

Düşük Çözünürlüklü Video Sahnelerinden Yüksek Çözünürlüklü Video Sahnelerinin Elde Edilmesi

Yıldıray Anagün

DOKTORA TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Ekim 2018

Generating High Resolution Video Scenes from Low Resolution Video Frames

Yıldıray Anagün

DOCTORAL DISSERTATION

Department of Electrical and Electronics Engineering

October 2018

Düşük Çözünürlüklü Video Sahnelerinden Yüksek Çözünürlüklü Video Sahnelerinin Elde Edilmesi

Yıldıray Anagün

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Elektrik Elektronik Mühendisliği Anabilim Dalı
Telekomünikasyon Sinyal İşleme Bilim Dalında
DOKTORA TEZİ
Olarak Hazırlanmıştır

Danışman: Dr. Öğr. Üyesi Erol Seke

Ekim 2018

ONAY

Elektrik Elektronik Mühendisliği Anabilim Dalı Doktora öğrencisi Yıldırım ANAGÜN' ün DOKTORA tezi olarak hazırladığı “Düşük Çözünürlüklü Video Sahnelerinden Yüksek Çözünürlüklü Video Sahnelerinin Elde Edilmesi” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğin ilgili maddeleri uyarınca değerlendirilerek oybirliği ile kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Erol Seke

İkinci Danışman : -

Doktora Tez Savunma Jürisi:

Üye : Dr. Öğr. Üyesi Erol Seke

Üye : Prof. Dr. Ömer Nezih Gerek

Üye : Prof. Dr. Rıfat Edizkan

Üye : Dr. Öğr. Üyesi Nihat Adar

Üye : Dr. Öğr. Üyesi Muammer Akçay

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve
..... sayılı kararıyla onaylanmıştır.

Prof. Dr. Hürriyet ERŞAHAN
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Dr. Öğr. Üyesi Erol Seke danışmanlığında hazırlamış olduğum “Düşük Çözünürlüklü Video Sahnelerinden Yüksek Çözünürlüklü Video Sahnelerinin Elde Edilmesi” başlıklı DOKTORA tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 02/10/2018

Yıldıray ANAGÜN

ÖZET

Görüntü çözünürlüğü, bir görüntünün kalitesini belirlemede temel ölçütlerden biridir. Yüksek çözünürlük (YÇ) bir resimde detayların daha çok olması demektir ve bu nedenle askeri, ticari, tıbbi ve benzeri birçok uygulamada istenen bir çözümdür. Kaliteli görüntü algılayıcıları veya optik donanım kullanılması ise pahalı ve sınırlayıcı bir çözümdür. Uygun maliyetli ve etkili bir çözüm, düşük çözünürlüklü (DÇ) görüntülerden yüksek çözünürlüklü görüntü (ler) üretebilen görüntü işleme tekniklerinin kullanılmasıdır. Bu tür görüntü çözünürlüğü iyileştirme yöntemleri süper-çözünürlük (SÇ) görüntü yeniden yapımı olarak adlandırılır.

Bu tez kapsamında öncelikle döndürme ile Değişken Blok Boyutlu-Hareket Tahmini (VBS-ME) kullanılarak yüksek çözünürlüklü görüntü elde edilmesi amaçlanmıştır. Daha sonra çıktı görüntü kalitesini arttırmak için, bu ilk çalışmaya ek olarak makro blok hareket kestirimine ve gradyan büyüklüğüne dayalı yeni bir video SÇ yöntemi önerilmiştir. Kötü durumlu SÇ probleminde yanlış hareket tahmini, çıktı görüntüsünün kalitesini doğrudan etkilemektedir. Bu nedenle hareket tahmininde blok eşleştirme temelli yöntemlerin sınırlı başarıya sahip olmasından dolayı, bir sonraki çalışmada translasyonel optik akış modeli tercih edilmiştir. Ayrıca, yeniden yapım aşamasında gürültü, gölgelenmeler veya yanlış hareket kestiriminden kaynaklanan sorunları ortadan kaldırmak için Ortak Vektör Yaklaşım (CVA) kullanılmıştır. Son yıllarda Evrişimsel Sinir Ağları (CNN) görüntü ve sinyal işlemede en güçlü araçlardan biri olarak kabul edilmiş ve büyük miktarda veriyi işleyebildiğinden literatürde çok yaygın hale gelmiştir. Son çalışmamızda, derin ve sığ CNN mimarileri kullanılarak Tek Resim Süper-Çözünürlük (SISR) performansı üzerinde çeşitli kayıp fonksiyonlarının etkinliği karşılaştırılmış ve eleştirisel bir inceleme yapılarak bazı öneriler sunulmuştur. Sonuç olarak, birçok SÇ metodu ve algoritması üzerinde çalışılarak önemli ve kayda değer sonuçlar elde edilmiştir.

Anahtar kelimeler: Süper-Çözünürlük, Yüksek Çözünürlük, Ara değerlendirme, Değişken Blok Boyutlu Hareket Tahmini, Ortak Vektör Yaklaşımı, Evrişimsel Sinir Ağları.

SUMMARY

Image resolution is one of the main criteria for determining the quality of an image. High resolution (HR) means more details in an image and therefore it is a desired solution in many applications such as military, commercial, medical and many other. The use of high-quality image sensors and optical hardware is an expensive and limited solution. A cost-efficient and effective solution is the use of image processing techniques that can produce high resolution image (s) from low resolution (LR) images. This type of image resolution improvement methods is called super-resolution (SR) image reconstruction.

In the initial studies of this thesis, it is aimed to obtain high resolution image using Variable Block Size Motion Estimation (VBS-ME) with rotation. Then, in addition to this previous work, a new video SR method based on macro block motion estimation and gradient magnitude was proposed in order to improve the output image quality. Inaccurate motion estimation directly affects the quality of the output image in ill-posed SR problem. In order to avoid it, the translational optical flow model was preferred in next study because of block matching based methods have limited success in motion estimation. Furthermore, the Common Vector Approach (CVA) was used in the reconstruction step to eliminate the problems caused by noise, shadows or incorrect motion estimation. In recent years CNN has been considered to be one of the most powerful tools in image and signal processing, and has become very popular in the literature as it is able to handle a huge amount of data. In our latest study, the effectiveness of various loss functions on Single Image Super-Resolution (SISR) performance is compared using deep and shallow CNN architectures and some suggestions are made by making a critical review. Consequently, important, and noteworthy results have been obtained by working on many SR methods and algorithms.

Keywords: Super-Resolution, High Resolution, Interpolation, Variable Block Size Motion Estimation, Common Vector Approach, Convolutional Neural Networks.

TEŞEKKÜR

Tez konumun belirlenmesinde, tez sürecinde ve tezimin tamamlanmasında, yapılan arařtırmalarda, karşılařtıđım sorunlarda ve yönlendirmesinde, tezimin tamamlanmasında destek olan tez danışmanım Sayın Dr. Öğr. Üyesi Erol SEKE' ye teşekkür ederim.

Tezimin her aşamasında yardımlarını esirgemeyen, her türlü fikir, görüş, düşünce ve yönlendirmesiyle ilerlememe yardımcı olan değerli hocam Dr. Öğr. Üyesi Nihat ADAR' a ve uygulama kısımlarında bana destek olan değerli hocam Doç. Dr. Kemal ÖZKAN' a teşekkür ederim.

Tezimin tüm aşamasında bana her türlü desteđi sağlayıp yardımcı olan, tezimin tamamlanmasında en büyük katkısı olan meslektaşım ve arkadaşım Arş. Gör. Dr. Şahin IŞIK' a teşekkür ederim.

Hayatım boyunca her zaman olduđu gibi bu süreçte de her türlü destekleriyle yanımda olan, hiçbir zaman maddi ve manevi desteklerini esirgemeyen aileme ve yanımda olan eşime teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
1. GİRİŞ VE AMAÇ	1
2. MATERYAL VE YÖNTEM	4
2.1. Görüntünün Algılanması ve Sayısallaştırılması	4
2.2. Yüksek (Süper) Çözünürlük	5
2.3. Gözleme Modeli	7
3. LİTERATÜR ARAŞTIRMASI	10
4. TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR	14
4.1. Dönme İçeren Değişken Blok Boyutlu Hareket Tahmini ile Süper-Çözünürlük	14
4.1.1. Uygulama Süreçleri ve Akış Diyagramı	18
4.1.2. Dönmeli VBS-ME Yöntemi Deneysel Çalışmaları	18
4.2. Blok Karşılaştırma ve Gradyan Büyüklüğüne Dayalı Video Süper-Çözünürlük	22
4.2.1. Uygulama Süreçleri ve Akış Diyagramı	23
4.2.2. Gradyan Temelli Blok Tahmini	25
4.2.3. Aykırı Piksellerin Ayıklanması	26
4.2.4. Blok Karşılaştırma ve Gradyan Büyüklüğüne Dayalı Video Süper-Çözünürlük Yöntemi Deneysel Çalışmaları	28
4.3. Ortak Vektör Yaklaşım Temelli Çoklu-Çerçeve Süper-Çözünürlük Yöntemi	33
4.3.1. Blok Hareket Tahmini	35
4.3.2. Ortak Vektör Yaklaşımı	35
4.3.3. CVA-tabanlı Süper-Çözünürlük Yeniden Yapımı	38

İÇİNDEKİLER (devam)**Sayfa**

4.3.4. CVA-tabanlı SÇ Yöntemi Deneysel Çalışmaları	43
4.4. Derin ve Sığ Konvolüsyonel Mimariler Üzerinde Süper-Çözünürlük İçin Farklı Kayıp Fonksiyonlarının Karşılaştırılması	53
4.4.1. CNN Mimarilerinde SÇ İçin Kayıp Fonksiyonlarının Analizi	54
4.4.2. Kayıp Fonksiyonlarının Sağlamlık Analizi.....	57
4.4.3. CNN Mimarilerinin Eğitim Süreci.....	60
4.4.4. Deneysel Sonuçlar ve Performans Değerlendirme.....	62
4.4.5. Kayıp Fonksiyonlarının Yakınsama Zamanları	71
5. BULGULAR VE TARTIŞMA	72
6. SONUÇ VE ÖNERİLER	74
KAYNAKLAR DİZİNİ	76
ÖZGEÇMİŞ	83

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
2.1. CCD ve CMOS sensörler.....	5
2.2. Görüntünün algılanması.....	5
2.3. Görüntü örnekleri (BSD100 imge seti/Zebra)	6
2.4. Gözleme Modeli.....	8
2.5. Kayıt ve ara değerlendirme temelli DÇ görüntülerden YÇ resim elde etme	9
4.1. Blok arama yöntemi	16
4.2. Çeşitli test görüntülerine ait örnek blok boyutları	17
4.3. Dönme içeren VBS-ME ile SÇ yöntemi.....	19
4.4. Uygulamada kullanılan klasik test görüntüleri	20
4.5. Dönmeli VBS-ME yöntemin görsel sonuçları	21
4.6. Uygulanan yöntemin akış diyagramı	24
4.7. <i>Foreman</i> video sahnesine ait örnek hareket tahmini	25
4.8. Kayıt algoritmasının ayrıntılı akış diyagramı	27
4.9. <i>Suzie</i> video sahnesi 6., 11., 16. ve 21. karelere ait sonuçlar	30
4.10. <i>Miss America</i> video sahnesi 6., 11., 16. ve 21. karelere ait sonuçlar.....	31
4.11. <i>Foreman</i> video sahnesi 6., 11., 16. ve 21. karelere ait sonuçlar	32
4.12. <i>Foreman</i> , <i>Miss America</i> ve <i>Suzie</i> 6. karesinin 3x yakınlaştırılmış görseli:.....	33
4.13. CVA-tabanlı süper-çözünürlük yöntemi blok diyagramı	34
4.14. Bloklardan (vektörlerden) sınıf oluşturulması	39
4.15. CVA-tabanlı süper-çözünürlük algoritması akış diyagramı	42
4.16. PSNR değerlerine ait grafik	45
4.17. SSIM değerlerine ait grafik.....	46
4.18. <i>Foreman</i> video sahnesi 22. karesine ait sonuçlar	48
4.19. <i>Suzie</i> video sahnesi 8. karesine ait sonuçlar.....	49
4.20. <i>Miss America</i> video sahnesi 23. karesine ait sonuçlar	50
4.21. <i>Stefan</i> video sahnesi 14. ve 23. karelere ait sonuçlar.....	52
4.22. <i>Coastguard</i> video sahnesi 14. ve 23. karelere ait sonuçlar.....	53
4.23. CNN mimarisinde gerçekleştirilen SISR	55
4.24. Gürültülü veriler için kayıp fonksiyonlarının duyarlılık analizi.....	59
4.25. Deneyde kullanılan sığ ve derin CNN mimarileri	61

ŒEKİLLER DİZİNİ (devam)**Sekil****Sayfa**

4.26. Derin CNN mimarisine ait SÇ sonuçları	63
4.27. Kayıp fonksiyonları için yakınsama zamanları.....	71

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
4.1. Değişken blok boyutlu hareket tahmini algoritması	17
4.2. Ortalama PSNR (dB) değerleri	22
4.3. Eşik değeri karar algoritması	25
4.4. Ortalama PSNR (dB) değerleri	29
4.5. CVA-tabanlı süper-çözünürlük yönteminin özet algoritması	42
4.6. Süper-çözünürlük yöntemleri ortalama PSNR (dB) ve SSIM değerleri	51
4.7. CNN mimarilerinde SÇ gerçekleştirmek için kullanılan hata fonksiyonları	56
4.8. Kayıp fonksiyonları için öğrenme katsayıları (Toplam 20 epoc)	60
4.9. Filtre derinliği 64 olan sığ CNN mimarisi PSNR/SSIM sonuçları	65
4.10. Filtre derinliği 128 olan sığ CNN mimarisi PSNR/SSIM sonuçları	66
4.11. Filtre derinliği 256 olan sığ CNN mimarisi PSNR/SSIM sonuçları	67
4.12. Filtre derinliği 512 olan sığ CNN mimarisi PSNR/SSIM sonuçları	68
4.13. Filtre derinliği 64 olan derin CNN mimarisi PSNR/SSIM sonuçları	69
4.14. Filtre derinliği 128 olan derin CNN mimarisi PSNR/SSIM sonuçları	70

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
3DSKR	3-Dimensional Steering Kernel Regression (3 Boyutlu Gerilmiş Çekirdek Regresyonu)
AS	Angle Search (Açılı Arama)
ASD	Analog-Sayısal Dönüştürücü
CCD	Charge-Coupled Device (Yükten Bağlısımlı Aygıt)
CI	Confidence Interval (Güven Aralığı)
CIF	Common Intermediate Format (Ortak Ara Format)
CMOS	Complementary Metal Oxide Semiconductor (Bütünleyici Metal Oksit Yarıiletken)
CNN	Convolutional Neural Networks (Evrışimsel Sinir Ağları)
CVA	Common Vector Approach (Ortak Vektör Yaklaşımı)
DÇ	Düşük Çözünürlüklü
DWT	Discrete Wavelet Transform (Sayısal Dalgacık Dönüşümü)
ES	Exhaustive Search (Tam Arama)
GPU	Graphics Processing Unit (Grafik İşleme Birimi)
İHA	İnsansız Hava Aracı
MAD	Mean Absolute Difference (Mutlak Fark Ortalaması)
MAP	Maximum a Posteriori (Sonsal Olasılığı En Büyükleme)
MÇ	Mevcut Çerçeve
MSE	Mean Square Error (Ortalama Kare Hatası)
NLM	Non-Local Means (Yerel-Olmayan Ortalamalar)
NN	Nearest-Neighbor (En yakın Komşuluk)
POCS	Projection onto Convex Sets (Konveks Setler Üzerine İzdüşüm)
PSF	Point Spread Function (Nokta Yayılım Fonksiyonu)
PSNR	Peak Signal to Noise Ratio (Tepe Sinyal Gürültü Oranı)
QCIF	Quarter Common Intermediate Format (Çeyrek Ortak Ara Format)

SİMGELER VE KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
RÇ	Referans Çerçeve
RANSAC	Random Sample Consensus
ReLU	Rectified Linear Unit (Düzeltilmiş Doğrusal Birim)
SRCNN	Super-Resolution Convolutional Neural Network (Evrışimsel Sinir Ağları Süper-Çözünürlük)
TVR	Total Variation Regularization (Toplam Varyasyon Regülasyonu)
VBS-ME	Variable Block Size Motion Estimation (Değişken Blok Boyutu ile Hareket Tahmini)
VDSR	Very Deep Super-Resolution (Çok Derin Süper-Çözünürlük)
VSRnet	Video Super-Resolution With Convolutional Neural Networks (Evrışimsel Sinir Ağları ile Video Süper-Çözünürlük)
SANC	Structure-Adaptive Normalized Convolution (Yapısal Uyarlamalı Normalize Evrişim)
SGDM	Stochastic Gradient Descent with Momentum (Momentumlu Stokastik Gradyan İnişi)
SISR	Tek Resim Süper-Çözünürlük (Single Image Super-Resolution)
SSIM	Structural Similarity Index Measurement (Yapısal Benzerlik İndeksi Ölçümü)
YÇ	Yüksek Çözünürlük

1. GİRİŞ VE AMAÇ

Son yıllardaki teknolojik gelişmeler, fotoğraf ve video endüstrisinin gelişmesine büyük katkı sağlamıştır. Sayısal ortamın gelişimi ile görüntüler bilgisayar ortamına aktarılmış ve araştırmacılara görüntü işlemede yeni fırsatlar sunmuştur. Görüntüleme teknikleri ise son on yılda hızla gelişerek çok iyi düzeylere ulaşmıştır. Günümüzde kullanılan donanımlarda YÇ resim elde edebilen işlemciler kullanılabilir. Örneğin yüksek çözünürlüklü televizyon (HDTV) için 1920×1080 veya 3840×2160 , bazı ultra HDTV ve mobil cihazlar için 2048×1536 çözünürlükte görüntü alabilmek mümkündür. Bu çeşit YÇ resimler, sağlık, uzay araştırmaları, askeri (kızılötesi görüntüleme vb.), ticari ve haritalama gibi birçok alanda kullanılmaktadır.

Yüksek çözünürlüklü resimler ile ayrıntılar daha net görülür. Örneğin, YÇ bir görüntü, tıbbi görüntüleme doktorlara teşhis koymada yardımcı olabilmektedir. Giderek kullanımı yaygınlaşan insansız hava araçları (İHA), özellikle gözetleme olmak üzere birçok askeri ve sivil alanda kullanılmaktadır. İHA ile elde edilen görüntüler genellikle bulanık, gürültülü ve yetersiz uzamsal çözünürlük sergileyebilmektedir. Bu nedenle İHA' lardan elde edilen görüntülerde yazılımsal olarak YÇ elde etme teknikleri daha sık kullanılmaktadır.

Literatürde SÇ olarak da bilinen bu kötü durumlu (ill-posed) problem uzun bir zamandır bilim adamları için bir araştırma konusudur. SÇ bir veya birden fazla DÇ, gürültülü ve bulanık görüntüden bir veya birden fazla YÇ görüntü elde etmeyi amaçlamaktadır. Dijital kameralar, telefonlar ve tabletler gibi günlük kullandığımız elektronik cihazlarda bulunan kamera sensörleri, uygun ortam ve ışık altında YÇ görüntü ve video üretebilmektedir. Ancak bazı durumlarda YÇ görüntü ihtiyacı kaçınılmazdır. Bunlar;

- İzleme sistemlerindeki cihazların YÇ görüntü üretememesi,
- Kameranın uzak olmasından ve çerçeve boyutunun küçük olması nedeniyle nesnelere detayların (insan yüzü, araç plakası vb.) tam olarak görülmemesi,
- Gürültü ve bulanıklık meydana gelmesi,

- Önişleme olarak çözünürlüğün arttırılması ihtiyacı (yüz algılama vb.),
- Bazı video ve resim uygulamalarının kameraların sunduğundan daha iyi çözünürlük talep etmesi

gibi durumlar olarak sıralanabilir.

Bu doktora tezinin amacı DÇ çoklu çerçevelerdeki bilgileri kullanarak daha kaliteli ve ayrıntılı bir veya birden çok görüntü elde etmektir. Önerilen yöntemlerin sonuçları, daha yüksek uzamsal (spatial) çözünürlüğe sahip olup keskin kenarlı ve daha az gürültüldür.

Tezin literatüre katkıları ise şöyledir;

1. VBS-ME tekniği ile kamera hareketine paralel olan dönme ve ötelenme değerlerini alt piksel seviyesinde kullanan bir yöntem geliştirilmiştir.
2. Önceki yöntem geliştirilerek makro blok hareket kestiriminin ve blokların gradyan büyüklüğünün birlikte ele alındığı yeni bir video SÇ yöntemi modellenmiştir.
3. Sonuç görüntüsünde aykırı değerlerden kaynaklanacak sorunları en aza indirebilen CVA-tabanlı yeniden yapım algoritması gerçekleştirilmiştir.
4. Son gelişmelere paralel olarak CNN-tabanlı SÇ yöntemleri analiz edilerek SÇ için en iyi regresyon kayıp fonksiyonları önerilmiştir.

Tezin genel yapısı ise aşağıdaki şekildedir.

Bu tez çalışmasının 1. bölümünde SÇ yöntemine neden ihtiyaç duyulduğu ve SÇ yaklaşımının genel kullanım alanlarından bahsedilmiştir.

2. bölümde materyal ve yöntemler ana başlığı altında genel kabul görmüş sayısal görüntü modeli ve teknolojik olarak kullanılan donanımlardan bahsedilmiştir. Ayrıca YÇ yaklaşımı ele alınarak, çeşitleri ve matematiksel modeli detayları ile anlatılmıştır.

3. bölümde, konu ile ilgili literatür araştırması sunulmuş ve daha önce yapılan çalışmalardan bahsedilmiştir.

4. bölümde tez kapsamında yapılan çalışmalar sırası ile anlatılmaktadır. Yüksek çözünürlük elde edebilmek için öncelikle doğru hareket tahmininin yapılabilmesi gerekmektedir. Hareket tahmini ne kadar iyi yapılırsa elde edilen YÇ görüntünün kalitesi de o oranda artmaktadır. İlk çalışmamızda dönme içeren VBS-ME kullanılarak yapılan SÇ yaklaşımından bahsedilmektedir (Anagün ve Seke, 2012). Daha sonra VBS-ME blok tabanlı hareket kestirimine ek olarak blokların gradyan büyüklükleri ve tiplerine (kenar veya düzlemsel) dayalı hareket tahmini modeli geliştirilmiştir. Ayrıca piksel ortalaması hesaplanırken doğrudan ortalama almak yerine ortalamaı saptıran aykırı piksellerin ayıklanabilmesi için istatistik tabanlı bir filtre uygulanarak SÇ sonuç görüntüsünün kalitesi artırılması hedeflenmiş ve gerçekleştirilmiştir (Anagün vd., 2015). Blok karşılaştırma ile hareket tahmini hassasiyeti büyüme katsayı ile orantılı olarak değişebilmektedir. Örneğin büyüme katsayısı 3 olduğunda yapılabilecek alt-piksel hesabı 0,33 piksel hassasiyeti kadar olmaktadır. Gerçekte ise daha hassas alt-piksel değerleri olabilir. Bu nedenle, bir sonraki çalışmamızda daha doğru ve hassas blok hareket tahmini (ME) için translasyonel optiksel akış yöntemi kullanılmıştır. Yeniden yapım aşamasında ise bir pikseli iyileştirebilmek için komşu pikselleri ağırlıklı olarak kullanan ve gürültünün neden olduğu sorunları büyük ölçüde ortadan kaldıran CVA temeline dayalı yeni bir yöntem önerilmiştir. Böylece sonuç görüntüsünde daha keskin ve gürültüsüz sonuçlar elde edilmiştir (Seke vd., 2018).

Ekran kartlarındaki Grafik İşleme Birimi (GPU) teknolojisinin gelişmesi ile derin öğrenme mühendislik uygulamalarında daha yaygın bir şekilde kullanılmaya başlamıştır. Derin öğrenmenin özelleşmiş bir mimarisi olan CNN görüntü işlemede oldukça başarılıdır. Gelecekte YÇ konusunda CNN modeli kullanılarak geleneksel yöntemlere göre daha başarılı sonuçlar üretilebilmesi mümkündür. Tez kapsamında yapılan son çalışmamızda görüntü işleme alanında yapılan en son teknolojik gelişmelere paralel olarak derin öğrenme tabanlı SÇ yöntemleri üzerinde durulmuştur. Bu bağlamda on iki farklı regresyon kayıp fonksiyonu ayrı ayrı derin ve sığ CNN mimarileri üzerinde kullanılarak performansları test edilerek CNN-tabanlı SÇ yöntemleri için hangi kayıp fonksiyonunun daha verimli olacağı deneysel olarak gösterilmiştir. 5. bölümde elde edilen sonuçlar ve önerilen tüm yöntemler karşılaştırmalı olarak sunulmuş, son bölümde ise sonuçların genel değerlendirilmesi yapılarak gelecekte planlanan çalışmalardan bahsedilmiştir.

2. MATERYAL VE YÖNTEM

2.1. Görüntünün Algılanması ve Sayısallaştırılması

Film kameralarında ve sayısal kameralarda görüntünün oluşturulması yapısal olarak aynıdır. Bunun için makinelerde lensler kullanılmaktadır. Lens, görüntüleme kalitesi açısından en önemli bileşenlerden biridir. Uygun olmayan lensler, netlik (çözünürlük) kaybına yol açarak optiksel bulanıklığa neden olabilmektedir. Merceğin içinden geçen ışınla (foton) resim oluşur ve oluşan resim ışığın lens içindeki hareketine göre değişir. Işığın lense giriş açısı ve lensin fiziksel yapısı söz konusu hareketi etkileyen önemli faktörlerdir.

Nesneden merceğe giden ışığın merceğe giriş açısı, nesne ile mercek arasındaki mesafeye göre değişiklik gösterir. Nesne uzakta olduğunda görüntü küçük, yakında olduğunda görüntü büyük olur. Nesneden çıkan ışınlar mercekte geçtikten sonra kesişmeleri gereken noktada kesişemezlerse görüntüde bulanıklık meydana gelir. Kamerayı nesneye çok yakın ya da çok uzak tuttuğumuzda bunu çok net olarak fark edebiliriz.


Piyasadaki endüstriyel kameralar için Yükten Bağlı Ayrık (CCD) ve Bütünleyici Metal Oksit Yarıiletken (CMOS) olmak üzere iki tip görüntü sensörü vardır. Mercekte geçen ışık makine içerisindeki ışığa duyarlı hücrelerden oluşmuş sensör üzerine düşer ve sayısal hale getirilir (Şekil 2.1). Her sensör, ışığa maruz kaldığında bir elektrik akımı oluşturur. Akımın gücü ışığın parlaklığı ile doğru orantılıdır. Ancak elektrik yükünün yakalanması ve bir görüntü dosyasına dönüşme şekli her tip sensör için çok farklıdır. Bir CCD cihazında, yük yonga üzerinden taşınır ve dizinin bir köşesinde okunur. Bir Analog-Sayısal Dönüştürücü (ASD), her bir pikselin değerini dijital bir değere dönüştürür. Çoğu CMOS cihazında, her bir pikselde, daha geleneksel bağlantılar kullanılarak şarjı çoğaltan ve hareket ettiren çeşitli transistörler vardır. CMOS yaklaşımı daha esnek, çünkü her piksel tek tek okunabilmektedir.

CMOS sensörleri, son yıllarda CCD sensörlerine göre önemli güncellemeler ve değişimler geçirmiştir. Yüksek hızları (kare hızı) ve çözünürlüğü (piksel sayısı), düşük güç tüketimi, gelişmiş gürültü karakteristikleri ve renk düzeni, daha önceden CCD sensörlerinin kullanıldığı alanlarda kullanımına olanak sağlamıştır.



Şekil 2.1. CCD ve CMOS sensörler

ASD, sensörden aldığı elektrik sinyalini bilgisayar ortamında işleyebilmek için ikilik tabanda sayısal görüntü verisine dönüştürür. ASD işlemleri örnekleme, niceleme ve kodlama olarak sıralanabilir (Şekil 2.2).



Şekil 2.2. Görüntünün algılanması

2.2. Yüksek (Süper) Çözünürlük

Çözünürlük çekilen bir fotoğrafın, toplamda ne kadar pikselden oluştuğunu belirtir. Yatay ve dikey piksellerin, diğer bir ifade ile çözünürlüğün çarpımı ile elde edilen bir sayıdır ve yaklaşık değere yuvarlanır. Piksel ise tüm sayısal görüntülerin en küçük parçası olan üçlü nokta grubudur. YÇ resim, içerisinde bilgi miktarının daha çok olmasıdır ve bilgiyi arttırabilmek için ise en sık kullanılan çözüm piksel boyutunu azaltarak alan başına düşen piksel sayısını arttırmaktır. YÇ resim, görüntüleme cihazlarının donanımsal

özellikleri (işlemci hızı, sensör boyutu vb.) arttırılarak veya yazılımsal olarak yapılabilir. Büyük boyutlu sensörlerin pikselleri daha büyük olduğu için, yüzeyine düşen foton miktarına bağlı olarak görüntünün kalitesi de artacaktır. Küçük pikselde enerji dağılımından kaynaklanan ısı fazlalığı ve dar alanda piksel sayısının artması piksel başına düşen ışık miktarını azaltır. Şu an günümüzde giga piksel çözünürlüğünde görüntü elde eden kameralar olmasına rağmen maliyet açısından fiyatları oldukça yüksektir. YÇ üretebilmek için alternatif çözüm maliyeti daha az olan yazılımları kullanmaktır.

Çözünürlükte kameranın tasarımı önemli bir faktördür. Aynı anda birden fazla resmi arka arkaya yakalamak oldukça zordur. DÇ resimler arasında kamera hareketinden ya da odaklamadan kaynaklanan farklılıklar meydana gelebilmektedir. YÇ resim, seri halde yakalanan DÇ resimlerdeki piksel bilgilerini kullanarak elde edilebilmektedir.

YÇ resim yapımındaki zorluklardan birincisi hareket parametrelerinin doğru bir şekilde hesaplanamamasıdır. Hareket tahmininde yapılacak yanlış bir tahmin, YÇ sonuç resminde bozulmaya neden olur. Bir başka zorluksa, farklı şekillerde kaydedilmiş DÇ resimlerdeki bilgiyi gürültü, ışık, parlama vb. nedenlerden dolayı doğru kullanamamaktır.

YÇ resim daha çok çözümüleme gücüne sahip resimdir diyebiliriz. Çözünürlük gücünü arttırmak için bir resme, yüksek frekanslı bilgilerini yani detayları eklemek gerekir (Şekil 2.3). DÇ resimden yukarı örneklenip ara değerlendirme yapılarak elde edilmiş resim orijinal resme göre YÇ değildir. Daha çok piksel sayısına sahiptir ancak çözünürlük gücü aynı kalmıştır. Ara değerlendirme yapılarak büyütülmüş görüntü orijinale göre daha çok ayrıntı içermez.



(a)

(b)

Şekil 2.3. Görüntü örnekleri (BSD100 imge seti/Zebra): a) DÇ görüntü, b) YÇ görüntü

YÇ, tek bir görüntü veya video sekansındaki birkaç kare kullanılarak da yapılabilir. Tek görüntülü (veya tek kare (çerçeve)) temelli YÇ yöntemlerinde, DÇ ve YÇ görüntü arasındaki eşleşme (mapping) yani haritalama kullanır. Bu amaçla DÇ ve YÇ çiftlerini içeren resimlerden veri tabanları oluşturulmakta ve eğitim seti olarak kullanılmaktadır. Öğrenilen haritalama, YÇ içindeki görüntü detaylarını yeni görüntüde tahmin edebilmek için kullanılmaktadır.

Diğer taraftan, çoklu-çerçeve (multi-frame) temeline dayanan YÇ yöntemlerinde, açı, aydınlatma veya konum gibi farklı koşullar altında alınan bir veya birden fazla sahneye ait görüntü arasındaki harekete bağlı ilişki kullanılmaktadır. Bu teknik ile çoklu görüntülerden gelecek farklı verileri (ayrıntılar) uygun şekilde kullanıp çözünürlüğü arttırabilmek mümkün olmaktadır.

2.3. Gözlemeleme Modeli

YÇ görüntü elde etme problemindeki ilk adım DÇ resimleri gözlemelemektir. YÇ resmin boyutu $L_1N_1 \times L_2N_2$ olarak kabul edildiğinde bunu vektör halinde $x = [x_1, x_2, x_3, \dots, x_K]^T$ şeklinde yazabiliriz. Burada $K = L_1N_1 \times L_2N_2$, L_1 yataydaki ve L_2 düşeydeki indirgeme parametreleridir. Her gözlem sonucu elde edilen DÇ resimlerin boyutu $N_1 \times N_2$ ' dir. k . DÇ resimi vektör olarak yazdığımızda $y_k = [y_{k,1}, y_{k,2}, y_{k,3}, \dots, y_{k,K}]^T$ şeklinde yazılabilir. Gözlemlenen DÇ görüntü YÇ görüntünün indirgeme, bulandırma, eğrilme veya dönme sonucu elde edilmiş halidir. Bu nedenle matematiksel olarak aşağıdaki şekilde yazabiliriz.

$$y_k = DH_k M_k X + \eta_k, \quad k = 1, \dots, K \quad (2.1)$$

$D : (N_1N_2)^2 \times L_1N_1L_2N_2$ boyutlu indirgeme matrisi,

$H_k : L_1N_1L_2N_2 \times L_1N_1L_2N_2$ boyutlu bulandırma matrisi,

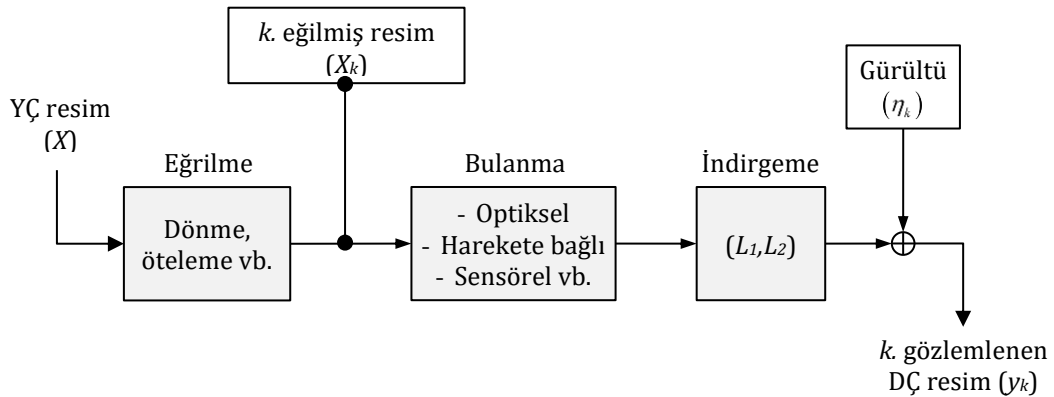
$M_k : L_1N_1L_2N_2 \times L_1N_1L_2N_2$ boyutlu eğme matrisi,

η_k : gürültü vektörünü ifade etmektedir.

Burada M_k dönme, öteleme gibi işlemleri kapsar. Bu işlemlerde her film karesi için referans film karesinden bir sonraki film karesine sahne hareketlerinin tahmin edilmesi gerekir. Bunun için bir tane DÇ resim referans olarak alınarak işleme başlanabilir. Bulanıklığın birçok nedeni olabilir. Optik sistemlerde odaklanmanın dışına çıkma, kırınım sınırı, orijinal görüntü ile görüntüleme sistemi arasındaki hareketten ya da sensörlerin fiziksel yapısı ile ilgili Nokta Yayılım Fonksiyonu'ndan (PSF) kaynaklanabilir. D alt örnekleme matrisi, eğilmiş, dönmüş ya da bulanıklaşmış YÇ görüntüden örtüşmüş DÇ görüntüleri elde eder. DÇ resimlerin boyutları aynı olmasına rağmen genellikle farklı alt indirgeme matrisleri (D_k) kullanılır. Bu açıklamalara dayanarak aşağıdaki matris ifadesini yazabiliriz.

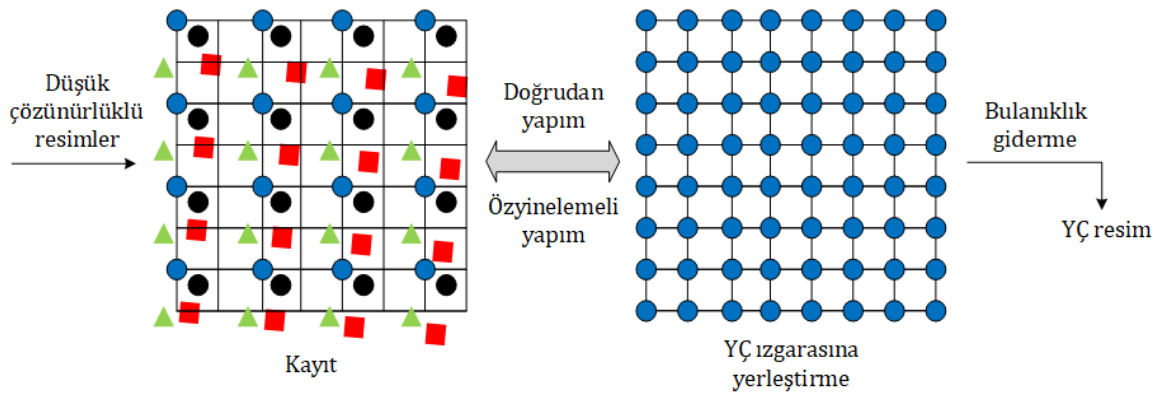
$$\begin{bmatrix} y_1 \\ y_2 \\ \cdot \\ \cdot \\ y_k \end{bmatrix} = \begin{bmatrix} DHM_1 \\ DHM_2 \\ \cdot \\ \cdot \\ DHM_k \end{bmatrix} X + \begin{bmatrix} \eta_1 \\ \eta_2 \\ \cdot \\ \cdot \\ \eta_k \end{bmatrix} \quad (2.2)$$

Dönmüş, eğilmiş ve bulanıklaşmış sahneler arka arkaya alınır. Bunun için kamera hareket halinde olabileceği gibi görüş alanı içindeki nesnelere de hareket edebilir. Şekil 2.4'deki gibi gözlemlenerek elde edilmiş DÇ görüntüleri kullanılarak YÇ resim elde etmek mümkündür.



Şekil 2.4. Gözleme Modeli

Farklı parametreler ile oluşmuş DÇ resimlerden biri referans resim olarak kabul edilir. YÇ için kullanılacak DÇ görüntüler tam piksel değerinde ötelendiğinde, çoğu aynı bilgiyi içerecektir. Bu nedenle söz konusu piksel değerleri yeniden yapılandırmak için kullanılabilir yeni bir bilgi içermeyecektir. Ancak referans resmin piksellerine göre diğer tüm DÇ resimlerin piksel hareketleri biliniyorsa veya alt piksel doğruluğu içinde tahmin edilebiliyorsa YÇ görüntü elde edilebilmesi mümkündür. YÇ ızgara üzerine yerleştirilen bu farklı pikseller ile çeşitli algoritmalar kullanılarak SÇ elde edilebilmektedir (Şekil 2.5).



Şekil 2.5. Kayıt ve ara değerlendirme temelli DÇ görüntülerden YÇ resim elde etme

3. LİTERATÜR ARAŞTIRMASI

Literatürde kısıtlı olmakla birlikte ara değerlendirme yaparak görsel çözünürlüğü arttırabilen en yakın komşuluk (NN) ile piksel çoğaltma, bilinear, bikübik ve Lanczos gibi çeşitli algoritmalar geliştirilmiştir (Wolberg, 1990; Turkowski, 1990). Lanczos, sinc ara değerlemesine yakın sonuçlar vermektedir ve kaliteli görüntü elde etmede sınırlı kalmaktadır (Li ve Orchard, 2001; Wang ve Ward, 2004).

Ara değerlendirme yöntemlerinin başarısının yeterli olmamasından dolayı ara değerlendirme yaparken görüntü kalitesinin artırılması probleminin çözümünde literatürde çeşitli YÇ yöntemleri önerilmiştir. İlk geliştirilen SÇ yöntemlerinde, bir görüntü dizisindeki her çerçeveden gelecek bilgiler ve detaylarla tek bir YÇ görüntü elde edilebileceği gösterilmiştir (Tsai ve Huang, 1984). Bu çalışmada aynı anda birden fazla çerçeveyi frekans ekseninde doğrusal olmayan en küçükleme ile kayıt etme işlemi yapılabildiği gösterilmiştir.

Yerel hareketin olmadığı statik görüntülerde genel çakıştırma (kayıt) kullanan YÇ algoritmaları başarılı sonuçlar vermektedir. Ancak, yerel hareketin olduğu görüntülerde bu tip yöntemler başarısız olmaktadır. Bu nedenle yerel hareketin olduğu görüntü dizilerinde çözünürlüğü arttırabilmek için iki temel işlem yapmak gerekmektedir. Birincisi bir çerçeveden diğer çerçeveye yerel hareket kestirimi yapmak, ikincisi hesaplanan hareket vektörleri kullanarak DÇ çerçevelerden YÇ çerçeve oluşturmaktır (Borman ve Stevenson, 1998; Park vd., 2003). Bu yöntemler YÇ elde etme mekanizmasını en basit durum ile

- i. Hareket tahmini veya kayıt aşaması,
- ii. Ara değerlendirme,
- iii. Gözlemlene modeline bağlı olarak bulanıklık giderme

olarak tanımlanmaktadır.

Zitova ve Flusser (2003) resim kayıt işlemini görsel eksende ve frekans ekseninde yapan bir yöntem sunmuştur. İlinti kullanılarak frekans ekseninde ötelenmiş iki görüntü

arasındaki faz kayması bulunabilir. Örtüşme olmaksızın frekans spektrumuna bağlı düzlemsel kayma tahmini ile ve ayrıca daha sonra örtüşmüş görüntülerden de YÇ resim elde edilebileceğini gösteren çeşitli yöntemler önerilmiştir (Kim ve Su, 1993; Stone vd., 2001; Vandewalle vd., 2006). Marcel vd. (1997), Lucchese ve Cortelazzo (2000) örtüşmüş görüntüler dışındaki görüntülerle çalışmış ve frekans eksenini kullanarak düzlemsel dönmeyi de içeren yeni bir teknik geliştirmişlerdir. Görsel eksen metotları genellikle daha genel hareket modelleri için tavsiye edilmektedir. Diğer bir ifade ile bu tip yöntemler tüm resmi temel almaktadır. Fischler ve Bolles (1981) tarafından geliştirilen RANSAC (Random Sample Consensus) algoritmasında ve Capel ve Zisserman (2003) yönteminde tüm resim ya da seçilmiş öznitelik vektörleri kullanılmaktadır. Schultz vd. (1998) ve Capel ve Zisserman (2003) Sonsal Olasılığı En Büyükleme (MAP) istatistiksel yöntemiyle YÇ resim elde etmişlerdir. Patti vd. (1997) Konveks Setler Üzerine İzdüşümü (POCS) algoritmasını kullanarak YÇ resim elde etmişlerdir. POCS algoritmasında farklı konveks setler üzerine izdüşüm alınarak hesaplama yapılmaktadır. Irani vd. (1994) görüntü dizisindeki kareler arası hareket tahmininde özyinelemeli bir yöntem sunmuşlardır. Taylor serisi kullanarak görüntüler arası hareket tahmini için hiyerarşik bir teknik Keren vd. (1988) tarafından geliştirilmiştir. Bu yöntem özyinelemeli geri yayılım algoritması olarak da bilinmektedir ve görüntü içerisindeki nesnelere görüntüyü parçalara ayırarak takip edilmektedir. Zomet vd. (2001) görüntülerdeki hataların ortalamasını alarak tipik özyinelemeli geri yayılım algoritmasını kullanarak YÇ elde edilebilen yeni bir yöntem geliştirmiştir. Liu vd. (2006) ve Ji ve Fermuller (2009) görüntünün gürültüden veya bulanıklıktan arındırılmasında dalgacık (wavelet) temelli bir yaklaşım sunmuşlardır. Yüksek frekanslı dalgacık katsayılarını DÇ görüntüden, YÇ görüntüyü ise dalgacık dönüşümünün tersini alarak elde etmişlerdir. Farsiu vd. (2004) L_1 -norm en küçüklemeyi kullanarak farklı gürültü ve veri modellerini içeren bir gürbüz YÇ görüntü elde etme modeli önermiştir. Sanchez-Beato ve Pajares (2008) özyinelemesiz ara değerlendirme temelli YÇ elde ederken frekans örtüşmesini ortadan kaldırmıştır. Ancak bu yöntem kayıt hatalarına karşı hassas olabilmektedir. Zhang vd. (2010), Cheng vd. (2011) ve Demirel vd. (2011) çözünürlük arttırmada video sahnelerini kullanmışlardır. Bu yöntemlerde DÇ çerçevelerden ince detayları elde etmede alt piksel seviyesinde kayma miktarını kullanılmaktadır. Buades (2005) Yerel Olmayan Ortalamalar (NLM) yöntemini hedef görüntüdeki benzer kısımlardaki gürültü azaltma işlem için geliştirmişlerdir. Daha sonra bu

düşünce çoklu-çerçevelerde YÇ elde etmek için referans olarak alınmıştır (Protter vd., 2009; Tekada vd., 2009).

Bir görüntüde kamera hareketinden bağımsız nesne hareketlerinin de olması durumunda, evrensel kayıt yapan SÇ yöntemleri başarısız sonuç vermektedir. Bunun üstesinden gelmek için her nesnenin hareketinin izlenmesi amacı ile blok tabanlı hareket kestirim yöntemleri veya optiksel akış yöntemleri kullanılabilir. Lucas ve Kanade (1981) yerel optiksel akış, Horn ve Schunck (1981) ise evrensel optiksel akış temelli yöntem geliştirmişlerdir. Marius ve Sergiu (2011) ise, her iki tekniğin avantajını da kullanarak toplam varyasyon regülasyonu ile birleşik yerel-evrensel optiksel akış yöntemi geliştirmişlerdir.

Brox vd. (2004) önerdiği yöntemde DÇ resimleri statik bloklara ayırması ve klasik YÇ elde etme algoritmalarını uygulamıştır. Izadpanahi vd. (2013) sabit blok boyutu temelli bir yöntem geliştirmiştir. Bu çalışmada DÇ çerçevelerdeki statik ve hareketli alanlar belirlenerek ayrı ayrı işlemlerden geçirilmiştir. Referans çerçeve ile komşu çerçeveler arasında blok eşleştirme temelli hareket tahmini yapılmıştır. YÇ için uygun olan bloklar ile olmayan bloklar uyarlamalı bir eşik değerine göre ayrılmıştır. YÇ yapım aşamasını Yapısal Uyarlamalı Normalize Evrişim (SANC) yöntemi ve ara değerlemeyi Sayısal Dalgacık Dönüşümü (DWT) ile gerçekleştirmişlerdir.

Orijinal YÇ çerçeveleri yeniden yapılandırırken, aynı zamanda hareket, bulanıklık ve gürültü düzeyini de tahmin eden bayes temelli, uyarlanabilir bir video süper çözünürlük yöntemi Liu ve Sun (2014) tarafından önerilmiştir. SÇ denetimsiz (unsupervised) yapılacağı gibi denetimli (supervised) olarak da yapılabilmektedir. Denetimli yöntemler öğrenmeye dayalı yöntemler olup, ana fikir giriş DÇ görüntüleri ile bir eğitim setine dayanan hedef orijinal YÇ görüntüleri arasında bir harita oluşturmaktır. Bu tip yöntemler, tek görüntülü SÇ probleminde yüksek performansa sahiptir. Sparsity tabanlı (sözlük tabanlı) yöntemler, özellikle tek görüntülü SÇ problemi için yaygın olarak kullanılmaktadır (Guo vd., 2012; Gao vd., 2012; Kang vd., 2015; Kaveh ve Ezzatollah, 2017; Mousavi ve Monga, 2017). Temel olarak bu tekniklerde, düşük ve yüksek çözünürlüklü görüntü blok (yama) çiftleri toplanır ve her DÇ blok, karşılık gelen YÇ bir bloğa eşlenir. Bu sayede DÇ görüntülerde eksik detayları bulmada başarılı sonuç sağlanabilmektedir. Ancak, bu

yöntemlerin performansları büyütme faktörü ile ters orantılı olarak değişmektedir. Daha az sayıda eğitim verisi ile hızlı ve daha doğru sonuçların elde edilmesi için yeni bir yöntem Kumar ve Amit (2016) tarafından sunulmuştur. Albu (2016) düşük hesaplama maliyetine sahip yeni bir görüntü kayıt tekniği önermiştir. Bu yöntem, integral izdüşüm vektörlerini kullanarak ölçeklendirme parametresini tahmin etmektedir.

Son yıllarda, derin öğrenme tabanlı yöntemler oldukça yaygın hale gelmiş ve ilk derin Evrişimsel Sinir Ağları Süper-Çözünürlük (SRCNN) yöntemi Dong vd., (2014) tarafından önerilmiştir. Artık (residual) net kullanımı, eğitim süresini ve daha hızlı yakınsama oranını azaltmada büyük başarı göstermiştir. Bu bağlamda He vd., (2016) derin öğrenme üzerine artık net temelli SÇ yöntemi geliştirmişlerdir. Video çerçeveleri üzerinde eğitim ve test işlemi yaparak başka bir Evrişimsel Sinir Ağları ile Video Süper-Çözünürlük (VSRnet) yöntemi Kappeler vd. (2016) tarafından önerilmiştir.

4. TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR

Süper-Çözünürlük probleminin çözümü eski bir araştırma konusu olmasına rağmen günümüzde hala bilim insanları tarafından yeni ve başarılı teknikler geliştirilmektedir. Teknolojik gelişmelere paralel olarak önceden uygulanan yöntemlerin yerini daha güncel araçlar ve algoritmalar almaktadır. Görüntü dizilerindeki hareket tahmini, klasik YÇ elde etmenin en önemli süreçlerden biridir. Önceki yapılan çalışmalarda hareket tahmini aşamasında blok eşleştirmeye dayalı yöntemler kullanırken daha sonraları hız ve doğruluk açısından daha etkili olan optiksel akış temelli yöntemler kullanılmıştır. Tez kapsamında yapılan ilk iki çalışma blok eşleştirme temeline dayanmaktadır.

Hareket kestirimi ne kadar doğru yapılırsa yapılsın sonuç görüntüsünde hareket kestirimindeki hataların etkisi kaçınılmazdır. SÇ alanında literatürde yapılan çeşitli çalışmalarda hareket kestiriminin etkisini azaltacak bir takım yöntemler önerilmiş ve geliştirilmiştir. Bunlardan en göze çarpanı bir pikseli komşu piksellerin ağırlıklı katkıları kullanılarak iyileştirilebildiği yöntemler olmuştur.

Son yıllarda makine öğrenme teknikleri gelişerek görüntü ve sinyal işleme alanında (örüntü tanıma, sınıflandırma, ses analizi, yapay zeka uygulamaları vb.) oldukça sık kullanılmaya başlamıştır. Derin öğrenme yüksek miktarda veri ile çalışmasından dolayı gelişmiş CPU ve (veya) GPU teknolojisine ihtiyaç duymaktadır. Derin öğrenme temeline dayanan yöntemler klasik yöntemlerden daha başarılı sonuçlar vermektedir. Ancak günümüzde hala bilim insanları için geliştirilmeye açık bir araştırma konusudur.

4.1. Dönme İçeren Değişken Blok Boyutlu Hareket Tahmini ile Süper-Çözünürlük

Blok eşleştirme algoritmaları yerel hareket tahmini için kullanılabilir. Başarı oranı sınırlı kalmakla birlikte bu çalışmada sabit blok boyutlu hareket tahmini yerine dönme içeren VBS-ME algoritması kullanılarak SÇ elde edilmesi hedeflenmiştir. Algoritmanın performansını arttırmak için VBS-ME' ye ek olarak makro bloğun dönme miktarı da kullanılmıştır. Önerilen yöntemin sonuçları, sabit blok boyutlu tam arama (ES) ve açılı

arama (AS) ile karşılaştırılmıştır. Her üç yöntemin karşılaştırılmasında hem Tepe Sinyal Gürültü Oranı (PSNR) hem de görsel sonuçlar kullanılmıştır.


Yerel hareketin olmadığı görüntülerde çakıştırma temelli evrensel YÇ elde etme algoritmaları başarılı sonuçlar verir. Ancak, görüntü içerisinde yerel hareketler varsa bu tip algoritmaların başarısı oldukça kötüdür ve kullanılamaz. Bu algoritmaları doğrudan uygulamadan önce, görüntü içerisindeki nesnelere izlenmesi veya hareket tahmini gibi ön işleme tabi tutmak gerekebilir.

Gerçekleştirdiğimiz yöntem yerel seviyede kayıt yaparak YÇ görüntü elde etmektedir. VBS-ME ile hareket parametreleri bulunduğundan sonra alt piksel seviyesinde daha hassas kayıt işlemi yapılarak kayma ve dönme parametreleri Keren vd.'nin (1988) gerçekleştirdiği yöntemle elde edilmektedir. Bu sayede ötelenme parametrelerine ek olarak dönme parametresi de kullanılabilir. Hareketin fazla olduğu bölgelerde büyük blok boyutu kullanılması istenmeyen nesnelere işleme dahil edilmesi anlamına gelmekte ve bu nedenle hata miktarı artmaktadır. Hareketin düşük olduğu yerlerde küçük blok boyutu kullanılması ise işlem karmaşıklığını arttırmaktadır. İki ardışık resim arasında yerel hareketin fazla olduğu bölgelerde daha küçük blok boyutu kullanılırken, hareketin az olduğu bölgelerde daha büyük blok boyutu kullanılmış ve her iki durumun avantajından yararlanılmıştır.

Blokların benzerliğini anlamak için Mutlak Fark Ortalaması (MAD) ölçütü olarak kullanılmıştır. MAD referans çerçeveden (RÇ) gelen blok ile mevcut çerçeveden (MÇ) gelen blok arasındaki mutlak ortalama farkını hesaplamaktadır. N , kullanılan blok boyutunu, sırası ile C ve R mevcut ve referans blok piksel değerlerini göstermek üzere MAD hesabı aşağıdaki denklemlerle hesaplanabilir.

$$MAD = \frac{1}{N^2} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} |C_{ij} - R_{ij}| \quad (4.1)$$

Blok arama yöntemi Şekil 4.1'de verilmiştir. 1. ve 2. en iyi eşleşen bloklar için hareket vektörleri sırası ile v_1 ve v_2 ise toplam hareket vektörü $\Delta v = v_1 + v_2$ olarak bulunur.



Şekil 4.1. Blok arama yöntemi

Şekil 4.2’de görüntü işleme uygulamalarında sık kullanılan çeşitli test resimleri için değişken blok boyutları gösterilmiştir. Bu gösterim için sadece iki çerçeve arasındaki hareketlilik referans olarak alınmıştır. RÇ ve diğer MÇ’ ler (referansa göre ileri ve geri çerçeveler) arasındaki sahne hareketliliğine göre Şekil 4.2’deki blok boyutları değişkenlik gösterebilmektedir. Bir video sekansında MÇ, RÇ’ den uzaklaştıkça çerçeveler arası farkın artacağı, RÇ’ ye yaklaştıkça çerçeveler arası farkın azalacağı varsayılmıştır. Buna göre MÇ üzerinde işlem yapılacak blok boyutları RÇ’ den uzaklaştıkça küçülerek, RÇ’ ye yaklaştıkça blok boyutları büyüyerek harekete uyumlu hale gelmektedir.


Uygun blok boyutu belirlendikten sonra referans alınan blok MÇ’ de belirli bir arama penceresi içerisinde ($p \times p$) tam arama yöntemiyle aranır. MÇ içerisinde referans blok ile en iyi eşleşen 1. en iyi eşleşen mevcut blok bulunur. Daha sonra bu blok etrafında daha küçük bir arama penceresi içerisinde ($r \times r$) dönmeyi de içeren ikinci bir açılı arama yapılır ve referans blok ile mümkün olan en iyi 2. eşleşen blok bulunur. SÇ için 2. en iyi eşleşen bu blok kullanılır. Uygun blok boyutunun tespit edilmesinde Çizelge 4.1’deki algoritma kullanılmıştır.

Çizelge 4.1. Değişken blok boyutlu hareket tahmini algoritması

```

Başla
for  $i = 1: n$ 
  if  $MAD_N^i > \text{eşik değeri}$ 
     $i$ . bloğu 4 eşit  $N/2 \times N/2$  boyutlu bloğa böl
    for  $j = 1: 4$ 
       $j$ . bloğu 4 eşit  $N/4 \times N/4$  boyutlu bloğa böl
      if  $MAD_{N/2}^j < \sum_{k=1}^4 MAD_{N/4}^k$ 
         $N/2 \times N/2$  ' lik blok boyutu kullan
      else
         $N/4 \times N/4$  ' lük blok boyutu kullan
      end if
    end for
  else
     $N \times N$  ' lik blok boyutu kullan
  end if
end for

```



(a)



(c)

Şekil 4.2. Çeşitli test görüntülerine ait örnek blok boyutları: a) Johnny, b) Race Horses

4.1.1. Uygulama Süreçleri ve Akış Diyagramı

Öncelikle DÇ görüntü seti g büyüme katsayı kadar bikübik ara değerlendirme ile üst örneklenir. Bir önceki bölümde açıklanan VBS-ME yöntemi ile t . zamandaki RÇ ve diğer MÇ arasında uygun blok boyutu belirlenir. Kayıt aşamasında, RÇ' den seçilen bloğu g_u^\uparrow ve MÇ' den seçilen bloğu mevcut blok g_v^\uparrow olarak belirlediğimizde iki çerçeve arasındaki öteleme (a,b) ve dönme miktarı θ alt piksel seviyesinde hesaplanır. MÇ bloğu, hareket parametrelerinin tersi kadar ötelenip döndürülerek kayıt işlemi tamamlanmış olur. Önerilen yöntemin akış diyagramı Şekil 4.3'de gösterilmiştir.

RÇ ve MÇ blokları arasındaki ilişki aşağıdaki denklemle verilmiştir.

$$g_u^\uparrow(x, y) = g_v^\uparrow(x \cos \theta - y \sin \theta + a, y \cos \theta + x \sin \theta + b) \quad (4.2)$$

RÇ ve MÇ blokları arasındaki hata miktarı ise aşağıdaki denklemle hesaplanabilir.

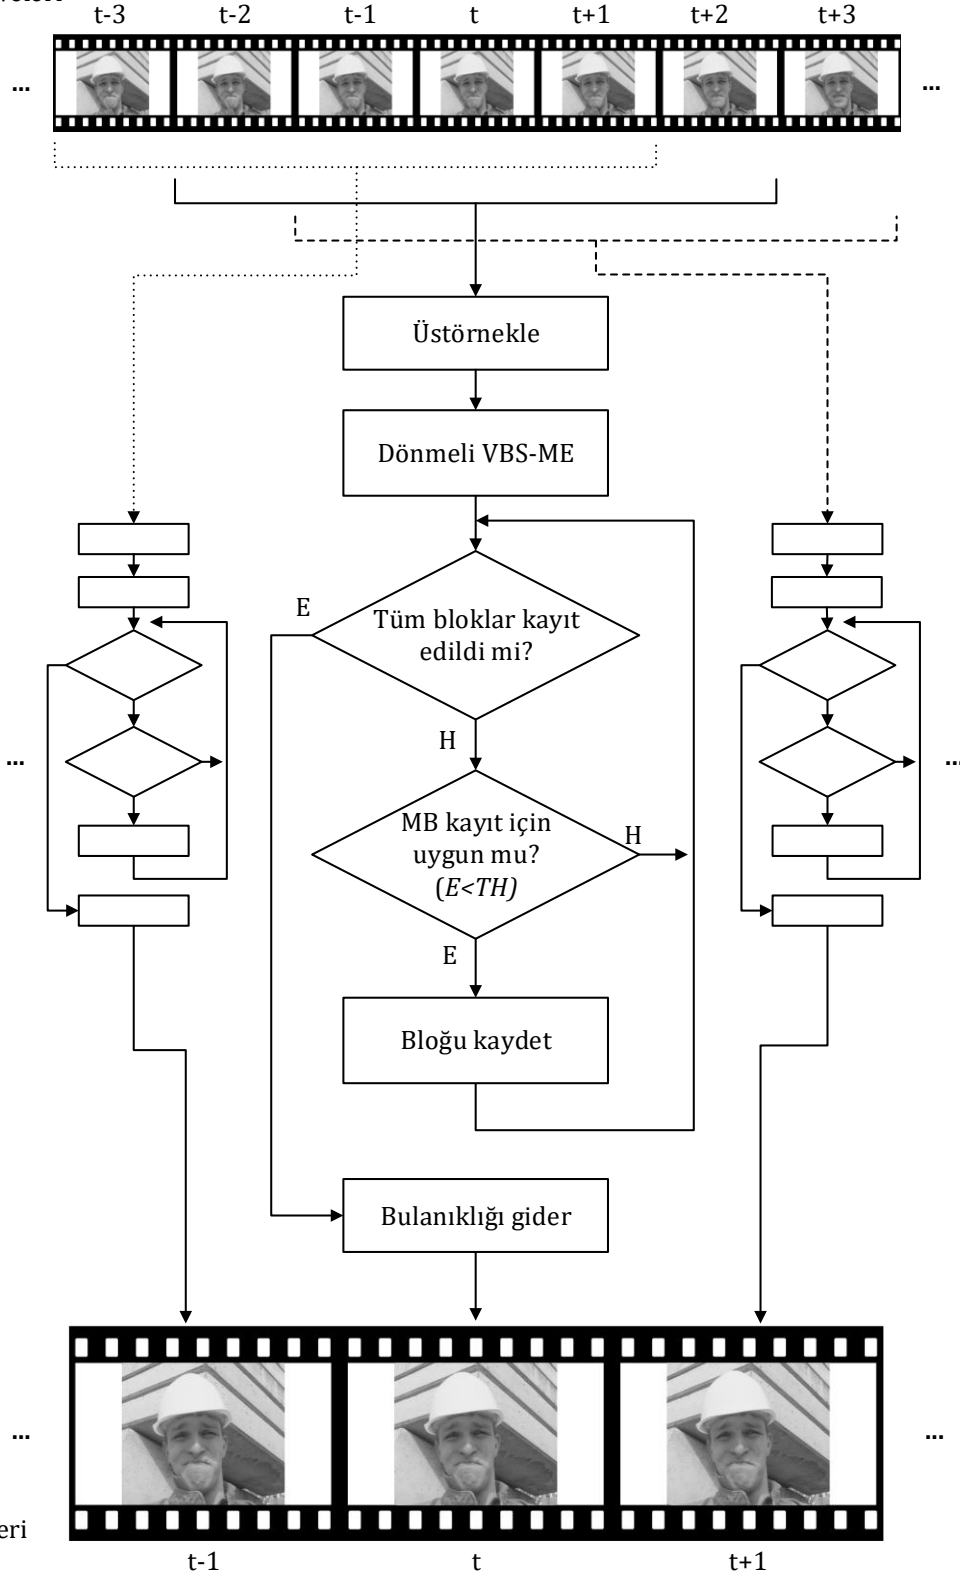
$$E_{u,v} = \left| g_u^\uparrow(x, y) - g_v^\uparrow(x \cos \theta - y \sin \theta + a, y \cos \theta + x \sin \theta + b) \right| \quad (4.3)$$

Bazı durumlarda yeni nesnelere görüntüye girebilir veya mevcut nesnelere görüntünün dışına çıkabilir. Başka bir deyişle, MÇ içerisinde, RÇ bloğuna ye en yakın bloğu bulduğumuzda, SÇ için uygun olmayabilir. Bu nedenle, hareket kestirimi sonucu bulunan en düşük maliyetli bloğun uygun olup olmadığı test edilmelidir. Çünkü uygun olmayan bir blok hata miktarını artırır ve YÇ görüntüsünde bozulmaya neden olur. Bu amaçla deneysel olarak belirlenmiş bir eşik değeri ($E_{u,v} < 0,1$) kullanılmıştır.

4.1.2. Dönmeli VBS-ME Yöntemi Deneysel Çalışmaları

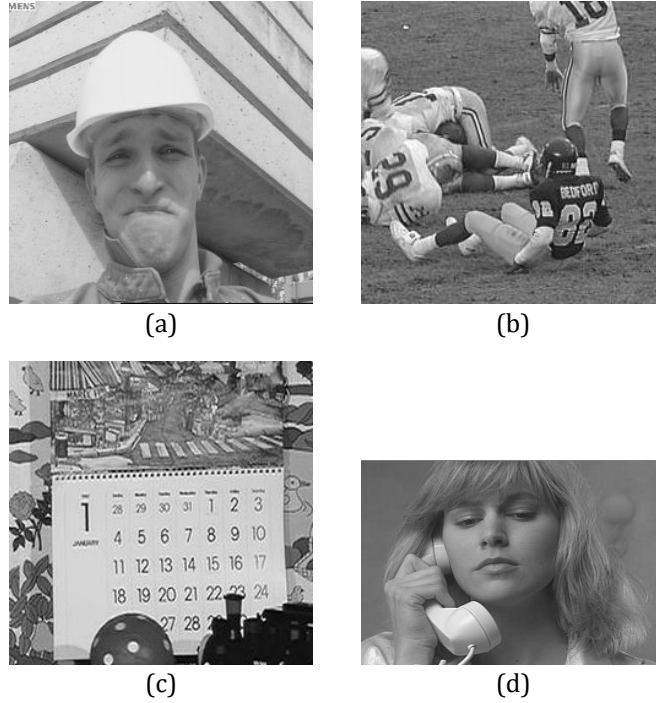
Önerilen yöntemin performansı, *Foreman*, *Football* ve *Mobile* video sahnelerinin Ortak Ara Format (CIF) sürümleri (çerçeve boyutu 352×288) ve *Suzie* video sahnesinin Çeyrek Ortak Ara Format (QCIF) sürümü (çerçeve boyutu 176×144) kullanılarak test edilmiştir. Şekil 4.4'de çalışmada kullanılan video sahnelerinin her birinden tipik çerçeveler gösterilmiştir. Karmaşık ön plan hareketi ve dinamik arka plan *Foreman* video

DÇ ve gürültülü
giriş çerçeveleri



Şekil 4.3. Dönme içeren VBS-ME ile SÇ yöntemi

sahnesinin tamamı boyunca bulunmaktadır. *Football* video sahnesi yerel detaylara ve yüksek miktarda harekete sahip olmakla beraber, insan uzuvları vücutlarından farklı hareket etmektedir. Bu nedenle, birden fazla sabit olmayan ön plan nesnelere içerdiği söylenebilir. *Mobile* ve *Suzie* video sahnelerinde ise sabit arka plan ile dinamik bir ön plan hareketi bulunmaktadır. DÇ test görüntü dizileri de bu görüntülerden yapay olarak elde edilmiştir. Kullanılacak her çerçeve satır ve sütunda 2 katsayısı ile alt örneklenmiş ve 3×3 Gauss bulanıklık filtresinden geçirilmiştir. Ayrıca her çerçeveye standart sapması 0,001 olan gürültü eklenmiştir. Bir tane SÇ çerçeve oluşturmak için 15 tane DÇ çerçeve (referansa göre 7 ileri, 7 geri ve 1 tane referans çerçeve) kullanılmıştır.



Şekil 4.4. Uygulamada kullanılan klasik test görüntüleri: a) Foreman, b) Football, c) Mobile, d) Suzie

Farklı blok arama yöntemleri kullanılarak algoritmanın performansı test edilmiştir. Sabit blok boyutlu ES hareket tahmini ile SÇ yöntemi, önerdiğimiz sabit ve dinamik blok boyutlu AS tabanlı SÇ algoritması ile karşılaştırılmıştır. Blok arama aralığı ES için ± 15 piksel ve AS için ± 3 piksel olarak ayarlanmıştır. Orijinal çerçeve ile birlikte, bikübik ara değerlendirme, evrensel kayıt, sabit blok boyutlu ve dönme içeren VBS-ME SÇ yöntemlerinin görsel sonuçları Şekil 4.5’de verilmiştir.



Şekil 4.5. Dönmeli VBS-ME yöntemin görsel sonuçları: a) Orijinal resim, b) Bikübik ara değerlendirme, c) Global kayıt, d) 8×8 blok boyutlu ES, e) 8×8 blok boyutlu AS, f) AS (VBS-ME) ait sonuçlar

Sonuçları görsel kalite olarak kıyaslamamızın yanında, benzerliği sınamak için matematiksel nesnel ölçüm birimi olan PSNR değeri kullanılmıştır. Ortalama Kare Hatası (MSE) ve PSNR hesabı aşağıdaki denklemlerde, elde edilen ortalama PSNR sonuçları ise Çizelge 4.2’de verilmiştir.

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i, j) - K(i, j)]^2 \quad (4.4)$$

$$PSNR = 20 \log_{10} \left(\frac{2^B - 1}{\sqrt{MSE}} \right) \quad (4.5)$$

Çizelge 4.2. Ortalama PSNR (dB) değerleri

Yöntem	<i>Foreman</i>	<i>Football</i>	<i>Mobile</i>	<i>Suzie</i>
Bicubic	32,85	24,61	21,40	34,43
Global kayıt	27,37	20,74	20,28	35,48
ES (8x8 blok boyutlu)	29,78	23,96	21,11	35,52
AS (8x8 blok boyutlu)	33,36	24,77	22,03	35,36
AS (VBS-ME)	33,73	25,06	22,10	35,96

4.2. Blok Karşılaştırma ve Gradyan Büyüklüğüne Dayalı Video Süper-Çözünürlük

SÇ teknolojisi gözlemlenen DÇ görüntü setinden yeni bir YÇ görüntü elde etmeyi amaçlamaktadır. Hatalı yapılacak hareket tahmini SÇ sonuç resminde istenmeyen sonuçlar meydana getirmektedir. Yapılan bu çalışmada önceki çalışmamızda meydana gelen hareket kestirimi hatalarının giderilmesi amaçlanmıştır. Bu nedenle blok eşleştirme ile hareket tahmininin yanında blokların gradyan büyüklükleri ve tiplerine dayalı bir SÇ yaklaşımı sunulmuştur. SÇ için uygun olmayan blokları ortadan kaldırarak daha kaliteli görüntü elde edebilmek için sabit ve uyarlanabilir eşik değerleri kullanılmıştır. Ayrıca uygun olmamasına rağmen eşik değeri ile süzölemeyen blok pikselleri için aykırı değer ayıklaması yapılarak sonuç görüntüsünde bir miktar daha iyileşme sağlanmıştır. Son olarak, YÇ resim üzerinde bulanıklık giderme işlemi ile kenar bölgeleri daha keskin hale getirilmiştir. Uygulanan yöntemin sonuçları NN ve Lanczos ara değerlendirme yöntemleri ile hem görsel hem de PSNR metriği ile karşılaştırılmıştır.

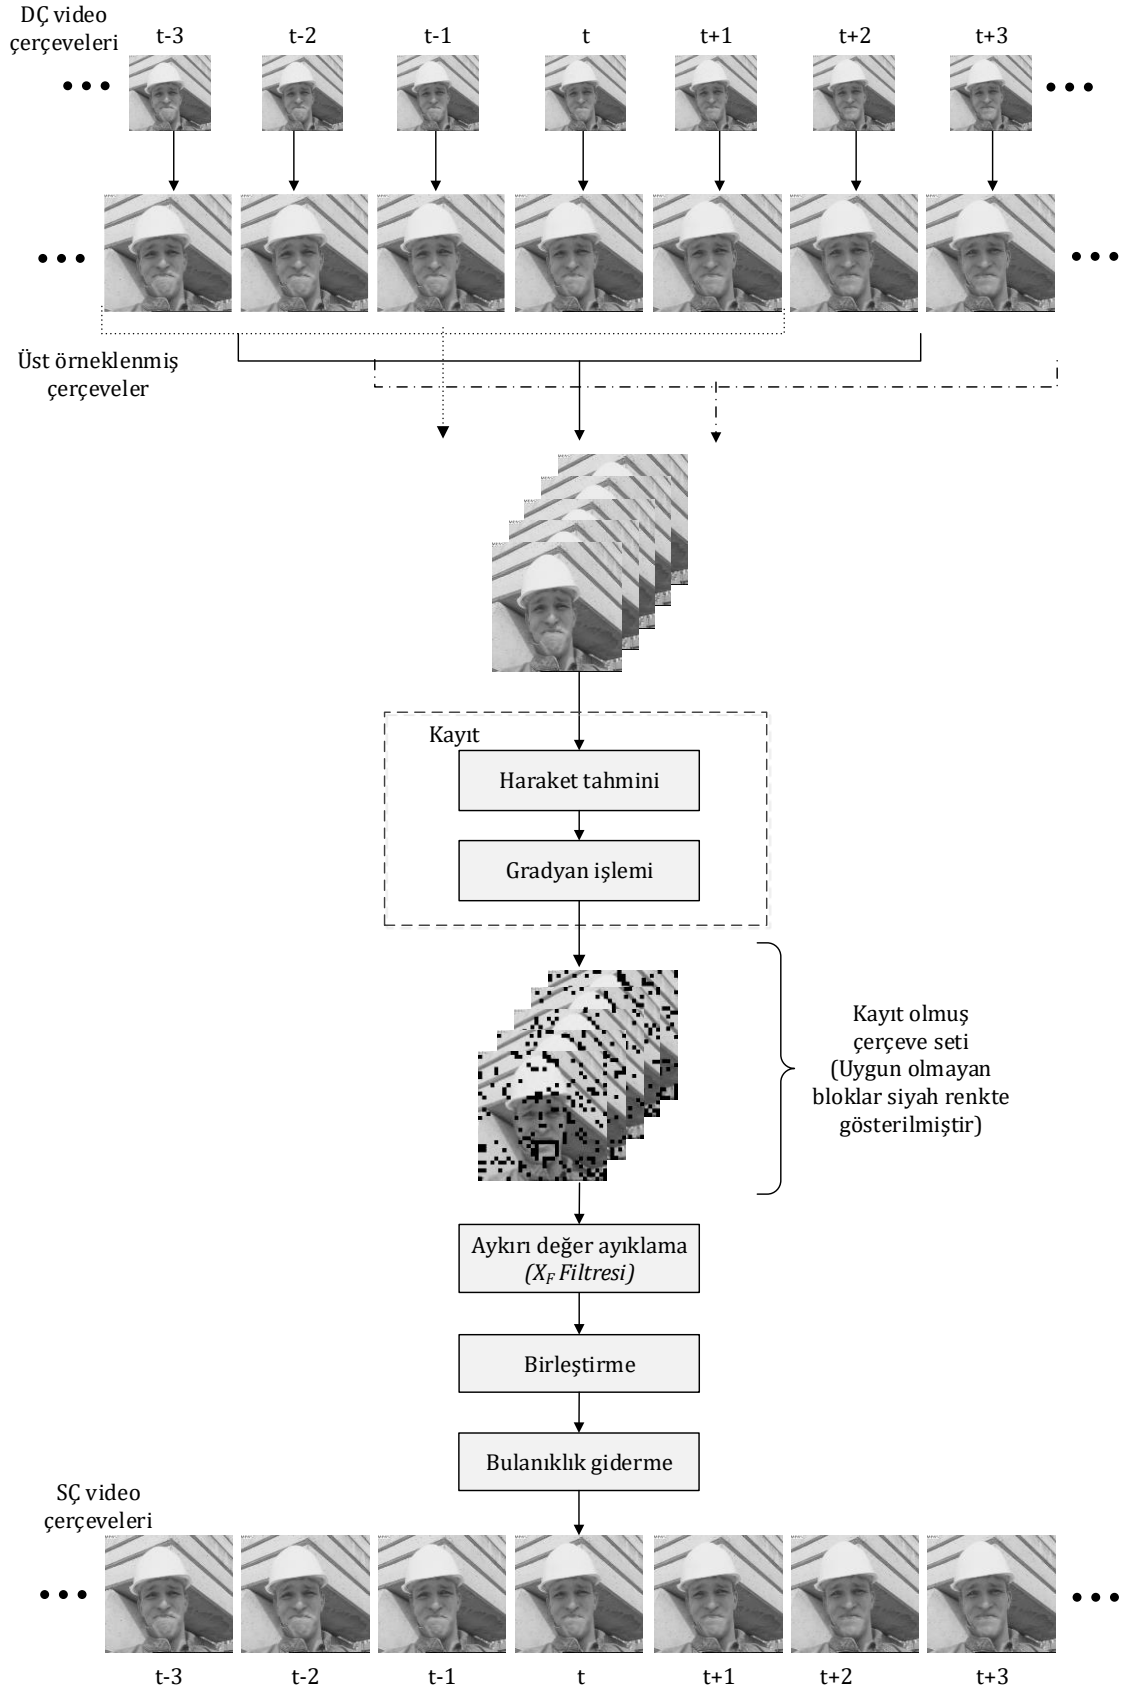
4.2.1. Uygulama Süreçleri ve Akış Diyagramı

Video SÇ yöntemleri, DÇ birbiri ardına gelen karelerin alt piksel bilgisini birleştirerek çıkış çerçevelerinin uzamsal çözünürlüğünü arttırmayı amaçlamaktadır. Önerdiğimiz bu çalışmada, blokların gradyan büyüklüğünün de hesaba katıldığı yeni bir yaklaşım geliştirilmiştir.

Öncelikle hareket kestirimi işleminden önce tüm DÇ çerçeveler büyüme katsayısı ile Lanczos ara değerlendirme kullanılarak üst örneklenir. Her ardışık DÇ çerçeve, yerel hareketleri tahmin etmek için 8×8 piksel boyutundaki makro bloklara bölünür ve t . zamandaki çerçeve referans olarak seçilir. Blok kaydı tamamlandıktan sonra piksellerin ortalaması alınmadan önce aykırı piksel ayıklaması gerçekleştirilir. Son olarak SÇ çerçevede kenar bilgisini korumak için bulanıklık giderme işlemi Toplam Varyasyon Regülasyon (TVR) yöntemiyle gerçekleştirilmektedir (Rudin vd., 1992). Bu çalışmada önceki bölümde bahsedilen yöntemle göre daha iyi sonuç alınması hedeflenmiştir. Kullanılan yöntemin blok diyagramı Şekil 4.6'da verilmiştir. Şekilde yeniden yapım aşamasına dahil edilmeyen bloklar siyah renkle belirtilmiştir.

Video karelerinde bağımsız nesnelere ait yerel hareket olabilir. Komşu karelerdeki aday bloklar arasında en küçük MAD' ye sahip en iyi eşleşen blok, nesnelere üst üste örtüşmesi, gürültü vb. nedenlerden dolayı SÇ için uygun olmayabilir. İlk olarak SÇ için uygun olmayan bloklar birinci eşik değeri kullanılarak yeniden yapım dışında tutulur. Eşik değerleri blok tipine göre iki çeşit olarak seçilmiştir. Blok tipini tanımlamak için Ouyang vd. (2005) tarafından önerilen varyans temeline dayanan model kullanılmıştır. Böylece RÇ blokları kenar veya düzlemsel blok olmak üzere iki sınıfa ayrılabilir. Sabit eşik Th_s ve dinamik eşik Th_d değerleri sırasıyla SÇ' yi bozan hatalı düzlemsel blokları ve kenar içeren blokları ortadan kaldırarak başarı oranı artırılmıştır. d MÇ' nin RÇ' ye zamansal uzaklığını ve z (deneysel olarak 1 olarak seçilmiştir) sabit bir başlangıç değeri göstermek üzere, t . zamandaki çerçeve için Th_d değeri aşağıdaki denklem kullanılarak belirlenmiştir.

$$TH_D = \frac{z}{\frac{|d-1|}{e^{\pi\sqrt{|d|}}}} \quad (4.6)$$



Şekil 4.6. Uygulanan yöntemin akış diyagramı

4.2.2. Gradyan Temelli Blok Tahmini

İkinci blok eleme işleminde RÇ bloğunun gradyan büyüklüğüne ve mevcut karenin en iyi eşleştirilmiş bloğuna dayanan yeni bir blok filtre tekniği uygulanmıştır. Bu noktada gradyan temeline dayanan, sırasıyla kenar bloklarına ve düzlemsel bloklara karşılık gelen Ψ_1 veya Ψ_2 olmak üzere ikinci bir eşik değeri kullanılmıştır. Kenar içeren bloğunun gradyan büyüklük değeri düzlemsel bir bloktan daha büyüktür. Bu nedenle, $\Psi_1 > \Psi_2$ olarak seçilmiştir. Eşik karar algoritması Çizelge 4.3’de verilmiştir.


Çizelge 4.3. Eşik değeri karar algoritması

```

if referans blok = kenar bloğu
    Eşik değeri 1 =  $Th_D$ 
    Eşik değeri 2 =  $\Psi_1$ 
else
    Eşik değeri 1 =  $Th_S$ 
    Eşik değeri 2 =  $\Psi_2$ 
end if

```

Örnek olarak Şekil 4.7’de *Foreman* video test dizisinin 11. çerçeve (referans) ile 12. çerçevesi arasında 8×8 boyutunda büyütülmüş iki makro blok görülmektedir. *Foreman*’ın şapka kenar bölgesine ait olan referans makro blok Şekil 4.7a’da, ardışık gelen bir sonraki çerçeveden hareket tahmini sonucu en iyi eşleşen blok ise Şekil 4.7b’de verilmiştir. Ancak görüldüğü gibi arka plan duvar bölgesine aittir ve SÇ için uygun değildir. Üstelik bloklar arasındaki minimum maliyete göre birinci eşik değeri ile elenmeden geçmiştir. Eğer Şekil 4.7b’deki blok SÇ için kullanılırsa sonuç resminde bozulmaya neden olacaktır.



Şekil 4.7. *Foreman* video sahnesine ait örnek hareket tahmini: a) 11. çerçeve (referans) bloğu, b) 12. çerçeve içinde en iyi eşleşen (hatalı) blok

Bu sorunun üstesinden gelerek çıktı görüntüsünde bozulmaları engellemek için, hem RÇ bloğu hem de en iyi eşleşen blok için gradyan büyüklükleri hesaplanmıştır. t . zamandaki RÇ' nin k . bloğun gradyan büyüklük matrisi G_k^t ve söz konusu blokla $(t-1)$. zamandaki çerçevenin en iyi eşleşen bloğun gradyan büyüklük matrisi ise $G_{\tilde{k}}^{t-1}$ olarak ifade edersek blok benzerliğini (β) aşağıdaki denklemlerle belirleyebiliriz.

$$\beta = \sum_{i=1}^N \sum_{j=1}^N |G_k^t(i, j) - G_{\tilde{k}}^{t-1}(i, j)| \quad (4.7)$$

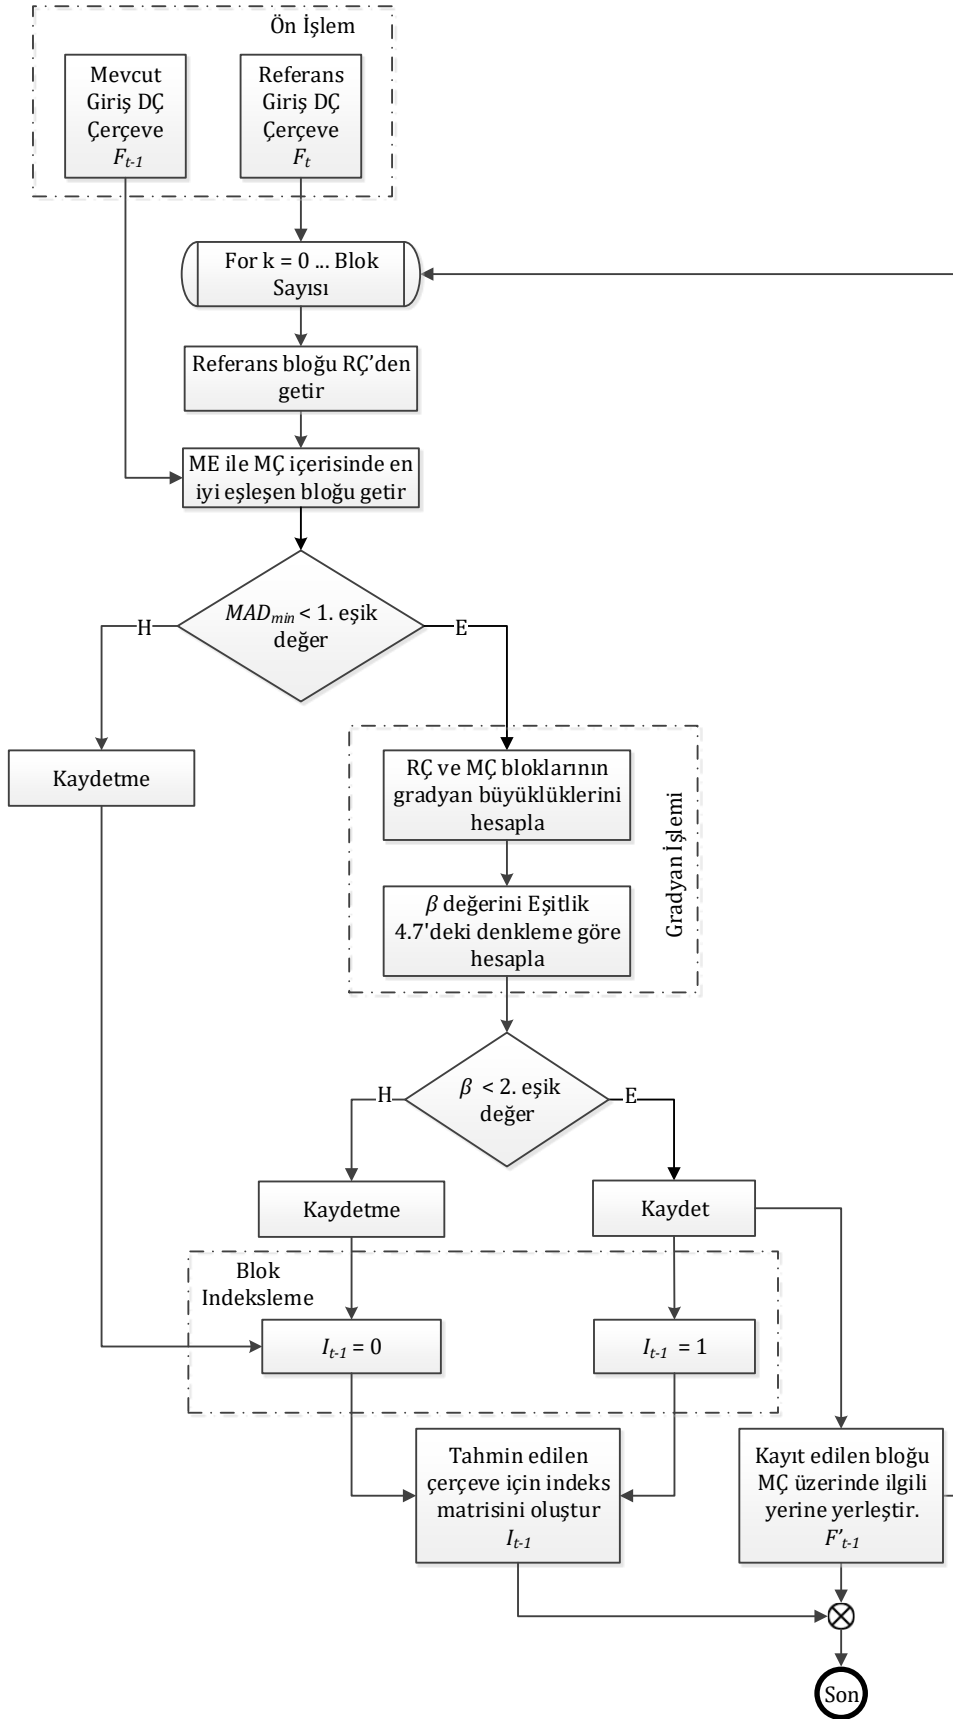
Bu değer bloklar birbirine ne kadar çok benzerse o oranda küçülmektedir. Eğer β ikinci eşik değerinden ($\Psi_1 \vee \Psi_2$) daha küçükse, en iyi eşleşen blok SÇ elde etmek için kullanılmaktadır. Buradaki amaç RÇ' den uzaklaştıkça uygun olmayan blokları baskılayarak işleme dahil etmemektir. Kullanılan blok kayıt algoritmasının ayrıntılı adımları Şekil 4.8'de gösterilmiştir.

4.2.3. Aykırı Piksellerin Ayıklanması

Aykırı bir piksel, diğer piksellerden belirgin şekilde farklıdır. Bu nedenle, yeniden yapım aşamasında kullanmadan önce ortalamadan çıkarılmalıdır. Bu amaçla istatistiksel yöntemlere dayanan X_F adında aykırı değer ayıklama filtresi tasarlanmıştır. Bir güven aralığı (CI), ölçüm hassasiyetinin bir göstergesidir ve bir örnekleme yöntemiyle ilişkili belirsizliği açıklar. CI tek veya çift taraflı olabilir. Tasarladığımız filtrede ise CI çift taraflı ve %95 olarak seçilmiştir. RÇ ile t . zamandaki hareket tahmini sonrası elde edilen çerçeve arasındaki (i, j) konumundaki piksel farkı aşağıdaki gibi yazılabilir.

$$\delta_t(i, j) = |F_{ref}(i, j) - F_t(i, j)| \quad (4.8)$$

$$\forall (i, j) \text{ ve } t \in [1, \dots, s]$$



Şekil 4.8. Kayıt algoritmasının ayrıntılı akış diyagramı

s çerçeve sayısını göstermek üzere, ortalama ve standart sapma değerleri sırası ile aşağıdaki denklemler kullanılarak hesaplanabilir.

$$\mu(i, j) = \frac{\sum_{t=1}^{s-1} \delta_t(i, j)}{s-1}, \quad \forall(i, j) \quad (4.9)$$

$$\sigma(i, j) = \sqrt{\frac{1}{s-1} \sum_{t=1}^{s-1} (\delta_t(i, j) - \mu(i, j))^2}, \quad \forall(i, j) \quad (4.10)$$

Bu denklemler, F_t çerçevesinin (i, j) konumunda piksel için bir CI tanımlamayı sağlar. Minimum ve maksimum limit matrisi ise aşağıdaki gibi yazılabilir.

$$L_{\min, \max}(i, j) = \mu(i, j) \pm \left[T_{\alpha/2} \times \left(\frac{\sigma(i, j)}{\sqrt{n}} \right) \right], \quad \forall(i, j) \quad (4.11)$$

Denklemdaki $T_{\alpha/2}$ ve n sırası ile güvenilirlik seviyesini ve piksel sayısını ifade etmektedir. İndeks matrisi I_t ' nin (i, j) konumundaki değer 1 olması söz konusu pikselin kayıt olması anlamına gelmektedir. Kayıt olunan piksel değerleri içindeki aykırı pikseller ortalama hesaplanmadan önce ayıklanmaktadır. p , t . çerçevenin (i, j) konumundaki limitler içerisinde kalan ve kayıt olan piksel değerini göstermek üzere X_F filtresi aşağıda verilen denklem kullanılarak uygulanmaktadır.

$$F_t(i, j) = \begin{cases} p & \text{eğer } L_{\min}(i, j) < \delta_t(i, j) < L_{\max}(i, j) \\ 0 & \text{değilse} \end{cases} \quad (4.12)$$

4.2.4. Blok Karşılaştırma ve Gradyan Büyüklüğüne Dayalı Video Süper-Çözünürlük Yöntemi Deneysel Çalışmaları

Uygulanan yöntemin performansını test etmek için yapılan deneyler Matlab 8.3 ortamında ve Intel (R) çekirdek (TM) i5-2400 CPU 3,1 GHz ve 3,4 GHz işlemciye sahip Microsoft Windows platformlu bilgisayar üzerinde gerçekleştirilmiştir. Algoritmanın performansı klasik video sahnelerinden *Foreman* (300 kare, 352×288 px), *Suzie* (150 kare, 176×144 px) CIF sürümü ve *Miss America* dizisinin (150 kare, 176×144 px) QCIF

sürümü kullanılarak test edilmiştir. *Suzie* ve *Miss America* sadece sabit arka plana sahip iken *Foreman* hem yerel hem de kamera hareketine sahiptir. Tüm test videoları için kare oranı 30 fps' dir. DÇ çerçeveler de orijinal çerçeveler kullanılarak yapay olarak hazırlanmıştır. Öncelikle orijinal çerçevelerin tümü 3×3 Gauss bulanıklık filtresinden geçirilmiş dikey ve yatay yönde 1:2 oranında alt örneklenmiştir. Daha sonra tüm çerçevelere standart sapması 2 olan Gauss gürültü eklenmiştir.

Hareket tahmini için 8×8 sabit blok boyutu kullanılmıştır. 1 tane SÇ çerçeve elde edebilmek için 15 çerçeve (7 ileri, 7 geri ve 1 tane referans çerçeve) işleme katılmıştır. Her test video sahnesi için 6., 11., 16. ve 21. çerçeveler referans olarak seçilmiştir ve yöntemin sonuçları orijinal görüntü, NN ve Lanczos ara değerlendirme ile karşılaştırılmıştır. Deneysel sonuçlar, Şekil 4.9, Şekil 4.10 ve Şekil 4.11'de gösterilmiştir. Görsel sonuçlardan da görüldüğü gibi önerilen yöntem, NN ve Lanczos ara değerlendirme ile karşılaştırıldığında kenar bölgelerde daha keskin, gürültüsüz ve kaliteli sonuçlar vermektedir.

Çizelge 4.4'de verilen ortalama PSNR (dB) sonuçlarına göre gerçekleştirilen yöntem (X_F : açık ve kapalıyken), NN ve Lanczos ara değerlemeden daha iyi sonuç üretmiştir. Piksel ortalaması hesaplanırken aykırı değer ayıklama filtresi uygulandığında, filtre uygulanmayan sonuçlara kıyasla ortalama 0,15 dB kadar iyileşme sağlanmıştır.

Çizelge 4.4. Ortalama PSNR (dB) değerleri

Yöntem	<i>Foreman</i>	<i>Miss America</i>	<i>Suzie</i>
NN ara değerlendirme	29,87	31,27	31,62
Lanczos	32,08	33,94	33,34
Önerilen Yöntem (X_F 'siz)	33,65	35,92	34,93
Önerilen Yöntem (X_F 'li)	33,85	36,04	35,01



Şekil 4.9. *Suzie* video sahnesi 6., 11., 16. ve 21. karelere ait sonuçlar: a) Orijinal çerçeve, b) NN ara değerlendirme, c) Lanczos, d) Önerilen Yöntem (X_F 'li)




Şekil 4.10. *Miss America* video sahnesi 6., 11., 16. ve 21. karelere ait sonuçlar: a) Orijinal çerçeve, b) NN ara değerlendirme, c) Lanczos, d) Önerilen Yöntem (X_F 'li)



Şekil 4.11. *Foreman* video sahnesi 6., 11., 16. ve 21. karelere ait sonuçlar: a) Orijinal çerçeve, b) NN ara değerlendirme, c) Lanczos, d) Önerilen Yöntem (X_F 'li)

Bulanıklık giderme işlemi SÇ probleminde önemli bir rol oynamaktadır. Bulanıklık giderme yineleme sayısı artırılarak görsel olarak daha keskin ve göze hoş gelen sonuçlar elde etmek mümkündür. Ancak, daha fazla yineleme görüntüyü bozabilmektedir. Bu nedenle, son SÇ çıktı görüntüsü üzerine toplam özyineleme sayısı iki olan bulanıklık giderme filtresi uygulanmıştır. Test resimlerinin 6. çerçevesinin yakınlaştırılmış hali Şekil 4.12'de gösterilmiştir. Algoritma başarısını göstermek için özellikle detaylı bölgeler seçilmiştir.



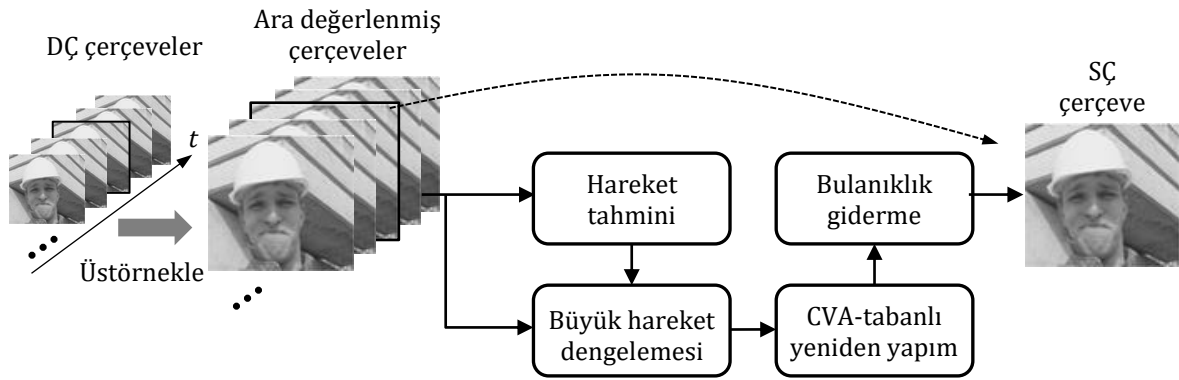
Şekil 4.12. *Foreman*, *Miss America* ve *Suzie* 6. karesinin 3x yakınlaştırılmış görseli: a) Orijinal çerçeve, b) NN ara değerleme, c) Lanczos, d) Önerilen Yöntem (X_F 'li)

4.3. Ortak Vektör Yaklaşım Temelli Çoklu-Çerçeve Süper-Çözünürlük Yöntemi

Süper-çözünürlük uygulamaları, YÇ görüntü (ler) elde etmek için bir veya birden fazla DÇ görüntü içerisindeki bilgileri doğru kullanmayı gerektirmektedir. DÇ görüntüler, bir video sekansının gürültülü ve bulanık ardışık kareleri olduğunda işlemi daha doğru yapmak gerekmektedir. Çoklu-çerçeveler arası hareket tahmini kötü durumda (ill-posed) SÇ sorununu çözmek için önemli bir aşamadır. Bu çalışmada, hareket tahmini için önceden bahsedilen çalışmalardan farklı olarak daha hassas ve doğru hareket tahmini için translasyonel optik akış kullanılmıştır. Ancak bu aşamada hareket tahmini ne kadar doğru yapılırsa yapılsın çeşitli sorunlardan (ışık, gürültü, bulanıklık vb.) dolayı sonuç çıktısında istenilen kaliteye ulaşmak her zaman mümkün olmaz. Hareket tahminini bozan bu tip sorunları çözmek veya etkilerini en aza indirebilmek için literatürde yapılan çalışmaları incelediğimizde, bir pikseli komşu piksellerdeki bilgileri kullanarak iyileştirebilen yaklaşımları da görmekteyiz. Bu bölümde birden fazla resmi kullanarak YÇ görüntü yeniden yapımı (rekonstrüksiyon) için komşu piksellerin de işleme dahil edildiği CVA-

tabanlı bir yöntem gerçekleştirilmiştir. CVA, gürültü, nesnelerin birbirine örtüşmesi, gölgelenme veya hatalı ME' nin yol açtığı problemleri azaltmanın bir yolunu sağlamıştır. YÇ görüntü blokları, ayrı ayrı ele alınan blok sınıfının ortak ve fark vektörlerini birleştirilerek elde edilmiştir. Fark vektörlerindeki gürültü, birleşmeden önce bilinen bir gürültü azaltma yöntemiyle azaltılmaktadır. Ortak ve fark birleşenlerinin ayrı değerlendirilmesi, daha iyi sonuç elde edilmesini ve çıktı görüntüsünde oluşabilecek bozulmaları büyük ölçüde azaltmayı garanti eder. Deneysel sonuçlar, elde edilen başarıyı görsel olmakla beraber PSNR ve SSIM ölçütlerine göre de doğrulamaktadır.

Çoklu-çerçeve SÇ algoritmaları, aralarındaki alt piksel farklılıklarını analiz ederek çok sayıda DÇ görüntüde bulunan uzamsal (spatial) bilgileri birleştirmeyi ve daha yüksek bilgi içeriğine sahip bir veya daha fazla görüntü oluşturmayı hedeflemektedir. Daha yüksek bilgi içeriği çoğu zaman artan uzamsal çözünürlüğü, daha fazla ayrıntıyı veya görsel olarak göze daha hoş gelmeyi ifade eder. Şekil 4.13'de gösterildiği gibi, ardışık video kareleri üzerinde çalışmak üzere tasarlanan yöntem, ilk olarak giriş DÇ görüntülerinin ara değerlendirme yoluyla yükseltilmesiyle artan piksel sayısına sahip görüntüler üzerinde çalışmaktadır. Her çerçevenin YÇ karşılığı bağımsız olarak elde edilmiştir. YÇ oluşturulacak çerçeve referans olarak seçildikten sonra bu çerçeveyi takip eden (zaman içinde) veya bu çerçeve öncesindeki komşu çerçeveler hedef çerçeve olarak belirlenmiştir.



Şekil 4.13. CVA-tabanlı süper-çözünürlük yöntemi blok diyagramı

Referans ve hedef (mevcut) çerçeveler arasındaki alt piksel hareketi, optiksel akış kullanılarak bulunmaktadır. Çerçevesel arasındaki gürültü seviyesi, örtüşmeler, ışık gibi çeşitli faktörler, büyük ölçüde hareket vektörlerini ve dolayısıyla ortaya çıkan YÇ

kalitesini doğrudan etkileyen faktörlerdir. Hareket dengelemeli bloklardan YÇ yeniden inşası aşamasında, CVA temeline dayanan yeni bir birleştirme yöntemi bu tür bozulmaların üstesinden gelmek için önerilmiştir. Referans bloğun yeniden yapımı hedef blokların ağırlıklı katkıları kullanılarak gerçekleştirilmektedir.

4.3.1. Blok Hareket Tahmini

Doğru hareket tahmini, SÇ algoritmaları ve görüntü yeniden yapımı için hayati önem taşımaktadır. Amaç, en küçük resim elemanı (blok veya piksel) için iki görüntü arasındaki hareketi mümkün olduğunca doğru tespit etmektir. Bu yöntemde, öncelikle tüm çerçeveler Lanczos ara değerlendirme kullanılarak yeniden boyutlandırıldıktan sonra referans alınana göre translasyonel optik akış modeli (Stiller ve Konrad, 1999) kullanılarak hareket tahmini gerçekleştirilmektedir.

RÇ (SÇ olarak yeniden oluşturulacak, 0 olarak indekslenen) ve hedef çerçeveler komşu çerçeveler, 0 hariç tutularak, $-N/2$ ' den $N/2$ ' ye indekslenmek suretiyle hareket vektörleri 3 katmanlı Gauss piramitli optik akış tekniği kullanılarak hesaplanmaktadır (Lucas ve Kanade, 1981; Wang vd., 2001). Bu sayede hareket vektörleri en az karmaşıklıkla daha doğru elde edilebilmektedir.

4.3.2. Ortak Vektör Yaklaşımı

CVA, temel olarak ses tanıma (Gulmezoglu vd., 1998, 1999, 2001), görüntü tanıma (Çevikalp vd., 2005), gürültü giderme (Özkan ve Seke, 2015) ve hatta motor arıza teşhisi (Gulmezoglu ve Ergin, 2007) için kullanılan bir alt uzay temelli görüntü tanıma yöntemidir. Sıfır olmayan temel bileşenler ve fark alt uzayı arasında yakın bir ilişki vardır. Bunun aksine, sıfır ana bileşenler ve ortak vektör arasında da yakın bir ilişki vardır (Gulmezoglu vd., 2001). Ortak vektör, bir sınıfın ortak özelliklerini tanımlayan eşsiz bir vektördür. Bu çalışmada CVA' nın kullanım amacı, tüm çerçevelerde yer alan muadillerinden tek bir YÇ bloğu yeniden oluşturmak için kullanılan blokların ortak ve fark kısımlarını ayırarak YÇ yeniden yapılanma aşamasında problemlili kısımları ortadan kaldırmaktır. Ayırma, fark bileşenlerindeki gürültüyü azaltmamıza ve ortak parçayı korumamıza izin verir, böylece enerjinin çoğu yeniden yapılanma ile ortaya çıkan bulanıklıktan etkilenmez. Matematiksel

gösterimde kolay anlaşılabilmesi için, vektörler ve matrisler kalın karakterlerle gösterilmektedir.

Eğitim setindeki öznitelik vektörlerini $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_m \in \mathfrak{R}^n$ olduğunu varsaydığımızda her bir vektörü ortak vektör cinsinden aşağıdaki gibi yazabiliriz.

$$\mathbf{a}_k = \mathbf{a}_{com} + \mathbf{a}_{k,diff} \quad (4.13)$$

Denklemden \mathbf{a}_{com} ile ifade edilen sınıfa ait ortak vektörü, $\mathbf{a}_{k,diff}$ ise \mathbf{a}_k vektörünün fark alt uzayındaki fark vektörünü temsil etmektedir. Ortak vektör, sınıf vektörleri içinde değişmez özelliklere sahiptir.

m vektör sayısı ve n bir vektörün boyutu olsun. CVA, yeterli ($m \geq n$) ve yetersiz ($m < n$) durumlar için uygulanabilir (Gulmezoglu vd., 1998, 2001). Gram-Schmidt ortogonalizasyon ve alt uzay tabanlı yöntemler, bir sınıfın ortak vektörünü bulmak için kullanılabilir (Gulmezoglu ve Ergin, 2007). Alt uzay yöntemlerinde, sınıf içi kovaryans matrisi (Φ), ortak vektörü hesaplamak için aşağıdaki denklemle ifade edilebilir.

$$\Phi = \sum_{k=1}^m (\mathbf{a}_k - \mathbf{a}_{avg})(\mathbf{a}_k - \mathbf{a}_{avg})^T \quad (4.14)$$

Bu denklemde, \mathbf{a}_{avg} ortalama vektörü ifade eder. Farklılık (\mathbf{B}) ve farksızlık (\mathbf{B}^T) alt uzayları ortonormal taban vektörleri $\mathbf{u}_x \in \mathfrak{R}^n$ tarafından sırası ile $x=1, 2, \dots, r-1, (r-1 < n)$ ve $x=r, r+1, \dots, n$ için gerilebilir. r , belirli bir sabit yüzdeden (E) daha az olan en küçük özdeğerlerin sayısını göstermektedir (Oja, 1983).

$$\left(\sum_{x=r}^n \lambda_i \right) / \left(\sum_{x=1}^n \lambda_i \right) < E \quad (4.15)$$

Sırası ile \mathbf{B} farklılık alt uzayı üzerindeki ortogonal izdüşüm matrisi \mathbf{P} ve \mathbf{B}^\perp farksızlık alt uzayı üzerindeki ortogonal izdüşüm matrisi \mathbf{P}^\perp aşağıdaki denklemler kullanılarak hesaplanabilir.

$$\mathbf{P} = \sum_{x=1}^{r-1} \mathbf{u}_x \mathbf{u}_x^T \quad (4.16)$$

$$\mathbf{P}^\perp = \sum_{x=r}^n \mathbf{u}_x \mathbf{u}_x^T \quad (4.17)$$

\mathbf{P} ve \mathbf{P}^\perp $n \times n$ boyutundaki simetrik matrislerin toplamları birim matrisine eşit olacaktır. Tüm öznitelik uzayını ikiye ayırmanın amacı, ortalamadan büyük değişikliklere sahip bazı bileşenleri ortadan kaldırmaktır (Landgrebe, 2002). $\mathbf{a}_{k,diff}$ fark vektörünü aşağıdaki gibi ifade etmek mümkündür.

$$\mathbf{a}_{k,diff} = \mathbf{P} \mathbf{a}_k = \sum_{x=1}^{r-1} \langle \mathbf{a}_k, \mathbf{u}_x \rangle \mathbf{u}_x \quad (4.18)$$

Bunun anlamı $\mathbf{P}^\perp \mathbf{a}_{k,diff} = 0$ ' dir. $\mathbf{a}_{k,diff}$, \mathbf{B} farklılık alt uzayı üzerinde herhangi bir öznitelik vektörü \mathbf{a}_k üzerine izdüşüm alınarak bulunabilir (Gulmezoglu vd., 2001). Yeterli veri durumundaki ortak vektör, \mathbf{B}^\perp farksızlık alt uzayı üzerinde ortalama vektörüne izdüşüm ile bulunabilmektedir (Gulmezoglu vd., 2007).

CVA yetersiz veri durumunda da ($m < n$) uygulanabilir. Kovaryans matrisinde bulunabilecek sıfır özdeğerlerin sayısı ($n - m + 1$) kadardır. $(\lambda_x, \mathbf{u}_x), x = 1, \dots, (n - m + 1)$ ise sıfır özdeğerlere karşılık gelen özvektörleri ifade etmektedir. Bir sınıfın \mathbf{B}^\perp farksızlık alt uzayı üzerine izdüşüm matrisi aşağıdaki denklemle hesaplanabilir.

$$\mathbf{P}^T = \sum_{x=1}^{n-m+1} \mathbf{u}_x \mathbf{u}_x^T \quad (4.19)$$

Bu denklem kullanılarak bir sınıfa ait ortak vektör \mathbf{a}_{com} herhangi bir öznitelik vektörü üzerine izdüşüm alınarak aşağıdaki denklem ile elde edilmektedir.

$$\mathbf{a}_{com} = \mathbf{P}^T \mathbf{a}_k, \quad k = 1, \dots, m \quad (4.20)$$

4.3.3. CVA-tabanlı Süper-Çözünürlük Yeniden Yapımı


Referans çerçeve blokları için çerçeveler arası hareket vektörlerinin tahmin edilmesinin ardından, referans alınan çerçeve, bu bölümde tarif edilen CVA-tabanlı yeniden yapılandırma yöntemi kullanılarak referans ve hedef karelerden yeniden oluşturulur. Ağırlıklı/ağırlıksız ortalamaların sonucu bulanık yeniden oluşturulmuş çerçeveye sahip olduğu açıktır. Bunun yerine, CVA-tabanlı yöntemin kullanımı, aykırı değerlerin ve aynı zamanda sıfır ortalama gürültünün etkilerini azaltmanın bir yolunu sağlar.

Süper-çözünürlüklü olması istenen referans çerçevesi $\mathbf{I}_{t=0}$ ve bu referansa göre hareket dengelemesi yapılmış hedef çerçeveler $\{\mathbf{I}_t\}_{t=-N/2}^{N/2}$ olsun. Yani, her hedef çerçeve için, referans kareler hedef çerçevelerin blokları kullanılarak yeniden oluşturulabilir. Bu noktada en basit gürültü azaltma ve SÇ yeniden yapımı, tüm bu karelerden gelen blokların bir çeşit ortalaması olacaktır. Ancak, bu işlem daha önce belirtildiği gibi bulanık bir SÇ sonucuna neden olur. Bunun yerine, CVA sınıfları, aşağıda açıklandığı gibi referans vektörüne (vektörleştirilmiş görüntü bloğu) benzerliklerine göre ağırlıklandırılan vektörler kullanılarak oluşturulabilir.

SÇ resmindeki (yeniden yapılandırılacak) her piksel için, tüm karelerdeki bu piksel çevresindeki $W \times W$ boyutundaki arama alanlarından $p \times p$ boyutunda bloklar toplanır. Bir arama alanı örneği, bu alandaki ilk blok ve yeniden yapılandırılacak blok ile Şekil 4.14'de gösterilmektedir.

SÇ resim içerisindeki $W \times W$ arama alanı içindeki her piksel konumundan $p \times p$ boyutundaki blokların sayısı $n = (W - p + 1)^2$ ' dir. Buna göre referansa göre her iki konumundaki çerçeve sayısı N olmak üzere tüm blokların toplam sayısı $M = (2 \times n \times N)$ olarak hesaplanabilir. Bu blokları $\mathbf{b}_k, k = 0, \dots, M - 1$ olarak ifade edersek, her bir bloğu $n \times 1$ boyutlu \mathbf{a}_k kolon vektörüne çevirmek ve bu sayede $\mathbf{\Omega}_C = \{\mathbf{a}_k, k = 0, \dots, M - 1\}$ vektör setini oluşturmak mümkündür. Bu set söz konusu pikselin $W \times W$ arama alanı içindeki tüm komşu bloklarını içerir. Başka bir ifadeyle, $\mathbf{\Omega}_C$ seti referans pikseli çevreleyen bloğa

değişen derecelerde katkı sağlayan referans pikseli hakkındaki tüm bilgileri içeren bir sınıftır.



Şekil 4.14. Bloklardan (vektörlerden) sınıf oluşturulması

Bu aşamada, referans vektör ile diğer vektörler arasındaki benzerlik ölçüsü, tüm vektörler için belirlenmeli ve hesaplanmalıdır, böylece aykırı değerler hariç tutulabilecektir. Referans ve k . vektör arasında aşağıdaki denklemde ifade edilen ortalama kare farkı ile bir Gauss penaltı fonksiyonu kullanılmıştır.

$$w_k = \exp\left(-\frac{\|\mathbf{a}_{ref} - \mathbf{a}_k\|_2^2}{2\sigma^2}\right) \quad (4.21)$$

Bu denklemde \mathbf{a}_{ref} referans çerçevesindeki referans bloğa, σ ise evrensel pürüzsüzleştirme parametresine karşılık gelmektedir. Vektörler birbirine ne kadar az benzer ise ağırlıklar da o derece düzenli olarak azalır. Daha iyi sınıf elde etmek için, aykırı değerler olarak daha küçük ağırlıkları olan vektörlerin sınıftan tamamen çıkarılması gerekmektedir. Bu amaçla gürültü istatistiğine dayanan bir eşik değeri kullanılmıştır.

Donoho ve Johnstone (1994) sinyali gürültüden ayıran basit bir yöntem önermişlerdir. Gürültünün standart sapması (std), yüksek-yüksek (HH) alt bandındaki dalgacık katsayıları ile yakından ilişkilidir ve aşağıdaki gibi ifade edilebilir.

$$\hat{\sigma} = median(C) / 0,6745 \quad (4.22)$$

Bu denklemde C , HH alt bandındaki katsayıları göstermektedir. Bu çalışmada benzerlik eşik değeri $\tau = 3\hat{\sigma}p^2$ formülü ile seçilmiştir. Bu eşik değeri, tahmin doğruluğu ve Ajit vd.'nin (2013) çalışmasında gösterildiği gibi hesaplama hızı arasında iyi bir denge sağlar. Böylece, bir sınıf içinde tamamen alakasız vektörlere sahip olmaktan kaçınılırken, birçok benzer olan vektörün de sonuç resmi geliştirmesine yardımcı olunur. Eşik değeri uygulanarak, referans vektörüne en benzer m tane vektörlerden oluşan yeni bir sınıf (Ω) oluşturulur. Bir sınıfa ait ağırlıklı ortalama vektörü \mathbf{a}_{wavg} aşağıdaki denklem ile hesaplanabilmektedir.

$$\mathbf{a}_{wavg} = \frac{\sum_{k=1}^m w_k \mathbf{a}_k}{\sum_{k=1}^m w_k} \quad (4.23)$$

Ağırlıkların toplamı ise aşağıdaki denklem kullanılarak hesaplanmaktadır.

$$\sum_{k=1}^m w_k \quad (4.24)$$

Bu işlem aynı zamanda, bir sınıftaki toplam benzerlik için de bir ölçüt olarak kullanılmaktadır. Ayrıca ağırlıkların toplamı, son SÇ resminde üst üste gelen bloklar birleştirilirken blok piksel değerlerinin normalizasyonu için kullanılmaktadır. Buradan sonra k indeks harfi, sınıf için m tane vektörü göstermek için kullanılacaktır. Belirli bir sınıftaki herhangi bir vektör aşağıdaki gibi yazılabilir.

$$\mathbf{a}_k = \mathbf{a}_{com} + \hat{\mathbf{a}}_{k,diff} + \boldsymbol{\eta}_k \quad (4.25)$$

Bu denklemde \mathbf{a}_{com} , $\hat{\mathbf{a}}_{k,diff}$ ve $\boldsymbol{\eta}_k$ sırası ile ortak vektörü, gürültüden arındırılmış k . fark vektörünü ve k . vektörün gürültü bileşenini göstermektedir. Sıfır ortalama gürültü

için, ortak vektörün neredeyse hiç gürültüsüz olması beklenir. Sınıfın ortak ve gürültülü fark bileşenleri, daha önce bahsedilen CVA yoluyla elde edilir. Bir sonraki adım, referans vektörü için fark vektörünün gürültüsüz bir parçasını elde etmektir. Fark vektörleri şu şekilde yazılabilir.

$$\mathbf{a}_{k,diff} = \hat{\mathbf{a}}_{k,diff} + \boldsymbol{\eta}_k \quad (4.26)$$

Satırları fark vektörlerinden oluşan \mathbf{A}_{diff} matrisi ise aşağıdaki gibi oluşturulabilir.

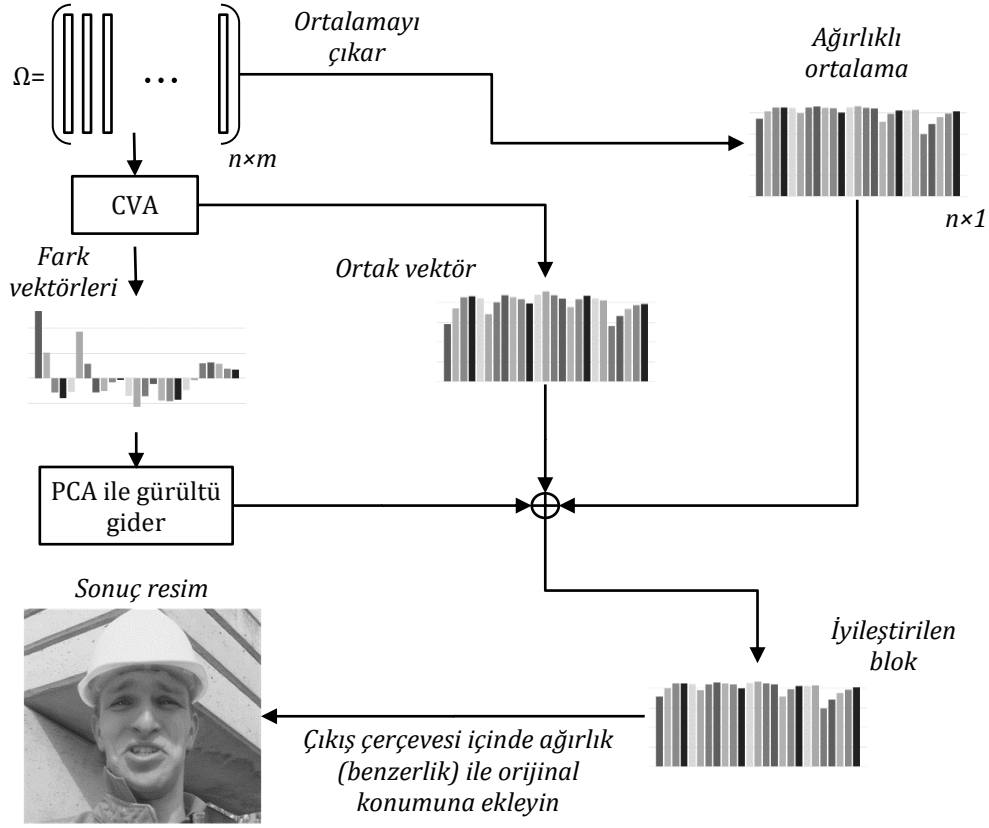
$$\mathbf{A}_{diff} = [\mathbf{a}_{1,diff}, \mathbf{a}_{2,diff}, \dots, \mathbf{a}_{m,diff}]^T \quad (4.27)$$

\mathbf{A}_{diff} bilinen herhangi bir gürültü azaltma algoritması kullanılarak gürültüden arındırılabilir. Bu çalışmada, Wen vd.'nin (2013) önermiş olduğu doğrusal minimum ortalama karesel hata yöntemi kullanılmıştır. Son olarak daha önce çıkarılmış olan ortak vektör ve ağırlıklı ortalama vektörü, gürültüsü giderilmiş fark vektörü üzerine eklenerek referans vektörü (veya referans bloğu) elde edilecektir.

$$\hat{\mathbf{a}}_{ref} = \mathbf{a}_{avg} + \mathbf{a}_{com} + \hat{\mathbf{a}}_{ref,diff} \quad (4.28)$$

Elde edilen tamir edilmiş blok, önceden hesaplanmış ağırlığı ile SÇ görüntüsünde orijinal yerine yerleştirilir. Aynı zamanda elemanları ağırlık değerine eşit olan bir blok, aynı konum üzerinde başka bir matris (resim) içinde depolanır. Bu sayede SÇ görüntüsündeki elemanlar, ağırlık görüntülerinde karşılık gelen elemanlara bölünerek normalize edilmiş olur. SÇ sonuç görüntüsünde oluşabilecek bulanıklığa karşı seçimli olmakla beraber bulanıklık giderme işlemi uygulanmıştır (Rudin vd., 1992).

CVA-tabanlı görüntü iyileştirme yönteminin detaylı akış diyagramı Şekil 4.15'te, uygulanan yöntemin özet algoritması ise Çizelge 4.5'de verilmiştir.



Şekil 4.15. CVA-tabanlı süper-çözünürlük algoritması akış diyagramı

Çizelge 4.5. CVA-tabanlı süper-çözünürlük yönteminin özet algoritması

Hedef : \hat{S}_{t_0} - t_0 anındaki başlangıç SÇ resmini elde etmek

Girişler: $\{I_t\}_{t=-N/2}^{N/2}$ - Büyütülmüş ve hareket dengelemesi yapılmış DÇ hedef çerçeveler

İlk Değer Atama: $Z_{t_0} = I_{t_0}$ ve I_{t_0} ile aynı boyutlu Q ve W sıfır resimlerini oluştur.

Tekrar et: I_{t_0} içindeki her i . vektörü a_i için

1. Ω_c sınıfını oluştur, eşik değerini uygula ve Ω sınıfını oluştur.
2. Sınıf için ortak vektör, ortalama vektör ve ağırlıkları hesapla.
3. A_{diff} matrisini oluştur.
4. PCA gürültü baskılama ile A_{diff} güncelle
5. Gürültüsüz vektörü (blok) orijinal konumuna ekle: $Q = Q + \hat{a}_i$;
6. Ağırlık resmine ağırlıkları ekle: $W = W + \sum w_k$;

Normalizasyon: $Z_{t_0} = Q / W$;

Bulanıklık Giderme (seçimli): S ' ye göre $\eta_{SR}(S) = \|Z_{t_0} - HS\|_2^2 + \lambda TV(S)$ hesapla sonucu \hat{S}_{t_0} olarak elde et.

Çıktı: \hat{S}_{t_0}

4.3.4. CVA-tabanlı SÇ Yöntemi Deneysel Çalışmaları

Bu bölümde, uygulanan yöntemin deneysel sonuçları, NN, bilineer ve Lanczos ara değerlemeye ek olarak sırası ile Protter vd., (2009), Tekada vd., (2009) ve Kappeler vd.’nin (2016) önerdikleri NLM-tabanlı, 3DSKR-tabanlı ve CNN-tabanlı SÇ yöntemi (VSRnet) ile karşılaştırılmıştır. Karşılaştırmalar PSNR (dB) ve SSIM (Wang vd., 2014) kullanılarak yapılmıştır. SSIM, yeniden yapılandırılmış ve orijinal resim arasındaki kenarların benzerliğini de dikkate alarak karşılaştırmaya olanak sağlayan algı temelli nesnel bir metriktir. SSIM formülü aşağıdaki denklemde verilmiştir.

$$SSIM(\hat{X}, X) = \frac{(2\mu_{\hat{X}}\mu_X + C_1) + (2\sigma_{\hat{X}X} + C_2)}{(\mu_{\hat{X}}^2 + \mu_X^2 + C_1)(\sigma_{\hat{X}}^2 + \sigma_X^2 + C_2)} \quad (4.29)$$

Bu denklemde μ ve σ^2 söz konusu resimlerin ortalama ve varyansını, $\sigma_{\hat{X}X}$ ise kovaryansı ifade etmektedir. Al-Najjar ve Soong’ a (2012) göre C_1 ve C_2 sabit değerler olup sırası ile $0,01L^2$ ve $0,02L^2$ olarak alınabilir.


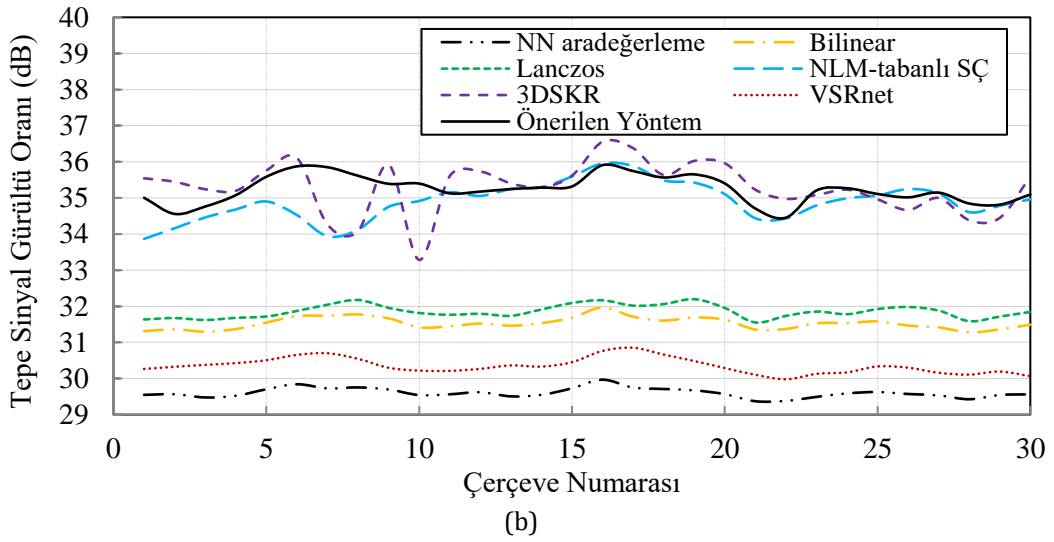
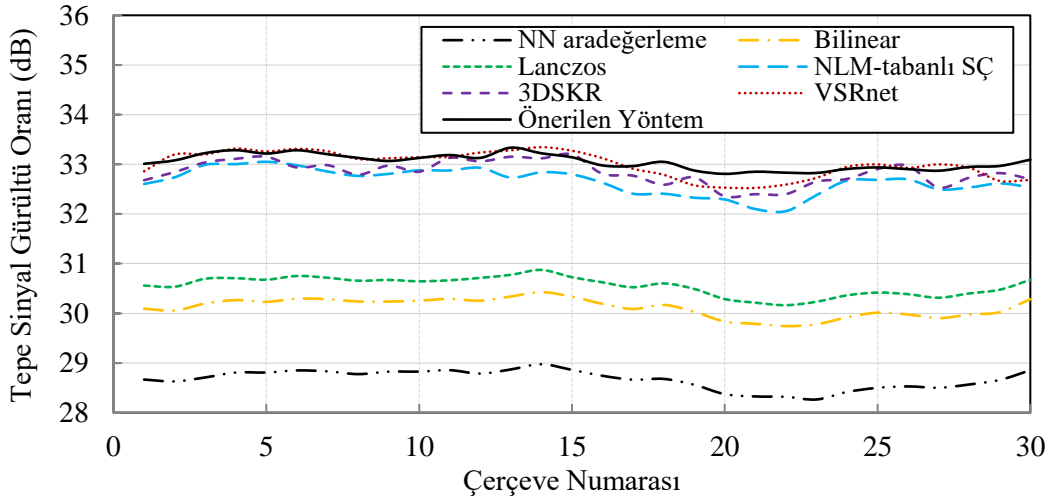
İlk deneyler, *Foreman* klasik test videosunun CIF sürümü (352×288) ile *Suzie* ve *Miss America*’nın ve QCIF sürümü (176×144) dizilerinin aşağı örneklenmiş ve bozulmuş sürümleri üzerinde gerçekleştirilmiştir. Test dizilerinin her biri 150 kare içermektedir. Bu sekanslardaki her bir çerçeve, 3×3 tekdüze bir PSF ile bulanıklaştırılmış ve daha sonra her iki uzamsal boyutta 1:3 oranında aşağı örneklenmiştir. Daha sonra bozulmuş resimlere $\sigma_n = 2$ olan beyaz gürültü eklenmiştir. Deneysel çalışmalarında, tek bir SÇ çerçevesinin elde edilmesi için toplam 11 DÇ çerçeve (1 referans, 5 geri, 5 ileri çerçeveler). Genel pürüzsüzleştirme parametresi aşağıdaki denklem kullanılarak hesaplanmıştır.

$$\sigma = \sqrt{2} \times std(I_0) \quad (4.30)$$




Ağırlık hesaplamasında kullanılan blok boyutu 5×5 ’ lik YÇ pikseldir. W arama alanı olarak çerçeveler arası büyük hareket içermesinden dolayı *Foreman* için 13×13 piksel, *Suzie* ve *Miss America* için 11×11 piksel seçilmiştir.

Ortak vektörü bulmak için kullanılan parametreler CVA yöntemi üzerinde önemli bir rol oynamaktadır. Örneğin, 5×5 piksel blok boyutu ve 11×11 piksel arama penceresi boyutlarına sahip bir işlemde toplam $(W - p + 1)^2 N = (11 - 5 + 1)^2 \times 11 = 539$ tane vektör CVA için yeterli veri durumunu sağlamaktadır. Çünkü bir tane vektörün boyutu $p \times p = 5 \times 5 = 25$ ' dir. Öte yandan, CVA' nın, kovaryans matrisinin tersinin gerekli olduğu diğer alt uzay tabanlı yöntemlerin aksine, yetersiz veri durumunun ele alınmasında bir problemi olmayacaktır.

VSRnet, son zamanlarda yapılan en gelişmiş video SÇ yöntemlerinden biridir. İki farklı operasyon durumundan ortaya çıkan farklı sonuçlar, bu yöntemin performansını belirlemektedir. Eğer giriş DÇ görüntüleri gürültüsüz ve bulanık değilse, VSRnet çok iyi sonuçlar vermektedir. (Ör., ortalama PSNR/SSIM: *Foreman* için 34,12 dB/0,9185). Ancak, ilginç bir nokta olarak belirtmek gerekirse, eğer giriş DÇ görüntüler gürültü ve bulanıklık içeriyorsa, VSRnet performansı oldukça sınırlı kalmaktadır. (Ör., ortalama PSNR/SSIM: *Foreman* için 32,98 dB/0,8988). *Foreman* için gürültülü ve bulanık durumda ortalama PSNR' nin 1,15 dB ve ortalama SSIM' nin 0,0197 azaldığı görülmektedir. Azalma miktarları *Suzie* için 3,25 dB/0,0670 ve *Miss America* için 7,63 dB/0,0893 kadardır. Çünkü derin öğrenmede CNN ağı gürültülü piksel değerini sanki normal piksel değeri olarak algılayıp gerçek görüntü pikseli ile haritalamaya çalışmaktadır. Bu yöntemin görüntü iyileştirmedeki yeniden yapım başarısı, gürültülü ve bulanık giriş görüntüleri altında *Suzie* ve *Miss America* için ara değerlendirme yöntemleri ile hemen hemen aynıdır. Şekil. 4.16 ve Şekil 4.17, sırasıyla test edilen video dizilerinin çerçeve başına PSNR ve SSIM değerlerini göstermektedir. Şekillerden görüldüğü gibi, gerçekleştirilen yöntem her zaman tüm kareler için ara değerlendirme yöntemlerinden daha iyi PSNR ve SSIM değerleri üretmiştir. Anlama kolaylığı için, tüm grafiklerde karşılaştırılan SÇ yöntemleri renkli, noktalı veya kesikli çizgilerle gösterilmiştir.



Şekil 4.16. PSNR değerlerine ait grafik: a) *Foreman*, b) *Miss America*, c) *Suzie*




Şekil 4.17. SSIM değerlerine ait grafik: a) *Foreman*, b) *Miss America*, c) *Suzie*

CVA-tabanlı yöntemle diğer yöntemler arasındaki ortalama PSNR/SSIM farkları ise sırası ile NLM-tabanlı, 3DSKR-tabanlı ve VSRnet sonuçlarında 0,26 dB/0,0073, 0,24 dB/0,0234 ve 2,54 dB/0,0533 olarak ölçülmüştür. PSNR grafiklerini incelediğimizde, CVA-tabanlı SÇ, neredeyse tüm kareler için NLM-tabanlı SÇ yönteminden daha iyidir. Yöntemin sonuçlarını 3DSKR-tabanlı yöntem ile karşılaştırdığımızda ise *Foreman* ve *Suzie* test dizilerinde daha iyi PSNR, *Miss America* test dizisinde hemen hemen aynı PSNR değerleri elde edilmiştir. SSIM grafiklerine ait değerlere göre *Foreman* video çerçevelerinde şaşırtıcı bir şekilde VSRnet yöntemi NLM-tabanlı yöntem ile yarışmaktadır. 3DSKR-tabanlı yöntem bu yöntemlere göre daha başarısız olup CVA-tabanlı yöntem diğer SÇ yaklaşımlarını geride bırakmıştır. *Miss America* ve *Suzie* video çerçevelerinde ise VSRnet yöntemi kötü sonuç vermektedir. 3DSKR-tabanlı yöntem genel olarak NLM-tabanlı yöntemin gerisinde kalmaktadır. SSIM ölçütüne göre uygulanan yöntemin diğer yöntemlerden daha başarılı sonuç ürettiğini söylemek mümkündür.

Örnek çerçevelere ait büyütülmüş görsel sonuçlar, Şekil 4.18, Şekil 4.19 ve Şekil 4.20’de verilmiştir. Uygulanan yöntemin sonuçları NN, bilineer ve Lanczos ara değerlendirme yöntemlerine göre daha keskin kenarlara ve daha iyi detaylara sahiptir.


NLM-tabanlı yöntem, piksel ortalaması yerine ağırlıklı ortalama kullanan bir filtreleme tekniği uyguladığı için resimde oluşabilecek merdiven etkisini büyük ölçüde azaltmaktadır. Bu yöntem yinelenen doku içeren düz bölgelerde iyi performans gösterirken, gürültünün varlığında ve daha az tekrar eden doku veya daha büyük hareketlere sahip kenarlarda, bozulma gözle görülür hale gelmektedir. Merdiven etkisine benzer bozulma, *Miss America*’nın yüz bölgesinde, *Foreman*’ın ağzında ve *Suzie*’nin gözlerinde net bir şekilde görülebilir. Bu etkiler, yeniden yapılandırma aşamasında yerel olarak gürültü azaltma uygulayan CVA sonuçlarında büyük ölçüde azalmaktadır.

3DSKR-tabanlı yöntem, komşu piksellerin katkılarını tanımlayan 3-boyutlu çekirdek regresyonu kullanarak DÇ bir pikseli iyileştirmektedir. NLM-tabanlı yöntemle karşılaştırıldığında daha bulanık sonuç elde etmektedir. Bununla birlikte, komşu piksellerdeki aykırı değerler, iyileştirilmeye çalışılan pikselde bozulmaya neden olabilmektedir.




Şekil 4.18. *Foreman* video sahnesi 22. karesine ait sonuçlar: a) Orijinal çerçeve, b) NN ara değerlendirme, c) Bilineer ara değerlendirme, d) NLM-tabanlı SÇ yöntemi, e) 3DSKR-tabanlı SÇ yöntemi, f) VSRnet yöntemi, g) CVA-tabanlı yöntem

Diğer yandan CVA-tabanlı yöntem, komşu piksellerin neden olduğu bozulmaları en aza indirmektedir. Örnek çerçevelerden görülebileceği gibi, CVA-tabanlı SÇ sonuçları diğer sonuçlara kıyasla orijinal çerçeveye daha yakındır.



Şekil 4.19. *Suzie* video sahnesi 8. karesine ait sonuçlar: a) Orijinal çerçeve, b) NN ara değerlendirme, c) Bilineer ara değerlendirme, d) NLM-tabanlı SÇ yöntemi, e) 3DSKR-tabanlı SÇ yöntemi, f) VSRnet yöntemi, g) CVA-tabanlı yöntem

Önerilen yöntemin performansı, en son SÇ yöntemlerinin (kamuya açık kaynak kodlarını kullanarak) çalışma zamanına göre de test edilmiştir. Referans alınan bir DÇ çerçevenin YÇ olarak yeniden oluşturulması için CVA-tabanlı yöntemin ortalama çalışma süresi, bulanıklık giderme işlemi dışında ortalama 40 dakikadır. 3DSKR için bu süre 17 dakikadır. VSRnet yönteminin bütün eğitim süreci 22 saat sürmektedir (Kappeler vd., 2016). Bu süreler göz önüne alındığında, CVA-tabanlı yöntemin çalışma zamanının VSRnet yönteminden daha iyi olduğunu ancak 3DSKR yönteminden daha kötü olduğunu söyleyebiliriz. Çalışma zamanının iyileştirilmesi gelecek çalışmalar için düşünülerek bu tez kapsamı dışında tutulmuştur.



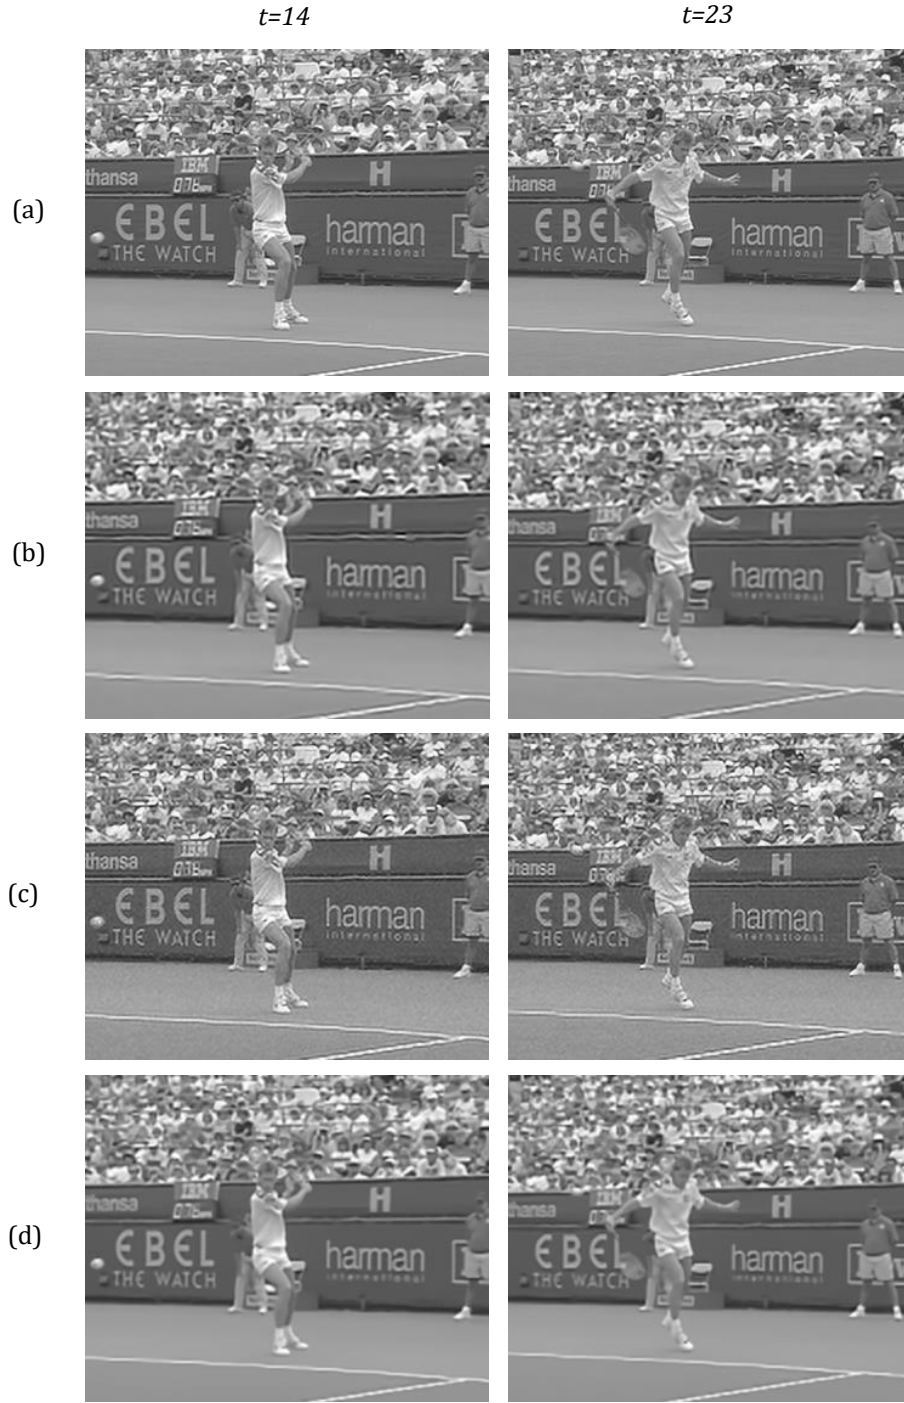
Şekil 4.20. *Miss America* video sahnesi 23. karesine ait sonuçlar: a) Orijinal çerçeve, b) NN ara değerlendirme, c) Bilineer ara değerlendirme, d) NLM-tabanlı SÇ yöntemi, e) 3DSKR-tabanlı SÇ yöntemi, f) VSRnet yöntemi, g) CVA-tabanlı yöntem

Stefan ve *Coastguard* (CIF formatı) video sahnelerinin farklı çerçeve sayısı ve boyutu olması nedeniyle, doğrudan PSNR ve SSIM grafiklerine dahil edilememiştir. Bu video sahnelerinde çerçeveler arasında daha büyük ve karmaşık hareketler bulunmaktadır. Önceki deneylere benzer olarak, DÇ test dizileri, tekdüze PSF kullanılarak karelerin bulanıklaştırılması, 1:2 oranında aşağı örnekleme ve beyaz Gauss gürültüsü eklenerek elde edilmiştir. CVA-tabanlı yöntem, 3DSKR ve VSRnet için ortalama PSNR ve SSIM sonuçlarının karşılaştırması Çizelge 4.6'da, görsel sonuçlar ise Şekil 4.21 ve Şekil 4.22'de verilmiştir.

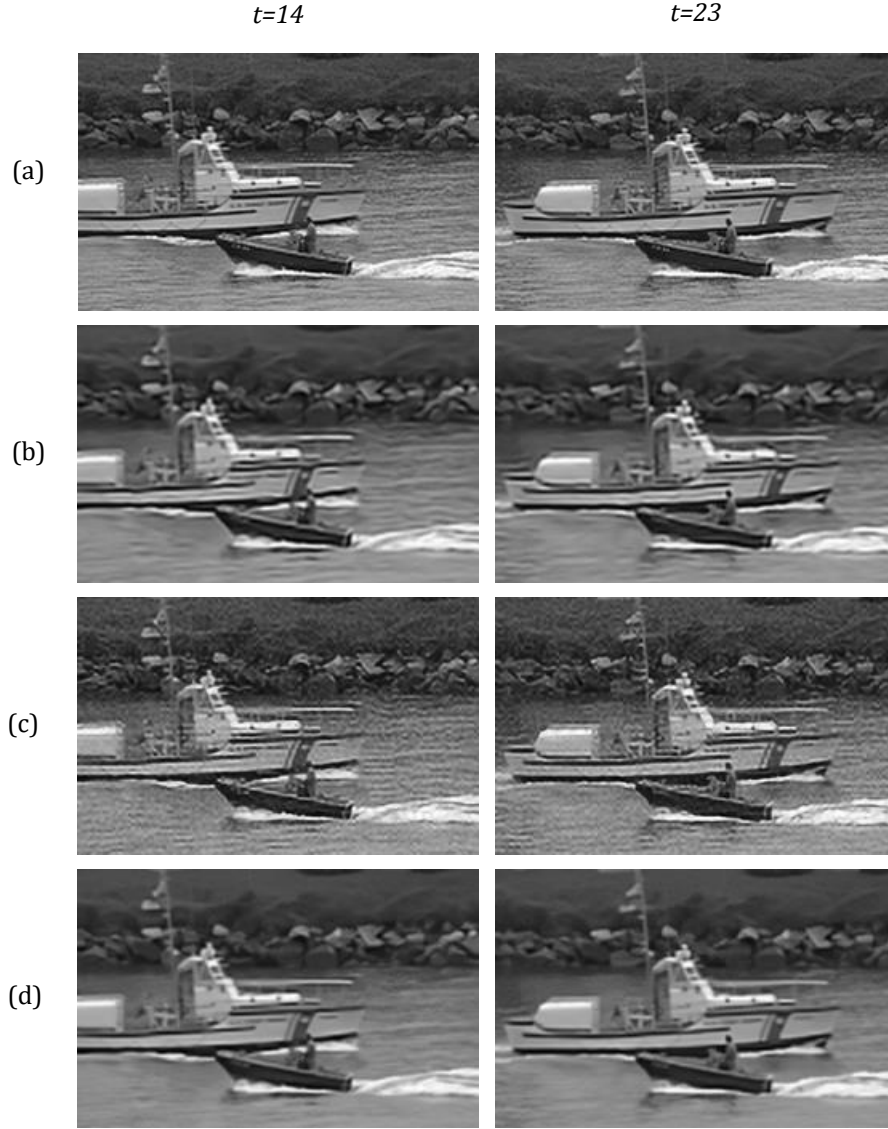
Çizelge 4.6. Süper-çözünürlük yöntemleri ortalama PSNR (dB) ve SSIM değerleri

	3DSKR	VSRnet	CVA
<i>Stefan</i>	26,96/0,8901	27,21/0,8871	27,34/0,8907
<i>Coastguard</i>	27,20/0,8327	28,02/0,8274	28,11/0,8330

Çizelgede verilen sonuçlara göre CVA-tabanlı yöntem hem PSNR hem de SSIM ölçümlerinde diğer yöntemlerden daha iyi performans göstermektedir. 3DSKR gürültüyü baskılamada CVA-tabanlı yöntem kadar iyi sonuç vermesine rağmen kenar bölgelerinde daha kötü sonuç vermektedir. VSRnet ise ayrıntıları çıkarmada oldukça başarılı olmasına rağmen aynı zamanda gürültüyü de ön plana çıkarmaktadır. Çünkü bu yöntem test edilen resimlerde gürültülü pikselleri de normal piksel olarak algılayıp YÇ piksele dönüştürmeye çalışmaktadır. Bu durum PSNR ve SSIM değerlerinde düşmeye, görsel sonuçlarda da normalde olmayan gürültülü sonuçlara neden olmaktadır.



Şekil 4.21. *Stefan* video sahnesi 14. ve 23. karelere ait sonuçlar: a) Orjinal çerçeve, b) 3DSKR-tabanlı SÇ yöntemi, c) VSRnet yöntemi, d) CVA-tabanlı yöntem



Şekil 4.22. *Coastguard* video sahnesi 14. ve 23. karelere ait sonuçlar: a) Orjinal çerçeve, b) 3DSKR-tabanlı SÇ yöntemi, c) VSRnet yöntemi, d) CVA-tabanlı yöntem

4.4. Derin ve Sığ Konvolüsyonel Mimariler Üzerinde Süper-Çözünürlük İçin Farklı Kayıp Fonksiyonlarının Karşılaştırılması

Süper-çözünürlük denetimsiz yapılacağı gibi denetimli olarak da yapılabilir. Yani elimizde var olan orijinal YÇ görüntü ve giriş DÇ görüntüleri arasında belirli bir eğitim setine dayanan haritalama ile DÇ piksel değerlerinin ne kadar iyileştirilebileceği tahmin edilebilir. Tez kapsamında şimdiye kadar denetimsiz SÇ yöntemleri üzerinde çalışmalar yapılmıştır. Bu bölümde ise SÇ alanında yapılmış denetimli yöntemler detayları ile incelenmiş ve tek görüntülü SÇ probleminde oldukça başarılı sonuçlar verdiği

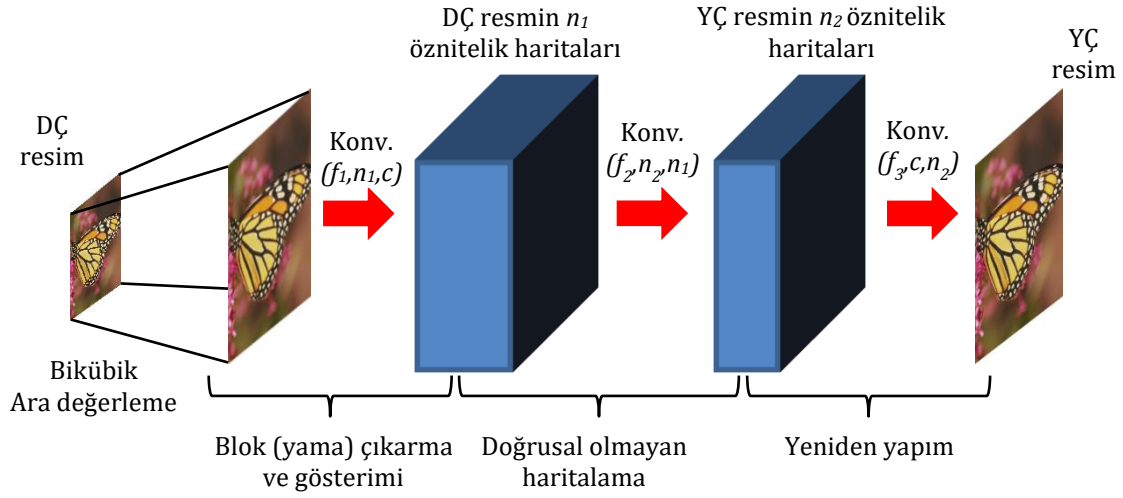
görülmüştür. Konvolüsyon filtreler ile DÇ ve YÇ görüntüler arasındaki rekonstrüktif harita belirlenerek, CNN modelleriyle SISR için performans iyileştirme üzerine çeşitli kayıp fonksiyonlarının etkinliği analiz edilmiştir. On iki kayıp fonksiyonu ayrı ayrı SGDM optimizasyon yöntemi kullanılarak incelenmiştir. Eğitim ve test simülasyonları hem sığ hem de derin CNN mimarileri üzerinde gerçekleştirilmiştir.

91 görüntü üzerinde yapılan deneysel değerlendirmeler sonucunda, bazı parametrik ve parametrik olmayan sağlam kayıp (hata) fonksiyonlarının etkileyici doğru sonuç verdiği, geriye kalanların ise gürültüye duyarlı olmaları nedeniyle öğrenme sürecini yanlış yönlendirdiği ve daha düşük kalitede YÇ çıktılarına neden olduğu gözlemlenmiştir. Sonuç olarak, YÇ görüntü yeniden yapılandırma sonuçları dikkate alınarak, Cauchy, Charbonnier, Fair, Geman, Huber, Phuber veya L1-norm kayıp fonksiyonlarının optimizasyon mekanizması içinde kullanılmasının uygun bir seçim olacağı tespitine varılmıştır. Bunlar arasında, hesaplama zamanı maliyetine göre incelendiğinde L1-norm kayıp fonksiyonunun en hızlı olduğu deneysel olarak kanıtlanmıştır.

4.4.1. CNN Mimarilerinde SÇ İçin Kayıp Fonksiyonlarının Analizi

SISR' nin amacı CNN mimarisi kullanılarak geri yayılım yoluyla eğitilen konvolüsyon filtreleri kullanılarak, bir tane DÇ görüntüsünden yeni bir SÇ görüntüsü üretmektir. Teknik olarak, CNN mimarileri, büyük hacimli veriler ve çeşitli özyinelemeler konusunda eğitilmiş çok sayıda gizli katmandan oluşmaktadır. YÇ görüntüsünü, CNN katmanları ile geri elde etmenin genel blok diyagramı, Şekil 4.23'de gösterilmektedir. Temsili bloklar DÇ görüntüsünden çıkartılıp bu bloklar üzerine önceden belirlenen konvolüsyon filtreleri uygulanmaktadır. Geri besleme yönünde, ilgili kayıp tahmincisinin türevi SGDM yöntemi ile hesaplanarak evrişim adımlarında kullanılan ağırlık ve bias parametreleri güncellenmektedir.

CNN mimarisi ile ilgili olarak, SISR problemi, tahmin edilen ve ulaşılmak istenen orijinal YÇ görüntü arasındaki hatayı en aza indirmek için, gradyan doğrultusunda en az hata oranını elde ederek mümkün olabilir. Bu amaçla, görüntü genellikle alt görüntü parçalarına bölünür ve bu küçük bölgeler için SÇ yöntemi gerçekleştirilir.



Şekil 4.23. CNN mimarisinde gerçekleştirilen SISR

$\{\mathbf{a}_k, k = 1, \dots, s\}$ YÇ ve $\{\mathbf{b}_k, k = 1, \dots, s\}$ DÇ resmin makro blokları olduğunu varsaydığımızda, söz konusu bloklar her bir resimden ayrı ayrı olarak birbirine örtüşecek ve eşit sayıda olacak şekilde, aynı boyuta sahip yüksek çözünürlüklü X ve düşük çözünürlüklü (bikübik ara değerlendirme ile üst örneklenmiş) y resimlerinden üretilmektedir. Aşağıda verilen denklem kullanılarak tahmin edilen \tilde{X} ve orijinal gerçek YÇ görüntü X arasında en küçükleme (minimizasyon) işlemi gerçekleştirilebilir.

$$J(w) = \frac{1}{n} \sum_{i=1}^n \|\tilde{X} - X\|^2 \quad (4.30)$$

Bu denklemdeki tahmin edilen $\tilde{X} = F(y_i; w_j, w_{j+1}, \dots, w_k)$ resmi konvolüsyonel katmanlar ile elde edilmektedir. Çoğu CNN algoritması, SGDM' deki ağırlıklar ile ilgili olarak hata oranlarını hesaplarken En Küçük Karesel Hata (L2-norm) olarak adlandırılan Öklid kayıp fonksiyonunu kullanır. η öğrenme oranını, $\frac{\partial J(w)}{\partial w}$ kayıp fonksiyonunun türevini, Δ , başlangıç değeri 0 olan hızı göstermek üzere SGDM denklemi aşağıda verilmiştir.

$$\begin{aligned} \Delta_{t+1} &= 0.9\Delta_t + \eta \frac{\partial J(w)}{\partial w} y_i, \\ w_{t+1} &= w_t + \Delta_{t+1} \end{aligned} \quad (4.31)$$

Her kayıp fonksiyonunun davranışı ve sağlamlığı gürültüye karşı farklılık göstermesi bu çalışmanın ana konusudur. Çizelge 4.7, bu çalışmada incelenen ve değerlendirilen en yaygın kayıp fonksiyonlarını listelemektedir. Bu çalışmanın amacı her kayıp fonksiyonunu SGDM optimizasyon yöntemi ile birlikte kullanarak, kayıp fonksiyonlarının SÇ problemi üzerindeki etkinliğini ortaya koymaktır. Kayıp fonksiyonlarının, CNN mimarilerinde ağırlık ve öngörü parametrelerinin güncellenmesinde önemli etkileri bulunmaktadır. Örneğin, L1-norm kayıp fonksiyonu aykırı değerlere karşı L2-norm kayıp fonksiyonundan daha sağlamdır. Ayrıca, L2-norm ikinci mertebeden kayıp fonksiyonunun ($J(r) = r^2$), tahmin edilen verilerin genel karakteristiğinden uzak olduğu durumlarda yüksek hata oranları vereceğini söylemek mümkündür. Bu, L2-norm kayıp fonksiyonunun aykırı değerlere karşı hassas olmasının nedenidir.

Çizelge 4.7. CNN mimarilerinde SÇ gerçekleştirmek için kullanılan hata fonksiyonları

Hata Tahmin Edici	Hata Fonksiyonu ($J(r)$)	Etki Fonksiyonu ($\psi(r)$)
L-1	$ r $	$sign(r)$
L-2	$r^2 / 2$	r
Cauchy	$\frac{c^2}{2} \log(1 + (r/c)^2)$	$\frac{r}{1 + (r/c)^2}$
Charbonnier	$\sqrt{r^2 + \epsilon^2}$	$\frac{r}{\sqrt{r^2 + \epsilon^2}}$
Huber	$\begin{cases} r^2 / 2 & \text{if } r \leq c \\ c(r - c/2) & \text{if } r \geq c \end{cases}$	$\begin{cases} r & \text{if } r \leq c \\ csign(r) & \text{if } r \geq c \end{cases}$
Pseudo-Huber	$c^2 \left(\sqrt{1 + r^2 / c^2} - 1 \right)$	$\frac{r}{\sqrt{1 + r^2 / c^2}}$
Tukey	$\begin{cases} \frac{c^2}{6} \left(1 - (1 - (r/c)^2)^3 \right) & \text{if } r \leq c \\ 0 & \text{if } r \geq c \end{cases}$	$\begin{cases} r \left(1 - (r/c)^2 \right)^2 & \text{if } r \leq c \\ 0 & \text{if } r \geq c \end{cases}$
Geman-McClure	$\frac{r^2 / 2}{c^2 + r^2}$	$\frac{c^2 r}{(c^2 + r^2)^2}$
Fair	$c^2 \left(r /c - \log(1 + r /c) \right)$	$\frac{r}{1 + r /c}$
Logistic	$c^2 \log(\cosh(r/c))$	$c \tanh(r/c)$
Talwar	$\begin{cases} r^2 & \text{if } r \leq c \\ c^2 & \text{if } r \geq c \end{cases}$	$\begin{cases} r & \text{if } r \leq c \\ 0 & \text{if } r \geq c \end{cases}$
Welsch	$\frac{c^2}{2} \left(1 - \exp(-(r/c)^2) \right)$	$r \exp(-(r/c)^2)$

Bazı kayıp fonksiyonları yüksek hata oranı oluşturmakta ve aşırı-uygunluğa (over-fitting) neden olmaktadır. Öte yandan, düşük hata oranları yetersiz-uygunluk (under-fitting) sebebidir. Bu nedenle, aşırı-uygunluk ve yetersiz-uygunluk arasındaki en iyi durum genellikle iyi bir çözüm olarak kabul edilir. Daha uygun bir model elde etmek için, çeşitli kayıp fonksiyonları parametrik ve parametrik olmayan denklemlerle geliştirilebilir.

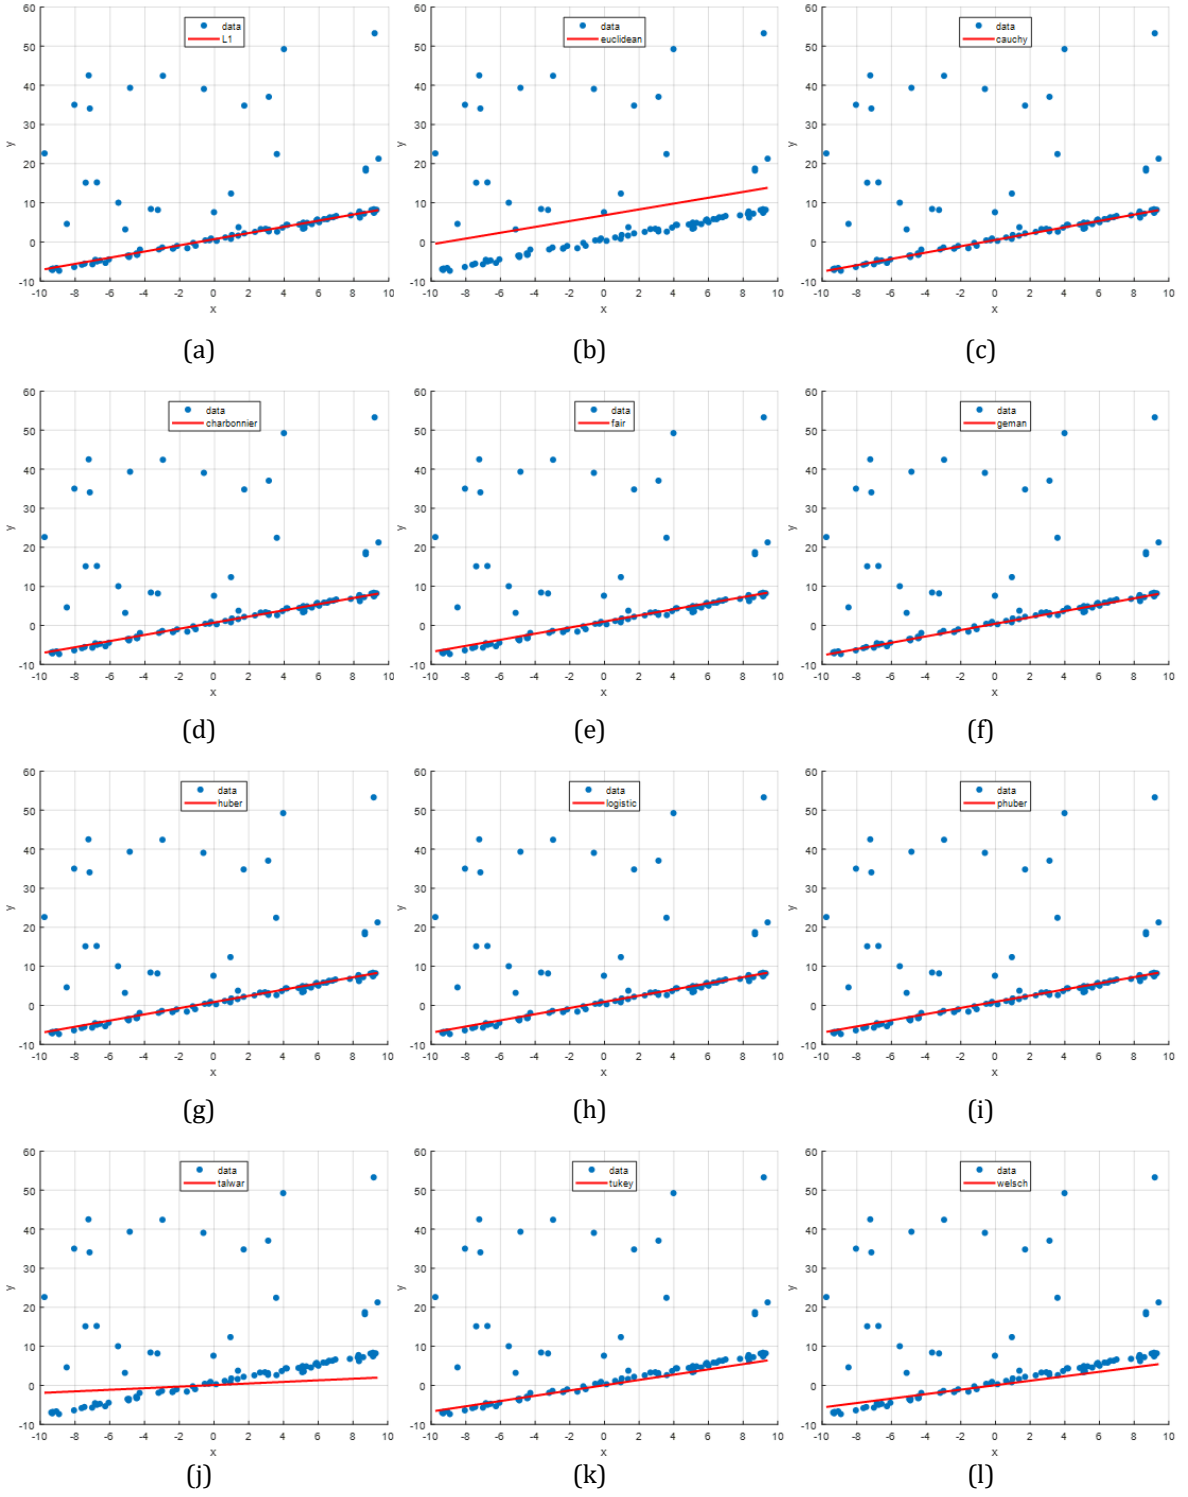
Yukarıda belirtilen önerileri dikkate alarak, bu çalışmada DÇ ve YÇ resim arasında sağlam bir haritalama modeli oluşturmak için Çizelge 4.7’de verilen kayıp fonksiyonları uygulanmıştır. r tahmin edilen ve gerçek veri arasındaki artık değeri, c ise kayıp fonksiyonunun ayar parametresini belirtmektedir. Bazı kayıp fonksiyonlarının parametresiz, bazılarının ise parametrelere bağlı olduğu çizelgeden görülebilir. Önceki çalışmalarda (Dong vd., 2014;Kim vd., 2016) yapıldığı gibi, sadece tek bir kayıp fonksiyonunu kullanmak yerine, SISR probleminde hatayı en küçükmek için sınırlı bir veri setinde çeşitli sağlam kayıp fonksiyonları etkin biçimde test edilmiştir. Bütünlük için, kayıp fonksiyonları hem sığ hem de derin CNN mimarilerde kullanılmıştır.

4.4.2. Kayıp Fonksiyonlarının Sağlık Analizi

İstenilen YÇ görüntülerini üretebilen bir CNN mimarisi tasarlanması, kayıp fonksiyonlarının, regresyondan sınıflandırmaya kadar değişebilen belirli bir hedef için seçilmesi ve benimsenmesi için ayrıntılı bir ön çalışma gerektirir. Yapılan çalışma, Janocha ve Czarnecki’ nin (2017) sınıflandırmada kayıp fonksiyonunun seçimiyle ilgili yapmış oldukları çalışma ile benzerlik göstermektedir.

Mevcut CNN çalışmaları üzerinde yapılan analiz, optimizasyonun genellikle eğitim sürecinde aykırı değerlere bakılmaksızın yapıldığını göstermektedir. SÇ problemi içinde, aykırı değer genel eğilime uymayan bir gözlem olarak nitelendirilebilir. Aykırı değerler, yanıltıcı tahminlerin nedenleridir ve kontrol edilen parametreler aracılığıyla bir kayıp fonksiyonunun davranışı ayarlanarak engellenmesi gerekmektedir. Çünkü CNN mimarilerinin eğitim sürecini yönlendirmek, optimum ve daha hızlı sonuçların üretilmesi için kayıp fonksiyonları kullanılmaktadır. Bir kayıp fonksiyonunun aykırı değerlere duyarlı olması arzu edilmediğinden, belirli bir uygulamada kayıp fonksiyonunun seçimi performansı büyük ölçüde etkiler.

Şekil 4.24 aykırı değerler ile aynı veri kümesi üzerinde on iki kayıp fonksiyonunun davranışlarını göstermektedir. Şekilde her kayıp fonksiyonu için doğrusal yerleştirilmiş bir model gösterilmiştir. Bu model, Albanie (2017) tarafından sağlanan açık kaynak kod ile oluşturulmuştur. Veriler rastgele olarak oluşturulmuştur. w ve b tek katmanlı bir algılayıcı (perceptron) algoritmasının ağırlık ve bias parametreleridir. Buna göre $X = w'y + b$ eşitliği her kayıp fonksiyonu ayrı ayrı kullanılarak artık hesaplama için SGDM ile hesaplanmaktadır. Test verisinde 100 tane rastgele nokta türetilmiştir. Ayrıca bu veri setinde olasılık değeri 0,2 olan aykırı değerler de bulunmaktadır. Ağırlık ve bias parametrelerinin eğitimi SGDM optimizasyon tarafından gerçekleştirilmiştir. Öğrenme katsayısı ve özyineleme sayısı sırasıyla $1e-3$ ve 300 olarak ayarlanmıştır. Şekilden görülebileceği gibi, her kayıp fonksiyonu ile eğitilen model, farklı tahminler üretmektedir. Her kayıp fonksiyonu için sonuçları incelediğimizde, bazı kayıp fonksiyonlarının, aykırı değerlere sahip veriler üzerinde diğerlerinden daha verimli ve sağlam olduğunu gözlemleyebiliriz. Sonuçların ayrıntılı incelenmesi, L2-norm kayıp fonksiyonunun, hata miktarının ikinci dereceden büyüme nedeniyle eğilim çizgisinden uzak tahminler yaptığını ortaya koymaktadır. Öte yandan, L1-norm kayıp fonksiyonu verileri tahmin etmede L2-norm kayıbdan daha iyidir. Talwar, Tukey ve Welsch kayıp fonksiyonları hata oranını hesaplarken aykırı değerlerden etkilenir ve verilerin genel karakteristiğini koruyamamaktadır. Parametrik olmayan Charbonnier ve L1-norm kayıp fonksiyonları ve parametrik Cauchy, Huber, Pseudo-Huber, Geman-McClure, Fair ve Logistic kayıp fonksiyonları, şaşırtıcı bir şekilde iyi tahminler üretmekte ve modellenen çizginin genel eğilimine tam olarak uymaktadır. Bu tür kayıp fonksiyonlarının iyi tarafı, Adam, SGD veya SGDM gibi iyi bilinen optimizasyon yöntemleri ile birleştirildiğinde etkileyici doğruluk sonuçlarının elde edebileceğinin bir göstergesidir. Güçlü bir kayıp fonksiyonunun, hızlı ve doğru bir şekilde verileri tahmin etmesi beklenirken aşırı-uygunluk veya yetersiz-uygunluk durumlarından kaçınması beklenir. Bu çalışma, kullanılan CNN mimarilerinin öğrenme sürecini analiz ederken, esnek bir kayıp fonksiyonunun seçilmesinin gerekliliğini ortaya koymaktadır.



Şekil 4.24. Gürültülü veriler için kayıp fonksiyonlarının duyarlılık analizi: a) L1-norm, b) L2-norm (Öklid), c) Cauchy, d) Charbonnier, e) Fair, f) Geman, g) Huber, h) Logistic, i) Phuber, j) Talwar, k) Tukey, l) Welsch kayıp fonksiyonları

4.4.3. CNN Mimarilerinin Eğitim Süreci

Eğitim aşamasında performans sınırlarının değerlendirilmesi amacıyla, iyi bilinen sığ ve derin CNN mimariler üzerinde ayrıntılı çalışma yapılmıştır. Deneyle, SRCNN ve Çok Derin Süper-Çözünürlük (VDSR) mimarilerine benzeyen gelişmiş CNN modellerinde gerçekleştirilmiştir. Her iki ağın performanslarını değerlendirmek ve kapsamlı olarak karşılaştırmak için, her birinin derinlik ayarları kademeli olarak değiştirilmiştir. Öğrenme süreci 20 epocdan oluşmaktadır ve mini yığın (batch) boyutu 1 olarak seçilmiştir. Standart olması amacı ile özellikle popüler T91 resim seti üzerinde eğitim yapılmıştır. Tüm CNN mimarileri, konvolüsyonlar ve Düzeltmiş Doğrusal Birim (ReLU) aktivasyon fonksiyonlarından oluşmaktadır. Test edilen kayıp fonksiyonları için öğrenme katsayıları Çizelge 4.8’de verilmiştir.

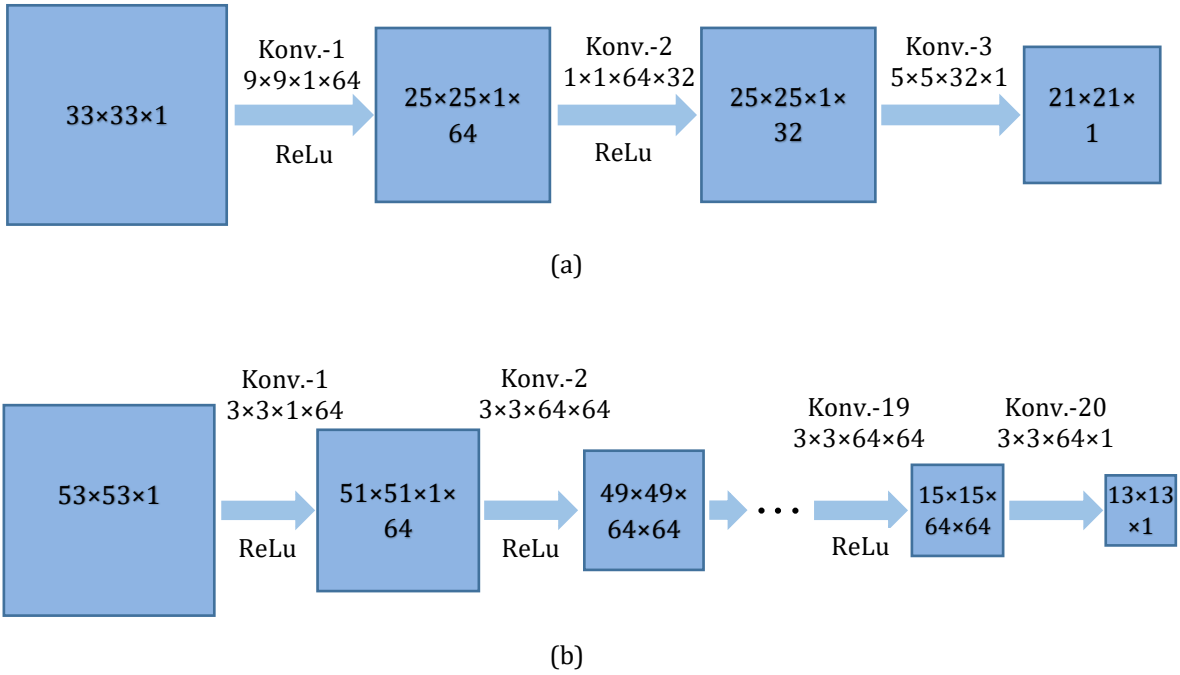
Çizelge 4.8. Kayıp fonksiyonları için öğrenme katsayıları (Toplam 20 epoc)

	1-18 epoc arası	19-20 epoc arası
Hata Fonksiyonu	Sığ/Derin Mimari	Sığ/Derin Mimari
L1-norm	1e-5/1e-5	1e-6/1e-6
L2-norm (Euclidean)	1e-5/1e-5	1e-6/1e-6
Cauchy	1e-3/1e-3	1e-4/1e-4
Charbonnier	1e-5/1e-5	1e-6/1e-6
Huber	1e-3/1e-4	1e-4/1e-5
Pseudo-Huber	1e-3/1e-3	1e-4/1e-4
Tukey	1e-3/1e-3	1e-4/1e-4
Geman-McClure	1e-3/1e-3	1e-4/1e-4
Fair	1e-3/1e-3	1e-4/1e-4
Logistic	1e-3/1e-3	1e-4/1e-4
Talwar	1e-3/1e-3	1e-4/1e-4
Welsch	1e-3/1e-3	1e-4/1e-4

Teknik olarak, kullanılan sığ CNN mimarisinde konvolüsyon katmanlarındaki çekirdek filtreler 9-1-5 olarak belirlenmiştir. Şekil 4.25a, sığ mimarinin akışını göstermektedir. Ayrıca, derinlik boyutu n , CNN modeli boyunca sabitlenmiş ve deneyler bağımsız olarak $n = 64, 128, 256$ ve 512 ile gerçekleştirilmiştir. Giriş DÇ blok büyüklüğü 33×33 , orijinal YÇ blok boyutu ise konvolüsyon filtrelerinin sayısına göre 21×21 olarak belirlenmiştir. 91 resimden, 5 adım (piksel) atlayarak kabaca 165.000 blok çıkartılmaktadır. Her deney 2, 3 ve 4 büyütme katsayıları ile tekrarlanmıştır.

VDSR ağına benzer olarak, sabit filtre boyutu (3×3) ve 20 katmanlı bir mimaride uygulama gerçekleştirilmiştir. Şekil 4.25b uygulanan derin CNN modelini göstermektedir. YÇ elde edilmesinin başarısını etkileyip etkilemediğini belirlemek için filtre derinlikleri 64 ve 128 olarak ayarlanmıştır. Derin mimariler için DÇ giriş blok boyutu 53×53 , orijinal YÇ blok boyutu 13×13 kullanılmıştır. Sığ mimari deneylerine benzer şekilde, 2, 3 ve 4' lük farklı büyüme oranları ile bloklar bağımsız olarak üretilmiştir. VDSR' nin aksine, bloklar, 4 piksel atlayarak 91 görüntüden çıkartılarak hazırlanmıştır.

Deneysel testler mevcut referans veri setleri, Set5 (Bevilacqua vd., 2012), Set14 (Zeyde vd., 2010), BSD100 (Martin vd., 2001) ve URBAN100 (Huang vd., 2015) üzerinde gerçekleştirilmiştir. Farklı kalite ve çözünürlükte yeterli sayıda görüntüye sahip olan bu veri setleri, SÇ modelinin performansını değerlendirmek için evrensel olarak onaylanmıştır. Bu tür büyük veri setleri, önerilen çalışmalar üzerinde gerçekçi bir değerlendirme ve mevcut çalışmalar ile karşılaştırma fırsatı vermektedir.




Şekil 4.25. Deneyde kullanılan sığ ve derin CNN mimarileri

4.4.4. Deneysel Sonular ve Performans Deęerlendirme

Bu alıřma sıę ve derin CNN modellerinin her ikisi de modern derin ęrenme aralarından Vedaldi ve Lenc (2015) tarafından geliřtirilen MatConvNet ortamı kullanılarak gereklenmiřtir. Tm deneyler, 20 masast bilgisayarından oluřan bir laboratuvar ortamında (Intel Core i7-6700 iřlemci, 3,4 GHz, 8 GB bellek ve 240 GB SSD HD) gerekleřtirilmiřtir. Derin CNN aę yapısında, 91 resimden ıkartılan 213.000 yama zerinde, epoc sayısı 20, mini-yıęın (mini-batch) boyutu 64, filtre derinlięi sabit 64 olduęunda eęitim sresi yaklaşık 36 saat srmektedir. Sıę CNN aę yapısında, 91 resimden ıkartılan 213.000 yama zerinde eęitim aynı sayıda epoc ve mini-batch iin 4 saat srmektedir.

nerilen CNN modelleri basit olmasının yanında etkileyici sper öznrlk sonuları elde etmektedir. Farklı kayıp fonksiyonlarına ait grsel sonular Őekil 4.26'da gsterilmiřtir. Ayrıca seilmiř olan bazı kenar ve dokularla ilgili bytlmř sonular da bu Őekil iinde sunulmuřtur. rnek sonuların Őekil 4.24'te verilen sonularla rtřtę grlmektedir. BSDS100/302008 numaralı grntsnde, Cauchy, Charbonnier, Fair, Geman, Huber, L1-norm ve Phuber kayıp fonksiyonlarının PSNR, SSIM ve grsel sonularının, dięer kayıp fonksiyonlarının sonularına kıyasla daha bařarılı olduęunu sylemek mmkndr.

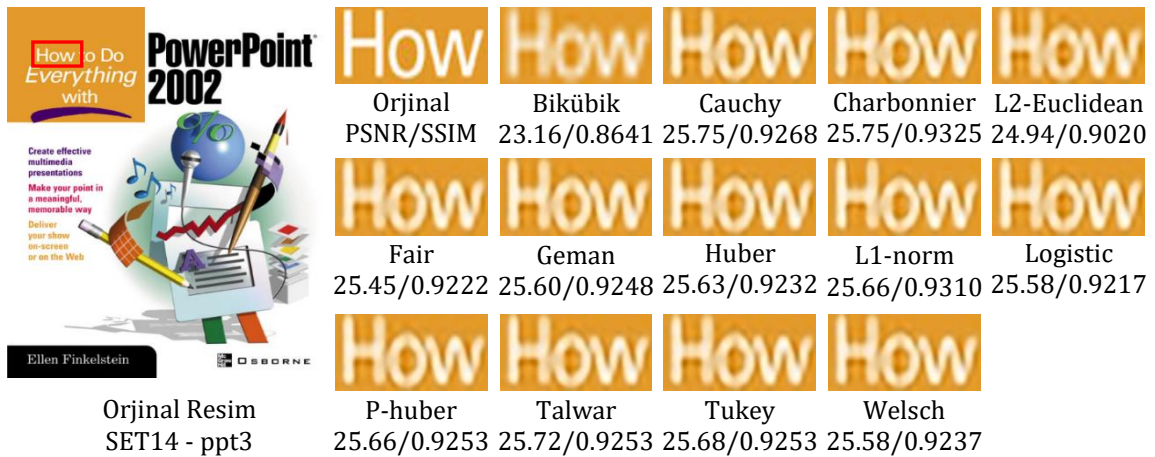
Őekil 4.26a'daki BSDS100/ 302008 resmindeki grsel sonuları incelendięinde, L2-norm dıřındaki tm kayıp fonksiyonlarının yksek kaliteli sonular rettięini gzlemleyebiliriz. Őekil 4.26b'de gsterilen Set5/Butterfly ve Őekil 4.26c'de gsterilen SET14/ppt3 grntsnde de benzer sonular elde edilmiřtir. L2-norm ve bikbik ara deęerleme dıřındaki tm kayıp fonksiyonları iyi sonu vermiřlerdir. Bununla birlikte, L2-norm ve bikbik, ortaya ıkan grntler zerinde bir miktar bulanıklıęa neden olmuřlardır. Metin karakterlerinin yapısını koruyarak en iyi  SSIM deęeri Cauchy, Charbonnier ve L1-norm tarafından elde edilmiřtir. En iyi PSNR sonuları, sırasıyla Set5/Butterfly, BSDS100/ 302008 ve SET14/ppt3 grntleri iin L1-norm 29,49 dB, Geman 33,35 dB, Cauchy/ Charbonnier 25,75 dB olarak elde edilmiřtir.



(a)



(b)



(c)

Şekil 4.26. Derin CNN mimarisine ait SÇ sonuçları (yakınlaştırma oranı: 3x)

Sırası ile Çizelge 4.9, Çizelge 4.10, Çizelge 4.11 ve Çizelge 4.12 kullanılan konvolüsyonel filtrelerin derinliği 64, 128, 256 ve 512 olarak ayarlandığı zaman, sığ CNN mimarisinin sonuçlarını göstermektedir. Bu çizelgelerdeki en iyi sonuçlar kalın punto ile gösterilmiştir. Aynı öğrenme hızı ve parametre ayarları altında, filtre boyutunun derinliğini arttırmanın performansı arttırdığını söylemek mümkündür. Ancak, performans artışı, artan karmaşıklık göz önünde bulundurduğumuzda küçüktür. PSNR/SSIM cinsinden sonuçlara baktığımızda, x3 büyüme oranında, filtre derinliği 64 olduğunda 32,57 dB/0,9052 iken, 512 için bu değerler 32,36 dB/0,9010 olarak ölçülmüştür. Bu sonuçlar nispeten küçük bir veri seti olan Set5 üzerinde ve Fair kayıp fonksiyonu kullanılarak elde edilmiştir. Genel olarak, sığ CNN mimarilerinde beklenen performans artışına ulaşamamıştır.

Derin CNN modelleri, Set5 veri setinin sayısal skorlarında oldukça iyi bir performans artışı göstermiştir. Çizelge 4.13 ve Çizelge 4.14' de, derin CNN mimarileri testlerinde elde edilen performans değerleri PSNR/SSIM olarak sunulmuştur. Set5 üzerinde elde edilen en yüksek ortalama PSNR/SSIM değerleri, 64 filtre derinliği ile sağlanan x2, x3 ve x4 büyüme katsayıları için sırası ile 36,77 dB/0,9543 ve 33,10 dB/0,9120 (L1-norm), 30,82 dB/0,8697 (Charbonnier)' dir. Bu değerler derin CNN modellerinde kayda değer bir performans artışını göstermektedir. Diğer bir ifade ile derin CNN mimarisi kullanılarak iyi eğitilmiş bir model, SÇ görüntüsü elde ederken iyi sonuçlar vermektedir.

Tüm sonuçları yalnızca 20 epoc, sabit öğrenim oranları ve herhangi bir öğrenme politikası olmaksızın elde ettiğimize dikkat edilmelidir. Deneyler MatConvNet ortamı kullanılarak gerçekleştirilmiştir. Hiper parametreler doğru bir şekilde ayarlandığında, derin ağların öğrenme sürecini ve performansını doğrudan etkileyen SGDM (yığın boyutu 1) ve büyük miktarda alt görüntü yamalarının kullanılmasıdır. Elde edilen daha yüksek PSNR skorları, tekrarlanan özyineleme sayısı ile açıklanabilir. Çünkü CNN modeli, geri besleme yönünde artan güncellemeler ile daha hızlı bir şekilde eğitilir. Birçok yapılan deneylerden sonra, yama sayısının arttırılması, SISR probleminde iyi sonuç elde edilmesini sağlamaktadır. Ancak donanım yetersizliği ve eğitim süresinin uzaması gibi sorunlarla karşılaşmak kaçınılmazdır.

Çizelge 4.9. Filtre derinliği 64 olan sığ CNN mimarisi PSNR/SSIM sonuçları

		SET5	SET14	BSDS100	URBAN100
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Biküvik		33.66/0.9296	30.24/0.8683	29.48/0.8427	26.85/0.8398
Cauchy		36.19/0.9501	32.14/0.9015	30.96/0.8818	28.77/0.8830
Charbonnier		35.75/0.9480	31.86/0.8987	30.74/0.8788	28.30/0.8751
Euclidean		35.13/0.9422	31.34/0.8943	30.43/0.8750	27.82/0.8651
Fair		36.22/0.9503	32.15/0.9015	30.98/0.8820	28.77/0.8830
Geman		36.27/0.9509	32.17/0.9022	30.98/0.8826	28.83/0.8848
Huber	x2	36.25/0.9504	32.17/0.9016	30.97/0.8820	28.82/0.8840
L1-norm		35.70/0.9483	31.82/0.8989	30.73/0.8787	28.29/0.8753
Logistic		36.23/0.9507	32.16/0.9017	30.97/0.8819	28.78/0.8835
Phuber		36.23/0.9504	32.18/0.9019	30.99/0.8824	28.82/0.8841
Talwar		36.25/0.9506	32.16/0.9015	30.97/0.8818	28.79/0.8834
Tukey		36.22/0.9505	32.16/0.9016	30.98/0.8819	28.79/0.8836
Welsch		36.17/0.9500	32.13/0.9015	30.95/0.8819	28.74/0.8826
Bicubic		30.42/0.8677	27.54/0.7730	27.13/0.7378	24.43/0.7341
Cauchy		32.34/0.9007	28.97/0.8115	28.08/0.7769	25.69/0.7815
Charbonnier		32.07/0.8975	28.82/0.8085	27.97/0.7731	25.48/0.7765
Euclidean		31.58/0.8853	28.43/0.8026	27.75/0.7704	25.13/0.7626
Fair		32.36/0.9010	28.97/0.8117	28.08/0.7769	25.70/0.7823
Geman		32.35/0.9009	28.98/0.8123	28.08/0.7775	25.71/0.7826
Huber	x3	32.34/0.9009	28.98/0.8121	28.08/0.7773	25.71/0.7824
L1-norm		32.17/0.8989	28.85/0.8083	27.98/0.7723	25.54/0.7777
Logistic		32.33/0.9004	28.97/0.8117	28.08/0.7768	25.70/0.7818
Phuber		32.33/0.9009	28.97/0.8120	28.08/0.7772	25.71/0.7826
Talwar		32.34/0.9009	28.98/0.8121	28.08/0.7773	25.71/0.7824
Tukey		32.33/0.9010	28.97/0.8119	28.08/0.7771	25.70/0.7822
Welsch		32.33/0.9004	28.98/0.8119	28.09/0.7773	25.71/0.7826
Bicubic		28.44/0.8105	26.00/0.7018	25.87/0.6671	23.11/0.6568
Cauchy		30.09/0.8512	27.20/0.7415	26.64/0.7027	24.10/0.7039
Charbonnier		29.92/0.8485	27.07/0.7376	26.55/0.6981	23.96/0.6992
Euclidean		29.48/0.8331	26.73/0.7295	26.38/0.6948	23.68/0.6838
Fair		30.03/0.8481	27.14/0.7387	26.60/0.7004	24.04/0.7002
Geman		30.03/0.8482	27.15/0.7388	26.60/0.7006	24.04/0.7005
Huber	x4	29.99/0.8473	27.12/0.7382	26.59/0.7001	24.03/0.6994
L1-norm		29.89/0.8471	27.05/0.7369	26.54/0.6977	23.93/0.6976
Logistic		29.97/0.8467	27.12/0.7383	26.60/0.7009	24.03/0.6994
Phuber		30.03/0.8484	27.15/0.7391	26.60/0.7007	24.04/0.7006
Talwar		29.98/0.8465	27.13/0.7382	26.59/0.7004	24.03/0.6997
Tukey		30.02/0.8475	27.14/0.7387	26.60/0.7001	24.05/0.7012
Welsch		29.99/0.8467	27.13/0.7380	26.60/0.7002	24.03/0.6993

Çizelge 4.10. Filtre derinliği 128 olan sıg CNN mimarisi PSNR/SSIM sonuçları

	SET5	SET14	BSDS100	URBAN100
	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Bikübik	33.66/0.9296	30.24/0.8683	29.48/0.8427	26.85/0.8398
Cauchy	36.36/0.9514	32.22/0.9024	31.03/0.8830	28.91/0.8859
Charbonnier	35.99/0.9499	32.01/0.9003	30.84/0.8802	28.53/0.8797
Euclidean	35.28/0.9437	31.46/0.8955	30.50/0.8764	27.91/0.8666
Fair	36.34/0.9513	32.22/0.9024	31.02/0.8827	28.89/0.8855
Geman	36.37/0.9513	32.23/0.9022	31.03/0.8825	28.93/0.8857
Huber x2	36.30/0.9506	32.20/0.9020	31.01/0.8823	28.87/0.8848
L1-norm	35.95/0.9497	31.98/0.9000	30.84/0.8800	28.52/0.8793
Logistic	36.33/0.9511	32.21/0.9022	31.02/0.8828	28.90/0.8855
Phuber	36.35/0.9514	32.22/0.9023	31.02/0.8826	28.91/0.8856
Talwar	36.33/0.9511	32.22/0.9021	31.02/0.8823	28.90/0.8852
Tukey	36.35/0.9513	32.23/0.9024	31.03/0.8828	28.90/0.8856
Welsch	36.33/0.9511	32.22/0.9021	31.01/0.8823	28.89/0.8849
Bicubic	30.42/0.8677	27.54/0.7730	27.13/0.7378	24.43/0.7341
Cauchy	32.46/0.9031	29.05/0.8140	28.13/0.7790	25.80/0.7859
Charbonnier	32.26/0.9012	28.90/0.8102	28.03/0.7749	25.61/0.7809
Euclidean	31.67/0.8873	28.48/0.8031	27.78/0.7707	25.16/0.7628
Fair	32.43/0.9024	29.03/0.8135	28.12/0.7786	25.78/0.7855
Geman	32.42/0.9025	29.03/0.8130	28.12/0.7782	25.79/0.7854
Huber x3	32.41/0.9023	29.03/0.8130	28.12/0.7784	25.76/0.7845
L1-norm	32.23/0.9004	28.91/0.8107	28.03/0.7749	25.60/0.7805
Logistic	32.41/0.9021	29.02/0.8132	28.12/0.7784	25.78/0.7849
Phuber	32.42/0.9025	29.02/0.8135	28.12/0.7787	25.76/0.7848
Talwar	32.43/0.9027	29.04/0.8129	28.13/0.7782	25.79/0.7852
Tukey	32.45/0.9031	29.05/0.8135	28.13/0.7785	25.79/0.7856
Welsch	32.42/0.9030	29.04/0.8132	28.13/0.7785	25.79/0.7855
Bicubic	28.44/0.8105	26.00/0.7018	25.87/0.6671	23.11/0.6568
Cauchy	30.09/0.8512	27.20/0.7415	26.64/0.7027	24.10/0.7039
Charbonnier	30.02/0.8506	27.13/0.7388	26.58/0.6986	24.02/0.7017
Euclidean	29.62/0.8362	26.81/0.7317	26.43/0.6966	23.75/0.6865
Fair	30.12/0.8512	27.22/0.7409	26.64/0.7019	24.12/0.7040
Geman	30.10/0.8514	27.21/0.7410	26.64/0.7021	24.11/0.7040
Huber x4	30.06/0.8499	27.18/0.7405	26.62/0.7017	24.09/0.7028
L1-norm	30.04/0.8522	27.15/0.7394	26.59/0.6994	24.04/0.7026
Logistic	30.10/0.8509	27.20/0.7408	26.63/0.7017	24.11/0.7036
Phuber	30.06/0.8500	27.20/0.7406	26.63/0.7016	24.10/0.7034
Talwar	30.10/0.8512	27.21/0.7409	26.64/0.7020	24.11/0.7035
Tukey	30.10/0.8519	27.19/0.7416	26.63/0.7026	24.11/0.7050
Welsch	30.08/0.8508	27.20/0.7411	26.63/0.7023	24.10/0.7040

Çizelge 4.11. Filtre derinliği 256 olan sıg CNN mimarisi PSNR/SSIM sonuçları

	SET5	SET14	BSDS100	URBAN100
	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Bikübik	33.66/0.9296	30.24/0.8683	29.48/0.8427	26.85/0.8398
Cauchy	36.45/0.9521	32.28/0.9032	31.08/0.8839	29.03/0.8882
Charbonnier	36.17/0.9512	32.09/0.9017	30.93/0.8819	28.71/0.8833
Euclidean	35.39/0.9448	31.53/0.8965	30.56/0.8774	27.99/0.8685
Fair	36.44/0.9522	32.29/0.9034	31.08/0.8838	29.02/0.8881
Geman	36.47/0.9522	32.30/0.9035	31.08/0.8839	29.02/0.8881
Huber x2	36.44/0.9519	32.28/0.9032	31.07/0.8836	29.01/0.8879
L1-norm	36.10/0.9510	32.10/0.9014	30.91/0.8816	28.66/0.8826
Logistic	36.44/0.9520	32.28/0.9032	31.07/0.8837	29.02/0.8880
Phuber	36.42/0.9519	32.30/0.9032	31.08/0.8837	29.00/0.8875
Talwar	36.44/0.9519	32.28/0.9032	31.06/0.8837	29.01/0.8877
Tukey	36.43/0.9520	32.26/0.9032	31.07/0.8838	28.99/0.8875
Welsch	36.43/0.9520	32.28/0.9033	31.07/0.8839	29.02/0.8881
Bicubic	30.42/0.8677	27.54/0.7730	27.13/0.7378	24.43/0.7341
Cauchy	32.50/0.9045	29.09/0.8151	28.16/0.7800	25.85/0.7883
Charbonnier	32.40/0.9034	29.03/0.8130	28.10/0.7772	25.74/0.7857
Euclidean	31.80/0.8906	28.57/0.8049	27.83/0.7719	25.23/0.7658
Fair	32.49/0.9037	29.09/0.8149	28.16/0.7801	25.84/0.7880
Geman	32.46/0.9037	29.08/0.8144	28.15/0.7795	25.83/0.7870
Huber x3	32.47/0.9036	29.08/0.8143	28.15/0.7794	25.83/0.7874
L1-norm	32.41/0.9033	29.01/0.8126	28.09/0.7768	25.74/0.7855
Logistic	32.47/0.9037	29.09/0.8146	28.16/0.7797	25.84/0.7874
Phuber	32.49/0.9037	29.10/0.8149	28.16/0.7798	25.84/0.7879
Talwar	32.47/0.9036	29.08/0.8143	28.15/0.7794	25.83/0.7874
Tukey	32.49/0.9043	29.10/0.8150	28.17/0.7801	25.85/0.7883
Welsch	32.47/0.9034	29.08/0.8142	28.15/0.7794	25.83/0.7873
Bicubic	28.44/0.8105	26.00/0.7018	25.87/0.6671	23.11/0.6568
Cauchy	30.09/0.8520	27.23/0.7424	26.66/0.7036	24.13/0.7058
Charbonnier	30.12/0.8547	27.20/0.7423	26.63/0.7018	24.10/0.7067
Euclidean	29.68/0.8375	26.85/0.7321	26.46/0.6966	23.78/0.6873
Fair	30.11/0.8529	27.25/0.7426	26.66/0.7033	24.15/0.7065
Geman	30.14/0.8531	27.23/0.7420	26.66/0.7030	24.14/0.7056
Huber x4	30.11/0.8518	27.21/0.7418	26.65/0.7027	24.12/0.7047
L1-norm	30.11/0.8549	27.21/0.7423	26.63/0.7019	24.10/0.7068
Logistic	30.11/0.8520	27.23/0.7423	26.66/0.7032	24.13/0.7056
Phuber	30.11/0.8529	27.23/0.7425	26.66/0.7032	24.14/0.7061
Talwar	30.10/0.8517	27.24/0.7419	26.66/0.7030	24.14/0.7054
Tukey	30.13/0.8535	27.23/0.7422	26.66/0.7030	24.14/0.7063
Welsch	30.12/0.8523	27.24/0.7420	26.66/0.7028	24.14/0.7055

Çizelge 4.12. Filtre derinliği 512 olan sıg CNN mimarisi PSNR/SSIM sonuçları

		SET5	SET14	BSDS100	URBAN100
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Bikübik		33.66/0.9296	30.24/0.8683	29.48/0.8427	26.85/0.8398
Cauchy		36.49/0.9524	32.32/0.9039	31.10/0.8845	29.07/0.8891
Charbonnier		36.29/0.9522	32.18/0.9027	31.00/0.8831	28.86/0.8864
Euclidean		35.49/0.9459	31.63/0.8977	30.60/0.8784	28.08/0.8705
Fair		36.52/0.9525	32.33/0.9038	31.10/0.8844	29.08/0.8894
Geman		36.48/0.9524	32.31/0.9038	31.09/0.8844	29.07/0.8893
Huber	x2	36.48/0.9522	32.30/0.9034	31.09/0.8840	29.04/0.8887
L1-norm		36.32/0.9521	32.18/0.9027	31.01/0.8832	28.87/0.8868
Logistic		36.47/0.9522	32.31/0.9035	31.09/0.8840	29.06/0.8887
Phuber		36.48/0.9523	32.31/0.9035	31.10/0.8841	29.04/0.8886
Talwar		36.29/0.9513	32.21/0.9028	31.01/0.8832	28.84/0.8850
Tukey		36.52/0.9527	32.33/0.9039	31.11/0.8846	29.08/0.8894
Welsch		36.52/0.9525	32.34/0.9039	31.11/0.8844	29.09/0.8895
Bicubic		30.42/0.8677	27.54/0.7730	27.13/0.7378	24.43/0.7341
Cauchy		32.55/0.9049	29.12/0.8151	28.17/0.7799	25.89/0.7895
Charbonnier		32.50/0.9051	29.08/0.8144	28.14/0.7786	25.83/0.7889
Euclidean		31.94/0.8940	28.67/0.8069	27.89/0.7734	25.32/0.7695
Fair		32.57/0.9052	29.14/0.8153	28.18/0.7800	25.92/0.7905
Geman		32.57/0.9053	29.14/0.8158	28.19/0.7805	25.91/0.7904
Huber	x3	32.55/0.9051	29.13/0.8155	28.18/0.7806	25.91/0.7904
L1-norm		32.51/0.9052	29.09/0.8147	28.14/0.7789	25.83/0.7892
Logistic		32.56/0.9052	29.13/0.8155	28.18/0.7803	25.91/0.7903
Phuber		32.57/0.9052	29.14/0.8160	28.19/0.7808	25.91/0.7903
Talwar		32.55/0.9051	29.13/0.8155	28.18/0.7806	25.91/0.7904
Tukey		32.56/0.9055	29.14/0.8160	28.20/0.7810	25.89/0.7896
Welsch		32.57/0.9056	29.14/0.8162	28.19/0.7813	25.91/0.7905
Bicubic		28.44/0.8105	26.00/0.7018	25.87/0.6671	23.11/0.6568
Cauchy		30.14/0.8541	27.28/0.7437	26.68/0.7043	24.17/0.7078
Charbonnier		30.18/0.8573	27.27/0.7446	26.66/0.7035	24.17/0.7103
Euclidean		29.79/0.8403	26.92/0.7340	26.49/0.6980	23.84/0.6902
Fair		30.15/0.8543	27.28/0.7437	26.68/0.7044	24.17/0.7081
Geman		30.15/0.8544	27.28/0.7438	26.68/0.7043	24.18/0.7083
Huber	x4	30.13/0.8533	27.25/0.7428	26.67/0.7036	24.16/0.7070
L1-norm		30.18/0.8573	27.28/0.7448	26.67/0.7041	24.17/0.7105
Logistic		30.13/0.8537	27.26/0.7431	26.67/0.7041	24.16/0.7072
Phuber		30.16/0.8546	27.25/0.7438	26.67/0.7043	24.17/0.7085
Talwar		30.13/0.8534	27.25/0.7429	26.67/0.7040	24.16/0.7071
Tukey		30.17/0.8549	27.28/0.7438	26.68/0.7046	24.17/0.7083
Welsch		30.15/0.8543	27.27/0.7434	26.68/0.7038	24.17/0.7078

Çizelge 4.13. Filtre derinliği 64 olan derin CNN mimarisi PSNR/SSIM sonuçları


	SET5	SET14	BSDS100	URBAN100
	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Biküçük	33.66/0.9296	30.24/0.8683	29.48/0.8427	26.85/0.8398
Cauchy	36.45/0.9519	32.06/0.9016	30.83/0.8809	28.80/0.8833
Charbonnier	36.76/0.9542	32.24/0.9039	30.97/0.8842	29.15/0.8907
Euclidean	35.58/0.9448	31.50/0.8956	30.40/0.8746	27.97/0.8665
Fair	36.40/0.9513	32.06/0.9011	30.82/0.8804	28.75/0.8824
Geman	36.45/0.9515	32.09/0.9016	30.85/0.8811	28.79/0.8829
Huber x2	36.44/0.9512	32.05/0.9009	30.83/0.8805	28.77/0.8823
L1-norm	36.77/0.9543	32.25/0.9041	30.97/0.8842	29.15/0.8909
Logistic	35.57/0.9448	31.48/0.8949	30.40/0.8742	27.98/0.8664
Phuber	36.46/0.9518	32.07/0.9016	30.84/0.8811	28.81/0.8837
Talwar	36.36/0.9510	32.04/0.9010	30.81/0.8803	28.73/0.8815
Tukey	36.40/0.9511	32.04/0.9009	30.82/0.8805	28.72/0.8818
Welsch	36.39/0.9510	32.06/0.9009	30.83/0.8804	28.77/0.8823
Bicubic	30.42/0.8677	27.54/0.7730	27.13/0.7378	24.43/0.7341
Cauchy	32.99/0.9094	29.06/0.8156	28.07/0.7799	25.92/0.7904
Charbonnier	33.09/0.9118	29.09/0.8159	28.09/0.7797	26.03/0.7947
Euclidean	32.20/0.8953	28.64/0.8065	27.76/0.7707	25.36/0.7689
Fair	32.96/0.9089	29.03/0.8144	28.05/0.7785	25.88/0.7884
Geman	32.99/0.9097	29.06/0.8149	28.06/0.7787	25.90/0.7892
Huber x3	32.95/0.9083	29.04/0.8144	28.05/0.7788	25.89/0.7887
L1-norm	33.10/0.9120	29.09/0.8163	28.09/0.7800	26.02/0.7946
Logistic	32.87/0.9075	28.99/0.8139	28.02/0.7782	25.85/0.7872
Phuber	33.00/0.9098	29.05/0.8154	28.06/0.7797	25.92/0.7900
Talwar	32.94/0.9086	29.03/0.8151	28.06/0.7793	25.90/0.7893
Tukey	32.93/0.9083	29.04/0.8151	28.05/0.7791	25.89/0.7888
Welsch	32.94/0.9091	29.03/0.8149	28.05/0.7788	25.89/0.7890
Bicubic	28.44/0.8105	26.00/0.7018	25.87/0.6671	23.11/0.6568
Cauchy	30.68/0.8648	27.26/0.7459	26.60/0.7046	24.26/0.7126
Charbonnier	30.82/0.8697	27.29/0.7469	26.61/0.7049	24.31/0.7168
Euclidean	30.17/0.8476	26.92/0.7346	26.37/0.6949	23.88/0.6913
Fair	30.68/0.8654	27.26/0.7459	26.60/0.7043	24.25/0.7121
Geman	30.68/0.8649	27.24/0.7450	26.58/0.7035	24.23/0.7107
Huber x4	30.68/0.8644	27.25/0.7453	26.59/0.7042	24.25/0.7114
L1-norm	30.77/0.8684	27.26/0.7460	26.60/0.7041	24.30/0.7160
Logistic	30.12/0.8452	26.91/0.7343	26.37/0.6948	23.86/0.6904
Phuber	30.69/0.8645	27.28/0.7459	26.60/0.7040	24.26/0.7118
Talwar	30.68/0.8644	27.25/0.7453	26.59/0.7042	24.25/0.7114
Tukey	30.65/0.8638	27.25/0.7448	26.58/0.7036	24.22/0.7105
Welsch	30.70/0.8645	27.23/0.7446	26.58/0.7036	24.24/0.7110

Çizelge 4.14. Filtre derinliği 128 olan derin CNN mimarisi PSNR/SSIM sonuçları

	SET5	SET14	BSDS100	URBAN100
	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Biküçük	33.66/0.9296	30.24/0.8683	29.48/0.8427	26.85/0.8398
Cauchy	36.60/0.9526	32.14/0.9022	30.89/0.8819	28.95/0.8860
Charbonnier	36.87/0.9549	32.31/0.9045	31.02/0.8847	29.28/0.8928
Euclidean	35.71/0.9462	31.60/0.8967	30.48/0.8759	28.06/0.8684
Fair	36.58/0.9526	32.13/0.9023	30.89/0.8820	28.94/0.8860
Geman	36.56/0.9524	32.12/0.9021	30.89/0.8819	28.92/0.8852
Huber	x2 36.56/0.9526	32.14/0.9022	30.89/0.8818	28.94/0.8858
L1-norm	36.81/0.9546	32.28/0.9042	31.00/0.8844	29.25/0.8922
Logistic	35.70/0.9462	31.59/0.8966	30.46/0.8757	28.06/0.8684
Phuber	36.55/0.9522	32.13/0.9018	30.89/0.8816	28.94/0.8854
Talwar	36.54/0.9520	32.11/0.9018	30.87/0.8815	28.91/0.8847
Tukey	36.54/0.9522	32.15/0.9023	30.90/0.8818	28.89/0.8845
Welsch	36.59/0.9524	32.15/0.9024	30.92/0.8824	28.93/0.8855
Bicubic	30.42/0.8677	27.54/0.7730	27.13/0.7378	24.43/0.7341
Cauchy	32.98/0.9095	29.00/0.8147	28.05/0.7795	25.91/0.7903
Charbonnier	33.13/0.9128	29.12/0.8175	28.11/0.7814	26.05/0.7966
Euclidean	32.26/0.8968	28.64/0.8072	27.76/0.7714	25.35/0.7689
Fair	33.09/0.9109	29.10/0.8169	28.10/0.7813	25.98/0.7928
Geman	33.03/0.9100	29.10/0.8169	28.10/0.7812	25.97/0.7925
Huber	x3 32.92/0.9089	29.00/0.8147	28.04/0.7792	25.89/0.7897
L1-norm	33.11/0.9126	29.08/0.8166	28.09/0.7806	26.01/0.7952
Logistic	33.04/0.9107	29.10/0.8166	28.10/0.7807	25.98/0.7927
Phuber	32.97/0.9094	29.01/0.8148	28.05/0.7792	25.90/0.7898
Talwar	33.04/0.9106	29.07/0.8164	28.09/0.7809	25.97/0.7922
Tukey	32.92/0.9087	28.99/0.8144	28.04/0.7788	25.89/0.7890
Welsch	33.07/0.9107	29.10/0.8167	28.11/0.7813	26.00/0.7931
Bicubic	28.44/0.8105	26.00/0.7018	25.87/0.6671	23.11/0.6568
Cauchy	30.75/0.8654	27.28/0.7462	26.60/0.7045	24.28/0.7134
Charbonnier	30.86/0.8702	27.30/0.7474	26.62/0.7051	24.32/0.7181
Euclidean	30.26/0.8492	26.99/0.7365	26.41/0.6963	23.92/0.6935
Fair	30.76/0.8656	27.27/0.7458	26.60/0.7042	24.28/0.7131
Geman	30.80/0.8671	27.30/0.7465	26.61/0.7050	24.29/0.7144
Huber	x4 30.77/0.8659	27.28/0.7460	26.60/0.7045	24.28/0.7134
L1-norm	30.85/0.8697	27.29/0.7471	26.62/0.7048	24.33/0.7177
Logistic	30.27/0.8497	26.98/0.7365	26.40/0.6962	23.92/0.6939
Phuber	30.76/0.8666	27.30/0.7472	26.62/0.7060	24.30/0.7153
Talwar	30.77/0.8668	27.27/0.7466	26.61/0.7054	24.29/0.7146
Tukey	30.77/0.8669	27.28/0.7467	26.61/0.7052	24.28/0.7140
Welsch	30.73/0.8658	27.28/0.7468	26.61/0.7054	24.28/0.7141

4.4.5. Kayıp Fonksiyonlarının Yakınsama Zamanları

Kayıp fonksiyonlarının hesaplama maliyetini analiz etmek için, konvolüsyon filtre boyutları 9-1-5 olan basit ve sığ CNN mimarisi modeli kullanılmıştır. Şekil 4.27, filtre derinliği 64 olduğunda x2, x3 ve x4 büyüme katsayıları üzerinden her kayıp fonksiyonu için yakınsama zamanlarını göstermektedir. Yakınsama süresi 1 ile 20 epoc arasında ölçülmüştür. Saat cinsinden minimum ortalama yakınsama süreleri L1-norm (4,3932), L2-norm (4,7081), Huber (4,7481) ve Charbonnier (4,8849)' dir. En düşük ortalama yakınsama süresi 4,3932 saat ile L1-norm kayıp fonksiyonuna ait olup en verimli olduğu deneysel olarak kanıtlanmıştır.



Şekil 4.27. Kayıp fonksiyonları için yakınsama zamanları

5. BULGULAR VE TARTIŞMA

Bu tez kapsamında, gürültülü ve bulanık düşük çözünürlüklü görüntülerden hem görsel olarak hem de PSNR ve SSIM gibi nesnel matematiksel ölçüm metriklerine göre iyileştirilmiş daha yüksek çözünürlüklü veya kaliteli görüntüler elde edilmesi hedeflenmiştir. Hedefimiz kapsamındaki ilk çalışmada gerçekleştirilen makro bloklara ait dönme parametresinin de kullanıldığı VBS-ME algoritması ile daha büyük bloklar sabit arka planının geniş alanlarında kullanılırken, görüntüdeki daha karmaşık ve ayrıntılı alanlarda daha küçük bloklar kullanılmaktadır. Bu sayede her bloğun boyutu, görüntü içindeki yerel harekete (dönme dahil) uyumlu hale gelerek daha doğru blok hareket tahmini gerçekleştirilmiştir. Deneylerden elde edilen sonuçlara göre evrensel kayıt ile elde edilen SÇ çıktı sonuçları bikübik ara değerlendirme ile büyütülmüş çıktı sonuçlarından daha kötüdür. Gerçeklenen yöntem ise blok tahmininde tam arama yöntemi kullanılarak elde edilen sonuçlara göre PSNR cinsinden ortalama 1,5 dB kadar iyileşme sağlamıştır. Sonuç olarak dönmeli VBS-ME temelli SÇ yöntemi, bikübik ara değerlendirme, evrensel kayıt ve sabit blok boyutlu tam arama ile SÇ yöntemlerine göre daha başarılıdır.

Gradyan büyüklüğünün blok hareket kestirimine dahil edilmesi ile gerçekleştirdiğimiz diğer SÇ yöntemimizde daha iyi sonuç elde edilmesi hedeflenmiş ve bu amaca ulaşılmıştır. Bu çalışma çok sık kullanılan NN ve Lanczos ara değerlendirme yöntemlerini geride bırakmaktadır. Ortalama PSNR sonuçlarına göre önerilen yöntem, NN ara değerlemeden 4 dB, Lanczos ara değerlemeden ise yaklaşık 1,85 dB daha iyi sonuç üretmiştir.

Blok eşleştirme tabanlı yöntemler alt piksel hassasiyetini resmi büyütme katsayısı ile orantılı olarak yapabilmektedir. Ancak gerçekte çok farklı değerlerde alt piksel hareketi olabilmektedir. Kesin bir doğrulukla hareket kestirimine ihtiyaç duyulmadan da SÇ elde edilebildiğini gösteren CVA-tabanlı önerilen diğer SÇ yöntemimizde, gürültü, bulanıklık, resim içi nesnelere birbiri üzerine örtüşmesi vb. nedenlerden dolayı yapılabilecek hareket tahmini hatalarının ortadan kaldırabilmek veya en aza indirebilmek için bir piksele ait komşu piksellerin bilgileri kullanılmıştır. Bu yöntemin sonuçları, NLM-tabanlı, 3DSKR-tabanlı ve VSRnet yöntemleri ile Lanczos gibi yaygın olarak bilinen ara değerlendirme

yöntemlerinin sonuçları ile karşılaştırılmıştır. Deneyler, önerilen yöntemin karşılaştırılan diğer SÇ yöntemlerini hem görsel hem sayısal olarak geride bıraktığını göstermektedir.

Derin ve sığ CNN mimarilerinin kayıp katmanında yapılacak değişimlerin SÇ problemi üzerinde etkilerinin incelendiği son çalışmamızda, sıklıkla kullanılan L2-norm gibi parametrik olmayan kayıp fonksiyonunun, aşırı-uygunluk problemi nedeniyle iyi tahmin yapamadığını söyleyebiliriz. Bunun aksine Huber, Fair ve Geman gibi parametrik kayıp fonksiyonları kalıntıları çok iyi tahmin ederek öğrenme sürecini hızlandırmaktadır. Aşırı-uygunluk problemi, verilerin ortak eğiliminden uzak olan gürültüyü öğrenmesi nedeniyle L2-norm kayıp fonksiyonunda diğerlerine göre daha çok ortaya çıkmaktadır. Ayrıca yapılan testler, Cauchy, Charbonnier, Fair, Geman, Huber, L1-norm, Phuber veya Fair kayıp fonksiyonlarının, SÇ problemi için doğruluk oranlarında test edilen tüm kayıp fonksiyonları arasında daha iyi bir seçim olduğunu göstermektedir. Ayrıca, L1-norm kayıp fonksiyonu, yakınsama süresi ve doğruluk arasındaki dengeleri göz önünde bulundurulduğunda en uygun seçimdir. Gürültülü verilerle çalışırken ve yüksek performans değerleri elde etmek için, diğer tüm kayıp fonksiyonlarının L2-norm kayıp fonksiyonundan daha uygun olduğunu söylemek mümkündür.

6. SONUÇ VE ÖNERİLER

Görüntü iyileştirme, bozulmuş görüntü içeriğinin geri elde edilmesi veya eksik bilgilerin tamamlanmasını hedefleyen önemli görüntü işleme uygulamalarıdır. Son yıllarda süper-çözünürlük konusu artan bir ilgiyle görüntü işleme alanında temel araştırma konusu haline gelmiştir. Sadece yapılan makale sayısının artması ile değil aynı zamanda uygulama alanı olarak da önemli ilerlemeler kaydedilmiştir. Yapılan her çalışma gelecekte insanların veya bilgisayarların görüntü kullanımı, görüntü iyileştirmesi veya geliştirmesinin önemli bir adımı olacaktır.

Görüntü işleme teknikleri ile düşük çözünürlüklü görüntülerdeki bilgiler kullanılarak SÇ görüntü elde etmek mümkündür. Bu amaçla öncelikle blok hareketlerinin belirlenmesinde dönmenin de hesaba katıldığı VBS-ME tekniği ile bir SÇ yöntemi gerçekleştirilmiştir. Sabit boyutlu blok arama tekniklerine göre önemli avantajlara sahip olduğu deneysel olarak gösterilmiştir.

Bir sonraki çalışmamızda sonuç görüntüsü kalitesini arttırabilmek için makro blok hareket kestirimine ve gradyan büyüklüğüne dayanan yeni bir video SÇ yöntemi gerçekleştirilmiştir. Farklı blok tipleri için farklı eşik değerleri kullanılarak SÇ için uygun ve uygun olmayan bloklar ayrılmıştır. Kayıt olan çerçeveleri birleştirme aşamasında doğrudan ortalama almak yerine istatistik tabanlı aykırı piksel ayıklama işlemi gerçekleştirilerek YÇ sonuç resminde bir miktar iyileşme elde edilmiştir. Bu yöntemin performansı hareket tahmininde optiksel akış (yerel, evrensel veya hibrit) vb. yöntemler kullanılarak geliştirilebilir. Bu sayede hesaplama maliyeti de azaltılabilir.

CVA görüntü işlemede kullanılan alt uzay tabanlı örüntü tanıma yöntemidir. CVA-temeline dayanan çalışmamızda referans olarak seçilen bir çerçevedeki her görüntü bloğu için, kendisi ve komşu çerçevelerden birbiri üzerine örtüşen benzer bloklar kullanılarak bir sınıf oluşturulmaktadır. CVA blokların birbiriyle olan ortak ve farklı kısımlarını ayırmaktadır ve bloklardaki enerjinin çoğunun, sınıfın ortak kısmında yoğunlaştığı gerçeğine dayanmaktadır. Bu sayede gürültü azaltma algoritmaları, ortak parçaya müdahale etmeden farklı parçalar üzerinde uygulanabilmektedir. CVA genellikle blokların

üst üste binmesi, geçici gölgelenmeler ve büyük hareketlerden kaynaklanan sorunları en aza indirerek SÇ çıktı görüntüsünde görsel kaliteyi arttırmıştır. Bu yöntem için daha geniş bir arama alanı kullanmak, süper çözümlenmiş görüntüde az da olsa bir iyileşme sağlamıştır. Ancak, çalışma süresi açısından, daha büyük blok boyutu ve arama alanı seçimi olumsuz etkilere neden olmaktadır. Hesaplama süresini yönetmek ve azaltmak için farklı test dizileri için farklı arama alanı boyutları kullanılmıştır. Blok büyüklüğünün, arama penceresi boyutunun veya diğer bazı parametrelerin uyarlanabilir seçimi, gelecekte araştırma konusu olabilir.

Son olarak SISR süper-çözünürlük problemi için derin ve sığ CNN modellerinde kullanılan çeşitli kayıp fonksiyonlarının performansı değerlendirmiştir. Bu amaçla literatürde kullanılan modeller referans olarak alınmıştır. Teknik olarak SGDM optimizasyon yöntemiyle birlikte on iki tane farklı kayıp fonksiyonu seçilmiştir. Ayrıca kayıp fonksiyonlarının yakınsama zamanları da değerlendirilmiştir. Farklı CNN mimarilerinin kayıp katmanında yapılacak değişimlerin SÇ problemi üzerinde etkilerinin incelendiği bu çalışmamızdaki deneysel sonuçlar, uygun hiper parametrelerin ayarlanmasıyla bazı kayıp fonksiyonlarının daha iyi yakınsama gösterdiğini ortaya koymaktadır. Deneylemlerden çıkartılacak bir başka sonuç ise, filtrelerin derinliğinin artırılmasının performans üzerinde az da olsa bir iyileşmeye neden olmasıdır. Bununla birlikte, katman sayısı, elde edilen PSNR/SSIM sonuçları üzerinde oldukça iyi bir etkiye sahiptir.

Gözetleme sistemleri, otomotiv endüstrisi, elektronik, uzaktan algılama ya da tıbbi görüntü analizi gibi alanlarda en az maliyetli süper-çözünürlük ihtiyacı giderek artmaktadır. Mobil cihazların da ortaya çıkması ve genellikle her alanda kullanılması, daha hızlı ve kullanımı kolay yöntemler için verimli bir uygulama ortamı sunmaktadır. Görüntü iyileştirme için mobil ortamdaki uygulamaların yaygınlaşması kaçınılmazdır. Gelecekte savuma cihazlarında kullanılan görüntüleme cihazlarında, İHA' ların çekmiş olduğu uzak yeryüzü görüntülerinde veya tıbbi görüntüleme gibi farklı alanlarda çalışma yapılması planlanmaktadır.

KAYNAKLAR DİZİNİ

- Ajit, R., Anand, R., Arunava, B., 2013, Image denoising using the higher order singular value decomposition. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 35(4), p. 849-862.
- Albanie, S., 2017, Robust regression loss functions, <https://github.com/albanie/mcnRobustLoss>, erişim tarihi: 30.05.2018.
- Albu F., 2016, Low complexity image registration techniques based on integral projections', 2016 International Conference on Systems, Signals and Image Processing (IWSSIP), Bratislava, Slovakia, p. 1-4.
- Al-Najjar, Y. A. Y., Soong, D.D.C., 2012, Comparison of image quality assessment: Psnr, hvs, ssim, uqi., *Int. Journal of Scientific and Engineering Research*, 3(8), p. 1-5.
- Anagün, Y., Seke, E., 2012, Super Resolution Using Variable Size Block-Matching Motion Estimation With Rotation, International Conference on Innovations in Intelligent Systems and Applications (INISTA), Trabzon, Turkey.
- Anagün, Y., Seke, E., Adar, N., 2015, Video super-resolution based on block motion estimation and gradient magnitude, International Conference on Innovations in Intelligent Systems and Applications (INISTA), Madrid, Spain.
- Bergen, J. R., Anandan, P., Hanna, K. J., Hingorani, R., 1992, Hierarchical model-based motion estimation, *Proc. Second European Conference on Computer Vision, Lecture Notes in Computer Science*, p. 237-252.
- Bevilacqua, M., Roumy, A., Guillemot, C., Alberi-Morel, M.L., 2012, Low-complexity single-image super-resolution based on nonnegative neighbor embedding, Guildford, Surrey, United Kingdom.
- Borman, S., Robertson M. A., Stevenson R. L., 1999, Block-matching sub-pixel motion estimation from noisy, under-sampled frames - An empirical performance evaluation, In: *Visual Communication Image Processing, San Jose, USA*, vol. 3653, p. 1442-1451.
- Borman, S., Stevenson, R. L., 1998, Super-resolution from image sequences - A review, In: *Midwest Symposium on Circuits and Systems, Notre Dame, USA*, p. 374-378.

KAYNAKLAR DİZİNİ (devam)

- Brox, T., Bruhn, A., Papenberg, N., Weickert, J., 2004, High accuracy optical flow estimation based on a theory for warping, in: Proc. 8th European Conference on Computer Vision, vol. 4, Prague, Czech Republic, p. 25-36.
- Buades, A., Coll, B., 2005, A non-local algorithm for image denoising, in CVPR.
- Capel, D., Zisserman, A., 2003, Computer vision applied to super resolution, IEEE Signal Processing Magazine, vol. 20, no. 3, p. 75-86.
- Cheng, M. H., Chen, H. Y., Leou, J. J., 2011, Video super resolution reconstruction using a mobile search strategy and adaptive patch size, Signal Processing, 91 (5), p. 1284-1297.
- Çevikalp, H., Neamtu, M., Wilkes, M., Barkana, A., 2005, Discriminative common vectors for face recognition, IEEE Trans. Pat. Analysis and Machine Intell., 27(1), p. 4-13.
- Demirel, H., Izadpanahi, S., Ozcinar, C., Anbarjafari, G., 2011, Video resolution enhancement by using complex wavelet transform, in: Proceedings of the IEEE International Conference on Image Processing (ICIP-2011), Brussels, Belgium.
- Dong, C., Loy, C. C., He, K., Tang, X., 2014, Learning a deep convolutional network for image super-resolution, Proc. IEEE European Conf. Computer Vision, Zurich, Switzerland, p. 184-199.
- Donoho, D.L., Johnstone, I.M., 1994, Ideal spatial adaptation via wavelet shrinkage, Biometrika, 81, p. 425-455.
- Drulea M., Nedevschi S., 2011, Total variation regularization of localglobal optical flow, in Proc. IEEE Conf. Intell. Transp. Syst. (ITSC), p. 318-323.
- Farsiu, S., Robinson, M. D., Elad, M., Milanfar, P., 2004, Fast and robust multiframe super resolution”, IEEE Transactions on Image Processing, vol. 13, no. 10, p. 1327-1344.
- Fischler, M. A., Bolles, R. C., 1981, Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography, Communications of the ACM, vol. 24, no. 6, p. 381-395.
- Gao, X., Kaibing, Z., Dacheng, T., Li, X., 2012, Image super-resolution with sparse neighbor embedding, IEEE Trans. Image Processing, 21(7), p. 3194-3205.

KAYNAKLAR DİZİNİ (devam)

- Gulmezoglu, M.B., Barkana, A., 1998, Text-dependent speaker recognition by using Gram-Schmidt orthogonalization method, Proc. IASTED Int. Conf. Signal Processing and Applications, Canary Islands, Spain, p. 438-440.
- Gulmezoglu, M.B., Dzhafarov, V., Barkana, A., 2001, The common vector approach and its relation to principal component analysis, IEEE Trans. on Speech and Audio Processing, 9(6), p. 655-662.
- Gulmezoglu, M.B., Dzhafarov, V., Edizkan, R., Barkana A., 2007, The common vector approach and its comparison with other subspace methods in case of sufficient data, Computer Speech & Language, 21(2), p. 266-281.
- Gulmezoglu, M.B., Dzhafarov, V., Keskin, M., Barkana A., 1999, A novel approach to isolated word recognition, IEEE Trans. Speech and Audio Processing, 7(6), p. 620-628.
- Gulmezoglu, M.B., Ergin, S., 2007, An approach for bearing fault detection in electrical motors, European Trans. Electrical Power, 17(6), p. 628-641.
- Guo, K., Yang, X., Lin, W., Zhang, R., Yu, S., 2012, Learning-based super-resolution method with a combining of both global and local constraints, IET Image Processing, 6(4), p. 337-344.
- He, K., Zhang, X., Ren, S., Sun, J., 2016, Deep residual learning for image recognition, IEEE Conf. on Comp. Vision and Pattern Recog., Las Vegas, USA, p. 770-778.
- Horn, B., Schunck, B., Determining optical flow, Artificial Intelligence, 17, p. 185-203, 1981.
- Huang, J.-B., Singh, A., Ahuja, N., 2015, Single image super-resolution from transformed self-exemplars, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, p. 5197-5206.
- Irani, M., Rousso, B., Peleg, S., 1994, Computing occluding and transparent motions, International Journal of Computer Vision, vol. 12, no. 1, p. 5-16.
- Janocha, K., Czarnecki, W.M., 2017, On loss functions for deep neural networks in classification, arXiv preprint arXiv:1702.05659.

KAYNAKLAR DİZİNİ (devam)

- Ji, H., Fermuller, C., 2009, Robust wavelet-based super-resolution reconstruction: Theory and algorithm, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 31, no. 4, p. 649-660.
- Kang, L. W., Hsu, C. C., Zhuang, B., Lin, C., Yeh, C., 2015, Learning-based joint super-resolution and deblocking for a highly compressed image, *IEEE Trans. on Image Processing*, 17(7), p. 921-934.
- Kappeler, A., Yoo, S., Dai, Q., Katsaggelos, A. K., 2016, Video super-resolution with convolutional neural networks, *IEEE Trans. on Computational Imaging*, 2(2), p. 109-122.
- Kaveh, A., Ezzatollah, S., 2017, Single-image super resolution using evolutionary sparse coding technique, *IET Image Processing*, 11(1), p. 13-21.
- Keren, D., Peleg, S., Brada, R., 1988, Image sequence enhancement using sub-pixel displacement, in *Proceedings IEEE Conference on Computer Vision and Pattern Recognition*, p. 742-746.
- Kim, S. P., Su, W.-Y., 1993, Subpixel accuracy image registration by spectrum cancellation, *IEEE International Conference on Acoustics, Speech, and Signal Processing. (ICASSP)*, Minneapolis, USA, vol. 5, p. 153-156.
- Kumar, N., Amit, S., 2016, Fast learning-based single image super-resolution, *IEEE Trans. Multimedia*, 18(8), p. 1504-1515.
- Landgrebe, D.A., 2002, Hyperspectral image data analysis, *IEEE Signal Processing Magazine*, 19(1), p. 17-28.
- Li, X., Orchard, M., 2001, New edge-directed interpolation, *IEEE Trans. Image Process.* 10 (10), p. 1521-1527.
- Liu, H. C., Feng, Y., Sun, G. Y., 2006, Wavelet Domain Image Super Resolution Reconstruction Based on Image Pyramids and Cycle Spinning, *Journal of Physics: Conference Series*, vol. 48, p. 4117-4121.
- Liu, C., Sun, D., 2014, On bayesian adaptive video super Resolution, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 36 (2), p. 346-360.

KAYNAKLAR DİZİNİ (devam)

- Lucas, B., Kanade, T., 1981, An iterative image registration technique with an application to stereo vision, in: Proc. Seventh International Joint Conference on Artificial Intelligence, Vancouver, Canada, p. 674-679.
- Lucchese, L., Cortelazzo, G. M., 2000, A noise-robust frequency domain technique for estimating planar roto-translations, *IEEE Transactions on Signal Processing*, vol. 48, no. 6, p. 1769-1786.
- Marcel, B., Briot, M., Murrieta, R., 1997, Calcul de translation et rotation par la transformation de Fourier, *Traitement du Signal*, vol. 14, no. 2, p. 135-149.
- Martin, D., Fowlkes C., Tal D., Malik J., 2001, A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics, *Proceedings Eighth IEEE Int. Conf. on Comp. Vision, ICCV 2001*, Vancouver, BC, Canada, p. 416-423.
- Mousavi, H.S., Monga, V., 2017, Sparsity-based color image super resolution via exploiting cross channel constraints, *IEEE Trans. Image Processing*, 26(11), p. 5094-5106.
- Oja, E., 1983, *Subspace Methods of Pattern Recognition*, Research Studies Press, New York, Wiley.
- Ouyang, K., Shen, G., Li, S., Gu, M., 2005, Advanced Motion Search and Adaptation Techniques for Deinterlacing, *ICME*, p. 374-377.
- Özkan, K., Seke, E., 2015, Image denoising using common vector approach, *IET Imag. Process.*, 9(8), p. 709-715.
- Park, S. C., Park, M. K., Kang, M. C., 2003, Superresolution Image Reconstruction: A Technical Overview, *IEEE Signal Processing Magazine*, p. 21-34.
- Patti, A. J., Sezan, M. I., Tekalp, A. M., 1997, Superresolution video reconstruction with arbitrary sampling lattices and nonzero aperture time, *IEEE Transactions on Image Processing*, vol. 6, no. 8, p. 1064-1076.
- Protter, M., Elad, M., Takeda, H., Milanfar, P., 2009, Generalizing the non- local-means to super-resolution reconstruction, *IEEE Transactions on Image Processing*, 18 (1), p. 36-51.

KAYNAKLAR DİZİNİ (devam)

- Rudin, L., Osher, S., Fatemi, E., 1992, Nonlinear total variation based noise removal algorithms, *Phys. D*, vol. 60, p. 259-268.
- Sanchez-Beato, A., Pajares, G., 2008, Noniterative interpolation-based super-resolution minimizing aliasing in the reconstructed image, *IEEE Trans. Image Process.*, vol. 17, no. 10, p. 1817-1826.
- Schultz, R. R., Meng, L., Stevenson, R. L., 1998, Subpixel motion estimation for super-resolution image sequence enhancement, *Journal of Visual Communication and Image Representation*, vol. 9, no. 1, p. 38-50.
- Seke, E., Anagün, Y., Adar, N., 2018, Multi-frame super-resolution algorithm using common vector approach, *IET Image Processing*, doi: 10.1049/iet-ipr.2018.5168 (in press).
- Stiller, C., Konrad, J., 1999, Estimating motion in image sequences - a tutorial on modeling and computation of 2d motion, *IEEE Signal Processing Magazine*, 16 (4), p. 70-91.
- Stone, H. S., Orchard, M. T., Chang, E.-C., Martucci, S. A., 2001, A fast direct Fourier-based algorithm for subpixel registration of images, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 10, p. 2235-2243.
- Su, H., Tang, L., Wu, Y., Tretter, D., Zhou, J., 2012, Spatially adaptive block-based super-resolution, *IEEE Trans. Image Process.*, vol. 21, no. 3, p. 1031-1045.
- Takeda, H., Milanfar, P., Protter, M., Elad, M., 2009, Super-resolution without explicit subpixel motion estimation, *IEEE Transactions on Image Processing*, 18 (9), p. 1958-1975.
- Tsai, R.Y., Huang, T.S., 1984, Multipleframe image restoration and registration, in *Advances in Computer Vision and Image Processing*. Greenwich, CT:JAI Press Inc., p. 317-339.
- Turkowsky, K., 1990, Filters for common resampling tasks, in *Graphics Gems*. New York: Academic.
- Vandewalle, P., Süsstrunk, S.E., Vetterli, M., 2006, A frequency domain approach to registration of aliased images with application to super-resolution, *EURASIP J. Adv. Signal Process.*, 2006, p. 1-14.

KAYNAKLAR DİZİNİ (devam)

- Vedaldi, A., Lenc, K., 2015, Matconvnet: Convolutional neural networks for matlab, Proceedings of the 23rd ACM Int. Conf. on Multimedia, ACM2015, p. 689-692.
- Wang, Z., Bovik, A. C., Sheikh, H. R., Simoncelli, E. P., 2004, Image quality assessment: from error visibility to structural similarity, *IEEE Trans. Image Process.*, vol. 13(4), p. 1-14.
- Wang, Q., Ward, R. K., 2007, A new orientation adaptive interpolation method, *IEEE Trans. Image Process.* 16 (4), p. 889-900.
- Wang, Y., Zhang, Y., Ostermann, J., 2001, *Video Processing and Com.*, (Prentice Hall, Upper Saddle River, NJ., 2001).
- Wen, C.K., Chen, J.C., Ting, P., 2013, A shrinkage linear minimum mean square error estimator, *IEEE Signal Processing Letters*, 20 (12), p. 1179-1182.
- Wolberg, G., 1990, *Digital image warping*, Washington, DC: IEEE Computer Soc. Press.
- Zeyde, R., Elad, M., Protter, M., 2010, On single image scale-up using sparse-representations, *Int. conference on curves and surfaces*, Springer, p. 711-730.
- Zhang, H., Zhang, L., Shen, H., 2012, A super resolution algorithm for hyperspectral images, *Signal Processing*, 92 (9), p. 2082-2096.
- Zhang, L., Zhang, H., Shen, H., Li, P., 2010, "A super resolution algorithm for surveillance images", *Signal Processing*, 90 (3), p. 848-859.
- Zitova, B., Flusser, J., 2003, Image registration methods: A survey, *Image and Vision Computing*, 22, p. 977-1000.
- Zomet A., Rav-Acha, A., Peleg, S., 2001, Robust super-resolution, In *Proceedings International Conference on Computer Vision and Pattern Recognition (CVPR)*.

ÖZGEÇMİŞ

1980 yılında Eskişehir’de doğan Yıldıray Anagün, ilköğrenimini Diyarbakır Mehmet Sabri Güzel İlkokulunda, orta öğrenimini İzmir Sabiha Gökçen Ortaokulunda ve lise öğrenimini Eskişehir Motor Anadolu Teknik Lisesinde tamamladıktan sonra 2003 yılında Çankaya Üniversitesi Bilgisayar Mühendisliği Bölümü’nden mezun olmuştur. 2004 yılında Kütahya Dumlupınar Üniversitesi Bilgisayar Mühendisliği Bölümü’nde araştırma görevlisi olarak akademik hayata başlamış olup, yüksek lisans derecesini 2007 yılında Kütahya Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Anabilim Dalı’ndan almıştır. 2008 yılından bu yana Eskişehir Osmangazi Üniversitesi Bilgisayar Mühendisliği Bölümünde Öğretim Görevlisi olarak görevini sürdürmektedir.