

# Derin Öğrenme ile Görüntülerde Gürültü Azaltma Üzerine Kapsamlı Bir İnceleme

## *A Comprehensive Review of Image Denoising With Deep Learning*

Ahmet YAPICI<sup>1</sup> , M. Ali AKCAYOL<sup>2</sup> 

<sup>1</sup>Gazi Üniversitesi, Bilişim Enstitüsü, Bilişim Sistemleri, 06680, Ankara, Türkiye

<sup>2</sup>Gazi Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, 06560, Ankara

### Öz

Günlük hayatımızda ve bilimsel araştırmalarda gerçeğe yakın ve gürültüsüz görüntülere olan ihtiyaç artmaktadır. Ancak görüntüler, gürültü ile bozulmakta ve bu da görsel görüntü kalitesinin düşmesine neden olmaktadır. Bu nedenle, görüntü özelliklerini kaybetmeden gürültüyü azaltmak için çalışmalar yapılmaktadır. Şimdiye kadar, gürültüyü azaltmak için çeşitli yöntemler önerilmiş olup, her yöntemin farklı avantajları bulunmaktadır. Bu makalede, alanında en iyi sonucu elde eden yöntemler hakkında bilgi verilerek, video ve sabit görüntülerinde gürültü azaltma alanında yapılan geleneksel gürültü giderme yöntemleri ve derin öğrenme yöntemlerine ait çalışmalar özetlenip, elde edilen sonuçlar birbirleriyle karşılaştırılmaktadır. Yapılan araştırmalar deneylerin toplamsal beyaz Gauss gürültüsü durumuna odaklandığını göstermektedir. Görüntülerde gürültü giderme aşamasında zaman içerisinde geleneksel gürültü giderme yöntemleri, makine öğrenmesi yöntemleri, derin öğrenme yöntemleri ve diğer matematiksel yöntemler kullanılmış olup, derin öğrenme yöntemleri daha başarılı sonuçlar elde etmektedir. Ancak elde edilen verilere göre orijinal görüntü çiftlerine sahip olmadan modelin eğitilmesi konusunda çalışmaların yetersiz olduğu ve değişik gürültü seviyelerinde tek bir yöntemin başarılı olamadığı görülmüştür. İleride yapılacak çalışmalarda gerçek hayattaki görüntülerde var olan gürültülerin nasıl giderileceği konusuna daha detaylı odaklanılması gerektiği görülmektedir.

**Anahtar Kelimeler:** Görüntülerde gürültü giderme, Görüntü restorasyonu, Video üzerinde gürültü azaltma, Derin öğrenme tabanlı gürültü giderme.

### Abstract

In daily life and scientific searches, the need for real-like and denoised images is increasing. But images are distorted by noise, resulting in lower visual image quality. For this reason, noise removal studies are carried out on images to increase the quality. Until now, various methods have been proposed to decrease noise, each technique has different advantages. This paper gives information about the methods that achieve the best results in their field and summarizes the studies about traditional denoising and deep learning based denoising methods in the field of noise reduction in video and images and compares the studies with each other. Researches show that experiments focus on the case of additive white Gaussian noise. Traditional noise removal methods, machine learning methods, deep learning methods and other mathematical methods have been used in image denoising problem over time, and deep learning methods achieve more successful results. However, according to the obtained data, it has been seen that the studies on training the model without having the original image pairs were insufficient and a single method could not be successful at different noise levels. In future studies, it is necessary to focus on how to remove the noise in real-life images.

**Keywords:** Image denoising, Image restoration, Video denoising, Deep learning-based noise reduction.

## I. GİRİŞ

Günümüzde video ve görüntüler hayatın çeşitli alanlarında kullanılmaktadır. Görüntü aktarma ve görüntü yakalama işlemleri sırasında video ve görüntülerde bozulma, bilgisayarla görme uygulamalarında yaşanan problemlerin başında gelmektedir. Ortamın, aktarım kanalının ve çevresel faktörlerin etkisiyle görüntüler, elde etme, sıkıştırma ve aktarım sırasında gürültü ile karşılaşmakta ve bunun sonucunda, görüntü bilgisi bozulmakta ve veri kaybı ortaya çıkmaktadır.

Görüntüde gürültü giderme, gürültülü bir görüntüden gürültüyü kaldırmaktır. Kenar ve dokular yüksek frekanslı bileşenler olduğundan, bunları gürültüden arındırma sürecinde, gürültüyü ayırt etmek zordur ve gürültüden arındırılmış görüntüler bazı ayrıntıları kaybedebilir. Gürültü giderme aslında klasik bir sorun olup, uzun süredir üzerinde çalışılmasına rağmen, gürültü gidermenin ters bir problem olması ve tek çözümün olmaması nedeniyle çalışmalar hala devam etmektedir. Video ve görüntülerde gürültü gidermek için, farklı yaklaşımlar yıllar içerisinde kullanılmıştır. Kullanılan geleneksel yöntemlerde uzamsal alan yöntemleri ile alan dönüşüm yöntemlerinden faydalanılmaktadır. Geleneksel yöntemlerin çoğu görüntüde gürültü giderme konusunda oldukça

iyi bir performans elde etmelerine rağmen, elle ayarlanan parametrelere sahip olması ve eğitim aşamasında en iyileme yöntemlerine ihtiyaç duyulması nedenleriyle son zamanlarda derin öğrenme yöntemleri kullanılmaya başlanmıştır. Derin öğrenme yöntemleri gürültüyü gidermek için istatistiksel hesaplamalar yaparak orijinal görüntüyü elde etmeyi amaçlamaktadır. Kullanılan yöntemle bağlı olarak yapılan tekrarlı hesaplamalar sayesinde orijinal görüntü elde etme başarısı artmaktadır. Yapay sinir ağları, GPU alanında gelişmeler ve diğer yöntemlere göre daha iyi performans sergilemelerinden ötürü popülerlik kazanmış, yapılan çalışmalarda daha performanslı ve değişik verilerle çalışabilecek yöntemler geliştirilmeye çalışılmıştır. Ancak, yapılan çalışmalarda derin öğrenme yöntemlerinin, değişik gürültü seviyelerine ve türlerine karşı esnek olmadığı için yüksek seviyede gürültüyle karşılaştıklarında performansları ve başarıları yeterli seviyede olmadığı görülmektedir [1-6].

### 1.1. Görüntülerdeki Gürültü Türleri

Gürültü, istenmeyen işaretlere verilen genel bir ad olup, görüntüleri bulanıklaştırıcı, kirlenici, bozucu etkilere sahiptir. Görüntüye etkime şekillerine göre gürültü görüntü üzerinde farklı dağılımlara sahiptir. Bazı gürültü bileşenleri düzgün dağılımlı olmayan uzamsal özellikler göstermektedirler. Değişik tipteki gürültüler görüntü üzerinde farklı dağılımlara sahiptir. Toplamsal Beyaz Gauss Gürültüsü, görüntü verileri bir kanalda iletilirken, görüntüye ait işaretlerden bağımsız olarak hareket eden ve kendiliğinden ortaya çıkan istenmeyen işaretlerden etkilenmektedir. Görüntülerdeki gürültü genelde toplamsal beyaz Gauss gürültüsü (AWGN) olarak ifade edilmektedir. Gauss Gürültüsü aşağıdaki denklem ile ifade edilmektedir. Görülen değer  $v(i)$  ile gürültüden arındırılmış değer  $u(i)$  ile gürültü de  $n(i)$  ile gösterilir.

$$v(i) = u(i) + n(i) \quad (1)$$

Diğer bir gürültü türü olan çarpımsal gürültüsü daha çok sentetik açıklıklı radar, sonar, ultrason ve lazer görüntülerde ortaya çıkmaktadır. Benek gürültüsü, çarpımsal bir gürültü çeşididir. Çarpımsal gürültü görüntüdeki piksel değerine bağlı olarak; düşük değerli piksellerde küçük miktarlarda gürültü değeri ve yüksek değerli piksellerin daha büyük miktarlarda gürültü değeri içerdiği anlamına gelmektedir [7]. Çarpımsal bir gürültüyü aşağıdaki denklemle ifade etmek mümkündür.

$$F(x, y) = G(x, y) \cdot E(x, y) \quad (2)$$

Bu denklemde  $F(x, y)$  gürültülü görüntüdeki piksel değerleri,  $G(x, y)$  gürültüsüz görüntüdeki piksel değerleri ve  $E(x, y)$  her piksele eklenen çarpımsal gürültünün şiddetini ifade eder [8].

Diğer bir gürültü türü olan Nicemleme (quantization) gürültüsü, analog bir sinyalin dijital bir sinyale

dönüştürüp daha sonra tekrar analog bir sinyale çevrildiğinde oluşan bozulmaya veya sürekli bir sinyalin ayırık olarak ifade edilmesi sırasında oluşan bozulmaya verilen isimdir. Görüntülerde nicemleme gürültüsü görüntü elde etme sırasında meydana gelmektedir. Az bir nicemleme düzeyine sahip bir görüntünün genel görünümü, dalgalı olarak tanımlanabilir, yoğun renkteki alanlardaki ince dereceler kaybolmaktadır. Şekil 1'de gösterilen San Francisco görüntüsünün 4 bit ile nicemlemesi sonucu gökyüzündeki merdiven basamaklarına benzer görüntüler yer almaktadır [9]. Daha önce pürüzsüz olan görüntülerin yerini, birbirinden ayrılmış farklı bölgeler almıştır.




Şekil 1. Görüntünün 4 bit ile nicemlemesi [9]

Gürültü değişik metotlarla; medyan mutlak sapma [10], blok tabanlı sapma [11] ve temel bileşenler analizi ile [12] bulunmaktadır. Görüntülerde gürültünün gidermenin temel amacı, gürültülü veriden temiz görüntünün elde edilmesidir. Kenar ve dokular yüksek frekanslı bileşenler olduğundan, bunları gürültüden arındırma sürecinde, gürültüyü ayırt etmek zordur ve gürültüden arındırılmış görüntüler bazı ayrıntıları kaybedebilmektedir.

Görüntü kalitesi matematiksel olarak, sinyalin gürültüye oranı hesaplanarak bulunabilir. Görüntü kalitesini ölçmek için MSE, MAE, PSNR, FSIM, SSIM, RMSE gibi yöntemler bulunmaktadır. Gürültü giderme sonucu görüntünün kalitesi değerlendirmek, görüntü yapısı ve doku benzerliğini farklı şekilde ölçümlemek için farklı yöntemler kullanılmaktadır. Yapılan çalışmalar PSNR ve SSIM yöntemlerinin Gauss gürültüsüne karşı daha duyarlı olduğunu ortaya koymuştur [13]. Bu yüzden görüntülerde gürültü giderme yöntemlerinin doğruluğunu değerlendirmek için daha çok Tepe Sinyali Gürültü Oranı (PSNR) ve Yapısal Benzerlik Endeksi (SSIM) kullanılmaktadır [14].

Tuz karabiber gürültüsü, görüntülerde oluşan temel gürültülerden birisi olup, görüntü üzerine rastgele olarak dağıtılan beyaz ve siyah pikselleri ifade eder [15]. Görüntülerde ayrıca Gaussian, Benek ve Poisson

gürültüleri meydana gelebilmektedir. Görüntülerde meydana gelen gürültülerin görüntüyü nasıl etkilediği Şekil 2'de gösterilmektedir. Gauss gürültüsü genelde yetersiz aydınlatma, Benek gürültüsü ultrason, lazer veya sonar sebebiyle, Poisson gürültüsü ışığın yansımaları, Tuz karabiber gürültüsü çevredeki toz veya cihaz kaynaklı olarak görüntülerde bozulmaya neden olmaktadır.



Şekil 2. Görüntülerde bozulmaya neden olan gürültü türleri

## 1.2. Görüntülerde Bozulmanın Sebepleri

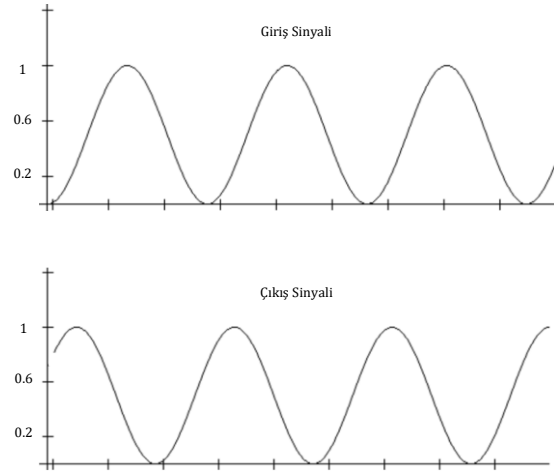
Video ve görüntüdeki gürültü, bilgisayarlı görü alanındaki temel sorunlardan biridir. Video ve görüntülerde gürültüye yol açan nedenler aşağıdaki bölümlerde açıklanmaktadır.

### a) Görüntü Aktarma Sırasında Verilerin Bozulması

İletim ortamının çeşidi, iletişim sağlayan cihaz mesafesi ve verinin iletim hızı görüntü kalitesini etkilemektedir. Veri iletimindeki bozulmalar; zayıflama, sınırlı bant genişliği, gecikme bozulması ve gürültü şeklinde ortaya çıkabilmektedirler [16].


- Zayıflama: Kablo uzunluğu, merkeze olan uzaklık, ortamın direnci gibi nedenlerden dolayı sinyal gücü azalmaktadır. Sinyaldeki zayıflama ve kazanç, desibel (dB) ile ifade edilmektedir.
- Sınırlı bant genişliği: Bant genişliği, ağ performansını belirleyen ölçütlerden birisidir. İletim zamanı, mesaj boyutunun bant genişliğine oranını ifade eder ve bant genişliği düşük olan hattın mesaj iletim zamanı yüksek olmaktadır.
- Gecikme Bozulması: Kaynak sinyali ile, hedefe ulaşan sinyalin ilerleme hızlarında farklılık oluşursa hedefte sinyalin şekli değişmektedir. Şekil 3'de gecikme bozulması yaşanan giriş

sinyalinin, gecikmesi ile çıkışta gözlenen durumu gösterilmektedir.



Şekil 3. Sinyallerdeki gecikme bozulması

- Gürültü: Sinyalde bozulma yapan etkilerin tümüne verilen isimdir. Sinyal termal gürültü, indüklenen gürültü, karışma ve darbe gürültüsü ile bozulabilmektedir. Görüntü yakalama ve aktarma sırasında veriler gürültüden etkilenip, görüntünün kalitesi düşmektedir. Şekil 4'de gürültünün orijinal sinyali nasıl etkilediği gösterilmektedir.



Şekil 4. Sinyallerdeki gürültü [17]

### b) Görüntü Yakalama Sırasında Verilerin Bozulması

Video görüntüleri, periyodik gürültülerle bozulabilmektedirler. Dijital videolar genellikle, görüntü yakalama işlemi sırasında kameranın donanımı veya işleme yazılımı tarafından ortaya çıkan sorunlar nedeniyle görsel olarak bozulabilmektedir [18].

## II. MATERYAL VE YÖNTEM

Görüntülerde gürültü giderme aşamasında zaman içerisinde geleneksel gürültü giderme yöntemleri, makine öğrenmesi yöntemleri, derin öğrenme yöntemleri ve diğer matematiksel yöntemler kullanılmıştır. Geleneksel yöntemlerden elde edilen tecrübeler ışında makine ve derin öğrenme yöntemlerinin donanım kullanma kabiliyetleri eklenerek yeni yöntemler geliştirilmiştir. İlerleyen bölümlerde geliştirilen geleneksel gürültü giderme yöntemleri ile derin öğrenme yöntemleri hakkında bilgi verilip bu alanda yapılan literatür çalışmaları açıklanacaktır.

### III. GELENEKSEL GÜRÜLTÜ GİDERME YÖNTEMLERİ

Görüntülerde gürültü giderme için kullanılan geleneksel yöntemler; alan dönüşüm yöntemleri ve uzamsal alan yöntemleri olarak iki gruba ayrılmaktadır [19]. Geleneksel yöntemler ile derin öğrenme yöntemleri Şekil 5'de gösterildiği şekilde sınıflandırabilmektedir.

#### 3.1. Uzamsal Alan Yöntemleri

Geleneksel yöntemlerden uzamsal alan filtrelemesinde, görüntü çerçevelere ayrılarak her çerçeveye ayrı ayrı filtreleme yapılmaktadır. Video üzerindeki her bir görüntü bir önceki görüntünün hareket etmesi, ekrandan bazı nesnelerin çıkması ve yeni nesnelerin ekrana girmesi ile oluşmaktadır. Bu yöntemde hem görüntülerde hem de video karelerindeki benzer çerçeveler bulunup gruplanarak, bu çerçevelerdeki gürültüler azaltılmaya çalışılır. Bu yöntemde kullanılan metotlar aşağıda belirtilmektedir.

##### a) Uzamsal Alan Filtreleme

Uzamsal alandaki gürültüyü gidermek için doğrusal filtreler kullanılmakta ancak görüntü dokularında kayıplar meydana gelebilmektedir. Gauss gürültüsü giderimi için ortalama filtreleme de [20] kullanılabilir olup, yüksek gürültülü görüntülerde bu filtre görüntüyü aşırı düzgün hale getirebilmektedir [21]. Bu durum için, Wiener filtrelemesi [22] kullanılabilir, ancak bu filtre görüntüdeki keskin kenarları bulanıklaştırabilmektedir. Medyan filtreleme [23] ve ağırlıklı medyan filtreleme [24] gibi doğrusal olmayan filtreler kullanılarak, gürültü seviyesi önceden bilinmeden gürültü giderilebilmektedir. Doğrusal olmayan, kenarı koruyan ve gürültü azaltıcı bir yumuşatma filtresi olarak Bilateral filtreleme [25],

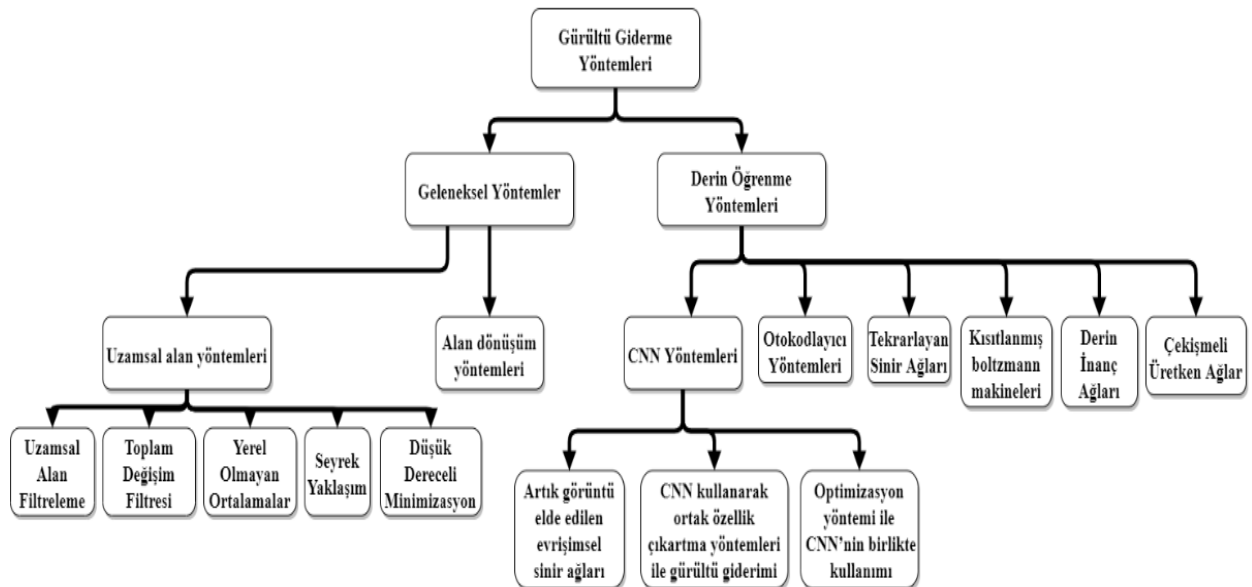
görüntülerin bozulmasını önlemek için yaygın olarak kullanılmaktadır. Her pikselin yoğunluk değeri, yakındaki piksellerden alınan ağırlıklı ortalama yoğunluk değerleriyle değiştirilmektedir.

##### b) Toplam Değişim Filtresi

Varyasyon modelleri matematiksel görüntü işleme ve bilgisayarla görme alanında aktif araştırma alanlarından biri olmaya devam etmektedir [26]. Toplam varyasyon tabanlı görüntü restorasyon modelleri ilk olarak Rudin, Osher ve Fatemi (ROF) tarafından kenar koruma görüntü gürültü giderme konusundaki yapılan çalışmalarda ortaya çıkmıştır [27]. Eşyönsüz doku filtresi ROF modeli kullanılarak geliştirilen görüntü kalitesini arttırmaya yönelik kullanılan bir yöntemdir [28]. Kısmi diferansiyel denklemler tabanlı kenar koruma, gürültü gidermenin iyi bilinen örneklerinden biri olup, gürültü ortadan kaldırırken görüntülerdeki kenarları korumak için tasarlanmıştır. Yıllar içinde, ROF modeli diğer birçok görüntü restorasyon görevine genişletilip ve performansını artırmak için çeşitli şekillerde değiştirilmiştir. Bu gelişmelerden bazıları yeni algoritmalara, bazıları ise yeni modellere ve teorilere yol açmıştır [29]. Bu modeller, görüntülerde gürültü giderme, bulanıklık giderme, kör gürültü giderme ve görüntü iç boyama gibi görüntü restorasyon problemlerinde kullanılmaktadır [30].


##### c) Yerel Olmayan Ortalamalar

Önemli detayların ve dokuların kaybolmasını engellemeyi amaçlayan bu yöntemde, görüntü çeşitli ölçeklerde alt parçalara ayrılıp görüntüye ait piksel değerlerinin ortalaması alınmaktadır [31].



Şekil 5. Görüntülerde gürültü azaltmada kullanılan geleneksel ve derin öğrenme yöntemlerinin sınıflandırılması

Hızlı Blok Eşleştirme ve 3 Boyutlu Filtreleme tekniğinde sabit görüntüler ve videoda benzer kareleri gruplayarak filtreleme yapmak için blok eşleştirme kullanılmaktadır. Bir çerçevenin, referans bir çerçeve ile benzerliği, belirtilen bir eşiğin altına düşerse gruplanıp, sonrasında 3 boyutlu filtre uygulanmaktadır [32]. Blok eşleme algoritması daha az hesaplama gerektirmektedir. Görüntünün içindeki bloklar kayar bir şekilde işlenip, işlenmiş olan bloğa benzer diğer bloklar aranarak blok eşleştirme yapılmaktadır [33]. Bu prosedürü tekrarlayan sürgülü pencereler (bloklar) için devam ettirdikten sonra, nihai tahmin, üst üste binen tüm blok tahminlerinin ağırlıklı ortalaması olarak hesaplanmaktadır. Gürültü kademeli olarak arttığında, BM3D'nin gürültü giderme performansı düşük kalmakta olup, özellikle düz alanlarda bozulmalar ortaya çıkmaktadır [34]. Bu yöntem görsel açıdan kaliteli bir sonuç elde etse de evrişimli sinir ağı (CNN) bazlı yöntemler BM3D yöntemine göre daha başarılı sonuçlar elde etmektedir [3]. Şekil 6'da Lena görüntüsünde gürültü giderme işlemi için blok olarak eşleştirilen benzer karelerin gruplanarak filtrelenmesi gösterilmektedir.



Şekil 6. Blok eşleme ve 3 Boyutlu filtreleme ile görüntülerde gürültü giderme işlemi [35]

VBM3D [36], VBM4D [37] blok eşleme ve 3 boyutlu filtreleme ile videolarda gürültüyü gidermek için kullanılmaktadır. VBM4D yöntemi ile nesnelerin hareketleri takip edilerek, bir önceki ve sonraki konumları bulunup, nesneler aynı ise gruplanarak filtreleme uygulanmaktadır. Bu yöntemde hareket vektörü ile cisimlerin takibi yapılmaktadır [38].

Yerel olmayan gürültü giderme modelleri görüntü restorasyon problemlerinde; gürültü giderme, iç boyama, ekleme yapma, görüntü sentezi için kullanılmaktadır. Bu modeller, görüntüleri bir dizi yerel komşuluk veya yama ile temsil eder ve gürültüyü tahmin etmeye çalışır. En Büyük Artçıl Kestirim (MAP) gürültülü görüntüden temiz bir yamayı tahmin etmek için kullanılabilir [39]. Bu yöntemde istatistiksel veriler kullanarak görüntü üzerindeki bir değer tahmini yapılmaktadır. Gerçek gürültü giderme problemleri için, hipotez uzayı genellikle çok büyük veya sonsuzdur. MAP hipotezlerini bulmak, optimizasyon problemini çözme gerektirdiğinden, gürültü tahmini için yapılan işlemler daha kısa

sürmektedir [40]. Bu yöntem kenar ve dokuların korunmasında etkili bir çözüm sunmaktadır.


#### d) Seyrek Yaklaşım

Sınıflandırma problemleri bilinmeyen bir nesneyi doğru sınıfa atamayı amaçlamaktadır. Seyrek yaklaşım metodunda seyrek gösterim vektörü kullanılarak nesnelerin hangi sınıfa ait olduğu bulunmaktadır [41]. Bu yöntem görüntü işlemede kullanılarak görüntüdeki bazı özelliklerin daha kolay ortaya çıkmasını sağlamaktadır [42]. Destek Vektör Makineleri [43] ve Çekirdek Tabanlı Seyrek Temsil [44] bu yaklaşımı kullanan önemli yöntemlerdir. Yerel olmayan merkezi seyrek temsil (NCSR) modeli, yaygın olarak kullanılan görüntü gürültü giderme yöntemlerinden biri olup, yerel olmayan merkezi seyrek temsil hem pürüzsüz hem de dokulu bölgelerin yeniden yapılandırılmasında başarılı sonuçlar elde etmektedir [45]. Ancak seyrek yaklaşım tekniklerinin yinelemeli sözlük öğrenme ve bilinmeyen seyrek katsayıların yerel olmayan tahminleri, hesaplama süresini uzatmakta ve uygulamalarda bu yöntemin kullanılabilirliğini sınırlamaktadır.

#### e) Düşük Dereceli En İyileme

Bu modelde, seyrek gösterim modelinden farklı olarak, benzer yamalar gruplanarak bir matris oluşturulmaktadır. Bu matrisin her bir sütununda, benzer yamalara ait veriler tutulmaktadır. Gürültü giderimi için düşük dereceli yaklaşımlar; düşük sıralı matris çarpanlarına dayalı yöntemler [46] ve nükleer norm en iyilemesine dayalı yöntemler (NNM) [47] olarak iki gruba ayrılmaktadır. Düşük sıralı matris çarpanlara ayırma, iki giriş arasındaki etkileşimleri bulmak ve ikili verileri analiz etmek için kullanılmaktadır [48]. Düşük dereceli model, gürültü gidermede iyi sonuçlar elde etmekte [49], ancak çok düşük veya çok yüksek gürültü değerlerinde ayrıntıların kaybolmasına neden olmaktadır.

Tekil Değer Ayrışımı (SVD), bir matrisi farklı boyutlara bölerek boyut azaltmayı amaçlamaktadır. Şekil 7'de verilerde Tekil Değer Ayrışımı yöntemi ile boyut azaltma işlemi gösterilmekte olup, matris 3 parçaya ayrılmıştır, orijinal veri bu matrisler kullanılarak elde edilebilmektedir [50].



Şekil 7. Verilerde Tekil Değer Ayrışımı yöntemi ile boyut azaltma [51]

K-Ortalamları kümeleme tekil değer ayrışımı (K-SVD), k-ortalamları kümeleme yönteminin geliştirilmiş hali olup, giriş verilerini geçerli sözlüğe dayanarak seyrek olarak kodlayıp, sözlükteki atomları verilere daha iyi uyacak şekilde güncelleyerek yinelemeli olarak çalışmaktadır [52]. K-SVD, görüntü işleme, ses işleme, biyoloji ve belge analizi gibi uygulamalarda yaygın olarak kullanılmaktadır.

Nükleer norm en iyilemesine dayalı yöntemler, tüm tekil değerleri eşit şekilde küçülterek matris sırasını yaklaşık olarak tahmin etmek için kullanılmaktadır. Nükleer norm en iyilemesine dayalı yöntemler baz alınarak, farklı boyutlardaki tekil değerlere uyarlanan ağırlık atayabilen ve yumuşak bir eşik yöntemi kullanan bir yöntem (WNNM) geliştirilmiştir. WNNM'nin gelişmiş gürültü giderme performansına sahip olup, yüksek gürültüde başarılı olması, yapay zekâ, görüntü işleme, örüntü tanıma, bilgisayarla görme gibi alanlarda yaygın olarak kullanılmasına imkân sağlamıştır [53]. Düşük dereceli en iyileme yöntemi diğer gürültü azaltma yöntemlerinden daha iyi performans gösterse de yinelemeli artırım adımının işlem süresi uzun olmaktadır.

### 3.1. Alan Dönüşüm Yöntemleri

Dönüşüm tabanlı gürültü giderme yöntemleri, dönüşüm alanındaki bir sinyalin gürültüden daha seyrek gösterime sahip olduğu varsayımına dayanmaktadır [54]. Alan dönüşüm yöntemleri ilk olarak Fourier dönüşümü kullanılarak geliştirilmiştir. Zaman içerisinde kosinüs dönüşümü, dalgacık alanı yöntemleri [55], gibi çeşitli dönüşüm alanı yöntemleri ortaya çıkmıştır. Verilen gürültülü görüntülerde dönüştürme araçları olarak bağımsız bileşen analizi [56] ve temel bileşen analizi [12] fonksiyonları kullanılmıştır. Bağımsız bileşen analizi yöntemi normal dağılıma sahip olmayan verilerin gürültü azaltmasında başarıyla uygulanmıştır. Bu yöntemin dezavantajı, yüksek hesaplama maliyeti olup, kayan pencereler kullanıldığı için, aynı kareden gürültüsüz bir görüntü örneği gerektirmesidir.

Alan dönüşüm yöntemlerinden dalgacık alanı yöntemleri görüntülerde gürültü giderme alanında basit algoritmalar ile başarılı sonuçlar elde etmektedir. [57] Bu alanda geliştirilmiş yöntemleri 4 kategoride inceleyebiliriz.

1. Doğrusal filtreler, gürültü giderme için kullanılan sayısal filtrelerdir [58]. Gauss gürültüsünü azaltmak için uyarlamalı bir doğrusal filtre türü olan Wiener filtresi tercih edilmektedir. Bu filtre statiksel bir yaklaşımla hata karelerinin ortalamasını en aza indirmeye çalışarak filtrelenmiş görüntüyü üretmektedir
2. Dalgacık Dönüşümü gürültü gidermede alanında, doğrusal olmayan katsayı eşikleme tabanlı

yöntemler de kullanılmaktadır. Gauss gürültüsü dalgacık alanında küçük değerlerle temsil edilme eğilimindedir ve belirli bir eşik altındaki katsayıları sıfıra ayarlayarak (sert eşikleme) veya eşik üzerindeki katsayıların eşik mutlak değeri ile küçültüldüğü yumuşak eşikleme teknikleri ile gürültü giderilmektedir [59]. Dalgacık büzülme literatürünün çoğu, görüntüye uyarlanabilen veya uyarlanamayan optimal eşik seçme yöntemlerine dayanmaktadır. VisuShrink yaklaşımı, tüm dalgacık detay katsayıları için tek bir eşik değeri kullanmaktadır [60]. Bu eşik, ilave Gauss gürültüsünü ortadan kaldırırken, aşırı düzgülü görüntüler ortaya çıkabilmektedir. BayesShrink algoritması, her dalgacık alt bandı için farklı bir eşik kullanıldığı, uyarlanabilir bir yaklaşımdır [61].

3. Dalgacık katsayısı yaklaşımında, Dalgacık Dönüşümünün çoklu çözünürlüklü özelliklerinden yararlanır. Bu teknik, sinyali çoklu çözünürlüklerde gözlemleyerek farklı çözünürlüklerde sinyalin yakın korelasyonunu tanımlar. Bu yöntem gürültüleri gidermede başarılı olup, hesaplama açısından karmaşıktır. Dalgacık katsayılarının modellenmesi deterministik veya istatistiksel yöntemlerle olabilmektedir. Deterministik modelleme yöntemi, dalgacık katsayılarını temsil eden düğümler ile bir ağaç yapısını oluşturmaktadır.
4. Gürültü sinyalini ayrıştırmak için, Kırılmamış Dalgacık Dönüşümü (UDWT) de kullanılmıştır [62]. Yapılan bir çalışmada, azaltılmış bir dönüşüm yerine kırılmış bir dönüşüm kullanılarak eşiklemenin, gürültü giderme uygulamalarında sonucu 2,5 dB'den fazla iyileştirebileceği gösterilmiştir [63]. Bu yöntemin UDWT kullanımının gürültü gidermede başarısı yanında, bir hesaplama yükü de getirmektedir.

Fourier tabanlı dönüşüm yöntemlerinden birisi olan Ayrık Kosinüs Dönüşümü (DCT) filtreleme algoritması, görüntülere sabit veya uyarlanabilir şekilde seçilen bloklar halinde uygulanmaktadır. Ayrıca DCT yüksek veri sıkıştırma oranlarında yüksek kalite elde edebilmektedir [64]. DCT tabanlı filtreleme yönteminde dikey dönüşüm alanındaki bir bileşen büyük bir mutlak değere sahipse, bilgi olarak değerlendirilmekte; eğer bileşen bir eşikten sınıra yakın bir genliğe sahipse, o zaman gürültü olarak değerlendirilmektedir [65]. DCT tabanlı filtreleme görüntülerde gürültü giderme, uygun doku koruma ve kenar ve detayların korunmasını sağlamaktadır. Ancak gürültü giderimi için kullanılan yöntemlerin içinde bu yöntemin işlemci gereksinimi oldukça yüksek olmaktadır. Şekil 8'de 3 Boyutlu Ayrık Kosinüs Dönüşümü ile sıkıştırılan görüntünün tekrar oluşturulması gösterilmektedir.



**Şekil 8.** 3 Boyutlu Ayırık Kosinüs Dönüşümü ile görüntü sıkıştırma ve geri oluşturma [35]

Görüntülerde gürültü giderme için kullanılan yöntemlerin seyrek sinyal eşleştirme ve blok eşleştirme özelliklerine göre uyarlanabilir veya sabit olması ile blok eşleştirme durumları Tablo 1'de kıyaslanmaktadır.

**Tablo 1.** Görüntülerde gürültü giderme için kullanılan geleneksel yöntemlerin kıyaslanması [3]

Yöntem	Seyrek Sinyal Modeli		Blok Eşleştirme
	Sabitlik	Uyarlanabilirlik	
fBM3D [42]	✓		✓
3D DCT [43]	✓		
KSVD [47]		✓	
VBM3D [48]	✓		✓
VBM4D [48]	✓		✓

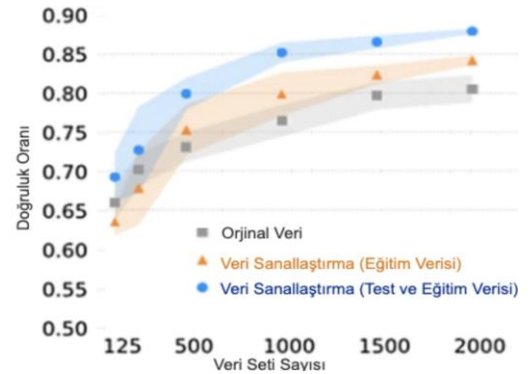
#### IV. DERİN ÖĞRENME YÖNTEMLERİNİN GÜRÜLTÜ GİDERME ÜZERİNDE KULLANILMASI

Görüntü üzerindeki gürültüleri gidermek için farklı derin öğrenme yöntemleri kullanılmaktadır. Kullanım kolaylığı, daha az kaynak tüketimi ve değişken gürültü türlerine uyarlanabilir oldukları için yapay sinir ağları görüntülerde gürültü azaltmak için tercih edilmektedir. Mevcut sinir ağı tabanlı yöntemlerin çoğu evrimsel sinir ağı tabanlı bir yaklaşım izlemektedir. Görüntülerde gürültü azaltmak için, derin öğrenme yöntemlerinden ilk olarak CNN mimarileri kullanılmaya başlanmıştır [66]. CNN tabanlı gürültü azaltma yöntemleri genel olarak diğer yöntemlere göre daha başarılı sonuç elde etmektedir [67, 68]. CNN ağlarında eklenen katmanlar yüksek düzey özelliklerin açığa çıkarılmasında ve görüntünün anlamlandırılmasında kullanılmaktadır.

Görüntülerde gürültü gidermenin başarısı orijinal görüntü ile gürültü giderme sonrası elde edilen görüntünün kıyaslanması ile ölçülebilmektedir. Ancak, gerçek hayatta çoğu zaman eşleştirilmiş gürültülü ve temiz görüntüler bulunmamaktadır. Bu durum eğitim ve test verilerini elde edilmeyi zorlaştırmaktadır. Tomografi, MR, ultrason, mikroskopik floresan

görüntüleri, uydu görüntüleri bu tür görüntüleme örnekleridir. Denetimli öğrenme, bozuk görüntü ve temiz görüntü çifti içeren bir regresyon modelidir. CNN modelleri görüntü çiftlerini kullanan ileri beslemeli evrim sinir ağlarıdır. DnCNN [69] gibi CNN tabanlı yöntemler, ek beyaz Gauss gürültüsünü kaldırmak için eşleştirilmiş temiz ve gürültülü verilerle derin bir sinir ağını eğiterek gürültüden arındırılmış görüntüler elde etmektedir. Denetimsiz öğrenme yöntemlerinde eğitim için temiz görüntü verisi olmadan veya gürültülü görüntü verisi olmadan gürültü doğrudan verilerden öğrenilerek giderilmektedir. Noise2Noise (N2N) [70], eşleştirilmiş bozuk gözlemlerden öğrenilen modeller gürültüyü ortadan kaldırmak için uygulanmaktadır. Noise2Self (N2S) [71] ve Noise2Void (N2V) [72], kör gürültü gidermek ve bir regresyon modeli eğitmek için kendi kendini denetleme stratejisini benimsemiştir. Bu, eğitim için gürültülü bir veri kümesi veya bir çift temiz görüntü, örneğin biyomedikal görüntü verisi bulamadığımız veri kümeleri için kullanılmaktadır.

Derin öğrenme modellerinin eğitimi modelin başarısında önemli ölçüde etkilidir. Gürültü giderme konusunda yapılan çalışmalarda artırılmış veri kümeleri ile çalışmak modelin performansını etkilemektedir [73]. Az veri ile yapılan çalışmalarda modelin ezberleme problemi ile karşılaşmaktadır. Görüntü verileri üzerinde döndürme, çevirme, ölçeklendirme, kırpma yöntemleri kullanılarak veri artırımı yapılmaktadır. Bir sınıflandırma çalışmasında test ve eğitim verisinin artırılmasının modelin doğruluk oranını etkilediği Şekil 9'da görülmektedir [74].



**Şekil 9.** Veri seti sayısının modelin doğruluk oranına etkisi [74]

#### 4.1. CNN Yöntemlerinin Gürültü Gidermede Kullanımı

Görüntülerde gürültü giderme için kullanılan yöntemler genel olarak ImageNet yarışmasındaki mimarilerden esinlenmektedir. ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC), CNN mimarilerinin gelişimi ve tanınmasında önemli bir yere sahiptir [75]. LeNet CNN mimarisi, el yazısıyla yazılmış rakam tanıma başarıyla olmuştur [76]. Ancak, LeNet mimarisi kaybolan eğim sorunu, sigmoid [77] ve tanh [78] gibi aktivasyon fonksiyonlarının hesaplama maliyeti sorunlarına

sahiptir. 2012 yılında AlexNet [79] ile, grafik işlem birimi kullanılmış, rastgele kırma ile aşırı uyum sorunları çözülmüştür. Sigmoid yerine ReLU [80] kullanımı, değişken eğim inişinin hızını iyileştirmektedir. Ayrıca veri artırma yöntemi ile aşırı uyum sorunu çözülmüştür. AlexNet iyi bir performans elde etmesine rağmen, büyük konvansiyonel katmanlardan dolayı önemli bellek kullanımına sahiptir. Bu sebeple, akıllı kameralar gibi gerçek dünyadaki uygulamalarda kullanımını sınırlı kalmıştır. 2014-2016 döneminde, yazılım performansını artırmak ve hesaplama maliyetlerini düşürmek için küçük filtreli daha derin ağ mimarileri tercih edilmiştir. VGG [81], 2014'teki ImageNet yarışmasını kazanmak için küçük çekirdek boyutlarıyla daha fazla evrimsel sinir ağı oluşturmuştur. GoogLeNet [82], görüntü uygulamalarının performansını iyileştirmek için genişliği artırmıştır. GoogLeNet ayrıca parametre sayısını ve hesaplama maliyetini azaltmak için büyük bir evrimsel çekirdeği iki küçük evrimsel çekirdeğe dönüştürüp, başlangıç modülünü [83] kullanmıştır. GoogLeNet 22 katmanlı bir yapıya sahip olup, ardışık konvolüsyon ve havuzlama katmanları yerine birbirine bağlı modüller kullanan bir yapıya sahiptir [84]. VGG ve GoogLeNet yöntemleri görüntü uygulamaları için etkili olsa da ağ çok derin ise, eğimin kaybolmasına; ağ çok geniş ise, aşırı uyum sorununa neden olmaktadır. Bu sorunları çözmek için ResNet mimarisi [85] önerilmiştir. ResNet mimarisinde her bloğa artık öğrenme işlemi eklemiştir. Çekişmeli Üretken Ağlar (GAN) [86] üretken ve ayırt edici ağlardan oluşmaktadır. Üretken ağ, girdi verilerine göre örnekler oluşturmak için; ayırt edici ağ hem girdi örneklerinin hem de üretilen örneklerin doğruluğunu değerlendirmek için kullanılmaktadır. GAN yüz tanıma [87] ve karmaşık gürültülü görüntülerde, gürültü gideriminde kullanılmaktadır. Yukarıda bahsedilen evrimsel sinir ağları, görüntülerde gürültü giderimi için temel oluşturan ağlardır. Bu mimariler kullanılarak değişik gürültü giderme yöntemleri oluşturulmuştur.

#### Görüntülerde Gürültü Giderme İçin CNN Yönteminin Kullanımı

Görüntülerde gürültü giderimi için derin öğrenme mimarileri ilk olarak Zhou ve arkadaşları tarafından kullanılmıştır [88]. Hesaplama verimliliğinin artırılması ve performans arasında bir denge kurmak için ileri beslemeli ağlar önerilmiştir [89]. İleri beslemeli ağ, verilen gürültülü görüntüyü, evrimsel benzer olarak Kuwahara filtreleri ile düzeltmektedir. Daha sonra, ağın doğruluğunu artırmak ve gürültüden giderme performansını artırmak için en iyileme algoritmaları kullanılmıştır. Yeni bir ağ mimarisi tasarlanarak ağ derinliği artırılmış ve aktivasyon işlemi değiştirilerek gürültü ortadan kaldırılmıştır. Hücresel sinir ağları (CENN), görüntülerde gürültüyü gidermek için şablonlu düğümler kullanılmaktadır [90]. Önerilen bu yöntem, başarılı gürültü giderme sonuçları elde

edebilmesine rağmen, parametrelerinin elle olarak ayarlanması gerekmektedir. Bu sorunu çözmek için azalan eğim inişi geliştirilmiştir. Hesaplama maliyetinin düşürmek için de evrimsel sinir ağları kullanılmaya başlanmıştır. Gürültü Gideren Evrimsel Sinir Ağları modeli konvolüsyon, toplu normalleştirme, düzeltilmiş doğrusal birim ve artık öğrenme ile görüntülerde gürültü giderme, süper çözünürlük ve JPEG görüntü bloklarında gürültü giderimi için kullanılmıştır [91]. Eşleştirilmemiş gürültülü görüntüleri işlemek için, çekişmeli üretici ağ (CBDNet) [92], biri gerçek gürültülü görüntünün gürültüsünü tahmin etmekten, diğeri ise gizli temiz görüntüyü elde etmekten sorumlu olan iki alt ağ tarafından verilen gerçek gürültülü görüntüden gürültüyü kaldırmıştır. Daha karmaşık bozuk görüntüler için, bulanıklık çizgisini ve gürültüyü tahmin etmek ve yüksek çözünürlüklü bir görüntüyü elde etmek için derin bir süper çözünürlük (DPSR) yöntemi [93] geliştirilmiştir.

#### *4.1.1. Gürültü gidermede kullanılan CNN mimarileri*

Görüntülerde gürültü giderme sırasında evrimsel sinir ağı modelini oluştururken, ek beyaz gürültülü görüntüler yaygın olarak kullanılmaktadır. Ek beyaz gürültülü görüntüler Gaussian, Poisson, tuz ve karabiber ve çarpımsal gürültülü görüntüleri içermektedir [94]. Görüntülerden gürültüleri gidermek için CNN ağları kullanılarak 3 farklı yöntem uygulanmaktadır.

##### a) Artık görüntü elde edilen evrimsel sinir ağları

Bu yöntemde gürültü gideren CNN mimarisi, normal CNN'den farklı olarak; sonuç verisinde, orijinal görüntüye ait parçalar yerine gürültü görüntü elde edilmektedir. Gürültü görüntü orijinal görüntüden çıkartılarak temiz görüntü elde edilmektedir [95]. Bu sistemin oluşturulması için farklı mimariler aşağıdaki yöntemlerle tasarlanmaktadır.

- CNN'nin çoklu girişlerindeki özellikleri birleştirmek: Bu yöntemde farklı ağlardan çok sayıda girdi sağlayabilmek için girdi verisinin farklı perspektifleri kullanılabilir [96].
- Kayıp fonksiyonunun değiştirilmesi: Farklı kayıp fonksiyonları tasarlanarak mimari hızı değiştirilebilmektedir.
- CNN'nin derinliği veya genişliğini değiştirmek: Ağın derinliğini veya genişliğini artırarak gürültü giderme performansını iyileştirmek için alıcı alan boyutu büyütülebilmektedir [97].
- CNN'lere yardımcı eklentiler koymak: CNN'nin başarısını artırabilmek için aktivasyon fonksiyonu, genişletilmiş evrim, tam bağlı katman ve havuzlama işlemleri gibi eklentiler uygulanabilmektedir [98].



- CNN'de atlama bağlantıları veya kademeli işlemleri kullanmak: Derin katmanlarda tamamlayıcı bilgi sağlamak için atlama bağlantıları [99] veya kademeli işlemler [100] kullanılabilir.
- b) CNN kullanarak ortak özellik çıkartma yöntemleri ile gürültü giderimi

Bu yöntem, gürültü giderimi sırasında CNN yöntemi ile birlikte başarı elde etmiş mimariler birlikte kullanılmaktadır. Bir çalışmada dalgacık dönüşümü ve U-ağını kullanılmaktadır [101]. Bu yöntemi kullanan bir çalışmada yüksek boyutlu gürültülü görüntüler için, CNN ve boyutsal indirgeme yönteminin kombinasyonu kullanılmaktadır [102]. Bir diğer çalışmada görüntülerde gürültü giderimi için temel bileşen analizi içeren bir CNN kullanılmıştır [103]. Bu mimarinin ilk adımında, öznelik çıkarmak için evrişim işlemi ikinci adımda, elde edilen özelliklerin boyutunu azaltmak için Temel Bileşen Analizi kullanılmıştır. Üçüncü adımda ise temiz bir görüntüyü yeniden oluşturmak için evrişimler kullanılmıştır.

- c) En iyileme yöntemi ile CNN'nin birlikte kullanımı


Bu yöntemde Çekişmeli Üretken Ağlar (GAN) kullanılmaktadır. Gürültü giderme hızını iyileştirmek için, en büyük artçıl kestirim (MAP) yöntemine sahip bir çekişmeli üretken ağ, gürültüyü tahmin etmek ve görüntü iç boyama ve süper çözünürlük gibi işlemler için kullanılmaktadır [104]. Gürültü giderme performansını iyileştirmek ve gürültülü bir görüntüyü pürüzsüz hale getirmek için CNN en iyileme yöntemi kullanılmaktadır [105].

#### 4.1.2. Gürültü gidermede kullanılan önemli CNN yöntemleri

Yukarıda bahsedilen CNN mimarileri kullanılarak farklı yöntemler geliştirilmiştir. Bu bölümde geliştirilen önemli yöntemlerden bahsedilmektedir.


- a) Gürültü Gideren Evrişimsel Sinir Ağları

Gürültü Gideren Evrişimsel Sinir Ağları (DnCNN) görüntülerde gürültü azaltmak ve performanslı bir çözüm sunabilmek için hazırlanan bir yöntemdir [69]. DnCNN, veri sayısını azaltarak işlem performansını artırmaktadır. CNN ağlarında, ağı derinliği arttıkça hata miktarında da artış meydana gelmektedir. Şekil-10'da CIFAR-10 veri setinde 20 ve 56 katmanlı ağda meydana gelen eğitim ve test hataları gösterilmektedir. DnCNN sayesinde ağı derinliği artsa da hata miktarının artışı sınırlanmıştır.



Şekil 10. CIFAR-10 veri setinde 20 ve 56 katmanlı ağda meydana gelen eğitim ve test hataları [69]

Gürültü giderme için kullanılan yöntemlerin başarılı olmasına rağmen, iki büyük dezavantaja sahiptir. Birincisi, bu yöntemler genellikle test aşamasında sinir ağının en iyileme aşaması, gürültü giderme işlemi zaman alıcı hale getirmektedir [106]. İkincisi, modeller genel olarak elle seçilen parametreler sebebiyle, gürültü giderme aşamasındaki esnekliği düşüktür. Gürültü Gideren Evrişimsel Sinir Ağı bu sorunlara toplu normalleştirme ve artık ağ ile çözüm sunmaktadır. Toplu normalleştirmede daha yüksek öğrenme derecesi elde etmek için her katmanın çıkışında normalleştirme yapılmaktadır. Artık ağ sayesinde, elle seçilen parametreler ortadan kaldırılarak, kısayol bağlantıları oluşturulup, önceki çıktı değeri girdi değeri olarak mimaride kullanılmaktadır. Böylece daha derin bir öğrenme ağı oluşması sağlanmaktadır. DnCNN mimarisi Şekil 11'de gösterilmektedir.



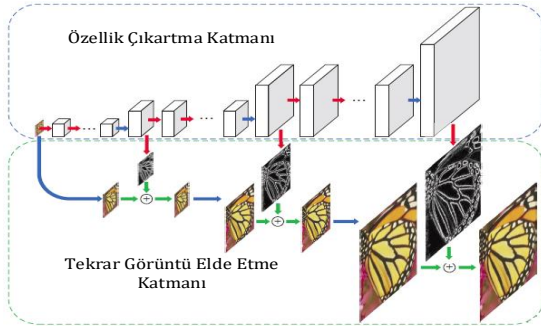
Şekil 11. Gürültü Gideren Evrişimsel Sinir Ağı mimarisi [69]

## b) Eğitilebilir Doğrusal Olmayan Reaksiyon Yayılması (TNRD)

Eşyönsüz yayılma yönteminde, filtreler, etki fonksiyonları ve diğer parametreler, doğrusal olmayan yayılma modellerinin aksine, kayıp tabanlı bir yaklaşımla, eğitim verilerinden eşzamanlı olarak öğrenilmektedir [107]. Bu model ilk olarak Perona ve Malik tarafından önerilmiş olup, görüntünün sınırlarını belirleme ve gürültü azaltmada başarılı bir yöntemdir. Bu yöntem, Gauss gürültüsünün giderilmesi, tek görüntüden süper çözünürlük görüntü elde etme ve JPEG görüntülerinde kayıp giderme işlemi için kullanılabilir.

## c) Laplas Piramit Süper-Çözünürlüklü Ağ (LapSRN)

Basamaklı alt ağlardan oluşan bir CNN ağıdır [108]. Yüksek çözünürlüklü bir ağ oluşturmak için kullanılmaktadır. Özellik çıkarım katmanı ile tersine evrişimsel dönüşüm katmanlarının birlikte kullanıldığı CNN mimarisine sahip bir ağıdır. Şekil 12'de bu yöntem için mimari gösterilmektedir. Ağ 27 katmandan oluşmakta olup, düşük çözünürlüklü görüntüleri süper çözünürlüğe ulaştırmak için de kullanılmaktadır.



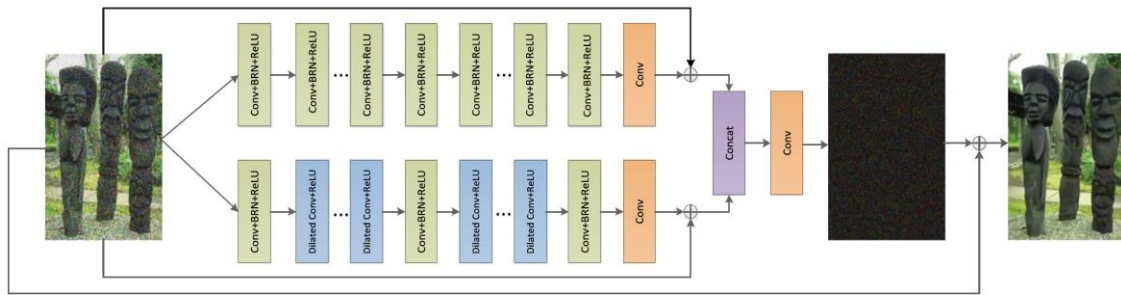
Şekil 12. LapSRN mimarisini [108]

## d) BRDNet


Derin evrişimli sinir ağlarında derinlik arttıkça sistemin eğitimi zorlaşmakta ve performans sorunları ortaya çıkmaktadır. BRDNet ağı genişliğini artırmak için iki ağı birleştirip daha fazla özellik elde etmeyi amaçlamaktadır [109]. Artık öğrenme, genişletilmiş evrişimler, görüntüleri gürültüden arındırmak ve daha fazla özellik elde etmek için kullanılmaktadır. Şekil 13'de BRDNet mimarisini gösterilmektedir. Mimari iki kısımdan oluşmakta olup, toplu yeniden normalleştirme katmanı yeşil ile, genişletilmiş evrişimsel ağ katmanı mavi ile gösterilmektedir. Orijinal görüntüden önce gürültü elde edilmekte, gürültü orijinal görüntüden çıkartılarak temiz görüntü elde edilmektedir.

## e) Çok Seviyeli Dalgacık Evrişimli Sinir Ağı

Bu yöntemin amacı daha hızlı çalışan bir gürültü giderici model oluşturup, görüntünün kalitesini artırmaktır. Bunu sağlayabilmek için özellik haritalarının boyutu küçültülüp, kanalları azaltmak için bir konvolüsyon katmanı kullanılmaktadır. Genişleyen alt ağda, yüksek çözünürlüklü özellik haritalarını yeniden yapılandırmak için ters dalgacık dönüşümü uygulanmaktadır. Çok Seviyeli Dalgacık Evrişimli Sinir Ağı (MWCNN) görüntü geri yükleme alanında kullanılmaktadır. 2 boyutlu ayrık dalgacık dönüşümünün (DWT), biortogonal özelliği nedeniyle, orijinal görüntü ters dalgacık dönüşümü (IWT) ile doğru bir şekilde yeniden oluşturulabilir [101]. Şekil 14'de bir görüntünün çok seviyeli dalgacık evrişimli sinir ağı mimarisini ile ayrışması ve yeniden yapılandırılması gösterilmektedir.




Şekil 13. BRDNet mimarisini [109]



Şekil 14. Bir görüntünün Çok Seviyeli Dalgacık Evrişimli Sinir Ağı mimarisini ile ayrışması ve yeniden yapılandırılması [101]

## f) CIMM

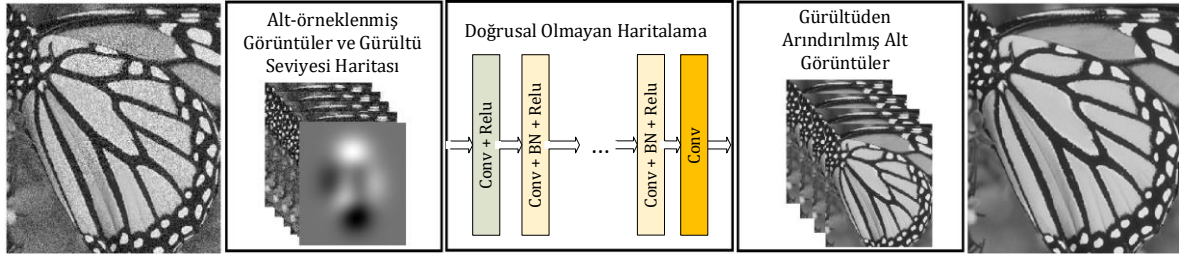
CIMM yönteminde görüntülerde gürültü giderme için Birim Eşleme Modülleri (CIMM) içeren tam evrişimli bir ağ modeli kullanılmıştır. CIMM mimarisi, eğitim açısını korumak için atlama bağlantıları olarak birim eşleştirmelerini kullanıp, önceden etkinleştirilen girdi alınmaktadır [110]. Ayrıca genişletilmiş çekirdekler kullanılarak, alıcı alanı genişletilmiştir. Şekil 15’de birim eşleme modülüne ait mimari gösterilmektedir.



Şekil 15. CIMM mimarisi [110]

## g) FFDNET

FFDNet gürültü seviyesi bilinmeyen görüntüler üzerinde gürültü giderme açısından, hızlı ve esnek bir yöntemdir [111]. İlk katman, gürültülü bir görüntüyü dört alt görüntüye yeniden şekillendiren tersine çevrilebilir bir alt örnekleme işlevine sahiptir. Her katman üç tür işlemten oluşmaktadır; ilk evrişim katmanı için “Conv + ReLU”, orta katmanlar için “Conv + BN + ReLU” ve son evrişim katmanı için “Conv” şeklindedir. Her evrişimden sonra özellik haritalarının boyutunu aynı tutmak için sıfır dolgu kullanılır. Son evrişim katmanından sonra, gürültüden arındırılmış görüntüyü elde etmek için giriş aşamasında uygulanan alt örnekleme operatörünün ters operatörü olarak yukarı ölçekleme işlemi uygulanır. Şekil 16’da FFDNet mimarisi gösterilmektedir. Karmaşıklık ve performans dengesini göz önünde bulundurarak, evrişim katmanlarının sayısı gri tonlamalı görüntü için 15 ve renkli görüntü için 12 olarak belirlenmiştir.

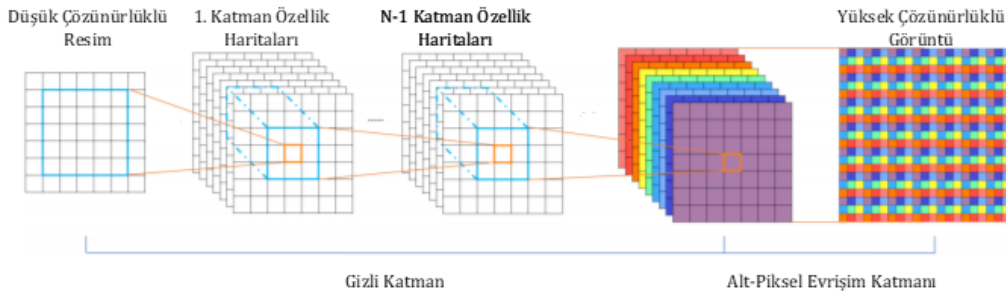


Şekil 16. FFDNet mimarisi [111]

## h) Verimli Alt-Piksel Evrişimli Sinir Ağı (ESPCN)

Düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntülerin elde edilmesi için kullanılan bir yöntemdir [112]. Diğer yöntemlere göre farklılıkları aşağıda belirtilmektedir:

- Görüntülerin kaydırma adımı (stride) değeri, orijinal görüntüdeki her bir pikselin, eğitim verisinde bir kez gözükmeye sağlanacak şekilde ayarlanmaktadır.
- ReLU aktivasyon fonksiyonu yerine, Tanh aktivasyon fonksiyonu kullanılmaktadır.
- Algoritmada en fazla 100 tekrar kullanılmakta, kayıp fonksiyonunda değişim olmazsa tekrar bitirilmektedir.
- İlk öğrenme oranı 0.01 ile başlayıp, en son 0.0001 değerine ulaşmaktadır. Ara değerlerde maliyet fonksiyonunun sonucu bir eşikten küçük olduğunda, maliyet fonksiyonu kademeli olarak güncellenmektedir. Mimari, 3 evrişim katmanından oluşmakta olup, 2 katman özellik haritası çıkarmak için kullanılıp, 1 katman düşük çözünürlüklü görüntüden süper çözünürlüklü görüntü elde etmek için kullanılmaktadır. Bu yönteme ait mimari Şekil 17’de gösterilmektedir.



Şekil 17. ESPCN mimarisi [112]


## i) ECDNET

ECNDNet mimarisi, genişletilmiş evrişim, artık öğrenme, toplu normalizasyon, evrişim ve ReLU'dan oluşur. Genişletilmiş evrişim 2., 5., 9. ve 12. katmanlarda uygulanmış olup, yakalanan bilgi artırılıp, hesaplama maliyeti düşürülmüştür. Önerilen ağın derinliği 17'dir [113]. Tasarlanan ağın mimarisi Şekil 18'de gösterilmektedir.

## j) Literatürde Yer Alan Diğer CNN Yöntemleri

ADNet yönetiminde gürültü seviyesi bilinmeyen gerçek gürültülü görüntülerde, gürültü gidermek ve düşük

frekanslı özellikleri düzleştirmek için artık bir yapı kullanılmaktadır [114]. EPLL yönteminde gürültü gidermek için Gauss Karışım Modeli kullanılmaktadır [115]. CSF, rastgele alan tabanlı bir mimari olan küçülme alanları öneren bir yapıya sahiptir [116]. PSN, yarı karesel bölme yönteminden ve yakın operatörlerden gelen öğelere dayalı olarak görüntü restorasyonu ilgili sorunları ele almak için kullanılmaktadır [117]. IRCNN yönteminde görüntüdeki gürültüyü tahmin etmek için yarı karesel bölme (HQS) ve CNN birlikte kullanılmaktadır [118].



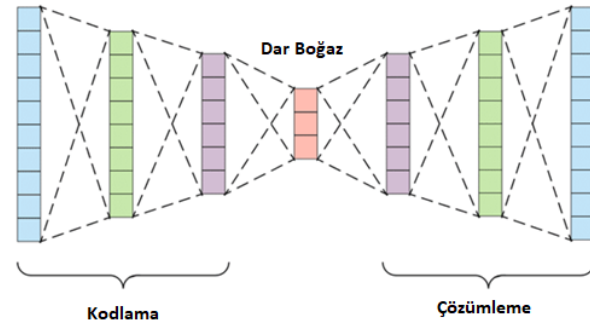
Şekil 18. ECDNET mimarisi [113]

#### 4.2. Görüntü Üzerinde Gürültü Giderimi İçin Kullanılan Otokodlayıcı Yöntemleri

Otokodlayıcılar, birden fazla gizli katmana sahip ileri beslemeli sinir ağlarıdır. Bu ağlar girdi verilerini çıkış katmanında yeniden elde etmeye çalışmakta olup, çıkış katmanındaki hedef veriler ile girdi verileri aynıdır [119]. Otokodlayıcılarda geri yayılım algoritmasında olduğu gibi gradyan alçalma yöntemini kullanarak eğitilmektedir. Otokodlayıcılar veri ve kod alanı arasında çift yönlü haritalandırma yapabilmektedir. Bir otokodlayıcıda fazla sayıda gizli katman kullanılarak büyük boyutlara sahip girdi verileri, çok daha az bir kod alanına kısıtlanabilir. Bununla birlikte birden fazla gizli katmana sahip bir sinir ağını eğitmek, alt seviyelerdeki gizli katmanların en iyileme aşamasından dolayı zordur.

Otomatik kodlayıcılar, girdi için sıkıştırılmış bilgi gösterimi gerçekleştiren bir darboğaz ağı içermektedir. Orta katmandaki nöron sayısı giriş katmanındaki nöron sayısından az ise ağ daha etkili bilgiyi çıkarmaktadır. Orta katmanın, gürültüleri gidererek görüntü kalıplarını oluşturmaya çalışmaktadır. Orta katmanda daha fazla nöron varsa, sinir ağına model öğrenme kapasitesi daha yüksek olduğundan, model giriş değerlerini kopyalayıp çıkış değerlerine yapıştırarak, gürültüyü öğrenecek ancak herhangi bir özelliği çıkarmayacaktır. Bu nedenle, darboğaz modeli gürültü giderme açısından önemlidir. Gürültüyü bir görüntüden çıkarmak için, görüntünün boyutsallığını azaltmak önemlidir. Otokodlayıcılar, doğrusal olmayan aktivasyon işlevleri ve çoklu katman yığını yardımıyla ağa doğrusal olmayan bir yapı sunmaktadır. Boyut azaltmanın ürünü olarak gürültülü

değerler, bu sinir ağı kullanılarak kolayca tespit edilebilmektedir. Şekil 17'de otokodlayıcılarda yapılan kodlama ve çözümlenme işlemi görselleştirilmektedir.




Şekil 17. Kodlama ve çözümlenme işlemleri [120]

Otokodlayıcılar genelde veri boyutunun azaltılması için kullanılmakta olup, otokodlayıcı mimarisi özelleştirilerek özellik seçimi, çıkarımı ve gürültü giderimi için yaygın olarak da kullanılmaktadır. Gürültü giderimi için kullanılan otokodlayıcı mimarilerinden aşağıdaki bölümde bahsedilmektedir.

## a) Gürültü Gideren Otokodlayıcı


Otokodlayıcılarda, gizli katmanda girdilerden daha fazla düğüm olduğunda, ağ "boş işlev" olarak da adlandırılan, çıkış verisinin girdi verisine eşit olduğu ve otokodlayıcıyı yararsız olarak işaretlediği duruma neden olmaktadır. Otokodlayıcılarda bu durum, giriş değerlerinden bazıları rastgele devre dışı bırakılarak veya bazı veriler bilerek bozularak çözümlenmektedir.

Genel olarak, sıfıra ayarlanan giriş düğümlerinin yüzdesi %30 ile %50 arasında olmaktadır [121]. Gürültü gideren otokodlayıcıda bazı nöronların devre dışı bırakılması Şekil 19'da gösterilmektedir.



Şekil 19. Gürültü gideren otokodlayıcıda bazı nöronların devre dışı bırakılması [122]

Gürültü gideren otokodlayıcıda aşırı öğrenmeyi engelleyip, daha iyi görüntü elde etmek için önce gürültü eklenip, orijinal görüntünün tekrar elde edildiği işlem Şekil 20'de gösterilmektedir.



Şekil 20. Gürültü gideren otokodlayıcının yapısı [123]


#### b) Yığıt Gürültü Gideren Otokodlayıcı

Otokodlayıcıda çözümleyici, gizli katman ve kodlayıcı kısımları yer almaktadır. Eğer ağa daha fazla gizli katman eklenirse, bu yapıya Yığıt Otokodlayıcı veya Derin Otokodlayıcı denilmektedir. Bu yöntem ile verilerin boyutu azaltılıp, daha çok sıkıştırılması sağlanmaktadır [124]. Gürültü gideren otokodlayıcılar, giriş verileri gürültü ile beslenen otokodlayıcılardır. Gürültüsüz veri ile çıkan veri karşılaştırılıp, hata oranı hesaplanmaktadır. Bu sayede, ağın ayrıntıları öğrenilmeyip, baskın özelliklerin öğrenilmesini sağlanmaktadır [121]. Yığıt Gürültü Gideren Otokodlayıcılarda da bazı nöronlar devre dışı bırakılarak daha derin bir ağın kurulması sağlanabilmektedir [125].

#### c) Evrimsel Gürültü Gideren Otokodlayıcı (CDAE)

Evrimsel Gürültü Gideren Otokodlayıcı yönteminde çözümleme işlemleri sırayla yapılmayıp, çözümleme işlemi kodlama ile birleştirilebilmektedir. Bu sayede bazı önemli veriler sıkıştırılmadan çıktı olarak kullanılabilir. Tıbbi görüntülerde gürültüyü gidermek için evrimsel gürültü gideren otokodlayıcılar kullanılmaktadır. Ayrıca görüntülerde filtreleme sonrası yeniden yapılandırma ve gürültü giderimi için de bu yöntem kullanılmaktadır. Şekil 21'de göğüs röntgen filmlerinde gürültü giderilmesi

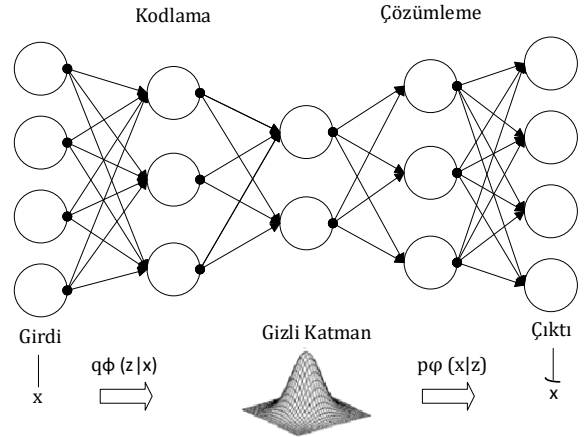
için kullanılan Evrimsel Gürültü Gideren Otokodlayıcı mimarisi gösterilmektedir.



Şekil 21. Göğüs röntgen filmlerinde kullanılan Evrimsel Gürültü Gideren Otokodlayıcı Mimarisi [6]

#### d) Gürültü Gideren Varyasyonel Otokodlayıcı

Seyrek otokodlayıcı yönteminde daha az veri ile işlem yapmak için veriler üzerinde deaktivasyon yapmadan aktivasyon fonksiyonları kullanılarak daha az sayıda nöronun aktive edilmesi sağlanmakta bu sayede performans korunup, otomatik kodlayıcının girdi verilerindeki gereksiz bilgiler yerine aslında istenen gösterimleri öğrenmesi sağlanmaktadır [126]. Bu mimariye benzer olarak Varyasyonel otokodlayıcı, gizli katmandaki vektörlerin dağılımını normal dağılıma zorlayan gözetimsiz ve üretken bir otokodlayıcı modelidir [127]. Varyasyonel otokodlayıcıda gizli katmana gauss eğrisinin uygulandığı mimari Şekil 22'de gösterilmektedir.



Şekil 22. Varyasyonel otokodlayıcı mimarisi [127]

Gürültü Gideren Varyasyonel Otokodlayıcı, Varyasyonel Otokodlayıcının gürültü giderimi üzerinde özelleştirilmesi sonucu bu yöntem ortaya çıkmıştır. Normal verilere gürültülü veriler eklenerek ağ üzerinde boş işlev olarak adlandırılan çıkış verisinin giriş verisine yaklaştığı sonuçlar önlenip, gizli katmanda işlem sonucunda normalleştirme yapılmaktadır. Değişimsel çıkarımı derin öğrenme ile birleştiren bir yaklaşımdır [128]. Bu yöntem gürültü gidermeyi ve düzenlemeyi tek bir üretken modelde birleştirmektedir. Varyasyonel Otokodlayıcının mimarisi geliştirilerek, bozulmuş görüntülerden temiz görüntü elde etmek ve görüntüleri sınıflandırmak için


kullanılabilmektedir [129].

### 4.3. Görüntü Üzerinde Gürültü Giderimi İçin Kullanılan Diğer Derin Öğrenme Yöntemleri

Gürültü giderme aşamasında kullanılan diğer derin öğrenme yöntemleri aşağıda belirtilmektedir.

#### 4.3.1. Tekrarlayan sinir ağı

Tekrarlayan Sinir Ağı (RNN) mimarisinde ileri beslemeli ağlardan farklı olarak, geri yayılım algoritması kullanılmaktadır. Bu yöntemde giriş ve çıkış değeri arasındaki hata bulunarak, ağı eğitimi sırasındaki hata değeri düşürülmeye çalışılmaktadır. Yinelenen yapılarda sonuç, sadece o andaki girdi değerine bağlı olmadan, diğer girdilere de bağlı olarak hesaplanmaktadır. Tekrarlayan Sinir Ağı mimarisinde, t anındaki girdi verilerinin yanında, t-1 anından gelen gizli katman sonuçları da gizli katmanın t anındaki girdisi olmaktadır. Tekrarlayan Sinir Ağı kullanarak videolarda gürültü giderimi için yapılan çalışmada; videoda üst üste binen görüntüler kare kare ayrılmaktadır. Aynı görüntüye ait veriler liste haline getirilip, listedeki verilerin ortalama değerleri alınıp, orijinal veriler yerine yama veriler koyulmaktadır [130]. Videoda gürültü gidermek için oluşturulan Tekrarlayan Sinir Ağı Şekil 23'de gösterilmektedir.



Şekil 23. Videoda gürültü gideren Tekrarlayan Sinir Ağı modeli [130]

Tekrarlayan Sinir Ağı ile EKG sinyallerindeki gürültülerin giderimi için yapılan diğer çalışmada orijinal veriye yakın sonuçlar elde edilmiştir [131].

Uzun Kısa Süreli Bellekler bilgiyi uzun süre hatırlayarak, bağımlılık probleminde kurtulmak için tasarlanmıştır. Uzun Kısa Süreli Bellekler önceki verilerle yeni kararlar vermek, verileri ilerde kullanmak ve verileri depolamak amacıyla içinde kapılar barındırırlar, bu nedenle daha esneklerdir. Ancak daha çok işlem yapıp, daha fazla hafıza gereksinimine sahiptirler. Bilgisayarla çekilmiş akciğer tomografi görüntülerinde meydana gelen gürültülerin giderimi için Uzun Kısa Süreli Bellek yöntemi kullanılmış ve sinyal gürültü oranı, tepe sinyal gürültü oranı ve ortalama hataların karesi

değerleri kıyaslanınca gürültü gidermede başarılı olduğu tespit edilmiştir [132].

#### 4.3.2. Kısıtlanmış boltzmann makineleri

Kısıtlı Boltzmann Makinesi iki katmanlı sinir ağıdır. Gürültü oranı yüksek görüntülerde, Kısıtlanmış Boltzmann Makinesinde derin ağların kullanılması ile gürültü gideren otokodlayıcı ve diğer yöntemlerden daha iyi sonuçlar ortaya çıkmaktadır [133].

#### 4.3.3. Derin inanç ağları

Derin İnanç Ağları, özellik gösterimi ve çıkartılması için etkili bir araçtır. Kısıtlanmış Boltzmann Makineleri iki katmanlı bir yapıya sahip olduğu için bu ağı derinleştirmek amacıyla derin inanç ağları oluşturulmuştur. Derin İnanç Ağlarında üst katmanlardaki bağlantılar yönsüz olup, alt katlardaki bağlantılar yönlüdür [134]. Derin İnanç Ağları görüntülerde gürültü giderme için de kullanılmaktadır. Yapılan bir çalışmada, ilave beyaz gauss gürültüsü ile bozulmuş MNIST veri setine Derin İnanç Ağları uygulanarak başarılı sonuçlar elde edilmiştir [135].

### 4.4. Videolarda Gürültü Giderimi

Videolar görüntü karelerinin bir araya getirilmesi ile oluşmaktadır. Video akış özellikleri saniyedeki kare sayısı ile belirlenmektedir. Gürültü giderimi sırasında video görüntüleri, fotoğraf makinesindeki seri çekim görüntülerine benzer şekilde, karelere ayrıştırılır. Sonrasında görüntülerde kullanılan gürültü giderme teknikleri videoda gürültü azaltmak için uygulanmaktadır [136]. Videoda gürültüyü gidermek için uygulanan yöntemlerde öncelikle yerel olmayan yama yöntemi kullanılmış olup, sonrasında CNN yöntemleri kullanılarak video ve görüntü üzerindeki gürültü giderilmeye çalışılmıştır [137]. Video üzerinde gürültü giderme aşamasında görüntü geçişlerinde titremenin olmaması, detayların korunması, gürültü giderme süresi ve orijinal görüntüye yakınlık video üzerinde gürültü gidermedeki başarı ölçütleri arasında yer almaktadır. Görüntülerde gürültü gidermede başarı elde etmiş yöntemler videolara da uyarlanarak uygulanmıştır. Örneğin BM3D ve NLB yöntemleri görüntüler üzerinde uygulanırken, VBM4D ve VNLB video üzerinde uygulanmaktadır.

Video üzerinde gürültü giderme için uygulanan bir yöntemde, görüntülerde gürültü gidermeden farklı olarak, ardışıl karelerde benzer yamalar bulunarak, gürültü benzer yamalarda ortak olarak giderilmiştir [37]. Benzer yamaların bulunması, uzamsal olarak benzer komşu karelerin bulunması ve hareket tahmininin kullanılması ile gerçekleştirilmektedir. Uzamsal komşuların bulunması aşamasında, belirli bir pikselde veya yamada gürültü giderme işlemi yapılırken dizinin bitişik karelerinde de benzer

pikseller veya yamalarda da gürültü giderme işlemi yapılır. Hareket tahmini kullanılarak video üzerinde gürültü giderme performansını iyileştirilmektedir [138,139].

VNLB yama tabanlı, Bayes teoremi kullanılarak video üzerinde gürültü giderme için oluşturulan bir yöntemdir. Bu yöntem, benzer uzay-zaman yamalarının her grubu için bir Bayes modeli oluşturur. VBM4D blok eşleme ve 3 boyutlu filtreleme ile videolarda gürültüyü gidermek için kullanılan, nesnelerin hareketleri takip edilerek, benzer nesnelerin gruplanarak filtrelemenin yapıldığı yöntemdir [37].

DVDNet yönteminde, videodan gürültü giderme çalışmasında performans ve eğitim zamanı arasında bir denge kurmak için zamansal bilgiler birleştirilmiştir [140]. Bu yöntem geleneksel gürültü giderme yöntemleri ile CNN tabanlı gürültü gidermenin birlikte kullanıldığı bir yöntemdir. Belirli bir pikselde gürültü giderimi yaparken, algoritmanın sadece aynı karede değil, aynı zamanda dizinin bitişik karelerinde de benzer pikseller aranmaktadır. Hareket tahmini yöntemiyle videoda farklı çerçevelerdeki benzer görüntüler bulunup, düzleştirilerek görüntü geçişleri arasındaki titreşimler yok edilmektedir. Son olarak elde edilen görüntüye gürültü gideren evrişimsel sinir ağı yöntemi uygulanmaktadır. DVDNet yöntemi geliştirilip U-ağı uygulanarak FastDVDNet yöntemi geliştirilmiştir [141]. FITVNet yöntemi iki aşamalı bir gürültü giderme modeline sahiptir. İlk aşamada görüntü içindeki gürültü giderilmekte, ikinci aşamada ekran geçişlerindeki titreşimin azaltılması için, video üzerinde uzamsal ve zamansal gürültü giderme yöntemleri uygulanmaktadır [136]. Video üzerinde gürültü gideren diğer bir modelde eğitim verisi olmadan video üzerinde gürültü giderme işlemi yapılmaktadır [142]. Eğitim verisi olarak videonun kendisi kullanılarak, video kareleri transfer öğrenme tekniği ile önceden eğitilmiş bir gürültü giderme ağına ince ayar yapılarak, gürültü videolar için gürültü gideren bir model oluşturulmuştur. Bu modelde iki aşamalı bir CNN ağı kullanılarak temiz video görüntüleri elde edilmiştir.

## V. YÖNTEMLERİN KIYASLANMASI

Yapılan bir çalışmada geleneksel gürültü yöntemleri kıyaslanmıştır [49]. Bu çalışmada kullanılan geleneksel yöntemlerden Wiener filtreleri, görüntüler üzerinde ortalama kare tahminini yaparak gürültülü ve bulanık görüntülerin restorasyonu için yaygın olarak kullanılmaktadır. Wiener filtreleme görüntü üzerindeki ayrıntıları korumaktadır. Bilateral Filtreleme gürültü giderme sürecini hızlandırmak için basit, kenar koruyucu, yinelemesiz bir yöntemdir. Her noktanın değeri yakınındaki noktaların ortalama yoğunluk

değerleri ile hesaplanmaktadır. PCA, veri kümelerini daha düşük boyutlara indirerek bir veri kümesini basitleştirmeye yönelik istatistiksel bir tekniktir, verileri küçülterek üzerindeki gürültüler giderilmektedir. Dalgacık dönüşüm yöntemi, bulanıklığın etkisini azaltmak için ortalama kare hatasını en aza indirmektedir, görsel olarak daha net görüntü elde etmektedir. BM3D görüntü parçaları, benzerlik temelinde birlikte gruplandırılmakta, gürültü için filtrelenmelerini ve farklı sinyallerini korumalarını sağlamak için ağırlık ortalaması alınarak filtreleme yapılmaktadır. Diğer yöntemlere göre PSNR değeri diğerlerine göre daha iyi sonuçlar ortaya koymaktadır, algılanabilir görsel sonuçlar elde etmişlerdir.


Bu çalışmada benzer görüntü parçalarını gruplamanın ve bunları birlikte filtrelemenin iyi sonuçları elde ettiği gözlemlenmiştir. Elde edilen sonuçlar Tablo 2'de gösterilmektedir.

**Tablo 2.** Set12 veri seti ile 30 dB gürültü seviyelerinde gürültü giderme sonucu elde edilen PSNR değerleri [49]

Metot	PSNR	SSIM
Wiener filtering	27.81	0.707
Bilateral filtering	27.88	0.712
PCA	26.68	0.596
Wavelet transform domain method	21.74	0.316
BM3D	<b>31.26</b>	<b>0.845</b>

Bu geleneksel yöntemleri uygularken bazı zorluklar yaşanmaktadır. Wiener filtrelerinde en uygun pencere boyutunu ayarlamak zor olmaktadır. Bilateral Filtreleme gürültü giderme sonrası görüntüde istenmeyen kalıntılar bırakmaktadır, yüksek gürültülerde başarı oranı düşük kalmaktadır. PCA görüntü detaylarını ve dokuları korumada zorluk oluşturmaktadır. Dalgacık dönüşüm yöntemine ait sonuçlar ayrıntılı yapıları koruyamama ve görsel açıdan daha az başarılı görüntüler elde edilmektedir. BM3D diğer yöntemlere göre başarı elde etmiş olsa da yönteminde gürültü içeriğindeki artışla performans önemli ölçüde azalmaktadır.

Geleneksel yöntemlerde doğru parametreleri ayarlamak her zaman mümkün olmamakta ve elle ayarlanan parametreler ile modeller oluşturulmaktadır. Şekil-111'de, farklı gürültü giderme parametre ayarlarıyla BM3D'nin gürültü giderme sonuçlarına ait bir örnek gösterilmektedir [143]. Şekil 24'de göz çevresi bölgesindeki görüntü (d), görüntü (c)'den daha fazla ayrıntıyı korumaktadır. Bu örnek, parametre seçiminin, görüntüdeki tüm bölgelerde, özellikle dokulu görüntü bölgelerinde gürültü giderme üzerinde etkisinin olduğunu göstermektedir.



**Şekil 24.** Parametre seçiminin gürültü giderme üzerinde etkisi [143]

(a) Orijinal Görüntü; (b) Gürültü Eklenmiş Görüntü; (c) 1. Parametrelere Göre Gürültü Giderme Sonucu Elde Edilen Görüntü; (d) 2. Parametrelere Göre Gürültü Giderme Sonucu Elde Edilen Görüntü.

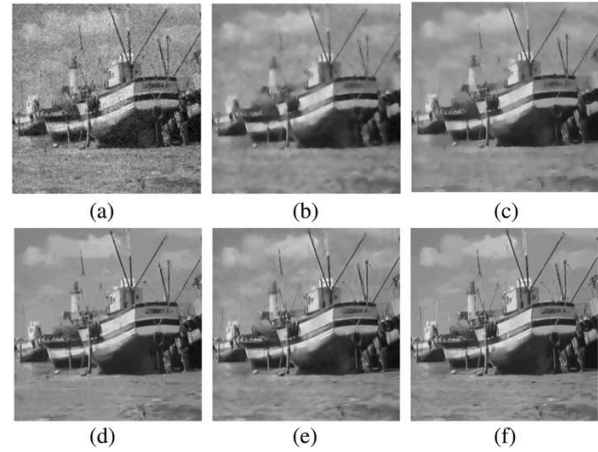
Derin öğrenme yöntemlerinin geleneksel yöntemlere üstünlüğü sadece parametre ayarlanması problemi ile sınırlı değildir. Gürültülerde bulunan yüksek frekanslı veriler kolaylıkla filtrelenebilmektedir. Fakat, asıl sinyal ile buna karışmış olan düşük frekanslı gürültünün ayırt edilmesi zor olduğu için düşük frekanslı gürültülerin filtrelenmesi de kolay olmamaktadır [49]. Geleneksel yöntemlerde gürültü türü ve dağılımına göre gürültüyü modelleyecek istatistiksel dağılım yöntemleri kullanılmaktadır. Bu yüzden gerçek dünyadaki görüntülerde gürültü tek bir dağılımla ifade edilemediği gibi her zaman dağılımı doğru bir şekilde belirlemek de mümkün olmayabilmektedir. Örneğin tıbbi görüntü türleri içerisinde ultrason görüntüsü benek gürültüsü içerirken, Manyetik rezonans (MR) görüntüleri ise Rician gürültüsü içermektedir [49].

Görüntülerde gürültü giderirken homojen bölgelerin yumuşatılması, kenarların, dokuların ve noktasal sinyallerin korunması gibi ihtiyaçların geleneksel yöntemlerle yapılması kolay olmamaktadır. Görüntü gürültü giderme aşamasında orijinal görüntüyü elde etmeye çalışırken bazı zorluklarla karşılaşılabilir. Gürültü giderme sürecinde dikkat edilmesi gereken kuralları şu şekilde sıralayabiliriz [49]:

- Gürültü giderildikten sonra görüntü üzerindeki düz alanlar gürültü giderildikten sonra da pürüzsüz olmalıdır.
- Kenarlar bulanıklaşmadan korunmalıdır.

- Görüntü üzerindeki dokular korunmalıdır.
- Görüntü üzerinde yeni gürültüler oluşturulmamalıdır.

Şekil 25'deki gösterilen çalışmada, toplam değişim (TV) tabanlı yöntemin [144] gürültü giderme sonucunda dokuları yumuşattığı ve görüntüde kalıntılar ürettiği gösterilmektedir. Ayarlanabilir yerel olmayan ortalamaların düzenlenmesi yöntemi (R-NL) [145] ve yerel olmayan ortalamalar (NLM) [146] yöntemleri daha iyi performanslar elde edebilmesine rağmen, bu iki yöntem küçük yapıları eski haline getirmekte güçlük çekmektedir. Temsili düşük sıra tabanlı yöntemlerin (WNNM [47], LRA\_SVD [147]) ve seyrek kodlama şemasının (NCSR [148]) homojen bölgelerde daha iyi sonuçlar ürettiği görülmektedir.



**Şekil 25.** Bot görüntüsü üzerinde gürültü giderme sonucu elde edilen sonuçlar [49]

- (a) Toplam Değişim Tabanlı Düzenleme [144] (PSNR = 22.95 dB; SSIM = 0.456)  
 (b) NLM [146] (PSNR = 24.63 dB; SSIM = 0.589)  
 (c) R-NL [145] (PSNR = 25.42 dB; SSIM = 0.647)  
 (d) NCSR model [148] (PSNR = 26.48 dB; SSIM = 0.689)  
 (e) LRA\_SVD [147] (PSNR = 26.65 dB; SSIM = 0.684)  
 (f) WNNM [47] (PSNR = 26.97 dB; SSIM = 0.708)

Gözetimli sınıflandırmada temel problem sınıfı bilinmeyen test nesnesini, farklı bilinen sınıf seti içinden doğru sınıfa atamaktır. Bu sınıflandırmayı seyreklik tabanlı olarak yapmak istediğimizde, öncelikle nesne ve sözlük arasındaki ilişkiyi ifade eden seyrek gösterim vektörünü elde etmemiz gereklidir [149]. Seyrek gösterime dayalı temsillerde iki ana problem mevcuttur. Birincisi, öğrenme verilerinden bir sözlük oluşturulması, ikincisi kodlanacak verinin oluşturulan bu sözlüğün atomlarının ağırlıklı toplamı olarak ifade edilen temsil ile asıl hali arasında en az uzaklık olacak şekilde ifade edilmesidir. Seyrek kodlama safhasında ise bir seferlik yapılan sözlük oluşturmanın ardından, nesne tanıma aşamasının



başında her bir görüntü var olan sözlük üzerinden seyrek olarak kodlanır. Kodlama problemi; eldeki test verisini, oluşturulan sözlük atomları cinsinden, minimum sayıda sözlük atomuna benzeterek orijinaline en yakın şekilde ifade etmeye çalışılmaktadır [150]. CNN yöntemleri seyrek yaklaşımlara benzer olarak görüntülerde seyrek etkileşim kullanmakta ve küçük çekirdekler ile görüntüyü filtrelemektedirler. Derin öğrenme modellerinde filtre bankaları eğitim esnasında oluşturulmaktadır. Bir sinir ağında evrişim işlemini kullanmanın yeniliği, filtreye ait ağırlık değerlerinin ağırlık eğitimi sırasında öğrenilmesidir. Filtre bankaları, görüntülerin doku özelliklerini çıkarmak için kullanılan ve doku analizinde yaygın olarak kullanılan araçlardır [151]. CNN'de bu filtrelerin tekrarlı öğrenme yapıları ile otomatik olarak oluşturulması sağlanmaktadır. Geleneksel yöntemlerde elle ayarlanan parametreler nedeniyle optimizasyon problemini çözmek için alternatif çözümler geliştirilmiştir [152]. Çoğu yöntem görüntüde gürültü giderme konusunda oldukça iyi bir performans elde etmelerine rağmen, elle ayarlanan parametrelere sahip olması, eğitim aşamasında optimizasyon yöntemlerine ihtiyaç duyulması gibi dezavantajlara sahiptir. Son zamanlarda, mimariler daha esnek hale geldikçe, derin öğrenme teknikleri bu dezavantajların üstesinden gelmeye başlamıştır [153-154].

Yapılan diğer çalışmada çeşitli gürültü seviyelerine sahip gri tonlamalı BSD68 test veri setindeki görüntülerin klasik yöntemler ve derin öğrenme yöntemleri kullanılarak gürültü giderme sonucu elde edilen ortalama PSNR (dB) ve SSIM sonuçları kıyaslanmıştır [155]. Elde edilen sonuçlara göre derin öğrenme yöntemi daha başarılı sonuç elde etmiştir. Elde edilen sonuçlar Tablo 3'de gösterilmektedir.

**Tablo 3.** Farklı standart sapma ile ilave beyaz Gauss gürültüsü tarafından bozulmuş BSD68 görüntüsü üzerindeki gürültü giderme sonuçlarının karşılaştırılması [155]

Gürültü Seviyesi	BM3D	WNNM	DnCNN
10	33.32	33.59	<b>33.88</b>
30	27.76	27.99	<b>28.36</b>
50	25.62	25.87	<b>26.23</b>
70	24.44	24.65	<b>24.90</b>

Otokodlayıcı gürültü giderme yöntemi ile CNN yöntemlerini kıyaslayabilmek için, CDAE ile DnCNN yöntemleri kullanılarak bir çalışma yapılmıştır.

CBSD400 veri setindeki  $\sigma=25$  gürültü seviyesine sahip  $176 \times 144$  boyutundaki görüntüler kullanılarak görüntüler üzerindeki gürültüler iki yöntem kullanılarak giderilmiştir. CDAE otokodlayıcı yöntemi hızlı eğitim süresine ve basit bir mimariye sahiptir. Ancak bu yöntemde resim üzerindeki detayların kaybolduğu gözlemlenmiştir. DnCNN yöntemi eğitim süresi olarak CDAE yönteminden biraz daha uzun eğitim süresine sahip olmasına karşın orijinal resme yakınlığı ön plana çıkmaktadır. Tablo 4'de DnCNN ve CDAE yöntemlerinin CBS400 veri setindeki  $\sigma=25$  gürültü seviyesine sahip görüntülerde gürültü giderme sonucu elde edilen ölçüm değerleri gösterilmektedir.

**Tablo 4.** DnCNN ve CDAE yöntemlerinin CBS400 veri setindeki  $\sigma=25$  gürültü seviyesindeki görüntülerde gürültü giderme sonucu elde edilen ölçümler

Yöntem	PSNR (dB)	SSIM	Toplam Parametre	Süre (sn)
DnCNN	26.94	0.83	560,320	605
CDAE	23.62	0.73	1,349,059	50

Başka bir çalışmada farklı derin öğrenme yöntemleri ve geleneksel gürültü giderme yöntemleri kıyaslanmıştır. DnCNN yöntemi az gürültülü görüntülerde başarılı sonuçlar elde etmiştir. Gürültü seviyesi arttıkça FFDNet yöntemi daha başarılı sonuç elde etmeye başlamıştır [155]. Derin öğrenme yöntemleri ve geleneksel gürültü giderme yöntemlerinin gürültü giderme sonuçları Tablo 5'de gösterilmektedir.

**Tablo 5.** Farklı standart sapma ile ilave beyaz Gauss gürültüsü tarafından bozulmuş BSD68 görüntüsü üzerindeki gürültü giderme sonuçlarının karşılaştırılması [155]

Gürültü (dB)	BM3D	WNNM	DnCNN	FFDNet
15	31.07	31.37	<b>31.72</b>	31.62
25	28.57	28.83	<b>29.23</b>	29.19
50	25.62	25.87	26.23	<b>26.30</b>
75	24.21	24.40	<b>26.64</b>	24.78

Diğer bir çalışmada gürültü gidermede kullanılan geleneksel ve CNN yöntemlerinin PSNR değerlerine ve çalışma sürelerine göre daha geniş bir karşılaştırma yapılmıştır. Değişik gürültü giderme metodlarının Set12 veri setindeki farklı gürültü seviyelerine sahip görüntülerde gürültü giderme sonucu elde edilen PSNR (dB) değerleri Tablo 6'da gösterilmektedir [84].

**Tablo 6.** Set12 veri seti ile farklı gürültü seviyelerinde gürültü giderme sonucu elde edilen PSNR değerleri [84]

	Airplane	Barbara	Boat	C.man	Couple	House	Lena	Man	Monarch	Parrot	Peppers	Starfish	Ortalama
Gürültü	$\sigma = 15$												
BM3D [32]	31.07	33.10	32.13	31.91	32.10	34.93	34.26	31.92	31.85	31.37	32.69	31.14	32.37
WNNM [53]	31.39	<b>33.60</b>	32.27	32.17	32.17	35.13	34.27	32.11	32.71	31.62	32.99	31.82	32.70
EPLL [116]	31.19	31.38	31.93	31.85	31.93	34.17	33.92	32.00	32.10	31.42	32.64	31.13	32.14
CSF [117]	31.33	31.92	32.01	31.95	31.98	34.39	34.06	32.08	32.33	31.37	32.85	31.55	32.32
TNRD [110]	31.46	32.13	32.14	32.19	32.11	34.53	34.24	32.23	32.56	31.63	33.04	31.75	32.50
ECNDNet [114]	31.70	32.41	32.37	32.56	32.39	34.97	34.52	32.39	33.11	31.82	33.25	32.17	32.81
DnCNN [69]	31.70	32.64	32.42	32.61	32.47	34.97	34.62	32.46	33.09	31.83	33.30	32.20	32.86
PSN-K [118]	31.75	32.64	<b>32.52</b>	32.58	32.43	35.04	34.62	32.39	33.11	31.89	33.23	32.17	32.86
PSN-U [118]	31.61	32.49	32.41	32.04	32.43	35.03	34.56	32.37	32.93	31.62	33.21	31.94	32.72
CIMM [112]	31.77	32.74	32.44	32.61	32.52	35.21	34.69	32.50	33.33	<b>32.01</b>	33.21	<b>32.35</b>	32.95
IRCNN [119]	31.70	32.43	32.34	32.55	32.40	34.89	34.53	32.40	32.82	31.84	33.31	32.02	32.77
FFDNet [113]	31.57	32.54	32.38	32.43	32.46	35.07	34.62	32.41	32.66	31.81	33.25	31.99	32.77
BRDNet [111]	31.85	32.93	32.55	<b>32.80</b>	<b>32.62</b>	<b>35.27</b>	<b>34.75</b>	<b>32.50</b>	<b>33.35</b>	32.00	33.47	32.24	<b>33.03</b>
ADNet [115]	<b>31.86</b>	32.80	32.57	32.81	32.58	35.22	34.71	32.47	33.17	31.96	<b>33.49</b>	32.17	32.98
Gürültü	$\sigma = 25$												
BM3D [32]	28.42	30.71	29.90	29.45	29.71	32.85	32.07	29.61	29.25	28.93	30.16	28.56	29.97
WNNM [53]	28.69	31.24	30.03	29.64	29.82	33.22	32.24	29.76	29.84	29.15	30.42	29.03	30.26
EPLL [116]	28.61	28.61	29.74	29.26	29.53	32.17	31.73	29.66	29.39	28.95	30.17	28.51	29.69
CSF [117]	28.72	29.03	29.76	29.48	29.53	32.39	31.79	29.71	29.62	28.90	30.32	28.80	29.84
TNRD [110]	28.88	29.41	29.91	29.72	29.71	32.53	32.00	29.87	29.85	29.18	30.57	29.02	30.06
ECNDNet [114]	29.07	29.84	30.14	30.11	30.03	33.08	32.38	30.03	30.30	29.38	30.85	29.43	30.39
DnCNN [69]	29.13	30.00	30.21	30.18	30.12	33.06	32.44	30.10	30.28	29.43	30.87	29.41	30.43
PSN-K [118]	<b>29.28</b>	30.17	30.31	30.28	30.18	33.26	32.57	30.10	30.30	29.38	31.01	29.57	30.53
PSN-U [118]	29.06	29.94	30.25	29.79	30.12	33.23	32.45	30.05	30.17	29.25	30.90	29.30	30.38
CIMM [112]	29.23	30.29	30.30	30.26	30.24	<b>33.44</b>	<b>32.66</b>	<b>30.18</b>	<b>30.62</b>	29.61	30.87	<b>29.77</b>	<b>30.62</b>
IRCNN [119]	29.12	29.92	30.17	30.08	30.08	33.06	32.43	30.04	30.09	29.47	30.88	29.27	30.38
FFDNet [113]	29.04	30.01	30.25	30.10	30.20	33.28	32.57	30.11	30.08	29.44	30.93	29.32	30.44
BRDNet [111]	29.20	<b>30.34</b>	30.33	<b>31.39</b>	<b>30.28</b>	33.41	32.65	30.14	30.50	<b>29.55</b>	<b>31.04</b>	29.46	30.61
ADNet [115]	29.17	30.25	<b>30.37</b>	30.34	30.24	33.41	32.61	30.08	30.39	29.49	<b>31.14</b>	29.41	30.58
Gürültü	$\sigma = 50$												
BM3D [32]	25.10	27.22	26.78	26.13	26.46	29.69	29.05	26.81	25.82	25.90	26.68	25.04	26.72
WNNM [53]	25.42	<b>27.79</b>	26.97	26.45	26.64	30.33	29.25	26.94	26.32	26.14	26.95	25.44	27.05
EPLL [116]	25.31	24.83	26.74	26.10	26.30	29.12	28.68	26.79	25.94	25.95	26.80	25.12	26.47
CSF [117]	25.56	25.24	27.03	26.37	26.67	29.64	29.32	27.06	26.26	26.12	26.68	25.43	26.78
TNRD [110]	25.59	25.70	26.94	26.62	26.50	29.48	28.93	26.98	26.31	26.16	27.10	25.42	26.81
ECNDNet [114]	25.79	26.26	27.16	27.07	26.84	30.12	29.29	27.11	26.82	26.32	27.30	25.72	27.15
DnCNN [69]	25.87	26.22	27.20	27.03	26.90	30.00	29.39	27.24	26.78	26.48	27.32	25.70	27.18
PSN-K [118]	25.90	26.45	27.20	27.10	27.09	30.34	29.54	27.21	26.92	26.56	27.40	<b>25.84</b>	27.30
PSN-U [118]	25.89	26.56	27.27	27.21	27.04	30.21	29.54	27.23	26.93	26.62	27.53	25.63	27.31
CIMM [112]	<b>26.06</b>	26.62	27.36	<b>27.25</b>	<b>27.24</b>	<b>30.70</b>	29.65	27.26	<b>27.21</b>	26.53	27.54	26.05	<b>27.46</b>
IRCNN [119]	25.89	26.24	27.17	26.88	26.88	29.96	29.40	27.17	26.61	26.55	27.33	25.57	27.14
FFDNet [113]	25.89	26.45	27.33	27.05	27.08	30.37	29.66	<b>27.29</b>	26.81	26.57	27.54	25.75	27.32
BRDNet [111]	25.93	26.85	<b>27.38</b>	27.44	27.17	30.53	<b>29.73</b>	27.27	26.97	<b>26.66</b>	27.67	25.77	27.45
ADNet [115]	25.88	26.64	27.35	27.31	27.07	30.59	29.59	27.17	26.90	26.56	<b>27.69</b>	25.70	27.37

CNN yöntemleri gerçek görüntü ve gürültülü görüntü çiftlerini kullanarak model oluşturulmaktadır. Gerçek hayatta bu görüntü çiftlerini elde etmek her zaman mümkün olmamaktadır. GAN yöntemleri görüntülerde gürültü giderme için kullanılarak öncelikle gürültü tahmini yapılmakta, sonrasında orijinal görüntü elde edilmeye çalışılmaktadır. GAN yöntemleri hem gürültü giderme hem de görselin yüksek çözünürlükteki detaylarını koruma ve boyutlarını artırma çalışmalarında başarılı sonuçlar elde etmektedir [156].

Elde edilen sonuçlara göre her gürültü seviyesinde farklı yöntemlerin başarılı olduğu görülmektedir. Görüntü boyutu arttıkça gürültü giderme yöntemlerinin işlem süreleri de artmaktadır. Derin öğrenme yöntemleri kullanılarak geleneksel yöntemlere göre daha iyi sonuçlar elde edilmekte ancak gerçek görüntü çiftleri olmadan bazı derin öğrenme yöntemleri başarılı sonuçlar elde edememektedir. Yapılan araştırmalar deneylerin toplumsal beyaz Gauss gürültüsü durumuna odaklandığını göstermektedir. Yapılan çalışmalar görüntülerdeki gürültü seviyesi arttıkça, gürültü giderme sonucu elde edilen görüntünün orijinaline olan yakınlığının da azaldığını göstermektedir.

## VI. BULGULAR VE TARTIŞMA

Bu makalede görüntülerde gürültü giderme aşamasında uygulanan derin öğrenme yöntemleri ile geleneksel yöntemlerden bahsedilip, bu yöntemler arasında kıyaslama yapılmıştır. Görüntü üzerindeki gürültü karmaşıklığı ve bu gürültüleri hızlı ve doğru şekilde giderme ihtiyacı sebebiyle bu alandaki araştırmalar halen devam etmektedir. Geleneksel gürültü giderme yöntemleri kısa sürede gürültüleri giderebilmekte olup, elde edilen görüntülerdeki kenarlar ve dokular daha düz hale gelmektedir.

Derin öğrenme yöntemleri kullanılarak yapılan gürültü giderme çalışmalarında farklı gürültü türlerinde tek bir derin öğrenme yönteminin başarılı olmadığı, farklı gürültü seviyeleri, farklı görüntüler ve farklı çözünürlüklü görüntüler için farklı derin öğrenme yöntemlerinin başarılı olduğu görülmüştür.


Ek beyaz gauss gürültüsünün giderilmesi konusunda birçok çalışma yapılmış olup, gerçek görüntülerdeki gürültünün karmaşıklığı ve orijinal görüntülerin olmaması nedeniyle görüntüler üzerinde doğru karşılaştırmalar yapılamamaktadır. Daha derin bir mimariye sahip ağlar, görüntü gürültü giderme sırasında daha iyi sonuçlar elde etmektedir. Bununla birlikte, daha derin ağlar daha fazla bellek tüketmekte, bu da aşırı uyum ve kaybolan eğitim sorununa neden olmaktadır. Tüm bu olumsuz yönlerin yanında gürültü giderme probleminde en başarılı sonuçlar CNN ve GAN yöntemleri ile elde edilmektedir.

### 6.1. CNN Mimarisinde Gürültü Giderme Sonucunu Olumlu Etkileyen Teknikler

Kullanım kolaylığı, daha az kaynak tüketimi ve değişken gürültü türlerine uyarlanabilir oldukları için yapay sinir ağları görüntülerde gürültü azaltmak için tercih edilmektedir. Oluşturulan evrimsel sinir ağlarında aşağıdaki tekniklerin kullanılması mimarilerin başarısını olumlu yönde etkilediği görülmüştür:

1. Alıcı alanı genişletmek, daha fazla bağlam bilgisi yakalayabilir. Alıcı alanın genişletilmesi, ağların derinliği ve genişliği artırılarak gerçekleştirilebilir. Ancak bu, daha yüksek hesaplama maliyetleri ve daha fazla bellek tüketimi gerektirmektedir. Bu sorunu çözmek için daha fazla uç bilgi sağlamada etkili olan genişletilmiş evrimsel kullanılmaktadır.
2. Seçilen kayıp fonksiyonu eğitim zamanını etkilemektedir. Seçilecek kayıp fonksiyonu eğitim süresini kısaltacak şekilde tercih edilmelidir.
3. Derin ağlar daha iyi gürültü giderimi sağladığı için, derin ağlar kullanılarak, ağlardaki performansı artırmak için de artık ağlar tercih edilmektedir.
4. CNN mimarisi içinde diğer tekniklerin koyulması daha iyi sonuçlar elde edilmesini sağlamaktadır. U-net ağının içine dalgacık dönüşümünün kullanılması bu tür kullanıma bir örnektir.
5. Eğitim verileri kullanılarak sanal verilerin oluşturulması daha fazla veri ile eğitim yapılmasını sağlamaktadır. Sanal eğitim verileri; eğitim verilerinin yatay ve dikey döndürülmesi, renklerin değiştirilmesi ile üretilebilmektedir.
6. Geleneksel yöntemler ile derin öğrenme yöntemlerinin beraber kullanılması video üzerinde gürültü giderme başarısını olumlu yönde etkilemektedir.

Literatür çalışmaları sonucu elde edilen bulgular, DnCNN yöntemi üzerinde uygulanarak yeni bir gürültü giderme modeli geliştirilmiştir. Elde edilen yeni model ile DnCNN yönteminin gürültü giderme başarısı kıyaslanmıştır. DnCNN yönteminin CBSD400 veri setindeki 180x180 boyutundaki görüntüler kullanılarak model eğitilmiştir. Oluşturulan modelde alıcı alan genişleterek daha fazla uç bilgi sağlanmıştır. Kayıp fonksiyonu DnCNN yöntemi ile aynı seçilmiş, DnCNN yönteminden daha derin bir ağ oluşturulmuştur. CBSD400 eğitim veri seti kullanılarak sanal verilerin oluşturulması sonucu daha fazla veri ile eğitim yapılmasını sağlanmıştır. Eğitim verisi artırılarak aynı model üzerinde yapılan çalışmada modelin artırılmış veri üzerinde daha iyi öğrenme sağladığı kayıp değerinin daha düşük olduğu görülmüştür. Hazırlanan modele ait mimari Şekil 26'da gösterilmektedir.



Şekil 26. Yeni oluşturulan yöntemin mimarisi

Hazırlanan Gürültü giderme yöntemi 19 katmandan oluşmaktadır. İlk katman Conv+Relu, ikinci katman Dilation+BN+Relu, 3 ve 18. Katmanlar Conv+Bn+Relu, 19. Katman Conv katmanından oluşmaktadır. Çizelge 7’de model katmanları gösterilmektedir.

Tablo 7. Hazırlanan Gürültü giderme yöntemi katmanları

Katman No	Model
1	conv + relu
2	dilation + bn + relu (1)
3 ... 18	conv + bn + relu (16)
19	conv (1)

Tablo 8’de hazırlanan gürültü giderme yöntemi ile DnCNN yönteminin CBSD68 test veri setindeki 180x180 boyutundaki görüntüler kullanılarak gürültü giderme sonucu elde edilen ölçüm değerleri gösterilmektedir. Elde edilen yeni modelin DnCNN yöntemine göre daha başarılı sonuçlar elde ettiği görülmüştür.

Tablo 8. Hazırlanan Gürültü giderme yöntemi ile DnCNN yönteminin CBSD400 veri setindeki görüntüler kullanılarak CBSD68 test veri setindeki gürültüleri giderme sonucu elde edilen ölçüm değerleri

Yöntem	Eğitim Verisi Sayısı	Katman Sayısı	PSNR (dB)	SSIM
DnCNN	400	17	24.95	0.76
DnCNN	400	19	25.75	0.80
Yeni Model	400	19	26.76	0.85
<b>Yeni Model</b>	<b>480</b>	<b>19</b>	<b>26.89</b>	<b>0.86</b>

## VII. SONUÇ VE DEĞERLENDİRMELER

Gürültü gidermede, gürültü giderme sonrası artık görüntülerin olmaması ve görüntünün düzgün özellikler ve kenarlar gibi niteliklerinin korunması önemli konulardır. Geleneksel yöntemlerden uzamsal alan yöntemleri kenarları korumada başarılı sonuçlar elde etmekte ancak düşük kontrastlı ayrıntıları korumada daha az başarılı olmaktadır. Alan dönüşüm yöntemleri kenarlardan çok düşük kontrastlı ayrıntıları koruyabilmektedir [157]. Önemli bilgileri koruyabilen çok sayıda uzamsal ve alan dönüşüm yöntemi filtreleri geliştirilmiş, ancak gürültü katsayıları arttıkça, artık gürültü kalıntıları oluşmakta ve gürültü giderme performansları azalmaktadır [158]. Derin öğrenmeye dayalı çalışmalarda farklı gürültü

türleri ve farklı görüntü çözünürlüklerinde tek bir derin öğrenme yönteminin başarı elde edemediği gözlenmiş olup, farklı gürültü seviyeleri ve farklı çözünürlükteki görüntüler için farklı derin öğrenme yöntemlerinin başarılı olduğu görülmektedir. İlave beyaz gauss gürültüsünün giderilmesiyle ilgili birçok derinlemesine araştırma yapılmasına rağmen, gerçek görüntülerdeki gürültünün karmaşıklığı ve orijinal görüntüye sahip olunmaması nedeniyle, kıyaslama yapılamamakta, gerçek görüntüde gürültü giderme üzerine yapılan çalışmalar sınırlı kalmaktadır. Gürültü giderimi sırasında daha derin mimariye sahip ağlar, daha başarılı sonuçlar elde etmektedir. Ancak daha derin ağlar, daha fazla bellek kaynağı harcamakta, aşırı öğrenme ve kaybolan eğim sorunları ortaya çıkmaktadır. İlave beyaz gauss gürültüleri gerçek hayattaki gürültüleri örnekleyememekte, bu ise yetersiz eğitim verilerini ortaya çıkarmaktadır.

Görüntüleme sistemindeki gürültü modeli çok karmaşık olduğundan ve yüksek kaliteli görüntüden gerçek gürültülü görüntünün sentezlenmesi zorlu bir problemdir. Ağ eğitimi gürültüden arındırmak için eşleştirilmemiş gürültülü ve temiz görüntülerden nasıl yararlanılacağı hala açık bir sorundur. [159]

Derin öğrenme yöntemleri geri beslemeli ağlar sayesinde kayıp değerlerini en aza indirebilmek için istatistiksel hesaplamalar yaparak orijinal görüntüyü elde etmeye çalışmaktadır. Kayıp fonksiyonları gürültü giderme ağlarının davranışını büyük ölçüde etkilediğinden, insan görsel sistemine iyi uyum iyi bir kayıp fonksiyonu bulmak önemli bir araştırma konusudur.

Gelecekteki çalışmalarda, gerçek hayattaki görüntülerde var olan gürültülerin nasıl giderileceği araştırılarak, derin öğrenme modellerinin, orijinal görüntü çiftlerine sahip olmadan eğitilmesi üzerine çalışmaların yapılması gerekmektedir. Geliştirilecek olan derin öğrenme mimarilerinin, kullanılan sistem kaynakları, eğitim süresi ve orijinal görüntüye olan yakınlık kriterleri göz önünde bulundurularak, çeşitli gürültü seviyelerinde de başarılı değerler elde etmesi gerekmektedir.

## KAYNAKLAR

- [1] Abiri, N., Linse, B., Edén, P., Ohlsson, M. (2019). Establishing strong imputation performance of a denoising autoencoder in a wide range of missing data problems, *Elsevier*, 137-146.

- [2] Zhou, C., Paenroth, R. (2017). Anomaly Detection with Robust Deep Autoencoders, *ACM KDD*, 13-17 Ağustos, Halifax, NS, Canada, 665-674.
- [3] Wen, B., Ravishankar, S., Bresler, Y. (2017). VIDOSAT: High-dimensional Sparsifying Transform Learning for Online Video Denoising, *IEEE Transactions on Image Processing*, 28(4), 1691-1704.
- [4] Chang, Y. (2019). Research on demotion blur image processing based on deep learning, *J. Vis. Commun. Image R. Elsevier*, 60, 371–379.
- [5] Erol A., Gürbüz M., Gangal, A. (2016). Video Görüntülerindeki Periyodik Gürültülerin Yok Edilmesi, *Researchgate*, 535-537.
- [6] Gondara, L. (2016). Medical image denoising using convolutional denoising autoencoders, *IEEE 16th International Conference on Data Mining Workshops*, 12-15 Aralık, Barselona, 241-246.
- [7] Hawwar, Y., Reza, A. (2002). Spatially adaptive multiplicative noise image denoising technique, *IEEE Transactions on Image Processing*, 11(12), 1397-1404.
- [8] Bioucas-Dias, J. M., Figueiredo, M. A. T., (2010). Multiplicative Noise Removal Using Variable Splitting and Constrained Optimization, *IEEE Transactions on Image Processing*, 19(7), 1720-1730
- [9] Bovik, A. (2000). *Handbook of Image and Video Processing*, Academic Press, Kanada, 330-331.
- [10] Leysa, C., Ley, C., Klein, O., Bernard, P., Licata, L. (2013). Detecting outliers: Do not use standard deviation around the mean, use absolute deviation around the median, *Journal of Experimental Social Psychology*, 49(4), 764-766.
- [11] Shin, DH., Park RH., Yang S., Jung JH. (2005). Block-based noise estimation using adaptive gaussian filtering, *IEEE Trans Consum Electron*, 51(1), 218–226.
- [12] Jolliffe, I. (2005). *Principal component analysis*, 2. Baskı. New York, Springer-Verlag.
- [13] Horé, A., Ziou, D. (2010). Image quality metrics: PSNR vs. SSIM, *20th International Conference on Pattern Recognition*, 2366-2369.
- [14] Liu, D., Li, D., Song, H. (2016). Image Quality Assessment Using Regularity of Color Distribution, *IEEE Access*, vol. 4, 4478-4483.
- [15] Pratt, W. K., (2007). *Digital Image Processing*, Fourth Edition, John Wiley & Sons Inc.
- [16] Proakis, J., Salehi, M. (2002). *Communication Systems Engineering*, Second Ed., Prentice-Hall, Upper Saddle River, 217-267.
- [17] Paonessa, S. (2021). Reducing Signal Noise in Practice. <https://www.predig.com/whitepaper/reducing-signal-noise-practice> (21.01.2021).
- [18] Kong, X. (2003). Removing Periodic Noise in F-wave: A Dynamic Notch Filter Approach, *Proceedings of the 25th Annual International Conference of the IEEE EMBS*, 17-21 Eylül, Cancun, Meksika, 2503-2506.
- [19] Diwakar, M., Kumar, M. (2018). A review on CT image noise and its denoising, *Biomed Signal Process Control*, Nisan, Dehradun, 73–88.
- [20] Weizheng, X., Chenqi, X., Zhengru, J., Yueping, H. (2020). Digital Image Denoising Method Based on Mean Filter, *International Conference on Computer Engineering and Application (ICCEA)*, 857-859.
- [21] Tania, S., Rowaida, R. (2016). A Comparative Study of Various Image Filtering Techniques for Removing Various Noisy Pixels in Aerial Image, *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 9(3), 113-124.
- [22] Pratt, W. K. (1972). Generalized Wiener Filtering Computation Techniques, *IEEE Transactions on Computers*, C-21(7), 636-641.
- [23] Lee, Y., Kassam, S. (1985). Generalized median filtering and related nonlinear filtering techniques, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 33(3), 672-683.
- [24] Yin, L., Yang, R., Gabbouj, M., Neuvo, Y. (1996). Weighted median filters: a tutorial, *IEEE Transactions on Circuits and Systems II Analog and Digital Signal Processing*, 43(3), 157-192.
- [25] Tomasi, C., Manduchi R. (1998). Bilateral filtering for gray and color images, *Sixth international conference on computer vision IEEE*, 7 Ocak, Bombay, India, 839–846.
- [26] Estrela V. V., Magalhães, H. A., Saotome, O. (2016). Total Variation Applications in Computer Vision, arXiv:1603.09599.
- [27] Rudin, L., Osher, S., Fatemi, E. (1992). Nonlinear Total Variation based Noise Removal Algorithms, *Physica D*, vol 60, 259–268.
- [28] Esedoglu, S., Osher, S. (2004). Decomposition of Images by the Anisotropic Rudin-Osher-Fatemi Model. *Communications on Pure and Applied Mathematics*, vol 57, 1609–1626.
- [29] Chambolle, A., Caselles, V., Novaga, M., Cremers, D., Pock, T. (2009). An introduction to Total Variation for Image Analysis, *Radon Series Comp. Appl. Math*, 9, 263–340
- [30] Chan, T. F., Esedoglu, S., Park, F., Yip, A. (2004). Recent developments in total variation image restoration, *Mathematical Models of Computer Vision*, CAM Report 05-01, Department of Mathematics, UCLA.
- [31] Buades, A., Coll, B., Morel, J. M. (2005). A non-local algorithm for image denoising, *IEEE computer society conference on computer vision and pattern recognition*, San Diego, 2(2), 60–65.

- [32] Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K. (2007). Image denoising by sparse 3-D transform-domain collaborative filtering, *IEEE Transactions on Image Processing*, 16(8), 2080-2095.
- [33] Mäkinen, Y., Azzari, L., Monge, E., Maggioni, M., Danielyan, A., Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K. (2019). Image and video denoising by sparse 3D transform-domain collaborative filtering. <https://www.cs.tut.fi/~foi/3D-DFT/> (21.02.2021).
- [34] Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K. (2009). BM3D image denoising with shape-adaptive principal component analysis, Signal processing with adaptive sparse structured representations, *SPARS'09- Signal Processing with Adaptive Sparse Structured Representations*, Saint Malo, France, DOI: 10.1109/TIP.2018.2865684.
- [35] Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K. (2006). Image denoising with block-matching and 3D filtering, *Proceedings of SPIE*, 6064, 354-365.
- [36] Makkar, H., Lamba, O. (2017). An Improved VBM3D Filtering Technique for Removal Noise in Video Signals, *European Journal of Advances in Engineering and Technology*, *ResearchGate*, 4(8), 584-591.
- [37] Maggioni, M., Boracchi, G., Foi, A., Egiazarian, K. (2012). Video denoising, deblocking, and enhancement through separable 4-D nonlocal spatiotemporal transforms, *IEEE Transactions on Image Processing*, 21(9), 3952–3966.
- [38] Khawase, S., Kamble, S., Thakur, N., Patharkar, A. (2017). An Overview of Block Matching Algorithms for Motion Vector Estimation, *Intelligent and Computing in Engineering*, Vol. 10 ISSN 2300-5963c, 217–222.
- [39] Delon, J., Houdard, A. (2018). Gaussian Priors for Image denoising, Bertalmío, Marcelo, *Denoising of Photographic Images and Video Fundamentals, Open Challenges and New Trends*, Advances in Computer Vision and Pattern Recognition book series (ACVPR), Springer.
- [40] Russel, S., Norvig, P. (2010). *Artificial Intelligence A Modern Approach*, Third Edition, Pearson Education.
- [41] Wright, J., Yang A. Y., Ganesh A., Sastry S. S., Ma, Y. (2009). Robust face recognition via sparse representation, *IEEE Transactions on Pattern analysis and Machine Intelligence*, 31(2), 210-227.
- [42] Deng, W., Hu, J., Guo, J. (2012). Extended SRC: Undersampled face recognition via intraclass variant dictionary, *IEEE Trans. Pattern Anal. Mach. Intell.*, 34(9), 1864-1870.
- [43] Zhang, L., Zhou, W. (2009). On the sparseness of 1-norm support vector machines, *Neural Networks*, 23(3), 373-385.
- [44] Gao, S., Tsang, I.W.H., Chia, L. T. (2010). Kernel sparse representation for image classification and face recognition, *11th Eur. Conf. Comput. Vis.*, 6314, 1-14.
- [45] Xu, S., Yang, X., Jiang, S. (2017). A fast nonlocally centralized sparse representation algorithm for image denoising, *Signal Processing*, Volume 131, 99-112.
- [46] Ji, H., Liu, C. Q., Shen, ZW., Xu, Y. H. (2010). Robust video denoising using low rank matrix completion, *IEEE computer vision and pattern recognition*, San Francisco, 1791–1798.
- [47] Gu, S. H., Xie, Q, Meng, D. Y, Zuo, W. M, Feng, X. C., Zhang, L. (2017). Weighted nuclear norm minimization and its applications to low level vision, *Int J Comput Vis*, 121(2), 183–208.
- [48] Ji, H., Huang, S. B., Shen, Z. W., Xu, Y. H. (2011). Robust video restoration by joint sparse and low rank matrix approximation, *SIAM J Imaging Sci*, 4(4), 1122–1142.
- [49] Fan, L., Zhang, F., Fan, H. (2019). Brief review of image denoising techniques, *Visual Computing for Industry, Biomedicine, and Art*, 2(7).
- [50] Şeker, Ş. (2008). Tekil Değer Ayrışımı. <http://bilgisayarkavramlari.com/2008/12/29/tekil-deger-ayrisimi-singular-value-decomposition/>, (21.01.2021).
- [51] Hornick, M. (2016). Using SVD for Dimensionality Reduction. <https://blogs.oracle.com/r/using-svd-for-dimensionality-reduction>, (01.02.2021).
- [52] Aharon, M., Elad, M., Bruckstein, A. (2006). K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation, *IEEE Transactions on Signal Processing*, 54(11), 4311-4322.
- [53] Gu, S., Zhang, L., Zuo, W. Feng, X. (2014). Weighted nuclear norm minimization with application to image denoising, *2014 IEEE conference on computer vision and pattern recognition*, Columbus, 2862–2869.
- [54] Mallat, S. (1998). *A Wavelet Tour of Signal Processing*, Academic Press, San Diego.
- [55] Bhuiyan, M., Ahmad, M., Swamy, M. (2008). Wavelet-based image denoising with the normal inverse Gaussian prior and linear MMSE estimator, *1st Image Processing*, volume 2, 203-217.
- [56] Hyvarinen, A., Oja, E., Hoyer, P., Hurri, J. (1998). Image feature extraction by sparse coding and independent component analysis, *IEEE 14th international conference on pattern recognition*, Brisbane, 1268–1273.
- [57] Nigam, V., Luthra, S., Bhatnagar, S. (2010). A Comparative Study of Thresholding Techniques for Image Denoising, *International Conference on Computer and Communication Technology*, Allahabad, 173-176.
- [58] Donoho, D. L., Johnstone, I. M. (1995). Adapting to unknown smoothness via wavelet

- shrinkage, *Journal of the American Statistical Association*, 90(432), 1200-1224.
- [59] Donoho, D. L. (1995). Denoising by soft-thresholding, *IEEE Trans. Information Theory*, 41(3), 613-627.
- [60] Biswas, M., Om, H. (2012). A New Soft-Thresholding Image Denoising Method, 2nd International Conference on Communication, Computing & Security [ICCCS-2012], 6, 10-15.
- [61] Chang, S. G., Yu, B., Vetterli, M. (2000). Adaptive wavelet thresholding for image denoising and compression, *IEEE Transactions on Image Processing*, 9(9), 1532-1546.
- [62] Starck, J., Fadili, J., Murtagh, F. (2007). The Undecimated Wavelet Decomposition and its Reconstruction, *IEEE Transactions On Image Processing*, 16(2).
- [63] Starck, J. L., Elad, M., Donoho, D. L. (2004). Redundant multiscale transforms and their application for morphological component analysis, *Adv. Imag. Electron Physics*, 287-348.
- [64] Barbero, M., Hofmann, H., Wells, N. (1991). DCT source coding and current implementations for HDTV, *EBU Technical Review*.
- [65] Lukin, V. V., Fevraleev, D. V., Nikolay, N., Abramov, S. (2010). Astola Discrete cosine transform-based local adaptive filtering of images corrupted by nonstationary noise, *Journal of Electronic Imaging*, 19(2).
- [66] Kim, J., Lee, J. K., Lee, K. M. (2016). Accurate image super-resolution using very deep convolutional networks, *IEEE conference on computer vision and pattern recognition*, 27-30 Haziran, Las Vegas, 1646-1654.
- [67] Wang, X., Chan, K., Yu, K., Dong, C., Loy, C. C. (2019). EDVR: Video restoration with enhanced deformable convolutional networks, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 1954-1963.
- [68] Lefkimmiatis, S. (2018). Universal denoising networks: A novel cnn architecture for image denoising, *CVPR*, 3204-3213.
- [69] Zhang, K., Zuo, W., Chen, Y., Meng, D., Zhang L. (2017). Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising, *IEEE Transactions on Image Processing*, 26(7), 3142-3155.
- [70] Lehtinen, J., Munkberg, J., Hasselgren, J., Laine, S., Karras, T., Aittala, M., Aila, T. (2018). Noise2Noise: Learning image restoration without clean data, *ICML*, volume 80, 2965-2974.
- [71] Batson, J., Royer, L. (2019). Noise2self: Blind denoising by self-supervision, *arXiv:1901.11365*
- [72] Krull, A., Buchholz, T., Jug, F. (2019). Noise2void - learning denoising from single noisy images, *CVPR*, arXiv:1811.10980.
- [73] Alimovskia, E., Erdemira, G. (2021). Veri Artırma Tekniklerinin Derin Öğrenmeye Dayalı Yüz Tanıma Sisteminde Etkisi, *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(1): 76-80.
- [74] Fabio, P., Christina, V., Sandra, A., Eduardo, V. (2018). Data augmentation for skin lesion analysis, *ISIC skin image analysis workshop and challenge*, MICCAI.
- [75] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., Fei-Fei, L. (2009). ImageNet: A Large-Scale Hierarchical Image Database, *IEEE Computer Vision and Pattern Recognition (CVPR)*.
- [76] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86(11), 2278-2324.
- [77] Szandala, T., (2020). Review and comparison of commonly used activation functions for deep neural networks, *Bio-inspired Neurocomputing*, 903, 203-224.
- [78] Ahn, H., Rhee, S. B. (2015). Research of Object Recognition and Tracking Based on Feature Matching, Park J., Stojmenovic I., Jeong H., Yi G. (eds) Computer Science and its Applications, Lecture Notes in Electrical Engineering, vol 330, Springer, Berlin, Heidelberg, 1071-1076.
- [79] Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks, *Advances, Neural Information Processing Systems*, Kasım 2012, NY United States, 1097-1105.
- [80] Nair, V., Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines, *27th international conference on machine learning*, Haziran 2010, Haifa, Israel, 807-814.
- [81] Simonyan, K., Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition, *arXiv:1409.1556*.
- [82] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. (2015). Going deeper with convolutions, *IEEE Conference on Computer Vision and Pattern Recognition*, Boston, USA, 1-9.
- [83] Lin, M., Chen, Q., Yan, S. (2013). Network in network, *Neural Computing and Applications*, *Journal of Computer and Communications*, 8(11), arXiv:1312.4400.
- [84] Chunwei, T., Lunke, F., Wenxian, Z., Yong, X., Wangmeng, Z., Chia-Wen L. (2020). Deep Learning on Image Denoising: An Overview, *Neural networks: the official journal of the International Neural Network Society*, 251-275. arXiv:1912.13171.
- [85] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition, *2016 IEEE Conference on Computer Vision and Pattern Recognition*, 27-30 Haziran, Las Vegas, NV, USA, 770-778.

- [86] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). Generative Adversarial Networks, *Advances in Neural Information Processing Systems*, 3(11), arXiv:1406.2661.
- [87] Tran, L., Yin, X., Liu, X. (2017). Disentangled representation learning gan for pose-invariant face recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, 1415–1424.
- [88] Li, Y., Li, Z., Kejun, K. (2013). A novel image restoration method assisted by reference image in dual-energy CT, *2013 IEEE Nuclear Science Symposium and Medical Imaging Conference*, 1-4, DOI: 10.1109/NSSMIC.2013.6829279.
- [89] Wu, Y., Zhao, W., Zhang, Q. (2013). The improvement of audio noise reduction system based on LMS algorithm, *2013 International Conference on Computer Sciences and Applications*, 590-594.
- [90] LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep learning, *Nature*, 521(7553), 436-444.
- [91] Ha, V. K., Ren, J., Xu, X., Zhao, S., Xie, G., Vargas, V. M. (2018). Deep Learning Based Single Image Super-Resolution: A Survey, *Advances in Brain Inspired Cognitive Systems BICS 2018*, Springer, vol 10989.
- [92] Guo, S., Yan, Z., Zhang, K., Zuo, W., Zhang, L. (2019). Toward convolutional blind denoising of real photographs, *IEEE Conference on Computer Vision and Pattern Recognition*, 16-20 Haziran, CA, USA, 1712–1722.
- [93] Liu, H., Ruan, Z., Zhao, P., Dong, C., Shang, F., Liu, Y., Yang, L. (2020). Video Super Resolution Based on Deep Learning: A Comprehensive Survey, *Computer Science, Computer Vision and Pattern Recognition*, arXiv:2007.12928.
- [94] Farooque, M. A., Rohankar, J. S. (2013). Survey on various noises and techniques for denoising the color image, *International Journal of Application or Innovation in Engineering & Management (IJAIEEM)*, 2(11), 217–221.
- [95] Tian, C., Xu, Y., Fei, L., Yan, K. (2019). Deep Learning for Image Denoising: A Survey, *ICGEC 2018 Advances in Intelligent Systems and Computing*, Singapore, vol 834.
- [96] Jeon, W., Jeong, W., Son, K., Yang, H. (2018). Speckle noise reduction for digital holographic images using multi-scale convolutional neural networks, *Optics Letters*, 43(17), 4240–4243.
- [97] Liu, S., Deng, W. (2015). Very deep convolutional neural network based image classification using small training sample size, *IAPR Asian Conference on Pattern Recognition (ACPR)*, 730-734.
- [98] Yu, F., Koltun, V., Funkhouser, T. (2017). Dilated residual networks, *Computer Vision and Pattern Recognition (CVPR)* (2017). arXiv: 1705.09914.
- [99] Chen, C., Xiong, Z., Tian, X., Wu, F. (2018). Deep boosting for image denoising, *European Conference on Computer Vision (ECCV)*, 4-8 Eylül, Munich, Germany, 3–18.
- [100] Tai, Y., Yang J., Liu, X. (2017). MemNet: a persistent memory network for image restoration, *IEEE Int. Conf. on Computer Vision (ICCV 2017)*, Venice, Italy, 4539–4547.
- [101] Liu, P., Zhang, H., Zhang, K., Lin, L., Zuo, W. (2018). Multi-level wavelet-cnn for image restoration, *IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 18-22 Haziran, Salt Lake City, Utah, 773–782.
- [102] Zhao, Y. Q., Yang, J. (2015). Hyperspectral image denoising via sparse representation and low-rank constraint, *IEEE Transactions on Geoscience and Remote Sensing*, 53(1), 296–308.
- [103] Bui A. T., Im, J. K., Apley, D. W., Runger G. C. (2019). Projection-free kernel principal component analysis for denoising, *Elsevier Neurocomputing*, 357, 163-176.
- [104] Cha, S., Park, T., Kim, B., Baek, J., Moon, T. (2021). GAN2GAN: Generative Noise Learning for Blind Denoising with Single Noisy Images, *International Conference on Learning Representations (ICLR)*.
- [105] Luo, Z., Chen, S., Qian, Y. (2019). A Deep Optimization Approach for Image Deconvolution, *Computer Vision and Pattern Recognition*, arXiv:1904.07516.
- [106] Wang, T., Sun, M., Hu, K. (2018). Dilated deep residual network for image denoising, *International Conference on Tools with Artificial Intelligence, ICTAI*, 6-8 Kasım, Boston, 1272-1279.
- [107] Chen, Y., Pock, T. (2016). Trainable nonlinear reaction diffusion: A flexible framework for fast and effective image restoration, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1256-1272.
- [108] Lai, W. S., Huang J. B., Ahuja, N., Yang M. H. (2017). Deep Laplacian Pyramid Networks for Fast and Accurate Super-Resolution, *30th IEEE Conference on Computer Vision and Pattern Recognition*, 21-26 Haziran, Honolulu, 5835-5843.
- [109] Tian, C., Xu, Y., Zuo, W. (2020). Image denoising using deep cnn with batch renormalization, *Neural Networks*, 121, 461–473.
- [110] Anwar, S., Huynh, C. P., Porikli, F. (2017). Chaining identity mapping modules for image denoising, arXiv:1712.02933.
- [111] Anandbabu, G., Merajothu, N., Kirankumar, G. (2018). Convolutional neural network based image denoising for better quality of images. *International Journal of Engineering and Technology(UAE)*, 7, 356-361.



- [112] Shi, W., Caballero, J., Huszar, F., Totz, J., Aitken, A., Bishop, R., Rueckert, D., Wang, Z. (2016). Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network, *IEEE conference on computer vision and pattern recognition*, 27-30 Haziran, Las Vegas, 1874-1883.
- [113] Tian, C., Xu, Y., Fei, L., Wang, J., Wen, J., Luo, N. (2019). Enhanced cnn for image denoising, *CAAI Transactions on Intelligence Technology*, 4(1), 17–23.
- [114] Tian, C., Xu, Y., Li, Z., Zuo, W., Fei, L., Liu, H. (2020). Attention-guided cnn for image denoising, *Neural Networks*, 124, 117-129.
- [115] Zoran, D., Weiss, Y. (2011). From learning models of natural image patches to whole image restoration, *IEEE International Conference on Computer Vision*, 6-13 Kasım, Barcelona, 479–486.
- [116] Schmidt, U., Roth, S. (2014). Shrinkage fields for effective image restoration, *IEEE Conference on Computer Vision and Pattern Recognition*, 24-27 Haziran, Columbus, 2774–2781.
- [117] Aljadaany, R., Pal, D. K., Savvides, M. (2019). Proximal splitting networks for image restoration, *International Conference on Image Analysis and Recognition*, Springer, 3-17.
- [118] Zhang, K., Zuo, W., Gu, S., Zhang, L. (2017). Learning deep cnn denoiser prior for image restoration, *IEEE Conference on Computer Vision and Pattern Recognition*, 21-27 Haziran, Honolulu, 3929–3938.
- [119] Bengio, Y. (2009). Learning deep architectures for AI, *Foundations and Trends in Machine Learning*, 2(1), 1–127.
- [120] Patilab, S., Naik, G., Pai, R., Gad, R. (2018). Stacked Autoencoder for classification of glioma grade III and grade IV, *Biomedical Signal Processing and Control*, Elsevier, 46, 67-75.
- [121] Vincent, P., Larochelle, H., Bengio, Y., Manzagol, P. (2008). Extracting and Composing Robust Features with Denoising Autoencoders, *25th International Conference on Machine Learning*, Haziran, Helsinki, Finland, 1096–1103.
- [122] Chinner, H. (2015). Denoising AutoEncoders, <http://www.rubylab.io/2015/04/28/denoising-autoencoder-tutorial/>, (01.11.2020).
- [123] Harish, H. (2019). Denoising AutoEncoders, <https://medium.com/@harishr2301/denoising-autoencoders-996e866e5cd0>, (01.11.2020).
- [124] Liu, G., Bao, H., Han, B. (2018). A Stacked Autoencoder-Based Deep Neural Network for Achieving Gearbox Fault Diagnosis, *Mathematical Problems in Engineering*, DOI: 10.1155/2018/5105709
- [125] Jozdani, S., Johnson, B., Chen, D. (2019). Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification, *Remote Sens*, 11(14), 1713s.
- [126] Ng, A. (2018), Sparse autoencoder, CS294A Lecture notes, [https://web.stanford.edu/class/cs294a/sparseAutoencoder\\_2011new.pdf](https://web.stanford.edu/class/cs294a/sparseAutoencoder_2011new.pdf), (07.04.2021).
- [127] Kingma, D., Welling, M. (2019). An Introduction to Variational Autoencoders, *Foundations and Trends in Machine Learning*, 12(2019), 307-392.
- [128] Im D., Im, J., Ahn, S., Memisevic, R., Bengio, Y. (2017), Denoising Criterion for Variational Auto-Encoding Framework, AAAI Publications, *Thirty-First AAAI Conference on Artificial Intelligence*, 2059-2065.
- [129] Creswell, A., Bharath, A. A. (2018). Denoising Adversarial Autoencoders, *arXiv:1703.01220v4*.
- [130] Chena, X., Songa, L., Yanga, X. (2016). Deep RNNs for Video Denoising, *Applications of Digital Image Processing*, SPIE vol 9971.
- [131] Antczak, K. (2018). Deep Recurrent Neural Networks for ECG Signal Denoising, 9(1), *arXiv:1807.11551*, 135s.
- [132] Rajeev, R., Samath, J., Karthikeyan, N. (2019). An Intelligent Recurrent Neural Network with Long Short-Term Memory (LSTM) BASED Batch Normalization for Medical Image Denoising, *Journal of Medical Systems*, Springer Science, 43(8), 234s.
- [133] Cho, K. (2013). Boltzmann Machines for Image Denoising, *Artificial Neural Networks and Machine Learning – ICANN*, Springer, 10-13 Eylül, Sofia, 611-618.
- [134] Hinton, G. E., Salakhutdinov, R. R. (2006). Reducing the Dimensionality of Data with Neural Networks, *Science*, 313(5786), 504–507.
- [135] Keyvanrad, M., Pezeshki, M., Homayounpour, M. (2013). Deep Belief Networks for Image Denoising, *arXiv:1312.6158*.
- [136] Wang, C., Zhou, S. K., Cheng, Z. (2020). First image then video: A two-stage network for spatiotemporal video denoising, *arXiv:2001.00346*.
- [137] Sheeba, M. C., Seldev C. D. C. (2019). A review on video denoising methods, *2019 International Conference on Recent Advances in Energy-efficient Computing and Communication (ICRAECC)*, 1-6.
- [138] Arias, P., Morel, J. M. (2018). Video Denoising via Empirical Bayesian Estimation of Space-Time Patches, *Journal of Mathematical Imaging and Vision*, 60(1). 70–93.
- [139] Buades, A., Lisani, J. (2016). Patch-Based Video Denoising With Optical Flow Estimation, *IEEE Trans. IP*, 25(6), 2573–2586.
- [140] Tassano, M., Delon, J., Veit, T. (2019). Dvdnet: A fast network for deep video denoising, *International Conference on Image*

- Processing (ICIP), IEEE, 22-25 Eylül, Taipei, 1805–1809.*
- [141] Paramkusam, A., Reddy, V. S. K. (2014). Two-layer motion estimation algorithm for video coding, *Electronics Letters*, vol 50, 276-278.
- [142] Chen, H., Jin, Y., Xu, K., Chen, Y., Zhu, C. (2021). Multiframe-to-Multiframe Network for Video Denoising, *IEEE Transactions on Multimedia*, DOI: 10.1109/TMM.2021.3077140.
- [143] Zhang, X., Yang, Y., Lin, L. (2018). Edge-aware image denoising algorithm, *Journal of Algorithms & Computational Technology*, Volume 13, 1–10.
- [144] Rudin, L. I., Osher, S., Fatemi, E. (1992). Nonlinear total variation based noise removal algorithms, *11th annual international conference of the center for nonlinear studies on experimental mathematics: computational issues in nonlinear science*, Elsevier North-Holland, Inc, New York, 259–268.
- [145] Sutour, C., Deledalle, C. A., Aujol, J. F. (2014). Adaptive regularization of the nl-means: application to image and video denoising, *IEEE Trans Image Process*, 23(8), 3506–3521.
- [146] Buades, A., Coll, B., Morel, J. M. (2005). A non-local algorithm for image denoising, *2005 IEEE computer society conference on computer vision and pattern recognition, IEEE, San Diego*, 60–65.
- [147] Guo, Q., Zhang, C. M., Zhang, Y. F., Liu, H. (2016). An efficient SVD-based method for image denoising, *IEEE Transactions On Circuits And Systems For Video Technology*, 26(5), 868–880.
- [148] Dong, W. S., Zhang, L., Shi, G. M., Li, X. (2013). Nonlocally centralized sparse representation for image restoration, *IEEE Trans Image Process*, 22(4), 1620–1630.
- [149] Yeşiloğlu, A., Ekşioğlu, E. M. (2016). Seyrek İşaret İşlemede Sınıflandırma Uygulamaları ve Çekirdek Tabanlı Yaklaşımlar, *24.Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Zonguldak*, 1157-1160.
- [150] Erdogan, H. T., Erdem, E., Erdem, A. (2013). Alan Kovaryansları İçin Grup Seyrekliğine Dayalı Seyrek Kodlama, *21. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Girne, K.K.T.C.*, 1-3.
- [151] Andrearczyk, V., Whelan, P. F. (2016). Using Filter Banks in Convolutional Neural Networks for Texture Classification, *arXiv:1601.02919*.
- [152] Eslahi, N., Aghagolzadeh, Q. (2016). Compressive sensing image restoration using adaptive curvelet thresholding and nonlocal sparse regularization, *IEEE Trans. Image Process.*, 25(7), 3126-3140.
- [153] Lucas, A., Iliadis, M., Molina, R., Katsaggelos, A. K. (2018). Using deep neural networks for inverse in imaging: beyond analytical methods, *IEEE Signal Processing Magazine*, Ocak 2018, 35(1), 20-36.
- [154] Zhang, Y., Xiao, J., Peng, J., Zong, X. (2018). Kernel Wiener Filtering Model with Low-Rank Approximation for Image Denoising, *Information Sciences*.
- [155] Jain, V., Seung, H. (2009). Natural Image Denoising with Convolutional Networks, *Advances in Neural Information Processing Systems*, 769–776.
- [156] Hüsem, H., Orman, Z. (2020). A Survey on Image Super-Resolution with Generative Adversarial Networks, *Acta Infologica*, 4(2), 139-154.
- [157] Donoho, D. L., Johnstone, J. M. (1994). Ideal spatial adaptation by wavelet shrinkage, *Biometrika*, 81(3), 425–455.
- [158] Girdher, A., Goyal, B., Dogra, A., Dhindsa, A., Agrawal, S. (2019). Image Denoising: Issues and Challenges, *Proceedings of International Conference on Advancements in Computing & Management (ICACM)*.
- [159] Gu, S., Timofte, R. (2019). A Brief Review of Image Denoising Algorithms and Beyond. Inpainting and Denoising Challenges, *The Springer Series on Challenges in Machine Learning*, 1-21.