



T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

EVRİŞİMSEL SİNİR AĞLARI KULLANARAK CİLT KANSERİ RİSK DEĞERLENDİRMESİ

Sarmad Mohsen Ali HURMUZI

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Kasım-2019
KONYA
Her Hakkı Saklıdır

ÖZET

YÜKSEK LİSANS TEZİ
EVRİŞİMSEL SİNİR AĞLARI KULLANARAK CİLT KANSERİ RİSK DEĞERLENDİRMESİ

Sarmad Mohsen Ali HURMUZI

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendislik Anabilim Dalı

Prof. Dr. Harun Uğuz

2019, 44 Sayfa

Jüri
Danışmanın Prof. Dr. Harun UĞUZ
Doç. Dr. Halife KODAZ
Doç. Dr. Erdinç KOÇER

Cilt kanseri insanları tehdit eden ve en sık görülen kanser türlerindendir. Göğüs, prostat, akciğer ve kolon kanseri ile hastalanan insanların sayısına göre, cilt kanseri insanlarda daha yaygın olan bir hastalıktır. Cilt kanseri, teşhisi doktorlar tarafından ciltten veya benlerden örnek alınarak yapılan ve uzmanlık isteyen bir kanser türüdür.

Bu tez çalışması kapsamında Evrişimli Sinir Ağları kullanılarak cilt kanser riskinin değerlendirilmesi için bir model oluşturulmuştur. Bu amaçla ISIC (The International Skin Imaging Collaboration) veri seti kullanılarak oluşturulan modelin başarası literatürde yer alan makine öğrenmesi ve evrişimsel sinir ağları ile gerçekleştirilen diğer çalışmaların başarıları ile kıyaslanmıştır. Yapılan değerlendirmeler neticesinde önerilen modelin başarısı, diğer çalışmalarla kıyaslanabilir seviyede bulunmuştur.

Anahtar kelimeler:

Cilt kanseri, ESA, ISIC veri kümesi, Derin öğrenme.

ABSTRACT

MS THESIS

SKIN CANCER RISK ASSESSMENT USING CONVOLUTIONAL NEURAL NETWORK

Sarmad Mohsen Ali HURMUZI

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF SELÇUK UNIVERSITY THE DEGREE OF MASTER OF SCIENCE IN COMPUTER ENGEENİRİNG

Prof. Dr. Harun Uğuz

2019, 44 Pages

Jury
Advisor Prof. Dr. Harun UĞUZ
Assoc. Prof. Dr. Halife KODAZ
Assoc. Prof. Dr. Erdinç KOÇER

Skin cancer is one of the most common types of cancer that threatens people. According to the number of people with breast, prostate, lung and colon cancer, skin cancer is more common in humans. Skin cancer is a type of cancer that is diagnosed by doctors by taking samples from the skin or moles and requires expertise.

Within the scope of this thesis, a model has been developed for the evaluation of skin cancer risk by using Convective Neural Networks. For this purpose, the success of the model, which was created by using ISIC (The International Skin Imaging Collaboration) dataset, was compared with the achievements of other studies performed with machine learning and convolutional neural networks in the literature. As a result of the evaluations, the success of the proposed model was found to be comparable to other studies.

Keyword

Skin cancer, CNN, ISIC dataset, Deep learning.

ÖNSÖZ

Yüksek Lisans eğitimim boyunca ve bu çalışmanın gerçekleştirilmesinde değerli bilgilerini benimle paylaşan, kıymetli zamanını ayırıp, sabırla ve büyük bir ilgiyle bana faydalı olabilmek için elinden geleni daha fazlasını sunan, en ufak bir sorunda bile yanına hiç çekinmeden gidebildiğim, güler yüzünü ve samimiyetini benden hiç esirgemeyen, gelecekteki mesleki hayatımda bana verdiği değerli bilgilerden faydalanabileceğimi düşündüğüm, değerli hocam Prof. Dr. Harun UĞUZ'a teşekkürü bir borç bilir ve şükranlarımı sunuyorum.

Bunun yanı sıra, bu çalışmanın başından beri en büyük destekçim olan ve çalışma esnasında ani bir şekilde vefat eden rahmetli babama çok minnettarım. Fiziksel olarak yanımızdan ayrılmış olsa da, ruhunu her zaman yanımızda hissediyor ve kalbimizde hatıralarını taşıyoruz. Çalışmanın sonunda da yanımda olmasını çok isterdim, fakat eminim ki o bir yerlerden beni görüyor ve benimle gurur duyuyordur.

Hayatım boyunca maddi ve manevi desteklerini esirgemeyen, aldığım her kararda arkamda duran, hoşgörü ve sabırla bugünlere gelmemi sağlayan çok kıymetli annem, eşim, kardeşlerim ve tüm arkadaşlarıma saygı ve teşekkürlerimi sunarım.

Aynı zamanda birlikte çalıştığım Özenir Değirmen ekibine, derslerimi ve çalışmalarımı birlikte sürdürebilmem için gösterdikleri anlayıştan dolayı çok teşekkür ederim ve her zaman bana destek oldukları için çok minnettarım.

Sarmad HURMUZII
KONYA-2019

İÇİNDEKİLER

ÖZET ..... **iv**

ABSTRACT ..... **v**

ÖNSÖZ ..... **vi**

İÇİNDEKİLER ..... **vii**

SİMGELER VE KISALTMALAR ..... **viii**

1. GİRİŞ **1**

1.1. Tezin Amacı 2
1.2. Tezin Önemi 2
1.3. Literatüre Katkısı 3

2. KAYNAK ARAŞTIRMASI **4**

3. MATERYAL VE YÖNTEM **12**

3.1. Veri kümesi 12
3.2. Dermoskopi Görüntüler 12
3.3. Evrişimsel Sinir Ağları (ESA) 13
3.3.1. Evrişim katmanı (Convolutional layer) 13
3.3.2. Havuzlama katman (Pooling layer) 14
3.3.3. Tamamen bağlı katman (Fully connected layer) 16
3.3.4. Eğitim stratejisi 16
3.3.5. ESA mimarisi 19
3.3.6. Aktivasyon fonksiyonu 21

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA **24**

4.1. Araştırmalar 24
4.1.1. Veri kümesi ön işlemesi: 24
4.1.2. ESA model: 25
4.1.3 ESA mimarisi 25
4.1.4 Model değerlendirmesi: 26
4.2. Sonuçlar 27
4.3. Tartışma 37

5. SONUÇLAR VE ÖNERİLER **39**

5.1. Sonuçlar 39
5.2. Öneriler 40

KAYNAKLAR **41**

ÖZGEÇMİŞ **44**

SİMGELER VE KISALTMALAR

Kısaltmalar

AUC Area Under The Curve

CIELAB Renk Alanı Tabanlı Segmentasyon

CNN Convolutional Neural Network

ESA Evrişimsel Sinir Ağları

FN False Negative

FP False Positive

GSH L-Glutatyon

ISBI International Symposium on Biomedical Imaging

ISIC International Skin Imaging Collaboration

MSN Mezofor Silika Nanopartikül

MSNs Mezofor Silika Nanopartiküller

ROC Receiver Operating Characteristic

TN True Negative

TP True Positive

1. GİRİŞ

Kanser hastalığı, vücuttaki herhangi organa ya da dokulardaki hücrelerin kontrolsüz ve düzensiz çoğalması ile sağlıklı ve normal hücrelere yer bırakmaması durumunda belirene kötü söylenir. Genel anlamında kanser vücuttaki hastalıklı hücreleri kontrolsüz yayılması ile oluşmaktadır. Kanser hastalığının yüzden fazla çeşidi bulunmaktadır. Bu kadar çeşitli olmasına rağmen, hepsi doğal olmayan hasta hücrelerin yayılmasını kontrol edilememesi ile başlar. Teşhisi yapılıp tedavi edilemese vücutta ciddi bir hastalıklara sebep olup ölümle dahi sonuçlanabilir. Tek bir organı etkileyebildiği gibi diğer organlarıda etkileyebilmektedir. Kansere neden olan anormal hücreler birikerek iyi ya da kötü huylu tümörler oluşturabilirler. İyi huylu olan tümör, kanser türü değildir ve çoğunlukla tekrarlanmazlar. Bu türlü tümörlere insanların hayatını tehdit etmesi çok nadirdir. Ancak diğer tümörler türleri insanın hayatının tehdidi kanserdir. Kötü huylu tümörlerde bulunan hücreler hasta ve anormal olduklarını denilir. Bu hasta olan hücreler kontrolsüz şekilde ve düzensiz halde bölünür.

Kanser olan tümörler normal dokulara sarılıp zarar verebilir, hücrelerin içine sızabilir veya tahrip etmek imkânı vardır. Dünya Sağlık Örgütüne bağlı Uluslararası Kanser Araştırmaları Kurumunun 2030 yılı için öngörüsü, ölüm sebepleri arasında kanser birinci sıraya gelmek yönündedir. Bu nedenle birçok kanser tedavi yöntemleri araştırılmış, hala da araştırılmaya devam edilmektedir. Kanser tedavisinde başlıca amaç; sağlıklı dokulara herhangi bir zarar vermeden hastalıklı dokuları tespit etmek ve yok etmektir. Günümüzde kanser tedavisinde; kimyasal tedavi, ışın tedavisi ve cerrahi yöntemler en yaygın olarak başvurulan yöntemler olmakla birlikte, kök hücre tedavisi, çeşitli hormonsal tedaviler ve çeşitli biyolojik yöntemler de kullanılmaktadır. Kemoterapi, kanserin tipine ve evresine göre kanseri tedavi etmek, yayılımını önlemek, tümörün büyümesini yavaşlatmak ve vücudun farklı bölgelerine yayılmış kanser hücrelerini yok etmek amacıyla uygulanır. Bazı durumlarda kimyasal tedavi tek tedavi seçeneğidir, bazen de kimyasal tedavi diğer tedavilerle (cerrahi ve ışın tedavisi) arka arkaya veya eş zamanlı olarak uygulanır.

Cerrahi öncesi tümörü küçültmek emeliyle veya operasyondan sonra dağılmasını önlemek için gözetici emelli kimyasal tedavi yapılabilir. Aynı uygulamalar ışın tedavisi evvelinde ve sonrasında yapılabildiği gibi, ışın tedavisi ile aynı anda da kimyasal tedavi yapılabilir. Kimyasal tedavi rehabilitasyonundaki en büyük kısıtlamalardan biri; kimyasal tedavi ilaçlarının kanser hücrelerine tesir ederken öteki sıhhatli hücrelere de hasar vermesidir. Bu vaziyete bağlı olarak hastaların, halsizliği, bulantısı, kusma, cilt ve

tırnak sorunu, bağırsak sorunu, iltihap, kan ve pıhtılaşma sorunu v.s gibi çok yan tesir görülecektir. Ayrıca kimyasal tedavi ilaçlarını tesir alanının sınırlı olması ve ilaç mukavemetine neden olması gibi bir hayli önemli dezavantajları vardır. Son zamanlarda nanoteknoloji; tıp bilimine özellikle de ilaç salım sistemleri alanına bir hayli yeni bakış açısı kazandırmıştır. Nano boyutta yeni akıllı sistemlerin tasarımı ve geliştirilmesi, sağladıkları avantajlardan dolayı oldukça ilgi görmektedir. Günümüzde grafen, karbon nanotüp, Mezofor Silika Nanopartikül MSN, altın nanopartikül, gümüş nanopartikül gibi çok muhtelif akıllı ilaç taşıyıcı sistemler geliştirilmiştir. Akıllı ilaç taşıma sistemlerinin önemi; ilacı sadece vücuttaki çok özel bölgelere tesir etmesi ve sağlıklı dokulara gelişigüzel bir zarar vermeden hastalığı rehabilit (Albayati, 2018).

Cilt Kanseri

Kanser hastalıkları içerisinde en yaygın kanserlerden biri de cilt (deri) kanseridir. Cilt kanseri ülkemizde de yaygın kanser türlerinden biri olup. Son 30 yılda bu hastalığın yükseliş oranı % 237 artmıştır. Melanom, cilt kanserinin en tehlikeli türü, cilt kanserin çeşitleri arasından en az görülen çeşittir %2'den az. Cilt kanserini vücuttaki diğer organlara dağılması nedeni ile insanların hayatlarına ciddi bir tehlikeli durum oluşturur. Bazal hücre kanseri en sık görülen cilt kanser ve düz kanser türüdür. Her yıl ABD'de 1 milyon yeni vaka var, bu oranda ülkemizde 100.000 erkekten 1.9 oranında etkisi vardır ve 100.000 kadından 1.3 oranında etki olmuştur. İnsanlarda yaşam kaybı oranı cilt kanseri sebebiyle her 100 hastada 1 olarak tahmin edilmektedir. Ölüm riskinin en az görüldüğü kanser tipi cilt kanseridir diyebiliriz.

1.1. Tezin Amacı

Bu tezin amacı, insan vücudunda bulunan benleri sınıflandırmaktır. Bu amaçla tespit edilen benleri normal veya cilt kanseri türü olarak sınıflandırmak için tez çalışması kapsamında bir ESA tabanlı bir yazılım oluşturulmuştur. Bu yazılımın asıl amacı doktorların yerini almaktan ziyade, onlara yardımcı olacak bir araç geliştirmektir. Özet olarak bu tez çalışması kapsamında, cilt kanseri risk değerlendirmesi için uzmanlara yardımcı olabilecek ESA tabanlı bir yazılım modeli oluşturmaktır.

1.2. Tezin Önemi

Cilt kanserin erken teşhisin önemi, hastalığın ciddiyetinden kaynaklanmaktadır. Hastalığın tespiti geciktiği zaman müdahale edilmesi zor olmaktadır. Amerikan kanser

Toplumuna göre 2018'de Amerikan Kanser Toplumu ile ilgili olarak, ABD'de cilt kanseri erken ayırt edilen hastalar için 5 yıllık sağ kalım oranı değerlendirilmiştir. Bu değerlendirmede erken teşhis edildiği zaman %98 civarında olan sağ kalım oranı sağlanmaktadır. Hastalık orta seviyeye vardığı zaman kurtarma şansı %62'ye düşmektedir. Hastalık ilerili seviyeye geldiği zaman bu oran %18'e düşmektedir.

Tez kapsamında oluşturulan ESA tabanlı yazılım ile vücutta bulunan benlerin riskleri değerlendirilerek, uzmanlara yardımcı olabilecek bir araç geliştirmektir.

1.3. Literatüre Katkısı

Bu çalışmadaki Evrişimsel Sinir Ağları (ESA) modelinin özelliği ile vücuttaki benleri test edilmesi için yapılmaktadır. Bu tez kapsamında oluşturulan yazılım ESA modeli kullanıldı ve özel bir model düzenlendi. Bu model sayesinde vücutta bulunan benleri teşhisi kolaylaşır ve hızlı şekilde cilt kanser olup olmadığını tespit edilir. Bu çalışma ile hastalığı kolay yollarla teşhis imkânı sunulmaktadır.

Daha geniş bir veri kümesi kullanılarak daha detaylı bir inceleme yapılması sağlanmaktadır. Kullanılan bu geniş veri kümesi ile daha geniş bir sınıflama sistemine tutularak modelleme yapılmıştır. Sonuç olarak kullanılan modelleme ile daha önce yapılan çalışmalardaki sonuca göre elde edilen sonuç iyi bir orana sahiptir.

Bu çalışmada yapılan ESA modeli (program) doktorların yerini asla alamaz, ancak insanlar bu ciddi hastalığı daha az maliyetle ve daha hızlı bir şekilde teşhisinde yardımcı olmaktadır.

2. KAYNAK ARAŞTIRMASI

Literatür incelendiğinde cilt kanserinin otomatik olarak teşhis edilmesi için birçok makine öğrenmesi metodunun, bu benlerin iyi huylu veya kötü huylu olup olmadığını bulmak için kullanıldığı görülmektedir. Aşağıda ilgili çalışmalarla ilgili ayrıntılar çalışma alanları kategorize edilerek sunulmuştur:

- Makine Öğrenme Alanındaki Çalışmalar

American cancer, 2012' de, iki derin öğrenme yöntemi uygulanmıştır. Lezyon İndeksleme Ağı (LIN) ve Lezyon Özellik Ağı (LFN). Cilt yaralanması görüntü hazırlamanın üç temel zorluğu ele alınarak yaralanma bölünmesi, dermoskopik vurgu çıkarma ve yaralanma karakterizasyonu ile bu çalışma %71 başarı elde etmiştir. (American Cancer, 2012).

Jain ve ark 2015 yılında IBM Araştırma Laboratuvarlarında, Sparse Coding ve Destek Vektör Makineleri (Support Vector Machine (SVM)) sınıflandırıcı ile dermoskopik görüntülerin tespit edilmesi için derin öğrenme uygulaması yapmışlardır (Jain ve ark. 2015).

Chris Pearce 2016 yılında derin öğrenme ağlarının tümör sınıflamasında uygulanması için fırsatları araştırmıştır. Aynı veri seti orta seviye performanslarla karşılaştırılarak, basit ağların makul performans sunabileceği saptanmıştır. Modeldeki parametre sayısının sınırlandırılmasının bir kombinasyonu ile çözülebilen ciddi bir problemdir. Eğitim verilerinin pozitif ve negatif gözlemler arasında dengeli olmasını sağlanmış, düşük öğrenme oranları ve girdi verileri örneklere doğru yinelenmiş; önceki eğitim dönemlerinden sonra ki model üzerindeki yanlış sınıflandırılmıştır (Chris Pearce, 2016).

Jeremy Kawahara 2016'da bilinmeyen bir cilt lezyonunun teşhisinde, uygun tedaviyi belirlemenin ilk adım olduğunu belirtmiştir. Doğal görüntülerde önceden tanımlanmış bir evrişimsel sinir ağından çıkarılan özellikler üzerine eğitilmiş lineer bir sınıflandırıcının, aynı veri setinde daha önce elde edilen son teknoloji sonuçlara göre daha yüksek bir hassasiyetle on cilt lezyonunu birbirinden ayırdığı gösterilmiştir. Ayrıca, rakip işlerin aksine, yaklaşım hiçbir lezyon segmentasyonu veya karmaşık ön

işleme gerektirmemektedir. Her görüntü normalizasyonu, çok ölçekli özellikleri çıkarmak için tamamen evrişimsel bir ağ kullanılarak ve artırılmış bir özellik alanını bir araya toplayarak doğruluk için tutarlı ek geliştirmeler elde edilmiştir. Öngörülen durumla karşılaştırıldığında, önerilen yaklaşım, düşük temsil edilen sınıfların (örneğin %15,6'ya kıyasla %60) doğruluğu gözle görülür gelişmelerle 5 sınıf (%75,1'e kıyasla) üzerinde %83,8'lik bir olumlu doğruluk elde etmektedir. Standart (dermoskopik olmayan) bir kameradan elde edilen 1300 görüntünün 10 sınıf veri setinin tamamında, önerilen yöntem daha önce bildirilen %67 doğruluğu geride bırakarak %81.8 kesinliğe ulaşmıştır (Jeremy Kawahara, 2016).

Jafari ve ark 2016 yılında, hastalık hücrelerinin tanımlanması konusunda çok çeşitli model türleri geliştirmiştir. Histopatolojik belirlemeye bağlı basit üç katmanlı sistemler ile % 82'ye varan hassasiyetinde ilerleme oranları sağlamıştır. Daha büyük bir bilgi endeksinden uzaklaşmak, ResNet tabanlı bir modelle kanıtlama kesinliği oranlarını ayırt eden en son mitozun nasıl gerçekleştirileceğini bulmuştur (Jafari ve ark. 2016).

Ehteshami Bejnordi ve ark., 2017'de, tüm slayt patolojisi resimlerinde derin öğrenme hesaplamaları kullanmışlardır. Semptomatik kesinliği ve etkinliği düşünülebilir şekilde iyileştirmişlerdir. Hematoksilen ve eozin rengindeki metastazlarda metastazları tanımada bilgisayarlı derin öğrenme hesaplamalarının uygulanmasını değerlendirmek, kadınların göğüslerinde kötü huylu büyümesi olan lenf göbeklerinin renk bölgelerinin rengini ve patologların bulgularını analitik bir ortamda karşılaştırmaktadır. Araştırmacı, lenf göbek metastazlarını tanımlamak ve mekanize cevaplar oluşturmak için rekabet içerisine girmiştir (CAMELYON16) (Kasım 2015-Kasım 2016). Hesaplamaların yapılmasında üyelerin kışkırtılması için immünohistokimyasal renklendirme ile kontrol edilen (n = 110) ve (n = 160) nodal metastazları olan 2 odaklamadan oluşan bütün slayt resimlerinin bir hazırlık bilgilendirme toplaması verilmiştir. Hesaplama yürütmesi, 129 bütün slayt resminin (49 ve metastazsız 80) ücretsiz test setinde değerlendirilmiştir. Cam slaytları karşılaştırmak için benzer bir test seti, 2 saatlik bir uyarlamada her bir slayt için nodal metastaz olasılığını belirlemek, rutin patoloji çalışma sürecini yeniden oluşturmak için Hollanda'dan zaman şartlı (WTC) olan 11 patologdan oluşan bir kurul tarafından değerlendirilmiştir. Rekreasyon pratiğinde yer alan 11 patolog, semptomatik kesinliklerini şüphesiz tipik, muhtemel sıradan, şüpheli, en muhtemel tümör veya

tartışılmaz tümör olarak değerlendirmiştir. Hesaplama için kolektör çalışanı ticari marka virajı (AUC) bölgesi 0,556'dan 0,994'e çıkmıştır. En iyi performans gösteren hesaplama, tipik tüm slayt resminin ortalama 0.0125 hatalı-pozitifinde patolog WOTC ile eşdeğer (% 72.4 [% 95 CI,% 64.3 -% 80.4]) ile eşdeğer bir gerçek pozitif bölme gerçekleştirmiştir (Ehteshami Bejnordi ve ark., 2017).

Esteva ve ark., 2017'de bilgi kaynağı olarak sadece pikselleri ve rahatsızlık izlerini ESA kullanarak cilt yaralarının karakterizasyonunu göstermiştir. 2.032 tekil hastalıktan oluşan 129.450 klinik resimden oluşan veri setini (geçmişteki veri setlerinden 12 büyük ölçüde daha büyük olan iki istek) kullanan bir ESA oluşturulmuştur. Asıl vaka, en iyi bilinen hastalıkların tanınabilir kanıtına değinirken, ikincisi, en ölümcül cilt kanseri büyümesinin kimliğiyle örtüşmesidir. ESA, denenen her bir görsele, iki atama üzerinde çapraz şekilde ilerleyerek, dermatologlara eşdeğer bir yetenek boyutuna sahip cilt kanseri büyümesini göstermek için uygun bir bilgisayarlı mantık sergileyen yürütmeyi gerçekleştirmektedir. Derin sinir ağları ile donatılan cep telefonları, dermatologların menzilini merkez dışında genişletebilmektedir. (Esteva ve ark., 2017).

Golden 2017'de düzenli olarak insan bilgisi gerektiren görevler gerçekleştirmeye hazır bilgisayar çerçevelerinin hipotezi ve ilerlemesi, mevcut yaşamın hemen hemen her özelliğine giren Yapay zekâyı (AI) kullanmıştır. Bütçe segmentinde, AI rutin olarak zorla yer, algoritma değiş tokuş ve sohbetler (örneğin çevrimiçi sanal asistanlarla, sese bağlı veya edebi stratejiler aracılığıyla tartışmaları yönlendiren görünen bilgisayar programları) için kullanılmaktadır. AI daha yavaş olmasına rağmen kullanım hızı büyük oranda hızlanmıştır. 2014 yılında, insan hizmetlerinde AI yeni işletmelerin satın alınması yaklaşık 600 milyon dolardı; 2021'de yıllık 6,6 milyar dolar ya da% 40 bileşik büyüme oranı öngörülmektedir. Sosyal sigortaların AI için hazır olmasının bir nedeni "büyük bilgidir": tıbbi hizmetler endüstrisi, bilgisayarın "öğrenebileceği" geniş kapsamlı bilgi test setlerinin gerekliliği göz önüne alındığında, AI için mükemmel olan zengin bilgi toplamalarına sahiptir (Golden, 2017).

Hart ve Norval, 2017 yılında, UV (Ultraviyole) ışınlamanın UVR maruz kalmasının, derideki karsinojenezin başlatılması için bastırılmış bir bağışıklık ortamına neden olabileceği iddiası ilk önce 40 yıldan daha önce tarif edilmiştir. Van der Leun ve

meslektaşları, bu bölgeye, 1980'lerde ve 90'larda, UVR'nin bağışıklık sistemi üzerindeki hem lokal hem de sistemik etkisini göstermenin yanı sıra, bu tür tümörlerin oluşumunda doza bağımlılığı içeren farelerde yapılan deneylerle katkıda bulunmuştur. Bu ilk günlerden beri, UV kaynaklı immün baskılanmanın karmaşık yollarının birçok yönü çalışılmış ve bu derlemede ana hatlarıyla belirtilmiştir. Çoğu deneysel çalışma fareyi içermesine rağmen, UVR'nin insanlarda azalmış bağışıklık yanıtlarına neden olduğu açıktır. İmmün sistemin insan derisi kanserleri riskini belirlemedeki önemini gösteren kanıtlar açıklanmıştır ve UVR maruziyetinin bu tür tümörlerin oluşumunda ve ilerlemesinde bağışıklığı nasıl azalttığına dair detaylar incelenmiştir. Bu bağlantılar ve UVR ile indüklenen immünosupresyonun mekanizması hakkındaki artan bilgiyle, insanlarda cilt tümörü antijenlerine karşı bağışıklığı arttırmaya yönelik yeni yaklaşımlar açık bir şekilde ortaya çıkmakta, umarım gelecekte UVR kaynaklı cilt kanserlerinin yükünü azaltmaktadır (Hart ve Norval, 2017).

- ESA Alanındaki Literatürler:

Barata ve ark 2014 yılında, cilt hastalıkları insanların günlük yaşamında çok yayınlanmıştır. Her yıl Amerikan kökenli milyonlarca insan her türlü cilt rahatsızlığından etkilenmektedir. Cilt hastalıklarının teşhisi, bazen görsel yönlerinin çeşitliliği nedeniyle yüksek düzeyde uzmanlık gerektirmektedir. İnsanın yargısı genellikle öznel ve zorlukla tekrarlanabildiğinden, daha objektif ve güvenilir bir tanı elde etmek için bilgisayar destekli bir tanı sistemi düşünülmektedir. Bu çalışmada Evrişimsel Sinir Ağını (ESA) kullanarak evrensel bir cilt hastalığı tanı sistemi kurmanın fizibilitesi araştırılmıştır. Dermnet veri setindeki 23.000 cilt hastalığı görüntüsünü kullanarak ESA mimarisi eğitilmiş ve performansı bir başka cilt hastalığı veri seti olan Dermnet ve OLE ile test edilmiştir. Dermnet veri setinde test yaparken sistemi % 73,1 Top-1 doğruluğunu ve %91,0 Top-5 doğruluğu elde edebilmektedir. OLE veri setindeki test için, Top-1 ve Top-5 doğrulukları %31,1 ve %69,5'tir. Daha fazla eğitim görüntüsü kullanılırsa bu hassasiyetin daha da geliştirilebileceğini göstermektedir (Barata ve ark., 2014).

E. Nasr-Esfahan 2016 yılında, cilt kanseri, en tehlikeli cilt kanseri tipidir ve günden güne artış göstermektedir. Bu çalışmada bir bilgisayar sunucusunda, grafik işlem birimi (GPU) ile donatılmış bir derinlemesine öğrenme sisteminin uygulanması,

melanom lezyonlarının saptanması için önerilmiştir. Önerilen sistemde, bu tip cilt kanserinin erken teşhisinde dermatoloğa yardımcı olabilecek klinik (non-dermoscopic) görüntüler kullanılmıştır. Bu tür eserlerin azaltılması için aydınlatma ve gürültü efektleri içerebilen giriş klinik görüntüleri önceden işlenir. Daha sonra gelişmiş görüntüler, derin öğrenme modellerinin bir üyesi olan önceden eğitilmiş bir ESA beslenir. Çok sayıda antrenman numunesi ile eğitilen ESA sınıflandırıcı, melanom ve iyi huylu olgular arasında ayrım yapar. Deneysel sonuçlara göre, önerilen yöntemin son teknoloji ile karşılaştırmalı olarak diagnostik doğruluk açısından üstün olduğunu göstermektedir (E. Nasr-Esfahani, 2016).

Yuan ve ark., 2017 yılında, derinlemesine öğrenme çerçeveleri adresini kullanarak kanseri tespit etmek için başka bir tür uygulamıştır. Ayrıca 2017 yılında ISIC'den gelen verileri kullanmıştır. Makale iki ana görevden bahsetmiştir:
1-Mevcut derin öğrenme yaklaşımları normal olarak, yaralanma bölünmesini ve düzenini bağımsız olarak gerçekleştirmek için iki sistemi kullanmıştır. Bu yazıda, aynı anda ağrılı bölünme ve yaralanma sırasına yönelik olarak çok ölçekli tamamen evrişimli dil sistemleri ve bir boğaz dosya hesaplama birimi (LICU) içeren bir sistem önerilmiştir. Önerilen yapı iki teşebbüste şaşırtıcı sonuçlar elde etmiştir. Bundan sonra, önerilen yapı Lezyon İndeksleme Ağı (LIN) olarak adlandırılmıştır.
2-Lesion Feature Network (LFN) adında ESA tabanlı bir sistemi, yani dermoskopik vurgulu çıkarma işlemine yönelik olarak önerilmiştir. Keşif sonuçları, sistemimizin agresif bir şekilde yürütülmesini göstermektedir (Yuan ve ark., 2017).

Hao Chang, 2017 yılında, bir kanser türü olarak cilt kanseri çok ciddidir. Dermoskopiye dayalı erken teşhis ve tanıma stratejisi cilt kanseri tedavisinde kritik öneme sahiptir. Bununla birlikte, iyi eğitimli dermatologlar tanısal doğruluğa hakimdir. Bu sorunu çözmek için, otomatik görüntü analiz sistemlerinin geliştirilmesine çok çaba sarfedilmiştir. Çalışmada derin öğrenme teknolojisine dayalı yeni bir strateji sunulmaktadır: 1) lezyon saptama limitleri çok yüksek bir doğruluk elde etti parça parça sinir ağı (skin_segnn) oluşturmak. 2) Google'ın v3 ağını temel alarak başka bir sinir ağı oluşturmak (Chang, 2017).

G Wiselin Jiji1, 2017 yılında, doğru tedaviye yol açan tanıyı iyileştirmek için melanomun tespiti ve analizi için otomatik bir yöntem sunulmaktadır.Özellik

tanımlayıcılarının segmentasyonu ve sınıflandırma modelleri gibi görüntü işleme teknikleri dahil edilmiştir. İlk aşamada, yaralanma bölgesi Renk Alanı Tabanlı Segmentasyon (CIELAB) kullanılarak parçalanır. Şekil, renk ve doku gibi özellikler ve özellikler daha sonra çıkartılır. Son olarak, evre III yaralanma alanında O-A SVM çok katmanlı model kullanılarak melanom, seboreik keratoz veya parankima olarak sınıflandırılır. ISIC 2017 arşivinden cilt kanser veri kümesi ile deneyim yapıldı ve sonuçlar analiz edilmiştir (G Wiselin Jiji1, 2017).

P. Mirunalini, 13 Mar 2017 yılında, cilt kanserini daha erken bir aşamada teşhisine çok ihtiyaç duyulmaktadır. Deri yüzeyinde bulunan lezyonlar dermoskopik görüntüleri kullanılarak analiz edilir ve iyi huylu ya da kötü huylu cilt kanseri formları tespit edilmektedir. Bu çalışmada, Google'ın Inception-v3 olarak bilinen önceden tanımlanmış ESA modelini kullanarak görüntünün temsilini öğrenen otomatik bir cilt lezyon algılama sistemi geliştirilmiştir. Giriş dermoskopik görüntülerimiz için gösterim vektörünü aldıktan sonra, iki katmanlı besleme ileri sinir ağını eğitmektedir. Görüntüleri kötü huylu veya iyi huylu olarak sınıflandırır. Bu görüntüleri Uluslararası Cilt Görüntüleme İşbirliği (ISIC) 2017 den alınmıştır. Bu sistem mücadelede verilen eğitim görüntüleri kullanılarak oluşturulan modele göre görüntüleri sınıflandırmayı öğrenir ve deney sonuçları validasyon ve test setleri kullanılarak değerlendirilir. Bu sistem validasyon seti için% 65,8 genel bir doğruluk sağlamıştır (P. Mirunalini, 13 Mar 2017).

Haney ve ark 2018 yılında günümüzde görüntü tanıma ile bilgisayar destekli tanı (CADx) hastanelerde sık görülen bir durumdur. Bilgisayarlar meme kanseri belirtilerini ve farklı tür akciğer hastalıklarını tespit edebilmektedir. Görüntüleri sınıflandıran ESA için, doğruluk, üzerinde çalıştığı verinin miktarına bağlıdır ve egzersiz verisi miktarı arttıkça daha iyi performans göstermektedir. Bu, sınıflandırıcının birbirinden ayırt etmesi gereken sınıflar için ilgili görüntülere ihtiyaç duyulmasını sağlamaktadır. Bununla birlikte, girdi verileri arttığında, hesaplama maliyeti de artmaktadır ve doğruluk ile hesaplama süresi arasında bir denge kurulmasına neden olmaktadır. Cho ve ark. Doğruluk iyileştirmesi, farklı eğitim verileri miktarıyla doğruluğu karşılaştırırken durgunlaşmıştır. Bu, durgunluk noktasını bulmak için ilgi yaratmıştır, çünkü girdi verilerinin daha fazla artması daha uzun hesaplama süresine yol açacağını düşünmüştür, ancak doğruluğu çok az etkilemektedir. Bu çalışmada, önceden eğitilmiş ESA Google Inception v3, çeşitli miktarlarda cilt lezyonu görüntüleri ile yeniden eğitilmiştir. Amaç,

görüntünün benign bir nevüs ya da Cilt Kanserini temsil ettiğini tespit etmektedir. Bu farklı eğitim seanslarının doğruluğunu karşılaştırırken, daha fazla veri ile eğitildiğinde doğruluğun arttığı sonucuna varılmaktadır. Ancak, doğruluk için bir durgunluk noktası bulunamamıştır (Haney ve ark., 2018).

Lin ve ark., 2018 yılında, nazofarengeal kanser (NPC) Güney Çin ve Güneydoğu Asya ülkelerinde görülme sıklığı yüksek bir endemiktir. Konvansiyonel beyaz ışık görüntüleme (WLI) nazofarinaskop muayenesinde NPC taraması, zayıf duyarlılığından dolayı büyük bir klinik sorun olmaya devam etmektedir. Burada, ilk kez in vivo endoskopik kanser tespiti için WLI, otofloresan görüntüleme (AFI), dağınık yansıma spektroskopisi ve Raman spektroskopisi teknolojilerini birleştiren entegre bir 4-modlu endoskopi sistemi geliştirilmiştir. Sistemin NPC tespiti için pilot bir klinik test gerçekleştirilmiştir, burada 303 NPC hastası ve 30 sağlıklı bireyin AFI ve WLI'nin rehberliğinde 283 in vivo Raman ve yaygın yansıtma spektral veri setleri elde edilmiştir. Hem yüksek tanısal duyarlılık hem de kanseri normal doku bölgelerinden ayırt etmek için yüksek özgüllük bu sistem kullanılarak, temel bileşen analizi-lineer ayırıcı analiz tanı algoritması ile birleştirilerek, in vivo olarak gerçek zamanlı iyileştirme için büyük bir potansiyel ortaya koymuştur (Lin ve ark., 2018).

Li ve Shen, 2018 yılında, dermoskopi görüntülerinde cilt kanserini erken saptanması, sağ kalım oranını belirgin olarak arıttığı ortaya koymuşlardır. Bununla birlikte, cilt kanserini doğru olarak tanınması aşağıdaki nedenlerden dolayı son derece zordur. Bunlar: lezyonlar ve cilt arasındaki düşük kontrast, melanom ve melanom dışı lezyonlar arasındaki görsel benzerlik vb. Dolayısıyla, cilt tümörlerinin güvenilir otomatik tespiti doğruluğu arttırmak için çok yararlıdır. Bu çalışmada, cilt lezyonu görüntü işleme alanında ortaya çıkan üç ana görevi, yani lezyon segmentasyonu (görev 1), lezyon dermoskopik özellik çıkarımı (görev 2) ve lezyon sınıflandırması (görev 3) ile ilgili iki derin öğrenme yöntemi önerilmiştir. Bölünme sonucunu ve kaba sınıflandırma sonucunu eş zamanlı olarak üretmek için iki tam konvolüser artık ağdan (FCRN) oluşan derin bir öğrenme çerçevesi önerilmiştir. Bu mesafe indeksi hesaplama birimi (LICU), mesafe ısı haritası hesaplanarak kaba sınıflandırma sonuçlarını iyileştirmek için geliştirilmiştir. Dermoskopik özellik çıkartma görevi için düz bir ESA önerilmiştir. Önerilen derin öğrenme çerçeveleri ISIC 2017 veri setinde değerlendirilmiştir. Deneysel sonuçlar, çerçevelerimizin ümit verici doğruluklarını, yani

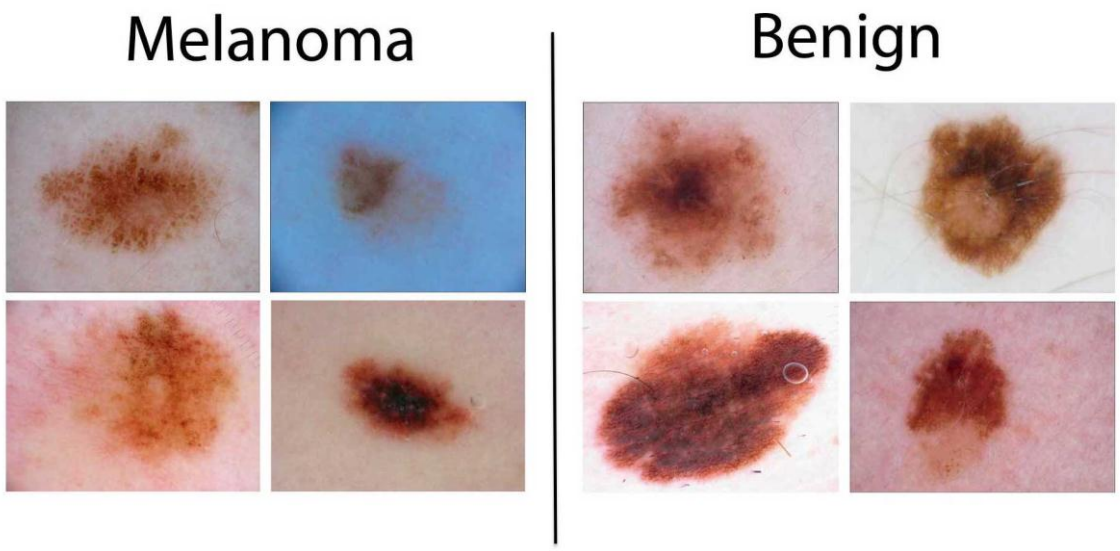
görev 1 için 0.753, görev 2 için 0,848 ve görev 3 için 0.912 elde edildiğini göstermektedir (Li ve Shen, 2018).

Codella ve ark, 2018 yılında, çok daha büyük veri kümeleriyle çalışmıştır ve farklı durumlarda aktarılabilecek modern algoritmalar yaratmıştır. Örneğin, geç saatlerden itibaren, cildin habis büyüme yaralarını, 125.000'den fazla algılayıcılı bir veri seti kullanılarak dermatolog düzeyinde kesinliğe göre tanımlamak için bir sistem hazırlanmıştır, daha sonra bir cep telefonuna gönderilmek üzere donatılmıştır (Codella ve ark, 2018).

3. MATERYAL VE YÖNTEM

3.1. Veri kümesi

ISIC cilt kanser merkezinden veri seti alınmıştır. Kullanılan veri kümesi diğer çalışmalarda kullanıldığı gibi ((P. Mirunalini, 13 Mar 2017), (Li ve Shen, 2018), (G Wiselin Jiji1, 2017)), (Chang, 2017)) toplam olarak 2000 görüntü kullanıldı içinde 1000 normal ben görüntüleri alınmıştır ve 1000 cilt kanseri (Melanoma) olan ben görüntüleri alınmıştır. Aynı anda test için farklı 600 görüntü kullanıldı. Bu veri kümesinde birçok parametrelere sahiptir. Örneğin yaş, ailenin kanser tarihçesi gibi veriler veri setinde bulunmaktadır. Şekil 3.1'de normal ben (Benigin) ve cilt kanseri olan benin (Melanoma) görselleri bulunmaktadır.



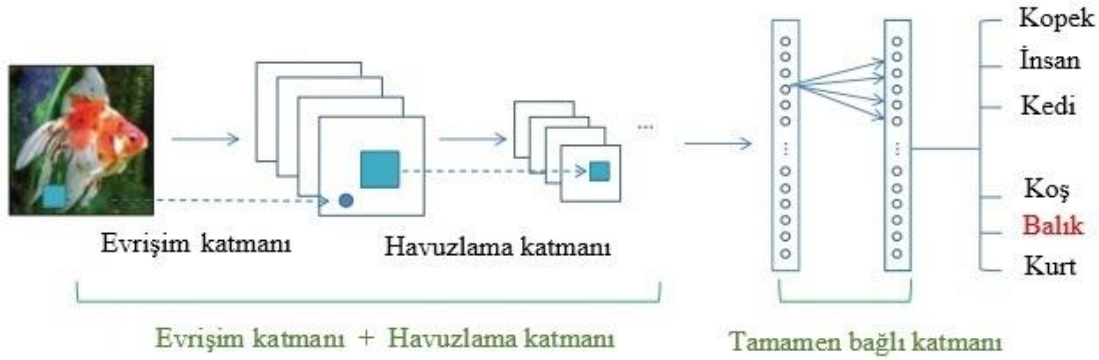
1 A: Cilt kanseri örnek görüntüleri (Melanom) 1 B: A: Cilt kanseri olmayan örnek görüntüler (Benign)
Şekil 3.1 ISIC Arşiv veri kümesinden oluşturulan örnek resimler

3.2. Dermoskopi Görüntüler

Dermoskopide görüntüleme çıplak gözle görünmeyen mikroskobik altında yapıların kapsamlı görülmesini sağlayan bir teknolojidir. Başlangıçta melanom lezyonlarının değerlendirilmesi ile sınırlı olmasına rağmen, bugün dermatoskopi uygulaması birçok dermatolojide genişlemiş ve dermatoskop, stetoskop veya genel pratisyen hekimler için benzer bir rol oynamaktadır.

3.3. Evrişimsel Sinir Ağları (ESA)

ESA, Şekil 3.2.'de genel ESA mimarisini gösterildiği gibi çoklu tabakalara sahip olup, baştanbaşa eğitildiği en dağılan derin öğrenme metotlarından birisidir. Çok tesirli ve fazla sayıda görüntü uygulamalarında kullanılmaktadır.

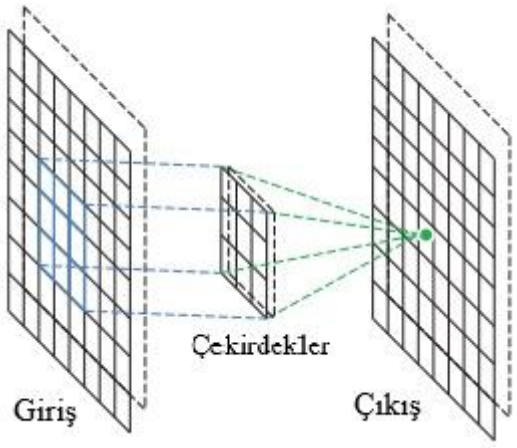


Şekil 3.2 Genel ESA mimarı

Genel olarak bir ESA; evrişim tabakası, havuzlama tabakası ve tamamıyla bağlı tabakası olan 3 ana sinir tabakadan oluşmaktadır. Her tabakanın değişik görev yapmaktadır. ESA genel mimarisi ve sınıflandırma türü şekil 3.2'de, göstermektedir. Ağın eğitilmesi iki etaptan oluşur: ileri ve geri. Öncelikle, ileri evrenın asıl görevi, girilen görsellerin her tabakasındaki geçerli parametreleri (ağırlıklar ve ön yargı) temsil edilmesidir. Sonradan tahmini verimler, yanlışlık oranının esansıyla gerçeği anlamak için kullanılmaktadır. İkinci olarak kayıp maliyete göre, geri evren, kademeli zincir kaideleri ile her bir parametrenin geçişlerini hesaplamaktadır. Bütün parametreler gelişmelerine göre güncellenip ve sonraki hesaplama işlem için hazırlanmaktadır. İleri ve geri evrelerin yeterli sayıda tekrarlanmasından sonra, ağın öğrenmesini durdurabilmektedir.

3.3.1. Evrişim katmanı (Convolutional layer)

Evrişim katmanı, bir ESA, farklı özellik haritalarını üreten ve tüm görüntünün piksellerini kontrol etmek için çok sayılı kernel kullanılmaktadır. Evrişim katmanı çalışması şekil 3.3'te göstermektedir.



Şekil 3.3 Evrişim katmanın çalışması.

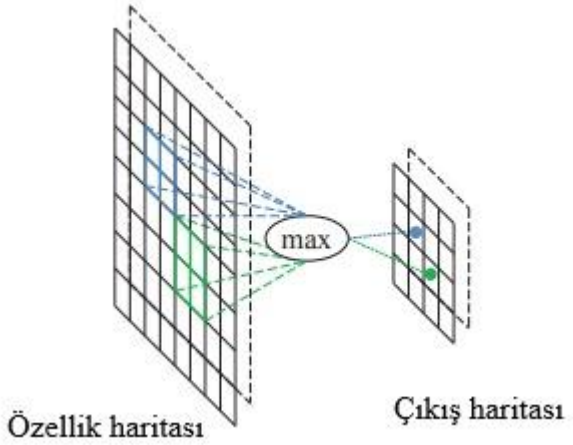
Evrişim katmanın 3 avantajı bulunmaktadır:

1. Görüntüdeki özellik haritasının ağırlık paylaşım mekanizması ile parametrelrin rakamını eksiltir.
2. Görüntüdeki piksellerin arasındaki iletişimi ve korelasyonu sağlar.
3. Görüntüdeki nesnelerin konum değiştirmesini sağlar.

Evrişim katmanın yararlar sebebiyle, kimi iyi araştırma raporları, öğrenme sürecini hızlandırmak için tam irtibatlı tabakaların yerine geçiyor. Bu katmanın kullanmanın enteresan bir yaklaşımda, evrişim katmanı, doğrusal olmayan aktivasyon işlevlerine sahip tam olarak birbirine bağlanmış çok fazla katmandan oluşan birçok küçük katmanlı algılayıcının yerine koymaktır. O zaman doğrusal filtreler doğrusal olamayan ile değiştirecektir. Bu yöntemi kullanarak, görüntülerin sınıflandırması daha iyi sonuçlar elde edilir.

3.3.2. Havuzlama katman (Pooling layer)

Genel olarak, bir havuz katmanı evrişimli katmanın dan sonra devreye girer, özellik haritasının ve ağın parametre ebatlarını eksiltmek için kullanılmaktadır. Bu katmanın en sık kullanılan yöntemleri orta ve max havuzlamadır. Max havuzlamanı anlatmak için şekil 3.4'te bir örnek göstermektedir. Girilen görüntü 8 × 8 için, çıktı haritası 4 × 4 ebatlarına indirgenir, ebat 2 × 2 olmaktadır.



Şekil 3.4 Max havuzlama.

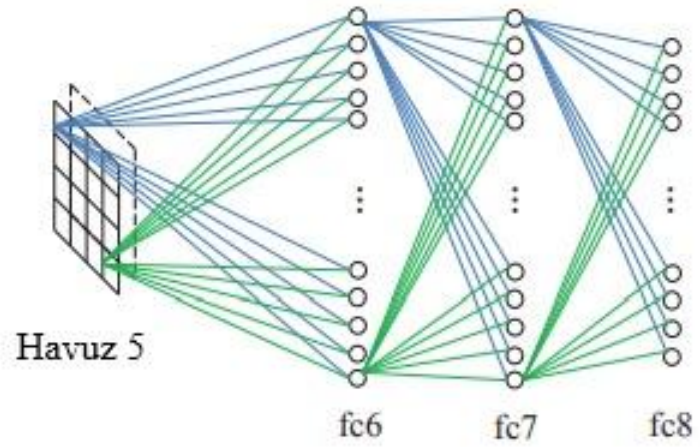
Max havuzlama ve orta havuzlama için (Bureau ve ark., 2010) performanslarının detaylı teorik analizini yapmışlardır (Scherer ve ark., 2010). Ayrıca iki havuzlama harekâtı arasında bir karşılaştırma yapmışlar ve maksimum havuzlamanın daha süratli yakınlaşmaya yol açabileceğini, üstün değişmez özellikler seçtiğini ve genellemeyi geliştirebileceğini keşfetmişlerdir. Son senelerde, ESA değişkenleri muhtelif süratli GPU uygulamaları sunulmuştur, çoğu max-pooling taktiğini kullanmıştır. Havuz tabakaları, üç tabaka arasında en geniş biçimde araştırılmıştır. Her biri değişik emellere sahip olan havuz tabakalarıyla alakalı iyi öğrenilen üç yaklaşım vardır.

- **Stokastik Havuzlama**: Maksimum havuzlamanın bir dezavantajı, eğitim setini tekrar giydirmeye duyarlı olması ve örneklerin test edilmesinde iyi bir şekilde genelleştirilmesinin zorlaşmasıdır. Bu sorunu çözmeyi amaçlayan (Zeiler ve Fergus, 2014) her bir bilardo bölgesi içindeki aktivasyonu rastgele bir şekilde toplayarak bir multinom dağılımına göre, geleneksel deterministik havuz operasyonlarını bir stokastik prosedürle değiştiren stokastik bir havuzlama yaklaşımı önermiştir. Standart maksimum havuzlamaya eşittir, ancak her biri küçük yerel deformasyonlara sahip olan giriş görüntüsünün birçok kopyası vardır. Bu stokastik yapı, fazla uydurma sorununun önlenmesine yardımcı olmaktadır.
- **Mekânsal Piramit Havuzlama**: Normal olarak, ESA tabanlı yöntemler sabit boyutlu bir giriş görüntüsü gerektirir. Bu kısıtlama, rastgele boyutlardaki görüntüler için tanıma doğruluğunu azaltabilmektedir. Bu sınırlamayı ortadan kaldırmak için (Sun ve ark., 2017) genel ESA mimarisini kullanmışlardır ancak son havuzlama katmanını uzamsal bir piramit havuzlama katmanıyla değiştirmişlerdir. Mekânsal piramit havuzu, rastgele görüntülerden (veya bölgelerden) sabit uzunluklu gösterimler çıkarabilir, farklı ölçekler, boyutlar, en boy oranlarının kullanımı için

esnek bir çözüm üretebilir ve bu yapının performansını artırmak için herhangi bir ESA yapısında uygulanabilir.

3.3.3. Tamamen bağlı katman (Fully connected layer)

Son havuzlama katmanının ardından, birçok tam bağlı katman kullanarak 2D özellik haritalarını 1D özelliğine dönüştürür. Şekil 3.5'te görüldüğü gibi, bir dizi tam bağlı katman bulunmaktadır.



Şekil 3.5 Tamamen bağlı katmanın çalışması.

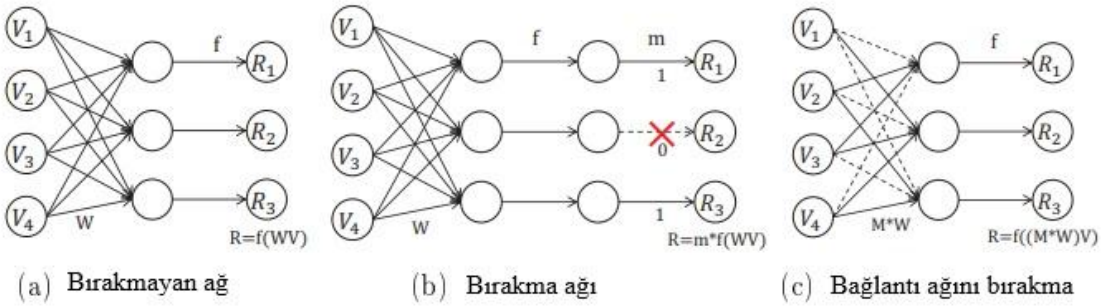
Tamamen bağlı katmanlar, geleneksel bir sinir ağı gibi performans göstermiş ve bir ESA'daki parametrelerin yaklaşık% 90'ını içermektedir. Sinir ağını önceden tanımlanmış uzunlukta bir ilerletmemizi sağlamaktadır. Tamamen bağlı katmanın yapısının değiştirilmesi nadirdir. ImageNet tarafından öğrenilen değişiklik, yeni görsel tanıma görevlerine uyum sağlamak için son tamamen bağlı katmanı iki yeni tam bağlı katmanla değiştirmiştir. Bu katmanların sakıncası, pek çok parametre içermeleridir, bu da onları eğitmek için büyük bir hesaplama çabasıyla sonuçlanmıştır. Bu nedenle, umut verici ve yaygın olarak uygulanan bir yön bu katmanları çıkarmak veya bağlantıları belirli bir yöntemle azaltmaktır. Örneğin, GoogLeNet, hesaplama bütçesini sabit tutarken, tamamen bağlı olan seyrek bağlantılı mimarilere geçerek derin ve geniş bir ağ tasarlamıştır.

3.3.4. Eğitim stratejisi

Sığ öğrenme (shallow learning) ile karşılaştırıldığında, derin öğrenmenin avantajı, daha soyut bilgileri öğrenmek için derin mimariler inşa edebilmesidir. Bununla birlikte, girilen çok sayıda parametre başka bir soruna yol açabilmektedir. Son

zamanlarda, yukarıda belirtilen stokastik havuz dâhil olmak üzere aşırı uyuşmanın savunulmasında çok sayıda düzenlileştirme yöntemi ortaya çıkmıştır. Bu bölümde, eğitim performansını etkileyebilecek diğer bazı düzenlileştirme tekniklerini tanıtmaktadır.

- **Bırakma ve Bırakma Bağlantısı**: Bırakma, (Zeiler ve Fergus, 2013) ve (Baldi ve ark, 2014) her eğitim durumu sırasında, algoritma, eğitim verileri üzerinde karmaşık eş uyarlamaları önlemek ve genelleme kabiliyetini arttırmak için özellik dedektörlerinin yarısını rasgele çıkarmıştır. Bu yöntem daha da geliştirilmiştir. Spesifik olarak, (Bouthillier ve ark, 2015) okuldan ayrılma derecelerini analiz etmişlerdir ve okuldan ayrılmanın son derece etkili bir topluluk öğrenme yöntemi olduğunu öne sürmüşlerdir. Dropout'tan türetilen bir genelleme, aktivasyonlardan ziyade rasgele ağırlıkları düşüren DropConnect olarak adlandırılmaktadır. Deneyler, biraz daha yavaş olmasına rağmen, çeşitli standart kriterler üzerinde rekabetçi veya daha iyi sonuçlar elde edebileceğini göstermiştir. Şekil 3.6 No-Drop, Dropout ve DropConnect ağlarının bir karşılaştırmasını vermektedir.



Şekil 3.6 Bırakmayan, Bırakma ve Bağlantı bırakma ağlarının karşılaştırması.

- **Veri artırımı**: Görsel nesne tanımaya bir ESA uygulandığında, ek etiketleme maliyetleri getirilmeden ek veri üretmek için veri büyütme işlemi sıklıkla kullanılmıştır. Tanınmış AlexNet, iki farklı veri büyütme biçimi kullanmıştır: birinci veri büyütme biçimi, görüntü çevirileri ve yatay yansımalar oluşturmaktan, ikinci biçimi ise eğitim görüntülerinde RGB kanallarının yoğunluğunu değiştirmekten ibarettir. (Taylor ve Nitschke, 2017), AlexNet'i temel model olarak aldı ve görüntü bitkilerini ekstra piksellerle genişletip ek renk manipülasyonları ekleyerek çeviri değişmezliğini ve renk değişimini geliştiren ek dönüşümler eklemişlerdir. Bu veri artırma metodu daha yakın

tarihli çalışmaların bazıları tarafından yaygın olarak kullanılmıştır. (Bloice ve ark., 2017) veri artışına dayanan denetimsiz bir özellik öğrenme yaklaşımı önermiştir: ilk olarak rastgele bir dizi görüntü yaması örneklemiş ve her birini bir vekil sınıf olarak ilan etmiş, sonra da bu sınıfları çeviriye, ölçeğe, renge ve kontrasta karşılık gelen dönüşümler uygulayarak genişletmişlerdir. Son olarak, bu vekil sınıflar arasında ayrım yapmak için bir ESA eğitmişlerdir. Ağ tarafından öğrenilen özellikler, çeşitli sınıflandırma görevlerinde iyi sonuçlar vermiştir. Ölçeklendirme, döndürme ve kırpma gibi klasik yöntemlerin yanı sıra, (Antoniou ve ark., 2017) ayrıca, daha geniş kapsamda daha fazla eğitim örneği veren renk döküm, vinyet ve mercek bozulma tekniklerini benimsemiştir.

- **Ön eğitim ve ince ayar**: Ön eğitim, ağları rastgele ayarlanmış parametreler yerine önceden eğitilmiş parametrelerle başlatmak demektir. Öğrenme sürecini hızlandırabileceği ve genelleme yeteneğini artırabileceği avantajlarından dolayı ESA'lere dayalı modellerde oldukça popülerdir. Önceden eğitilmiş ağların neden geleneksel bir şekilde eğitilmiş ağlardan daha iyi çalıştığını bulmak için mevcut algoritmalar üzerinde kapsamlı simülasyonlar yapmışlardır. AlexNet mükemmel performansa ulaştığında ve halka yayınlandığında, birçok yaklaşım ImageNet2012'de temel derin modeli olarak eğitilmiş AlexNet'i seçmiştir ve parametrelerin özel görevlerine göre ince ayarını kullanmıştır. Bununla birlikte, diğer modeller üzerinde eğitim alarak daha iyi performans sağlayan yaklaşımlar vardır. Bunlar, Clarifai, GoogLeNet ve VGG dir.

İnce ayar, modellerin belirli görevlere ve veri kümelerine uyum sağlaması için rafine edilmesi için çok önemli bir aşamadır. Genel olarak, ince ayar işlemi, kayıp fonksiyonlarını hesaplamak için kullanılan yeni eğitim veri seti için sınıf etiketleri gerektirir. Bu durumda, yeni veri kümesinin sınıf etiketlerinin sayısına bağlı olan son çıktı katmanı dışında, AlexNet gibi önceden eğitilmiş modele dayalı olarak yeni modelin tüm katmanları başlatılacaktır ve bu nedenle rastgele başlatılmıştır. Ancak, bazı durumlarda, herhangi bir yeni veri kümesi için sınıf etiketleri edinmek çok zordur. Bu sorunu ele almak için, sınıf etiketi olmayan zarar fonksiyonları olarak kullanılmak üzere bir benzerlik öğrenme amacı işlevi önerilmiştir, böylece geri yayılma normal şekilde çalışabilir ve modelin katman bazında rafine edilmesine izin verilmiştir. Önceden eğitilmiş modelin verimli bir şekilde nasıl aktarılacağını açıklayan çok sayıda araştırma

sonucu vardır. Belirli bir katmanın genel veya spesifik olduğu dereceyi ölçmek için yeni bir yol, yani bu katmandaki özelliklerin bir görevden diğerine ne kadar iyi transfer olduğunu tanımlanmıştır. Neredeyse herhangi bir sayıda katmandan aktarılmış özelliklere sahip bir ağın başlatılmasının, yeni bir veri kümesinde ince ayar yapıldıktan sonra genelleme performansını artıracağı sonucuna varılmıştır.

3.3.5. ESA mimarisi

Bilgisayar görme alan ESA programlarının son büyümeleriyle, bazı iyi öğrenilen ESA modelleri ortaya çıkmıştır. Muhtelif tipik ESA modellerinin yapılandırmaları ve ilk katkıları çizelge 3.1'de listelenmiştir.

Çizelge 3.1. ESA Mimarileri

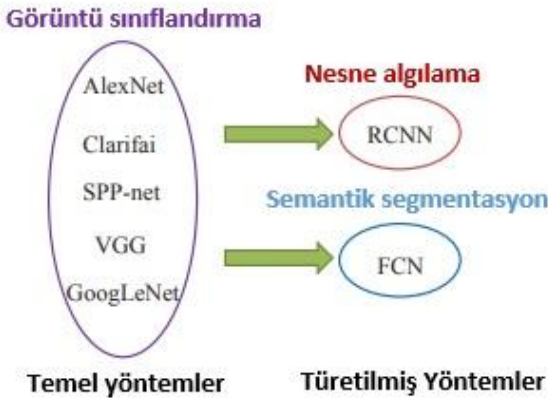
Yöntem	Yıl	Yapılandırma	Katkı
AlexNet	2012	Beşli evrişim katmanı, üçlü tamamen birbirine bağlı katmanı	önemli bir ESA mimarisi bir çok bilgisayarlı vizyon araştırmacısı için sistemi belirleyen
Clarifai	2013	Beşli evrişim katmanı, üçlü tamamen birbirine bağlı katmanı	Aradaki özel katmanların görevini tahmin etmektir
SPP	2014	Beşli evrişim katmanı, üçlü tamamen birbirine bağlı katmanı	Görüntüdeki çözünürlüğü ortadan yok için tavsiye edilir
VGG	2014	Üçlü tam bağlı + Onüç / Onbeş Evrişim katmanlar	Derinliği arttırıçak olan ağların Kapsamlığını değerlendirmek
Google Net	2014	Yirmi bir evrişim katmanı + bir tam bağlı katmanı	Bilgi işlem gereksinimlerini arttırmadan derinlik ve genişliği arttırmaktır

AlexNet, beş evrişim tabaka ve üç tane tamamen bağlı tabakadan oluşan ehemmiyetli bir ESA mimarisidir. Bir statik ebatlı 224 × 224 fotoğraf girdikten sonra, ağ tekerrür direnmekte ve aktivasyonları bir araya getirmekte, ardından neticeleri bütün bağlı tabakalara iletmektedir. Ağ, ImageNet konusuna tertip edilmiştir ve bilgi çoğaltıma, vazgeçme, vb. Gibi muhtelif kumpaslılaştırma teknikleriyle bütünleşmiştir. AlexNet, ILSVRC2012 müsabakasını kazanmıştır ve derin evriyal asap ağlarına olan alakanın çoğalmasına taban hazırlamıştır. Bununla beraber, bu modelin iki ana dezavantajı vardır:

- Sabit bir görüntü çözünürlüğü gerektirir;
- İyi performansından dolayı net bir anlayış yok.

(Zeiler ve Fergus, 2013) Ara özellik sınıflarının iç mekanizmasını anlamak için yeni görselleştirme tekniğini tanıtmıştır. Bu görseller Alex Net'ten Image Net derecelendirme kriterlerinde en iyi performans yapılarını bulmalarını sağladı ve Clarifai ILSVRC2013'te en yüksek performansı elde edilmiştir.

Tutarlı bir kararın bir gereği olarak, görüntü boyutu kısıtlamalarını gidermek için yeni bir toplama stratejisi, mekânsal hiyerarşik bir toplamayı önermiştir. Ağ çeşitli tasarımlar rağmen çıkan SPP çeşitli, ESA yapıları yayınlanan doğruluğunu artırabilmektedir. ESA (üç tam bağlı katmanlara ek olarak beş evrimsel katman) büyük ölçekli yapısı üzerinde kullanıcının yapılandırmasına ek olarak, daha derin ağları keşfetmek için çalışıyor yolları vardır. Alex Net'in aksine, VGG daha fazla evrim katmanı ekleyerek ve her aşamada çok küçük evrimsel filtreler kullanarak ağın derinliğini arttırmıştır. Benzer şekilde, (Ye ve ark., 2015), ILSVRC2014 yarışmasında çok derin bir yapıya sahip olan (22 tabakalı) bir modeli olan GoogLe Net'in uygulamasını önerilmiştir. Her ne kadar farklı modellerde yüksek kaliteli değerlendirme performansı elde edilse de, ESA ile ilgili modeller ve uygulamalar görüntü sınıflandırmasıyla sınırlı değildir. Bu modellere dayanarak, nesne idrak etme, manasal bölümleme, vb. Gibi diğer zorlu görevlere yönelik yeni çerçeveler türetilmiştir. Şekil 3.7'de gösterilmiş olduğu gibi iki adet iyi türetilmiş çerçeve vardır: RCNN (ESA özellikli bölgeler) (Savalle ve ark., 2014) ve FCN (tam evrim) ağı (Long ve ark., 2015).



Şekil 3.7 ESA yöntemleri ve türev yöntemler.

Ana fikri birden fazla nesne önerileri oluşturulması için RCNN ve ESA kullanarak her teklifin özellikleri elde, ve daha sonra bir doğrusal SVM spesifik bir kategori kullanarak her pencere filtresi sınıflandırır. Bölgeler paradigması kullanan tanıma, nesne tespitinde performansı teşvik etmiştir ve zaman içinde gelecek vaat eden nesne tespit algoritmaları için genel boru hattı haline gelmiştir. Bununla birlikte, RCNN'nin performansı, sağlamlığını sınırlayabilen nesne konumunun kesinliğine çok fazla güvenmektedir. Ayrıca, çok sayıda teklifin üretilmesi ve işlenmesi de verimliliğini azaltmaktadır. Son gelişmeler temel olarak bu iki konuya odaklanmaktadır. RCNN, ESA modellerini özellik çıkarıcı olarak almaktadır ve ağlarda herhangi bir değişiklik yapmamaktadır. Buna karşılık, FCN, ESA modellerini, görüntü çözünürlüğünün kısıtlanmasını ortadan kaldıran ve verimli bir şekilde karşılık gelen boyutlu çıktılar üretebilen, tamamen evrimsel ağlar olarak yeniden düzenlemeyi önermiştir. Her ne kadar FCN esas olarak semantik segmentasyon için önerilmiş olsa da, teknik başka görüntü sınıflandırma, kenar algılama vb uygulamalarda da kullanılabilmektedir.

3.3.6. Aktivasyon fonksiyonu

Aktivasyon, bir sinir sisteminin verimini belirleyen sayısal koşullardır. Kapasite, sistemdeki her nörona eklenir ve her nöronun bilgilerinin modelin beklentisi için önemli olup olmadığına karar verilmesine karar verilip verilmemesi gerektiğine karar verir. Aynı zamanda, yasalaştırma çalışmaları da her nöronun verimini 1 ile 0 ya da - 1 ile 1 arasında bir aralıkta standartlaştırmaya yardımcı olur. Aktivasyon ekstra bir kısmı, her bir referans testi için, binlerce üzerinde çapraz bir şekilde tespit edildikleri gerekçesiyle hesaplanabilir şekilde etkili olmaları gerektiğidir. Günümüzde sinir sistemleri, başlatma kapasitesine ve bunun yardımcı kapasitesine genişletilmiş bir hesaplama zorlaması getiren modeli hazırlamak için geri yayılım adı verilen bir yöntemi kullanmaktadır. (Nwankpa ve ark., 2018).

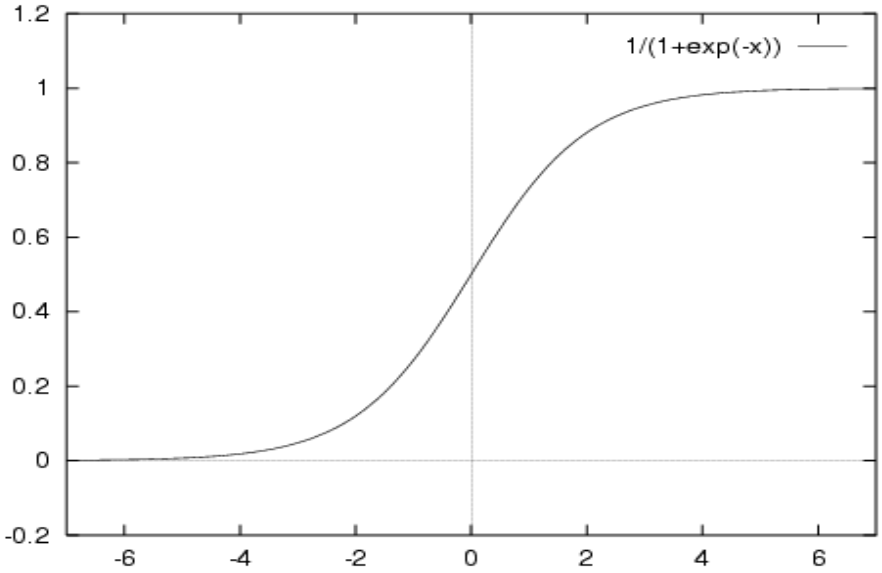
Aktivasyon Fonksiyonlarının çok kullanılan tipleri:

- **Softmax Aktivasyonu**: Genel olarak çok katmanlı sinir ağlarının çıktı katmanlarında sınıflandırma görevi yapmak için kullanılır. Reelinde her bir sınıfın ihtimalini hesaplar. İhtimallerden bahsettiğimizden, tüm softmax'ların toplamı bir çıktı tabakasına denktir. Sınıflar arasında katı bir seçim yapmak yerine, softmax, girdinin büyük olasılıkla hangi sınıfa ait olduğunu tahmin etmektedir. M sınıfının olduğu varsayılarak, softmax şu şekilde temsil edilebilir (Martins ve Astudillo, 2016):

$$softmx\ (x\square) = \frac{e^{xk}}{\sum_{i=1}^{M} e^{x_i}}$$

- **Sigmoid Aktivasyonu**: Sigmoid fonksiyonları, lojistik regresyon ve temel sinir ağı uygulamaları için makine öğrenmesinde kullanılır ve bunlar giriş aktivasyon üniteleridir. Ancak gelişmiş Sinir Ağı Sigmoid fonksiyonları, çeşitli sakıncalar nedeniyle tercih edilmez.

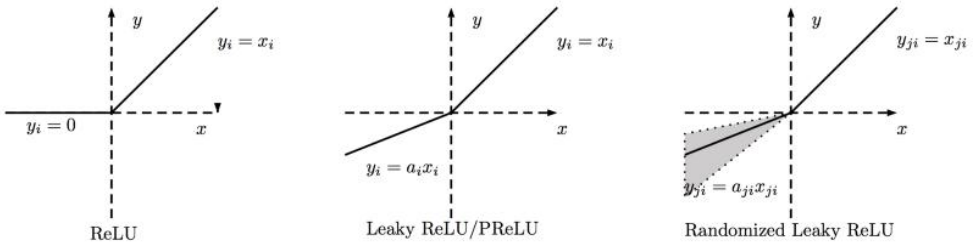
f (x) = 1/1 + exp (-x) formunun aktivasyon işlevidir. Şekil 3.8'de sigmoid aktivasyon çizimi göstermektedir (Karlik ve ark., 2011).



Şekil 3.8 Sigmoid Aktivasyonu

- **ReLu Aktivasyonu:** Tüm derin öğrenme Modelleri günümüzde ReLu'yu kullanmaktadır. Ancak sınırlaması, sadece bir sinir Ağı Modelinin gizli katmanları içinde kullanılması gerekmektedir. Bu nedenle, çıktı katmanları için, sınıfların olasılıklarını hesaplamak adına bir sınıflandırma problemi için Softmax fonksiyonunu kullanmalı ve bir regresyon problemi için basitçe doğrusal bir fonksiyon kullanmalıdır. ReLu ile ilgili diğer bir problem, bazı gradyanların eğitim sırasında kırılgan olabileceği ve ölebileceğidir. Hiçbir veri noktasında tekrar aktive etmemesini sağlayacak bir ağırlık güncellemesine neden olabilmektedir. Basitçe söylemek gerekirse, ReLu Ölü Nöronlar ile sonuçlanabilmektedir. Bu sorunu çözmek için yani ölmekte olan nöronların problemini çözmek için Leaky ReLu adı

verilen başka bir değişiklik daha yapılmıştır. Güncellemeleri canlı tutmak için küçük bir eğim sunulmaktadır. (Ramachandran ve ark., 2017). Şekil 3.p'de relu aktivasyon çizimi göstermektedir.

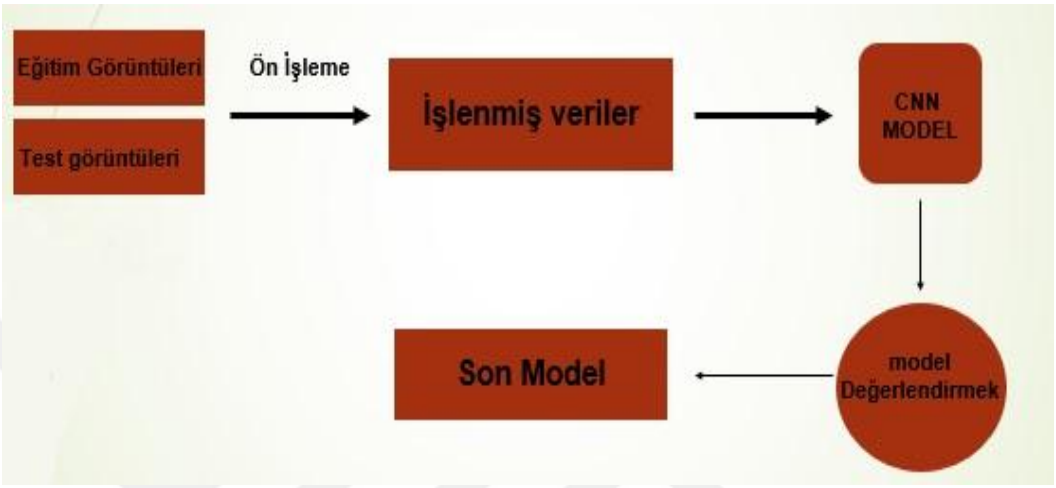


Şekil 3.9 ReLu- Rectified Linear üniteleri

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

4.1. Araştırmalar

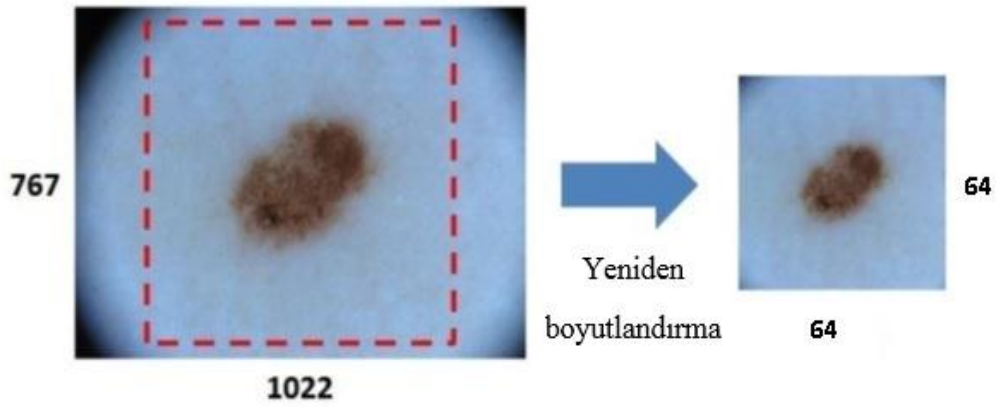
Şekil 4.1'de, bu çalışma için yaratılan ve modelin oluşturulduğu adımları açıklayan diyagram görülmektedir.



Şekil 4.1 Son işlem şeması.

4.1.1. Veri kümesi ön işlemesi:

İlk adım görüntüleri hazırlamaktır. Derin öğrenme sistemi için benin görüntülerini yeniden düzenlemek esastır. Özel olarak görselleri yeniden boyutlandırmak. İç karenin kapsamı, resmin netliğinin 64 x 64'ü olarak ayarlanmış, ayrıca resim odağına göre doğal olarak düzenlenmiştir. Şekil 4.2'te tanımlandığı gibi, bu metodoloji sadece vurgulama tanımlaması için yaralanma bölgesini genişletmekle kalmaz, aynı zamanda cilt ağrısının durumunu da korumaktadır. Veri kümesinin ön işleme örneği şekil 4.2 gösterilmektedir.



Şekil 4.2. cilt görüntüsü için ön işleme. Görseli yeniden boyutlandırın.

4.1.2. ESA model:

Düşünce, dışarıdan yardım almadan başlayarak temel bir ESA ekranı oluşturmak ve bir desen belirlemek için yürütmeyi değerlendirmektir. Modeli geliştirmek için eşlik eden adımlar şunlardır. (American Cancer, 2012)

Veri büyütme: Pivotlar, gürültülü, fazla uydurmaktan kaçınmak için ölçeklendirmedir.

Aktarılan öğrenme: Önceden hazırlanmış bir sistemin kullanılması, modelimizi ayar yapmak için sonuca doğru bazı ekstra katmanlar oluşturur.

4.1.3 ESA mimarisi

Şekil 4.3 'de, bu çalışma için yaratılmış olan ve modelin inşa edildiği adımları açıklayan mimari görünmektedir.

Çizelge 4.1 ESA mimarisi.

Katmanlar	Parameterler	Değerler
Giriş katmanı	Input size	64*64*3
Görüntü jeneratör	Her bir görüntüyü birden fazla olacak şekilde eğitime sunacaktır	
Evreşimsel katmanı	Filtrelerin sayıları Kernel Aktivasyon işlev	16 3*3 Relu katmanı
Havuz katmanı	Kernel	2*2
Evreşimsel katmanı	Filtrelerin sayıları Kernel Aktivasyon işlev	32 3*3 Relu katmanı
Havuz katmanı	Kernel	2*2
Evreşimsel katmanı	Filtrelerin sayıları Kernel Aktivasyon işlev	64 3*3 Relu katmanı
Havuz katmanı	Kernel	2*2
Tam bağlı katmanı	Filtrelerin sayıları Aktivasyon işlev	64 Sigmoid
Çıkış	Sigmoid Aktivasyon	İki çeşit

- Giriş resmi: 64x64x3 Resim boyutudur
- Görüntü Jeneratör: Her bir görüntüyü birden fazla olacak şekilde eğitime sunacaktır.
- Evrişim katmanı: ConvNet'in ortaya çıkması gerektiğinde Katlamanın temel rolü, vurguları bilgi resminden ayırmaktır. Katlama, küçük bilgi kareleri kullanarak resim olaylarını öğrenerek pikseller arasındaki uzamsal bağlantıyı korumaktadır, mimaride 3x3 kanallı Conv katmanlarını kullanılmıştır.
- Havuzlama katmanı: Kapasite, sistemdeki parametrelerin ve hesaplamaların ölçülmesini azaltmak ve böylece aynı şekilde kontrolün aşırı yüklenmesini azaltmak için portrenin uzaysal boyutunu sürekli olarak azaltmaktır. Havuz Katmanı, bilginin her kestirme kesiminde bağımsız olarak çalışmaktadır ve MAX faaliyetini kullanarak, mekânsal olarak yeniden boyutlandırmaktadır. 2x2 kanallı Havuzlama katmanı kullanılmıştır.
- Düzleştirim katmanı: Düzleştirme, sonuçta elde edilen tüm 2 boyutlu kümeler üzerinde, sınıflandırıcı katman (Yoğun Katman) için bir katkı olarak olmak üzere, bir 1D direkt vektörüne geçmenin yoludur.
- Dropout layer: Bırakma, sinir hazırlama sistemlerindeki aşırı uyumu azaltmak için, bilgi hazırlarken karmaşık eş ayarlamaları engelleyerek yapılan bir düzenleme sistemidir. Sinir sistemlerinde ortalama alma modeli yapmak için son derece yetkin bir yöntemdir. "Bırakma" ifadesi, bir sinir sisteminde (hem örtülmüş hem de dikkat çeken) birimleri bırakmaya hitap etmektedir

4.1.4 Model değerlendirmesi:

- Modeli değerlendirmek için ROC Eğrileri ve AUC kullanılmıştır. Doğru modeli seçmek için Doğru Pozitif Oran (TPR True Positive Rate) ve Yanlış Pozitif Oran (FPR False Positive Rate) değerlendirilecektir.
- Evrişim Matrisi: Bir evrişim matrisi nedir? Matematiksel araçlar kullanılmadan kaba bir fikir edinmek mümkündür. Matriksi, bir başkası matrix tarafından işlenen olarak "Kernel" adlandırmaktadır. Çoğu filtre, evrişimli bir matris kullanır. Convolution Matrisi, işlenecek görüntü olan birinci matris kullanılır. Görüntü, dikdörtgen koordinatlardaki iki boyutlu bir piksel setidir. Kullanılan çekirdek, istediğiniz etkiye bağlıdır. Filtre, sırasıyla görüntünün her pikselini inceler. "Birincil piksel" olarak adlandıracağımız her biri, bu pikselin değerini ve sekiz çevre pikselin değerlerini, çekirdeğin karşılık gelen değeri ile çarpar. Sonra sonuçları ekler ve ilk piksel bu son

sonucun değerine ayarlanır. Bu çalışmada yapılan Evrişim Matrisi Çizelge 4.2'de verilmiştir.

Çizelgede (4.2) Çalışmanın Evrişim Matrisi sonuçları

Evrişim Matrisi		Sonuç tahminler	
		Evet	Hayır
Gerçek değer	Hayıt	TP 325	FN 35
	Evet	FP 49	TN 246

- ROC: Alıcı Çalışma Karakteristiği Performans grafiklime yöntemidir. Verileri değerlendirmek ve farklı sınıflandırıcılar arasında göreceli performansı karşılaştırmak için kullanılan Gerçek pozitif (TP) ve yanlış pozitif (FP) oranlarının bir grafiği.
- Gerçek pozitif oran TPR = TP / P

(TPR= p olarak doğru sınıflandırılanların sayısı / Test verilerinde pozitif sayısı)

- Yanlış pozitif oran FPR = FP / N

(FPR= p olarak yanlış sınıflandırılmış sayı / Test verilerindeki negatiflerin sayısı).

Not:

TP + FN = P

TN + FP = N

4.2. Sonuçlar

Modelin daha iyi sonuç almasını sağlamak için, modelin özelliği değiştirilmiştir. Fotoğraf kalitesi, katmanların sayısı ve türleri gibi parametreler değiştirilerek her biri için farklı bir sonuç ve doğruluk elde edilebilir.

Her bir değişiklik sonucu için gereken süre, doğruluk oranı sırası ile çizelge 4.3'de gösterilmiştir:

Çizelge (4.3) Her bir değişiklik sonucu için gereken süre ve doğruluk değerinin sırası

No	Değişikler	Doğruluk	Süre
1	Tek Katmanlı ESA 16, 3*3 kernel, 15 Epoch.	%73,43	12 Sn/Epoch
2	Çift katmanlı ESA 16 ve 32, 3*3 kernel, 15 Epoch.	%73,43	23Sn/Epoch
3	Üç Katmanlı ESA 16 ve 32 3*3 kernel, 15 Epoch.	%73,67	35Sn/Epoch
4	İki Katmanlı ESA 16 ve 32 3*3 kernel, 15 Epoch.	%74,5	13Sn/Epoch
5	İki Katmanlı ESA 16 ve 32 5*5 kernel, 15 Epoch.	%74,5	25Sn/Epoch
6	İki Katmanlı ESA 16 ve 32 ve 64 7*7 kernel, 15 Epoch.	%75,1	39Sn/Epoch
7	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 15 Epoch.	%78,21	16Sn/Epoch
8	Üç Katmanlı ESA 16, 32 ve 64. 5*5 kernel, 15 Epoch.	%78,3	23Sn/Epoch
9	Üç Katmanlı ESA 16, 32 ve 64. 7*7 kernel, 15 Epoch.	%78,3	45Sn/Epoch
10	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 15 Epoch.	%80,5	23Sn/Epoch
11	Üç Katmanlı ESA 32, 64 ve 128. 5*5 kernel, 15 Epoch.	%80,6	33Sn/Epoch
12	Üç Katmanlı ESA 32, 64 ve 128. 7*7 kernel, 15 Epoch.	%80,6	45Sn/Epoch
13	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 20 Epoch.	%83,76	31Sn/Epoch
14	Üç Katmanlı ESA 32, 64 ve 128. 5*5 kernel, 20 Epoch.	%83,75	52Sn/Epoch

15	Üç Katmanlı ESA 32, 64 ve 128. 7*7 kernel, 20 Epoch.	%83,76	74Sn/Epoch
16	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 25 Epoch.	%84,43	32Sn/Epoch
17	Üç Katmanlı ESA 32, 64 ve 128. 5*5 kernel, 25 Epoch.	%84,4	68Sn/Epoch
18	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 30 Epoch.	%84,6	35Sn/Epoch
19	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 30 Epoch.	%84,6	71Sn/Epoch
20	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 35 Epoch.	%84,7	36Sn/Epoch
21	Üç Katmanlı ESA 32, 64 ve 128. 5*5 kernel, 35 Epoch.	%84,9	69Sn/Epoch
22	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 40 Epoch.	%82,5	43Sn/Epoch
23	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 40 Epoch.	%82,7	74Sn/Epoch
24	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 35 Epoch. Aktivasyör Relu	%46,6	21Sn/Epoch
25	Üç Katmanlı ESA 316, 32 ve 64. 3*3 kernel, 35 Epoch, Aktivasyör Softmax	%84,14	34Sn/Epoch
26	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 35 Epoch, Aktivasyör Sigmoid	%85,76	32Sn/Epoch
27	Üç Katmanlı ESA 16, 32 ve 64. 5*5 kernel, 35 Epoch, Aktivasyör Sigmoid	%84,16	46 Sn/Epoch

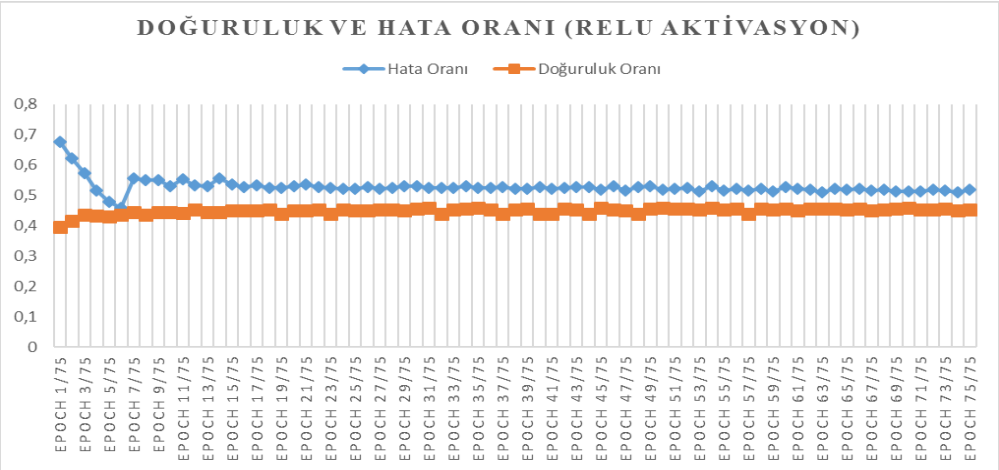
28	Üç Katmanlı ESA 16, 32 ve 64. 7*7 kernel, 35 Epoch, Aktivasyör Sigmoid	%83,17	59 Sn/Epoch
29	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 45 Epoch. Aktivasyör Relu	%49,6	21Sn/Epoch
30	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 45 Epoch, Aktivasyör Softmax	%84,04	34Sn/Epoch
31	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 45 Epoch, Aktivasyör Sigmoid	%84,19	32Sn/Epoch
32	Üç Katmanlı ESA 16, 32 ve 64. 5*5 kernel, 45 Epoch, Aktivasyör Sigmoid	%84,18	46 Sn/Epoch
33	Üç Katmanlı ESA 16, 32 ve 64. 7*7 kernel, 55 Epoch, Aktivasyör Sigmoid	%82,7	59 Sn/Epoch
34	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 60 Epoch, Aktivasyör Sigmoid	%82,9	45Sn/Epoch
35	Üç Katmanlı ESA 32, 64 ve128. 3*3 kernel, 70 Epoch, Aktivasyör Sigmoid	%83,69	48Sn/Epoch
36	Üç Katmanlı ESA 32, 64 ve 128. 3*3 kernel, 75 Epoch, Aktivasyör Sigmoid	%81,3	47Sn/Epoch
37	Üç Katmanlı ESA 64, 32 ve 16. 3*3 kernel, 75 Epoch, Aktivasyör Sigmoid, Resim boyutu 64*64	%80,5	56 Sn/Epoch

38	Üç Katmanlı ESA 64, 32 ve 16. 3*3 kernel, 75 Epoch, Aktivasyör Softmax, Resim boyutu 64*64	%79,1	54 Sn/Epoch
39	Üç Katmanlı ESA 64, 32 ve 16. 3*3 kernel, 75 Epoch, Aktivasyör Sigmoid, Resim boyutu 224*224	%81.11	660 Sn/Epoch
40	Üç Katmanlı ESA 64, 32 ve 16. 3*3 kernel, 75 Epoch, Aktivasyör softmax, Resim boyutu 224*224	%80.9	606 Sn /Epoch
41	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 75 Epoch, Aktivasyör Sigmoid, Resim boyutu 224*224	%82.31	535 Sn/Epoch
42	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 75 Epoch, Aktivasyör softmax, Resim boyutu 224*224	%80.01	555 Sn/Epoch
43	Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 75 Epoch, Aktivasyör Sigmoid, Resim boyutu 64*64 (En yüksek olan sonuç)	%85.76	65 Sn/Epoch

Çizelge 4.2'ye göre yapılan değişikler ile farklı sonuçlar elde edilmiştir ve her yapılan değişiklikte alınan sonuç 10 çalışmadan en iyi sonucu vermektedir. En iyi olan sonuç (Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 75 Epoch, Aktivasyör Sigmoid) olmaktadır.

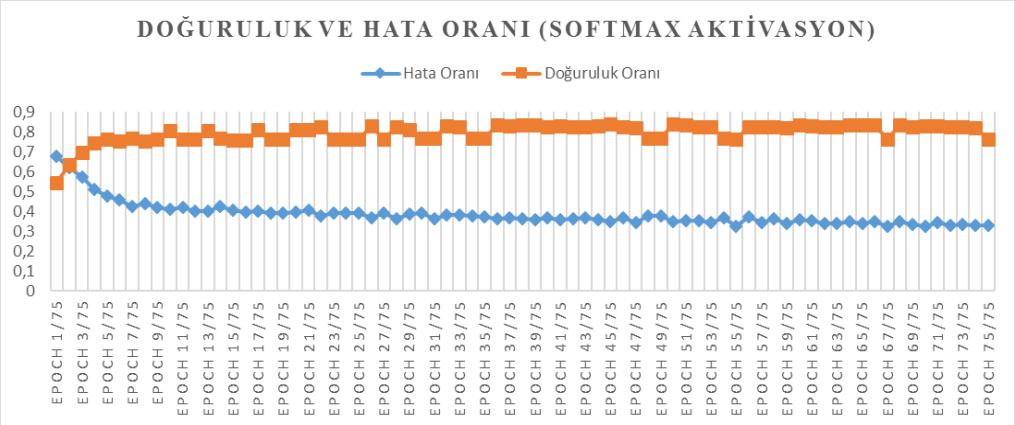
Şekil (4.4), (4.5) ve (4.6) de (Üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 75 Epoch) modelin farklı aktivasyon kullanılarak sonuçları göstermektedir.

(Relu Layer) 10 devirle kullanıldığında olduğu gibi aktivasyon katmanlarını değiştirdiğimizde bu sonuç farklı olabilir, Şekil (4.4) 'de gösterildiği gibi% 45 veya% 48 gibi düşük doğruluk elde edilir.



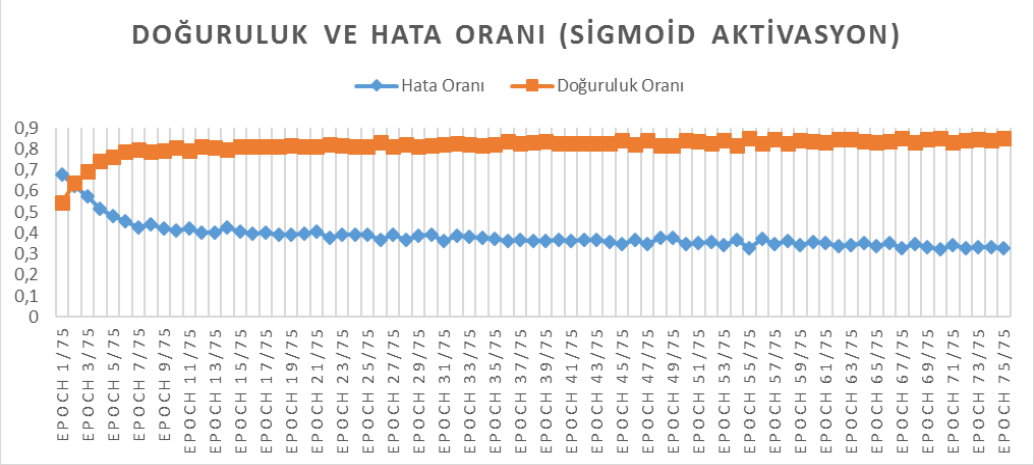
Şekil (4.4) Relu Aktivasyonunu kullanarak modelin sonucu.

Softmax Aktivasyon olarak 10 devirle kullanıldığında, Şekil 4.5'de gösterildiği gibi % 84,04 sonuç alınmıştır.



Şekil (4.5) Softmax Aktivasyonunu kullanarak modelin sonucu.

Sigmoid Aktivasyonu olarak 10 devirle kullanıldığında, Şekil 4.6 'da gösterildiği gibi % 85,76 sonuç alınmıştır.



Şekil (4.6) Sigmoid Aktivasyon Kullanarak modelin sonucu.

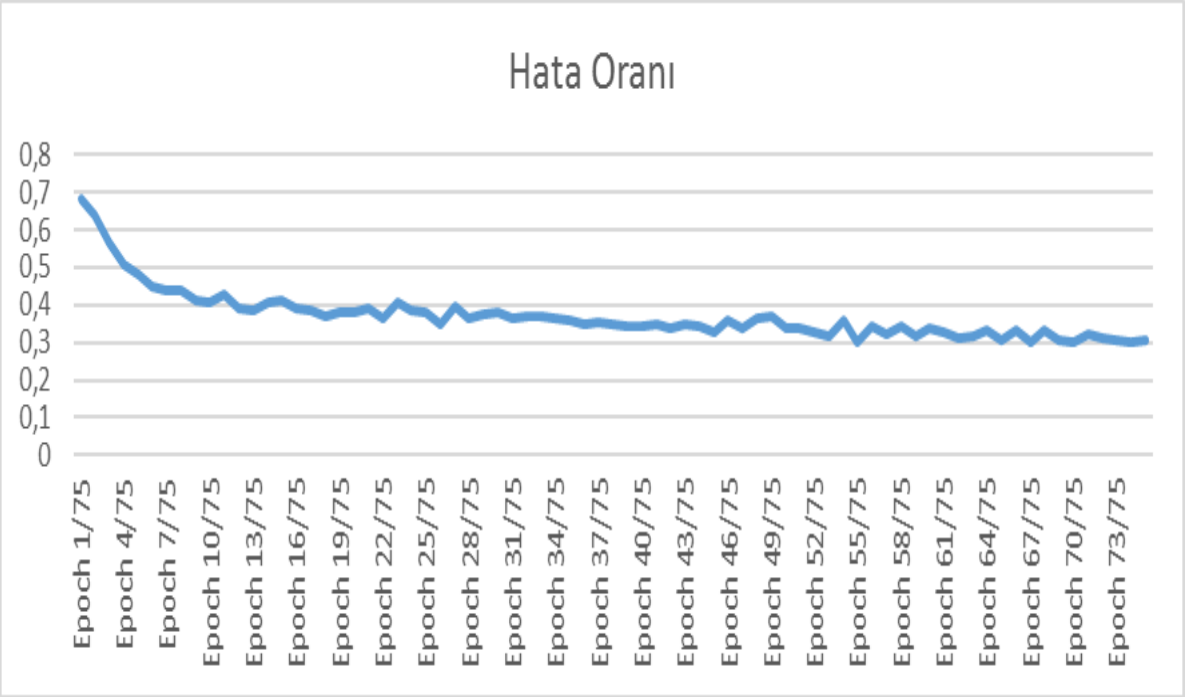
Bu çalışmanın üç Katmanlı ESA 16, 32 ve 64. 3*3 kernel, 75 Epoch ve Aktivasyör Sigmoid modelini kullanarak, elde edilen en iyi sonuçlardan pozitif olan değerleri. Çizelge 4.4'te en iyi modelin sonuçlar yazılmıştır.

Çizelge (4.4) en iyi modelin sonuçlar

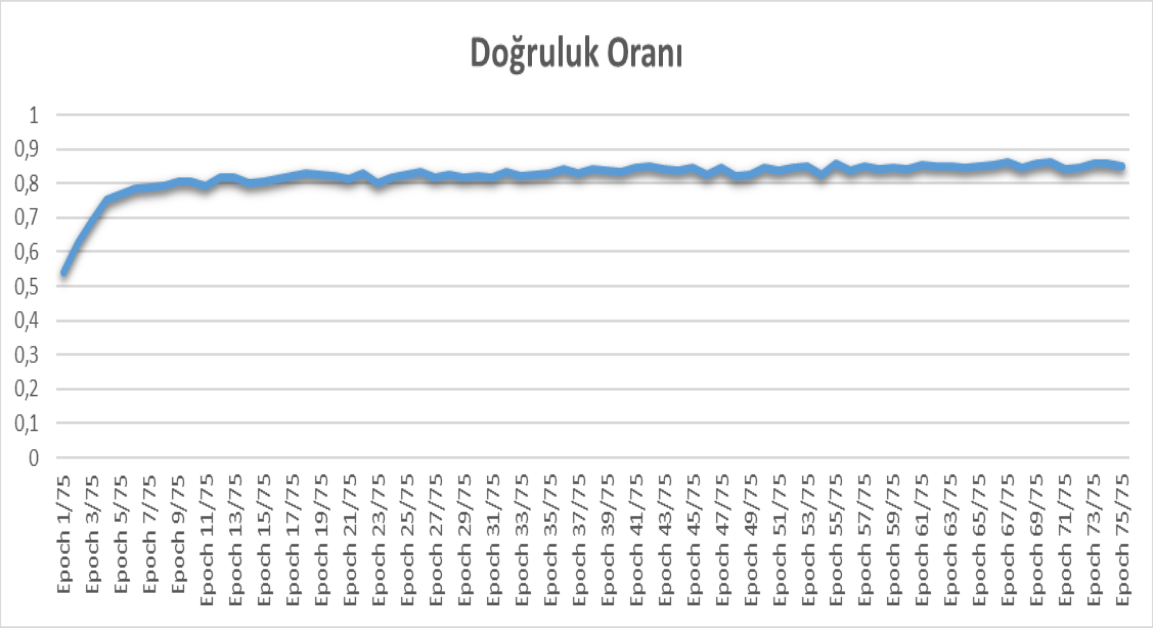
Epoch	E-Time/Step	Hata Oranı	Doğuruluk Oranı
Epoch 1/75	30,7	0,676	0,5446
Epoch 2/75	28,6	0,6221	0,6368
Epoch 3/75	28,5	0,5739	0,6949
Epoch 4/75	27,6	0,5131	0,7434
Epoch 5/75	27,6	0,4787	0,7614
Epoch 6/75	28,6	0,4573	0,7847
Epoch 7/75	28,68	0,4259	0,7981
Epoch 8/75	27,66	0,441	0,7848
Epoch 9/75	28,69	0,4211	0,794
Epoch 10/75	28,67	0,4101	0,8052
Epoch 11/75	27,66	0,4222	0,791
Epoch 12/75	28,67	0,4016	0,8119
Epoch 13/75	27,66	0,4015	0,8044
Epoch 14/75	28,67	0,4265	0,7963
Epoch 15/75	27,66	0,4065	0,8103
Epoch 16/75	27,66	0,398	0,8103
Epoch 17/75	27,65	0,4028	0,8092
Epoch 18/75	28,69	0,3939	0,813
Epoch 19/75	28,68	0,3937	0,8145
Epoch 20/75	27,66	0,3987	0,8092
Epoch 21/75	28,68	0,4049	0,8094
Epoch 22/75	28,68	0,3774	0,8229
Epoch 23/75	27,66	0,3942	0,8145
Epoch 24/75	27,66	0,3922	0,8127
Epoch 25/75	27,66	0,3903	0,8107
Epoch 26/75	27,666	0,3686	0,8311
Epoch 27/75	27,69	0,3928	0,8119
Epoch 28/75	25,6	0,3655	0,8233
Epoch 29/75	25,6	0,3887	0,8096
Epoch 30/75	25,6	0,3899	0,8164
Epoch 31/75	25,6	0,363	0,8199
Epoch 32/75	25,6	0,3848	0,8283
Epoch 33/75	25,59	0,3839	0,8228
Epoch 34/75	25,6	0,3791	0,8161
Epoch 35/75	25,61	0,3732	0,8199
Epoch 36/75	25,61	0,3639	0,8354
Epoch 37/75	26,62	0,367	0,8282
Epoch 38/75	25,6	0,3623	0,8327

Epoch 39/75	25,61	0,3601	0,8355
Epoch 40/75	25,6	0,3683	0,824
Epoch 41/75	25,6	0,3606	0,8281
Epoch 42/75	25,59	0,3651	0,8255
Epoch 43/75	25,617	0,3685	0,8239
Epoch 44/75	26,62	0,3582	0,8274
Epoch 45/75	25,59	0,3492	0,8395
Epoch 46/75	25,61	0,3691	0,8229
Epoch 47/75	25,612	0,3459	0,84
Epoch 48/75	25,619	0,3761	0,8179
Epoch 49/75	25,615	0,3787	0,8157
Epoch 50/75	26,63	0,3479	0,8399
Epoch 51/75	26,627	0,3527	0,8358
Epoch 52/75	25,617	0,3556	0,8253
Epoch 53/75	25,621	0,3428	0,8426
Epoch 54/75	25,612	0,3688	0,8173
Epoch 55/75	24,59	0,3259	0,8521
Epoch 56/75	25,6	0,3714	0,826
Epoch 57/75	25,621	0,3455	0,8441
Epoch 58/75	25,6	0,3624	0,825
Epoch 59/75	26,62	0,3418	0,8417
Epoch 60/75	25,614	0,3577	0,8657
Epoch 61/75	26,634	0,3528	0,8303
Epoch 62/75	25,613	0,3395	0,8457
Epoch 63/75	25,619	0,3406	0,845
Epoch 64/75	25,611	0,3508	0,8655
Epoch 65/75	25,614	0,3376	0,8334
Epoch 66/75	25,62	0,3508	0,8358
Epoch 67/75	26,623	0,3256	0,8514
Epoch 68/75	25,62	0,3486	0,8336
Epoch 69/75	25,615	0,3342	0,8456
Epoch 70/75	25,612	0,3235	0,8491
Epoch 71/75	26,646	0,3432	0,8317
Epoch 72/75	25,616	0,3298	0,8425
Epoch 73/75	25,613	0,3348	0,8462
Epoch 74/75	25,616	0,3308	0,8404
Epoch 75/75	25,6	0,3285	0,8533

En iyi modelin sonuçları Şekil 4.7’de hata Oranı ve Şekil 4.8’de doğruluk oranı olarak gösterilmiştir.



Şekil (4.7) en iyi modelin hata oranı.



Şekil (4.8) en iyi modelin doğruluk oranı.

Bu sonuçlara göre doğruluk ve hata oranları belli olduktan sonar, Sensitivity ve Specificity oranlarını görülmektedir.

TP: 325
FN: 35
FP: 49
TN: 246

Model performansı
Sensitivity=TP/ (TP+FN) =%89,8
Specificity=TN/ (TN+FP) =%72
Test başarısı % 85.76

Çizelge 4.5'te bu çalışmanın daha önceki yapılan farklı ESA çalışmalarında kullanılan modeller ve ISIC veri kümesinin kullanılan ve ortaya çıkan sonuçları, yapılan çalışmanın sonuçları ile karşılaştırmaktadır. Bu çizelgeye göre elde edilen sonuçlar diğer sonuçlara göre kıyaslanabilir sonuçlar elde edilmiştir.

Çizelge (4.5) diğer ESA İşlerinin performansı

Yazar	Veri kümesi	Kullanılan görüntü	Accur.	Sens.
(G Wiselin Jiji1, 2017)	ISIC 2017	2000 Train 600 Test	%72,2	% 68
(P. Mirunalini, 13 Mar 2017)	ISIC 2017	2000 Train 600 Test	%65,8	%61
(Chang, 2017)	ISIC 2017	2000 Train 600 Test	%80,1	%63,2
(Amirreza Mahbod, 2017)	ISIC 2017	2000 Train 600 Test	%83.83	%69
(Moraes, 2017)	ISIC 2017	2000 Train 600 Test	%89,3	%78
(Harangi, 2017)	ISIC 2017	2000 Train 600 Test	%86,15	%76,3
(Shen, 2017)	ISIC 2017	2000 Train 600 Test	%85,1	%79,4
Önerilen yöntem (Evrişimsel Sinir Ağları Kullanarak Cilt Kanseri Risk Değerlendirmesi)	ISIC 2017	2000 Train 600 Test	%85,76	%89,8

Çizelge 4.6'te bu çalışmanın daha önceki yapılan farklı makine öğrenme yöntemlerinde kullanılan modeller ve farklı veri kümesinin kullanılan ve ortaya çıkan sonuçları, yapılan çalışmanın sonuçları ile karşılaştırmaktadır. Bu çizelgeye göre elde ettiğimiz sonucun diğer elde edilen sonuca göre daha yüksek olduğu görülmektedir.

Çizelge (4.6) Diğer Sınıflandırma Tekniklerinin Performansı

Yazar (Yıl)	Veri kümesi	Sınıflandırıcı	Performans ölçümü
(Mahammed ve ark., 2009)	CHUT (Centre hospitalier Universitaire de Tlemcen, Algeria)	ANN	Sens: %67.50 Accur: %74.50
(Mondal ve ark., 2010)	The Herbal Grand Research Center 2009	KNN NN SVM, ML GAUSSİAN	Accur: %75.69
(Rietveld ve ark., 2013)	----	SVM, LDA	Sens: %83.53 Accur: %80.46
(Oliveira ve ark., 2016)	----	ANN	Accur: %73.80
Önerilen yöntem (Evrişimsel Sinir Ağları Kullanarak Cilt Kanseri Risk Değerlendirmesi)	ISIC 2017	ESA	Accur: %85.76 Sens: %89.8 Spens: %72

4.3. Tartışma

Cilt kanseri alanında yapılmış birçok proje bulunmaktadır. Araştırmacılar, yukarıda belirtilen farklı metotlar ile yapılan çalışmalarda çoğunlukla olumlu sonuçlara ulaşmayı başarabilmişlerdir. Bazılarının başarısızlığa uğrayarak, farklı sonuçları elde ettikleri önceki çalışmalarda yukarıda belirtilen çeşitli yöntemlerle birçok başarıya ulaşabilen bir proje oluşturmuşlardır.

Yapılan çalışmalarda önceki araştırmalar ile mevcut araştırmalar karşılaştırıldığında, önceki araştırmalar incelendiğinde ve onlardan profesyonellerin elde ettiği farklı yöntem ve verilerin kaynaklarına göre sonuçlardaki benzerliklerin

bulunduğu bilinmektedir. Bu projedeki çalışmanın temelinde önceki çalışmaların deneyimlerinden yararlanılmıştır. Aynı sayıda veri seti kullanılarak daha detaylı bir inceleme yapılması sağlanmıştır. Kullandığımız bu veri kümesi ile daha geniş bir sınıflama sistemine tabii tutularak modelleme yapılmıştır. Sonuç olarak kullanılan modelleme ile daha önce yapılan çalışmalardaki sonuca göre elde edilen sonuç daha yüksek bir orana sahiptir. Yapılan çalışmalar incelenip geliştirilerek, kullanılan farklı bir metot ile daha iyi bir sonuç elde edildiği görülmektedir. Çalışma ile benlerin kansere karşı oluşturabileceği tehdidin daha hızlı ve kolay anlaşılması hedeflenerek elde edilen pozitif etkili sonuç görülmektedir. Bu sayede birçok insanın hayati risk taşımasını ve sağlığı için büyük oranda tehdit oluşturabilecek benlerin erken teşhisi saklanılacaktır.

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Cilt kanseri, insan gruplarının büyük bir ölçüsünü etkileyen tipik bir hastalıktır. Dünyada 30.770 yeni bir obtrusif Cilt Kanseri vakası incelenmiştir. 2018'de Amerikan Kanser toplumu ile ilgili olarak, ABD'de Cilt Kanseriu erken ayırt edilen hastalar için 5 yıllık sağ kalım oranı değerlendirilmiştir. ABD'de yüzde 98 civarında olan sağ kalım oranı, enfeksiyon lenf göbeklerine ulaştığında yüzde 62'ye, hastalık metastaz yaptığında yüzde 18'e düşmektedir.

Tıp alanındaki Cilt Kanserini teşhis etmek için doktorlar kanseri bulmak veya teşhis etmek için birçok test kullanmaktadırlar. Doktorlar ayrıca hangi tedavilerin en iyi sonucu verebileceğini öğrenmek için testler yapmaktadırlar. Çoğu kanser türü için, biyopsi vücudun bir bölgesinin kanser olup olmadığını öğrenilmesinin tek kesin yoludur.

Bu tezin amacı, insan vücudunda bulunan Benleri tespit etmek ve bunları normal bir Ben veya bir tür cilt kanseri (malign) olarak sınıflandırmak için bir program oluşturmaktır. Aynı sayıda veri kümesi kullanılarak daha detaylı bir inceleme yapılması sağlanmıştır. Kullanılan bu veri kümesi ile daha geniş bir sınıflama sistemine tabii tutularak modelleme yapılmıştır. Sonuç olarak kullanılan modelleme ile daha önce yapılan çalışmalardaki sonuca göre elde edilen sonuç daha yüksek bir orana sahiptir. Yapılan çalışmalar incelenip geliştirilerek, kullanılan farklı bir metot ile daha iyi bir sonuç elde edildiği görülmektedir. Bu program doktorların yerini almaz ancak insanların bu ciddi hastalığı daha az maliyetle ve daha hızlı bir şekilde tanımlamalarına yardımcı olmaktadır.

Doktorlar, bu hastalığı, ameliyat yoluyla atılan toksinin bir kısmını naklederek ve tümörün normal ve vücutta iyi huylu olduğu, doğru sonuçlar vermesi uzun zaman alabilen birçok pahalı analizler yaparak tespit edebilirler.

Bu tezin amacı, insanlara yardımcı olmak ve gereksiz olabilecek testler ve cerrahi prosedürler için doktora gitmelerini engellemek ve vücuttaki tümörlerin derecesini belirlemek için bu programı deneyimlemektir.

Bu çalışmada ISIC den alınan veri kümesindeki görüntülere göre bir ESA modeli oluşturulmuş ve bu modelde bu benlerin hangisinin kanser olduğunu tespit

etmek için yapılmıştır, ancak bu çalışmadan alınan sonuçlar iyi bir derecede olmaktadır ve doğruluk derecesi %85.76 olarak elde edilmiştir.

5.2. Öneriler

Gelecekteki işler için şu yol izlenmiştir:

(I) Daha iyi sonuçlar elde etmek için daha büyük bir veri kümesi kullanmak.

(II) Bu programı bir uygulamaya dönüştürmek akıllı telefonlarda kullanılabilmektedir. Böylece herkes bu projeyi en basit formatta kullanma şansına sahiptir.

KAYNAKLAR

2009, Skin Cancer, In: Encyclopedia of Cancer, Eds: Schwab, M., Berlin, Heidelberg: Springer Berlin Heidelberg, p. 2751-2751., H. S. J., †,Received for review July 15, 2013, <nn405383a.pdf55.pdf>.

Albayatı, s. h. m., 2018, yeni silika tabanlı akıllı ilaç taşıyıcı sistemin geliştirilmesi ve ilaç salım özelliklerinin incelenmesi.

American Cancer, S., 2012, Melanoma skin cancer : what you need to know-- now.

Antoniou, A., Storkey, A. ve Edwards, H., 2017, Data augmentation generative adversarial networks, arXiv preprint arXiv:1711.04340.

Baldi, Agostinelli, F., Hoffman, M., Sadowski, P. ve Baldi, P., 2014, Learning activation functions to improve deep neural networks, arXiv preprint arXiv:1412.6830.

Barata, C., Ruela, M., Francisco, M., Mendonça, T. ve Marques, J. S., 2014, Two Systems for the Detection of Melanomas in Dermoscopy Images Using Texture and Color Features, IEEE Systems Journal, 8 (3), 965-979.

Bloice, M. D., Stocker, C. ve Holzinger, A., 2017, Augmentor: an image augmentation library for machine learning, arXiv preprint arXiv:1708.04680.

Boles ve Boashash, B., 1998, A human identification technique using images of the iris and wavelet transform, IEEE Transactions on Signal Processing, 46 (4), 1185-1188.

Bouthillier, X., Konda, K., Vincent, P. ve Memisevic, R., 2015, Dropout as data augmentation, arXiv preprint arXiv:1506.08700.

Bureau, D., Dumas, A. ve France, J., 2010, Modelling growth and body composition in fish nutrition: where have we been and where are we going?, Aquaculture Research, 41 (2), 161-181.

Chang, H., 2017, Skin cancer reorganization and classification with deep neural network.

Chris Pearce, C. R., D. Suster, and D. Wang.,, 2016, "Deep Learning Assessment of Tumor Proliferation in Breast Cancer Histological Images",.

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. ve 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), 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), 168-172.

Cruz-Roa, A. A., Arevalo Ovalle, J. E., Madabhushi, A. ve González Osorio, F. A., 2013, A Deep Learning Architecture for Image Representation, Visual Interpretability and Automated Basal-Cell Carcinoma Cancer Detection, Berlin, Heidelberg, 403-410.

E. Nasr-Esfahani, S. S., N. Karimi, 2016, Melanoma Detection by Analysis of Clinical Images Using Convolutional Neural Network.

Ehteshami Bejnordi, B., Veta, M., Johannes van Diest, P., van Ginneken, B., Karssemeijer, N., Litjens, G., van der Laak, J. A. W. M. ve Consortium, a. t. C., 2017, Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast CancerMachine Learning Detection of Breast Cancer Lymph Node MetastasesMachine Learning Detection of Breast Cancer Lymph Node Metastases, JAMA, 318 (22), 2199-2210.

Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. ve Thrun, S., 2017, Dermatologist-level classification of skin cancer with deep neural networks, Nature, 542, 115.

Golden, J. A., 2017, Deep Learning Algorithms for Detection of Lymph Node Metastases From Breast Cancer: Helping Artificial Intelligence Be SeenDeep Learning Algorithms for Detection of Lymph Node Metastases From Breast CancerEditorial, JAMA, 318 (22), 2184-2186.

G Wiselin Jiji1, P. J. D. R., 2017, An Extensive Technique to Detect and Analyze Melanoma: A Challenge at the International Symposium on Biomedical Imaging (ISBI) 2017.

Haney, M. O., Bahar, Z., Beser, A., Arkan, G. ve Cengiz, B., 2018, Psychometric Testing of the Turkish Version of the Skin Cancer and Sun Knowledge Scale in Nursing Students, J Cancer Educ, 33 (1), 21-28.

Hart, P. H. ve Norval, M., 2017, Ultraviolet radiation-induced immunosuppression and its relevance for skin carcinogenesis, Photochem Photobiol Sci.

Jafari, M. H., Karimi, N., Nasr-Esfahani, E., Samavi, S., Soroushmehr, S. M. R., Ward, K. ve Najarian, K., 2016, Skin lesion segmentation in clinical images using deep learning, 2016 23rd International Conference on Pattern Recognition (ICPR), 337-342.

Jain, S., jagtap, V. ve Pise, N., 2015, Computer Aided Melanoma Skin Cancer Detection Using Image Processing, Procedia Computer Science, 48, 735-740.

Jeremy Kawahara, 2016, <DEEP FEATURES TO CLASSIFY SKIN LESIONS.pdf>.

Karlik, B., Olgac, A. V. J. I. J. o. A. I. ve Systems, E., 2011, Performance analysis of various activation functions in generalized MLP architectures of neural networks, 1 (4), 111-122.

Li, Y. ve Shen, L., 2018, Skin Lesion Analysis towards Melanoma Detection Using Deep Learning Network, Sensors (Basel), 18 (2).

Lin, D., Qiu, S., Huang, W., Pan, J., Xu, Z., Chen, R., Feng, S., Chen, G., Li, Y., Short, M., Zhao, J., Fawzy, Y. ve Zeng, H., 2018, Autofluorescence and white light imaging-guided endoscopic Raman and diffuse reflectance spectroscopy for in vivo nasopharyngeal cancer detection, J Biophotonics, 11 (4), e201700251.

Long, J., Shelhamer, E. ve Darrell, T., 2015, Fully convolutional networks for semantic segmentation, Proceedings of the IEEE conference on computer vision and pattern recognition, 3431-3440.

Mamoshina, P., Vieira, A., Putin, E. ve Zhavoronkov, A., 2016, Applications of Deep Learning in Biomedicine, Molecular Pharmaceutics, 13 (5), 1445-1454.

Martins, A. ve Astudillo, R., 2016, From softmax to sparsemax: A sparse model of attention and multi-label classification, International Conference on Machine Learning, 1614-1623.

Mondal, D., Nasrin, K. N., Huda, M. M., Kabir, M., Hossain, M. S., Kroeger, A., Thomas, T. ve Haque, R., 2010, Enhanced Case Detection and Improved Diagnosis of PKDL in a Kala-azar-Endemic Area of Bangladesh, PLOS Neglected Tropical Diseases, 4 (10), e832.

Noar, S. M., Leas, E., Althouse, B. M., Dredze, M., Kelley, D. ve Ayers, J. W., 2018, Can a selfie promote public engagement with skin cancer?, Prev Med, 111, 280-283.

Oh, E. J., Choi, J. S., Kim, H. M., Joo, C. K. ve Hahn, S. K., 2011, Anti Flt1 Peptide-Hyaluronate Conjugate for the Treatment of Retinal Neovascularization and Diabetic Retinopathy, Biomaterials, 32, 3115.

Oliveira, R., Papa, J., S. Pereira, A. ve Tavares, J., 2016, Computational Methods for Pigmented Skin Lesion Classification in Images: Review and Future Trends, p.

Ramachandran, P., Zoph, B. ve Le, Q. V. J. a. p. a., 2017, Searching for activation functions.

Rietveld, C. A., Medland, S. E., Derringer, J., Yang, J., Esko, T., Martin, N. W., Westra, H.-J., Shakhbazov, K., Abdellaoui, A., Agrawal, A., Albrecht, E., Alizadeh, B. Z., Amin, N., Barnard, J., Baumeister, S. E., Benke, K. S., Bielak, L. F., Boatman, J. A., Boyle, P. A., Davies, G., de Leeuw, C., Eklund, N., Evans, D. S., Ferhmann, R., Fischer, K., Gieger, C., Gjessing, H. K., Hägg, S., Harris, J. R., Hayward, C., Holzapfel, C., Ibrahim-Verbaas, C. A., Ingelsson, E., Savalle, P.-A., Tsogkas, S., Papandreou, G. ve Kokkinos, I., 2014, Scherer, D., Müller, A. ve Behnke, S., 2010, Evaluation of pooling operations in convolutional architectures for object recognition, International conference on artificial neural networks, 92-101.

Sun, M., Song, Z., Jiang, X., Pan, J. ve Pang, Y., 2017, Learning pooling for convolutional neural network, Neurocomputing, 224, 96-104.

Taylor, L. ve Nitschke, G., 2017, Improving deep learning using generic data augmentation, arXiv preprint arXiv:1708.06020.

Ye, H., Wu, Z., Zhao, R.-W., Wang, X., Jiang, Y.-G. ve Xue, X., 2015, Evaluating two-stream CNN for video classification, Proceedings of the 5th ACM on International Conference on Multimedia Retrieval, 435-442.

Yuan, Y., Chao, M. ve Lo, Y., 2017, Automatic Skin Lesion Segmentation Using Deep Fully Convolutional Networks With Jaccard Distance, IEEE Transactions on Medical Imaging, 36 (9), 1876-1886.

Zeiler, M. D. ve Fergus, R., 2013, Stochastic pooling for regularization of deep convolutional neural networks, arXiv preprint arXiv:1301.3557.

Zeiler, M. D. ve Fergus, R., 2014, Visualizing and understanding convolutional networks, European conference on computer vision, 818-833.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : SARMAD MOHSEN ALI HURMUZI
Uyruğu : IRAK
Doğum Yeri ve Tarihi : KERKÜK, 1987
Telefon : 0530 200 9226
Faks :
e-mail : srmd.1987@yahoo.com

EĞİTİM

Derece
Lise : **Al-Jihad lisesi – Kerkük – 2006.**
Üniversite : **Kerkük Üniversitesi – Kerkük - 2010**
Yüksek Lisans : **Selçuk Üniversitesi – Selçuklu – Konya – 2019**
Doktora :

İŞ DENEYİMLERİ

Yıl	**Kurum**	**Görevi**
2010 - 2013	Zain Telecom	Muhasebe ve Arşif Bölümünde
2013 - 2014	Shania Com for Mix Concret	Muhasebe Sorumlusu
2014 - 2016	Kerkük Üniversitesi	İdari Görevli
2017 - Hala devam ediyorum	Özenir Değirme MAK.NAK.TİC.LTD.STİ	Diş ticaret sorumlsu

UZMANLIK ALANI: BİLGİSAYAR MÜHENDİSLİĞİ

YABANCI DİLLER: TÜRKMENCE, TÜRKÇE, ARAPÇA, İNGİLİZCE.

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR:

Sarmad.M .A. Hurmuzi ve Harun UĞUZ, 2019**,** Skin Cancer Risk Assessment Using Convolutional Neural Network, *III. International Congress on Science and Education, P*: 1468-1474.