

Bozuk Görüntülerin İyileştirilmesinde Ortak Vektör Yaklaşımının Kullanılması

Hasan Başar Kalyoncu

DOKTORA TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Aralık 2018



The Use of Common Vector Approach in Image Denoising

Hasan Bařar Kalyoncu

DOCTORAL DISSERTATION

Department of Electrical and Electronics Engineering

December 2018

Bozuk Görüntülerin İyileştirilmesinde Ortak Vektör Yaklaşımının Kullanılması

Hasan Başar Kalyoncu

Eskişehir Osmangazi Üniversitesi

Fen Bilimleri Enstitüsü

Lisansüstü Yönetmeliği Uyarınca

Elektrik Elektronik Mühendisliği Anabilim Dalı

Telekomünikasyon - Sinyal İşleme Bilim Dalında

DOKTORA TEZİ

Olarak Hazırlanmıştır

Danışman: Prof. Dr. Mehmet Bilginer Gülmezoğlu

Aralık 2018

ONAY

Elektrik - Elektronik Mühendisliđi Anabilim Dalı Doktora öđrencisi Hasan Bařar Kalyoncu'nun DOKTORA tezi olarak hazırladıđı "Bozuk Görüntülerin İyileřtirilmesinde Ortak Vektör Yaklařımının Kullanılması" bařlıklı bu alıřma, jürimizce lisansüstü yönetmeliđin ilgili maddeleri uyarınca deđerlendirilerek oybirliđi ile kabul edilmiřtir.

Danıřman : Prof. Dr. Mehmet Bilginer Gülmezođlu

İkinci Danıřman : -

Doktora Tez Savunma Jürisi:

Üye : Prof. Dr. Mehmet Bilginer Gülmezođlu

Üye : Do. Dr. Semih Ergin

Üye : Dr. Öğr. Üyesi Muammer Akay

Üye : Dr. Öğr. Üyesi Erol Seke

Üye : Dr. Öğr. Üyesi İdil Iřıklı Esener

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

Prof. Dr. Hürriyet ERŐAHAN
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Mehmet Bilginer Gülmezođlu danışmanlığında hazırlamış olduğum Bozuk Görüntülerin İyileştirilmesinde Ortak Vektör Yaklaşımının Kullanılması 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 çalışmamada yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 17.12.2018

Hasan Başar Kalyoncu

İmza

ÖZET

Bu tezde, bir görüntünün gürültülü bloklarını belirlemek için Ortak Vektör Yaklaşımına dayalı yeni bir yöntem önerilmiştir. Herhangi bir görüntünün bloklarının gürültülü veya temiz olarak sınıflandırılması için kullanılan bir eşik değeri, o görüntünün temiz örneklerinden oluşan referans veri setine Ortak Vektör Yaklaşımının uygulanmasıyla belirlenmiştir. Bu çalışmada kullanılan gürültü tipi, sıfır ortalama değerinde “Gauss” gürültüsüdür. Herhangi bir görüntünün blok tabanlı olarak gürültülü veya temiz olarak sınıflandırılmasıyla, tüm görüntüyü temizleme işlemine sokmak yerine, sadece gürültülü blokları temizleme işlemine sokmak mümkün olacaktır. Deneysel çalışmalar, önerilen yöntemin bir görüntünün bloklarının gürültülü veya temiz olarak sınıflandırılmasında çok başarılı olduğunu göstermektedir. 8x8 blok boyutlu test görüntülerinde 30-32 dB ve 12x12 ve 16x16 blok boyutlu test görüntülerinde 30-31 dB hariç olmak üzere, tüm PSNR (peak signal to noise ratio) değerleri için yaklaşık %100 sınıflandırma sonuçları elde edilmiştir. Son olarak, popüler görüntü temizleme algoritmaları gürültülü görüntülere uygulanmış ve bu algoritmaların sonuçları karşılaştırılmıştır. Temizleme işlemine sokulan gürültülü görüntülerin etkin bir şekilde temizlendiği görülmüştür; başka bir deyişle, gürültülü görüntülerin PSNR değerleri kayda değer ölçüde artmıştır.

Anahtar kelimeler: Ortak Vektör Yaklaşımı, “Gauss” gürültüsü, PSNR, gürültülü/temiz görüntü sınıflandırma, görüntü temizleme

SUMMARY

In this thesis, a novel method depending on the common vector approach is proposed to determine noisy blocks of an image. A threshold value for noisy/clean classification of the blocks of any image is determined by applying the common vector approach to the reference data set consisting of the clean samples of that image. The noise addressed in this paper is Gaussian noise with zero mean. By making a block based noisy/clean classification of any image; it is possible to expose only the noisy blocks into the denoising process, rather than subjecting the entire image to denoising. The results indicate that the proposed method is very successful for noisy/clean classification of the noisy blocks of an image. Approximately 100% classification results for all PSNR (peak signal to noise ratio) values except 30-32 dB for 8x8 block sized test images and except 30-31 dB for both 12x12 and 16x16 block sized test images are obtained. Finally, popular image denoising algorithms are applied to the noisy images and the results of these algorithms are compared. It is observed that the PSNR values of noisy images are appreciably increased.

Keywords: Common Vector Approach, Gaussian noise, PSNR, noisy/clean image classification, image denoising

TEŐEKKÜR

Bu alıőmanın gerekleőtirilmesinde; teknik desteklerini veren tez danıőmanım Prof. Dr. Mehmet Bilginer Gölmezođlu'na ve tez izleme komitesi üyesi Do. Dr. Semih Ergin'e, her türlü desteklerini hep hissettiđim aileme ve dostlarıma teőekkür ederim.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	4
2.1. Giriş	4
2.2. Gürültü Çeşitleri	5
2.2.1. “Gauss” gürültü modeli	5
2.2.2. Beyaz gürültü modeli	7
2.2.3. Tuz ve biber gürültü modeli	7
2.2.4. “Speckle” gürültü modeli	8
2.2.5. “Poisson (foton)” gürültü modeli	9
2.2.6. Periyodik gürültü modeli	10
2.2.7. Niceleme (quantization) gürültüsü	12
2.3. Gürültü Seviyesi Belirleme Yöntemleri	13
2.3.1. Blok tabanlı gürültü seviyesi belirleme yöntemleri	14
2.3.2. Filtreleme tabanlı gürültü seviyesi belirleme yöntemleri	16
2.3.3. Dönüşüm tabanlı (transform based) gürültü seviyesi belirleme yöntemleri ...	18
3. TEORİK BİLGİ	19
3.1. Ortak Vektör Yaklaşımı (OVY)	19
4. MATERYAL VE YÖNTEM	21
4.1. Önerilen Yöntem	21
4.1.1. Görüntünün temiz örneklerinden eğitim setinin oluşturulması	21
4.1.2. OVY kullanarak eşik değerinin belirlenmesi	22
4.1.3. PSNR değeri bilinmeyen görüntülerin test edilmesi	25
5. BULGULAR VE TARTIŞMA	27
5.1. Standart Test Görüntüleriyle Yapılan Deneysel Çalışmalar	27

İÇİNDEKİLER (devam)

Sayfa

5.2. Eğitim Setinde Çoklu Sayıda Görüntü Kullanılarak Yapılan Deneysel Çalışma	35
5.3. “Lenna” Görüntüsünün Döndürülmüş Örnekleriyle Yapılan Deneysel Çalışmalar	38
5.4. Görüntü Temizleme İşlemi	41
5.3.1. Medyan filtreleme.....	41
5.3.2. “Wiener” filtreleme	41
5.3.3. “Bilateral” filtreleme	42
5.3.4. Non-local means (NLM) filtreleme	43
5.3.5. Principal Component Analysis (PCA) ve lokal pixel grouping (LPG) ile filtreleme.....	44
5.3.6. Temizleme sonuçları.....	45
6. SONUÇ VE ÖNERİLER	51
KAYNAKLAR DİZİNİ.....	53
EK AÇIKLAMALAR	57
Ek Açıklama-A: Özvektörlerin Bulunmasına Yönelik Kaynak Kod.....	58
Ek Açıklama-B: Ortak Vektörlerin Bulunmasına Yönelik Kaynak Kod	59
Ek Açıklama-C: Eşik Değerlerinin Bulunmasına Yönelik Kaynak Kod.....	60
Ek Açıklama-D: Bir Görüntünün Bloklarının Test Edilmesine Yönelik Kaynak Kod .	62
ÖZGEÇMİŞ	63

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
2.1. “Gauss” Olasılık Dağılım Fonksiyonu	6
2.2. “San-Francisco” görüntüleri	6
2.3. Olasılık değeri 0.05 olan tuz biber gürültüsü eklenmiş “San Francisco” görüntüsü	8
2.4. Varyansı 0.04 olan “Speckle” gürültülü “Lenna” görüntüsü	9
2.5. “Poisson” gürültülü “San-Francisco” görüntüsü	10
2.6. Periyodik gürültülü “Lenna” görüntüsü	11
2.7. Düzgün dağılımlı olasılık yoğunluk fonksiyonu	12
2.8. (3x3) boyutundaki görüntü blokları için yüksek-geçirgen operatörler.....	15
4.1. Önerilen yöntemin akış şeması.....	21
4.2. Eşik değerlerinin OVY kullanılarak belirlenmesine dair akış şeması.....	25
5.1. Deneysel çalışmalarda kullanılan görüntüler:	28
5.2. Test edilen “Lenna” görüntüsünün farklı PSNR değerlerindeki örnekleri:.....	32
5.3. Test edilen “Barbara” görüntüsünün farklı PSNR değerlerindeki örnekleri:	32
5.4. Test edilen “Peppers” görüntüsünün farklı PSNR değerlerindeki örnekleri:.....	33
5.5. Test edilen “Zelda” görüntüsünün farklı PSNR değerlerindeki örnekleri:.....	33
5.6. Test edilen “Baboon” görüntüsünün farklı PSNR değerlerindeki örnekleri:	34
5.7. Gürültülü blokları gösteren “Peppers” görüntüleri:.....	35
5.8. Eğitim setinde kullanılan görüntüler ve PSNR değerleri:	36
5.9. Farklı açılarda döndürülmüş Lenna görüntüleri:	39
5.10. PCA-LPG gürültü temizleme şeması	45
5.11. Beş farklı yöntemle temizlenen “Lenna” görüntüleri:.....	46
5.12. Beş farklı yöntemle temizlenen “Lenna” görüntüleri:.....	47
5.13. Beş farklı yöntemle temizlenen “Lenna” görüntüleri:.....	48
5.14. Beş farklı yöntemle temizlenen “Lenna” görüntüleri:.....	49

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
5.1. Eğitim setinde kullanılan görüntülerin PSNR değerleri	29
5.2. (8x8) boyutlu görüntü bloklarının sınıflandırma sonuçları	30
5.3. (12x12) boyutlu görüntü bloklarının sınıflandırma sonuçları	30
5.4. (16x16) boyutlu görüntü bloklarının sınıflandırma sonuçları	31
5.5. Önerilen yöntemin test bloğuna doğrudan uygulanması sonucu elde edilen sınıflandırma sonuçları	37
5.6. Test bloğunun en benzer olduğu “Lenna” görüntü bloğunun belirlenmesi sonrası elde edilen sınıflandırma sonuçları	37
5.7. Test bloğunun en benzer olduğu ortalama vektörünün belirlenmesi sonrası elde edilen sınıflandırma sonuçları	38
5.8. Döndürülmüş “Lenna” görüntülerinden oluşan gruplar	39
5.9. Farklı açılarda döndürülmüş “Lenna” görüntülerinin sınıflandırma sonuçları	40
5.10. Temizleme yöntemlerinin sonuçları	45
5.11. Farklı boyutlardaki görüntü bloklarının sınıflandırmasında geçen süre.....	50
5.12. Blok tabanlı ve tüm görüntünün temizlenmesinde geçen süre (saniye)	50
5.13. Görüntü temizleme sonrası PSNR karşılaştırması (PSNR birimi = dB)	50

SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler</u>	<u>Açıklama</u>
σ	Standart Sapma
μ	Ortalama Değer
Pr	Olasılık
φ	Kovaryans Matrisi

<u>Kısaltmalar</u>	<u>Açıklama</u>
ADC	Analog to Digital Conversion
CCD	Charge Coupled Device
LPG	Local Pixel Grouping
MSE	Mean Squared Error
NLM	Non Local Means
OVY	Ortak Vektör Yaklaşımı
PCA	Principal Component Analysis
PSNR	Peak Signal to Noise Ratio
SGO	Sinyal Gürültü Oranı
SNR	Signal to Noise Ratio
SSIM	Structural Similarity Index Measure

1. GİRİŞ VE AMAÇ

İnternetin yaygın bir şekilde kullanılmaya başlanması ile birlikte bilgiyi yayma ve bilgiye ulaşma oldukça kolaylaşmıştır. Çoğunlukla görsel olarak yayılan bu bilgi; resim, metin ve video gibi biçimlerde sunulmaktadır. Resim ve videonun, bilgisayar ortamında işlenebilecek şekilde mantıksal 0 ve 1'lerden oluşan sayısal veri biçimine çevrilmiş haline sayısal görüntü adı verilmektedir (Bovik, 2010). M satır ve N sütundan oluşan bir sayısal görüntü, $f(x, y)$ şeklinde iki boyutlu bir fonksiyon olarak tanımlanabilir. Tamsayı olan x ve y , sırasıyla görüntünün satırları ve sütunları boyunca uzaysal koordinatları temsil ederken, f fonksiyonunun büyüklüğü de görüntünün o koordinatlardaki ton değerini temsil etmektedir (Gonzalez ve Woods, 2009).

Sayısal görüntü işleme, temel olarak, iki boyutlu bir görüntünün bilgisayar teknolojilerinin kullanımıyla işlenmesi olarak tanımlanır. Bu işlemin amacı, üzerinde çalışılan görüntüden algılanan kaliteden daha iyi bir kalitede görüntü elde etmek veya ondan bazı faydalı bilgileri ortaya çıkarmaktır. Görüntü işleme, aşağıdaki adımları içerir (Dewangan, 2016).

- Görüntüyü elde etme
- Ön işlemler
- Ayırt edici özellikler çıkarma veya görüntü üzerinde değişiklikler yapma
- İşlemden geçirilen görüntünün veya özelliklerinin çıktı olarak verilmesi

Görüntü; fotoğraf makinesi, video ve tarayıcı gibi cihazlarla elde edilip işleneceği bilgisayar ortamına girildiği olarak verilir. Elde edilen görüntünün verimli bir şekilde işlenebilmesi için, görüntü boyutunun değiştirilmesi, istenmeyen bozulmaların giderilmesi, küçük parçalara ayrılması ve başka bir formata çevrilmesi gibi ön işlemler gerçekleştirilir. İşlenmeye hazır hale getirilmiş görüntüye, uygulamanın niteliğine göre görüntü işleme teknikleri uygulanır ve son olarak, elde edilen çıktılar değerlendirilir. Başlıca görüntü işleme

teknikleri; görüntü iyileştirme, görüntü restorasyonu, görüntü sıkıştırma ve görüntü algılama olarak tanımlanır.

Görüntü iyileştirmenin temel hedefi belirsiz olan bazı ayrıntıların ortaya çıkartılması veya belli özelliklerin daha görünür hale getirilmesidir. Görüntü restorasyonu da görüntü iyileştirme gibi görüntü kalitesinin artırılmasına yönelik olsa da, görüntü iyileştirmedeki öznel algının yeterli bulunması görüntü restorasyonunda geçerli değildir. Gerçekleştirilen restorasyonun, görüntü bozulmasının matematiksel ve olasılık modellerine dayanıyor olması gerekir. Görüntü sıkıştırma, bir görüntünün veri kaybı olmaksızın olabildiğince az bit sayısı ile saklanmasını sağlama ve böylece iletimini hızlandırma amaçlarını güder. Görüntü algılama da, bir görüntü içerisinde belirli objelerin varlığının veya yokluğunun belirlenmesi olarak tanımlanır (Gonzalez ve Woods, 2009; Bovik, 2010; Pratt, 2001).

Günümüzde, sayısal görüntü işleme en başta bilgisayar bilimleri olmak üzere mühendislik alanlarında yaygın olarak kullanılmaktadır ve kullanım alanı her geçen gün genişlemektedir. Günlük hayatta karşılaşılan birçok probleme görüntü işleme teknikleri kullanılarak çözüm oluşturulmaktadır. Görüntü işleme alanındaki önemli uygulamalardan bazıları; uzaktan algılama, yüz tanıma, parmak izi tanıma, biyomedikal görüntü iyileştirme ve analizi, sahte resimleri ayırt etme, video analizi, hareket takibi, hedef tayini, 2 boyutlu görüntülerden 3 boyutlu görüntüler oluşturma, karakter tanıma, yapay zeka ve arttırılmış gerçeklik ve trafik sistemleri olarak sıralanabilir.

Görüntü işleme uygulamalarının hayatın birçok alanına girmesiyle birlikte görüntü kalitesinin ve görüntüyü işleme hızının önemi artmıştır. Görüntü içindeki istenmeyen bilgi olarak tanımlanan gürültü, iletişim kanallarındaki girişimlerden görüntünün elde edilmesinde kullanılan sensör teknolojisine kadar birçok farklı sebepten oluşabilir. Üzerinde çalışılan görüntünün gürültüden ve bozulmalardan arındırılmış olması görüntü işleme tekniklerinin etkili bir şekilde uygulanabilmesi için gereklidir. Herhangi bir görüntüdeki gürültü seviyesinin ve özelliklerinin bilinmesi etkili bir görüntü temizleme için gereklidir. Konunun öneminden dolayı, görüntüdeki gürültü seviyesinin ve özelliklerinin belirlenmesi ve görüntünün gürültüden temizlenmesi konularında oldukça fazla çalışma yapılmıştır.

Bu tezde, görüntünün gürültülü bloklarının belirlenmesi için Ortak Vektör yaklaşımına (OVY) dayalı yeni bir yöntem önerilmektedir. OVY; bir sınıfa dahil olan tüm vektörlerin belirgin veya değişmez özelliklerini içeren ve tek olan bir ortak vektörün belirlenmesine dayalı bir alt uzay yöntemidir. Önerilen yöntem, görüntülerin temiz/gürültülü olarak sınıflandırılmasında OVY'nin sınıflandırma kabiliyetinin kullanılmasını kapsamaktadır. Bir görüntünün, belli sayıda temiz örneği varsa, o görüntünün bilinmeyen bir örneğinin gürültülü veya temiz olarak blok bazında sınıflandırılabileceği gösterilmektedir. Bir görüntünün temiz örneklerinden bir eğitim seti oluşturulur ve eğitim setindeki her görüntü, görüntünün tamamını kapsayacak şekilde eşit boyutlarda bloklara bölünür. Her bir görüntü bloğu için bir eşik değeri, OVY'nin uygulanması ile bulunur ve bu eşik değeri, içindeki gürültü miktarı bilinmeyen bir görüntünün bloklarının gürültülü/temiz ayrımında kullanılır. Bu tür bir gürültülü/temiz sınıflandırma sonucunda, sadece gürültülü görüntü blokları görüntü temizleme işlemine sokularak, görüntü temizleme süresi hızlandırılmış ve ayrıca görüntüdeki ince detay ve dokuların kaybolmasının önüne geçilmiş olunur.

Önerilen yöntemin uygulanması sonucunda gürültülü olarak belirlenen görüntülere literatürde sıklıkla kullanılan “Median”, “Wiener”, “Bilateral”, “Non-Local Means (NLM)” ve “Principal Component Analysis (PCA) with local pixel grouping (LPG)” temizleme algoritmaları uygulanmış ve bu temizleme algoritmalarının performansları, görüntülerin temizleme işlemine sokulmadan önceki ve temizleme işleminden geçirildikten sonraki “peak signal to noise ratio (PSNR)” değerleri kullanılarak karşılaştırılmıştır.

Görüntülerde çoğunlukla oluşan gürültü, tüm bant aralığında düzgün dağılımlı enerji seviyesine sahip olup “Gauss” olasılık dağılımına sahiptir (Krishnan ve Viswanathan, 2013). Görüntülerin doğrudan uydu kanallarından iletilmesiyle birlikte görüntülerin üzerine “Gauss” gürültüsü binmekte ve bozulmalar oluşmaktadır (Bystrom ve Modestino, 2000). Bu tezin deneysel çalışmalarında ve gürültü temizleme aşamalarında “Gauss” gürültüsü içeren standart “Lenna”, “Barbara”, “Baboon”, “Zelda” ve “Peppers” görüntüleri kullanılmıştır.

2. LİTERATÜR ARAŞTIRMASI

2.1. Giriş

Gürültü çeşitlerini incelemeye geçmeden önce, “gürültü nedir?” sorusunun cevaplanması önemlidir. Gürültü, görüntüde istenmeyen bileşen olarak tanımlanır ve görüntünün kalitesinde azalmaya sebep olur. Bir görüntüyü $f(.)$ olarak tanımlayalım. Görüntü temiz bileşen $g(.)$ ve gürültülü bileşen $q(.)$ olarak iki parçaya ayrılabilir. Görüntünün bu iki bileşenin toplamı olarak ifade edilmesi en yaygın modelleme şeklidir.

$$f(.) = g(.) + q(.) \quad (2.1)$$

Bu tip modellemeye örnek olarak “Gauss” gürültüsü verilebilir. İkinci en yaygın modelleme şekli, görüntünün bu iki bileşenin çarpımı olarak gösterilmesidir:

$$f(.) = g(.)q(.) \quad (2.2)$$

“Speckle” gürültüsü, çarpım şeklinde modellenen gürültü tipine örnek olarak verilebilir. Bazı gürültü tipleri vardır ki, ne toplam ne de çarpım olarak ifade edilebilirler. Tuz ve biber gürültüsü ile “Poisson” gürültüsü bu tür gürültülerdir (Bovik, 2010). Görüntü iyileştirme algoritmalarının çoğunda kullanılan gürültü tipleri, toplam olarak ifade edilebilen gürültülerdir (Dougherty, 2010).

Gürültünün başlıca kaynakları, görüntü elde etme ve/veya görüntü iletimi sırasında ortaya çıkar. Görüntü elde etmede kullanılan sensörlerin performansı çevresel etkilere ve kullanılan sensörün kalitesine bağlıdır. CCD kamera ile elde edilen görüntüde oluşan gürültünün kaynağı, sensörün sıcaklığı ve ortamın ışık seviyesi ile ilgilidir. Görüntü iletimi esnasında oluşan gürültü de, iletim ortamındaki girişimlerden dolayı oluşur. Örneğin, bir kablosuz ağ kullanılarak iletilen bir görüntüdeki gürültü, yıldırım veya başka atmosferik etkilerin bir sonucu olarak ortaya çıkar (Gonzalez ve Woods, 2009). Bu bozulmalara ilave olarak örnekleme, yüksek frekanslı sinyal bileşenlerinin üst üste binmesinden (aliasing)

kaynaklı gürültüye neden olur. Görüntü sıkıştırma ve “(Analog to Digital Conversion) ADC” işlemleri sonucunda da görüntüde bozulmalar görülmektedir (Dougherty, 2010).

Gürültünün rastlantısal ve stokastik bir süreç olmasından dolayı değerini tam olarak tahmin etmek mümkün olmamakla birlikte, istatistiksel özelliklerini ortaya koymak mümkündür. Her ne kadar gürültünün bütün özelliklerini tanımlamak için matematiksel bir ifade yazmak mümkün değilse de; beklenen değer, beklenen değer karesi ve olasılık yoğunluk fonksiyonu gibi özelliklerle gürültünün tanımlanması mümkündür. Rastgele bir değişkeni en kolay modelleme yolu, o değişkenin beklenen değerinin ve varyansının kullanılmasıdır (Dougherty, 2010).

Her gürültü tipi, kendine has özelliklere sahiptir ve görüntülerde farklı şekillerde bulunurlar (Umbaugh, 2016). Çok bilinen gürültü tipleri ve özellikleri aşağıda başlıklar altında incelenmiştir.


2.2. Gürültü Çeşitleri

2.2.1. “Gauss” gürültü modeli

“Gauss” gürültüsü sinyal üzerine eşit olarak dağılır. Bu durum, gürültülü görüntüdeki her pikselin, gerçek piksel değeri ile ve rastgele bir “Gauss” dağılımlı gürültü değerinin toplamı olduğu anlamına gelir (Garg ve Kumar, 2012). Bir x değişkenine ait “Gauss” gürültüsünün olasılık dağılım fonksiyonu aşağıdaki formül ile verilir:

$$P(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-(x-\mu)^2/2\sigma^2} \quad (2.3)$$


Bu formülde, x , gri seviyesini; μ , fonksiyonun ortalama değerini ve σ da gürültünün standart sapmasını ifade etmektedir. Bu ifadenin grafiği Şekil 2.1’de verilmiştir.



Şekil 2.1. “Gauss” Olasılık Dağılım Fonksiyonu

“Gauss” olasılık dağılım fonksiyonuna göre, x değerinin yaklaşık %70’i $[(\mu - \sigma), (\mu + \sigma)]$ aralığında ve %95’i $[(\mu - 2\sigma), (\mu + 2\sigma)]$ aralığında yer alır.

Yükseltici devrelerinde veya algılayıcılarda ortaya çıkan “Gauss” gürültüsü, elektronik gürültü olarak da adlandırılır. Atomların termal titreşimi gibi doğal sebeplerden kaynaklandığı için termal gürültünün modellenmesinde kullanılmaktadır. “Gauss” gürültüsü, gerçek dünyada karşılaşılan birçok durumun iyi bir yaklaşımını oluşturur ve matematiksel olarak uygulanabilir modeller üretir (Bovik,2010; Boyat ve Josji, 2015). “Gauss” gürültüsünün frekans spektrumundaki dağılımı da aynıdır. Şekil 2.2’de farklı standart sapma değerlerinde “Gauss” gürültüsü içeren görüntüler verilmiştir.



Şekil 2.2. “San-Francisco” görüntüleri:

a) orijinal görüntü, b) standart sapma değeri =10, c) standart sapma değeri = 30.

2.2.2. Beyaz gürültü modeli

Sabit enerji spektrumuna sahip bir gürültü çeşididir, başka bir deyişle tüm frekanslarda eşit enerjiye sahiptir. Teorik olarak tüm frekanslarda bulunur ve bu da gürültünün enerjisinin sonsuz olması anlamına gelir. Pratikte ise beyaz gürültünün enerji seviyesi yeterince yüksek frekanslarda düşer. Beyaz gürültü ifadesi güneş ışığından esinlenilerek kullanılmıştır. Güneş ışığı da görünür ışık spektrumundaki hemen hemen tüm frekansları eşit oranda içerir. Beyaz gürültünün korelasyonu sıfırdır, yani bir piksel komşu pikselleri ile ilişkili değildir.

2.2.3. Tuz ve biber gürültü modeli

Tuz ve biber gürültüsü, impuls gürültüsü olarak da adlandırılır. Kamera sensörlerindeki ve bellek alanlarındaki donanımsal hatalar ve görüntünün gürültülü bir iletim kanalından transferi oluşma sebepleri olarak gösterilebilir. Tuz biber gürültüsü ile bozulmuş görüntüdeki gürültülü piksellerin değeri, bir pikselin alabileceği maksimum ya da minimum değerdir (Chan vd., 2005).

Tuz biber gürültüsünün olasılık dağılım fonksiyonu şu şekilde modellenebilir. $f(x, y)$ temiz görüntüyü, $q(x, y)$ de tuz ve biber gürültüsü ile bozulmuş görüntüyü ifade etsin.


$$Pr[q = f] = 1 - \alpha$$

$$Pr[q = MAX] = \alpha/2 \quad (2.4)$$

$$Pr[q = MIN] = \alpha/2$$

Burada, Pr, olasılık fonksiyonunu göstermektedir. 8 bit/piksel bir görüntü için MIN piksel değeri 0 iken MAX piksel değeri 255'dir. Görüntüdeki pikseller α olasılığı ile 0 ve 255 değerini alırlar. Gürültülü pikseller görüntü üzerinde siyah ve beyaz noktalar olarak görülürler. Biber gürültüsünün tipik piksel değeri 0 iken tuz gürültüsünün tipik piksel değeri 255 olarak tanımlanır. Şekil 2.3'te tuz biber gürültüsü içeren "San Francisco" görüntüsü

verilmiştir. Piksellerin yaklaşık olarak %5'i tuz biber gürültüsünden etkilenmiştir (Piksellerin %95'inin değerinde bir değişim olmamıştır).



Şekil 2.3. Olasılık değeri 0.05 olan tuz biber gürültüsü eklenmiş “San Francisco” görüntüsü

Medyan filtreleme, hesaplama süresinin kısa olması sebebiyle tuz ve biber gürültüsü ile bozulmuş görüntülerin iyileştirilmesinde sıklıkla kullanılmaktadır (Ko ve Lee, 1991; Nodes ve Callager, 1989; Pitas ve Venetsanopoulos, 2013).

2.2.4. “Speckle” gürültü modeli

“Coherent” görüntüleme (Coherent Light Imaging) bir cisim, lazer veya radar iletici ile aydınlatılır. “Coherent” ışık, yüzeye çarptığında geri yansır. Yüzeydeki pürüzlerden kaynaklı olarak, geriye dönen sinyal faz ve büyüklükte rassal değişikliklere maruz kalır. Bu değişiklikler, görüntüde güçlü koyuluklara veya güçlü açıklıklara sebep olur. Bu tür bozulmalara “Speckle” denir (Dougherty, 2010). Bu tip gürültü, “Coherent” görüntüleme uygulamaları olan uzay ve ultrasonografi görüntülerinde görülür (Rabbani, 2008). Şekil 2.4’te “Speckle” gürültüsü içeren “Lenna” görüntüsü verilmiştir. Görüntü incelendiğinde net bir şekilde görülmektedir ki, açık renkli alanlar gürültüden daha fazla

etkilenmiştir. “Speckle” gürültüsü “gamma” olasılık dağılım fonksiyonuna sahiptir ve matematiksel modeli aşağıda verilmiştir (Tao vd., 2006):

$$F(x) = \frac{x^{\alpha-1}}{(\alpha-1)! a^\alpha} e^{-\frac{x}{a}} \quad a \geq 0 \quad (2.5)$$

Formüldeki x , piksel değerini; $a^2\alpha$ da varyans değerini göstermektedir. Bu dağılımın $\alpha = 2$ deki durumu “Rayleigh” dağılımı olarak tanımlanır.



Şekil 2.4. Varyansı 0.04 olan “Speckle” gürültülü “Lenna” görüntüsü

2.2.5. “Poisson (foton)” gürültü modeli

“Poisson” gürültüsü, düşük ışık koşullarında, görüntü algılayıcı sensörler üzerinde toplanan foton sayısının az olması durumunda oluşur (Deledalle vd., 2010). Medikal görüntüleme için kullanılan x ışınları ve gamma ışınları düşük ışık koşullarındaki uygulamalara örnek olarak gösterilebilir (Dougherty, 2010). Varsayalım ki a , bir görüntünün bir pikselinde toplanan foton sayısını belirtsin. a sayısının olasılık yoğunluk fonksiyonu, λ parametresi kullanılarak “Poisson” dağılımı ile modellenir.

$$P(a = k) = \frac{e^{-\lambda} \lambda^k}{k!} \quad k = 0,1,2, \dots \text{ için} \quad (2.6)$$

λ değeri büyük olduğunda “Poisson” dağılımına “Gauss” dağılımı olarak yakınsanır. Bu durumda, beklenen değer ve varyans, λ değerine eşit olur. Şekil 2.5’te “Poisson” gürültülü “San-Francisco” görüntüsü verilmiştir. Gürültülü görüntü, orijinal görüntüdeki her pikselin değerine eşit olan λ değerinin kullanılmasıyla oluşturulmuştur. Şekil 2.5’te beyaz alanların koyu alanlara nazaran daha gürültülü olduğu görülmektedir (Bovik, 2010).



Şekil 2.5. “Poisson” gürültülü “San-Francisco” görüntüsü

2.2.6. Periyodik gürültü modeli

Gürültü, görüntünün piksel değerindeki herhangi bir bozulma veya hata olarak tanımlanır ve bu durum dış bir etkinin sonucudur. Bu etki rassal olarak değil de periyodik olarak gerçekleştiğinde, görüntüdeki bozulma çubuklar şeklinde görülür. Bir elektrik motorunun oluşturduğu elektromanyetik alanın iletilmekte olan bir görüntü üzerinde oluşturduğu gürültü periyodik gürültüye örnek olarak verilebilir. Uzaysal boyutta bozulmalara maruz kalmış görüntü “Fourier” dönüşümü alınarak frekans boyutuna aktarıldığında iki tepe noktası oluşur. Bu iki tepe noktasının konumları görüntüdeki

periyodik bozulmaların yerini belirlemeye yardımcı olur. “Band reject” ve “notch” filtreleme yöntemleriyle bu tür gürültü yok edilebilir (Hamd, 2014).

Yapısal gürültü, sabit (stationary) veya sabit olmayan (non-stationary) periyodik gürültü olarak tanımlanır. Sabit gürültü; sabit genliğe, frekansa ve faz açısına sahiptir. Çoğunlukla elektronik cihazlar arasındaki girişimlerden kaynaklı oluşur. Sabit olmayan gürültülerde ise genlik, frekans ve faz açısı değişkendir. Görüntü üzerinde çubuklar şeklinde oluşan bu gürültü aşağıdaki formül ile modellenir:

$$\text{Periyodik Gürültü} = \text{Sin}(w_1x + w_2y) + 1 \quad (2.7)$$

Burada x ve y , görüntünün piksel koordinatlarını ifade ederken w_1 ve w_2 periyodik gürültünün frekans değerlerini gösterir. Şekil 2.6’da periyodik gürültülü “Lenna” görüntüsü verilmiştir.



Şekil 2.6. Periyodik gürültülü “Lenna” görüntüsü


2.2.7. Niceleme (quantization) gürültüsü

Niceleme gürültüsü, analog bir sinyalin sayısal bir sinyale dönüştürülmesi sürecinde oluşur. Gürültü, çevrimdeki çözünürlük (bit sayısı) dörtten büyük olduğunda sinyalden bağımsızdır ve toplam olarak ifade edilir. Minimum ve maksimum piksel değeri x_{min} ve x_{max} olan dijital bir sinyal için sinyal/gürültü oranı aşağıdaki formülle ifade edilir (Dougherty, 2010):

$$SNR = 20 \log(x_{max} - x_{min}) / \sigma_n \quad (2.8)$$

Burada σ , gürültünün standart sapmasını, n değeri de bit sayısını gösterir.

Niceleme gürültüsü düzgün dağılım özelliğindedir ve bu yüzden de düzgün (uniform) gürültü olarak da adlandırılır (Boyat ve Josji, 2015). Düzgün dağılımlı olasılık yoğunluk fonksiyonunun grafiği Şekil 2.7’de verilmiştir.



Şekil 2.7. Düzgün dağılımlı olasılık yoğunluk fonksiyonu

Düzgün dağılımın beklenen değeri $\mu = \frac{a+b}{2}$ ve varyansı $\sigma^2 = \frac{(b-a)^2}{12}$ olarak ifade edilir.

2.3. Gürültü Seviyesi Belirleme Yöntemleri

Görüntüdeki gürültü seviyesinin düşürülmesi (görüntünün temizlenmesi) görüntü işlemede önemli bir konudur. Görüntü temizleme işleminden sonra gerçekleştirilecek işlemlerin doğruluğu ve performansı görüntü temizleme adımının performansı ile direkt ilişkilidir. Görüntü temizleme işlemi sonrasında uygulanabilecek diğer işlemlere, görüntü segmentasyonu (Zaitoun ve Aqel, 2015), görüntü tanıma (Jafri ve Arabnia, 2009) ve görüntü sınıflandırma (Kamavisdar vd., 2013) örnek olarak verilebilir. Literatürdeki görüntü temizleme algoritmalarının çoğu, görüntüdeki gürültü seviyesinin daha önceden bilindiği varsayımı üzerine kuruludur ve varsayılan gürültü toplam olarak ifade edilebilen sıfır ortalama değere sahip “Gauss” gürültüsüdür (Olsen, 1993; Liu ve Lin, 2013). Bir görüntünün aşağıdaki ifade ile modellendiğini varsayalım.

$$I_n(x, y) = I(x, y) + n(x, y) \quad (2.9)$$

Bu ifadede (x, y) görüntünün piksel koordinatlarını ifade ederken, $I_n(x, y)$, $I(x, y)$, $n(x, y)$ de sırasıyla; gürültülü görüntü, orijinal görüntü ve gürültüyü ifade eder. Gürültü seviyesi belirleme yöntemlerinin amacı, gürültünün standart sapması olan σ_n 'e yakınsamadır. “Gauss” dağılımına sahip bir gürültünün genliği de aşağıdaki şekilde ifade edilir:

$$f(n) = \frac{1}{\sigma_n \sqrt{2\pi}} e^{-\frac{n^2}{2\sigma_n^2}} \quad (2.10)$$

Bu ifadedeki n , piksel değerini ifade etmektedir. Gürültünün standart sapmasının bilinmesi durumunda, görüntü temizleme yöntemlerinde kullanılan parametreler ve eşik değerleri bu standart sapma değerine göre belirlenir ve temizleme yönteminin daha iyi sonuçlar vermesi sağlanır.

Tek bir görüntünün gürültü seviyesinin belirlenmesinde iki önemli zorluk vardır. Bunlardan birincisi, gürültünün görüntüden ayırt edilmesinde kullanılacak bilgiler için bir veri tabanı oluşturulmasıdır. İkincisi de yöntemin görsel içeriğe uyarlanabilir (adaptive to visual content) olmasının sağlanarak farklı görüntüler için de uygulanabilir olmasıdır.

Literatürde var olan gürültü seviyesi belirleme yöntemleri 3 ana sınıfa ayrılabilir. Bunlar; filtre tabanlı, blok tabanlı ve dönüşüm tabanlı gürültü seviyesi belirleme yöntemleridir. Bu yöntemlerin her biri aşağıdaki başlıklar altında incelenmiştir.

2.3.1. Blok tabanlı gürültü seviyesi belirleme yöntemleri


Blok tabanlı gürültü seviyesi belirleme yöntemlerinde görüntü belirli sayıda bloklara bölünür. Amaç, bir grup homojen görüntü bloklarının istatistiksel analizi ile görüntünün bütününde var olan gürültünün varyansının elde edilmesidir. Bu yöntemdeki temel varsayım; homojen görüntü bloklarının, kenar veya köşeler gibi keskin geçişlerin olmadığı, muhtemelen aynı veya benzer renk değerlerine sahip pürüzsüz alanlardan seçilmiş olmasıdır. Tüm görüntülere uygulanabilir model parametreleriyle, homojen görüntü bloklarının nasıl seçileceği önemli bir konudur. Bu yöntemler genellikle basittir ancak düşük gürültülü görüntülerde yüksek gürültü seviyesi belirleme ve yüksek gürültülü görüntülerde düşük gürültü seviyesi belirleme özellikleri vardır.

Tian ve Chen (2012), gürültü seviyesi belirlemeyi karınca kolonisi optimizasyonu algoritmasını (Dorigo vd., 2006) kullanarak gerçekleştirmişlerdir. İki aşamalı bu yaklaşımda, öncelikle bir görüntü bloğunun merkez pikselinin komşuluk yapısı grafiksel olarak tanımlanır. İkinci aşamada, karınca kolonisi algoritması belirlenen komşuluk yapısı kullanılarak uygulanır ve algoritma tarafından en çok ziyaret edilen görüntü blokları (homojen görüntü blokları) gürültü seviyesinin belirlenmesinde kullanılır. Algoritma tarafından belirlenen görüntü bloklarının varyans değerlerinin ortalaması, gürültünün varyans değeri olarak belirlenir.

Turajlic vd. (2007), tekil değer ayrışımına (Singular Value Decomposition) dayalı blok tabanlı gürültü seviyesi belirleme yöntemini X ışını görüntülerine uygulamışlardır. Yöntemlerinin birinci aşaması görüntüdeki homojen bölgelerin belirlenmesidir. Bu bağlamda, görüntü bloklara bölünür ve her bir blok standart sapması hesaplanır. En küçük standart sapma değerine sahip olan görüntü bloğu homojen alan olarak belirlenir. En küçük standart sapma değerine belli bir eşik değerinde yakın olan görüntü bloklarından homojen blok görüntüler kümesi oluşturulur. Oluşturulan bu görüntü bloklarının her birine Liu ve

Lin'in (2013) önerdikleri tekil değer ayrışımı algoritması uygulanır ve her bir parçanın gürültü seviyesi belirlenir. Belirlenen gürültü seviyelerinin ortalaması görüntünün gürültü seviyesi olarak değerlendirilir.

Amer ve Dubois'in (2005) yönteminde, homojen görüntü bloklarının belirlenmesinde görüntü bloklarının varyans değerlerinin kullanılması yerine, içerisinde çizgi ve köşe gibi keskin hatlar bulunan görüntü bloklarının belirlenmesi üzerine kuruludur. Keskin hatlar içeren görüntü bloklarının belirlenmesinde ikinci türev maskeleri kullanılmaktadır. (3x3) boyutundaki görüntü blokları için önerilen yüksek-geçirgen operatörler Şekil 2.8'de 8 farklı yön için gösterilmiştir.



Şekil 2.8. (3x3) boyutundaki görüntü blokları için yüksek-geçirgen operatörler

Yüksek geçirgen operatörlerin katsayıları $\{-1, -1 \dots (W - 1) \dots - 1, -1\}$ şeklindedir. (3x3) boyutu için W (boyut) değeri 3'tür. Eğer bir yöndeki koyuluk düzgün ise, yüksek-geçirgen operatörün çıktısı 0 değerine yakındır. Görüntü bloğunun homojenlik ölçüsünün hesaplanması için 8 yön için hesaplanan değerlerin mutlak değerleri toplanır. Homojen olarak belirlenen görüntü bloklarının sahip oldukları varyans değerlerinin ortalaması hesaplanarak tüm görüntünün gürültü seviyesi belirlenir.

Mikolajczak ve Peksinski (2016), görüntünün medyan filtreden geçirilmesi sonucunda sadece gürültü bileşeninin yok olduğu varsayımına dayalı bir gürültü seviyesi belirleme yöntemi geliştirmişlerdir. Önerilen yöntem, filtreleme işlemi sonunda sadece gürültü bileşeninin varyansının düştüğünü varsayar. Gürültü bileşeninin varyans değeri σ_n^2 iken, filtreleme işleminden sonra bu değerin $\frac{\pi}{2N}\sigma_n^2$ olduğu belirtilmiştir. N sayısı görüntü bloğu içerisindeki piksel adedidir. Bu yöntemde, gürültü bileşeni ile orijinal görüntü arasında bir korelasyon olmadığı varsayılmaktadır. Filtreleme işleminin gerçekleştirileceği görüntü bloklarının belirlenmesinde, Kowalski vd.'nin (2013) oto-kovaryansa dayalı korelasyon katsayılarının belirlendiği yöntemleri kullanılmıştır. Bu yöntem, homojen bölgelerdeki piksellerin kendi aralarındaki korelasyonunun düşük olması gerekliliğine dayanır.

Gao (1993), görüntüleme spektrometresinden elde edilen görüntülerin sinyal gürültü oranının (SGO) bulunmasına yönelik bir yöntem geliştirmiştir. Görüntünün tamamı bloklara ayrılır ve her bloğun standart sapması hesaplanır. Blokların standart sapmalarının ortalama değeri ve bloklar arasındaki maksimum standart sapma değeri ile minimum standart sapma değeri belirlenir. Maksimum standart sapma ve minimum standart sapma değerleri arasında belirli sayıda gruplar oluşturulur ve her görüntü bloğu bu gruplardan birisine standart sapma değerine göre dahil edilir. En yüksek sayıda görüntü bloğunun bulunduğu grup görüntüdeki gürültüyü temsil eder. SGO, görüntünün ortalama değeri ile en yüksek görüntü bloğunun bulunduğu grubun oranına eşittir.

2.3.2. Filtreleme tabanlı gürültü seviyesi belirleme yöntemleri

Filtreleme tabanlı gürültü seviyesi belirleme yöntemlerinde gürültülü görüntü öncelikle alçak-geçirgen bir filtreden geçirilir. Gürültü bileşeninin varyansı, gürültülü görüntü ile filtrelenen görüntü arasındaki fark kullanılarak belirlenir. Bu tür yöntemlerin dezavantajı, filtrelenen görüntünün orijinal görüntü olarak kabul edilmesi esasına dayanmasıdır. Birçok uygulamada filtrelenen görüntü orijinal görüntünün özelliklerini tam olarak içermez. Özellikle keskin ton geçişleri ve görsel detayları çokça içeren görüntüler alçak-geçirgen filtreden geçirildiğinde orijinal görüntünün özelliklerini içermezler. Filtreleme tabanlı yöntemler, blok tabanlı yöntemlere göre daha iyi sonuçlar vermekle birlikte, işlem süreleri daha uzundur.

Rank ve Markus'un (1999) önerdikleri yöntemde, gürültünün varyans değeri 3 aşamalı bir işlemle belirlenmektedir. Birinci adımda, gürültülü görüntü düşey ve yatay yönlerde tek boyutlu fark operatörü ile filtrelenir. Filtreleme sonucunda elde edilen görüntünün varyansının gürültülü görüntü ile aynı olduğu ön kabulü vardır. Bu varsayım, gürültü bileşeninin görüntüden bağımsız olduğu ve normal dağılım sergilediği durumlar için geçerlidir. Fark operatörü, görüntüde lineer artış gösteren piksel değerlerinin sabit bir değere dönüşmesini sağlar ve gürültü bileşeninin varyans değerine yakınsamasını kolaylaştırır. İkinci adımda, görüntü (3x3) boyutlarında bloklara bölünür ve her bloğun varyans değeri hesaplanır. 3. adımda da, hesaplanan varyans değerleri kullanılarak histogram grafiği oluşturulur ve bu histogram grafiğinden gürültünün varyans değeri belirlenir. Ikeda ve arkadaşları (2010), bu yöntemi bilgisayar tomografisi ile çekilen görüntülere uygulamışlar ve olumlu sonuçlar elde etmişlerdir. Immarker'in (1995) çalışmasında, gürültü bileşeninin "Laplace" operatörüne duyarlı olması gerektiği teziyle gürültülü görüntüyü "Laplace" operatöründen geçirmiş ve gürültünün varyansını bu işlemten sonra hesaplamıştır. Immarker'in elde ettiği sonuçlar da olumludur. En iyi sonucu elde etmek için, kullanılacak operatörün seçimi görüntünün özelliklerine göre yapılmalıdır.

Russo (2007) yayınladığı bildirisinde, filtre tabanlı gürültü seviyesi belirleme yöntemlerine farklı bir yaklaşım getirmiştir. Önerdiği yöntem, gürültülü görüntünün parçalı lineer bir filtreden geçirilerek gürültünün daha belirgin hale getirilmesi ile başlar (Russo, 2006). Elde edilen yeni görüntü bloklara ayrılır ve her bir blok için varyans değeri hesaplanır. Hesaplanan bu değerler görüntünün bütününe ait olan gürültü varyansının belirlenmesinde kullanılır. Parçalı lineer filtre parametreleri, farklı varyans değerlerinde gürültü eklenmiş görüntülerden oluşan bir eğitim seti kullanılarak belirlenir.

2.3.3. Dönüşüm tabanlı (transform based) gürültü seviyesi belirleme yöntemleri

Dönüşüm tabanlı yöntemlerde görüntünün spektrum analizi gerçekleştirilerek gürültü seviyesine yakınsanır. Spektrum analizi için, ayrık dalgacık dönüşümü literatürde sıklıkla kullanılır. Yaygın olarak kullanılan yakınsama yöntemi ortalama mutlak sapma (mean absolute deviation) değerine dayanır (Donoho, 1995). Bu yöntemde görüntüdeki gürültünün varyans değeri şu şekilde modellenir:

$$\sigma_n = \frac{\text{median}(|y_i|)}{0.6745}, \quad y_i \in HH \text{ alt bandı} \quad (2.11)$$

Bu modellemede *HH*, dalgacık ayrıştırmasındaki diyagonal bandı; y_i , diyagonal banttaki katsayıları belirtir. Bu yaklaşım, *HH* alt bandındaki katsayıların gürültü tarafından domine edildiği (gürültünün yüksek frekans bileşenlerinde bulunduğu) varsayımına dayanır. Bu varsayım her zaman doğru değildir, zira *HH* alt bandındaki katsayıları görüntü içindeki detaylar da etkiler. Bu sebepten de, dönüşüm tabanlı gürültü seviyesi belirleme yöntemleri düşük gürültülü ve yüksek detaylar içeren görüntülerde iyi sonuçlar vermezler. Aynı zamanda bu yöntemler, yüksek hesaplama yükü getirir ve gerçek zaman uygulamaları için uygun değildir. Donoho'nun çalışmasındaki eksik noktaları iyileştirmek için, yine dalgacık ayrıştırmasının kullanıldığı adaptif gürültü yakınsama yöntemleri geliştirilmiştir (Chang vd., 2000; Hashemi ve Soosan., 2010).

3. TEORİK BİLGİ

3.1. Ortak Vektör Yaklaşımı (OVY)

Ortak Vektör Yaklaşımı, görüntü ve ses işleme alanlarında, sınıflandırma yapmak amacıyla kullanılan bir alt uzay yöntemidir. (Gülmezoğlu vd., 1999, 2001, 2007; Çevikalp vd., 2006). Bir sınıfın ayırt edici veya değişmeyen özellikleri o sınıfa dair ortak vektör ile karakterize edilebilir. Bir sınıf içerisindeki vektör sayısı m , sınıf içerisinde yer alan vektörlerin boyutu da n olarak ifade edilmiş olsun. (Ortak vektör yaklaşımı, hem yetersiz veri ($m \leq n$), hem de yeterli veri ($m > n$) durumlarına uygulanabilir. Bu tezde yetersiz veri durumu kullanılmıştır). Bu n boyutlu örnek uzayı, birbirine dik olan iki alt uzaya ayrılabilir. Bu alt uzaylardan birincisi ($m - 1$) boyutlu farklılık alt uzayı B ve ikincisi de ($n - m + 1$) boyutlu farksızlık alt uzayı B^\perp olarak ifade edilebilir. (Gülmezoğlu vd., 2001, 2007).

Bir sınıf içerisindeki öznitelik vektörleri aşağıdaki gibi ifade edilmiş olsun.

$$a_i = a_{com} + a_{i,dif} \quad (i = 1, 2, \dots, m) \quad (3.1)$$

Bu ifadedeki a_{com} sınıfa dair ortak vektör iken; $a_{i,dif}$ de; arka plan gürültüsü, kayıt sistemi, iletim ortamı vb. sebeplerden kaynaklanan farklılıkları içeren vektördür. Yetersiz veri durumunda, herhangi bir sınıfın kovaryans matrisinin sıfır öz değerlerine karşılık gelen öz vektörler kullanılarak, o sınıfa dair ortak vektör hesaplanabilir. (Gülmezoğlu vd., 2001).

Herhangi bir sınıfın kovaryans matrisi φ aşağıdaki şekilde formüle edilir:

$$\varphi = \sum_{i=1}^m (a_i - a_{ort})(a_i - a_{ort})^T \quad (3.2)$$

a_{ort} , sınıf içerisindeki öznitelik vektörlerinin ortalama vektörüdür. Kovaryans matrisinin ($n - m + 1$) adet öz değeri, yetersiz veri durumu için sıfır değerlidir. Sıfır öz değerlere

karşılık gelen öz vektörler farksızlık alt uzayı B^\perp 'yi gerer. Sıfır olmayan öz değerlere karşılık gelen öz vektörler de farklılık alt uzayı olan B 'yi gerer. Tüm öz değerlere karşılık gelen öz vektörler u_1, u_2, \dots, u_n olarak ve sıfır öz değerlere karşılık gelen öz vektörler $u_1, u_2, \dots, u_{n-m}, u_{n-m+1}$ olarak ifade edilmiş olsun. Herhangi bir sınıfa ait ortak vektör, o sınıf içerisinde yer alan herhangi bir vektörün farksızlık alt uzayı B^\perp 'yi geren öz vektörler üzerine projeksiyonun alınması ile hesaplanır. Bu hesaplama aşağıdaki gibi formüle edilir.

$$a_{com} = \sum_{j=1}^{n-m+1} u_j u_j^T a_i \quad (\text{herhangi bir } i = 1, 2, \dots, m) \quad (3.3)$$

Bir sınıfa ait ortak vektörün bulunması ile birlikte bilinmeyen bir vektörün o sınıfa ait olup olmadığının testi yapılabilir. Bu sınıflandırma için aşağıdaki ölçüt uygulanır.

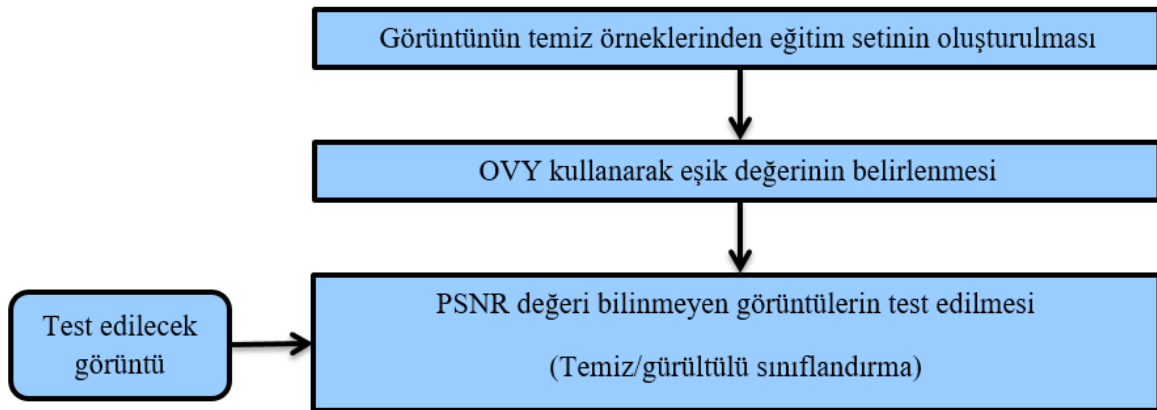
$$\text{uzaklık} = \operatorname{argmin}_{1 \leq c \leq S} \left\| \sum_{j=1}^{n-m+1} \{[(a_x - a_i^c)^T u_j^c] u_j^c\} \right\|^2 \quad (3.4)$$

a_x , test edilecek öznitelik vektörünü; a_i^c , c 'inci sınıfa ait herhangi bir öznitelik vektörünü, u_j^c , c 'inci sınıfın j 'inci öz değerine karşılık gelen j 'inci öz vektörü ve S 'de toplam sınıf sayısını gösterir. Minimum uzaklığın elde edildiği sınıf, test edilen öznitelik vektörünün ait olduğu sınıf olarak belirlenir.

4. MATERYAL VE YÖNTEM

4.1. Önerilen Yöntem

Önerilen yöntem, OVY'nin sınıflandırma özelliğinin görüntü işleme alanına uygulanarak bir görüntünün gürültülü bloklarının belirlenmesini kapsar. Bir görüntünün temiz kabul edilen örneklerinden bir eğitim seti oluşturulur ve bu eğitim setindeki görüntüler bloklara ayrılır. Görüntü bloklarına OVY uygulanır ve her bir blok için bir eşik değeri belirlenir. Her bir blok için bulunan eşik değeri, Peak Signal to Noise Ratio (PSNR) değeri bilinmeyen bir görüntünün bloklarının temiz veya gürültülü ayrımının yapılmasında kullanılır. Önerilen yöntem, Şekil 4.1'deki gibi 3 kısma ayrılır.



Şekil 4.1. Önerilen yöntemin akış şeması

4.1.1. Görüntünün temiz örneklerinden eğitim setinin oluşturulması

Literatürde, bir görüntünün kalitesinin belirlenmesi amacıyla, gürültülü görüntünün temiz görüntü ile matematiksel karşılaştırılmasına dayanan metrikler kullanılmaktadır. Mean Squared Error (MSE) ve PSNR bu amaç için en çok kullanılan objektif metriklerdir (Avcıbaş vd., 2002; Eskicioğlu ve Fisher, 1995). Temiz görüntü (referans görüntü) $f(x,y)$ ve gürültülü görüntü de (test görüntüsü) $g(x,y)$ olarak ifade edilsin ve bu görüntülerin boyutu da $(M \times N)$ olsun. $MSE(f, g)$ ve $PSNR(f, g)$ şu şekilde verilir:

$$MSE(f, g) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (f(i, j) - g(i, j))^2 \quad (4.1)$$

$$PSNR(f, g) = 10 \log_{10} \frac{255^2}{MSE(f, g)} \quad (4.2)$$

MSE değerinin sıfır olması durumunda PSNR değeri sonsuza yakınsar. Bu durum, yüksek PSNR değerine sahip görüntünün daha kaliteli olduğunun göstergesidir. PSNR, basit yapısı, kolay gerçekleştirilebilirliği ve düşük hesaplama yükü sebebiyle görüntü kalitesinin ölçülmesinde sıklıkla kullanılır. Tek bir gürültü tipinin farklı miktarlarının var olduğu görüntülerin karşılaştırılması için oldukça elverişlidir (Silpa ve Mastani, 2012). PSNR değerinin “Gauss” gürültüsünün miktarına olan duyarlılığından dolayı (Hore ve Ziou, 2010), deneysel çalışmalarda görüntülere eklenen “Gauss” gürültüsü PSNR değeri ile ölçülmüştür. PSNR değeri 30 ve üzerinde olan görüntüler temiz olarak ele alınmıştır ve eğitim seti bu özellikteki görüntülerden oluşturulmuştur.

Eğitim seti, $(M \times N)$ boyutunda bir görüntünün m adet temiz örneklerinden oluşur. Eğitim setindeki görüntüler r_x olarak isimlendirilir ve x değeri 1’den m ’e kadar ardışıl ilerler. Önerilen yöntemin blok tabanlı olmasından dolayı eğitim setindeki her görüntü $k \times k$ boyutunda görüntü bloklarına ayrılır. Amaç, üzerinde çalışılmakta olunan görüntünün, $\frac{M \cdot N}{k^2}$ adet görüntü bloklarının her biri için bir eşik değerinin belirlenmesidir.

4.1.2. OVY kullanarak eşik değerinin belirlenmesi

Eğitim setindeki görüntüler kullanılarak görüntü grupları oluşturulur. Grup içerisinde yer alacak görüntüler, m adet görüntüden her seferinde l adet görüntünün dışarıda bırakılması yoluyla belirlenir. Şöyle ki; birinci grup, l ile m arasındaki (m dahil) indise sahip görüntülerden oluşur, ikinci grup da indisi $l + 1$ ile $2l$ arasında olmayan ($m - l$) adet görüntüden oluşur ve bu böyle devam eder. Eğer m değeri l değerinin tamsayı katlarından seçilirse toplam grup sayısı $\frac{m}{l}$ olur. Gruplar C^i olarak adlandırılır ve i , grup indisini gösterir. Grup içindeki görüntüler ve grup dışında bırakılan görüntülerin her biri $k \times k$ boyutunda

görüntü bloklarına ayrılır. Bu işlemle birlikte her bir görüntü, $\frac{M.N}{k^2}$ adet görüntü bloğundan oluşur. Her bir görüntüdeki bloklar kullanılarak $\frac{M.N}{k^2}$ adet sınıf oluşturulur. Sınıf içinde yer alan görüntü sayısı ve aynı zamanda blok sayısı $(m - l)$ olmakla birlikte sınıf dışında bırakılan l adet görüntüdeki l blok da o sınıfa dair eşik değerinin belirlenmesinde eğitim amaçlı kullanılır. Sınıflar C_j^i ile gösterilir ve bu gösterimde i grup indisi j 'de, 1'den $\frac{M.N}{k^2}$ 'ye uzanan sınıf indisidir. Her bir sınıf içindeki $k \times k$ boyutlu $(m - l)$ adet blok, $n \times 1$ boyutunda ($n = k^2$) öznitelik vektörü olarak ifade edilerek OVY'nin uygulanmasına olanak sağlanır. Bu tezde, vektör boyutu olan n , sınıf içerisindeki blok sayısından büyük olacak şekilde seçilerek OVY'nin yetersiz veri durumunun her bir sınıfa uygulanması sağlanmıştır.

Aşağıdaki işlemler, her bir grubun tüm sınıflarına uygulanır ve böylece eşik değeri belirlenmesinde kullanılan ortak vektör ve farksızlık alt uzayı bulunur. Her grup içerisinde $\frac{M.N}{k^2}$ adet sınıf bulunmasından dolayı hesaplanan ortak vektör ve farksızlık alt uzayı sayısı da $\frac{M.N}{k^2}$ adettir.

- $n \times n$ boyutlu kovaryans matrisi φ ve bu kovaryans matrisine dair öz değerler ve öz vektörler bulunur. n sayısı $(m - l)$ 'den büyük olduğu için, kovaryans matrisinin $n - (m - l) + 1$ adet öz değeri sıfırdır. Bu öz değerlere karşılık gelen öz vektörler ilgili sınıfın farksızlık alt uzayı B^\perp 'yi gerer. Özvektörler, tüm sınıflar için $eig_{j,y}^i$ notasyonu ile gösterilir. Bu notasyonda; i , 1 ile $\frac{m}{l}$ arasında değişen grup indisini; j , 1 ile $\frac{M.N}{k^2}$ arasında değişen sınıf indisini ve y , 1 ile $n - (m - l) + 1$ arasında değişen o sınıfa ait öz vektör indisini gösterir.
- Sınıf içindeki herhangi bir öznitelik vektörü referans vektör olarak seçilir ve bu sınıfa dair farksızlık alt uzayı B^\perp 'yi geren öz vektörler üzerine projeksiyonu alınır. Bu işlemin sonucunda ilgili sınıfa ait ortak vektör belirlenmiş olur. C_j^i olarak adlandırılan sınıflara dair ortak vektörler $C_{j,com}^i$ notasyonu ile gösterilir.

PSNR değeri bilinmeyen görüntü bloklarının temiz/gürültülü sınıflandırmasında kullanılan eşik değeri, eğitim seti dışında bırakılan her bir sınıftaki görüntü blokları ve bu

sınıflara ait ortak vektörler ve öz vektörler kullanılarak belirlenir. Bir sınıfın dışında bırakılan görüntü bloklarının her biri, o sınıfa dair farksızlık alt uzayını geren öz vektörler üzerine projekte edilir. Sınıf dışında bırakılan görüntü blokları $v_{j,z}^i$ olarak ifade edildiğinde projeksiyon vektörü olan $p_{j,z}^i$ aşağıdaki formül ile bulunur:

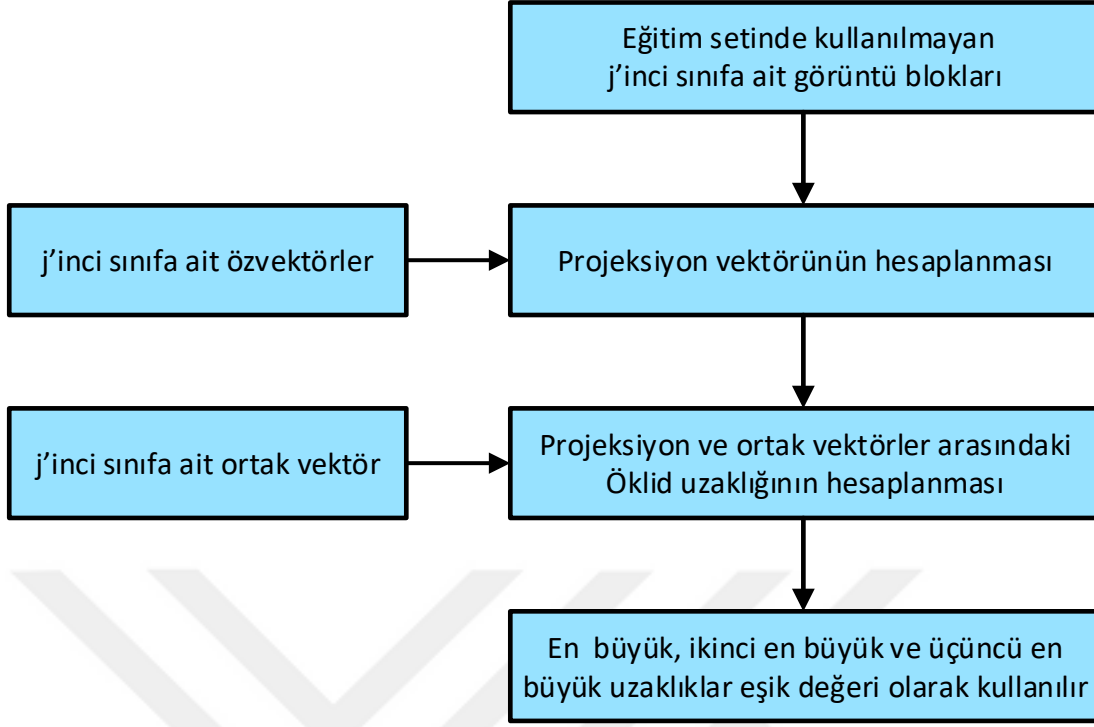
$$p_{j,z}^i = \sum_{y=1}^{n-(m-l)+1} (v_{j,z}^i * eig_{j,y}^{i,T}) eig_{j,y}^i \quad (4.3)$$

Formüldeki i , görüntü grubunun indisini; j , sınıf dışı bırakılan görüntü bloklarının ait oldukları sınıfın indisini ve z , 1 ile l arasında değişen, sınıf dışı bırakılmış görüntü bloklarının indisini gösterir.

Sınıf dışı bırakılmış bir blok için bulunmuş projeksiyon vektörü ile o sınıfa ait ortak vektör arasındaki Öklid uzaklığı aşağıdaki formül ile hesaplanır:

$$d_{j,z}^i = arg \min_{1 \leq i \leq m} \|p_{j,z}^i - C_{j,com}^i\| \quad (4.4)$$

Yukarıdaki formülden görüldüğü üzere her bir sınıf için bulunan uzaklık sayısı m 'dir. Bu uzaklıklardan en büyüğü, ikinci en büyüğü ve üçüncü en büyüğü ilgili sınıf, başka bir deyişle ilgili görüntü bloğunun eşik değeri olarak ele alınır. Bir görüntünün her bir bloğu için hesaplanan eşik değeri Th_j olarak gösterilir ve j , 1 ile $\frac{M.N}{k^2}$ arasında değer alır. Eşik değerlerinin OVY kullanılarak belirlenmesine dair akış şeması Şekil 4.2'de verilmiştir.



Şekil 4.2. Eşik değerlerinin OVY kullanılarak belirlenmesine dair akış şeması

4.1.3. PSNR değeri bilinmeyen görüntülerin test edilmesi

PSNR değeri bilinmeyen görüntülerin test edilmesine dair adımlar ve işlemler aşağıda maddeler halinde listelenmiştir.

- Gürültülü görüntülerden oluşan test seti, temiz görüntüye sıfır ortalama değerli “Gauss” gürültüsü eklenerek oluşturulur. Test setinde, PSNR değeri 7 dB ila 40 dB arasında değişen gürültülü görüntüler kullanılmıştır. Görüntülerin PSNR değerlerinin bilinmediği varsayımı yapılmıştır.
- Test edilecek gürültülü görüntü, eşik değeri belirleme adımında olduğu gibi $k \times k$ boyutunda görüntü bloklarına ayrılır.
- Her görüntü bloğu, eşik belirleme adımında ilgili sınıf için bulunan öz vektörler üzerine projekte edilir. Bu işlem herhangi bir görüntü grubunda o sınıf (C_j^i) için bulunan öz vektörler kullanılarak gerçekleştirilebilir zira sınıflandırma sonuçları çok küçük farklılıklar göstermektedir.

- Eğer test edilen görüntü bloğunun projeksiyon vektörü ile ilgili sınıfa ait ortak vektör arasındaki Öklid uzaklığı ilgili sınıfa dair eşik değerden küçük ise temiz olarak sınıflandırılır, aksi durumda ise gürültülü olarak sınıflandırılır.



5. BULGULAR VE TARTIŞMA

Önerilen yöntem, farklı görüntüler kullanılarak test edilmiştir. Deneysel çalışmalar her bir görüntü için elde edilen 40 adet temiz görüntünün eğitim setinde kullanılması ile yürütülmüştür. İlk deneysel çalışma, standart test görüntülerinin kullanılması ile görüntü bazlı yapılmıştır. İkinci deneysel çalışmada, üç görüntüden alınan 240 adet temiz görüntü eğitim setinde kullanılmıştır. Üçüncü deneysel çalışma, standart Lenna görüntüsünün farklı açılarda döndürülmüş versiyonlarının eğitim setinde kullanılması ile yapılmıştır. Tüm deneysel çalışmalar ve sonuçları aşağıdaki başlıklar altında tartışılmıştır.

5.1. Standart Test Görüntüleriyle Yapılan Deneysel Çalışmalar

Deneysel çalışmalarda 512x512 piksel boyutunda gri seviyeli standart test görüntüleri kullanılmıştır. Bunlar; literatürde “Lenna”, “Barbara”, “Peppers”, “Zelda” ve “Baboon” olarak anılan görüntülerdir. Bu görüntüler, Şekil 5.1’de verilmiştir. Bu görüntülerin deneysel çalışmalarda kullanılma sebebi, literatürde sıklıkla kullanılıyor olmalarıdır.

Önerilen yöntem, görüntülerin her birine ayrı ayrı olarak uygulanmıştır. Yöntemin uygulanmasında kullanılan eğitim setleri, PSNR değerleri 30 ile 69 arasında ardışıl sıralanan 40 farklı görüntüye Matlab ortamında sıfır ortalamalı “Gauss” gürültüsü eklenerek oluşturulmuştur. Her bir görüntü için ayrı ayrı oluşturulan eğitim setlerinde yer alan görüntülerin PSNR değerleri Çizelge 5.1’de verilmiştir. Her seferinde beş görüntünün dışarıda bırakılması ile sekiz farklı görüntü grubu oluşturulmuştur. Her görüntü grubu, $m = 35$ görüntüden oluşmaktadır. Görüntü bloklarının boyutu olan $(k \times k)$, (8×8) , (12×12) ve (16×16) olacak şekilde üç farklı deneysel çalışma yürütülmüştür. Yöntemin, bu m ve k değerleriyle uygulanması sonucu her bir görüntü bloğu için üç farklı eşik değeri belirlenmiştir. (8×8) boyutundaki görüntü blokları için, toplam 4096x3 farklı eşik değeri, (12×12) boyutundaki görüntü blokları için 1820x3 eşik değeri ve (16×16) boyutundaki görüntüler için, toplam 1024x3 farklı eşik değeri belirlenmiştir. Bir görüntü bloğu için eşik değeri, o görüntü bloğunun ilgili olduğu ortak vektör ile test vektörünün görüntü bloğunun ilgili olduğu farksızlık alt uzayına projekte edilmesiyle elde edilen kalan vektörü arasındaki

Öklid uzaklığıdır. Belirlenen eşik değerleri, bulunan 40 farklı uzaklıktan en büyüğü (Eşik değeri 1), ikinci en büyüğü (Eşik değeri 2) ve üçüncü en büyüğüdür. (Eşik değeri 3).



Şekil 5.1. Deneysel çalışmalarda kullanılan görüntüler: a) "Lenna", b) "Barbara", c) "Peppers", d) "Zelda", e) "Baboon"

Test adımında da, PSNR değeri 7 ile 40 arasında değişen 34 farklı görüntü, orijinal görüntüye sıfır ortalama değerli "Gauss" gürültüsü eklenerek Matlab ortamında oluşturulmuştur. Bu 34 farklı görüntü, önerilen yöntem ile test edilmiştir. (8x8) boyutundaki görüntü bloklarına dair sınıflandırma sonuçları Çizelge 5.2'de, (12x12) boyutundaki görüntü bloklarına dair sınıflandırma sonuçları Çizelge 5.3'de ve (16x16) boyutundaki görüntü bloklarına dair sınıflandırma sonuçları Çizelge 5.4'te verilmiştir.

Çizelge 5.1. Eğitim setinde kullanılan görüntülerin PSNR değerleri

Görüntü #	PSNR Değerleri				
	Lenna	Barbara	Peppers	Zelda	Baboon
1	30,18	30,05	30,03	30,07	30,02
2	30,94	31,03	30,99	31,03	31,02
3	32,18	32,06	32,23	32,03	32,01
4	33,03	33,09	33,02	33,10	33,08
5	34,04	34,10	33,95	34,09	34,09
6	34,99	35,07	35,23	35,06	35,04
7	36,07	36,02	36,01	36,00	36,08
8	37,07	36,95	36,96	37,17	37,08
9	38,08	37,92	38,22	38,20	38,08
10	39,00	39,17	38,98	39,19	39,18
11	39,92	39,94	39,96	40,05	40,03
12	41,16	41,03	40,91	41,02	41,03
13	42,09	42,12	42,12	42,05	42,01
14	43,11	43,09	42,91	43,07	43,10
15	44,13	44,07	44,01	44,06	44,07
16	44,98	45,06	45,12	45,04	45,07
17	46,03	46,15	46,05	46,14	46,16
18	47,03	47,17	47,01	47,16	47,05
19	47,99	48,16	48,03	48,18	48,02
20	49,06	49,10	49,08	49,09	49,10
21	50,04	50,00	50,10	50,32	50,09
22	51,03	51,03	51,08	51,10	51,10
23	51,97	52,05	52,03	52,04	52,03
24	53,09	53,02	52,83	53,07	53,05
25	53,96	54,11	54,03	54,14	54,10
26	55,08	55,02	55,01	55,01	55,10
27	56,06	56,08	56,11	56,23	56,08
28	57,07	57,06	57,09	57,10	57,12
29	57,92	58,00	58,01	58,20	58,02
30	59,07	59,11	59,16	59,13	59,13
31	60,18	60,25	60,00	60,23	60,19
32	61,06	61,23	61,09	61,18	61,11
33	62,13	61,98	62,07	62,26	62,23
34	62,89	63,01	62,79	63,06	63,18
35	63,98	64,13	64,38	64,09	64,11
36	65,10	65,09	65,03	65,16	65,07
37	66,17	65,95	66,08	66,16	66,10
38	67,26	67,12	67,05	67,19	67,19
39	68,17	68,04	67,98	68,16	68,13
40	68,80	69,25	69,11	69,25	69,26

Çizelge 5.2. (8x8) boyutlu görüntü bloklarının sınıflandırma sonuçları

PSNR	Lenna			Barbara			Peppers			Zelda			Baboon		
	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3
7,00-22,00	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
23	100	100	100	100	100	100	100	100	100	100	100	100	99,98	100	100
24	99,95	99,98	100	100	100	100	99,95	99,98	100	100	100	100	99,98	100	100
25	99,98	100	100	99,93	100	100	100	100	100	99,93	100	100	99,78	100	100
26	99,34	99,98	100	99,22	100	100	99,32	99,98	100	99,19	100	100	99,1	99,9	100
27	96,48	99,66	99,98	96,88	99,61	99,98	96,68	99,54	99,98	96,9	99,8	99,98	96,04	99,51	99,98
28	88,06	98,02	99,83	89,53	98,12	99,61	88,35	98,07	99,88	87,23	97,71	99,54	86,57	97,78	99,8
29	63,4	88,72	97,66	65,19	90,06	97,41	62,92	88,57	97,78	70,68	92,16	98,19	69,95	91,8	98,32
30	30,59	65,58	88,16	55,83	23,46	6,96	68,63	34,45	12,23	55,1	22,73	7,1	57,69	24,63	7,25
31	81,13	50,05	21,17	79,1	46,92	20,34	80,86	49,88	22	80,32	49,9	21,78	81,47	50,61	22,88
32	96,48	81,25	52,49	96	81,57	53,74	96,51	81,76	52,08	94,41	77,29	48,46	94,24	76,46	47,95
33	99,19	93,46	73,85	99,29	94,41	77,15	99,27	92,99	73,71	99,12	93,26	76,29	99,27	92,97	75,39
34	99,98	98,95	92,29	99,98	99,15	92,72	99,9	99,07	92,58	99,98	99,05	93,19	99,9	98,85	93,58
35	100	99,9	99,24	100	99,98	99,02	100	99,88	99,19	100	99,88	99,17	100	99,93	99,17
36	100	100	100	100	100	99,8	100	100	99,9	100	99,98	99,85	100	100	99,98
37,00-40,00	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100

Çizelge 5.3. (12x12) boyutlu görüntü bloklarının sınıflandırma sonuçları

PSNR	Lenna			Barbara			Peppers			Zelda			Baboon		
	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3
7,00-26,00	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
27	100	100	100	100	100	100	99,94	100	100	100	100	100	100	100	100
28	99,6	100	100	99,60	100	100	99,32	100	100	99,3	100	100	98,9	99,9	100
29	90,99	99,15	100	85,54	99,04	100	82,94	99	100	88,0	99,4	100	90,0	99,9	100
30	44,22	9,98	0,23	48,19	8,11	0,45	74,21	26,53	1,87	48,92	9,52	0,34	49,94	9,41	0,51
31	86,62	49,83	7,54	87,59	44,61	6,92	89,85	50,00	7,03	90,53	49,94	10,32	90,48	51,19	9,64
32	99,60	90,87	44,44	99,94	94,27	56,46	99,94	94,05	51,98	99,38	90,08	48,87	99,43	90,08	49,43
33	100	99,60	86,39	100,0	99,77	91,61	100	99,32	85,66	100	99,4	91,04	100	99,66	88,55
34	100	100	99,32	100	100	99,77	100	100	99,15	100	100	99,60	100	100	99,21
35,00-40,00	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100

Çizelge 5.4. (16x16) boyutlu görüntü bloklarının sınıflandırma sonuçları

PSNR	Lena			Barbara			Peppers			Zelda			Baboon		
	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3	Eşik Değeri 1	Eşik Değeri 2	Eşik Değeri 3
7,00-27,00	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
28	100	100	100	99,9	100	100	100	100	100	100	100	100	99,8	100	100
29	97,66	100	100	92,77	100	100	90,72	100	100	96,19	99,9	100	95,9	100	100
30	39,36	3,32	0	47,46	3,03	0	80,96	19,43	0,2	47,27	3,61	0	50,88	3,13	0
31	92,48	51,46	1,86	94,43	43,07	2,44	96,68	49,41	2,54	96,88	49,12	4,49	96,68	48,73	4,69
32	100	96,97	40,82	100	98,24	59,67	100	98,63	49,32	99,9	96,48	49,12	100	96,58	49,02
33	100	100	93,55	100	100	96,97	100	100	91,31	100	100	96,48	100	100	95,31
34	100	100	99,8	100	100	100	100	100	99,9	100	100	100	100	100	100
35,00-40,00	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100

Çizelge 5.1’de verilen PSNR değerlerine sahip temiz görüntü örnekleri kullanılarak, bu görüntülerin bloklarına ait eşik değerleri hesaplanmıştır. Bununla birlikte; Çizelge 5.2, Çizelge 5.3 ve Çizelge 5.4’te verilen PSNR değerlerine sahip görüntülerin blokları temiz/gürültülü sınıflandırmasında kullanılmıştır. Çizelge 5.2, Çizelge 5.3 ve Çizelge 5.4 karşılaştırıldığında Eşik Değeri 1’in en iyi temiz/gürültülü sınıflandırma sonucunu verdiği görülmektedir.

(16x16) boyutlu görüntü blokları kullanılarak yapılan sınıflandırmanın (8x8) ve (12x12) boyutlu görüntü blokları ile elde edilen sonuçlara göre daha iyi olduğu görülmektedir. Beş farklı görüntünün sınıflandırma sonuçlarının temiz/gürültülü geçiş noktası olan 30 PSNR dışında birbirine çok benzer olması da önerilen yöntemin tutarlı sonuçlar verdiğinin göstergesi olması açısından önemlidir. Test işlemine sokulan beş görüntünün farklı PSNR değerlerindeki bazı örnekleri Şekil 5.2 – Şekil 5.6 arası görüntülerde verilmiştir.



a

b

c

Şekil 5.2. Test edilen "Lenna" görüntüsünün farklı PSNR değerlerindeki örnekleri:
a) PSNR = 10,03 dB, b) PSNR = 14,98 dB, c) PSNR = 20,08 dB




a

b

c

Şekil 5.3. Test edilen "Barbara" görüntüsünün farklı PSNR değerlerindeki örnekleri:
a) PSNR = 10,13 dB, b) PSNR = 15,00 dB, c) PSNR = 20,13 dB



a

b

c

Şekil 5.4. Test edilen “Peppers” görüntüsünün farklı PSNR değerlerindeki örnekleri:
a) PSNR = 9,99 dB, b) PSNR = 15,06 dB, c) PSNR = 19,97 dB




a

b

c

Şekil 5.5. Test edilen “Zelda” görüntüsünün farklı PSNR değerlerindeki örnekleri:
a) PSNR = 10,10 dB, b) PSNR = 15,09 dB, c) PSNR = 20,17 dB




a

b

c

Şekil 5.6. Test edilen “Baboon” görüntüsünün farklı PSNR değerlerindeki örnekleri:
a) PSNR = 10,16 dB, b) PSNR = 15,05 dB, c) PSNR = 20,03 dB

Şekil 5.7'de, 29, 30 ve 31 dB PSNR değerleri için, 8x8 ve 16x16 boyutlu gürültülü blokları gösteren altı adet “Peppers” görüntüsü verilmiştir. Bu şekilden, gürültülü blokların görüntünün arka planında veya keskin geçiş noktalarında olup olmadığı görülmektedir.



Şekil 5.7. Gürültülü blokları gösteren “Peppers” görüntüleri:

- a) Blok boyutu = 8×8 , PSNR = 29 dB b) Blok boyutu = 8×8 , PSNR = 30 dB
 c) Blok boyutu = 8×8 , PSNR = 30 dB d) Blok boyutu = 16×16 , PSNR = 29 dB
 e) Blok boyutu = 16×16 , PSNR = 30 dB f) Blok boyutu = 16×16 , PSNR = 31 dB

5.2. Eğitim Setinde Çoklu Sayıda Görüntü Kullanılarak Yapılan Deneysel Çalışma

Deneysel çalışmada 512×512 piksel boyutunda gri seviyeli ”Lenna”, ”Zelda” ve ”Peppers” görüntüleri kullanılmıştır. Üç görüntünün her biri için, Çizelge 5.1’de PSNR değerleri verilmiş olan 40 farklı görüntü örneğinin ortalaması alınmıştır ve ortaya çıkan üç görüntü eğitim setinin oluşturulmasında kullanılmıştır. Bu üç görüntü, PSNR değerleri ile birlikte Şekil 5.8’de verilmiştir.



a

b

c

Şekil 5.8. Eğitim setinde kullanılan görüntüler ve PSNR değerleri:

- a) "Lenna" görüntüsü, PSNR = 50,66 dB b) "Zelda" görüntüsü, PSNR = 50,67 dB
c) "Peppers" görüntüsü, PSNR = 50,65 dB

Eğitim seti, "Lenna" görüntüsünden elde edilen 16x16 boyutundaki 1024 bloğun her birinin, 16x16 boyutundaki "Lenna", "Zelda" ve "Peppers" görüntü bloklarıyla karşılaştırılması ve en yakın (Öklid uzaklığı en düşük olan) 240 görüntü bloğunun alınmasıyla oluşturulmuştur. Bu durumda, her biri 240 görüntü bloğundan oluşan 1024 sınıf vardır. Önerilen yöntem, her seferinde 40 görüntü bloğunun dışarıda bırakılması ile ($m = 200$) altı adımda uygulanmış ve her bir sınıf için bir eşik değeri belirlenmiştir. Bulunan 240 uzaklıktan en büyüğü eşik değeri olarak alınmıştır.

"Lenna", "Zelda" ve "Peppers" görüntülerinin her biri için; orijinal görüntüye sıfır ortalama değerli "Gauss" gürültüsü eklemek suretiyle PSNR değeri 25 ile 35 arasında değişen 11 adet görüntü elde edilmiştir. Bu görüntüler, önerilen yöntemde belirlenen eşik değeri kullanılarak üç farklı şekilde gürültülü/temiz olarak test edilmiştir. Birinci testte, önerilen yöntem test edilecek görüntü bloğuna doğrudan uygulanmıştır, yani, test edilecek bloğun hangi hangi blok olduğu bilinip o bloğun eşik değeri kullanılmıştır. İkinci testte; test edilecek görüntü bloğu ile "Lenna" görüntüsünün 1024 adet görüntü bloğu arasındaki Öklid uzaklığı hesaplanır ve önerilen yöntem, en düşük uzaklığın bulunduğu sınıfa (görüntü bloğuna) ait eşik değeri kullanılarak uygulanır. Üçüncü testte, eğitim setindeki 1024 sınıfın her biri için, o sınıfta bulunan 240 görüntü bloğunun ortalamasına karşılık gelen vektör bulunur. Test edilecek görüntü bloğu ile bulunan 1024 adet ortalama vektörü arasındaki Öklid uzaklığı hesaplanır ve önerilen yöntem, en düşük uzaklığın bulunduğu sınıfa (görüntü

bloğuna) ait eşik değeri kullanılarak uygulanır. Bu üç farklı teste dair sonuçlar Çizelge 5.5, Çizelge 5.6 ve Çizelge 5.7’de verilmiştir.

Çizelge 5.5. Önerilen yöntemin test bloğuna doğrudan uygulanması sonucu elde edilen sınıflandırma sonuçları

PSNR	Lenna	Zelda	Peppers
25	97,95	95,12	96,39
26	94,53	90,53	93,55
27	91,80	83,89	87,89
28	84,67	75,10	83,01
29	72,66	65,92	74,51
30	44,43	44,92	35,94
31	63,77	60,64	39,16
32	80,76	72,46	49,41
33	87,70	81,35	54,10
34	90,04	87,30	59,77
34	93,16	88,18	64,36
ORTALAMA	81,95	76,86	67,10

Çizelge 5.6. Test bloğunun en benzer olduğu “Lenna” görüntü bloğunun belirlenmesi sonrası elde edilen sınıflandırma sonuçları

PSNR	Lenna	Zelda	Peppers
25	97,95	98,73	98,14
26	94,53	96,97	96,19
27	91,80	93,16	92,77
28	84,67	85,84	86,91
29	72,75	74,51	72,27
30	44,24	47,95	48,63
31	63,77	71,00	56,45
32	80,76	84,57	71,39
33	87,70	90,23	76,37
34	90,04	92,09	80,27
34	93,16	92,58	82,81
ORTALAMA	81,94	84,33	78,38

Çizelge 5.7. Test bloğunun en benzer olduğu ortalama vektörünün belirlenmesi sonrası elde edilen sınıflandırma sonuçları

PSNR	Lenna	Zelda	Peppers
25	87,11	82,81	90,92
26	80,76	69,82	79,88
27	65,63	56,84	71,78
28	56,54	40,53	59,08
29	43,65	30,08	41,89
30	69,73	81,93	72,46
31	83,01	91,89	79,49
32	91,80	96,48	87,01
33	95,41	98,05	88,09
34	96,97	98,83	90,72
34	97,56	98,83	91,80
ORTALAMA	78,92	76,92	77,56

Çizelge 5.6’da verilen sonuçların diğer sonuçlara kıyasla daha iyi olduğu görülmektedir. Bu çalışmada, görüntü bloklarının boyutunun (256x1) olması ve OVY’nin yetersiz veri durumunun kullanılmasından dolayı sınıflardaki görüntü bloğu sayısı 240 olarak belirlendi. Bu sonuçlardan; daha fazla görüntüden daha fazla görüntü bloğu alınarak oluşturulan eğitim seti kullanılarak eşik değerinin belirlenmesi durumunda, herhangi bir görüntünün bloklarının büyük oranda doğru bir şekilde gürültülü/temiz olarak sınıflandırılabilceği sonucu çıkarılabilir.

5.3. “Lenna” Görüntüsünün Döndürülmüş Örnekleriyle Yapılan Deneysel Çalışmalar

512x512 piksel boyutlarında “Lenna” görüntüleri içeren sekiz farklı görüntü grubu oluşturulmuştur. Her grupta yer alan görüntülerin PSNR değerleri farklıdır. Görüntü gruplarına “Lenna” görüntüsünün döndürülmüş örnekleri de eklenmiştir. Gruplarda yer alan görüntülerin PSNR değerleri ve döndürme açıları Çizelge 5.8’de verilmiştir.

Çizelge 5.8. Döndürülmüş “Lenna” görüntülerinden oluşan gruplar

	Grup-1	Grup-2	Grup-3	Grup-4	Grup-5	Grup-6	Grup-7	Grup-8
PSNR	30.46	35.08	40.4	45.05	50.34	55.18	60.09	65.02
Görüntü-1	0°	0°	0°	0°	0°	0°	0°	0°
Görüntü-2	-3°	-3°	-3°	-3°	-3°	-3°	-3°	-3°
Görüntü-3	3°	3°	3°	3°	3°	3°	3°	3°
Görüntü-4	-5°	-5°	-5°	-5°	-5°	-5°	-5°	-5°
Görüntü-5	5°	5°	5°	5°	5°	5°	5°	5°

Önerilen yöntem, $m = 40$, $l = 5$ ve $k = 8$ parametreleri kullanılarak uygulanmıştır. Her bir görüntü bloğu için bulunan en büyük değer, eşik değeri olarak belirlenmiştir. “Lenna” görüntüsünün farklı açılarda döndürülmüş örnekleri Şekil 5.9’da verilmiştir.



Şekil 5.9. Farklı açılarda döndürülmüş Lenna görüntüleri:
a) 0°, b) -3°, c) 3°, d) -5°, e) 5°

Farklı açılarda döndürülmüş her bir “Lenna” görüntüsü için 7 ile 40 arasında PSNR değere sahip test görüntüleri oluşturulmuştur. Bu görüntüler, her görüntünün temiz örneğine (orijinal görüntüye) sıfır ortalamalı Gauss gürültüsünün Matlab ortamında eklenmesi yoluyla elde edilmiştir. Test görüntüleri önerilen yöntemle göre test edilmiştir ve sınıflandırma sonuçları Çizelge 5.9’da verilmiştir.

Çizelge 5.9. Farklı açılarda döndürülmüş “Lenna” görüntülerinin sınıflandırma sonuçları

PSNR	-5° Rotated	-3° Rotated	Not Rotated	3° Rotated	5° Rotated
7	97,19	98,68	100	98,68	97,19
8	97,24	98,73	100	98,68	97,17
9	97,19	98,66	100	98,61	97,19
10	97,14	98,61	100	98,61	97,14
11	97,19	98,66	100	98,58	97,14
12	97,14	98,63	100	98,63	97,14
13	97,12	98,63	100	98,61	97,14
14	97,09	98,56	100	98,56	97,09
15	97,05	98,54	100	98,58	97,07
16	97	98,51	100	98,54	97,07
17	97	98,54	100	98,51	97
18	97,05	98,46	100	98,54	96,92
19	96,97	98,34	100	98,44	96,92
20	96,85	98,41	100	98,39	96,85
21	96,78	98,34	100	98,39	96,83
22	96,68	98,29	100	98,19	96,66
23	96,51	98,1	100	98,24	96,66
24	96,53	98,05	99,95	97,97	96,22
25	95,92	97,61	99,88	97,53	95,97
26	94,65	96,04	98,61	96,26	94,73
27	88,18	89,58	92,46	89,97	88,28
28	78,88	80,44	83,01	79,47	79,64
29	48,12	49,1	50,66	49,98	48
30	73,71	72,83	72,29	74	74,54
31	91,7	90,87	91,43	91,31	91,92
32	98,66	98,71	98,73	98,63	98,34
33	99,93	99,93	99,83	99,98	99,9
34	100	100	100	100	100
35	100	100	100	100	100
36	100	100	100	100	100
37	100	100	100	100	100
38	100	100	100	100	100
39	100	100	100	100	100
40	100	100	100	100	100

Çizelge 5.9'daki sınıflandırma sonuçlarından görüldüğü üzere; önerilen yöntem, görüntünün farklı açılarda döndürülmüş örneklerinin eğitim setinde kullanılması durumunda da olumlu sonuçlar vermektedir.

5.4. Görüntü Temizleme İşlemi

Her görüntü, kalitesini olumsuz yönde etkileyen çeşitli seviyelerde istenmeyen gürültü içerir ve bu gürültünün görüntü kullanılmadan veya analiz edilmeden önce temizlenmesi gerekir. Görüntü temizlemede, gürültünün bastırılması ve görüntü detaylarının korunması arasında ters orantı vardır. (Kaur ve Singh, 2014). Son yıllarda, Görüntü detaylarında en az kayıpla temizleme yapılması amacıyla çok fazla çalışma yürütülmüş ve birçok algoritma geliştirilmiştir. Bu çalışmada, önerilen yöntemde kullanılan görüntülere beş farklı görüntü temizleme algoritması uygulanmış ve performansları değerlendirilmiştir. Performans değerlendirmesi, görüntünün temizleme işleminden önceki ve sonraki PSNR değerleri karşılaştırılarak yapılmıştır. Uygulanan görüntü temizleme algoritmaları aşağıda başlıklar altında açıklanmıştır.

5.3.1. Medyan filtreleme

Medyan filtre, bir görüntüdeki olağan dışı (outlier) pikselleri bastırmak için yaygın olarak kullanılan doğrusal olmayan bir filtredir. Medyan filtre, temizleme işlemine sokulan görüntüdeki keskin geçişlere zarar vermez iken, ince çizgilerin ve köşelerin yok olmasına sebep olmaktadır. (Ko ve Lee, 1991). Temizleme işlemi, her bir pikselin değerinin belirli bir komşulukta bulunan piksellerin medyan değeri ile değiştirilmesinden ibarettir. Komşuluk piksellerinin sayısı, her bir piksel üzerinden geçecek şekilde görüntü üzerinde gezdirilen pencerenin boyutu ile belirlenir. Pencerenin boyutu 3x3, 5x5 veya 7x7 gibi tek sayılardan seçilir ve işleme sokulan piksel bu pencerenin orta noktasındadır.

5.3.2. “Wiener” filtreleme

“Wiener” filtreleme, görüntüdeki gürültü bileşenlerinin yok edilmesi için görüntünün istatistiksel özelliklerinden yararlanan doğrusal bir temizleme yöntemidir. (Lim, 1990).

Wiener filtrelemede, her pikselin komşuluğundaki yerel ortalama (local mean) ve varyans hesaplaması yapılır. Gürültülü bir görüntünün $n(x, y)$ olarak ve bu gürültülü görüntünün $M \times N$ boyutundaki yerel komşuluk penceresinin W olarak tanımlandığını varsayalım. Bu durumda, yerel komşuluk penceresinin ortalama (μ) ve varyans (σ^2) değerleri şu şekilde hesaplanır:

$$\mu = \frac{1}{MN} \sum_{x,y \in W} n(x, y) \quad (5.1)$$

$$\sigma^2 = \frac{1}{MN} \sum_{x,y \in W} n^2(x, y) - \mu^2 \quad (5.2)$$

$s(x, y)$ olarak ifade edilen temizleme işleminden geçirilmiş görüntünün yakınsanması aşağıdaki şekilde formüle edilir. Formüldeki v^2 , gürültünün varyansıdır. Eğer gürültünün varyansı bilinmiyorsa, hesaplanan tüm yerel varyansların ortalaması gürültünün varyansı olarak ele alınır.

$$s(x, y) = \mu + \frac{\sigma^2 - v^2}{\sigma^2} (n(x, y) - \mu) \quad (5.3)$$

Keskin geçişlerin ve yüksek frekanslı bileşenlerin korunması, “Wiener” filtrelemenin avantajıdır.

5.3.3. “Bilateral” filtreleme

“Bilateral” filtreleme, piksellerin yerel bir komşuluktaki ağırlıklı ortalamalarının alınmasına dayanan, tekrarlamayan (non-iterative) bir temizleme yöntemidir. (Tomasi ve Manduchi, 1998; Zhang ve Gunturk, 2008). Bu temizleme yönteminde, görüntüdeki keskin geçişler korunur. Komşuluk sınırları içerisindeki piksellerin yakınlıklarına (closeness) ve benzerliklerine dayanan iki ağırlık fonksiyonu kullanılır. x , bir pikselin yerini ve $I(x)$, o

pikselin o noktadaki koyuluğunu gösterebilir. Ağırlık fonksiyonlarının “Gaussian” olduğu varsayımı ile “Bilateral” filtrenin x komşuluğundaki çıkışı şu şekilde ifade edilir:

$$BF(x) = \frac{1}{C} \sum_{y \in N(x)} e^{-\frac{\|y-x\|^2}{2\sigma_d^2}} e^{-\frac{|I(y)-I(x)|}{2\sigma_r^2}} I(y) \quad (5.4)$$

$$C = \sum_{y \in N(x)} e^{-\frac{\|y-x\|^2}{2\sigma_d^2}} e^{-\frac{|I(y)-I(x)|}{2\sigma_r^2}} \quad (5.5)$$

İfadedeki σ_d ve σ_r , sırasıyla uzaysal ve koyuluk bölgelerini karakterize eden ölçeklendirme (scaling) parametreleridir. C , normalizasyon sabitidir ve $N(x)$, x pikselinin yerel komşuluğudur.

Ölçeklendirme parametrelerinin değeri, “Bilateral” filtrelemenin performansında büyük rol oynar. Zhang ve Gunturk (2008), σ_d değerinin 1.5 seçildiği durumda, $\frac{\sigma_d}{\sigma_n}$ oranının optimum değerinin 3 civarında olması gerektiğini belirtmişlerdir. σ_n , görüntüdeki “Gauss” gürültüsünün standart sapma değeridir. Papari vd. (2017), “Bilateral” filtrelemenin hesaplama yükünü azaltmak için çalışmalar yapmıştır.

5.3.4. Non-local means (NLM) filtreleme

NLM filtreleme, Buades vd. (2005) tarafından geliştirilmiş bir temizleme yöntemidir. Bir görüntünün blokları arasındaki benzerliklerin belirlenmesi ilkesine dayanır. Görüntünün keskin kenarlarının ve yapısal özelliklerinin korunmasını sağlamasından dolayı literatürdeki popüler temizleme yöntemlerinden biridir.

N_i ve N_j sırasıyla i ve j piksellerinin komşuluklarını gösterebilir. Verilen bir gürültülü V görüntüsünün NLM çıktısı şu şekilde verilir:

$$NL(i) = \frac{\sum_{j \in V} w(i, j) V(j)}{\sum_{j \in V} w(i, j)} \quad (5.6)$$

Burada $w(i, j)$, sabit boyutlu N_i ve N_j blokları arasındaki benzerliğe dayanır ve şu şekilde ifade edilir:

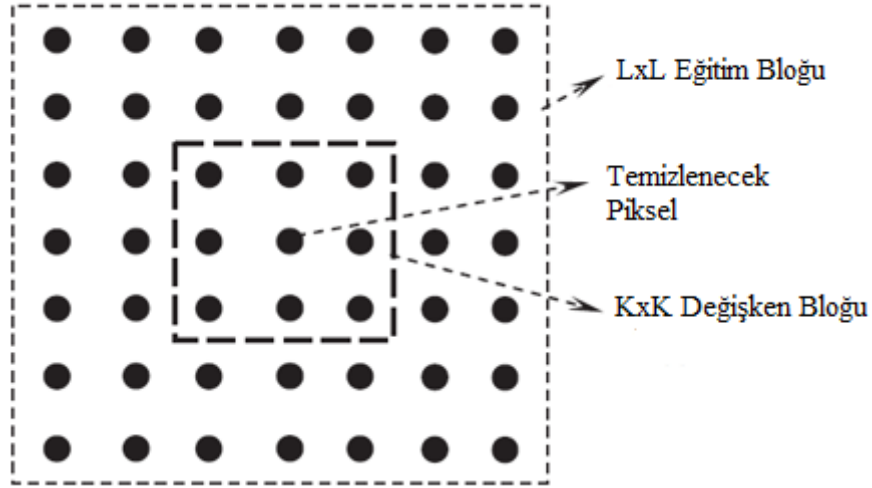
$$w(i, j) = e^{-\frac{\|V(N_i) - V(N_j)\|_{2, \alpha}^2}{h^2}} \quad (5.7)$$

$V(N_i)$ ve $V(N_j)$ sırasıyla i ve j piksellerinin komşuluklarının piksel değerlerini gösterirken, h parametresi de filtreleme derecesini gösterir. Öklid uzaklığı ile bloklar arasındaki benzerliklerin derecesi ölçülmektedir. “Gaussian” kernelin standart sapması da, α ile gösterilmektedir.

NLM filtrelemenin de “Bilateral” filtrelemede olduğu gibi yüksek hesaplama yükü vardır. Literatürde NLM filtrelemenin işlem zamanını kısaltmaya yönelik çalışmalar vardır (Huang vd., 2017; Liu ve Wu, 2016).

5.3.5. Principal Component Analysis (PCA) ve lokal pixel grouping (LPG) ile filtreleme

PCA ve LPG filtreleme, Zhang vd. (2010) tarafından öne sürülen bir görüntü temizleme yöntemidir. PCA, görüntünün belli bir bölgesinde öne çıkan bileşenlerin kullanılmasına dayanır. $K \times K$ boyutlarındaki pencere, temizleme işlemi yapılacak pikseli orta noktasına alacak şekilde oluşturulur. Arama alanı $L \times L$ boyutlarındadır ($L > K$). Arama alanındaki tüm $K \times K$ boyutundaki bloklar vektör olarak ifade edilir ve eğitim örnekleri birbirine benzeyen bloklardan seçilir. Birbirine benzeyen görüntülerin eğitim setinde kullanılmasından dolayı görüntünün keskin kenarları ve yapısal özellikleri temizleme işlemi sonunda korunmuş olur. Yöntem, daha iyi sonuç alabilmek için iki kere uygulanmaktadır. PCA-LPG gürültü temizleme şeması Şekil 5.10’da verilmiştir.



Şekil 5.10. PCA-LPG gürültü temizleme şeması

5.3.6. Temizleme sonuçları

Önerilen yöntemin deneysel çalışmalarında kullanılan bazı görüntülere 5 farklı temizleme yöntemi uygulanmıştır. Temizleme yöntemlerinin performansı, işleme sokulan görüntünün öncesi ve sonrası PSNR değerleri karşılaştırılarak ölçülmüştür. Sonuçlar, Çizelge 5.10'da verilmiştir. En iyi temizleme sonuçlarını ifade eden koyu yazılmış PSNR değerleri PCA-LPG yöntemine aittir.

Çizelge 5.10. Temizleme yöntemlerinin sonuçları

İlk PSNR	Temizleme işleminden sonraki PSNR				
	Non Local	Bilateral	PCA-LPG	Wiener	Median
12,57	26,01	24,58	27,2	20,59	20,22
14,15	27,06	25,44	28,28	21,9	21,7
16,09	28,34	26,59	29,53	23,61	23,5
18,03	29,63	27,69	30,73	25,39	25,27
20,17	31,02	28,9	32,02	27,37	27,15
22,11	32,23	30	33,15	29,16	28,77
24,05	33,41	31,1	34,22	30,89	30,27
26,55	34,85	32,55	35,51	32,98	31,99
28,13	35,7	33,48	36,29	34,14	32,94
30,07	36,67	34,61	37,19	35,37	33,94
32,57	37,76	36,09	38,32	36,61	34,96
34,15	38,36	37,01	39,01	37,23	35,46

Görsel analize (Subjektif analiz) göre de görüntüdeki keskin geçişler ve yapısal özelliklerin korunumu diğer yöntemlerle kıyaslandığında PCA-LPG yönteminde daha fazladır. Temizlenmiş bazı görüntüler aşağıdaki şekillerde verilmiştir.



Şekil 5.11. Beş farklı yöntemle temizlenen “Lenna” görüntüleri:

- a) 12,57 dB PSNR değerli görüntü, b) Medyan filtreleme, c) “Wiener” filtreleme, d) “Bilateral” filtreleme, e) NLM filtreleme, f) PCA-LPG filtreleme



Şekil 5.12. Beş farklı yöntemle temizlenen “Lenna” görüntüleri:
a) 20,17 dB PSNR değerli görüntü, b) Medyan filtreleme, c) “Wiener” filtreleme,
d) “Bilateral” filtreleme, e) NLM filtreleme, f) PCA-LPG filtreleme



Şekil 5.13. Beş farklı yöntemle temizlenen “Lenna” görüntüleri:
a) 24,05 dB PSNR değerli görüntü, b) Medyan filtreleme, c) “Wiener” filtreleme,
d) “Bilateral” filtreleme, e) NLM filtreleme, f) PCA-LPG filtreleme



Şekil 5.14. Beş farklı yöntemle temizlenen “Lenna” görüntüleri:
 a) 28,13 dB PSNR değerli görüntü, b) Medyan filtreleme, c) “Wiener” filtreleme,
 d) “Bilateral” filtreleme, e) NLM filtreleme, f) PCA-LPG filtreleme

Görüntü bloklarının temiz/gürültülü olarak sınıflandırılması işleminde geçen zaman 8x8, 12x12 ve 16x16 boyutlu bloklar için Çizelge 5.11’de verilmiştir. Gürültülü görüntü bloklarının önerilen yöntem ile tespit edilmesinden sonra, tüm görüntünün temizleme işlemine sokulması yerine sadece gürültülü bloklar temizleme işlemine sokulmuştur. Böylece, NLM ve PCA-LPG gibi yöntemlerde daha hızlı işlem süresi elde edilmiştir. Beş farklı yönteme ait işlem süreleri Çizelge 5.12’de verilmiştir.

Çizelge 5.11. Farklı boyutlardaki görüntü bloklarının sınıflandırmasında geçen süre

Blok boyutu	Toplam blok sayısı	Toplam geçen zaman (sn.)
8x8	4096	195.5
12x12	1820	255.9
16x16	1024	370.5

Çizelge 5.12. Blok tabanlı ve tüm görüntünün temizlenmesinde geçen süre (saniye)

Temizleme yöntemi	Blok tabanlı temizlemede geçen zaman	Tüm görüntünün temizlenmesinde geçen zaman
Median	2,76	0,53
Wiener	13,31	0,46
Bilateral	9,67	15,62
Non Local Means	1396,32	2909
PCA-LPG	837,5	1333,5

PSNR değeri 30 civarında olan 3 farklı “Lenna” görüntüsüne hem NLM hem de PCA-LPG yöntemleri kullanılarak blok tabanlı temizleme ve tüm görüntünün temizlenmesi gerçekleştirilmiştir. Görüntülerin PSNR değerlerindeki iyileşme Çizelge 5.13’te verilmiştir.

Çizelge 5.13. Görüntü temizleme sonrası PSNR karşılaştırması (PSNR birimi = dB)

Görüntü #	İlk PSNR	Non-Local Means		PCA-LPG	
		Tüm görüntünün temizlenmesi sonrası PSNR	Blok tabanlı temizleme sonrası PSNR	Tüm görüntünün temizlenmesi sonrası PSNR	Blok tabanlı temizleme sonrası PSNR
1	30	34,94	31,57	36,92	32,65
2	29,99	34,94	31,63	36,92	32,75
3	29,98	34,9	31,64	36,9	32,8

Blok tabanlı temizlemede elde edilen PSNR iyileştirmesi tüm görüntünün temizlenmesinde elde edilen iyileşmeye nazaran daha az olsa da, işlem zamanı göz önünde bulundurulduğunda önerilen yöntem daha avantajlıdır.

6. SONUÇ VE ÖNERİLER

Bu tezde, bir görüntünün OVY yardımı ile blok tabanlı olarak gürültülü/temiz sınıflandırılması önerilmiştir. Eğer bir görüntünün temiz olarak nitelenen örnekleri var ise, bu görüntünün özellikleri bilinmeyen bir örneğinin gürültülü/temiz sınıflandırmasının blok tabanlı yapılabileceği gösterilmiştir. Böylece; sadece gürültülü olarak sınıflandırılan görüntü blokları temizleme işlemine sokularak temizleme işleminin hızlandırılması sağlanır.

Görüntünün temiz olarak nitelenen örneklerinden bir eğitim seti oluşturulmuştur. Görüntünün temiz örneklerinin PSNR değerinin 30 ve üzeri olduğu varsayılmıştır. Blok tabanlı gürültülü/temiz sınıflandırmada kullanılan eşik değeri, OVY'nin bu eğitim setine uygulanması yoluyla elde edilir. Farklı PSNR değerinde birçok görüntü, her bir görüntü bloğu için belirlenen eşik değerleri kullanılarak test edilmiştir. Deneysel sonuçlara göre, 28 ve altı PSNR değere sahip görüntülerin hemen hemen tüm görüntü blokları gürültülü olarak sınıflandırılırken, 32 ve üzeri PSNR değere sahip görüntülerin hemen hemen tüm görüntü blokları temiz olarak sınıflandırılmıştır. 28 ila 32 PSNR değere sahip görüntülerin test sonuçları incelendiğinde en kötü sonuçların 30 PSNR değere sahip görüntülerin sınıflandırmasında olduğu görülmektedir. Bu durumun sebebi, 30 PSNR değerinin gürültülü/temiz geçiş noktası olmasıdır. Tüm bu sonuçlar değerlendirildiğinde, önerilen yöntemin görüntü bloklarının gürültülü/temiz ayrımını etkin bir şekilde yaptığı görülmektedir.

Önerilen yöntemin uygulanması sonucunda gürültülü olarak belirlenen bazı görüntülere beş farklı popüler görüntü temizleme algoritması uygulanmış ve bu algoritmaların başarısı karşılaştırılmıştır. Algoritmaların başarısı, temizleme işlemine sokulan görüntülerin ilk PSNR değerleri ve temizleme işleminden sonraki PSNR değerlerinin karşılaştırılması yoluyla belirlenmiştir. En iyi PSNR sonuçları PCA-LPG filtreleme yönteminde elde edilmiştir.

Önerilen yöntem, görüntülerin gürültülü/temiz olarak sınıflandırılmasına yeni bir bakış açısı getirmektedir. Bu yöntemin kullanılması ile görüntünün tamamının temizleme işleminde sokulması yerine sadece gürültülü görüntü blokları temizleme işlemine sokulabilir

ve temizleme süresi kısaltılır. Temizleme işlemine sokulan görüntü blokları, ana görüntünün çeşitli gürültü kaynaklarından etkilenmiş bir bölümü olarak düşünülebilir. Görüntünün döndürülmüş örneklerinin eğitim setinde kullanılması ile yapılan deneysel çalışmaların sonuçları da tatmin edici düzeydedir.

Gelecekteki çalışmalarda, gürültülü görüntü blokları eğitim setine dahil edilerek daha güvenilir eşik değerleri belirlenebilir. Bu sayede görüntü bloklarının gürültülü/temiz sınıflandırılmasında performansı daha yüksek sonuçlar elde edilebilir. Gelecekte üzerinde çalışılabilecek bir diğer konu, önerilen yöntemin PSNR dışında başka bir görüntü kalitesi belirleme yolu olan yapısal benzerlik ölçütüne de Structural similarity index measure (SSIM) uygulanabilirliğinin araştırılmasıdır.

KAYNAKLAR DİZİNİ

- Amer, A., Dubois, E., 2005, Fast and reliable structure-oriented video noise estimation, *IEEE Transactions on Circuits and Systems for Video Technology*, 15, 1, 113-118.
- Avcibas, I., Sankur, B., Sayood, K., 2002, Statistical evaluation of image quality measures, *Journal of Electronic Imaging*, 11, 2, 206-223.
- Bovik, A. C., 2010, *Handbook of image and video processing*, Academic press.
- Boyat, A. K., Joshi, B. K., 2015, A review paper: noise models in digital image processing, *Signal and Image Processing*, 6, 2, 63.
- Buades, A., Coll, B., Morel, J. M., 2005, A non-local algorithm for image denoising, *IEEE Computer Society Conference*, Vol. 2, p. 60-65.
- Bystrom, M., Modestino, J. W., 2000, Combined source-channel coding schemes for video transmission over an additive white Gaussian noise channel, *IEEE Journal on Selected Areas in Communications*, 8.6: 880-890.
- Chan, R. H., Ho, C-W., Nikolova, M., 2005, Salt-and-pepper noise removal by median-type noise detectors and detail-preserving regularization, *IEEE Transactions on Image Processing*, 14, 10, 1479-1485.
- Chang, S. G., Yu, B., Vetterli, M., 2000, Spatially adaptive wavelet thresholding with context modeling for image denoising, *IEEE Transactions on image Processing*, 9, 9, 1522-1531.
- Çevikalp, H., Neamtu, M., Wilkes, M., 2006, Discriminative common vector method with kernels, *IEEE Transactions on Neural Networks*, 17, 6, 1550-1565.
- Deledalle, C-A., Tupin, F., Denis, L., 2010, Poisson NL means: Unsupervised non local means for Poisson noise, 17th IEEE international conference on Image Processing.
- Dewangan, S. K., 2016, Importance & applications of digital image processing, *International Journal of Computer Science & Engineering Technology (IJCSET)*, 7, 7, 316-320.
- Donoho, D. L., 1995, De-noising by soft-thresholding, *IEEE Transactions on Information Theory*, 41, 3, 613-627.
- Dorigo, M., Birattari, M., Stutzle, T., Ant colony optimization, *IEEE Computational Intelligence Magazine*, 1, 4, 28-39.
- Dougherty, G., 2009, *Digital image processing for medical applications*, Cambridge University Press.
- Eskicioğlu, A. M., Fisher, P. S., 1995, Image quality measures and their performance, *IEEE Transactions on communications*, 43, 12, 2959-2965.

KAYNAKLAR DİZİNİ (devam)

- Gao, B-C., 1993, An operational method for estimating signal to noise ratios from data acquired with imaging spectrometers, *Remote Sensing of Environment* 43, 1, 23-33.
- Garg, R., Kumar, A., 2012, Comparison of various noise removals using Bayesian framework, *International Journal of Modern Engineering Research*, 2, 1, 265-270.
- Gonzalez, R. C., Woods, R. E., 2009, *Digital image processing*, Prentice Hall.
- Gülmezoğlu, M. B., Dzhafarov, V., Keskin, M., Barkana, A., 1999, A novel approach to isolated word recognition, *IEEE Transactions on Speech and Audio Processing*, 7, 6, 620-628.
- Gulmezoğlu, M. B., Dzhafarov, V., Barkana, A., 2001, The common vector approach and its relation to principal component analysis, *IEEE Transactions on Speech and Audio Processing*, 9, 6, 655-662.
- Gülmezoğlu, 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, 266-281.
- Hamd, M. H., 2014, Auto detection and removal of frequency domain periodic noise, *Computer & Information Technology Global Summit on IEEE*.
- Hashemi, M., Beheshti, S., 2010, Adaptive noise variance estimation in BayesShrink, *IEEE Signal Processing Letters*, 17, 1, 12-15.
- Hore, A., Ziou, D., 2010, Image quality metrics: PSNR vs. SSIM, *International Conference on Pattern recognition*, IEEE, 2366-2369.
- Huang, F., Lan, B., Tao, J., Chen, Y., Tan, X., vd., 2017, A parallel nonlocal means algorithm for remote sensing image denoising on an Intel Xeon Phi platform, *IEEE Access*.
- Ikeda, M., Makino, R., Imai, K., Matsumoto, M., Hitomi, R., 2010, A method for estimating noise variance of CT image, *Computerized Medical Imaging and Graphics*, 34, 8, 642-650.
- Immerkaer, J., 1996, Fast noise variance estimation, *Computer Vision and Image Understanding*, 64, 2, 300-302.
- Jafri, R., Arabnia, H. R., 2009, A survey of face recognition techniques, *Journal of Information Processing Systems*, 5, 2, 41-68.
- Kamavisdar, P., Saluja, S., Agrawal, S., 2013, A survey on image classification approaches and techniques, *International Journal of Advanced Research in Computer and Communication Engineering*, 2, 1, 1005-1009.

KAYNAKLAR DİZİNİ (devam)

- Kaur, S., Singh, N., 2014, Image denoising techniques a review, *International Journal of Innovative Research in Computer and Communication Engineering*, Vol. 2, Issue 6.
- Ko, S-J., Lee, Y. H., 1991, Center weighted median filters and their applications to image enhancement, *IEEE Transactions on Circuits and Systems*, 38, 9, 984-993.
- Kowalski, J. P., Peksinski, J., Mikolajczak G., 2013, Detection of noise in digital images by using the averaging filter name COV, *Asian Conference on Intelligent Information and Database Systems*, 1-8.
- Krishnan, M. H., Viswanathan, R., 2013, A new concept of reduction of Gaussian noise in images based on fuzzy logic, *Applied Mathematical Sciences*, 7(12), 595-602.
- Lim, J. S., 1990, *Two-dimensional signal and image processing*, Englewood Cliffs, NJ, Prentice Hall, p. 710.
- Liu, W., Lin, W., 2013, Additive white Gaussian noise level estimation in SVD domain for images, *IEEE Transactions on Image processing*, 22, 3, 872-883.
- Liu, W., Wu, S., 2016, Superpixels-based non-local means image denoising, *11th Conference on industrial Electronics and Applications*, IEEE, 673-677.
- Mikolajczak, G., Peksinski, J., 2016, Estimation of the variance of noise in digital images using a median filter, *Telecommunications and Signal Processing, 39th International Conference on IEEE*.
- Nodes, T. A., Gallagher N.C., 1982, Median filters: Some modifications and their properties, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 30, 5, 739-746.
- Olsen, S. I., 1993, Estimation of noise in images: An evaluation, *CVGIP: Graphical Models and Image Processing* 55, 4, 319-323.
- Papari, G., Idowu, N., Varslot, T., 2017, Fast bilateral filtering for denoising large 3D images, *IEEE Transactions on Image Processing*, 26, 1, 251-261.
- Pitas, I., Venetsanopoulos, A. N., 2013, *Nonlinear digital filters: principles and applications*, Springer Science & Business Media, Vol.84.
- Pratt, W. K., 2001, *Digital image processing*, Wiley.
- Rabbani, H., Vafadust, M., Abolmaesumi, P., Gazor, S., 2008, Speckle noise reduction of medical ultrasound images in complex wavelet domain using mixture priors, *IEEE Transactions on Biomedical Engineering*, 55, 9, 2152-2160.

KAYNAKLAR DİZİNİ (devam)

- Rank, K., Lendl, M., Unbehauen, R., 1999, Estimation of image noise variance, IEE Proceedings-Vision, Image and Signal Processing, 146, 2, 80-84.
- Russo, F., 2007, Gaussian noise estimation in digital images using nonlinear sharpening and genetic optimization, Instrumentation and Measurement Technology Conference Proceedings, IEEE.
- Russo, F., 2006, Image enhancement based on noise estimation, Instrumentation and Measurement Technology Conference, Proceedings of the IEEE.
- Silpa, K., Mastani, S. A., 2012, Comparison of image quality metrics, International Journal Engineering Research and Technology, 1, 4.
- Tao, Z., Tagare, H. D., Beaty, J. D., 2006, Evaluation of four probability distribution models for speckle in clinical cardiac ultrasound images, IEEE Transactions on Medical Imaging, 25, 11, 1483-1491.
- Tian, J., Chen, L., 2012, Image noise estimation using a variation-adaptive evolutionary approach, *IEEE Signal Processing Letters*, 19, 7, 395-398.
- Tomasi, C., Manduchi, R., 1998, Bilateral filtering for gray and color images, Sixth International Conference on Computer Vision, IEEE, 839-846.
- Turajlic, E., Skaljo, N., Begovic A., 2017, A block-based noise level estimation from X-ray images in SVD domain, International Conference on Systems, Signals and Image Processing, IEEE.
- Umbaugh, S. E., 2016, Digital image processing and analysis: human and computer vision applications with CVIptools, CRC press.
- Zaitoun, N. M., Aqel, M. J., 2015, Survey on image segmentation techniques, Procedia Computer Science, 65, 797-806.
- Zhang, L., Dong, W., Zhang, D., Shi, G., 2010, Two-stage image denoising by principal component analysis with local pixel grouping, Pattern Recognition, 43, 4, 1531-1549.
- Zhang, M., Gunturk, B. K., 2008, A new image denoising framework based on bilateral filter, Visual Communications and Image Processing, 6822, 68221B.

EK AÇIKLAMALAR

Ek Açıklama-A: Özvektörlerin Bulunmasına Yönelik Kaynak Kod

Ek Açıklama-B: Ortak Vektörlerin Bulunmasına Yönelik Kaynak Kod

Ek Açıklama-C: Eşik Değerlerinin Bulunmasına Yönelik Kaynak Kod

Ek Açıklama-D: Bir Görüntünün Bloklarının Test Edilmesine Yönelik Kaynak Kod



Ek Açıklama-A: Özvektörlerin Bulunmasına Yönelik Kaynak Kod

```

clc;
clear all;

begin = 30; % Hesaplama dışı bırakılacak görüntülerin indis aralığı
end = 34;

filepath_cell = sprintf('Görüntü bloklarının bulunduğu klasörün adresi');
filepath_cells_grouped = sprintf(' Gruplanmış görüntü bloklarının kaydedileceği klasörün adresi');

for row = 1:1:64
    for column = 1:1:64

        index = 0;

        for goruntu = 30: 1: 69

            if goruntu >= begin && goruntu <=end
                continue
            end

            image = imread(sprintf('%s%d_%d_%d.png', filepath_cell, goruntu,row,column));
            image_64_1 = image(:);
            index = index + 1;
            totalimage(index,:) = image_64_1;

        end

        save (sprintf('%stotalimage_%d_%d',filepath_cells_grouped,row,column),'totalimage');
        A1 = cov(totalimage);
        [v,d]=eig(A1);
        c = (diag(d));
        [y,x]=sort(c);

        for m=1:1:30

            eigvec=v(:,x(m));
            fid=fopen(sprintf('Özvektörlerin kaydedileceği klasörün adresi\\%d_%d_%d.eig',row,column,m),'w');
            fprintf(fid,'%f\n',eigvec);
            fclose(fid);
            clear eigvec;

        end

    end

end

end

```

Ek Açıklama-B: Ortak Vektörlerin Bulunmasına Yönelik Kaynak Kod

```
filepath_commonvector = sprintf(Ortak vektörlerin kaydedileceği klasörün adresi\\');  
filepath_cells_grouped = sprintf(Gruplanmış görüntü bloklarının bulunduğu klasörün adresi\\');  
filepath_eigenvecs = sprintf('Özvektörlerin bulunduğu klasörün adresi\\');
```

```
commonvector = zeros(64,1);
```

```
for row = 1:1:64
```

```
    for column = 1:1:64
```

```
        Reference = load(sprintf('%stotalimage_%d_%d.mat',filepath_cells_grouped,row,column));  
        Ref = Reference.totalimage(1,:);  
        commonvector = zeros(64,1);
```

```
        for o = 1:1:30
```

```
            fid=fopen(sprintf('%s%d_%d.eig',filepath_eigenvecs,row,column,o),'r');  
            eigenvect = fscanf(fid,'%f');  
            fclose(fid);  
            commonvector = commonvector + ((Ref*eigenvect)*eigenvect);
```

```
        end
```

```
        save (sprintf('%scommonvector_%d_%d',filepath_commonvector,row,column),'commonvector');
```

```
    end
```

```
end
```


Ek Açıklama-C: Eşik Değerlerinin Bulunmasına Yönelik Kaynak Kod

```

clear all
filepath_cell = sprintf(Görüntü bloklarının bulunduğu klasörün adresi\);
filepath_thresholds = sprintf(Eşik değerlerinin saklanacağı klasörün adresi\);

Thresholds = zeros(64,64);
m = -4;
n = 0;

for gr = 1:1:8

    filepath_grup = sprintf(İlgili gruptaki görüntülere ait özvektörlerin bulunduğu klasörün adresi_%d\,gr);
    filepath_grup_cv = sprintf(İlgili gruptaki görüntülere ait ortak vektörlerin bulunduğu klasörün adresi_%d\,gr);
    m = m + 5;
    n = n + 5;

    for row = 1:1:64
        index2 = 0;

        for column = 1:1:64

            index2 = 0;
            index = 0;
            distance = zeros(40,1);

            for pic = 30: 1: 69

                image = imread(sprintf('%s%d_%d_%d.png', filepath_cell, pic,row,column));
                image_64_1 = image(:);
                index = index + 1;
                Allvectors(index,:) = image_64_1;

            end

        end

        for i = m:1:n

            Selected_Vect = Allvectors(i,:);
            Selected_Vect = double(Selected_Vect);
            Projection = zeros(64,1);

            for x = 1:1:30

                fid=fopen(sprintf('%s%d_%d_%d.eig',filepath_grup,row,column,oo),'r');
                eigenvector = fscanf(fid,'%f');
                fclose(fid);
                Projection = Projection + ((Selected_Vect*eigenvector)*eigenvector);

            end

        end
    end
end

```

```
cmmnvect = load(sprintf('%scommonvector_%d_%d.mat',filepath_grup_cv,row,column));
index2 = index2+1;
distance (index2,:) = norm(Projection-cmmnvect.commonvector);

end

sortmax = sort(distance);
Thresholds(row,column) = sortmax(40);

end

end

end

save (sprintf('%sThresholds.mat',filepath_thresholds),'Thresholds');
```

Ek Açıklama-D: Bir Görüntünün Bloklarının Test Edilmesine Yönelik Kaynak Kod

```

array_noise_results = zeros(4096,1); % Sonuçların saklanacağı dizi

filepath_cells_test = sprintf('Test edilecek görüntünün bloklarının yer aldığı klasörün adresi\\');
filepath_eigenvecs = sprintf('Özvektörlerin bulunduğu klasörün adresi\\');
filepath_common_vector = sprintf('Ortak vektörlerin bulunduğu klasörün adresi\\');
filepath_thresholds = sprintf('Eşik değerlerinin bulunduğu klasörün adresi\\');

Thresholds = load(sprintf('%sThresholds.mat',filepath_thresholds));

for row = 1:1:64

    for column = 1:1:64

        SelectedVector1 = imread(sprintf('%s%d_%d_%d.png',filepath_cells_test,row,column));
        SelectedVector = SelectedVector1(:);
        SelectedVector = double(SelectedVector);
        SelectedVector = SelectedVector';
        Projection = zeros(64,1);

        for x = 1:1:30

            fid=fopen(sprintf('%s%d_%d_%d.eig',filepath_eigenvecs,row,column,x),'r');
            eigenvect = fscanf(fid,'%f');
            fclose(fid);
            Projection = Projection + ((SelectedVector*eigenvect)*eigenvect);

        end

        cmmnvect = load(sprintf('%scommonvector_%d_%d.mat',filepath_common_vector,row,column));
        distance = norm(Projection-cmmnvect.commonvector);

        if (distance >= Thresholds.Thresholds(row,column))

            Noise_Results(row,column) = 1;

        end

    end

end

end

```

ÖZGEÇMİŞ

Hasan Başar Kalyoncu, 31.08.1980 tarihinde Eskişehir’de doğmuştur ve Türkiye Cumhuriyeti vatandaşıdır. Eskişehir Anadolu Lisesi’nden 1998 yılında mezun olduktan sonra, Elektrik Elektronik Mühendisliği lisans ve yüksek lisans derecelerini sırasıyla, 2003 ve 2006 yıllarında Eskişehir Osmangazi Üniversitesi’nden almıştır. Kendisinin çalışma ilgi alanları, gömülü sistem donanımı ve yazılımı tasarımları, görüntü işleme teknikleri ve demiryolu sinyalizasyon sistemleridir.

