



**T.C.**  
**SELÇUK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**EVRIŞİMSEL SİNİR AĞLARI TABANLI  
GÜRÜLTÜ GİDERİCİ OTOMATİK  
KODLAYICI KULLANARAK GÖRÜNTÜYÜ  
GÜRÜLTÜDEN ARINDIRMA**

**Mohammed Shamil Ibrahim IBRAHİM**

**YÜKSEK LİSANS TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Nisan-2020**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Mohammed Shamil Ibrahim IBRAHİM tarafından hazırlanan “Evrişimsel Sinir Ağları Tabanlı Gürültü Giderici Otomatik Kodlayıcı Kullanarak Görüntüyü Gürültüden Arındırma” adlı tez çalışması 21/04/2020 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Doç.Dr. Humar Kahramanlı ÖRNEK

### İmza

.....  

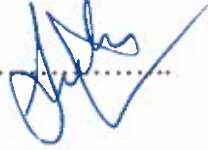

#### Danışman

Dr.Öğr.Üyesi Betül UZBAŞ

.....  


#### Üye

Doç.Dr. Gülay TEZEL

.....  


Yukarıdaki sonucu onaylarım.

.....  
  
Prof. Dr. Mustafa YILMAZ  
FBE 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.



Mohammed Shamil Ibrahim IBRAHIM

21/04/2020

## ÖZET

### YÜKSEK LİSANS TEZİ

## EVRIŞİMSEL SİNİR AĞLARI TABANLI GÜRÜLTÜ GİDERİCİ OTOMATİK KODLAYICI KULLANARAK GÖRÜNTÜYÜ GÜRÜLTÜDEN ARINDIRMA

**Mohammed Shamil Ibrahim IBRAHİM**  
**Selçuk Üniversitesi Fen Bilimleri Enstitüsü**  
**Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman: Dr. Öğr. Üyesi Betül UZBAŞ**

**2020, 41 Sayfa**

**Jüri**

**Dr. Öğr. Üyesi Betül UZBAŞ**  
**Doç. Dr. Humar Kahramanlı ÖRNEK**  
**Doç. Dr. Gülay TEZEL**

Günümüzde, insan vücudu için yüksek çözünürlüklü görüntüler elde etmek amacıyla kullanılan tıbbi görüntüleme, tıbbi ortamlarda önemli bir rol oynamaktadır. Tıbbi görüntüleme teknikleri genellikle Gauss, tuz, biber ve benek gürültüleri (Speckle Noise) gibi birçok gürültü türünden etkilenmektedir. Bu nedenle yüksek çözünürlüklü bir vücut görüntüsü almak çok zor olmaktadır. Birçok hastalığın teşhisi için doğru tıbbi görüntüler gereklidir. Bu tezde, Evrişimsel Sinir Ağları (ESA) tabanlı Gürültü Giderici Oto-kodlayıcı (Denoising Autoencoder, DAE) ile tıbbi görüntülerde gürültü giderme tekniği önerilmiştir. Katman sayısı ve evrişim filtre boyutu gibi farklı konfigürasyonlara sahip mimariler değerlendirilmiştir. ReLU aktivasyon fonksiyonunu 7, 10 ve 12 gibi 3 farklı evrişimli katman sayısı ile kullanılmıştır. Kullanılan filtre boyutları 16,32,64 ve 128'dir. Çalışmada Kaggle NIH göğüs röntgeni veri kümesinden toplam 30000 görüntü, eğitim seti için 20.000, doğrulama seti için 5.000 ve test seti için 5.000 görüntü olacak şekilde ayrılmıştır. Görüntülere Gauss gürültüsü eklenmiş ve gürültü giderme işlemi gerçekleştirilmiştir. Tüm konfigürasyonlar karşılaştırıldığında ReLU aktivasyon fonksiyonu kullanan model, 7 katman ve 64 filtre boyutunda en iyi sonuçlara sahiptir.

Önerilen model, ortalama ve medyan filtreler gibi geleneksel filtreleme yöntemleriyle karşılaştırılmıştır. Önerilen ESA tabanlı DAE kullanılarak görüntüden elde edilen Ortalama Karesel Hata (OKH) ve Tepe Sinyal-gürültü Oranı (Peak Signal-to-Noise Ratio, PSNR) değerlerinin ortalaması sırasıyla 100.895, 28,100'dür. Aynı görüntüler için ortalama filtre kullanılarak 101.234 OKH ve 28.087 PSNR değerleri, medyan filtre kullanılarak 102.063 OKH ve 28.049 PSNR değerleri elde edilmiştir.

**Anahtar Kelimeler:** Evrişimli Sinir Ağları, Derin Öğrenme, Görüntü Filtreleme, Görüntü İşleme, Oto Kodlayıcı,

## ABSTRACT

### MS THESIS

## IMAGE DENOISING USING DEEP CONVOLUTIONAL BASED ON DENOISING AUTOENCODER

**Mohammed Shamil Ibrahim IBRAHIM**  
**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF**  
**SELÇUK UNIVERSITY**  
**THE DEGREE OF MASTER OF SCIENCE**  
**IN COMPUTER ENGINEERING**

**Advisor: Asst. Prof. Dr. Betül UZBAŞ**

**2020, 41 Pages**

**Jury**  
**Assist.Prof.Dr. Betül UZBAŞ**  
**Assoc.Prof.Dr. Humar Kahramanlı ÖRNEK**  
**Assoc.Prof.Dr. Gülay TEZEL**

Nowadays, medical imaging used to obtain high-resolution images for the human body plays an important role in medical settings. The medical imaging techniques usually suffer from many types of noises such as Gaussian, salt and pepper and speckle noises. So, getting a high-resolution body image is so difficult. The accurate medical images are necessary for diagnosis of many diseases. In this thesis, denoising technique in medical images has been proposed with the Convolutional Neural Network based Denoising Autoencoder (DAE). Architectures with different configurations, such as layer number and convolution filter size, were evaluated. The ReLU activation function was used with 3 different convolutional layers such as 7, 10 and 12. The filter sizes used are 16, 32, 64 and 128. In the study, a total of 30000 images from the Kaggle NIH chest X-ray data set were separated as 20,000 for the training set, 5,000 for the validation set and 5,000 for the test set. The Gaussian noise was added to the images and denoising was performed. Compared to all configurations, the Model that uses ReLU activation function with 7 layers and 64 filters size has the better results.

This proposed model is compared to the traditional filtering methods such as mean and median filters. The average of the Mean Square Error and Peak Signal-to-Noise Ratio (PSNR) values obtained from the image using the proposed ESA-based DAE is 100.895, 28.100, respectively. For the same images, 101.234 MSE and 28.087 PSNR values were obtained using the average filter, and 102.063 MSE and 28.049 PSNR values were obtained using the median filter.

**Keywords:** Autoencoder, Convolutional Neural Networks, Deep Learning, Image Filtering, Image Processing.

## ÖNSÖZ

Bu tez çalışmasında bana yardımlarını, bilgilerini ve desteğini esirgemeyen değerli danışmanım sayın Dr. Öğr. Üyesi Betül UZBAŞ'a sonsuz şükranlarımı sunarım.

Öğrenim hayatım boyunca maddi ve manevi olarak sürekli yanımda olan ve yüksek lisans çalışmam süresince desteklerini her daim hissettiğim aileme ve özellikle değerli babama ve abime teşekkürlerimi bir borç bilirim.

Ayrıca tez çalışmasında bana yardımcı olan değerli hocam Dr. Öğr. Üyesi Sait Ali UYMAZ'a teşekkür ediyorum.

Mohammed Shamil Ibrahim IBRAHİM  
KONYA-2020



# 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>ix</b>
<b>GİRİŞ .....</b>	<b>1</b>
1.1. Tezin Amacı ve Önemi .....	1
1.2. Literatüre Katkısı .....	2
1.3. Tezin Organizasyonu .....	2
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>4</b>
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>12</b>
3.1. İleri beslemeli yapay sinir ağı .....	13
3.1.1. Tek Katmanlı algılayıcı .....	13
3.1.2. Çok katmanlı algılayıcı .....	14
3.1.3. Geri beslemeli ağlar .....	15
3.2. Evrimsel Sinir Ağları .....	15
3.2.1. Evrimsel Katmanlar .....	16
3.2.2. Havuzlama Katmanları .....	17
3.2.3. Tam Bağlantılı Katmanlar .....	18
3.2.4. Toplu Normalleştirme (Batch Normalization).....	18
3.2.5. Aktivasyon Fonksiyonları .....	19
3.3. Evrimsel tabanlı Gürültü Giderici Otomatik Kodlayıcı .....	20
3.4. Gauss Gürültüsü.....	22
3.5. Ortalama Filtre .....	22
3.6. Medyan Filtre.....	23
3.7. NIH Göğüs Röntgeni Veri Kümesi.....	24
3.8. Değerlendirme Metrikleri .....	24
3.8.1. Ortalama Karese Hata (OKH) .....	25
3.8.2. Tepe Sinyal-Gürültü Oranı (Peak Signal-to-Noise Ratio, PSNR).....	25
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>26</b>
4.1. Araçlar .....	26
4.2. Veri Ön İşleme.....	27
4.3. Gürültü Giderici Oto-kodlayıcı Mimarisi .....	27
<b>5. SONUÇLAR VE ÖNERİLER .....</b>	<b>34</b>
5.1. Sonuçlar .....	34

5.2. Öneriler .....	34
<b>KAYNAKLAR .....</b>	<b>36</b>
<b>ÖZGEÇMİŞ .....</b>	<b>41</b>





## SİMGELER VE KISALTMALAR

### Kısaltmalar

ADD	: Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform).
AKD	: Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform).
BT	: Bilgisayarlı Tomografi (Computer Tomography).
ÇÜA	: Çekişmeli Üretici Ağ (generative adversarial network).
DAE	: Gürültü Giderici Oto-kodlayıcı (Denoising Autoencoder).
ESA	: Evrimsel sinir ağları (Convolutional Neural Network).
GAN	: Üretken Rakip Ağ (Generative Adversarial Network).
GGF	: Görüntü Geliştirme Faktörü (Image Enhancement Factor).
GPU	: Grafik İşleme Ünitesi (Graphics Processing Unit).
LDCT	: Düşük Doz Bilgisayarlı Tomografi (low-dose computer tomography ).
MBIR	: Model Tabanlı İteratif Rekonstrüksiyon (Model Based Iterative Reconstruction).
MDBUTMF	: Modifiye Karar Tabanlı Simetrik Kesilmiş Medyan Filtre (Modified Decision Based Unsymmetric Trimmed Median Filter).
MRG	: Modifiye Bölge Yetiştiriciliği (Modified Region Growing).
MRI	: Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging).
NIH	: Ulusal Sağlık Enstitüleri (National Institutes of Health).
NLM	: Yerel Olmayan Araçlar (Non-Local Means).
OKH	: Ortalama Karese Hata (Mean Square Error).
PDE	: Kısmi Diferansiyel Denklemler (Partial Differential Equations).
PSNR	: Tepe Sinyal-gürültü Oranı (Peak Signal-to-Noise Ratio).
Relu	: Doğrultulmuş Doğrusal Birim (Rectified linear Unit).
RGB	: Kırmızı, Yeşil Ve Mavi (Red, Green, and Blue).
SDCT	: Standart Doz Bilgisayarlı Tomografi (standard-dose computer tomography).
SDD	: Sabit Dalgacık Dönüşümü (Stationary wavelet transform).
SGD	: Stokastik Gradyan İniş (Stochastic Gradient Descent) .
SNR	: Sinyal Gürültü Oranı (Signal-To-Noise Ratio).
SSIM	: Görüntü Kalitesini Ölçmek için Yapısal Benzerlik Endeksi (Structural similarity index for measuring image quality).
TADD	: Ters Ayrık Dalgacık Dönüşümü (Inverse Discrete Wavelet Transform).
TBA	: Temel bileşenler Analizi (Principal Component Analysis).
UFÖ	: Uzumsal Frekans Ölçümü (Spatial Frequency Measurement).
YPG	: Yerel piksel gruplaması (Local Pixel Grouping).
YSA	: Yapay Sinir Ağları (Artificial neural networks).

## GİRİŞ

Tıbbi görüntüleme, klinik analiz ve tıbbi müdahale için insan vücudunun cilt, kemikler, kan akışı vb. yapısal ve fonksiyonel yönlerinin görsel temsillerini elde etme işlemidir. Yıllar boyunca, optik görüntüleme, röntgen, Bilgisayarlı Tomografi (BT) veya bilgisayar destekli tomografi, Manyetik Rezonans Görüntüleme (MRG), ultrason, vb. çeşitli tıbbi görüntüleme yöntemleri geliştirilmiştir (Meyer ve Schmid, 2014).

Göğüs röntgeni, meme kanseri teşhisinde ve kan damarlarını ve organlarını incelemede yardımcı olmaktadır. Vücut organlarımız ve cildimiz radyasyona karşı hassastır. Röntgen görüntüsü üretilirken, düşük radyasyon kullanmak için özel dikkat gösterilmektedir. İyon radyasyona daha sık maruz kalan hastalar, kanser hastalığı riskine daha fazla maruz kalmaktadır (Saadia, 2017).

Röntgen birçok durumda kullanılması ideal bir görüntüleme aracıdır. Göğüs röntgeni, özellikle kalp görüntülemede daha fazla popülerlik kazanmaktadır. Akciğerleri ve göğsü incelemek için kullanılan özel bir X-ışını biçimi vardır. Göğüs röntgeni görüntüleri, akciğer büyüklüğü şekli hakkında bilgi sağlar. Göğüs röntgeni videosu, kasılma ve akciğer gevşemesinin farklı aşamalarını gösterir. Uygulamalardaki artışla birlikte, daha iyi görüntü işleme teknikleri için göğüs röntgeni tarama cihazlarının gerekliliği de artar (Tulum ve Kahraman, 2017).

### 1.1. Tezin Amacı ve Önemi

Görüntü elde etme ve aktarma sırasında röntgenlerin görüntüleri gürültüden etkilenir. Gürültü, görüntüdeki istenmeyen bilgilerdir. Görüntünün orijinal bilgisini değiştirir, görsel kalitesini bozar ve görüntü yoğunluğunda değişiklik meydana getirir. Röntgendeki ana gürültü kaynağı, alıcılar tarafından yeterince foton alınmamasından kaynaklanmaktadır. Buda gürültüye neden olur. Farklı gürültü türlerinin, diğerlerinden ayırt edici özellikleri vardır. Görüntünün önemli özelliklerini etkilemeden bu gürültüyü gidermek için görüntü üzerinde gürültü giderici teknikler uygulanır. Göğüs röntgen görüntülerinin kalitesini etkileyen en temel gürültü Gauss gürültüsüdür. Gürültü giderici, göğüs röntgeninden görüntü işleme için kritik bir ön işleme adımı haline gelir. Bu tezin amacı, akciğer hastalıkları görüntülerinin doğru teşhisine yardımcı olan, yani doktorların hastanın sağlığını değerlendirmelerine yardımcı olacak bilgileri sağlamak için, gürültü gidermek ve iyileştirme teknikleri geliştirmektir. Bu, maksimum gürültü miktarını

bastırarak ve önemli detayları ve yapıyı koruyarak yapılabilir. Filtrelenmiş görüntü, farklı yapılar hakkında daha doğru bilgi sağlar ve segmentasyon, kayıt, birleştirme vb. diğer görüntü işleme görevlerini yerine getirmeye yardımcı olur.

## **1.2.Literatüre Katkısı**

Gauss gürültüsünün varlığında filtreleme işlemi, göğüs röntgeni görüntüleri için ön işlem adımı haline gelir. Filtreleme işlemi görüntünün kalitesini ve teşhis değerini artırır. Bu, tıbbi görüntü işlemenin ön işleme aşaması olarak uygulanacak olan etkili Gauss filtrelemesine vurgu yapmaktadır. Bu tez çalışmasında, Gauss gürültüsü azaltmak için kullanılan klasik teknikler hakkında genel bilgi verilmektedir ve bir röntgen görüntüsünden gelen gürültüyü bastırmada etkili olan ESA tabanlı gürültü bastırma yöntemi sunulmaktadır. Bu tezin amacı, göğüs röntgen görüntülerindeki gürültü miktarını en aza indirerek veya kaldırarak kontrastı ve görüntünün kalitesini arttırmaktır. Bu sorunun çözümü için kullanılan klasik yöntemlerle (ortalama ve medyan filtre) önerilen yöntemin karşılaştırması yapılmıştır.

## **1.3.Tezin Organizasyonu**

Bu tez beş bölüme ayrılmıştır. Her bölümün kısa bir incelemesi aşağıda verilmiştir.

Birinci bölüm, problemin tanımı, tez amacı ve organizasyonu hakkında bilgiler vermektedir. Bu araştırmanın arkasındaki motivasyon ve çalışmanın amacı açıklanmıştır.

İkinci bölümde, önceki çalışmaların literatür taraması ve tıbbi görüntülerin geliştirilmesinde makine öğrenme yöntemlerinin kullanılması sunulmaktadır.

Üçüncü bölümde, bu tezde kullanılan algoritmalar ve bunların arkasındaki teoriler anlatılmaktadır. Makine öğrenme yöntemlerinden başlayarak ESA'dan bahsedilmektedir.

Dördüncü bölümde, ESA tabanlı DAE'ye dayalı algoritma, bu algoritmanın uygulanma mimarisi, eğitim ve test sonuçları verilmiştir. Ayrıca gürültü gidermek için kullanılan klasik yöntemlerle (ortalama ve medyan filtre) önerilen yöntemin karşılaştırması yapılmıştır

Son bölümde, bu tezin sonucu tartışılmıştır. Ayrıca gelecekteki çalışmalara ve önerilere yer verilmiştir.



## 2. KAYNAK ARAŞTIRMASI

Dabhi ve Bari (2015) meteoroloji, oşinografi, balıkçılık, tarım, biyolojik çeşitliliğin korunması, ormancılık, peyzaj, jeoloji, haritacılık, bölgesel planlama, eğitim, istihbarat ve savaş gibi birçok uygulamada uydu görüntüleri üzerinde çalışmıştır. Görüntüler görünür renklerde ve diğer spektrumlarda olabilmektedir. Genellikle radar görüntüleri ile yapılan yükseklik haritaları da vardır. Bu tür görüntülerde düşük çözünürlük ana dezavantajdır. Uydu görüntülerinin çözünürlüğü, kullanılan cihaza ve uydunun yörüngesinin yüksekliğine bağlı olarak değişir. Bilgiden yararlanmak ve görüntüyü analiz etmek için görüntünün çözünürlüğü artırılmalıdır. Çözünürlük geliştirme için çeşitli görüntü işleme teknikleri mevcuttur. Çözünürlük geliştirme için en son kullanılan yöntemlerden biri dalgacık tekniklerinin uygulanmasıdır. Bu çalışmada, iki ana dalgacık tekniğinin karşılaştırılması yani Ayrık Dalgacık Dönüşümü (ADD) ve Sabit Dalgacık Dönüşümü (SDD), görüntü kalitesi ölçümlerine dayanılarak incelenmiştir ve dalgacık füzyon algoritmasına dayanan yeni bir görüntü kalitesi geliştirme tekniği üzerinde çalışılmıştır. Önerilen teknikteki görüntü geliştirme ve görüntü kalitesi ölçümlerinin hesaplama sonuçları mevcut tekniklerle karşılaştırılmıştır. Önerilen tekniğin mevcut tekniklerden daha yüksek çözünürlük geliştirme kabiliyetine sahip olduğu kanıtlanmıştır (Dabhi ve Bari, 2015).

Prandnya ve Ruikar (2013) çalışmasında tanımlanmış görüntü füzyonu, iki veya daha fazla benzemeyen görüntünün, geniş bilgi içeriğine sahip görüntülerin her bir bölümünden ana özelliklerini koruyarak yeni bir tek görüntüde birleştirilmesi işlemidir. Görüntü füzyonunun iki yaklaşımı, Mekansal Füzyon ve Dönüşüm füzyonudur. Burada, hem birinci seviye hem de seviye 2'de kenar görüntü bilgisini elde etmek için ilk olarak orijinal görüntüye uygulanan SDD'ye dayalı bir görüntü füzyon yaklaşımı önerilmiştir. Daha sonra, her iki kenar görüntüsü, birkaç basit füzyon yöntemi ile karşılaştırılan Uzamsal Frekans Ölçümü (UFÖ) kullanarak tam bir kenar görüntüsü elde etmek için birleştirilmiştir (Pradnya ve Ruikar, 2013).

Kumar ve Nagaraj (2013) ADD ve giriş görüntüsü ile elde edilen yüksek frekanslı alt bant görüntülerin enterpolasyonuna dayanan bir görüntü çözünürlüğü geliştirme tekniği önermiştir. Kenarlar, SDD kullanılarak bir ara aşama tanıtılarak artırılmıştır. Bir giriş görüntüsünün farklı alt bantlara ayrıştırılması için ADD uygulanmıştır. Ardından giriş frekansı gibi yüksek frekanslı alt bantlar enterpolasyonu yapılmıştır. Tahmini yüksek frekans alt bantlar, SDD'den elde edilen yüksek frekans alt bant kullanılarak

değiştirilmektedir. Sonra tüm bu alt bantlar Ters ADD (TADD) kullanılarak yeni bir yüksek çözünürlüklü görüntü üretmek için birleştirilir. Kantitatif ve görsel sonuçlar, önerilen tekniğin evrimsel ve son teknoloji görüntü çözünürlüğü geliştirme tekniklerine göre üstünlüğünü göstermektedir (Kumar ve Nagaraj, 2013).

Kannan ve ark. (2010) çalışmalarında dijital görüntü işlemenin hızlı bir şekilde gelişmesini sunmuşlardır. Her bir fotoğraftaki belirgin özellikleri koruyarak iki farklı görüntüyü yeni bir tek görüntüde birleştirme işlemi, görüntü füzyonu olarak bilinir. Görüntü füzyonunda iki yaklaşım, mekansal füzyon ve dönüşüm füzyonu vardır. ADD görüntü füzyonunda hayati bir rol oynar, çünkü çeşitli dönüşümler arasındaki yapısal bozulmaları en aza indirir. Değişkenlik eksikliği, zayıf yön seçiciliği ve faz bilgisinin olmaması ADD'nin dezavantajlarıdır. Bu dezavantajlar, SDD ve Çift Ağaç Kompleksi Dalgacık Dönüşümü ile giderilir. Bu yazıda, OKH, PSNR ve Kalite İndeksi açısından çok odaklı görüntülerin daha iyi piksel tabanlı füzyonu için gerekli olan ADD, SDD ve İkili Ağaç Kompleksi dalgacık dönüşümünün optimal ayrışma seviyesi açıklanmaktadır (Kannan ve ark., 2010).

Zhang ve ark. (2010) çalışmalarında, yerel piksel gruplaması (YPG) ile Temel Bileşen Analizi (TBA) kullanarak etkili bir görüntüden gürültü giderme şeması sunmuşlardır. Görüntü yerel yapılarının daha iyi korunması için, bir piksel ve en yakın komşuları bir vektör değişkeni olarak modellenmiştir, eğitim örnekleri yerel pencereden blok eşleştirme tabanlı YPG kullanılarak seçilmiştir. Böyle bir YPG prosedürü, TBA dönüşümü tahmini için yerel istatistik hesaplamasında yalnızca benzer içeriklere sahip örnek blokların kullanılmasını garanti eder, böylelikle görüntü yerel özellikleri TBA etki alanındaki katsayıyı büzdükten sonra gürültüyü gidermek için iyi korunabilir. YPG ve TBA gürültü giderme prosedürü, gürültü giderme performansını daha da iyileştirmek için bir kez daha yinelenir ve gürültü seviyesi ikinci aşamada uyarlanabilir şekilde ayarlanır. Benchmark test görüntülerindeki deneysel sonuçlar, YPG-TBA yönteminin çok rekabetçi bir gürültü giderme performansı elde ettiğini göstermektedir (Zhang ve ark., 2010).

K. Prasad ve ark. (2012)'de çalışmaları ile görüntüdeki gürültüyü arındırmışlardır. Bozuk görüntü, gürültülü görüntü olarak adlandırılır ve düzeltilen görüntü dezene görüntü olarak adlandırılır. Bildiğimiz gibi, Gauss gürültüsü, benek gürültüsü, rastgele gürültü, tuz ve biber gürültüsü gibi görüntü işlemlerinde farklı gürültü türleri vardır. Bunların arasında tuz ve biber gürültüsü diğer gürültülere kıyasla çok tehlikelidir. Farklı algoritmalar kullanarak görüntüdeki gürültü azaltılabilmektedir. Görüntü işlemedeki renkli görüntüler uygulama olarak çok yaygındır. Böylece, gri skalanın restorasyonu için

simetrik olmayan kesilmiş bir medyan filtre algoritmasına dayalı değiştirilmiş bir karar ve tuz ve karabiber gürültüsüyle yüksek oranda bozulan renkli görüntüler ortaya çıkmıştır. Diğer piksel değerleri, seçilen pencerede bulunan 0 ve 255'ler olduğunda ve tüm piksel değerleri 0 ve 255 olduğunda, gürültü pikselinin mevcut tüm öğelerin ortalama değeri ile değiştirilmesi durumunda, gürültülü pikseli kesilmiş ortanca değerle değiştiren algoritma çalıştırılır. Seçilen pencerede bu algoritma, farklı gri tonlamalı ve renkli görüntülere karşı test edildiğinde önceki algoritmadan daha iyi sonuçlar verir ve daha iyi PSNR ve Görüntü Geliştirme Faktörü (GGF) sağlar. Bu nedenle, MDBUTMF (Modified Decision Based Unsymmetric Trimmed Median Filter,) algoritması, yüksek gürültü yoğunluklu görüntülerde tuz ve biber gürültüsünü gidermede etkilidir (K.Prasad, 2012).

Preethi ve Narmadha (2012) tıbbi görüntülerin gürültülerini gidermek için doğrusal olmayan bir model önermiştir. Doğrusal olmayan model geliştirirken, çeşitli görüntü dengeleme süreçleri için kapsamlı literatür taraması yapmışlar ve PSNR görüntü kalitesini ölçmek için yapısal benzerlik endeksi (Structural similarity index for measuring image quality, SSIM) ve Sinyal Gürültü Oranı (Signal-To-Noise Ratio, SNR) gibi benzerlik ölçümlerine dayanarak TBA tabanlı görüntü ölçümleri ve benzerlik ölçümlerinden daha iyi sonuçlar elde etmişlerdir. (Preethi ve Narmadha, 2012).

Desale ve Verma'nın (2013) makalelerinde, Formülasyon, Proses Akış Diyagramları ve TBA, AKD (Ayrık Kosinüs Dönüşümü) ve ADD bazlı görüntü füzyon tekniklerinin algoritmaları tartışılmaktadır. Çalışmada, TBA tabanlı görüntü dengeleme tekniklerinin AKD ve ADD kullanılarak karşılaştırmalı olarak incelenmesi gerçekleştirilmiştir. Karşılaştırma sonucu, TBA-ADD tabanlı yöntem AKD tabanlı yöntem üzerinde üstünlük sağlamıştır (Desale ve Verma, 2013).

Tej ve Shah (2015), çalışmalarında görüntü filtrelemesi için ortalama filtreleme, medyan filtreleme, wiener filtreleme, dalgacık dengelemesi ve çözünürlük geliştirme için enterpolasyon esaslı kesikli ve sabit dalgacık dönüşümü teknikleri üzerinde yoğunlaşarak, etkili dengeleme ve çözünürlük sağlayan PSNR gibi bazı performans parametrelerinin temelinde hesaplanmaktadır (Tej ve Shah, 2015).

Füzyonun sonucu insan ve makine algısı için daha uygun yeni bir görüntüdür. Purushotham ve ark. (2015) çalışmalarında dalgacıklar ve TBA kullanılarak piksel seviyesinde görüntü füzyonu, referans görüntüsü olan ve olmayan farklı performans ölçümleri üzerinde durmuş ve çalışmışlardır. Tüm parametrelerdeki ADD, TBA füzyon algoritmasından daha iyi sonuç vermektedir, bu nedenle son olarak ADD'nin TBA'dan daha iyi performans gösterdiği sonucuna varılmaktadır (Purushotham ve ark., 2015).

McVeigh ve ark. (1985) MR görüntülerinde Gauss gürültüsünü azaltmak için uzamsal filtre ve geçici filtreyi önermişlerdir. Uzamsal filtre, bir görüntüyü uzamsal alanda bir filtreyle evrimleştirerek yerleştirme yöntemidir. Bu teknik, görüntüdeki farkı azaltır, ancak evrişimde kullanılan işlevin şekliyle ilgili bir miktarda keskin kenarları bulanıklaştırır. Bu işlem, görüntüdeki yüksek uzaysal frekansları azaltmak için eşdeğerdir. MR görüntüleme, evrişim filtrelemeye özellikle uygundur, çünkü frekans alanında elde edilen veriler, daha yüksek uzamsal frekansları azaltan bir filtre fonksiyonu ile çarpılabilir. Bu filtre türü son görüntüyü pürüzsüzleştirir, ancak frekansın bir fonksiyonu olarak sinyal-gürültü oranı etkilenmez, çünkü hem gürültü hem de sinyal aynı faktör tarafından azaltılır. Bu tür görüntü yumuşatma ile gürültü ve yapay doku azalması ile uzamsal çözünürlük kaybı arasında bir uzlaşma vardır. Örtüşme kusurlarını önlemek için geçici filtre örnekleme aralığına uygun olarak seçilmelidir. En iyi ihtimalle bu filtre yalnızca döndürme eko görüntülerinde çalışır. Çok dar bir frekans yanıtına sahip geçici bir filtre, görüntünün kenarlarındaki sinyali azaltır, çok geniş bir frekans yanıtı ortaya çıkar ve ek gürültü ile örtüşür (McVeigh ve ark., 1985).

Perona ve Malik (1990) anizotropik difüzyon filtresi adı verilen çok ölçekli bir yumuşatma ve kenar algılama şeması geliştirmişlerdir. Bu uzaysal filtrelemenin dezavantajının üstesinden gelmektedir ve nesne sınırlarını koruyarak, homojen olmayan bölgelerde gürültüyü etkin bir şekilde ortadan kaldırarak ve keskinleştirmeyi netleştirerek görüntü kalitesini önemli ölçüde iyileştirmektedir. Bu filtre, problemi anizotropik bir ortamda ikinci mertebeden kısmi diferansiyel denklemi temel alan bir ısı denklemi açısından ortaya koymaktadır. Düzleştirme, farklı derecelerde yerel gradyan kuvvetlerini seçerek sınırlarda bastırılmış veya durdurulmuş difüzyon bir işlem olarak formüle edilir. Bu yaklaşımda, görüntü, yalnızca kenarların korunmasını sağlayan görüntünün gradyanına dik olan yöne çevrilir (Perona ve Malik, 1990).

Krissian ve Aja-Fernández (2009) Rician gürültüsünü MRG'den uzaklaştırmak için gürültüye dayalı anizotropik difüzyon filtresi önermişlerdir. Bu filtre, gürültünün standart sapmasının sağlam bir tahminine dayanır ve MRI için yerel doğrusal minimum OKH değerleri ve kısmi diferansiyel denklemleri birleştirir. Filtrenin parametreleri, tahmini gürültüden otomatik olarak seçilir. Filtrenin kısmi türev denklemi, görüntünün yerel yapısına ve karşılık gelen yönlendirilmiş yerel standart sapmalara dayanan tutarlı bir difüzyona izin veren yeni bir matris difüzyon filtresine genişletilir. Bu filtre, konturları korurken difüzyonun yakınsama hızını artırabilen, daha sağlam ve sezgisel filtrelemeye



yol açan, yerel görüntü yapısının hacimsel, düzlemsel ve doğrusal bileşenlerini birleştirir (Krissian ve Aja-Fernández, 2009).

Zhang ve Ma, (2010) MRI gürültü giderici için anizotropik çift difüzyon denklemlerini tanıtmıştır. Birleştirilmiş kısmi difüzyon denklemlerinde, bir denklem difüzyon yönünü kontrol eden anizotropik bir difüzyon terimini, filtrelenmiş görüntünün başlangıç görüntüsünden uzak olmamasını sağlayan bir doğruluk terimini ve her pikselin difüzyon hızını kontrol eden bir difüzyon genini içermektedir ve başka bir difüzyon denklemi ile bağlanmaktadır. Bu, iyi bir gürültü azaltma ve ayrıntı koruma özelliği sağlamıştır (Zhang ve Ma, 2010).

Rajan ve ark. (2009) çalışmalarında anizotropik difüzyonun işlenmiş görüntüsündeki bloklu etkilerden kaçınmak için dördüncü dereceli kısmi diferansiyel denklemleri'nin bir teknik olarak kullanılmasını önerilmiştir. Bu, Laplacian imajının işlevselliğini en aza indirerek elde edilir. Bu tekniği uzay ve zamanda MR görüntülerinin gürültülerini gidermek için kullanmışlardır (Rajan ve ark., 2009).

Lu ve ark. (2009)'da MRG'den gürültü gidermek için yaklaşımı genişletmişlerdir. Bu yöntem, yoğunluk değerinde yumuşak bir değişiklikte sinyalleri işleme ve kenarları koruma özelliğine sahiptir. MR görüntülerinin gürültü gidericisi, dördüncü dereceden karmaşık difüzyon bazlı standart difüzyon denklemi ile serbest Schrodinger denklemi birleştirilerek elde edilmiştir (Lu ve ark., 2009).

Buades ve ark. (2005), Yerel Olmayan Araçlar (Non-Local Means, NLM) filtresini önermişlerdir. Mevcut gürültü giderme yöntemlerinin çoğu, gürültüyü gidermek için çoğunlukla küçük bir komşunun içindeki yerel piksellere dayanmaktadır. Sonuç olarak, büyük ölçekli yapılar korunurken, küçük yapılar gürültü olarak kabul edilir ve kaldırılır. NLM filtresi, gürültüyü gidermek için görüntülerdeki bilgilerin fazlalığından yararlanır. Vokselin geri yüklenen yoğunluk değeri, görüntüdeki tüm voksel yoğunluklarının ağırlıklı ortalaması olarak hesaplanır (Buades ve ark., 2005).

Manjon ve ark. (2007) paralel görüntüleme ve yüzey bobini edinimleri ile elde edilenler gibi, mekansal olarak değişen gürültü seviyelerinde MR görüntülerini gürültü gidermek için uyarlamalı NLM filtresini önermişlerdir. Yerel görüntü parazit seviyesine ilişkin bilgi, filtrenin gürültü giderici mukavemetinin miktarını ayarlamak için kullanılır. Bu tür bilgiler, yerel gürültü tahmin yöntemi kullanılarak görüntülerden otomatik olarak elde edilir. Bu yöntem, MRG tarayıcısındaki bobin hassasiyeti profilleri hakkında önceden bilgi sahibi olmayı gerektirmez (Manjon ve ark., 2007).

Tomasi ve Manduchi (1998) çift taraflı filtreyi, anizotropik difüzyon filtresine yinelemeli olmayan bir alternatif olarak önermişlerdir. Her iki yaklaşımda da, kenarlar korunurken görüntüler yumuşatılır. Anizotropik difüzyonun aksine, çift taraflı filtreleme Kısmi Diferansiyel Denklemlerinin (Partial Differential Equations, PDE) çözümünü içermez ve tek bir yinelemede uygulanabilir. Bu filtre iki Gaussian filtresinin, yani alan ve aralık filtrelerinin bir birleşimidir. Alan filtresinin ağırlıkları, çevresindeki pikselin uzamsal mesafesine (geometrik) orantılıdır. Mesafe filtresi katsayıları, bir pikselin çevresindeki fotometrik (yoğunluk) mesafe ile orantılıdır. Filtrelenen görüntü, her bir pikselin yoğunluk değerinin, uzaysal bir pencerede bulunan pikseller arasındaki geometrik ve fotometrik benzerliklerle ağırlıklandırılmış ortalama bir değerle değiştirilmesiyle elde edilir (Tomasi ve Manduchi, 1998). Walker ve ark. (2006) ve Xie ve ark (2008) bu filtreyi MRI için uyguladılar ve Hamarneh ve Hradsky, (2007) bu filtreyi Difüzyon Tensör MRG'da gürültüyü azaltmak için kullanılmışlardır.

Placidi ve ark. (2003) farklı ölçeklerde dalgacık katsayıları arasındaki dalgalanma katsayıları arasındaki korelasyon faktörünün hesaplanmasına dayanan dalgalanma yöntemini ve MRG'yi dengelemek için Sobel operatörü ile kombine etmişler ve bir araya getirmişlerdir. Bu, kullanışlı özelliklerin daha fazla uzamsal çözünürlüğünü korurken gürültü gücünü azaltır (Placidi ve ark., 2003).

Yu ve Zhao, (2008)'de MR görüntülerinde Rician gürültüsünü azaltmak için dalgacık büzülmesine dayanan yinelemeli bir şema önermişlerdir. Dalgacık alanındaki yerel wiener büzülme fonksiyonu kullanılarak, sinyal dalgacık katsayıları gürültülü gözlemden tahmin edilmektedir (Yu ve Zhao, 2008).

Chen ve ark. (2017), ESA'ya dayanan Düşük Doz Bilgisayarlı Tomografi (Low-Dose Computer Tomography, LDCT) gürültü giderici tekniği önermiştir. LDCT taramaları, normal yoğunluklu BT taramalarına kıyasla daha az radyasyon yaydığından dolayı önemlidir. Önerdikleri algoritma ESA kullanarak orijinal projeksiyon verilerine erişmeden giriş görüntüsünü filtrelemektedir. Bu çalışmada geliştirilen model, LDCT görüntüleri parça parça normal yoğunluklu BT görüntülerine dönüştürmek için eğitilmiştir (Chen ve ark., 2017).

Kang ve ark. (2017)'de tıbbi görüntüleme cihazlarından kansere neden olma potansiyel riskini azaltmak için düşük yoğunluklu X-röntgeni BT görüntüleri rekonstrüksiyonu için bir algoritma önermişlerdir. Bunlar LDCT görüntülerinin dalgacık dönüşüm katsayılarına uygulanan ESA kullanan algoritmalarıdır. Daha spesifik olarak, eserlerin yönelimli bileşenini çıkarmak ve bant içi ve gruplar arası korelasyonlardan

yararlanmak için yönlü bir dalgacık dönüşümü kullanarak, derin ağları BT'ye özgü gürültüyü etkili bir şekilde bastırabilir. Buna ek olarak, ESA'ları daha hızlı ağ eğitimi ve daha iyi performans için artık bir öğrenme mimarisi ile tasarlanmıştır (Kang ve ark., 2017).

You ve ark. (2018) LDCT görüntü kalitesini artırmak için yapısal olarak duyarlı çok ölçekli üretken çekişsel ağ adı verilen yeni bir 3 boyutlu gürültü azaltma yöntemi önermiştir. Özellikle, görüntü kalitesini artırmak için 3 boyutlu hacimsel bilgiler içerirler. Ayrıca, gürültü giderici modellerinin eğitimi için farklı kayıp fonksiyonları araştırılmaktadır. Deneyler, önerilen yöntemin, normal yoğunluklu BT görüntülerine referansla yapısal ve dokusal bilgileri etkili bir şekilde koruyabildiğini ve gürültüyü ve artefaktları önemli ölçüde baskıladığını göstermektedir. Üç deneyimli radyolog tarafından yapılan nitel görsel değerlendirmeler, önerilen yöntemin daha fazla bilgi aldığını ve rakip yöntemlerden daha iyi performans gösterdiğini göstermektedir (You ve ark., 2018).

Kang ve ark. (2017)'de düşük yoğunluklu X-röntgeni BT için derin bir ESA önermiştir. Düşük yoğunluklu X- röntgeni BT için Model Tabanlı İteratif Rekonstrüksiyon (Model Based İterative Reconstruction, MBIR) algoritmaları, ileri ve geri projeksiyonun tekrar tekrar kullanılması nedeniyle hesaplama açısından karmaşıktır. Bilgisayarlı görme uygulamalarındaki bu derin öğrenmenin başarısından esinlenerek, kısa bir süre önce düşük yoğunluklu X- röntgeni BT için derin bir ESA önerilmiştir ve 2016'da (American Association Of Physicists Medicine Challenge, AAPM) LDCT Büyük Mücadelesinde ikinci sırada yer almıştır. Bununla birlikte, radyologlara yabancı olan dokulardan bazıları iyi sonuçlar elde etmemiştir. Bu sorunla başa çıkmak, sorunu çözmek ve önceki çalışmalara göre performansı artırmak için yönlü dalgacık alanında doğrudan bir kalıcı öğrenme yaklaşımı önerilmektedir. Özellikle, yeni ağ, her bir giriş dalgacık dönüşümünün gürültüsünü tahmin eder ve daha sonra gürültü giderilmiş dalgacık katsayıları, gürültüyü giriş dalgacık dönüşüm bantlarından çıkararak elde edilir. Deneysel sonuçlar, önerilen ağın, orijinal görüntülerin ayrıntı dokusunu koruyarak performansı önemli ölçüde geliştirdiğini doğrulamaktadır (Kang ve Ye, 2017).

Park ve ark. (2019), eşleştirilmiş eğitim verilerinin yokluğunda gürültülü LDCT görüntüleri için derin öğrenme tabanlı bir gürültü giderici yöntemi önermektedir. Önerilen yöntem, LDCT ve Standart Yoğunluklu BT (Standard-Dose Computer Tomography, SDCT) görüntülerin eşleştirilmemiş eğitim verilerinden gürültü giderme işlevini öğrenmek için aslına uygun gömülü bir Üretken Rakip Ağ (Generative

Adversarial Network, GAN) kullanır. Burada, gürültü giderme işlevi GAN çerçevesinde en uygun jeneratördür. Bu çalışmada f-GAN hedefini, iki kayıp ağırlıklı bir toplamı en aza indirerek optimize edilmiş uygun bir jeneratör türetmek için analiz eder: SDCT veri dağıtımı ile oluşturulan dağıtım arasındaki Kullback-Leibler sapması ve LDCT görüntüsü ile oluşturulan karşılık arasındaki  $\ell_2$  kaybı görüntülerdir (veya gürültüden giderilmiş görüntü). Hesaplanan jeneratör, eğitim yoluyla SDCT veri dağıtımı hakkındaki önceki görüşü yansıtmaktadır. Önerilen yöntemin gürültüyü ortadan kaldırırken ince anormal özelliklerin korunmasına izin verdiğini gözlemlenmiştir. Deneysel sonuçlar, eşleştirilmemiş veri kümelerine sahip önerilen derin öğrenme yönteminin, eşleştirilmiş veri kümeleri kullanan bir yöntemle karşılaştırıldığında daha iyi performans göstermektedir. Düşük yoğunluklu X- röntgeni BT'sinde ortaya çıkan gürültü için önerilen yöntemin geçerliliğini göstermek için bir klinik deney de yapılmıştır (Park ve ark., 2019).

### 3. MATERYAL VE YÖNTEM

Derin öğrenme, örüntü tanıma ve makine öğrenmesinde çığır açmıştır. Bu, eylemler ve sonuçlar arasında potansiyel olarak nedensel bağlantılar içeren uzun zincirlere sahip uyarlanabilir sistemlerde itibar tahsisi ile ilgilidir.

Standart bir sinir ağı, her biri gerçek değerli aktivasyonlar dizisi üreten ve birimler adı verilen birçok basit, bağlı işlemciden oluşur. Girdi üniteleri, çevreyi algılayan sensörler aracılığıyla, diğer üniteler ise daha önce aktif olan ünitelerin gerçek değerli ağırlıkları olan bağlantılarla aktifleştirilir. Bazı birimler eylemleri tetikleyerek çevreyi etkileyebilir.

Sıralı işlemlerli tekrarlayan sinir ağları en üst düzey sinir ağlarıdır, çünkü bunlar genel bilgisayarlardır (tekrarlayan sinir ağı bir mikroçipin devrelerini taklit edebilir). Tamamen bağlı tekrarlayan sinir ağlarında, bütün birimlerin girdisiz tüm birimlere bağlantıları vardır. İleri beslemeli sinir ağlarının aksine, tekrarlayan sinir ağlarında döngüler, özyineleme vb. sırasında uygulanabilir. Tekrarlayan sinir ağının programı onun ağırlık matrisidir. Tekrarlayan sinir ağları, sıralı ve paralel bilgi işlemeyi doğal ve verimli bir şekilde harmlayan programları öğrenebilir.

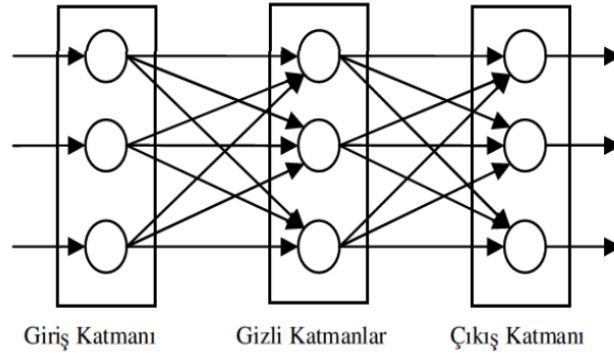
Verilen bir sinir ağı uygulamasındaki güven atamasının derin veya sığ tipte olup olmadığını ölçmek için, karşılık gelen güven atama yollarının uzunluğunu dikkate alırız. Sonraki birim aktivasyonları arasında olası nedensel bağlantıların zincirleri olan bu yollar, örneğin geri besleme bağlantıları olmayan ileri beslemeli sinir ağlarında girdi birimlerinden gizli birimler üzerinden çıkış birimlerine doğru olan yollar veya tekrarlayan sinir ağlarında zaman içindeki dönüşümler vasıtasıyla olan yollardır. Sabit topolojiye sahip ileri beslemeli sinir ağları, ünite katmanlarının sayısı ile sınırlı, problemde bağımsız maksimum problem derinliğine sahiptir. Tüm sinir ağlarının en derinleri olan tekrarlayan sinir ağları, potansiyel olarak sınırsız derinlikteki problemleri çözmeyi öğrenebilirler. Örneğin, gelişigüzel zaman aralıkları için belirli önemli önceki gözlemlerin aktivasyon tabanlı "kısa süreli bellek" temsillerinde saklamayı öğrenerek problemleri çözebilirler (Schmidhuber, 2015b)

Bir problemin zorluğu, problemin derinliği ile çok az ilgili olabilir ya da ilgili olmayabilir. Bazı sinir ağları rastgele ağırlık tahminiyle bazı derin ama basit problemleri hızlı bir şekilde çözmeyi öğrenebilirler (Hochreiter ve Schmidhuber, 1997). Bununla birlikte genel olarak, belirli bir eğitim setini (giriş modeller ve karşılık gelen etiketleri)

hassas bir şekilde modelleyen bir sinir ağı bulmak, derin sinir ağları söz konusu olduğunda da bir NP-tam problemdir (Šima, 1994).

### 3.1. İleri beslemeli yapay sinir ağı

Düğümler arasındaki bağlantıların bir döngü oluşturmadığı YSA ileri beslemeli YSA olarak tanımlanır. (Zell, 1994). Tekrarlayan sinir ağlarından bu yönüyle ayrışır. İleri beslemeli YSA, icat edilmiş ilk ve en yalın YSA tipidir. (Schmidhuber, 2015a). Bu ağda bilgi, giriş düğümlerinden sadece tek yönlü olarak, ileri doğru varsa gizli düğümler üstünden geçerek çıkış düğümlerine ilerler. Ağda döngü ya da devir bulunmamaktadır. İleri beslemeli YSA'da, bilgi her zaman bir istikamette hareket eder; Şekil 3.1'de gösterildiği gibi asla geriye doğru gitmez.



Şekil 3.1. Basit bir ileri beslemeli YSA mimarisi (Öztürk ve Şahin, 2018)

#### 3.1.1. Tek Katmanlı algılayıcı

En basit sinir ağı türüdür. Tek bir çıkış düğümü katmanından oluşan, girişlerin bir seri ağırlık vasıtasıyla doğrudan çıkışlara bağlı olan bir katmanlı algılayıcı YSA'dır. Ağırlıkların ve girişlerin ürünlerinin toplamı her bir düğümde hesaplanır. Değer bir eşik (tipik olarak 0) üzerindeyse nöron aktif değeri alır (tipik olarak 1), aksi durumda devre dışı değeri alır (genellikle -1). Algılayıcı (perceptron) terimi genellikle bu birimlerden yalnızca birinden oluşan ağları ifade etmektedir. Benzer bir nöron Warren McCulloch ve Walter Pitts tarafından 1940'larda tasvir edilmiştir. Aktifleştirilen ve devre dışı bırakılan durumlarda eşik değeri ikisi arasında kaldığı sürece herhangi bir değer kullanılarak bir algılayıcı oluşturabilir. Algılayıcılar, genel olarak delta kuralı ile adlandırılan basit bir öğrenme algoritmasıyla eğitilebilir. Algılayıcı, örnek çıktı ve hesaplanan çıktı verisi arasındaki hataları hesaplar ve bunu ağırlıkları düzeltmek için kullanır, böylelikle bir

eğim azaltma biçimi uygular. Tek katmanlı algılayıcılar sadece doğrusal olarak ayrılabilir ve kalıpları öğrenebilir; 1969'da Perceptrons adlı ünlü bir monografda Marvin Minsky ve Seymour Papert, tek katmanlı bir algılayıcı ağının bir XOR işlevini öğrenmesinin imkânsız olduğunu göstermişlerdir (yine de çok katmanlı algılayıcıların olası herhangi bir boolean işlevi üretme kapasitesine sahip olduğu biliniyordu) (Minsky ve Papert, 1969).

Tek eşikli bir birim hesaplama gücünde oldukça sınırlı olmasına karşın, paralel eşikli birim ağlarının gerçek sayıların kompakt bir aralığından  $[-1,1]$  aralığına kadar herhangi bir sürekli işlevi aşağı yukarı hesaplayabildiği gösterilmiştir (Auer ve ark., 2008).

### 3.1.2. Çok katmanlı algılayıcı

Bu sınıfa giren ağlar genellikle ileri beslemeli şekilde birbirine bağlanmış birden fazla hesaplama birimi katmanından oluşur. Bir katmandaki her nöron bir sonraki katmanın nöronları ile yönlü bir bağlantıya sahiptir. Birçok uygulamada bu ağların birimleri, aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanırlar.

Sinir ağları için evrensel yakınsama teoremi, gerçek sayıların aralıklarını gerçek sayıların bir çıktı aralığına eşleyen her sürekli fonksiyonun, sadece tek bir gizli katmana sahip çok katmanlı bir algılayıcı tarafından isteğe bağlı olarak yakınlştırılabileceğini belirtir. Bu sonuç, örneğin sigmoidal fonksiyonlar gibi çok çeşitli aktivasyon fonksiyonları için geçerlidir.

Çok katmanlı ağlar, en ünlüsü geri beslemeli olan çeşitli öğrenme tekniklerini kullanır. Burada, çıkış değerleri, bazı önceden tanımlanmış hata fonksiyonlarının değerini hesaplamak için doğru cevapla karşılaştırılır. Çeşitli tekniklerle, hata daha sonra ağ üzerinden geri besleme ile bildirilir. Bu bilgiyi kullanarak algoritma, hata fonksiyonunun değerini küçük bir miktar azaltmak için her bağlantının ağırlığını ayarlar. Bu işlemi yeterince çok sayıda eğitim döngüsü için tekrarladıktan sonra, ağ genellikle hesaplama hatasının küçük olduğu bir duruma yakınsayacaktır. Bu durumda, ağın belirli bir hedef fonksiyonu öğrendiği söylenebilir. Ağırlıkları düzgün bir şekilde ayarlamak maksadıyla, doğrusal olmayan optimizasyon için genel bir yöntem olan ve eğim azaltma adı verilen bir yöntem uygulanır. Bunun için ağ, ağ fonksiyonlarına göre hata fonksiyonunun türevini hesaplar ve ağırlıkları hatanın azalacağı şekilde değiştirir (böylece hata fonksiyonunun

yüzeyinde aşağı yönlü değişim gösterir). Bu nedenle geri besleme yalnızca türevi alınabilir aktivasyon fonksiyonlarına sahip ağlara uygulanabilir.

Genellikle bir eğitim numunesi olarak kullanılmayan numunelerde bile bir ağın iyi performans göstermesini öğretme sorunu, ilave teknikler gerektiren oldukça hassas bir konudur. Bu özellikle çok sınırlı sayıda eğitim numunesinin mevcut olduğu vakalar için önemlidir (Balabin ve ark., 2007). Tehlike, ağın eğitim verilerini ezberlemesi ve veriyi üreten gerçek istatistiksel süreci yakalayamamasıdır. Hesaplamalı öğrenme teorisi sınırlı miktarda veri üzerindeki eğitim sınıflandırıcıları ile ilgilenir. Sinir ağları bağlamında, erken durdurma adı verilen basit bir sezgisel yaklaşım, çoğunlukla ağın eğitim setinde olmayan örneklere iyi bir genelleme yapmasını sağlar.

Geri besleme algoritmasının diğer karakteristik problemleri, yakınsama hızı ve hata fonksiyonunun yerel minimumunda son bulma olasılığıdır. Günümüzde çok katmanlı algılayıcılarda geri beslemeli birçok makine öğrenmesi görevi için tercih edilen araç yapan pratik yöntemler vardır (Zhang ve ark., 2007).

Ayrıca beyinde meydana gelen davranışa benzer bir şekilde, bazı araçlar tarafından yönetilen bir dizi bağımsız sinir ağı da kullanılabilir. Bu nöronlar ayrı ayrı performans gösterebilir ve büyük bir görevin üstesinden gelebilir ve sonuçlar nihai olarak birleştirilebilir (Tahmasebi ve Hezarkhani, 2011).

### **3.1.3. Geri beslemeli ağlar**

Geri beslemeli YSA, çıkış ve ara katmanlardaki çıktıların, giriş birimlerine veya önceki ara katmanlara geri beslemeli bir ağ yapısıdır. Böylece girişler hem ileri yönde hem de geri yönde aktarılmış olur. Geri beslemeli YSA'ların dinamik hafızaları vardır ve bir andaki çıktı hem o andaki hem de önceki girdileri yansıtır. Bu ağlar çeşitli tipteki problemlerin tahmininde oldukça başarılıdır (Uygunoğlu ve Yurtcu, 2006).


### **3.2. Evrimsel Sinir Ağları**

Evrimsel Sinir Ağları (ESA), bilgi akışının girişlerinden çıktılarına yalnızca bir yönde gerçekleştiği için ileri beslemeli ağlardır. Beyindeki, basit ve karmaşık hücrelerin (Hubel ve Wiesel, 1962) dönüşümlü katmanlarından oluşan görsel korteks, mimarilerini motive eder. ESA mimarileri çeşitli varyasyonlara sahiptir. Bununla birlikte, bunlar genel olarak, modüller halinde gruplandırılmış evrimsel ve havuzlama (veya alt-örnekleme)



katmanlarından oluşur. Standart bir ileri beslemeli sinir ağında olduğu gibi bir tam bağlı katman bu modülleri takip eder. Modüller genellikle derin bir model oluşturmak için üst üste istiflenir.

Şekil 3.2’de bir görüntü sınıflandırma görevi için tipik ESA mimarisini göstermektedir. Bir görüntü doğrudan ağa verilir ve bunu birkaç evrişim ve havuzlama aşaması izler. Daha sonra, bu işlemlerden temsiller bir tam bağlı katmanı besler. Son olarak, son tam bağlanan katman sınıf etiketini çıkarmaktadır.




Şekil 3.2. Görüntü sınıflandırmada kullanılan ESA Mimarisi (Fırıldak ve Talu, 2019)

### 3.2.1. Evrişimsel Katmanlar

ESA’ların temelini oluşturan bu katmana dönüşüm katmanı da denir. Bu dönüşüm, belirli bir filtrenin tüm görüntünün üzerine taşınması işlemine dayanır. Bu nedenle, filtreler katmanlı mimarinin ayrılmaz bir parçası olarak kabul edilir. Filtreler, 2x2 ve 3x3 olmak üzere farklı boyutlarda olabilmektedir. Filtreler, görüntülerin önceki katmandaki evrişimsel çıktı verilerini meydana getirir. Bu evrişim işlemi bir aktivasyon haritasını (özellik matrisi) oluşturur. Aktivasyon haritası, her bir filtreye özgü özelliklerin keşfedildiği bölgedir. Bu filtrelerin ESA’ların eğitimi sırasındaki katsayıları, eğitim setindeki her öğrenme tekrarına göre değişir. Bu sayede, ağ özelliklerini belirlemek için gereken verilerin hangi bölgelerinin önemli olduğu belirlenmiş olur (LeCun ve ark., 2015). Girdiler, yeni bir özellik haritasının hesaplanması için öğrenilen ağırlıklarla dönüşür ve kıvrımlı sonuçlar doğrusal olmayan bir etkinleştirme fonksiyonu ile gönderilir. Bir özellik haritasındaki tüm nöronlar eşit olmak üzere kısıtlanmış ağırlıklara sahiptir. Bununla birlikte, aynı evrişimsel katman içindeki farklı özellik haritaları farklı ağırlıklara sahiptir, böylece her bir konumda birkaç özellik elde edilebilir.  $k$  çıktı özelliği haritası  $Y_k$  Denklem 3.1 ile hesaplanabilir:

$$Y_k = f(W_k * x) \quad (3.1)$$

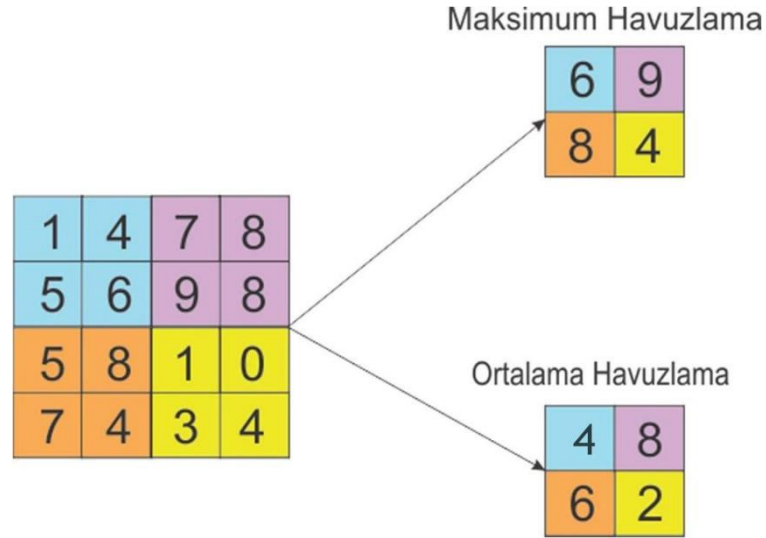
Burada giriş görüntüsü  $x$  ile  $k$ . özellik haritasına ilişkin evrişim filtresi  $W_k$  ile gösterilir. Bu bağlamdaki çarpma işareti (\*), giriş görüntüsünün her bir yerinde filtre modelinin iç çarpımını hesaplamak için kullanılan 2 boyutlu evrişimsel operatörünü ifade eder.  $f$  doğrusal olmayan aktivasyon fonksiyonunu temsil eder. Doğrusal olmayan aktivasyon fonksiyonları, doğrusal olmayan özelliklerin çıkarılmasına izin verir. Geleneksel olarak sigmoid ve hiperbolik tanjant fonksiyonları kullanılmaktadır. Son zamanlarda, Doğrultulmuş Doğrusal Birim (Rectified linear Unit ReLU) popüler hale gelmiştir (LeCun ve ark., 2015). Popülerlikleri ve başarıları, dekonvolüsyon sinir ağı performansının çeşitli özelliklerini geliştirmek için yeni dekonvolüsyon sinir ağı aktivasyon fonksiyonlarının geliştirilmesi ve uygulanmasına odaklanan bir araştırma alanı açmıştır. Şekil 3.3'te Evrişim Katmanının nasıl oluşturulduğu gösterilmektedir.



Şekil 3.3. Evrişim Katmanı (Cengil ve Cinar, 2019)

### 3.2.2. Havuzlama Katmanları

Havuzlama katmanlarının amacı, özellik haritalarının uzamsal kararlarını azaltmak böylelikle girişin bozulmalarına ve çevrilere mekansal değişmezlik sağlamaktır. Başlangıçta, görüntünün küçük bir komşusunun, tüm giriş değerlerinin ortalamasını ondan sonraki katmana yaymak için, ortalama birleştirme toplama katmanlarının kullanılması genellikle kullanılan bir uygulamadır (LeCun ve ark., 1998). Bununla beraber, daha yeni modellerde maksimum havuzlama toplama katmanları, alıcı bir alandaki en fazla değeri bir sonraki katmana yayar (Boureau ve ark., 2010). Şekil 3.4'te Havuzlama Katmanlarının işlemleri gösterilmiştir.



Şekil 3.4. Havuzlama türleri örneği (Scherer ve ark., 2010)

### 3.2.3. Tam Bağlantılı Katmanlar

Bu katman havuzlama katmanını takip eder. Bu katmana tamamen birleştirilmiş katman denir; arka katmanlardaki tüm nöronlara bağlanır. Özellik çıkarma işlemi önceki katmanda gerçekleştirilir ve bu katmanda bir sınıflandırma işlemi gerçekleştirilir. Evrişim ve havuz katmanlarında işlemden sonraki çıktı, giriş görüntüsünün üst düzey özelliklerini temsil eder. Tam bağlantılı katmanın amacı, giriş görüntüsünü eğitim verilerini temel olarak sınıflandırmak için bu özellikleri kullanmaktır (Serengil, 2017).

### 3.2.4. Toplu Normalleştirme (Batch Normalization)

Toplu normalleştirme, YSA'nın hızını, performansını ve stabilitesini artırmak için kullanılan bir tekniktir. Toplu normalleştirme ilk olarak 2015 yılında makalede sunulmuştur (Ioffe ve Szegedy, 2015). Yeniden ortalayarak ve yeniden ölçeklendirerek giriş katmanını normalleştirmek için kullanılır. Toplu normalleşmesinin etkisi açık olmakla birlikte, etkinliğinin ardındaki nedenler tartışılmaktadır. Parametre başlatma ve her bir katmanın girdilerinin dağılımındaki değişikliklerin ağı öğrenme hızını etkilediği dahili ortak değişken kayması sorununu azaltabileceğine inanılmaktadır (Ioffe ve Szegedy, 2015). Son zamanlarda, bazı araştırmacılar, toplu normalleşmenin iç değişken kaymasını azaltmadığını aksine performansı iyileştiren objektif işlevi düzelttiğini savunmuşlardır (Santurkar ve ark., 2018). Toplu normalleşmesinin arkasındaki motivasyon, bir nöral ağı her katmanının, eğitim işlemi sırasında parametre


başlatmadaki rasgele ve giriş verilerindeki rasgelelikten etkilenen karşılık gelen bir dağılıma sahip girişlere sahip olmasıdır. Bu rasgelelik kaynaklarının, eğitim sırasında girdilerin iç katmanlara dağılımı üzerindeki etkisi, iç değişken kayması olarak tanımlanmaktadır. Net bir kesin tanım eksik gibi görünse de, deneylerde gözlemlenen olgu, eğitim sırasında girdilerin araçlardaki ve iç katmanların varyanslarındaki değişikliklerdir. Ağların eğitim aşamasında, önceki katmanların parametreleri değiştikçe, girdilerin mevcut katmana dağılımı buna göre değişir, böylece mevcut katman sürekli olarak yeni dağıtımlara yeniden ayarlanmalıdır. Bu sorun özellikle derin ağlar için şiddetlidir, çünkü daha sık gizli katmanlardaki küçük değişiklikler, ağ içinde yayıldıkça çoğalır ve daha derin gizli katmanlarda önemli ölçüde kaymaya neden olmaktadır. Bu nedenle, eğitimi hızlandırmak ve daha güvenilir modeller üretmek için bu istenmeyen kaymaları azaltmak için toplu normalleştirme yöntemi önerilmektedir (Ioffe ve Szegedy, 2015).

### **3.2.5. Aktivasyon Fonksiyonları**

Aktivasyon fonksiyonu, YSA'da sinir düğümlerinin çıktısının hesaplanmasında kullanılan fonksiyondur. Transfer fonksiyonu olarak da bilinmektedir. Aktivasyon fonksiyonunun seçimi ağ eğitim süresini etkiler ve dekonvolüsyon sinir ağların büyük veri setleri üzerindeki performansı üzerinde önemli bir etkiye sahiptir (Krizhevsky ve ark., 2012). Nair ve Hinton (2010) tarafından derin Boltzmann makineleri için tanıtılan ReLU'lar, dekonvolüsyon sinir ağlar için denetimsiz ön eğitime gerek kalmadan tam denetimli ağlarda daha hızlı eğitim sürelerine yol açtıklarını göstermişlerdir.

#### **3.2.5.1. Doğrultulmuş Doğrusal Birim fonksiyonu (Rectified Linear Unit - ReLU)**

ReLU fonksiyonu günümüzde en çok kullanılan aktivasyon fonksiyonudur. ESA ve derin öğrenmede çoğunlukla ReLU kullanılmaktadır. Şekil 3.5'te ReLU fonksiyonunun denklemi ve şeması açıklanmıştır.



Şekil 3.5. ReLU fonksiyonunun denklemleri ve şeması (Xu ve ark., 2015)

Şekil 3.5'te de gösterildiği gibi  $z$  0'dan büyükken  $z$ 'ye, 0'a eşit ve 0'dan küçük iken 0'a eşittir. ReLU fonksiyonunun hem kendisi hem de türevi monoton fonksiyondur. Herhangi bir negatif değer ReLU tarafından sıfır olarak döndürülür. Tüm negatif değerlerin 0'a çevrilmesi modelin uygun bir şekilde eğitilmesini engeller. Bu nedenle model negatif değerler ile eğitilemez (Hara ve ark., 2015).

### 3.3. Evrişimsel tabanlı Gürültü Giderici Otomatik Kodlayıcı

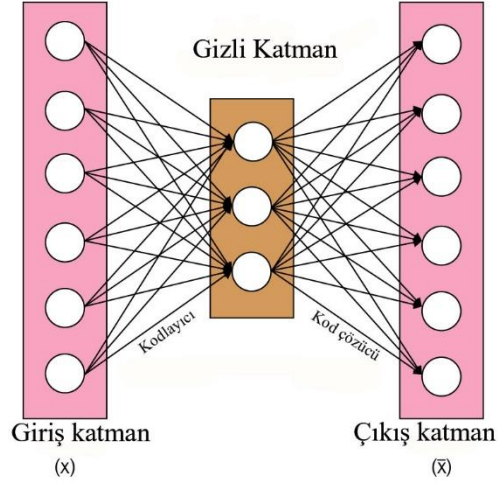
Bir oto-kodlayıcı, girdisini çıktısına kopyalamayı öğrenen bir sinir ağıdır. Girişi temsil etmek için kullanılan bir kodu tanımlayan bir iç (gizli) katmana sahiptir ve iki ana bölümden oluşur: girişi koda eşleyen bir kodlayıcı ve kodu orijinal girişin yeniden yapılandırılmasına eşleyen bir kod çözücüdür (Gondara, 2016).

Kopyalama görevini mükemmel bir şekilde gerçekleştirmek sinyali basitçe çoğaltır ve bu nedenle otomatik kodlayıcılar genellikle girdiyi yaklaşık olarak yeniden yapılandırmaya zorlayacak şekilde kısıtlanır.

Otomatik kodlayıcı fikri yıllardır sinir ağları alanında popüler olmuştur ve ilk uygulamalar 80'lerde meydana çıkmıştır. Geleneksel uygulamaları boyutsallığın azaltılması ya da özelliklerin öğrenilmesiyle, ancak daha yakın zamanda otomatik kodlayıcı konsepti, üretken veri modellerini öğrenmek için daha yaygın olarak kullanılmaktadır.

Bir otomatik kodlayıcının en basit şekli, bir giriş katmanına, bir çıkış katmanına ve bunları birleştiren bir veya daha fazla gizli katmana sahip, ileri beslemeli, geribeslemeli olmayan bir sinir ağıdır. Giriş katmanı ile çıkış katmanı aynı sayıda düğüme (nöron) sahiptir ve  $X$  girişlerinde verilen  $\tilde{X}$  hedef değerini tahmin etmek yerine girişlerini yeniden yapılandırmak (giriş ve çıkış arasındaki farkı en aza indirmek) amacıyla yapılmıştır. Bu nedenle, otomatik kodlayıcılar denetimsiz öğrenmedir. Modeller

öğrenmeyi sağlamak için etiketli girdiler gerektirmez. Şekil 3.8’de Temel Otomatik Kodlayıcı Mimarisi gösterilmiştir.



Şekil 3.8. Temel Otomatik Kodlayıcı Mimarisi (Zhang ve ark., 2017)

DAE’ler, yeniden yapılandırma kriterlerini değiştirerek iyi bir temsil elde etmeye çalışan otomatik kodlayıcılardır. DAE’ler kısmen bozuk bir girdi alır ve orijinal bozulmamış girdiyi kurtarmak için eğitilir. Uygulamada, otomatik kodlayıcıları hedefi, bozuk girdiyi temizlemek veya gürültüyü azaltmaktır. Temelde iki varsayım bu yaklaşımın doğasında vardır:

- Daha üst düzey temsiller nispeten istikrarlı ve girdinin bozulmasına karşı sağlamdır.
- Gürültü gidermek işlemini iyi yapmak için, modelin, girdinin dağıtımında yararlı bir yapı yakalayan özellikleri çıkarması gerekir.

### 3.4. Gauss Gürültüsü

Gauss gürültüsü ismini Carl Friedrich Gauss'tan alır. Gauss modeli doğal gürültü sürecini modellemek için kullanılan en genel yöntemdir. Bu yöntem özellikle görüntü elde etme sürecinde elektriksel olarak ortaya çıkan gürültüleri modellemek için kullanılmaktadır. Bir Gauss rastgele değişken  $x$  olasılık yoğunluk fonksiyonu  $p$  ile verilir:

$$P(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (3.2)$$

burada  $x$  gri seviyesini,  $\mu$  ortalama değer ve  $\sigma$  standart sapmayı temsil etmektedir (Değirmenci ve ark., 2018).

### 3.5. Ortalama Filtre

Ortalama filtrede, görüntüleri yumuşatmak için kolay ve uygulanması basit bir yöntemdir. Diğer ifade ile, bir piksel ve diğerleri arasındaki değişim miktarını azaltmaktır (Çakici ve Şahin, 2013). Çoğunlukla görüntülerdeki gürültüyü en aza indirmek için kullanılır. Ortalama filtre, bir görüntünün her bir piksel değerini komşuları ve kendisinin de içinde olduğu ortalama değerle değiştirerek gerçekleştirilir. Bu durum, çevresindekileri ifade etmeyen piksel değerlerinin ortadan kalkmasını sağlar.


Ortalama filtrede genellikle  $3 \times 3$  kare kernel kullanılır. Daha büyük şablonlar ( $5 \times 5$ ,  $7 \times 7$  gibi) bazı yumuşatma işlemlerinde kullanılabilir. Büyük şablonun bir tek taramadaki etkisine benzeyen bir etki, küçük şablonun birden fazla geçişiyle de sağlanabilir (Celik ve ark., 2015). Şekil 3.9'da ortalama filtrenin  $3 \times 3$  şablonu gösterilmiştir.

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

Şekil 3.9. Ortalama filtresinde kullanılan  $3 \times 3$  şablonu

### 3.6. Medyan Filtre

Medyan filtresi, normal olarak ortalama filtrede olduğu gibi bir görüntüdeki gürültüyü en aza indirmek için kullanılır. Fakat görüntü üzerindeki ayrıntıların kaybolmaması noktasında ortalama filtre, medyan filtresinden daha iyi sonuç vermektedir. Medyan filtrede, ortalama filtrede olduğu gibi her pikselin değerini hesaplamak için çevresindeki komşularına bakar. Ortalama filtresinde olan piksel değeri komşu piksel değerlerinin ortalaması ile değiştirmek yerine, medyan filtresi komşu pikselleri en küçükten en büyüğe ya da en büyükten en küçüğe doğru sıraya koyarak sıranın ortasındaki değeri alır. Eğer incelenen bölge (Şablonun içerisi) çift sayıda piksel var ise, orta değer için ortada bulunan iki pikselin toplamının ikiye bölümü kullanılır (Celik ve ark., 2015). Şekil 3.10'da medyan filtrenin nasıl kullanıldığı gösterilmiştir.




Şekil 3.10. Medyan filtre mimarisi (Celik ve ark., 2015)

Burada kullanılan şablon 3x3 piksel boyutlarındadır. Daha büyük şablonların kullanılması daha fazla yumuşatma etkisi gösterir.



### 3.7. NIH Göğüs Röntgeni Veri Kümesi

Bu çalışmada NIH göğüs röntgeni veri kümesi kullanılmıştır. Veri kümesinden örnek bazı görüntüler Şekil 3.11’de gösterilmektedir. Bu veri kümesi 30.805 farklı hastadan gelen hastalık teşhisli 112.120 röntgen görüntüsünden oluşmaktadır. Bu hastalık teşhisleri, Wang ve arkadaşları tarafından ilgili radyolojik raporlardaki hastalık teşhisleri bölümlerinden doğal dil işleme kullanılarak metin madenciliği yöntemiyle elde edilmiştir (Wang ve ark., 2017). Bu tez çalışmasında NIH göğüs röntgeni veri kümesinden rassal seçilmiş 30000 görüntü kullanılmıştır.



Şekil 3.11. NIH göğüs röntgeni veri kümesi örnekleri (Kaggle)

### 3.8. Değerlendirme Metrikleri

Değerlendirme metrikleri, sonuçların başarısını hesaplamak ve karşılaştırmak için kullanılmıştır. OKH orijinal ve filtrelenmiş görüntü arasındaki farkı hesaplamak için kullanılmıştır. PSNR ise bir sinyalin maksimum gücü ile OKH’dan beklenen değeri arasındaki oranı vermektedir. PSNR oranının yüksek çıkması görüntünün bozulma gürültüsüne oranla daha güçlü olduğunu göstermektedir.

### 3.8.1. Ortalama Karesel Hata (OKH)

OKH, gerçek ve ideal piksel değerleri arasındaki ortalama karesel farkı ölçer. Bu metriğin hesaplanması basittir ancak insanın kalite algısına uygun değildir. OKH ne kadar küçükse, aslına o kadar yakındır (Altınışık ve Sezgin, 2009). OKH Denklem 3.3 ile hesaplanır:

$$OKH = \frac{1}{N} \sum_{i=1}^N (Y_i - \check{Y}_i)^2 \quad (3.3)$$

Denklemden görüldüğü gibi N görüntüdeki piksel sayısı, Y gürültülü görüntü ve  $\check{Y}$  temiz görüntü piksel değerleridir.

### 3.8.2. Tepe Sinyal-Gürültü Oranı (Peak Signal-to-Noise Ratio, PSNR)

PSNR, bir işaretin olası maksimum gücünün işaret üzerindeki gürültünün gücüne oranını gösteren bir metriktir. PSNR değerinin yüksek olması görüntü kalitesinin yüksek olduğu anlamına gelmektedir. PSNR genellikle logaritmik desibel ölçeği olarak ifade edilir (Hore ve Ziou, 2010). PSNR Denklem 3.4 ile hesaplanır:


$$PSNR = 10 \log_{10} \left( \frac{MAX^2}{OKH} \right) \quad (3.4)$$

PSNR denklemi OKH değeri kullanılarak hesaplanır, denklemde ifade edilen MAX pikselin mümkün olan en yüksek değeridir.

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tezde, göğüs röntgeni görüntülerinden Gauss gürültüsünü gidermek için ESA tabanlı DAE tekniği önerilmiştir. Modellerin eğitiminde NIH göğüs röntgeni veri kümesi kullanılmıştır. DAE için en uygun mimariyi bulmak amacıyla ESA'nın farklı katman sayısı, filtre sayısı ve aktivasyon fonksiyonları karşılaştırılmıştır. En uygun mimari yapı elde edildikten sonra önerilen mimari ortalama ve medyan filtreler gibi geleneksel filtreleme yöntemleriyle karşılaştırılmıştır.

Şekil 4.1'de önerilen ESA tabanlı DAE yönteminin akış şemasını gösterilmiştir.



Şekil 4.1. Önerilen modelin akış şeması

Şekil 4.1'de gösterildiği gibi ilk olarak göğüs röntgeni görüntülerine %50 Gauss gürültüsü eklenmiştir. Daha sonra önerilen ESA tabanlı DAE kullanılarak görüntüdeki gürültü giderilme işlemi gerçekleştirilmektedir. Son olarak elde edilen görüntü ile orijinal görüntüyü karşılaştırmak için OKH ve PSNR değerleri kullanılmıştır.

##### 4.1. Araçlar

Modeller, TensorFlow arka katmanlı Keras kütüphanesi kullanılarak GPU destekli Python programlama dilinde uygulanmıştır. TensorFlow'daki her şey, bir formun veya diğerinin tensörü olarak depolanır. Bu durum, girdilerin tutarlı bir formda olması nedeniyle geniş bir fonksiyon dizisinin verimli bir şekilde tatbik edilmesine olanak sağlar.

Belirsiz modern ađ mimarileri inşa etmek için öntanımlı fonksiyonlardan modüler bir şekilde istifade edilebilir. Bu modülerlik, TensorFlow'un hesaplamalı bir grafik oluşturmasından ileri gelmektedir. Modül, iyi tanımlanmış bir gradyana sahip olduđu sürece, diđer TensorFlow fonksiyonları ile kolayca bütünleştirilebilir.

Programımızın uygulanması için tensorflow kütüphanesinden aşağıdaki katmanları ve fonksiyonları kullanılmıştır:

- Conv2D: Conv2D, görüntü işleme ve 2 boyutlu verilerde kullanılan evrişimsel katmandır.
- ReLU: her Conv2D katmanında kullanılan aktivasyon fonksiyonu olan ReLU fonksiyonudur.
- Toplu Normalleştirme: ESA'yı daha hızlı eğitmek ve ađdaki aşırı uyumu azaltmak için kullanılan bir katmandır.
- SGD Optimizasyonu: (Stochastic gradient descent, SGD) ađı eğitmek için kullanılan optimizasyondur.

## 4.2. Veri Ön İşleme

Bu çalışmada NIH göğüs röntgeni veri kümesi kullanılmıştır. Bu veri kümesi 112.120 göğüs röntgeni görüntüsü içermektedir. Bu veri kümesi 5000 görüntüden oluşan kümelere ayrılmıştır. Bu çalışmada kullanmak için 6 adet küme rassal seçilmiştir. Toplam 30.000 görüntü kullanılmıştır. Kullanılan veri kümesinin tüm görüntüleri 64x64 olarak yeniden boyutlandırılmıştır. Yeniden boyutlandırılmış görüntüler ESA tabanlı DAE'yi eğitmek için kullanılmıştır.

## 4.3. Gürültü Giderici Oto-kodlayıcı Mimarisi

Bu tez çalışmasında, farklı konfigürasyonlara sahip (katman sayısı, filtre boyutu) çeşitli gürültü giderici mimarileri ile deneyler yapılmıştır. Her model 20.000 görüntü üzerinde eğitilmiş, 5.000 görüntü üzerinde doğrulanmış ve 5.000 görüntü üzerinde test edilmiştir.

Veri kümesinde bulunan görüntüler gri seviye görüntülerdir ve piksel değerleri 0-255 arasında değişmektedir. ESA modelinde kullanılacak veri kümesindeki tüm görüntülerin piksel değerleri -1 ve 1 arasına normalleştirilmiştir ve kayıp fonksiyonu

olarak OKH kullanılmıştır. Aktivasyon fonksiyonu olarak RELU aktivasyon fonksiyonu kullanılmıştır. Uygun mimariyi bulabilmek için katman sayısı ve filtrelerin konfigürasyonları ile deneyler yapılmıştır. İlk olarak 7 katman ve dört farklı filtre sayısı vardır (16, 32, 46 ve 128). Daha sonra aynı filtrelerle 10 katman ve son olarak aynı filtrelerle yapılandırılmış 12 katman kullanılmıştır. Bu mimariler aşağıda sıra ile gösterilmiştir.

Çizelge 4.1'de 7 katmanlı olan ESA mimarisinde farklı filtre boyutları ile eğitim, doğrulama ve test sonuçları karşılaştırılmıştır.

**Çizelge 4.1.** 7 katmanda farklı filtre boyutların karşılaştırması

Filtre sayısı	Eğitim Kaybı	Doğrulama Kaybı	Test Kaybı
16	0.022890	0.019767	0.01510
32	0.016200	0.013790	0.01267
<b>64</b>	<b>0.013770</b>	<b>0.011310</b>	<b>0.01222</b>
128	0.272780	0.086260	0.08968

7 katmanlı ESA mimarisinde en iyi sonuç OKH kullanılarak hesaplanan 0.01222 test kaybı ile 64 filtre kullanıldığında elde etmiştir.

Çizelge 4.2'de 10 katmanlı olan ESA mimarisinde farklı filtre boyutları ile eğitim, doğrulama ve test sonuçları karşılaştırılmıştır.

**Çizelge 4.2.** 10 katmanda farklı filtre boyutların karşılaştırması

Filtre sayısı	Eğitim Kaybı	Doğrulama Kaybı	Test Kaybı
16	0.033799	0.031296	0.029575
32	0.020980	0.017800	0.027450
<b>64</b>	<b>0.015260</b>	<b>0.012200</b>	<b>0.022240</b>
128	0.195080	0.086320	0.089840

10 katmanda da en iyi sonuç 0.022240 test kaybı değeri ile 64 filtre kullanılarak elde etmiştir. Çizelge 4.3'de 12 katmanlı olan ESA mimarisinde farklı filtre boyutları ile eğitim, doğrulama ve test sonuçları karşılaştırılmıştır.

**Çizelge 4.3.** 12 katmanda farklı filtre boyutların karşılaştırması

Filtre sayısı	Eğitim Kaybı	Doğrulama Kaybı	Test Kaybı
16	0.040930	0.038180	0.035549
32	0.026060	0.022630	0.034660
<b>64</b>	<b>0.016150</b>	<b>0.012680</b>	<b>0.028358</b>
128	0.165420	0.082650	0.077086

Çizelge 4.3'e bakıldığında 12 katmanda da en iyi sonuç 0.028358 test kaybı değeri ile 64 filtre kullanılarak elde etmiştir.

Çizelge 4.1, 4.2 ve 4.3'te farklı konfigürasyonlara sahip (katman sayısı ve filtre boyutu) modellerin test sonuçları gösterilmektedir. 7, 10 ve 12 katmanlı mimarilerin hepsinde en uygun filtre boyutu 64 olarak elde edilmiştir. Farklı katman sayılarına sahip mimariler karşılaştırıldığında ise 0.01222 test kaybı ile 64 filtreye ve 7 katmanlı mimariye sahip model en başarılı sonucu vermektedir.



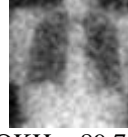














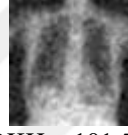
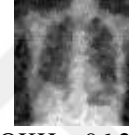



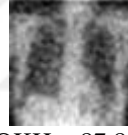
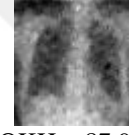








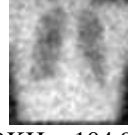




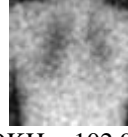




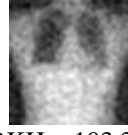


RELU aktivasyon fonksiyonlu ve 64 filtre boyutuna sahip 7 evrişim katmanı en iyi model olarak seçilmiştir. Modelin mimarisi Çizelge 4.4'te gösterilmiştir.













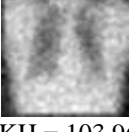

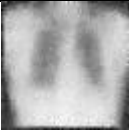


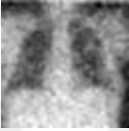




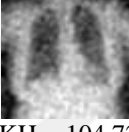









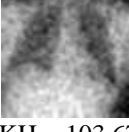
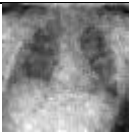








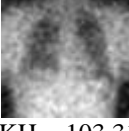


**Çizelge 4.4. Model Mimarisi**

Katman	Aktivasyon	Filtreler
Giriş Katmanı	Yok	
Conv2D	RELU	64
Conv2D	RELU	64
Toplu Normalleştirme		
Conv2D+	RELU	64
Toplu Normalleştirme		
Conv2D +	RELU	64
Toplu Normalleştirme		
Conv2D +	RELU	64
Toplu Normalleştirme		
Conv2D +	RELU	64
Toplu Normalleştirme		
Conv2D	Yok	1













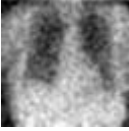




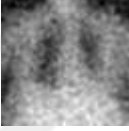









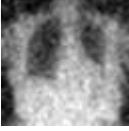




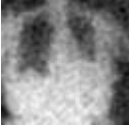









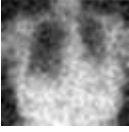







Gürültü gidermek için önerilen ESA tabanlı DAE yönteminin başarısı bölüm 3.5 ve 3.6 da anlatılan ortalama ve medyan filtreleme yöntemleri ile karşılaştırılmıştır. NIH göğüs röntgeni veri kümesinden seçilen rassal 30 görüntüye %50 Gauss gürültüsü eklenmiş ve ortalama, medyan filtreleme teknikleri ve önerilen ESA tabanlı DAE kullanılarak gürültü giderme işlemi gerçekleştirilmiştir. Temiz görüntü ile filtrelenmiş görüntüler arasındaki OKH ve PSNR hesaplanmıştır. Gürültü giderme işlemi sonucunda elde edilen görüntüler ve karşılaştırma sonuçları Çizelge 4.6' da verilmiştir.








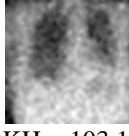


**Çizelge 4.6.** Gürültü gidermek için Ortalama, Medyan Filtreleri ve önerilen ESA tabanlı DAE karşılaştırılması

Temiz Görüntü	Gürültülü Görüntü	Ortalama Filtre	Medyan Filtre	ESA tabanlı DAE
		 OKH = 89.706 PSNR = 28.602	 OKH = 89.856 PSNR = 28.595	 OKH = 87.535 PSNR = 28.708
		 OKH = 106.318 PSNR = 27.864	 OKH = 98.289 PSNR = 28.205	 OKH = 99.608 PSNR = 28.147
		 OKH = 100.241 PSNR = 28.120	 OKH = 98.817 PSNR = 28.182	 OKH = 100.495 PSNR = 28.109
		 OKH = 101.558 PSNR = 28.063	 OKH = 96.286 PSNR = 28.295	 OKH = 90.585 PSNR = 28.560
		 OKH = 87.827 PSNR = 28.694	 OKH = 87.903 PSNR = 28.690	 OKH = 88.284 PSNR = 28.671
		 OKH = 83.260 PSNR = 28.926	 OKH = 87.196 PSNR = 28.725	 OKH = 89.287 PSNR = 28.622
		 OKH = 104.932 PSNR = 27.921	 OKH = 108.559 PSNR = 27.774	 OKH = 97.545 PSNR = 28.238
		 OKH = 102.926 PSNR = 28.005	 OKH = 103.482 PSNR = 27.982	 OKH = 106.583 PSNR = 27.853
		 OKH = 103.387 PSNR = 27.986	 OKH = 102.133 PSNR = 28.039	 OKH = 97.721 PSNR = 28.230

		 OKH = 100.061 PSNR = 28.128	 OKH = 101.096 PSNR = 28.083	 OKH = 103.199 PSNR = 27.994
		 OKH = 104.902 PSNR = 27.922	 OKH = 103.364 PSNR = 27.987	 OKH = 102.584 PSNR = 28.019
		 OKH = 103.960 PSNR = 27.962	 OKH = 105.795 PSNR = 27.886	 OKH = 97.952 PSNR = 28.220
		 OKH = 101.625 PSNR = 28.060	 OKH = 104.353 PSNR = 27.945	 OKH = 98.789 PSNR = 28.183
		 OKH = 104.726 PSNR = 27.930	 OKH = 104.062 PSNR = 27.957	 OKH = 103.431 PSNR = 27.984
		 OKH = 103.769 PSNR = 27.970	 OKH = 104.876 PSNR = 27.924	 OKH = 93.736 PSNR = 28.411
		 OKH = 103.672 PSNR = 27.974	 OKH = 103.333 PSNR = 27.988	 OKH = 102.250 PSNR = 28.034
		 OKH = 93.326 PSNR = 28.430	 OKH = 98.016 PSNR = 28.217	 OKH = 108.086 PSNR = 27.793
		 OKH = 103.319 PSNR = 27.988	 OKH = 107.249 PSNR = 27.826	 OKH = 109.081 PSNR = 27.753



		 OKH = 104.391 PSNR = 27.944	 OKH = 105.403 PSNR = 27.902	 OKH = 102.764 PSNR = 28.012
		 OKH = 105.618 PSNR = 27.893	 OKH = 109.618 PSNR = 27.731	 OKH = 110.419 PSNR = 27.700
		 OKH = 103.217 PSNR = 27.993	 OKH = 103.019 PSNR = 28.001	 OKH = 102.013 PSNR = 28.044
		 OKH = 83.828 PSNR = 28.896	 OKH = 105.609 PSNR = 27.893	 OKH = 100.627 PSNR = 28.103
		 OKH = 103.974 PSNR = 27.961	 OKH = 91.958 PSNR = 28.494	 OKH = 98.160 PSNR = 28.211
		 OKH = 105.772 PSNR = 27.887	 OKH = 104.817 PSNR = 27.926	 OKH = 108.854 PSNR = 27.762
		 OKH = 104.858 PSNR = 27.924	 OKH = 106.514 PSNR = 27.856	 OKH = 109.812 PSNR = 27.724
		 OKH = 106.967 PSNR = 27.838	 OKH = 105.962 PSNR = 27.879	 OKH = 99.714 PSNR = 28.143
		 OKH = 101.986 PSNR = 28.045	 OKH = 107.249 PSNR = 27.826	 OKH = 109.236 PSNR = 27.747
				

		OKH = 105.813 PSNR = 27.885	OKH = 104.054 PSNR = 27.958	OKH = 98.039 PSNR = 28.216
		 OKH = 107.960 PSNR = 27.798	 OKH = 106.095 PSNR = 27.873	 OKH = 105.447 PSNR = 27.900
		 OKH = 103.125 PSNR = 27.997	 OKH = 106.915 PSNR = 27.840	 OKH = 105.007 PSNR = 27.918
Ortalama		OKH = 101.234 PSNR = 28.087	OKH = 102.063 PSNR = 28.049	OKH = 100.895 PSNR = 28.100

ESA tabanlı DAE yöntemi kullanılarak Çizelge 4.6'da gösterilen 30 görüntüden elde edilen ortalama OKH ve PSNR değerleri sırasıyla 100.895, 28.100 olarak bulunmuştur. Aynı görüntüler için ortalama filtre kullanılarak 101.234 OKH ve 28.087 PSNR değerleri, medyan filtre kullanılarak 102.063 OKH ve 28.049 PSNR değerleri elde edilmiştir.

## 5. SONUÇLAR VE ÖNERİLER

### 5.1. Sonuçlar

Bu tezde, derin öğrenme yöntemlerine dayalı görüntü arındırma tekniği önerilmiştir. Bu çalışmada kullanılan algoritma, NIH göğüs röntgeni veri kümesi üzerinde eğitilmiş bir ESA tabanlı DAE'dir.

En uygun modeli elde etmek için ESA mimarisi üzerinde farklı evrişim katman sayıları ve filtre boyutları karşılaştırılmıştır. 7, 10 ve 12 katmanlı olmak üzere toplam üç evrişim katman sayısı ve 16, 32, 64 ve 128 olmak üzere dört farklı filtre boyutunun konfigürasyonu toplam 12 mimariye bakılarak en uygun model elde edilmiştir. Aktivasyon fonksiyonu olarak RELU kullanılmıştır. Veri kümesindeki 30000 görüntüden 20.000 görüntü eğitim ve 5.000 görüntü doğrulama olacak şekilde ayrılmıştır. Test seti için eğitim setinde olmayan 5.000 görüntü kullanılmıştır. Mimari konfigürasyonlarına bakıldığında, RELU aktivasyon fonksiyonlu, 64 filtre boyutuna sahip 7 Katmanlı mimarinin eğitim, doğrulama ve test setlerinde en iyi sonuçları elde ettiği bulunmuştur.

Önerilen model daha sonra geleneksel filtreleme yöntemleri ortalama ve medyan filtreler ile karşılaştırılmıştır. NIH göğüs röntgeni veri kümesinden seçilen rassal 30 görüntü üzerine Gauss gürültüsü eklenerek ortalama, medyan ve önerilen ESA tabanlı DAE yöntemleri kullanılarak gürültü giderme işlemi gerçekleştirilmiştir. Önerilen modelin performansını ölçmek için OKH, PSNR kullanılmıştır. Bu 30 görüntünün gürültü giderme işlemi sonrasında elde edilen ortalama OKH ve PSNR sonuçları karşılaştırılmıştır. Ortalama OKH ve PSNR değerlerine bakıldığında ortalama filtre 101.234 OKH ve 28.087 PSNR ve medyan filtre 102.063 OKH ve 28.049 PSNR değerlerini elde etmiştir. Önerilen ESA tabanlı DAE modeli ise OKH değerini 100.894 ve PSNR değerini 28.1003 olarak bulmuştur. Sonuçlara baktığımızda önerdiğimiz modelin geleneksel filtreleme yöntemlerinden daha başarılı olduğu gözükmektedir.

### 5.2. Öneriler

Bu çalışmada Gauss gürültüsü eklenmiş görüntülerden gürültü giderme işlemi için ESA tabanlı DAE önerilmiştir. İlerdeki çalışmalarda tuz ve karabiber, Poisson gürültü (Poisson noise) gibi farklı gürültü türlerini gidermeyi ve tıbbi görüntüleme yerine,

normal görüntülerde bulunan farklı tipte gürültüyü temizlemek için bir mimari geliřtirmeyi hedefliyoruz.

Gelecek alıřmalarda Güçlü bir Grafik iřleme birimi (GPU) kullanmak eğitim süresini azaltacak ve daha yüksek çözünürlüklü ve daha fazla sayıda eğitim verisi görüntüleri kullanılmasına izin vermiş olacaktır.



## KAYNAKLAR

- Altınışık, A. G. P. ve Sezgin, H., 2009, Tuz ve Biber Gürültüsünü Gidermek İçin Şartlı Dört Yönlü Ortalama Süzgeç Uygulaması.
- Auer, P., Burgsteiner, H. ve Maass, W., 2008, A learning rule for very simple universal approximators consisting of a single layer of perceptrons, *Neural networks*, 21 (5), 786-795.
- Balabin, R. M., Safieva, R. Z. ve Lomakina, E. I., 2007, Comparison of linear and nonlinear calibration models based on near infrared (NIR) spectroscopy data for gasoline properties prediction, *Chemometrics and intelligent laboratory systems*, 88 (2), 183-188.
- Boureau, Y.-L., Ponce, J. ve LeCun, Y., 2010, A theoretical analysis of feature pooling in visual recognition, *Proceedings of the 27th international conference on machine learning (ICML-10)*, 111-118.
- Buades, A., Coll, B. ve Morel, J.-M., 2005, A review of image denoising algorithms, with a new one, *Multiscale Modeling & Simulation*, 4 (2), 490-530.
- Çakıcı, S. ve Şahin, İ., 2013, FPGA Tabanlı Ortalama Görüntü Filtresi Tasarımı, *İleri Teknoloji Bilimleri Dergisi*, 2 (2), 1-13.
- Celik, K., Sayan, H. H. ve Demirci, R., 2015, Gradient adaptive Gaussian image filter, *2015 23rd Signal Processing and Communications Applications Conference (SIU)*, 879-882.
- Cengil, E. ve Cinar, A., 2019, Classification of Human Driving Behaviour Images Using Convolutional Neural Network Architecture, *International Conference on Hybrid Artificial Intelligence Systems*, 264-274.
- Chen, H., Zhang, Y., Zhang, W., Liao, P., Li, K., Zhou, J. ve Wang, G., 2017, Low-dose CT denoising with convolutional neural network, *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*, 143-146.
- Dabhi, P. R. ve Bari, S., 2015, Resolution Enhancement of High Noise Satellite Images Using DT-DWT Based Fusion Algorithm, *JETIR*.
- Değirmenci, A., ÇANKAYA, İ. ve DEMİRCİ, R., 2018, Gradyan Anahtarlamalı Gauss Görüntü Filtresi, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6 (1), 196-215.
- Desale, R. P. ve Verma, S. V., 2013, Study and analysis of PCA, DCT & DWT based image fusion techniques, *2013 International Conference on Signal Processing, Image Processing & Pattern Recognition*, 66-69.
- Fırıldak, K. ve Talu, M. F., 2019, *Anatolian Journal of Computer Science*, Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi 8.

- Gondara, L., 2016, Medical image denoising using convolutional denoising autoencoders, *2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW)*, 241-246.
- Hamarneh, G. ve Hradsky, J., 2007, Bilateral filtering of diffusion tensor magnetic resonance images, *IEEE Transactions on image Processing*, 16 (10), 2463-2475.
- Hara, K., Saito, D. ve Shouno, H., 2015, Analysis of function of rectified linear unit used in deep learning, *2015 International Joint Conference on Neural Networks (IJCNN)*, 1-8.
- Hochreiter, S. ve Schmidhuber, J., 1997, Long short-term memory, *Neural computation*, 9 (8), 1735-1780.
- Hore, A. ve Ziou, D., 2010, Image quality metrics: PSNR vs. SSIM, *2010 20th International Conference on Pattern Recognition*, 2366-2369.
- Hubel, D. H. ve Wiesel, T. N., 1962, Receptive fields, binocular interaction and functional architecture in the cat's visual cortex, *The Journal of physiology*, 160 (1), 106-154.
- Ioffe, S. ve Szegedy, C., 2015, Batch normalization: Accelerating deep network training by reducing internal covariate shift, *arXiv preprint arXiv:1502.03167*.
- K.Prasad, B. J. n., B.Hymavathi, 2012, High Density Salt and Pepper Noise Removal in color and grayscale images Through Modified DTMF, *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 1 (7), 7.
- Kaggle, <https://www.kaggle.com/nih-chest-xrays/data>, [Sayfanın ziyaret edildiği tarih 29/01/2019].
- Kang, E., Min, J. ve Ye, J. C., 2017, A deep convolutional neural network using directional wavelets for low-dose X-ray CT reconstruction, *Medical physics*, 44 (10), e360-e375.
- Kang, E. ve Ye, J. C., 2017, Wavelet domain residual network (WavResNet) for low-dose X-ray CT reconstruction, *arXiv preprint arXiv:1703.01383*.
- Kannan, K., Perumal, A. S. ve Arulmozhi, K., 2010, Optimal decomposition level of discrete, stationary and dual tree complex wavelet transform for pixel based fusion of multi-focused images, *Serbian Journal of Electrical Engineering*, 7 (1), 81-93.
- Krissian, K. ve Aja-Fernández, S., 2009, Noise-driven anisotropic diffusion filtering of MRI, *IEEE transactions on image processing*, 18 (10), 2265-2274.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 1097-1105.

- Kumar, B. S. ve Nagaraj, S., 2013, Discrete and stationary wavelet decomposition for image Resolution Enhancement, *International Journal of Engineering Trends and Technology (IJETT)*, 4 (7), 2886-2889.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278-2324.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015, Deep learning, *nature*, 521 (7553), 436-444.
- Lu, B., Deng, C., Liu, Q. ve Li, J., 2009, Four order adaptive PDE method for MRI denoising, *2009 3rd International Conference on Bioinformatics and Biomedical Engineering*, 1-4.
- Manjon, J., Robles, M. ve Thacker, N., 2007, Multispectral MRI de-noising using non-local means, *Proc. MIUA*, 41-45.
- McVeigh, E., Henkelman, R. ve Bronskill, M., 1985, Noise and filtration in magnetic resonance imaging, *Medical physics*, 12 (5), 586-591.
- Meyer, A. ve Schmid, V. J., 2014, Pattern recognition and signal analysis in medical imaging, Elsevier, p.
- Minsky, M. ve Papert, S., 1969, An introduction to computational geometry, *Cambridge tiass., HIT*.
- Öztürk, K. ve Şahin, M. E., 2018, Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış, *Takvim-i Vekayi*, 6 (2), 25-36.
- Park, H. S., Baek, J., You, S. K., Choi, J. K. ve Seo, J. K., 2019, Unpaired image denoising using a generative adversarial network in X-ray CT, *IEEE Access*, 7, 110414-110425.
- Perona, P. ve Malik, J., 1990, Scale-space and edge detection using anisotropic diffusion, *IEEE Transactions on pattern analysis and machine intelligence*, 12 (7), 629-639.
- Placidi, G., Alecci, M. ve Sotgiu, A., 2003, Post-processing noise removal algorithm for magnetic resonance imaging based on edge detection and wavelet analysis, *Physics in Medicine & Biology*, 48 (13), 1987.
- Pradnya, M. ve Ruikar, S. D., 2013, Image fusion based on stationary wavelet transform, *International Journal of Advanced Engineering Research and Studies*, 2 (4), 99-101.
- Preethi, S. ve Narmadha, D., 2012, A survey on image denoising techniques, *international journal of computer applications*, 58 (6).
- Purushotham, A., Rani, G. U. ve Naik, S., 2015, Image Fusion with Contrast Enhancement Using DWT & SVD, *International Journal of Advanced Networking and Applications*, 6 (6), 2573.

- Rajan, J., Jeurissen, B., Sijbers, J. ve Kannan, K., 2009, Denoising magnetic resonance images using fourth order complex diffusion, *2009 13th International Machine Vision and Image Processing Conference*, 123-127.
- Saadia, A., 2017, Denoising and enhancement of medical images, *College of Signals, National University of Sciences and Technology ...*.
- Santurkar, S., Tsipras, D., Ilyas, A. ve Madry, A., 2018, How does batch normalization help optimization?, *Advances in Neural Information Processing Systems*, 2483-2493.
- 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.
- Schmidhuber, J., 2015a, Deep learning in neural networks: An overview, *Neural networks*, 61, 85-117.
- Schmidhuber, J., 2015b, Deep Learning, *Scholarpedia*, 10 (11), 32832.
- Serengil, Ş. I., 2017, A Gentle Introduction to Convolutional Neural Networks, <http://sefiks.com/2017/11/03/a-gentle-introduction-to-convolutional-neural-networks>.
- Šíma, J., 1994, Loading deep networks is hard, *Neural computation*, 6 (5), 842-850.
- Tahmasebi, P. ve Hezarkhani, A., 2011, Application of a modular feedforward neural network for grade estimation, *Natural resources research*, 20 (1), 25-32.
- Tej, G. A. ve Shah, P. K., 2015, Efficient quality analysis and enhancement of MRI image using Filters and Wavelets, *Int J Adv Res Comp Communi Eng*, 4 (6).
- Tomasi, C. ve Manduchi, R., 1998, Bilateral filtering for gray and color images, *Iccv*, 2.
- Tulum, G. ve Kahraman, M., 2017, Akciğer BT Görüntülerinin Bölütlenmesi ve Matlab ile Nodül Tespiti.
- Uygunoğlu, T. ve Yurtcu, Ş., 2006, Yapay Zeka Tekniklerinin İnşaat Mühendisliği Problemlerinde Kullanımı, *Yapı Teknolojileri Elektronik Dergisi*, 2 (1), 61-70.
- Walker, S. A., Miller, D. ve Tanabe, J., 2006, Bilateral spatial filtering: Refining methods for localizing brain activation in the presence of parenchymal abnormalities, *NeuroImage*, 33 (2), 564-569.
- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M. ve Summers, R. M., 2017, Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2097-2106.
- Xie, J., Heng, P.-A. ve Shah, M., 2008, Image diffusion using saliency bilateral filter, *IEEE Transactions on Information Technology in Biomedicine*, 12 (6), 768-771.



- Xu, B., Wang, N., Chen, T. ve Li, M., 2015, Empirical evaluation of rectified activations in convolutional network, *arXiv preprint arXiv:1505.00853*.
- You, C., Yang, Q., Gjestebj, L., Li, G., Ju, S., Zhang, Z., Zhao, Z., Zhang, Y., Cong, W. ve Wang, G., 2018, Structurally-sensitive multi-scale deep neural network for low-dose CT denoising, *IEEE Access*, 6, 41839-41855.
- Yu, H. ve Zhao, L., 2008, An efficient denoising procedure for magnetic resonance imaging, *2008 2nd International Conference on Bioinformatics and Biomedical Engineering*, 2628-2630.
- Zell, A., 1994, Simulation neuronaler netze, 5.3, Addison-Wesley Bonn, p.
- Zhang, F. ve Ma, L., 2010, MRI denoising using the anisotropic coupled diffusion equations, *2010 3rd International Conference on Biomedical Engineering and Informatics*, 397-401.
- Zhang, J.-R., Zhang, J., Lok, T.-M. ve Lyu, M. R., 2007, A hybrid particle swarm optimization–back-propagation algorithm for feedforward neural network training, *Applied mathematics and computation*, 185 (2), 1026-1037.
- Zhang, L., Dong, W., Zhang, D. ve Shi, G., 2010, Two-stage image denoising by principal component analysis with local pixel grouping, *Pattern recognition*, 43 (4), 1531-1549.
- Zhang, Y., Shen, D., Wang, G., Gan, Z., Heno, R. ve Carin, L., 2017, Deconvolutional paragraph representation learning, *Advances in Neural Information Processing Systems*, 4169-4179.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Mohammed Shamil Ibrahim IBRAHİM  
**Uyruğu** : Irak  
**Doğum Yeri ve Tarihi** : Irak- Kerkük 1989  
**Telefon** : 00905342059421  
**Faks** :  
**E-Posta** : [Mohammed89shamil@gmail.com](mailto:Mohammed89shamil@gmail.com)

### EĞİTİM

Derece	Adı	İlçe	İl	Bitirme Yılı
Lise	: Al-Sadır	Kerkük	Kerkük	2009
Üniversite	: Al-Qalam	Kerkük	Kerkük	2016
Yüksek Lisans	: Konya Teknik Üni.	Konya	Konya	

### UZMANLIK ALANI

**YABANCI DİLLER** (Arapça -İngilizce)

### YAYINLAR

M.Ibrahim ve S. Uymaz, 2019, Chest X-ray Image denoising based on Convolutional denoising autoencoder. International Conference on Engineering Technologies (ICENTE'19). Konya, Turkey: 88.