

T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DİFERANSİYEL GELİŞİM ALGORİTMASI İLE
MEDİKAL GÖRÜNTÜ BİRLEŞTİRME

Tezi Hazırlayan
Abdullatif DOĞAN

Tezi Yöneten
Yrd. Doç. Dr. Veysel ASLANTAŞ

Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Temmuz 2008
KAYSERİ

Yrd. Doç. Dr. Veysel ASLANTAŞ danışmanlığında **Abdullatif DOĞAN** tarafından hazırlanan “**Diferansiyel Gelişim Algoritması İle Medikal Görüntü Birleştirme**” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

22.07.2008

JÜRİ:

Başkan : Prof. Dr. Derviş KARABOĞA

Üye : Doç. Dr. Nurhan KARABOĞA

Üye : Yrd. Doç. Dr. Veysel ASLANTAŞ

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulunun **15/08/2008** tarih ve **2008/24-08** sayılı kararı ile onaylanmıştır.

15/08/2008



N. Ayyıldız
Prof. Dr. Nusret AYYILDIZ

Enstitü Müdürü

TEŞEKKÜR

Tezin hazırlanmasındaki bütün aşamalarda bilgi ve tecrübeleri ile desteğini hiç esirgemeyen tez danışmanı hocam Yrd. Doç. Dr. Veysel ASLANTAŞ'a, çalışmanın sonuçlarını değerlendirme aşamasındaki katkılarından ötürü Tekden Hastanesi'nde görevli Uz. Dr. Mustafa Güneş'e, yüksek lisans öğrenimimi 2228 no'lu burs kapsamında destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK)'na, hayatım boyunca hep yanımda olmuş, bugünlere gelmemde büyük emekleri bulunan aileme, doğrudan ya da dolaylı katkıda bulunan herkese teşekkürü bir borç bilirim.

DİFERANSİYEL GELİŞİM ALGORİTMASI İLE MEDİKAL GÖRÜNTÜ BİRLEŞTİRME

Abdullatif DOĞAN

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Temmuz 2008

Tez Danışmanı: Yrd. Doç. Dr. Veysel ASLANTAŞ

ÖZET

Görüntü birleştirme, farklı tür sensörlerle elde edilen çok-sensörlü görüntülerin veya farklı odağa sahip kameralarca elde edilen çok-odaklı görüntülerin, tek bir görüntü halinde ifade edilmesi amacıyla birleştirilmesi işlemidir. Birleştirilmiş görüntü, hem görüntünün hitap edeceği kullanıcılar hem de bilgisayarlar tarafından daha kolay analiz edilebilmekte ve her bir görüntünün tek tek analizi ile elde edilemeyen bilgilerin elde edilmesi sağlanmaktadır.

Çok-sensörlü görüntü birleştirme sahası içerisinde medikal görüntü birleştirme çalışmaları önemli yer tutmaktadır. Klinik uygulamalarda ortaya çıkan yüksek ilgiden dolayı son yıllarda çok-sensörlü medikal görüntü birleştirme konusu dikkatleri üzerine çekmiştir. Tomografi (CT) görüntüleri gibi sert dokuya duyarlı görüntüler ile yumuşak dokuyu görüntülemeye daha hassas olan manyetik rezonans (MR) görüntülerinin birleştirilmesi sonucu hem sert hem de yumuşak dokuda yüksek detay elde edilebilmektedir.

Hâlihazırda literatürde önerilmiş çok-sensörlü görüntü birleştirme teknikleri mevcuttur ve temelde bir çok-sensörlü görüntü birleştirme işlemi olan medikal görüntü birleştirilmede de bu teknikler kullanılabilir. Dalgacık Dönüşümü metodu ve piramit metotları ile gayet olumlu sonuçlar alınmıştır.

Bu çalışmada, halen çok-sensörlü görüntü birleştirme işlemlerinde sıkça kullanılan Dalgacık Dönüşümü metodunun, Diferansiyel Gelişim Algoritması yardımı ile

birleřtirilmesi esasına dayanan yeni bir grnt birleřtirme teknięi nerilmiřtir. nerilen teknięin performansı Laplacian Piramidi, Ayrık Dalgacık Dnřm, Kaymadan Baęımsız Ayrık Dalgacık Dnřm, Ortalama ile Birleřtirme, Morfolojik Piramit, Kontrast Piramidi, Ratio Piramidi teknikleri ile karřılařtırılmıř ve daha verimli olduęu gzlenmiřtir.

Anahtar Kelimeler: Grnt Birleřtirme, Dalgacık Dnřm, Diferansiyel Geliřim Algoritması

MEDICAL IMAGE FUSION USING DIFFERENTIAL EVOLUTION ALGORITHM

Abdullatif DOĞAN

Erciyes University, Graduate School of Natural and Applied Sciences

M. Sc. Thesis, July 2008

Thesis Supervisor: Assist. Prof. Veysel ASLANTAŞ

ABSTRACT

Image fusion is an operation that includes composing multi-sensor or multi-focus images in a single image that contains features of source images. Fused image can easily be analyzed by both human beings and computers, and provide information that can not be acquired analyzing source images separately.

Medical image fusion is an important issue in multi-sensor image fusion area. Recently, multimode medical image fusion has attracted more attention due to the increasing interest by the clinical applications. By fusing CT images, which are sensitive to bone tissue, and MR images, which are sensitive to soft tissue, details in both soft and bone tissues can be achieved.

In literature, there are a lot of methods proposed for multi-sensor image fusion. Most of them can be used to fuse multimode medical images, because medical image fusion process also includes multi-sensor image fusion operations. Acceptable results in medical fusion have been obtained using Discrete Wavelet Transform based method and pyramid based techniques.

This thesis proposes a novel technique that fuses medical images obtained by different sensors using Wavelet Transform and Differential Evolution Algorithm. Performance of the proposed method has been compared with the existing methods such as Laplacian Pyramid, Ratio Pyramid, Contrast Pyramid, Morphological Pyramid, Fusion by Averaging, Discrete Wavelet Transform and Shift Invariant Discrete Wavelet

Transform. Conducted experiments show that the developed technique produced better results than the others.

Keywords: Image Fusion, Wavelet Transform, Differential Evolution Algorithm.

İÇİNDEKİLER

KABUL VE ONAY	i
TEŞEKKÜR.....	ii
ÖZET	iii
ABSTRACT	v
ŞEKİLLER LİSTESİ	ix
1. BÖLÜM	
GİRİŞ	1
2. BÖLÜM	
GÖRÜNTÜ BİRLEŞTİRME TEKNİKLERİ	5
2.1. Dalgacık Dönüşümü Temelli Görüntü Birleştirme	5
2.1.1. Dalgacık Dönüşümü	5
2.1.2. Dalgacık Teorisi	11
2.1.3. Çok Çözünürlüklü Analiz	13
2.1.4. Ayrık Dalgacık Dönüşümü	13
2.1.5. Ayrık Dalgacık Dönüşümü İle Görüntü Birleştirme	18
2.2. Laplacian Piramidi Temelli Görüntü Birleştirme	21
2.2.1. Temel Teori	21
2.2.2. Birleştirme Algoritması	25
2.3. Morfolojik Piramit Temelli Görüntü Birleştirme	27
2.3. Ratio Piramidi Temelli Görüntü Birleştirme	27
2.4. Kaymadan Bağımsız Ayrık Dalgacık Dönüşümü	29
3. BÖLÜM	
DİFERANSİYEL GELİŞİM ALGORİTMASI	30
3.1. Algoritmanın Temeli	30

3.2.	Problem ve Parametreler	32
3.3.	Kodlama ve başlangıç popülasyonu	33
3.4.	Mutasyon.....	33
3.5.	Çaprazlama.....	34
3.6.	Uygunluk fonksiyonu.....	34
3.7.	Seçim.....	34
4. BÖLÜM		
	BİRLEŞTİRME SONUCUNUN DEĞERLENDİRİLMESİ	36
4.1.	Karşılıklı Bilgi.....	37
4.2.	Tsallis Entropisine Dayalı Karşılıklı Bilgi.....	38
4.3.	Kalite indeksi	39
5. BÖLÜM		
DİFERANSİYEL GELİŞİM ALGORİTMASI İLE MEDİKAL GÖRÜNTÜ		
	BİRLEŞTİRME	42
5.1.	Çok-Sensörlü Görüntü Birleştirme	42
5.2.	ADD İle Medikal Görüntü Birleştirme	44
5.2.1.	Kullanılan Dalgacık Dönüşümü Yöntemi.....	44
5.2.2.	Uygunluk Fonksiyonu.....	47
5.2.3.	Diferansiyel Gelişim Algoritması İle Medikal Görüntü Birleştirme	51
5.2.4.	DeneySEL Çalışma.....	53
6. BÖLÜM		
	SONUÇ.....	68
	KAYNAKLAR	70
	ÖZGEÇMİŞ	75

ŞEKİLLER LİSTESİ

Şekil 1.1.	Çok-sensörlü görüntü birleştirme işleminin temeli.....	2
Şekil 1.2.	(a) CT görüntüsü, (b) MR görüntüsü.....	4
Şekil 2.1.	Farklı frekanstaki bileşenlerden oluşan işaret.....	6
Şekil 2.2.	Şekil 2.1.'deki işaretin Fourier ve Ters Fourier Dönüşümü işlemine tabi tutulması sonucu oluşan işaret.....	6
Şekil 2.3.	Bir dalgacık örneği.....	8
Şekil 2.4.	Bir dalga örneği.....	8
Şekil 2.5.	s ölçekleme parametresinin bir işaret üzerindeki etkisi: (a) $s=1$, (b) $s=0.2$, (c) $s=0.1$, (d) $s=0.05$	10
Şekil 2.6.	Şekil 2.1.'teki işaretin Dalgacık Dönüşümü sonucu.....	10
Şekil 2.7.	Çok Çözünürlüklü Analizde alt uzayların ifadesi.....	13
Şekil 2.8.	Frekans uzayında alt frekans bölgeleri.....	14
Şekil 2.9.	Üç seviyeli bir ADD işleminin adımları.....	15
Şekil 2.10.	İki boyutlu tek seviyeli ADD işlemi.....	16
Şekil 2.11.	(a) Woman isimli görüntünün alt bantları, (b) alt bantların frekans yönleri	16
Şekil 2.12.	(a) Daubechies ailesinden bir dalgacık (Daubechies(2)), (b) Haar dalgacığı.....	17
Şekil 2.13.	Dalgacık Dönüşümü yöntemiyle İşaret İşleme'nin temel adımları.....	18
Şekil 2.14.	Ayrık Dalgacık Dönüşümü yöntemiyle görüntü birleştirmenin temel adımları.....	19

Şekil 2.15.	Piksel tabanlı ve pencere tabanlı görüntü birleştirme.....	20
Şekil 2.16.	Alan tabanlı birleştirme algoritması.....	20
Şekil 2.17.	Çok çözünürlüklü piramidin oluşturulması.....	22
Şekil 2.18.	İndirgeme işleminin gerçekleştirilmesi.....	23
Şekil 2.19.	Gaussian Piramidi Algoritması ile üretilmiş görüntüler.....	24
Şekil 2.20.	Laplacian Piramidi birleştirme algoritması.....	26
Şekil 3.1.	Yeni vektörün oluşturulması işlemi.....	31
Şekil 3.2.	DGA algoritmasının akış şeması.....	35
Şekil 5.1.	Ayrık dalgacık dönüşümü sonucu oluşan alt bantlar.....	44
Şekil 5.2.	İki seviyeli ayrıştırılmış görüntülerin birleştirilmesi.....	46
Şekil 5.3	Pencereleme işleminin gerçekleştirilmesi.....	50
Şekil 5.4.	(a), (b) Kaynak görüntüler, (c) Birleştirilmiş kontrastı düşük görüntü.....	51
Şekil 5.5.	(a) A görüntüsünün katsayılar haritası, (b) B görüntüsünün katsayılar haritası.....	54
Şekil 5.6.	Birinci grup deney görüntüleri: (a) ve(b) Kaynak görüntüler, (c) Geliştirilen teknikle birleştirilmiş görüntü, (d), (e), (f), (g), (h), (i) ve (j) değişik yöntemlerle birleştirilmiş görüntüler ve uygunluk değerleri.....	56
Şekil 5.7.	İkinci grup deney görüntüleri: (a) ve(b) Kaynak görüntüler, (c) Geliştirilen teknikle birleştirilmiş görüntü, (d), (e), (f), (g), (h), (i) ve (j) değişik yöntemlerle birleştirilmiş görüntüler ve uygunluk değerleri.....	59

- Şekil 5.8. Üçüncü grup deney görüntüleri: (a) ve(b) Kaynak görüntüler, (c) Geliştirilen teknikle birleştirilmiş görüntü, (d), (e), (f), (g), (h), (i) ve (j) değişik yöntemlerle birleştirilmiş görüntüler ve uygunluk değerleri.....62
- Şekil 5.9. Dördüncü grup deney görüntüleri: (a) ve(b) Kaynak görüntüler,(c) Geliştirilen teknikle birleştirilmiş görüntü, (d), (e), (f), (g), (h), (i) ve (j) değişik yöntemlerle birleştirilmiş görüntüler ve uygunluk değerleri.....65


1. BÖLÜM

GİRİŞ

Görüntü birleştirme, iki veya daha fazla görüntüden her birinin en fazla bilgi içeren karakteristik bölümlerinin birleştirilerek tek bir görüntü halinde ifade edilmesi işlemidir. Gece görüş kamerası ile çekilmiş (Image Intensified-II) bir görüntü ile termal kameradan alınmış (Forward Looking Infrared-FLIR) bir görüntünün birleştirilmesi sonucu iki görüntünün de özelliklerini içeren tek bir görüntü elde edilebilir. Kızılötesi ışınlar, ağaç arkası gibi görünür ışığın geçemeyeceği engellerden geçebilirler, ayrıca termal görüntüler ısıya duyarlı olduklarından canlı nesnelerin algılanmasında kullanılabilirler. Bununla birlikte, II görüntüleri arazinin termal kamera tarafından yakalanamayan detaylarını, yükselti ve ağaçlık alan gibi termal görüntü tarafından ayırt edilemeyen verileri elde edebilirler. Bu sayede iki tekniğin de avantajlarını taşıyan ve fazla miktarda veri taşıyarak, görüntülenen bölgenin analizinde kolaylık sağlayan tek bir görüntü meydana getirilmektedir.

Görüntü birleştirme; bilgisayarlı görme, otomatik nesne bulma [1], görüntü işleme, medikal görüntüleme [2], paralel ve dağıtık işlemler ve robotik gibi birçok alanda kullanılmaktadır. Görüntü birleştirmede kullanılan veriler aynı çevrenin farklı gösterimlerini içeren birden fazla görüntü kümesidir. Bu farklı gösterimler görüntü şartlarındaki değişikliklerden kaynaklanabileceği gibi farklı görüntüleme elemanları (algılayıcılar) kullanımından da kaynaklanabilir. Görüntü birleştirme ile hem görüntülerdeki olumsuzluklar giderilir hem de daha anlamlı bilgiler elde edilir [3].

Görüntü birleştirme işlemlerinin amacı; kaynak görüntülerden faydalı olan bilgilerin çıkarılması, birleştirilen görüntülerde akıl karıştırıcı yapay veri bölgelerinin bulunmasının önlenmesi ve yanlış hizalama (registration) işlemine karşı dayanıklılığın sağlanması olmalıdır. Şekil 1.1.'de görüntü birleştirmenin temeli sembolize edilmiştir.



Şekil 1.1. Çok-sensörlü görüntü birleştirme işleminin temeli.

Öncelikle başarılı bir görüntü birleştirme işlemi için birleştirilecek kaynak görüntülerin hizalanmış (registered) olması gerekmektedir. Hizalanmamış görüntülerin birleştirilmesi sonucu arzu edilmeyen çıktı görüntüler meydana gelmekte ve görüntü birleştirme işlemi sonuçsuz bir çaba olarak kalmaktadır. Bu çalışma boyunca kaynak görüntü olarak hizalanmış görüntüler kullanılmıştır. Kaynak görüntülerin hizalanması amacıyla birçok hizalama metodu literatüre sunulmuştur [4, 5]. Bu konu çalışmanın kapsamı dışında olduğu için hizalama konusuna değinilmeyecektir.

Görüntü birleştirme teknikleri, resim uzayı teknikleri ve dönüşüm uzayı teknikleri olmak üzere ikiye ayrılmaktadır. Resim uzayı tekniklerinden en basiti, iki kaynak görüntünün piksel piksel gri ton seviyelerinin ortalamalarının alınmasıdır. Bu işlem görüntünün genel kontrastının azalmasına sebep olur. Dönüşüm uzayı teknikleri ise, Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform- DWT), Laplacian Piramidi, Morfolojik Piramit gibi dönüşüm teknikleri ile kaynak görüntüleri dönüştürdükten sonra dönüşüm uzayı verilerini kullanarak birleştirme işlemini gerçekleştirirler.


Günümüzde görüntü birleştirme teknikleri görüntü işlemenin önemli alanlarından biri haline gelmiştir. Her biri değişik yöntemler kullanan çok sayıda görüntü birleştirme algoritması önerilmiş ve literatüre katılmıştır [6, 7, 8]. Her bir algoritmanın avantajları, dezavantajları, uygun kullanım sahaları ve amaçları vardır.

Görüntü kaynağı bakımından görüntü birleştirme teknikleri ana iki kola ayrılmaktadır: Farklı odaklara sahip kameralarca elde edilmiş görüntüleri birleştirmekte kullanılan çok-odaklı (multi-focus) görüntü birleştirme ve farklı tür sensörlerle elde edilmiş görüntüleri birleştirmekte kullanılan çok-sensörlü (multi-sensor) görüntü birleştirme.

Çok-sensörlü görüntü birleştirme sahası içerisinde medikal görüntü birleştirme çalışmaları önemli yer tutmaktadır. Klinik uygulamalarda ortaya çıkan yüksek ilgiden dolayı son yıllarda çok-modlu medikal görüntü birleştirme konusu dikkatleri üzerine çekmiştir. Örneğin radyoterapi planı, farklı moddaki çeşitli medikal görüntülerden gelen verilerden destek alınarak oluşturulmaktadır. Doz hesaplaması, bilgisayarlı tomografi (Computed Tomography-CT) verilerine dayanırken, tümör takibi Manyetik Rezonans (Magnetic Resonance-MR) verileri ile gerçekleştirilmektedir. CT görüntüleri yoğun yapılarda yüksek gri ton seviye değeri, seyrek yapılarda ise düşük gri ton seviye değeri üretmektedir. İnsan vücudunun CT ile görüntülenmesi sonucu en yoğun yapılar olan kemikler, en yüksek gri ton değerlerini, yumuşak doku, yoğunluğuna göre orta seviyede gri ton değerlerini, boşluklar ise en düşük gri ton değerlerini içerecektir. MR görüntüleme ise hidrojen atomuna duyarlı bir görüntüleme sistemidir. Hidrojenin çokça içerildiği yumuşak dokularda en yüksek gri ton değerlerini, içerilmediği bölgelerde ise düşük gri ton değerlerini vermektedir. Şekil 1.2.'de CT ve MR görüntüleri görülmektedir. Ayrıca CT görüntüleri çok az bozulma ile sonuçları verirken MR görüntüleri çeşitli uzaysal ve radyometrik bozulmalar sergilemektedir. Bundan başka Pozitron yayılım tomografisi (Positron Emission Tomography-PET) vb. gibi bazı farklı görüntüleme teknikleri de medikal alanda kullanılmaktadır. Her biri farklı özellik ve veri içeren bu görüntülerin tümleyen verilerinin birleştirilerek tek bir görüntü halinde kullanılması hem hekimler açısından kolaylık sağlayacaktır hem de bu verilerin tek bir görüntü halinde saklanabilmesinden dolayı depolama sorunlarının azaltılması mümkün olacaktır.

Bu tez çalışmasında çok-modlu medikal görüntü birleştirme konusu ele alınmıştır. Şimdiye kadar yapılan görüntü birleştirme algoritmalarının bazı yetersizlikleri vardır. Örneğin ortalama ile birleştirme tekniğinde iki görüntünün piksel değerlerinin ortalaması alındığından birleştirilmiş görüntüde kontrast çok düşük olmaktadır. Piramit tekniklerinde ise dönüşüm yapıldıktan sonra genellikle katsayılar arasından maksimumu seçme işlemi gerçekleştirilerek birleştirme yapılmaktadır. Bunun sonucunda, hem düşük

frekans hem de düşük gri ton değeri içeren bölgeler seçilememektedir. Bu eksikliklerin giderilmesi ve uygun bir birleştirme sağlanabilmesi için optimizasyon tekniklerinden olan Diferansiyel Gelişim Algoritması (DGA)’ndan yararlanılmıştır.



Şekil 1.2. (a) CT görüntüsü , (b) MR görüntüsü.

Bölüm 2’de literatürde önerilmiş dönüşüm tabanlı görüntü birleştirme teknikleri hakkında bilgi verilecektir. Bölüm 3’de çalışmada kullanılan optimizasyon tekniği olan DGA’dan bahsedilirken Bölüm 4’de optimizasyon işleminde de önemli yer tutan, birleştirilen görüntünün kalitesi ve uygunluğu hakkında bilgi veren metriklerden bahsedilecektir. Bölüm 5’de ise tez çalışmasının konusu olan, DGA ile medikal görüntü birleştirme tekniği tanıtılacak ve tez çalışmasının, diğer çalışmalarla karşılaştırılmasını ve performansını da içeren deneysel sonuçlar bölümü verilecektir. Bölüm 6’da yapılan çalışmanın bir değerlendirilmesini içeren sonuç kısmı yer alacaktır

2. BÖLÜM

GÖRÜNTÜ BİRLEŞTİRME TEKNİKLERİ

Bu bölümde literatürde önerilmiş görüntü birleştirme teknikleri hakkında bilgiler verilecektir. Yapılan çalışma Ayırık Dalgacık Dönüşümü tabanlı olduğundan dolayı öncelikle Dalgacık Teorisi, Dalgacık Dönüşümü ve Ayırık Dalgacık Dönüşümü ile görüntü birleştirme konusu ele alınacaktır. Daha sonra ise Laplacian Piramidi, Morfolojik Piramit, Ratio Piramidi ve Kaymadan Bağımsız Ayırık Dalgacık Dönüşümü tabanlı görüntü birleştirme tekniklerinden bahsedilecektir. Bu metotlar ile önerilen tekniğin performans karşılaştırılması Bölüm 4’de yer almaktadır


2.1. Dalgacık Dönüşümü Temelli Görüntü Birleştirme

2.1.1. Dalgacık Dönüşümü


İşaret işlemede kullandığımız işaretlerin çoğu zaman eksenli olarak elde edilmektedir. Bu işaretlerin gösteriminde x eksenini zamanı, y eksenini ise genliği ifade eder. Bu tür bir gösterim işaret işleme açısından her zaman uygun bir gösterim tarzı değildir. Genellikle ayırt edici ve işareti kimliklendirebilecek bilgi, işaretin frekans içeriğinde gizlidir. Örneğin ECG (Electrocardiogram) analizi esnasında, genel halden ufak sapmaların tespiti önem kazanmaktadır. Bu sapmalar çoğu zaman periyodik tekrarların bozulması şeklinde kendisini gösterir. İşaret uzayında uzun çabalar harcayarak bu analizin yapılması yerine işaretin frekans uzayında analizini yapmak periyodik hataların tespitini oldukça kolaylaştırmaktadır.

İşaret işleme alanında, işaretlerin frekans uzayını elde etmek üzere sıklıkla Fourier Dönüşümü kullanılmaktadır. Fourier Dönüşümü bir işareti durağan işaret olarak kabul

ederek frekans içeriğini vermektedir. Durağan işaretler belirli bir periyotla sürekli kendini tekrar eden işaretlerdir. Dolayısıyla Fourier Dönüşümü sonucu elde edilen frekans bileşenlerinin, işaretin tümünde etkili olduğu kabul edilir. Şekil 2.1.'de durağan olmayan bir işaret örneği verilmiştir. Bu işaret Fourier Dönüşümü'ne tabi tutulduğunda içerisindeki dört farklı frekans bilgisi elde edilmektedir. Ancak Fourier Dönüşümü'yle işaret içerisindeki frekansların hangi zaman aralıklarında oluştuğu elde edilemediği için bu frekansların tüm zamanlarda oluştuğu kabul edilir ve bu sonucun ters dönüşümü alındığında Şekil 2.2.'deki işaret elde edilir [9].



Şekil 2.1. Farklı frekanstaki bileşenlerden oluşan işaret.




Şekil 2.2. Şekil 2.1.'deki işaretin Fourier ve Ters Fourier Dönüşümü işlemine tabi tutulması sonucu oluşan işaret.


Çevremizde gördüğümüz çoğu işaret durağan olmadığı için işaretin içerisindeki frekansların hangi zaman aralıklarında işarete bulunduğu büyük önem arz eder. Böyle durumlarda Fourier Dönüşümü uygun bir yöntem olmayacaktır. Fourier Dönüşümü'nün bu eksikliği Kısa Zamanlı Fourier Dönüşümü (KZFD) adı verilen bir yöntemle aşılmaya çalışılmıştır. KZFD'de dönüşümü alınacak işaret, öncelikle bir pencereleme fonksiyonu ile çarpılarak işaretin sadece belirli bölgesinin etkili olması sağlanır. Bu pencereleme fonksiyonu, işaretin sadece belirli bölgelerini bırakarak diğer bölgelerini sıfırlayan Gaussian gibi bir fonksiyon seçilebilir. Daha sonra pencerelenmiş işaretin Fourier Dönüşümü alınır. Bu işlem pencere fonksiyonunu işaret üzerinde öteleyerek tüm işareti kapsayınca kadar devam ettirilir. KZFD'nin dezavantajı ise seçilen pencerenin zaman eksenindeki genişliğine göre dönüşüm sonucunun farklılık göstermesidir. Pencere boyutu küçültüldükçe zaman eksenindeki çözünürlük artarken frekans ekseninde çözünürlük azalmaktadır, zira zaman ekseninde az yer kaplayan bir işaretin frekans içeriği tam olarak elde edilememektedir. Pencere boyutu büyüdükçe işaretin frekans çözünürlüğü artmakta ve hatta pencere boyutu işaret ile aynı seçildiği takdirde işaretin tüm frekans içeriği elde edilebilmektedir. Fakat bu kez de işaretin zaman çözünürlüğü düşmekte ve hangi frekansın hangi zaman aralığında işarete etkili olduğu bilgisi zayıflamaktadır. Bu olumsuz etkiye zaman-frekans belirsizliği adı verilmektedir ve KZFD'nin en büyük sorunu olarak karşımıza çıkmaktadır [10].

Bu sorunu ortadan kaldırmak için Dalgacık Dönüşümü (Wavelet Transform) fikri ortaya atılmıştır. Literatüre son yıllarda katılan bu yeni dönüşüm şimdiden kendine görüntü birleştirme dâhil birçok uygulama alanı bulmuştur [11, 12].

Bu işlem için *Dalgacık Dönüşümü* ifadesinin kullanılmasının nedeni, frekans bilgilerine ulaşmak için dönüşümü gerçekleştirmekte kullanılan temel işaretlerin tüm zaman eksenini boyunca uzanan birer dalga olmaması, bunun yerine zamanın belirli bölgesinde beliren ve sonra kaybolan bir dalgacık olmasıdır. Şekil 2.3.'de dalgacık ve Şekil 2.4.'de dalga örnekleri görülmektedir [13]. Bu grafiklerde yatay eksen zamanı, dikey eksen ise genliği ifade etmektedir. İşaretin içerisinde bulunan frekans bilgilerinin hangi zaman aralıklarında meydana geldiğinin hesaplanmasını da dalgacığın belirli zaman aralığında meydana gelmesi sağlamaktadır. Dalgacık Dönüşümü'ndeki temel eleman Fourier Dönüşümü'nde olduğu gibi sinüs ve kosinüs değil bu dalgacıktır.



Şekil 2.3. Bir dalgacık örneği.



Şekil 2.4. Bir dalga örneği.


Bu ana dalgacığın zaman ekseninde ötelenmesi (transform) ve ölçeklendirilmesi (scaling) sonucu birçok alt dalgacık meydana getirilir ve bu alt dalgacıklar ile işaretin içsel çarpımı (inner product) alınarak işaretin o ana dalgacık için Dalgacık Dönüşümü bulunur. Denklem 2.1.'de formülü de verilen bu işlem tüm zaman eksenini boyunca her bir alt dalgacık için yapılır. Elde edilen sonuç işaretin o ölçekleme ve öteleme parametreleri için dönüşüm katsayısı olarak adlandırılır.

$$CWT_x^\psi(\tau, s) = \Psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (2.1)$$


Burada τ öteleme parametresini s ise ölçekleme parametresini ifade etmektedir. ψ kullanılan ana dalgacık fonksiyonunu belirtmektedir. ψ^* , ψ dalgacık fonksiyonunun eşleniğini, $x(t)$ ise dönüşümü alınacak işareti ifade etmektedir. τ dalgacığın orijinden ne kadar öteleneceğini ifade eden parametredir. s ise dalgacığın ne kadar büyüyüp küçüleceğinin bir ölçüsüdür. Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform- CWT), CWT_x^ψ şeklinde ifade edilebildiği gibi Ψ_x^ψ şeklinde de ifade edilmektedir. Denklem 2.1.'de bu iki ifade biçimi de belirtilmiştir. Şekil 2.5.'de ölçekleme parametresinin işaret üzerindeki etkisi görülmektedir. Ölçekleme parametresi büyüdükçe dalgacığa doğru yaklaşma, ölçekleme parametresi küçüldükçe ise dalgacıktan uzaklaşma etkisi meydana gelmektedir. Şekil 2.6.'da ise Şekil 2.1.'de verilen işaretin Sürekli Dalgacık Dönüşümü sonucu görülmektedir. Yüksek frekansların (düşük ölçek), işaretin başlarında (düşük öteleme), düşük frekansların ise (yüksek ölçek), işaretin sonlarında (yüksek öteleme) meydana geldiği şekilden anlaşılmaktadır.

Dalgacık Dönüşümü'nün hesaplanması aşağıdaki adımlarla gerçekleşir:

- Öncelikle kullanılacak ana dalgacık fonksiyonu seçilmelidir. Daha önceden tasarlanmış dalgacık fonksiyonları kullanılabileceği gibi istenilen özelliklerde bir dalgacık fonksiyonu da tasarlanabilir.
- Kaydırma ve ölçekleme parametrelerine başlangıç değerleri atanır. Bu değerlere göre ana dalgacık fonksiyonu değiştirilerek bir alt dalgacık fonksiyonu elde edilir. Bu fonksiyonla dönüşümü alınacak işaret, içsel çarpım işlemine tâbi tutulur. Kaydırma ve ölçekleme parametrelerinin başlangıç için 1 değerini



Şekil 2.5. s ölçekleme parametresinin bir işaret üzerindeki etkisi: (a) $s=1$, (b) $s=0.2$, (c) $s=0.1$, (d) $s=0.05$.



Şekil 2.6. Şekil 2.1.'teki işaretin Dalgacık Dönüşümü sonucu.

aldıkları varsayılırsa $\Psi_x''(1,1)$ değeri hesaplanmış olur.

- Daha sonra ölçekleme ve kaydırma parametreleri değiştirilerek işlemler tekrarlanır.

2.1.2. Dalgacık Teorisi

Dalgacık Dönüşümü de tıpkı Fourier Dönüşümü gibi fonksiyon tabanı (function base) ve içsel çarpım kavramlarına dayanmaktadır. Bir V vektör uzayının tabanı (basis), lineer bağımsız vektörlerden oluşan bir settir, öyle ki bu setteki vektörler kullanılarak V vektör uzayındaki herhangi bir vektör bu taban vektörlerin lineer kombinasyonları şeklinde ifade edilebilir. Denklem 2.2.'de bir v vektörünün taban vektörleri b_k , ve bu taban vektörlerin katsayılarından v^k , oluşmasının matematik ifadesi verilmiştir. Bir vektör uzayı için birden fazla taban bulunabilir, fakat hepsi aynı sayıda taban vektörden oluşur. Bu taban vektör sayısı vektör uzayının boyutu olarak bilinir. Örneğin iki boyutlu Öklid uzayının biri x eksenindeki birim vektör diğeri de y eksenindeki birim vektör olmak üzere iki taban vektörü bulunmaktadır.

$$v = \sum_k v^k b_k \quad (2.2)$$

Vektörler için yapılan yukarıdaki tanımlar fonksiyonlar için de uygulanabilir. Aşağıdaki ifadede de görüldüğü gibi bir fonksiyon, taban fonksiyonlar, $\phi_k(t)$ ve karşılık gelen katsayılar, μ_k şeklinde ifade edilebilmektedir. Sinüs ve Kosinüs dalgaları Fourier Dönüşümü için taban fonksiyonlar olarak seçilmişlerdir. Bu iki fonksiyonun ortagonal olması da bazı önemli özellikleri beraberinde getirmektedir.

$$f(t) = \sum_k \mu_k \phi_k(t) \quad (2.3)$$

$f(t)$ ve $g(t)$, $L^2[a,b]$ içinde iki fonksiyon olmak üzere bu iki fonksiyonun içsel çarpımı Denkle 2.4.'teki biçimde ifade edilmektedir. $L^2[a,b]$, a ve b değerleri arasında karesi integallenebilen veya başka bir ifade ile karesinin integrali sonlu olan fonksiyonları içeren fonksiyon uzayıdır.

$$\langle f(t), g(t) \rangle = \int_a^b f(t) \cdot g^*(t) dt \quad (2.4)$$

Eğer iki fonksiyonun içsel çarpımları sifıra eşit ise, yani Denklem 2.5'teki ifade sağlanıyorsa bu iki fonksiyon ortogonaldir.

$$\langle f(t), g(t) \rangle = \int_a^b f(t) \cdot g^*(t) dt = 0 \quad (2.5)$$

Bir fonksiyon kümesi $(\phi_k(t), k = 1, 2, 3, \dots)$, aşağıdaki şartı sağlıyorsa ortonormal olarak adlandırılır.

$$\int_a^b \phi_k(t) \phi_l^*(t) dt = \delta_{kl} \quad (2.6)$$

Burada δ , Kronecker delta fonksiyonu olarak adlandırılır ve aşağıdaki biçimde ifade edilir.

$$\delta_{kl} = \begin{cases} k = l \Rightarrow 1 \\ k \neq l \Rightarrow 0 \end{cases} \quad (2.7)$$

Yukarıda da ifade edildiği gibi bir fonksiyon uzayının birden fazla tabanı bulunabilmektedir. Bunların arasında ortonormal taban fonksiyonları özel öneme sahiptirler. Çünkü dönüşüm işlemlerinde kolaylık sağlayacak yukarıda bahsedilen ortonormalite özellikleri bulunmaktadır. Ortonormal tabanlar için μ_k fonksiyon katsayıları Denklem 2.8.'deki biçimde hesaplanabilir.

$$\mu_k = \langle f, \phi_k \rangle = \int f(t) \cdot \phi_k^*(t) dt \quad (2.8)$$


$f(t)$ fonksiyonu da Denklem 2.3.'deki gibi hesaplanabildiğinden yerinde koyulduğunda Denklem 2.9.'da belirtildiği gibi $f(t)$ 'nin yeni bir ifadesini elde ederiz ki bu ters dönüşüm özelliğini belirtmektedir.

$$\begin{aligned} f(t) &= \sum_k \mu_k \phi_k(t) \\ &= \sum_k \langle f, \phi_k \rangle \phi_k(t) \end{aligned} \quad (2.9)$$

2.1.3. Çok Çözünürlüklü Analiz

Çok Çözünürlüklü Analiz (Multi-resolution Analysis)'de, bir işaret çok boyutlu bir vektör uzayı olarak kabul edilmektedir. Analiz sırasında bu uzaydan her adımda bir alt uzay çıkarılarak ardışık olarak işlem sürdürülür. Şekil 2.7.'de de görüldüğü gibi V_0 uzayından ilk adımda W_1 alt uzayı çıkarılarak V_1 alt uzayı elde edilir. Çok Çözünürlüklü Analiz'in frekans uzayında gösterimi Şekil 2.8.'deki gibidir. Çok Çözünürlüklü Analiz işleminde, tek filtre kullanılarak herhangi bir adımdaki alt uzay V_x 'i elde etmek için, sonsuz adet dönüşüm yapılmalı ve elde edilen tüm W alt uzayları toplanmalıdır. Bunun yerine W alt uzaylarını ifade etmek için bir filtre kullanılırken V alt uzaylarını ifade etmek içinse başka bir filtre kullanılarak işlem kolaylaştırılmaktadır.

Dalgacık Dönüşümü de bir Çok Çözünürlüklü Analiz metodudur. Herhangi bir W alt frekans uzayı ana dalgacık fonksiyonu kullanılarak elde edilmektedir. V alt uzaylarını elde etmek için ise ölçekleme fonksiyonu (scaling function) adı verilen bir fonksiyon kullanılır.




Şekil 2.7. Çok çözünürlüklü analizde alt uzayların ifadesi.

2.1.4. Ayrık Dalgacık Dönüşümü

Şu ana kadar anlatılan işlemler Sürekli Dalgacık Dönüşümü (SDD)'nü ifade etmekteydi. SDD'de ölçekleme ve kaydırma parametreleri sonsuz değer alabildiğinden dönüşüm sonucu çok fazla miktarda veri meydana gelmektedir. SDD'deki bu veri fazlalığından ve hesaplama zorluğundan dolayı *alt bant kodlama* mantığından esinlenilerek Ayrık

Dalgacık Dönüşümü (ADD) fikri ortaya atılmıştır. Bu işlemde işaret bir grup alçak ve yüksek geçiren filtrelerden geçirilerek frekans bölgelerine ayrılmaktadır. Yüksek geçiren filtre ana dalgacık fonksiyonunu temsil ederken alçak geçiren filtre ölçekleme fonksiyonunu temsil etmektedir. Şekil 2.9.'da üç seviyeli ADD işlemi görülmektedir. Görüldüğü gibi işaret her adımda bahsedilen filtrelerden geçirilerek alt frekans bölgelerine ayrılmaktadır. Bu şekilde $h[n]$ alçak geçiren filtreyi, $g[n]$ ise yüksek geçiren filtreyi ifade etmektedir.




Şekil 2.8. Frekans uzayında alt frekans bölgeleri.

Bu ardışık işlemin her seviyesinde işaretten belirli bir frekans bölgesi ayrılır, kalan bölge ise ikinci seviyede aynı işleme dâhil edilerek, işlem istenilen seviyeye gelinceye kadar sürdürülebilir. Her seviyede elde edilen işaretler ayrıca alt örnekleme yardımı ile yarı boyutuna indirilmektedir. Bu işlem sayesinde ölçekleme işlemi gerçekleştirilmiş olmaktadır. İşaretin yarı boyutuna indirilmesiyle kullanılan filtre işarete göre büyüyeceği için ölçekleme parametresinin artırılması işlevini görür. ADD işleminde ölçekleme ve öteleme parametreleri ikinin katları olan değerler almaktadır. Bu sayede veri fazlalığından sakınılmış olmaktadır. Şekil 2.10.'da ise örnek bir iki boyutlu işaretin ADD işlemine tâbi tutulması gösterilmektedir. Dönüşüm sonucu oluşan katsayılardan işaretin yeniden elde edilebilmesi için her seviyedeki katsayıların ters işleminden geçirilmesi gerekmektedir.

İki boyutlu ADD de bir boyutlu ADD işlemine benzer adımlar içermektedir. Farklı olarak her bir seviyede öncelikle satırlar filtrelerden geçirilir, daha sonra ise alt


örnekleme işleminden geçirildikten sonra elde edilen sonuçların sütunları aynı filtrelerden geçirilerek işlem gerçekleştirilir. Şekil 2.10.'da da tek seviyeli iki boyutlu ADD işlemi şematik olarak verilmiştir. Şekil 2.11.'de ise bir görüntünün bu dönüşüm sonucu oluşan alt bantları ve yön bilgilerinin yapısı görülmektedir. *YA* alt bandı yukarıdan aşağıya, *AY* alt bandı soldan sağa *YY* alt bandı ise çapraz olarak yüksek frekans bölgelerini içermektedir. *AA* alt bandı görüntüye alçak geçiren filtre uygulanmasının sonucudur ve her seviye ayrıştırmada biraz daha bulanıklaşmaktadır.




Şekil 2.9. Üç seviyeli bir ADD işleminin adımları.

Dalgacık Dönüşümü'nde ana dalgacık fonksiyonu olarak kullanılan çok sayıda temel fonksiyon vardır. Dönüşüm sonucu elde edilen katsayılar ana dalgacık fonksiyonunun ötelenmesi ve ölçeklenmesi sonucu elde edilen alt dalgacıklara bağlı olduğundan seçilen ana dalgacık fonksiyonu sonuca direkt etki eder. Bu sebeple uygulamaya uygun ana dalgacık fonksiyonu seçimi önem arz etmektedir. Şekil 2.12.'de yoğun olarak kullanılan

iki ana dalgacık fonksiyonu verilmiştir. Bu fonksiyonlar bu tez çalışmasındaki deneylerde de kullanılmıştır.




Şekil 2.10. İki boyutlu tek seviyeli ADD işlemi.



Şekil 2.11. (a) Woman isimli görüntünün alt bantları, (b) alt bantların frekans yönleri.

Ana dalgacık fonksiyonları, ters dönüşümün sağlıklı yapılabilmesi amacıyla Denklem 2.10.'da verilen koşulları sağlamak zorundadırlar.




Şekil 2.12. (a) Daubechies ailesinden bir dalgacık (Daubechies (2)), (b) Haar dalgacığı.

$$\begin{aligned}
 \int |\psi(x)|^2 dx &= 1 \\
 \int |\psi(x)| dx &< \infty \\
 \int \psi(x) dx &= 0
 \end{aligned} \tag{2.10}$$

Bu şartlara göre bir ana dalgacık fonksiyonu; sonlu enerjiye sahip, karesel integrallenebilir fonksiyonlar uzayına ait ($\in L^2(\mathbb{R})$) ve sıfır ortalamaya sahip olmalıdır. Sıfır ortalamaya sahip olması sayesinde dalgacık katsayıları, işaretin toplam akısını değiştirmeden toplanabilir [11]. Bunların dışında uygulamaya bağlı olarak çok sayıda özellik ana dalgacık fonksiyonundan beklenebilir. Bunlar arasında; belirli sayıda sıfır noktasının olması, sürekli ve integrallenebilir olması veya belirli bir aralıkla desteğe (compact support) sahip olması sayılabilir. Bu şartlar ana dalgacık fonksiyonu seçimini belirleyen faktörlerdir.

Dalgacık Dönüşümü sonucu elde edilen katsayılar üzerinde işlemler yaptıktan sonra ters dönüşüm işlemiyle tekrar bu katsayılardan dönüşümü yapılan işaret elde edilebilir. İşaret İşleme’de de dalgacık dönüşümünün kullanımı bu biçimde olmaktadır. Şekil 2.13.’de görüleceği üzere öncelikle işaret Dalgacık Dönüşümü yardımıyla istenilen seviyede ayrıştırılır. Daha sonra katsayılar üzerinde istenilen işlemler yapılır. Elde edilen işlenmiş katsayılar kullanılarak Ters Dalgacık Dönüşümü yöntemiyle işlenmiş işaret elde edilir.




Şekil 2.13. Dalgacık dönüşümü yöntemiyle İşaret İşleme'nin temel adımları.

2.1.5. Ayırık Dalgacık Dönüşümü İle Görüntü Birleştirme

Bir işaretin uzaysal detaylarının yüksek frekans bölgelerinde olması, Dalgacık Dönüşümü'nün görüntü birleştirmede kullanılmasının temelini oluşturmaktadır. İki görüntünün belirli seviyede ayrıştırılması sonucu oluşan dalgacık katsayılarından amaca uygun olanlar seçilerek, uzaysal olarak hangi görüntünün detayının birleştirilmiş görüntüde yer alacağı belirlenir. Bu belirleme işlemi birleştirme karar haritası yardımıyla yapılır. Birleştirme kurallarına göre hazırlanan birleştirme karar haritası, hangi kaynak görüntünün dönüşüm katsayılarının birleştirilmiş katsayılar haritasında yer alacağını tayin eder. Birleştirme kuralları, ADD ile görüntü birleştirmenin temelini teşkil etmektedir. Şekil 2.14.'de blok diyagramı görüleceği üzere, öncelikle iki kaynak görüntü ADD işleminden geçirilir ve her bir kaynak görüntü için katsayılar haritası oluşturulur. Daha sonra elde edilen dönüşüm katsayılarından hangilerinin birleştirilmiş katsayılar haritasında yer alacağı belirlenir. Birleştirilmiş katsayılar haritasının Ters Ayırık Dalgacık Dönüşümü (TADD) alınarak birleştirilmiş görüntü elde edilir.

Birleştirme kuralları; piksel, pencere ve alan tabanlı olmak üzere aşağıda anlatıldığı gibi üç gruba ayrılmaktadır [14].

Piksel tabanlı birleştirme: Görüntü birleştirme işlemi sırasında hangi katsayıların birleştirilmiş katsayılar haritasında yer alacağını belirlemek üzere, kaynak görüntü katsayıları karşılıklı olarak piksel piksel incelenerek iki katsayı pikselinden birinin seçilmesi suretiyle gerçekleştirilmektedir. Ağırlıklı olarak kullanılan piksel tabanlı birleştirme yöntemi iki kaynak görüntünün dalgacık dönüşümü katsayılarından büyük olanı alarak yapılan birleştirme yöntemidir [15].



Şekil 2.14. Ayrık Dalgacık Dönüşümü yöntemiyle görüntü birleştirmenin temel adımları.


Pencere tabanlı birleştirme: Kaynak görüntü katsayılarından hangisinin birleştirilmiş katsayılar haritasında yer alacağını belirlemek için sadece piksel piksel bir karşılaştırma yapmak yerine, ilgilenilen pikselin yakın komşularının da seçme işleminde rol oynaması sağlanarak gerçekleştirilmektedir. Şekil 2.15.'de piksel tabanlı ve pencere tabanlı birleştirme algoritmaları ifade edilmektedir.

Bölge tabanlı birleştirme: Sabitler belirlenirken pencere tabanlı kurallara ek olarak sabitlerin bulunduğu bölgeler de dikkate alınır. Bölgeler bazı özelliklerine göre belirlenmiş görüntü alanlarıdır. Tespit edilmek istenen bir silahın ilgilenilen bölgeyi belirtebileceği gibi, bir insan da ilgilenilen bölgeyi belirtebilir. Şekil 2.16.'da alan tabanlı görüntü birleştirme kurallarının nasıl belirlendiği şematik olarak görülmektedir [14].


Bölge tabanlı kurallar belirlenirken görüntünün kenarları ya da alan bilgileri gibi özellikleri de dikkate alınmaktadır. Lehigh Üniversitesi görüntü birleştirme araştırmaları sayfasında açıklanan teknikte öncelikle kaynak görüntünün ADD sonucu oluşan

katsayılar haritasındaki *AA* bandında *Canny* köşe belirleme yöntemi uygulanmaktadır [14]. Bu bilgi daha sonra bölge bölümlenmede kullanılmaktadır.

Kaynak görüntülerin katsayıları



Şekil 2.15. Piksel tabanlı ve pencere tabanlı görüntü birleştirme.



Şekil 2.16. Alan tabanlı birleştirme algoritması.

Yüksek frekanslı dalgacık sabitlerinin ortalaması alınarak aktivite seviyeleri belirlenir. Bu aktivite seviyeleri kullanılarak aktivite tabloları oluşturulur. Aktivite değerinin yüksek olması o alanın birleştirme işlemi için daha fazla bilgi sunabileceği anlamını taşır. Her bir kaynak görüntünün görüntü alanı ve bu alanların aktivite tabloları kullanılarak birleştirme kuralları belirlenir. Bu kuralların bütünü füzyon karar haritasını oluşturur. Bu haritalar kullanılarak ADD işlemi ile birleştirilmiş görüntü elde edilir.

Bu yaklaşımda kullanılan tercih edilen özellikler şu şekilde tanımlanmıştır;

- Aktivite seviyesi yüksek olan bölgeler,
- Köşe noktalar,
- Küçük alanlar.

Ayrıca önerilen teknikte karar haritasında yer alan bağımsız (tek) noktalar ihmal edilmektedir.


Köşe ve kenar bilgilerini daha belirgin hale getirerek birleştirme işlemi yapan başka bir yaklaşım [16] no'lu kaynakta sunulmaktadır. Bu yaklaşımda en büyük ölçülü dalgacık dönüşümü kullanılarak nesnelerin köşe özelliklerini ve bileşen bilgilerini son birleştirilmiş görüntüde daha iyi belirtebilen, farklı seviye ve bant genişliklerinde uygulanabilen bir yapı oluşturulmuştur. Görüntü birleştirilmesi dört temel adımda gerçekleştirilmektedir. İlk olarak görüntülerin ADD ile ayrıştırılması işlemi gerçekleştirilir. İkinci adımda kaynak görüntülerin her farklı seviyesi için en yüksek ölçüt hesaplaması yapılır. Üçüncü adımda füzyon kuralları kullanılarak görüntüler birleştirilir. Bu yöntemde kullanılan seçim kistası, ADD uygulanan her noktanın katsayılarının mutlak değeri olarak en büyük olanının kullanılmasına dayanır. En son adımda TADD işlemi ile birleştirilmiş görüntü elde edilir.

2.2. Laplacian Piramidi Temelli Görüntü Birleştirme

2.2.1. Temel Teori

Görüntü piramitleri ilk defa çok çözünürlüklü görüntü analizi ve insan görme sisteminde bulunan iki gözden gelen görüntülerin birleştirilmesindeki modeli ifade etmekte kullanılmıştır. Bir görüntü piramidi, dönüşümü alınacak görüntünün alçak veya

bant geçiren filtreden geçirilmiş kopyalarından oluşur. Bu oluşan kopya görüntülerde bant limiti ve çözünürlük adım adım azaltılmıştır [17]. Burt ve Andelson, Laplace algoritmasını 1983'te görüntü kodlama metodu olarak tanıtmışlardır [18]. Laplacian Piramidi çok çözünürlüklü analiz yapabilen bir algoritmadır. Çok çözünürlüklü Analiz, görüntüyü farklı ölçeklere sahip birçok çözünürlük katmanına ayırmaktadır. Piramit, her katmanında bir önceki görüntünün küçültülmüş ve filtrelenmiş örneğini bulunduran bir görüntü dizisidir. En aşağıdaki katmanda orijinal görüntü ile aynı ölçekte ve en yüksek çözünürlüğe sahip bir görüntü bulunur. Yukarıdaki katmanlar ise bu görüntünün hem büyüklüğü hem de çözünürlüğü küçültülmüş birer örneğinden ibarettir. Şekil 2.17.'de çok çözünürlüklü piramitin oluşturulması şeması verilmiştir [19].



Şekil 2.17. Çok çözünürlüklü piramidin oluşturulması.


Laplacian Piramit Dönüşümü'ndeki ilk adım orijinal görüntü g_0 'ı alçak geçiren filtreden geçirmektir ki, bunun sonucunda g_0 'ın küçültülmüş hali olan g_1 oluşmaktadır. Daha sonraki katmanda g_1 'in küçültülmüş hali g_2 oluşturulur. Bu, katman katman işlenen süreç; $0 < l < N$ katmanları ve $0 \leq i < C_l$, $0 \leq j < R_l$ noktaları ifade etmek üzere aşağıdaki formülde belirtilmiştir:

$$g_l(i, j) = \sum_{m=-2}^2 \sum_{n=-2}^2 w(m, n) g_{l-1}(2i + m, 2j + n) \quad (2.11)$$

Denklem 2.11.'de N piramitteki katman sayısını ifade ederken w ise işlemin gerçekleştirildiği pencereyi ifade etmektedir ve yukarıdaki ifadede 5×5 boyutlu olarak seçilmiştir. m ve n pencere içerisindeki piksellerin koordinatlarını belirtmektedir. Daha

önce bahsedilen C_l ve R_l ise l 'nci katmanın boyutunu ifade ederler. Bu indirgeme işlemi aşağıdaki *indirgeme fonksiyonu* ile ifade edilebilir. İndirgeme işlemi Şekil 2.18.'de grafik olarak da ifade edilmiştir.

$$g_l = \text{indirge} (g_{l-1}) \quad (2.12)$$



Şekil 2.18. İndirgeme işleminin gerçekleştirilmesi.

İndirgeme işlemi, görüntünün yerel, simetrik ağırlık fonksiyonlarından birisiyle konvolüsyon işlemine tabi tutulmasıyla elde edilir. Bu fonksiyonlardan birisi Gaussian dağılımıdır. $g_0, g_1, \dots, g_n$ görüntü dizisine ise Gaussian Piramidi denir. Burt ve Andelson'un da önerdikleri gibi boyutu 5x5 olan bir pencere seçilmiştir, çünkü bu durumda kısa hesaplama ile güzel bir filtreleme etkisi meydana gelmektedir [18]. İşlem çekirdeği olarak bilinen bu ağırlık maskesi seçilirken belirli şartlara dikkat edilmelidir. Mesela sadeleştirme için kısımlara ayrılabilirdir. Bu ifade Denklem 2.13.'de verilmektedir.

$$w(m, n) = \hat{w}(m) \cdot \hat{w}(n) \quad (2.13)$$

Burada bir boyutlu ve uzunluğu 5 olan $\hat{w}$ fonksiyonu normalize edilmiş ve simetriktir ve aşağıdaki denklemde de ifade edildiği gibi değerleri toplamı 1'dir.

$$\sum_{m=-2}^2 \hat{w}(m) = 1 \quad (2.14)$$

Ayrıca aşağıda belirtildiği gibi $\hat{w}$ fonksiyonu simetriktir.

$$\hat{w}(i) = \hat{w}(-i), \quad i = 0, 1, 2 \quad \text{için} \quad (2.15)$$

Diğer bir şart ise “eşit katılım” dır. Bu şarta göre bir seviyedeki tüm elemanlar bir yüksek seviyedeki elemanlara eşit oranda ($=1/4$) etki etmelidir. Mesela $\hat{w}(0) = a$, $\hat{w}(-1) = \hat{w}(1) = b$ ve $\hat{w}(-2) = \hat{w}(2) = c$ olsun, bu durumda eşit katılım şartına göre $a - 2c = 2b$ olur. Bu üç şart aşağıdaki durumda sağlanmış olur.

$$\begin{aligned} \hat{w}(0) &= a \\ \hat{w}(-1) &= \hat{w}(1) = 1/4 \\ \hat{w}(-2) &= \hat{w}(2) = 1/4 - a/2 \end{aligned} \quad (2.16)$$

Şekil 2.19.’da Gaussian Piramit Algoritması’yla üretilmiş görüntüler görülmektedir [18].



Şekil 2.19. Gaussian Piramidi Algoritması ile üretilmiş görüntüler.

İndirgeme fonksiyonun tersi genişletme fonksiyonudur ve Denklem 2.17.’deki biçimde tanımlanmıştır.

$$g_{l,n} = \text{genislet}(g_{l,n-1}) \quad (2.17)$$

Bu fonksiyonun amacı, dizinin boyutu $(M+1) \times (N+1)$ iken elemanların arasına yeni değerleri eklemek suretiyle $(2M+1) \times (2N+1)$ haline getirmek, yani genişletmektir.

Denklem 2.18.’de bu işlemin matematik ifadesi verilmektedir.

$$g_{l,n}(i,j) = 4 \sum_{m=-2}^2 \sum_{n=-2}^2 w(m,n) g_{l,n-1}(\frac{i-m}{2}, \frac{j-n}{2}) \quad (2.18)$$

Burada l ve n katmanları ($0 < l < N$, $0 \leq n$), i ve j ise elemanları, ($0 \leq i < C_{l-n}$, $0 \leq j < R_{l-n}$) olmak üzere ifade ederler.

Laplace Piramidi $L_0, L_1, \dots, L_n$ hata görüntüler dizisinden ibarettir. Bunlardan her biri Gaussian Piramidi'nin iki katmanı arasındaki farkı ifade eder. Öyle ise $0 < l < N$ için,

$$\begin{aligned} L_l &= g_l - \text{genislet}(g_{l+1}) \\ &= g_l - g_{l+1,1} \end{aligned} \quad (2.19)$$

dir. g_N 'in tahmini için gerekli g_{N+1} görüntüsü bulunmadığından dolayı, $L_N = g_N$ 'dir. Denklem 2.20.'de ifade edildiği gibi genişletme işlemi yapıldıktan sonra Laplace Piramidi'nin tüm katmanları toplanırsa orijinal görüntü, hiçbir veri kaybı olmadan, yeniden elde edilebilir.

$$g_0 = \sum_{l=0}^N L_{l,l} \quad (2.20)$$


2.2.2. Birleştirme Algoritması

İlk defa 1983'te Burt ve Andelson tarafından önerilen bu metot, sonraki yıllarda geliştirilen birçok yaklaşıma esas olmuştur [20,21]. Temel mantığı, her bir giriş görüntüyü piramit bölümlmeye tabi tutup oluşan piramitleri birleştirmek ve sonunda meydana gelen bu birleştirilmiş yapıyı ters piramit dönüşümüne tabi tutup birleştirilmiş sonuç görüntüyü elde etmektir.

Laplacian Piramit birleştirme metodunun şematik diyagramı Şekil 2.20.'de gösterilmiştir [22]. Aslında algoritma iki giriş görüntüden daha çok görüntü işleyebilmektedir, ama anlatım kolaylığı için iki girişli bir sistem gösterilmiştir.

Algoritmanın birinci adımı, her bir giriş görüntüsü için birer piramit oluşturmaktır. Bundan sonra piramidin her bir katmanı için seçme mekanizması kullanılarak birleştirme işlemi gerçekleştirilir.

Birleştirmenin birçok mantığı kullanılabilir, mesela seçme veya ortalama alma [21]. Seçme mantığına göre incelenen pencere için giriş görüntülerinden en uygun pencere seçilir ve bileşik piramide kopyalanır, uygun olmayan pencere ise atılır. Seçme işleminin matematik ifadesi Denklem 2.21’de verilmektedir.



Şekil 2.20. Laplacian Piramidi birleştirme algoritması.

Ortalama alma mantığına göre ise giriş görüntülerdeki pencerelerin ortalaması alınır. Bu ortalama alma süreci, giriş görüntülerin aynı görüntülere sahip bölgelerinde hem gürültüyü azaltır, hem de kararlılık sağlar. Bu iki mantık içerisinde birincisi giriş görüntülerin birbirinden farklı olduğu açıkça görüldüğünde, öteki ise girişlerin birbirine benzediği durumlarda kullanılır.

$$F_l(x, y) = \begin{cases} A_l(x, y), & |A_l(x, y)| > |B_l(x, y)| \text{ ise} \\ B_l(x, y), & \text{diger} \end{cases} \quad (2.21)$$

Buradaki A_l ve B_l kaynak görüntülerini F_l ise birleştirme sonucunu ifade eder (katman aralığı $0 \leq l \leq N - 1$).

2.3. Morfolojik Piramit Temelli Görüntü Birleştirme

Morfolojik Piramit Dönüşümü esnasında Laplacian Piramidi Dönüşümü'nden farklı olarak morfolojik filtreler olarak adlandırılan özel filtreler kullanılır. Morfolojik filtreler alçak geçirgen ya da bant geçirgen filtreler kullanılarak yapılan dönüşümlerde ortaya çıkan şekil değişimlerini ve konum kaymalarını azaltır [23]. Serra tarafından geliştirilen morfolojik filtreler iki basit dönüşüme dayanır. Bu dönüşümler kapanış ve açılış operatörleri ile gerçekleştirilir [24].

Açılış aynı giriş üzerinde işlem yapan ve birbirini takip eden iki operatörü içerir. Bu iki operatörden ilki aşındırma operatörüdür ve şeklin yerel olarak karşılaştırılması işlevini gerçekleştirir. Aşındırma operatörünün hemen ardından genişletme operatörü işlem yapar. Bu iki operasyon için kullanılan girdi yapısal eleman olarak adlandırılır. Yapısal eleman 0 ve 1'lerden oluşan ve komşu biçim ve büyüklüklerini açıklamak için kullanılan bir matristir. Bu matrisin biçim ve boyutu isteğe bağlı olarak belirlenmektedir.

Morfolojik Piramit dönüşümü yapılmış görüntülerin birleştirilmesi Laplacian Piramidi dönüşümü yapılmış görüntülerin birleştirilmesi işlemi sırasında yapılan işlevler ile aynıdır.

2.3. Ratio Piramidi Temelli Görüntü Birleştirme

Ratio Piramidi'nin oluşturulması da Laplacian Piramidi'nin oluşturulmasına benzemektedir. Öncelikle giriş görüntüsü için Gaussian Piramidi oluşturulur. Daha sonra Laplacian Piramidi metodunda olduğu gibi sıralı katmanlar arasındaki farkı hesaplamak yerine, sıralı katmanlar arasındaki oran hesaplanır. Ratio Piramidi aşağıdaki gibi ifade edilir [25].

$$R_i = G_i / GENISLET[G_{i+1}] \quad 0 < i < N-1 \text{ için} \quad (2.22)$$

Son dönüşüm değerleri N'inci seviye için Gaussian ve Ratio Piramitleri aynı değeri ifade etmektedir:

$$R_N = G_N. \quad (2.23)$$

Burada G_i Gaussian Piramidi'ndeki seviyeleri R_i ise Ratio Piramidi'ndeki seviyeleri ifade etmektedir. Ratio Piramidi'ndeki her seviye Gaussian Piramidi'ndeki ardışık iki seviyenin oranıdır.

Kontrast serisi aşağıdaki gibi ifade edilirse:

$$C_i = G_i / G_{i+1} - 1, \quad (2.24)$$

$$R_i = C_i + 1 \quad (2.25)$$

şeklinde ifade edilebilir [25].

Ratio Piramidi kaynak görüntünün tam ifadesidir, yani kaynak görüntü (G_0), piramidi oluşturmakta kullanılan işlemler ters çevrilerek tam olarak elde edilebilir:

$$G_N = C_N \text{ olmak üzere,}$$

$$G_i = C_i \cdot GENISLET[G_{i+1}], \quad 0 < i < N-1 \text{ için} \quad (2.26)$$

Ratio Piramidi ile görüntü birleştirme işlemi Laplacian Piramidi ile görüntü birleştirme işlemi ile aynıdır. Öncelikle kaynak görüntülerin piramidi kurallara uygun olarak oluşturulur. Daha sonra birleştirilmiş piramit, iki piramitten istenen bölgelerin transfer edilmesiyle elde edilir. Bu birleştirilmiş piramit ters dönüşüm işleminden geçirilerek birleştirilmiş görüntü elde edilir. Birleştirilmiş piramidin oluşturulması sırasında kullanılan seçme işlemi diğer piramit yöntemlerinde olduğu gibi, kaynak piramit piksellerinden maksimum olanının alınması, minimumunun alınması veya kaynak piramit piksellerinin ortalamalarının alınması şeklinde olabilir.

2.4. Kaymadan Bağımsız Ayırık Dalgacık Dönüşümü

ADD işleminin en önemli potansiyel sorunu kaymadan olumsuz etkilenmesidir. Bu sorun ADD işlemindeki alt-örnekleme işleminden ileri gelmektedir. Alt-örnekleme işlemi ikici (dyadic) olarak yapıldığından, her iki dalgacık katsayısından birinin atılması yoluyla gerçekleştirilmektedir. Alt-örnekleme, fazla işlem ve veri yükünden kurtulmak için yapılmaktadır. Bu biçimde yapılan alt-örnekleme sonucu katsayılar bulundukları konuma yüksek oranda bağımlı olmaktadır. Bunun sonucunda katsayılar için konum bağlamında en ufak sapmalar enerji dağılımında yüksek değişimlere ve ters dönüşüm sonucu elde edilen işaretlerde büyük değişikliklere neden olmaktadır.

ADD dönüşümünü kaymadan bağımsız yapmanın en kolay yolu alt-örnekleme işlemini gerçekleştirilmemektir. Bu işlem *algorithm à trous* [26] olarak bilinir. Alt-örnekleme ve işaretin küçülmesi işlemi gerçekleştirilmediği için ana dalgacığın her seviyede sıfır eklenerek genişletilmesi söz konusu olmaktadır. Bu işlem herhangi bir ana ADD işleminde kullanılan dalgacık fonksiyonu ile gerçekleştirilebilir. Bu işlem fazla hafıza ve işlem gücü gerektirmektedir, zira işaret alt-örnekleme yapılmadığı için küçülmemekte ve fazladan veri bölgeleri oluşmaktadır. Kaymadan bağımsız bir ADD elde edebilmek amacıyla bu olumsuz yönler göze alınmaktadır. *À trous* işlemi dairesel kaymalara karşı duyarsızdır [27].

Kaymadan bağımsızlığı sağlamanın daha karmaşık bir yolu ise iki dalgacık ayrıştırma ağacı oluşturmaktır. Bu iki ağacın birbirinden farkı, ilk ağacık tek simetrlili ikinci ağacın ise çift simetrlili ana dalgacık içermesidir. Bu şekilde çift ağaçlı karmaşık dalgacık dönüşümü (Dual-Tree Complex Wavelet Transform (DTCWT)) işlemi işaretin gerçek ve sanal kısımlarının elde edilmesini sağlar [28]. Bu işlem sonucu hem büyüklük hem de faz bilgisi içerdiği için kaymadan büyük oranda bağımsızdır. Bu işlemde de hafıza ve işlem maliyeti ADD işlemine göre hayli fazladır.

Belirlenen yöntemler kaymadan bağımsız dalgacık dönüşümü alınan görüntülerin birleştirilmesi işlemi standart ADD ile görüntü birleştirme işlemi ile aynıdır. Karşılıklı katsayılardan maksimum olanını alma, karşılıklı katsayıların ortalamasını alma veya her alt bant için farklı seçim metodu uygulama yoluna gidilebilir.

3. BÖLÜM

DİFERANSİYEL GELİŞİM ALGORİTMASI


3.1. Algoritmanın Temeli

Gündelik hayatta karşımıza çıkan bir çok problem doğrusal veya doğrusal olmayan optimizasyon problemi olarak modellenebilmektedir. Bu problemlerin birçoğu doğrusal olmayan problemlerdir ve bu tür problemlerin çözümü amacıyla birçok teknik geliştirilmiştir. Bu tip problemlerin çözümü için deterministik yöntemler kullanmak, modellemede ve çözümde zorluklarla karşılaşılacağı için pek uygun değildir. Bu sorunu aşmak için sezgisel yöntemler geliştirilmiştir. Özellikle popülasyon temelli sezgisel algoritmalar çok noktayı aradıkları için çok hızlı sonuç vermektedirler. Genetik Algoritma, Diferansiyel Gelişim Algoritması, Yapay Arı Kolonisi Algoritması [29] bunlardan bazılarıdır.

Diferansiyel Gelişim Algoritması (DGA), Price ve Storn tarafından geliştirilmiş, sürekli verilerin söz konusu olduğu problemlerde etkin sonuç verebilen, temel olarak Genetik Algoritmaya (GA) bağlı sezgisel bir optimizasyon tekniğidir [30]. Popülasyon tabanlı olması sebebiyle aynı anda birçok noktada araştırma yapmaktadır. Çalışması süresince operatörler yardımıyla problemin çözümü için daha iyi noktalar araştırılmaktadır. İkili (binary) GA'dan farklı olarak değişkenler kendi değerleriyle temsil edilmektedir. Price ve Storn gerçek değerlerin kullanıldığı problemlerin çözüm performansını artırmaya çalışmışlardır. GA'daki çaprazlama, mutasyon ve seçim operatörleri DGA'da da kullanılmaktadır. GA'dan farklı olarak her operatör tüm popülasyona sırayla uygulanmamakta, vektörler tek tek ele alınarak rastgele seçilen diğer üç vektörle yeni bir birey elde etmede kullanılmaktadır. Yeni vektörün oluşturulma adımları Şekil 3.1.'de verilmektedir [31].

Bu işlemler sırasında mutasyon ve çaprazlama operatörleri kullanılmış olmaktadır. Mevcut vektörle yeni vektörün uygunlukları (fitness) karşılaştırılarak uygunluğu daha iyi olan vektör yeni birey olarak bir sonraki popülasyona aktarılmaktadır. Böylelikle seçim operatörü de kullanılmış olmaktadır.. Üretilen çözümün uygunluk değeri, uygunluk fonksiyonu tarafından üretilen çözüme verilen uygunluk değeridir.

DGA'nın diğer sezgisel algoritmalarından önemli bir üstünlüğü de kolay kodlanabilmesi ve daha az satır kodla gerçekleştirilebilmesidir.



Şekil 3.1. Yeni vektörün oluşturulması işlemi.

3.2. Problem ve Parametreler

NP : Popülasyon büyüklüğü $NP \geq 4$ (1, 2, 3, ..., i)

D : Değişken sayısı (1, 2, 3, ..., j)

CR : Çaprazlama oranı [0.1,1.0]

G : Jenerasyon (1, 2, 3, ..., $G_{\max}$)

F : Ölçekleme faktörü

$x_{j,i,G}$: G jenerasyonunda, i . vektörün j parametresi

$n_{j,i,G+1}$: Mutasyon ve çaprazlamaya tabi tutulmuş ara vektör

$u_{j,i,G+1}$: $x_{j,i,G}$ den bir sonraki jenerasyon için üretilen vektör

$r_{1,2,3}$: Yeni vektörün hesaplanmasında kullanılacak rastgele seçilmiş vektörler $r_{1,2,3} \in \{1,2,3,\dots, NP\}$ $r_1 \neq r_2 \neq r_3 \neq i$

$x_j^{(l)}, x_j^{(u)}$: Değişkenlere ait alt ve üst sınır değerleri

Optimizasyon problemleri genel olarak aşağıdaki gibi ifade edilebilir [32].

$f(X)$ 'i

$g_k(X) \leq 0$ ve

$x_j^{(l)} \leq x_j \leq x_j^{(u)}$ $j = 1, \dots, n$

kısıtları ile minimize et.

Burada $f(X)$ uygunluk fonksiyonunu, $g_k(X)$ kısıtlar setini ve $X = \{x_1, x_2, \dots, x_n\}$ gerçek değerli değişkenler setini ifade etmektedir. $x_j^{(l)}$ ve $x_j^{(u)}$ sırasıyla değişkenlere ait alt ve üst sınır değerleridir.

Amaç tüm kısıtları sağlayan en iyi çözümü araştırmaktır. Uygunluk fonksiyonu DGA'da uygunluk fonksiyonu olarak belirlenmekte ve her bir vektör için bir çözümü temsil etmektedir. DGA da GA gibi kısıtlarla çalışmamaktadır. Kısıtların amaç fonksiyonu içerisinde ele alınması gerekmektedir. Bunun için ceza yöntemi kullanılabilir. Kısıtlardan uzaklaşmalar meydana geldiğinde uygunluk değerine ceza değeri eklenerek bu noktanın iyi bir çözüm olmadığı DGA'ya dikte edilmelidir. Ayrıca

problem parametrelerinin belirlenen alanın dışına çıkmasına izin verilmemelidir. Zira buna izin verilirse DGA sonsuza gidebilecektir. Bu sorun için ya parametreler sınır değerlere çekilmeli veya sınır dışında değer almış parametrelerin yeni değerleri rastgele olarak sınır değerleri içinde yeniden belirlenmelidir. Problemin amaç fonksiyonu, değişkenler ve kısıtlar belirlendikten sonra aşağıdaki adımlar izlenerek DGA uygulanır.

3.3. Kodlama ve başlangıç popülasyonu

Probleme ait değişken sayısı her bir vektöre ait parametre (boyut (D)) sayısını belirlemektedir. NP ise kullanıcı tarafından belirlenen vektör sayısıdır. Vektör sayısı üçten büyük olmalıdır. Çünkü DGA’da yeni vektörlerin üretilmesi için mevcut vektör dışında üç adet vektör gerekmektedir. Başlangıçta NP adet D boyutlu vektörden meydana gelen başlangıç popülasyonu (P_0) aşağıdaki gibi üretilir [33].

$$\forall_i \leq NP \wedge \forall_j \leq D : x_{j,i,G=0} = x_j^{(1)} + rand_j[0,1].(x_j^{(u)} - x_j^{(1)}) \quad (3.1)$$

3.4. Mutasyon

Mutasyon, mevcut vektörün bir kısım parametreleri üzerinde, rastgele belirlenmiş miktarlarda değişiklikler yapmaktır. Bu değişiklikler sayesinde vektörünün temsil ettiği çözüm noktası, artık çözüm uzayında farklı bir noktayı temsil etmektedir. Mutasyonun hedefine ulaşabilmesi için, doğru yönde doğru miktarda hareketi sağlayacak değişikliklerin belirlenmesi gerekmektedir.

DGA’da, mutasyon işlemine tabi tutulacak olan vektör dışında ve birbirlerinden de farklı olan üç vektör seçilir. Seçilen vektörlerden ilk ikisinin farkı alınır. Daha sonra bu fark vektörü F parametresiyle çarpılır. F parametresi genellikle 0-2 arasında değerler almaktadır. Elde edilen ağırlıklandırılmış fark vektörü ile seçilen üçüncü vektör ile toplanır. Böylece, mutasyon sonucu çaprazlamada kullanılacak olan vektör elde edilmiş olur ($n_{j,i,G+1}$). Bu işlem Denklem 3.2’de matematiksel olarak ifade edilmiştir. Literatürde, kullanılan farklı birçok mutasyon operatörü bulunmaktadır [34].

$$\forall_j \leq D : n_{j,i,G+1} = x_{j,r_3,G} + F.(x_{j,r_1,G} - x_{j,r_2,G}) \quad (3.2)$$

3.5. Çaprazlama

Çaprazlama yapılırken, mutasyon sonucu elde edilen fark vektörü ve $x_{i,G}$ vektörü kullanılarak yeni jenerasyona aday, deneme vektörü ($u_{i,G+1}$) üretilir. Deneme vektörüne ait her bir parametre CR olasılıkla fark vektöründen $1-CR$ olasılıkla mevcut vektörden seçilir. Düzenli çaprazlamada her bir parametre ayrı olarak değerlendirilip eşit olasılıkla iki ebeveyn vektöründen birinden seçilmektedir.

DGA'da ise eşit olasılık yerine CR olasılığı söz konusudur. 0 ile 1 arasında üretilen rasgele sayı CR 'den küçükse $gen, n_{j,i,G+1}$ 'den aksi takdirde mevcut vektörden seçilir. Denklem 3.3'de bu ifade yer almaktadır. Amaç belirlenen oranda parametrenin yeni fark vektöründen alınmasıdır. Buradaki $j = j_{rand}$ koşulu, en az bir tane parametrenin üretilen yeni vektörden alınmasını garanti etmek amacıyla konulmuştur. Rastgele seçilen j_{rand} noktasındaki parametre CR 'ye bakılmaksızın $n_{j,i,G+1}$ 'den seçilir.

$$\forall_j \leq D : x_{j,u,G+1} = \begin{cases} x_{j,n,G+1} & \text{eğer } rand[0,1] \leq CR \vee j = j_{rand} \\ x_{j,i,G} & \text{aksi durumda} \end{cases} \quad (3.3)$$


3.6. Uygunluk fonksiyonu

Yukarıdaki adımlardan sonra elde edilen yeni vektörün veya mevcut vektörün yeni jenerasyona geçmesi söz konusudur. Bu noktada elde edilen yeni vektörün uygunluk değeri hesaplanır. Mevcut vektörün uygunluk değeri zaten bilinmektedir. Seçim operatörü ile yeni jenerasyon eldeki vektörlerden üretililecektir.

3.7. Seçim

Seçim operatörü ile mevcut jenerasyon ve üretilen yeni vektörler değerlendirilerek yeni jenerasyon oluşturulur. Vektörlerin yeni jenerasyonda yer alma olasılıkları uygunluklarına bağlıdır. DGA' da karşılaştırma birebir yapıldığından seçim için karmaşık prosedürü olan seçim operatörlerine ihtiyaç duyulmamaktadır. Karşılaştırılan vektörlerden uygunluğu yüksek olan vektör yeni jenerasyonun bireyi olarak atanmaktadır [35].

Algoritma yukarıda verilen adımlarda ilerleyerek optimizasyon işlemini gerçekleştirecektir. Bu noktada dikkat edilmesi gereken husus durdurma kistasının belirlenmesidir. Durdurma kistası olarak belirli bir iterasyon sayısı verilebilir. Bu durumda algoritma istenen iterasyona ulaştığında çalışmasını durduracaktır. Veya çalışma esnasında elde edilen en iyi uygunluk değeri ile en kötü uygunluk değerinin birbirine çok yaklaşması durumunda da çalışma sonlandırılabilir. Eğer algoritmanın ulaşması istenen uygunluk değeri önceden biliniyorsa bu değer verilerek de algoritmanın çalışması durdurulabilir. Şekil 3.2.'de DGA algoritmasının akış şeması verilmiştir.



Şekil 3.2. DGA algoritmasının akış şeması.

4. BÖLÜM

BİRLEŞTİRME SONUCUNUN DEĞERLENDİRİLMESİ

Görüntü birleştirme, çeşitli kaynaklardan alınmış iki yada daha fazla görüntünün insan görsel algılamasına veya bilgisayar yorumlamasına daha uygun sonuçlar elde etmek amacıyla birleştirilmesi esasına dayanmaktadır. Görüntü birleştirme algoritmalarının sonuçlarının verimliliğini ölçmek veya birleştirme esnasında kullanılacak parametreleri belirlemek amacıyla kalite değerlendirme metriklerine ihtiyaç duyulmaktadır. Bu konudaki ihtiyaçları karşılamak amacıyla literatürde birçok metrik önerilmiştir.

Görüntü birleştirme işleminin sonuçlarının değerlendirmesinde sıklıkla kullanılan metot insan görsel algılamasıdır. Bu yöntemin dezavantajı ise değerlendirme işlemine sübjektif bir yaklaşım getirmesidir. Objektif kalite ve performans değerlendirmesi genellikle başarılması zor bir amaç olarak karşımıza çıkmaktadır.

Çok-odaklı görüntü birleştirme işleminde, farklı noktaları bulandırılmış kaynak görüntülerle işlem yapıldığı için elde tamamen net bir kıstas görüntünün bulunması değerlendirme işlemine kolaylık getirmektedir. Bu sayede farklı odaklı görüntülerin birleştirilmesi sonucu elde edilen birleştirilmiş görüntü kıstas görüntü ile karşılaştırılabilmektedir. Bu karşılaştırma işlemi çoğunlukla hataların karelerinin ortalaması (Mean Square Error-MSE) metodu kullanılarak gerçekleştirilmektedir.

Buna karşın elde bir kıstas görüntünün bulunmadığı çok-sensörlü görüntü birleştirme işlemlerinde kalite ve performans değerlendirmesi yapmak daha güç hale gelmektedir. Bu konuda literatürde kullanılan çeşitli metrikler bulunmaktadır. Aşağıda bunlardan bazıları ele alınmıştır.

4.1. Karşılıklı Bilgi

Karşılıklı Bilgi (Mutual information), iki rastgele değişken arasındaki istatistiksel bağımlılığın bir ölçüsü olarak kullanılan, bilgi teorisinin en genel kavramlarından birisidir. Başka bir ifadeyle bir değişkenin diğer değişkenlerle alakalı içerdiği bilginin miktarını verir.

Iraksama iki ayrı rastgele değişken dağılımı arasındaki uzaklığın bir ölçüsüdür ve Denklem 4.1 ile hesaplanır.

$$D(P\|Q) = \sum_i p_i \log \frac{p_i}{q_i} \quad (4.1)$$

Burada p_i ve q_i , sırasıyla P ve Q dağılımlarının olasılık dağılımlarını ifade etmektedir. Karşılıklı Bilgi, birleşik olasılık yoğunluklarının iraksaması ve marjinal olasılıkların çarpımının özel bir ifadesidir [36] ve aşağıdaki şekilde elde edilir.

$$I_{XY}(x, y) = \sum_{x,y} P_{XY}(x, y) \log \frac{P_{XY}(x, y)}{P_X(x)P_Y(y)} \quad (4.2)$$

$P_{XY}(x, y)$ birleşik dağılımı, $P_X(x)$ ve $P_Y(y)$ ise sırasıyla x ve y 'nin marjinal dağılımlarını belirtmektedir. Görüntü birleştirmede Karşılıklı Bilgi çeşitli şekillerde kullanılabilir. Birleştirilmiş görüntünün öncelikle birinci kaynak görüntü ile Karşılıklı Bilgi değerinin hesaplanması daha sonra ise birleştirilmiş görüntünün ikinci kaynak görüntü ile Karşılıklı Bilgi değerinin hesaplanması ve sonuçların toplanması yöntemlerden birisidir [37]. Fakat kaynak görüntülerden bir tanesine fazla yaklaşmasını dolayısıyla diğer kaynak görüntüden fazla uzaklaşmasını önlemek açısından bu iki Karşılıklı Bilgi sonucunun toplanması yerine çarpılması daha iyi bir tercih olabilir. Bu sayede birleştirilmiş görüntünün iki kaynak görüntüden de belirli oranda bilgi içermesi sağlanmış olmaktadır. Karşılıklı Bilgi'nin görüntü birleştirmede metrik olarak kullanılması aşağıda özetlenmiştir.

Öncelikle birleştirilmiş görüntü ile birinci kaynak görüntünün Karşılıklı Bilgi değeri aşağıdaki biçimde elde edilir.

$$I_{FX}(f, x) = \sum_{f, x} P_{FX}(f, x) \log \frac{P_{FX}(f, x)}{P_F(f)P_X(x)} \quad (4.3)$$

Daha sonra birleştirilmiş görüntü ile ikinci kaynak görüntünün Karşılıklı Bilgi değeri benzer şekilde aşağıdaki biçimde elde edilir.

$$I_{FY}(f, y) = \sum_{f, y} P_{FY}(f, y) \log \frac{P_{FY}(f, y)}{P_F(f)P_Y(y)} \quad (4.4)$$

Metrik ise bu iki sonucun çarpılması ile elde edilir ve ifadesi Denklem 4.5’de verilmiştir.

$$m_{fxy} = I_{FX}(f, x) \cdot I_{FY}(f, y) \quad (4.5)$$

Yukarıdaki ifadelerde f birleştirilmiş görüntüyü, x birinci kaynak görüntüyü y ise ikinci kaynak görüntüyü belirtmektedir.

4.2. Tsallis Entropisine Dayalı Karşılıklı Bilgi

Karşılıklı Bilgi metriğinin bazı dezavantajları bulunmaktadır. Sürekli olarak en iyi metrik değerini iki kaynak görüntünün ortalamasının alınmasıyla oluşan ortalama birleştirilmiş görüntüye vermektedir. Ortalama ile birleştirme genellikle kontrastı düşük ve sübjektif olarak ta tatminkâr sonuç vermeyen bir birleştirme yöntemidir. Fakat birleştirilmiş görüntüye iki kaynak görüntüden de bol miktarda bilgi taşınması söz konusu olduğu için Karşılıklı Bilgi değeri çok yüksek çıkmaktadır [38].

Bu yüzden kaynak görüntülerden birleştirilmiş görüntüye transfer işlemini daha iyi modelleyen yeni bir istatistiksel yaklaşıma gerek duyulmaktadır. Tsallis Entropi, geleneksel Boltzmann-Gibbs istatistiğini genelleştirmede kullanılmış genişlemesiz bir entropi çeşididir [38]. Tsallis Entropi, tanım itibari ile Denklem 4.6.’da da ifade edildiği üzere Shannon Entropisi’nin bir parametre genelleştirilmiş halidir. L’Hopital kuralına göre $\alpha \rightarrow 1$ ’e giderken Tsallis Entropi, Shannon Entropisine yakınsamaktadır.

$$H^\alpha = (1 - \alpha)^{-1} \left(\sum_x p(x)^\alpha - 1 \right) \quad (4.6)$$

x ve y kaynak görüntüler f ise birleştirilmiş görüntü olmak üzere f ile x 'in ve f ile y 'nin arasındaki benzerlik metriği aşağıdaki gibi ifade edilir.

$$\begin{aligned} I_{FX}^\alpha(f, x) &= \frac{1}{1-\alpha} \left(1 - \sum_{f,x} \frac{(p_{FX}(f, x))^\alpha}{(p_F(f)p_X(x))^{\alpha-1}} \right) \\ I_{FY}^\alpha(f, y) &= \frac{1}{1-\alpha} \left(1 - \sum_{f,y} \frac{(p_{FY}(f, y))^\alpha}{(p_F(f)p_Y(y))^{\alpha-1}} \right) \end{aligned} \quad (4.7)$$

Yine Karşılıklı Bilgi metriğinde olduğu gibi sonuç metrik değeri bu iki değerlerin çarpılması veya toplanması şeklinde aşağıdaki denklem ile elde edilebilir.

$$M_{FXY}^\alpha = I_{FX}^\alpha(f, x) + I_{FY}^\alpha(f, y) \quad (4.8)$$

4.3. Kalite indeksi

Reel değerli $x = (x_1, x_2, \dots, x_n)$ ve $y = (y_1, y_2, \dots, y_n)$ dizileri için $\bar{x}$, x dizisinin ortalamasını σ_x^2 ve σ_{xy} sırasıyla x 'in varyansı ve x ile y 'nin kovaryansını göstermek üzere Wang ve Bovik'in kalite indeksi aşağıdaki şekilde tanımlanmaktadır [39].

$$\sigma_x^2 = \frac{1}{n-1} \sum_i^n (x_i - \bar{x})^2, \quad \sigma_{xy} = \frac{1}{n-1} \sum_i^n (x_i - \bar{x})(y_i - \bar{y}). \quad (4.9)$$

$$Q_0 = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\bar{x}^2 + \bar{y}^2)(\sigma_x^2 + \sigma_y^2)}, \quad (4.10)$$

veya başka bir ifadeyle bu tanım Denklem 4.11. ile elde edilebilir.

$$Q_0 = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \cdot \frac{2\bar{x}\bar{y}}{\bar{x}^2 + \bar{y}^2} \cdot \frac{2\sigma_x \sigma_y}{\sigma_x^2 + \sigma_y^2} \quad (4.11)$$

Bu denklemde birinci bileşen işaretler arasındaki korelasyon katsayısını ifade eder ve $[-1,1]$ aralığında değer alır. İkinci bileşen parlaklık bozulmasını üçüncü bileşen ise kontrast bozulmasını ifade ederken iki bileşen de $[0,1]$ aralığında değer almaktadır. Dolayısıyla üç bileşenin çarpımı olan kalite indeksi $[-1,1]$ aralığında değer alır. İki

görüntünün birbirine yakınlığı 1'e yakın değerler meydana getirirken uzaklığı ise -1'e yakın değerler üretmektedir.

Görüntü işaretleri genellikle durağan olmayan işaretler olduğu için, kalite indeksi Q_0 'ın bölgesel olarak hesaplanması ve elde edilen sonuçların derlenmesi daha uygun olmaktadır. Wang ve Bovik çalışmalarında kayan pencere mantığını kullanmışlardır [39]. Sabit boyutlu bir pencere görüntülerin sol üst köşesinden başlamak suretiyle sağ alt köşeye gelinceye kadar kaydırılarak tüm görüntü taranmış olmaktadır. Her bir pencerede elde edilen kalite indekslerinin ortalamaları alınarak genel kalite indeksi elde edilmektedir. Bu işlem aşağıdaki denklemde ifade edilmiştir.

$$Q_0(a, b) = \frac{1}{|W|} \sum_{w \in W} Q_0(a, b|w), \quad (4.12)$$

Wang ve Bovik kendi metriklerini literatürde hâlihazırda var olan MSE gibi bazı metriklerle karşılaştırmışlar ve Q_0 kalite indeksinin diğer metriklerden daha iyi sonuç verdiğini tespit etmişlerdir. Kendi metotlarının MSE'den daha iyi sonuç vermesinin nedenini, kendi metotlarının, L^2 enerji hatalarına daha duyarlı olan MSE'nin aksine, yapısal hatalara daha duyarlı olması olarak açıklamışlardır [39].

Piella ve Heijmans ise bu kalite indeksini geliştirerek daha performanslı hale getirmeye çalışmışlardır [40]. Sonuç olarak Wang ve Bovik'in metriğinden esinlenerek Denklem 4.13.'da verilen metriği önermişlerdir.

$$Q_0(a, b, f) = \frac{1}{|W|} \sum_{w \in W} (\lambda(w)Q_0(a, f|w) + (1 - \lambda(w))Q_0(b, f|w)). \quad (4.13)$$

$$\lambda(w) = \frac{s(a|w)}{s(a|w) + s(b|w)} \quad (4.14)$$

Burada a ve b iki kaynak görüntüyü ifade ederken f ise birleştirilmiş görüntüyü belirtmektedir. $s(a|w)$ bir a görüntüsünün w penceresi içerisindeki belirginlik (saliency) değerini ifade etmektedir. Piella ve Heijmans, yaptıkları deneysel çalışmalarda belirginlik ifadesi olarak varyans kullanmışlardır [40]. a ve b 'nin lokal belirginlik

değerleri kullanılarak lokal ağırlık değeri olan ve $[0,1]$ arasında değer alan $\lambda(w)$ değeri elde edilmekte ve metriğin hesaplanmasında kullanılmaktadır.

Böylece a 'nın belirginlik değerinin b 'ye oranla daha büyük olduğu lokal bölgelerde, $Q(a,b,f)$ değeri ağırlıklı olarak a görüntüsü tarafından belirlenmektedir. Ters durumda ise, $Q(a,b,f)$ değeri genel olarak b görüntüsü tarafından belirlenmektedir.

Bu noktada bu model, her bir kaynak görüntüden belirginlik değeri yüksek ne kadar bilginin birleştirilmiş görüntüye taşındığını ölçen ve bozulma bilgisi içermeyen bir metrik durumundadır. Fakat bu işlem, her pencere için üretilen değere eşit önem vermektedir. Bu durum yüksek belirginlik değerine sahip bölgelere daha fazla önem veren insan görme mekanizmasına pek uygun olmamaktadır. Bu sebeple Piella ve Heijmans belirginlik değeri yüksek olan bölgelere daha fazla önem veren bir yaklaşımla aşağıdaki modeli geliştirmişlerdir [40].

$$c(w) = C(w) / (\sum_{w' \in W} C(w')) \quad (4.15)$$

olmak üzere,

$$Q_W(a,b,f) = \sum_{w \in W} c(w) (\lambda(w) Q_0(a,f|w) + (1 - \lambda(w)) Q_0(b,f|w)) \quad (4.16)$$

Denklem 4.16. üzerinde gerçekleştirilen son bir güncelleme ile model daha da verimli hale getirilmiştir. Bu güncelleme ile kenarlara daha fazla önem veren insan görme mekanizması taklit edilmiştir. Bu yeni modelde, görüntülerin metrik değeri ile kenar görüntülerin (örneğin dikey ve yatay gradyen görüntülerin öklid normu) metrik değerleri çarpılarak sonuç metrik değeri elde edilmektedir. Bir a görüntüsünün kenar görüntüsü a' ile ifade edilmek üzere yeni model aşağıdaki şekilde ifade edilmektedir.

$$Q_E(a,b,f) = Q_W(a,b,f) \cdot Q_W(a',b',f')^\alpha \quad (4.17)$$

Burada α parametresi kenar görüntüsünün gerçek görüntü ile karşılaştırıldığında metrik sonucuna ne kadar etki edeceğini belirleyen bir parametredir.

5. BÖLÜM

DİFERANSİYEL GELİŞİM ALGORİTMASI İLE MEDİKAL GÖRÜNTÜ BİRLEŞTİRME

Daha önce de belirtildiği gibi yapılan çalışma çok-sensörlü medikal görüntü birleştirme alanında yapılmıştır. Yapılan çalışmaya geçmeden önce çok-sensörlü görüntü birleştirme ve medikal alanda uygulaması ele alınacaktır. Daha sonra ise yapılan çalışma ayrıntılarıyla anlatılarak son bölümde de deneysel sonuçlar verilecektir.

5.1. Çok-Sensörlü Görüntü Birleştirme

Çok-sensörlü görüntü birleştirme, son yıllarda gerek askerî, gerekse sivil sahalarda oldukça ilgi toplamış bir konudur. Veri birleştirme teknikleri, iki veya daha fazla sensörden alınan görüntüleri bir araya getirme yoluyla tek bir sensörden alınan görüntüden elde edilemeyecek bazı etkileşimli bilgilerin ve hassaslığın elde edilmesini sağlarlar [41, 42]. Çok-sensörlü görüntü birleştirme konusu literatüre yeni katılan alanlardandır. İnsanlar ve hayvanlar çeşitli duyularını kombine ederek hayatta kalma kabiliyetlerini geliştirmişlerdir. Örneğin yenebilir bir nesnenin kalitesi sadece görme ve dokunma duyularını kullanmakla anlaşılmayabilir. Fakat koklama ve tatma duyularının kullanılması sayesinde bu nesnenin kalitesi hakkında yorum getirmek çok daha kolaylaşacaktır. Aynı mantıkla çalılıkların arkasındaki bir nesnenin varlığı bilgisi sadece görme duyusuyla elde edilemeyeceği halde duyma duyusunun yardımıyla böyle bir nesnenin varlığı çeşitli canlılar tarafından algılanabilir. Doğada çeşitli canlılar çok-sensörlü (çok duyulu) veri birleştirme yöntemiyle daha hassas, daha kesin ve daha verimli bilgi elde edebilmektedirler [43]. Yapay zekâ tekniklerinin de gelişmesiyle veri birleştirme konusu çok daha verimli bir şekilde gerçekleştirilebilir hale gelmiştir. Günümüzde veri birleştirme teknikleri genellikle hedef izleme, hedef kimliklendirme ve

otomatik sonuç çıkarma uygulamalarında sıklıkla kullanılmaktadır. Gerekli matematik altyapının da son yıllarda oldukça gelişmesiyle veri birleştirme işlemi daha kolay gerçekleştirilebilir hale gelmiş ve yeni bir boyut kazanmıştır. Ticareti yapılan veri birleştirme ile alakalı çok sayıda paket yazılım da piyasada bulunabilmektedir.

Çok-sensörlü veri birleştirme çok geniş bir konudur ve kendisine birçok uygulama alanı bulmuştur. Sivil alanda üretim sürecinin takibi, robotik ve medikal uygulamalar bunlara örnek olarak gösterilebilir. Veri birleştirmede kullanılan teknikler işaret işleme, yapay zekâ teknikleri, klasik sayısal metotlar vb. [44, 45, 46] çok çeşitli disiplinlere dayanmaktadır.

Çok-sensörlü görüntü birleştirme sahası içerisinde medikal görüntü birleştirme çalışmaları önemli yer tutmaktadır. Klinik uygulamalarda ortaya çıkan yüksek ilgiden dolayı son yıllarda çok-sensörlü medikal görüntü birleştirme konusu dikkatleri üzerine çekmiştir. Örneğin radyoterapi planı farklı moddaki çeşitli medikal görüntülerden gelen veriler destek alınarak oluşturulmaktadır. Doz hesaplaması CT verilerine dayanırken, tümör takibi MR verilerine dayanmaktadır. CT görüntüleri yoğun yapılarda yüksek gri ton seviye değeri, seyrek yapılarda ise düşük gri ton seviye değeri üretmektedir. İnsan vücudunun CT ile görüntülenmesi sonucu en yoğun yapılar olan kemikler en yüksek gri ton değerlerini, yumuşak doku orta seviyede gri ton değerlerini, boşluklar ise en düşük gri ton değerlerini içerecektir. MR görüntüleme ise hidrojen atomuna duyarlı bir görüntüleme sistemidir. Hidrojenin çokça içerildiği yumuşak dokularda en yüksek gri ton değerlerini, içerilmediği bölgelerde ise düşük gri ton değerlerini vermektedir. Ayrıca CT görüntüleri çok az bozulma ile sonuçları verirken MR görüntüleri çeşitli uzaysal ve radyometrik bozulmalar sergilemektedir. Benzer şekilde MR görüntüleri de kendi içinde özelliklerine göre çeşitlere ayrılmaktadır. MRI-T1 anatomik yapılar için daha detaylı görüntüler üretirken MRI-T2 normal ve normal olmayan dokular arasında daha iyi kontrast gösteren görüntüler üretir. İki özelliğin de içinde bulunduğu bir görüntü elde etmek için görüntü birleştirme teknikleri kullanılabilir. Bundan başka PET gibi çeşitli farklı görüntüleme teknikleri de medikal alanda kullanılmaktadır. Her biri farklı özellik ve veri içeren bu görüntülerin tümleyen verilerinin birleştirilerek tek bir görüntü halinde kullanılması hem hekimler açısından kolaylık sağlayacaktır hem de bu verilerin tek bir görüntü halinde saklanabilmesinden dolayı depolama sorunlarının azaltılması mümkün olacaktır.

Literatürde medikal görüntü birleştirme üzerine yapılmış birçok çalışma bulunmaktadır. Bunlar arasında; Laplacian Piramidi [6], Gradient Piramidi [47], ADD metodu [7], SIDWT metodu [48] ve Ratio Piramidi [49] sayılabilir.

5.2. ADD İle Medikal Görüntü Birleştirme

Geliştirilen teknik dalgacık dönüşümü temelini kullanarak optimum bir birleştirme yapmayı amaçlamaktadır. Optimizasyon yapılabilmesi için bir uygunluk fonksiyonu tasarlanmış ve Diferansiyel Gelişim Algoritması ile optimize edilmiştir. İlk olarak kullanılan dalgacık temeli ve geliştirilen uygunluk fonksiyonu ele alınacak daha sonra ise bu uygunluk fonksiyonunun optimize edilmesi anlatılacaktır.

5.2.1. Kullanılan Dalgacık Dönüşümü Yöntemi

Daha önce de ele alındığı gibi Ayrık Dalgacık Dönüşümü (ADD), her bir ayrıştırma seviyesinde (AS) dönüşümü yapılacak görüntüyü 4 alt banda ayırmaktadır. *YY* (Yatay olarak yüksek frekans, dikey olarak yüksek frekans filtresinden geçirilmiş), *YA* ve *AY* bantları kısmen yüksek frekans bilgisi içerirken, *AA* alt bandı düşük frekans bilgisi içerir. *AA* alt bandı, AS artırılarak ADD işlemi ile ayrıştırılmaya devam edilebilir. Üç AS sonucu Şekil 5.1.'de görülen yapı ortaya çıkmaktadır.

AA	YA3	YA2	YA1
AY3	YY3		
AY2		YY2	
AY1			YY1

Şekil 5.1. Ayrık Dalgacık Dönüşümü sonucu oluşan alt bantlar.

Birleştirilmek istenen iki görüntünün istenen seviyede ayrıştırılmasıyla, karşılıklı alt bantlar arasında bir birleştirme işlemi gerçekleştirilebilir. Bu birleştirme işlemi sonucunda elde edilen birleştirilmiş katsayılar haritası Ters Ayırık Dalgacık Dönüşümü (TADD) yöntemine tabi tutulursa birleştirilmiş görüntü elde edilmektedir. Bu işlem sırasında önemli olan husus bu iki kaynak görüntüden alt bantların ne şekilde birleştirilmiş karar haritasına aktarılacağıdır. Bu çalışmada karşılıklı alt bantların belirli bir katsayı ile birleştirilmiş karar haritasında yer alması yöntemi tercih edilmiştir. Bu yapıya göre α kullanılacak katsayıyı, $A1$ ve $B1$ herhangi bir AS'de, kaynak görüntüden elde edilen karşılıklı alt bantları belirtmek üzere bu işlem aşağıdaki biçimde ifade edilebilir.


$$Af = A1 * \alpha + B1 * (1 - \alpha) \quad (5.1)$$

Burada Af , birleştirilmiş karar haritasında yer alacak, $A1$ ve $B1$ alt bantlarının yukarıdaki işlem sonucu birleştirilmesiyle elde edilen alt bandı ifade edilmektedir. Bu işlem, iki seviyeli ayrıştırılmış iki kaynak görüntünün birleştirilmesi durumunda Şekil 5.2.'deki gibi gerçekleştirilmektedir. $YA1a$, a kaynak görüntüsünün birinci seviye ayrıştırılması sonucu oluşan YA alt bandını ifade etmektedir. Benzer şekilde $AY2b$, b kaynak görüntüsünün ikinci seviye ayrıştırılması sonucu oluşan AY alt bandını ifade etmektedir. f ise birleştirilmiş görüntüyü sembolize etmektedir.

Bu çalışmada, işlem sırasında birleştirme işleminin sonucunu direkt etkileyen katsayıların (α) optimizasyon algoritması ile bulunması yoluna gidilmiştir. Böyle bir işlem sırasında optimize edilmesi gereken katsayı sayısı $AS+1$ adettir. Zira her bir alt bant için bir katsayı belirlemek yerine her bir AS için bir katsayı belirlenmiştir. AA bandı sürekli işleme tabi olduğu için sadece son AS'de AA alt bandı katsayı ile çarpılarak işleme dâhil edilmiştir.

Örneğin Şekil 5.2.'de, iki seviyeli ayrıştırılan iki görüntünün birleştirilmesi şematik olarak verilmiştir. Bu işlemde üç katsayı kullanılmaktadır. Birinci katsayı kaynak görüntülerin birinci seviye ayrıştırılması sonucu oluşan YY , AY ve YA bantları için kullanılmaktadır. Birleştirilmiş kaynak görüntünün YY alt bandı, birinci kaynak görüntünün YY alt bandı ile ikinci kaynak görüntünün YY alt bandının birinci katsayı ile Denklem 5.1.'de ifade edilen işleme tabi tutulmasıyla elde edilir. Birleştirilmiş

görüntünün YY alt bandını $YY1_F$ ile kaynak görüntülerin YY alt bantlarını ise sırasıyla $YY1_A$ ve $YY1_B$ ile ifade edersek bu işlem Denklem 5.2.'deki gibi ifade edilebilir.



Şekil 5.2. İki seviyeli ayrıştırılmış görüntülerin birleştirilmesi.

$$YY1_F = \alpha_1 \cdot YY1_A + (1 - \alpha_1) \cdot YY1_B. \quad (5.2)$$

Burada α_1 birinci katsayıyı ifade etmektedir. Bütün katsayılar taşma olmaması için $(0,1)$ aralığında olmalıdır. Katsayıların hepsi 1 olduğunda birleştirilmiş görüntü birinci

kaynak görüntü, 0 olduğunda ise ikinci kaynak görüntü olarak elde edilmektedir. Bu aralıktaki diğer değerler ise kaynak görüntülerin alt bantlarının birleştirilmiş görüntünün söz konusu alt bandında ne kadar etkili olacağını belirtir. Yukarıdaki işlem sadece YY bandı için verilmiştir. Aynı işlem yine birinci katsayı ile işleme giren AY ve YA alt bantları için de aynıdır. AA alt bandı ise ikinci seviye ayırtırmaya girmiş ve ikinci seviye YY , AY ve YA alt bantlarını oluşturmuştur. İkinci seviye için yapılan işlem aşağıdaki gibi olacaktır.

$$YY2_F = \alpha_2 \cdot YY2_A + (1 - \alpha_2) \cdot YY2_B. \quad (5.3)$$

Bu sefer ikinci katsayıyı ifade eden α_2 değeri kullanılmıştır. Diğer değerler ise ikinci seviye YY , AY ve YA alt bantlarını ifade etmektedir. İki seviyeli ayırtırma yapıldığı için AA alt bandı daha fazla ayırtırılmayarak, ayırtırma sonucu oluşan haritada yer almaktadır. Dolayısıyla birleştirilmiş görüntü haritasının AA alt bandı kaynak görüntülerin karşılık gelen AA alt bandı yoluyla aşağıdaki şekilde elde edilir.

$$AA_F = \alpha_3 \cdot AA_A + (1 - \alpha_3) \cdot AA_B. \quad (5.4)$$

AA alt bantları birleştirilirken üçüncü katsayı olan α_3 kullanılmıştır.

5.2.2 Uygunluk Fonksiyonu

Optimizasyon uygulamalarında en temel işlem uygunluk fonksiyonunun tasarlanmasıdır. Uygunluk fonksiyonu sayesinde optimize edilecek parametrelerin uygunluğu optimizasyon algoritması tarafından değerlendirilebilir ve bu sayede yeni değerler üretilebilir. Uygunluk fonksiyonunun temel işlevi optimizasyon algoritması tarafından üretilen parametreleri kullanılan algoritmada yerine koymak ve bir uygunluk değerini optimizasyon algoritmasına geri döndürmektir. Bu uygunluk değeri optimizasyon algoritması tarafından daha önceden belirlenen bir hedefe vardırılmaya çalışılır. Bu hedef kimi çalışmalar için uygunluk değerinin minimum olması iken bazı çalışmalar için maksimum olmasıdır. Yapılan bu çalışmada kullanılan metriğin yüksekliği, birleştirme sonucunun daha iyi olduğunu belirttiği için uygunluk değerinin maksimize edilmesi söz konusu olmuştur. Optimize edilen değerler ise katsayılardır ve AS'ye göre sayıları değişmektedir.

Optimizasyon işleminde yukarıda bahsedildiği üzere bir uygunluk değeri dönüşünün beklenmesi dolayısıyla diğer bazı görüntü birleştirme tekniklerinin aksine sübjektif bir yaklaşım getirmek imkânsız hale gelmektedir. Çok-odaklı görüntü birleştirme işleminde, farklı noktaları bulandırılmış kaynak görüntülerle işlem yapıldığı için elde tamamen net bir kriter görüntünün bulunması değerlendirme işlemine kolaylık getirmektedir. Bu sayede farklı odaklı görüntülerin birleştirilmesi sonucu elde edilen birleştirilmiş görüntü kriter görüntü ile karşılaştırılabilmektedir. Bu karşılaştırma işlemi çoğunlukla *MSE* (hataların karelerinin ortalaması) metodu kullanılarak gerçekleştirilmektedir. Buna karşın elde bir kıstas görüntünün bulunmadığı çok-sensörlü görüntü birleştirme işlemlerinden biri olan medikal görüntü birleştirmede kalite ve performans değerlendirmesi yapmak daha güç hale gelmektedir. Bu konuda literatürde kullanılan metrikler bulunmaktadır ve bunlardan bazılarını Bölüm 4’de değinilmiştir.

Yapılan çalışmada öncelikle uygunluk fonksiyonu geri dönüşü, yani birleştirilen görüntünün ne kadar uygun olduğunun değerlendirme kıstası olarak Karşılıklı Bilgi metriği kullanılmıştır. Literatürdeki bir çok görüntü birleştirme çalışmasında da kullanılan bu metriğin bazı dezavantajları vardır ve bu dezavantajlar optimizasyon işleminde daha belirgin bir şekilde ortaya çıkmaktadır. Bunlardan en önemlisi Karşılıklı Bilgi metriğinin değerinin iki görüntüden de maksimum oranda bilginin birleştirilmiş görüntüye getirilmesi durumunda çok yüksek değer üretmesidir. Bu sebeple iki kaynak görüntünün karşılıklı piksel piksel ortalamasının alınması yoluyla yapılan görüntü birleştirme işleminde çok yüksek değer üretmektedir. Bu dezavantajın bir sonucu olarak optimizasyon algoritması, yüksek uygunluk değeri ürettiği için ortalama yoluyla birleştirilen görüntüye yakınsamaya çalışmakta ve sonuç olarak böyle bir görüntüye çok yakın bir çıkış görüntüsü vermektedir.

İkinci bir dezavantaj olarak literatürde olan çalışmalarda kaynak görüntülerin birleştirilmiş görüntü ile ayrı ayrı Karşılıklı Bilgi değeri hesaplanıp bu iki değer toplandıktan sonra uygunluk değeri elde edildiği için bir istenmeyen durum ortaya çıkmaktadır. Karşılıklı Bilgi metriği tanımı dolayısıyla belirli bir ölçekte değer üretmemekte dolayısıyla üretilen değer yüksek mi yoksa düşük mü olduğu değerlendirilememektedir. Bazı görüntülerin kendisi ile Karşılıklı Bilgi işlemine tabi tutulması sonucu 5 veya 6 gibi yüksek Karşılıklı Bilgi değerleri oluşabilirken bazılarının

Karşılıklı Bilgi değeri 1 veya altında olabilmektedir. Bu yüzden böyle iki farklı tür görüntünün optimizasyon algoritmaları yoluyla birleştirilmek istenmesi sonucu daha büyük uygunluk değeri döndüreceği için görüntülerden birine yakınsama ve birleştirilmiş görüntüde diğer görüntüden hiç bilgi içermeme durumu meydana gelebilmektedir. Örnek olarak, kendisi ile Karşılıklı Bilgi işlemi sonucu 1.2 olan bir görüntü ile kendisi ile Karşılıklı Bilgi işlemi sonucu 4.9 olan bir görüntü, optimizasyon algoritmalarından biri ile birleştirilmeye çalışılırsa sonuç kendisi ile 4.9 Karşılıklı Bilgi sonucu veren görüntü olacak, diğer görüntüden birleştirilmiş görüntüde hemen hemen hiç bilgi bulunmayacaktır. Bu dezavantajı çözmek için iki kaynak görüntünün birleştirilmiş görüntü ile Karşılıklı Bilgi sonuçları toplanmak yerine çarpılabilir. Bu sayede birleştirilmiş görüntünün kaynak görüntülerden birine yakınsaması engellenmiş olur. Zira optimizasyon algoritması birleştirilmiş görüntüyü kaynak görüntülerden birine yaklaştırmaya çalıştığında Karşılıklı Bilgi değerlerinden biri yüksek çıkarken diğer çok düşük çıkacaktır. Bu iki değerın çarpılması sonucunda ise çok yüksek olmayan bir uygunluk değeri çıkacaktır. Bu sayede optimizasyon algoritması bu noktalara fazla yaklaşmayacaktır.

Karşılıklı bilgi metriği kullanılarak yazar tarafından yapılan optimizasyon deneyleri sonucunda, uygunluk değeri literatürde bulunan çalışmalardan yüksek olan birleştirmeler gerçekleştirilebilmiştir. Ancak bu birleştirme sonucu elde edilen birleştirilmiş görüntüler Karşılıklı Bilgi metriğinin bir dezavantajı olarak ortalama yoluyla birleştirilen görüntüye çok yakınsamış ve sübjektif değerlendirmelerimiz sonucu tatmin edici bulunmamıştır. Bu sebeple literatürde önerilmiş birleştirilmiş görüntünün kalitesinin değerlendirilmesinde kullanılan diğer bazı metrikler denenmiştir.

Belirli bir ölçekte güvenilir sonuç veren bir metrik ihtiyacı gündeme gelmiştir. Literatürde yapılan tarama sonucu Piella ve arkadaşlarının geliştirdiği Wang ve Bovik kalite indeksi uygun bir metrik olarak kullanılmıştır. Bu metrik $(-1,1)$ aralığında değer üretmekte ve sonucun yorumlanmasını kolaylaştırmaktadır. Piella ve arkadaşlarının önerdikleri metrik, a ve b kaynak iki veriyi f ise birleştirilmiş veriyi ifade etmek üzere;


$$Q_w(a, b, f) = \sum_{w \in W} c(w) (\lambda(w) Q_0(a, f|w) + (1 - \lambda(w)) Q_0(b, f|w)) \quad (5.5)$$

olmak üzere,

$$Q_E(a, b, f) = Q_W(a, b, f) \cdot Q_W(a', b', f')^\alpha \quad (5.6)$$

Şeklindedir. Burada a' , b' ve f' sırasıyla a , b ve f görüntülerinin kenar görüntülerini ifade etmektedir [40]. Bu metrik ile ilgili detaylı bilgiler Bölüm 2’de ele alınmıştır.

Yapılan çalışmada bu metrik üzerinde bazı değişikliklere gidilmiştir. Öncelikle Piella ve arkadaşlarının çalışmasında pencereleme işlemi piksel piksel gerçekleştirilmiştir [40]. Görüntü boyutları dikkate alındığında bu çok uzun zaman alan bir işlem olacaktır. Ayrıca Q_W değerinin hesaplanması kendi içerisinde birçok pencereleme içerdiği için hesaplanması yine çok uzun zaman almaktadır. Yapılan çalışma bir optimizasyon çalışması olduğu için zaman oldukça önem teşkil etmektedir. Optimizasyon sırasında yalnızca bir parametre için bile uygunluk fonksiyonu binlerce kez çağrılmaktadır. Bu yüzden pencereleme işlemi piksel piksel değil pencere pencere kaydırmak suretiyle gerçekleştirilmiştir. Bu işlem şu şekilde gerçekleştirilmektedir: Pencere, 1 nolu konumdan başlayarak sırayla pencere boyutu kadar sağa kaydırılmakta ve sağ alt köşeye kadar bu işlem devam ettirilmektedir. Şekil 5.3.’de bu işlem şekilsel olarak ifade edilmektedir.



Şekil 5.3. Pencereleme işleminin gerçekleştirilmesi.

Q_E indeksinin yapısında da bazı değişikliklere gidilmiş ve aşağıdaki şekilde tanımlanmıştır.


$$Q_E(a, b, f) = Q_0(a, b, f) \cdot Q_0(a', b', f')^\alpha \quad (5.7)$$

Yukarıdaki denklemde a' , b' ve f' sırasıyla a , b ve f görüntülerinin kenar görüntülerini ifade etmektedir. α ise kenar görüntülerinin birleştirilmiş görüntünün kalitesinin belirlenmesinde ne kadar etkili olacağını belirten bir parametredir ve tez çalışmasında 1 olarak alınmıştır. Böylece Q_w değeri hesaplanmadan metrik değeri elde edilmiştir.

Uygunluk fonksiyonunda geri dönüş değeri olarak bu metrik kullanılmıştır.

5.2.3. Diferansiyel Gelişim Algoritması İle Medikal Görüntü Birleştirme

Alt bantların, ifade edildiği gibi katsayılar yardımı ile birleştirilmesi sonucu elde edilen birleştirilmiş görüntünün kontrastında düşüklük meydana gelmektedir. İki görüntüden de belirli oranda veri alınması neticesinde bu istenmeyen durum meydana gelmektedir. Şekil 5.4.'de görülen iki kaynak görüntü olan (a) ve (b)'nin birleştirilmesi sonucu (c)'de görülen görüntü elde edilmektedir.



Şekil 5.4. (a), (b) Kaynak görüntüler, (c) Birleştirilmiş kontrastı düşük görüntü.

Şekilden de görüldüğü gibi birleştirme işlemi istendiği gibi sert dokuları CT görüntüsünden yumuşak dokuları ise MR görüntüsünden birleştirilmiş görüntüye aktarmayı başarmıştır. Ancak birleştirilmiş görüntünün kontrastı düşüktür ve bu sebeple analizinde ve anormalliklerin tespitinde zorluklar meydana gelebilecektir.

Böyle bir sorunla karşılaşmamak için birinci kaynak görüntüden ikinci kaynak görüntü piksel değerleri bazında çıkarıldıktan sonra elde edilen sonuç belirli bir katsayıyla toplanmaktadır. Bu katsayı da optimizasyon algoritmasına gönderilerek optimize

edilecektir. İki görüntü arasındaki fark bazen kontrastı artırmaya yeterli olmadığı için bu tez çalışmasında böyle bir yöntem tercih edilmiştir.

Yapılan çalışma ana hatları ile şu şekildedir: Öncelikle birleştirilecek olan iki kaynak görüntü belirlenmektedir. Daha sonra ise birleştirilmenin yapılacağı AS belirlenir. Belirlenen AS'lerde kaynak görüntüler ayrıştırılarak her ikisi için de katsayılar haritası oluşturulur. Her AS için bir adet, ayrıştırma sonrası meydana gelen AA alt bandı için bir adet ve görüntülerin birbirinden çıkarılması aşaması sonucu elde edilen matrisle toplanmak üzere bir adet olmak üzere başlangıç katsayı değerleri optimizasyon algoritması tarafından rastgele olarak oluşturulur. Her iki görüntünün katsayılar haritasında bulunan her AS 'deki YY , AY ve YA alt bantları kendilerine atanan katsayılar ile Denklem 5.1.'de belirtilen işleme tabi tutulur ve elde edilen değerler birleştirilmiş görüntünün katsayılar haritasındaki uygun yerlere koyulur. Kaynak görüntülerin AA alt bantları yine kendilerine atanan katsayı ile aynı işlemden geçirilerek birleştirilmiş görüntünün AA alt bandını oluştururlar. Yapılan bu işlemlerle birleştirilmiş görüntünün katsayılar haritası meydana gelmiş olmaktadır. Elde edilen katsayılar haritası Ters Ayrık Dalgacık Dönüşümü'ne tabi tutularak ara birleştirilmiş görüntü elde edilmektedir. Daha sonra iki görüntü birbirinden aşağıdaki şekilde çıkarılarak fark görüntüsü elde edilir. Elde edilen fark görüntüsü ara birleştirilmiş görüntüye eklenerek sonuç birleştirilmiş görüntü elde edilir. Aşağıdaki ifadede F' ara birleştirilmiş görüntüyü, F ise birleştirilmiş görüntüyü belirtmektedir. α_F ise iki kaynak görüntünün birbirinden çıkarılması ile elde edilen matrise eklenen parametreyi ifade etmektedir.

$$\begin{aligned} Fark &= A - B + \alpha_F \\ F &= Fark + F' \end{aligned} \quad (5.8)$$

Bu aşamada bu birleştirilmiş görüntünün uygunluk değeri üretilerek optimizasyon algoritmasına geri dönderilir. Bu uygunluk değeri yardımıyla, optimizasyon algoritması uygunluk fonksiyonuna gönderilen parametrelerin uygunluğunu belirleyerek ürettiği yeni parametrelerle uygunluk fonksiyonunu yeniden çağırır. Bu işlem belirli bir iterasyon süresince veya belirli bir değere ulaşıncaya kadar devam eder. Aşağıda gerçekleştirilen işlemin adım adım işleyişi verilmiştir.

1. Kaynak görüntüleri oku, birinci kaynak görüntüyü A ikinci kaynak görüntüyü


ise B olarak ata.

2. AS'yi ve dalgacık dönüşümünde kullanılacak ana dalgacık fonksiyonunu belirle.
3. A ve B kaynak görüntülerini ayrı ayrı ADD işlemine tabi tutarak A görüntüsü için AAI_A, AYI_A, YAI_A ve YYI_A ve B görüntüsü için AAI_B, AYI_B, YAI_B ve YYI_B alt bantlarını elde et.
4. 3. adımda elde edilen AA alt bantlarını ADD işlemi ile ayrıştırarak AAI_A için AAi_A, AYi_A, YAi_A ve YYi_A , AAI_B için AAi_B, AYi_B, YAi_B ve YYi_B alt bantlarını elde et. Belirlenen AS'ye ulaşılmaya kadar en son oluşan AA alt bantlarını ayrıştırmaya devam et ($i=2, \dots, AS$ olmak üzere)
5. Uygulanan dönüşümler yoluyla elde edilen alt bantları her bir görüntünün katsayılar haritasını oluşturmak üzere yerine koy (bu işlem sonucu oluşan katsayılar haritası A ve B görüntüleri için Şekil 5.5.'de verilmiştir).
6. Her bir kaynak görüntünün katsayılar haritasında birbirine karşılık gelen seviyedeki alt bantları katsayılar yardımı ile birleştirme işlemine tabi tut.

$$YYi_F = \alpha_j \cdot YYi_A + (1 - \alpha_j) \cdot YYi_B \quad (AAi_F, \text{ birleştirilmiş katsayılar haritasının } AAi \text{ alt bandını temsil etmek ve } i=1, \dots, AS \text{ olmak üzere}).$$
7. 6. adımdaki işlemi AA, AY ve YA alt bantları için de tekrarla.
8. Elde edilen katsayılar haritasındaki alt bantları kullanarak ve en yüksek seviyeden başlamak üzere $TADD$ (Ters Ayrık Dalgacık Dönüşümü) işlemini gerçekleştirerek bir üst seviye AA alt bantlarını elde et. $AA(i-1) = TADD(YYi, YAi, AYi, AAi)$ ($i=AS, \dots, 2$ olmak üzere)
9. $F = TADD(YYI, YAI, AYI, AAI)$ işlemi sonucunda F birleştirilmiş görüntüsünü oluştur.

5.2.4. Deneysel Çalışma

Yapılan deneysel çalışmada dört set medikal görüntü birleştirilmiş ve literatürde var olan çeşitli görüntü birleştirme algoritmalarıyla karşılaştırılarak performans sonuçları sunulmuştur. Görüntü setleri 256X256 boyutlarında medikal görüntülerden oluşmaktadır. Bu çalışmada optimizasyon algoritması olarak DGA kullanılmıştır. DGA, her bir görüntü deney seti için ayrı ayrı, çaprazlama oranı (0,4, 0,5, 0,6, 0,7, 0,8, 0,9) ve



Şekil 5.5. (a) A görüntüsünün katsayılar haritası, (b) B görüntüsünün katsayılar haritası.

ölçekleme faktörü (0,5, 0,6, 0,7, 0,8, 0,9, 1, 2) değerleri kullanılarak 30’ar defa koşturulmuştur. Her bir F-CR parametre ikilisinin 30 defa koşturulmasıyla elde edilen uygunluk değerlerinin ortalama ve standart sapma değerleri aşağıdaki tablolarda verilmiştir. Bu deneysel çalışma sırasında, jenerasyon sayısı (G) her görüntü seti için sabit olarak 100 seçilmiştir. Dörtten yüksek seviyelerde ayrıştırma 256X256 boyutlarındaki görüntüler için çok küçük AA alt bandı üreteceğinden ve fazla bir anlam ifade etmeyeceğinden AS, 4 seçilmiştir. Bu AS değerinin seçilmesiyle optimize edilecek parametre sayısı 6 olmaktadır, dolayısıyla problem boyutu 6 olarak DGA algoritmasına verilmiştir. Arama uzayı ise problemin yapısı gereği [0,1] aralığı olmaktadır. Her bir görüntü seti için, optimizasyon çalışması sonucu elde edilen parametrelerden en iyileri kullanılarak birleştirilmiş görüntüler, aşağıdaki şekillerde DGA ile birleştirilmiş görüntüler olarak yer almaktadır.


Aşağıdaki şekillerde; CT, Kaynak CT görüntüsünü, MR, Kaynak MR görüntüsünü, T1, MR-T1 tipi kaynak MR görüntüsünü, T2, MR-T2 tipi kaynak MR görüntüsünü, DE, DGA ile optimizasyon sonucu elde edilen birleştirilmiş görüntüyü, Ortalama, ortalama alma metodu ile birleştirilmiş görüntüyü, SIDWT, Kaymadan Bağımsız Ayrık Dalgacık Dönüşümü metodu ile birleştirilmiş görüntüyü, Laplacian, Laplacian Piramidi metodu ile birleştirilmiş görüntüyü, Kontrast, Kontrast Piramidi metodu ile birleştirilmiş görüntüyü, ADD, Ayrık Dalgacık Dönüşümü yöntemiyle birleştirilmiş görüntüyü,


Morfolojik, Morfolojik Piramit metodu ile birleştirilmiş görüntüyü ve Ratio, Ratio Piramidi metodu ile birleştirilmiş görüntüyü ifade etmektedir.

Deneyisel çalışma ayağında, DGA ile birleştirme tekniği ile karşılaştırmada kullanılan diğer dönüşüm metotlarında da AS 4 seçilmiştir. Yine bu dönüşüm metotlarında, AA alt bandı için ortalama seçme metodu diğer alt bantlar için ise maksimumu seçme metodu kullanılmıştır. SIDWT metodu için dalgacık ailesi olarak Haar, diğer dalgacık dönüşümü içeren metotlar için ise Daubechies(2) tercih edilmiştir.

Birinci grup deney görüntüleri Şekil 5.6.'da verilmiştir. Tablo 5.1.'de ise birinci grup deney görüntülerinin DGA ile birleştirilmesi sonucu elde edilen uygunluk değerleri görülmektedir. Tablodaki her bir hücre, karşılık gelen çaprazlama (CR) ve ölçekleme parametresi (F) değerlerini kullanarak, optimizasyon algoritmasının 30 defa koşturulması sonucu elde edilen uygunluk değerlerinin ortalamasını ve standart sapmasını içermektedir. Görüldüğü gibi elde edilen uygunluk değerleri tüm DGA parametreleri için karşılaştırılan tekniklerin hepsinden daha iyi sonuçlar vermiştir. Bu deney grubu için elde edilen en iyi uygunluk değeri ortalaması 0,56389 olmuştur ve F, 0,8 ve CR, 0,8 parametrelerinden elde edilmiştir. Bu ortalamayı veren uygunluk değerlerinden en iyisi olan 0,56578 değerini veren katsayılar ise (0,055355, 0,025039, 0,024163, 0,03114, 0,025971, 7,2) olarak elde edilmiştir. Birinci deney grubu görüntüleri için her AS'de bir katsayı ile birleştirme yapmak yerine her alt bantta bir katsayı ile birleştirme yöntemi de denenmiştir. Bu biçimde yapılan birleştirme işleminde her AS için elde edilen 3 alt banda ayrı ayrı birleştirme parametreleri atanmış ve DGA ile bu parametrelerin optimizasyonu yoluna gidilmiştir. 4 seviyeli bir ayrıştırma sonucu; her AS için 3'er adet olmak üzere 12, bir adet LL alt bandına bir adet de fark resimle toplanmak üzere toplam 14 parametre optimize edilmektedir ve DGA'nın G parametresi de 14 olarak belirlenmiştir. DGA ile 30 koşma sonucu oluşan uygunluk değerlerinin ortalama ve standart sapmaları Tablo 5.2.'de verilmiştir. Tablodaki ortalama değerlerden en iyisi F, 0,6 ve CR, 0,7 parametrelerinden 0,55507 olarak elde edilmiştir. Bu ortalama değerini veren değerlerden en iyisi olan 0,56480 değerini (0,038471, 0,037206, 0,038771, 0,067535, 0,069285, 0,068229, 0,06695, 0,068287, 0,068953, 0,070183, 0,066642, 0,067296, 0,072582, 6,8) parametreleri vermiştir. Her alt bant için bir parametre belirlenmesi sonucu elde edilen değerler her AS için bir parametre belirlenmesi sonucu elde edilen değerlerle çok yakınlık arz etmektedir. Ayrıca her

seviyedeki alt bantların parametreleri birbirine çok yakın çıktığı için böyle bir yöntem sadece birinci deney grubu için denenmiş diğer deney grupları için çalışma tekrarlanmamıştır, zira 14 parametrenin optimizasyonu 6 parametrenin optimizasyonundan daha fazla zaman, işlem gücü ve hafıza kaynağı tüketmektedir.





Şekil 5.6. Birinci grup deney görüntüleri: (a) ve(b) Kaynak görüntüler, (c) Geliştirilen teknikle birleştirilmiş görüntü, (d), (e), (f), (g), (h), (i) ve (j) değişik yöntemlerle birleştirilmiş görüntüler ve uygunluk değerleri

Tablo 5.1. Birinci grup deney görüntüleri için, kullanılan F ve CR parametrelerine göre 30 koşma sonucu elde edilen uygunluk değerlerinin ortalaması ve standart sapması.


F CR	56	0,5	0,6	0,7	0,8	0,9	1	2
0,4	Ort.	0,50591	0,54901	0,53447	0,53968	0,50639	0,49557	0,47503
	Std. Sapma	0,04151	0,00714	0,00954	0,00824	0,03532	0,02452	0,08353
0,5	Ort.	0,53484	0,55879	0,52159	0,53446	0,49108	0,50424	0,48108
	Std. Sapma	0,03053	0,00636	0,01502	0,00712	0,05210	0,00712	0,05532
0,6	Ort.	0,52496	0,53384	0,55045	0,50156	0,53716	0,50084	0,48537
	Std. Sapma	0,04378	0,02721	0,02152	0,04750	0,03934	0,03960	0,05901
0,7	Ort.	0,49460	0,55227	0,55321	0,55916	0,52450	0,48146	0,47524
	Std. Sapma	0,04836	0,01267	0,00918	0,00400	0,02832	0,04196	0,07767
0,8	Ort.	0,49937	0,52243	0,50083	0,56389	0,49354	0,49541	0,48973
	Std. Sapma	0,03003	0,06092	0,04310	0,00119	0,03356	0,01258	0,03371
0,9	Ort.	0,50944	0,52804	0,53781	0,51687	0,53443	0,50717	0,52081
	Std. Sapma	0,06721	0,04601	0,01065	0,05213	0,02177	0,04208	0,03663


Tablo 5.2. Birinci grup deney görüntülerinin her alt banda ayrı parametre atanması yoluyla birleştirme işlemi için, kullanılan F ve CR parametrelerine göre 30 koşma sonucu elde edilen uygunluk değerlerinin ortalaması ve standart sapması.

F CR	56 14	0,5	0,6	0,7	0,8	0,9	1	2
0,4	Ort.	0,51457	0,53406	0,53739	0,54239	0,51438	0,48693	0,48272
	Std. Sapma	0,02064	0,00428	0,01629	0,01264	0,05302	0,02421	0,05368
0,5	Ort.	0,53605	0,5443	0,50954	0,54416	0,50411	0,50841	0,49048
	Std. Sapma	0,01968	0,02397	0,02042	0,01257	0,02516	0,00852	0,02322


0,6	Ort.	0,51873	0,55357	0,55184	0,51692	0,52648	0,49854	0,49446
	Std. Sapma	0,05863	0,02234	0,03092	0,02049	0,00194	0,01472	0,06158
0,7	Ort.	0,51494	0,55507	0,55407	0,54872	0,51420	0,49855	0,48827
	Std. Sapma	0,03061	0,01801	0,02154	0,00168	0,04254	0,05569	0,03836
0,8	Ort.	0,50482	0,52343	0,51540	0,55384	0,50492	0,48103	0,48044
	Std. Sapma	0,05357	0,05782	0,01590	0,00200	0,05773	0,03651	0,03932
0,9	Ort.	0,50925	0,53027	0,54175	0,52721	0,52872	0,51524	0,50927
	Std. Sapma	0,03189	0,04683	0,02537	0,03304	0,05983	0,02751	0,04840

Şekil 5.7.'de ikinci grup deney görüntüleri verilmiştir. İkinci grup deney görüntüleri için optimizasyon algoritması tarafından elde edilen ortalama uygunluk değerleri ve standart sapmaları Tablo 5.3.'de görülmektedir. Bu deney grubu için elde edilen en iyi uygunluk değeri ortalaması 0,58411 olmuştur ve F, 0,6 ve CR, 0,7 parametrelerinden elde edilmiştir. Bu ortalamayı veren uygunluk değerlerinden en iyisi olan 0,58415 değerini veren katsayılar ise (0,043813, 0,12539, 0,15856, 0,19276, 0,20324, 44,5) olarak elde edilmiştir.







(c) DE (0,58415)




(d) Ortalama (0,4292)




(e) SIDWT (0,5697)




(f) Laplacian (0,4274)



(g) Kontrast (0,1545)



(h) ADD (0,4761)




Şekil 5.7. İkinci grup deney görüntüleri: (a) ve(b) Kaynak görüntüler, (c) Geliştirilen teknikle birleştirilmiş görüntü, (d), (e), (f), (g), (h), (i) ve (j) değişik yöntemlerle birleştirilmiş görüntüler ve uygunluk değerleri.

Tablo 5.3. İkinci grup deney görüntüleri için, kullanılan F ve CR parametrelerine göre 30 koşma sonucu elde edilen uygunluk değerlerinin ortalaması ve standart sapması.

F	Ct2pd	0,5	0,6	0,7	0,8	0,9	1	2
0,4	Ort.	0,58323	0,58306	0,58332	0,58004	0,58184	0,57516	0,50684
	Std. Sapma	0,00013	0,00171	0,00060	0,00086	0,00171	0,00392	0,03938
0,5	Ort.	0,58195	0,58295	0,58377	0,58112	0,58012	0,58006	0,44802
	Std. Sapma	0,00259	0,00301	0,00011	0,0021	0,00167	0,00311	0,10646
0,6	Ort.	0,58290	0,58354	0,58092	0,58574	0,57923	0,57233	0,46283
	Std. Sapma	0,00023	0,00089	0,00255	0,00298	0,00194	0,02944	0,07010
0,7	Ort.	0,58301	0,58411	0,56916	0,57819	0,56916	0,55909	0,45462
	Std. Sapma	0,00015	7,5E-05	0,02528	0,00023	0,02528	0,02436	0,08726
0,8	Ort.	0,58224	0,58399	0,58222	0,57496	0,57538	0,56183	0,43051
	Std. Sapma	0,00011	0,00020	0,00203	0,00192	0,00263	0,03580	0,06518
0,9	Ort.	0,58373	0,58395	0,56885	0,57514	0,56381	0,52363	0,42727
	Std. Sapma	0,00024	7E-05	0,02503	0,00018	0,03539	0,05963	0,04611

Üçüncü grup deney görüntüleri Şekil 5.8.'de ve bu grup için DGA tarafından elde edilen ortalama uygunluk değerleri ve standart sapmaları Tablo 5.4.'de verilmiştir. F, 0,9 ve CR, 0,9 parametreleri ile en iyi sonuç 0,42568 olarak elde edilmiştir. Bu gruptaki en iyi uygunluk değeri olan 0,42644 değerini veren katsayılar ise (0,17641, 0,32559, 0,36534, 0,38097, 0,41184, 149,3) olarak elde edilmiştir. Bu deney grubu için Laplacian Piramidi ve SIDWT metotları DGA ile birleştirmeden daha iyi sonuç vermişlerdir.






Şekil 5.8. Üçüncü grup deney görüntüleri: (a) ve (b) Kaynak görüntüler, (c) Geliştirilen teknikle birleştirilmiş görüntü, (d),(e),(f),(g),(h),(i) ve (j) değişik yöntemlerle birleştirilmiş görüntüler ve uygunluk değerleri


Tablo 5.4. Üçüncü grup deney görüntüleri için, kullanılan F ve CR parametrelerine göre 30 koşma sonucu elde edilen uygunluk değerlerinin ortalaması ve standart sapması.

F CR	Ct10p d10	0,5	0,6	0,7	0,8	0,9	1	2
0,4	Ort.	0,39067	0,41412	0,40705	0,41275	0,39197	0,39129	0,37257
	Std. Sapma	0,04751	0,02038	0,02106	0,02853	0,02392	0,00317	0,05236
0,5	Ort.	0,41209	0,41125	0,40951	0,42483	0,42168	0,40216	0,38216
	Std. Sapma	0,02080	0,01881	0,01894	0,00145	0,00553	0,00254	0,07438
0,6	Ort.	0,39798	0,41111	0,40187	0,38882	0,41148	0,41529	0,37523
	Std. Sapma	0,01527	0,01869	0,02133	0,00069	0,01966	0,02609	0,02719
0,7	Ort.	0,42426	0,41349	0,38926	0,39809	0,38648	0,39377	0,36712
	Std. Sapma	0,00405	0,02008	0,00030	0,01518	0,00217	0,00238	0,02894
0,8	Ort.	0,41053	-0,4042	0,38967	0,42252	0,37354	0,38097	0,37003
	Std. Sapma	0,01937	0,02070	0,00052	0,00599	0,01886	0,00867	0,00966
0,9	Ort.	0,41186	0,38891	0,39891	0,40521	0,42568	0,41244	0,38174
	Std. Sapma	0,01993	0,00061	0,02132	0,01803	0,00074	0,00443	0,00871


Şekil 5.9’da ve Tablo 5.5.’de ise dördüncü grup deney görüntüleri ve elde edilen ortalama uygunluk değerleri yer almaktadır. Bu grup için en iyi sonuç olan 0,84126 değeri F, 0,8 ve CR, 0,5 parametreleri ile elde edilmiştir. Bu ortalamayı veren 5 sonuçtan en değer olan 0,84208’i veren katsayılar (0,032623, 0,00047417, 0,0093629, 0,0033261, 0,00014675, 7,9) şeklindedir.




(a) CT




(b) MR




(c) DE (0,84208)




(d) Ortalama (0,3692)



(e) SIDWT (0,5136)



(f) Laplacian (0,4727)



Şekil 5.9. Dördüncü grup deney görüntüleri: (a) ve (b) Kaynak görüntüler, (c) Geliştirilen teknikle birleştirilmiş görüntü, (d), (e), (f), (g), (h), (i) ve (j) değişik yöntemlerle birleştirilmiş görüntüler ve uygunluk değerleri

Tablo 5.5. Dördüncü grup deney görüntüleri için, kullanılan F ve CR parametrelerine göre 30 koşma sonucu elde edilen uygunluk değerlerinin ortalaması ve standart sapması.

F CR	meda	0,5	0,6	0,7	0,8	0,9	1	2
0,4	Ort.	0,81812	0,82016	0,82924	0,83306	0,82492	0,80539	0,70442
	Std. Sapma	0,01826	0,02030	0,00312	0,00297	0,05644	0,01237	0,04333
0,5	Ort.	0,82996	0,83569	0,83953	0,84126	0,83114	0,81006	0,64925
	Std. Sapma	0,01018	0,01074	0,00261	0,01846	0,01674	0,00976	0,06742
0,6	Ort.	-0,8234	0,83497	0,83524	-0,8378	0,83658	0,81771	0,69245
	Std. Sapma	0,02245	0,00987	0,01107	0,00404	0,00245	0,00609	0,07491
0,7	Ort.	0,79519	0,83272	0,83258	0,83902	0,83620	0,7923	0,56006
	Std. Sapma	0,04012	0,01286	0,01565	0,00238	0,00088	0,05317	0,07016
0,8	Ort.	0,72934	0,81815	0,82924	0,82699	0,83073	0,80793	0,58701
	Std. Sapma	0,05526	0,04937	0,01826	0,02093	0,00874	0,00196	0,07016
0,9	Ort.	0,78082	0,78846	0,84043	0,83602	0,82546	0,76618	0,54412
	Std. Sapma	0,04332	0,03125	0,00266	0,00293	0,01947	0,01490	0,06158

6. BÖLÜM

SONUÇ

Bu çalışmada çok-sensörlü medikal görüntü birleştirme konusu ele alınmıştır. Konu ile ilgili literatür araştırması yapılmış ve bazı birleştirme tekniklerine Bölüm 2’de yer verilmiştir. Ele alınan görüntü birleştirme yaklaşımları aşağıda verilmiştir.

- Laplacian Piramidi metodu
- Ayırık Dalgacık Dönüşümü metodu
- Morfolojik Piramit metodu
- Ortalama ile birleştirme metodu
- Kaymadan Bağımsız Ayırık Dalgacık Dönüşümü Metodu (SIDWT)
- Ratio Piramidi metodu

Bu yaklaşımların temel yapısı, kaynak görüntüleri çok çözünürlüklü analiz metodu uyarınca alt bantlara ayırarak her iki kaynak görüntü için katsayılar haritasını oluşturmak, daha sonra bu katsayılar haritasından istenilen bölgeleri birleştirilmiş katsayılar haritasına atamaktır. Son olarak elde edilen bu birleştirilmiş katsayılar haritası ters dönüşüme tabi tutularak birleştirilmiş görüntü elde edilmektedir. Birleştirilmiş katsayılar haritasına iki kaynak katsayılar haritasından atama işlemi genellikle *LL* alt bandı için ortalama almak diğer alt bantlar için ise maksimumu almak şeklinde gerçekleştirilmektedir. Maksimum işlemi yüksek frekansı dolayısıyla kenar bilgisini birleştirilmiş görüntüye aktardığı için bu yaklaşımlar başarılı sonuçlar vermektedirler. Fakat medikal görüntü birleştirme sadece yüksek frekans bilgisinin birleştirilmiş görüntüde yer almasını amaçlamamaktadır. Gerektiğinde düşük frekans bilgisi de seçilebilmelidir.

Örneğin beyin içi MR görüntülerinde, bazı bölgelerde hem değer olarak hem de frekans olarak alçak bölgeler yer almaktadır. Bu bölgeler yerine CT görüntüsünden gelen frekans olarak alçak fakat değer olarak yüksek bölgeler bu mantığa göre seçileceği için olumsuz bir durum meydana gelebilecektir. Bu sorunu ortadan kaldırmak için optimizasyon algoritmalarının kaynak görüntülerin katsayılar haritasındaki bölgelerin seçiminde kullanılması düşünülmüş ve DGA ile görüntü birleştirme çalışması gerçekleştirilmiştir. Alınan sonuçlar literatürde bulunan birçok görüntü birleştirme algoritması ile karşılaştırılmış ve elde edilen veriler deneysel çalışma bölümünde verilmiştir. Bu sonuçlar göstermiştir ki önerilen metot bir deney seti dışında test edilen diğer birleştirme algoritmalarından daha iyi sonuçlar vermiştir. Sadece üçüncü deney seti için, SIDWT ve Laplacian Piramidi metotları ile birleştirilmiş görüntüler DGA ile birleştirilmiş görüntüden daha iyi uygunluk değeri vermişlerdir.

Yapılan çalışmada, katsayılar haritasından piksel olarak değer seçmek yerine alt bantlar bütünüyle seçme işlemine tabi tutulmuştur. Pikselleri tek tek ele alarak bir seçme işlemi uygulamak daha iyi sonuçlar verebilecektir, fakat işlem ve hafıza yükünün fazla olması nedeniyle bu çalışmada piksel üzerinde bir birleştirme çalışması yapılmamıştır. Önerilen DGA ile görüntü birleştirme algoritması optimizasyon tabanlı olduğundan, sadece medikal görüntü birleştirmede değil diğer çok-sensörlü ve çok-odaklı birleştirme işlemlerinde de kullanılabilir. Deneysel çalışma bölümünde de görüleceği gibi SIDWT, klasik ADD'den daha iyi uygunluk değerleri vermiştir. Yapılacak benzer çalışmalarda klasik Ayrık Dalgacık Dönüşümü yerine SIDWT tercih edilebilir.

KAYNAKLAR

1. Roggermann, M.C., Mills, J.P., Kabrisky, M., Rogers, S.K., Tatman, J.A., An approach to multiple sensor target detection, Sensor Fusion II, Proceedings of SPIE, 1100, 42-52, 1989.
2. Wang, Y. , Freedman, M.T., Xuam, J.H. , Zheng, Q., Mun, S.K., Multimodality medical image fusion: probabilistic quantification, segmentation and registration, Medical Imaging 1998: Image Display, Proceedings of SPIE, 3335, 239-249, 1998.
3. Sharma, R.K., Probabilistic model-based multisensor image fusion, Oregon Graduate Institute of Science and Technology, Phd. Thesis, 1999.
4. Maintz, J. B. A., Viergevet, M: A., A Survey of Medical Image Registration, Medical Image Analysis 2(1), 1-36, 1998.
5. Kapoor, R., et al., Fusion for registration of medical images - a study, Applied Imagery Pattern Recognition Workshop, 2003. Proceedings. 32nd, 180-185, 2003.
6. Burt, P.J., Adelson, E.H. , The Laplacian pyramid as a compact image code, IEEE Transactions on Communications COM-31, 532-540, 1983.
7. Li, H., Manjunath, B.S., Multisensor image fusion using the Wavelet transform, Computer Vision, Graphics and Image Processing: Graphical Models and Image Processing, 235-245, 1995.
8. Wang, Z., Ma, Y., Medical image fusion using m-PCNN, Information Fusion, 9(2), 176-185, 2008.
9. The wavelet tutorial, <http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html>, 1996.
10. Short time fourier transform, http://en.wikipedia.org/wiki/Short-Time_Fourier_transform.
11. Amolins, K., Zhang, Y., Dare, P., Wavelet based image fusion techniques – An

- introduction,review and comparison, ISPRS Journal of Photogrammetry&Remote Sensing, 62, 249-263, 2007.
12. Aslantas, V., Dogan, A., Ozturk, S., Dwt-svd based image watermarking using particle swarm optimizer, ICME Proceedings, 2008.
 13. Sripathi, D., Efficient Implementations of Discrete Wavelet Transforms Using FPGAs, Florida State University College of Engineering, M.S Thesis, 2003.
 14. Lehigh University, Investigations of Image Fusion,
http://www.ece.lehigh.edu/SPCRL/IF/image_fusion.htm.
 15. Hui Li; Manjunath, B.S., Mitra, S.K., Multi-sensor image fusion using the wavelet transform, Image Processing 1994 Proceedings, 51-55, 1994.
 16. Guihong, Q., Dali, Z., Pingfan, Y., Medical image fusion by wavelet modulus maxima, Opt. Express, 184-190, 2001.
 17. Wang, Y., Multisensor Image Fusion: Concept, Method and Applications, Faculty of Electrical and Information Engineering, Hunan University, Changsha, 410082, China, 2000.
 18. Burt, P. T., Andelson, E. H., The Laplacian pyramid as a compact image code, IEEE Trans. Commun., 31 (4), 532-540, 1983.
 19. Bulatov, A., Çok Odaklı Görüntü Füzyonu, Erciyes Universitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2006.
 20. Aiazzi, B., Alparone, L., Baronti, S., Pippi, I., Fusion of 18 m MOMS-2P and 30 m Landsat TM Multispectral Data by the Generalized Laplacian Pyramid, 1999.
 21. Shechtman, E., Sequence Fusion Based on 3D Pyramids, Project Report, 2000.
 22. Şimşek, M., Ayırıştırma teknikleri kullanarak görüntü birleştirme, Gebze Yüksek Teknoloji Enstitüsü, Seminer raporu, 2006.
 23. Sadjadi, F., Comparative Image Fusion Analaysais, Proceedings of the 2005 IEEE

Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05) Workshops, 3, 8, 2005.

24. Serra, J. Image Analysis and Mathematical Morphology. Academic Press, London, 1982.
25. Toet, A., Image fusion by a ratio of low-pass pyramid, Pattern Recognition Letters, 9(4), 245-253, 1989.
26. Mallat, S.G., A Wavelet tour of signal processing, 2nd Ed, Academic Pres, 1999.
27. Bradley, A., P., Shift-invariance in the Discrete Wavelet Transform, Cooperative Research Centre for Sensor Signal and Information Processing, School of Information Technology and Electrical Engineering, The University of Queensland, 2003.
28. Kingsbury, N.G., Complex Wavelets and shift invariance, Proceedings IEE Colloquium on Time-Scale and Time-Frequency Analysis and Applications, London, 2000.
29. Karaboga, D. , Akay, B., Artificial Bee Colony (ABC) Algorithm on Training Artificial Neural Networks, Signal Processing and Communications Applications, SIU 2007. IEEE 15th, 1-4, 2007.
30. Storn, R., Price, K., Differential Evolution: A Simple and Efficient Adaptive Scheme for Global Optimization over Continuous Spaces, International Computer Science Institute, Berkeley, TechnicalReport, 95-012, 1995.
31. Keskinturk, T., Diferansiyel gelişim algoritması, Istanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 9, 85-99, 2006.
32. Shiakolas, P. S., Koladiye, D., Kebrle, J., On The Optimum Synthesis of Six-Bar Linkages Using Differential Evolution and The Geometric Centroid of Precision Positions Technique, Mechanism and Machine Theory, 40, 319-335, 2005.

33. Karaboga, D., Yapay Zeka Optimizasyonu Algoritmaları, AtlasYayın Dağıtım, 2004.
34. Mayer, D.G., Kinghorn, B.P., Archer, A.A., Differential Evolution – An Easy and Efficient Evolutionary Algorithm for Model Optimisation, *Agricultural Systems*, 83, 315-328, 2005.
35. Sun, J. ,et al., DE/EDA: A New Evolutionary Algorithm for Global Optimization, *Information Sciences*,169, 249-262, 2005.
36. Qu, G., Zhang, D., Yan, P., Information measure for performance of image fusion, *Electron Lett.*, 38, 313-315, 2002.
37. Guihong, Q., Dali, Z, Pingfan, Y., Medical image fusion by wavelet transform modulus maxima, *Optics Express*, 9, 184,2001.
38. Martin, S., et al., Fast and accurate image registration using Tsallis entropy and simultaneous perturbation stochastic approximation, *Electron Lett.*, 40, 595-597,2004.
39. Wang, Z., Bovik, A. C., A universal image quality index, *IEEE Signal Processing Letters*, 9(3), 81-84, 2002.
40. Piella, G., Heijmans, H., A new quality metric for image fusion, *ICIP 2003 Proceedings*, 3, 173-177, 2003.
41. Waltz, E., Data fusion for C3I: A tutorial, *Command, Control, Communications Intelligence (C3I) Handbook*, 217-226, 1986.
42. Lawrance, A.K., *Sensor and Data Fusion Concepts and Applications*, SPIE Opt. Engineering Press, Tutorial Texts, 14,1993.
43. Hall, D.L., Llinas, J., An introduction to multisensor data fusion, *Proceedings of the IEEE*, 85, 6-23, 1997.
44. Kessler et al., *Functional Description of the Data Fusion Process*, Tech Rep., Office of Naval Technol., Naval Air Development Ctr., 1992.

45. Hall, D. L., Linn, R. J., Survey of commercial software formultisensor data fusion, Proc. SPIE Conf. Sensor Fusion and Aerospace Applications, 1991.
46. Wright,F., The fusion of multi-source data, Signal, 39-43, 1980.
47. Burt, P.J., A gradient pyramid basis for pattern-selective image fusion, Proceedings SID International Symposium, Society for Information Display, 467-470, 1992.
48. Rockinger, O., Image sequence fusion using a shift-invariant wavelet transform, Proceedings of the IEEE International Conference on Image Processing, 288-291,1997.
49. Toet, A., Image fusion by a ratio of low-pass pyramid, Pattern Recognition Letters, 9 (4), 245-253, 1989.

ÖZGEÇMİŞ

Abdullatif Doğan 1984 yılında Kayseri’de doğdu. 2002 yılında Sema Yazar Anadolu Lisesi’ni kazandı ve aynı yıl Erciyes Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü’nü kazandı. 2006 yılında lisans öğrenimini tamamlayarak Erciyes Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda yüksek lisans eğitimine başladı.

Adres: İldem Koop.

Turkuaz Apt. A/91-8

Melikgazi / KAYSERİ

Tel: +90 555 639 01 30

E-posta: latif84@mynet.com