

T.C.

EGE ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

**DERİN ÖĞRENME YÖNTEMLERİ İLE GÖRÜNTÜ
ÜZERİNDE DİYABETİK AYAK ÜLSERİNİN TESPİT
EDİLMESİ**

Mehmet Cihat AKYOL

Danışman: Doç. Dr. Evren Homan GÖKÇE

Biyomedikal Teknolojiler Anabilim Dalı

Biyomedikal Teknolojiler Tezli Yüksek Lisans Programı

İZMİR 2021

EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ETİK KURALLARA UYGUNLUK BEYANI

Ege Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “Derin Öğrenme Yöntemleri İle Görüntü Üzerinde Diyabetik Ayak Ülserinin Tespit Edilmesi” 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 planlamasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davranıldığını ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

02/03/2021

İmzası

Mehmet Cihat AKYOL

ÖZET

DERİN ÖĞRENME YÖNTEMLERİ İLE GÖRÜNTÜ ÜZERİNDE DİYABETİK AYAK ÜLSERİNİN TESPİT EDİLMESİ

AKYOL, Mehmet Cihat

Yüksek Lisans Tezi, Biyomedikal Teknolojiler Anabilim Dalı

Tez Danışmanı: Doç. Dr. Evren Homan GÖKÇE

2021, 84 sayfa

Bu çalışma kapsamında derin öğrenme yöntemleri ile görüntü üzerinde diyabetik ayak ülserlerinin tespiti çalışılmıştır.

Evrişimsel sinir ağları nesne tespiti ile ilgili yarışmalarda başarısını kanıtlamıştır. Bu sebeple bu çalışmada da uygun bir yaklaşım olduğu düşünülmüştür ve başarı ile uygulanmıştır. Tasarlanan modelde Faster RCNN ile birlikte ResNet50 ve MobileNetV2 mimarileri kullanılmıştır. DFUC2020 yarışmasında kullanılan 2000 diyabetik ayak ülser görüntüsü ve uzmanlar tarafından işaretlenmiş referansları içeren veri seti edinilmiştir. Tasarlanan modeller Google Colab servisi kullanılarak eğitilmiştir ve hesaplanan ağırlıklar dondurularak depolanmıştır. Eğitilen modeller tahmin hızı, diskteki boyutu ve mAP skorları ile karşılaştırılmıştır.

ResNet50 ile tasarlanan Faster RCNN modeli ile 43 mAP skoru ile 34 mAP skoru elde edilen MobileNetV2 ile tasarlanan Faster RCNN modeline göre daha başarılı sonuçlar elde edilmiştir. Dondurulmuş ağırlıklarının ResNet50 ve MobileNetV2 ile tasarlanan Faster RCNN modellerinin diskteki boyutları sırasıyla 158 ve 120 MB olduğu gözlemlenmiştir ve yine sırasıyla bir görüntü için tahmin süreleri sırasıyla 24 ms ve 10 ms olarak ölçülmüştür.

Anahtar sözcükler: Derin öğrenme, nesne tanıma, tıbbi görüntü işleme, diyabetik ayak ülseri, Faster RCNN, ResNet, MobileNet



ABSTRACT**LOCATION OF DIABETIC FOOT ULCER ON THE IMAGES BY
DEEP LEARNING**

AKYOL, Mehmet Cihat

MSc in Department of Biomedical Technologies

Supervisor: Assoc. Dr. Evren Homan GÖKÇE

2021, 84 pages

Within the scope of this study, the detection and localization of diabetic foot ulcers on the image was studied with deep learning methods.

Convolutional neural networks have proven success in many object detection and localization related competitions. For this reason, it was thought to be an appropriate approach for this study, and it was applied successfully. In this scope, two Faster RCNN method proposed with the MobileNetV2 and ResNet50 backbone. Data set including 2000 diabetic foot ulcer images and references marked by experts has been gotten. The proposed models have been trained with Google Colab service and calculated weight are frozen and stored. The models are compared by mAP scores, estimation time and model size.

With the ResNet50 backbone Faster RCNN model we acquired 43 mAP score and with the other model that proposed with MobileNetV2 Faster RCNN acquired 34 mAP. As expected with the Faster RCNN with ResNet 50 backbone model has gotten better results. The size of proposed models on disk have observed for Faster RCNN ResNet50 158 MB and for Faster RCNN MobileNetV2 120MB. The estimation time for one image has been observed 24 ms for Faster RCNN with ResNet50 models and 10 ms for MobileNetV2 models.

Keywords: Deep learning, object detection, object localization, medical image processing, diabetic foot ulcer, Faster RCNN, ResNet, MobileNet



ÖNSÖZ

Bu çalışma kapsamında görüntü üzerinde diyabetik yara ülserinin yerini tespit etmek için Faster RCNN ResNet50 ve Faster RCNN MobilenetV2 mimarileri kullanılmıştır.

Çalışma boyunca hesaplamaları yapmak için yerel ve uzak bilgisayarlar kullanılmıştır. Hesaplama maliyetlerinin bilgisayar sınırlarını zorladığı görülmüş ve bu problemlere çözümler geliştiren araştırmacılar açık kaynaklı olarak toplumla paylaştığı gözlemlenmiştir. Ayrıca makine öğrenmesinin uygulanabilir alanlarında problem çözümü için araştırmacıların birlikte çalışması desteklendiği ve etik kurallarca bilgi paylaşımı yapıldığı, bu cömert yaklaşımın gelenek olarak benimsendiği görülmüştür. Problem çözümü haricinde benzer konularda eğitimlerini, kitaplarını tüm dünya ile paylaşan Andrew Ng, Ian Goodfellow ve adını saymadığım birçok araştırmacıların bu alanda muazzam katkıları fark edilmiştir.

Çalışma boyunca çalışılan problemlerin, gerçek dünya problemleri olduğu ve DFUC yarışması ile çözülmeye dünyanın çeşitli ülkelerinde katılımcılar ile yöntemler geliştirilerek çözülmeye çalışılmaktadır. Bu araştırma yarışmasına gayri resmi de olsa katılmış olmak çalışma için gurur verici bir çıktı olmuştur. Bununla birlikte çalışma sürem boyunca diyabetik ayak ülser yara yönetimi ile ilgili ürünlerin hızla sağlık sektörüne girdiği fark edilmiş ve bu ilerlemeler ürün geliştirilmesi için araştırmacılar için umut verici olduğu düşünülmektedir.

Bu çalışmaya yön veren ve benim bu alanda çalışmamı destekleyen hocalarıma teşekkürlerimi sunarım.

İzmir

02/03/2021

Mehmet Cihat AKYOL



İÇİNDEKİLERSayfa

İÇ KAPAK	ii
ETİK KURALLARA UYGUNLUK BEYANI	vi
ÖZET.....	viii
ABSTRACT	x
ÖNSÖZ	xii
İÇİNDEKİLER	xiv
ŞEKİLLER DİZİNİ.....	xvii
ÇİZELGELER DİZİNİ	xx
SİMGELER VE KISALTMALAR DİZİNİ	xxi
1. GİRİŞ	1
2. GENEL BİLGİLER	4
2.1. Yara Değerlendirmesi	4
2.2. Dijital Ortamda Görüntü	7

İÇİNDEKİLER (devam)

2.3. Derin Öğrenmenin Temelleri	10
2.3.1. Gradyan Öğrenme	12
2.3.2. Aktivasyon fonksiyonu.....	14
2.3.3. Düzenlileştirme.....	18
2.3.4. İleri Beslemeli Yapay Sinir Ağları	19
2.3.5. Geri Yayılım	19
2.3.6. Evrişimli Sinir Ağları (CNN)	20
2.3.7. Öğrenme Transferi.....	28
2.3.8. Değerlendirme Yöntemleri.....	29
3. GEREÇ VE YÖNTEM	32
3.1. Kullanılan Veri Seti	32
3.2. Kullanılan Yazılım ve Donanım Altyapıları.....	33
3.3. Ağ Parametreleri, Eğitim ve Eğitim Sonuçları	34
4. SONUÇLAR VE TARTIŞMA	46
KAYNAKLAR DİZİNİ	49
TEŞEKKÜR.....	58

ÖZGEÇMİŞ59

EKLER.....60



ŞEKİLLER DİZİNİ

Şekil

Sayfa

1.1 “Deep learning” ve “medical” anahtar kelimelerinin “Google Scholar” arama sonuçlarında elde edilen çalışma sayılarının yıllara göre dağılımı	2
2.1 Model yara üzerinde cetvel ile yara ölçümü (Shah ve ark., 2013)	6
2.2 El ile kopya yöntemi ile yara ölçümü uygulaması (Nichols, 2015).....	6
2.3 Siyah beyaz bir görüntü ve dijital ortamdaki temsili	8
2.4 Gözdeki reseptörlerin duyarlı olduğu ışıık dalga boyları.....	9
2.5 Görünür bölgeleri gösteren spektrum	10
2.6 Yapay nöron ve bileşenleri	11
2.7 Basitleştirilmiş bir yapay sinir ağının katmanları	11
2.8 İç bükey grafiklerin sağdan ve soldan türevleri.....	12
2.9 h hipotezinin doğrusal veri setine yakınsaması ve tek boyutlu bir kayıp fonksiyonu üzerinde gradyan iniş algoritmasının adımları.....	13
2.10 $f(x)$ aktivasyon fonksiyonlu bir yapay nöron.....	14
2.11 Doğrusal olmayan aktivasyon fonksiyonlarının arka arkaya sıralanması	15
2.12 Sigmoid aktivasyon fonksiyonu.....	15
2.13 ReLu aktivasyon fonksiyonu (kesikli çizgiler)	16

ŞEKİLLER DİZİNİ (devam)

2.14 İki farklı yapay sinir ağı ve el yazısı ile 0 rakamının sınıflandırma sonuçları (Softmax aktivasyon fonksiyonu kullanılmadan)	17
2.15 İki farklı yapay sinir ağı ve el yazısı ile 0 rakamının sınıflandırma sonuçları (Son katmanda softmax aktivasyon fonksiyonu ile)	18
2.16 Yetersiz uyum (sol), tam uyum (orta) ve aşırı uyum (sağ) grafikleri ..	18
2.17 İleri beslemeli bir yapay sinir ağı.....	19
2.18 Temsili bir sinir ağında geri yayılım.....	20
2.19 Izgara topolojisinde evrişim operasyonu	21
2.20 Evrişimsel sinir ağı katmanları	22
2.21 Maksimum havuzlama (max pool veya argmax) operasyonu	22
2.22 ResNet mimarisinde derin mimarilerde öğrenme probleminin çözümü için kullanılan blok.....	24
2.23 Standart ve derinlemesine ayriabilir evrisimsel bloklar	26
2.24 Bölgesel evrişimsel sinir ağları	28
2.25 Kesişimlerin birleşime oranı	30
2.26 Keskinlik ve hatırlama değerinde maksimum interpolasyon.....	30
3.1 DFUC 2020 veri setinden rastgele görüntüler	33
3.2 Girdi görüntülerinde çeşitlilik artırıldıktan sonraki görüntüler	35

ŞEKİLLER DİZİNİ (devam)

3.3 Faster RCNN ResNet50 model kayıp grafiği	36
3.4 Faster RCNN ResNet modeli mAP skor grafiği	36
3.5 Faster RCNN MobileNetV2 model kayıp grafiği.....	40
3.6 Faster RCNN MobileNetV2 model mAP skor grafiği.....	41



ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
2.1 Farklı derinlikteki ResNet mimarisi tasarım blokları	23
2.2 MobilNetV2 mimarisi tasarım blokları.....	26
3.1 Teklif edilen yapay sinir ağı eğitim parametreleri	34
3.2 Eğitim sonucu teklif edilen modellerin başarı metrikleri	35
3.3 Faster RCNN ResNet50 mimarili modelin başarılı tahmin sonuçları ...	37
3.4 Faster RCNN ResNet mimarili modelin başarısız tahmin sonuçları	39
3.5 Faster RCNN MobileNetV2 mimarili modelin doğru tahmin sonuçları	42
3.6 Faster RCNN MobileNetV2 mimarili modelin yanlış tahmin sonuçları	44
4.1 DFUC 2020 yarışmasında teklif edilen diğer mimarilerin mAP skorları ve bu çalışma kapsamında elde edilen mAP skoru	47

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar


ILSVRC	ImageNet Large Scale Visual Recognition Competition
MRI	Magnetic Resonance Imaging
CT	Computed Tomography
ISIC2019	International Skin Imaging Collaboration
SLIC	Simple Linear Iterative Clustering
DFUC	Diabetic Foot Ulcer Challenge
M COCO	Microsoft Common Objects in Context
SI	International System of Units
SGD	Stochastic Gradient Descent
ReLu	Rectified Linear Unit
CNN	Convolutional Neural Network
ResNet	Residual Neural Network
RCNN	Regional Neural Network
mAP	Mean of Average Precision
TP	True Positive
FP	False Positive
FN	False Negative
IoU	Intersection Over Union
GPU	Graphical Processing Unit

1. GİRİŞ

Diyabet yaklaşık 425 milyon insanı etkileyen global bir epidemidir. Bu yayılma hızına göre 2045'te 629 milyon insanı etkileyeceği beklenmektedir (Cho ve ark., 2018). Diyabet, diyabetik ayak ülserlerine bunlarda enfeksiyon, alt ekstremitte organlarının amputasyonu ve ölümle sonuçlanabilmektedir. Gerekli yara bakımları ve değerlendirmelerin yapılması bu senaryolar engellenebilmektedir (Aalaa ve ark., 2012; Shahbazian ve ark., 2013). Çoğunlukla yaraların kendiliğinden iyileşebilme yetenekleri vardır. Ancak diabetes mellitus sonucu oluşan diyabetik ayak ülseri gibi komplikasyonlarda yara, kendiliğinden iyileşme davranışı bozulabilmektedir (McLennan ve ark., 2006). Bu durumda uygulanan tedavi hasta durumuna özel olarak planlanmalıdır (Yazdanpanah, 2015).

Yara değerlendirmesinde tedaviyi sistematik hale getirmek için farklı yöntemler geliştirilmiştir. Bu yöntemlerde belirli parametreler izlenerek yara hakkında değerlendirme yapılması hedeflenmektedir. Bu parametreler genel olarak; yaranın büyüklüğü, kenarları, vücut üzerindeki konumu, yara yatağı, derinliği, yaranın etrafındaki derinin durumu, enfeksiyon olup olmaması ve ağrı parametreleridir (Young, 2019).

Görüntü işleme tabanlı yara değerlendirme yöntemleri, geleneksel görüntü işleme algoritmaları ve derin öğrenme yöntemleri kullanılarak yapılabilir. Derin öğrenme alanında yapılan son çalışmalardan nesne tanıma, sınıflandırma gibi görüntüleri sanal ortamda anlaşılmasını sağlayacak yöntemler üzerine oldukça başarılı sonuçlar alınmaktadır (Lecun ve ark., 2015). Oldukça popüler bir bilgisayar görüşü yarışması olan "ImageNet Large Scale Visual Recognition Competition" veya daha yaygın adıyla ILSVRC'de evrimsel sinir ağları ile geliştirilen algoritma üstünlüğünü kanıtlamıştır (Krizhevsky ve ark., 2017). Ayrıca hesaplama yöntemlerinde optimizasyon ve grafik işlem birimi teknolojilerinin gelişmesi ile hesaplama maliyetleri her geçen gün düşmektedir ve daha fazla araştırmacıya konu üzerinde çalışma imkânı sağlamaktadır. Bu savı "Google Scholar" arama motorunda "Deep learning" ve "medical" anahtar kelimeleri ile yapılan aramaların sonuçları da desteklemektedir. Bu anahtar kelimelerin ilgili arama motorunda yapılan aramaların sonuçları Şekil 1.1'de verilmiştir.



Şekil 1.1 “Deep learning” ve “medical” anahtar kelimelerinin “Google Scholar” arama sonuçlarında elde edilen çalışma sayılarının yıllara göre dağılımı

Bilgisayar görüşü ve derin öğrenme uygulamaları MRI, CT, X-ray gibi medikal görüntüleme sistemlerinde kullanılmaktadır (Ravi ve ark., 2017). Meyer ve arkadaşlarının derlemesinde radyoloji üzerine derin öğrenme ile çözülebilecek problemler üzerine çalışma yapılmıştır (Meyer ve ark., 2018).

Suzuki ve arkadaşları akciğer lezyonu sınıflandırması için başarılı bir yapay sinir ağı modeli geliştirmiştir. Bu yapay sinir akciğer görüntülerini girdi olarak kullanarak lezyonun bölütlemesi için kullanmıştır (Suzuki ve ark., 2003).

Gessert ve arkadaşları “International Skin Imaging Collaboration” adı verilen ve kısaltması daha yaygın olarak kullanılan ISIC2019 yarışması ile sağlanan 25000 görüntü içeren veri seti ile 8 farklı deri lezyonun 70 ± 5 doğrulukta sınıflandırmıştır (Codella ve ark., 2018; Gessert ve ark., 2019).

Moi Hoon Yap ve arkadaşları diyabetik ayak ülseri fotoğraflarını standartlaştırmak ve farklı durumlar ve farklı operatörler arasında güvenilirliğini test etmek için “FootSnap” adlı uygulamayı geliştirmiştir. 30 farklı diyabetik ülserli ve 30 farklı sağlıklı ayak kontrol grubuyla, iki farklı uzmanla birlikte kullanılmıştır. Elde edilen resimlerin tekrarlanabilirliği Jaccard benzerlik indeksi ile diyabetik ülserli ayakta 0.89-0.91 olarak ve diyabetik ülseri olmayan ayakta ise 0.93-0.94 olarak hesaplanmıştır (Yap ve ark., 2018).

Bo Song çalışmasında otomatik olarak yaraları bölütlemeye çalışmıştır. Çalışması için gerekli veri setini Drexel Üniversitesinde 2006 – 2008 yılları arası

19 hastadan dijital bir kamera ile toplamıştır. Elde edilen veri setinde geliştirilen program ile hedef bölgeler uzmanlar tarafından işaretlenmiştir. Geliştirdiği yapay sinir ağı ise MATLAB R2012A Neural Network Toolbox ile tasarlanmıştır. Değerlendirme sonuçlarında %71.4 oranında doğru sınıflandırmıştır (Song, 2012).

Manu Goyal ve arkadaşları, diyabetik ayak ülserlerinde enfeksiyon ve iskeminin tanınması ile ilgili teknikleri ve veri setlerini incelemişlerdir. Bu çalışmada, geleneksel görüntü işleme algoritmaları ve derin öğrenme yöntemleri ile sınıflandırma yapmak için çalışılmıştır. Geleneksel görüntü işleme algoritmalarından SLIC Superpixel tekniği ile bölümlenmiş ve destek vektör makineleri yöntemi ile süper pikseller sınıflandırılmıştır. Derin öğrenme ile sınıflandırmak için BayesNet, InceptionV3, ResNet50, InceptionResNetV2 mimarileri ile modeller geliştirilmiştir. Her iki yöntemle de başarıya ulaştığını ancak sınıflar arası benzer olduğunu, sınıfların özelliklerinin diyabetik ayak ülserlerinde çok ince ve zayıf olduğunu, ortam ışığı ve ten rengi gibi parametrelerin tahmini zorlaştırdığını raporlamıştır. Ayrıca daha fazla etiketlenmiş veri ile doğruluk oranlarının artacağını öngörmüştür (Goyal ve ark., 2020).

Artan dünya nüfusu ve ortaya çıkabilen global salgınlar gibi krizler sebebiyle değerlendirmelerinin uzaktan olması ihtiyaç haline gelmektedir ki bunu son zamanlarda bilgisayar görüşü ve derin öğrenmenin medikal alanlara uygulanması temelli çalışmaların artması yarışmalar ile desteklemektedir (Cassidy ve ark., 2020; Codella ve ark., 2018). Diyabetik ayak ülserleri üzerine araştırmalar da “Diabetic Foot Ulcer Contest” veya kısa adıyla DFUC ile desteklenmektedir.

Bu çalışma kapsamında diyabetik ayak ülserleri için bir görüntü sınıflandırma ve yaranın görüntü üzerinde yerinin belirlenmesi için bir model tasarlanmıştır. Sınıflandırma için derin öğrenme yöntemleri seçilmiştir. ResNet50 ve MobilNetV2 mimarili iki farklı model öğrenme transferi metodu ile M-COCO veri setinin ağırlıkları kullanılarak, DFUC2020 veri seti ile ince ayar (fine tune) yapılmıştır ve nesne tanıma için Faster RCNN mimarisiyle kullanılmıştır. Geliştirilen model yara değerlendirme ve bakım süreçlerinde dokümantasyona yardımcı bir araç olarak veya uzaktan değerlendirmede görüntü materyalinin elde edilmesi için kullanılabilecektir.

2. GENEL BİLGİLER

2.1. Yara Değerlendirmesi

Yüzeysel bir yara meydana geldiğinde ilgili bölgeyi temizlemek için sayısız sistem aktifleşir. Ancak bu metabolik taleple uyumlu bir oranla çeşitli enflamantuar hücrelerin, kemokinlerin, sitokinlerin, matriks moleküllerinin ve besin maddelerinin yara bölgesinde toplanmasını gerektirir. Bu süreçler genellikle iltihaplı, proliferatif ve yeniden modelleme olarak üç ayrı sürece bölünür (Han & Ceilley, 2017).

İltihaplı süreç, hemostaz başladıktan kısa bir süre sonra başlar. Bu süreçle patojenler ve yabancı materyaller zarar gören bölgeden uzaklaştırılır. Vasküler geçirgenlik artar, böylelikle nötrofiller ve monositlerin yara bölgesinde birikmesi sağlanır. Yara meydana geldikten yaklaşık 3 gün sonra proliferatif süreç başlar. Bu süreçte yara bölgesinde doku iskelesinin temellerini oluşturacak kolajen ve besin maddeleri biriktirilir. Bu arada endotel hücreleri büyüme sürecine girer ve granülleşen dokunun etrafında anjiyogenez ile yoğun damar ağı oluşur ve bu oldukça aktif bölgeyi besler. Yaklaşık 2 – 3 hafta sonunda yara olgunlaşma sürecine girer ve burada yeniden modelleme yapılır ve oluşturulan yoğun damar ağı geriler ve doku neredeyse normal haline dönüşür. Tamir edilen doku eski gerilme kuvvetine ulaşamaz (Han & Ceilley, 2017).

Yara yatağında oksijen yoğunluğu yara iyileşmesinde önemli bir faktördür. Yara iyileşmesi sürecinde sayısız sitokin iletişimine aktif olarak hücre çoğalmasına kaynak olarak oksijen kullanılmaktadır. Normal koşullarda iyileşen bir yaranın 20 mmHg doku oksijen gerilimine sahip olduğu düşünülmektedir. Bu değer iyileşmeyen yaralarda 5 mmHg e kadar düştüğü görülmüştür. Beslenemeyen dokular nekrotik doku haline gelecek ve bu bakteri oluşmasına sebep olacaktır. Bu sebeple iyileşemeyen yaralar için özel bir tedavi düzeni gerekmektedir. Oksijenin yanında çok sayıda maddenin yara iyileşmesinde önemi ve gereklilikleri kanıtlanmıştır (Han & Ceilley, 2017).

Önceki paragraflarda bahsedildiği üzere yara iyileşmesi uzun zincirleme süreçlere bağlıdır. Herhangi bir akut yaranın sonucunda bu süreçler gerçekleşmektedir. Yaranın tamamen iyileşmesi, konumuna boyutuna derinliğine tipine bağlı olacaktır. Ancak diyabet gibi patolojik bir durum söz konusu olduğunda bu süreçler bozulabilmektedir.


Çin’de yapılan epidemiyolojik çalışmalarda diyabetik ayak ülseri diyabetli hastaların hastaneye yatmasındaki en büyük neden olduğu gözlemlenmiştir (Zhang ve ark., 2017). Diyabetik ayak ülserinin 12 haftalık tedavi sonrası iyileşme şansı %24-82 arasında değişmektedir (Bus ve ark., 2016). Diyabetik ayak ülseri amputasyona ve ölüme sebebiyet verebilmektedir. Bu sebeple tedavi ve teşhisi için yara bakımını mümkün olduğunca standart haline getirilmeye çalışılmaktadır. Bu çalışmalar uluslararası bir organizasyon olan “International Working Group on the Diabetic Foot” (IWGDF) tarafından çeşitli ülkelerden ve disiplinlerden uzmanlar ile iletilemektedir. Yara yönetim sistemi hastayı ve yarayı bütünsel tamamlayıcı ve sistematik şekilde ele alması gerektiği büyük çoğunluk tarafından kabul edilmiştir. Bu yaklaşım sağlık profesyonellerinin iyileşme sürecine müdahale eden engelleri belirlemesini, tedavi hedefleri oluşturabilmesini ve bireysel hasta ihtiyaçlarına göre en uygun tedaviyi planlamasını mümkün kılmaktadır (Gil, 2020).

Yara, çalışmalar ışığında TIME ve MEASURE gibi akronimler ile ifade edilen prensipler ile değerlendirilip yönetilebilir. TIME prensibi ile doku “tissue”, enfeksiyon “infection”, nem “moisture” ve kenarlar “edge” değerlendirirken; MEASURE prensibi ile ölçüleri “measure”, eksudatı “exudate”, görünüşü “appearance”, acıyı “suffering”, altında yatan sebepler “undermining cause”, yeniden değerlendirmeyi “reevaluate” ve kenar “edge” parametreleri ile değerlendirir (Keast ve ark., 2004; Schultz ve ark., 2004).

Deborah ve arkadaşlarının yaptığı çalışmada yara ölçüm sistemleri, temaslı ve temassız ölçüm sistemleri olarak iki başlık altında incelemiştir (Wendland & Taylor, 2017).

Temaslı yara ölçüm sistemleri veya cihazları, tanımdan da anlaşılacağı gibi yara yatağına direkt temas halindedir. Uzunluk, genişlik, derinlik, yüzey alanı ve hacim ölçümlerini ölçebilirler. Bunlar cetvel ile ölçüm, Kundin cihazı, el ile kopya olarak örneklendirilebilir (Wendland & Taylor, 2017).

Cetvel ile ölçümde, yara yüzeyinin en uzun yatay ve dikey mesafeleri ölçülür. Cetvel tekniğinde birden fazla yaklaşım mevcuttur, Langemo ve arkadaşları baştan başa ölçümün en doğru ölçüm tekniği olduğunu ortaya koymuştur. Doğruluk olarak düşük olmasına rağmen kullanım kolaylığı ve ulaşılabilirliği sebebiyle sıklıkla kullanılmaktadır (Wendland & Taylor, 2017).



Şekil 2.1 Model yara üzerinde cetvel ile yara ölçümü (Shah ve ark., 2013)

El ile kopya ise yaranın üzerine yerleştirilen transparan bir materyal üzerinden yara kenarları işaretlenerek elde edilen çıktı bilgisayarlı veya kare sayma yöntemiyle ölçümün yapılmasıdır (Wendland & Taylor, 2017).



Şekil 2.2 El ile kopya yöntemi ile yara ölçümü uygulaması (Nichols, 2015)

Temassız ölçüm sistemleri, yara yüzeyine direkt temas etmeye gerek kalmadan yapılan ölçüm sistemleri veya cihazlarıdır. Bu metotlar dijital fotoğraflama, 3 boyutlu lazer teknolojisi ve stereo fotogrametri olarak örneklendirilebilir. Dijital kameraların fiyatlarının yüksek olmasının yanında fotoğrafın çekildiği yüzey ışık ve ortam sabit olmadığı için kullanımı zorlayıcı olabilmektedir (Wendland & Taylor, 2017).

Stereo fotogrametri birden fazla kameranın kullanılarak konumun yakınsamasıdır. Daha önceki çalışmalarda başarılı sonuç üreten bir yöntem olsa da yara yüzeyinde ışığın ulaşamadığı bölgelerde yönetim yapılandırılmış ışığa bağlı olmasında dolayı hatalı sonuçlar üretmektedir. Pahalı bir teknoloji olmasına karşın yanık gibi kullanılmasını gerektiren klinik durumlar mevcuttur (Wendland & Taylor, 2017).


Dijital fotoğraflama yara dokümantasyonunda oldukça yaygın olarak kullanılmaya başlanmıştır. Elde edilen fotoğraflardan bilgisayar görüş yöntemleri ile kopya tekniğine benzer şekilde sonuçlar elde edilebilmektedir. Benzer uygulamalar güvenilirliğini ve doğruluğunu göstermiş olmasına rağmen bazı zorluklar olduğu rapor edilmiştir (Wendland & Taylor, 2017). Görüntüyü dijital ortam yorumlama yöntemleri hızla gelişmektedir. Bu kapsamda “Perspective – 3D Wound Management”, “Healthy.io Silhouette”, “eKare InSight” gibi ürünler geliştirilmiştir. Bu ürünler yara boyutunu ve geometrisini yara yatağını sıcaklık farkından yararlanarak kızılötesi kameralar ile veya derin öğrenme yöntemleri ile tahmin edebilmektedir.

Pokorná ve arkadaşının yapmış olduğu çalışmada iyileşmeyen yara dokümantasyonunda kullanılan fotoğrafların büyük çoğunluğunun kalitesinin zayıf olduğunu tespit etmiştir. Bu kaliteyi düşüren parametreleri aydınlatma mesafe ve odaklama olarak belirlemiştir (Pokorná & Leaper, 2015).

2.2. Dijital Ortamda Görüntü


Görüntü, etraftaki objelerden yansıyan ışığın görünür spektrumuna ait olan kısmının yorumlanmasıdır.

Memeliler özelinde görüntü, kornea ve lens etraftaki ışığı retina üzerine düşürerek üzerinde bulunan koniler ve çubuklar adı verilen reseptörler ile elektriksel titreşimlere dönüştürerek oluşturulur. Dijital sistemlerde de buna bezer şekilde görüntü, lens yardımıyla toplanan ışık sensörler veya sensör setleri üzerine düşürülerek oluşturulan elektriksel sinyalin yorumlanmasıyla elde edilir (Yuan ve ark., 2018). Dijital bir görüntü $f(x, y)$ şeklinde iki boyutlu bir fonksiyon olarak tanımlanabilir, burada x ve y uzaysal koordinatlar ve f , x ve y ikilisindeki yoğunluk olarak adlandırılan büyüklüktür Şekil 2.3'teki gibi gösterilebilir (Gonzalez ve ark., 2009). Bu fonksiyondan yola çıkılarak renkli bir resim de x ve y ikilisi yine yoğunluğu ifade ederken z ile renk katmanını ifade edecek şekilde $f(x, y, z)$ tanımlanabilir.




Şekil 2.3 Siyah beyaz bir görüntü ve dijital ortamdaki temsili

Retina üzerinde bulunan koni ve çubuk reseptörleri ışığın bütün dalga boylarına aynı hassasiyette değildir. Bazı çubuk reseptörlerde bulunan rhodopsin denilen ışığa karşı duyarlı pigmentler bulunur. Bu pigment en çok görünen ışığın mavi-yeşil spektrumunu kapsayan bölgeye duyarlıdır. Dalga boyu arttığında veya azaldığında bu duyarlılığı azalır. Gözlemcilerin düşük yoğunluk aralığında sabit bir dalga boyundaki bir ışık denetinin yoğunluğunu, referans dalga boyundaki ışık demetinin yoğunluğuyla aynı olacak şekilde ayarlamasıyla Şekil 2.3'teki kesikli çizgi elde edilmiştir. Bu kesikli çizgi çubuk reseptörlerin duyarlı olduğu dalga boyu aralığını gösterir (Crawford, 1949). Burada ışık yoğunluğu, bir kaynaktan belli bir yöne doğru yayılan dalga boyu ağırlıklı gücü olarak tanımlanır ve SI sistemde candela (c) ile gösterilir (Bureau international des poids et mesures, 2019). Düşük yoğunluk ile $10^{-3} - 10^{-6} \text{ cd/m}^2$ olarak belirtilmektedir (Kelber ve ark., 2002).



Şekil 2.4 Gözdeki reseptörlerin duyarlı olduğu ışık dalga boyları

Şekil 2.4 üzerindeki eğriler koni reseptörlerinin tepki gösterdiği aralıklardır (Smith & Pokorny, 1975; Stockman ve ark., 1993). Bu aralıklar Şekil 2.5'te görünür bölgeyi görselleştiren spektrumda yerine koyulduğuna S, M, L ile işaretlenen eğriler sırasıyla kırmızı, yeşil, mavi alanlarıyla eşleşmektedir. Bu sebeple, çoğunlukla dijital görüntü RGB, XYZ gibi tristimulus değerlerle ifade edilir (Kriss ve ark., n.d.).



Şekil 2.5 Görünür bölgeleri gösteren spektrum


2.3. Derin Öğrenmenin Temelleri

Derin öğrenme, yapay sinir ağlarını kullanarak problem setleri üzerine otomatik olarak özniteliklerini çıkarabilen veya sınıflandırabilen bir makine öğrenmesi metodudur. Buradaki öğrenme gözetimli, yarı gözetimli ve gözetimsiz olabilir (Schmidhuber, 2015).

Öğrenme kavramı aslında, bir fonksiyonun yakınsamasıdır. Gözetimli ve gözetimsiz öğrenme ise sırasıyla bu öğrenmenin örnek girdi-çıkıtları ile yeni bir girdiyi çıktıya eşlemesi ve eşleşmiş girdi-çıkıtları olmadan girdiye göre bir çıktı oluşturabilmesidir (Russell & Norvig, 1995).

Yapay sinir ağları, derin öğrenme metodunun temellerini oluşturmaktadır. Yapay sinir ağları birbirine bağlı yapay nöron adı verilen birimlerden oluşmaktadır. Bu birimler aralarında başka bir birimden veya birimlerden aldığı değeri yorumlayarak başka bir birime iletir. Burada bahsi geçen değer aslında bir reel sayı, yorumlama ise bu değerlerin öğrenme gerçekleştikçe güncellenen ağırlık değeri ile çarpılıp lineer olmayan aktivasyon fonksiyonuna girdi olarak verilmesidir. Her bir yapay nöronun girdileri ve bu girdilerden oluşturduğu, birden fazla yapay nörona girdi olarak gönderebildiği bir çıktısı vardır. Bu yapı Şekil 2.6'da diğer nöronlardan

gelen değerler x_n , ağırlık değerleri w_n , fonksiyon $f(x)$, fonksiyon çıktısı ise y ile gösterilmiştir.




Şekil 2.6 Yapay nöron ve bileşenleri

Bir yapay nöron, matematiksel olarak Denklem 2.1'deki gibi ifade edilebilir.

$$y = \sum_{j=0}^m f(x_j w_j) \quad (2.1)$$

Girdi ve çıktılar sırasıyla, üzerinde işlem yapılan veri setinin değerleri örneğin görüntü üzerinde işlem yapan bir yapay sinir ağı için görüntü üzerindeki pikseller ya da örneklenmiş piksel değerleri, ara katmanlardaki çıktılar öznelilikler ve final katmanındaki çıktılar ise yapay sinir ağının tasarım görevinin sonucu olarak örneklendirilebilir. Bu karmaşık yapı Şekil 2.7'de basitleştirilerek gösterilmiştir.




Şekil 2.7 Basitleştirilmiş bir yapay sinir ağının katmanları

2.3.1. Gradyan Öğrenme

Bir çok derin öğrenme algoritması bir optimizasyon algoritması içerir. Burada optimizasyon bir fonksiyonun maksimize veya minimize edilmesi olarak düşünülebilir. Maksimize veya minimize edilen fonksiyona amaç işlevi veya ölçüt adı verilir. Minimize edilen fonksiyona ise maliyet fonksiyonu, kayıp fonksiyonu veya hata fonksiyonu denir. Bu ifadeler yayınlarda atfedilen anlama göre değişken göstererek kullanılır (Goodfellow ve ark., 2016).

Bir fonksiyonu minimize edilirken kullanılan algoritmalarından biri de gradyan iniş algoritmasıdır. Bu algoritma ve türevleri makine öğrenmesinde sıklıkla kullanılmaktadır. Temel olarak kayıp fonksiyonu üzerinde küçük adımlarla ile optimum değer bulunana kadar ilerleyerek optimum değeri bulur (Bengio ve ark., 1994).

Şekil 2.8’de türevi alınacak fonksiyonun grafiği kırmızı çizgi ile iç bükey bir grafik ile ifade edildiğinde. Şekil 2.8’de mavi gösterilen eğri ise θ noktasındaki türev kısmıdır. Eğer seçilen θ , lokal minimum değerın sağ tarafında kalırsa bağıntının türev kısmı pozitif olacaktır. Böylelikle θ minimum değere yakınsayacaktır. Benzer şekilde seçilen θ minimum değerin sol tarafında kalacak şekilde seçilmiş ise bağıntının türev kısmı negatif olacaktır ve θ artırılarak minimum değere yakınsayacaktır.



Şekil 2.8 İç bükey grafiklerin sağdan ve soldan türevleri

Bir gradyan iniş algoritması $h_{\theta}(x)$ hipotezi, doğrusal bir $(x^{(i)}, y^{(i)}) (i = 1, 2, 3, \dots, m)$ veri setine, $J(\theta)$ $\theta = \theta_1, \theta_2, \theta_3, \dots$ parametrelili kayıp fonksiyonu ile örneklendirilecek olursa. Bu bağlamda hipotez Denklem 2.2’deki gibi olur.


$$h_{\theta} = \theta_0 + \theta_1 x \quad (2.2)$$

Bu hipotezi Denklem 2.3'teki karelerin toplamı kayıp fonksiyonu ile yakınsarsak gradyan iniş optimizasyon algoritmasının iterasyonu Denklem 2.4'teki gibi gösterilebilir.

$$J(\theta) = \frac{1}{2m} \sum_i^m [h_{\theta}(x^{(i)}) - y^{(i)}]^2 \quad (2.3)$$

$$\theta_j \rightarrow \theta_j - \alpha \frac{\partial}{\partial \theta_j} J(\theta) \quad (2.4)$$

Şekil 2.9'da bu doğrusal veri setine uydurulan hipotez ve kayıp fonksiyon grafiği verilmiştir. Gradyan iniş algoritmasının adımları kırmızı oklar ile kayıp fonksiyonu grafiğinde gösterilmiştir.



Şekil 2.9 h hipotezinin doğrusal veri setine yakınsaması ve tek boyutlu bir kayıp fonksiyonu üzerinde gradyan iniş algoritmasının adımları

Gradyan iniş algoritmasında veri seti sınır ağı derinleştikçe veya genişledikçe hesaplama maliyeti ağırlıklar ve bias değerlerinin yani eğitilebilir parametrelerin artmasından dolayı artar. Pratikte bu karmaşıklığın üstesinden gelmek için geliştirilen yöntemlerden biri olan stokastik gradyan iniş algoritması (Stochastic Gradient Descent-SDG) kullanılmaktadır (Goodfellow ve ark., 2016).


SGD genel olarak aşağıdaki adımları izleyerek çalışır;

- Veri setinin rastgele olarak karıştırır.
- Bütün veri setini küçük “mini-batch” olarak ifade edilen gruplara böler.
- Gradyan iniş adımlarını bu “mini-batch” göre hesaplar.

Bu yöntem minimum değeri bulmak için mükemmel değildir ancak hesaplama maliyetini ekstrem bir şekilde düşürmektedir.

2.3.2. Aktivasyon fonksiyonu

Aktivasyon fonksiyonu verilen girdiye göre yapay nöronun çıktısını belirleyen fonksiyondur. Şekil 2.10'daki görseldeki yapay nöronda $f(x)$ aktivasyon fonksiyonudur.



Şekil 2.10 $f(x)$ aktivasyon fonksiyonlu bir yapay nöron

Gradient öğrenme yalnızca doğrusal olmayan aktivasyon fonksiyonları kullanıldığında başarılı olmaktadır (Kulathunga ve ark., 2020). Örnek olarak görselde verilen, basitleştirilmiş bir yapay sinir ağında aktivasyon fonksiyonu lineer bir fonksiyon seçildiğinde yapay sinir ağının çıktısı Denklem 2.5'teki gibi olur.


$$y = x_0 w_0 w_1 w_2 \quad (2.5)$$

Burada ağırlık değerleri tek bir değer skalar olan w_c olarak yazılabilir. Bu bütün ağıın Denklem 2.6'da gösterildiği gibi tek bir fonksiyona dönüştüğünü gösterir.

$$y = x_0 w_c \quad (2.6)$$

Ancak seçilen aktivasyon fonksiyonu doğrusal olmayan bir fonksiyon seçildiğinde yapay sinir ağının çıktısı Denklem 2.7'deki gibi olur.

$$y = f(f(f(x_0 w_0) w_1) w_2) \quad (2.7)$$




Şekil 2.11 Doğrusal olmayan aktivasyon fonksiyonlarının arka arkaya sıralanması

Aktivasyon fonksiyonu olarak lineer olmayan birçok fonksiyon seçilebilir. Pan ve arkadaşları otomatik konuşma tanıma çalışmasında sigmoid fonksiyonu aktivasyon fonksiyonu olarak kullanmıştır (J. Pan ve ark., 2012). Bir bilgisayar görüş mimarisi olan AlexNet ise ReLu aktivasyon fonksiyonu kullanılmıştır (Krizhevsky ve ark., 2017).

Sigmoid fonksiyon matematiksel olarak Denklem 2.8’de ifade edilmiştir. Grafik olarak ise Şekil 2.12’de gösterilmiştir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.8)$$




Şekil 2.12 Sigmoid aktivasyon fonksiyonu

Gradyan tabanlı öğrenme sırasında yapay sinir ağının gizli katmanlarında gradyan o kadar küçük hale gelmektedir ki sonraki ağırlıkları neredeyse hiç

etkileyemeyecek hale gelmektedir. Bu probleme kaybolan gradyan adı verilir. Çözüm olarak Glorot ve arkadaşları tarafından ReLu aktivasyon fonksiyonun kullanılmasını önerilmiştir (Glorot ve ark., 2011).

ReLu aktivasyon fonksiyonu bağıntı olarak Denklem 2.8’de ifade edilmiştir. Grafik olarak ise Şekil 2.13’te gösterilmiştir.

$$f(x) = \begin{cases} 0 & \text{icin } x \leq 0 \\ x & \text{icin } x > 0 \end{cases} = \max\{0, x\} = x1_{x>0} \quad (2.8)$$



Şekil 2.13 ReLu aktivasyon fonksiyonu (kesikli çizgiler)

Softmax aktivasyon fonksiyonu veya normalleştirilmiş üstel fonksiyon olarak ifade edilen fonksiyon, lojistik fonksiyonun birden çok boyuta genelleştirmesidir (Goodfellow ve ark., 2016). Genellikle sınıflandırma yapay sinir ağlarında son katmanda elde edilen tahmin sonuçlarını bir olasılık dağılımında normalleştirmek için kullanılır.


Softmax fonksiyonu, K gerçık sayılarından oluşan z vektörünü girdi olarak alır ve girdi sayılarının üstel değeriyle orantılı, K olasılıklarından oluşan bir olasılık dağılımına normalleştirir. Yani softmax fonksiyonun uygulamasından önce girdiler negatif veya pozitif ve 0 ile 1 arasında olmayabilir. Ancak softmax

uygulandıktan sonra çıktılar 0 ile 1 arasında toplamaları 1'e yakın olarak dağılmış olur. Bu fonksiyon Denklem 2.9'da gösterilmiştir (Goodfellow ve ark., 2016).

$$\sigma: \mathbb{R}^K \rightarrow \mathbb{R}^K$$


$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2.9)$$

Örnek olarak, 0, 1 ve 2 sınıflandırması yapan bir yapay sinir ağında son katmanında çıkışlar [4.14, 1.03, 0.89] olarak hesaplanmıştır. Bu sonuca göre el yazısı ile 0 yazısının görüntüsü girdi olarak verildiğinde çıktı olarak 0 olduğu tahmin edilmektedir. Başka bir görüntü için son katmanında hesaplanan ağırlıklar [4.14, 3.89, 4.12] olarak hesaplandığında girdinin yine 0 olduğu tahmin edilmektedir ancak burada ilk örnekte verilen 0 tahmini ikinci örnekte verilen 0 tahminine göre daha başarılı olduğu açıkça görülmesine rağmen softmax fonksiyonu olmayan aktivasyon fonksiyonların çıktıları her iki tahminde de aynı başarıdaymış gibi değer üretmektedir. Bu sonuç softmax olmayan aktivasyon fonksiyonları birbirlerinin değerlerini etkileyemedikleri için ortaya çıkmaktadır.



Şekil 2.14 İki farklı yapay sinir ağı ve el yazısı ile 0 rakamının sınıflandırma sonuçları (Softmax aktivasyon fonksiyonu kullanılmadan)

Softmax aktivasyon fonksiyonu son katmanda uygulandığında son katmanın çıktıları [0.932, 0.041, 0.035] ve [0.362, 0.282, 0.355] olarak hesaplanmış ve ilk çıktının çok daha başarılı bir tahmin olduğu görülmektedir.




Şekil 2.15 İki farklı yapay sinir ağı ve el yazısı ile 0 rakamının sınıflandırma sonuçları (Son katmanda softmax aktivasyon fonksiyonu ile)

2.3.3. Düzenleştirme

Düzenleştirme, gradyan öğrenmenin gerçekleştirildiği modelde parametre sayılarının azaltılmasıdır. Fazla parametre, model karmaşıklığını artıracaktır, model karmaşıklığının artması ise modelin hesaplama zorluğunu arttırabilir veya aşırı uyumasına yol açabilir (Goodfellow ve ark., 2016).

Aşırı uyuma modelin, belirli veri kümesine çok yakın veya tam olarak karşılık gelen tahminler üretmesi ve bu nedenle gelecekteki tahminleri güvenilir bir şekilde tahmin etmede başarısız olmasıdır. Şekil 2.16’da yetersiz uyum, tam uyum ve aşırı uyum grafik üzerinde gösterilmiştir. Aşırı uyumuş modelde örneklerle örtüşmesine rağmen grafikteki ara değerlerde gerçek fonksiyondan farklı değerler üretmektedir.




Şekil 2.16 Yetersiz uyum (sol), tam uyum (orta) ve aşırı uyum (sağ) grafikleri

Bu bağlamda birçok farklı düzenleştirme algoritmaları geliştirilmiştir. Bunlardan en sık kullanılanı Ridge regresyonu olarak da bilinen L2 düzenleştirmesidir. Bu algoritmada, model karmaşıklığını azaltmak için kayıp fonksiyonuna ağırlık parametresi eklenir. (Hoerl & Kennard, 1970).

2.3.4. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli sinir ağları, derin öğrenme içerisinde bir f^* fonksiyonunu yakınsamak amaçlı bir konsepttir. Örnek olarak $y = f^*(x)$ şeklinde bir sınıflandırıcı modelde x girdisini y kategorisine göre haritalasın. İleri besleme bir sinir ağı, $y = f(x; \theta)$ bağıntısında θ parametresinin değerini öğrenerek en iyi yaklaşımı bulur (Goodfellow ve ark., 2016).

Bu modellerde bilgi akışı ileri doğru olduğu için ileri beslemeli olarak adlandırılır. Mimari üzerinde geri besleme bağlantısı yoktur (Goodfellow ve ark., 2016).




Şekil 2.17 İleri beslemeli bir yapay sinir ağı

2.3.5. Geri Yayılım

Herhangi bir denetimli öğrenme algoritmasının amacı, bir dizi girdiyi doğru çıktılarına en iyi şekilde eşleşen bir fonksiyon bulmaktır. Geri yayılım, çok katmanlı bir sinir ağında, girdinin çıktıya herhangi bir keyfi eşleşmesini sağlayacak değerleri öğrenmesini sağlar (Rumelhart, David E.; Hinton, Geoffrey E.; Williams, 1986).

Eğitim süresince ileriye doğru yayılma, bir kayıp fonksiyonu $J(\theta)$ oluşana kadar devam eder. Geri yayılma, kayıp fonksiyonun gradyanından gelen bilginin sinir ağı üzerinden ağırlıkları güncellemesini sağlar (Goodfellow ve ark., 2016).

Şekil 2.18’de rastgele ağırlık ve bias değerleri olan henüz öğrenmemiş temsili bir sinir ağında aktivasyon çıkışında değerler $[0.20, 0.89, 0.40]$ olarak tamamen rastgele olduğu görülmektedir. Geri yayılım aktivasyon çıkışlarını veri seti ile hesaplanan kayıp fonksiyonuna göre güncellenmesini sağlar. Bir iterasyon sonunda geri yayılımla $[0.20, 0.89, 0.40]$ çıktısını veren ve veri setine göre $[1.00, 0.00, 0.00]$ olması beklenen aktivasyon çıktıları üreten ağırlık ve biaslar çıktıyı üretecek şekilde güncellenecektir.



Şekil 2.18 Temsili bir sinir ağında geri yayılım

2.3.6. Evrişimli Sinir Ağları (CNN)


Evrişimli sinir ağları, ızgara topolojideki veri setleri üzerinde işlem yapmak üzere özelleştirilmiş yapay sinir ağlarıdır. Bir boyutlu zaman serisi veri setleri ya

da, görüntü verileri ızgara topolojisindeki verilere örnek verilebilir (Goodfellow ve ark., 2016).

Evrişim, Denklem 2.10'da da ifade edildiği gibi matematiksel olarak iki fonksiyonun şekillerine bağlı olarak üçüncü bir fonksiyon üretmesidir. Burada ilk argüman genellikle girdi, ikinci argüman çekirdek (kernel) ve çıktı ise öznelik haritasıdır.


$$(f * g) = \int_0^t f(\tau)g(t - \tau)d\tau \quad (2.10)$$

2 boyutlu ızgara topolojisindeki veri seti örneği olan görüntü verisi üzerinde evrişim Şekil 2.19'da gösterilmiştir. Görselde yukardaki parçada girdi evrişim işaretinin sol tarafında, çekirdek kernel) evrişim işaretinin sağ tarafında, görselin alt kısmında ise öznelik haritası gösterilmiştir.




Şekil 2.19 Izgara topolojisinde evrişim operasyonu

Evrişimsel sinir ağları, mimari açıdan evrişimsel katmanlar ve tam bağlantılı ağlar olarak iki farklı başlık altında incelenebilir. Evrişimsel katmanlar, girdi görüntülerinden öz niteliklerini çıkarmak için filtreler kullanır. Tam bağlantılı katmanlar, çıkarılan öz nitelikleri hipotez için skora indirger (Schwing & Urtasun, 2015).



Şekil 2.20 Evrişimsel sinir ağı katmanları

Evrişimsel sinir ağlarının diğer bir özelliği havuzlama katmanıdır. Havuzlama bir çeşit lineer olmayan alt örnekleme fonksiyonudur. Birkaç farklı lineer olmayan fonksiyon mevcuttur, en sık kullanılanı ise maksimum havuzlama yöntemidir. Maksimum havuzlama (max pool veya argmax) yöntemi, girdi görüntüsünü üst üste binmeyen bir dizi dikdörtgene böler ve bu her alt bölge için maksimum değerleri çıktı olarak verir (Zeiler & Fergus, 2013). Şekil 2.21’de 4x4’lük bir görüntünün, 2x2’lik bir maksimum havuzlama fonksiyonu ile oluşan çıktısı gösterilmiştir.



Şekil 2.21 Maksimum havuzlama (max pool veya argmax) operasyonu

$$f_{X,Y}(S) = \max_{a,b=0}^1 S_{2X+a, 2Y+b} \quad (2.11)$$

2.3.6.1. ResNet

Artan (Residual) yapay sinir ağları Microsoft Araştırma Takımı tarafından 2015 yılında ILSVRC (ImageNet Large Scale Visual Recognition Challenge)


yarışmasında birinciliği %3.57'lik hata oranı ile kazandığı yapay sinir ağı mimarisidir (Russakovsky ve ark., 2015).

Çizelge 2.1 Farklı derinlikteki ResNet mimarisi tasarım blokları

l.n.	o.s.	50	101	152
conv1	112 x 112	7 x 7, 64, stride 2		
conv2_x	56 x 56	3 x 3 max pool, stride 2		
		$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28 x 28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14 x 14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7 x 7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1 x 1	Average pool, 1000-d fc, softmax		
FLOPs		3.8×10^9	7.6×10^9	11.3×10^9

Yapay sinir ağları ve evrimsel sinir ağları alanında yapılan çalışmalarda, mimaride derinlik arttıkça modelin temsil kapasitesinin artırdığından dolayı başarı oranlarının arttığı görülmüştür. Bu çıkarım daha derin yapay sinir ağı mimarilerinin geliştirilmesini desteklemiştir. Ancak mimari derinleştikçe her bir yapay nörona ağırlık olarak ifade edilen eğitilebilir parametrelerin artması nedeniyle yapay sinir ağının optimizasyonu zorlaşmaktadır. Derin yapay sinir ağlarında bir diğer problem de kaybolan gradyandır. Derin bir yapay sinir ağı mimarisinde geri yayılım sürecinde bazı yapay nöronlar aktivasyon değerleri çok küçük hale geldiği için artık öğrenmeye etki etmemektedir (Bengio ve ark., 1994; He ve ark., 1994).

Normal bir evrişimli sinir ağında girişten çıkışa kadar doğrusal olmayan bir $\mathcal{H}(x)$ fonksiyonu ile ifade edilebilir. ResNet mimarisinde ise $\mathcal{H}(x)$ yerine $\mathcal{F}(x) := \mathcal{H}(x) - x$ olarak tanımlanan başka bir doğrusal olmayan fonksiyon şeklinde ifade edilmektedir. Buna ek olarak giriş değeri $\mathcal{F}(x)$ fonksiyonuna aritmetik olarak eklenmektedir. $\mathcal{F}(x) + x$ olarak ReLU aktivasyon fonksiyonuna uygulanır. Bu sayede bir önceki katmanın çıktısı daha güçlü bir şekilde sonraki katmana aktarılır. Bu mantık Şekil 2.22’de gösterilmiştir. Ayrıca bu fonksiyon haritalamasıyla yapay sinir ağında optimizasyonun orijinal fonksiyona oranla daha kolay olduğu gözlemlenmiştir (He ve ark., 1994).



Şekil 2.22 ResNet mimarisinde derin mimarilerde öğrenme probleminin çözümü için kullanılan blok

2.3.6.2. MobileNet

Howard ve arkadaşları tarafından gömülü ve mobil platformlarda görüş uygulamalarında çalışması için MobileNet mimarisi geliştirilmiştir. Önerilen algoritma, derinlemesine ayrılabilir (depth-wise separable) evrişimsel katmanlar temellidir. Derinlemesine ayrılabilir katmanlar, katmanları ayıran ve noktasal evrişim olarak adlandırılan 1×1 boyutunda evrişimsel katmalardır. MobileNet her biri giriş kanalına derinlemesine evrişim uygular. Daha sonrasında noktasal 1×1 evrişim uygulanarak derinlemesine evrişim çıkışlarını birleştirir. Standart evrişim girdileri filtreler ve yeni bir çıkış şeklinde tek adımda birleştirir. Derinlemesine ayrılabilir evrişim ise bu aşamaları ikiye ayırır. Bu ayırım, hesaplama maliyetini ve model boyutunu güçlü bir şekilde azaltır (Howard ve ark., 2017).

Standart bir evrişimsel katman girdi olarak $D_F \times D_F \times M$ şekline öznitelik haritası F 'i alır ve $D_F \times D_F \times N$ şeklinde öznitelik haritası G 'yi çıktı olarak verir. Burada D_F , girdi öznitelik haritasının kare düzlemsel genişlik ve yüksekliğidir. M , girdi kanal sayısı ve N , çıktı kanal sayısıdır. K kernel büyüklüğü olduğunda, standart evrişim operasyon işlemi Denklem 2.12'de ve hesaplama maliyeti ise Denklem 2.13'te verilmiştir (Howard ve ark., 2017).


$$G_{k,l,n} = \sum_{i,j,m} K_{i,j,m} \cdot F_{k+i-1,l+j-1,m} \quad (2.12)$$

$$D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F \quad (2.13)$$

Derinlemesine ayrılabilir evrişimsel katman ise derinlemesine evrişim ve noktasal evrişim olarak iki alt katmandan oluşturulmuştur. Burada derinlemesine evrişim katmanı her bir girdi kanalına bir filtre uygular. Noktasal evrişim katmanı ise derinlemesine evrişim katmanının çıktısından doğrusal kombinasyonunu oluşturur. Derinlemesine ayrılabilir ayrılabilir katman, K' kernel büyüklüğü olduğu yerde Denklem 2.14 ile ifade edilebilir. Hesaplama maliyeti ise Denklem 2.15 ile ifade edilebilir (Howard ve ark., 2017).

$$G'_{k,l,m} = \sum_{i,j} K'_{i,j,m} \cdot F_{k+i-1,l+j-1,m} \quad (2.14)$$

$$D_K \cdot D_K \cdot M \cdot D_F \cdot D_F \quad (2.15)$$



Şekil 2.23 Standart ve derinlemesine ayrılabilir evrisimsel bloklar

Çizelge 2.2 MobilNetV2 mimarisi tasarım blokları

Girdi	Operator	t	c	n	s
$224^2 \times 3$	conv2d	-	32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	conv2d 1 x 1	-	1280	1	1
$7^2 \times 1280$	Avgpool 7 x 7	-	-	1	-
$1 \times 1 \times 1280$	conv2d 1 x 1	-	k	-	-


2.3.6.3. Bölgesel evrişimsel sinir ağları

Bir nesne konumu belirleme probleminde, görüntü çeşitli bölgelere ayrılır, bu bölgeleri tek tek evrişimsel sinir ağıdan geçirir ve sınıflandırılır. Sınıflandırılan nesneler birleştirilerek girdi olarak kullanılan resim üzerinde sınırlayıcı kutular ile görülebilir. Ancak burada sınıflandırılan nesnenin en boy veya görüntü üzerinde kapladığı alan değişiklik gösterebilir. Bu durumda girdi olarak alınan görüntü irili ufaklı birçok bölgeye ayırma ihtiyacı doğmaktadır. Bu problemi aşmak için bölgesel evrişimsel sinir ağları bilgisayar görüş uygulamalarında nesne konumun belirlemede kullanılmıştır. Bu modeller R-CNN, Fast R-CNN ve Faster R-CNN olarak sıralanabilir (Girshick, 2015; Girshick ve ark., 2014; Ren ve ark., 2017).

R-CNN dörtgen şeklinde görüntü parçalarını belirler ve bu parçaların bir nesneye karşılık gelip gelmediğini kontrol eder. Görüntü parçalarını belirlerken seçici arama algoritmasını kullanır. Seçici arama girdi olarak verilen görüntüyü Felzenszwalb ve Huttenlocher'in grafik tabanlı bölütlemesi ile çok parçalı olacak şekilde bölütler. Bu parçaları birbirleri arasında renk, doku, büyüklük, şekil benzerliklerine göre gruplar (Felzenszwalb & Huttenlocher, 2015; Uijlings ve ark., n.d.). Bu oluşturulan görüntüleri evrişimsel sinir ağına girdi olarak verir ve çıktıları destek vektör makineleri algoritması ile sınıflandırılır (Girshick ve ark., 2014).

R-CNN oldukça iyi çalışmasına rağmen oluşturulan her bir görüntü parçası ayrı ayrı evrişimsel sinir ağından geçmektedir. Bu işlem maliyetli bir hesaplama tekniği ve tekrarlı bir işlem olduğu için modeli yavaşlatmaktadır. Bu kapsamda Girshick, R-CNN'den farklı olarak her bir görüntü parçasını evrişimsel sinir ağından geçirmek yerine görüntünün tamamını evrişimsel sinir ağından geçirip bu özniteliklerin havuzlamasını teklif etmiştir. Bu işleme ilgi alanı havuzlaması (ROI Pooling) adını vermiştir. Ayrıca R-CNN modelinde ayrı olarak eğitilen ve hafızada tutulan üç farklı model burada tek model içerisinde birleştirilmiştir ve bu modeli Fast R-CNN olarak isimlendirmiştir (Girshick, 2015).

R-CNN ve Fast R-CNN nesnenin olması muhtemel kısımları benzer algoritmalarla elde etmekteydi ve modelin dar boğaz olduğu yer bu bölümdü. Ren ve arkadaşları bu bölgelerin oluşturulması için evrişimsel sinir ağları kullanmıştır ve bu modele Faster R-CNN adını vermiştir (Ren ve ark., 2017).



Şekil 2.24 Bölgesel evrişimsel sinir ağları

2.3.7. Öğrenme Transferi

Gerçek dünyada öğrenme transferi birçok alanda gözlemlenmektedir. Örneğin elmaları tanımayı öğrenmemiz armutları tanımaya yardımcı olacağını öngörebiliriz. Benzer şekilde elektronik klavye çalmayı bilen bir kişi piyano çalmayı daha kolay öğrenebilir. Öğrenme transferi çalışmaları, insanların yeni problemleri çözmek için eski tecrübelerinden öğrendiklerini akıllıca kullanmasını incelemektedir (S. J. Pan & Yang, 2010).

Makine öğrenmesi alanında öğrenme transferi, “Naturel Information Processing System 1995” veya kısa şekliyle NIPS-95 atölyesinde tartışılmış ve günümüz çalışmalarına temel olan “Learning to Learn” kitabı yayınlanmıştır. 1995’ten bu yana git gide artan çalışmalarda öğrenme transferi öğrenmeyi öğrenmek, hayat boyu öğrenim, çoklu görev öğrenme, bilgi birleştirme, bağlama duyarlı öğrenme, bilgiye dayalı tümevarımla öğrenme gibi çeşitli terimlerle adlandırılmıştır (Thrun & Pratt, 1998).

Kaynak domain $\mathcal{D}_s$, öğrenme görevi $\mathcal{T}_s$ ve hedef domain $\mathcal{D}_T$ ve öğrenme görevi $\mathcal{T}_T$ olarak tanımlanır. Öğrenme transferi, $\mathcal{D}_s \neq \mathcal{D}_T$ ve $\mathcal{T}_s \neq \mathcal{T}_T$ durumunda, $\mathcal{D}_s$ ve $\mathcal{T}_s$ ’deki bilgileri kullanarak $\mathcal{D}_T$ domaininde $\mathcal{T}_T$ görevini gerçekleştirebilecek fonksiyonun geliştirilmesine yardım eder.

Derin öğrenme algoritmaları başarıya ulaşmak için oldukça büyük veri setlerine ihtiyaç duymaktadırlar. Veri toplamının masraflı olduğu alanlarda öğrenme transferi oldukça popüler bir çözüm olarak karşılaşılmaktadır. Bu duruma medikal görüntüler üzerine çalışmalar örnek verilebilir. Çözüm olarak daha önce medikal olmayan görüntüler üzerinde eğitilmiş modeller, medikal görüntüler ile ince ayar yapılarak başarılı bir şekilde kullanılmıştır (Carneiro & Nascimento, 2013; Hofmanninger & Langs, 2015; Li ve ark., 2014).

2.3.8. Değerlendirme Yöntemleri

Çalışma kapsamında yapılan karşılaştırmalarda, nesne tanımada oldukça popüler bir değerlendirme yöntemi olan COCO değerlendirme yöntemi ile değerlendirilmiştir. Bu değerlendirme yöntemi, güvenlik skoru (confidence score), kesişimlerin birleşimlere oranı, hatırlama parametreleri ile hesaplanan ortalama hassasiyet kavramı (mAP) etrafında türetilen değerler ile ölçülmektedir (Lin ve ark., 2014).


Keskinlik (precision), bütün pozitif tahminlerde gerçek pozitif sayısıdır ve Denklem 2.16'daki gibi gösterilir. Hatırlama ise bütün gerçek pozitiflerdeki doğru pozitif sayısıdır ve Denklem 2.17'deki gösterilir (Everingham ve ark., 2010).

$$Keskinlik (precision) = \frac{TP}{TP + FP} \quad (2.16)$$

$$Hatırlama (recall) = \frac{TP}{TP + FN} \quad (2.17)$$

Kesişimlerin birleşimlere oranı, model tarafından önerilen sınırlayıcı kutunun referans sınırlayıcı kutuyla kesişiminin birleşime oranıdır. Tahmin, $IoU > eşik\ değer$ olduğu durumda doğru pozitif, $IoU < eşik\ değer$ olduğu durumda yanlış pozitif olarak değerlendirilir (Everingham ve ark., 2010).

$$IoU = \frac{alan(BBox_p \cap BBox_{gt})}{alan(BBox_p \cup BBox_{gt})} \quad (2.18)$$



Şekil 2.25 Kesişimlerin birleşime oranı

Ortalama hassasiyet kavramı (mAP) için ilk olarak hassasiyet kavramının (AP) hesaplanması gereklidir. Hassasiyet kavramı, hesaplanan keskinlik(precision) ve hatırlama(recall) parametrelerinin grafiği ile özetlenmektedir, eşit aralıklı 11 hatırlama aralığındaki keskinlik değerlerinin ortalaması olarak kabul edilir. Her hatırlatma seviyesindeki keskinlik değeri grafikte maksimum interpolasyon yapacak şekilde seçilir. Her bir nesne için hesaplanan hassasiyet değerlerinin (AP) ortalaması alınarak ortalama hassasiyet değeri (mAP) hesaplanır (Everingham ve ark., 2010).

$$AP = \frac{1}{11} \sum_{r \in (0,0.1,...,1)} p_{interp}(r) \quad (2.19)$$

$$p_{interp}(r) = \max p(r)$$



Şekil 2.26 Keskinlik ve hatırlama değerinde maksimum interpolasyon

COCO değerlendirme yönteminde bu mAP değerine ek olarak IoU hesaplamasında eşik değeri 0.5'ten 0.95'e kadar 0.05 adım sayısı ile hesaplanan mAP değerlerinin ortalaması alınır (Lin ve ark., 2014).

$$mAP_{coco} = \frac{mAP_{0.5} + mAP_{0.55} + \dots + mAP_{0.95}}{10} \quad (2.20)$$

Aynı zamanda çalışma kapsamında geliştirilen modellerin diskteki boyutu ve tahmin hızı da karşılaştırılacaktır.



3. GEREÇ VE YÖNTEM

3.1. Kullanılan Veri Seti

Bu çalışmada amacımız öğrenme transferi ile görüntü üzerinde diyabetik ayak ülserinin konumunun tespit edilip sınırlayıcı kutular ile işaretlenmesidir. Bu işlem için tercih edilen yöntem dolayısıyla ilgili uzmanlar tarafından işaretlenmiş veri setine ihtiyaç duyulduğu için Bill Cassidy ve arkadaşları tarafından Birleşik Krallık Ulusal Sağlık Hizmeti Araştırma Etik Komitesi'nden 15/NW/0539 referans numarası ile araştırma için görüntü toplanması onaylanmış olan, 2200 adet işaretli diyabetik ayak ülseri görüntüsü içeren veri seti bu çalışma için kullanılmıştır. Diyabetik ayak ülseri görüntüleri EK-1 deki anlaşma ile Lancashire Araştırma Hastanesinden alınmıştır (Cassidy ve ark., 2020).

Görüntüler, ülser yüzeyine paralel olacak şekilde 30-40 cm uzaklıktan, Kodak DX4530, Nikon D3300 ve Nikon COOLPIX P100 fotoğraf makineleri kullanılarak medikal fotoğrafçılar tarafından alınmıştır. Ana ışık kaynağı olarak flaş kullanımından kaçınılmış ve bunun yerine fotoğraflarda tutarlı renkler elde etmek için oda ışıkları kullanılmıştır. Ön işleme olarak odağı bozuk olan görüntüler elenmiştir. Ayrıca her bir görüntü için anahtar değerler oluşturulmuştur (Cassidy ve ark., 2020).



Şekil 3.1 DFUC 2020 veri setinden rastgele görüntüler

3.2. Kullanılan Yazılım ve Donanım Altyapıları

Bu çalışma aşağıdaki kütüphaneler kullanılarak oluşturulmuştur.

1. PyTorch (Paszke ve ark., 2019)
2. NumPy (Harris ve ark., 2020)
3. OpenCV
4. SciPy (Virtanen ve ark., 2020)
5. Albumentations (Buslaev ve ark., 2020)
6. PyPlot (Hunter, 2007)

Burada PyTorch kütüphanesi yapay sinir ağının tasarlanmasında, evrimsel işlemlerin gerçekleştirilmesinde, kayıp fonksiyonu ve optimizasyon algoritmasının uygulanmasında kullanılmıştır. NumPy kütüphanesi numerik ve matris işlemler için, OpenCV görüntülerin okunması ve sınırlayıcı kutunun görüntü üzerine çizilmesi için, SciPy kütüphanesi veri seti ile ilgili tablolar için, Albumentations kütüphanesi görüntü zenginleştirme için, sonuçları izlemek ve grafikleri görüntülemek için ise PyPlot kütüphanesi kullanılmıştır.

Bunlarla birlikte Intel i5 işlemcili, 16 GB DDR4, 4GB Nvidia GeForce GTX 1050Ti grafik işlem birimli bilgisayar kullanılmıştır. Ayrıca Google Colab servisi kullanılmıştır.

3.3. Ağ Parametreleri, Eğitim ve Eğitim Sonuçları

Bu çalışma kapsamında DFUC2020 veri setinin 2000 diyabetik ayak ülser görüntüsü ile sınırlı olmasından dolayı öğrenme transferi yöntemi tercih edilmiştir.

Faster RCNN-ResNet50 ve Faster RCNN-MobileNetV2 mimarileri daha önce Microsoft COCO veri seti üzerinde eğitilmiş ağırlıkları ile kullanılmıştır.


Teklif edilen her iki model için giriş boyutu 512 x 512, epok sayısı 20, küme boyutu eğitim setinde 8 ve doğrulama setinde 4 olacak şekilde eğitim parametreleri ayarlanmıştır. Optimizasyon algoritması olarak öğrenme oranı 0,005, moment değeri 0,9, ağırlık azalması değeri 0,0009 olan SGD seçilmiştir. Bu değerler her bir model için Çizelge 3.1’de gösterilmiştir.

Epok sayısı Google Colab çalışma sınırından dolayı 20 ile sınırlandırılmıştır. Herhangi bir hiper-parametre optimizasyonuna gidilmemiştir. Optimizasyon algoritmasında kullanılan değerler M-COCO veri setinde kullanılan varsayılan parametrelerdir.

Çizelge 3.1 Teklif edilen yapay sinir ağı eğitim parametreleri

	Opt. Algoritması	Epok Sayısı	Giriş Boyutu	Küme Boyutu (Eğitim, Doğrulama)
Faster R-CNN ResNet50	SGD	20	512 x 512	4, 2
Faster R-CNN MobieNetV2	SGD	20	512 x 512	4, 2

Girdi olarak kullanılan görüntüler yatay, dikey veya hem yatay hem dikey olacak şekilde çevirerek ve rastgele yerlerinde parlaklık ve kontrast değerleri değiştirilerek çeşitlilik artırılmıştır. Burada daha fazla çeşitlendirme metodu işlem maliyetini artırdığı için kaçınılmıştır. Bu işlemler uygulandıktan sonra görüntü Şekil 3.2’de gösterilmiştir.



Şekil 3.2 Girdi görüntülerinde çeşitlilik artırıldıktan sonraki görüntüler


Eğitilen modellerin 20 epok sonrası hızı, diskteki boyutu ve mAP skoru Çizelge 3.2’de gösterilmiştir.

Burada hız Google Colab ortamında test veri setinin GPU üzerine yüklendikten sonra her bir kümeyi test etme süresi üzerinden değerlendirilmiştir. Bir test kümesinde 100 resim olmak üzere toplam 400 test görüntüsü 4 iterasyon ile test edilerek model doğrulanmıştır. Bu doğrulama sureleri ölçülerek test kümesi eleman sayısına bölünerek bir görüntü için işlem süresi hesaplanmıştır.

Çizelge 3.2 Eğitim sonucu teklif edilen modellerin başarı metrikleri


	Hız (ms)	Diskteki boyutu (MB)	mAP
Faster R-CNN ResNet50	24	158	44
Faster R-CNN MobieNetV2	15	120	34

Faster RCNN ResNet50 modelinin DFUC2020 veri seti ile eğitimi sonrası model kayıp grafiği Şekil 3.3’te gösterilmiştir.



Şekil 3.3 Faster RCNN ResNet50 model kayıp grafiği


Bu modelde COCO stili nesne tespitinde kullanılan mAP skoru Şekil 3.4'te gösterilmiştir.




Şekil 3.4 Faster RCNN ResNet modeli mAP skor grafiği

Faster R-CNN ResNet50 mimarili model, veri setinin test için ayrılmış olan grubundan görüntüler ile test edilmiştir. Sonuç referans sınırlayıcı kutular ve tahmin edilen sınırlayıcı kutular Çizelge 3.3’te görülmektedir.


Çizelge 3.3 Faster RCNN ResNet50 mimarili modelin başarılı tahmin sonuçları


Referans	Tahmin
	
	
	




Faster RCNN-ResNet50 mimarili model ile yanlış veya düşük skorlu tahmin edilmiş görüntüler Çizelge 3.4'te verilmiştir.

Çizelge 3.4 Faster RCNN ResNet mimarili modelin basarisiz tahmin sonuçları


Referans	Tahmin
	
	
	
	



Faster RCNN MobileNetV2 modelinin DFUC2020 veri seti ile eğitimi sonrası model kayıp grafiği Şekil 3.5'te mAP skor grafiği ise Şekil 3.6'da gösterilmiştir.



Şekil 3.5 Faster RCNN MobileNetV2 model kayıp grafiği




Şekil 3.6 Faster RCNN MobileNetV2 model mAP skor grafiği

Faster RCNN MobileNetV2 mimarili model, test veri seti ile test edilmiştir. Sonuç olarak doğru tahmin edilen görüntüler Çizelge 3.5'te referans görüntüler ile karşılaştırmalı olarak verilmiştir.

Çizelge 3.5 Faster RCNN MobileNetV2 mimarili modelin doğru tahmin sonuçları

Referans	Tahmin
	
	
	
	



Faster RCNN MobileNetV2 modeli ile hatalı olarak tahmin edilen görüntüler referans sınırlayıcı kutu ile karşılaştırmalı olarak Çizelge 3.6'da verilmiştir.

Çizelge 3.6 Faster RCNN MobileNetV2 mimarili modelin yanlış tahmin sonuçları

Referans	Tahmin
	
	
	
	



4. SONUÇLAR VE TARTIŞMA

Bu çalışma kapsamında Faster RCNN ResNet50 ve Faster RCNN MobileNetV2 mimarileri kullanılarak görüntü üzerinde yara tespiti yapılmıştır. Sınıflandırıcı yapay sinir ağlarında COCO veri setindeki eğitilmiş model ağırlıkları ve bias değerleri kullanılmıştır. Bu ağırlık ve bias değerlerinin üstüne 2200 adet diyabeti ayak ülseri görüntüsünü içeren DFUC2020 veri seti ile eğitilmiştir.

Eğitim sürdürülen 20 epok boyunca COCO mAP değerleri ve kayıp değerleri izlenmiştir. Bu değerler Faster RCNN ResNet50 için kayıp ve mAP değerleri sırasıyla Şekil 3.3 ve Şekil 3.4'te verilmiştir. Model ağırlıkları rastgele yüklenmesi yerine MCOCO veri setinde daha önce eğitilmiş modelin ağırlıkları kullanıldığı için yüksek olmayan kayıp değerleri ile başlamıştır ve beklenen öğrenme eğrisi her iki performans metrik grafiğinde de göreceli olarak sağlanmıştır. Aynı şekilde Faster RCNN MobileNetV2 için ise Şekil 3.5 ve Şekil 3.6'da verilmiştir. Burada da beklenen öğrenme metrikleri görülmüştür. MobileNetV2, ResNet50 mimarisine göre daha yüzeysel bir mimari olduğundan mAP skoru ResNet50 mimarisine göre daha düşük olacağı öngörülmüş ve nihai olarak bu öngörü ile örtüşen sonuçlar elde edilmiştir.

Zaman açısından Faster RCNN ResNet50 modeli tahmini süresi Google Colab ortamında, Çizelge 3.2'de görüldüğü gibi 24 ms olarak hesaplanmıştır. Ancak NVidia GeForce 1050Ti GPU'lu yerel cihazda 500 ms olarak ölçülmüştür. Bu gecikme, temel olarak çalışılan Jupyter Notebook ortamından kaynaklanmıştır. Dondurulan modelin ağırlıkları boyut olarak ise yine Çizelge 3.2'de görüldüğü üzere 158 MB olduğu görülmüştür. Faster RCNN MobileNetV2 mimarili model Google Colab ortamında 10 ms olarak ölçülmüştür ve diskteki model 120 MB olduğu görülmüştür.

Sonuçlar Çizelge 3.3, Çizelge 3.4, Çizelge 3.5 ve Çizelge 3.6'da referans görüntüler ile karşılaştırılmış. ResNet50 modeli geliştirilen nesne belirleme modelinde 43.5 mAP skoru elde edilmiştir. Bu mAP skoru ile çalışma, DFUC2020 yarışmasında gayri resmi olarak 13. sıraya yerleşmektedir. Yarışma dahilindeki çalışmalar Çizelge 4.1'de verilmiştir.

Çizelge 4.1 DFUC 2020 yarışmasında teklif edilen diğer mimarilerin mAP skorları ve bu çalışma kapsamında elde edilen mAP skoru

#	Takım	mAP
1	Ryo Hachiuma	69
2	Raphael Brüngel	69
3	Fangzhao Li	66
4	Azadeh Alavi	66
5	Moshe Olshansky	65
6	Zu Hongtao	64
7	Xiao Huang	64
8	Reza Basiri	61
9	Yongsheng Pan	59
10	Manu Goyal	57
11	Artur Costa	56
12	Shuhui Jia	48
13	Bu çalışma	43

Faster RCNN Resnet50 modeli beklenildiği üzere daha başarılı olduğu görülmüştür. Ten rengi, kontrast, ortam aydınlatması gibi değişken şartlarda yapılan tahminler başarılıdır. Skoru düşük olarak gözlemlenen tahminlerde ise sınıflandırma doğru ancak teklif edilen bölgeler hatalıdır. Bir yara üzerinde birden fazla alan üzerine odaklanmıştır. Bu hata, yaranın bulunduğu yüzeyin bozukluğundan meydana gelmektedir. Sağlıklı deri ve yara sınırlarının öz niteliklerinin çıkarılamaması bu hatayı artırmaktadır. Ayrıca yüzeyi bozulmuş tırnak görüntüleri de yara yüzeyinden ayırmakta güçlük çekildiği görülmüştür. Bu tırnak görüntülerinin yara öz niteliklerine benzerliğinden kaynaklanmaktadır. Daha geniş bir veri seti bu hataları azaltabilir.

Faster RCNN MobliNetV2 modeli mAP skoru 34 olarak hesaplanmıştır. Bu model Faster RCNN ResNet50 modeline göre daha yüzeysel bir model olup hesaplama maliyeti açısından düşük işlem kapasiteli donanımlar için daha uygundur. Bu sebeple, ARM mimarili sistemlerde ve gerçek zamanlı uygulamalarda bu model kullanılabilir. Geliştirilen model çeşitli ışık, kontrast, renk ve büyüklükteki diyabetik ayak yara bölgelerini tanıyabilmektedir. Hesaplanan mAP skorundan da tahmin edilebileceği üzere Faster RCNN ResNet50 modeline göre görüntünün daha karışık bölgelerinde hatalı tahminler yapması daha olasıdır. Çizelge 3.6'da da görülebileceği gibi Faster RCNN ResNet50 ile yüksek skor ile

tanımlanmış bir yara görüntüsü Faster RCNN MobileNetV2 ile 0.5 mAP skorunun altında kaldığı için tanınmamıştır.

Bu gelişmelerin yanı sıra uzak grafik işlem birimi ile ve sınırlı kaynaklı yerel grafik işlem birimi ile çalışmalar yapılmıştır. Geliştirme sürecinde ortaya çıkabilecek hesaplama maliyeti, süresi üzerine ve veri seti ile ilgili hukuki, lisans, etik problemler üzerine tecrübe edinilmiştir. Bu tecrübeleri endüstriye ve akademiye olumlu yansıyacağı düşünülmektedir.

Derin öğrenme üzerine yapılan yarışmalar ve bu yarışmalara katkıda bulunan akademik ve akademik olmayan birey ve takımların gayreti ve kat edilen ilerlemelerin farklı domainlere kaydırılarak çalışmaların genişletilebildiği gözlemlenmiştir.

KAYNAKLAR DİZİNİ

- Aalaa, M., Malazy, O. T., Sanjari, M., Peimani, M., & Mohajeri-Tehrani, M. R.** (2012). Nurses' role in diabetic foot prevention and care; a review. *Journal of Diabetes and Metabolic Disorders*, 11(1), 1–6. <https://doi.org/10.1186/2251-6581-11-24>
- Bengio, Y., Simard, P., & Paolo, F.** (1994). Learning Long-Term Dependencies with Gradient Descent is Difficult. *IEEE Transactions on Neural Networks*, 5, 157–166.
- Bureau international des poids et mesures.** (2019). *Édition 2019*.
- Bus, S. A., Netten, J. J. van, Lavery, L. A., Monteiro-Soares, M., Ramussen, A., Jubiz, Y., & Price, P. E.** (2016). IWGDF guidance on the prevention of foot ulcer in at-risk patients with diabetes. *International Working Group on the Diabetic Foot*, 32(30), 16–24. <https://doi.org/10.1002/dmrr>
- Buslaev, A., Iglovikov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M., & Kalinin, A. A.** (2020). Albumentations: Fast and flexible image augmentations. *Information (Switzerland)*, 11(2). <https://doi.org/10.3390/info11020125>
- Carneiro, G., & Nascimento, J. C.** (2013). Combining multiple dynamic models and deep learning architectures for tracking the left ventricle endocardium in ultrasound data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(11), 2592–2607. <https://doi.org/10.1109/TPAMI.2013.96>
- Cassidy, B., Reeves, N. D., Joseph, P., Gillespie, D., O'Shea, C., Rajbhandari, S., Maiya, A. G., Frank, E., Boulton, A., Armstrong, D., Najafi, B., Wu, J., & Yap, M. H.** (2020). DFUC 2020: Analysis towards diabetic foot ulcer detection. *ArXiv*, 1–10.
- Cho, N. H., Shaw, J. E., Karuranga, S., Huang, Y., da Rocha Fernandes,**

- J. D., Ohlrogge, A. W., & Malanda, B.** (2018). IDF Diabetes Atlas: Global estimates of diabetes prevalence for 2017 and projections for 2045. *Diabetes Research and Clinical Practice*, 138, 271–281. <https://doi.org/10.1016/j.diabres.2018.02.023>
- Codella, N. C. F., Gutman, D., Celebi, M. E., Helba, B., Marchetti, M. A., Dusza, S. W., Kalloo, A., Liopyris, K., Mishra, N., Kittler, H., & Halpern, A.** (2018). Skin lesion analysis toward melanoma detection: A challenge at the 2017 International symposium on biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC). *Proceedings - International Symposium on Biomedical Imaging, 2018-April*, 168–172. <https://doi.org/10.1109/ISBI.2018.8363547>
- Crawford, B. H.** (1949). The scotopic visibility function. *Proceedings of the Physical Society. Section B*, 62(5), 321–334. <https://doi.org/10.1088/0370-1301/62/5/305>
- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A.** (2010). The pascal visual object classes (VOC) challenge. *International Journal of Computer Vision*, 88(2), 303–338. <https://doi.org/10.1007/s11263-009-0275-4>
- Felzenszwalb, P. F., & Huttenlocher, D. P.** (2015). *Efficient Graph-Based Image Segmentation*. Pedro. 1–26. [papers3://publication/uuid/D1250C05-2FC7-4954-A734-E33EBBEECB95](https://arxiv.org/abs/1505.04596)
- Gessert, N., Nielsen, M., Shaikh, M., Werner, R., & Schlaefer, A.** (2019). Skin lesion classification using ensembles of multi-resolution efficientnets with meta data. *ArXiv*.
- Gil, S. B.** (2020). Implementing the triangle of wound assessment framework to transform the care pathway for diabetic foot ulcers. *Journal of Wound Care*, 29(6), 363–369. <https://doi.org/10.12968/jowc.2020.29.6.363>
- Girshick, R.** (2015). Fast R-CNN. *Proceedings of the IEEE International*

Conference on Computer Vision, 2015 Inter, 1440–1448.
<https://doi.org/10.1109/ICCV.2015.169>

Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 580–587.
<https://doi.org/10.1109/CVPR.2014.81>

Glorot, X., Bordes, A., & Bengio, Y. (2011). Deep Sparse Rectifier Neural Networks Xavier. *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*.
<https://doi.org/10.1002/ecs2.1832>

Gonzalez, R. C., Woods, R. E., & Masters, B. R. (2009). Digital Image Processing, Third Edition. *Journal of Biomedical Optics*, 14(2), 029901.
<https://doi.org/10.1117/1.3115362>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*.

Goyal, M., Reeves, N. D., Rajbhandari, S., Ahmad, N., Wang, C., & Yap, M. H. (2020). Recognition of ischaemia and infection in diabetic foot ulcers: Dataset and techniques. *Computers in Biology and Medicine*, 117, 103616. <https://doi.org/10.1016/j.compbimed.2020.103616>

Han, G., & Ceilley, R. (2017). Chronic Wound Healing: A Review of Current Management and Treatments. *Advances in Therapy*, 34(3), 599–610. <https://doi.org/10.1007/s12325-017-0478-y>

Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., del Río, J. F., Wiebe, M., Peterson, P., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357–362. <https://doi.org/10.1038/s41586-020-2649-2>

He, K., Zhang, X., Ren, S., & Sun, J. (1994). Deep residual learning for

image recognition. *IEEE Transactions on Neural Networks*, 157–166.
<https://doi.org/10.1109/CVPR.2016.90>

Hoerl, A. E., & Kennard, R. W. (1970). Ridge Regression: Biased Estimation for Nonorthogonal Problems. *Technometrics*, 12(1), 55–67.
<https://doi.org/10.1080/00401706.1970.10488634>

Hofmanninger, J., & Langs, G. (2015). Mapping visual features to semantic profiles for retrieval in medical imaging. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 07-12-June, 457–465.
<https://doi.org/10.1109/CVPR.2015.7298643>

Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *ArXiv*.

Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science and Engineering*, 9(3), 90–95.
<https://doi.org/10.1109/MCSE.2007.55>

Keast, D. H., Bowering, C. K., Evans, A. W., Mackean, G. L., Burrows, C., & D’Souza, L. (2004). Contents. MEASURE: A proposed assessment framework for developing best practice recommendations for wound assessment. *Wound Repair and Regeneration*, 12(s1), s1–s17.
<https://doi.org/10.1111/j.1067-1927.2004.0123s1.x>

Kelber, A., Balkenius, A., & Warrant, E. J. (2002). Scotopic colour vision in nocturnal hawkmoths. *Nature*, 419(6910), 922–925.
<https://doi.org/10.1038/nature01065>

Kriss, M. A., Macdonald, L. W., Fairchild, M. D., Ebner, M., & Ed, P. G. (n.d.). *Measuring Colour*.

Krizhevsky, A., Sutskever, I., & Hinton, G. (2017). ImageNet Classification with Deep Convolutional Neural Networks.

Communications of the ACM, 84–90.
<https://doi.org/10.1201/9781420010749>

Kulathunga, N., Ranasinghe, N. R., Vrinceanu, D., Kinsman, Z., Huang, L., & Wang, Y. (2020). *Effects of the Nonlinearity in Activation Functions on the Performance of Deep Learning Models*.
<http://arxiv.org/abs/2010.07359>

Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>

Li, R., Zhang, W., Suk, H., Wang, L., Li, J., Shen, D., & Ji, S. (2014). Deep Learning Based Imaging Data Completion for Improved Brain Disease Diagnosis. *International Conference on Medical Image Computing and Computer Assisted Intervention*, 305–312.

Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8693 LNCS(PART 5), 740–755.
https://doi.org/10.1007/978-3-319-10602-1_48

McLennan, S., Yue, D., & Twigg, S. (2006). Molecular Aspects of Wound Healing in Diabetes. *Primary Intention: The Australian Journal of Wound Management*, 14(1).

Meyer, P., Noblet, V., Mazzara, C., & Lallement, A. (2018). Survey on deep learning for radiotherapy. *Computers in Biology and Medicine*, 98(March), 126–146.
<https://doi.org/10.1016/j.combiomed.2018.05.018>

Nichols, E. (2015). Wound assessment part 1 : how to measure a wound. *Wound Essentials*, 10(2), 51–55.

Pan, J., Liu, C., Wang, Z., Hu, Y., & Jiang, H. (2012). Investigation of Deep Neural Networks (DNN) for large vocabulary continuous speech

recognition: Why DNN surpasses GMMS in acoustic modeling. *2012 8th International Symposium on Chinese Spoken Language Processing, ISCSLP 2012*, 301–305. <https://doi.org/10.1109/ISCSLP.2012.6423452>

Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>

Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Köpf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., ... Chintala, S. (2019). PyTorch: An imperative style, high-performance deep learning library. *ArXiv, NeurIPS*.

Pokorná, A., & Leaper, D. (2015). Assessment and documentation of non-healing, chronic wounds in inpatient health care facilities in the czech republic: An evaluation study. *International Wound Journal*, 12(2), 224–231. <https://doi.org/10.1111/iwj.12372>

Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2017). Deep Learning for Health Informatics. *IEEE Journal of Biomedical and Health Informatics*, 21(1), 4–21. <https://doi.org/10.1109/JBHI.2016.2636665>

Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>

Rumelhart, David E.; Hinton, Geoffrey E.; Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533–536. <https://doi.org/10.1016/j.measurement.2017.09.025>

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., & Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition

Challenge. *International Journal of Computer Vision*.
<https://doi.org/10.1007/s11263-015-0816-y>

Russell, S., & Norvig, P. (1995). Artificial Intelligence: A Modern Approach. In *Manufacturing Engineer* (Vol. 74, Issue 3).
<https://doi.org/10.1049/me:19950308>

Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, 61, 85–117.
<https://doi.org/10.1016/j.neunet.2014.09.003>

Schultz, G. S., Barillo, D. J., Mozingo, D. W., Chin, G. A., Ayello, E., Dowsett, C., Falanga, V., Harding, K., Romanelli, M., Sibbald, G., Stacey, M., Teot, L., & Vanscheidt, W. (2004). Wound bed preparation and a brief history of TIME. *International Wound Journal*, 1(1), 19–32.
<https://doi.org/10.1111/j.1742-481x.2004.00008.x>

Schwing, A. G., & Urtasun, R. (2015). *Fully Connected Deep Structured Networks*. 1–10. <http://arxiv.org/abs/1503.02351>

Shah, A., Wollak, C., & Shah, J. B. (2013). Wound Measurement Techniques: Comparing the Use of Ruler Method, 2D Imaging and 3D Scanner. *Journal of the American College of Clinical Wound Specialists*, 5(3), 52–57. <https://doi.org/10.1016/j.jccw.2015.02.001>

Shahbazian, H., Yazdanpanah, L., & Latifi, S. M. (2013). Risk assessment of patients with diabetes for foot ulcers according to risk classification consensus of international working group on diabetic foot (IWGDF). *Pakistan Journal of Medical Sciences*, 29(3), 730–734.
<https://doi.org/10.12669/pjms.293.3473>

Smith, V. C., & Pokorny, J. (1975). Spectral sensitivity of the foveal cone photopigments between 400 and 500 nm. *Vision Research*, 15(2), 161–171. [https://doi.org/10.1016/0042-6989\(75\)90203-5](https://doi.org/10.1016/0042-6989(75)90203-5)

Song, B. (2012). *An Automated Wound Identification System Based On Image Segmentation and Artificial Neural Networks*. June.

- Stockman, A., MacLeod, D. I. A., & Johnson, N. E.** (1993). Spectral sensitivities of the human cones. *Journal of the Optical Society of America A*, 10(12), 2491. <https://doi.org/10.1364/josaa.10.002491>
- Suzuki, K., Armato, S. G., Li, F., Sone, S., & Doi, K.** (2003). Massive training artificial neural network (MTANN) for reduction of false positives in computerized detection of lung nodules in low-dose computed tomography. *Medical Physics*, 30(7), 1602–1617. <https://doi.org/10.1118/1.1580485>
- Thrun, S., & Pratt, L.** (1998). Learning to learn. In *Library of Congress Cataloging-in-Publication Data*. <https://doi.org/10.1109/DEVLRN.2007.4354070>
- Uijlings, J. R. ., van de Sande, K. E. ., Gevers, T., & Smeulders, A. W. .** (n.d.). Selective Search for Object Recognition. *Technical Report 2012, Submitted to IJCV*. <https://doi.org/10.1109/FG.2018.00058>
- Virtanen, P., Gommers, R., Oliphant, T. E., Haberland, M., Reddy, T., Cournapeau, D., Burovski, E., Peterson, P., Weckesser, W., Bright, J., van der Walt, S. J., Brett, M., Wilson, J., Millman, K. J., Mayorov, N., Nelson, A. R. J., Jones, E., Kern, R., Larson, E., ... Vázquez-Baeza, Y.** (2020). SciPy 1.0: fundamental algorithms for scientific computing in Python. *Nature Methods*, 17(3), 261–272. <https://doi.org/10.1038/s41592-019-0686-2>
- Wendland, D. M., & Taylor, D. W. M.** (2017). Wound Measurement Tools and Techniques. *Journal of Acute Care Physical Therapy*, 8(2), 42–57. <https://doi.org/10.1097/jat.0000000000000050>
- Yap, M. H., Chatwin, K. E., Ng, C. C., Abbott, C. A., Bowling, F. L., Rajbhandari, S., Boulton, A. J. M., & Reeves, N. D.** (2018). A New Mobile Application for Standardizing Diabetic Foot Images. *Journal of Diabetes Science and Technology*, 12(1), 169–173. <https://doi.org/10.1177/1932296817713761>

- Yazdanpanah, L.** (2015). Literature review on the management of diabetic foot ulcer. *World Journal of Diabetes*, 6(1), 37. <https://doi.org/10.4239/wjd.v6.i1.37>
- Young, S.** (2019). Wound assessment. *British Journal of Community Nursing*, 24(February), S5. <https://doi.org/10.12968/bjcn.2019.24.Sup9.S5>
- Yuan, Q., Chen, Y.** (Frank), Yang, J., & Zhou, Y. (2018). Joint Control of Emissions Permit Trading and Production Involving Fixed and Variable Transaction Costs. *Production and Operations Management*, 27(8), 1420–1454. <https://doi.org/10.1111/poms.12875>
- Zeiler, M. D., & Fergus, R.** (2013). Stochastic pooling for regularization of deep convolutional neural networks. *1st International Conference on Learning Representations, ICLR 2013 - Conference Track Proceedings*, 1–9.
- Zhang, P., Lu, J., Jing, Y., Tang, S., Zhu, D., & Bi, Y.** (2017). Global epidemiology of diabetic foot ulceration: a systematic review and meta-analysis†. *Annals of Medicine*, 49(2), 106–116. <https://doi.org/10.1080/07853890.2016.1231932>

TEŞEKKÜR

Yüksek lisans eğitimim boyunca desteklerini esirgemeyen çalışma için gerekli materyalleri sağlayan yapıcı eleştirileri ve bilimsel bakış açısı ile çalışmayı yönlendiren sayın Doç. Dr. Evren Homan GÖKÇE hocama teşekkürlerimi ve saygılarımı sunarım.

Çalışma boyunca desteklerini esirgemeyen bilgisayar görüşü ve derin öğrenme konusunda muazzam bilgi ve tecrübeye sahip arkadaşım Uysal ALTAŞ'a teşekkür ederim.



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, Adı : Akyol, Mehmet Cihat

Eğitim

Yüksek Lisans Ege Üniversitesi
Biyomedikal Teknolojiler

Lisans Afyonkarahisar Üniversitesi
Biyomedikal Mühendisliği

İş Denevimi

2018 Kütahya Dumlupınar Üniversitesi Bursiyer
FOTAM Laboratuvarı

2020 Cezeri Teknoloji Yazılım
Geliştirici/
Biyomedikal
Mühendisi

Yabancı Dil

İngilizce / İleri Düzey

EKLER

Ek 1. Sözleşme

Diabetic Foot Ulcer Dataset: Release Agreement

Introduction:

The goal of the Diabetic Foot Ulcer (DFU) Dataset is to develop new techniques, technology, and algorithms for the automatic interpretation and analysis of ulcers. Lancashire Teaching Hospital ("LTH") has copyright on the data and is the principal distributor of the DFU Dataset. Manchester Metropolitan University ("MMU") is involved in an ongoing effort to develop this dataset and provide the compatible version of ground truth annotations for computer algorithm. The dataset is meant to aid research efforts in the general area of developing, testing and evaluating algorithms for DFU analysis.

Release of the dataset:

To advance the state-of-the-art in DFU research and analysis, this dataset is made available to the research community. To receive access to the dataset, for non-commercial research into DFU analysis and other branches of related research, you must sign this document agreeing to the conditions and restrictions listed below:

Consent:

I/We agree to the following conditions and restrictions of access and use of the DFU Dataset:

1. **Redistribution:** Without prior written approval from LTH and MMU, the DFU Dataset, will not be further distributed, published, copied, or disseminated in any way or form whatsoever, in whole or in part, whether for profit or not. This includes further distributing, copying or disseminating to a different facility, department or organisational unit within any university, organisation, or company.
2. **Modification and Commercial Use:** Without prior written approval from LTH and MMU, the DFU Dataset, in whole or in part, should not be modified or used for commercial purposes. If any unauthorised use is made of the Dataset and such use is attributable to your act or default then, without prejudice to MMU's other rights and remedies, LTH and MMU can terminate this Agreement with immediate effect by serving you with written notice.
3. **Requests for the DFU Dataset:** All requests for the DFU Dataset will be forwarded to MMU Principal Investigator(s).
4. **Publication Requirements:** Where permitted to publish by agreement of LTH and MMU, publication will be restricted to paper, web-based data and image data, for scientific purposes only.
5. **Intellectual Property Rights Ownership:** You acknowledge that all Intellectual Property Rights in the DFU Dataset are the property of LTH and MMU, as the case may be; and you shall have no rights in or to the DFU Dataset other than the right to use it in accordance with the express terms of this Agreement. You assign to MMU, and shall assign to it, with full title guarantee all Intellectual Property Rights arising from the use of the Dataset, by way of future assignment. You shall use all reasonable endeavours to procure that any necessary third party shall, at MMU's cost, promptly execute such documents and perform such acts as may reasonably be required for the purpose of giving full effect to this Agreement. The Intellectual Property Rights assigned to MMU shall be deemed to be included in the Release of the Dataset from the date when such rights arise.

Ek 1 Sözleşme (Devam)

6. **Citation/Reference:** All documents and papers that report on research that uses the DFU Dataset will acknowledge the use of the dataset by including an appropriate citation to the following:

For users who report on Part A DFU dataset for healthy and DFU skin classification should include a citation to:

Goyal, M., Reeves, N.D., Davison, A.K., Rajbhandari, S., Spragg, J. and Yap, M.H. (2018), *DFUNet: Convolutional neural networks for diabetic foot ulcer classification*, *IEEE Transactions on Emerging Topics in Computational Intelligence*. doi: [10.1109/TETCI.2018.2866254](https://doi.org/10.1109/TETCI.2018.2866254)

For users who report on Part B DFU dataset for ischaemia and infection skin classification should include two citations to:

Goyal, M., Reeves, N.D., Rajbhandari, S. and Yap, M.H., 2018. *Robust methods for real-time diabetic foot ulcer detection and localization on mobile devices*. *IEEE journal of biomedical and health informatics*, 23(4), pp.1730-1741.

Goyal, M., Reeves, N.D., Rajbhandari, S., Ahmad, N., Wang, C. and Yap, M.H., 2020. *Recognition of ischaemia and infection in diabetic foot ulcers: Dataset and techniques*. *Computers in Biology and Medicine*, p.103616. <https://www.sciencedirect.com/science/article/pii/S0010482520300160>

7. **Publications to MMU:** A copy of all reports and papers that are for public or general release that use the DFU Dataset should be forwarded immediately upon release or publication to MMU Principal Investigator(s).
8. **Termination:** MMU may terminate this Agreement (wholly or in part) at any time with immediate effect. Either party may terminate this Agreement with immediate effect by giving written notice to the other party if the other party commits a material breach of any term of this Agreement and (if that breach is remediable) fails to remedy that breach within a period of 30 days after being notified in writing to do so.
9. **Assignment:** This Agreement is personal to you and you shall not assign, transfer, mortgage, charge, sub-contract, declare a trust of or deal in any other manner with any of its rights and obligations under this Agreement without the prior written consent of the MMU. You confirm that you are acting on your own behalf and not for the benefit of any other person or organisation. MMU may at any time assign, transfer, mortgage, charge, sub-contract, declare a trust of or deal in any other manner with any of its rights and obligations under this Agreement without your consent.
10. **No Warranty:** THE PROVIDER OF THE DATA MAKES NO REPRESENTATIONS AND EXTENDS NO WARRANTIES OF ANY KIND, EITHER EXPRESSED OR IMPLIED. THERE ARE NO EXPRESS OR IMPLIED WARRANTIES OF MERCHANTABILITY OR FITNESS FOR A PARTICULAR PURPOSE, OR THAT THE USE OF THE MATERIAL WILL NOT INFRINGE ANY PATENT, COPYRIGHT, TRADE-MARK, OR OTHER PROPRIETARY RIGHTS.
11. **Governing Law:** This Agreement and any dispute or claim arising out of or in connection with it or its subject matter or formation (including non-contractual disputes or claims) shall be governed by and construed in accordance with the law of England and Wales.
12. **Jurisdiction:** Each party irrevocably agrees that the courts of England and Wales shall have exclusive jurisdiction to settle any dispute or claim arising out of or in connection with this agreement or its subject matter or formation (including non-contractual disputes or claims). The MMU, LTH or the Principal investigators of DFU dataset accept no liability for any action resulting from inappropriate use of the images that falls outside of the terms of this agreement.
13. **Access:** The user may only use the datasets after this License Agreement has been signed by his/her group

Ek 1 Sözleşme (Devam)

leader or professor (who has fixed position in the data requiring institution). If a student is sending the email, the email should be copied to the leader or professor who has signed the License Agreement.

By signing this license agreement, I agree that all students and researchers that reported to me are eligible of using the data. I am familiar with the latest EU General Data Protection Regulation (GDPR), and I am responsible for controlling my research group gets access to the data, how the data will be stored and used properly according to GDPR. I am fully responsible if any issue rises in relation to the GDPR on the usage of shared data in my group.

Signature: 

Name (please print): Evren Homan Göktepe

Role: Associate Professor

Date: 21.06.2020

Email: evren.homan.goktepe@ege.edu.tr

Organisation: Ege University

Address: Ege University Campus
35100 Bornova - Izmir

DFU Dataset Principal Investigators:
Neil Reeves at N.Reeves@mmu.ac.uk or Moi Hoon Yap at M.Yap@mmu.ac.uk
Rajbhandari Satyan at Satyan.Rajbhandari@htr.nhs.uk

Address: Manchester Metropolitan University, Department of Computing, Mathematics and Digital Technology, John Dalton Building, Chester Street, Manchester M1 5GD.

Please email a scanned signed copy to Moi Hoon Yap at M.Yap@mmu.ac.uk

1

