



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**TERMAL GÖRÜNTÜ İŞLEME İLE DİZ**  
**OSTEOARTRİTİNİN TESPİT EDİLMESİ**

**Afrah Abdulsattar Jasim QALI**

**YÜKSEK LİSANS TEZİ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Temmuz-2021**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Afrah Abdulsattar Jasim QALI tarafından hazırlanan “ Termal Görüntü İşleme İle Diz Osteoartritinin Tespit Edilmesi ” adlı tez çalışması 14/07/2021 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. Cemil SUNGUR

.....

#### Danışman

Doç.Dr. Murat SELEK

.....

#### Üye

Dr. Öğr. Üyesi Hakan TERZİOĞLU

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN  
Enstitü Müdürü

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Afrak Abdulsattar Jasim QALI

Tarih: 29 / 07 / 2021

## ÖZET

### YÜKSEK LİSANS TEZİ

## TERMAL GÖRÜNTÜ İŞLEME İLE DİZ OSTEOARTRİTİNİN TESPİT EDİLMESİ

**Afrah Abdulsattar Jasim QALI**

**Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Elektrik- Elektronik Mühendisliği Anabilim Dalı**

**Danışman: Doç. Dr. Murat SELEK**

**2021, 45 Sayfa**

**Jüri**

**Doç. Dr. Murat SELEK  
Prof. Dr. Cemil SUNGUR  
Dr. Öğr. Üyesi Hakan TERZİOĞLU**

Osteoartrit (OA) hastalığı olan kişilerde Osteoartritin bulunduğu diz bölgesindeki sıcaklık normal kişilere göre daha yüksektir. Çalışmamızda, yüksek sıcaklıktan faydalanarak OA hastalığını termografi ile elde edilen görüntülemeyle faydalanılarak erken teşhisi üzerine inceleme gerçekleştirilecektir. Bu çalışmada yöntem olarak CNN, Destek Vektör Makineleri ve VGG-16 mimarisi kullanılacaktır. Çalışmamız, esnek sistem ve etkili araçlar sağladığı için teşhis sürecinde doktora yardımcı olabilecek termal görüntüleme kullanılarak bir hastalık teşhis sistemi tasarlamayı amaçlamaktadır. Önerilen sistemin tasarımında ve programlanmasında programlama dili olarak "Phyton" kullanılacaktır. Termografi ile elde edilen görüntüleri söz konusu yöntemleri kullanarak en yüksek doğruluk oranını ortaya koyan yöntemi bulmaktır. Söz konusu çalışmada FLIR E45 termal kamera tipi kullanılarak farklı kişilerden toplam 998 görüntü elde edilmiştir. Bu termal görüntülerin 284'ü hasta, 714'ü ise sağlıklı görüntülerdir. Yapılan çalışmada derin öğrenme, makine öğrenme algoritmaları kütüphanelerinden faydalanılmıştır. Termografi ile alınan görüntülerdeki renk farklılığı, Osteoartrit hastalığının olup olmadığını tek başına ortaya koyamazken yukarıda zikredilen yöntemler yardımıyla bu hastalığı tespit etme imkânı sağlanmaktadır. Derin öğrenme metotlarının eğitilebilmesi için binlerce görüntü gerekmektedir. Fakat medikal ortamda böyle bir veri kümesi oluşturmak çok uzun zaman alacağından görüntü artırma metotları kullanılmıştır. Uygulanan yöntemler arasında en iyi sınıflandırma sonucu evrişimsel sinir ağları ve görüntü artırımı kullanılarak %90 doğruluk oranı ile ulaşılmıştır. Elde edilen sonuçlar derin öğrenme metotlarını termografik görüntülerin sınıflandırılmasında çok başarılı olduğunu ortaya koymaktadır.

**Anahtar Kelimeler:** Destek Vektör Makineleri, Evrişimsel Sinir Ağları, Osteoartrit, Termal kamera, Termografi, VGG-16

## **ABSTRACT**

### **MS THESIS**

## **DETECTION OF KNEE OSTEOARTHRITIS WITH THERMAL IMAGE PROCESSING**

**Afrah Abdulsattar Jasim QALI**

**Konya Technical University  
Graduate Education Institute  
Department of Electrical and Electronics Engineering**

**Advisor: Assoc. Prof. Dr. Murat SELEK**

**2021, 45 Pages**

**Jury**

**Assoc. Prof. Dr. Murat SELEK**

**Prof. Dr. Cemil SUNGUR**

**Asst. Prof. Dr. Hakan TERZİOĞLU**

In people with osteoarthritis (OA) disease, the temperature in the knee area where osteoarthritis is present is higher than in normal people. In our study, an examination will be carried out on the early diagnosis of OA by using the imaging obtained by thermography by making use of high temperature. In this study, CNN, Support Vector Machines, and VGG-16 architecture will be used as a method. Our study aims to design a disease diagnostic system using thermal imaging that can assist the doctor in the diagnostic process as it provides a flexible system and effective tools. "Python" will be used as the programming language in the design and programming of the proposed system. The aim is to find the method that reveals the highest accuracy rate by using the images obtained by thermography. In this study, a total of 998 images were obtained from different people using the FLIR E45 thermal camera type. Of these thermal images, 284 are patient images and 714 are healthy images. In the study, deep learning and machine learning algorithms libraries were used. While the color difference in the images taken with thermography cannot reveal whether there is Osteoarthritis disease on its own, it is possible to detect this disease with the help of the methods mentioned above. Thousands of images are required to train deep learning methods. However, since it would take a long time to create such a dataset in the medical environment, image enhancement methods were used. Among the applied methods, the best classification result was achieved by using convolutional neural networks and image augmentation with 90% accuracy. The obtained results reveal that deep learning methods are very successful in classifying thermographic images.

**Keywords:** Convolutional Neural Networks, Osteoarthritis, Support-Vector Machines, Thermal Camera, Thermography, VGG-16

## ÖNSÖZ

Yüksek lisans eğitime başladığım ilk yıldan tez aşamasına kadar desteğini esirgemeyen, çalışmalarımın gerek araştırma, gerekse yazım aşamasında, bilgi ve desteği ile bu çalışmayı yönlendiren çok değerli danışmanım Sayın Doç. Dr. Murat SELEK'e teşekkür etmeyi borç bilirim. Ayrıca, tez çalışmama ilk başladığım anda bana yol gösteren Sarmad HURMUZI'ye teşekkür ederim. Bu çalışmada bilgi ve tecrübeleriyle bana destek olan, Sameer Saeed Abbas ve Mutlu ODUŞLU'ya; hep yanımda olan, beni maddi manevi hep destekleyen aileme sonsuz şükranlarımı sunarım.

Bu tez çalışmamı bir buçuk yıl önce kaybettiğim bu hayattaki en değerli varlığım olan rahmetli anneme ithaf ediyorum.

Afrah Abdulsattar Jasim QALI  
KONYA-2021

# İÇİNDEKİLER

<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>v</b>
<b>ÖNSÖZ</b> .....	<b>vi</b>
<b>İÇİNDEKİLER</b> .....	<b>vii</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>iii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>3</b>
<b>3. MATERYAL VE YÖNTEM</b> .....	<b>6</b>
3.1. Kızılötesi Termografi.....	6
3.2. Termal Kamera Yapıları .....	7
3.2.1. Optik mekanik birimler.....	8
3.2.2. Algılayıcı, soğutma birimi .....	9
3.2.3. Elektronik sinyal işleme birimi.....	10
3.3. Deneyde Kullanılan Flir E45 Termal Kamera.....	11
3.4. Termal Görüntüleme Algılama Merkezleri .....	13
3.5. Osteoartrit .....	14
3.6. Evrimsel Sinir Ağları ( ESA ) .....	14
3.6.1. Katman türleri .....	15
3.6.1.1. Evrişim katmanı (Convolution layer) .....	15
3.6.1.2. Havuzlama katmanı (Pooling layer) .....	16
3.6.1.3. Tamamen bağlı katman (Fully connected layer) .....	17
3.7. Eğitim Stratejisi .....	17
3.8. Destek Vektör Makineleri (SVM) .....	20
3.8.1. SVM'nin çalışması .....	21
3.8.2. SVM çekirdekleri.....	22
3.8.3. SVM sınıflandırıcılarının artıları .....	24
3.8.4. SVM sınıflandırıcılarının eksileri .....	24
3.9. VGG-16 Modeli .....	24
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA</b> .....	<b>26</b>
4.1. Veri Kümesi .....	26
4.2. Veri Kümesinin Hazırlanması .....	26
4.3. İstatistiksel Analiz.....	28
4.4. Python Programlama Arayüzü .....	29
4.4.1. Ana sayfa (Osteoartrit Teşhis Arayüzü) .....	30
4.4.2. Sistem uygulamasının anlatımı .....	31
<b>5. SONUÇLAR VE ÖNERİLER</b> .....	<b>34</b>

5.1. Sonular.....	34
5.2. neriler .....	34
<b>KAYNAKLAR .....</b>	<b>35</b>
<b>EKLER .....</b>	<b>38</b>





## SİMGELER VE KISALTMALAR

### Kısaltmalar

<b>CNN</b>	: Evrişimsel Sinir Ağları (Convolutional Neural Networks)
<b>IR</b>	: İnfrared (Kızılötesi)
<b>IRT</b>	: İnfrared Termografi
<b>IRFPA</b>	: İnfrared Odak Düzlemi Dizisi (focal plane array)
<b>OA</b>	: Osteoartrit
<b>LCD</b>	: Sıvı Kristal Görüntü (Liquid Crystal Display)
<b>SVM</b>	: Destek Vektör Makineleri



## 1. GİRİŞ

Termal görüntüleme bir termal kamera sistemi, üzerine düşen kızılötesi (Infrared – IR) radyasyonu meydana gelen termal değişimin iki boyutlu görsel görüntüsüne dönüştürür. Mutlak sıfırın üzerindeki sıcaklıktaki tüm nesnelere IR ışınım yayar ve yayılan radyasyonun miktarı sıcaklıkla birlikte artar (Turan, 2019).

William Herschel, ışıkların ısı içeriğini ölçmek için 1800'lerde cam prizma ile yaptığı deneylerle IR radyasyonu (ışınım) ilk keşfeden bilim insanı olmuştur. Güneş ışığını spektral bileşenlerine ayırmak için bir prizma kullanmış, daha sonra, güneş ışığının spektrumunun enerji dağılımını gözlemlemek amacıyla farklı renkli ışınların her biri için ayrı bir termometre kullanmıştır. Sıcaklığın görünür spektrumun kırmızı ucunun ötesinde yükseldiğini ve sonuçta ışık spektrumunun aynı zamanda bir tür görünmez ışın içerdiğini tespit etmiştir (Ring E. , 2000).

John Herschel'de babasının ölümünden sonra bazı deneyler yapmış ve güneş ışınımını kullanarak başarılı bir görüntü elde etmiştir. Alkoldeki karbon süspansiyonu kullanarak bir görüntü oluşturmayı başarmış olup bu görüntüye termogram adını vermiştir. Herschel'in üzerinde çalıştığı görünür ışık, tüm spektrumu görünür hale getirmiştir. Ayrıca görünür ışıktan daha uzun bir dalga boyuna sahip radyasyon bölgesi olan IR bölgesini keşfetmeyi başarmıştır (Ring E. , 2006).

Termografi ilk olarak 1950'li yıllarda, özellikle gece görüşü için askeri amaçla tasarlanmıştır (Flir, 2010). Daha sonra askeri araç sürücülerinin duman, toz, hafif sis ve yağmur altındaki çevre görüşlerini artırmak, gözetleme, hedef arama ve izleme faaliyetlerini geliştirmek amacıyla kullanılmıştır (Vollmer ve Möllmann, 2007)

Modern termal görüntüleme günümüzde, dijital görüntüleri saklayabilen, taşınabilir veya masaüstü bir bilgisayarla çevrimiçi olarak kullanılabilen küçük güvenilir kamera sistemleri haline gelmiştir. Son yıllardaki yenilikler maliyetleri düşürmüş, güvenilirliği artırmış ve ölçüm için mobil ve daha küçük birimler sunan temassız IR sensörlerle sonuçlanmıştır.

Osteoartrit (OA) milyonlarca insanı etkileyen en yaygın artrit şeklidir. Dünya çapında hastalık ağrı, sertlik ve işlev kaybı ile ilişkilidir. 2030 yılına kadar Amerikan nüfusunun 65 yaş üzerinde olan yaklaşık % 20'sinin (35 milyon hasta) bu anlamda yüksek risk altında olacağı öngörülmektedir. OA'nın çoğalmasıyla birlikte tedaviler için büyük miktarda sağlık harcamasına ve cerrahi işlemlere ihtiyaç duyulacaktır (Tan ve ark., 2007). Başlangıçta, tüm eklem dokularını etkileyen ve eklem hem

dejenerasyonuna hem de kusurlu restorasyonuna neden olan bir hastalık olduđu bilinmesine rađmen, kıkırdaktaki bir bozulmaya atfedilmiřtir. Yařlanmaya bađlı vücuttaki yapısal deđiřikliklerin bir sonucu olarak ortaya çıkan OA'yı, patolojik deđiřikliklerden ayırmak zor olabilir (Koay ve ark., 2004). Birkaç on yıl öncesine kadar, OA yalnızca yařlanmayla ilgili bir hastalık olarak görölüyordu, ancak řimdi hastalıđın her yařta görülebileceđi tespit edilmiřtir.

Evriřimli Sinir Ađları (Convolutional Neural Networks - CNN), görüntüleri sınıflandırmak için kullanılan en geliřtirilmiř derin öğrenme modellerinden biridir (Krizhevsky ve ark., 2012). Nesne saptaması, kenar bulma, izlenim türevleri elde etme üzerindeki üstün başarısı, tıbbi görüntüler üzerindeki çözümleme işlemlerini kolaylařtırmaktadır (Erdem ve Aydın, 2021).

Destek Vektör Makineleri (Support Vector Machines - SVM), son yıllarda sınıflandırma sorunlarının çözümü için en başarılı makine öğrenimi tekniklerinden biridir. Ayrıca SVM birçok sınıflandırma sorunlarının çözümünde başarı ile uygulanmış olup genelleme performansı yüksek ve aktif makine öğrenimi algoritmalarından biri olarak arařtırmalardaki yerini almıřtır (Ayhan ve Erdođmuş, 2014).

Eđitilmiř ađ olan VGG-16 sınıflandırma üzerindeki başarılı performansı ve asgari hata vermesinden dolayı bu projede kullanılmıřtır (Erdem ve Aydın, 2021).

Destek Vektör Makinesi (SVM), Evriřimli Sinir Ađı, VGG-16 metotları dikkate alınarak, üç ayrı uygulama oluřturulmuřtur. Bu çalışmada, IR termal kamera görüntüleri, yaralanmış kiřilerin dizinin birinden ya da her ikisinden alınmıřtır. Bu kiřilerden alınan görüntüler, CNN, SVM, VGG-16 metotları kullanılarak işlenecektir. Termal kamera ile problemlili bölgeden ekstremite görüntü alınarak osteoartrit olduđu ortaya çıkarılacaktır. Klinik ve radyolojik tetkikler sonrası teřhisi konulan hastaların, OA gibi hastalıklar sonucunda oluřan ateř yükselmesi termografi ile görüntülenecektir.

Bu projenin amacı, termal görüntüler üzerinden derin öğrenme ve makine öğrenme yöntemlerini kullanarak Osteoartrit rahatsızlıklarını erken teřhis edebilmektir. Gerçekleřtirilen uygulama, ortopedi inceleme mekanizmasında OA'nın ön tanısında kullanılarak hastaların gereksiz radyasyona maruz kalmalarını önlemek, daha sonraki ařamalarda oluřabilecek maddi giderleri azaltmak ve zamandan tasarruf yapmayı amaçlamaktadır.

## 2. KAYNAK ARAŞTIRMASI

Bu bölümde Osteoartritin erken teşhisinde incelenen literatürdeki bazı çalışmalara yer verilmiştir.

Arif ve Wang. 2019'daki derlemelerinde curvelet dönüşümüne ve genetik algoritmaya (GA) dayanan multimodal medikal görüntüler için yeni bir füzyon yöntemi önermiştir. GA'nın çalışmada kullanılmasının giriş görüntüsünde var olan şüpheleri çözebileceği ve görüntü kaynaşmasının özelliklerini daha da iyi optimize edebileceği vurgulanmaktadır. Önerilen yöntemin birçok tıbbi görüntü grubunda test edildiği ve aynı zamanda son tıbbi görüntü füzyon teknikleri ile karşılaştırıldığı belirtilmektedir. Nicel değerlendirme ve görsel analiz sonuçlarının, önerilen yöntemin temel görüntüde mükemmel veri bilgileri ve renk uyumu sağlayarak diğer yöntemlere göre tıbbi füzyon görüntülerinde en iyi avantajı sağladığı vurgulanmaktadır.

Calin ve ark.2015 çalışmalarında, termal kızılötesi görüntülemenin bazı diz patolojilerinin tanı, değerlendirme ve izlenmesinde etkili olduğunu kanıtlamaktadır. Dejeneratif ve inflamatuvar diz patolojisinin tanı, değerlendirme ve izlenmesi için klasik tıbbi görüntüleme ile ilişkili olarak tamamlayıcı bir yöntem olabileceği kanıtlanmıştır.

Glehr ve ark. 2011 çalışmalarında, ilk kez termografi ile ölçülen yapay diz eklemlerinin implantasyonundan sonra cilt sıcaklığındaki artış ile mevcut frontal (ön) diz ağrısı arasında doğrudan bir korelasyon olduğunu tespit etmektedirler. ROC (Receiver Operating Characteristic) analizine tabi tutulan termografi görüntülerinin, eklem protezi olan hastalarda ağrıyı daha kesin olarak lokalize etme ve değerlendirme olasılığını artırdığını ifade etmektedirler.

Hwang ve ark. 2020'deki çalışmalarında, geliştirilen termal dağılım algoritması ile hastanın hipertermi öncesi iç sıcaklığının tahmin edilebileceğini ve normal organlarda nekroz oluşmasını önleyerek tedavi doğruluğunu artırabileceğini belirtmektedir. Ek olarak, lezyonların teşhisi için çekilen Bilgisayarlı Tomografi (BT) görüntülerini modellemeden hipertermi sıcaklığını kolayca tahmin edilebilmektedir.

Fokam ve Lehmann (2018) bu çalışmada, artrit gibi enflamatuvar durumlarda, periartiküler cilt yüzeyinde Kızılötesi Termografi (Infrared Thermography - IRT) ile ölçülebilen doku sıcaklığının yüksekliğini ortaya koymuştur. Bu derlemede, cilt sıcaklığı (IRT ile ölçülen) ve artritik diz ağrısı arasındaki ilişkiye dair kanıtlar değerlendirilerek, artrit klinik ortamlarında IRT'nin sınırları tartışılmıştır.

Vardasca ve ark. (2019) için IR termal görüntüleme sisteminin cilt sıcaklığı ölçümü yoluyla sağladığı fizyolojik verilerin, patolojik durumlarla olası ilişkisi nedeniyle biyomedikal kas-iskelet uygulamaları için bir araştırma konusu olmuştur.

Lasanen ve ark. (2015) ayak bileği eklemleri ile orta ve yan kısımlarındaki deri yüzeyleri arasında önemli ısı farklılıkları tespit etmiştir. Bunun yanında, diz eklemlerinde ortalama sıcaklığın, orta ve yan kısımlara göre önemli ölçüde fark ettiğini tespit etmişlerdir ( $P = 0.004$ ).

Varju ve ark. (2004) dijital osteoartritin anatomik evrelerini, radyografik olarak ilerledikçe karakterize etmiştir. Normal durumdan OA'nın oluşumuna kadar sıralı aşamalar; artan eklem boşluğu kaybı, eklem erozyonu ve eklem yeniden şekillenmesidir. Söz konusu çalışma, Bilgisayarlı Dijital IR Termal Görüntüleme ile ölçülen bir fizyolojik parametreyi, eklem yüzey sıcaklığı ve radyografik OA'nın (ROA) sıralı aşamaları ile ilişkisini değerlendirmek için tasarlanmıştır.

Warashina ve ark. 2002'deki termografinin, romatizmal sinovit tedavisi için nonsteroid antiinflamatuvar ilaçların değerlendirilmesini sağladığı bildirilmiştir. Bununla birlikte, az sayıda rapor hastalarda cilt sıcaklığı ile semptomlar, fiziksel belirtiler ve radyografik özellikler arasındaki ilişkiden bahsetmektedir. Bu çalışmada, radyografik ve klinik bulgular ile deri arasındaki ilişki değerlendirilmiştir.

Salisbury ve ark. 1983 yılında, ayak bileği ve dirsek eklemleri üzerinde düzenli termal desenler belirlenmiş olup, sinovitin nasıl olduğunu göstermiştir. Klinik sinovit kanıtı olan hiçbir eklemden normal bir termal model bulunmamıştır. Sıcaklığa dayalı parametrelerin belirgin olarak günlük değişim gösterdiği ve nispi frekans dağılımlarının dezavantajının bulunmadığı vurgulanmaktadır. Bunlara bağlı olarak, sinovitin termografi ile ölçülmesinin gelecekte mutlak cilt sıcaklığı değerlerinden ziyade termal model anormalliklerine dayandırılması gerektiği önerilmektedir.

Monique Frize ve ark. (2011) romatoid artrit (RA), ağrı, şişlik, sertlik ve eklemlerde fonksiyon kaybına neden olan enflamatuvar bir hastalık olduğunu ifade etmektedir. Söz konusu hastalığı erken aşamalarda teşhis etmek zordur. Erken bir tanı ve tedavi, ciddi sakatlığın başlangıcını geciktirebilmektedir. Kızılötesi (IR) Görüntüleme, inflamasyon derecesindeki değişiklikleri tespit etmek için potansiyel bir yaklaşım sunar. Sonuç olarak romatoid artrit hastalığı olan bireylerde termal görüntüler ile hastalık tespit edilebilir.

Rajakpase ve ark. (1981) periferik eklem iltihabının bir ölçüsü olarak kantitatif kızılötesi termografinin tekrarlanabilirliğini ve duyarlılığını yeniden değerlendirmiştir.

Sonuçlar, incelenen termografik tekniğin diz, ayak bilekleri ve dirseklerdeki enflamatuvar değişiklikleri saptamak için yeterli olduğunu, ancak ellerin küçük eklemlerindeki enflamasyonun ölçülmesi için yetersiz olduğunu göstermiştir.

Monique Frize ve ark.'nın (2009) bu çalışmada, erken sinovit tanısı için düşük maliyetli bir yöntem önermektedir. Sonuç olarak istatistiksel analize göre kontrol denekleri ve hastalar arasında ölçülen her eklem ve el bölgesi arasında önemli sıcaklık farkları ortaya konulmuştur.

Devereaux ve ark.'na (2015) göre romatoid artrit hastalık aktivitesinin değerlendirilmesiyle ilgili birçok zorluk vardır. Bu çalışmada IRT, ortak inflamasyonu ölçmek için kullanılmıştır. Isı dağılım endeksi (Heat Dissipation Index - HDI) tekrarlanabilir, duyarlı, ölçülebilir ve sirkadiyen varyasyona veya ara sıra hataya tabi değildir. Ritchie artiküler endeksi, Malya skoru, kavrama gücü, eritrosit sedimentasyon hızı ve ağrı skoru ile termografi arasında önemli bir korelasyon ( $P < 0,001$ ) vardır. Bireysel hastalarda bu parametrelerle termografi için önemli korelasyonlar ( $p < 0,05$ ) bulunmuştur. Toplanan HDI, romatoid artritli hastalarda tedaviye yanıtın değerlendirilmesi için uygun objektif bir yöntemdir.

Denoble ve ark.'nın (2010) çalışmasının amacı, dizin seri kızılötesi ölçümlerinin yeniden üretilebilirliğini geliştirmek ve diz sıcaklığının bölgeye göre ilişkisini değerlendirmektir. Sonuç olarak, kızılötesi diz görüntüleme yönteminin güvenilir olduğu belirtilmektedir.

Spalding ve ark. (2008) göre aktif artrit sahip eklemlerin değerlendirilmesi, yaygın olarak kullanılan sonuç ölçümlerinin temel bir bileşenidir. Bununla birlikte, bu aktif ortak sayımların değerlendirilmesinde incelemeler sırasında önemli değişiklikler vardır. Aktif eklem sayımları sırasında tahmin edilen iki özellik olan şişme ve sıcaklık değişimleri, temassız dijital görüntüleme teknolojileri kullanılarak nicelleştirilebilmektedir. Bu çalışmanın sonucunda, eklem şeklini ve sıcaklığını güvenilir bir şekilde ölçmek için üç boyutlu (3D) termal görüntülemenin yeteneği keşfedilmeye çalışılmıştır.

### 3. MATERYAL VE YÖNTEM


#### 3.1. Kızılötesi Termografi

Kızılötesi radyasyon, elektromanyetik spektrumun görünür ve mikrodalga kısımları arasında bulunur. Kızılötesi radyasyonun birincil kaynağı ısı veya termal radyasyondur. Mutlak sıfırın (-273,15 santigrat derece veya 0 Kelvin) üzerinde bir sıcaklığa sahip herhangi bir nesne, kızılötesi bölgede radyasyon yayar. Buz küpleri gibi çok soğuk olduğunu düşündüğümüz nesnelere bile kızılötesi radyasyon yayar. Her gün kızılötesi radyasyona maruz kalmaktayız. Güneş ışığından, ateşten veya radyatörden hissettiğimiz ısı tamamen kızılötesidir. Gözlerimiz göremese de cildimizdeki sinirler onu ısı olarak hissedebilir. Nesne ne kadar sıcaksa, o kadar çok kızılötesi radyasyon yayar (Anonymous, 2021).

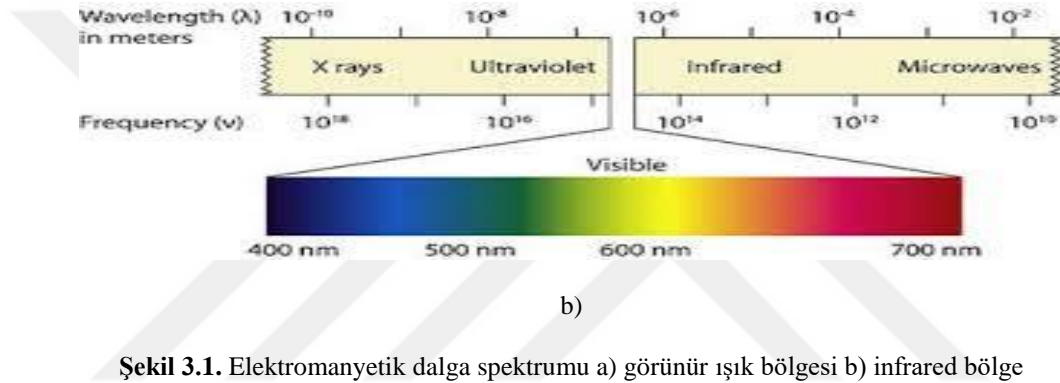
1800'lerde Alman gökbilimci William Herschel kızılötesi radyasyonu keşfetmiştir. Her nesnenin molekülleri, dönme-titreşim hareketlerinin bir sonucu olarak kızılötesi radyasyon (elektromanyetik dalgalar) yayarlar (Kastberger ve Stachl, 2003). Bu radyasyon ışık gibi yansıtılır, kırılır ve tespit edilebilir. IRT, bu radyasyonu yakalamak ve sinyali ölçmek için kullanılan bir yöntemdir (Meola ve Carlomagno, 2004). Böylece kızılötesi radyasyonun tespiti için ilk elektronik sensörler ordu tarafından tasarlanmış ve gece görüş sistemi olarak kullanılmıştır. O zamanlar IRT teknolojisi büyük ve pahalıydı, ayrıca görüntülerin kalitesi düşüktü (Swiderski ve Vavilov, 2015). Geçtiğimiz birkaç yıl, tıp da dâhil olmak üzere birçok bilimsel ve ticari alana yayılan IRT'nin evrimine tanık olmuştur.

Tıbbi kullanım için ilk IRT cihazı, temas termografisine dayanmaktaydı. Cihaz, yalnızca sıvı kristal siyah kolesterol içeren bir tabaka ile ayrılmış, deri ile temas halinde tutulmuştur. Temas ettiği cildin sıcaklığına bağlı olarak rengini değiştirmiştir. Ardından, kızılötesi emisyonu belirli bir mesafeden yakalayan ve gerçek zamanlı olarak sıcaklık dağılımının bir görüntüsünü oluşturan uzaktan algılama termografisine ulaşmıştır (Fokam ve Lehmann, 2018).

Günümüzde IRT resimleri hızlı bir şekilde işleyen, yüksek çözünürlüklü termal görüntüler sağlayan bilgisayarlar ve kameralar kullanılmaktadır. Dahası, bu cihazlar, diğer teknikleri (örneğin radyografi) kullananlara kıyasla küçük, ucuz ve yüksek çözünürlüklü görüntüler sağlamaktadır (Fokam ve Lehmann, 2018).



a)



b)

Şekil 3.1. Elektromanyetik dalgaların yelpazesini gösteren grafik a) görünür ışık bölgesi b) infrared bölge


### 3.2. Termal Kamera Yapıları

Kızılötesi kamera zamanla üç nesil ilerleme geçirmiştir. İlk tek detektör ve iki tarama kamerasından oluşmaktaydı. İkinci nesil, iki tarama aynasından oluşuyordu ve detektör olarak 2 boyutlu küçük bir dizi oluşturuldu ve ikinci nesil kameralarda görüntü geliştirme için zaman gecikme entegrasyon algoritması kullanılmıştır. Üçüncü nesil kameralar, infrared odak düzlemlili dizi (IRFPA) algılayıcıları ve çip üstü görüntü işleme özellikli aynalar olmadan sistemin güvenilirliğini ve hassasiyetini artırmaktadır. İnfrared odak düzlemlili dizi (IRFPA) en yaygın olanıdır. Hiç bir hareketli parçası yoktur, daha hızlıdır ve tarama cihazlarından daha iyi uzaysal çözünürlüğe sahiptir (Kaplan, 2007).



### 3.2.1. Optik mekanik birimler

IR görüntülemenin kalitesi çevre şartlarına, hedefin türüne ve görüntülemeyi oluşturan bölümlere bağlıdır. Hedefin görüntüsünü elde edebilmek için detektörde geçirgen aynalar veya lensler kullanılabilir. Merceklerin geçirgenlik kabiliyeti olabildiğince maksimum olmalı ayrıca kırılma dizininin dalga boyuna ve sıcaklığa olan tabiiliği düşük olmalıdır. Anti-yansıma kaplamasının spektrumu ve mercek malzemesi, lensin geçirgen olduğu dalga boyunu belirlemektedir (Çalışan ve Türkoğlu, 2011). Ayna kullanmak optik sistemin merkez düzlemi üzerinde görüntü oluşturmanın başka bir yoludur. Aynalar akromatiktir (ak ışığı ayrıştırmadan geçiren) özelliği ile merceklerden farklı olarak tüm kızılötesi dalga boylarında çalışmasını sağlamaktadır. Yansımayı artırabilmek için aynalara kaplama yapılabilir. Şekil 3. 2'de, termal kameranın optik birimleri gösterilmektedir (Kılınç, 2017).



Şekil 3.2. Bir termal kameranın optik birimi


Tipik termal kameralar; mercek, mercek koruması, ekran, detektör ve sinyal işleme birimi, veri işleme, veri depolama birimi, rapor oluşturma yazılımı ve kumanda araçları gibi birçok ortak faktörden oluşmaktadır. Bu faktörler IR görüntüleme sisteminin modeline ve tipine bağlı olarak farklılık gösterebilir. Termografinin en az bir lensi bulunmaktadır (Çalışan ve Türkoğlu, 2011). Bir obje üzerinden gelen kızılötesi enerji, lens vasıtasıyla kamera içindeki kızılötesi üzerine düşürülür. Bu algılayıcı görselin oluşması için gerekli elektriksel çıkışı üretir. Bu elektriksel çıkışların işlenmesi sonucunda bizim görebileceğimiz bir resim kamera ekranında oluşması sağlanır (Kosikowski ve ark., 2011). Termal kameraların en az bir merceği bulunur ve bu mercek önce kızılötesi ışınımı alır ve detektöre odaklar ve detektör de bir çıkış oluşunca

görüntü elde edilir. Aslında mercek ışınlarını algılayıcıda toplamak ve odaklamak amacıyla kullanılır. Bu mercekler germanyumdan yapılmıştır (Physiotherm, 2021).

Çeşitli alan ölçümlerinde karşı kaşıya kalınan farklı aydınlatma koşulları altında, termal bir kameranın üzerine konumlandırılmış sıvı kristal görüntüleyici (LCD) ekranındaki görüntünün kolayca incelemesi için yeterince geniş ve parlak olması gerekir. Bu termal görüntünün içeriği iki boyutlu sıcaklık görüntüsünü, yayıncılık, batarya şarj, tarih, saat, hedef sıcaklığı, sıcaklık değişimini ifade eden renk çubuğu gibi bilgileri sağlamalıdır (Çalışan ve Türkoğlu, 2011).

### 3.2.2. Algılayıcı, soğutma birimi

Sıradan kameralar görüntüyü görünen ışık vasıtasıyla meydana getirirken, termografi ise görüntüyü ısı vasıtasıyla meydana getirir. İnsan gözü ve beyni görüntüyü oluşturmak için renkleri ve ışıkları kullanırken renk değişiklikleri önemlidir. Örneğin, beyaz bir duvar önünde bulunan beyaz bir nesnenin görülebilmesi oldukça zor olması gibi ortam sıcaklığına eşit bir sıcaklıktaki bir nesnenin termografiyle görüntülenebilmesi de oldukça güçtür (Çalışan ve Türkoğlu, 2011). Bunları ayırt edebilen kameralarda kullanılan algılayıcı çok küçük sıcaklık ayrımlarını yakalayabilmekte (0.01 °C gibi) ve bu farklılıklardan görüntü oluşturabilmekte olup belli bir sıcaklık aralığına sahiptirler (Ansiklopedi, 2021). Algılayıcılar belli sıcaklık aralıklarında görüntü verebilmektedirler çünkü her sıcaklık değerinde farklı IR yayımlar mevcuttur ve her IR yayılımı farklı dalga boyuna sahiptir. Şekil 3. 3'te, termal kamera algılayıcılarının yapısı verilmiştir. Algılayıcılarda optik-mekanik sistem ile alınan kızılötesi ışınlar sonucu termik değişimler oluşur. Kameradaki algılayıcıya düşen ışık, ışık ölçüsüne bağlı olan bu termik farklılıklara göre değerlendirilerek elektriksel sinyale çevrilir (Çalışan ve Türkoğlu, 2011).



Şekil 3.3. Termal kamera algılayıcısı

IR algılayıcılar içerdikleri teknolojilere ve kullandıkları malzemelere göre sınıflandırılırlar. Algılayıcı tipleri termal ve foton algılayıcılar olarak sınıflandırılır.

1. Termal algılayıcılar: Termal algılayıcılar de foton- fonon (ısı) (bir kristal örgüsünde bulunan atomların ortak titreşimlerinin nicesidir) dönüştürme işlemi yapılır, bu sırada direnç (bolometric) veya kutup (polarizasyon, pyroelectric) değiştirilir (Vollmer ve Möllmann, 2007).

Bu tür algılayıcılarda infrared ışının ölçülmesi zordur çünkü kaynak şiddetinin ve infrared fotonun enerjisi düşüktür. Bu özelliklerden dolayı bir infrared algılayıcıdan alınan sinyal küçük olmaktadır. Ayrıca ölçümün yapılabilmesi için büyük kuvvetlendirmeye ihtiyaç duyulur. Bir termografi cihazının doğruluğu ve duyarlılığı algılayıcı sistemine bağlıdır. Bu tür algılayıcılar oda sıcaklığına yakın sıcaklıklarda çalışır, fiyatları ucuzdur, hassaslığı ise düşüktür.

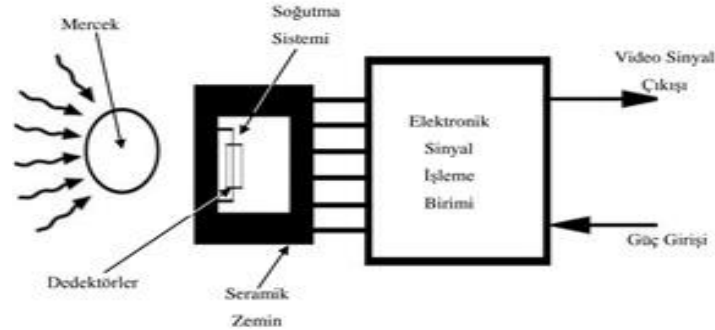
2. Foton algılayıcılar: foton algılayıcılarda foton-elektron dönüştürme işlemi yapılır, bu sırada elektron veya akımı (foto iletken veya foto voltaik yarıiletken) değiştirilir. Bu algılayıcılar  $-269^{\circ}\text{C}$  ile  $-73^{\circ}\text{C}$  sıcaklık aralığında çalışır, sıcaklığının düşük olmasından dolayı özel Soğutma sistemi gereklidir, fiyatı pahalı, hassaslığı ise yüksektir. Saf kristal detektör olarak tanımlananlar foto iletken veya foto voltaik iken, katkılı detektör olarak tanımlananlar foton yayıcı veya kuantum kuyulu algılayıcılardır (Vollmer ve Möllmann, 2007).

### 3.2.3. Elektronik sinyal işleme birimi

Termografiyi diğer kameralardan ayıran en önemli niteliklerinden birisi de analiz yazılımlarına sahip olmasıdır. Bilgisayarda çekimi yapılan nesnelere ait sorunlar, analiz yazılımı vasıtasıyla ortaya konulabilir. Ortama göre farklılıklar ya da eşdeğer noktaları birbirlerinden ayıran farklılıkların tespiti yapılabilir. Bu tespitler belli bir formatta raporlar haline getirilir ve bakım ekibi bu raporları anlaşılır hale çevirir (Çalışan ve Türkoğlu, 2011).

Analiz esnasında çekimi yapılan gereçlerin türünün ne olduğu doğru bir şekilde girilirse sonuçlar çok net bir şekilde alınabilir. Çekimi yapılan gereçlerin yayılım oranı doğru bir şekilde girilmelidir. Çünkü bacada kullanılan topraktan yapılmış olan bir tuğla ile paslı bir metal gövdenin ya da parlak bakır bir elektrik sisteminin aynı gerilim ve frekanstaki elektrik enerjisinin toplandığı ve dağıtıldığı ünitenin kızılötesi yayılımları

aynı değildir (Berkmen, 2001). Her gerecin kızılötesi yayılım oranını tespit etmek bazen mümkün olmayabilir. Bu durumda analiz yazılımı vasıtasıyla doğada bulunan neredeyse tüm gereç türlerinin kızılötesi yayılım oranı bulunabilir.



Şekil 3.4. Termal kameranın şematik görünümü

Çizelge 3.1. Bazı maddelerin yayma faktörleri

Materyal	Yayma Oranı
Su	0.98
Kâğıt Beton	0.54
Tuğla, basit	0.85
Alüminyum	0.02
Cam	0.92
Alüminyum, parlatılmış	0.05
Beyaz boya	0.93
Siyah boya	0.90
Parlatılmış gümüş	0.02
İnsan derisi	0.95
* Neredeyse bütün materyallere bağlı yayma oranı 0°C’de ölçülmektedir. Ancak oda sıcaklığında dikkate değer farklılık göstermemektedir.	

Nesnelerin kızılötesi spektrumda ışınım oranı yani ısı yayım katsayısına yayımcılık (emissivity) denir (Değirmenci, 2010). Her nesne farklı ısı yayım oranına sahiptir. Bu değer 0.0 ısı yayımı olmayan ve 1.0 ısı yayımı arasında değerlendirilmektedir. Siyah bir objenin yayımcılık değeri 1.0'dır. Diğer tüm objeler içinse yayımcılık değeri 1.0'ın altındadır (Anonim, 2021). Çizelge 3.1'de örnek maddelerin IR yayma faktörleri görülmektedir (Turan, 2019).

### 3.3. Deneyde Kullanılan Flir E45 Termal Kamera

Şekil 3.5'te gösterilen Flir E45 Termal Kamera bu tez çalışmasındaki deney görüntülerini elde etmek için kullanılmıştır. Çizelge 3. 2'de ise IR kameranın özellikleri verilmektedir.

45 derece geniş açılı lense sahip E45, denetçinin tahtadaki söz konusu küçük parçayı yakından görmesi gereken zamanlar için yakın plan lens olarak ikiye katlanır. Kamera taşınabilir, pille çalışır ve bir LCD ekrana sahiptir, böylece kullanıcı muayenesi için herhangi bir yere taşıyabilir. Aynı zamanda kamerayı uzun incelemeler için sabit bir yerde çalıştırabilen bir A/C güç kaynağına sahiptir ve pil aynı anda şarj edilebilir (Anonim, 2021).



a)



b)



c)

**Şekil 3.5.** Flir E45 Termal Kamera

**Çizelge 3.2.** IR kameranın özellikleri

Algılayıcı türü	Focal Plane Array (FPA), 160x120 piksel soğutmasız Mikrobolometre
Taif aralığı	7.5 – 13µm
Sıcaklık aralığı (°C)	-20°C - +250°C veya -4°F - +482°F
Termal duyarlılığı	0.1°C (30°C)
Video çıkışı	PAL, NTSC, Standart RCA karma video sinyali
Görüntü frekansı	50/60Hz
Görüş alanı/Min. Odak mes.	9.2mm lens ile tipik olarak 34°x25°/0.1m
Odaklama	Manuel
Ekran	2,5inch renkli LCD
Ölçme düzeltmeleri	Yayıcılık ayarlayabilme aralığı 0.1 - 1.0

### 3.4. Termal Görüntüleme Algılama Merkezleri

Dünyada birçok hastalığı tespit etmek için termal görüntüleme teknolojisini kullanan birçok Merkez var. Örneğin:


Merkez	Şehir
 <p>Thermography for Health New York          a Thermography Unlimited Certified Clinic</p> <ul style="list-style-type: none"> <li>No Radiation</li> <li>No Contact</li> <li>Painless</li> <li>Can Detect Tumors 8-10 Years Before a Mammogram</li> </ul>	<p>York (ABD)</p>
 <p>Thermography Medical Clinic          The Future of Preventative Healthcare...Today!</p>	<p>Londra( Birleşik Krallık)</p>
 <p>Home Thermography Examination Procedures The Company Clinic Locations Contact Us</p> <p>Articles Blog Studies Videos Book Appointment Search...</p> <p>THERMOGRAPHY CLINIC INC.</p>	<p>Toronto (Kanada)</p>
 <p>AMERICAN COLLEGE OF MEDICAL THERMOLOGY</p> <p>Email us: <a href="mailto:acct@thermologyonline.org">acct@thermologyonline.org</a>          ACCT BLOG - Click to visit</p> <p>Home Professionals Patients Breast Thermography Membership Clinics Research</p> <p>ACCT Approved Thermography Clinic</p>	<p>Washington (ABD)</p>

### 3.5 Osteoartrit

Osteoartrit yaşlanan nüfus üzerindeki etkisi giderek daha belirgin hale geldiğinden çok büyük bir klinik yük haline gelmiştir. Eklem fonksiyonunun yavaş ilerleyen kaybı olarak karakterize edilen OA, yalnızca Amerika Birleşik Devletleri'nde 27 milyondan fazla yetişkini etkilemektedir (Lawrence ve ark., 2008). Yaşlıların en yaygın kronik hastalığı haline gelmiştir (Felson ve ark., 1995). OA kalça, omurga ve el dahil olmak üzere vücuttaki çeşitli eklemleri etkilese de, klinik önemi nedeniyle OA araştırmalarının ve görüntülemelerinin büyük çoğunluğu diz eklemi üzerinde yapılmaktadır (Bijlsma ve ark., 2011). OA geleneksel olarak artiküler kıkırdak “aşınma ve yıpranma” tarafından yönlendirilen dejeneratif bir hastalık olarak kabul edilse de, son kanıtlar OA patofizyolojisinin birkaç doku tutulumu ile birlikte tüm eklem bağlamında algılanması gerektiğine dair yeni bir görüşe yol açmıştır (Roemer ve ark., 2011). OA'nın artık eklem dokusundaki katabolik ve anabolik aktiviteler arasındaki dengesizliğin sonucu olduğu ve sonunda kalıcı doku bozulmasına, ağrıya, fiziksel sakatlığa ve psikolojik sıkıntıya yol açtığı anlaşılmaktadır (Felson ve ark., 2007). Bu dokuların farklı özellikleri ve OA'ya verdikleri yanıtlar nedeniyle, OA'yı uygun şekilde değerlendirmek için çeşitli doku tiplerine duyarlı ileri görüntüleme yöntemlerine ihtiyaç vardır. OA prevalansının yüksek olmasına rağmen, ilerlemesini önleyecek, tedavi edecek veya durduracak herhangi bir tedavi mevcut değildir. Mevcut terapötik yaklaşımlar semptomatiktir. Ağrıyı hafifletmeye ve eklem fonksiyonunu sürdürmeye odaklanmaktadır (Zhang ve ark., 2008).

### 3.6. Evrişimsel Sinir Ağları ( ESA )

Convolution Neural Networks (CNN), birden fazla katmanın sağlam bir şekilde eğitildiği en önemli derin öğrenme yaklaşımlarından biridir ( Lecun ve ark., 1998). Bu yöntem oldukça etkili bulunmakta olup aynı zamanda çeşitli bilgisayar görme uygulamalarında en yaygın olarak kullanılmaktadır. Genellikle, bir CNN, evrişim katmanları, havuz katmanları ve tamamen bağlı katmanlar olan üç ana sinir katmanından oluşmakta olup her katman farklı roller oynamaktadır (Krizhevsky ve ark., 2012). Şekil 3. 6'da, görüntü sınıflandırması için genel ESA mimarisi gösterildiği gibi çoklu katmanlara sahiptir.



Şekil 3.6. Genel CNN mimarısı

Ağı eğitmek için ileri ve geri aşamaları olmak üzere iki aşama bulunmaktadır. İlk olarak, ileri aşamanın temel amacı, giriş görüntüsünü her katmandaki geçerli parametrelerle (ağırlıklar ve sapma) temsil etmektir. Daha sonra tahmini verimler, zarar maliyetini temel gerçek etiketleriyle hesaplamak için kullanılır. İkinci olarak, kayıp maliyetine göre, geri aşama her parametrenin eğimlerini zincir kurallarıyla hesaplar. Tüm parametreler eğimlere göre güncelleştirilir ve bir sonraki ileri hesaplama için hazırlanır. İleri ve geri aşamaların yeterli sayıda tekrarlandıktan sonra, ağın eğitilmesini durdurulabilmektedir (Guo ve ark., 2016).

### 3.6.1. Katman türleri


CNN, genel olarak, evrişimli katmanları havuz katmanları ile dönüşümlü olan ve ardından bazı tamamen bağlı katmanların izlediği hiyerarşik bir sinir ağıdır. Bu bölümde, üç katmanın işlevini sunacaktı.

#### 3.6.1.1. Evrişim katmanı (Convolution layer)

Bir ESA'nın Evrişim katmanı, farklı nitelik haritalarını üretmekte olan ve bütün görüntülerin piksellerine kontrol sağlamak için çok sayıda çekirdek kullanılmaktadır. Evrişim katmanı çalışması şekil 3. 7'de gösterilmektedir (Zeiler, 2013):

- 1) Görüntülerde aynı özellik haritasındaki ağırlık paylaşım mekanizması parametre sayısını azaltır.
- 2) Görüntülerde pikseller arasındaki bağlantı sağlayıp koordine eder.
- 3) Görüntülerde nesnelerin konumlarını değiştirmelerine izin verir.






Şekil 3.7. Evrişim katmanının çalışması

### 3.6.1.2. Havuzlama katmanı (Pooling layer)

Havuzlama Katmanları: Genellikle, bir havuz katmanı evrişim katmanının izler, nitelik haritasının ve ağ parametrelerinin boyutlarını azaltmak için kullanılabilir. Ortalama havuzlama ve maksimum havuzlama en sık kullanılan yöntemleridir. Şekil 3. 8, maksimum havuzlama işlemi için bir örnek göstermektedir. Boyutu  $2 \times 2$  ve 2. adım olan maksimum havuzlama operatörü, girilen görüntü  $8 \times 8$  boyuta sahip özellikli harita için, çıkış haritaları  $4 \times 4$  boyuta düşürülür.




Şekil 3.8. Maksimum havuzlama

Boureau ve arkadaşları için maksimum havuzlama ve ortalama havuzlama başarımlarının ayrıntılı bir teorik analizini sağlamışlardır. Scherer ve arkadaşları iki havuzlama işlemi arasında bir karşılaştırma yapmışlar olup maksimum havuzlamanın daha hızlı yakınsamaya yol açabileceğini, ayrıca üstün değişmez özellikleri seçebileceğini ve genellemeyi iyileştirebileceğini bulmuşlardır (Krizhevsky ve ark., 2012). Son yıllarda, CNN varyantlarının çeşitli hızlı GPU uygulamaları sunulmuş olup çoğu maksimum havuz stratejisi kullanmaktadır (Cireşan ve ark., 2011).

### 3.6.1.3. Tamamen bağı katman (Fully connected layer)

Son havuzlama katmanından sonra, birçok tamamen bağı katman kullanılarak 2D nitelik haritalarını 1D özelliğine dönüştürmektedir. Şekil 3. 9'da tamamen bağı katman dizisi gösterilmektedir.



Şekil 3.9. Tamamen bağı katman çalışması


Geleneksel bir sinir ağı gibi başarımlarını göstermiş olan Tam bağı katmanlar, bir CNN'deki değişkenliklerin yaklaşık % 90'ını kapsamaktadır. Tam bağı katmanın yapısının değiştirilmesi nadir bir işlemdir (Krizhevsky ve ark., 2012) ImageNet ile öğrenilen değişiklik, yeni görsel tanıma işlevlerine uyum sağlayabilmesi için son tam bağı katmanı iki yeni tamamen bağı katmanla değiştirmiş bulunmaktadır (Oquab ve ark., 2014). Bu katmanların dezavantajı, birçok değişkenlik içermeleridir. Bu yüzden bu katmanları eğitebilmek büyük bir hesaplama çabasıyla sonuçlanmaktadır. Bu sebepten dolayı, bu katmanları kaldırmak veya belirli bir yöntemle bağlantıları azaltmak yaygın olarak ve umut verici bir şekilde uygulanan bir yöntemdir. Mesela, GoogLeNet, maddi programlamasını sabit tutarken, tam bağlantılı mimarilerden seyrek bağlantılı mimarilere geçerek geniş ve derin bir ağ tasarlamış bulunmaktadır (Szegedy, ve ark., 2015).

### 3.7. Eğitim Stratejisi

Derin öğrenmeyi, sığ öğrenme (shallow learning) ile karşılaştırıldığımızda, derin öğrenmenin avantajı daha teorik bilgileri öğrenmek için derin öğrenme modelleri inşa edebilme gücüne sahip olmasıdır. Buna ek olarak, girilen çok sayıda değişkenlik farklı bir probleme neden olabilmektedir. Son çalışmalarda, yukarıda belirtilmiş olan değişken

havuz dâhil olmak üzere aşırı uyumluluğu korumak için çok sayıda düzenleme metodu meydana gelmiştir (Yanming Guo ve ark., 2016).

**Bırakma ve Bırakma Bağlantısı:** Bırakma, Hinton ve ark. Tarafından önerilmiş olup ve Baldi ve arkadaşları tarafından değerlendirilmesi yapılmıştır. Her bir eğitim durumu esnasında, algoritma, eğitim girdileri üzerinde karmaşık eş adaptasyonlarını önlemek ve genelleme yeteneğini arttırabilmek için nitelik algılayıcıların yarısını rastgele çıkarmış bulunmaktadır. Dropout'tan türetilen iyi bilinen bir genelleme, etkinleştirmeler yerine rastgele ağırlık düşüren Drop Connect olarak adlandırılır (Wan ve ark., 2013). Denemelerin daha yavaş ilerlemesine rağmen, çeşitli standart özellikler üzerinde daha iyi veya rekabetçi sonuçlara ulaşabileceğini göstermiştir. Şekil 3.10 No-Drop, Dropout ve DropConnect ağlarının bir karşılaştırmasını vermektedir (Wan ve ark., 2013).



Şekil 3.10. Bırakmayan, bırakma ve bağlantı bırakma ağlarının karşılaştırması

**Veri büyütme:** Görsel objeyi tanımak için bir ESA uygulandığı zaman, ek veri üretmek için ek etiketleme masrafları getirilmek yerine veri büyütme prosedürü sıklıkla kullanılmıştır. Tanınmış olan AlexNet (Krizhevsky ve ark., 2012): Yatay yansımalar ve görüntü çevirileri oluşturmaktan ibaret olan veri büyütme birinci biçimi olmak üzere ve eğitim görüntülerinde RGB kanallarının yoğunluğunu değiştirmekten ibaret olan ikinci biçimi olmak üzere iki farklı veri büyütme biçimi kullanmıştır. Howard ve arkadaşları AlexNet'i esas yöntem olarak almışlar olup, görüntü mahsullerini ekstra piksellerle genişleterek, ek renk yönlendirmelerini ekleyerek çeviri ve renk değişmezliğini artıran ek dönüşümler eklemiştir (Szegedy ve ark., 2015). Bu veri büyütme yöntemi, son zamanlardaki çalışmaların bazıları tarafından yaygın olarak kullanılmıştır. Dosovitskiy ve arkadaşları veri büyütmeyle dayalı denetimi olmayan bir nitelik öğrenme bakış açısı önermişlerdir. İlk başta rastgele bir seri görüntü yaması örneklemiştir olup her birini yardımcı sınıf olarak belirlemiştir. Ardından bu sınıfları genişletmek için, ölçek, çeviri, kontrasta ve rengi karşılık gelen dönüşümler uygulamışlardır. En son aşama olarak, bir CNN'i bu yardımcı sınıflar arasında ayırması için eğitmişlerdir. Ağ

vasıtasıyla öğrenilen nitelikler farklı sınıflandırma işlevlerinde iyi sonuçlar ortaya koymuştur. Wu ve arkadaşları Ölçekleme, döndürme ve kırpma gibi klasik metotlardan başka, lens distorsiyon, vinyet ve renk dökümü gibi teknikleri daha da çok kabul etmişlerdir.

**İlk eğitim ve ince ayar:** İlk eğitim, ağırları rastgele bir şekilde ayarlanmış olan parametrelerin yerine daha önce eğitilmiş olan parametrelerle başlatmaktır. CNN'lere dayalı modeller epey popüler olmuştur. Çünkü öğrenme sürecini hızlandırabilir ve genelleme yeteneğini artırabilir. AlexNet (Krizhevsky ve ark., 2012). Mükemmel bir performans elde ettiğinde ve kamuya duyurulduğunda, çok sayıda yaklaşım, temel derin öğrenme modeli olarak ImageNet2012 üzerinde eğitilmiş AlexNet'i, (Girshick ve ark., 2014) seçmiş olup özel görevlerine göre parametrelerin ince ayarını kullanılmıştır (Ouyang ve ark., 2014). Buna ek olarak, başka modeller üzerinde eğitim vererek daha iyi bir performans sağlayan bakış açıları bulunmaktadır (Long ve ark., 2015). Öreğin, VGG-16 (Simonyan ve Zisserman, 2014). Clarifai (Zeiler, 2013) ve GoogLeNet (Szegedy ve ark., 2015). İnce ayar, modelleri belirli işlevlere ve veri kümelerine uyarlamak üzere iyileştirmek için oldukça önemli evredir. Genellikle, ince ayar, kayıp işlevlerinin hesaplanması için kullanılmakta olan yeni eğitim veri kümesi için sınıf etiketi gerektirmektedir. Bu duruma göre, yeni modelin tüm katmanları, yeni veri kümesinin sınıf etiketlerinin sayısına bağlı olan ve bu nedenle rastgele başlatılacak olan son çıkış katmanı hariç, AlexNet gibi önceden eğitilmiş modele dayanarak başlatılacaktır. Fakat bazen herhangi bir yeni veri seti için sınıf etiketi elde etmek oldukça güçtür (Krizhevsky ve ark., 2012). Bu problemi çözmek için, sınıf etiketleri olmadan kayıp fonksiyonları olarak kullanılacak olan bir benzerlik öğrenme hedefi fonksiyonu önerilmiştir (Wan ve ark., 2013). Böylelikle geri yayılım normal çalışabilir ve modelin katman katman rafine yapılmasına izin verebilmektedir. Daha önceden eğitilmiş olan modelin nasıl verimli bir şekilde aktarılacağını açıklamakta olan birçok araştırma yapılmıştır. Belirli bir katmanın genel veya spesifik olma derecesini, yani o katmandaki özelliklerin bir görevden diğerine ne kadar iyi aktarıldığını ölçmek için yeni bir yol tanımlanmıştır (Yosinski ve ark., 2014). Hemen hemen her sayıda katmandan aktarılan özelliklere sahip bir ağı başlatmanın, yeni bir veri setine ince ayar yaptıktan sonra genelleme başarımını artırabileceği sonucu elde edilmiştir.

### 3.8. Destek Vektör Makineleri (SVM)


Destek vektör makineleri, hem sınıflandırma hem de regresyon için kullanılan güçlü ancak esnek denetimli makine öğrenme algoritmalarıdır. Ancak genel olarak sınıflandırma problemlerinde kullanılırlar. 1960'larda Svm'ler ilk kez tanıtılmış olup daha sonra 1990 yılında rafine edilmiştir. Svm'ler, diğer makine öğrenme algoritmalarına kıyasla benzersiz uygulama yöntemlerine sahiptir. Son zamanlarda, birden fazla sürekli ve kategorik değişkeni ele alma yetenekleri nedeniyle son derece popüler olmuştur (Anonymous, 2021).

Destek vektör makineleri, hem gerileme hem de sınıflandırma sorunları için güçlü bir makine öğrenimi yöntemidir. Ancak, çeşitli SVM formülasyonlarının her biri, kullanıcının eğitim sürecini yöneten iki veya daha fazla parametre ayarlamasını gerektirir ve bu parametre ayarları elde edilen motorun performansı üzerinde derin bir etkiye sahip olabilir (Staelin, 2002).

Makine öğrenimi yöntemi performansını değerlendirmenin standart sorunu olan parametrenin etkinliğinin nasıl değerlendirileceğine karar vermektir. En yaygın yöntem bir çeşit N-fold çapraz doğrulamadır. Ancak bir kerelik izin ve Dietterich'in 5x2cv testi gibi diğer yaklaşımlar da mümkündür. Tüm bu yöntemler, tek bir parametre ayarı için tek bir performans elde etmek için makinenin öğrenim motoru birden çok kez eğitilmelidir (Staelin, 2002).

Parametre seçimine en yaygın ve güvenilir yaklaşım, parametre aralıklarına karar vermek ve daha sonra en iyi ayarı bulmak için parametre alanı üzerinde kapsamlı bir kılavuz araması yapmaktır. Ne yazık ki, orta derecede yüksek çözünürlüklü aramalar bile çok sayıda değerlendirmeye ve kabul edilemeyecek kadar uzun çalışma sürelerine neden olabilmektedir (Montgomery, 2008). SVM'ler, şekil 3. 11'de gösterildiği gibi, bir veri kümesini en iyi şekilde iki sınıfa ayıran bir hiper düzlem bulma fikrine dayanmaktadır (Bambrick ve Aylien, 2021).


SVM'ler, diğer makine öğrenimi algoritmalarına kıyasla benzersiz bir uygulama yöntemine sahiptir. Son zamanlarda, birden fazla sürekli ve kategorik değişkeni ele alma yetenekleri nedeniyle son derece popülerdirler.




Şekil 3.11. Veri kümesini iki sınıfa ayıran bir hiper düzlemi

### 3.8.1. SVM'nin çalışması

Destek vektör makinelerini kullanmadan önce öznitelik ölçeklendirmesi yapmak, karar sınırları arasındaki uzaklığın maksimum olmasını sağlayacaktır. SVM modeli temelde çok boyutlu uzaydaki bir hiper düzlemde farklı sınıfların bir gösterimidir. Hiper düzlem, hatanın en aza indirilebilmesi için SVM tarafından yinelemeli bir şekilde oluşturulur. SVM'nin amacı, maksimum marjinal hiper düzlem (MMH) bulmak için veri kümelerini sınıflara bölmektir (Anonymous, 2021).



Şekil 3.12. SVM algoritmasının problem sınıflandırması.



Şekil 3.13. SVM'lerin çalışma şeması.

SVM'de aşağıdakiler önemli kavramlardır.

1. Destek Vektörleri – Hiper düzleme en yakın olan veri noktalarına destek vektörleri denir. Bu veri noktaları yardımıyla ayırma çizgisi tanımlanacaktır. Destek vektörleri, alt düzleme en yakın veri noktalarıdır, bir veri kümesinin noktaları çıkarılırsa bölünen altdüzlemin konumunu değiştirir. Bu nedenle, bir veri setinin kritik unsurları olarak kabul edilebilir (Bambrick ve Aylie, 2021).
2. Hiper düzlem – Yukarıdaki diyagramda gördüğümüz gibi, farklı sınıflara sahip bir nesne kümesi arasında bölünmüş bir karar düzlemi veya uzayıdır. Bir hiper düzlemi

bir veri kümesini doğrusal olarak ayıran ve sınıflandıran bir çizgi olarak düşünülebilir.

3. Marj – Farklı sınıfların gizli veri noktalarında iki çizgi arasındaki boşluk olarak tanımlanabilir. Hattan destek vektörlerine dikey mesafe olarak hesaplanabilir. Büyük marj, iyi bir marj olarak kabul edilmekte ve küçük marj, kötü bir marj olarak kabul edilmektedir (Anonymous, 2021).

SVM'nin temel amacı, maksimum marjinal hiper düzlem (MMH) bulmak için veri kümelerini sınıflara bölmektir. Ve bu amaç aşağıdaki iki adımda yapılabilir. Aşağıdaki resimler, iyi ve kötü marjın görsel örneğini vermektedir. İyi bir marj, puanların diğer sınıfa geçmeden kendi sınıflarında olmasını sağlar (Patel, 2017).



Şekil 3.14. İyi marj ve kötü marj grafikleri

- İlk olarak, SVM, sınıfları en iyi şekilde ayıran yinelemeli olarak hiper düzlemler oluşturacaktır.
- Ardından, sınıfları doğru şekilde ayıran hiper düzlemi seçecektir.

### 3.8.2. SVM çekirdekleri

SVM, maksimum kenar boşluğu ölçütüne göre en uygun ayırma hiper düzlemini öğrenebilen bir sınıflandırıcı sınıftır. Doğrusal SVM'nin iki sınıf arasındaki ayrışa bilirliliği artırmak için daha yüksek boyutlu bir alanda çalışmasını sağlamak için farklı çekirdekler kullanabilir. Çekirdek uzantısı SVR öğrenimine benzer (Guo ve ark., 2016).

Uygulamada, SVM algoritması, bir girdi veri alanını gerekli forma dönüştüren çekirdekle uygulanır. SVM, çekirdeğin düşük boyutlu bir girdi alanı aldığı ve daha yüksek boyutlu bir alana dönüştürdüğü çekirdek hilesi adı verilen bir teknik kullanır. Basit bir deyişle, çekirdek bölünemeyen sorunları daha fazla boyut ekleyerek ayrılabilir sorunlara dönüştürür. SVM'yi daha güçlü, esnek ve doğru hale getirir. Aşağıda, SVM tarafından kullanılan çekirdek türlerinden bazıları bulunmaktadır (Anonymous, 2021).

### 1. Doğrusal çekirdek (Linear kernel)

Herhangi iki gözlem arasında noktalı bir ürün olarak kullanılabilir. Doğrusal çekirdeğin formülü aşağıdaki gibidir:

$$K(x, x_i) = \sum (x * x_i)$$

Yukarıdaki formülden, iki vektör arasındaki ürünün  $x$   $x_i$ 'nin her girdi değeri çiftinin çarpımının toplamı olduğunu söyleyebiliriz.

### 2. Polinom çekirdeği (Polynomial kernel)

Veri setine polinomial öznelikler eklemek basit ve kullanışlı ayrıca diğer makine öğrenimi modellerinde de kullanılabilmesine rağmen, düşük dereceden polinomlar, karmaşık veri setlerinde işe yaramaz yüksek dereceden polinomlar ise modele yüksek sayıda öznelik ekleyerek oldukça yavaşlatmaktadır. Polinom, doğrusal çekirdeğin daha geliştirilmiş şeklidir ve kavisli veya doğrusal olmayan giriş alanını ayırt eder. Polinom çekirdeği formülü aşağıdadır (Anonymous, 2021).

$$K(x, x_i) = 1 + \sum (\sum(x * x_i))^d$$

Burada  $d$ , öğrenme algoritmasında manuel olarak belirtmemiz gereken polinom derecesidir.

### 3. Radyal temel işlev (RBF) çekirdeği (Radial basis function (RBF) kernel)

Çoğunlukla SVM sınıflandırmasında kullanılan RBF çekirdeği, girdi alanını belirsiz boyutsal alanda eşler. Aşağıdaki formül bunu matematiksel olarak açıklar.

$$K(x, x_i) = \exp(-\gamma * \sum(x - x_i)^2)$$

Burada  $\gamma$  0 ile 1 arasında değişmektedir. Öğrenme algoritmasında bunu manuel olarak belirtmek gerekir. İyi bir varsayılan  $\gamma$  değeri 0.1'dir.

Doğrusal olarak ayrılabilir veriler için SVM'yi uyguladığında, doğrusal olarak ayrılabilen veriler Python'da uygulanabilir. Bu aşama çekirdekler kullanılarak yapılabilir.

Doğrusal, polinom ve RBF veya Gauss çekirdeği, sınıflar arasında hiper düzlem karar sınırının oluşturulması durumunda basitçe farklıdır.

Çekirdek fonksiyonları, orijinal veri kümesini (doğrusal / doğrusal olmayan) doğrusal veri kümesi haline getirme görünümüyle daha yüksek boyutlu bir alana eşlemek için kullanılabilir. Genellikle doğrusal ve polinom çekirdekler daha az zaman alır ve rbf veya Gauss kernellerinden daha az doğruluk sağlar.  $K$  çapraz doğrulama, eğitim setini  $k$  farklı alt gruba bölmek için kullanılır. Daha sonra her alt küme eğitim



için kullanılır ve diğer k-1 eğitim aşamasının tamamında doğrulama için kullanılır. Bu, sınıflandırma görevinin daha iyi eğitilmesi için yapılı (Anonymous, 2021).

#### 4. Sigmoid çekirdek

Sigmoid çekirdeği sinir ağları için vekil olarak kullanabiliriz. Aşağıdaki denklem bu aşamayı açıklamaktadır.

$$\mathcal{K}(x, y) = \tanh(\alpha x^T y + c)$$

SVM'ler görüntüleri daha yüksek arama doğruluğuyla sınıflandırabilir. Doğruluğu geleneksel sorgu tabanlı iyileştirme düzenlerinden daha yüksektir.

#### 3.8.3. SVM sınıflandırıcılarının artıları


- SVM sınıflandırıcılar büyük bir doğruluk sunar ve yüksek boyutsal alanla iyi çalışır.
- SVM sınıflandırıcılar temelde eğitim noktalarının bir alt kümesini kullanır. Bu nedenle sonuç olarak çok daha az bellek kullanır (Bambrick ve Aylien, 2021).

#### 3.8.4. SVM sınıflandırıcılarının eksileri

- SVM'lerle eğitim süresi yüksek olabileceğinden daha büyük veri kümelerine uygun değildir.
- Çakışan sınıflarla daha gürültülü veri kümelerinde daha az etkilidir (Bambrick ve Aylien, 2021).

### 3.9. VGG-16 Modeli

VGG-16, Oxford Üniversitesinden K. Simonyan ve A. Zisserman tarafından "Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağlar" makalesinde önerilen evrişimli bir sinir ağı modelidir. Model, ImageNet'te %92,7 ilk 5 test doğruluğuna ulaşır, 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan bir veri kümesidir. Şekil 3.15 VGG-16'nın katmanlı mimarisini göstermektedir. ILSVRC-2014'te sunulan ünlü modellerden biri olmaktadır. Büyük çekirdek boyutlu filtreler (sırasıyla birinci ve ikinci evrişimli katmanda 11 ve 5) birden çok 3×3 çekirdek boyutlu filtrelerle birbiri ardına değiştirilerek AlexNet'e göre iyileştirme yapmaktadır. NVIDIA Titan Black GPU'ları kullanarak VGG-16'yı haftalarca eğitmiştir (Anonymous, 2021).



Şekil 3.15. VGG-16 'nın katmanlı mimarisi


VGG-16'nın Temel Özellikleri:

1. Aynı zamanda Oxford'daki Visual Geometry Group'un adını taşıyan Oxford Net modeli olarak da adlandırılır.
2. 16 numara, bazı ağırlıklara sahip toplam 16 katmana sahip olduğunu ifade eder.
3. Evrişim ve havuz katmanlarını içeriyor.
4. Evrişim için her zaman 3 x 3 Çekirdek kullanılmalıdır.
5. Maksimum havuz boyutu 2x2'dir.
6. Toplamda yaklaşık 138 milyon parametreye sahiptir.
7. Image Net verileri üzerinde eğitilmiştir.
8. Sahip olduğu doğruluk oranı % 92. 7'dir
9. VGG-16'nın bir sürümü daha vardır (VGG-19), ağırlıkları olan toplam 19 katmandan oluşmaktadır (Parashar, 2020).

## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

### 4.1. Veri Kümesi

FLIR ThermaCAM™ E45 kızılötesi kamera kullanılarak çekilen diz termal görüntüleri, Ağustos 2020 - Ocak 2021 tarihleri arasında Özel Ankara Umut ve Ankara Gazi Üniversitesi hastanelerinin Ortopedi bölümünde elde edilmiştir. Görüntüler çekilirken alanın nemi ve aydınlatılması dikkatle kontrol edilmiştir. Çünkü bu etkenler kızılötesi termografi sinyalini etkileyebilmektedir. Termografik görüntüler diz rahatsızlığı olan deneklerden alınmıştır. Deneklerin ayağına giydiği çorabın çıkarılması ve giysilerini dizine kadar çekmesi istenmiştir. Amaç, termogramı yakalamadan önce termal dengeye ulaşmaktır. Kızılötesi kamera, objeden yaklaşık 50 cm uzaklıkta bir odak mesafesine yerleştirilmiştir. Kontrast ortam sıcaklığı ile dengeleme sağlanmıştır. Kızılötesi kamera, sıcaklık ölçeğini ortamdaki en soğuk ve en sıcak noktalara göre otomatik olarak kalibre etmiştir. Söz konusu görüntüler farklı kişilerden alınmış olup bu kişilerin her iki dizi ya da bir dizi yaralı ve bir dizi sağlıklı veyahut da tamamen sağlıklıdır. Şekil 4. 1’de IR ile alınan hasta ve sağlıklı diz görüntüleri verilmiştir.




Şekil 4.1. IR ile hasta ve sağlam diz görüntüleri

### 4.2. Veri Kümesinin Hazırlanması

Python programlama dilinde bütün deneyler için uygulanma gerçekleştirilmiştir. Keras ve tensorflow kütüphaneleri kullanılmıştır. Eğitilmiş ağ olan ESA'nın sınıflandırma üzerinde yüksek başarımı ve minimum hata vermesinden dolayı bu çalışma için kullanılması uygun görülmüştür.

Termal kamerayla alınan görüntüler sayısı toplam 998 görüntüdür. Bu görüntülerden hasta sayısı 284, kontrol grubu sayısı 714 olacak şekilde üzerinde ölçüm

yapılmıştır. Derin öğrenme ve makine öğrenme modelleri, modelin daha önce görmediği görüntülerde hastalığı sınıflandırmak ve tanımlamak amacıyla hastalığın görüntüleri üzerinde değerlendirilmiş ve eğitilmiştir. Önerilen modellerde veri setinin ‘hasta’ ve ‘sağlam’ şeklinde yeniden ölçeklendirilmesi yapılmıştır.



**Şekil 4.2.** Çalışma şeması

Söz konusu görüntüler üzerinde görüntü işleme yöntemleri uygulanmıştır. Bu yöntemler ise aşağıdaki gibidir:

1. Uygulanan CNN modelinin girdisi 64, 64, 3 piksel görüntülerdir. 16, 3, 3 boyutunda bir evrişim katmanı vardır. Ardından, görüntünün yüksekliğini ve genişliğini 2x2 'e düşüren bir maksimum havuz katmanı mevcuttur. Daha sonra 32x3x3 boyutunda olmak üzere bir evrişim katmanı bulunmaktadır. Ardından yine görüntünün yüksekliğini ve genişliğini 2x2'e düşüren bir maksimum havuz katmanı vardır. Sonra 64x3x3 boyutunda olan evrişim katman bulunmakta olup bundan sonra yine bir maksimum havuz katmanı görüntü boyutunu 2x2'ya düşürmektedir. Daha sonra düzleştirilmiş doğrusal birim katmanı, seyreltme Katmanı ve dense 2'dir. Son olarak çıktı katmanı mevcuttur.

**Çizelge 4.1.** CNN veri oluşturma Çizelgesi

Yöntem	Tip	Eğitim	Test	En iyi Başarım %'si
CNN	Hasta	271	13	% 90
	Sağlam	597	117	

2. Uygulanan SVM yöntemi: Sklearn'de SVM kullanılması kapsamında birkaç önemli parametreler verilmiştir.

Parametre - grid = [1, 10, 100, 1000]

Kernel: ['Linear']

Gamma: [0.001, 0.0001], 'kernel': ['rbf']

**Çizelge 4.2.** SVM veri oluşturma Çizelgesi

Yöntem	Tip	Eğitim	Test	En iyi Başarım %'si
SVM	Hasta	271	13	% 77
	Sağlam	597	117	

3. Uygulanan VGG-16 modelinin girdisi 320x320x3 piksel görüntülerdir. Her biri 320x240x64 boyutunda olmak üzere iki evrişim katmanı vardır. Ardından görüntünün yüksekliğini ve genişliğini 160x120x64'e düşüren bir havuz katmanı mevcuttur. Sonradan her biri 160x120x128 boyutunda iki evrişim katman bulunmakta, ardından yine görüntünün yüksekliğini ve genişliğini 80x60x128'e düşüren bir havuz katmanı vardır. Daha sonra, her biri 80x60x256 boyutunda olan üç evrişim katman var, bundan sonra yine bir havuz katmanı görüntü boyutunu 40x30x256'ya düşürmektedir. Sonra, her biri 40x30x512 boyutunda üç evrişim katmanı mevcut, bundan sonra yine bir havuz katmanı görüntü boyutunu 20x15x512'ye düşürmektedir. Sonra yine her biri 20x15x521 katmanı olan üç evrişim katmanı bulunmakta, bundan sonra 10x7x512'lik bir havuz katmanı vardır. Sonra düzleştirilmiş doğrusal birim katmanı 35840 ve dense-2 vardır. Son olarak çıktı katmanı bulunmaktadır.

**Çizelge 4.3.** VGG-16 veri oluşturma çizelgesi

Yöntem	Tip	Eğitim	Test	En iyi Başarım %'si
VGG-16	Hasta	271	13	% 69,23
	Sağlam	597	117	

### 4.3. İstatistiksel Analiz

Veriler SPSS ( Statistical Package for the Social Sciences ) version 25 istatistik paket programına girilmiştir. Kişilerden alınan görüntüler, isim ve soy isim, yaş ve cinsiyet grupları; sağ ve sol sıcaklık extremist sınıflandırılmasına göre excel programında listelenmiştir.

Sayım deęişkenleri (cinsiyet ve yař grubu) sayı ve yzdelere sunulmuřtur. lm deęişkenleri olan sıcaklık dereceleri aritmetik ortalama ve standart sapma ile sunulmuřtur. Hasta ve saęlamlar arasındaki sıcaklık farkına non parametrik test olan Mann-Whitney U testi ile bakılmıřtır.

Hasta ve saęlam sıcaklık dereceleri tm istatistiksel analizlerde  $p < 0.05$  dzeyinde anlamlı deęerlendirilmiřtir.

**izelge 4.4.** Cinsiyet grubu izelgesi

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	KADIN	323	64,1	64,1	64,1
	ERKEK	181	35,9	35,9	100,0
	Total	504	100,0	100,0	

**izelge 4.5.** Normallik testleri

	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
Yař	,056	502	,001	,979	502	,000

a. Lilliefors nem dzeltmesi.

#### 4.4. Python Programlama Arayz

Genel kavramlar, kullanılacak ara, teknikler ve termal kameranın yapıları ile ilgili nceki blmlerde bilgi sahibi olduktan sonra, řimdi grntnn okunmasına deęinmek iin sistemde kullanılan ekranlara geiř yapıyoruz. Sz konusu sistem Python ile baęlanacaktır.

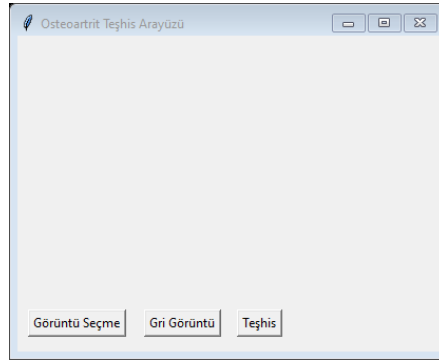
ok eřitli aık kaynak kitaplıkları sayesinde, gnmzde Python'da basit makine ęrenimi algoritmalarını kullanarak veri kmelerini keřfetmeye ve bazı ilk tahminleri yapmaya bařlamak nispeten kolaydır. Her ne kadar bu eęitilmiř modellerin gerek dnyada kullanıřlı hale getirilmesi iin paylařılması ve tahminlerde bulunabilmesi iin dięer kullanıcıların makinelerinde kolayca eriřilebilir hale getirilmesi gerekmektedir. makine ęrenimi ancak bu řekilde topluma fayda saęlamak iin kullanılabilir.

Projenin bu blmnde, nerilen sistemin sunduęu aralarla, hastaların vakalarının teřhis edilmesinde doktorun ihtiyalarını karřılayan nerilen sistemin ekranları netleřtirilecektir.

#### 4.4.1. Ana sayfa (Osteoartrit Teşhis Arayüzü)

Şekil 4. 3'te aşağıdaki komut setini içeren sistemin ana ekranını göstermektedir.

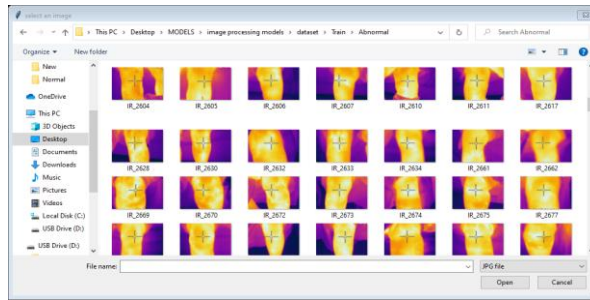
- Termal görüntü yükleme komutu (Görüntü Seçme)
- Termal görüntüyü gri görüntüye dönüştürme komutu (Gri Görüntü)
- Sistemi çalıştıran komut (Teşhis).



Şekil 4.3. Ana ekran.

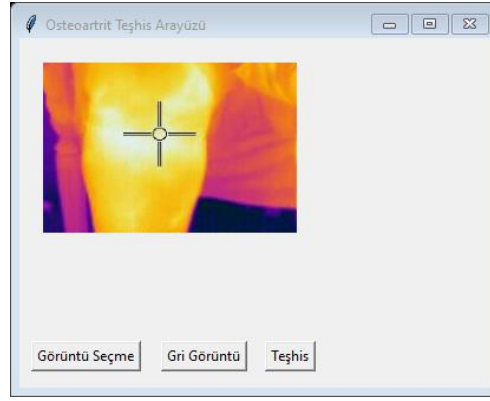
Termal görüntü yükleme komutu:

Hastanın termal görüntüsünü yüklemek için (Görüntü Seçme) düğmesine tıklanır, daha sonra hastanın görüntüsünün bulunduğu dosya açılır ardından fotoğraf türü seçilir, fotoğraflar ekranda görüldükten sonra istenen fotoğraf seçilir. Şekil 4. 4'te gösterildiği gibidir.



Şekil 4.4. Görüntü yükleme ekranı

Daha sonra gerekli tedavi (tanı) için seçilen hastanın termal görüntüsü Şekil 4.5 teki gibi gösterilir. Hastanın termal görüntüsünün yüklenmesinin amacı, hastanın durumunu teşhis etmek ve hastalığın veya hastalıkların doktor tarafından belirlenmesidir.



**Şekil 4.5.** Hasta görüntüsü

Termal görüntüyü gri görüntüye dönüştürme:

Şekil 4.6'da gösterildiği gibi gri düğmesine (Gri Görüntü) basarak gri tonlamaya dönüştürülür. Termal görüntüyü griye dönüştürmenin amacı, renkli görüntüde bulunmayan diğer özellikleri göstermektir.



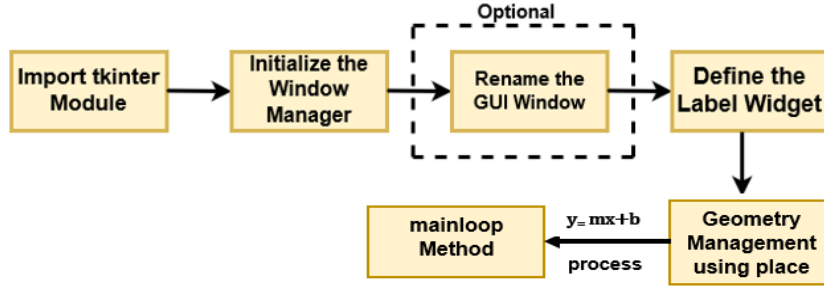
**Şekil 4.6.**Görüntüyü griye dönüştürme

#### 4.4.2. Sistem uygulamasının anlatımı

Tkinter: Python için "standart" GUI araç takımı olarak adlandırılabilir tek bir paket olsaydı, bu Tkinter olurdu. Tkinter, popüler bir grafik arabirim ve ilk olarak 90'ların başında popüler hale gelen dil eşleştirmesi olan Tcl/ Tk'yi çevreleyen bir sarmalayıcıdır. Tkinter'ı seçmenin avantajı, kitaplar ve kod örnekleri de dahil olmak üzere çok sayıda kaynağın yanı sıra, sorularınız olduğunda size yardımcı olabilecek geniş bir kullanıcı topluluğudur. Tkinter modülünü uygulamadan önce CNN yöntemini kaydetmekten (model.save) hedef, hastalığın teşhisi için zamandan kazanmaktır. Çünkü bu yöntem



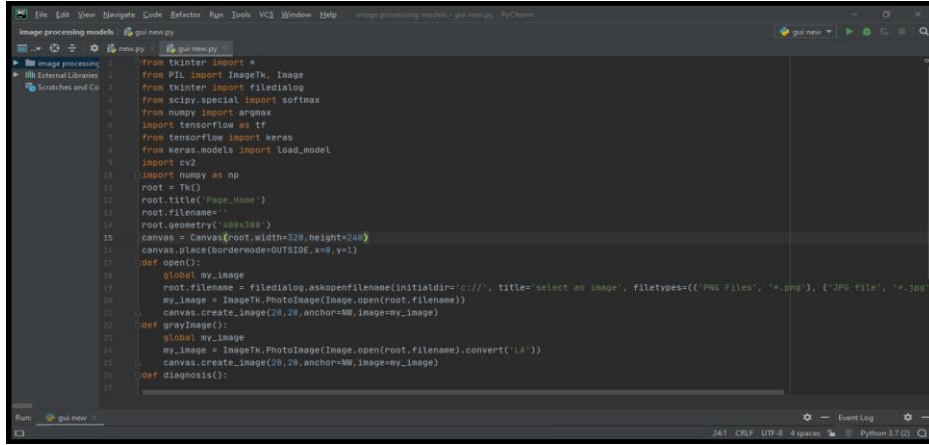
fazla zaman almaz ve modelin yeniden eğitilmesine gerek duyulmaz. Ardında şekil 4.7’de arayüz programının oluşturma akış şeması gösterilmiştir.



Şekil 4.7. Arayüz oluşturmak için akış şeması

Yukarıdaki akış şemasını bölümleyelim ve her bir bileşenin işlevini anlayalım!

- İlk olarak, anahtar bileşeni, yani Tkinter modülü içe aktarılır.
- Bir sonraki adım olarak, pencere yöneticisi Tkinter’ı Tk()yöntemle başlatılır ve bir değişkene atanır. Bu yöntem, normal bir GUI’de olması gerektiği gibi üstte kapat, büyüt ve küçült düğmeleri olan boş bir pencere oluşturur.
- Ardından isteğe bağlı bir adım olarak, Rename pencerenin başlığı isteye göre yapılır, root.title ('Osteoartrit Teşhis Arayüzü')
- Ardından, pencereye metin eklemek için kullanılan Label adlı bir widget çağrı kullanılır.
- Ardından, parçacığı gereken boyutta görüntülemek için Tkinter'ın place () adlı geometri yönetimi özelliği kullanılır.
- Ardından, Canvas, GUI’de şekiller çizmek için kullanılır ve çeşitli çizim yöntemlerini destekler, canvas = Canvas ().
- Ardından, Teşhis butonuna tıklayarak görüntüyü modele yüklediğimizde model hastalığın bulunup bulunmadığı konusunda ve hastayı teşhis etme tahmininde bulunur model = load\_model.
- Son adım olarak, pencereyi manuel olarak kapatana kadar görüntülemek için mainloop() yöntemi kullanılır. Arka uçta sonsuz bir döngü çalıştırılır.



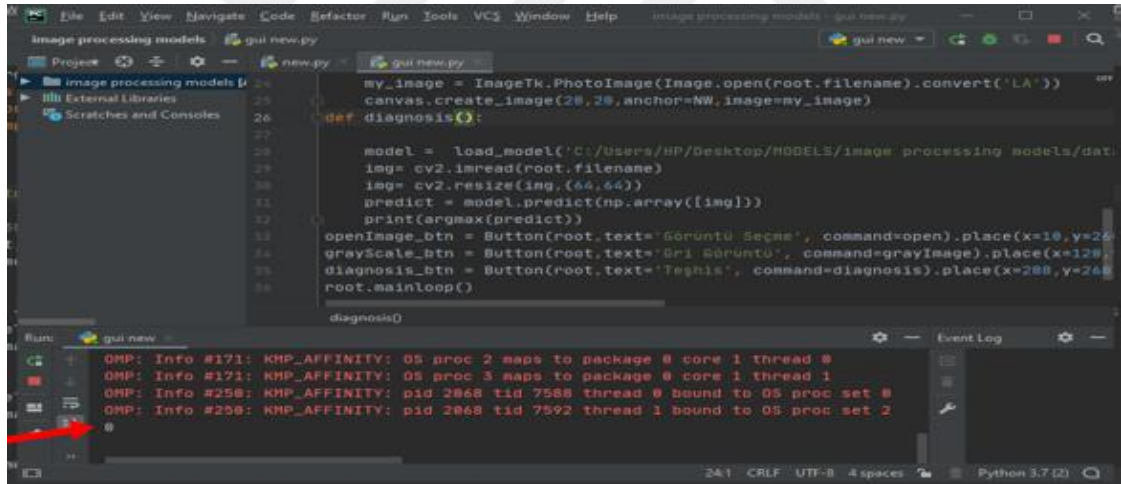
```

1 from tkinter import *
2 from PIL import ImageTk, Image
3 from tkinter import filedialog
4 from scipy.special import softmax
5 from numpy import argmax
6 import tensorflow as tf
7 from tensorflow import keras
8 from keras.models import load_model
9 import cv2
10 import numpy as np
11 root = Tk()
12 root.title('Page_Name')
13 root.filename = ''
14 root.geometry('400x300')
15 canvas = Canvas(root,width=320,height=240)
16 canvas.place(bordermode=OUTSIDE,x=0,y=1)
17 def open():
18     global my_image
19     root.filename = filedialog.askopenfilename(initialdir='/', title='select an image', filetypes=[('PNG Files', '*.png'), ('JPG file', '*.jpg')])
20     my_image = ImageTk.PhotoImage(Image.open(root.filename))
21     canvas.create_image(20,20,anchor=NW,image=my_image)
22 def grayImage():
23     global my_image
24     my_image = ImageTk.PhotoImage(Image.open(root.filename).convert('LA'))
25     canvas.create_image(20,20,anchor=NW,image=my_image)
26 def diagnosis():
27

```

Şekil 4.8. Python ile arayüz programlama

Teşhis butonuna tıklayarak program hastalığın bulunup bulunmadığı konusunda ve hastalığın teşhis etme tahmininde bulunur. Örneğin şekil 4.9'da hastalığın bulunduğunu göstermektedir.



```

25 my_image = ImageTk.PhotoImage(Image.open(root.filename).convert('LA'))
26 canvas.create_image(20,20,anchor=NW,image=my_image)
27 def diagnosis():
28
29     model = load_model('C:/Users/HP/Desktop/MODELS/image processing models/dati
30 img = cv2.imread(root.filename)
31 img = cv2.resize(img,(64,64))
32 predict = model.predict(np.array([img]))
33 print(argmax(predict))
34 openImage_btn = Button(root,text='Görüntü Seçme', command=open).place(x=10,y=26
35 grayScale_btn = Button(root,text='Gri Görüntü', command=grayImage).place(x=120,
36 diagnosis_btn = Button(root,text='Teşhis', command=diagnosis).place(x=200,y=260
37 root.mainloop()
38
39 diagnosis()

```

Run console output:

```

OMP: Info #171: KMP_AFFINITY: OS proc 2 maps to package 0 core 1 thread 0
OMP: Info #171: KMP_AFFINITY: OS proc 3 maps to package 0 core 1 thread 1
OMP: Info #208: KMP_AFFINITY: pid 2868 tid 7588 thread 0 bound to OS proc set 0
OMP: Info #208: KMP_AFFINITY: pid 2868 tid 7592 thread 1 bound to OS proc set 2

```

Şekil 4.9. Hasta tahmin örneği

## 5. SONUÇLAR VE ÖNERİLER

### 5.1. Sonuçlar

Bu tez çalışmamızda termografik görüntülerin makine öğrenimi ve derin öğrenme metotları ile sınıflandırılması yapılmıştır. Derin öğrenme metodu ile sınıflandırma uygulanacağı zaman çok sayıda veri gerekmektedir. Bu nedenle elde edilen toplamda 998 görüntü veri artırma yöntemi kullanılarak görüntü sayısı artırılmıştır. Geleneksel veri artırma yöntemleri kullanarak kontrast değiştirme, parlaklık artırma gibi veri artırımı yöntemleri uygulanmıştır. Bu görüntüleri eğitim ve test verisi şeklinde uygulayarak CNN ile sınıflandırma gerçekleştirildiğinde % 90 doğruluk oranına ulaşılmıştır.

Görüntü artırma yöntemi kullanmadan da derin öğrenme ile sınıflandırma yapmak için ilk-eğitilmiş transfer öğrenme yöntemi uygulanmıştır. Görüntü işlemede uygulanan CNN modelinden doğruluk %90, VGG-16 modelinden %69.23 ve SVM modelinden %77 doğruluk oranı elde edilmiş olup uygulanan görüntü işleme yöntemleri arasında en yüksek ve en sağlam doğruluk oranı CNN modelinde ortaya çıkmıştır. Python dili büyük potansiyeli nedeniyle önerilen sistemin tasarımında ve programlanmasında programlama dili olarak Python, CNN modeline bağlanarak kullanılmıştır. Termografi hastalığı teşhis etme sürecinde bir çok araç sağladığından bu süreçte doktora yardımcı olabilecek termal görüntüleme kullanarak bir sistem tasarlanmıştır. Söz konusu kişilerden alınan görüntüler SPSS version 25 istatistik paket programına girilmiştir. Tüm istatistiksel analizlerde  $p < 0.05$  düzeyinde anlamlı değerlendirilmiştir.

### 5.2. Öneriler

1. Görüntü sayısı artırılarak daha yüksek bir doğruluk yüzdesi elde edilebilir, doktor için de hastalığı teşhis etmekte sağlam bir sonuca ulaşılabilir.
2. Görüntüyü kaydetme, büyütme, Sistemin nasıl çalıştırılacağına ilişkin talimatlar (Yardım) ve ısı derecesini gösterme, butonlarını uygulayarak arayüz grafiği geliştirilebilir.

## KAYNAKLAR

- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *in Proceedings of the IEEE, vol. 86, no. 11*, 2278-2324.
- Anonim. (2021, Nisan 21). *Termal görüntüleyiciler ve gaz detektörleri | Fluke*. Termal görüntüleyiciler ve gaz detektörleri | Fluke Web Sitesi: <https://www.fluke.com/tr-tr/urunler/termal-goruntuleme/termal-goruntuleyiciler> adresinden alındı
- Anonymous. (2021, Mart 10). *instrumentsgroup*. 05 16, 2021 tarihinde instrumentsgroup Web Sitesi: [http://www.instrumentsgroup.com.za/index\\_files/Flir/Learn/Elec.Mech\\_Diagnostics.pdf](http://www.instrumentsgroup.com.za/index_files/Flir/Learn/Elec.Mech_Diagnostics.pdf) adresinden alındı
- Anonymous. (2021, Nisan 2). *Support Vector Machine (SVM)*. Support Vector Machine (SVM) Web Sitesi: [https://www.tutorialspoint.com/machine\\_learning\\_with\\_python/classification\\_algorithms\\_support\\_vector\\_machine.htm](https://www.tutorialspoint.com/machine_learning_with_python/classification_algorithms_support_vector_machine.htm) adresinden alındı
- Anonymous. (2021, Nisan 29). *VGG16 – Convolutional Network for Classification and Detection*. VGG16 – Convolutional Network for Classification and Detection Web Sitesi: <https://neurohive.io/en/popular-networks/vgg16/> adresinden alındı
- Ansiklopedi, Ö. (2021, Nisan 18). *Termal kamera - Vikipedi*. Termal kamera - Vikipedi Web Sitesi: [https://tr.wikipedia.org/wiki/Termal\\_kamera](https://tr.wikipedia.org/wiki/Termal_kamera) adresinden alındı
- Ayhan, S., & Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Bambrick, N., & Aylien. (2021, Nisan 28). *Support-Vector-Machines-Simple-Explanation*. Support-Vector-Machines-Simple-Explanation Web Sitesi: <https://www.kdnuggets.com/> adresinden alındı
- Berkmen, G. (2001). Dış Cephe Yalıtım Sistemleri ve Uygulama Prensipleri. *Ulusal Tesisat Mühendisliği Kongresi*. İzmir.
- Çalışan, M., & Türkoğlu, İ. (2011). *Termal Kameralar ve Uygulamaları*. Bingöl: Elektrik-Elektronik ve Bilgisayar Sempozyumu.
- Cireşan, D., Meier, C., Masci, U., & Gambardella, J. (2011). High-performance neural networks for visual object classification. *arXiv preprint arXiv:1102.0183*.
- Değirmenci, A. (2010). *Türkiye’de uygulanan yalıtım tekniklerinin araştırılmasında termal kameranın etkin biçimde kullanılması*. Fen Bilimleri Enst. Yüksek Lisans.
- Erdem, E., & Aydın, T. (2021). Detection of Pneumonia with a Novel CNN-based Approach. *Sakarya University Journal of Computer and Information Sciences*, 4(1), 26-34.
- Flir, A. (2010). *The ultimate infrared handbook for RveD professionals*. Boston.
- Fokam, D., & Lehmann, C. (2018). Clinical assessment of arthritic knee pain by infrared thermography. *Journal of Basic and Clinical Physiology and Pharmacology*, 1-5.
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (s. 580-587).
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., & Wu, S. (2016). Deep learning for visual understanding. *A review. Neurocomputing*, 187, 27-48.
- Kaplan, H. (2007). Practical Applications of Infrared Thermal Sensing and Imaging Equipment, third edn. *third edn. SPIE Press*.

- Kastberger , G., & Stachl, R. (2003). Infrared imaging technology and biological applications. *Behavior Research Methods, Instruments, & Computers*, 35(3), 429-439.
- Kılınç, T. O. (2017). *Kızılötesi Dedektör Tasarımı İçin Doğadan Esinlenmiş Göz Yapılarının Dalga Analizi* . Ankara: Tobb Ekonomi Ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü. Ankara: TOBB ETÜ Fen Bilimleri Enstitüsü.
- Koay, J., Herry, C., & Frize, M. (2004). Analysis of breast thermography with an artificial neural network. *In The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (s. 1159-1162). IEEE.
- Kosikowski, M., Suszyński, Z., & Bednarek, M. (2011). Processing and recognition of the thermal images using wavelet transforms. *Microelectronics Reliability*, 51(7), 1271-1275.
- Krizhevsky , A., Sutskever, I., & Hinton, G. (2012). Derin evrişimli sinir ağları ile Imagenet sınıflandırması. *Sinirsel bilgi işleme sistemlerindeki gelişmeler* , 25, 1097-1105.
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (s. 3431-3440).
- Meola, C., & Carlomagno, G. M. (2004). Recent advances in the use of infrared thermography. *Measurement science and technology*, 15(9), R27.
- Montgomery, D. (2008). *Design and Analysis of Experiments*. John Wiley & Sons. ISBN: 9780470128664.
- Oquab, M., Bottou, L., Laptev, I., & Sivic, J. (2014). Learning and transferring mid-level image representations using convolutional neural networks. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (s. 1717-1724).
- Ouyang, W., Luo, P., Zeng , X., Qiu, S., Tian, Y., Li, H., & Tang, X. (2014). Deepid-net: multi-stage and deformable deep convolutional neural networks for object detection. *arXiv preprint arXiv:1409.3505*.
- Parashar, A. (2020, Ekim 8). *Vgg 16 Architecture, Implementation and Practical Use*. Vgg 16 Architecture, Implementation and Practical Use Web Sitesi: <https://medium.com/pythoneers/vgg-16-architecture-implementation-and-practical-use-e0fef1d14557> adresinden alındı
- Patel, S. (2017, 3 Mayıs). *Chapter 2 : SVM (Support Vector Machine) — Theory*. Chapter 2 : SVM (Support Vector Machine) — Theory Web Sitesi: <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72> adresinden alındı
- Physiotherm. (2021, Nisan 21). *Kızılötesi Nedir? « Physiotherm Derin Isı Kabinleri* . Kızılötesi Nedir? « Physiotherm Derin Isı Kabinleri Web Sitesi: <http://www.physiotherm.com.tr/kizilotesi.html> adresinden alındı
- Ring, E. (2000). The discovery of infrared radiation in 1800. *The Imaging Science Journal*.48(1), 1-8.
- Ring, E. (2006). The historical development of thermometry and thermal imaging in medicine. *Journal of Medical Engineering ve Technology*, 192-8.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Staelin, C. (2002). Parameter Selection For Support Vector Machines. *Approved for External Publication*.

- Swiderski , W., & Vavilov, V. (2015). Ultrasonic IR thermographic inspection of graphite epoxy composite: a comparative study of piezoelectric and magnetostrictive stimulation. *Opto-Electronics Review*, 23(1), 35-38.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., & Rabinovich, A. (2015). Going deeper with convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (s. 1-9).
- Tan , T. Z., Quek, C., Ng , G. S., & Ng, E. K. (2007). A novel cognitive interpretation of breast cancer thermography with complementary learning fuzzy neural memory structure. *Expert Systems with Applications*, 33(3), 652-666.
- Turan, R. (2019). *Akut/Kronik Fiziksel Travmalı Olguların Dijital Kızılötesi Termal Kamera İle Değerlendirilmesi Ve Elde Edilen Bulguların Travma İle Nedensellik Bağının İncelenmesi*. İstanbul: İstanbul Tıp Fakültesi Adli Tıp Anabilim Dalı Uzmanlık Tezi.
- Vollmer, M., & Möllmann, K. P. (2007). Infrared thermal imaging as a tool in university physics education. *European Journal of Physics*, S37.
- Wan, L., Zeiler, M., Zhang, S., Le Cun, Y., & Fergus, R. (2013). Regularization of neural networks using dropconnect. *In International conference on machine learning*, (s. 1058-1066).
- Yanming Guo, Yu Liu, Ard Oerlemans, Songyang Lao, Song Wu, & Michael S.Lew. (2016). Deep learning for visual understanding: A review. *Neurocomputing* 187, 27–48.
- Yosinski, J., Clune, J., Bengio, Y., Lipson, H., & . (2014). How transferable are features in deep neural networks?. *arXiv preprint arXiv:1411.1792*.
- Zeiler, M. D. (2013). *Hierarchical convolutional deep learning in computer vision* . Doctoral dissertation, New York University.

**EKLER****EK-1** Hastanelerden Görüntülerin Alınması için gerekli olan yazılar.

Evrak Tarih ve Sayısı: 15/12/2020-E.16927



T.C.  
KONYA TEKNİK ÜNİVERSİTESİ REKTÖRLÜĞÜ  
Öğrenci İşleri Daire Başkanlığı

**Sayı** : 46665609-622.03/  
**Konu** : Bilgi ve Belge Talepleri

**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜNE**

**İlgi** : 18.11.2020 tarih ve 21775101-100/E.15476 sayılı yazınız

Enstitünüz Dr.Öğr.Üyesi Murat SELEK'in danışmanlığını yaptığı Elektrik-Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans Programı öğrencisi Afrah Abdulsattar Jasim QALI'nin "Termal Görüntü İşleme ile Osteoartritin Tespit Edilmesi" isimli tez çalışmasında kullanılmak üzere hasta verilerine ihtiyaç duyulduğu ve bu verilerin kullanılması hususunda gerekli iznin verilmesine ilişkin, Gazi Üniversitesinin 14.12.2020 tarih ve 82642947-622.01/30327 sayılı yazısı gönderilmektedir.

Bilgilerini ve gereğini rica ederim.

**e-imzalıdır**  
**Prof. Dr. Hüseyin Selçuk HALKACI**  
**Rektör a.**  
**Rektör Yardımcısı**

Ek : Gazi Üniversitesinin yazısı (3 sayfa)



Evrak Tarih ve Sayısı: 16/12/2020-E.17043



T.C.  
**KONYA TEKNİK ÜNİVERSİTESİ REKTÖRLÜĞÜ**  
**Lisansüstü Eğitim Enstitüsü Müdürlüğü**

**Sayı** : 21775101-100/  
**Konu** : Bilgi ve Belge talepleri Hk.

**Sayın Dr. Öğr. Üyesi Murat SELEK**

Anabilim Dalınız Öğretim Üyelerinden Dr.Öğr.Üyesi Murat SELEK'in danışmanlığını yaptığı yüksek lisans öğrencisi Afrah Abdulsattar Jasim QALİ'nin tez çalışması yapmak istediği izin yazısı hakkındaki, Üniversitemiz Öğrenci İşleri Daire Başkanlığının 15.12.2020 tarih ve E.16927 sayılı yazısı ekte gönderilmektedir.  
Bilgilerinizi ve gereğini rica ederim.

**e-imzalıdır**  
**Prof. Dr. Saadettin Erhan KESEN**  
**Enstitü Müdürü**

Dağıtım:  
Elektrik-Elektronik Mühendisliği Anabilim  
Dalı Başkanlığına  
Sayın Dr. Öğr. Üyesi Murat Selek

**Evrakı Doğrulamak İçin** : <http://161.9.217.14/enVision-Sorgula/belgedogrulama.aspx?V=BEL95TMH4>

Bilgi için: İlknur AKÇİL

