ağ mimarilerinden elde edilen bulgular da sunulmaktadır.

Bölüm 3’de açıklanan doğruluk, hassaslık, özgüllük, F1-skor ve MKK değerlendirme ölçütleri ile hesaplanmış olan sonuçlar % olarak Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. Uygulanan ağ mimarilerinden elde edilen sonuçlar ile hesaplanan performans değerleri

Ağ Mimarileri	Doğruluk (%)	Hassaslık (%)	Özgüllük (%)	F1-Skor (%)	MKK (%)
VGG16	64.29	67.71	94.24	62.96	59.12
ResNet18	68.10	68.58	94.85	66.82	62.64
Orijinal Kapsül Ağ	74.76	77.90	96.02	73.06	71.11
VGG16 ile Kapsül Ağ	85.71	86.16	97.74	84.48	83.10
ResNet18 ile Kapsül Ağ	88.10	89.18	98.11	87.25	86.20

Çalışmalarımızda ayrıca ağ mimarilerinin, oluşturmuş olduğumuz eğitim veri setleri ile eğitilmesi ve test veri setleri ile test edilmesi için gerekli olan süreler de incelenmiştir.

Uygulamalarda kullandığımız VGG16 ve ResNet18 mimarileri daha önceden ImageNet verileri ile eğitilmiş olan mimariler olup, oluşturduğumuz veri setleri ile tekrar eğitilip test edilmiş ve bu adımlar için gerekli olan süreler tespit edilmiştir.

Uyguladığımız diğer bütünleşik ağ mimarilerinin eğitilmesi ve test edilmesi için gerekli olan süreler de tespit edilmiş ve elde edilen bulgular Çizelge 4.2’de sunulmuştur.

Çizelge 4.2. Mimarilerin eğitim ve test edilme süreleri

Ağ Mimarisi	Eğitim Süresi (saniye)	Test Etme Süresi (saniye)
VGG16	178	87
ResNet18	59	26
Orijinal Kapsül Ağ	21	12
VGG16 ile Kapsül Ağ	201	102
ResNet18 ile Kapsül Ağ	82	39

5. TARTIŞMA

Cilt hastalığı ve özellikle cilt kanserleri, kısa sürede ve doğru teşhis edilmesi gereken yaygın ve ciddi bir hastalıktır. Erken evrede doğru teşhisin ve tedavinin yapılmadığı durumda ölüm vakaları ile sonuçlanan bu hastalıklar her yaş, cinsiyet ve ırktan kişilerde görülebilmektedir. Fakat yeterli sayıda dermatolog bulunmaması, özellikle nüfusun kalabalık olduğu ülkelerde veya erişimin zor olduğu uzak bölgelerde, kırsal kesimlerde ya da yaşlılık, salgın hastalık gibi etkenlerden dolayı dermatoloğa gidilememesi durumunda bu hastalıkların erken evrede teşhisi ve tedavisi mümkün olmayabilmektedir.

Bununla birlikte, dermatologlar tarafından lezyonların görsel incelenmesine dayalı olarak uygulanan geleneksel yöntemler, öznel ve dermatologların tecrübelerine dayalı olduğundan yanlış teşhislere ve dolayısı ile yanlış tedavi uygulamalarına sebep olabilmektedir. Farklı cilt hastalıklarına ait lezyonların benzer görünüşte olması bu lezyonların görsel incelemeye dayalı olarak sınıflandırılmasını daha da zorlaştırmaktadır. Bu durum, dermatoloji alanındaki yanlış teşhis ve tedaviye yol açan problemlerin ortadan kalkması, hastalıkların erken evrede ve doğru bir şekilde teşhis edilebilmesi için bilgisayar destekli otomatik yöntemlerden yararlanılmasına gereksinim duyulduğunu ortaya koymaktadır. Bu nedenle, bu tez çalışmasında üzerinde durulan konu, ele alınması gereken önemli bir konudur.

Bölüm 2’de sunulduğu gibi, literatürdeki çalışmalar derin sinir ağ mimarileri ile cilt lezyonlarının sınıflandırılmasında başarılı sonuçların elde edildiğini göstermektedir. Yapılan çalışmalarda çeşitli veri tabanlarından farklı özelliklerde görüntüler kullanılmış ve farklı hastalık türlerinin tespiti sağlanmaya çalışılmıştır. Genellikle melanoma hastalığı için lezyonların tespit edilmesi, bu lezyonların iyi huylu veya kötü huylu olup olmadıklarının belirlenmesi için ikili sınıflandırma çalışmaları yapılmıştır.

Yapılmış çalışmalarda sunulan sonuçlar evrışimsel derin sinir ağ mimarilerinin görüntülerden özniteliklerin otomatik olarak belirlenip çıkarılmasında daha önce uygulanmış olan geleneksel makine öğrenmesi tekniklerine göre daha etkili olduğunu göstermiştir. Bu nedenle, bu çalışmada da derin sinir ağ mimarisine dayalı olarak cilt lezyonlarının sınıflandırılması üzerinde durulmuştur.

Literatürde uygulanmış olan yöntemlerde, ağ mimari yapıları incelendiğinde, cilt lezyonlarının tespit edilmesi ve sınıflandırılmasında genellikle evrışimsel sinir ağı mimarilerinin kullanıldığı gözlenmiş olsa da bu ağ mimariler görüntü sınıflandırmada yeterince başarılı olamamaktadır. Ağ mimarilerinin derinliklerinin artırılması ile daha yüksek performans ile sonuçların elde edilebileceği düşünülmüş ve çalışmalarda daha derin ağ yapıları tasarlanıp uygulanmıştır. Ağ mimarilerinin tasarımında kullanılan çeşitli fonksiyonlar ve parametreler de değiştirilerek lezyonların başarılı bir şekilde sınıflandırılması için çeşitli uygulamalar yapılmıştır. Fakat tasarlanan evrışimsel ağ mimarileri cilt lezyonlarının otomatik olarak sınıflandırılmasında yeterli olamamaktadır. Bunun nedeni, mimari yapısında kullanılan havuzlama katmanında görüntülerin boyutlarının düşürülmesi ve dolayısı ile görüntülerdeki bazı önemli özniteliklerin kaybolmasıdır.

Evrışimsel sinir ağı mimarilerinin yapısından kaynaklanan bu sorunun çözümü

için yeni bir ağ mimarisi olan kapsül ağı ilgi çekmektedir. Bölüm 2’de açıklandığı gibi, literatürdeki çalışmalarda da kapsül ağ mimarilerine dayalı yöntemlerin evrimsel sinir ağı mimarileri ile elde edilen yöntemlere göre daha başarılı sonuçlar verdiği gösterilmiştir.

Bu çalışmada yüksek doğruluk değeri ile dermatoskop görüntülerinden lezyonların otomatik olarak 7 sınıfa sınıflandırılmasını sağlayan evrimsel sinir ağı ve kapsül ağın birlikte kullanıldığı bir yöntemin geliştirilip uygulanması amaçlanmıştır.

Çalışmalarımızda katman sayısının fazlalaştırılması ile derinliği artırılmış olan (ResNet50, ResNet101 veya DenseNet201 gibi) mimariler kullanılmamıştır. Çünkü ağ mimarisinin derinliği arttıkça ağın eğitimi ve test edilmesi için gereken sürenin de artacağı bilinmektedir. Bu dezavantajı nedeniyle çalışmalarımızda hedefimiz en yüksek doğrulukta sonuçların yine benzer derinliklerdeki ağ mimarileri ile elde edilmesini sağlamak olmuştur.

Yaptığımız uygulamalardan elde edilen ve Çizelge 4.1’de sunulmuş olan bulgularda görüldüğü gibi, artık bağlantıları ve kapsül katmanları içeren birleşik ağ mimarisi dermatoskop görüntülerinden cilt lezyonlarının sınıflandırılmasında diğer yöntemlere göre daha etkili olmuştur.

VGG16 ağ mimarisinin kullandığımız veri setlerindeki görüntüleri sınıflandırma becerisi diğer ağ mimarilerine göre daha düşük çıkmıştır. Çünkü bu ağ mimarisinin yapısında adım büyüklüğü 2 olan 3x3’lük filtreler ile evrişimin yapıldığı 13 evrişim katmanı bulunmakta ve 5 defa havuzlama işlemi uygulanmaktadır. Bu nedenle ağın öğrenmesi gereken bazı öznitelikler kaybolmaktadır.

ResNet18 ağ mimarisinin görüntüleri sınıflandırmadaki performansı VGG16 mimarisine göre daha başarılıdır. Çünkü mimaride, 17 evrişim katmanından sonra bir havuzlama işlemi uygulanmakta, sonra da sınıflandırmanın yapıldığı softmax fonksiyonuna sahip 1 tam bağlantılı katman kullanılmaktadır. Evrimsel katmanlarda 3x3 filtreler kullanılmakta, çıktı özellik haritası aynı boyuttaysa katmanlarda aynı sayıda filtre kullanılmaktadır. Eğer, çıktı özellik haritası yarıya inmiş ise, filtreler katmanlarda iki katına çıkmaktadır. Aşağı örnekleme işlemi, adım büyüklüğü 2 alınarak evrişimin uygulandığı evrimsel katmanlar tarafından gerçekleştirilir. Evrişim katmanlarından sonra bir defa ortalama havuzlama işlemi uygulanıp veriler son katmana aktarılmaktadır. Son katman ise, sınıflandırmanın yapıldığı softmax fonksiyonunu içeren bir tam bağlantılı katmandır. Ağ boyunca, artık kısa yol bağlantıları katmanlar arasına eklenmektedir. Bu ağ yapısı sayesinde sınıflandırma işleminin daha yüksek performans ile yapılması sağlanmaktadır.

Kapsül ağ mimarisinin görüntüleri sınıflandırmadaki performansının ResNet18 ve VGG16 mimarisi ile yapılan sınıflandırmalara göre daha başarılı olduğu gözlenmiştir. Bir kapsül ağ ile yapılan sınıflandırmanın evrimsel bir derin sinir ağ mimarisinden daha başarılı olduğunu literatürdeki çalışmalar göstermiştir (Pal vd. 2018; Tiwari 2021; Pérez ve Ventura 2021). Bu nedenle bu tez çalışmasında, diğer evrimsel derin sinir ağ mimarilerinin performansları kapsül ağ mimarisinin performansı ile karşılaştırmaya gereksinim duyulmamıştır. Kapsül ağı diğer evrimsel ağ mimarilerinden daha başarılı sonuçlar verdiği için, önerilen ResNet18 ve kapsül ağ

mimarisinin birleştirilmesi ile oluşan ağ yapısı da diğer evrimsel ağ mimarilerinden daha başarılı sonuçlar verecektir.

Görüntülerin yedi sınıfa sınıflandırılmasında sadece kapsül ağ mimarisinin kullanılması uygulanan evrimsel ağ mimarilerine göre daha iyi olsa da yeterli bir performans sağlamamıştır. Bunun nedeni, ağ yapısında birincil kapsül katmanından önce sadece bir evrim katmanı kullanılmaktadır. Bu durum görüntülerden derin bilgilerin çıkarılması için yeterli olmamaktadır. Sınıflandırma için gerekli olan bazı öznitelikler çıkarılamadığından sınıflandırma performansı düşük çıkmaktadır.

Orijinal kapsül ağındaki bu sorunlardan dolayı, farklı fonksiyonlar kullanılarak oluşturulan çeşitli ResNet ağlarının kapsül ağı ile birleştirildiği uygulamalar araştırıldığında 5580 sonuca ulaşılması (Anonim 1), bu çalışma sonuçlarının orijinal kapsül ağdan daha iyi olduğunun gösterilmesi, bu birleşik mimarinin görüntü sınıflandırmada umut verici olduğunu göstermektedir. Bununla birlikte, ulaşılan bu çalışmalarda ağ mimarilerinin de çoğunlukla, yine FASH-MNIST ve CIFAR-10 veri tabanlarındaki görüntüler olmak üzere çeşitli özelliklerdeki görüntü türleri ile eğitilip test edildikleri gözlenmektedir.

Bu tez kapsamında gerçekleştirilen çalışmada ise, dermatoskop görüntülerinden cilt lezyonlarının sınıflandırılması üzerinde durulmuş, birleşik ağ mimarisinin sınıflandırma becerisi incelenmiştir. Bunun yanı sıra, orijinal kapsül ağı ve VGG16 ile orijinal kapsül ağı birleştirilmesi ile oluşmuş olan ağ mimarisi de bu görüntü veri setleri ile eğitilip test edilmiş ve sınıflandırma becerileri gösterilmiştir.

Dermatoskop görüntülerinin ikili sınıflandırılmasında (binary classification), örneğin lezyonların sadece melanoma olup olmadığına karar veren bir sınıflandırmada, VGG16 ile orijinal kapsül ağı birleştirilmesi ile oluşmuş olan ağ mimarisi yazarlarının belirttiği sonuçlara göre %92.40 doğruluk oranı ile kabul edilebilir bir başarı göstermektedir (Boaro vd. 2020). Fakat sınıflandırma çok sınıflı yapıldığında, ki bu tez çalışmasında olduğu gibi 7 sınıflı bir sınıflandırma yapıldığında, bu başarı oranı düşmektedir. Bunun nedeni ise, farklı sınıflardaki cilt lezyonlarının birbirlerine çok benzerlikler göstermesidir.

Orijinal kapsül ağının VGG16 yerine ResNet18 ile birlikte kullanılması durumunda ise, cilt lezyonlarının 7 sınıfa sınıflandırılması daha başarılı sonuçlar vermektedir. Çünkü ResNet18 mimarisindeki artık bağlantıların yanı sıra, VGG16 mimarisine göre daha fazla katman bulunmakta ve dolayısı ile daha fazla evrim işlemi ile daha fazla öznitelik çıkarımı sağlanmaktadır. Görüntülerden öznitelik çıkarımı ve öğreniminin daha etkili olması bu birleşik ağ mimarisinden daha başarılı sonuçların elde edilmesini sağlamaktadır.

Uygulanan tüm ağların görüntüleri sınıflandırmadaki becerileri ayrıca mimarilerin eğitimi ve test edilmesi için gereken süreler dikkate alınarak da karşılaştırılmıştır. Çizelge 4.2’de görüldüğü gibi, VGG16 ile kapsül ağı birleştirilerek oluşmuş olan mimaride ağı eğitimi ve test edilmesi için gereken süre diğerlerine göre daha fazladır.

Sınıflandırma işlemleri sadece kapsül ađ mimarisi ile yapıldığında, ađın eđitimi ve test edilmesi en kısa sürede gerekleşebilmektedir. Bu nedenle, eđer kullanıcılar için en dođru sonuçlar deđil de en kısa sürede sonucu öđrenmek önemli ise, sadece kapsül ađ mimarisi tercih edilebilir.

Ađ mimarilerinde derinlik arttıka, genellikle ađın eđitimi ve test edilmesi için gereken süre de artmaktadır. Önerilen ađ mimarisinde hem 18 katmanlı artık bađlantıları içeren evriřimsel bir ađ yapısı hem de kapsül ađ yapısı bulunmaktadır. Bu nedenle, bu ađ mimarisinin eđitimi ve test edilmesi için gereken süreler, sadece ResNet18 veya sadece kapsül ađ yapısının kullanılması durumunda gereken sürelerden daha fazladır. Fakat aradaki süre farkının ok fazla olmadığı ve ayrıca önerilen ađ yapısının sınıflandırma işlemlerini daha yüksek dođruluk ile gerekleştirebilme becerisi önem kazanmaktadır.



6. SONUÇLAR

Bilim ve teknolojinin gelişmesiyle birlikte, cilt lezyonlarının daha yüksek doğruluk ile tespit edilmesi ve sınıflandırılması ile ilgili yapılan çalışmalar da sürekli gelişmektedir. Dermatoloji alanında karşılaşılan sorunların en aza indirgenebilmesi için, hastalıkların teşhis ve tedavi sürecinde bilgisayar destekli otomatik yöntemlerden yararlanılması gerekmektedir.

Bu tez çalışması kapsamında elde edilen bulgular, VGG16 mimarisinin çalışmalarımızda uyguladığımız diğer mimarilere göre cilt lezyonlarının 7 sınıfa sınıflandırılmasında en az hassasiyette olduğunu göstermiştir.

Dermatoskop görüntü verilerinin sınıflandırılmasında yapısında artık ağ katmanlarının bulunduğu ResNet mimarisi, VGG16 mimarisine göre daha başarılı sınıflandırma sağlayabilmektedir.

Kapsül ağ mimarisinin görüntüleri sınıflandırmadaki performansı uygulanan ResNet18 ve VGG16 ağ mimarilerinden daha yüksektir.

VGG16 ve ResNet18 evrimsel ağ mimarilerinin kapsül ağlar ile birlikte kullanılması durumunda, sadece evrimsel veya sadece kapsül ağ kullanılması durumlarına göre daha iyi öznetelik çıkarımı ve öğrenmenin gerçekleştirildiği, dolayısı ile dermatoskop görüntü verilerinin sınıflandırılmasında performans artışının sağlandığı gözlenmiştir.

Gerçekleştirilen bu tez çalışmasında, kapsül ağlarına aktarılan ilk ağırlık değerlerinin rastgele seçilen ağırlık değerleri yerine ResNet18 mimarisinden elde edilen daha iyi ağırlık değerlerinin kullanılması, dermatoskop görüntü verilerinin sınıflandırılmasında daha doğru ve daha yüksek hassasiyette sonuçların alınmasını sağlamıştır.

Farklı değerlendirme ölçütleri ile elde edilen bulgular göstermiştir ki, cilt lezyonlarının otomatik olarak yedi sınıfa ayrıştırılması için önerdiğimiz ResNet18 ve kapsül ağın birleştirilmesi ile oluşan mimari, uyguladığımız diğer mimarilere göre en başarılı sonuçların elde edildiği ağ mimarisidir.

Ağ mimarileri eğitim ve test etme süreleri açısından karşılaştırıldığında önerdiğimiz ResNet18 ve kapsül ağın birleştirilmesi ile oluşan ağ mimarisi, VGG16 ve VGG16 ile kapsül ağın birleşiminden oluşan ağ mimarilerinden daha kısa sürede eğitilip test edilebilmektedir. Bununla birlikte bulgular göstermiştir ki, VGG16 mimarisi ResNet18 mimarisine göre daha uzun sürede eğitilmektedir. Sınıflandırma işlemi sadece kapsül ağ mimarisi ile yapıldığında, ağın eğitimi ve test edilmesi için gereken süre diğerlerine göre daha azdır.

Bu tez çalışmasının bir uzantısı olarak ileride yapılacak çalışmalarda, ResNet18 ve kapsül ağ mimarisi ile oluşturulan ağ yapısı daha fazla veri içeren genişletilmiş veri setleri ile eğitilecek ve daha fazla sayıda veriler kullanılarak test edilecektir. Artırılmış sayıdaki veriler ağın eğitilmesi sayesinde, daha fazla özellik çıkarımı ve öğrenimi

sağlanacağı için, önerilen bu bütünleşik ağ mimarisi ile daha iyi sonuçların elde edilebileceği düşünülmektedir.

Bu çalışmalar sonucunda elde edilecek olan otomatik lezyon sınıflandırma yöntemi, üzerinde durulan cilt hastalıkları için, bu hastalıkların doğru, nesnel ve erken evrede teşhis edilmesinde dermatologlara yardımcı olacaktır.



7. KAYNAKLAR

- Aljohani, K., and Turki, T. 2022. Automatic Classification of Melanoma Skin Cancer with Deep Convolutional Neural Networks. *AI*, 3(2): 512-525.
- Al-Otaibi, H. O., Alotibi, N. O. S., Althiyabi, F. F., Alosaimi, S. B. H., Alharbi, Y. Y., and Alateeq, A. K. A. 2020. Prevalence and factors associated with anxiety among patients with common skin diseases. *International Journal of Medicine in Developing Countries*, 4(1): 153-159.
- Arnold, J. D., Yoon, S., and Kirkorian, A. Y. 2019. The national burden of inpatient dermatology in adults. *Journal of the American Academy of Dermatology*, 80(2): 425-432.
- Assiri, A., et al. 2013. Hospital outbreak of Middle East respiratory syndrome coronavirus. *The New England Journal of Medicine*, 369(5): 407-416.
- Bechelli, S., and Delhommelle, J. 2022. Machine Learning and Deep Learning Algorithms for Skin Cancer Classification from Dermoscopic Images. *Bioengineering*, 9(3): 97.
- Boaro, J. M. C., dos Santos, P. T. C., Rocha, C. V. M., Fontenele, T., Júnior, G. B., de Almeida, J. D. S., de Paiva, A. C. and Rocha, S. 2020. Hybrid Capsule Network Architecture Estimation for Melanoma Detection. International Conference on Systems, Signals and Image Processing (IWSSIP), pp. 93-98, 1-3 July, IEEE, Niteroi.
- Budhiman, A., Suyanto, S., and Arifianto, A. 2019. Melanoma Cancer Classification Using ResNet with Data Augmentation. International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), pp. 17-20, 5-6 December, IEEE, Yogyakarta.
- Cruz, M. V., Namburu, A., Chakkaravarthy, S., Pittendreigh, M., and Satapathy, S. C. 2020. Skin cancer classification using convolutional capsule network (CapsNet). *Journal of Scientific and Industrial Research*, 79(11): 994-1001
- Feng, H., Berk-Krauss, J., Feng, P. W., and Stein, J. A. 2018. Comparison of dermatologist density between urban and rural counties in the United States. *JAMA Dermatology*, 154(11): 1265-1271.
- Flohr, C., and Hay, R. 2021. Putting the burden of skin diseases on the global map. *British Journal of Dermatology*, 184(2): 189-190.
- Forton, F. M., Germaux, M. A., Thibaut, S. C., Stene, J. J., Brasseur, T. V., Mathys, C. L., Tytgat, M. D., and Laporte, M. F. 2015. Demodicosis: descriptive classification and status of Rosacea, in response to prior classification proposed. *Journal of the European Academy of Dermatology and Venereology*, 29(4): 829-832.
- Goodfellow, I., Bengio, Y., and Courville, A. 2017. Deep learning (adaptive computation and machine learning series). The MIT Press, Cambridge, Massachusetts, 800 p.
- Govindaswamy, B., and Mallappa, M. 2022. Detection and segmentation of melanoma skin cancer in dermoscopy images using modified Alexnet convolutional neural

- network-morphological methodology. *Concurrency and Computation: Practice and Experience*, 34(25): e7266.
- Gulati, S., and Bhogal, R. K. 2019. Detection of Malignant Melanoma Using Deep Learning. *International Conference on Advances in Computing and Data Sciences*, pp. 312-325, 20 July, Springer, Singapore.
- He, K., Zhang, X., Ren, S., and Sun, J. 2016. Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 20 June - 1 July, Computer Vision Foundation, Las Vegas.
- Hirano, G., et al. 2020. Automatic diagnosis of melanoma using hyperspectral data and GoogLeNet. *Skin Research and Technology*, 26(6): 891-897.
- Hopkinson, D., Tuchayi, S. M., Alinia, H., and Feldman, S. R. 2015. Assessment of rosacea severity: a review of evaluation methods used in clinical trials. *Journal of the American Academy of Dermatology*, 73(1): 138-143.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6): 84-90.
- Laverde-Saad, A., Milan, R., Mohand-Saïd, S., LeLorier, J., Litvinov, I. V., and Rahme, E. 2020. The risk of suicidal behaviour in individuals with psoriasis: A retrospective cohort study in Quebec, Canada. *Journal of the European Academy of Dermatology and Venereology*, 34(12): e800-e802.
- LeCun, Y. A., Bottou, L., Orr, G. B., and Müller, K. R. 2012. Efficient backprop. In: Montavon, G., Orr, G. B., and Müller, K. R. (Eds.), *Neural Networks: Tricks of the Trade*. Springer, Berlin, pp. 9-48.
- Leisner, M. Z., Riis, J. L., Schwartz, S., Iversen, L., Østergaard, S. D., and Olsen, M. S. 2019. Psoriasis and risk of mental disorders in Denmark. *JAMA Dermatology*, 155(6): 745-747.
- Lukaviciute, L., Ganceviciene, R., Navickas, P., Navickas, A., Grigaitiene, J., and Zouboulis, C. C. 2020. Anxiety, depression, and suicidal ideation amongst patients with facial dermatoses (acne, rosacea, perioral dermatitis, and folliculitis) in Lithuania. *Dermatology*, 236(4): 314-322.
- Mento, C., Rizzo, A., Muscatello, M. R. A., Zoccali, R. A., and Bruno, A. 2020. Negative emotions in skin disorders: A systematic review. *International Journal of Psychological Research*, 13(1): 71-86.
- Mijwil, M. M. 2021. Skin cancer disease images classification using deep learning solutions. *Multimedia Tools and Applications*, 80: 26255-26271.
- Munaf, A., Hoque, A., and Jawwad, K. A. 2021. DenseNet based skin lesion classification and melanoma detection. Ph.D. dissertation, Brac University, Dhaka, 37 p.
- Ngesthi, S. O., Setyawan, I., and Timotius, I. K. 2021. The Effect of Partial Fine Tuning on AlexNet for Skin Lesions Classification. *13th International Conference on Information Technology and Electrical Engineering (ICITEE)*, pp. 147-152, 14-15 October, IEEE, Chiang Mai.

- Nielsen, M. A. 2015. Neural networks and deep learning. Determination Press, San Francisco, California, 216 p.
- Pal, A., Chaturvedi, A., Garain, U., Chandra, A., Chatterjee, R., and Senapati, S. 2018. CapsDeMM: Capsule Network for Detection of Munro's Microabscess in Skin Biopsy Images. International Conference on Medical Image Computing and Computer-Assisted Intervention, pp. 389-397, 26 September, Springer, Cham.
- Patrick, M. K., Adekoya, A. F., Mighty, A. A., and Edward, B. Y. 2022. Capsule networks—a survey. *Journal of King Saud University-Computer and Information Sciences*, 34(1): 1295-1310.
- Pérez, E., and Ventura, S. 2021. Melanoma Recognition by Fusing Convolutional Blocks and Dynamic Routing between Capsules. *Cancers*, 13(19): 4974.
- Puttagunta, M., and Ravi, S. 2021. Medical image analysis based on deep learning approach. *Multimedia Tools and Applications*, 80: 24365-24398.
- Reed, R., and Marks II, R. J. 1999. Neural smithing: supervised learning in feedforward artificial neural networks. The MIT Press, Cambridge, Massachusetts, 360 p.
- Reusken, C. B., et al. 2013. Middle East respiratory syndrome coronavirus neutralising serum antibodies in dromedary camels: a comparative serological study. *The Lancet Infectious Diseases*, 13(10): 859-866.
- Ridell, P., and Spett, H. 2017. Training set size for skin cancer classification using Google's inception v3. Ph.D. dissertation, School of Computer Science and Communication, Stockholm, 26 p.
- Russakovsky, O., et al. 2015. ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115: 211-252.
- Sabour, S., Frosst, N., and Hinton, G. E. 2017. Dynamic Routing Between Capsules. 31st Conference on Neural Information Processing Systems (NIPS), pp. 3856-3866, 4-9 December, Curran Associates Inc., Long Beach.
- Sallam, A., Ba Alawi, A. E., and Saeed, A. Y. A. 2020. A CNN-Based Model for Early Melanoma Detection. International Conference of Reliable Information and Communication Technology, pp. 41-51, 6 May, Springer, Cham.
- Schuster, B., Ziehfrend, S., Albrecht, H., Spinner, C. D., Biedermann, T., Peifer, C., and Zink, A. 2020. Happiness in dermatology: a holistic evaluation of the mental burden of skin diseases. *Journal of the European Academy of Dermatology and Venereology*, 34(6): 1331-1339.
- Serrano, C., Lazo, M., Serrano, A., Toledo-Pastrana, T., Barros-Tornay, R., and Acha, B. 2022. Clinically Inspired Skin Lesion Classification through the Detection of Dermoscopic Criteria for Basal Cell Carcinoma. *Journal of Imaging*, 8(7): 197.
- Simonyan, K., and Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Stofa, M. M., Zulkifley, M. A., Zainuri, M. A. A. M., and Moubark, A. M. 2022. DenseNet with Atrous Spatial Pyramid Pooling for Skin Lesion Classification. 11th International Conference on Robotics, Vision, Signal Processing and Power Applications, pp. 827-833, 11 February, Springer, Singapore.

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A. 2015. Going deeper with convolutions. IEEE Conference on Computer Vision and Pattern Recognition, pp. 1-9, 7-12 June, Computer Vision Foundation, Boston.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. 2016. Rethinking the inception architecture for computer vision. IEEE conference on computer vision and pattern recognition, pp. 2818-2826, 20 June - 1 July, Computer Vision Foundation, Las Vegas.
- Tabrizchi, H., Parvizpour, S., and Razmara, J. 2022. An improved VGG model for skin cancer detection. *Neural Processing Letters*, 1-18.
- Tan, J. K. L., and Bhate, K. 2015. A global perspective on the epidemiology of acne. *British Journal of Dermatology*, 172(S1): 3-12.
- Tiwari, S. 2021. Dermatoscopy using multi-layer perceptron, convolution neural network, and capsule network to differentiate malignant melanoma from benign nevus. *International Journal of Healthcare Information Systems and Informatics (IJHISI)*, 16(3): 58-73.
- Tizek, L., Schielein, M. C., Seifert, F., Biedermann, T., Böhner, A., and Zink, A. 2019. Skin diseases are more common than we think: screening results of an unreferral population at the Munich Oktoberfest. *Journal of the European Academy of Dermatology and Venereology*, 33(7): 1421-1428.
- Tschandl, P., Rosendahl, C., and Kittler, H. 2018. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific Data*, 5: 1-9.
- Two, A. M., Wu, W., Gallo, R. L., and Hata, T. R. 2015. Rosacea: part I. Introduction, categorization, histology, pathogenesis, and risk factors. *Journal of the American Academy of Dermatology*, 72(5): 749-758.
- Xie, P., Zuo, K., Zhang, Y., Li, F., Yin, M., and Lu, K. 2019. Interpretable classification from skin cancer histology slides using deep learning: A retrospective multicenter study. arXiv preprint arXiv:1904.06156.
- Xue, C., Dou, Q., Shi, X., Chen, H., and Heng, P. A. 2019. Robust Learning at Noisy Labeled Medical Images: Applied to Skin Lesion Classification. 16th International Symposium on Biomedical Imaging (ISBI), pp. 1280-1283, 8-11 April, IEEE, Venice.
- Yan, P., Wang, G., Chen, J., Tang, Q., and Xu, H. 2022. Skin lesion classification based on the VGG-16 fusion residual structure. *International Journal of Imaging Systems and Technology*, 1-16.
- Zare, R., and Pourkazemi, A. 2021. DenseNet approach to segmentation and classification of dermatoscopic skin lesions images. arXiv preprint arXiv:2110.04632.
- Zielecki, F., Weber, M., Eickmann, M., Spiegelberg, L., Zaki, A. M., Matrosovich, M., Becker, S. and Weber, F. 2013. Human cell tropism and innate immune system interactions of human respiratory coronavirus EMC compared to those of severe acute respiratory syndrome coronavirus. *Journal of Virology*, 87(9): 5300-5304.

Zink, A., Herrmann, M., Fischer, T., Lauffer, F., Garzorz-Stark, N., Böhner, A., Spinner, C.D., Biedermann, T. And Eyerich, K. 2017. Addiction: an underestimated problem in psoriasis health care. *Journal of the European Academy of Dermatology and Venereology*, 31(8): 1308-1315.

Anonim 1: https://scholar.google.com.tr/scholar?start=20&q=resnet+%2B+capsule+network&hl=en&as_sdt=0,5 [Son erişim tarihi: 24.09.2022]



ÖZGEÇMİŞ

YUSUF YETGİN

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2020-2023	Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Antalya
Lisans	Erciyes Üniversitesi
2008-2013	Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri

MESLEKİ VE İDARİ GÖREVLER

Biyomedikal Mühendisi	Antalya Eğitim ve Araştırma Hastanesi
2015-Devam Ediyor	Biyomedikal Cihaz Takip Birimi, Antalya
Biyomedikal Mühendisi	Antalya İli Kamu Hastaneleri Birliği Genel Sekreterliği (Mülga)
2013-2014	Klinik Mühendislik Hizmetleri Birimi, Antalya