



T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü



DERİN ÖĞRENME VE GÖRÜNTÜ ÖN İŞLEME YÖNTEMLERİ İLE OTOMATİK DERİ LEZYONU TESPİTİ

Yüksek Lisans Tezi

Behlül SARIKAYA

Bilgisayar Mühendisliği Anabilim Dalı

İzmir
2022

T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

**DERİN ÖĞRENME VE GÖRÜNTÜ ÖN İŞLEME
YÖNTEMLERİ İLE OTOMATİK DERİ LEZYONU
TESPİTİ**

Behlül SARIKAYA

Danışman : Prof. Dr. Aybars UĞUR

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Yüksek Lisans Programı

İzmir
2022

EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

ETİK KURALLARA UYGUNLUK BEYANI

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “**DERİN ÖĞRENME VE GÖRÜNTÜ ÖN İŞLEME YÖNTEMLERİ İLE OTOMATİK DERİ LEZYONU TESPİTİ**” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

06 / 09 / 2022

Behlül SARIKAYA

ÖZET**DERİN ÖĞRENME VE GÖRÜNTÜ ÖN İŞLEME YÖNTEMLERİ İLE
OTOMATİK DERİ LEZYONU TESPİTİ**

SARIKAYA, Behlül

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Aybars UĞUR

Eylül 2022, 59 sayfa

Cilt kanseri günümüzde görülen en yaygın kanser türlerinden biridir. Cilt kanserleri de kendi içlerinde türlere ayrılmaktadır. Görülme sıklıkları göz önünde bulundurulduğunda, Melanom en nadir görülen türlerden olsa da bu hastalığın sebep olduğu ölümler diğer cilt kanseri türlerine göre oldukça fazladır. Cilt lezyonlarının bazıları kanser olarak nitelendirilmese de zamanla kalıtsal özelliklere ve çevresel faktörlere göre kansere dönüşebilmektedir. Pek çok hastalık gibi cilt lezyonlarının ön teşhisi de oldukça önemlidir. Cilt lezyonunun ön tespiti profesyoneller tarafından dermoskopik yöntemler ile yapılabilir. Ancak bazı vakalarda zaman alabilmekte ve patoloji sonuçlarına göre farklılık gösterebilmektedir. Bu tez çalışmasında da cilt lezyonlarının sınıflandırılması ele alınmaktadır. Günümüzde cilt lezyonlarının sınıflandırılması için pek çok çalışma yapılmıştır. Veri artırım tekniklerinin kullanıldığı çalışmalar olsa da bu çalışmayı diğerlerinden ayıran nokta farklı görüntü ön işleme yöntemlerinin ve veri artırım stratejilerinin cilt lezyonu sınıflandırma performansına etkisinin incelenmesidir. Veri artırımı için geleneksel transform yöntemleriyle birlikte çekişmeli üretici ağlar gibi derin öğrenme tabanlı yöntemler de uygulanmıştır. Ön eğitilmiş VGG-16 modeli üzerinde gerçekleştirilen deneylerde transform yöntemleri ile birlikte derin öğrenme tabanlı veri artırımının sınıflandırma başarımını daha da geliştirdiği gözlenmiştir.

Anahtar sözcükler: Cilt Lezyonu, Derin Öğrenme, Veri Artırımı, Çekişmeli Üretici Ağlar, Görüntü Ön İşleme

ABSTRACT**AUTOMATIC SKIN LESION DETECTION WITH DEEP
LEARNING AND PREPROCESSING METHODS**

SARIKAYA, Behlül

MSc in Computer Eng.

Supervisor: Prof. Dr. Aybars UĞUR

September 2022, 59 pages

Skin cancer is one of the most common types of cancer seen today. Skin cancers are also divided into types. Considering the incidence of cancer types, although melanoma is one of the rarest types, the deaths caused by this disease are quite high compared to other types of skin cancer. Although some of the skin lesions are not considered cancer, they can develop into cancer over time due to hereditary characteristics and environmental factors. As with many diseases, a preliminary diagnosis is very important for skin lesions. A preliminary diagnosis of a skin lesion can be carried out by professionals using dermoscopic methods. However, in some cases, it may take time and the pathology may differ depending on the results. In this thesis, the classification of skin lesions is also discussed. Currently, many studies have been conducted on the classification of skin lesions. Although many studies that use data augmentation techniques such as this study, the point that distinguishes this from others is the study of the effect of different image preprocessing methods and data augmentation strategies on skin lesion classification performance. Along with traditional transform methods, deep learning-based methods like generative adversarial network have also been applied for data augmentation. In experiments performed on the pre-trained VGG-16 model, It has been observed that deep learning-based data augmentation in combination with transform methods further improves classification performance.

Keywords: Skin Lesion, Deep Learning, Data Augmentation, Generative Adversarial Networks, Image Preprocessing

ÖNSÖZ

Bu tez çalışmasında cilt lezyonlarının tespitinde derin öğrenme tabanlı yöntemler uygulanmış ve veri artırım yöntemlerinin etkisi incelenmiştir. Farklı veri artırım stratejileri incelenerek performansı daha iyi yönde etkileyen yöntemler birlikte kullanılmıştır. Bu sayede başarımın artırılması amaçlanmıştır.

Bu tez çalışmasının konusunun belirlenmesinde ve tez çalışmasının hazırlanmasında bilgilerini ve tecrübelerini hiçbir zaman esirgemeyen ve çalışmanın her aşamasında yardımcı olan değerli hocam Prof. Dr. Aybars UĞUR'a teşekkürü bir borç bilirim.

İZMİR

06/09/2022

Behlül SARIKAYA

İÇİNDEKİLER

	<u>Sayfa</u>
İÇ KAPAK	ii
KABUL ONAY SAYFASI	iii
ETİK KURALLARA UYGUNLUK BEYANI.....	v
ÖZET	vii
ABSTRACT	ix
ÖNSÖZ	xi
İÇİNDEKİLER DİZİNİ.....	xiii
ŞEKİLLER DİZİNİ	xvii
TABLolar DİZİNİ.....	xix
SİMGELER VE KISALTMALAR DİZİNİ.....	xxi
1 GİRİŞ.....	1
2 KURAMSAL TEMELLER.....	3
2.1 Cilt Lezyonu	3
2.1.1 Biyopsi türleri	3
2.1.2 Cilt lezyonu türleri.....	4

İÇİNDEKİLER (devam)

2.1.3	Melanom	7
2.2	Makine Öğrenmesi	10
2.2.1	Denetimli öğrenme	10
2.2.2	Denetimsiz öğrenme	12
2.3	Derin Öğrenme	13
2.3.1	Konvolüsyonel sinir ağları (CNN)	14
2.3.2	Çekişmeli üretici ağ (Generative adversarial network - GAN)	16
3	LİTERATÜR İNCELEMESİ	18
4	DERİN ÖĞRENME VE GÖRÜNTÜ ÖN İŞLEME YÖNTEMLERİ İLE OTOMATİK DERİ LEZYONU TESPİTİ	25
4.1	Giriş	25
4.2	Kullanılan Dönüşüm Yöntemleri	26
4.3	Ön Eğitilmiş VGG-16 Modeli	27
5	DENEYSEL ÇALIŞMALAR	29
5.1	Giriş	29
5.2	Deneyler ve Sonuçları	30
5.2.1	Yalnızca ön işlemenin değerlendirildiği deneyler	30
5.2.2	Dönüşüm yöntemlerinin değerlendirildiği deneyler	31

İÇİNDEKİLER (devam)

5.2.3	Renk uzaylarının değerlendirildiği deneyler	34
5.2.4	Görüntü çözünürlüklerinin değerlendirildiği deneyler	36
5.2.5	DCGAN ile farklı yaklaşımların değerlendirildiği deneyler	39
5.2.6	Oylama yöntemleri ile modellerin birleştirilmesi.....	44
6	SONUÇ VE ÖNERİ	48
	KAYNAKLAR DİZİNİ.....	51
	TEŞEKKÜR	58
	ÖZGEÇMİŞ.....	59

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1. CNN Mimarisi	15
2.2. Çekişmeli üretici ağların çalışma şeması.....	16
2.3. DCGAN eğitiminde aşamalarda üretilmiş cilt kanseri görüntüleri	17
4.1. Deneilerdeki modellerin veri artırımı ve eğitim şeması	26
4.2. Transform yöntemleri ile türetilmiş görüntüler. (Kaggle, 2018).....	27
5.1. Dönüşüm yöntemlerinin görüntülere uygulanması ile veri artırımının gerçekleştirilmesi.....	33
5.2. Renk uzayı deneylerinde veri artırımının ve eğitimin uygulanma şeması	35
5.3. Görüntü çözünürlüğü deneylerinde veri artırımı ve model eğitimi.....	38
5.4. DCGAN eğitiminde veri artırımın uygulanması	42
5.5. Veri artırımında DCGAN dan yararlanılan deneylerdeki veri artırım ve eğitim şeması	43
5.6. Yumuşak oylama ile topluluk modelinin oluşturulması.....	45
5.7. Sert oylama ile topluluk modelinin oluşturulması.....	46

TABLolar DİZİNİ

<u>Tablo</u>	<u>Sayfa</u>
5.1. Görüntü ön işleme ile ve görüntü ön işleme olmadan gerçekleştirilen deneylere ait sonuçlar.....	30
5.2. Transform yöntemlerinin uygulandığı deney sonuçları.....	33
5.3. Renk uzaylarının uygulandığı deneylere ait sonuçlar.....	36
5.4. Görüntü çözünürlükleri üzerine yapılan deneylerin sonuçları	38
5.5. DCGAN stratejilerinin kullanıldığı deneylere ait sonuçlar	43
5.6. Oylama yöntemleri ile birleştirilen modellerin sonuçları (64x64)	46
5.7. Oylama yöntemleri ile birleştirilen modellerin sonuçları (128x128)	47

SİMGELER VE KISALTMALAR DİZİNİ**Kısaltmalar**

ACS Amerikan Kanser Topluluğu

BCC Bazal Hücreli Karsinom

CNN Convolutional Neural Networks

DCGAN Derin Evrişimli Çekişmeli Üretici Ağlar

GAN Çekişmeli Üretici Ağlar

SCC Skuamöz Hücre Karsinoması

1 GİRİŞ

Cilt kanseri, en yaygın rastlanan kanser türlerinden biridir. Amerikan Kanser Topluluğunun (ACS) verdiği bilgilere göre her yıl 5 milyondan fazla cilt kanseri vakası görülmektedir. Yıllık olarak sistematik bir şekilde kanser verilerini paylaşan ACS'nin Amerika Birleşik Devletleri için 2022 yılındaki cilt kanseri vaka sayısı tahmini 99.780 iken bu vakaların 7.650'sinin ölümle sonuçlanması beklenmektedir (American Cancer Society, 2022a). Bazı cilt lezyonları kanser grubunda olmasa da kanser öncüsü olarak değerlendirilmektedir. Cilt kanseri risk faktörlerine maruz kalma durumuna ve genetik yatkınlığa göre bu tür lezyonların kansere dönüşme süreçleri değişmektedir (Yesiloglu, t.y.a).

Cilt lezyonlarının biyopsi ve tedavisinde başvurulabilecek birden fazla yöntem bulunmaktadır. Ancak işlem sonrası komplikasyonların oluşmaması için cilt lezyonlarının türüne göre uygun yöntemin seçilmesi gerekmektedir. Bu süreçte lezyonların ön teşhisi uzmanlar tarafından yapılmaktadır. Ancak yapılan bazı çalışmalarda patoloji sonuçlarının dermatolojik teşhisler ile uyuşmadığı gözlemlenmiştir. Ön teşhisteki bu uyuşmazlık sebebiyle son zamanlarda teşhise yardımcı olabilecek pek çok araştırma gerçekleştirilmiştir.

Yapılan araştırmalarda cilt lezyonlarının sınıflandırmasında farklı derin öğrenme ağları ile birlikte veri artırımı ve görüntü ön işleme yöntemlerine de yer verilmektedir. Veri seti olarak ise HAM10000, ISIC2018, ISIC2019 setleri kullanılmıştır.

Bu çalışmada, cilt lezyonlarının tespitinde ön eğitilmiş VGG-16 modeli kullanılmıştır. Bu modelin seçilmesinin sebebi pek çok çalışmada araştırma konusu olması ve performansının bilinmesidir. Veri seti olarak 7 sınıftan toplam 10015 görüntüye sahip HAM10000 veri seti kullanılırken veri artırımı için geleneksel transform teknikleri ve sentetik veri üretimi için farklı stratejiler ile eğitilmiş DCGAN modelleri kullanılmıştır.

Tez çalışmasında veri artırımı ve ön işleme tekniklerinin etkinliğini daha iyi ölçebilmek ve daha fazla görüntü ekleyebilmek için görüntüler 64x64 çözünürlüğüne düşürülmüştür. Çözünürlük düşürmenin bir amacı Google Colab üzerinde gerçekleştirilen bu çalışma için kaynakların daha verimli kullanılmasıdır.

Literatürdeki cilt lezyonu tespiti için yapılan çalışmalarda genel olarak derin öğrenme ve transfer öğrenme modellerinden yararlanılmıştır. Veri artırımı için ise döndürme, yansıtma, küçültme, yakınlaştırma, kırpma gibi yöntemler kullanılmıştır (Dildar et al., 2021; Kassem et al., 2021). Bazı çalışmalarda ise sentetik veri üretimi ile sınıflandırma başarısı iyileştirilmeye çalışılmaktadır. Bu tez çalışmasının önemi ve farklılığı, klasik veri artırım teknikleri dışında farklı derin öğrenme tabanlı veri artırım modellerinin, veri ön işleme yöntemlerinin ve transfer öğrenme yöntemlerinin kullanılması ve topluluk öğrenmesi kapsamında modellerin birleştirilmesidir. Bu katkı yolu ile başarımın artırılması hedeflenmiştir.

Veri artırım stratejilerinin farklı kullanımları yalnızca birbirleriyle karşılaştırılmamıştır. Aynı zamanda bu stratejiler bir arada kullanılarak sınıflandırma performansının artırılması hedeflenmiştir.

Tez çalışmasının ikinci bölümünde cilt lezyonu, makine öğrenmesi ve derin öğrenme hakkında detaylı bilgilerin verildiği kuramsal temeller yer almaktadır. Üçüncü bölümde, literatürdeki cilt lezyonlarının sınıflandırılması üzerine yapılan çalışmalar incelenmektedir. Dördüncü bölümde, tez çalışması kapsamında gerçekleştirilen deneylere ait yöntemler açıklanmaktadır. Beşinci bölümde, gerçekleştirilen çalışmalarda performansı ölçülen deneyler açıklanmakta ve bu deneylere ait sonuçlar paylaşılmaktadır. Altıncı bölümde ise deney sonuçlarının değerlendirilmesi ve gelecek çalışmalar için sunulan öneriler yer almaktadır.

2 KURAMSAL TEMELLER

Bu bölümde, tez çalışmasında kullanılan yöntemlerin ve işlenen problemin bilimsel açıklamaları yer almaktadır. Cilt lezyonları, cilt kanseri olarak adlandırılan türleri ve cilt kanserlerine yönelik; biyopsi, tedavi ve önleme yöntemleri hakkında detaylı bilgi verilmektedir. Ayrıca makine öğrenmesinin alt dalları olan derin öğrenme ve topluluk öğrenmesi temel alınarak makine öğrenmesi yöntemleri üzerinde belli ölçüde detaylı bir anlatım yapılmaktadır.

2.1 Cilt Lezyonu

Cilt kanserleri melanom ve melanom dışı olmak üzere iki gruba ayrılmaktadır. Melanom, daha düşük olasılıkla meydana gelse de melanom dışı kanserlere göre ölüm sayısı daha yüksektir. Cilt kanserleri bozulma olan hücre tipine göre çeşitlenmektedir. Örnek olarak; cilde rengini veren melanosit hücrelerden kaynaklanan kanserler Malign melanoma olarak adlandırılırken, bazal hücrelerden kaynaklanan kanserler bazal hücreli karsinom türüne girer. Cildin dış tabakasındaki yassı hücrelerden kaynaklanan kanserler ise yassı hücreli karsinomlardır. Cilt lezyonlarının bir çok türü vardır. Bazı türleri kanser olarak nitelendirilmese de kansere dönüşme eğilimindedirler (Sarıkaya & Ugur, 2022; Öztekin'den, t.y.). Şüpheli lezyonlarda, tanının net olmadığı durumlarda ve tedavi amaçlanıyorsa; cilt lezyonlarına biyopsi uygulanmaktadır (Linares et al., 2015). Cilt lezyonu için uygun biyopsiyi seçmek ise oldukça önemlidir.

2.1.1 Biyopsi türleri

Punch biyopsi

Keskin, içi boş, dairesel bir alet kullanılarak küçük bir yuvarlak doku parçasının çıkarılması işlemidir. Doku daha sonra hastalık belirtileri için mikroskop altında kontrol edilir. Kansere yol açabilecek bazı cilt durumlarını ve değişiklikleri kontrol etmek için kullanılabilir (Azman, t.y.). Bu biyopsi türünde kullanılan punch'ın genişliğine göre alınacak kesit değişmektedir (Türk Dermatoloji Derneği,

t.y.b). Bundan dolayı belli genişliğin üzerinde olan cilt lezyonlarının biyopsisin bu yöntem ile yapılması uygun olmamaktadır.

Shave biyopsi

Shave biyopsi, en sık kullanılan biyopsi türlerindedir. Epidermiste (deriyi oluşturan 3 katmandan ve yüzeye en yakın olan katman) bulunan lezyonların biyopsisi için uygundur (Buzoğlu, t.y.). Seboreik keratoz, piyojenik granülom, polip gibi lezyonların tanı ve tedavisinde sıkça kullanılan bir yöntemdir (Saliha, t.y.). Bu yöntemde lokal anestezi enjeksiyonu ile lezyon deriden yukarı kaldırılır ve uygun bistüri ile doku yüzeyden tıraşlanır (Akgül, t.y.). Tıraşlama sonrası kanamalı bir zemin meydana gelir. Bu yöntemde dikiş zorunlu değildir. Uygun hastalarda ve uygun bölgelerde kullanıldığı takdirde verimli ve kozmetik sonuçları iyi bir biyopsi yöntemidir. Derine inen lezyonlar için kullanılması uygun değildir.

Eksizyonel biyopsi

Cerrahi bir yöntemdir. Bu yüzden uygulamanın yapıldığı bölge minör cerrahi işlemler için gereken koşulları sağlamalıdır. Malign melanom şüphesi taşıyan pigmentli lezyonlarda da özellikle tercih edilir (Türk Dermatoloji Derneği, t.y.a). Lezyonlu bölge dışında bir miktar temiz bölge de biyopsi kapsamında temizlenebilir. Lezyon, bir doku çengeli yardımıyla tutularak istenilen derinlikte makas veya bistüri ile kesilir (Akgül, t.y.). Lezyonların tümünün çıkarılabilmesi için bu yöntem en uygun biyopsi yöntemidir. İşlemin ardından dikiş gereklidir.

2.1.2 Cilt lezyonu türleri

Bazal hücreli karsinom (BCC)

BCC, epidermisin bazal tabakasından ve eklerinden kaynaklanan bir cilt kanseridir (Linares et al., 2015). Ultraviyole radyasyonun neden olduğu mutasyonlardan kaynaklanır. Güneşe en çok maruz kalan; tenoz, kulaklar, yüz ve ellerin dış bölgesinde oluşur ve bu nedenle en çok tenoz, kulaklar, yüz ve ellerin arkası gibi güneşe maruz kalan alanlarda ortaya çıkar, ancak vücudun herhangi bir

yerinde ortaya çıkabilir. Ekvator bölgelerinde sıklıkla görülen bir kanser türüdür. Risk faktörlerinden bazıları; radyasyon tedavisi, açık ten ve artan yaş (Mayo Clinic, t.y.). Bu lezyona sahip kişilerin yaklaşık %40'ında 5 yıl içinde başka bir lezyon gelişir.

BCC, 3 ana alt tipe ayrılabilir: yüzeysel, nodüler ve morfeaform. Her grubun kendine özgü fiziksel özellikleri ve histolojik bulguları vardır (Linares et al., 2015).

- **Nodüler BCC** : Nodüler BCC, baş ve boyun kısmında sıklıkla görülen BCC'nin en yaygın türüdür (Yesiloglu, t.y.b). Papül tipik olarak yarı saydam bir inci görünümüne, telenjektazilere sahiptir ve ülserasyona sahip olabilir
- **Yüzeysel BCC** : Genç yetişkinlerde en sık görülen bcc türüdür. En sık üst gövde ve omuzlarda görülür. eritemli, pul pul veya plak şeklinde kendini gösterir.
- **Morfeaform BCC** : Genelde yüz bölgelerinde bulunur. Bu lezyon türünde lezyonun sınırları net bir şekilde belli değildir. Rritematöz veya cilt renginde bir papül veya plak olarak ortaya çıkar (Linares et al., 2015). Lezyon, sertleşme, atrofi ve düzensiz sınırlarla skar benzeri görünebilir.

Bazal hücreli karsinom'un tedavisi

Bazal hücreli karsinom, ayakta tedavi ortamında kolayca tedavi edilir (Linares et al., 2015). Bazal hücreli karsinom en sık olarak tüm kanseri ve çevresindeki sağlıklı dokuların bir kısmını çıkarmak için ameliyatla tedavi edilir (Mayo Clinic, t.y.) Ameliyatlı yöntem için iki farklı seçenek bulunur. Göğüs, sırt, eller ve ayaklardaki gibi tekrarlama olasılığı daha düşük olan vakalar için cerrahi eksizyon önerilebilir. Lezyonun tekrarlama riski daha yüksekse, örneğin daha büyükse, deride daha derine uzanıyorsa veya yüz bölgesinde bulunuyorsa Mohs ameliyatı önerilebilir. Tedavi seçimindeki temel aşama, lezyonun ilk defa ya da tekrarlı olup olmadığının belirlenmesidir.

Ameliyatın mümkün olmadığı durumlarda da farklı tedavi yöntemleri önerilebilir (Mayo Clinic, t.y.). Alternatif tedaviler Küretaj ile elektrodessikasyon, Radyasyon tedavisi, dondurma, krem türü merhemler ve fotodinamik terapi seçeneklerini içerir.

Nadir de olsa bazal hücreli karsinomun lenf düğümlerine ve vücudun diğer bölümlerine yayıldığı durumlarda ilaç tedavisi veya kemoterapi uygulanabilir. (Snow et al., 1994)'ün çalışmalarında, yayılcı bazal hücre karsinomlarının (MBCC) yaklaşık %67'sinin yüz bölgesinden kaynaklandığı belirlenmiştir. Çalışmada Mohs Cerrahi Kliniğinin veri tabanı kullanılmıştır. MBCC gelişiminin olasılığı için vakalar 10 yıl veya daha uzun süreler boyunca takip edilmelidir.

Skvamöz hücre karsinomu (SCC)

Cilt kanserlerinden en yaygın 2. Olanı Kutanöz SCC'dir (Linares et al., 2015). Melanom dışı cilt kanserlerinin yaklaşık yüzde 20'si skuamöz hücreli karsinomlardır (Alam and Ratner, 2001). Bazal hücreli karsinoma benzer şekilde SCC'de büyük ölçüde UV ışınlarına maruziyetten kaynaklanmaktadır (Linares et al., 2015). Ancak, kutanöz SCC'de metastaz riski daha yüksektir. SCC'nin iki farklı formu bulunmaktadır;

- **Bowen hastalığı** : SCC'nin intraepitelyal formudur. Tipik cilt kanseri risk faktörlerine ek olarak insan papilloma virüsü ile de ilişkilidir. Epidermiste görülen bir hastalıktır. Düzensiz sınırları olan pürüzlü, pullu, eritemli bir plak olarak ortaya çıkar. Vakaların çoğu alt bacaklarda ve güneşe maruz kalan ciltte bulunur. Ancak bu lezyon herhangi bir yerde ortaya çıkabilir. Bowen hastalığı, kriyoterapi, koterizasyon ve topikal 5-florourasil ile etkili tedavi görülebilir.
- **Queyrat eritroplazisi** : Genital bölgede ortaya çıkan bir SCC insitu şeklindedir. Bowen hastalığı gibi epidermis ile sınırlıdır. Bu tür, insan papilloma virüsü ile ilişkilidir. Lezyon, kanama veya ülserasyona sahip olabilen eritematöz-pullu veya kabuklu bir plak olarak ortaya çıkar. Etkili tedavi, Bowen hastalığında olduğu gibi aynı modalitelerle kolayca elde edilir.

SCC, en sık güneşe maruz kalan bölgelerde görülmekle beraber vücudun herhangi bir yerinde de gelişebilir. Genellikle kaba, eritemli papüller, plaklar ve iyi sınırlı sınırları ve kabuklu nodüller olarak ortaya çıkar. Lezyonlar ülserasyon, pigmentasyon, eritem, pullanma veya hiperkeratoz gösterebilir. Biyopsi ve histopatolojik inceleme ile tanı konur. Tıraş, punch veya eksizyonel biyopsiler, şüpheli SCC teşhisi için kabul edilebilir yöntemlerdir.

SCC'nin tedavisi

SCC'nin tedavisi BCC'ye benzer şekilde yapılabilir. Metastaz riskinin artması nedeniyle eksizyon veya Mohs cerrahisi tercih edilebilir. Eksizyon için 4mm-6mm hedefiyle yapılmalıdır. Ameliyatın uygun olmadığı durumlarda radyasyon tedavisi önerilebilir.

2.1.3 Melanom

Melanom, melanositlerden türetilen agresif bir malign neoplazmdır (Linares et al., 2015). Melanositler epidermisin bazal tabakasında bulunur. En nadir görülen kanser türlerinden olsa da ölüm oranı oldukça yüksektir. Ultraviyole ışığa maruz kaldıklarında onkogenleri aktive eden, tümör baskılayıcı genleri inaktive eden ve DNA onarımını bozan bir genetik mutasyon birikimi olur. Bu süreç, melanositlerin kontrolsüz çoğalmasına ve nihayetinde melanoma yol açabilir. Melanom'un 4 ana alt tipi vardır: yüzeysel, nodüler, lentigo maligna ve akrall lentiginöz.

- **Yüzeysel (Superficial) Melanom:** En sık görülen melanom türüdür ve malign melanomların %75'ini oluşturmaktadır (Linares et al., 2015). Yüzeysel Melanom, derine büyümeden önce çevreye doğru yayılır. Lezyon, dermis tabakasını aştıktan sonra dikey büyüme aşamasında olduğu kabul edilir. Lezyon, değişken renklerde (siyah, mavi, kahverengi, beyaz, gri, kırmızı) olabilir. Düzensiz sınırlar ve lezyonun sınırında melanositlerin ilerleyen proliferasyonunu temsil eden asimetrik bir alevlenme ile ortaya çıkabilir.
- **Nodüler Melanom :** Melanomların %15 ila %30'unu oluşturan agresif, dikey olarak büyüyen bir melanomdur (Linares et al., 2015). Yüzeysel

melanomdaki gibi bir radyal büyüme aşamasına sahip değildir. Bu nedenle kişinin lezyondan şüphelenmesi daha uzun sürebilir. Nodüler melanom genellikle koyu pigmentli pedinküllü veya polipoid nodüller olarak bulunur.

- **Lentigo Malign Melanom** : Melanomun en yaygın 2. Türüdür (Linares et al., 2015). Yaygın bir şekilde baş ve kollar gibi güneşe maruz kalan alanlarda görülür (Yesiloglu, t.y.c). Küçük, düz, ten rengi, düzensiz kenarlı, asimetric olarak ortaya çıkar, zamanla büyür ve rengi değişmeye başlar.
- **Akrall lentiginöz** : En sık palmar, plantar ve subungual yerleşimlerde görülür (Linares et al., 2015). Bu melanom en az görülen alt tiptir ve vakaların %5'inden azını oluşturur. Akrall lentiginözler genel olarak ileri evrelerde tanılanmaktadır (Esbah et al., 2016).

Melanom'a ait risk faktörleri ise şu şekildedir;

- Çok sayıda ortak nevüs varlığı
- Bir veya daha fazla atipik nevüs
- Açık ten
- Güneşe maruz kalma
- Güneş yanığı geçmişi
- Bronzlaşma yatağına maruz kalma
- İleri yaş
- Birinci derece akrabalarda aile öyküsü

Melanom teşhisi

Histopatoloji, tanıda altın standarttır (Linares et al., 2015). Melanom olduğundan şüphelenilen herhangi bir lezyondan biyopsi yapılmalıdır. Lezyonun iyi huylu olup olmadığı veya biyopsi endikasyonu belirsizse hasta dermatoloğa sevk edilmelidir. Tüm lezyonu 1 mm ila 3 mm normal cilt ve subkutan yağın bir kısmı ile mümkün olduğunda içeren bir eksizyonel biyopsi yapılmalıdır. Lezyonun derinliği evreleme amacıyla hayati önem taşıdığından, melanomdan şüpheleniliyorsa tıraş biyopsisi kullanılmamalıdır. Eksizyonel biyopsi, terapötik olduğu kadar tanısal olma avantajına da sahiptir.

Melanomun Tedavisi

Doktorların önerdiği tedavi türü, melanomun evresine ve konumuna bağlı olacaktır (American Cancer Society, 2022b). Ancak kanser hücrelerinde belirli gen değişiklikleri varsa, tedaviden sonra kanserin geri dönme riski ve hastanın genel sağlığı gibi diğer faktörler de önemli olabilir. Melanomun tedavisi 5 evrede farklılık göstermektedir (American Cancer Society, 2022b). Melanomun temizlenmesinde eksizyonel biyopsi kullanılmaktadır. İlerleyen evrelerde lenf düğümü biyopsisi önerilebilmektedir (National Cancer Institute, 2019). Lenf düğümlerinde kanser görüldüğü durumlarda radyasyon tedavisi önerilebilir.

Kanserin önlenmesi

Cilt kanseri pek çok nedene bağlı olarak gelişim gösterebilir (Linares et al., 2015). Risk faktörlerinden bazıları; UV ışına maruz kalma, yaşanılan bölge, genetik yatkınlık, ileri yaş, cinsiyet, baskılanmış bağışıklık ve ten rengidir (Linares et al., 2015). Risk faktörlerinin çoğu güneş ışınlarının cilde olan etkisi ile ilgilidir. Cilt kanseri vakfının cilt kanserinden kaçınmak için vermiş olduğu öneriler ise şu şekildedir (Skin Cancer Foundation, t.y.);

- Özellikle 10.00-16.00 saatleri arasında gölgede kalınmalı.
- Bronzlaşmaktan kaçınılmalı ve UV bronzlaşma yatakları kullanılmamalı.
- Geniş kenarlı bir şapka ve UV engelleyici güneş gözlükleri de dahil olmak üzere vücut giysilerle örtülmeli.
- Her gün SPF'si 15 veya daha yüksek olan geniş spektrumlu (UVA/UVB) bir güneş kremi kullanılmalı. Uzun süreli açık hava etkinliği için, 30 veya daha yüksek SPF'li suya dayanıklı, geniş spektrumlu (UVA/UVB) bir güneş koruyucu kullanılmalı.
- Açık alana çıkmadan 30 dakika önce tüm vücuda 1 ons (2 yemek kaşığı) güneş kremi sürülmeli. Her iki saatte bir veya yuzdükten veya aşırı terledikten sonra tekrar uygulanmalı.
- Bebekler güneşten uzak tutulmalı. Altı aylıktan büyük bebeklerde ise güneş kremi kullanılmalı.
- Kişi her ay cildini tepeden tırnağa incelemeli.

- Profesyonel bir cilt muayenesi için yılda en az bir kez bir dermatoloğa görünmeli.

2.2 Makine Öğrenmesi

Makine öğrenimi, insan zekasını taklit edebilen bilgisayar algoritmaları geliştirme teknolojisidir (el Naqa & Murphy, 2015). Makine öğrenmesi; robotik, sanal kişisel asistanlar, bilgisayar oyunları, örüntü tanıma, doğal dil işleme, veri madenciliği, trafik tahmini, çevrimiçi ulaşım ağı gibi pek çok uygulama alanında kullanılmaktadır (Ray, 2019). Problemin tanımını ne olursa olsun o alan için geliştirilecek makine öğrenmesi uygulamasının başarısı için girdi yoluyla öğrenme yeteneği oldukça önemlidir.

Bazı makine öğrenmesi algoritmaları öğrenimden önce verileri işlemek için veri madenciliği yöntemlerini kullanmaktadır. Benzer şekilde Veri madenciliği yöntemlerinde de verilerdeki gizli bilgileri keşfetmek için makine öğrenmesi yöntemleri kullanılır (Kargupta et al., 2008). Bu bilgilere göre makine öğrenmesi ile veri madenciliğinin iç içe olduğu söylenebilir.

Makine öğrenimi, psikoloji ve felsefeden fikirler almaktadır. Bu sayede hem veri yapıları, algoritmalar, olasılık ve istatistik gibi mühendislik bilimi yönlerine hem de bilgi ve kontrol teorisi ve sosyal bilim yönlerine sahiptir (el Naqa & Murphy, 2015).

Algoritmalar makine öğrenimine güç sağlayan yapılardır (Oracle, t.y.). Makine öğrenimi yöntemleri ise tahminleme için veriyi öğrenme yöntemlerine göre sınıflara ayrılır; bunlar denetimli öğrenme ve denetimsiz öğrenmedir (el Naqa & Murphy, 2015; Oracle t.y.).

2.2.1 Denetimli öğrenme

Denetimli öğrenme, makine öğreniminde sınıflandırma veya tüme varımsal öğrenme olarak da adlandırılmaktadır (Liu, 2011). Bu öğrenme türü, insandaki öğrenmeye benzer şekilde; gerçek dünyadaki görevleri yerine getirmede geçmiş deneyimler yardımıyla çıkarım yapmaya benzer. Bilgisayar için deneyim eğitime dahil edilen veriler yoluyla elde edilir.

Denetimli öğrenmede, çalışmaya konu olan veri setinde her bir girdinin hangi çıktı grubuna veya sınıfına ait olduğu bilgisi yer almaktadır. Bu bilgiye göre makine öğrenmesi modeli veri setindeki eşlemeyi tahmin etmeye çalışmaktadır. Bu yöntemle, veri bilimcisi bir rehber görevi görür ve algoritmaya hangi sonuçları çıkarması gerektiğini öğretir (Oracle, 2021).

Denetimli makine öğrenimi örnekleri, doğrusal ve lojistik regresyon, çok sınıflı sınıflandırma ve destek vektör makineleri gibi algoritmaları içerir (IBM, t.ya).

Denetimli öğrenme veri madenciliği aşamasında sınıflandırma ve regresyon şeklinde iki farklı problem olarak incelenebilir (IBM, t.yb). Sınıflandırma veri kümesi içindeki belirli varlıkları tanır ve bu varlıkların nasıl etiketlenmesi tanımlanması gerektiği konusunda bazı sonuçlar çıkarmaya çalışır. Regresyon ise bağımlı ve bağımsız değişkenler arasındaki ilişkiyi anlamak için kullanılır.

Denetimli Öğrenme Algoritmaları

Denetimli makine öğrenme süreçlerinde çeşitli algoritmalar ve hesaplama teknikleri kullanılmaktadır. Yaygın olarak kullanılan öğrenme yöntemlerinden bazıları şu şekildedir;

- **Yapay Sinir Ağları (Artificial Neural Networks)** : Derin öğrenme algoritmaları için kullanılan sinir ağları, insan beynini taklit ederek eğitim verilerini işlemektedir. Her düğüm girdilerden, ağırlıklardan, bir eşikten ve bir çıktıdan oluşmaktadır. Çıkış değeri bir eşiği aşarsa, veri bir sonraki katmana ileterek düğümü etkinleştirir. Sinir ağları, bu haritalama işlevini denetimli öğrenme yoluyla öğrenir ve gradyan inişi süreci boyunca kayıp işlevine göre ayarlama yapar. Kayıp fonksiyonu sıfıra yakın olduğunda, modelin doğru işlediği söylenebilir.
- **Naive Bayes** : Naive Bayes, Bayes teoreminin uygulanmasına dayalı bir olasılıklı sınıflandırma yaklaşımıdır. Çekirdek yoğunluğu tahmini ile birleştiğinde yüksek doğruluğa ulaşabilmektedir (Piryonesi and El-

Diraby, 2020). Bu teknik daha çok metin sınıflandırma ve öneri sistemlerinde kullanılmaktadır (IBM, t.yb).

- **Doğrusal Regresyon** : Gelecekteki sonuçlar hakkında tahminde bulunmak için, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi belirlemede kullanılmaktadır (IBM, t.yb). Üç farklı türü vardır; tek bir bağımsız değişken olduğunda, basit doğrusal regresyon; birden fazla bağımsız değişkenin olduğu durumlarda çoklu doğrusal regresyon; çoklu doğrusal regresyonun özel bir durumu olan, bağımlı ve bağımsız değişkenlerin eğrisel etkileşimi ile harmanlanan polinom regresyondur.

2.2.2 Denetimsiz öğrenme

Kümeleme

Etiketlenmemiş veriler üzerinde gerçekleştirilen, verileri benzerlik ve farklılıklarına göre ayıran bir veri madenciliği yöntemidir. Kümeleme algoritmaları ise özel ve örtüşen, hiyerarşik ve olasılıksal olarak gruplara ayrılmaktadır.

- **Özel ve Örtüşen Kümeleme** : Bir veri noktasının yalnızca bir kümede var olabileceğini belirten gruplandırma biçimi özel kümelemedir. Örtüşen kümelemenin özel kümelemeden ayrıldığı nokta ise, veri noktalarının farklı üyelik derecelerinde olmasına izin vermesidir.
- **Hiyerarşik Kümeleme** : Hiyerarşik kümeleme toplayıcı ve bölücü olarak iki gruba ayrılmaktadır. Toplayıcı kümelemede veri noktaları başlangıçta ayrı gruplamalar olarak izole edilir ve daha sonra bir küme elde edilene kadar benzerlik temelinde yinelemeli olarak birleştirilir. Bu yöntemde dört farklı yöntem kullanılmaktadır. Bunlar; Ward bağlantısı, ortalama bağlantı, tam (maksimum) bağlantı ve tek (minimum) bağlantıdır (IBM, t.yb). Bölücü kümelemede veri kümesi, noktalar arasındaki farklara göre bölünmektedir.
- **Olasılıksal Kümeleme** : Olasılıksal kümelemede, veri noktaları olasılıklarına göre kümelenir (IBM, t.yb). Bu kümeleme yönteminde Gauss Karışım Modeli yaygın olarak kullanılmaktadır.

Birliktelik Kuralı

Olayların birlikte gerçekleşme olasılıklarının belirlenmesi için kullanılan yöntemlerdir (IBM, t.yb). Bu yöntemler, pazar sepeti analizi ve öneri sistemleri için sıklıkla kullanılmaktadır. Birlikte satın alınan ürünler ve müşteri alışkanlıkları tespit edilebilmektedir. Bu sayede işletmeler, daha iyi çapraz satış stratejileri ve öneri motorları geliştirebilmektedir. Pek çok alışveriş sitesi ve sosyal içerik platformlarında bu yöntemler ile analiz yapılmaktadır.

Boyutsal Küçültme

Fazla miktardaki veri genellikle daha doğru sonuçlar verirken, makine öğrenimi algoritmalarının performansını da olumsuz yönde etkileyebilmekte ve veri kümelerinin görselleştirilmesini de zorlaştırabilmektedir (IBM, t.yb). Boyut azaltma, belirli bir veri kümesindeki özellik veya boyut sayısının çok fazla olduğu durumlarda kullanılan bir tekniktir. Veri girişlerinin sayısını yönetilebilir bir boyuta düşürürken, veri kümesinin bütünlüğünü de mümkün olduğunca korur. Veri ön işleme aşamasında yaygın olarak kullanılır ve kullanılacak birkaç farklı boyut azaltma yöntemi vardır, bunlar; temel bileşenler analizi, tekil değer ayrışımı, otomatik kodlayıcılarıdır.

2.3 Derin Öğrenme

Derin öğrenme, birden çok işleme katmanından oluşan hesaplama modellerinin, birden çok soyutlama düzeyiyle verilerin temsillerinin öğrenilmesini sağlayan bir makine öğrenmesi yöntemidir (Lecun et al., 2015). Veri miktarının artması ve hesaplama gücünün gelişmesi ile daha karmaşık yapılara sahip olan sinir ağları yoğun ilgi görmüş ve çeşitli alanlarda uygulanmıştır (Hao et al., 2016). Karmaşık yapılara sahip birden fazla katman ile modelleme yapıldığı için sığ makine öğrenimi modellerinin aksine çoklu doğrusal olmayan dönüşümlerden oluşur. Derin mimarilerin çok sayıda çeşidi vardır ve farklı veri kaynaklarını temsil etmek için farklı mimariler kullanılabilir. Örneğin, evrişimli sinir ağı, görüntü tanıma için en popüler mimaridir ve tekrarlayan sinir ağı, el yazısı veya konuşma tanıma gibi sıralı görevlere uygulanabilmektedir.

Özellik çıkarımı açısından derin öğrenmede makine öğrenmesine göre bazı farklılıklar bulunmaktadır (İnik & Ülker, 2017). Makine öğrenmesinde özellik çıkarımı yaklaşımı yapılan probleme göre genelde alanında uzman olan kişilerce yapılmaktadır. Bu işlemler hem çok zaman almakta hem de uzmanı çok meşgul edebilmektedir. Ancak derin öğrenmede ham veriler üzerinden işlem gerçekleştirdiğinden ham veriyi işlerken katmanlar arası oluşturulan temsillerle özellik çıkarımı işlemi alanında uzman kişilere gerek kalmadan otomatik bir şekilde gerçekleştirilmektedir. Derin öğrenmede katmanların özellik çıkarımında aldıkları roller farklıdır. Rollerine göre katmanlar alt ve üst olarak iki grupta incelenirse; veri girişine en yakın olan alt katmanlar basit özellikleri öğrenir (Zhang et al., 2018). Üst katmanlarda ise alt katmanlarda türetilen daha karmaşık özellikler öğrenilir (Zhang et al., 2018). Mimari bu yönden hiyerarşiktir ve güçlü bir özellik çıkarımı sağlamaktadır (Zhang et al., 2018).

Derin öğrenme günümüzde endüstri, tıp, robotik, görüntü işleme, bilgisayarlı görü, nesne tespiti, ses işleme-tanıma, çeviri, gelecek tahmini ve finans gibi birçok çalışma alanında başarılı sonuçlar elde etmiştir (Doğan ve Türkoğlu, 2019). Derin öğrenmenin çeşitli alanlarda başarı elde etmesinin bir nedeni veri miktarlarındaki artıştır. Ancak veri miktarındaki aşırı artış veri etiketlemenin çok maliyetli bir aşamaya dönüşmesine neden olmaktadır. Yüksek miktardaki bu veriler derin öğrenme eğitim aşamasında gelişmiş cihazların kullanımını gerektirmektedir.

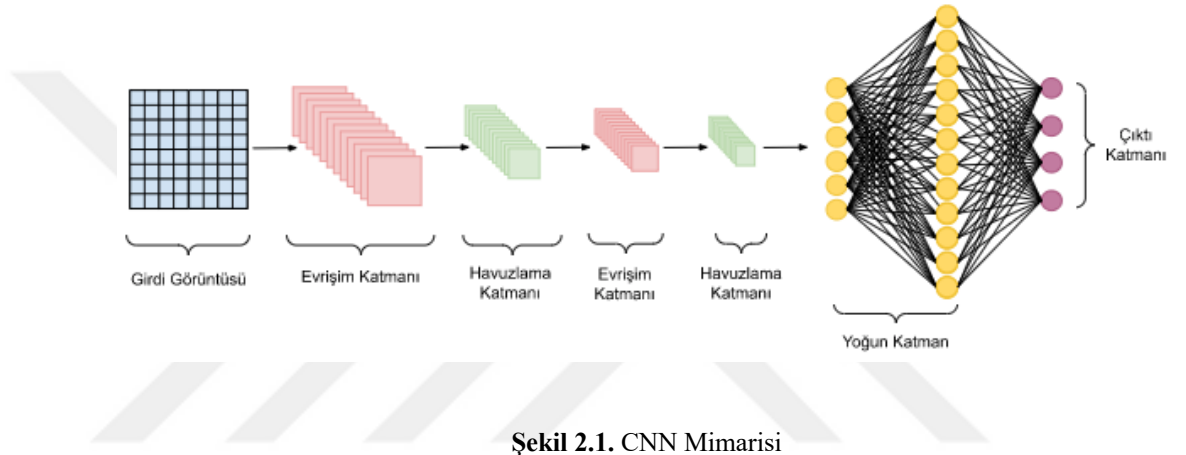
Çeşitli problemlerin çözümünde tek bir sinir ağı kullanmak uygun değildir (Doğan ve Türkoğlu, 2019). Problemin çözümü için kullanılan veri türüne ve probleme göre yapay sinir ağı seçilmelidir. Çeşitli yapay sinir ağlarının sınıflandırma, tespit, tahmin gibi problemlerde özel olarak kullanılmadığıdır. Benzer şekilde verinin; görüntü, ses, sinyal olması da kullanılacak yapay sinir ağının türünü değiştirmektedir.

2.3.1 Konvolüsyonel sinir ağları (CNN)

CNN bir tür ileri beslemeli yapay sinir ağıdır. Eğitim için video ve resimlerden oluşan veri setlerinin kullanıldığı problemler için uygundur (Hao et al., 2016). Görüntüler doğrudan giriş olarak kullanılabilir (Hao et al., 2016). Karmaşık

özellik çıkarımı süreçlerini ortadan kaldırır (Hao et al., 2016). Canlıların doğal görsel algı mekanizmasından esinlenerek geliştirilen CNN, son dönemlerde en kapsamlı şekilde incelenen derin sinir ağlarıdır (Gu et al., 2018).

CNN'in yapısında her katman bir sonraki katmanı besler. Herhangi bir katmandaki nöron bir önceki ve bir sonraki katmanlardaki tüm nöronlar ile bağlantılıdır. Ancak kendi katmanındaki nöronlar ile bağlantısı yoktur. Bu yüzden CNN'de nöronlar arasında bir döngü bulunmamaktadır. CNN mimarisi Şekil 2.1'deki gibidir.



Şekil 2.1. CNN Mimarisi

Pek çok CNN mimarisi geliştirilmiş olsa da mimariler temel bileşenler bakımından birbirlerine benzemektedir (Gu et al., 2018). CNN mimarilerinde giriş ve çıkış katmanları arasında 3 temel katman bulunur. Bu 3 temel katman, evrişim (convolution) katmanı, havuzlama (pooling) katmanı ve tam bağlantılı (fully-connected) katmanlardır.

Evrişim (Convolution) Katmanı

Evrişim katmanında görüntüdeki özellikleri çıkarmak için resme bazı filtreler uygulanır. Filtre resim üzerinde dolaştırılarak matris çarpımı gerçekleştirilir ve özellik haritası bu şekilde ortaya çıkar. Bu katmandaki filtreler (kernel) farklı CNN mimarilerinde farklılık gösterebilir. Örneğin; AlexNet'in ilk evrişim katmanında 11x11, 5x5 ve 3x3 boyutlarında filtreler kullanılırken; VGG-16'da 3 adet 3x3 boyutunda filtreler bulunur (Yu et al., 2016).

Havuzlama (Pooling) Katmanı

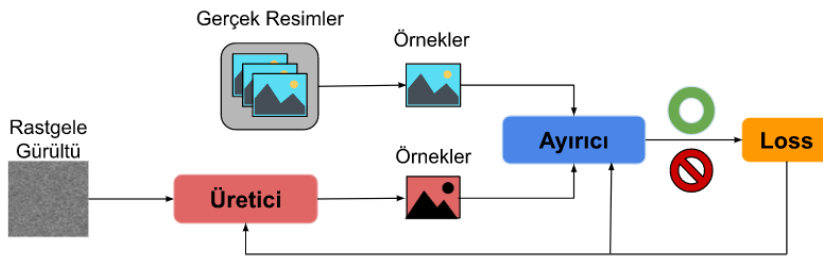
Havuzlama katmanları, girdi hacminin boyutlarını azaltarak bir sonraki evrişim katmanına hazırlama işlemini gerçekleştirir. Bu katmanda özellik haritasındaki değerler seçilecek matris boyutlarına göre alt matrislere bölünür. Parçalara ayrılan her matristeki değerlerin en büyüğü ya da o değerlerin ortalaması alınarak çıktı için hazırlanacak matriste yerine yerleştirilir. Bu sayede önemli özellikler özellik haritasında taşınmış olur. Bir sonraki evrişim katmanı için girdi hacminin uzamsal boyutlarını (genişlik yüksekliği) azaltmaktan sorumludur.

Tam Bağlantılı (Fully-Connected) Katman

Fully Connected katman, evrişim ve havuzlama katmanlarının ardından, sonuca varma aşamasında bulunmaktadır. Önceki katmanlardaki tüm nöronlar ile bağlantılıdır. Bu katmanlardan önce düzleştirme (flatten) katmanı ile iki boyutlu özellik haritaları tek boyutlu özellik vektörüne dönüştürülür.


2.3.2 Çekişmeli üretici ağ (Generative adversarial network - GAN)

GAN, Ian Goodfellow ve arkadaşları tarafından geliştirilmiş bir makine öğrenimi çerçevesidir. Esasında GAN'ın iki oyunculu bir oyun olduğu düşünülebilir. Bu oyunda oyunculardan biri veri üretirken; diğer oyuncu üretilen bu verinin gerçek olup olmadığını anlamaya çalışır. Bu sayede iki oyuncu da sahte veri gerçek veriden ayırt edilemez duruma gelene kadar kendilerini geliştirecektir. GAN'da ise bu iki oyuncu; üretici ve ayırt edici sinir ağlarıdır (Tolstikhin et al., 2014). GAN'ların çalışma stili Şekil 2.2'de verilmiştir.



Şekil 2.2. Çekişmeli üretici ağların çalışma şeması.

Çekişmeli üretici ağlarda hem üretici sinir ağı hem de ayırıcı sinir ağı eğitim boyunca kendilerini yeniler. Yeterli veri ve gelişen modellerle birlikte üretici ağı çıktıları giderek gerçeğe yakınlaşmaya başlar. Şekil 2.3'te bir üretici ağı eğitiminde ilk aşama ve 269. Aşamada ürettiği cilt kanseri resimleri yer almaktadır. Buradaki çıktılara bakıldığında; üretici ağı git gide daha gerçekçi görüntüler ürettiği görülmektedir.



Şekil 2.3. DCGAN eğitiminde aşamalarda üretilmiş cilt kanseri görüntüleri

Derin Evrişimli Çekişmeli Üretici Ağlar (DCGAN)

DCGAN, Radford ve diğerleri tarafından geliştirilmiştir. DCGAN'da GAN'ların mimari topolojisini daha kararlı bir hale getirmek için bir kısıtlama önerilmiştir (Radford et al., 2016). Radford ve diğerlerinin yaklaşımı esasında yakın zamanda CNN mimarilerindeki değişiklikleri GAN'a uygulamayı baz almıştır. Bunlar ;

- Havuzlama katmanlarının ayırıcı ve üretici ağlarda kullanılmamaktadır.
- Her iki ağda (üretici ve ayırıcı) batch normalizasyon kullanılır.
- Daha derin mimarilerde tamamen bağlı gizli katmanlar kullanılmamaktadır.
- Üretici ağda Tanh kullanan çıktılar dışındaki tüm katmanlarda ReLU Aktivasyonu kullanılmaktadır.
- Ayırıcı ağda Tüm katmanlar için LeakyReLU aktivasyonu kullanılır.

3 LİTERATÜR İNCELEMESİ

Tez çalışmasının literatür incelemesi kısmında cilt lezyonu sınıflandırma problemine ışık tutmak için yapılan çalışmalar incelenmiştir. Çalışmalardaki benzerlik her birinde deneyler için HAM10000 veri setinin kullanılıyor olmasıdır. Çalışmalarda cilt lezyonlarının sınıflandırılmasına farklı açılardan yaklaşmıştır. Çalışmalarda farklı modellerin cilt lezyonlarında değerlendirilmesi, veri artırımı, görüntü ön işleme ve segmentasyon gibi konular ele alınmıştır. Sonraki paragraflarda her bir çalışmaya detaylıca yer verilmiştir.

(Ali et al., 2021), yaptıkları çalışmada; iyi huylu ve kötü huylu cilt lezyonları arasında doğru sınıflandırma için bir derin evrişimli sinir ağı (DCNN) modeli geliştirmişlerdir. Yapılan çalışmanın ön işleme kısmında ilk olarak, gürültü ve artefaktları gidermek için filtre veya çekirdek uygulanmıştır. Ardından görüntüler normalleştirilerek, veri artırma yapılmıştır. Yazarlar tarafından önerilen DCNN'in performansı AlexNet, ResNet, VGG-16, DenseNet, MobileNet gibi transfer öğrenme modelleriyle karşılaştırılmıştır. HAM10000 veri seti ile 2 farklı deney yapılmış bu deneylerin ilkinde veri seti; %70 eğitim, %20 validasyon ve %10 test olacak şekilde ayrılırken, ikinci deneyde %80 eğitim, %10 validation, %10 test olarak parçalanmıştır. İlk deneyde önerilen model, test doğruluğu için %90,16'lık başarıya ulaşırken, ona en yakın model %88,81 ile AlexNet olmuştur. İkinci deneyde ise doğruluk değerleri, önerilen model için %91,43, ona en yakın model olan ResNet için %90,93'lük değerler elde edilmiştir.

Yapılan diğer bir çalışmada deri kanseri görüntülerinin sınıflandırılması için iki adımdan oluşan, transfer öğrenme ve derin öğrenme temelli bir yöntem sunulmaktadır (Moldovan, 2019). Veri setine ait yedi sınıf 2 adımda uygulanmak için iki etiket kümesine bölünmüştür. İlk adım için nv, mel ve vasc sınıfındaki görüntüler kullanılırken, ikinci adımdaki veri kümesi için akiec, bcc, bkl, df sınıflarından görüntüler kullanılmıştır. Her iki adımda da ön eğitimden geçmiş denseNet121 modeli kullanılmıştır. Veri seti olarak HAM10000 veri seti kullanılırken tüm sınıflardan eşit sayıda görüntü eğitim ve test verilerine eklenmiştir. Eğitim için her sınıftan rastgele 20 görüntü; test için ise her sınıftan rastgele 5 görüntü seçilmiştir. Görüntülere eğitim öncesinde döndürme (rotate),

kesme (crop), tensor'e çevirme ve normalizasyon gibi işlemler uygulanmıştır. Çalışmanın ilk adımında ulaşılan doğruluk değeri %85; ikinci adımdaki doğruluk %75'tir. Bu çalışmanın literatürdeki diğer çalışmalar ile doğru bir şekilde karşılaştırılabilmesi için eğitim ve test aşamasındaki veri sayılarının artırılması daha sağlıklı olacaktır.

(Jain et al., 2021) ait çalışmada çok sınıflı cilt kanseri sınıflandırması için farklı transfer öğrenme ağlarının performansı değerlendirilmiştir. Kullanılan HAM10000 veri setindeki tekrarlayan görüntülerden kurtularak, sınıflar arası dengesizliği önlemek için düşük frekanslı sınıflara ait veri artırımı uygulanmıştır. Veri artırımı için görüntülere döndürme, yakınlaştırma ve kaydırma gibi teknikler uygulanarak yaklaşık 32 bin görüntü elde edilmiştir. Görüntüler önceden eğitilmiş VGG19, InceptionV3, InceptionResNetV2, ResNet50, Xception ve MobileNet modellerinde uygulanmış ve performansları değerlendirilmiştir. Deneyler sonucunda %90,48 ile XceptionNet en yüksek doğruluk değerine ulaşmıştır. Diğer modeller sırası ile MobileNet: %88,57, InceptionResNetV2: %85,8, InceptionV3: %79,23, ResNet50: %77,60, VGG-19: %66,36 doğruluk değerlerine ulaşmıştır.

Öğrenim aktarımı ve topluluk öğrenmesinin birleştirildiği bir çalışmada cilt lezyonlarının sınıflandırma problemine çözüm aranmıştır (Le et al., 2020). Önerilen modelde, ön eğitime sahip ResNet50 modelini mimarisini değiştirilerek kullanılmıştır. Bu değişiklikler, ortalama havuzlama yerine global ortalama havuzlamayı kullanmayı ve tam bağlı katmana dropout (0,5) eklemeyi içermektedir. Yazarlar tarafından önerilen model ardından VGG-16, MobileNet ve EfficientNet B1 mimarileri ile karşılaştırılmıştır. Veri Seti olarak HAM10000 kullanan yazarlar, görüntülerin çalışmalarında veri ön işlemeye başvurmamışlardır. Sonuçlar değerlendirildiğinde ise önermiş oldukları ResNet mimarisi, %90 doğruluk değeri ile karşılaştırıldığı diğer modellerden daha iyi performans göstermiştir. İkinci en iyi sonuç %89 ile EfficientNet B1 olurken; MobileNet ve VGG-16 sırasıyla %88 ve %85'lik doğruluğa ulaşmıştır. Önerilen mimariye benzer şekilde modifiye edilmiş farklı modellerin topluluk öğrenmesi yöntemleri ile değerlendirilmesiyle, %93'lük doğruluk değeri elde edilmiştir.

(Kondaveeti & Edupuganti, 2020)'ın yaptıkları çalışmada ResNet50, MobileNet, Xception, InceptionV3 modellerini cilt lezyonu sınıflandırma problemine öğrenim aktarımı yöntemi ile uyarlamışlardır. İlgili veri setindeki tekrarlayan görüntülerden kurtularak 9077 veriyi eğitim için, 938 görüntüyü de doğrulama için kullanmışlardır. Veri artırma aşamasında çevirme, kırpma ve döndürme yöntemleri kullanılarak görüntüler 224x224 çözünürlüğe sabitlenmiştir. Sınıflar arası oranı korumak için ise tabakalı örnekleme kullanmışlardır. Kullanılan modellerde üst katman kaldırılmış ve Global ortalama havuzlama katmanı, bırakma ve yoğun katmanlar eklenmiştir. Yapılan deneyler sonucunda ise en iyi sonucu veren model %90 ile ResNet50 olmuştur. MobileNet, Xception ve InceptionV3'e ait doğruluk değerleri ise sırasıyla %87, %84 ve %85 olmuştur.

(M. A. Khan et al., 2021) yaptıkları çalışmada segmentasyon için Mask-RCNN ve sınıflandırma için DenseNet mimarilerini kullanan bir tanı sistemi önermişlerdir. Çalışmada ISBI2016, ISBI2017 ve HAM10000 olmak üzere üç farklı veri seti kullanılmıştır. Önerilen sistemde, ön işleme lezyon görüntülerinin segmentasyonunu içermektedir. Elde edilen bölümlere ayrılmış görüntüler sonrasında özellik çıkarımı için DenseNet derin modeline geçirilmiştir. Özellik vektörü entropi kontrollü en küçük kare SVM (LS-SVM) kullanılarak seçim bloğuna iletilmiştir. Doğrulama için üç veri seti ile yapılan deneylerde doğruluk değerleri ISBI2016, ISBI2017 ve HAM10000 için sırasıyla %96,3, %94,8 ve %88,5 olarak elde edilmiştir.

Farklı çözünürlüklü görüntülerin kullanıldığı bir çalışmada 80x80, 64x64 ve 32x32 çözünürlüğe sahip gri tonlamalı görüntüler ile ön eğitilmiş modellerin performansını karşılaştırılmıştır. (M. D. R. H. Khan et al., 2022). Değerlendirmeye konu olan modeller; VGG-16, DenseNet169, DenseNet161 ve ResNet50'dir. Üç farklı çözünürlüğe sahip veriler ile ayrı ayrı yapılan deneylerde tüm VGG-16 modeli çözünürlüklerde en iyi performansı göstermiştir. VGG-16 modeli ile yapılan deneylerde 80x80, 64x64 ve 32x32 çözünürlükler için sırasıyla %80,46, %78,56 ve %74,15 doğruluk değerleri elde edilmiştir.

(Abuared et al., 2020)'nın çalışmalarında üç sınıflı bir cilt kanseri sınıflandırıcısı önerilmiştir. HAM10000 veri setinden seçilmiş üç sınıf;

Dermatofibroma (DF), Bazal Hücreli Karsinom (BCC) ve Benign Keratoz benzeri Lezyonlardır (BKL). Seçilen üç sınıf arasındaki dengesizliği önlemek için DF ve BCC sınıflarına ait görüntüler çoğaltılmıştır. Veri artırımı için kırpma, ölçekleme, kontrast ve parlaklık ayarı, yatay ve dikey çevirme ve bu yöntemlerin kombinasyonları kullanılmıştır. Veri artırımı sonrası 3000 veri elde edilmiştir. Sınıflandırma için VGG-16 modeli öğrenim aktarımı (transfer learning) tekniği kullanılmıştır. Görüntülerin %80'si eğitim, %20'si doğrulama için bölünmüştür. 25, 50 ve 100 aşamalık deneyler sonucunda elde edilen doğruluk değerleri sırasıyla %97,08, %97,50 ve %97,50'dir.

(Miglani & Bhatia, 2021)'nin çalışmalarında HAM10000 veri setindeki görüntüler ResNet-50 ve EfficientNet-B0 modelleri ile sınıflandırılmıştır. İki modelin performansının değerlendirildiği bu çalışmada iki model de transfer öğrenme yöntemi ile uygulanmıştır. EfficientNet-B0 modeli, ResNet-50 modelinden daha iyi sonuç üretmiştir. EfficientNet-B0 modeli için ROC ve AUC değerleri sırasıyla 0,93 ve 0,97'iken ResNet-50 için 0,91 ve 0,96 değerleri elde edilmiştir.

Yapılan bir çalışmada yazarlar cilt lezyonu sınıflandırması için ön eğitilmiş ResNet, Xception ve DenseNet modelini kullanmışlardır. Ayrıca bu üç modelin yer aldığı bir topluluk modeli geliştirmişlerdir (Rahman and Ami, 2020). Çalışmada kullanılan HAM10000 veri setindeki örnek dengesizliğinin üstesinden gelebilmek için ağırlık kaybı yöntemini kullanmışlardır. Görüntülerin ön işleme, görüntülerdeki tüy ve saçların kaldırılmasından ibarettir. Bunun için blackHat filtresi ile siyah konturlar belirlenerek görüntülerden çıkarılmıştır. 35 epoch'ta gerçekleştirilen deneyler sonucunda; dengeli doğrulukta DenseNet ve Xception için %82 değeri elde edilirken ResNet, %78 ile diğer iki modelin gerisinde kalmıştır. Geliştirilen ağırlıklı topluluk modeli ise %85,8 ile tüm modellerden daha iyi sonuç üretmiştir.

(Cakmak ve Tenekeci, 2021)'nin çalışmalarında HAM10000 veri seti kullanılarak Melanom tespiti gerçekleştirilmiştir. Deneylerde NasNet Mobile mimarisi, öğrenim aktarımı yöntemi ile kullanılmıştır. Veriler Melanom ve Melanom olmayanlar olarak iki sınıfa ayrılmıştır. Çalışmada, eğitim verilerindeki

örnek sayısını artırmak ve dengesizliğin üstesinden gelmek için veri artırımı uygulanmıştır. Veri artırımında dikey, yatay çevirme ve rastgele döndürme yöntemlerinden yararlanılmıştır. Veri artırımı sonrasında Toplam 17805 görüntü elde edilmiştir. Deney sonucunda, Veri artırımı olmadan %89,20 olarak elde edilen doğruluk değeri, veri artırımının ardından %97,90'a yükselmiştir.

(Islam et al., 2021) 'nın çalışmalarında, cilt lezyonlarını diğer mevcut modellerden daha yüksek oranda sınıflandırmaya yardımcı olan bazı görüntü ön işleme adımlarına sahip bir derin öğrenme modeli geliştirmişlerdir. Ön işleme için normalleştirme yönteminin seçildiği bu çalışmada veriler üzerinde azaltma ve artırma yöntemleri de uygulanmıştır. HAM10000 veri setindeki görüntüler iyi huylu ve kötü huylu olarak ayrılmıştır. Ardından görüntüler filtrelenerek, arka planlarındaki gürültü ve yapaylıkları azaltılmıştır. Ayrıca gürültü içeren bazı görüntüler de veri setinden çıkarılmıştır. Son adımda veriler %80 eğitim, %10 doğrulama ve %10 test olarak bölünmüştür. 200 aşamada gerçekleştirilen deney sonucunda yazarların önerdikleri mimari popüler mimarilerden olan AlexNet, ResNet, InceptionV4 ve VGG-16 modelleri ile karşılaştırılmıştır. Önerilen model, ResNet ile %90,93 ile aynı doğruluk değerine ulaşırken, bu iki modeli AlexNet, InceptionV4 ve VGG-16 modelleri takip etmektedir. Diğer modellere ait doğruluk değerleri ise sırasıyla %90,86, %88,26 ve %86,02 olarak elde edilmiştir.

Başka bir çalışmada HAM10000 veri seti üzerindeki görüntüler iyi huylu ve kötü huylu sınıflara ayırmak için bir evrişimsel sinir ağı önerilmiştir (Ameri, 2020). Model olarak, ön eğitilmiş AlexNet modeli tercih edilmiştir. Veri setindeki 100015 görüntüden 1700 iyi huylu, 1700 de kötü huylu olacak şekilde ayrılmıştır. Elde edilen görüntülerin %90'ı eğitim için %10'u da test aşamasında kullanılmak üzere bölünmüştür. Modelin girdi boyutu olarak 227x227 çözünürlük belirlenmiştir. 40 devir gerçekleştirilen deney sonucunda AlexNet modeli ile %84 doğruluk, %81 hassaslık ve %88 özgüllük değerleri elde edilmiştir.

(Younis et al., 2019) tarafından yapılan çalışmada ön eğitilmiş MobileNet modeli kullanılarak cilt lezyonlarının tespiti ele alınmıştır. Veri seti olarak HAM10000 veri seti kullanılırken; 10015 görüntünün 9000'i eğitim için ayrılmış ve tüm görüntüler 224x224 çözünürlüğüne ayarlanmıştır. Veri setindeki örnek

dengeşizliđin üstesinden gelmek için ayrıca veri artırımı uygulanmıřtır. 30 aşamada gerekleřtirilen deneyler sonucunda MobileNet; %97 kategorik dođruluk, %90 kesinlik ve %91 duyarlılık deđerlerini elde etmiřtir.

(Shete et al., 2021) tarafından gerekleřtirilen alıřmada cilt lezyonlarının sınıflandırılmasında ResNet ađı, ğrenimi aktarma yaklařımı ile kullanılmıřtır. Yazarlar, modele beslemeden önce; görüntüler üzerinde ön iřleme ve veri artırımı uygulamıřlardır. Bu aşamada kullanılan yöntemler ise Histogram eřitleme ve veri artırımı için de döndürme ve yakınlařtırmadır. Yazarlar, deneyler sonucunda XGBoost, SVM ve Rastgele orman algoritmalarını karřılařtırmıřlardır. ğrenim aktarımı yöntemini kullanan ResNet Modeli için %90,51 dođruluk deđerini elde edilirken; ađırlıklı ortalama ile kesinlik, duyarlılık ve f1 skor deđerleri sırasıyla 0,88, 0,74 ve 0,77 olmuřtur. ResNet modelinin karřılařtırılan diđer algoritmalara göre cilt lezyonu sınıflandırma görevi için daha etkili olduđu keřfedilmiřtir.

(Chaturvedi et al., 2021) tarafından yapılan alıřmada ğrenimi aktarma yöntemi ile MobileNet modeli kullanılarak cilt lezyonu tespiti için bir yaklařım önerilmiřtir. Veri seti olarak HAM10000 kullanan yazarlar MobilNet modeli üzerinde ince ayar uygulamıřlardır. Deneyler sonucunda genel dođruluk deđerini %83,1 elde edilirken; ilk 2 ve ilk 3 dođruluklar için %91,36 ve %95,34 deđerleri elde edilmiřtir. Kesinlik, duyarlılık ve f1 skorun ađırlıklı ortalama deđerleri ise sırasıyla %89, %83 ve %83 olarak bulunmuřtur.

İyi huylu ve kötü huylu cilt lezyonlarının tespit edildiđi bir alıřmada, Inception modeline dayalı InSiNet önerilmiřtir (Reis et al., 2022). alıřmada önerilen yöntemin performansı HAM10000, ISIC 2019 ve ISIC 2020 veri setleri üzerinde gerekleřtirilen deneyler ile deđerlendirilmiřtir. Görüntülerdeki tüylerin kaldırılması ve lezyon dıřı bölgelerin görüntüden ıkarılması için ön iřleme uygulanmıřtır. Deneylerde eğitim, dođrulama ve test verileri için 90:5:5, 80:10:10 ve 70:15:15 olmak üzere 3 farklı seçim yapılmıřtır. Deneyler sonucunda Önerilen InSiNet modeline ait dođruluk deđerini %94,59'iken DenseNet, ResNet52V2, InceptionV3 ve EfficientNetB0 mimarilerine ait dođruluk deđerleri sırasıyla %87,84, %86,49, %83,78 ve %82,43 olarak elde edilmiřtir.

(Singh et al., 2022) tarafından yapılan çalışmada cilt lezyonu sınıflandırmada en iyi algoritmanın seçilebilmesi için dört farklı derin öğrenme tekniği karşılaştırılmaktadır. Çalışmada veri seti olarak HAM10000 veri seti kullanılmış ve veri artırma uygulanmıştır. Veri artırımı için kullanılan yöntemler; 90° döndürme, yatay ve dikey kaydırma, rastgele yakınlaştırma ve yatay-dikey çevirmelerdir. Karşılaştırılması yapılan yöntemler; yazarlar tarafından geliştirilmiş RNN ve CNN modelleri, Xception ve ResNet50 modelleridir. Görüntülerin %20'sinin test için kullanıldığı deneyler sonucunda en iyi performansa sahip model Xception olmuştur. Xception modeline ait performans değerleri şu şekildedir; 0,93 (doğruluk), 0,93 (duyarlılık), 0,89 (kesinlik), 0,93 (F1 Skor) ve 0,9058 (AUC) olarak elde edilmiştir.

(Diwan et al., 2022) tarafından gerçekleştirilen çalışmada, cilt kanseri tespiti için ön eğitilmiş mimarilerden esinlenerek geliştirilen hibrit bir CNN mimarisi önerilmiştir. Önerilen mimaride AlexNet, öğrenim aktarımı yöntemi ile kullanılmış ve VGG modelinde olduğu gibi filtreler daha düşük boyutlu filtreler ile değiştirilmiştir. Ayrıca ResNet mimarisinde bulunan artık ve atlama bağlantıları kullanılmıştır. Çalışmada görüntülere ön işleme olarak yalnızca boyut küçültme uygulanmıştır. Deneyler sonucunda HAM10000 veri setindeki 7 sınıfa ait duyarlılık değerleri 0,646 (Aktinik Keratoz), 0,787 (Bazal hücreli karsinom), 0,732 (İyi huylu Keratoz), 0,787 (Dermatofibrom), 0,99 (Melanom), 0,527 (Melanositik Nevüs) ve 0,948 (Vasküler cilt lezyonları) olarak elde edilmiştir.

4 DERİN ÖĞRENME VE GÖRÜNTÜ ÖN İŞLEME YÖNTEMLERİ İLE OTOMATİK DERİ LEZYONU TESPİTİ

Bu bölümde, tez çalışmasında cilt lezyonu tespiti için geliştirilen derin öğrenme ve veri artırımına dayalı yöntemler ve modeller anlatılmaktadır.

4.1 Giriş

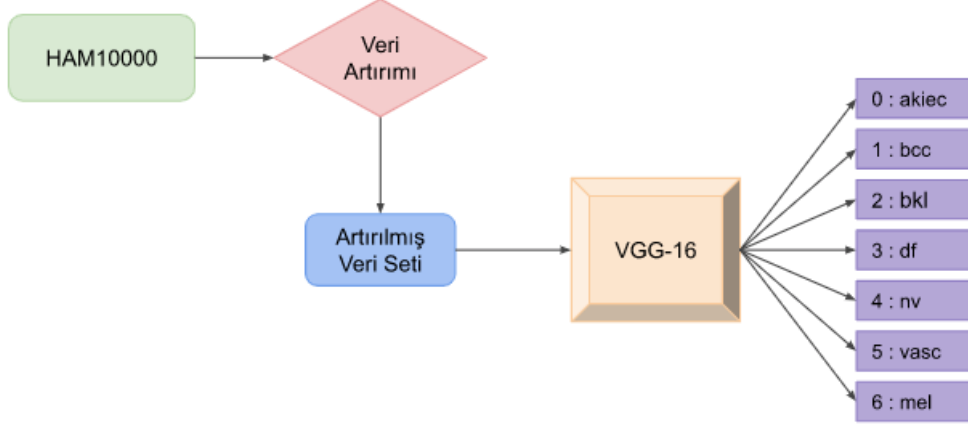
Tez çalışması sürecinde geliştirilen yöntemler, derin öğrenme ve veri artırım teknikleri kullanılarak cilt lezyonlarının sınıflandırılmasındaki iyi sonuç veren yöntemlerin belirlenmesini amaçlamaktadır.

Bu çalışmada cilt lezyonu sınıflandırma problemini konu alan önceki çalışmalardan farklı olarak; sınıflandırma performansını iyi yönde etkileyen transform yöntemleri ile sentetik veri üretimi için kullanılan yeni yöntemleri bir araya getirmesidir. Literatürde veri artırımı kullanan çalışmalara bakıldığında; bazı çalışmalarda geleneksel yöntemler ile veri artırımı yapılırken, bazı çalışmalarda ise derin öğrenme tabanlı veri artırımı uygulanmıştır. Bu çalışmada ise performansı iyi yönde etkileyen veri artırımı için kullanılacak transform teknikleri belirlenerek sentetik veri üretimi için kullanılan derin öğrenme tabanlı güncel veri artırım teknikleri ile birlikte kullanılmıştır.

Farklı veri artırım ve görüntü ön işleme tekniklerinin deneyimlendiği bu çalışmada farklı veri artırım stratejileri ile elde edilen veri kümeleri üzerinde eğitilen derin öğrenme modellerinin performansı karşılaştırılmıştır. Model olarak ön eğitilmiş VGG-16 modeli kullanılmaktadır. Öğrenim aktarımı yönteminde ön eğitilmiş model, doğrudan probleme dahil edilebilirken ayrıca modelin ilk katmanları dondurularak, tam bağlı katmanlar yeniden oluşturulabilmekte ve yalnızca yeniden oluşturulan katmanlar eğitilmektedir. Öğrenim aktarımı yöntemi ile bir modeli sıfırdan eğitmeye göre daha yüksek başarıya ulaşılabilmektedir. Bu çalışmada da imajnet veri seti üzerinde eğitilmiş VGG-16 modelinin alt katmanları dondurulmuş ve tam bağlı katman yeniden oluşturulmuştur.

Çalışmada ayrıca sınıflandırma performansına daha çok katkıda bulunan veri artırım teknikleri tespit edilmiş ve bu teknikler ile eğitilen modellerin sonuçlarının

birleştirilmesi için uygun topluluk öğrenme yöntemleri belirlenmiş ve uygulanmıştır. Çalışmada eğitilen modellerin veri artırımı ve eğitim şeması Şekil 4.1’de verilmiştir.




Şekil 4.1. Deneylerdeki modellerin veri artırımı ve eğitim şeması

4.2 Kullanılan Dönüşüm Yöntemleri

Bu aşamada veri artırımı için deneylerde kullanılan dönüşüm yöntemleri ele alınmaktadır. Sınıflandırma problemlerinde veri seti üzerinde veri artırımının uygulanması, sınıflandırma performansının artmasını sağlamaktadır.

Bu çalışmada sınıflandırma doğruluğunu artırma ve GAN ile görüntü üretimine katkıda bulunmak için veri artırımı uygulanmaktadır. Veri artırımı teknikleri olarak ise kesme (crop), döndürme (rotation) ve bu iki yöntemin farklı birleşimleri uygulanmaktadır. Resimlere uygulanan yöntemlerde kesme için piksel değeri ve döndürme açısı değeri rastgele seçilmiştir. Rastgele seçilen değerlerde limit değerleri, kesme yöntemi için 90-128 piksel aralığı döndürme yöntemi için ise -15° ve $+15^\circ$ döndürme açısı belirlenmiştir. Yöntemlerde belirtilen limit değerleri, Bölüm 5’te açıklanan deneysel çalışmalarda ürettikleri sonuçlara göre belirlenmiştir. Şekil 4.2’de örnek olarak orijinal görüntü (ilk sıradaki) ve transform yöntemlerinden kesme yöntemi ile türetilen (2. görüntü), döndürme yöntemi ile türetilen (3. görüntü) ve her iki yöntem ile türetilen (4. görüntü) yeni cilt lezyonu görüntüleri verilmiştir.



Şekil 4.2. Transform yöntemleri ile türetilmiş görüntüler. (Kaggle, 2018)

Çalışmada ayrıca sınıflandırma performansına daha çok katkıda bulunan veri artırım teknikleri tespit edilmiş ve bu teknikler ile eğitilen modellerin sonuçlarının birleştirilmesi için uygun topluluk öğrenme yöntemleri belirlenmiş ve uygulanmıştır.

4.3 Ön Eğitimli VGG-16 Modeli

Çalışmada, veri artırım tekniklerinin performansa etkisinin incelenmesi için deneyler ön eğitimli VGG-16 modeli üzerinde yapılmıştır. VGG-16 modeli 13 adet evrişim katmanı ve 3 tam bağlı katman olmak üzere 16 katmandan oluşmaktadır. Mimari yapısında Giriş katmanı 224x224 boyutlu ve 3 kanallıdır. Bu da modelin varsayılan olarak 224x224 çözünürlüklü ve 3 kanallı görüntüleri girdi olarak kabul edebileceğini gösterir. Giriş katmanından sonra gelen evrişim katmanlarında filtre boyutu 3x3'tür. Bu da özellik çıkarımı için görüntü üzerinde 3x3'lük filtrelerin dolaştırılması demektir. VGG mimarisinde evrişim katmanlarının kanal boyutu 64'ten başlamaktadır. Her bir evrişim grubunda bu kanal sayıları 2 kat artmaktadır. Bu çarpım kanal boyutu 512 olana dek devam eder. Ayrıca her bir evrişim grubunun ardından 2x2 çerçeveye sahip Maksimum havuzlama katmanları kullanılır.

İlk evrişim grubunda 224x224 boyutlu ve 64 kanallı 2 adet evrişim katmanı bulunmaktadır. Bu iki katman 224x224 boyutlu ve 64 kanallıdır. Sonraki evrişim grubunda 112x112 boyutlu ve 128 kanal sayısına sahip 2 evrişim katmanı bulunmaktadır. 3. evrişim grubunda, 56x56 boyutunda 256 kanal sayısında sahip 3 adet evrişim katmanı yer almaktadır. 4. evrişim grubunda da 3 adet evrişim katmanı bulunurken, bu katmanlar 28x28 boyutlu ve 512 kanallıdır. Son evrişim grubunda ise 14x14 boyutlu ve 512 kanala sahip 3 katman yer almaktadır.

VGG-16 mimarisinde evriřim katmanlarını üç tam baęlı katman takip etmektedir. İlk ikisinde 4096 kanal, üçüncüsünde ise 1000 kanal yer almaktadır. VGG-16'nın son katmanı softmax katmanıdır.

Tez çalışması kapsamında modellerin eğitimi için belirlenen parametreler řu şekildedir; 30 devir (epoch), 64 yığm boyutu (batch-size). Optimizer fonksiyonu için 0,001 öğrenme oranı ile Adam fonksiyonu seçilmiştir.



5 DENEYSEL ÇALIŞMALAR

5.1 Giriş

Bu çalışmada ele alınan cilt lezyonu sınıflandırma probleminin çözümü için görüntü ön işleme teknikleri ile birlikte veri artırımı uygulanmıştır. Uygulanan veri artırımında transform yöntemleri ve çekişmeli üretici ağlar (DCGAN) kullanılmıştır. Transform yöntemleri ile veri artırımında her yeni görüntü türetildiği görüntünün bir kopyası olsa da DCGAN ile üretilen sentetik görüntüler benzersizdir. Çalışmada farklı veri artırım yöntemleri ile eğitilen modeller karşılaştırılarak en iyi sonuç veren modellere ait sonuçlar topluluk öğrenmesi yöntemleri ile birleştirilmiş ve sonuçlar değerlendirilmiştir. Ayrıca veri artırımlarında sınıf sayısına duyarlı örnekleme yöntemi de kullanılmıştır. Çalışmada kullanılan veri seti, 10015 görüntü barındıran 7 sınıfa sahip HAM10000 veri setidir (Sarıkaya & Ugur, 2022). Ön işleme ve veri artırımları için OpenCV, Scikit-image, Scikit-learn, Numpy ve Albumentations kütüphaneleri kullanılmıştır. Elde edilen sonuçların görselleştirilmesinde Matplotlib kütüphanesinden yararlanılmıştır.

Modeller kullanılan veri artırım ve ön işleme yöntemlerine göre gruplara ayrılarak incelenmiştir. Modeller aşağıdaki özelliklere göre gruplandırılmıştır;

- Veri setinde görüntü artırımı olmadan yalnızca ön işlemenin etkisinin incelendiği deneyler
- Transform yöntemlerinden kesme ve döndürme yöntemleri ile geliştirilen stratejilerin kullanıldığı deneyler
- Farklı renk uzaylarının kullanıldığı deneyler
- Farklı görüntü çözünürlüklerinin kullanıldığı deneyler
- Farklı yaklaşımlar ile eğitilen DCGAN'ların kullanıldığı deneyler
- Sınıflandırma performansı en yüksek olan modellerin farklı oylama yaklaşımlarıyla birleştirilmesinden elde edilen topluluk modellerinin değerlendirildiği deneyler

5.2 Deneyler ve Sonuçları

Cilt lezyonu sınıflandırma için HAM10000 veri setinin kullanıldığı bu çalışmada eğitim ve test aşamalarında kullanılmak üzere veriler %70 eğitim, %30 doğrulama olmak üzere ayrılmıştır. Ardından veri artırımı yalnızca eğitim için kullanılacak görüntülere uygulanmıştır. Deneylerde görüntüler 128x128 ve 64x64 olarak kullanılmıştır.

5.2.1 Yalnızca ön işlemenin değerlendirildiği deneyler

Cilt lezyonu sınıflandırmada veri artırımı ve ön işlemenin sınıflandırma performansına etkisinin değerlendirilebilmesi için veri artırımı ve ön işlemenin uygulandığı deneyler ile eğitim aşamasında herhangi bir veri artırımı ve ön işlemenin uygulanmadığı deney sonuçlarının incelenmesi gerekmektedir. Bu deney grubunda değerlendirilen modeller aşağıdaki gibidir.

- İlk deneyde herhangi bir ön işleme ve veri artırımı uygulanmamıştır.
- İkinci deneyde veri artırımı uygulanmazken görüntülere standardizasyon uygulanmıştır.

Veri artırımı ve ön işlemenin uygulanmadığı görüntüler ile eğitilen model ve ön işleme için standardizasyon uygulanan bir modele ait sınıflandırma performansı karşılaştırılmıştır. Deney sonuçları **Tablo 5.1**'de gösterilmiştir.

Tablo 5.1. Görüntü ön işleme ile ve görüntü ön işleme olmadan gerçekleştirilen deneylere ait sonuçlar

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
Ön işleme ve veri artırımı olmadan gerçekleştirilen eğitim	0,6744	0,6012	0,6741	0,6266
Ön işlemede standardizasyon uygulanarak gerçekleştirilen eğitim	0,7524	0,7167	0,7537	0,7227

Deney sonuçlarına bakılacak olursa herhangi bir ön işleme olmadan gerçekleştirilen eğitimde model doğruluğu %67,44 iken; görüntü ön işlemede standardizasyon uygulanan model doğruluğu %75,24 olarak elde edilmiştir.

5.2.2 Dönüşüm yöntemlerinin değerlendirildiği deneyler

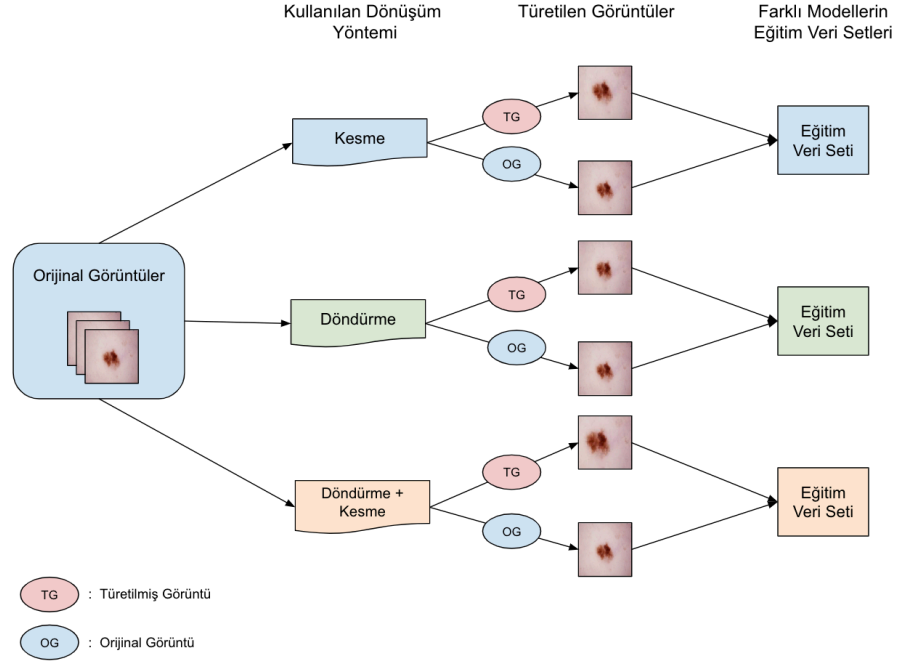
Bu bölümde yer alan modeller veri artırımı aşamasında kırpma ve döndürme tekniklerinin farklı kullanımlarını içermektedir. Toplamda 14 farklı kullanımın değerlendirildiği bu bölümde deney numaraları ve deneylerde kullanılan yöntemlere ait detaylı bilgiler aşağıda incelenmiştir.

- **Deney 1** : Veri artırımı için Kesme (Crop) yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her bir görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 2** : Veri artırımı için Kesme yöntemi kullanılmıştır. Sayı olarak daha az veriye sahip sınıflara ait her bir görüntüden 3 yeni görüntü üretilmiştir.
- **Deney 3** : Veri artırımı için Kesme yöntemi kullanılmıştır. Sayı olarak daha az veriye sahip sınıflara ait her bir görüntüden 2 yeni görüntü üretilirken; daha fazla örneğe sahip sınıflara ait görüntülerden 1 yeni görüntü üretilmiştir.
- **Deney 4** : Veri artırımı için Döndürme (Rotate) yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her bir görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 5** : Veri artırımı için Döndürme yöntemi kullanılmıştır. Sayı olarak daha az veriye sahip sınıflara ait her bir görüntüden 2 yeni görüntü üretilirken; daha fazla örneğe sahip sınıflara ait görüntülerden 1 yeni görüntü üretilmiştir.
- **Deney 6** : Veri artırımı için Döndürme yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her bir görüntüden 2 yeni görüntü üretilmiştir.
- **Deney 7** : Veri artırımı için Döndürme ve Kesme yöntemleri bir arada kullanılmıştır. Üretilen yeni görüntü sayıları ise şu şekildedir; sınıfa ait örnek sayısı 100 ve daha az ise her bir görüntüden 11 görüntü, örnek sayısı 500 ve daha az ise her bir görüntüden 6 görüntü, örnek sayısı 1000'den daha

az ise her bir görüntüden 3 yeni görüntü, örnek sayısı 2000'in altında ise o sınıfa ait her görüntüden 2 yeni görüntü üretilmiştir, örnek sayısı 2000'in üzerinde ise veri artırımı uygulanmamıştır.

- **Deney 8 :** Veri artırımı için kesme yöntemi kullanılmıştır. Üretilen yeni görüntü sayıları ise şu şekildedir; sınıfa ait örnek sayısı 100 ve daha az ise her bir görüntüden 11 görüntü, örnek sayısı 500 ve daha az ise her bir görüntüden 6 görüntü, örnek sayısı 1000'den daha az ise her bir görüntüden 3 yeni görüntü, örnek sayısı 2000'in altında ise o sınıfa ait her görüntüden 2 yeni görüntü üretilmiştir, örnek sayısı 2000'in üzerinde ise veri artırımı uygulanmamıştır.
- **Deney 9 :** Veri artırımı için Döndürme ve Kesme yöntemleri kullanılmıştır. Yalnızca eğitim aşamasındaki örnek sayısı 4000'in altındaki sınıflara ait her görüntüden 2 yeni görüntü üretilmiştir. Üretilen görüntülerin bir tanesi döndürme yöntemi ile bir tanesi de kesme yöntemi ile üretilmiştir.
- **Deney 10 :** Veri artırımı için Döndürme ve Kesme yöntemleri kullanılmıştır. Her bir görüntüden 1 yeni görüntü üretilmiştir. Kullanılacak yöntem rastgele seçilmiştir. Veri artırımı yalnızca örnek sayısı az olan sınıflara uygulanmıştır.
- **Deney 11 :** Veri artırımı için Kesme yöntemi kullanılmıştır. Tüm sınıflara veri artırımı uygulanmıştır. Her bir görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 12 :** Veri artırımı için merkezi kesme (Center-Crop) yöntemi kullanılmıştır. Tüm sınıflara veri artırımı uygulanmıştır. Her bir görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 13 :** Veri artırımı için merkezi kesme yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 14 :** Veri artırımı için döndürme yöntemi kullanılmıştır. Tüm sınıflara veri artırımı uygulanmıştır. Her bir görüntüden 1 yeni görüntü üretilmiştir.

Dönüşüm yöntemlerinin görüntülere uygulanarak ve veri setine eklenmesini gösteren şema Şekil 5.1'de verilmiştir.



Şekil 5.1. Dönüşüm yöntemlerinin görüntülere uygulanması ile veri artırımının gerçekleştirilmesi

Dönüşüm yöntemlerinin sınıflandırma performansına etkisinin incelendiği deneylere ait sonuçlar Tablo 5.2’de yer almaktadır.

Tablo 5.2. Transform yöntemlerinin uygulandığı deney sonuçları

		Doğruluk	Kesinlik	Duyarlılık	F1-skor
Deney 1	Crop	0,7681	0,7480	0,7698	0,7538
Deney 2	Crop	0,7265	0,7721	0,7272	0,7435
Deney 3	Crop	0,7698	0,7489	0,7702	0,7516
Deney 4	Rotate	0,7604	0,7597	0,7618	0,7576
Deney 5	Rotate	0,7594	0,7485	0,7597	0,7435
Deney 6	Rotate	0,7443	0,7616	0,7446	0,7488
Deney 7	Crop, Rotate	0,6868	0,7714	0,6888	0,7156
Deney 8	Crop	0,7208	0,7756	0,7191	0,7372
Deney 9	Crop, Rotate	0,7554	0,7627	0,755	0,7575
Deney 10	Crop, Rotate	0,7604	0,7437	0,7608	0,7463

Deney 11	Crop	0,7678	0,7333	0,7675	0,7386
Deney 12	Crop	0,751	0,7221	0,753	0,7144
Deney 13	Crop	0,745	0,7198	0,7463	0,7307
Deney 14	Rotate	0,7628	0,7302	0,7641	0,7314

Deney sonuçlarına bakıldığında en yüksek kesme yöntemi ile görüntü sayısı daha az olan sınıflarda her görüntüden 2 yeni görüntü, eğitim aşamasındaki görüntü sayısı 1000 adetten fazla olan sınıflardaki her görüntüden 1 yeni görüntü üretilerek eğitim aşamasına dahil edilen 3. deneyde doğruluk değeri olarak **%76,98** değeri elde edilmiştir. Yalnızca döndürme yöntemi ile yapılan veri artırım deneylere bakıldığında en yüksek doğruluk değeri tüm görüntülerden 1 yeni görüntünün üretilerek eğitim aşamasına dahil edilmesinin performansa etkisinin incelendiği 14. deneyde **%76,28** doğruluk değeri elde edilmiştir. İki teknik ile her görüntüden 1 adet döndürme yöntemi ile 1 adet de kesme yöntemi ile görüntü türetilerek eğitim aşamasına dahil edilmesinin incelendiği 9. deneyde **%75,54**'lük doğruluk değeri elde edilmiştir. Bu deney grubunda **%68,68** ile en düşük doğruluk değerini, görüntülere her iki tekniğin aynı anda uygulandığı ve farklı sayıda görüntülerin türetildiği 7. deney elde etmiştir.

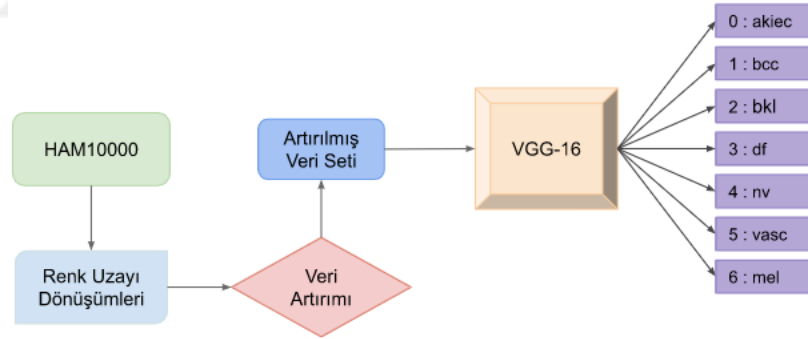
5.2.3 Renk uzaylarının değerlendirildiği deneyler

Tez çalışması kapsamında renk uzayı dönüşümlerinin cilt lezyonu sınıflandırmada model performansına etkisinin değerlendirildiği deneyler yapılmıştır. Model eğitimlerinde yararlanılan veri artırım teknikleri ve görüntülere ait renk uzayları aşağıda açıklanmıştır;

- **Deney 1** : Veri artırımı için Kesme yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her bir görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 4** : Veri artırımı için Döndürme yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her bir görüntüden 1 yeni görüntü üretilmiştir.

- **Deney 14** : Veri artırımı için döndürme yöntemi kullanılmıştır. Tüm sınıflara veri artırımı uygulanmıştır. Her bir görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 15** : Görüntüler HSV'ye dönüştürüldükten sonra veri artırımı uygulanmıştır. Veri artırımı için döndürme yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 16** : Görüntüler HSV'ye dönüştürüldükten sonra veri artırımı uygulanmıştır. Veri artırımı için rastgele kırpma yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her görüntüden 1 yeni görüntü üretilmiştir.
- **Deney 17** : Görüntülere CLAHE dönüşümü uygulandıktan sonra veri artırımı için rastgele kırpma yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her görüntüden 1 yeni görüntü üretilmiştir.

Renk uzaylarının incelendiği deneylere ait veri artırımı eğitim şeması Şekil 5.2'de verilmiştir.



Şekil 5.2. Renk uzayı deneylerinde veri artırımının ve eğitimin uygulanma şeması

Farklı renk uzaylarındaki görüntüler ile eğitilen modellerin incelendiği deneylerin sonuçları Tablo 5.3'te listelenmiştir.

Tablo 5.3. Renk uzaylarının uygulandığı deneylere ait sonuçlar

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
Deney 1	0,7681	0,7480	0,7698	0,7538
Deney 4	0,7604	0,7597	0,7618	0,7576
Deney 14	0,7628	0,7302	0,7641	0,7314
Deney 15	0,709	0,6478	0,7087	0,6537
Deney 16	0,7053	0,6568	0,7053	0,6635
Deney 17	0,669	0,4489	0,67	0,5376

Renk uzaylarının sınıflandırma performansında etkisinin incelendiği bu deney grubunda sonuçlara göre RGB görüntüler ile gerçekleştirilen ve kesme yöntemi kullanılarak görüntü sayısı az olan sınıflarda bulunan görüntülere 1 defa veri artırımının uygulandığı 1. deney **%76,81**'lik doğruluk değeri elde etmiştir. Aynı koşullarda HSV renk uzayı üzerinde gerçekleştirilen 16. deneyde **%70,53**'lük doğruluk değeri elde edilmiştir. Diğer benzer koşullarda yapılan deneylerde de RGB renk uzayının kullanılması sınıflandırma performansının daha iyi olduğu gözlenmiştir.

5.2.4 Görüntü çözünürlüklerinin değerlendirildiği deneyler

Çalışmada, veri artırım ve ön işlemenin sınıflandırma performansına etkisi incelenmiştir. Bu yüzden kısıtlı sistem kaynakları ile daha fazla veri artırımı uygulanabilmesi için görüntülerin çözünürlükleri düşürülmüştür. Görüntü çözünürlüklerinin sınıflandırma performansına etkisinin ölçülebilmesi için aynı veri artırım teknikleri farklı çözünürlükteki görüntülere uygulanmış ve farklı çözünürlükteki görüntüler ile eğitilmiş modellerin performansları ölçülmüştür. Aşağıda deneylere ait bilgilere yer verilmiştir.

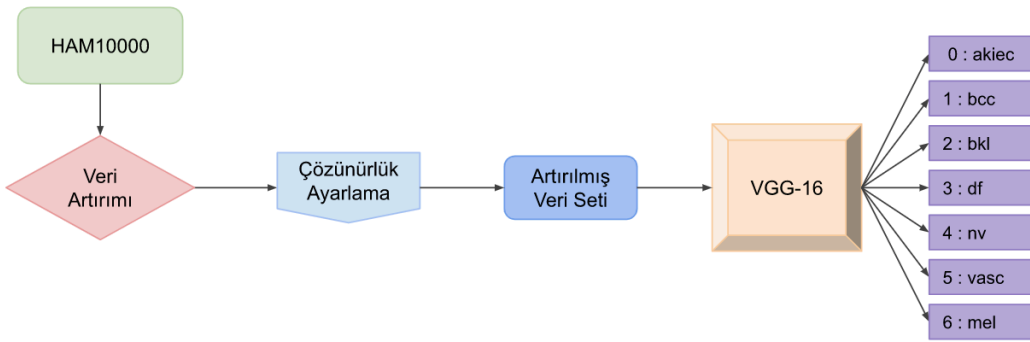
- **Deney 4** : Deney 64x64 çözünürlüklü görüntüler üzerinde gerçekleştirilmiştir. Veri artırımı için Döndürme (Rotate) yöntemi kullanılmıştır. Sayı olarak daha az örneğe sahip sınıflara ait her bir görüntüden 1 yeni görüntü üretilmiştir.

- **Deney 9** : Deney 64x64 çözünürlüklü görüntüler üzerinde gerçekleştirilmiştir. Veri artırımı için Döndürme ve Kesme yöntemleri kullanılmıştır. Yalnızca eğitim aşamasındaki örnek sayısı 4000'in altındaki sınıflara ait her görüntüden 2 yeni görüntü türetilmiştir. Üretilen görüntülerin bir tanesi döndürme yöntemi ile bir tanesi de kesme yöntemi ile üretilmiştir.
- **Deney 10** : Deney 64x64 çözünürlüklü görüntüler üzerinde gerçekleştirilmiştir. Veri artırımı için Döndürme ve Kesme yöntemleri kullanılmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir. Kullanılacak yöntem rastgele seçilmiştir. Veri artırımı yalnızca örnek sayısı az olan sınıflara uygulanmıştır.
- **Deney 11** : Deney 64x64 çözünürlüklü görüntüler üzerinde gerçekleştirilmiştir. Veri artırımı için Kesme yöntemi kullanılmıştır. Tüm sınıflara veri artırımı uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.
- **Deney 18** : 64x64 çözünürlüklü görüntüler üzerinde gerçekleştirilen deneyde veri artırımı için kesme ve döndürme yöntemi görüntülere aynı anda uygulanmıştır. Her bir görüntüden bir yeni görüntü türetilmiştir.
- **Deney 19** : 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımı için kesme yöntemi uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.
- **Deney 20** : 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımı için Döndürme ve Kesme yöntemleri kullanılmıştır. Kullanılacak yöntem rastgele seçilmiştir. Veri artırımı yalnızca örnek sayısı az olan sınıflara uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.
- **Deney 21** : 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımı için Döndürme ve Kesme yöntemleri kullanılmıştır. Veri artırımı yalnızca örnek sayısı az olan sınıflara uygulanmıştır. Her bir görüntüden döndürme yöntemi ile 1 adet ve kırpma yöntemi ile 1 adet görüntü türetilmiştir.
- **Deney 22** : 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımı için Döndürme yöntemi kullanılmıştır. Veri artırımı yalnızca

örnek sayısı az olan sınıflara uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.

- **Deney 23** : 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımı için Döndürme ve Kesme yöntemleri aynı anda olacak şekilde yalnızca örnek sayısı az olan sınıflara uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.

Farklı çözünürlüklerdeki görüntüler ile gerçekleştirilen deneylere ait görüntü artırımı ve model eğitime ait şema Şekil 5.3'te gösterilmiştir.



Şekil 5.3. Görüntü çözünürlüğü deneylerinde veri artırımı ve model eğitimi

64x64 ve 128x128 çözünürlüklere sahip görüntüler ile eğitilen modellere ait deney grubunun sonuçları Tablo 5.4'te listelenmiştir.

Tablo 5.4. Görüntü çözünürlükleri üzerine yapılan deneylerin sonuçları

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
Deney 4	0,7604	0,7597	0,7618	0,7576
Deney 9	0,7554	0,7627	0,755	0,7575
Deney 10	0,7604	0,7437	0,7608	0,7463
Deney 11	0,7678	0,7333	0,7675	0,7386
Deney 18	0,7584	0,7513	0,7564	0,7444
Deney 19	0,7685	0,7497	0,7705	0,7547
Deney 20	0,7725	0,7768	0,7725	0,772

Deney 21	0,7655	0,7711	0,7655	0,7645
Deney 22	0,7735	0,7551	0,7712	0,7611
Deney 23	0,7772	0,7495	0,7752	0,7585

Deney grubunda sınıflandırma performansı en iyi olan model, %77,72'lik doğruluk değeri ile 23. deney olmuştur. Bu deneyde 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Kesme ve döndürme yöntemleri bir arada kullanılarak az sayıda görüntü içeren sınıflara veri artırımı uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir. Diğer deneyler incelendiğinde yüksek çözünürlüğe sahip görüntüler ile eğitilen modellerin sınıflandırma başarısının daha yüksek olduğu görülmektedir.

5.2.5 DCGAN ile farklı yaklaşımların değerlendirildiği deneyler

Sentetik görüntü üretimi de veri artırım yöntemlerinden biri olarak kullanılmaktadır. Bu çalışmada da farklı teknikler ile DCGAN'lar eğitilerek ağlardan sentetik görüntüler üretilmiştir. Eğitilen DCGAN modellerinde üretici ve ayırıcı ağ bulunmaktadır. 270 devir (epoch) gerçekleştirilen eğitimlerde eğitilen modellere ait yapı ise;

- Üretici ağda, ilk aşamada yoğun katman (4096) ve ardından girdiyi yeniden şekillendiren reshape (4,4,256) bulunur. Sonrasında üç adet evrişim grubu yer almaktadır. İlk evrişim grubu ve ikinci evrişim grubu aynıdır ve sırasıyla; örnekleme katmanı (UpSampling2D), evrişim katmanı (filters: 128, kernel_size: 3), batchNormalization katmanı (momentum:0,8) ve son olarak aktivasyon katmanı (relu) bulunur. Üçüncü evrişim grubunda ise örnekleme katmanı (UpSampling2D), evrişim katmanı (filters: 256, kernel_size: 3), batchNormalization katmanı (momentum:0,8) ve son olarak aktivasyon katmanı (relu) yer almaktadır.
- Ayırıcı ağda, ilk aşamada evrişim katmanı (filters:32, kernel_size:3) ve LeakyReLU (alpha:0,2) yer almaktadır. Ardından 4 adet evrişim grubu yer almaktadır. İlk grupta, dropout katmanı

(rate:0,25), evrişim katmanı (filter:64, kernel_size:3, strides=2), batchNormalization katmanı (momentum=0,8) ve leakyReLU katmanı (alpha=0,2) yer almaktadır. Diğer evrişim gruplarında ise yalnızca evrişim katmanının “filters” parametresi değişmektedir. Bu parametre her gruptaki evrişim katmanlarında sırasıyla 128, 256 ve 512’dir. Son kısımda ise seyreltme (dropout) katmanı (0,25), düzleştirme (flatten) katmanı ve aktivasyon parametresi olarak sigmoid fonksiyonuna sahip yoğun (dense) katman yer almaktadır.

Bu aşamada yer alan deneylerde VGG-16 modelinin eğitiminde veri artırımı sentetik görüntüler ve dönüşüm yöntemleri ile orijinal görüntülerden elde edilen dönüşümler kullanılmıştır. Deneylere ait detaylar aşağıda belirtilmiştir.

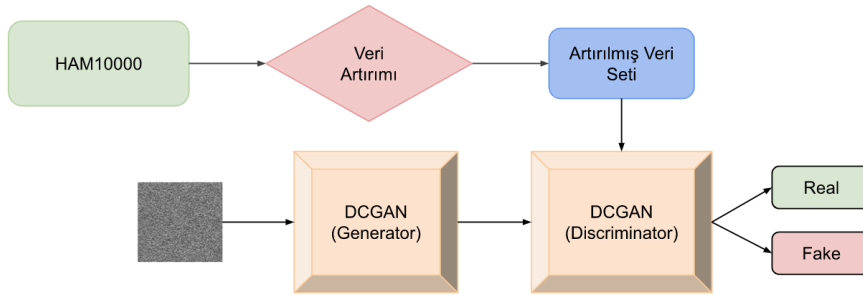
- **Deney 24** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. Tüm sınıflarda 4000 eğitim verisi olacak şekilde görüntüler eklenmiştir.
- **Deney 25** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. Tüm sınıflarda 4000 eğitim verisi olacak şekilde görüntüler eklenmiştir. Veri setine eklenirken görüntülere blur tekniği uygulanmıştır.
- **Deney 26** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, her sınıftan yaklaşık 1500 görüntü olacak şekilde sınıflardaki görüntüler artırılarak eğitilmiştir. Eğitilen DCGAN ile sınıflardaki görüntü başına 1 adet sentetik görüntü üretilmiştir.
- **Deney 27** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, her sınıftan yaklaşık 1500 görüntü olacak şekilde sınıflardaki görüntüler artırılarak eğitilmiştir. Eğitilen DCGAN ile sınıflardaki görüntü başına 2 adet sentetik görüntü üretilmiştir.
- **Deney 28** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, her sınıftan yaklaşık 3000 görüntü olacak şekilde sınıflardaki görüntüler artırılarak eğitilmiştir. Eğitilen DCGAN ile sınıflardaki görüntü başına 2

adet sentetik görüntü üretilmiştir. Ardından orijinal görüntülere kesme yöntemi ile ön işleme uygulanmıştır.

- **Deney 29** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, her sınıftan yaklaşık 3000 görüntü olacak şekilde sınıflardaki görüntüler artırılarak eğitilmiştir. Eğitilen DCGAN ile sınıflardaki görüntü başına 2 adet sentetik görüntü üretilmiştir. Ardından kesme yöntemi ile orijinal görüntülerden, görüntü az sayıda örnek barındıran sınıflara ait ise 2 değilse 1 yeni görüntü üretilmiştir.
- **Deney 30** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, her sınıftan yaklaşık 3000 görüntü olacak şekilde sınıflardaki görüntüler artırılarak eğitilmiştir. Eğitilen DCGAN ile sınıflardaki görüntü başına 2 adet sentetik görüntü üretilmiştir. Ardından döndürme yöntemi ile orijinal görüntülerden; görüntü az sayıda örnek barındıran sınıflara ait ise 2, değilse 1 yeni görüntü üretilmiştir.
- **Deney 31** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, az sayıda örnek bulunduran sınıflara ait DCGAN ağları ile örnek sayılarının 2 katı kadar görüntü üretilmiştir. Bu aşamada DCGAN ağları, orijinal görüntülere rastgele dönüşüm uygulanarak eğitilmiştir.
- **Deney 32** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, az sayıda örnek bulunduran sınıflara ait DCGAN ağları ile 1000 adet görüntü üretilmiştir. Bu aşamada DCGAN ağları, orijinal görüntülere rastgele dönüşüm uygulanarak eğitilmiştir.

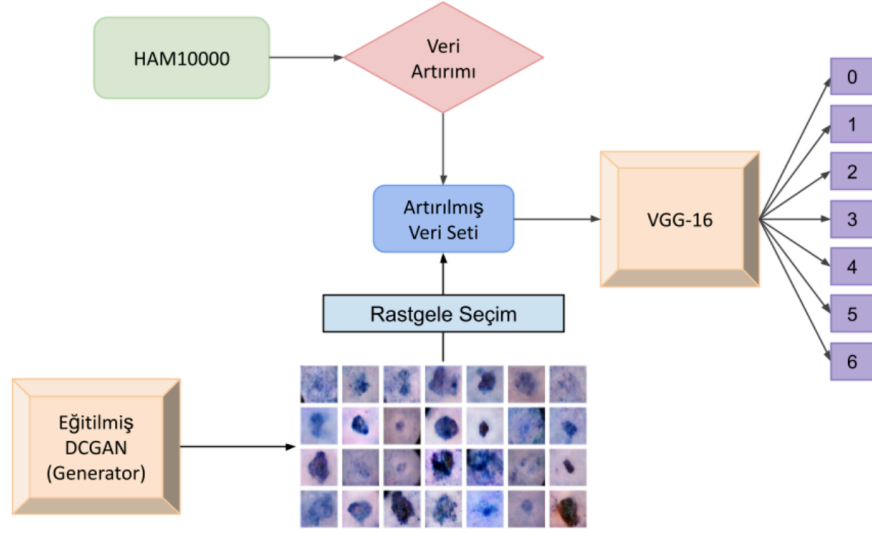
- **Deney 33** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, az sayıda örnek bulunduran sınıflara ait DCGAN ağları ile 2000 adet görüntü üretilmiştir. Bu aşamada DCGAN ağları, orijinal görüntülere rastgele dönüşüm uygulanarak eğitilmiştir.
- **Deney 34** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN yardımıyla az sayıda örnek bulunduran sınıf hariç diğer sınıflara 4000 adet görüntü üretilmiştir. Bu aşamada DCGAN ağları, orijinal görüntülere rastgele dönüşüm uygulanarak eğitilmiştir.

DCGAN eğitimi için kullanılan veri artırımın şeması Şekil 5.4'te verilmiştir.



Şekil 5.4. DCGAN eğitiminde veri artırımın uygulanması

Veri artırımının DCGAN ile gerçekleştirildiği deneylerdeki veri artırımı ve modelin eğitimi ise Şekil 5.5'teki gibidir.



Şekil 5.5. Veri artırımında DCGAN dan yararlanılan deneylerdeki veri artırım ve eğitim şeması

Veri artırımı için kullanılan DCGAN'ın eğitim stratejisi ve eğitim sonrası veri setine eklenen görüntü sayılarının cilt lezyonu sınıflandırmaya etkisinin incelendiği deneylere ait sonuçlar Tablo 5.5'te listelenmiştir.

Tablo 5.5. DCGAN stratejilerinin kullanıldığı deneylere ait sonuçlar

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
Deney 24	0,7339	0,714	0,7319	0,7196
Deney 25	0,7335	0,713	0,7329	0,7191
Deney 26	0,7661	0,741	0,7668	0,7478
Deney 27	0,7665	0,7327	0,7668	0,7455
Deney 28	0,7702	0,7661	0,7692	0,7667
Deney 29	0,7806	0,7708	0,7816	0,7741
Deney 30	0,7792	0,7729	0,7786	0,7734
Deney 31	0,7702	0,7584	0,7718	0,7616
Deney 32	0,7675	0,7534	0,7681	0,7554
Deney 33	0,756	0,7374	0,756	0,741
Deney 34	0,749	0,7358	0,748	0,7288

Deney sonuçlarına göre sınıflandırma performansı en iyi olan model doğruluk değeri olarak **%78,06** elde edilen 29. deneyde eğitilen modeldir. Bu modelde DCGAN ile görüntü başına 2 adet sentetik görüntü üretilirken, orijinal görüntülere de dönüşüm yöntemleri ile veri artırımı uygulanmıştır.

5.2.6 Oylama yöntemleri ile modellerin birleştirilmesi

Farklı yöntemler ve görüntüler ile eğitilen modellere ait özellik haritaları birbirinden farklılık gösterebilmektedir. Bu yüzden girdi olarak aynı görüntüyü alan modeller farklı olasılıklar ile farklı çıktılar üretebilmektedirler. Bu çalışmada da farklı stratejiler ile üretilmiş görüntüler üzerinde eğitilen modellerin çıktıları topluluk öğrenmesi kapsamında birleştirilmiştir. Bu aşamada birleştirilen modellerin seçiminde modellerin farklı stratejiler ile eğitilmesine ve modellerin iyi sonuç vermesine odaklanılmıştır. Modeller yumuşak oylama ve sert oylama olacak şekilde iki farklı oylama türü ile birleştirilmiştir. Bu deney grubunda deneyler 5 defa tekrarlanmış ve ortalama performans değerleri raporlanmıştır.

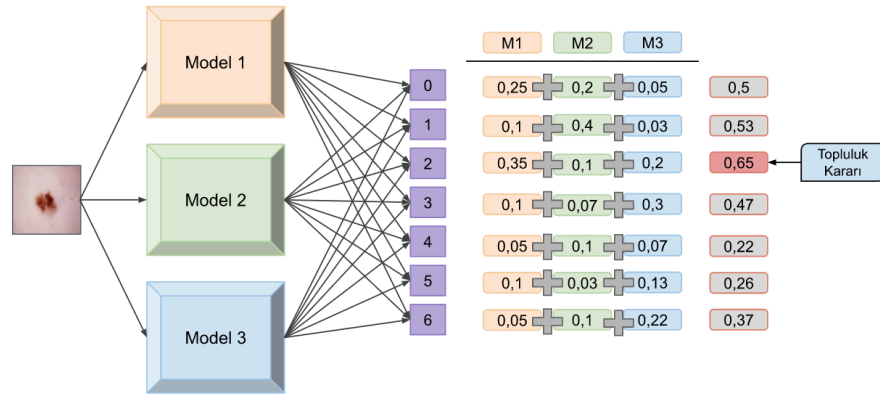
Model birleşiminde 64x64 ve 128x128 çözünürlüğündeki görüntüler olmak üzere modeller 2 farklı gruba ayrılmıştır. 64x64 çözünürlüklü görüntüler ile eğitilen modeller arasında en iyi sonuca ulaşmış 3 model seçilmiştir. Bu modeller;

- **Deney 3** : Veri artırımı için Kesme yöntemi kullanılmıştır. Sayı olarak daha az veriye sahip sınıflara ait her bir görüntüden 2 yeni görüntü üretilirken; daha fazla örneğe sahip sınıflara ait görüntülerden 1 yeni görüntü üretilmiştir.
- **Deney 14** : Veri artırımı için döndürme yöntemi kullanılmıştır. Tüm sınıflara veri artırımı uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.
- **Deney 29** : 64x64 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımında DCGAN ile sentetik görüntüler üretilmiştir. DCGAN, her sınıftan yaklaşık 3000 görüntü olacak şekilde sınıflardaki görüntüler artırılarak eğitilmiştir. Eğitilen DCGAN ile sınıflardaki görüntü başına 2 adet sentetik görüntü üretilmiştir. Ardından kesme yöntemi ile orijinal görüntülerden, görüntü az sayıda örnek barındıran sınıflara ait ise 2 değilse 1 yeni görüntü türetilmiştir.

128x128 çözünürlüklü görüntüler ile eğitilen modeller arasında seçilen üç model ise aşağıda belirtilmiştir;

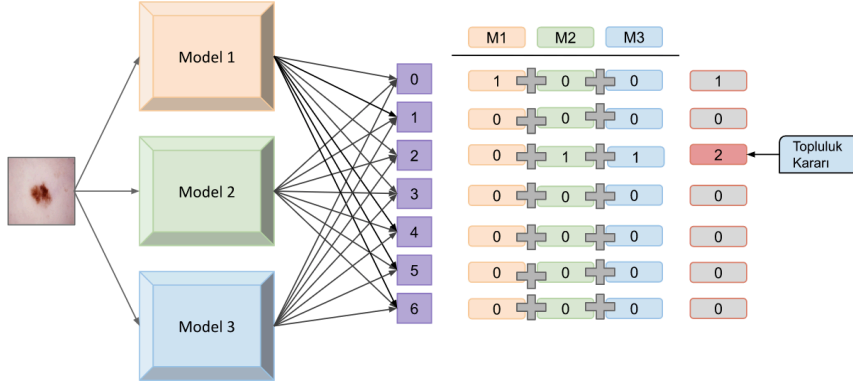
- **Deney 20** : 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımı için Döndürme ve Kesme yöntemleri kullanılmıştır. Kullanılacak yöntem rastgele seçilmiştir. Veri artırımı yalnızca örnek sayısı az olan sınıflara uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.
- **Deney 22** : 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımı için Döndürme yöntemi kullanılmıştır. Veri artırımı yalnızca örnek sayısı az olan sınıflara uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.
- **Deney 23** : 128x128 çözünürlüğündeki görüntüler kullanılmıştır. Veri artırımı için Döndürme ve Kesme yöntemleri aynı anda olacak şekilde yalnızca örnek sayısı az olan sınıflara uygulanmıştır. Her bir görüntüden 1 yeni görüntü türetilmiştir.

Topluluk öğrenmesi kapsamında kullanılan oylama yöntemlerinden yumuşak oylamaya ait şema Şekil 5.6'da gösterilmiştir.



Şekil 5.6. Yumuşak oylama ile topluluk modelinin oluşturulması

Sert oylama ile topluluk modelinin oluşturulması ise Şekil 5.7'de gösterilmiştir.



Şekil 5.7. Sert oylama ile topluluk modelinin oluşturulması

64x64 çözünürlüklü görüntüler ile eğitilen modeller arasında sınıflandırma performansı en iyi olan 3 tanesi seçilmiştir. Deney sonuçları Tablo 5.6'da listelenmiştir.

Tablo 5.6. Oylama yöntemleri ile birleştirilen modellerin sonuçları (64x64)

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
Deney 3	0,7698	0,7489	0,7702	0,7516
Deney 14	0,7628	0,7302	0,7641	0,7314
Deney 29	0,7806	0,7708	0,7816	0,7741
Yumuşak Oylama (Soft Voting)	0,7905	0,7733	0,7905	0,7786
Sert Oylama (Hard Voting)	0,7859	0,768	0,7859	0,7729

Modellerde birleşim yapılmadan önce en yüksek doğruluk değeri 29. Deneyde %78,06 olarak elde edilirken yumuşak oylama ile model sonuçları birleştirildiğinde doğruluk değeri %79,05'a yükselmiştir. Sert oylama ile modeller birleştirildiğinde doğruluk değeri %78,59 olarak elde edilmiştir.

128x128 çözünürlüklü görüntüler ile eğitilen modeller arasında yapılacak deneylerde sınıflandırma performansı iyi olan 3 deney seçilmiştir. Oylama yöntemleri ile birleştirilen modellerin oluşturduğu deney grubuna ait sonuçlar Tablo 5.7'de listelenmiştir.

Tablo 5.7. Oylama yöntemleri ile birleştirilen modellerin sonuçları (128x128)

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
Deney 20	0,7725	0,7768	0,7725	0,7720
Deney 22	0,7735	0,7551	0,7712	0,7611
Deney 23	0,7772	0,7495	0,7752	0,7585
Yumuşak Oylama (Soft Voting)	0,7885	0,7706	0,7886	0,7769
Sert Oylama (Hard Voting)	0,779	0,7704	0,7789	0,7692

Modellerde birleşim yapılmadan önce en yüksek doğruluk değeri 23. Deneyde %77,72 olarak elde edilirken yumuşak oylama ile model sonuçları birleştirildiğinde doğruluk değeri **%78,85**'a yükselmiştir. Sert oylama ile modeller birleştirildiğinde doğruluk değeri **%77,90** olarak elde edilmiştir.

6 SONUÇ VE ÖNERİ

Bu tez çalışmasında cilt lezyonlarının tespit edilebilmesi için derin öğrenme tabanlı çözümlerde kullanmak üzere sınıflandırma performansını geliştirmek için en uygun veri artırımı ve ön işleme tekniklerini seçmek amaçlanmıştır. Bu bağlamda veri artırımı için bazı dönüşüm yöntemleri ve sentetik görüntüler kullanılmıştır.

Deneylerin değerlendirilmesi kullanılan yöntemlerin benzerliklerine göre gruplandırılarak yapılmıştır. Deneylerin grupları ise şu şekildedir;

- Veri setinde görüntü artırımı olmadan yalnızca ön işlemenin etkisinin incelendiği deneyler
- Transform yöntemlerinden kesme ve döndürme yöntemleri ile geliştirilen stratejilerin kullanıldığı deneyler
- Farklı renk uzaylarının kullanıldığı deneyler
- Farklı görüntü çözünürlüklerinin kullanıldığı deneyler
- Farklı yaklaşımlar ile eğitilen DCGAN'ların kullanıldığı deneyler
- Sınıflandırma performansı en yüksek olan modellerin farklı oylama yaklaşımlarıyla birleştirilmesinden elde edilen topluluk modellerinin değerlendirildiği deneyler

Herhangi bir ön işleme uygulanmadan ve görüntülere standardizasyon uygulanarak yapılan deneylerde bir geliştirme yapılmadan doğruluk değerinin %67,44 olduğu, görüntülerde standardizasyon uygulandığında ise doğruluk değerinin %75,24 olduğu görülmektedir. Buna göre görüntülere standardizasyon uygulamak VGG-16 modeline ait doğruluk değerinin gelişmesini sağlamıştır.

Transform yöntemlerinden kesme ve döndürmenin kullanıldığı deneyler değerlendirildiğinde veri artırımında kesme ve döndürme teknikleri ile veri artırmanın cilt lezyonlarını sınıflandırmada başarıyı artırdığı gözlenmiştir. Kesme ve döndürme teknikleri arasında bir seçim yapılacak olursa kesme tekniğinin benzer artırım stratejilerinde döndürme tekniğine göre başarıyı daha iyi artırdığı gözlenmiştir. Veri artırım miktarları değerlendirilecek olursa örnek sayısı az olan sınıflara daha fazla veri artırımı uygulamanın başarıyı artırdığı gözlenmiştir.

Farklı renk uzaylarının kullanıldığı deneyler değerlendirildiğinde, her ne kadar farklı renk uzaylarında yapılan deneylerde sınıflandırma performansının iyileştirilebildiği bilinse de çalışma kapsamında gerçekleştirilen çalışmalarda RGB renk uzayı dışındaki renk uzaylarına dönüştürülen görüntüler cilt lezyonlarını sınıflandırma doğruluğunu olumsuz etkilemiştir.

Farklı çözünürlükte görüntülerin kullanıldığı deneylerde bazı veri artırım stratejilerinde düşük çözünürlüklü ve yüksek çözünürlüklü görüntülerden kaynaklanan sınıflandırma başarısı arasındaki fark az olsa da genel olarak daha yüksek çözünürlüklü görüntülerin kullanılması cilt lezyonu sınıflandırmayı olumlu yönde etkilemiştir.

Farklı stratejiler ile eğitilmiş DCGAN'lar yardımıyla türetilen görüntülerin sınıflandırma performansları incelendiğinde DCGAN eğitiminde de veri artırım stratejileri ile veri setinin büyütülmesi üretilen görüntülerin daha gerçekçi olmasını sağlamış ve sınıflandırma performansını oldukça iyi yönde etkilemiştir. DCGAN ile veri setine sağlanan görüntülerin orijinal veri sayısının çok fazla artırılması cilt lezyonların sınıflandırılmasını olumsuz yönde etkilemiştir. Bunun yanında veri setine orijinal verilerden daha fazla miktarda sentetik veri eklemenin ve orijinal görüntülere de transform yöntemleri ile veri artırımı uygulamak sınıflandırma performansını oldukça iyileştirmiştir. Öyle ki bu yöntem deneyler içerisinde başarısı en yüksek yöntem olmuştur.

Cilt lezyonunun sınıflandırılmasında uygun topluluk modelinin belirlenebilmesi için yapılan deneylerde 64x64 çözünürlüklü görüntüler ile eğitilen modeller içinde üç model seçilmiştir. Bu modeller; kesme yöntemi ile veri artırımının gerçekleştirildiği 3. Deney, döndürme yöntemi ile veri artırımının gerçekleştirildiği 14. deney ve DCGAN ile üretilen görüntüler ile veri artırımının uygulandığı 29. deneylerdir. Hem yumuşak oylama hem de sert oylama yöntemi ile sonuçların birleştirilmesiyle sınıflandırma başarısının bir miktar daha artırılabilirdiği gözlenmiştir. Ancak yumuşak oylama yöntemi ile sınıflandırma performansı daha fazla iyileştirilmiştir.

128x128 çözünürlüklü görüntüler ile eğitilen modellerden üç tanesi seçilmiştir. Bu modeller; veri artırımı için dönüşüm yönteminin rastgele seçildiği

20. Deney, veri artırımında döndürme yönteminin kullanıldığı 22. Deney, veri artırma için döndürme ve kesme yönteminin aynı anda uygulandığı 23. deneylerdir. Modellerin sert oylama yöntemi ile birleştirilmesi sınıflandırma performansını az da olsa iyileştirmiştir. Ancak yumuşak oylama yöntemi ile modelleri birleştirmenin sınıflandırmayı daha fazla iyileştirdiği gözlenmiştir.

Literatürdeki diğer çalışmalar ile tez çalışmasındaki sonuçlar karşılaştırıldığında bazı çalışmalarda doğruluk değerinin yüksek olmasının nedeni; daha gelişmiş modellerin kullanılması, sınıflandırmada daha az sınıfta deneylerin gerçekleştirilmesi ve yüksek çözünürlüklü görüntülerin kullanılmasıdır.

Yapılan geliştirmeler ışığında daha gelişmiş derin öğrenme modelleri ve gelişmiş cihazlar ile cilt lezyonları daha doğru bir şekilde sınıflandırılabilir. Bu doğrultuda geliştirilecek bilgisayar destekli cilt lezyonu tespit sistemlerinin cilt lezyonlarının ön teşhisinde doktorlara yardımcı olabileceği düşünülmektedir.

KAYNAKLAR DİZİNİ

- Abuared, N., Panthakkan, A., Al-Saad, M., Amin, S. A., & Mansoor, W.,** 2020, Skin Cancer Classification Model Based on VGG 19 and Transfer Learning. *2020 3rd International Conference on Signal Processing and Information Security, ICSPIS 2020*. <https://doi.org/10.1109/ICSPIS51252.2020.9340143>
- Akgül, A.,** “Yara ve Deri Biyopsileri”. <https://www.ahmetakgul.com.tr/index.php/uzmanliklar/yara-bakimi/2155-yara-ve-deri-biyopsileri> (Erişim Tarihi : 1 Eylül 2022)
- Alam, M., & Ratner, D.,** 2001, Cutaneous Squamous-Cell Carcinoma. *The New England Journal of Medicine*, 344(13), 975–983. <https://doi.org/10.1056/NEJM200103293441306>
- Ali, M. S., Miah, M. S., Haque, J., Rahman, M. M., & Islam, M. K.,** 2021., An enhanced technique of skin cancer classification using deep convolutional neural network with transfer learning models. *Machine Learning with Applications*, 5, 100036. <https://doi.org/10.1016/J.MLWA.2021.100036>
- Ameri, A.,** 2020, A Deep Learning Approach to Skin Cancer Detection in Dermoscopy Images. *Journal of Biomedical Physics & Engineering*, 10(6), 801. <https://doi.org/10.31661/JBPE.V0I0.2004-1107>
- American Cancer Society.,** 2022a, “Skin Cancer Research Highlights | Skin Cancer New”, <http://web.archive.org/web/20220517010505/cancer.org/research/acs-research-highlights/skin-cancer-research-highlights.html>
- American Cancer Society.,** 2022b, “Treatment of Melanoma”. <https://web.archive.org/web/20220407114836/https://www.cancer.org/cancer/melanoma-skin-cancer/treating/by-stage.html> (Erişim Tarihi : 7 Haziran 2022)
- Azman, E.,** “Punch Biopsi”. <https://www.esraazman.com/TR/Uygulamalar/punch-biopsi> (Erişim Tarihi : 1 Eylül 2022)
- Buzoğlu, H.,** “Deri Biyopsileri”, <https://www.hakanbuzoglu.com/deri-biyopsileri> (Erişim Tarihi : 3 Eylül 2022)

KAYNAKLAR DİZİNİ (devam)

- Cakmak, M., & Tenekeci, M. E.**, 2021., Melanoma detection from dermoscopy images using Nasnet Mobile with transfer learning. *SIU 2021 - 29th IEEE Conference on Signal Processing and Communications Applications, Proceedings*. <https://doi.org/10.1109/SIU53274.2021.9477985>
- Chaturvedi, S. S., Gupta, K., & Prasad, P. S.**, 2021, Skin lesion analyser: an efficient seven-way multi-class skin cancer classification using mobilenet. *Advances in Intelligent Systems and Computing*, 1141, 165–176. https://doi.org/10.1007/978-981-15-3383-9_15/COVER/
- Dildar, M., Akram, S., Irfan, M., Khan, H. U., Ramzan, M., Mahmood, A. R., Alsaiari, S. A., Saeed, A. H. M., Alraddadi, M. O., & Mahnashi, M. H.**, 2021, Skin Cancer Detection: A Review Using Deep Learning Techniques. *International Journal of Environmental Research and Public Health*, 18(10), 5479. <https://doi.org/10.3390/IJERPH18105479>
- Diwan, T., Shukla, R., Ghuse, E., & Tembhurne, J. v.**, 2022, Model hybridization & learning rate annealing for skin cancer detection. *Multimedia Tools and Applications*, 1–24. <https://doi.org/10.1007/S11042-022-12633-5/TABLES/6>
- Doğan, F., & Türkoğlu, İ.**, 2019, Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*, 10(2), 409–445. <https://doi.org/10.24012/dumf.411130>
- el Naqa, I., & Murphy, M. J.**, 2015, What Is Machine Learning? *Machine Learning in Radiation Oncology*, 3–11. https://doi.org/10.1007/978-3-319-18305-3_1
- Esbah, O., Ekinci, A. Ş., & Aktas, H.**, 2016, Tipik dermatoskopik bulguları olan Akral lentiginöz malign melanom vakası. *ACTA ONCOLOGICA TURCICA*, 49(1), 61–63. <http://search/yayin/detay/216891>
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T.**, 2018, Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377. <https://doi.org/10.1016/J.PATCOG.2017.10.013>

KAYNAKLAR DİZİNİ (devam)

- Hao, X., Zhang, G., & Ma, S.,** 2016, Deep Learning. *International Journal of Semantic Computing*, 10(3), 417–439. <https://doi.org/10.1142/S1793351X16500045>
- İnik, Ö., & Ülker, E.,** 2017, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Journal of Scientific Research*, 6(3), 85–104. <http://dergipark.gov.tr/gbad>
- IBM., a,** “*What is Supervised Learning?*”, <https://web.archive.org/web/20220606173931/https://www.ibm.com/cloud/learn/supervised-learning> (Erişim Tarihi : 8 Haziran 2022)
- IBM., b,** “*What is Unsupervised Learning?*” <https://web.archive.org/web/20211103201423/https://www.ibm.com/cloud/learn/unsupervised-learning> (Erişim Tarihi : 10 Haziran 2022)
- Islam, M. K., Ali, M. S., Ali, M. M., Haque, M. F., Das, A. A., Hossain, M. M., Duranta, D. S., & Rahman, M. A.,** 2021, Melanoma Skin Lesions Classification using Deep Convolutional Neural Network with Transfer Learning. *2021 1st International Conference on Artificial Intelligence and Data Analytics, CAIDA 2021*, 48–53. <https://doi.org/10.1109/CAIDA51941.2021.9425117>
- Jain, S., Singhania, U., Tripathy, B., Nasr, E. A., Aboudaif, M. K., & Kamrani, A. K.,** 2021, Deep Learning-Based Transfer Learning for Classification of Skin Cancer. *Sensors 2021, Vol. 21, Page 8142, 21(23)*, 8142. <https://doi.org/10.3390/S21238142>
- Kargupta, H., Han, J., Philip, S., Motwani, R., & Kumar, V.,** 2008, *Next generation of data mining*.
- Kassem, M. A., Hosny, K. M., Damaševičius, R., & Eltoukhy, M. M.,** 2021, Machine Learning and Deep Learning Methods for Skin Lesion Classification and Diagnosis: A Systematic Review. *Diagnostics*, 11(8), 1390. <https://doi.org/10.3390/DIAGNOSTICS11081390>

KAYNAKLAR DİZİNİ (devam)

- Khan, M. A., Akram, T., Zhang, Y. D., & Sharif, M.,** 2021, Attributes based skin lesion detection and recognition: A mask RCNN and transfer learning-based deep learning framework. *Pattern Recognition Letters*, 143, 58–66. <https://doi.org/10.1016/J.PATREC.2020.12.015>
- Khan, M. D. R. H., Uddin, A. H., Nahid, A. al, & Bairagi, A. K.,** 2022, Skin Cancer Detection from Low-Resolution Images Using Transfer Learning. *Lecture Notes in Networks and Systems*, 213, 317–334. https://doi.org/10.1007/978-981-16-2422-3_26/COVER/
- Kondaveeti, H. K., & Edupuganti, P.,** 2020, Skin Cancer Classification using Transfer Learning. *Proceedings of IEEE International Conference on Advent Trends in Multidisciplinary Research and Innovation, ICATMRI 2020*. <https://doi.org/10.1109/ICATMRI51801.2020.9398388>
- Le, D. N. T., Le, H. X., Ngo, L. T., & Ngo, H. T.,** 2020, Transfer learning with class-weighted and focal loss function for automatic skin cancer classification, *arXiv*, <https://doi.org/10.48550/arxiv.2009.05977>
- Lecun, Y., Bengio, Y., & Hinton, G.,** 2015, Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Linares, M. A., Zakaria, A., & Nizran, P.,** 2015, Skin Cancer. *Primary Care*, 42(4), 645–659. <https://doi.org/10.1016/J.POP.2015.07.006>
- Liu, B.,** 2011, Supervised Learning. In *Web Data Mining* (pp. 63–132). Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-19460-3_3
- Mayo Clinic.** *Basal cell carcinoma - Diagnosis and treatment - Mayo Clinic*. <https://web.archive.org/web/20220402043829/> <https://www.mayoclinic.org/diseases-conditions/basal-cell-carcinoma/diagnosis-treatment/drc-20354193> (Erişim Tarihi : 5 Haziran 2022)
- Miglani, V., & Bhatia, M.,** 2021, Skin lesion classification: a transfer learning approach using efficientnets. *Advances in Intelligent Systems and Computing*, 1141, 315–324. https://doi.org/10.1007/978-981-15-3383-9_29/COVER/

KAYNAKLAR DİZİNİ (devam)

- Moldovan, D.**, 2019, Transfer learning based method for two-step skin cancer images classification. *2019 7th E-Health and Bioengineering Conference, EHB 2019*. <https://doi.org/10.1109/EHB47216.2019.8970067>
- National Cancer Institute.**, 2019, *PDQ Melanoma Treatment*. National Cancer Institute; National Cancer Institute (US). <https://www.cancer.gov/types/skin/patient/melanoma-treatment-pdq>
- Öztekin, C.** “*Deri Kanseri Tedavisi*”, <https://web.archive.org/web/20210922145204/https://canoztekin.com/uzmanliklar/deri-kanseri-tedavisi-ankara/> (Erişim Tarihi: 3 Eylül 2022)
- Piryonesi, S. M., & El-Diraby, T. E.**, 2020, Role of Data Analytics in Infrastructure Asset Management: Overcoming Data Size and Quality Problems. *Journal of Transportation Engineering, Part B: Pavements*, 146(2). <https://doi.org/10.1061/JPEODX.0000175>
- Radford, A., Metz, L., & Chintala, S.**, 2016, May 2, Unsupervised Representation Learning With Deep Convolutional Generative Adversarial Networks. *4th International Conference on Learning Representations*.
- Rahman, Z., & Ami, A. M.**, 2020, A transfer learning based approach for skin lesion classification from imbalanced data. *Proceedings of 2020 11th International Conference on Electrical and Computer Engineering, ICECE 2020*, 65–68. <https://doi.org/10.1109/ICECE51571.2020.9393155>
- Ray, S.**, 2019, A Quick Review of Machine Learning Algorithms. *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing*, 35–39. <https://doi.org/10.1109/COMITCON.2019.8862451>
- Reis, H. C., Turk, V., Khoshelham, K., & Kaya, S.**, 2022, InSiNet: a deep convolutional approach to skin cancer detection and segmentation. *Medical and Biological Engineering and Computing*, 60(3), 643–662. <https://doi.org/10.1007/S11517-021-02473-0/FIGURES/18>
- Saliha, K.** “*Deri Biyopsisi*”. <https://www.salihakirbas.com.tr/tedaviler/dermatoloji/deri-biyopsisi> (Erişim Tarihi : 13 Eylül 2022)

KAYNAKLAR DİZİNİ (devam)

- Sarikaya, B., & Ugur, A.,** 2022, Farklı Veri Artırım Teknikleri ile Derin Öğrenme Tabanlı Cilt Lezyonu Tespiti. *II. Uluslararası Yapay Zeka Konferansı*, 54–58. <https://ykb.ikcu.edu.tr/Share/8498D4CA8B5DCF5FA7F630481D13F4EE>
- Shete, A. S., Sanjay Rane, A., Gaikwad, P. S., & Patil, M. H.,** 2021, Detection of skin cancer using CNN algorithm. *INTERNATIONAL JOURNAL OF ADVANCE SCIENTIFIC RESEARCH AND ENGINEERING TRENDS*, 6(5). <https://doi.org/10.51319/2456-0774.2021.5.0051>
- Singh, P., Kumar, M., & Bhatia, A.,** 2022, A Comparative Analysis of Deep Learning Algorithms for Skin Cancer Detection. *Proceedings of the Sixth International Conference on Intelligent Computing and Control Systems (ICICCS 2022)*, 1160–1166. <https://doi.org/10.1109/ICICCS53718.2022.9788197>
- Kaggle.,** 2018, “*Skin Cancer MNIST: HAM10000 | Kaggle*”, <http://web.archive.org/web/20220507101104/https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000> (Erişim Tarihi : 29 Nisan 2022)
- Skin Cancer Foundation.,** “*Skin Cancer Prevention*”, <https://www.skincancer.org/skin-cancer-prevention/> (Erişim Tarihi : 7 Haziran 2022)
- Snow, S. N., Sahl, W., Lo, J. S., Mohs, F. E., Warner, T., Dekkinga, J. A., Arid, Y., & Feyzi, J.,** 1994, Metastatic Basal Cell Carcinoma Report of Five Cases. *Cancer*, 73(2), 328–335. [https://doi.org/10.1002/1097-0142\(19940115\)73:2](https://doi.org/10.1002/1097-0142(19940115)73:2)
- Tolstikhin, I., Bousquet, O., Schölkopf, B., Thierbach, K., Bazin, P. L., de Back, W., Gavriilidis, F., Kirilina, E., Jäger, C., Morawski, M., Geyer, S., Weiskopf, N., Scherf, N., Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... Doersch, C.,** 2014, Generative Adversarial Networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11046 LNCS(NeurIPS), 1–9. <https://doi.org/10.48550/arxiv.1406.2661>

KAYNAKLAR DİZİNİ (devam)

- Türk Dermatoloji Derneği a.**, “*Eksizyonel Biyopsi*”, <https://turkdermatoloji.org.tr/icerik/detay/88> (Erişim Tarihi : 7 Haziran 2022)
- Türk Dermatoloji Derneği b.**, “*Punch Biyopsi*”, <https://turkdermatoloji.org.tr/icerik/detay/96> (Erişim Tarihi : 7 Haziran 2022)
- Oracle.**, “*What is Machine Learning?*” <https://web.archive.org/web/20211023235445/https://www.oracle.com/data-science/machinelearning/what-is-machine-learning/> (Erişim Tarihi : 8 Haziran 2022)
- Yesiloglu, N., a.**, “*Deri Kanseri Öncüsü Lezyonlar*”, <https://web.archive.org/web/20210622145255/https://www.derikanseri.org/lezyon-deri-kanseri> (Erişim Tarihi : 21 Nisan 2022)
- Yesiloglu, N., b.**, “*Bazal Hücreli Karsinom*”, <https://www.derikanseri.org/bazal-hucreli-karsinom> (Erişim Tarihi : 21 Nisan 2022)
- Yesiloglu, N., c.**, “*Melanom (Malign Melanom)*”, Retrieved, from <https://www.derikanseri.org/melanom> (Erişim Tarihi : 22 Nisan 2022)
- Younis, H., Bhatti, M. H., & Azeem, M.**, 2019, Classification of skin cancer dermoscopy images using transfer learning. *15th International Conference on Emerging Technologies, ICET 2019*. <https://doi.org/10.1109/ICET48972.2019.8994508>
- Yu, W., Yang, K., Bai, Y., Xiao, T., Yao, H., & Rui, Y.**, 2016, Visualizing and Comparing AlexNet and VGG using Deconvolutional Layers, *Proceedings of the 33 Rd International Conference on Machine Learning*. <http://www.robots.ox.ac.uk/>
- Zhang, L., Wang, S., & Liu, B.**, 2018, Deep Learning for Sentiment Analysis : A Survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4). <https://doi.org/10.48550/arxiv.1801.07883>

TEŐEKKÜR

Bu alıőma boyunca deęerli grüşlerini, bilgisini ve yardımlarını hiçbir zaman esirgemeyen, önerileri ile ve yönlendirmeleri ile gelişmemi saęlayan saygı deęer hocam Prof. Dr. Aybars UęUR'a iten teőekkürlerimi sunarım.

Tüm eęitim öęretim hayatım süresince her zaman yanımda olan ve bana destek veren; tez alıőma sürecimde de gösterdikleri fedakarlıklardan dolayı tüm aileme teőekkür ederim.

06 / 09 / 2022

Behlül SARIKAYA

ÖZGEÇMİŞ

Soyadı : SARIKAYA

Adı : Behlül

Eğitim Bilgileri

Yüksek Lisans : Ege Üniversitesi, Bilgisayar Mühendisliği
Anabilim Dalı 2020 - Devam ediyor

Lisans : Pamukkale Üniversitesi, Bilgisayar
Mühendisliği Bölümü 2015-2019

İş Deneyimi

Stajyer : Denizli Büyükşehir Belediyesi, Bilgi İşlem
Daire Başkanlığı 2017-2017

Stajyer : Kodpit Teknoloji A.Ş. 2018-2019

Full-Stack Geliştirici : Kodpit Teknoloji A.Ş. 2019-2021

Araştırma Görevlisi : Pamukkale Üniversitesi, Bilgisayar
Mühendisliği Bölümü 2021 – Devam
Ediyor