



**ULTRASON GÖRÜNTÜLERİNDE DERİN ÖĞRENME YAKLAŞIMIYLA
SÜPER ÇÖZÜNÜRLÜK**

Hakan TEMİZ

**DOKTORA TEZİ
BİLGİSAYAR BİLİMLERİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ**

HAZİRAN 2020

Hakan TEMİZ tarafından hazırlanan “ULTRASON GÖRÜNTÜLERİNDE DERİN ÖĞRENME YAKLAŞIMIYLA SÜPER ÇÖZÜNÜRLÜK” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Bilişim Enstitüsü Bilgisayar Bilimleri Ana Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Hasan Şakir BİLGE

Elektrik-Elektronik Mühendisliği, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Başkan: Prof. Dr. Refik SAMET

Bilgisayar Mühendisliği, Ankara Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Prof. Dr. M. Ali AKCAYOL

Bilgisayar Mühendisliği, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Prof. Dr. Suat ÖZDEMİR

Bilgisayar Mühendisliği, Hacettepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Doç. Dr. Osman ABUL

Bilgisayar Mühendisliği, TOBB-ETÜ Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Tez Savunma Tarihi: 19/06/2020

Jüri tarafından kabul edilen bu tezin Doktora Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Aslıhan TÜFEKÇİ

Bilişim Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Bilişim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Hakan TEMİZ

19/06/2020

ULTRASON GÖRÜNTÜLERİNDE DERİN ÖĞRENME YAKLAŞIMIYLA SÜPER ÇÖZÜNÜRLÜK

(Doktora Tezi)

Hakan TEMİZ

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ

Haziran 2020

ÖZET

Bu çalışmada ultrason görüntüleme yöntemindeki düşük görüntü çözünürlüğü ve kalitesini iyileştirmek için Derin Öğrenme algoritmalarından yararlanılarak süper çözünürlük uygulanmıştır. Diğer yöntemlerden farklı olarak, süper çözünürlük, ultrason görüntülemenin son safhası olan B-mod görüntüler üzerinde uygulanmıştır. Bu maksatla, tasarlanan bir derin ağ (DECUSR ağı) 28 bine yakın ultrason görüntüsüne sahip bir eğitim kümesi ile 4 farklı (2, 3, 4 ve 8 kat) büyültme faktörü için eğitilmiş ve en iyi performans için optimize edilmiştir. DECUSR modelinin başarısı 8 adet görüntü kalitesi metriği ile literatürdeki diğer 7 yöntemle kıyaslanmıştır. Uygulanan yöntemin başarısı ayrıca tek yönlü varyans analizi (ANOVA) ve Welch t-testi ile de doğrulanmıştır. Sonuçlar derin öğrenme algoritmaları ile B-mod safhasında elde edilen süper çözünürlüğün diğer safhalarda ve yöntemlerle elde edilen çözünürlükten daha başarılı olduğunu gözler önüne sermiştir. İlave olarak, derin öğrenme ağlarının eğitilmesinde izlenecek en iyi yöntemin bulunması amacıyla; insan vücudunun belirli bir bölgesi veya organına ait görüntüler ile bir derin ağın yerel eğitilmesinin ya da her bölgeden rastgele alınan karma görüntüler ile eğitilmesinin ağın performansı üzerindeki etkileri kapsamlı bir deney düzeneğiyle araştırılmıştır. Bunun haricinde, eğitim verisi miktarının eğitimin başarısını nasıl etkilediği de irdelenmiştir. Neticede, yerel eğitim yapılmasının ağın başarısını artırmadığı, hatta kimi durumda rastgele karma görüntüler ile eğitim yapmanın daha başarılı sonuç verdiği ve derin ağların eğitimden edindiği bilgilerin eğitim bölgesinden bağımsız olduğu gösterilmiştir. Diğer taraftan, eğitimde kullanılan görüntü miktarının artırılmasının ağın performansına doğrudan katkı sağladığı da gözler önüne serilmiştir. İlave olarak, B-mod görüntüler üzerinde mi yoksa radyo frekans sinyali formatındaki ultrason verisi üzerinde mi uygulanan süper çözünürlüğün daha başarılı olduğu da ayrıca ele alınmıştır. Bulgular, B-mod görüntülerde elde edilen süper çözünürlüğün çok daha üstün olduğunu ortaya koymuştur. Bu çalışmadan elde edilen tüm sonuçlar B-mod ultrason görüntülerinde derin öğrenme ile süper çözünürlüğün ultrason görüntülemelemedeki düşük çözünürlük sorununun giderilmesinde umut vaat ettiğini göstermiştir.

Bilim Kodu : 92418

Anahtar Kelimeler : Derin öğrenme, ultrason, süper çözünürlük, konvolüsyonel sinir ağı

Sayfa Adedi : 127

Danışman : Prof. Dr. Hasan Şakir BİLGE

ULTRASOUND IMAGE SUPER RESOLUTION WITH DEEP LEARNING APPROACH

(Ph. D. Thesis)

Hakan TEMİZ

GAZİ UNIVERSITY
INFORMATICS INSTITUTE

June 2020

ABSTRACT

In this study, the low image resolution and quality in the ultrasound imaging was improved by implementing the super resolution with Deep Learning algorithms. Unlike other methods, the super resolution is applied to B-mode images, which is the final stage of ultrasound imaging. For this purpose, a deep network (denominated as DECUSR) has been trained for 4 different (2, 3, 4, and 8 scales) magnification factors and optimized for the best performance with a training set consists of nearly 28 thousand ultrasound images. The success of the DECUSR network was compared with 7 other methods in the literature via 8 image quality metrics. The success of the applied method was also confirmed by one-way analysis of variance (ANOVA) and Welch's t-test. The results revealed that the super resolution obtained in the B-mode phase with deep learning algorithms is more successful than the resolution obtained in other phases or other methods. In addition, in order to find the best method to be followed in the training of deep learning networks; the effects of local training of a deep network with images from a specific region or organ of the human body, or, training with fused random images taken from each region were investigated with a comprehensive experiment. Apart from this, how the amount of training data affects the success of education was also examined. As a result, it has been shown that local training a deep network with a particular region does not improve its success. However, in some cases, training with fused random images yields more successful results. The information obtained by deep networks is independent of the training region. On the other hand, it has been demonstrated that increasing the number of training images directly contributes to the performance of the network. In addition, it is also examined whether the super resolution applied to B-mode images or ultrasound radio frequency signals is more successful. The findings revealed that obtaining the super resolution on B-mode images is much superior. All the results obtained from this study showed that the super resolution implemented by deep learning algorithms on B-mode ultrasound images is promising in eliminating the low resolution problem in ultrasound imaging.

Science Code : 92418

Key Words : Deep learning, ultrasound, super resolution, convolutional neural networks

Page Number : 127

Supervisor : Prof. Dr. Hasan Şakir BİLGE

TEŞEKKÜR

Çalışmalarında bana sabırla destek veren ve müstesna kişiliğiyle örnek olan kıymetli hocam Prof. Dr. Hasan Ş. BİLGE hocama ve yardımını hiç esirgemeyen kıymetli hocam Doç. Dr. Aslıhan TÜFEKÇİ hocama canı gönülden teşekkür ederim. Ayrıca, isimlerini tek tek sayamayacağım kadar fazla olan, çocukluğumdan günümüze dek üzerimde emeği olan tüm hocalarıma da çok teşekkür ederim. Bu anlamda, herkesin olduğu gibi, benim de ilk öğretmenlerim olan ve emeklerinin karşılığını hiçbir zaman ödeyemeyeceğim canım annem Münise TEMİZ ve canım babam Salih TEMİZ'e sonsuz teşekkür ederim.

Hayatımın diğer anlarında olduğu gibi, bu zorlu süreçte de her daim yanımda olan ve bana katlanan sevgili eşim Emine TEMİZ'e teşekkürden çok daha fazlasını borçluyum. Doğduğu günden beri ve bu çalışmanın her safhasında kâh tepemde, kâh kucağımda, kâh yanımda oynayarak ve benimle çalışarak büyüyen; kendisinden çok şey öğrendiğim canım kızım Azra'ya yaşanan her an için sonsuz teşekkür ederim. O'nu bana verene de sonsuz teşekkür ederim.

Her daim ailemizin yanında olup desteklerini hiç esirgemeyen ve dolayısı ile bu çalışmada da gizli emekleri bulunan sevgili kayınvalidem Zeynep ÇİFÇİ ve ailesinin değerli üyeleri Kenan, Sündüs, Betül ve Ali Kaan'a ayrı ayrı teşekkür ederim.

Bu doktora tezi Türkiye Bilimsel Araştırma Kurumu (TÜBİTAK) tarafından 119E015 numaralı 1002 Hızlı Destek Programı ile desteklenmiştir. Bu vesile ile projenin hayat bulmasında emeği geçenlere -ki danışman hocamın katkısı çok büyüktür-, TÜBİTAK çalışanlarına ve ödedikleri vergilerle donanım ihtiyacımızı gideren ve dolayısı ile bu çalışmaya vesile olan bütün vatandaşlarımıza da çok teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	x
ŞEKİLLERİN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. SÜPER ÇÖZÜNÜRLÜK.....	7
3. DERİN ÖĞRENME.....	19
3.1. Derin Öğrenme Mimarileri.....	19
3.1.1. Derin inanç ağları	19
3.1.2. Otomatik kodlayıcılar	20
3.1.3. Çekişmeli üretici ağlar.....	20
3.1.4. Yinelemeli sinir ağları	20
3.1.6. Özyineli sinir ağları	21
3.1.6. Konvolüsyonel sinir ağları.....	22
3.2. Derin Öğrenme ve Grafik İşleme Birimi (GPU)	23
4. ULTRASON GÖRÜNTÜLEME	27
4.1. Sesin Özellikleri.....	29
4.2. Ultrasonda Uzamsal Çözünürlük.....	32
4.3. Ultrasonun Ortam ile Etkileşimi	33

	Sayfa
4.3.1. Yansıma.....	35
4.3.2. Kırılma	36
4.3.3. Saçılma.....	36
4.3.4. Zayıflama	37
4.4. Ultrason Görüntüleme Modları	38
4.4.1. A-mod görüntüleme	38
4.4.2. B-mod görüntüleme.....	39
4.4.3. C-mod görüntüleme.....	39
4.4.4. M-mod görüntüleme.....	39
4.4.5. 3B ve 4B görüntüleme.....	40
4.4.6. Doppler görüntüleme.....	40
4.4.7. Kontrast ajanları ile görüntüleme	41
4.4.8. Harmoni görüntüleme.....	41
5. DERİN ÖĞRENME İLE B-MOD ULTRASON GÖRÜNTÜLERİNDE SÜPER ÇÖZÜNÜRLÜK	43
5.1. Yöntem	43
5.2. Derin Ağ	44
5.2.1. Derin ağın yapısı.....	46
5.3. Veri Seti ve Eğitim	53
5.4. Değerlendirme	56
5.5. Sonuçlar	57
6. DERİN ÖĞRENME MODELLERİNİN EĞİTİMİNDE EN İYİ EĞİTİM STRATEJİSİNİN BELİRLENMESİ	63
6.1. Yöntem ve Deney	63
6.2. Sonuçlar	67

	Sayfa
7. B-MOD ULTRASON GÖRÜNTÜSÜNE KARŞIN RF SİNYALİ SEVİYESİNDE SÜPER ÇÖZÜNÜRLÜK.....	81
8. SONUÇ VE ÖNERİLER.....	89
KAYNAKLAR	93
EKLER.....	101
EK-1. Metotların tüm büyültme ölçeklerindeki performans grafikleri.....	102
EK-2. İstatistiksel anlamlılık testleri.....	103
EK-3. Test bölgelerine göre gruplanmış ortalama GKM skor grafikleri.....	104
EK-4. Modellere göre gruplanmış ortalama GKM skor grafikleri.....	108
EK-5. Korelasyon analizi	115
EK-6. B-mod görüntüde ve RF sinyalinde elde edilen süper çözünürlüğün Karşılaştırılması	122
ÖZGEÇMİŞ	126

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Ultrason görüntüleme ve diğer görüntüleme tekniklerinin karşılaştırılması	28
Çizelge 4.2. Tıbbi ultrasonun doku ve materyallerdeki yoğunluk ve ses hızları	31
Çizelge 4.3. Farklı dokuların akustik dirençleri	35
Çizelge 5.1. Temel modelin (3 YB'li) bileşenlerinin performansa katkısı	49
Çizelge 5.2. DECUSR (4 YB'li) modelinin katman detayları	52
Çizelge 5.3. Eğitim parametreleri	54
Çizelge 5.4. Yöntemlerin TestSeti-I ve TestSeti-II üzerinde elde ettikleri niceliksel sonuçlar.....	58
Çizelge 6.1. Eğitim ve test setlerine dair detaylar	65
Çizelge 6.2. DECUSR (3 YB'li) modelinin katman detayları	66
Çizelge 6.3. Yerel eğitilmiş modeller arasından tüm test setlerinde en iyi ilk üç performansı gösteren modeller	68
Çizelge 6.4. Yerel modellerin aralarında yapılan kıyaslamaya göre test setlerinin tamamında en iyi ilk üç model arasına girme sayıları	70
Çizelge 6.5. Eğitilmiş modellerin tamamından tüm test setlerinde en iyi ilk üç performansı gösteren modeller	71
Çizelge 6.6. Bütün modellerin dâhil edilerek yapılan kıyaslamaya göre yerel modellerin en iyi ilk üç model arasına girme sayıları.....	72
Çizelge 7.1. RF sinyali safhasında süper çözünürlüğün gerçekleştirilmesiyle elde edilen nicel sonuçlar	84
Çizelge 7.2. Nihai B-mod görüntü safhasında süper çözünürlüğün gerçekleştirilmesiyle elde edilen nicel sonuçlar	85

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Süper çözünürlük uygulama modeli	8
Şekil 2.2. Çoklu görüntüye dayalı süper çözünürlük uygulama modeli	9
Şekil 3.1. Konvolüsyon (katlama) işlemi.....	22
Şekil 3.2. Google Brain sistemi ile NVIDIA Titan Z GPU'sunun karşılaştırılması.....	24
Şekil 3.3. Bir DÖ ağının farklı işlemcilerde 500 imgeyle eğitilme süreleri	25
Şekil 4.1. Ultrason görüntülemenin temel aşamaları	29
Şekil 4.2. Ultrason görüntülemeye frekans, dalga boyu ve genlik	30
Şekil 4.3. Ultrason görüntülemeye çözünürlük.....	32
Şekil 4.4. Ultrasonda görüntüleme modları	38
Şekil 5.1. Ultrasonda görüntülemenin aşamaları ve SÇ'nin elde edildiği safha.....	43
Şekil 5.2. Dört YB'li DECUSR modeline ait detaylar	47
Şekil 5.3. Temel modelin (3 YB'li) ana bileşenlerinin varlığı/yokluğundaki eğitim grafiği	50
Şekil 5.4. DECUSR ağının YB adedine bağlı olarak gösterdiği eğitim performansları.	51
Şekil 5.5. DECUSR ağının YB adedine bağlı olarak TestSeti-I'de gösterdiği performanslar	51
Şekil 5.6. DECUSR ağı ile eğitime dair kavramsal şema.....	53
Şekil 5.7. TestSeti-I'den alınan örnek bir ultrason görüntüsünden elde edilen görsel sonuçlar	60
Şekil 5.8. TestSeti-II'den alınan örnek bir ultrason görüntüsünden elde edilen görsel sonuçlar	61
Şekil 5.9. Metotların çalışma zamanı sonuçları ve PSNR metriğindeki ortalama skorları	62
Şekil 6.1. Üç YB'den oluşan DECUSR modeline ait detaylar	67
Şekil 6.2. Modellerin en iyi ilk üç model arasına girme durumları ve en başarılı model seçilme sayıları ve eğitim görüntüsü sayısı arasındaki ilişki	73

Şekil	Sayfa
Şekil 6.3. Test kümelerine göre gruplanmış ortalama PSNR (dB) skorları.....	74
Şekil 6.4. Modellere göre gruplanmış ortalama PSNR (dB) skorları	76
Şekil 6.5. Modeller arasındaki korelasyonun PSNR (dB) metriği üzerinde yapılan niceliksel ölçüm sonuçları.....	78
Şekil 7.1. B-mod görüntü safhası ve RF sinyali safhasındaki süper çözünürlük.....	81
Şekil 7.2. RF sinyali safhasında ve Nihai B-mod görüntü üzerinde süper çözünürlüğün elde edilmesine dair kavramsal şema	82
Şekil 7.3. RF sinyali safhasında ve Nihai B-mod görüntü safhasında elde edilen süper çözünürlük sonuçlarının PSNR (dB) metriği üzerinde görsel olarak karşılaştırılması	86

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklamalar
c	Ultrason dalgası ilerleme hızı
cm	Santimetre
cm²	Santimetrekare
db	Desibel
f	Frekans
Hz	Hertz
kg	Kilogram
KHz	Kilohertz
kW	Kilowatt
m²	Metrekare
m³	Metreküp
MHz	Megahertz
Rayl	Akustik direnç (kg/(m ² s))
s	saniye
µm	Mikrometre
θ	Açı

Kısaltmalar	Açıklamalar
2B	İki boyutlu
3B	Üç boyutlu
4B	Dört boyutlu
ADMM	Alternatif yönelim yöntemi (Alternating direction method of multipliers)
AE	Otomatik kodlayıcı (Autoencoder)
ANOVA	Tek yönlü varyans analizi (One-way analysis of variance)

Kısaltmalar	Açıklamalar
BDBM	Çift doğrusal değişim blok eşleştirme (Bilinear deformable block matching)
BT	Bilgisayarlı tomografi (Computerized tomography)
CPU	Merkezi İşlem Birimi (Central Processing Unit)
ÇDE	Çift doğrusal enterpolasyon (Bilinear interpolation)
ÇG	Çoklu görüntü
ÇKE	Çift kübik enterpolasyon (Bicubic interpolation)
DÇ	Düşük çözünürlük
DÖ	Derin öğrenme
ERGAS	Boyutsal evrensel görelî sentez hatası (Dimensional global relative error of synthesis)
EYKE	En yakın komşu enterpolasyonu (Nearest neighbor interpolation)
FSIM	Nitelik benzerlik indeksi (Feature similarity index)
GAN	Çekişmeli üretici ağ (Generative adversarial network)
GKM	Görüntü kalitesi metriği
GMSD	Gradyan büyüklük benzerlik sapması (Gradient magnitude similarity deviation)
GPU	Grafik işlemci birimi (Graphical processing unit)
GPY	Gradyan patlaması veya yitimi (Exploding or vanishing gradient)
HaarPsi	Haar dalgacık temelli algısal benzerlik indeksi (Haar wavelet-based perceptual similarity index)
HDTV	Yüksek tanımlı televizyon (High definition television)
HVS	İnsan görme sistemi (Human visual system)
IQ	Eş fazlı dördün (In-phase quadrature)
IoT	Nesnelerin interneti (Internet of things)

Kısaltmalar	Açıklamalar
KAG	Kontrast ajanları ile görüntüleme (Contrast agents imaging)
KSA	Konvolüsyonel sinir ağı (Convolutional neural network)
L_{BK}	Birleşme katmanı
L_{DBK}	Doğrudan büyültme katmanı
L_{NÇK}	Nitelik çıkarma katmanı
LSTM	Uzun kısa dönemli hafıza (Long short term memory)
MAD	Ortalama mutlak sapma (Mean absolute deviation)
MAP	Maksimum sonsal tahmin (Maximum posteriori)
MRG	Manyetik rezonans görüntüleme
MSE	Ortalama karesel hata (Mean squared error)
MSSSIM	Çok boyutlu yapısal benzerlik indeksi (Multi-scale structural similarity index)
NÇB	Nitelik çıkarma bloku
PAMSE	Algısal uygunluk ortalama karesel hata (Perceptual-fidelity aware mean squared error)
PC-MUSIC	Faz uyumlu çoklu sinyal sınıflandırma (Phase coherent multiple signal classification)
PSF	Nokta saçılım fonksiyonu (Point spread function)
PSNR	Tepe sinyalin gürültüye oranı (Peak signal to noise ratio)
RBM	Yasaklı Boltzman makinesi (Restricted Boltzman machine)
ReLU	Doğrultulmuş doğrusal birim (Rectified linear unit)
RNN	Yinelemeli sinir ağı (Recurrent neural network)
RvNN	Özyineli sinir ağı (Recursive neural network)
SAM	Spektral açı eşleyici (Spectral angle mapper)
SCC	Uzamsal korelasyon indeksi (Spatial correlation index)
SÇ	Süper çözünürlük (Super resolution)

Kısaltmalar	Açıklamalar
SDTV	Standart tanımlı televizyon (Standard definition television)
SK	Seyrek kodlama (Sparse coding)
SSIM	Yapısal benzerlik indeksi (Structural similarity index)
TPU	Tensör işleme birimi (Tensor processing unit)
TR-MUSIC	Zaman tersinme çoklu sinyal sınıflandırma (Time reversal multiple signal classification)
YB	Yineleme bloku
YÇ	Yüksek çözünürlük
YDK	Yarım değer kalınlığı (Half-value thickness)
YSA	Yapay sinir ağı
VIF	Görsel uygunluk indeksi (Visual fidelity index)

1. GİRİŞ

Ultrason görüntüleme (UG) yüksek frekansa sahip ses dalgalarının görüntülenen ortama (doku, organ vb.) gönderilmesi ve yansıyan ses dalgalarının çeşitli tekniklerle işlenmesi ile gerçekleştirilen bir görüntüleme tekniğidir. 1950'lerden günümüze gittikçe yaygın bir biçimde kullanılmaktadır. Jinekolojide, kalp, karaciğer, böbrek, pankreas, prostat gibi organların görüntülenmesinde yaygın bir biçimde kullanılmaktadır. UG, durağan bir medikal görüntü ediniminin yanında, hızlı ve dinamik görüntülerin edinimine de olanak sağlamaktadır. Örneğin, kardiyologlar sıkça kalbin ve kalp kapakçıklarının anlık görüntülerini UG ile görebilmekte, kadın doğum doktorları ise ana rahmindeki bebeğin durumunu anlık izleyebilmektedir. Benzeri şekilde, acil ve hızlı görüntüleme ihtiyacı duyulduğunda ilk başvuru yöntemlerin başında gelmektedir. Ayrıca, diğer medikal görüntüleme tekniklerine nazaran hem hasta hem de uygulayıcı (radyolog, doktor vb.) açısından radyasyon yaymadığı için daha zararsız, güvenilir ve maliyeti düşüktür. Günümüzde portatif şekilde de üretilmektedir. Mobil kullanıma uygun olduğu için ihtiyaç duyulan yere kolaylıkla taşınıp götürülebilir.

Bahsi geçen avantajlarının yanında UG'nin en büyük dezavantajı çözünürlüğünün oldukça düşük oluşudur. Düşük çözünürlüklü (DÇ) ultrason görüntülerinin daha yüksek çözünürlüğe (YÇ) sahip görüntülere dönüştürülmesi tıbbi açıdan teşhis ve tanıda büyük önem arz etmektedir. Görüntü kalitesinin düşüklüğü tıbbi görüntüleme uzmanının veya doktorların görüntüyü yorumlamasını güçleştirmekte, bazı durumlarda yanlış teşhis yapmalarına neden olabilmektedir.

UG, iki ana aşamada uygulanan yöntem ve teknikler ile elde edilir. İlk aşama ön işleme safhası, ikinci aşama ise ardıl işleme safhası olarak adlandırılır. Ön işleme safhası ses dalgasının evre uyum (coherence), bant genişliği, doğrusal olmayan yayılım, sönümlenme, emilim gibi çeşitli fiziksel özellikleriyle ilgilenir ve ayrıca kullanılan cihaz üzerinde değişik teknikler ile görüntünün daha iyi elde edilmesine çalışır. İkinci aşama ise, hâlihazırda bir radyo frekans (RF) sinyaline dönüşmüş olan ses verisi üzerinde çeşitli sinyal işleme ve görüntü işleme yöntem ve teknikleri uygulanarak nihai görüntü en iyi şekilde elde edilmeye çalışır [1].

UG'nin DÇ sorununun üstesinden gelmek için hem ön işleme hem de ardıl işleme safhalarında çeşitli yöntemler ve teknikler kullanılmıştır. Ön işleme safhasında ultrason dalgasında çeşitli hüzeleme (beamforming) yöntemleri, odaklanmayla ilgili çeşitli yöntemler, apodizasyon, dürtü sıkıştırma (puls compression) teknikleri, çeşitli (uzamsal, frekans vb.) kuvvetlendirme (compounding), ses dalgası harmonileri üzerinde uygulanan teknikler ve dürtü evirme (pulse inversion) gibi pek çok yöntem denenmiştir. Hüzeleme yöntemleri ses dalgasının görüntüleme ortamında daha iyi şekilde yayılması için farklı çeşitli düzenlemeleri içerir. Kuvvetlendirme teknikleri daha iyi kalitede görüntü elde etmek için çoklu görüntünün birleştirilmesine odaklanır. Dürtü evirme yöntemi ultrason dalgasının ardışık gönderiminden ve ters kopyasından elde edilen iki yankı arasındaki farkların analizinden yararlanarak görüntü kalitesini iyileştirmeyi amaçlar. Ardıl işleme safhasında ise çeşitli filtreleme teknikleri, dalgacık (wavelet) dönüşümleri, ters konvolüsyon (deconvolution), bazı enterpolasyon teknikleri, öğrenmeye dayalı teknikler vb. yöntemler uygulanmıştır [1].

Derin öğrenme (DÖ) kavramı, geleneksel yapay sinir ağlarından (YSA) çok daha derin, yani katman sayısı geleneksel YSA'lara göre oldukça fazla olan ağlar için kullanılan bir terimdir. Ayrıca, konvansiyonel sinir ağlarından çok daha gelişkin ve başarımı yüksek farklı tipte ağ mimarilerini de ifade etmektedir. Günümüzde, hesaplama başarımı yüksek donanımlar sayesinde, yüzlerce katman sayısından oluşan ve milyonlarca parametreye (nöron vb.) sahip derin ağlar ile büyük veri gibi yüksek hacimli veriler üzerinde çok yüksek hesaplama işlerinin icrası sıradan ve günlük yapılabilen işler haline gelmiştir. Bu donanımların başında paralel işlem birimleri (GPU) gelmektedir. GPU'lar çok boyutlu dizilerin (tensör) tek seferde işlenebilmesine imkan verdikleri için, merkezi işlem birimlerine (CPU) göre oldukça yüksek hızlarda hesaplama işlerini kotarabilmektedir. Böylece, oldukça yüksek parametre sayılarına sahip DÖ algoritmaları ile bile muazzam büyüklükteki verilerin işlenmesi ve yüksek hacimli hesaplama görevlerinin kabul edilebilir makul zaman dilimleri içerisinde kotarılabilmesi sağlanmıştır.

Bir dönem araştırmacıların ilgisinin azalmaya başladığı DÖ algoritmaları, ImageNet görüntü sınıflandırma yarışmasında Krizhevsky, Sutskever ve Hinton'un [2] geliştirdikleri DÖ algoritmasının gösterdiği üstün performans ile tekrar araştırmacıların dikkatini üzerine çekmiştir. Bu tarihten sonra çoğu araştırma ve uygulama alanında, göstermiş oldukları üstün performanslar ile diğer yöntem ve tekniklere çok ciddi fark atmıştır. Örneğin, sınıflandırma,

nesne tanıma, örüntü tanıma, doğal dil işlemede, bilgisayarla görmede, medikal görüntülerin işlenmesinde ve daha birçok sayısız alanda başarısını kanıtlamıştır ve günümüzde yaygın bir biçimde kullanılmaktadır.

Süper çözünürlük (SÇ), mevcut olan görüntünün belirli bir ölçekte büyütülmesi ile beraber mevcut olan görüntü çözünürlüğünü iyileştirme hatta daha iyi detaylara sahip görüntü elde etme işidir. Optik görüntüleme, havadan görüntüleme, astronomide ve tıbbi görüntüleme gibi pek çok alanda uygulanan aktif bir konudur. Mevcut donanımsal çözümlerin limitlerine ulaşıldığından, günümüzde algoritma tabanlı (yazılımsal) çözümler üzerinde daha fazla odaklanılmaktadır.

DÖ algoritmalarının diğer bilim alanlarında gösterdiği üstün performansı SÇ konusunda da göstermiş, mevcut diğer geleneksel metotlardan çok daha iyi sonuçlar üretmiştir. DÖ algoritmaları 2014 yılından bu yana optik görüntüler üzerinde SÇ probleminde kayda değer önemli başarılarla imza atmıştır. Bu başarısının ardından pek çok diğer görüntüleme yöntemlerinde de ciddi başarılarla imza atmıştır. Hatta son yıllardaki başarılı çalışmaların büyük çoğunluğu DÖ algoritmaları üzerinedir.

Bu doktora tezinde, yukarıda bahsi geçen ultrason görüntülerindeki DÇ ve düşük görüntü kalitesi sorununun çözümünü için DÖ algoritmaları aracılığı ile ultrason görüntülerinde SÇ uygulaması gerçekleştirilmiştir. UG'de çok daha YÇ ve iyi kalitede ultrason görüntülerinin elde edilmesi sayesinde tıbbi tanı ve teşhisin doğruluğu artacak ve tıbbi görüntüleme uzmanlarına ve bu görüntüler üzerinden analiz ve yorumlama gibi işleri gerçekleştiren diğer uzman ve doktorlara kolaylık sağlanmış olacaktır. İlave olarak, ultrason görüntüleri üzerinde gerçekleştirilen yukarıda bahsi geçen işler daha kısa zamanda tamamlanacağından, sağlık kurumlarında sıkça karşılaşılan sorun olan işlerin yığılmasının da önemli ölçüde önüne geçilmiş olacaktır.

Geleneksel SÇ çalışmaları çoğunlukla UG'nin ön işleme safhasında veya ardıl işleme safhasının bazı ara aşamalarında, nihai hale gelmemiş olan ultrason dalgaları veya sinyalleri üzerinde gerçekleştirilmiştir. Diğer çoğu ön işleme ve ardıl işleme tekniklerinden farklı olarak, bu doktora tezinde UG'nin en son safhası olan ve nihai hale gelmiş B-mod ultrason görüntüleri üzerinde SÇ uygulanmıştır. Nihai B-mod ultrason görüntüleri üzerinde SÇ elde etmenin bir çok avantajı vardır. Şöyle ki; sadece ileride elde edilecek olan UG'de SÇ elde

etmek değil, halihazırda elde mevcut olan ultrason görüntüleri üzerinde de SÇ elde etmek mümkündür. Ayrıca, bir donanım değişikliğine gerek kalmadan ve ilave bir maliyet oluşturmada, görüntüleme cihazı üzerine bir yazılım olarak bütünleştirilebilir. Ya da, ultrason görüntüleri üzerinde çeşitli analiz ve işleme yapan tekniklere bir ön işlem safhası olarak uyarlanabilir.

SÇ'nin elde edilmesinde danışmanlı öğrenme (supervised learning) türü olan, örneklerden öğrenme yaklaşımı benimsenmiştir. Bu maksatla 28 bine yakın örnek ultrason görüntüsüne ait DÇ ve karşılık gelen YÇ görüntü parçaları bir DÖ ağına verilerek, ağın DÇ ile YÇ ultrason görüntüleri arasındaki doğrusal olmayan SÇ fonksiyonunu öğrenmesi sağlanmıştır. Ayrıca, DÖ ağının en iyi performansı verecek şekilde optimize edilmesi için ağ mimarisi üzerinde çeşitli düzenlemeler ve deneyler gerçekleştirilmiştir. Neticede, oldukça iyi performans gösteren ve DECUSR (deep convolutional neural network for ultrasound super resolution) adı verilen bir DÖ ağı meydana getirilmiştir.

Tasarlanan DÖ ağının performansı dört adet enterpolasyon yöntemi, bir adet regresyon yöntemi ve 2 adet başarılı DÖ modeli ile kıyaslanmıştır. Kıyaslanma hem niceliksel hem de insan görme sistemi (HVS) açısından niteliksel olarak yapılmıştır. Niceliksel kıyaslamalarda sekiz farklı görüntü kalitesi metriği (GKM) kullanılmıştır. Ayrıca, DECUSR ağı ile diğer metotlar arasındaki başarı farkı tek yönlü varyans analizi (ANOVA) ve Welch t-testi ile doğrulanmıştır. Birkaç küçük istisna haricinde, neredeyse tüm GKM'ler DECUSR ağı ile elde edilen SÇ'nin diğer metotlarla elde edilen SÇ'ye nazaran kayda değer oranda iyi olduğunu gözler önüne sermiştir. Sonuçlar hem niceliksel olarak hem de insan görme sistemi açısından göz alıcıdır ve UG'deki DÇ sorunun giderilmesinde önemli katkı sağlayacağı açıktır.

Yukarıda bahsi geçen çalışmalara ilave olarak, DÖ ağlarının ultrason görüntüleri üzerinde en başarılı SÇ elde etmesini sağlayacak en iyi eğitim şeklinin bulunması adına kapsamlı bir deneysel çalışma gerçekleştirilmiştir. Bu bağlamda, DÖ ağlarının başarımı belirli bir organ veya bölge görüntüleriyle yerel eğimi, her bölgeden rastgele görüntüler ile eğitimi ve eğitim görüntüsünün miktarı açısından etraflıca ele alınmıştır.

UG genellikle kliniklerde insan vücudunun belirli bir organı veya bölgesi üzerinde uygulanmaktadır. Dolayısı ile belirli bir bölge veya organ görüntülerinde uzman olan DÖ

modellerinin geliştirilip geliştirilemeyeceği ilginç bir konudur. Bu soruya cevap bulmak adına, DÖ ağlarının insan vücudunun belirli bir organı veya bölgesi ile yerel eğitilmesinin DÖ ağlarının daha iyi SÇ elde etmesine imkân verip vermediği deneysel olarak kapsamlı bir şekilde incelenmiştir. Bununla birlikte, yerel eğitime alternatif olarak, her bölgeden alınan rastgele görüntüler ile eğitilmesinin (genel eğitim) de ne gibi etkileri olduğu, ağın performansını artırıp artırmadığı gibi sorulara da cevap aranmıştır. Ayrıca, eğitim görüntüsü miktarının derin ağın SÇ performansına nasıl etki ettiği de detaylı bir şekilde incelenmiştir.

Yukarıda bahsi geçen tüm sorulara cevap bulmak adına, insan vücudunun belirli bir organ veya bölgesine ait 12 farklı eğitim seti ile ve ayrıca rastgele seçilmiş ve giderek artan miktarda 15 adet rastgele eğitim setleri oluşturulmuştur. Son olarak, tüm görüntülerden oluşan bir eğitim seti ile birlikte toplamda 28 adet farklı eğitim seti oluşturulmuştur. DECUSR ağının bir türevi bu 28 adet eğitim seti ile eğitilmiş ve 28 farklı model elde edilmiştir. Elde edilen modellerin performansı 12 yerel bölgeye ait test setleri üzerinde sekiz adet GKM ile ölçülmüştür. Ayrıca, modellerin performanslarındaki korelasyonun derecesi de ölçülmüştür. Ölçüm sonuçları yerel eğitimin, beklenenin aksine, DÖ algoritmalarının SÇ'deki başarısını artırmadığı; kimi zaman yerel eğitim kümesindeki görüntü miktarı ile yaklaşık aynı sayıda ve her bölgeden rastgele alınan görüntüler ile genel eğitim yapmanın daha iyi sonuç verdiğini ortaya konmuştur. Modellerin her bir yerel bölge üzerinde benzeri performans davranışı sergilemesi ve performanslarındaki korelasyon derecesinin yüksekliği modeller tarafından yerel eğitim ile öğrenilen bilgilerin yerelden daha ziyade tüm bölgeler için geçerli özelliğe sahip olduğunu gözler önüne sermiştir. İlave olarak, eğitim görüntüsü adedinin artırılmasının DÖ ağlarının SÇ'deki başarısına gözle görülür katkı sağladığı da yine bu çalışma sayesinde ortaya konan sonuçlardandır. Eğitim görüntüsü miktarı arttıkça ağın SÇ'deki performansı da artmıştır.

İlave olarak, UG'nin son safhası olan B-mod görüntüler üzerinde mi, yoksa ardıl işleme safhasının ara aşamalarında radyo frekans (RF) sinyali formatında bulunan ultrason verisi üzerinde mi SÇ elde edilmesinin daha başarılı sonuç verdiği de deneysel olarak etraflıca incelenmiştir. Bu bağlamda, aynı RF verisi üzerinden elde edilen eğitim ve test kümelerinden yararlanılarak, geleneksel UG'de yapıldığı şekilde, B-mod ultrason görüntülerinden oluşan eğitim ve test kümeleri oluşturulmuştur. Ardından, bir DECUSR ağının bir türevi her iki formattaki eğitim kümesi ile ayrı ayrı eğitilmiş ve eğitilen iki modelin başarı düzeyleri test kümeleri üzerinde ölçülmüştür. Ölçüm için yine sekiz adet GKM

kullanılmıştır. Elde edilen sonuçlar, B-mod görüntüler üzerinde yapılan SÇ'nin RF sinyalinden elde edilen SÇ'den gözle görülür oranda daha başarılı olduğunu ortaya koymuştur.




2. SÜPER ÇÖZÜNÜRLÜK

SÇ, birim alana düşen piksel sayısını artırarak mevcut örneklemden daha iyi detaylara sahip görüntü elde etme işidir. Güvenlik, keşif, medikal görüntüleme, uydu ve astronomi görüntüleme gibi daha fazla görüntü detaylarının elde edilmesine ihtiyaç duyulan alanlarda sıklıkla kullanılmaktadır. Ayrıca, resim iyileştirme (photo enhancement) ve standart tanımlı televizyon (SDTV) görüntüsünün yüksek tanımlı televizyon (HDTV) görüntüsüne dönüşüm gibi uygulamalarda başvurulmaktadır. Medikal görüntülemede manyetik rezonans görüntüleme (MRI), bilgisayarlı tomografi (BT), elektron mikroskopisi ve ultrason gibi tıbbi görüntüleme teknikleriyle elde edilen görüntülerde DÖ mimarileri SÇ elde edilmesinde oldukça başarılı sonuçlar elde edebilmektedir.

SÇ problemin tanımı Eş. 2.1’de ve kavramsal şeması Şekil 2.1’de verilmiştir. Bilinen yüksek çözünürlüklü (YÇ) x imgesi sırasıyla çarpıtma (M), bulandırma (B), seyreltme (D) ve gürültü ekleme (η) işlemlerine tabi tutularak düşük çözünürlüklü (DÇ) y imgesi elde edilir. DÇ y imgesinin üretilmesini sağlayan oldukça fazla sayıda YÇ x imgesi olabileceğinden, SÇ problemi tersine (inverse) problem veya kötü tanımlanmış (ill-posed) problem olarak adlandırılır. Yani, belirli olmayan tersine problem olarak adlandırılmaktadır. Çözüm tek bir tane değildir. Buradaki amaç, türetilmiş olan DÇ imge y ’den yola çıkarak bilinen YÇ x imgesini üretmektir.

$$y(i, j) = D(B(M(x))) + \eta(i, j) \quad (2.1)$$

Problemin çözümü için düşünülen ilk yaklaşım donanım vasıtasıyla yapılan yöntemlerdir. Donanım vasıtası ile çözümde iki yönetime başvurulmaktadır: (i) piksel boyutunu azaltmak ve (ii) piksel (sensör) sayısını artırmak. Günümüz teknolojisi ile oldukça küçük boyutlarla çalışılabilmekle beraber, esas sorun piksel boyutunun küçültülmesi durumunda boyut küçüldükçe sensördeki ilgili piksele düşen ışık miktarının azalmasıdır. Piksel sayısının artırılması mikro devre (chip) boyutunun artmasına ve kullanılan sistemin kapasitesinin de artmasına neden olmaktadır. Bunun sonucunda şarj transfer oranı düşmektedir. Ayrıca, bahsi geçen donanım düzeyindeki yaklaşımlar pahalıdır. Bu nedenle, genellikle algoritmaya dayalı (yazılım tabanlı) yaklaşımlar tercih edilir.




Şekil 2.1. Süper çözünürlük uygulama modeli

SÇ çalışmaları frekans alanı ve uzamsal alan olmak üzere iki ana grupta yapılmaktadır. Frekans alanında yapılan çalışmalarda hızlı Fourier dönüşümü (fast Fourier transform), ayırık kosinüs dönüşümü ve benzeri dalgacık dönüşümlerle görüntü üzerinde çalışılmaktadır. Uzamsal alanda yapılan çalışmalar doğrudan pikseller üzerine uygulanır ve literatürde çalışmaların büyük çoğunluğu bu alanda yapılmıştır. Uzamsal çalışmalar da çoklu ve tekil görüntü üzerinde yapılanlar olmak üzere iki ana hat üzerinden devam etmektedir [3].

Çoklu görüntü (ÇG) temelli SÇ (Şekil 2.2) algoritmaları genellikle hedeflenen bir YÇ görüntünün var olduğunu kabul eder ve DÇ görüntü ile YÇ görüntü arasında bazı göreceli geometrik ve fotometrik değişimlerin olduğunu varsayar. ÇG temelli algoritmalar DÇ gözlemlerdeki farkları kullanarak hedeflenen YÇ görüntüyü elde etmeye çalışır. Bu nedenle geri çatma (reconstruction) temelli SÇ algoritmaları olarak da anılırlar [3]. Aynı sahneye ait bir'den fazla görüntü belirli bir referans koordinat sistemine iz düşürülür. Ardından, çift kübik enterpolasyon (ÇKE), çift doğrusal enterpolasyon (ÇDE) gibi teknikler kullanılarak YÇ görüntü elde edilmiş olur.

SÇ algoritmalarında kestirim (prediction) modelleri, kenar temelli yöntemler, görüntü istatistiğine dayalı yöntemler ve yerel parça temelli yöntemler olmak üzere genel olarak dört ana yaklaşım vardır. En iyi sonuçlar son zamanlarda örneğe dayalı (yerel görüntü parçalara dayalı) yöntemlerle elde edilmektedir. Doğası gereği çok sayıda çözüme sahip olması nedeniyle, aynı sonucu veren bir'den çok fonksiyon bulunabilir. Çözümü belirli bir çözüm uzayına sınırlandırmak maksadıyla çeşitli önsel bilgilerden yararlanılır. Analitik önsellerden birisi olan ÇKE, düzgün (smooth) olan yerlerde iyi sonuçlar vermektedir. Kenar ve gradyan istatistiklerine dayalı yöntemler ise daha keskin görüntü ediniminde; yerel parça temelli

olanlar ise harici veri tabanlarından veya benzer DÇ örneklerden elde edilen bilgileri bir sözlükte barındırarak ve bunları aday YÇ parça görüntüleri ile seyrek doğrusal (sparse linear) kombinasyonlar yaparak bulmaya çalışır [4].



Şekil 2.2. Çoklu görüntüye dayalı süper çözünürlük uygulama modeli

Önsel bilginin ediniminde son yöntemler genellikle örneğe dayalı yaklaşımı kullanmaktadır. Bu yöntemler ya aynı görüntüdeki dâhili benzerlikleri ya da harici DÇ/YÇ görüntü örneklerindeki eşleşmelerden öğrenmektedir. Harici örneğe dayalı yöntemlerde DÇ/YÇ görüntü parçaları arasındaki eşleşme için en yakın komşu algoritması, manifold, ya da çekirdek regresyonu (kernel regression), rastgele orman (random forest), sabitlenmiş komşuluk bağlantısı (anchored neighborhood regression) gibi yaklaşımlar önerilmiştir. Harici örneğe dayalı yöntemler genel SÇ için veya verilen örneklerle göre konuya özel (yüz halüsinasyonu gibi) tasarlanabilirler. Seyrek kodlama (SK) yöntemleri harici örneklerle dayalı SÇ yöntemlerinden biridir. İlk önce birbiri üzerine binen yerel parçalar girdi görüntüsünden yoğun bir şekilde alınır ve ortalamasının çıkarılması ve normalizasyon işlemi ile ön işleme tabi tutulur. Sonrasında, bu parçalar DÇ sözlüğüne kodlanarak saklanır. SK katsayıları YÇ sözlüğüne YÇ görüntü parçalarının geri çatımı (reconstruction) esnasında kullanılmak üzere verilir. Birbiri üzerine binen geri çatılmış YÇ parçalar toplanır (ağırlıklı ortalamalar ile) ve nihai görüntü elde edilir. Bu süreç çoğu örnek temelli yaklaşımda kullanılmaktadır [4].

İlave olarak, son zamanlarda örneklerden öğrenme yaklaşımı ile tekil görüntü üzerinden SÇ elde etmek ÇG temelli SÇ elde etmeye göre daha tercih edilmektedir. Örneklerden öğrenme yaklaşımıyla uygulanan yöntemlerden olan DÖ algoritmaları sıkça ve diğer tekniklere nazaran oldukça yüksek başarıyla kullanılmaktadır. DÖ ağırları özel bir eğitim süreci ile

kendisine verilen DÇ ve YÇ imgeler arasındaki doğrusal olmayan fonksiyonu öğrenmeye çalışır.

Havadan görüntüleme, tıbbi görüntüleme, uydu görüntüleme, mikroskopik görüntüleme gibi pek çok görüntüleme metodu üzerinde çokça sayıda SÇ çalışması gerçekleştirilmiş ve problemin çözümü için değişik yaklaşımlar önerilmiştir. İlerleyen kısımlarda optik görüntüler üzerinde ve ardından UG’de yapılan SÇ çalışmaları derlenmiştir.

Optik Görüntülerde Süper Çözünürlük

İlk yapılan çalışmalarda çift kübik enterpolasyon (ÇKE) [5] ve Lanczos yeniden örnekleme gibi ara değerlendirme teknikleri kullanılmıştır. Bu metotlar görüntünün istatistik önsel bilgilerini veya dâhili belirli bir bölgenin yinelenmesinden yararlanmaktadır.

Günümüzde öğrenme tabanlı yaklaşımlar [6], [7], [8], [9] YÇ ile DÇ görüntüler arasındaki eşleşmeyi modellemek için sıkça kullanılmaktadır. Eşleşme için seyrek gösterim, rastgele orman gibi teknikler kullanılmaktadır. Komşu yerleştirme (neighbor embedding) yerel alt parçaları kullanmaktadır. Bir diğeri seyrek kodlama (SK) yöntemleri bir sözlükten seyrek sinyal gösterimini kullanarak öğrenilmiş bilgileri kullanmaktadır. Rastgele orman (random forest) ve özellikle en yeni çalışmalarda katlamalı sinir ağları (KSA) ve çekişmeli üretici ağlar (GAN) oldukça başarılı sonuçlar vermeleri nedeniyle odakları üzerine çekmiştir.

Dong, Loy, He ve Tang [4] SRCNN modeli ile ilk defa bir DÖ algoritmasını SÇ için uygulamıştır. Seyrek kodlama yöntemini DÖ tekniğine uyarlanabileceği fikrinden hareketle oluşturulmuştur. Üç katmanlı KSA yapısına sahiptir. İlk katman parçaların alınması ve temsili; ikinci katman doğrusal olmayan eşleşme ve üçüncü katman geri çatma işlevi görür. 9-1-5, 9-1-1-5, 9-3-5 ve 9-3-1-5 şeklinde filtre boyutlu katmanlar üzerinde çalışmalar yapılmış ve daha evvel yapılmış çalışmalardan kayda değer miktarda üstün başarı elde edilmiştir. Ardından, SÇ’de gerçek zamanlı görüntü işleme (24 fps) hızına erişmek amacıyla FSRCNN [10] modeli önerilmiştir. Gerçek zamanlı görüntü işleme hızına erişmek için performans kaybına uğramayacak şekilde ağın parametre sayısı azaltılmıştır. SRCNN modelinden farklı olarak orijinal görüntüyü girdi olarak almakta ve büyütme işlemini ters katlama katmanında gerçekleştirmektedir. Önerilen modellerden biri SRCNN’e göre 30,1 kat bir diğeri 41,3 kat hızlı olmuştur. Benzeri şekilde, DCSCN [11] modeli derin

mimarilerin tablet ve nesnelerin interneti (IoT) aygıtları gibi hesaplama gücü düşük olan cihazlarda da çalıştırılabilmesi maksadıyla tasarlanmıştır. Model daha evvel yapılan çalışmalardan daha iyi sonuçlar sunarken, hesaplama maliyeti on kat azaltılmıştır. Hem resim hem de video görüntülerinde SÇ elde etme amacıyla ESPCN modeli [12] DÇ görüntü parçalarının istenen ölçekte ara değerlendirme ile büyütülmüş halini girdi olarak alan bir ağ oluşturmak yerine, ölçek büyütmeyi ağın sonundaki katmanda gerçekleştirmiştir. Yapılan deneyler sonucunda modelin SRCNN çalışmasındaki 9-5-5 modeli ile kıyaslanmış ve 10 kattan fazla daha hızlı bulunmuştur. Bu hızın HD videoların tek bir GPU üzerinden gerçek zamanlı yürütülmesi için yeterli olduğu belirtilmiştir. ESPCN modeli gibi piksel altı katlama (sub-pixel convolution) mimarisine sahip bir diğer model NTIRE 2017 SÇ yarışmasının finalisti olan EDSR'dir [13].

Li, Li, Wang ve Wang [14] DCNN modeli ile çoklu çerçeve (multi frame) görüntülerden elde edilen bir hedef görüntüyü SRCNN ile aynı yapıda olan bir ağa vererek SÇ probleminde çözüm aranmıştır. Araştırmacılar, DÇ görüntü pikselleri ve hedef görüntü piksellerinin karesel hatasını hesaplayan bir terim, yüksek geçiren bir filtre parametresine sahip bir terim ve bir de yumuşatma (smoothing) terimine sahip olan bir maliyet fonksiyonu kullanmıştır. Zhong, Mei, Wang, Shao ve He [15] de, SRCNN modelini temel alarak farklı filtre boyutları ve sayıları ile farklı katman sayıları ile daha iyi sonuçlar elde etmek maksadıyla RSRCNN modelini önermiştir.

DRCN [16], VDSR [17], DRRN [18] modelleri farksal öğrenme (residual learning) yaklaşımını benimsemiştir. Farksal öğrenmedeki mekanizma, giriş verisi belirli art arda konmuş KSA katmanlarından sonra bu katmanların çıkışlarına giriş görüntüsünün verilmesi prensibine dayanır. DRCN modelinde aynı KSA 16 defaya kadar yinelemektedir. Yinelemeli ağlarda sıkça karşılaşılan gradyan patlaması veya yitimi (GPY) sorununu çözmek için gelişmiş model önerilmiştir. Bu modelde, aynı gösterim tekrar tekrar katlamada kullanılabileceği düşüncesiyle her bir yinelemede aynı geri çatma ağı YÇ görüntü tahmini için kullanılmıştır ve sonuçta D adet (yineleme sayısı kadar) tahmin görüntüsü elde edilmiştir. Geri çatma ağından elde edilen D adet görüntünün ortalaması alınarak sonuç tahmin görüntü elde edilmektedir. VDSR modeli SRCNN modelindeki küçük yerel (33x33 piksel) parçalar yerine daha büyük (41x41 piksel) yerel parçalar üzerinde işlem yapan 20 katmanlı KSA'dır. Modelde, ayarlanabilir gradyan kırpması (adjustable gradient clipping) tekniği ile gradyan değerleri $[-\Theta, \Theta]$ gibi bir aralığa çekilerek GPY sorununa çözüm

aranmıştır. Böylece ağı eğitilmesinde çok hızlı bir yakınsama sağlanmıştır. Yang, Xu ve Tian VDSR [19] mimarisini daha az bellek ve işlem yükü ihtiyacı duyacak şekilde yeniden ele alarak VDSRX modelini geliştirmiştir. VDSR modelinden esinlenerek geliştirilen bir diğer model DRRN'dir [18]. DRRN modelinde hem genel kısa yol yaklaşımını hem de alt KSA grupları içerisinde de ResNet [20] modelindeki gibi öz yinelemeli ve yerel kısa yol bağlantısı adı verilen bağlantı türünü birleştirerek kullanılmıştır.

Mao, Shen ve Yang [21] kodlayıcı-kod çözücü yaklaşımına sahip RED-NET modelini önermiştir. Modelde, KSA'lar görüntü detaylarını elde eden nitelik çıkarıcısı olarak kullanırken, aynı zamanda gürültü ve bozulmaları da elimine etmiştir. Ters katlama (deconvolution) katmanları görüntü detayları elde etmek maksadıyla kullanılmıştır.

SCN modelinde konu uzmanı (domain expertise) kavramı üzerinde durularak ve LIST'den (iterative shrinkage and thresholding algorithm) yararlanmak suretiyle ileri beslemeli bir ağ kullanılmıştır [22]. Her bir büyütme ölçek için ayrı ağ oluşturma fikri yerine kademeli (cascade) bir yapı kullanılmış ve bir den çok ölçek için tek bir model tasarlanmıştır. Böylece esnek bir yapıya ve özellikle yüksek ölçeklerde ortaya çıkan yapay oluşumlara (artifacts) dayanıklı bir model elde edilmiştir. Wang, Liu, Yang, Han ve Huang [23], SCN modelini işbirlikçi modeller yaklaşımı ile yeniden ele alarak ESCN modelini oluşturmuştur. Bir den fazla SCN modeli çıktısı geri iz düşün yöntemiyle ağırlıklandırılmış ve ortalamalar kullanılarak YÇ görüntü elde etmiştir. Bu sayede önceki çalışmalardan daha iyi sonuçlar elde edilmiştir. Wang, Huang, Yong ve Pan [24] tarafından MSCN modelinde komşu yerleştirme tekniği ile birlikte sinir ağları kullanmıştır. Ağ birkaç SÇ çıkarım modülü ve bir uyarlamalı ağırlık modülünden oluşmaktadır. Her bir SÇ çıkarım modülü belirli bir türde görüntü yerel örüntüsünü çıkarmak üzere oluşturulmuştur ve her biri bağımsız olarak DÇ görüntüye uygulanarak YÇ görüntüyü tahmin etmesi istenmiştir. Tahminler daha sonra uyarlamalı olarak piksel ağırlıklarının uyarlama modülünde toplanması ile nihai YÇ görüntü elde edilmiştir.

Zhang, Zuo, Gu ve Zhang [25], IRCNN modelini görüntü onarımı için özellikle gürültü giderme için kullanmakla beraber, SÇ amacıyla da kullanmıştır. Lai, Huang, Ahuja ve Yang [26] ise derin laplas piramit ağları (laplacian pyramid super-resolution) kullanan LAPSRN modelini önerilmiştir. Araştırmacılar, Ağa verilecek DÇ görüntünün ara değerlendirme ile büyütülmesindeki gereksiz hesaplama yükünü, geri çatma esnasında meydana gelen gözle

görülür yapay oluşumları (artifacts) ve l_2 hata hesabını kullanılması nedeniyle oluşan bulanık kestirim sorununu gidermeyi amaçlamıştır. İlave olarak, elde edilen görüntülerin insan görme sistemine yakın olmayışı ve her bir ölçek için ayrı bir model oluşturma sorunlarına da çözüm getirmeye çalışılmıştır. Hata fonksiyonu olarak sıra dışı değerler için daha iyi sonuç veren Charbonnier hata fonksiyonu kullanılmıştır. Sajjadi, Scholkopf ve Hirsch [27] de, LAPSRN'deki gibi gerçekçi (realistic) görüntü üretmeye odaklanarak EnhanceNet modelini geliştirmiştir. Sıkı bağlantılı (densely connected) katman mimarisi DenseNet [28] ve RDN [29] modellerinde başarılı bir şekilde uygulanmıştır. Tai, Yang, Liu ve Xu [30] ise yinelemeli (recursive) ve kapı (gate) birimi olmak üzere iki ana unsurdan meydana gelen MemNet modelini önermiştir. Hiyerarşik yapıya sahip HCNN [31] derin ağı ve çok etiketli gen ifade programlama (multilable gene expression programming) yönteminin kullanıldığı MGEP-SRCNN [32] modeli de en son geliştirilen KSA ağlarındandır.

KSA mimarisine sahip derin ağlara ilave olarak, özellikle son yıllarda, GAN mimarisine sahip derin ağlar da oldukça önemli başarılarla imza atmıştır. Bu tür ağların ilk örneklerinden biri SRGAN [33] modelidir. Bu model sayesinde özellikle yüksek büyültme faktörlerinde, yanlış maliyet fonksiyonu (adversarial loss) ve içerik maliyet fonksiyonu (content loss) olmak üzere iki farklı fonksiyondan meydana gelen algısal maliyet fonksiyonu (perceptual loss) kullanarak, daha yüksek doku detaylarına sahip görüntü oluşturulmaya çalışılmıştır. Wang ve diğerleri [34] SRGAN üzerinden ESRGAN modelini geliştirerek daha iyi sonuçlar elde etmeyi amaçlamıştır. Hu ve diğerleri [35] ise ESRGAN modelinin avantajlarını ESPCN modelinin gerçek zamanlı işleme performansı ile birleştirerek RTSRGAN modelini geliştirmiştir. Bu modellerin amaçladığı gibi, insan görme sistemine daha uygun YÇ görüntü oluşturmak için gradyan büyüklük benzerlik sapması (GMSD) tekniğini kullanan GMGAN [36] ağı Zhu, Zhang, Zhang, Liu, Shen ve Zhao tarafından önerilmiştir. Benzeri şekilde, Zhang, Wang, Lin, ve Qi de SRNTT [37] modelinde DÇ görüntülerdeki bilgi kaybına odaklanarak, daha iyi doku detayları üretebilmek adına referansa dayalı (reference-based) SÇ yaklaşımı uygulamıştır.

Zareapoor, Celebi ve Yang [38] çoklu üreteç (multi generators) mimarisi fikrinden hareketle çoklu üretece sahip bir model olan DGAN'ı tasarlamıştır. Çevrim döngüsü fikri yakın zamanda MCinCGAN [39] modelinde önerilmiştir. ZHANG, Song, Zhang, Qiao ve Liu [40] tasarladıkları CGAN modelinde LAPSRN benzeri laplas piramiti yaklaşımını benimsemiştir. Wassertein mimarisi ise Wu, Wang, Cui ve Li tarafından WGAN [41]

modelinde başarı ile uygulanmıştır. SRGAN modeline nitelik güdümlü (feature-guided) yaklaşımının uygulanması ile FG-SRGAN [42] modeli oluşturulmuştur. Seddik, Tamaazousti ve Lin [43] işbirlikçi GAN fikrinden hareketle birbiriyle işbirliği içerisinde olan alt modüllerden oluşan GCN ağını önermiştir. Olasılığa dayalı GAN fikri Wang, Chen, Zhang ve Liu [44] tarafından PGM modelinde uygulanmıştır. Shamsolmoali, Zareapoor, Wang, Jain ve Yang [45] ise, yakın zamanda kademeli GAN fikrini G-GANISR modeli ile gerçekleştirmiştir.

Ultrason Görüntülerinde Süper Çözünürlük

Ultrason görüntüsünü iyileştirme teknikleri ön işleme ve ardıl işleme olarak iki ayrı yaklaşımla ele alınmaktadır. Ön işleme teknikleri görüntünün edinilmesini olumsuz yönde etkileyen evre uyum, bant genişliği, doğrusal olmayan yayılım, sönümleme, emilim gibi fiziksel özelliklere ilave olarak ortama gönderilen veya cihaza gelen sinyalleri işleme veya farklı görüntüleme metotlarına odaklanır. Harmoni görüntüleme, dürtü kodlama/sıkıştırma, sentetik açıklık görüntüleme, uzamsal birleştirme ve frekans birleştirme ön işleme safhasında uygulanan tipik yöntemlerdendir [1].

İlave olarak, zaman tersinme çoklu sinyal sınıflandırma (TR-MUSIC), faz uyumlu çoklu sinyal sınıflandırma (PC-MUSIC) son yıllarda uygulanan yöntemler arasındadır. TR-MUSIC yönteminde ses sinyali bir dizi evirgeç (transducer) tarafından alınır, zamanı tersine çevrilir ve yeniden görüntüleme ortamına gönderilir. Gönderilen sinyal ortamdan tekrar geri yayılır ve yaklaşık olarak gönderildiği yerde yeniden toplanır. Homojen ve sönümlemeyen (non attenuative) ortam içerisindeki noktaya benzer yansıtıcıların (scatterer) görüntülenmesinde kullanılır [46]. PC-MUSIC en gürbüz SÇ yöntemlerinden biridir. TR-MUSIC yöntemini değiştirerek, SÇ elde etmek ve gürültüyü gidermek için çoklu frekanslardan elde edilen faz bilgisini kullanır. Evirgeç elemanlarının faz yanıtlarını dikkate almaz.

Ardıl işleme tekniklerindeki çalışmalar

Ardıl işleme teknikleri hâlihazırda elde edilmiş olan görüntü verisi üzerine çeşitli sinyal işleme teknikleri uygulanması ile görüntünün iyileştirilmesine çalışmaktadır. Bu teknikler kenarların iyileştirilmesini, daha iyi zıtlık ve çözünürlük elde edilmesini sağlarken

gürültünün azaltılmasını amaçlar. SÇ yöntemleri bu noktada görüntü kalitesinin artırılması amacıyla çözünürlüğü artırmakla beraber görüntüdeki mevcut detayları korumayı ve hatta daha da iyileştirmeyi hedefler. Filtreleme ve ters konvolüsyon (deconvolution) ilk başlarda kullanılan tipik uygulamalardandır.

B-mod ultrason görüntüleri yayılan dürtü (pulse) sinyali ve görüntülenen dokudaki akustik reflektörler arasında iki boyutlu (2B) konvolüsyon sonucu modellenenbilir. Dürtü ile ters konvolüsyon yapılması aracılığıyla çözünürlüğün artırılması için dürtünün önceden bilinmesi veya gözlemlenen görüntü üzerinden tahmin edilmesi gerekir. Bu tahmin işlemi kör ters konvolüsyon (blind deconvolution) olarak adlandırılır [47].

Abeyratne, Petropulu ve Reid [48] RF sinyali seviyesinde kör ters konvolüsyon metodu ile çözünürlüğü iyileştirmeye çalışmıştır. Bir boyutlu çarpıklık çekirdekleri (distortion kernel) RF verisi üzerinde icra edilen çift kepstrum (bicepstrum) operasyonları ile bulunan çekirdekler kör ters konvolüsyon metodunda uygulanmıştır. Araştırmacılar bu yöntemi [49] daha sonra göğüs görüntüleri üzerinde uygulamış ve başarılı sonuçlar elde etmiştir. Taxt ve Strand [47], bu yöntemlerin aksine, 2B dürtülerde herhangi bir kısıtlamaya ihtiyaç duymayan bir kör eşyapılı (homomorphic) ters konvolüsyon yöntemi geliştirmiştir. Yöntem, kaydedilen görüntünün alt görüntülere ayrılarak, alt görüntüler üzerinde dürtünün tahmin edilmesine ve tahmin edilen dürtünün ortalama değerinin ters konvolüsyon işleminde kullanılmasına dayanmaktadır.

Parker [50] Z dönüşümünden yararlanarak benek gürültüsünü azaltmak ve DÇ sorununu gidermek için asimetrik dürtü tabanlı bir ters filtre üzerine çalışmıştır. Chen ve Parker [51] bu çalışmayı stabil simetrik ışın deseni için (beampattern) geliştirerek, dengelenmiş dürtü metodunu sınırlandırılmış bir ters filtre yaklaşımıyla birlikte yanal eksen üzerinde ters konvolüsyon yapmak gayesiyle kullanmıştır. Daha sonra, derinlik ekseni üzerinde de konvolüsyon yöntemi uygulamışlar ve böylece daha önce gerçekleştirmiş oldukları tek boyutlu ters konvolüsyon tekniğini iki boyutlu ters konvolüsyon haline dönüştürmüşlerdir [52].

Michailovich ve Adam [53] eşyapılı ters konvolüsyon metodunu nokta saçılım fonksiyonunun (PSF) tahmini için RF sinyalleri üzerinde kullanmıştır. Michailovich ve Tannenbaum [54] da, parametrik ters filtreleme dayalı bir teknik kullanarak çözünürlüğü

iyileştirmeye çalışmıştır. Kullanılan filtre PSF'ye dair kısmi bilginin edinimi ve sonrasında da bu bilgi ters filtrenin tayfsal şeklinin baskılanması (constrain) şeklinde iki aşamadan oluşan bir kör (blind) ters konvolüsyon tekniğinden meydana gelmiştir. Kouamé ve Ploquin de [55] PSF'nin parametrik modellenmesine dayalı bir metot önermiştir. Araştırmacılar diğer bir çalışmada [56] en küçük kareler yöntemine dayalı çok boyutlu parametrik modelleme yapan bir yöntem önermiştir. Morin, Basarab ve Kouamé ise PSF tahmini için farklı bir yol izleyerek, RF sinyali yerine eş fazlı dördün (IQ) sinyallerine çarpanların alternatif yönelim yöntemi (ADMM) tekniğini uygulamıştır [57]. Araştırmacılar, bir diğer parametrik model çalışmasında [58] B-mod ultrason görüntülerinin çözünürlüğünü iyileştirmek için RF sinyal zarflarının (envelope) tahmini için çok boyutlu otomatik bağlanım (autoregressive) tekniği uygulamıştır. Zhao, Wei, Basarab, Kouamé ve Tourneret [59] doku yansıtma fonksiyonunun (tissue reflectivity function) optimizasyonu için ℓ_2 normunda bir düzenleyiciye dayalı bir analitik çözümü ADMM metoduna uyarlayarak hesaplama zamanını düşürmüş ve daha iyi SÇ elde etmiştir. Zhang ve Xie [60] seyrek düzenlenmiş (sparse regularized) kör ters konvolüsyon modeli ile hesaplama yükünü büyük ölçüde azaltmış ve önerilen modelin çözümü için ADMM algoritmasını uygulamıştır.

Jensen, eksenel çözünürlüğü artırmak amacıyla Kalman filtresine dayalı gerçek zamanlı (realtime) bir ters konvolüsyon algoritması tasarlamıştır [61]. Dürtünün tahmini için öz bağlanımlı hareketli ortalama (auto regressive moving average) metodunu kullanmıştır. Algoritma çok çekirdekli CPU'lar üzerinde gerçek zamanlı uygulamalarda hızlı koşturulabilecek şekilde tasarlanmıştır.

Yang, Tuthill, Raunig, Fox ve Analoui [62] ardışık B-mod ultrason görüntüleri üzerinde piksel birleştirme (pixel compounding) tekniği uygulayarak çözünürlüğü artırmaya çalışmıştır. Piksel altı çakıştırma işlemi için maksimum sonsal tahmin (MAP) yöntemini ve ardından YÇ elde etmek için de eşyönsüz yayılım (AD) tekniğini uygulamıştır. Dai, Wang ve Liu da benzeri şekilde AD tekniğini MAP ile birlikte, damar genişliğinin ölçümünü zorlaştıran DÇ sorununu gidermek kullanmıştır [63]. Wang, Cao, Dai ve Liu, AD tekniğinin benek gürültüsünü gidermede yetersiz kaldığı fikrinden hareketle doğrusal olmayan yayılım (ND) yöntemine dayalı bir SÇ metodu geliştirilmiştir [64].

Geleneksel SÇ algoritmaları ultrason görüntüleri dizilerine uygulandığı için gerçek elastik hareketi tahmin etmede başarısız olmakla beraber benek gürültüsünün karakteristiğini de

bozarak DÇ görüntü üretilmesine neden olmuştur. Benek gürültüsü kaydırma (speckle tracking) diye de adlandırılan blok eşleşme (block matching) metodu bu hareketin tahmini için kullanılan yöntemlerdendir. Çift doğrusal değişim blok eşleştirme (BDBM) metodu ise BM'nin geliştirilmiş halidir. BM metodu sadece iki parametre kullanarak rijit değişimleri tahmin etmeye çalışırken, BDBM 8 parametrelili çift doğrusal enterpolasyon (ÇDE) model ile yerel doğrusal hareketleri tahmin etmeye çalışır [65]. Morin, Basarab, Ploquin ve Kouamé [66] elastik hareketin tahmini için değişik hareket tahminleri üzerine bir çalışma yapmıştır. Çalışmada, kaliteli ultrason görüntüsü elde edebilmek maksadıyla imge çakıştırma safhasına odaklanılmıştır. B-mod ultrason RF dizileri BDBM yöntemi hareket tahmini ve yerel küçük değişimlerin belirlenmesi için kullanılmıştır. Morin, Basarab, Bidon ve Kouamé ise BDBM yöntemini karmaşık doku hareketlerinin tahmini ve yerel bölge değişimlerinin bulunması için adapte etmiştir [65]. Hareketin tahmininden sonra çift kübik enterpolasyon (ÇKE) yöntemi ile imge geri çatılarak YÇ görüntü elde edilmiştir.

Sharabati ve Bowei [67] YÇ imgelerdeki piksellerin tahmini için DÇ imgelerdeki piksellerin karesel 3 komşuluğundaki piksellerin mesafelerine dayalı bir ağırlıklı regresyon modelini uygulamıştır. Cüneytoğlu Özkul, Mumcuoğlu ve Sancak [68] da benek gürültüsünün uzamsal bağıntılı gürültü modelini ve çeşitli önsel bilgileri (prior information) ters konvolüsyon operasyonuna dâhil edebilmesi nedeniyle Bayes yaklaşımı uygulamıştır. Hem tekil imge hem de çoklu imge üzerinde SÇ olmak üzere iki farklı yaklaşım önerilmiştir. SÇ algoritmaları çözünürlüğün iyileştirilmesine ilave olarak farklı amaçlarla da kullanılmıştır. Örneğin, Abdel-Nasser, Melendez, Moreno, Omer ve Puig [69] meme tümörünün sınıflandırılmasında tekil görüntüler kullanılmasının görüntülerdeki benek gürültüsü ve düşük karışıklık (contrast) nedeniyle sınıflandırma başarısını düşürdüğü gerekçesiyle çoklu imgeye dayalı SÇ yaptıktan sonra elde edilen görüntüler vasıtası ile sınıflandırma doğruluğunu artırmaya çalışmıştır.

Öğrenmeye dayalı (learning-based) SÇ algoritmaları bir görüntü kütüphanesinden alınan YÇ ve HÇ görüntüler ile öğrenme algoritmasının uygulanması şeklinde uygulanmaktadır. SK ve son yıllarda çok ciddi başarılarla imza atan DÖ algoritmaları da bu tekniklerdendir. Yang, Sun, Chen ve Jiao [70] Tıbbi görüntülerin sıklıkla benzer ve tekrarlayan yapılara sahip olduğu düşüncesinden hareketle SK yöntemini uygulamıştır. Her bir yerel parçaya benzeyen imge parçaları Gauss komşuluğu ile bulunmuştur. Zhang, Li, Shen ve Yang da [71] B-mod

ultrason görüntülerinin yeniden çatılmasıyla (reconstruction) SÇ elde etmek maksadıyla SK tekniğini kullanmıştır.

Topluluktan öğrenme (learning from crowds) çoklu yorumcudan öğrenme diye de adlandırılan bir danışmanlı öğrenme (supervised learning) tekniklerindendir. Aynı tahmin problemine dair, farklı uzmanlardaki bilgilerin birleştirilmesi prensibine dayanır. Gonzalez, Alvarez ve Orozco [72] bir'den çok sayıda enterpolasyon tekniğini görüntüdeki her bir piksele dair bilgi sağlayan birer uzman gibi görerek, topluluktan öğrenme yöntemini Gauss sürecine dayalı regresyon ile birlikte kullanarak YÇ imgenin çatılmasını sağlamıştır.

Son birkaç yılda DÖ algoritmaları diğer alanlarda olduğu gibi ultrason görüntülemeye de geleneksel metot ve tekniklerden daha başarılı sonuçlar sunmuş ve yaygın kullanım alanı bulmuştur. Optik akış (OA) algoritmasına çok benzeyen bir başka derin ağ Abdel-Nasser ve Omer [73] tarafından çoklu imgelerden SÇ elde etmek maksadıyla tasarlanmıştır. Araştırmacılar ultrason imgelerinin kalitesini artırmak için çoklu imgelerden SÇ elde etme sürecinin hareket kestirimi safhasına odaklanmıştır. Choi, Kim, HakLee, Kim ve BeomRa [74] benek gürültüsünü görüntüdeki bir nevi doku olarak ele alıp, optik görüntülerde daha yüksek doku detaylarına sahip görüntü oluşturulmak maksadıyla tasarlanan SRGAN modelini [33] değiştirmiş ve B-mod ultrason görüntülerinde uygulayarak yanal çözünürlüğü artırmak için sadece yüksek frekans bölgelerinde (kenarlar gibi) değil benek gürültüsüne sahip bölgelerde de daha iyi SÇ etmeye çalışmıştır. Wu, Yang, Huang ve Liu [75] da SRGAN modelini damar içi (intravascular) ultrason görüntülerinde SÇ için kullanmıştır. Lu ve Liu [76] danışmansız öğrenme (unsupervised learning) yaklaşımı ile geliştirdikleri genişlemeli (dilated) KSA modelini kullanarak tekil imge üzerinden SÇ elde etmeye çalışmıştır. Zhou, Wang, Yu, Guo ve Fang [77] ise düzlemsel dalga görüntüleme (plane wave imaging) tekniğinde kullanmak üzere bir KSA modelini daha hızlı yakınsama sağlaması için olasılıksal paralel eğim iniş optimizasyon tekniğinin (stochastic parallel gradient descent optimization) her bir yinelemesine geri bildirim yapan bir sistem ile geliştirmiştir.

3. DERİN ÖĞRENME

Derin öğrenme (DÖ) algoritmaları esasen uzun zamandır kullanılmakta olan yapay sinir ağlarının (YSA) özel mimarilere sahip ve çok daha gelişkin türevleridir. Genellikle, geleneksel YSA'dan daha fazla sayıda katman ve nöron içerir. Geleneksel YSA'larda birkaç katman bulunurken DÖ mimarilerinde katman sayısı yüzler mertebesinde olabilmektedir. Ayrıca, daha karmaşık bağlantılara sahip katman türlerine sahiptir. Günümüzde DÖ ağlarındaki parametre (nöron, çekirdek vs.) sayısı milyonlar mertebesinde olabilmektedir. Son on yılda DÖ algoritmaları bilimin birçok alanında geleneksel algoritmalarından daha iyi sonuçlar vermiştir. DÖ'de çok farklı formatlarda mimariler kullanılmaktadır. Bu mimarilerin belli başlıları şöyle sıralanabilir [78]:

- Danışmansız ön eğitilmiş ağlar (unsupervised pretrained networks)
 - Derin inanç ağları (deep belief networks)
 - Otomatik kodlayıcılar (autoencoders)
 - Çekişmeli üretici ağlar (generative adversarial networks)
- Konvolüsyonel sinir ağları (convolutional neural networks)
- Yinelemeli sinir ağları (recurrent neural networks)
- Özyineli sinir ağları (recursive neural networks)

İlerleyen bölümlerde yukarıda verilen DÖ ağları özet olarak değinilmektedir.

3.1. Derin Öğrenme Mimarileri

Bu tez çalışmasında konvolüsyonel sinir ağları (KSA) modelleri ile çalışıldığından, ilerleyen bölümlerde diğer belli başlı DÖ mimarileri kısa açıklanmış, KSA'lar ise detaylı bir şekilde tanıtılmıştır.

3.1.1. Derin inanç ağları

Derin inanç ağları ön eğitim aşamasında yasaklı Boltzman makinesi (RBM) kullanan ve sonrasında ise ileri beslemeli sinir ağından oluşmaktadır. RBM'ler ilk etapta yüksek seviye özniteliklerin ham giriş vektörlerinden elde edilmesinde kullanılır. RBM'lere bir giriş kaydı verildiğinde bu girişi yeniden inşa etmesi istenir. Tüm bunları danışmansız öğrenme ile yapması beklenir [78].

3.1.2. Otomatik kodlayıcılar

Otomatik kodlayıcılar (AE) bir kodlayıcı (encoder) ve ardından da bir kod çözücü (decoder) alt ağına sahiptir. Kodlayıcı tarafı ağa verilen girdi verisinin bir özeti veya indirgenmiş halini çıktı olarak üretilirken, kod çözücü tarafı indirgenmiş veriyi alarak orijinal veriyi tekrar elde etmeye çalışır. Konvolüsyon ağları genellikle büyük miktarlardaki veri setlerinin etiketlenmiş olmasına ihtiyaç duyar. Çoğu durumda etiketlenmiş veriyi elde etmek oldukça zahmetli bir iş olmaktadır. Etiketlenmemiş verilerin de işlenebilmesi maksadıyla AE'ler önerilmiştir. Kodlayıcı tarafı veriyi alarak verinin daha az boyutlu öznitelikler temsilini oluşturmakta, bir nevi temel bileşenler analizi gibi önemli bilgilerini saklayıp sıkıştırma yapmaktadır. Kod çözümü de sıkıştırılmış veriyi alarak etiketlemek yerine orijinale dönüştürmeye çalışır [78].

3.1.3. Çekişmeli Üretici Ağlar

Çekişmeli üretici ağlar (GAN) eğitim görüntülerine dayanarak yeni görüntülerin sentetik üretiminde oldukça başarılı sonuçlar vermiştir. Ses, video ve metin ifadelerinden görüntü üretme gibi kavramlar için de kullanılmaktadır. GAN'lar danışmansız öğrenme yapan modellerden biridir. İki alt ağdan meydana gelmektedir: üretici (generative) ve ayırtıcı (discriminative) ağı. İlk ağ orijinal verilerden sentetik veriler üretir ve ikinci alt ağa verir. İkinci alt ağ ise verilen sentetik veriyi gerçek veya sentetik diye sınıflandırmaya çalışır. İlk ağın amacı bir nevi, ikinci ağı kandırmak; ikinci ağın amacı ise gerçek veri ile sentetik veriyi doğru tespit etmektir [78].

3.1.4. Yinelemeli sinir ağları

Yinelemeli sinir ağları (RNN) döngüler çıktısını tekrar kendisine girdi olarak veren sabit yapıya sahip bir sinir ağı modelidir. Döngüsel bir yapıya sahip olması nedeniyle zaman serileri, dil, ses ve metin verilerini işlemede oldukça yararlıdır. Ağa verilen veriler sıralıdır ve sonraki değerler önceki değerlere bağlıdır. Veriler değişken uzunlukta olabilmektedir. RNN'ler zaman serileri arasındaki zamansal bağıntıyı tutmak için parametre matrisine de sahiptir. Belirli bir andaki çıktı o andaki girdi verisine ve daha önceki zaman çıktılarına bağlıdır. Gradyanların hesaplanmasında zamanda geri yayılım (backpropagation through time) algoritması kullanılır. Görüntü etiketleme, konuşma sentezleme, müzik üretme, video

oyunları oynama, dil modelleme, karakter seviyesinde metin türetme, zaman serisi kestirimi, video analizi, doğal dil tercümesi ve robot kontrolünde kullanılmaktadır. Geleneksel modeller sabit boyutlu veriler üzerinde işlem sabit girdiden sabit çıktıyı verirken RNN’de girdi vektörleri zaman boyutuyla birlikte değişken uzunluklu dinamik bir yapı şeklindedir. Örneğin görüntü etiketlemede girdi bir resim iken çıktı kelimeler vektörü olmaktadır.

Uzun kısa dönemli hafıza


En yaygın kullanılan RNN çeşidi uzun kısa dönemli hafıza (LSTM) ağlarıdır. LSTM bünyesinde bir hafıza hücresi (memory cell), bir giriş kapısı (input gate) ve bir unutma kapısı (forget gate) bulunur. Hafıza hücresinin içeriği giriş ve unutma kapıları tarafından düzenlenir. Belirli bir zaman adımında giriş ve unutma kapıları kapalı olduğunda hafıza hücresindeki veri değişmeden kalır. Gradyan patlaması veya yitimi (GPY) problemini kapılar sayesinde çözer. Kapılar bilginin birçok zaman adımında saklı kalmasını sağlar. Cümle kurulması, zaman serileri sınıflandırma, konuşma tanıma, el yazısı tanıma, görüntü etiketleme, tercüme gibi alanlarda kullanılmaktadır. Durumu saklayan en önemli bileşen hafıza hücresidir. Giriş kapısı alakasız verilerin girmesini önlerken, unutma kapısı bir önceki hafızadaki bileşenlerin atılmasına yardımcı olur. Ağın çıktısı blok girişine ve tüm kapılara girdi olarak tekrar verilir. Giriş, unutma ve çıkış kapıları Sigmoid fonksiyonunu kullanır. Blok giriş ve blok çıkış ise tanh fonksiyonunu kullanır.

3.1.5. Özyineli sinir ağları

Değişken uzunluklu veri girdileri üzerinde çalışabilen özyineli sinir ağları (RvNN), RNN’ler gibi, hiyerarşik yapıdaki verileri de işleyebilmektedir. RvNN paylaşımlı bir ağırlık matrisi ve değişken kelime dizileri veya görüntü parçalarını özyinelemeli öğrenebilen bir ikili ağaç yapısından oluşmaktadır. Görüntülerdeki sahneleri bileşenlerine ayırmada ve cümleleri ayırmada oldukça başarılıdır. Tipik bir RvNN, yapıda geri yayılım (backpropagation through time) adında geri yayılım algoritması türevini kullanır. Özyineli AE ve özyineli sinir tensör (tensor) ağı şeklinde türevleri mevcuttur. Özyineli AE’ler doğal dil işlemede cümlelerin bölümlerine ayrılmasında, görüntü sahnelerini ayrıştırma, doğal dil işleme ve sesten metne çeviri gibi uygulama alanları mevcuttur. Özyineli tensör ağları ise görüntü sahnelerini oluşturan bileşenlerine ayrılmasında kullanılmaktadır.

3.1.6. Konvolüsyonel sinir ağıları

Konvolüsyon (katlama veya evrişim diye de adlandırılır) kavramı görüntü ve sinyal işlemede uzun zamandır sıkça kullanılan bir işlemdir. Şekil 3.1’de konvolüsyon işlemine dair bir örnek verilmiştir. Şeklin sol tarafında bulunan giriş verisi (şekildeki gibi sayısal formatta bir resim olarak tasavvur edilebilir) üzerinde bir filtre çekirdeği (kernel) matrisi gezdirilerek, matrisin her bir hücresine karşılık gelen giriş verisindeki eleman matrisin ilgili elemanı ile çarpılır ve tüm çarpımlar toplanarak elde edilen sonuç yeni bir matrise (şekildeki sonuç imge) yazılır. Şekilde verilen filtre 3x3 boyutlu bir filtre olmakla beraber, filtre çekirdeği farklı boyutlarda (örneğin, 1x1, 1x3, 3x1, 5x5 gibi) olabilir. Konvolüsyon işlemiyle elde edilen yeni veri geleneksel sinir ağlarındaki gibi bir etkinlik fonksiyonuna verilerek katmanın çıktısı hesaplanır.



Şekil 3.1. Konvolüsyon (katlama) işlemi

Konvolüsyonel sinir ağıları (KSA) yüksek mertebeden öznitelikleri konvolüsyon operasyonunu kullanarak öğrenir. Görüntülerdeki nesne tespitinde ve görüntü sınıflandırmada oldukça başarılı sonuçlar vermektedir. Yüzleri, kişileri, sokak tabelalarını tanımda, karakter tanımda vb. sıkça kullanılmaktadır. Ayrıca ses analizinde de başarılı sonuç vermektedir. MRG verileri 3B şekil verilerinde, çizge şeklindeki verilerde ve doğal dil işlemede kullanılmaktadırlar.

KSA’larda normal sinir ağlarından farklı olarak yukarıda bahsedilen bir filtre ile bir sonraki katmana bir önceki katmanın belirli bir yerel bölgesine ait özet veri iletilir. Normal sinir

ağlarında ise bir katmandaki nöronların çıktısı sonraki katmandaki her bir nörona giriş olarak verilir. KSA'ların belirli bir yerel bölgeye ait verileri işlemesi özellikle görüntü işleme uygulamalarında geleneksel sinir ağlarındakine nazaran çok daha hızlı hesaplama işlemi sağlamaktadır. Bu doktora tezi kapsamında yapılan çalışmalarda da farklı derinlik ve parametrelere sahip KSA modelleri ile çalışılmıştır.


3.2. Derin Öğrenme ve Grafik İşleme Birimi (GPU)

İnsanoğlu tarih boyunca evreni anlamaya ve yeni keşifler yapmaya çalışmıştır. Arayışların sonucunda bilim denem metodolojik yaklaşımları bulmuştur. Bu yaklaşımlar ile birçok bilimsel bilgi çıkarımında bulunmuş, yeni yöntem ve teknikler geliştirmiştir. Hayatı kolaylaştıran sayısız yeni icatlara imza atmıştır. Bunun yanında, kimi zaman, teorik olarak yapılabilirliği kanıtlanmış olan bazı icatların uygulamaya konması gerekli donanım, teçhizat vb. olmayışı yüzünden zaman almıştır. Prof. Dr. Doğan CÜCER'in deyişi gibi ("ilim ilerler teknik malzemeyi bekler") [79] DÖ'de malzemeyi beklemiştir. DÖ tekniklerinin uygulanabilirliğini sağlayan teknolojik icat grafik işleme birimlerinin (GPU) üretilmesi olmuştur. Günümüzde sıradan sayılabilecek hesaplama, veri işleme gibi görevlerin gerçekleştirilmesi normalde merkezi işlem birimlerinde (CPU) haftalar, aylar alabilecekken, GPU'lar sayesinde günler, hatta saatler içerisinde tamamlanabilir hale gelmiştir. Üstüne üstlük CPU'lar üzerinde gerçekleştirilmesi mümkün olmayan kimi işler de mümkün hale gelmiştir.

GPU çok boyutlu veri dizilerinin (tensör) hızlıca işlenebilmesi için tasarlanmış özel donanımlardır. Başlangıçta bilgisayar oyunlarının yüksek görüntü kalitesinde oynanabilmesi için kullanılan donanımlar iken, zamanla bilimsel çalışmalar, mühendislik hesaplamaları vb. çok yüksek hacimli verilerin işlenmesi veya hesaplamaların yapılabilmesi amacıyla da kullanılmaya başlanmıştır. Bu bağlamda, DÖ algoritmalarının Terabayt, Eksabayt mertebesinde ve hatta çok daha yüksek miktarda veriler üzerinde oldukça yüksek hesaplama yükü gerektiren işlerin gerçekleştirilebilmesi GPU'lar sayesinde kolayca mümkün hale gelmiştir.

GPU'ların ne derece önemli bir icat olduğunun anlaşılması için Şekil 3.2'de 2000 adet CPU sunucusundan oluşan Google Brain sistemi ve NVIDIA Titan Z GPU kartının karşılaştırılması verilmiştir [80]. Google Brain sistemi iki bin adet CPU ile ancak 16 bin


adet işlemci çekirdeğine sahip iken, bir Titan Z GPU'su 17280 adet çekirdeğe sahiptir. Benzeri şekilde, 600kW enerji çeken sistemin yerini 2kW (300 kat daha az enerji) harcayan ve 400 kat daha az ucuz bir donanım kartı almıştır.



Şekil 3.2. Google Brain sistemi ile NVIDIA Titan Z GPU'sunun karşılaştırılması [80].

Şekil 3.3'de ise sıradan bir Intel i7 CPU ile orta seviyede sayılabilecek 3 adet GPU'nun tipik bir DÖ ağını 500 adet görüntüye sahip bir eğitim seti ile eğitilmesinde gösterdiği performanslar verilmiştir. NVIDIA K80 ve GTX 1050Ti GPU'ları yaklaşık 24 dakikada eğitimi tamamlarken, i7 CPU'su neredeyse 9 saatte tamamlayabilmıştır. Görüldüğü üzere, günümüzün sıradan GPU'ları olarak gösterilebilecek donanım kartları aynı miktardaki işi sıradan bir CPU'ya göre yaklaşık 22,1 kat gibi çok daha kısa bir sürede tamamlamıştır. Günümüzdeki veri miktarlarının büyüklüğü düşünüldüğünde GPU'ların önemi daha da iyi anlaşılacaktır.

GPU teknolojisine ilave olarak, günümüzde Google tarafından uygulamaya yönelik geliştirilen ve çok boyutlu matris ve vektör işlemeye imkân veren, tensör işleme birimlerinden (TPU) de söz edilmektedir [81]. Böylece, makine öğrenmesi ve DÖ uygulamalarının çok daha yüksek verimlilikte ve hızlarda gerçekleştirilmesi mümkün olmaktadır.



Şekil 3.3. Bir DÖ ağının farklı işlemcilerde 500 imgeyle eğitilme süreleri [82]

Bu doktora tezi çalışmasında da orta boyutta sayılabilecek parametre sayısına sahip ve kimi zaman çok daha yüksek miktarda parametrelili DÖ ağları yüksek miktarda (örneğin, yaklaşık 28 bin adet ultrason görüntüsü) veriler üzerinde eğitilmiştir. Bu eğitimlerin tamamlanabilmesinde GPU donanım kartları önemli rol oynamıştır. Hatta GPU'ların icat edilmemiş olması durumunda bu tez çalışmasının gerçekleştirilmesinin neredeyse imkânsız olacağı rahatlıkla söylenebilir.



4. ULTRASON GÖRÜNTÜLEME

Ultrason yüksek frekansa sahip olan ses dalgaları için kullanılmakta olan bir terimdir. Bahsi geçen yüksek frekanslar insanın duyabileceği aralığın (15 Hz ile 20 KHz arası) üzerindeki (20 KHz üzeri) frekanslardır. 15 Hz frekansından daha düşük frekanslara sahip olan ses dalgalarına infrason denmektedir. Medikal ultrason 2 MHz ile 10 MHz frekans aralığında olmakla birlikte, özel ekipmanlar ile 50 MHz frekanslarına da çıkılabilmektedir [83]. Ultrason görüntüleme (UG) hâlihazırda kullanılan ve kullanım oranı gittikçe artmakta olan tıbbi görüntüleme tekniklerinden biridir. 1950'lerden beri gittikçe yaygın kullanılmaktadır. Diğer, manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT) gibi görüntüleme tekniklerine nazaran oldukça düşük maliyetli olmakla birlikte, kolay elde edilebilir ve her yerde kullanılabilir. Sağlık açısından diğer görüntüleme tekniklerine nazaran hem hasta hem de doktor ve tıbbi görüntüleme uzmanı için çok daha güvenilir ve zararsızdır. Ayrıca, müdahalesiz (non-invasive) bir görüntüleme yöntemi oluşu da UG yöntemini cazip kılmaktadır. Görüntü diğer yöntemlere göre oldukça kısa bir zaman içerisinde elde edilir. Görüntüleme aracı olarak kullanılmasının dışında fizik tedavisinde, tümör tedavisinde ve böbrek taşı kırma operasyonunda da kullanılmaktadır. UG yönteminin diğer yöntemlerle kıyaslanması Çizelge 4.1'de verilmiştir [83].


UG ses dalgalarının vücuda veya dokuya gönderilmesi ve doku veya organdan gelen ses yansımalarının ölçülmesi ile görüntünün edinimi prensibiyle gerçekleştirilmektedir. Ses dalgalarının yumuşak dokulu ortamlardan (organ veya dokulardan) başarılı bir şekilde ilerleyebilmesi ultrason görüntüleme yönteminin kardiyoloji, jinekoloji gibi tıp alanlarında başarılı bir şekilde uygulanmasını mümkün kılmaktadır. Böbrek, karaciğer, prostat, tiroit, kas vb. organların görüntülenmesinde yaygın biçimde kullanılmaktadır. Ayrıca görüntünün anlık olarak elde edilebilmesi kalp gibi sürekli hareket halindeki organların gerçek zamanlı görüntülenmesine imkân sağlamaktadır.

Çizelge 4.1. Ultrason görüntüleme ve diğer görüntüleme tekniklerinin karşılaştırılması [83]

GÖRÜNTÜLEME YÖNTEMİ	ULTRASON	X IŞINI	BİLGİSAYARLI TOMOGRAFİ	MANYETİK REZONANS
Neyi Görüntülüyor	Boyuna, enine, Mekanik özellikler	Dokunun ortalama X ışını soğurması	Bölgesel dokunun X ışını soğurması	Biyokimya (T1 ve T2)
Erişim	Küçük bir pencere yeterli	2 yüzeyden alınması gerekiyor	Vücut etrafından alınması gerekiyor (~1 mm)	Vücut etrafından alınması gerekiyor (~1 mm)
Uzamsal çözünürlük	Frekans ve eksene bağımlı (0.2-3mm)	~1mm	~1mm	~1mm
Nüfuz	Frekansa bağımlı 3 - 25 cm	Çok iyi	Çok iyi	Çok iyi
Emniyet	Çok iyi	İyonlaştırıcı ışın	İyonlaştırıcı ışın	İyi
Hız	100 çerçeve/saniye	Dakikalar	20 dakika	Tipik: 45 dakika hızlı:10 çerçeve /s
Maliyet	\$	\$	\$\$	\$\$\$
Taşınabilirlik	Çok iyi	İyi	Zayıf	Zayıf
Hacim kapsamı	Gerçek zamanlı 3 boyutlu	2 boyutlu	Geniş 3 boyutlu	Geniş 3 boyutlu
Kontrast	Artmakta (kesitte)	Sınırlı	Sınırlı	Daha esnek
Müdahale	Gerçek zamanlı 3 boyutlu	Yok, flüoroskopi sınırlı	Yok	Evet, sınırlı
İşlevsel	İşlevsel ultrason	Hayır	Hayır	İşlevsel MRG

Tıbbi görüntüleme yapılmak istenen bölgeye oldukça yüksek frekans değerlerine sahip ses dalgaları evirgeç (transducer) adı verilen aparatlar vasıtası ile görüntüleme ortamına gönderilir. Ses dalgaları ortam içerisinde mekanik hareket ile yayılır. Gönderilen ses dalgaları dokulara çarparak daha büyük dalga boyları ile geri yansır. Geri yansıyan ses dalgalarına çeşitli tekniklerin ön işleme ve ardıl işleme adı verilen iki ana safhada uygulanması sonucunda nihai ultrason görüntüsü elde edilmiş olur. UG'nin iki ana safhası ve ardıl işlemede gerçekleştirilen ana işlemler Şekil 4.1'de verilmiştir. Ardıl işleme safhasında geri yansımış olan ses sinyalleri radyo frekans (RF) sinyallerine dönüştürülmüştür. RF sinyalleri daha sonra sırasıyla zarf bulma (envelope detection), logaritmik sıkıştırma ve dönüşüm işlemlerine tabi tutulduktan sonra nihai ultrason görüntüsü

elde edilmiş olur. Çeşitli türde nihai görüntü tipleri bulunmaktadır ve bunlar Bölüm 4.4’de özetlenmiştir.



Şekil 4.1. Ultrason görüntülemenin temel aşamaları

Ultrason dalgası ortam içerisinde ilerlerken çeşitli engellemelerle karşılaşır ve derinlik arttıkça şiddeti azalır. Ortamda ilerlerken karşılaştığı engeller ultrason dalgasının bir kısmının farklı yöne yansımaya, bir kısmının ısıya dönüşmesine, bir kısmının da sönümlenmesine neden olur.

Ultrason görüntülerinin düşük kalitede oluşunun temel sebeplerinden biri benek (speckle) gürültüsüdür. Benek gürültüsü ses dalgasını geri yansıtan yayılma ortamı içerisindeki yansıtıcılardan geri yayılan yapıcı (constructive) ve bozucu (destructive) yankıların (echo) doğal etkileşimi neticesinde ortaya çıkmaktadır [84]. Benek gürültüsü arttıkça görüntüdeki kontrast ve uzamsal çözünürlüğün azalmasına ve buna bağlı olarak görüntü kalitesinin giderek azalmasına neden olmaktadır.

Belirtilen olumsuzluklarına rağmen, günümüzde oldukça yaygın bir biçimde kullanılmaktadır. Düşük maliyetli oluşu, her yere taşınabilir ve her yerde kullanılabilir oluşu, görüntüleme yapılan hastaya diğer görüntüleme teknikleri kadar zarar vermeyişi gibi faydaları sayesinde en çok tercih edilen tıbbi görüntüleme tekniklerinden biridir.


4.1. Sesin Özellikleri

Ses dalgaları mekanik hareket ile yayıldıkları için maddeden oluşan bir ortama ihtiyaç duyarlar. Örneğin uzayda ses dalgalarının yayılması mümkün değildir. Yayıldıkları ortama göre farklı hızlarla ilerlerler. Yumuşak dokulu organlardan çok iyi bir şekilde yayılabilirken, içerisinde hava veya boşluk bulunan akciğer, bağırsak, kemik ve mide gibi organlardan iyi geçemezler. Hava ve boşluk içeren organlar içerisinde ilerleyemeyişinin temel sebebi hava-

doku ara yüzünde meydana gelen ses dalgasının kırılma/yansıma direncidir. Bu direnç çok yüksek olduğundan, hava-doku gibi iki farklı ortamdan geçmeleri pek mümkün değildir. Bu nedenle beyin, akciğer, kemik vb. organlarda UG yapılamamaktadır.

Ses dalgasının dalga boyu sıkıştırma (compression) ve gevşeme (rarefaction) arasındaki veya sinüs eğrisi şeklindeki basınç genliğinin tekrar ettiği iki nokta arasındaki mesafedir. Dalga boyu genellikle (λ) ile gösterilir ve birimi genellikle milimetre (mm) olarak verilir. Frekans (f) birim zamanda (genellikle saniyede) gerçekleşen dalga çevriminin adedi olarak tanımlanır ve birimi Hertz (Hz) şeklinde verilir (Şekil 4.2). Saniyede 15 Hz altında çevrim yapan ses dalgaları infrasound olarak adlandırılır. Duyulabilir seslerin frekansları 15 Hz ile 20 kHz aralığındadır. Tıbbi UG sistemlerinde genellikle 2 ile 10 MHz frekans aralıklarındaki ses dalgaları kullanılırken, bu değer özel durumlarda 50 MHz mertebelerine kadar çıkabilmektedir. Ses hızı, ses dalgasının birim zamanda (saniye) kat ettiği yol olarak tanımlanır ve (c) ile gösterilir. Sesin hızı Eş. 4.1'de verildiği gibi dalga boyu ile frekansın çarpımı ile bulunur. Hızın birimi metre/saniye (m/s) ve dalga boyunun (λ) birimi metredir (m) [85].

$$c = \lambda f \quad (4.1)$$



Şekil 4.2. Ultrason görüntüleme frekans, dalga boyu ve genlik

Sesin hızı ortamın sertliği ve sıkıştırılmaya karşı göstermiş olduğu direncin değerini veren Bulk modülü (B) değerine bağlı olarak, yayıldığı ortamın materyaline göre değişik değerler alır. Sertliğin artması ve yoğunluğunun azalması ile ultrason dalgasının hızı artar. Bu ilişki Eş. 4.2 ile tanımlanmıştır.

$$c = \sqrt{\frac{B}{\rho}} \quad (4.2)$$

Standart birimlere (SI) göre B'nin birimi $\text{kg}/(\text{m}\cdot\text{s}^2)$; ρ , kg/m^3 ve c'nin birimi m/s 'dir. Ortamın sıkıştırılabilme değeri arttıkça ses hızı düşerken, sıkıştırılabilme değeri azaldıkça ses hızı artmaktadır. Örneğin, havanın sıkıştırılabilme özelliği yüksek ve sesin havada ilerleme hızı yavaştır. Kemiğin ise sıkıştırılabilme değeri düşük ve sesin kemik üzerinde ilerleme hızı yüksektir.

Ultrason dalgasının yumuşak dokulardaki ilerleme hızı 1540 m/s olarak kabul edilmektedir. Sesin doku sınırlarındaki hız değişimi yansıyan sinyallerin oluşumunu ve dolayısı ile kontrastın oluşumunu sağlayan temel özelliktir. Ultrason dalgasının frekansı farklı ortamlarda ilerleyen sesin hız değişiminden bağımsız olmakla birlikte, ultrason dalga boyu ses hızına bağlıdır. Ultrason dalgalarının çeşitli doku ve materyallerdeki ilerleme hızları Çizelge 4.2'de verilmiştir.

Çizelge 4.2. Tıbbi ultrasonun doku ve materyallerdeki yoğunluk ve ses hızları [85]


MATERYAL	YOĞUNLUK (kg/m^3)	Hız (m/s)
Hava	1,2	330
Akciğer	300	600
Yağ	924	1'450
Su	1'000	1'480
Yumuşak doku	1'050	1'540
Böbrek	1'041	1'565
Kan	1'058	1'560
Karaciğer	1'061	1'555
Kas	1'068	1'600
Kafatası kemiği	1'912	4'080
Piezoelektrik	7'500	4'000

Örneğin, ultrason dalga boyu 10 MHz frekansında 0,154 mm olurken, 1 MHz frekansında ise 1,54 mm olur. Ultrason görüntüsünün uzamsal çözünürlüğü frekans arttıkça yani dalga boyu azaldıkça artış gösterir. Buna karşın, çözünürlük dalga boyuna bağımlı iken ultrason demeti enerjisinin sönümlenmesi (attenuation) frekansa bağımlı olduğu için ultrason

demetinin nüfuz etme derinliği frekans arttıkça azalır. Bu nedenle, derinlik arttıkça ultrason görüntüleme imkansızlaşmaktadır. Görüntüleme derinliğini artırmak için daha düşük frekanslar kullanılır. Fakat gönderilen dalgaının frekansı azaldıkça dalga boyu uzamakta ve üzerlerine gelen ses dalgasını yansıtan iki farklı yansıtıcı noktanın ayırt edilebilme yeteneği ses dalgasının gönderim eksenini doğrultusunda azalmaktadır. Sonuçta daha düşük çözünürlüğe sahip ultrason görüntüleri elde edilir.

4.2. Ultrasonda Uzamsal Çözünürlük

UG'de üç boyutta çözünürlükten bahsedilir: eksenel, yanal ve yükseklik. Eksenel çözünürlük boyuna veya derinlik çözünürlük diye de adlandırılır. Görüntüleme ortamına gönderilen ses dalgasının yönü ile aynı yöndedir. Eksenel çözünürlüğün iyi olması temelde yansıyan ekoların birbirine girişmeden ayrık olarak elde edilebilmesine bağlıdır. Gönderilen dürtü boyunun yarısından daha küçük boyutlardaki nesnelerin algılanabilmesi mümkün değildir. Gönderilen dürtü dalgası ne kadar kısa boylu olursa o kadar daha iyi eksenel çözünürlük elde edilir. UG'de çözünürlük kavramı Şekil 4.3'de verilmiştir.



Şekil 4.3. Ultrason görüntülemesinde çözünürlük

Yanal çözünürlük aynı zamanda azimut çözünürlüğü diye de adlandırılır ve gönderilen ses demetine dik olan birbirine çok yakın iki küçük nesnenin ayırt edilebilme gücünü temsil eder. Yanal çözünürlük ultrason dalgasını gönderimini ve alınmasını sağlayan odaklama elektronigine bağlıdır. Ayrıca, ses demetinin çapı yanal çözünürlüğü belirler. Ses demetinin

çapı (genişliği) odak noktasının gerisinde veya ilerisinde daha yüksek olduğu için çözünürlük bu bölgelerde düşer. Dolayısı ile yanal çözünürlük derinliğe bağlı olarak değişir. Odak noktasında eksenel çözünürlük yanal çözünürlükten; yanal çözünürlük de yükseklik çözünürlüğünden daha iyi olur. En iyi yanal çözünürlük uzak alan ile yakın alan arasındaki sınır bölgesinde elde edilir.

Yükseklik çözünürlüğü gönderilen ses demetinin görüntüleme düzlemine dik olan iki farklı noktayı ayırt edebilme kabiliyetini ifade eder. Yükseklik çözünürlüğü evirgeçteki elemanların yüksekliğine bağlıdır.

Genellikle, UG'de çözünürlüğü artırmak amacıyla frekans artırılır fakat bu sefer de görüntüleme derinliği azalmaktadır. Görüntüleme derinliğinin yüksek frekanslarda azalmasının nedeni yüksek frekanslı ses dalgaların çok daha fazla zayıflama davranışı sergilemesinden kaynaklanmaktadır. Görüntüleme derinliği ve çözünürlük arasındaki ödünleşim UG'deki dikkate alınması gereken önemli hususlardan biridir. Görüntüleme yüzeyine yakın yerlerde daha yüksek frekanslı dalgalar ile çözünürlüğü yüksek görüntü edinimi amaçlanırken, derin bölgelerde görüntüleme yapmak için frekans seviyesi daha düşük değerlere çekilir. Frekans arttıkça çözünürlük artmakta fakat nüfuz etme derinliği azalmaktadır.

4.3. Ultrasonun Ortam ile Etkileşimi

Ultrason dalgaları ortamda ilerlerken çeşitli durumlara maruz kalmaktadır. Bu durumlar dalganın yayıldığı ortamı oluşturan maddenin akustik özelliklerine göre değişir. Ultrason dalgasının maruz kaldığı durumlar şunlardır [85]:

- Yansıma
- Kırılma
- Saçılma
- Zayıflama

Belirli bir ortama gönderilen yüksek ses dalgaları ortamda yayılırken, bir kısmı karşılaştığı engel veya iki farklı yüzey arasındaki hat gibi etmenler nedeniyle geriye doğru yansıyabilir. İki farklı yüzeyin farklı akustik dirençlere sahip olmaları nedeniyle yayılım doğrultusundaki

açısını değiştirebilir, karşılaşılan engel nedeniyle çok farklı yönlerde saçılmaya maruz kalabilir veya daha zayıf hale gelmiş ses dalgası olarak yoluna devam edebilir.

Akustik direnç

Uluslararası standartlar (SI) birimlerine göre akustik direnç rayl adı verilen bir birim ile ölçülür.

$$Z = \rho c \quad (4.3)$$

Eş. 4.3’de ρ , maddenin yoğunluğunu verir ve birimi kg/m^3 şeklinde verilirken, c ise hızı ifade eder ve birimi m/s cinsinden verilir. Şu durumda 1 rayl değeri $1 \text{ kg}/(\text{m}^2\text{s})$ değerine denk gelir.

Akustik direnç değeri ses dalgasının yayılmakta olduğu sıkıştırılabilirlik özelliğine sahip ortamı oluşturan maddenin sertliğine ve esnekliğine bağlıdır. Ses dalgasının ilerlemekte olduğu birbirine bitişik olan iki ortam maddesinin sertlik değerlerindeki farkın yüksek olması yüksek yansımaya sebep olurken; düşük sertlik değeri farkı ise yansımanın az olması anlamına gelmektedir. Bu sebeple, örneğin akciğer organı içerisinde hava oluşu ve hava ile doku arasındaki akustik direnç farkının yüksek oluşu nedeniyle gönderilen ultrason dalgasının neredeyse tamamı geri yansır. Böylece, hava-doku sınırının ötesine çok az bir kısım oldukça zayıflamış olarak geçerler. Bunun doğal bir sonucu olarak da daha derin bölgelerden ultrason görüntüsünün edinilmesi güçleşir. Aynı veya birbirine oldukça yakın akustik dirençli iki ortam arasındaki sınırda neredeyse hiçbir yansımaya maruz kalmadan kolayca ilerler. Bu sayede daha derin bölgelere nüfuz etmeleri kolaylaşır.

Farklı doku ve organlara ait olan akustik empedans değerleri Çizelge 4.3’de verilmiştir. Akustik direnç değerinin yüksek oluşu ortamın ses dalgasını oldukça iyi iletebildiğine dair bir ölçüttür. Havanın akustik empedansı oldukça düşük olduğundan, ses dalgaları diğer ortamlara göre daha yavaş hızlarla iletilir. Yoğunluğu yüksek olan ortamların akustik direnç değerleri de yüksek olmaktadır.

Çizelge 4.3. Farklı dokuların akustik dirençleri

Organ / Madde	Direnç (rayl)
Hava	0,0004 x10 ⁶
Akciğer	0,18 x10 ⁶
Yağ	1,34 x10 ⁶
Su	1,48 x10 ⁶
Böbrek	1,63 x10 ⁶
Kan	1,65 x10 ⁶
Karaciğer	1,65 x10 ⁶
Kas	1,71 x10 ⁶
Kemik	7,8 x10 ⁶

4.3.1. Yansıma

Birbirine komşu iki farklı ortamı (doku veya organ vb.) oluşturan maddelerin akustik dirençlerinin farklı olması gönderilen ultrason enerjisinin bir kısmının iki maddenin akustik dirençlerine bağlı olarak enerjinin gönderim yönünün aksi istikametinde yansımaya sebep olur. Yansıma katsayısı (R_I) gönderilen ses dalgasının ne kadarının yansıdığını belirten bir değerdir ve Eş. 4.4'deki gibi tanımlanır [85].

$$R_I = \frac{I_r}{I_i} = \left(\frac{Z_2 - Z_1}{Z_2 + Z_1} \right)^2 \quad (4.4)$$

Eşitlikte verilen 1 ve 2 alt simgeleri iki dokunun sınırına ait yakın (proximal) ve uzak (distal) değerlerini ifade etmektedir. Enerjinin korunumu kanununa bağlı olarak, yoğunluk iletim katsayısı (T_I), iki dokunun sınırından öteye geçebilen ultrason enerjisini temsil eder ve $T_I = 1 - R_I$ şeklindeki eşitlik ile ifade edilir.

Akciğer içerisinde hava barındırdığından, doku ve hava arasındaki sınır hattında akustik direnç farkı oldukça yüksek olacağından, ultrason demetinin ilerlemesi mümkün olamamaktadır. Bununla birlikte, akciğer gibi bazı organlar ultrason demetinin geçmesine imkan verecek kadar çok küçük doku bölgelerine sahip olur. Bu tür bölgelere “akustik pencere” adı verilir.

Gönderilen ultrason demeti geçmekte olduğu iki farklı ortamın sınırına dik olarak varırsa geriye yankı olarak yansır. Düşük akustik direnç bölgesinden yüksek akustik direnç bölgesine geçmeye çalışırken 180 derecelik faz kaymasına maruz kalır. Ultrason demetinin yüzeye dik olarak gelmemesi durumunda, gelen açının dokuların sınır hattına değme açısına bağlı olarak belirli bir açı doğrultusunda yansır.

İki farklı dokunun sınır yüzeyi ultrason dalgasının dalga boyuna göre göreceli olarak oldukça düzgün bir yapıda ise geri yansıma olayı yukarıda izah edildiği gibi gerçekleşir. Ultrason dalgasının dalga boyu küçüldükçe, yani frekans artırıldıkça, dalga boyuna göre sınır hattı bozuk bir satıh gibi davranır ve yansıma geriye doğru düzgün bir doğrultu yerine saçılım yaparak her yöne doğru yayılmaya başlar. Yansıyan dalgaların çok az bir bölümü (dalga boyuna bağlı olarak) ultrason demetini gönderen ve aynı zamanda yansımaları kayıt etmekte olan kaynak cihaza ulaşır.

4.3.2. Kırılma

Kırılma gönderilen ultrason demetinin iki farklı ortamın sınır hattına eğik açı ile çarpması neticesinde yönünü değiştirerek devam etmesi olayıdır. Sınır hattına çarpma açısı değişiminin yönünü ve sınır hattından sonra ultrason enerjisinin nasıl ilerleyeceğinin tespit edilmesini tayin eder [85]. Kırılma açısına dair formül Eş. 4.5’de verilmiştir.

$$\frac{\sin \theta_t}{\sin \theta_i} = \frac{c_2}{c_1} \quad (4.5)$$

Eşitlikteki (θ_t) parametresi kırılma açısını ifade etmektedir ve ultrason ses demetinin sınır hattında hızında meydana gelen değişim miktarı ile tayin edilir ve geliş açısı (θ_i) ile Snell kuralı aracılığı ile bağlıdır. Eşitlikteki (c_1) ve (c_2) parametreleri ultrason dalgasının ilgili iki ortamdaki ilerleme hızlarını vermektedir. Sinüs fonksiyonu davranışının bir sonucu olarak, küçük değerdeki yaklaşım ve kırılma açıları olması durumunda açıların birbirine oranı yaklaşık olarak iki ortamdaki hızların birbirine oranına denktir.

4.3.3. Saçılma

Akustik saçılma ultrason demetinin ilerlediği ortamın (doku veya organ) kendisini meydana getiren parçacıkların veya iki farklı ortam arasındaki sınırın boyutlarının ultrason dalgasının

dalga boyuna eşit veya daha küçük olması ile birlikte pürüzlü veya kaba olması nedeniyle, tıpkı bir ayna gibi üzerlerine gelen ultrason enerjisini düzgün biçimde geri yansıtamaması durumunda ortaya çıkar. Organların büyük çoğunluğu kendilerine has bir geri saçılma karakteristiği gösterir.

Pürüzlü ve kaba bir doku veya iki doku arasındaki sınır sathı üzerlerine gelen ultrason dalgalarını her yöne düzensiz bir şekilde dağıtırlar. Bu nedenle güçsüz bir yankı sinyali tüm görüntüleme ortamı üzerinden ultrason cihazına doğru oldukça düşük genlik (amplitude) değerine sahip olarak geri gider. Yankı sinyalinin oluşmasına neden olan doku bileşenleri ve parçacıklara saçıcı (scatterer) adı verilmektedir. Dokulardan geri yansıyan yankı sinyalinin genliği dokunun birim hacmindeki saçıcıların sayısına, saçıcıların boyutlarına, saçıcıların akustik dirençlerindeki farklara ve ultrason dalgasının frekansına bağlı olarak değişir [85]. Frekansın artması ayna gibi yansıtma yapamayan pürüzlü ve kaba yüzeylerde daha fazla saçılmanın meydana gelmesine sebep olur.

4.3.4. Zayıflama


İlerlemekte olan ultrason dalgası saçılma veya yayıldığı ortam (organ, doku vb.) tarafından soğurulması (absorption) gibi olaylar nedeniyle enerjisinin bir kısmını kaybeder ve zayıflamış bir sinyal olarak yoluna devam etmeye çalışır. Ortam tarafından soğurulması akustik dalga enerjisinin ısı enerjisine dönüşmesine sebebiyet verir.

Zayıflama ölçütü dB/cm cinsinden verilir ve yaklaşık olarak frekans ile orantılıdır. Genel kabul gören bir yaklaşım olarak 0,5 dB/cm zayıflamanın her bir mega hertz (MHz) frekans artışında meydana geleceği varsayılır [85]. Yarım değer kalınlık (YDK) değeri ultrason dalgasının yoğunluğunu yarı yarıya düşüren (ki bu, yoğunluğun 3 dB azalması anlamına gelir) doku kalınlığını ifade etmektedir. Yani, frekansın 6 MHz artırılması demek YDK değerinin yarı yarıya azalması anlamına gelir. YDK değerinin yarı yarıya azalması ultrason demetinin frekansı 6 MHz artırmadan önce 3 dB değerinde zayıflamasına neden olan kalınlığın (derinliğin) artık yarıya inmesi ve bunun neticesinde daha kısa mesafede ultrason demetinin enerjisini tüketmesi ve ilerleyen derinliklere gidecek enerjisinin azalması anlamına gelmektedir. Bu nedenledir ki frekans arttıkça ultrason görüntüleme derinliği azalmaktadır. 1 MHz'lik frekansı değerine sahip ultrason demeti yaklaşık 30 cm derinliğe

nüfuz edebilirken, bu değer 5 MHz frekans değerinde yaklaşık 6 cm ve 20 MHz için 1,5 cm'dir [86].

4.4. Ultrason Görüntüleme Modları

Ultrason görüntülemeye yansıyan sinyalin genliğinden faydalanarak elde edilen grafikler ilk başlarda A-mod görüntüleme olarak kullanılmıştır. Ardından, yeğinlik değerlerinin renk parlaklığına dayanan ve günümüzde en yaygın kullanılan görüntüleme modu B-mod, görüntüleme; C-mod görüntüleme ve sonrasında zaman bilgisinin de dahil edilmesiyle M-mod görüntülemeye faydalanılmıştır (Şekil 4.4). İlave olarak, özellikle akışkanlar için Doppler etkisinden yararlanarak geliştirilen Doppler görüntüleme; ses dalgasının harmonisinden yararlanan harmonik görüntüleme ve kontrast ajanları ile görüntüleme gibi yeni teknolojiler kullanılmaya başlanmıştır. Bu teknikler ilerleyen bölümlerde kısaca açıklanmıştır.



Şekil 4.4. Ultrasonda görüntüleme modları [85]

4.4.1. A-mod görüntüleme

Ultrason görüntüleme yönteminin ortaya çıktığı ilk dönemde A-modu görüntüleme yöntemi kullanılmaktaydı. A-mod görüntülemeye edinilen sinyal genlik (amplitude) değeri ile birlikte ekrana verilmekteydi. Yansıyan dalgaların genliği sinyali alan cihaza erişim süresi dikkate alınarak derinliğin bir fonksiyonu şeklinde gösterilir. Günümüzde A-mod yerine

B-mod görüntüleme yöntemi yaygın olarak kullanılmaktadır. A-mod görüntüleme tekniği günümüzde oftalmolojide göz mesafesinin hassas ölçümü amacıyla hâlâ kullanım alanı bulmaktadır.

4.4.2. B-mod görüntüleme

B-mod ultrason görüntüleme yöntemi günümüzde en yaygın kullanılan görüntüleme yöntemlerinden biridir. A-mod görüntülemenin elektronik dönüşüm ile parlaklık değerleri olarak gösterilmesidir. B-mod görüntülemeye, elde edilen ultrason sinyalleri zarf bulma (envelope detection), logaritmik sıkıştırma işlemlerinin ardından, sinyalin genlik değerlerinin şiddetine bağlı olarak gri tonda yeğnlik değerlerine dönüştürülür ve gri tonlu görüntü olarak ekranda gösterilir. Bu moda aynı zamanda parlaklık modu (brightness mode) da denilmektedir.

4.4.3. C-mod görüntüleme

C-mod görüntüleme tekniğinde sabit derinlikte iki boyutlu ultrason görüntülerinin elde edilmesi amaçlanır. Tarama eylemi ultrason dalgasının yayılma doğrultusu üzerinde sabit derinlikteki bir noktanın üzerinde olduğu ve dalganın yayılma doğrultusuna dik olan bir düzlem için yapılır. B-mod görüntülemenin aksine zaman bilgisi sadece düzlem üzerindeki saçıcı (scatterer) noktalardan gelen yansımaların tespitini sağlar. B-mod görüntülemeye zaman bilgisi görüntüdeki derinlik bilgisini sağlarken, C-mod görüntülemeye böyle bir bilgi sunulmamaktadır. Parlaklık değerleri B-mod görüntülemeye gibi elde edilen yankının genliğiyle orantılı olarak gösterilir.

4.4.4. M-mod görüntüleme

M-modu hareket modunu ifade eder. Hareketli organların zaman içerisindeki görüntülerini üretmek amacıyla kullanılmaktadır. Kalp kapakçığının davranışının dinamik olarak görüntülenmesi veya anne karnındaki ceninin hareketlerinin görüntülenmesi M-mod görüntülemeye bir örnektir. B-mod görüntülerinin bir video çerçevesi gibi art arda birleştirilmesi neticesinde zamana bağlı olarak süreklilik arz eden bir görüntü videoya benzer şekilde üretilmiş olur. Gösterilen grafik üzerinde yatay eksen zaman bilgisi, düşey eksen derinliğine dair bilgi verilir.

4.4.5. 3B ve 4B görüntüleme

Üç boyutlu (3B) görüntüleme dokunun düzlemsel kesit görüntüsünün edinilmesinden ziyade doku hacminden elde edilen yansıma bilgisini kullanarak görüntü elde edilmesini amaçlar. 3B görüntüleme yansıyan dalgaların edinimi, yansıma bilgisinden ilgili dokuya ait kaplama (render) yapılması ve görselleştirme aşamalarından meydana gelir. 3B görüntüleme yöntemine bir de zaman bilgisi eklendiğinde dört boyutlu (4B) görüntüleme elde edilmiş olur. 3B ultrason görüntüleme için özel tasarlanmış faz dizilimi dönüştürücüler (transducer) kullanılır. Anne karnındaki fetüs yüzünün betimlenmesi ve kalp içerisindeki yapılar ile damarların ve göz yüzeylelerinin incelenmesi 4B görüntülemeyle yapılan tipik uygulama alanlarıdır [87].

4.4.6. Doppler görüntüleme

Doppler görüntüleme kan akışının karakteristiğinin incelenmesi, fetüs kalbinin izlenmesi gibi amaçlar için kullanılmaktadır. Bir dönüştürücüden gönderildikten sonra geri yansıyan ses dalgaları genellikle yine aynı probun içerisinde bulunan başka bir dönüştürücü aracılığı ile toplanır. Yansıyan dalgaların toplanmasının ardından frekanstaki sapma ve akış hızı gibi özellikler hesaplanır. [87].

Hareketli bir cisimden yansıyan ultrason dalgalarının frekansında cismin hareketinden kaynaklanan bir kayma meydana gelir. Frekanstaki kayma cismin hareket hızına, yönüne ve probun konumundaki değişime bağlı olarak değişir. Frekanstaki bu kaymaya doppler kayması denir ve Eş. 4.6’da verildiği gibi tanımlanır.

$$\nabla f = \pm \frac{2fV \cos \theta}{c} \quad (4.6)$$

Eşitlikteki f , ultrason dalgasının frekansını; V parametresi kanın ilerleme hızını; θ , ultrason dalgasının yayılım yönü ile kanın akış yönü arasındaki açıyı ve c ise ultrason dalgasının ilerleme hızını vermektedir.

Doppler görüntülemede yansıyan sinyalin gücüne bağlı olarak renk ataması yapılarak renkli bir gösterim elde edilir. Kullanılan renkler ortalama frekans kaymasını gösteriyorsa renkli

akış haritalaması olarak; sinyalin ortalama gücünü temsil ediyorsa güç doppleri görüntülemesi olarak isimlendirilir.

4.4.7. Kontrast ajanları ile görüntüleme

Kontrast ajanları içerisinde hava, nitrojen veya çözünmeyen bir gaz olan perfluorokarbon içeren, 3 ile 5 mikrometre (μm) büyüklüğündeki mikro gaz (microbubble) kapsülleri vasıtası ile damar ve perfüzyonların görüntülenmesi için kullanılan maddelerdir. Kapsüller insan albüminlerinden meydana getirilir ve içlerinde bahsi geçen gazları enjekte edildikten sonra belirli bir süre istikrarlı (stable) şekilde saklayabilen yapıdadır. Enjeksiyon ile saniyeler içerisinde kan dolaşımına karışırlar.

Kontrast ajanları ile görüntülemenin temelinde gaz kapsüllerinin içerisinde gaz bulunması nedeniyle gaz ile sıvı ve dokular arasında yüksek direnç göstermelerine dayanır. Gaz kapsülleri ultrason dalgasının dalga boyundan oldukça küçük oldukları için damar içerisinde saçılma kaynağı olarak işlev yaparlar. Ultrason dalgalarının saçılmasını sağlayan bu noktalar ultrason hüzmesinin her yöne yansımaları sağlar. Ayrıca, gaz kapsüllerinin sıkıştırılabilirlik özelliği yansıyan ses dalgalarının frekanslarında kaymalara neden olarak ana ultrason demetinin frekansından daha yüksek frekanslarda geri dönen ses dalgalarını meydana getirir. Frekansı artmış olan bu geri yansıyan ses dalgalarına harmoni adı verilmektedir. B-mod görüntülemeye temel farkı gaz kapsüllerinin doğrusal olmayan sıkıştırılabilirlik özelliğine sahip olması ve meydana gelen frekans harmonilerine dayanmaktadır [85].

4.4.8. Harmoni görüntüleme

Harmoni frekansları ana ultrason demetinin yayılma ortamı ile etkileşime girmesiyle birlikte ana frekansı (f_0)'nın, $(2f_0)$, $(3f_0)$, $(4f_0)$ vb. katları şeklinde harmonilerden meydana gelir. Bahsedilen yüksek frekanslar kontrast ajanları olarak kullanılan gaz kapsüllerinin titreşimleri sonucunda ortaya çıkar. Titreşen gaz kapsülleri yüksek mertebeden harmonilerin oluşmasını sağlar. Harmoni görüntüleme daha düşük değerli frekansların kullanılmasına ve çoklu frekans evirgeci kullanılması ile kontrast ajanları ile görüntüleme'den daha iyi görüntü oluşturulmasını sağlar. Harmoni frekanslarına sahip yankı sinyallerinin ana frekans sinyaline karışması önlenerek (echo clutter) yakın bölgelerde daha başarılı görüntülerin oluşturulmasına imkân sağlar. Geri dönen harmoni sinyalleri daha yüksek zayıflamaya

maruz kalsa bile ana ultrason drtsnn yarısı kadar bir mesafeyi kat etmesi gerekeceğinden, daha byk bir sinyal olarak elde edilir. Bu amala daha uzun sreli drt sinyalleri kullanılır.




5. DERİN ÖĞRENME İLE B-MOD ULTRASON GÖRÜNTÜLERİNDE SÜPER ÇÖZÜNÜRLÜK

Bu bölümde nihai B-mod görüntü formatına getirilmiş olan ultrason verileri üzerinde derin öğrenme (DÖ) algoritmaları vasıtası ile süper çözünürlük (SÇ) yapılarak çözünürlük artırılmıştır.

5.1. Yöntem

Ultrason görüntüleme (UG) esas olarak iki ana safha olan ön işleme ve ardıl işleme safhalarından meydana gelmektedir (Şekil 5.1). Geleneksel SÇ çalışmaları ön işleme safhasında gönderilen ve alınan sesin fiziksel özelliklerine ve kullanılan cihazın bazı bileşenlerine odaklanırken; ardıl işleme safhasının özellikle ilk aşamalarında RF sinyali formatındaki ultrason verisine odaklanır. Bu tez çalışmasında, geleneksel yöntemlerden farklı olarak, ardıl işleme safhasının ve hatta UG sürecinin en son işlemi sonunda elde edilen B-mod ultrason görüntüleri üzerinde SÇ elde edilmeye çalışılmıştır.



Şekil 5.1. Ultrasonda görüntülemenin aşamaları ve SÇ'nin elde edildiği safha

SÇ'nin elde edilmesinde DÖ algoritmalarından yararlanılmıştır. Çalışma kapsamında değişik derin ağ mimarileri ile çalışılmış ve en başarılı sonucu verecek olan derin ağ modeli optimize edilerek başarımı en üst seviyeye çıkarılmıştır. Tasarlanan derin ağa DECUSR (deep super resolution for ultrasound super resolution) adı verilmiştir. DECUSR ağının eğitilmesinde danışmanlı öğrenme (supervised learning) yaklaşımı uygulanmıştır. Bu bağlamda, yaklaşık 28 bin adet örnek ultrason görüntüsünden oluşan bir eğitim seti kullanılmıştır. Eğitim setinden alınan her bir imgeye ait düşük çözünürlüklü (DÇ) ve yüksek çözünürlüklü (YÇ) imgeler ağa eğitim esnasında verilerek, ağın DÇ görüntüden YÇ görüntüyü vermesini sağlayacak doğrusal olmayan fonksiyonel ilişkiyi öğrenmesi

sağlanmıştır. Çalışmada 4 farklı büyültme ölçeği (2, 3, 4 ve 8 kat büyültme) için SÇ elde etmek üzere dört farklı derin ağ modeli elde edilmiştir.

Çalışmada kullanılan yazılımın geliştirilmesinde açık kaynak bir dil olan Python dili kullanılmıştır. DÖ modellerinin oluşturulmasında Keras [88] programlama çerçevesi kullanılmıştır. Keras kütüphanesi kullanılarak tasarlanan derin ağlar arka planda Keras tarafından Tensorflow [89] kütüphanesine dönüştürülmüş ve Tensorflow aracılığı ile GPU'lar üzerinde koşturulmuştur.

İlerleyen bölümlerde çalışmanın detayları ve sonuçları etraflıca verilmiştir.

5.2. Derin Ağ

Bir konvolüsyonel sinir ağı (KSA) belirli bir aktivasyon fonksiyonu ve $\Theta = \{\mathcal{W}, \mathcal{B}\}$ gibi parametrelere sahip konvolüsyon katmanlarından meydana gelir. Burada $\mathcal{W}$ konvolüsyon filtrelerinin (filter) bir kümesini temsil eder. Filtreler aynı zamanda çekirdek (kernel) diye de adlandırılır. $\mathcal{B}$ ise her katmandaki bias değerini temsil eder. Giriş imgesi her bir katmanda K adet ($\mathcal{W} = \{W_1, W_2, \dots, W_K\}$) filtre/çekirdek tarafından konvolüsyon işlemine tabi tutulur ve işlem sonucunda o katmana ait bias ($\mathcal{B} = \{b_1, b_2, \dots, b_K\}$) değeri eklenir. Her katmanda gerçekleştirilen konvolüsyon işlemi yeni bir nitelik/özellik haritasını (x_k) üretir. Ardından, bu nitelikler eleman elemana doğrusal olmayan (non-linear) dönüşüm yapan bir aktivasyon fonksiyonuna verilir. Bir katmanın çıktısı $\sigma(W * x + b)$ şeklinde yazılabilir. Eşitlikteki “*” ve σ sembolleri sırasıyla konvolüsyon ve aktivasyon işlemlerini ifade eder. Bahsedilen çıktı işlemi her bir katmanda tekrar eder. Bir l katmanındaki çıktı Eş. 5.2’de verildiği gibi hesaplanır [90]:

$$x_k^l = \sigma(W_k^{l-1} * x^{l-1} + b_k^{l-1}) \quad (5.2)$$

Sonuç olarak, L adet katmandan oluşan bir KSA ağı şöyle formüleleştirilebilir:

$$f(x; \Theta) = \sigma(W^L * \sigma(W^{L-1} \dots \sigma(W^0 * x + b^0) + b^{L-1}) + b^L) \quad (5.3)$$

Eş. 5.3’de, W^n , n katmandaki K adet filtreyi ifade eder.

Deneyde kullanılan KSA bir DÇ x imgesini $\hat{y} = f(x; \theta)$ şeklinde gösterilen ve bilinen bir referans (ground-truth) imgesi olan y 'ye en iyi şekilde benzeyen tahmini bir YÇ imgeye dönüştürmeye çalışır. Bu maksatla örneklerden öğrenme yaklaşımı ile ağ kendisine verilen DÇ x imgesi ile $\hat{y}$ imgesi arasında doğrusal olmayan eşleşmeyi öğrenmeye çalışır. Ağı eğitilmesi için $D\{x^{(i)}, y^{(i)}\}_{i=1}^N$ şeklinde bir eğitim setinden yararlanır.

Eğitim boyunca, ağı hatasının ölçülmesi için Eş. 5.4'deki gibi bir hata (loss) fonksiyondan yararlanır.

$$\mathcal{L}(y, \hat{y}; \theta) = \frac{1}{N} \sum_{i=1}^N \|y_i - f(x_i; \theta)\|^2 \quad (5.4)$$

Burada, N eğitim görüntüsü miktarını temsil eder. Eş. 5.4'de verilen hesaplama esasen ortalama karesel hata (MSE) olarak adlandırılır ve farklı en ve boy oranına sahip imgeler için şöyle verilir:

$$MSE = \frac{1}{PR} \sum_{i=1}^P \sum_{j=1}^R \|y(i, j) - \hat{y}(i, j)\|^2 \quad (5.5)$$

Eş. 5.5'deki P ve R imgenin iki yöndeki piksel adedini ifade etmektedir. Eşitlikten anlaşılacağı üzere MSE, iki görüntü arasındaki piksel farklarını hesaplar. Optimizasyon işlemindeki amaç, $\hat{y}$ ve y arasındaki farklılığın minimize edilmesidir. Bu bağlamda, derin ağdan beklenen şey, giriş görüntüsü x 'i alarak referans görüntü y 'yi mümkün olduğunca en iyi şekilde üretmesidir.

Optimizasyon işlemine bir cezalandırma terimi de ekleyerek, amaç (objective) fonksiyonu denilen ve Eş. 5.6.'da verilen fonksiyon elde edilir.

$$\mathcal{J}(\theta) = \frac{1}{N} \sum_i \mathcal{L}(x^i) + \lambda r(\theta) \quad (5.6)$$

Burada, r cezalandırma terimi, $\lambda > 0$ ağırlık ve $\mathcal{L}$ ise Eş. 5.4.'de verilen hata fonksiyonudur. Böylece, optimizasyon problemi $\mathcal{J}$ amaç fonksiyonunun minimize edilmesine dönüşür. Diğer bir deyişle, eğitimin amacı $\mathcal{J}$ amaç (maliyet adı da verilir) fonksiyonunu minimize eden $\theta = \{\mathcal{W}, \mathcal{B}\}$ ağ parametrelerini bulmaktır. Bu tür bir problemin çözümünde eğimli iniş (gradient descent) algoritması kullanılabilir.

Eğitim için kullanılan eğitim seti D , hesaplama açısından oldukça büyük olduğu için ufak grup (mini batch) eğitim yöntemi kullanılmıştır. Ufak grup yönteminde Eş. 5.7’de verildiği gibi, her seferinde ağa $M \ll N$ adet örnek görüntü (bu çalışmada 128 adet kullanılmıştır) D setinden alınarak ağ eğitilir.

$$\mathcal{J}(\Theta) = \frac{1}{N} \sum_i^N \mathcal{L}(\mathbf{x}^i) + \lambda r(\Theta) \quad (5.7)$$

M adet imge için eğitim yapıldıktan sonra $\mathcal{L}$ ve $\mathcal{L}$ ’nin eğimi/gradyanı (gradient) $\nabla \mathcal{L}$ değeri hesaplanır. Ardından, geri yayılım (back propagation) aşamasında ağ parametrelerinin eğimleri $\nabla(\mathcal{W}, \mathcal{B})$, $\nabla \mathcal{L}$ ve cezalandırıcı terimin eğimi ∇r aracılığıyla bulunur. Bulunan parametre eğimleri ağ parametrelerinin $\Theta = \{\mathcal{W}, \mathcal{B}\}$ güncellenmesi için kullanılır. Ağ parametrelerinin güncellenme yöntemi birinci dereceden eğimli iniş tabanlı bir optimizasyon yöntemi olan ADAM [91] kullanılmıştır.

5.2.1. Derin ağın yapısı


Çalışmada kullanılan DECUSR ağı, nitelik çıkarma bloku (NÇB), yineleme blokları (YB) ve büyültme (upsampling) katmanlarından meydana gelmektedir. Ağın tamamında, konvolüsyon (convolution), büyültme ve birleştirme (concatenation) olmak üzere üç değişik katman tipi mevcuttur. Her bir konvolüsyon katmanı sadece bir adet 1x1 boyutlu filtreye sahip olan son katman haricinde, 16 filtreye sahiptir. Bir KSA katmanı için aktivasyon fonksiyonu olarak doğrultulmuş doğrusal birim (ReLU) kullanıldığında, Eş. 5.2 yeniden şöyle yazılabilir (Eş. 5.8):

$$x_k^l = ReLU(W_k^{l-1} * x^{l-1} + b_k^{l-1}) \quad (5.8)$$

Burada, ağdaki son katman için $k=1$ iken, diğer konvolüsyon katmanları için $k=16$ ’dır.

SÇ probleminde, giriş görüntüsünün bir derin ağ tarafından büyütülmesi durumunda genellikle bir adet büyültme katmanı ağın yapısına dâhil edilir. Diğer durumlarda, giriş görüntüsü bir enterpolasyon yöntemi ile (örneğin çift kübik enterpolasyon) ağa verilmeden önce istenilen ölçekte büyütülür. Ardından büyütülmüş olan görüntü ağa giriş görüntüsü olarak verilir. Dolayısı ile bu tür ağlarda büyültme katmanı bulunmaz. Giriş görüntüsü hâlihazırda istenilen ölçekte büyütülmüştür.

Ağın giriş görüntüsünü kendisinin büyütmesi durumunda, giriş görüntüsünün, ağın bölümünde veya diğer bir deyişle hangi işlem safhasında büyültme işlemine tutulacağı önemli bir konudur. Örneğin, giriş imgesi ağa verilir verilmez, üzerinde bir işlem yapılmadan, ilk katmanda mı? Yoksa bir tür özellik çıkarım işleminin ardından mı? Her iki durumda da belirli miktarda bilgi kaybı olacağı düşünüldüğünden (ki bu durum daha sonra ilerleyen bölümlerde irdelenecektir) iki adet büyültme katmanına sahip bir ağ modeli oluşturulmuştur. Bu katmanlardan biri doğrudan büyültme katmanı L_{DBK} , diğer ise NÇB'den sonra büyültme yapan L_{NBK} katmanıdır. Yapılan deneylerde, her iki katmanın da ağın performansına olumlu katkı sağladığı görülmüştür. Dört adet YB'ye sahip ve en iyi performansı sunan DECUSR derin ağ modeli Şekil 5.2'de verilmiştir.



Şekil 5.2. Dört YB'li DECUSR modeline ait detaylar [90]

DECUSR ağında, daha evvel DenseNet modelinde kullanılmış olan yoğun bağlantılı katman mimarisi [28] geliştirilerek yoğun bağlantılı YB mimarisi şeklinde bu kullanılmıştır. Her bir YB'nin ilk katmanı bir birleşme (L_{BK}) katmanıdır. Bu katmanı ardışık üç adet konvolüsyon katmanı izlemektedir. İlk iki katman 16 adet 3x3 boyutlu filtreden oluşurken, sonuncusu 16 adet 1x1 boyutlu filtreye sahiptir. Her bir L_{BK} , sırasıyla L_{DBK} , L_{NBK} ve kendinden önceki her bir YB'nin çıktısını birleştirir. Birleşme katmanlarında bir araya getirilen bilgiler ağın DÇ görüntü ile YÇ görüntü arasındaki doğrusal olmayan dönüşüm

öğrenmesine son derece önemli katkı sağlamaktadır. Ayrıca, ağı daha sağlam (robust) olması ve çok daha hızlı öğrenmesini sağlamaktadır. YB mekanizması sonraki bölümde detaylı izah edilmiştir.

Yineleme blokları ve birleştirme katmanları

Sırasıyla, $\mathcal{X}_\ell$ and $\mathcal{T}_\ell \in \mathbb{R}^{w \times h \times k}$ bir ağıdaki ℓ nci katmanın çıktısı ve özellik haritası olsun. w , h , ve $k \in \mathbb{Z}^+$ ve sırasıyla katmanın genişlik, yükseklik ve derinliğini temsil etsin. Sıradan bir KSA katmanı doğrusal olmayan bir $\mathcal{F}(\cdot)$ dönüşümü gerçekleştirir. Tipik bir KSA ℓ nci katmanın çıktısını $(\ell+1)$ nci katmanın girdisi olarak ele alır. Bu bağlamda ℓ nci katmanın çıktısı $\mathcal{X}_\ell = \mathcal{F}_\ell(\mathcal{X}_{\ell-1})$ şeklinde tanımlanır. Geleneksel KSA katmanlarından farklı olarak, bir birleşme katmanı kendisine verilen tüm girdileri veriliş sırasına göre yığarak, tek bir tensör (çok boyutlu dizi) halinde çıktı olarak verir. n adet özellik haritası için, bir birleşme katmanının çıktısı $\mathcal{X}_{BK} = \mathcal{F}_{BK}(\mathcal{T}_1^{w \times h \times k_1}, \mathcal{T}_2^{w \times h \times k_2}, \dots, \mathcal{T}_n^{w \times h \times k_n})$ şeklinde olur. Çıktı $\mathcal{X}_{BK}$, $\mathcal{T}^{w \times h \times (k_1+k_2+\dots+k_n)}$ şeklinde bir tensördür. Her bir birleşme katmanı L_{BK} , sırasıyla L_{DBK} , L_{NBK} ve kendinden önceki her bir YB'nin çıktısını birleştirir. Böylece k nci YB^k, L_{DBK} ve L_{NBK} katmanları ve $YB^1, \dots, YB^{k-1}$ ile bağlantılı olur. DECUSR başlangıç olarak 3 adet YB ile tasarlanmıştır ve en optimum YB adedi deneysel olarak araştırılmıştır. Çalışmalar neticesinde 4 adet YB'ye sahip DECUSR modelinin en iyi performansı sağladığı sonucuna varılmıştır. Detaylar ilerleyen bölümlerde verilmiştir.

Bileşenlerin incelenmesi

Ağıda bulunması gereken YB'lerin adedini araştırmadan önce ağı temel bileşenlerinin ağı performansına katkı yapıp yapmadığı; katkı sağlıyorsa ne derecede olduğunu bulmak adına temel model olan 3 YB'li DECUSR modeli her bir ana bileşenin (NÇB, L_{DBK} , ve L_{BK}) varlığı ve/veya yokluğu ile 2 kat büyültme yapmak üzere eğitilmiştir. Sonuçlar Çizelge 5.1'de verilmiştir.

Çizelge 5.1. Temel modelin (3 YB'li) bileşenlerinin performansa katkısı

Birleşme katmanı (L_{BK})	✓	✓	✗	✓
Nitelik çıkarma bloku (NÇB)	✓	✗	✓	✓
Doğrudan büyültme katmanı (L_{DBK})	✗	✗	✗	✓
PSNR (dB)	43,8772	43,8147	43,5736	43,9777


Çizelge, her senaryoda TestSeti-I'den elde edilen PSNR skorlarını vermektedir. Sonuçlara göre, L_{DBK} az da olsa (0,1 dB) ağın performansını artırmaktadır. L_{BK} ve L_{DBK} 'nin yokluğunda PSNR skoru 43,5736 (dB) iken, sadece L_{DBK} 'nin yokluğunda 43,8772 olmaktadır. Bu sonuç birleşme katmanlarının (L_{DBK}) ağın performansına kayda değer miktarda (0,3036 db PSNR) katkı yapmaktadır. Benzeri şekilde, NÇB'nin yokluğunda PSNR skoru 43,8147 (dB) olmaktadır. Yani, ağın performansında 0,0625 dB PSNR skoru kadar bir iyileşme sağlamaktadır. Bu sonuçlar ışığında her bir ana unsurun az veya çok ağın performansını iyileştirdiği açıkça görülmektedir. Bu nedenle, tüm ana bileşenler DECUSR modeline entegre edilmiştir [90].

Ayrıca, her senaryoya ait eğitim grafikleri Şekil 5.3'de verilmiştir. Temel modelin NÇB, L_{DBK} , ve L_{BK} 'nin yokluğu durumunda gösterdiği performans sırasıyla turuncu, yeşil ve kırmızı rankle gösterilmiştir. Mavi renk tüm bileşenlerin varlığı durumunda temel modelin gösterdiği performansı ifade etmektedir. Tüm bileşenlerin varlığında eğitim hatası minimum olmaktadır. Şekilden (Şekil 5.3) kolayca anlaşılabacağı üzere, tüm bileşenlerin varlığı ağın performansına olumlu katkı sağlamaktadır.

Yineleme bloklarının sayısı


Derin ağı ana unsurlarının performansa yaptıkları katkının incelenmesinin ardından, kaç adet YB'nin ağda olması gerektiğini tayin etmek adına, temel model (3 YB'li) ile başlanıp mevcut YB'lerin kaldırılması ve yeni YB'lerin eklenmesi ile ağ yeniden eğitilmiş ve gösterdiği performans her bir ekleme veya çıkarma işleminin ardından ölçülmüştür. Birbirini izleyen iki YB ekleme işleminde ağın performansında bir iyileşme olmaması durma kriteri olarak belirlenmiştir. 5. Ve 6. YB'lerin eklenmesi 4 YB'li modelden daha başarılı sonuç sunmadığı için 6 YB'den daha fazla YB ekleme yapılmamıştır. Böylece, her biri 1'den 6'ya kadar adette YB'ye sahip toplamda 6 farklı model elde edilmiştir. Her bir modelin eğitim

grafiği ve Test-Seti I'den elde ettiği ortalama PSNR skorları sırasıyla Şekil 5.4'de ve Şekil 5.5'de verilmiştir. Hata grafiği (Şekil 5.4) incelendiğinde hata değerini en küçükleyen eğitim performansı 4 YB'li DECUSR ağından elde edilmiştir. Diğer taraftan, YB adedinin 4 olması durumunda ağ çok hızlı bir biçimde yakınsama sağlamakta ve başarısını eğitim boyunca stabil bir biçimde korumaktadır. 5 adet YB olması durumunda ağ benzeri bir eğitim grafiği sergilemekle beraber, 4 YB'li modelden çok az bir miktarda düşük performans vermektedir. 6 adet YB'li modelin performansı daha da kötüleşmektedir [90].




Şekil 5.3. Temel modelin (3 YB'li) ana bileşenlerinin varlığı/yokluğundaki eğitim grafiği

TestSeti-I üzerinden elde edilen PSNR skorları (Şekil 5.5) incelendiğinde, 4 YB'li DECUSR modeli diğer modellere nazaran daha yüksek değerlere sahip olduğu ve neredeyse her bir devir sonunda da yaklaşık benzer yüksek PSNR değerleri elde ettiği görülmektedir. Eğitim grafiğinde (Şekil 5.4) de olduğu gibi, 5 YB'li model de benzeri yüksek PSNR skorları elde etmesine rağmen, 4 YB'li DECUSR modelinden çok az bir miktar daha düşük değerler elde etmiştir. 6 YB'li model ise daha düşük puanlar elde etmiştir. Her iki grafikten de açıkça görüldüğü üzere, YB adedinin 3'den az olması ağın performansını ciddi oranda düşürmektedir. Tüm bu sonuçların ışığında, en iyi eğitim grafiği ve performansı sunması nedeniyle, ağda 4 adet YB kullanılmasına karar verilmiştir.



Şekil 5.4. DECUSR ağının YB adedine bağlı olarak gösterdiği eğitim performansları



Şekil 5.5. DECUSR ağının YB adedine bağlı olarak TestSeti-I'de gösterdiği performanslar

Nihai model olan, 4 adet YB'ye sahip DECUSR modeli toplamda 39265 adet parametre değerine sahiptir ve toplamda 23 katmandan oluşmaktadır. Ağın katmanlarına ait detaylar Çizelge 5.2'de verilmiştir.


Çizelge 5.2. DECUSR (4 YB'li) modelinin katman detayları

Katman	Çıktı Şekli sx(wxh)xÖzellik Sayısı	Parametre Sayısı	Bağlı olduğu katman
Giriş katmanı	(wxh)x1	0	
Conv2D_01	(wxh)x16	160	Giriş katmanı
Conv2D_02	(wxh)x16	2320	Conv2D_01
Conv2D_03	(wxh)x16	2320	Conv2D_02
Conv2D_04	(wxh)x16	272	Conv2D_03
L _{FUP}	s(wxh)x16	0	Conv2D_04
L _{DUP}	s(wxh)x1	0	Giriş katmanı
L _{CONCAT_1}	s(wxh)x17	0	L _{FUP} , L _{DUP}
Conv2D_05	s(wxh)x16	2464	L _{CONCAT_1}
Conv2D_06	s(wxh)x16	2320	Conv2D_05
Conv2D_07	s(wxh)x16	272	Conv2D_06
L _{CONCAT_2}	s(wxh)x33	0	L _{FUP} , L _{DUP} , Conv2D_07
Conv2D_08	s(wxh)x16	4768	L _{CONCAT_2}
Conv2D_09	s(wxh)x16	2320	Conv2D_08
Conv2D_10	s(wxh)x16	272	Conv2D_09
L _{CONCAT_3}	s(wxh)x49	0	L _{FUP} , L _{DUP} , Conv2D_07, Conv2D_10
Conv2D_11	s(wxh)x16	7072	L _{CONCAT_3}
Conv2D_12	s(wxh)x16	2320	Conv2D_11
Conv2D_13	s(wxh)x16	272	Conv2D_12
L _{CONCAT_4}	s(wxh)x65	0	L _{FUP} , L _{DUP} , Conv2D_07, Conv2D_10, Conv2D_13
Conv2D_14	s(wxh)x16	9376	L _{CONCAT_4}
Conv2D_15	s(wxh)x16	2320	Conv2D_14
Conv2D_16	s(wxh)x16	272	Conv2D_15
Conv2D_17	s(wxh)x1	145	Conv2D_16
	Toplam	39.265	

Kısaltmalar: Conv2D, 2 boyutlu konvolüsyon katmanı; L_{NBK}, nitelik büyütme katmanı; L_{DBK}, doğrudan büyütme katmanı; L_{BK}, birleşme katmanı layer; s, ölçek; w, genişlik; h, yükseklik [90].

5.3. Veri Seti ve Eğitim

Veri setlerinin oluşturulması için iki farklı web sitesinden yararlanılmıştır. İlk sitedeki [92] ultrason görüntüleri eğitim, doğrulama (validation) ve TestSeti-I'in oluşturulması için kullanılmıştır. Yazılan özel bir web gezgini programı vasıtası ile, web sitesindeki 36149 adet ultrason görüntüsü otomatik olarak indirilmiştir. Üzerinde karalamalar, işaretlemeler ya da görüntüleme cihazının yazdırdığı çeşitli yazı ve işaretlemeler barındıran görüntüler atılarak geriye toplamda 29696 adet görüntü kalmıştır. Doğrulama seti ve TestSeti-I, bu görüntülerden rastgele ve yerine koymamak şartıyla seçilen 1000'er adet görüntüden oluşturulmuştur. Eğitim testi için geriye 27696 görüntü kalmıştır. DECUSR ağıının eğitilmesinde sadece bu eğitim seti kullanılmıştır. Eğitimin gerçekleştirilmesine dair kavramsal şema Şekil 5.6'de verilmiştir.



Şekil 5.6. DECUSR ağı ile eğitime dair kavramsal şema

Eğitim setinden rastgele sırada alınan her bir B-mod ultrason görüntüsünden büyültme ölçeğine göre belirlenmiş boyutta (örneğin 2 kat büyültme için 16x16 piksel) görüntü parçaları rastgele olarak görüntü üzerinden alınarak DÇ görüntü çift kübik enterpolasyon (ÇKE) yöntemiyle ölçek değeri kadar küçültülmüş ve aktif görüntü parçası YÇ görüntü olarak kabul edilerek, ağı DÇ ve YÇ imgeleri verilmiş ve ağı DÇ'den YÇ'ye dönüşüm fonksiyonunu öğrenmesine istenmiştir. Bu süreç eğitim setindeki tüm görüntüler için devam etmiştir.

İkinci web sitesindeki [93] görüntüler ise sadece TestSeti-II'nin oluşturulması için kullanılmıştır. İlkine benzer bir metotla web sitesinden yaklaşık 2500 civarı görüntü

indirilmiş ve kullanılabilecek durumda olmayanlar ayıklandıktan sonra geriye kalanlar içerisinde rastgele ve yerine koymamak şartıyla 500 adet görüntü TestSeti-II'nin oluşturulmasında kullanılmıştır. Görüntülerin kenarlarında bulunan çeşitli damgalamalar, işaretlemeler ve özellikle gereksiz siyah alanların atılması için görüntülerin kenarları görüntü boyutu 600x450 piksel olacak şekilde kırpılmıştır.

Derin ağın programlanması Keras DÖ çerçevesi (framework) ile yapılmıştır. Tüm konvolüsyon katmanlarının başlangıç değerleri Glorot tekdüze (uniform) dağılım şeklinde verilmiştir. Aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Dolgu (padding) değeri “same” verilerek çıktı görüntüsünün bazı diğer modellerde olduğu gibi kenarlar kırpılmadan, tam boyutlu imge olarak çıkması sağlanmıştır.

Eğitim esnasında ağa verilen her bir görüntü ÇKE ile ölçek kadar küçültüldükten (downscaling) sonra 255 değerine bölünmüştür. Giriş imgelerinin boyutları ölçeğin tam katı olacak şekilde kenarları kırpılmıştır. Derin ağ her bir ölçek için NVIDIA GeForce RTX 2080Ti GPU üzerinde maksimum 10 devir (epoch) için eğitilmiştir. Yığın sayısı (batch) 128, öğrenme katsayısı 1×10^{-3} , en küçük öğrenme katsayısı 1×10^{-7} , erken durdurma (early stopping patience) devir sayısı 5 ve ağırlık azaltma (weight decay) değeri 1×10^{-6} alınmıştır. Eğitim parametreleri Çizelge 5.3’de verilmiştir [90].

Çizelge 5.3. Eğitim parametreleri

Ölçek	Adım (stride)	Giriş imgesi parça boyutu	Öğrenme katsayısı	Minimum öğrenme katsayısı	Yığın (batch) sayısı	Devir Sayısı (epoch)	Durma kriteri
2	6	16	1,0E-03	1,0E-07	128	10	5 devir
3	4	11					
4	3	8					
8	1	4					

Eğitim parametrelerinin seçiminde, literatürde yapılmış çalışmaların deneyimlerinden yola çıkılmıştır. Örneğin, öğrenme katsayısı genellikle 10^{-1} ile 10^{-5} arasında başlangıç değeri ile başlatılmaktadır. Farksal öğrenme yapan VDSR [17] ağı çalışmasında 10^{-1} ile 10^{-3} arasındaki öğrenme katsayıları denenmiş ve 10^{-1} değerinin hızlı yakınsama sağladığı görülmüştür. DRRN [18] ve DenseNet [28] modellerinde de 10^{-1} değeri kullanılmıştır ve belirli bir devir

sayısından sonra bu katsayı düşürülmüştür. LAPSRN ağında 10^{-5} gibi oldukça düşük bir öğrenme katsayısı ile başlanmış ve her 50 devirde yarıya indirilmiştir. DRCN [16] ağında ise 2×10^{-2} değeri ile başlanmış ve her 5 devirde katsayı düşürülmüştür. Diğer taraftan, SRCNN [4] ağında öğrenme katsayısı 10^{-4} alınmış ve ağın yakınsaması bu nedenle oldukça uzun sürmüştür. Yüksek öğrenme katsayısı hızlı öğrenme sağlamakla beraber, yakınsama sorununu da beraberinde getirmektedir. VDSR ağında yüksek öğrenme katsayısının neden olduğu yakınsama problemi gradyan kırpma tekniği ile aşılmaya çalışılmıştır. Sonuçta, elde edilen tecrübeler ve diğer çalışmalar dikkate alınarak 10^{-3} değerinin ılımlı bir öğrenme katsayısı olduğu kabul edilmiş ve bu tez çalışmasında kullanılmıştır.

Benzeri şekilde, yığın sayısı da genellikle 2'nin bir katı (32, 64, 128, 256, gibi) olacak şekilde alınmaktadır. Yüksek yığın sayısı, donanımın desteklemesi durumunda hızlı işlem yapma imkânı sağlamakla beraber yakınsama için bir garanti sunmamaktadır. Kimi durumda donanım kapasitesi belirleyici olmaktadır. Örneğin, GPU belleğinin yetersiz kalması nedeniyle, EDSR [13] ve DenseNet [28] modellerinin eğitiminde yığın değeri 16 olarak alınmıştır. Bazı çalışmalarda yığın sayısı 8'e bile indirilmiştir. Bu tez çalışmasında önerilen modelde hem çalışma zamanı açısından, hem de yakınsamada ılımlı bir rejimin sürdürülmesi adına 128 değeri alınmıştır. Diğer parametreler de benzeri yaklaşımla ve daha önceki çalışmaların bulgularına göre, en iyi performans ve başarıyı sağlayacak şekilde düzenlenmiştir.

Girdi imgelerinin boyutları (genişlik ve yükseklik aynı) 2, 3, 4 ve 8 büyültme ölçekleri için sırasıyla 16, 11, 8 ve 4 piksel seçilmiştir. Bu değerler de, yukarıda izah edildiği gibi, literatürdeki çalışmalar ışığında belirlenmiştir. Girdi imgelerinin boyutları 24 ile 48 piksel aralığında ve çoğunlukla 30 piksel civarı boyutlarda alınmaktadır (2 kat büyültme için). Örneğin, DRCN ağı 41x41 ve EDSR ağı 48x48, DRRN 31x31 ve SRCNN ağında 33x33 piksel boyutlu giriş imge parçaları eğitim için kullanılmıştır. Bu bilgiler ışığında, girdi imge boyutları, çıkışta 32x32 piksel boyutlu olacak şekilde (3 kat büyültmede 33x33 olacak şekilde) ayarlanmıştır.

Adım (stride) değerleri de benzer bir yaklaşım ile 2, 3, 4 ve 8 ölçekleri için 6, 4, 3 ve 1 olacak şekilde uygulanmıştır. Böylece, her bir ölçekte yaklaşık olarak aynı miktarda eğitim imgesi ağı verilmiştir. Eğitim setindeki görüntüler ağı her bir devir başlangıcında rastgele

sıralandıktan sonra verilmiştir. Giriş görüntüsünden elde edilen imge parçaları da benzeri şekilde rastgele sıralandıktan sonra ağa eğitim için verilmiştir.

5.4. Değerlendirme

YÇ imgelerin kalitesinin niceliksel ölçülmesinde şu görüntü kalitesi metrikleri (GKM) kullanılmıştır: tepe sinyalin gürültüye oranı (PSNR), yapısal benzerlik indeksi (SSIM) [94], çok ölçekli yapısal benzerlik indeksi (MSSSIM) [95], nitelik benzerlik indeksi (FSIM) [96], ortalama mutlak sapma (MAD), Haar dalgacık temelli algısal benzerlik indeksi (HaarPsi) [97], gradyan büyüklük benzerlik sapması (GMSD) [98] ve görsel uygunluk indeksi (VIF) [99]. Düşük değerler GMSD ve MAD metriklerinde başarı anlamına gelirken, diğer modellerde yüksek değerler başarı anlamına gelmektedir. PSNR en yaygın kullanılan metriklerin başında gelmektedir ve Eş. 5.9'da verilen formül ile tanımlanmaktadır [90]:

$$PSNR = 10 \log_{10} \left(\frac{L^2}{MSE} \right) \quad (5.9)$$

L değeri görüntüdeki en yüksek yeğlilik (intensity) değeridir (255). MSE ise Eş. 5.5'de tanımlanmıştır.

DECUSR modelinin performansı ÇKE, ÇDE, Lanczos ve en yakın komşu enterpolasyon (EYKE) yöntemlerine ilave olarak, SRCNN ve EDSR DÖ modelleri ve [100] çalışmasında önerilen gürbüz ağırlıklı regresyon yöntemi (kolay referans vermek adına RWRUSR adıyla kısaltılmıştır) ile kıyaslanmıştır.

RWRUSR metodunun regresyon sürecinde tasarım matrisinin (design matrix) oluşturulmasından önce DÇ görüntünün nasıl büyültüldüğü kaynakta belirtilmediğinden, en iyi performansı sağlaması adına üç farklı yöntem kullanılmıştır. İlk yaklaşımda mevcut DÇ görüntüdeki mevcut satır ve sütunlar yeni satır ve sütunlara çoğaltılmıştır. İkinci yaklaşımda, aynı satır ve sütun değerlerinin yeni satır ve sütunlara yazılması yerine, birbirini izleyen mevcut iki satırın veya sütunun ortalamaları yeni satırlara veya yeni sütunlara verilmiştir. Üçüncü yaklaşımda ise, büyütülmüş görüntü ÇKE yöntemiyle elde edilmiştir. En iyi sonucu verdiği için, ilk yöntem 2, 4 ve 8 ölçekleri için kullanılmıştır. RWRUSR sadece 2 kat ve katları şeklinde büyültme için önerilmiştir. Bu nedenle 3 kat büyültme yönteminde en iyi sonucu verdiği için ÇKE yöntemi kullanılmıştır.

5.5. Sonular

Her yntemin performansı hem niceliksel hem de niteliksel olarak llmştr. Niceliksel lm sonuları izelge 5.4’de verilmiştir. Kırmızı renk en yksek deęeri gsterirken, mavi renk ikinci en yksek deęeri temsil etmektedir. DECUSR dięer yntemlere aık ara stnlk saęlamıştır. izelgeden grleceęi zere, ikinci test setinde FSIM skorunun 3, 4 ve 8 leklerindeki deęerleri hari, DECUSR her iki test setinde de en yksek deęerlere sahip olmuştur. EDSR modeli TestSeti-I zerinde ikinci en iyi deęerlere sahipken, SRCNN modeli ise TestSeti-II zerinde en iyi ikinci deęerler sahiptir. Her iki test setinde de D modelleri haricinde, dięer tekniklerin hibiri bařarılı olamamıřtır. EDSR modelinin PSNR skorları dięer metotlardan gzle grlr derecede dřk ıkmıřtır. EDSR modeli orijinal alıřmada, PSNR metrięini maksimum yapan ℓ_1 tipinde hata fonksiyonu yerine, daha hızlı yakınsama saęlayan ℓ_2 tipinde hata fonksiyonu ile tasarlanmıřtır. Bu durumun EDSR modelinde ℓ_1 tipinde hata fonksiyonu kullanılmıř olmasından kaynaklandığı dřnlmektedir. Dięer bir gzle grlr sonu, Lanczos enterpolasyon teknięinin dięer enterpolasyon tekniklerinden daha bařarılı oluřudur. Enterpolasyon yntemleri arasında en dřk performans EYKE teknięi gstermiřtir.


Grsel deęerlendirme yapabilmek adına, izelge 5.4’deki sonular Ek-1’de řekil 1 ve řekil 2’de verilmiřtir. Alt řekiller (a), (b), (c), (d), (e), (f), (g) ve (h) sırasıyla FSIM, GMSD, HAARPSI, MAD, MS-SSIM, PSNR, SSIM ve VIF metriklerine ait deęerleri grafiksel olarak sunmaktadır. DECUSR modeline ait deęerler yeřil izgi ile gsterilmiřtir. Metotların bařarı sıralamalarındaki sabitlik her iki řekilden de kolayca grlebilmektedir. DECUSR aęına ait eęriler oęu durumda en st sırada yer almıřtır. Ardından, EDSR modeli ve TestSeti-I’e ait grafiklerde (řekil 1); SRCNN modeli ise TestSeti-II’ye ait grafiklerde (řekil 2) ikinci sırada grlmektedir. RWRUSR ynteminin 3 kat byltme leęinde gsterdięi sapma her iki řekildeki tm GKM grafiklerinde hemen gze arpmaktadır. Ayrıca, EYKE yntemiyle birlikte, en dřk puan eęrilerine sahiptir.

Çizelge 5.4. Yöntemlerin TestSeti-I ve TestSeti-II üzerinde elde ettikleri niceliksel sonuçlar [90]


TestSeti-I										TestSeti-II							
METOT	FSIM	GMSD	HAARPSI	MAD	MSSSIM	PSNR	SSIM	VIF		FSIM	GMSD	HAARPSI	MAD	MSSSIM	PSNR	SSIM	VIF
2x																	
ÇKE	0,9535	0,0185	0,8706	1,4998	0,9824	40,8414	0,9719	0,7745		0,9441	0,0557	0,6163	3,6253	0,9391	28,4820	0,9143	0,5735
ÇDE	0,9501	0,0295	0,8329	1,9883	0,9719	38,3645	0,9574	0,6982		0,9411	0,0632	0,5826	4,1297	0,9216	27,6981	0,8938	0,5138
LANCZOS	0,9552	0,0123	0,8881	1,3238	0,9853	41,9543	0,9767	0,8076		0,9450	0,0509	0,6292	3,4559	0,9447	28,8120	0,9206	0,6009
EYKE	0,9474	0,0297	0,6048	2,4628	0,9646	36,1492	0,9482	0,6547		0,9420	0,0632	0,4533	4,1949	0,9248	27,6200	0,8971	0,5127
RWRUSR	0,9474	0,0298	0,6184	2,5915	0,9632	36,0017	0,9405	0,6524		0,9418	0,0632	0,4583	4,2956	0,9244	27,6036	0,8947	0,5118
SRCNN	0,9588	0,0071	0,9183	1,2097	0,9885	43,1829	0,9810	0,8414		0,9481	0,0401	0,6729	3,2171	0,9547	29,2911	0,9306	0,6389
EDSR	0,9607	0,0245	0,9114	1,0206	0,9958	38,7039	0,9843	0,8506		0,9488	0,0922	0,5770	3,6799	0,9703	24,3891	0,9278	0,5905
DECUSR	0,9602	0,0055	0,9304	1,1016	0,9978	44,1133	0,9837	0,8467		0,9495	0,0322	0,7080	2,8020	0,9915	30,5537	0,9404	0,6391
3x																	
ÇKE	0,9421	0,0492	0,7226	2,7021	0,9475	35,6253	0,9201	0,5786		0,9340	0,0837	0,4824	5,1305	0,8815	26,2538	0,8420	0,4074
ÇDE	0,9397	0,0596	0,6777	3,0930	0,9320	34,3312	0,9029	0,5229		0,9317	0,0903	0,4618	5,4147	0,8664	25,9196	0,8273	0,3746
LANCZOS	0,9432	0,0435	0,7463	2,5088	0,9540	36,3586	0,9282	0,6133		0,9350	0,0798	0,4916	5,0235	0,8880	26,3999	0,8481	0,4259
EYKE	0,9095	0,0550	0,4103	3,7437	0,9128	32,3509	0,8780	0,4605		0,9105	0,0841	0,3078	5,7498	0,8592	25,5089	0,8174	0,3513
RWRUSR	0,9415	0,0534	0,7122	9,8225	0,9447	27,3613	0,8985	0,6099		0,9343	0,0844	0,4847	6,7489	0,8827	25,5703	0,8284	0,4134
SRCNN	0,9480	0,0291	0,7910	2,5121	0,9627	37,1659	0,9304	0,6659		0,9401	0,0589	0,5456	4,9067	0,9049	27,1015	0,8459	0,4687
EDSR	0,9487	0,0344	0,7963	2,0260	0,9902	36,3102	0,9485	0,6858		0,9410	0,0942	0,4952	4,9766	0,9625	24,4698	0,8710	0,4633
DECUSR	0,9486	0,0259	0,8044	2,0758	0,9914	38,5420	0,9470	0,6839		0,9403	0,0564	0,5566	4,4042	0,9793	27,4008	0,8740	0,4821
4x																	
ÇKE	0,9329	0,0919	0,5852	3,8359	0,8992	32,5970	0,8580	0,4276		0,9261	0,1217	0,4017	6,1552	0,8304	25,1760	0,7837	0,3042
ÇDE	0,9302	0,1066	0,5441	4,2945	0,8757	31,6114	0,8377	0,3817		0,9242	0,1321	0,3792	6,4900	0,8099	24,8524	0,7676	0,2759
LANCZOS	0,9336	0,0856	0,6103	3,6775	0,9077	33,0334	0,8648	0,4519		0,9270	0,1181	0,4147	6,0722	0,8374	25,2908	0,7880	0,3179
EYKE	0,8815	0,1008	0,2618	4,7625	0,8606	30,3313	0,8132	0,3338		0,8821	0,1261	0,1985	6,8089	0,8038	24,4282	0,7574	0,2535
RWRUSR	0,8829	0,1007	0,2732	4,9647	0,8587	30,2282	0,8007	0,3326		0,8839	0,1260	0,2094	6,9668	0,8029	24,4066	0,7526	0,2523
SRCNN	0,9394	0,0710	0,6513	3,4470	0,9238	34,0981	0,8738	0,5036		0,9346	0,0943	0,4613	5,8631	0,8593	25,8619	0,7897	0,3560
EDSR	0,9406	0,0722	0,6630	3,2774	0,9747	32,3757	0,8919	0,5392		0,9355	0,1112	0,4473	5,9889	0,9489	24,2466	0,8110	0,3768
DECUSR	0,9411	0,0664	0,6760	3,2150	0,9764	34,7470	0,8806	0,5397		0,9346	0,0917	0,4746	5,5224	0,9605	26,0336	0,8137	0,3851
8x																	
ÇKE	0,9078	0,1847	0,3337	6,8447	0,7203	27,7036	0,7029	0,1883		0,9094	0,1925	0,2644	8,4830	0,6951	23,2878	0,6704	0,1476
ÇDE	0,9047	0,1939	0,3135	7,2258	0,7009	27,2690	0,6925	0,1728		0,9076	0,2014	0,2483	8,8399	0,6783	23,0319	0,6592	0,1366
LANCZOS	0,9095	0,1795	0,3491	6,7492	0,7269	27,8645	0,7042	0,1956		0,9103	0,1876	0,2760	8,3989	0,7007	23,3907	0,6717	0,1527
EYKE	0,8310	0,2238	0,1504	7,6639	0,6729	26,4055	0,6576	0,1268		0,8348	0,2268	0,1208	9,2193	0,6584	22,6021	0,6375	0,1031
RWRUSR	0,8368	0,2190	0,1495	7,9387	0,6732	26,0784	0,6453	0,1253		0,8454	0,2236	0,1225	9,5784	0,6547	22,3502	0,6316	0,1023
SRCNN	0,9173	0,1615	0,3866	6,2971	0,7573	28,6281	0,7165	0,2178		0,9167	0,1738	0,2973	8,3248	0,7189	23,6237	0,6413	0,1673
EDSR	0,9212	0,1677	0,3822	6,4011	0,8904	25,4221	0,7387	0,2528		0,9205	0,1918	0,2930	8,7150	0,8579	21,3377	0,6943	0,1936
DECUSR	0,9205	0,1536	0,4118	6,0668	0,8942	28,9230	0,7252	0,2484		0,9200	0,1641	0,3161	7,7954	0,8864	23,7852	0,6963	0,1947

Metotların başarısını niteliksel karşılaştırmak adına, Şekil 5.7 ve Şekil 5.8’de sırasıyla TestSeti-I ve TestSeti-II’den alınmış birer örnek imgeden metotların ürettikleri YÇ imgelere ait sonuç görüntüleri verilmiştir. Tam boy orijinal imge ve referans imge parçası da şekillerde sağ tarafta verilmiştir. Her metodun elde ettiği PSNR ve SSIM skorları imgelerin altında sırasıyla yer almaktadır. Sonuç imge parçaları incelendiğinde, insan görme sistemi (HVS) açısından en kaliteli görüntülerin DECUSR modeli tarafından üretildiği açıkça görülmektedir. Modelin ürettiği imgeler yüksek frekanslı detayları (kenarlar gibi) başarılı bir şekilde üretmektedir. En düşük kaliteli çıktıyı EYKE ve ardından RWRUSR üretmiştir. Her iki yöntemin de ürettiği imgelerdeki örtüşme (aliasing) ve bulanıklık sorunu özellikle büyük ölçeklerde daha da net görülmektedir. EDSR’nin ürettiği görüntülerin özellikle siyah bölgelerinde bazı piksel bozulmaları da göze çarpmaktadır. Buna karşın, DECUSR oldukça iyi çözünürlük ve keskinlik sunmuştur. Ölçek değeri arttıkça DECUSR ile diğer metotlar arasındaki kalite farkı daha bariz hale gelmiştir.

DECUSR modelinin diğer metotlara göre başarısı ayrıca istatistiksel olarak ölçülmüştür. Bu maksatla, 0,05 anlamlılık seviyesinde tek yönlü varyans analizi (ANOVA) ve Welch t-testi yapılmıştır. Toplamda 224 ölçüm (4 farklı ölçek x 8 GKM x 7 farklı metot) her iki test seti için de uygulanmıştır. Ölçümlerden elde edilen p değerleri Ek-2’de Çizelge 2.1’de verilmiştir. Sadece 0,05 anlamlılık seviyesinden daha yüksek p değerine sahip istisna ölçümler kırmızı renk ile verilmiştir. Sırasıyla TestSeti-I’de 211 ve TestSeti-II’de 208 adet ölçüm DECUSR modelinin başarısını doğrulamıştır. Anlamlı bir fark bulamayan 29 ölçüm EDSR ve SRCNN modellerine karşı yapılan ölçümlerdir. Bu ölçümlerin neredeyse yarısı FSIM metriğinde yapılan ölçümlerden meydana gelmektedir. Ki bu durum TestSeti-II’de EDSR’nin 3, 4 ve 8 ölçeklerinde TestSeti-I üzerinde elde ettiği skarlardan bir miktar daha yüksek skarlara sahip olmasından kaynaklanmaktadır. Geriye kalan diğer ölçümler ise büyük çoğunlukla VIF ve SSIM metriklerinde gerçekleştirilmiş olanlardır. HaarPsi ve MSSSIM metriklerindeki tüm ölçümler DECUSR ile diğer yöntemler arasında istatistiksel olarak anlamlı bir fark olduğunu doğrulamıştır. GMSD, MAD ve PSNR metriklerindeki ölçümlerden ise sırasıyla sadece bir, iki ve üç ölçüm haricinde, kalanların tamamı istatistiksel bir fark olduğuna işaret etmektedir.




Şekil 5.7. TestSeti-I'den alınan örnek bir ultrason görüntüsünden elde edilen görsel sonuçlar [90]



Şekil 5.8. TestSeti-II'den alınan örnek bir ultrason görüntüsünden elde edilen görsel sonuçlar [90]

Yukarıda bahsi geçen tüm kıyaslamalara ilave olarak, metotların çalışma zamanı ve başarıları üzerine de bir kıyaslama da yapılmıştır. Elde edilen sonuçlar Şekil 5.9'da verilmiştir. Parantez içerisindeki ilk değer yöntemlerin elde ettiği ortalama PSNR skorunu temsil ederken, ikinci değer çalışma zamanını (saniye) vermektedir. Şekilden açıkça görüldüğü üzere, DECUSR modeli ılımlı bir çalışma zamanı performansı ile diğer metotlardan daha başarılı olmuştur. Kendisine en yakın performansı gösteren SRCNN modelinden 0,93 dB PSNR kadar daha yüksek ortalamaya sahiptir. Beklendiği üzere, EDSR modeli çok yüksek parametre sayısına sahip olduğundan (yaklaşık 1,3 milyon) çalışma zamanı değeri oldukça yüksektir. Enterpolasyon teknikleri arasında, Lanczos yöntemi hem ortalama PSNR skoru hem de çalışma zamanı açısından dikkatleri üzerine çekmektedir. En düşük PSNR ortalamasına RWRUSR yöntemi sahiptir [90].



Şekil 5.9. Metotların çalışma zamanı sonuçları ve PSNR metriğindeki ortalama skorlar

6. DERİN ÖĞRENME MODELLERİNİN EĞİTİMİNDE EN İYİ EĞİTİM STRATEJİSİNİN BELİRLENMESİ

Bu bölümde, B-mod ultrason görüntülerinde SÇ elde edilmesinde DÖ algoritmalarının başarısını artırmanın yolları kapsamlı bir deneyle araştırılmıştır. Temel olarak üç konuya odaklanılmıştır: yerel eğitim, genel eğitim ve eğitim verilerinin miktarı. İlk etapta, derin bir ağın başarısının, insan vücudunun yalnızca belirli bir bölgesi veya organına özgü yerel görüntülerle eğitilmesiyle geliştirip geliştirilemeyeceği incelenmiştir. Buna paralel olarak, her bir bölgeden alınan rasgele görüntülerden oluşan eğitim setleri ile genel eğitimin ve eğitim için kullanılan görüntü sayısı adedinin ağın performansını nasıl etkilediği incelenmiştir.

6.1. Yöntem ve Deney

Ultrason görüntüleme kliniklerde genellikle insan vücudunun kalp, böbrek, karaciğer gibi belirli bir bölümüne uygulanmaktadır. Belirli bir organ veya vücut bölgesinde SÇ üretmede uzmanlaşmış bir algoritma geliştirmek bu manada oldukça faydalı olabilir. Bu nedenle, DÖ algoritmalarının belirli bir bölge veya organdaki başarısının insan vücudunun yalnızca yerel bir bölgesiyle veya organıyla eğitilmesiyle artırılıp artırılamayacağı araştırılmıştır. Yerel eğitim ile DÖ ağının eğitilmesi sonucu, eğitilen ağın, eğitildiği bölgedeki görüntüleri tanımasını sağlayacak nitelik, özellik vb. bilgileri edinin edinemeyeceği ilginç bir konudur. Eğer bahsi geçen nitelik veya özelliklerin ağ tarafından öğrenilmesi mümkünse, o ağın eğitildiği bölgeyi diğer bölgeler üzerinden eğitilmiş olan diğer derin ağlardan daha iyi tanıması ve bunun sonucunda daha başarılı SÇ elde etmesi beklenir. Yani, ağın, eğitildiği bölgeden alınmış bir DÇ imgeyi gördüğünde o imgeyi YÇ imgeye dönüştürmesini sağlayacak, doğrusal olmayan dönüşüm işini çok daha başarılı bir şekilde yapması beklenebilir.

Yerel eğitim ile böyle bir başarımlı sağlanabilirse, belirli bölge için uzmanlaşmış derin ağlardan bahsedilmesi mümkün olacaktır. Bahsi geçen uzman ağlar, uzman oldukları vücut bölgeleri için kullanılarak, uygulamada çok daha iyi çözünürlüğe sahip ve kaliteli ultrason görüntüsünün üretilmesini mümkün kılabilir. Bu beklentilerin ne derece mümkün olduğu bu bölümde incelenmiştir.

Diğer taraftan, eğitim görüntülerindeki çeşitliliğin ağın performansına nasıl bir katkı sağladığı da bir diğer ilginç konudur. Yerel eğitime karşın, bir derin ağın vücudun değişik bölge veya organına ait karma görüntülerle eğitilmesinin, yani genel eğitim yapılmasının, bölgesel özelliklerden ziyade, her bölge için geçerli olan ve DÇ imgeden YÇ imgeye olan doğrusal olmayan dönüşümün çok daha başarılı yapılmasını sağlayacak bilgilerin edinimini mümkün kılıp kılmadığı da incelenmiştir. Eğitim görüntüsü çeşitliliğine ilave olarak, belirli bir bölgeye ait olsun veya olmasın, eğitim görüntüsü sayısının ağın performansına yaptığı etkiler de bir diğer ilginç konudur. Ağın SÇ performansı eğitim verisinin fazlalığı ile iyileştirilebilirse, çok daha fazla örnek ultrason görüntüsü ile eğitim yapılarak derin ağların başarısı artırılabilir. Daha başarılı ağlar daha kaliteli ve çözünürlüğü ve dolayısı ile daha yüksek kalitede ultrason görüntüsü demektir.

DÖ algoritmalarının B-mod ultrason görüntülerinin SÇ’de en iyi başarımı elde etmenin yolları yukarıda bahsi geçen üç ana husus açısından kapsamlı bir deney ile etraflıca araştırılmıştır. Bu maksatla, yerel eğitim için kullanılmak üzere, önceki bölümde bahsedilen birinci web sitesinden [92] 12 farklı bölge veya organa ait ultrason görüntülerinden 12 farklı eğitim seti ve bu setlerin her biri için bir test seti oluşturulmuştur. İlave olarak, bir tanesi bahsi geçen 12 yerel eğitim setindeki tüm görüntülerden ve geriye kalan 15 tanesi de tüm görüntülerden rastgele ve binin katları kadar adette görüntüler içeren toplam 16 eğitim seti daha oluşturulmuştur. Sonuçta, 12 tanesi yerel bir bölgeye ait, bir tanesi tüm görüntüleri içeren ve 15 tanesi de rastgele ve biner biner artan görüntülerden oluşan eğitim setleri olmak üzere, toplamda 28 adet farklı eğitim seti oluşturulmuştur. Rastgele eğitim setlerinin adının başına “R” harfi ayırt edicilik sağlanması adına konmuştur. Böylece rastgele görüntülerden oluşan eğitim kümeleri R1000’den R15000’e kadar isimlendirilmiştir. Tüm eğitim verisini içeren eğitim setine ise “Tüm” adı verilmiştir. Yerel eğitim setlerinde yaklaşık 1000 ile 2500 arasında değişen sayıda görüntü bulunmaktadır. Kıyaslama için, söz konusu 12 yerel bölgenin her biri için bir test seti oluşturulmuştur. Test setlerinde eğitim setlerindeki imge sayısının yaklaşık olarak yüzde onu kadar görüntü bulunmaktadır. Eğitim ve test setlerine ait detaylar Çizelge 6.1’de verilmiştir.

Çizelge 6.1. Eğitim ve test setlerine dair detaylar


	Eğitim Seti Adı	Eğitim İmgesi Sayısı	Test İmgesi Sayısı
Yerel bölge setleri	Ayak	1014	112
	Ayak bileği	1378	153
	Böbrek	1165	129
	Dirsek	834	92
	Diz	1017	112
	El Bileği	1306	145
	Göğüs	2462	185
	Karaciğer	1437	159
	Omuz	2413	182
	Parmak	1032	114
	Safra kesesi	1294	143
	Salgı Bezi	1621	180
Rastgele setler	R1000	1000	
	...	...	-
	R15000	15000	
	Tüm	16973	-

Önceki bölümde tanıtılan 3 YB’li DECUSR modeli eğitim setlerinin her biri ile maksimum 100 devir ve 2 kat büyültme faktörü için eğitilmiş ve sonuçta 28 farklı DÖ modeli elde edilmiştir. 3 YB’li DECUSR ağına ait detaylar Şekil 6.1’de verilmiştir. Derin ağın katman detayları ise Çizelge 6.2’de verilmiştir. Tüm modellerin performansı 12 test setinin her birinde sekiz farklı GKM ile ölçülmüştür. Ölçümlerde boyutsal evrensel görelî sentez hatası (ERGAS), GMSD [98], algısal uygunluk ortalama karesel hata (PAMSE) [101], PSNR, spektral açı eşleyici (SAM) [102] , uzamsal korelasyon indeksi (SCC), SSIM [94] ve VIF [99] GKM kullanılmıştır.

Çizelge 6.2. DECUSR (3 YB'li) modelinin katman detayları

Katman	Çıktı Şekli sx(wxh)xÖzellik Sayısı	Parametre Sayısı	Bağlı olduğu katman
Giriş katmanı	(wxh)x1	0	
Conv2D_01	(wxh)x16	160	Giriş katmanı
Conv2D_02	(wxh)x16	2320	Conv2D_01
Conv2D_03	(wxh)x16	2320	Conv2D_02
Conv2D_04	(wxh)x16	272	Conv2D_03
L _{FUP}	s(wxh)x16	0	Conv2D_04
L _{DUP}	s(wxh)x1	0	Giriş katmanı
L _{CONCAT_1}	s(wxh)x17	0	L _{FUP} , L _{DUP}
Conv2D_05	s(wxh)x16	2464	L _{CONCAT_1}
Conv2D_06	s(wxh)x16	2320	Conv2D_05
Conv2D_07	s(wxh)x16	272	Conv2D_06
L _{CONCAT_2}	s(wxh)x33	0	L _{FUP} , L _{DUP} , Conv2D_07
Conv2D_08	s(wxh)x16	4768	L _{CONCAT_2}
Conv2D_09	s(wxh)x16	2320	Conv2D_08
Conv2D_10	s(wxh)x16	272	Conv2D_09
L _{CONCAT_3}	s(wxh)x49	0	L _{FUP} , L _{DUP} , Conv2D_07, Conv2D_10
Conv2D_11	s(wxh)x16	7072	L _{CONCAT_3}
Conv2D_12	s(wxh)x16	2320	Conv2D_11
Conv2D_13	s(wxh)x16	272	Conv2D_12
Conv2D_14	s(wxh)x1	145	Conv2D_13
	Toplam	27,297	

Kısaltmalar: Conv2D, 2 boyutlu konvolüsyon katmanı; L_{NBK}, nitelik büyültme katmanı; L_{DBK}, doğrudan büyültme katmanı; L_{BK}, birleşme katmanı; s, ölçek; w, genişlik; h, yükseklik.



Şekil 6.1. Üç YB'den oluşan DECUSR modeline ait detaylar.

6.2. Sonuçlar

Çizelge 6.3'de 12 yerel bölge ile eğitilen modeller arasında en iyi üç performansı gösteren yerel modeller verilmiştir. Geriye kalan 16 model yalnızca yerel eğitimin sonuçlarını kıyaslamak amacıyla tabloda kıyaslamaya dâhil edilmemiştir. Çizelge yerel eğitimin bir DÖ modelinin eğitim bölgesini diğer bölgelerde eğitilmiş modellerden daha iyi tanımasını sağlayıp sağlamadığının anlaşılması açısından önem arz etmektedir. Her bir test kümesinde başarı sıralamasında ilk üçe giren (en iyi ilk üç ortalama skorları elde eden) modeller isimleri ile birlikte verilmiştir. Çizelgedeki ilk bölüm test kümelerinde birinci gelen yerel modelleri; ikinci bölüm ikinci gelen yerel modelleri, üçüncü bölüm ise üçüncü gelen yerel modelleri belirtmektedir. Ayrıca, sadece eğitildikleri bölgenin test setinde en iyi ilk üçe girebilen modeller renklendirilmiştir. Kendi test setinde birinci olan modeller açık turuncu renk ile; ikinci olan modeller açık yeşil renk ile ve üçüncü olan modeller açık mavi renk ile renklendirilmiştir.

Çizelge 6.3. Yerel eğitilmiş modeller arasından tüm test setlerinde en iyi ilk üç performansı gösteren modeller

Birinci												
Metrik	Ayak	A.Bileği	Böbrek	Dirsek	Diz	E.Bileği	Göğüs	Karaciğer	Omuz	Parmak	S.Bezi	S.Kesesi
ERGAS	A.Bileği	S.Bezi	S.Bezi	Göğüs	A.Bileği	Parmak	Göğüs	S.Bezi	Göğüs	Parmak	Göğüs	A.Bileği
GMSD	Parmak	Parmak	Omuz	Omuz	Omuz	Omuz	Omuz	Omuz	Omuz	Omuz	Omuz	Omuz
PAMSE	Ayak	Parmak	Parmak	Ayak	Parmak	Parmak	Parmak	Parmak	Ayak	Parmak	Omuz	Parmak
PSNR	Ayak	Ayak	Ayak	Ayak	Ayak	Ayak	Ayak	Ayak	Omuz	Ayak	Omuz	Omuz
SAM	Ayak	Ayak	Omuz	Ayak	Omuz	Ayak	Omuz	Omuz	Omuz	Parmak	Omuz	Omuz
SCC	Göğüs	Göğüs	Karaciğer	Göğüs	Göğüs	Göğüs	Göğüs	Karaciğer	Göğüs	Parmak	Göğüs	Karaciğer
SSIM	Parmak	Parmak	Parmak	Parmak	A.Bileği	Parmak	Göğüs	Göğüs	Göğüs	Parmak	Göğüs	Parmak
VIF	Ayak	Ayak	Karaciğer	Ayak	Ayak	Ayak	Karaciğer	Karaciğer	Ayak	Ayak	Ayak	Karaciğer
İkinci												
Metrik	Ayak	A.Bileği	Böbrek	Dirsek	Diz	E.Bileği	Göğüs	Karaciğer	Omuz	Parmak	S.Bezi	S.Kesesi
ERGAS	Parmak	Göğüs	A.Bileği	Parmak	Parmak	Göğüs	S.Bezi	A.Bileği	A.Bileği	Göğüs	S.Bezi	Göğüs
GMSD	Ayak	Ayak	Parmak	Ayak	Ayak	Parmak	Ayak	Karaciğer	Ayak	Ayak	A.Bileği	Karaciğer
PAMSE	Parmak	Ayak	Omuz	Parmak	Ayak	Ayak	Ayak	Ayak	Parmak	Ayak	Parmak	Ayak
PSNR	Parmak	Parmak	Omuz	Omuz	Omuz	Parmak	Omuz	Omuz	Ayak	Parmak	Ayak	Ayak
SAM	Omuz	Parmak	Ayak	Omuz	A.Bileği	Omuz	A.Bileği	S.Kesesi	Ayak	Ayak	A.Bileği	Ayak
SCC	S.Kesesi	Parmak	S.Kesesi	S.Kesesi	S.Kesesi	Parmak	S.Kesesi	S.Kesesi	S.Kesesi	S.Kesesi	S.Kesesi	S.Kesesi
SSIM	Göğüs	Göğüs	Göğüs	Göğüs	Parmak	Göğüs	Parmak	Parmak	A.Bileği	Göğüs	Parmak	Göğüs
VIF	E.Bileği	E.Bileği	Ayak	E.Bileği	Böbrek	Karaciğer	Ayak	Ayak	Karaciğer	E.Bileği	Karaciğer	Ayak
Üçüncü												
Metrik	Ayak	A.Bileği	Böbrek	Dirsek	Diz	E.Bileği	Göğüs	Karaciğer	Omuz	Parmak	S.Bezi	S.Kesesi
ERGAS	Göğüs	A.Bileği	Parmak	A.Bileği	S.Bezi	S.Bezi	Parmak	Göğüs	Parmak	A.Bileği	A.Bileği	Parmak
GMSD	Omuz	A.Bileği	Böbrek	Dirsek	Böbrek	Dirsek	A.Bileği	Böbrek	Dirsek	Parmak	Karaciğer	Dirsek
PAMSE	Omuz	Göğüs	Ayak	Omuz	Göğüs	Omuz	S.Bezi	Omuz	Omuz	Omuz	Ayak	Omuz
PSNR	Omuz	Göğüs	Göğüs	Parmak	Göğüs	Göğüs	S.Bezi	Parmak	Dirsek	Omuz	S.Bezi	Parmak
SAM	Parmak	A.Bileği	S.Kesesi	Parmak	Ayak	Parmak	Ayak	Ayak	A.Bileği	Omuz	S.Kesesi	S.Kesesi
SCC	Parmak	S.Kesesi	Göğüs	Parmak	Parmak	S.Kesesi	Parmak	Göğüs	Omuz	Göğüs	Karaciğer	Göğüs
SSIM	A.Bileği	A.Bileği	A.Bileği	Ayak	Göğüs	A.Bileği	S.Bezi	A.Bileği	Parmak	Ayak	A.Bileği	A.Bileği
VIF	Karaciğer	Böbrek	Böbrek	Karaciğer	E.Bileği	E.Bileği	Böbrek	Böbrek	E.Bileği	Karaciğer	E.Bileği	S.Kesesi

Tüm GKM'lere göre, 12 yerel modelin 7'sinden hiçbiri (Ayak Bileği, Dirsek, Safra Kesesi, Bezler, Böbrek, Diz ve El Bileği) kendi test setlerinde birinci sırada yer alamamıştır. Bununla birlikte, Ayak, Karaciğer, Parmak, Salgı Bezi ve Safra Kesesi modelleri sadece birer GKM'ye göre bir kez ikinci olmuştur. Dirsek, El Bileği, Parmak ve Salgı Bezi modelleri 1; Böbrek, Omuz ve Safra Kesesi modelleri 2 ve Ayak Bileği modeli 4 GKM tarafından üçüncü gösterilmiştir. Diz modeli kendi bölgesine ait test kümesinde en iyi ilk üç model arasına hiç girememiştir. Dirsek ve El Bileği modelleri birer kez ve Böbrek modeli iki kez üçüncü olmak dışında ilk üçte hiç bulunamamıştır. Ayak Bileği modeli kendi bölgesine ait test setinde sadece 5 GKM tarafından üçüncü sırada gösterilmesi dışında ilk üçe girememiştir. Salgı Bezi modeli sadece 1 GKM tarafından; benzeri şekilde Safra Kesesi de sırasıyla 1 ve 2 GKM tarafından ikinci ve üçüncü tayin edilmiş ve bu istisnalar haricinde kendi test bölgelerine ait test setlerinde en iyi ilk üç model arasına hiç girememiştir. Parmak modeli kendi test setinde ilk üçe girebilen tek modeldir. Buna karşın, 8 GKM'nin sadece 5 tanesi birinci olarak göstermiştir. Benzer şekilde, Ayak modeli 4; Göğüs modeli ve Omuz modeli 3 GKM tarafından birinci sırada gösterilmiştir.

Görüldüğü üzere, modellerin büyük çoğunluğu kendi test setlerinde ilk üçe girememiş, ya da çok az sayıda GKM tarafından ilk üçte gösterilmiştir. Bununla birlikte yerel modellerin büyük çoğunluğu kendi test kümelerinde neredeyse hiç birinci olamamıştır. Genellikle, her bir test setinde diğer bir bölgenin eğitim seti ile eğitilmiş olan bir başka model ilk üç sırada yer almıştır.

Çizelge 6.4 her bir yerel eğitilmiş modelin 12 yerel test setinde kaç defa birinci, ikinci veya üçüncü olduğunu; ayrıca toplamda kaç defa ilk üçe girdiğini özet olarak vermektedir. Her bir sıralama için $12 \text{ test} \times 8 \text{ adet GKM} = 96 \text{ GKM}$ skoru bulunmaktadır. Ayak, Omuz ve Parmak modelleri birincilik sıralamasına ait 96 GKM skorunun yaklaşık 3'te 2'sine göre birinci seçilmiştir. Diğer taraftan Ayak modeli ve Parmak modeli de ikincilik için alınabilecek skorların yaklaşık yarısını elde etmiştir. Üçüncülük için, modeller daha homojen bir başarı dağılımı sergilemekle beraber dengeli bir dağılımdan söz etmek hâlâ mümkün değildir. Toplam sayılar incelendiğinde, Ayak ve Parmak modeli birbirine oldukça yakın sayıda (sırasıyla 56 ve 57) GKM skoru tarafından ilk üçte gösterilmiştir. Ardından, Omuz ve Göğüs modelleri de geriye kalan modellere göre kayda değer sayıda GKM (sırasıyla 40 ve 42) tarafından ilk üçte gösterilmiştir. Diğer yerel modeller ise dikkate değer bir performans gösterememiştir.

Çizelge 6.4. Yerel modellerin aralarında yapılan kıyaslamaya göre test setlerinin tamamında en iyi ilk üç model arasına girme sayıları

Sıralama	Ayak	Ayak Bileği	Böbrek	Dirsek	Diz	El Bileği	Göğüs	Karaciğer	Omuz	Parmak	Salgı Bezi	Safra Kesesi	Toplam
1	24	4	0	0	0	0	16	7	21	21	3	0	96
2	25	8	1	0	0	4	11	5	9	20	2	11	96
3	7	15	7	5	0	4	13	5	12	16	6	6	96
Toplam	56	27	8	5	0	8	40	17	42	57	11	17	

Yerel modellerin performansının kendi aralarında karşılaştırılmasına ek olarak, diğer modellerin de (geriye kalan 16 model) dâhil edildiği kıyaslama sonuçları Çizelge 6.5’de sunulmuştur. Bu kez toplamda 28 farklı modelin kıyaslanması söz konusudur. Önceki kıyaslamada yapıldığı gibi, burada da her test setinde sadece en iyi ilk üç sıralamaya giren modeller isimleri ile verilmiştir. Çizelgenin ilk bölümü birinci; ikinci bölümü ikinci ve üçüncü bölümü her bir GKM’ye göre en iyi üçüncü olan modelleri göstermektedir. Öncekine benzer şekilde, kendi bölgesine ait test setinde ilk üç sıralamada gösterilen yerel modeller birinci, ikinci ve üçüncü sıralama için sırasıyla açık turuncu, açık yeşil ve açık mavi renk ile renklendirilmiştir.

Çizelgeden açıkça görüldüğü üzere 12 yerel eğitilen modelin 7 tanesi hiçbir GKM tarafından en iyi ilk üç model arasında gösterilmemiştir. Geriye kalan yerel modeller de çok az sayıda GKM tarafından ilk üçte gösterilmiştir. Şöyle ki, Ayak ve Omuz modelleri sırasıyla sadece 2 ve 1 GKM tarafından birinci sırada gösterilmiştir. Omuz modeli sadece iki GKM tarafından ikinci gösterilirken, Karaciğer, Parmak ve Göğüs yerel modelleri sadece bir GKM tarafından ikinci seçilmiştir. Ayak modeli sadece 2, Göğüs ve Karaciğer modelleri de sadece bir GKM tarafından üçüncü gösterilmiştir.

Çizelge 6.5. Eğitilmiş modellerin tamamından tüm test setlerinde en iyi ilk üç performansı gösteren modeller

Birinci												
Metrik	Ayak	A.Bileği	Böbrek	Dirsek	Diz	E.Bileği	Göğüs	Karaciğer	Omuz	Parmak	S.Bezi	S.Kesesi
ERGAS	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm
GMSD	R5000	R10000	R5000	Omuz	R5000	R6000	R10000	R5000	Omuz	R5000	Omuz	R5000
PAMSE	Ayak	R14000	Parmak	Ayak	R14000	R7000	R7000	R7000	Ayak	R14000	R7000	Parmak
PSNR	Ayak	Ayak	R14000	R14000	R14000	R14000	R7000	R14000	R14000	R14000	R7000	R14000
SAM	R10000	R10000	R10000	R10000	R10000	R10000	R10000	R10000	R10000	R10000	R10000	R10000
SCC	Tüm	Tüm	Tüm	Tüm	Tüm	R14000	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm
SSIM	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm	Tüm
VIF	R14000	R14000	R14000	R14000	R14000	R14000	R14000	R14000	R14000	R14000	R14000	R14000
İkinci												
Metrik	Ayak	A.Bileği	Böbrek	Dirsek	Diz	E.Bileği	Göğüs	Karaciğer	Omuz	Parmak	S.Bezi	S.Kesesi
ERGAS	R14000	R14000	R14000	R14000	R12000	R14000	R12000	R14000	R12000	R14000	R14000	R12000
GMSD	R10000	Parmak	R4000	R5000	R10000	R10000	R6000	Tüm	R10000	Omuz	R4000	R6000
PAMSE	R7000	Parmak	R12000	R3000	Parmak	Parmak	Parmak	Parmak	R14000	Parmak	R13000	R14000
PSNR	R5000	R14000	R7000	Ayak	Tüm	R7000	R14000	R5000	Omuz	R3000	R14000	R5000
SAM	R5000	R5000	R12000	R12000	R6000	R14000	R6000	R12000	Omuz	R3000	R6000	R12000
SCC	R14000	R14000	R14000	R14000	R14000	Tüm	Göğüs	R14000	R5000	R14000	R14000	R14000
SSIM	R14000	R5000	R6000	R14000	R12000	R12000	R5000	R5000	R12000	R14000	R6000	R6000
VIF	R10000	R12000	R12000	Ayak	Tüm	Tüm	R12000	Karaciğer	Tüm	Tüm	R12000	Karaciğer
Üçüncü												
Metrik	Ayak	A.Bileği	Böbrek	Dirsek	Diz	E.Bileği	Göğüs	Karaciğer	Omuz	Parmak	S.Bezi	S.Kesesi
ERGAS	R6000	R12000	R4000	R12000	R14000	R6000	R6000	R6000	R6000	R6000	R12000	R14000
GMSD	R4000	Ayak	Omuz	R14000	Tüm	R5000	R4000	R6000	Ayak	R6000	R6000	Omuz
PAMSE	Parmak	Ayak	R3000	R7000	Tüm	R3000	R3000	R14000	R7000	R3000	R3000	Ayak
PSNR	R14000	R7000	R12000	R3000	R12000	R3000	R3000	R7000	R5000	Ayak	R3000	Tüm
SAM	Ayak	R6000	R6000	R5000	R5000	R6000	R4000	R5000	R5000	R5000	R7000	R5000
SCC	R8000	R8000	R8000	R5000	Göğüs	R8000	R14000	Karaciğer	R14000	R8000	R8000	Karaciğer
SSIM	R6000	R12000	R12000	R5000	R6000	R6000	Göğüs	R6000	R14000	R12000	R12000	R12000
VIF	Ayak	Tüm	Karaciğer	R12000	R10000	R12000	Karaciğer	R12000	R12000	R10000	R10000	R12000

Elde edilen sonuçlar yerel eğitim ile bir modelin eğitildiği bölgeye ait ultrason görüntülerinde SÇ elde etmesine bariz bir katkı sağlamadığını belirtmektedir.

Yerel modellerin tüm GKM'ler tarafından herhangi bir test setinde ilk üçte gösterilmelerine dair toplam adetleri Çizelge 6.6'da görülmektedir. Ayak modeli 14, Göğüs modeli 3,


Karaciğer modeli 6, Omuz modeli 8 ve son olarak Parmak modeli 10 GKM tarafından herhangi bir yerel test setinde ilk üçte gösterilmiştir. Bunların dışında kalan A.Bileği, Böbrek, Dirsek, Diz, El Bileği, Salgı Bezi ve Safra Kesesi modellerinin hiç biri, hiçbir test setinde en iyi ilk üçte gösterilmemiştir.

Çizelge 6.6. Bütün modellerin dâhil edilerek yapılan kıyaslamaya göre yerel modellerin en iyi ilk üç model arasına girme sayıları

Sıra	Ayak	A.Bileği	Böbrek	Dirsek	Diz	E.Bileği	Göğüs	Karaciğer	Omuz	Parmak	S.Bezi	S.Kesesi	Toplam
1	5	0	0	0	0	0	0	0	3	2	0	0	96
2	2	0	0	0	0	0	1	2	3	7	0	0	96
3	7	0	0	0	0	0	2	4	2	1	0	0	96
Toplam	14	0	0	0	0	0	3	6	8	10	0	0	

Buna karşın en iyi ilk üçe giren modellerin çok büyük çoğunluğu yerel olmayan modellerdir. Özellikle, yüksek miktarda görüntü sayısına sahip olan eğitim setleriyle eğitilen modeller daha başarılı olmuştur. Birincilik sıralamalarına bakıldığında, ERGAS, SCC ve SSIM metrikleri “Tüm” modelini birinci sırada göstermiştir. VIF metriği tüm testlerde, PSNR metriği ise 12 test setinin 8’inde R14000 modelini birinci olarak göstermiştir. SAM ise R10000 modelini ilk sırada göstermiştir. GMSD ve PAMSE ise karışık sonuçlar vermiştir.

Şekil 6.2’de bütün modeller arasından, sadece en az bir GKM tarafından en iyi ilk üç sıralamada gösterilen modellere dair bir grafik verilmiştir. Çizelgede yalınlık sağlanması açısından, en iyi ilk üç sıralamaya giremeyen modeller gösterilmemiştir. Çizelgede, mavi turuncu ve yeşil renkli sütunlar modellerin kaç adet GKM tarafından sırasıyla birinci, ikinci ve üçüncü seçildiğine dair sayı bilgisini vermektedir. Karmaşıklığı önlemek adına sadece birincilik adetleri mavi sütunlar üzerine mavi renkle verilmiştir. Kırmızı renkli çizgi ise birinci seçilen modellerin eğitildiği eğitim setlerindeki imge sayılarını temsil etmektedir. Şekilde göze çarpan ilk bulgu eğitim görüntüsü adedi fazla olan modeller yüksek miktarda GKM tarafından birinci seçilmiştir. Eğitim görüntüsü miktarı ile birlikte modeller daha fazla sayıda en iyi ilk üç model arasına girme imkânı bulmuştur.




Şekil 6.2. Modellerin en iyi ilk üç model arasına girme durumları ve en başarılı model seçilme sayıları ve eğitim görüntüsü sayısı arasındaki ilişki

96 GKM'nin 35, 24, 11, 6, 6, 5, 3, 2 ve 1 tanesi sırasıyla "Tüm", R14000, R11000, R7000, R5000, Ayak, Omuz, Parmak ve R6000 modellerini birinci göstermiştir. Yerel modellerin eğitildiği imge adetleri yaklaşık 1000 ile 2500 arasında değişmektedir. R3000 modeli ise adından da anlaşılacağı üzere 3000 adet ve rastgele seçilmiş karma imgelerden oluşan bir eğitim seti ile eğitilmiştir. Şekilden de açıkça görüldüğü üzere, R3000 modeli rastgele görüntüler ile eğitilmiş olmasına ve hiç birinci seçilmemiş olmasına rağmen, yerel modellerden daha başarılı sonuç sergilemiştir. Dikkat edilecek olursa, Şekil 6.2'de sadece 5 adet yerel model en iyi ilk üç performans sergileyen modeller arasına girebilmiş ve geriye kalan 7 yerel model ise sıralamaya hiç girememiştir. Hâlbuki R3000 modeli sıralamaya girebilen yerel modellerin çoğundan daha fazla sayıda en iyi ilk üç model arasında göstermiştir.

Modellerin performanslarının görsel incelenebilmesi adına, PSNR (dB) metriğine göre modellerin (yerel veya diğerleri) tamamının her bir test setinden elde ettiği ortalama skorlar Şekil 6.3'de verilmiştir. Diğer GKM skorlarına ait şekiller Ek-3'de verilmiştir. Yatay eksen 28 modelin her birini, dikey eksen ise ortalama PSNR (dB) skorlarını vermektedir. Farklı renkteki her bir çizgi bir test setini ve o test setinden modellerin elde ettiği ortalama değerleri temsil etmektedir. Örneğin, gri renkli çizgi sadece Böbrek test setine aittir. Bu test setinde, modellerin tamamı diğer test setlerine nazaran daha yüksek ortalama skorları elde etmiştir.

En düşük PSNR skorları ise koyu mavi renkli çizgi ile temsil edilen Ayak Bileği test setinde elde edilmiştir.



Şekil 6.3. Test kümelerine göre gruplanmış ortalama PSNR (dB) skorları


Şekilden (Şekil 6.3) açıkça görüldüğü üzere, grafikteki çizgiler birini andıran paralel tabakalar şeklinde dizilmiştir. İki farklı teste ait olan skor çizgiler neredeyse hiçbir yerde birbirini kesmemektedir. Yani, bir testten elde edilen skorlar diğer bir testten elde edilen skorlardan, duruma göre, ya hep aşağıda ya da hep yukarıda kalmaktadır. Diğer bir deyişle, modellerin neredeyse tamamı birbirine benzer şekilde, testler boyunca ya yüksek ya da daha düşük skor elde etmiştir. Modellerin başarısı belirli bir testte hep birlikte ya düşmüş ya da artmıştır. İstisna olarak, bazı yerel modeller kendi bölgelerine ait test kümesinde diğer modellerden farklı olarak bir miktar daha iyi performans göstermiştir. Örneğin, Parmak modeli kendi bölgesine ait test kümesinde diğerlerine nazaran daha yüksek PSNR skoru elde etmiştir. Bu tür istisnalar çok az sayıda yerel model için geçerlidir. Yukarıda bahsi geçen durumların neredeyse tamamı Ek-5’de verilen diğer GKM’lere ait grafiklerde de açıkça görülmektedir.

Grafikte (Şekil 6.3) dikkati çeken bir diğer bulgu; R1000 modeli çoğu yerel modelin eğitildiği eğitim setlerinin sahip olduğundan daha az sayıda imgeye sahip bir eğitim kümesi ile eğitilmiş olmasına rağmen, kayda değer sayıda yerel modelden daha iyi performans

sergilemiştir. Bu durumun daha net görülebilmesi adına grafik üzerinde kırmızı ve siyah kesik yatay çizgiler çizilmiştir. Çizgilerin kırmızı olanı Ayak Bileği testinde R1000 modelinin elde ettiği PSNR skoru seviyesine yaklaşık olarak hizalanmıştır. Siyah kesikli çizgi ise R1000 modelinin Böbrek test setindeki skor seviyesine hizalanmıştır. Ayak Bileği testine bakılırsa (mavi çizgi) R1000 modelinin PSNR skoru Ayak Bileği, Diz ve Karaciğer modellerinin elde ettiği skorlardan daha yüksek ve Böbrek modelinin skoruna oldukça yakındır. Üstüne üstlük, Ayak Bileği modeli bu bölge ile eğitilmiş olmasına rağmen R1000 modelinden daha düşük bir performans sergilemiştir. Benzeri durum grafik içerisinde sıkça görülmektedir. Siyah kesikli çizginin bulunduğu bölge de incelenirse, R1000 modelinin Ayak Bileği ve Diz modelini Böbrek test setinde geçmiş ve hatta Böbrek modeline oldukça benzer bir performans sergilediği görülecektir. Bu ve benzeri durumlar grafik içerisinde yaygın bir biçimde görülmektedir. Yalınlık adına, sadece iki örnek durum burada sergilenmiştir. Benzeri örnekler grafik üzerinde görülebilir.

Bir diğer önemli bulgu ise, eğitim görüntüsü adedi fazla olan modellerin PSNR skorları çoğu durumda eğitimde kullanılan görüntü miktarıyla uyumlu bir şekilde artıyor oluşudur. Kimi modellerde performans düşüşü görülse de, giderek artan bir eğimin varlığı grafikte net bir şekilde görülmektedir. Ek-3'de verilen diğer grafikler de incelenirse, diğer GKM'lerin de bu bulguyu doğrulamakta olduğu görülecektir.

Yukarıda bahsi geçen sonuçların başka bir açıdan incelenebilmesi adına, aynı niceliksel sonuçlar bu kez yatay eksen test setleri ve her farklı renkteki çizgi bir eğitilmiş DÖ modelini temsil edecek şekilde yeniden grafik olarak sunulmuştur. Sekiz GKM'den PSNR skoruna ait grafik (Şekil 6.4) burada gösterilmiş ve diğer GKM'lere ait grafikler Ek-4'de sunulmuştur. Yatay eksen test setlerini temsil etmekte ve her bir farklı renkteki çizgi ise bir modelin test setlerinin her birinden elde ettiği ortalama PSNR skorlarını temsil etmektedir. Çizgilerdeki paralellik ilk göze çarpan bulgulardan biridir. Neredeyse bütün modeller birbirleri arasındaki paralelliği bozmayacak şekilde, belirli bir test üzerinde ya düşük ya da yüksek sonuç almıştır. Modellerin performans çizgileri tabakalar halinde ve birbirini kesmeyecek ya da aşmayacak biçimde, aralarındaki ahengi bozmadan sıralanmıştır. Aralarında gözle görülür neredeyse hiç değişmeyen bir performans sıralaması vardır. Birkaç istisna dışında, neredeyse hiç biri performans sıralamasındaki yerini bozmamaktadır. Bir model diğerlerine göre kaçınıcı sıradaysa, o sırasını hemen hemen tüm test setlerinde korumaktadır.




Şekil 6.4. Modellere göre gruplanmış ortalama PSNR (dB) skorları

Bahsi geçen paralellik ve katmanlar şeklinde sıralanma Ek-6'da verilen diğer GKM'lere ait grafiklerde de çok net bir biçimde görülmektedir. Yukarıda bahsi geçen durumlar özellikle SAM (Ek-5 Şekil 5.4), SCC (Ek-5 Şekil 5.5) ve VIF (Ek-5 Şekil 5.7) metriklerine ait grafiklerde hat safhadadır. Bazı küçük istisnalar (örneğin SSIM metriğinin grafiğinde birkaç yerde) dışında, GKM'lerin büyük çoğunluğu modellerin performansları arasındaki paralellik ve benzerliği grafiksel olarak net bir biçimde ortaya koymaktadır.

Modellerin performanslarındaki benzerlik ve paralellikten yola çıkarak, aralarındaki korelasyonun derecesinin de niceliksel olarak değerlendirilmesi için korelasyon ölçümleri yapılmıştır. Bu bağlamda 28 modelin her birinin birbiriyle olan korelasyon değerleri bütün GKM'ler üzerinde hesaplanmış ve sonuçlar ısı haritası (heatmap) şeklinde grafiksel olarak hazırlanmıştır. Yalınlık adına, PSNR metriğine ait ısı haritası (Şekil 6.5) burada; geriye kalan diğer 7 GKM'nin korelasyon grafiklerine ait ısı haritaları Ek-5'de verilmiştir. Isı haritalarındaki renklerin açıklığı yüksek korelasyonu temsil ederken, renklerin koyuluğu korelasyonun düşüklüğü anlamına gelmektedir.

Isı haritalarındaki her bir kutucuğun içerisinde ilgili iki model arasında ölçülen korelasyonun sayısal değeri bulunmaktadır. Isı haritalarının sağ tarafında ise, her bir modelin diğer modellerle arasındaki minimum, maksimum ve ortalama korelasyon değerleri verilmiştir.

Şekillerde ilk göze çarpan bulgu, ERGAS (Ek-5 Şekil 5.1), PAMSE (Ek-5 Şekil 5.3) ve SSIM (Ek-5 Şekil 5.6) metriklerindeki birkaç küçük istisna dışında ısı haritalarındaki renklerin oldukça açık ve homojen bir tona sahip oluşudur. Açık renk tonlarındaki homojenlik modeller arasındaki korelasyonun kuvvetli oluşunun bir işaretidir. Nitekim PSNR grafiği örnek olarak incelenirse (Bkz. Şekil 6.5), tüm şekil neredeyse tek bir renge sahip olduğu olayca görülecektir. Bu durum modellerin aynı test kümelerinde gösterdikleri performansları arasında çok kuvvetli bir korelasyon olduğuna işaret etmektedir. Isı haritasının yanında verilen tablo incelendiğinde, bütün modeller arasında en düşük korelasyon değerinin Karaciğer modeli ile Ayak modeli arasında hesaplanan 0,960 değeri olduğu görülecektir. Ki bu değer bile çok kuvvetli bir korelasyon anlamına gelmektedir. Bununla beraber, diğer değerler bu değer de üzerinde ve 1 değerine oldukça yakındır.



Şekil 6.5. Modeller arasındaki korelasyonun PSNR (dB) metriği üzerinde yapılan niceliksel ölçüm sonuçları

Birkaç ufak istisna ERGAS (Ek-5 Şekil 5.1), GMSD (Ek-5 Şekil 5.2) ve SSIM (Ek-5 Şekil 5.6) metrikleri üzerinde yapılan ölçümlerde görülmüştür. Şöyle ki, ERGAS üzerinde yapılan korelasyon ölçümlerine göre, El Bileği R2000, R13000 modelleri ve bazı yerlerde “Tüm” modeli ile diğer modeller arasında kimi yerlerde düşük değerler elde edilmiştir. En düşük değerler “Tüm” modeli ile El Bileği, R2000 ve R13000 arasında sırasıyla 0,253, 0,210 ve 0,229 olarak elde edilmiştir. Buna karşın diğer değerler bu seviyelerden çok daha yüksektir. ERGAS metriğindeki en küçük ortalama korelasyon değeri 0,682’dir. Diğer korelasyon değerleri çok daha yüksek, hatta birçoğu 0,90 üzerinde ve 1’e yakındır.

GMSD metriğinde (Ek-5 Şekil 5.2) göze çarpan bir istisna Safra Kesesi modeli ile diğer modeller arasında yapılan ölçümlerde meydana gelmiştir. En düşük korelasyon değeri olan 0,464 değeri Safra Kesesi ile Ayak modelleri arasında hesaplanmıştır. Safra Kesesi modelinin en yüksek korelasyon değeri olan 0,815 değeri kendisi ile El Bileği modeli arasında ölçülmüştür. Esasen, GMSD metriğindeki ölçümler de bu istisna dışında oldukça yüksektir. Diğer modellerin ortalama korelasyon değerleri Parmak modelinin ortalama değeri olan 0,914 değerinden daha yüksektir. Görüleceği üzere, bahsi geçen istisnalar dışında, GMSD metriği üzerinde yapılan ölçümler de modeller arasında kuvvetli korelasyon olduğunu açığa vurmaktadır.

En aykırı ölçüm sonuçları SSIM metriği (Ek-5 Şekil 5.6) üzerinde yapılan ölçümlerden elde edilmiştir. Özellikle, El Bileği, R1000, R2000 ve R13000 modelleri ile diğer modeller arasındaki korelasyonda çok sıra dışı sonuçlar elde edilmiştir. Bu ve bunun gibi aykırı ölçümler SSIM metriğinin korelasyon grafiğinde de gözle görülebilmektedir. En düşük korelasyon El Bileği ve diğer modeller arasında hesaplanmıştır. Şöyle ki, El Bileği modelinin en düşük korelasyon değeri -0,022, en yüksek korelasyon değeri 0,917 ve ortalama korelasyon değeri 0,145'dir. El Bileği modeli haricinde, diğer modeller zaman zaman çok düşük korelasyon değerleri vermiş olsalar da çoğu değerleri çok daha yüksektir. grafiklerden de anlaşılacağı üzere, düşük korelasyon ölçümleri oldukça nadir ve birkaç yerde karşımıza çıkmaktadır. Bazı modellerde sıfır değerine veya sıfır değerinin altında olan korelasyon değerleri yer yer elde edilmiş olsa bile, bu modellerin büyük çoğunluğunun korelasyon değerlerinin ortalamasının yaklaşık 0,83'ün üzerinde ve maksimum değerlerinin de 1'e oldukça yakın olduğu gözlenmiştir.

Yukarıda bahsedilen istisnalar dışında, diğer GKM'ler üzerindeki ölçümler çok kuvvetli korelasyona işaret etmektedir. Örneğin SAM, SCC, VIF ve daha önceden bahsi geçen PNSR metriklerindeki korelasyon değerleri oldukça yüksektir. Bu metriklerin ısı haritaları da neredeyse hep aynı açık renk ile resmedilmiştir. SAM metriğinde ölçülen en düşük korelasyon 0,896 değeri ile Diz modeli ile R3000 modeli arasında ölçülmüştür. En düşük ortalama değer ise 0,944 ile Karaciğer modeline aittir. Diğer ortalamalar ve tahmin edileceği üzere, maksimum değerler bu seviyelerin üzerinde ve 1'e çok yakındır.

SCC metriğindeki ölçümler çok daha yüksektir (Ek-5 Şekil 5.5). En küçük korelasyon değeri 0,978 ile R12000 ve R14000 modelleri arasında ölçülmüştür. Ki bu değer bile modellerin


performanslarında ne derece kuvvetli bir korelasyon olduğunu kanıtlamak için yeterlidir. Keza, VIF metriğindeki ölçümler SCC metriğinden elde edilenlerden bile yüksek korelasyon değerleri vermiştir. En düşük ölçülen korelasyon değeri olan 0,989 R4000 ve R5000 arasında ölçülmüştür. Tahmin edileceği üzere diğer ölçümler bu değerin de üzerindedir. Hatta, virgülden sonra 4'ncü basamakta yapılan yuvarlama yapılmasına rağmen maksimum değerlerin çoğu 1 (bir) değerine yuvarlanmıştır.

Sonuç olarak, bu bölümde yapılan deneysel çalışmalar, ultrason görüntülerinde SÇ elde etme açısından, DÖ ağlarını belirli bir bölgeye veya organa ait örnek görüntüler ile eğitmenin, yani yerel eğitim yapmanın, eğitilen modelin başarısını artırmadığını ortaya koymuştur. Test edildikleri test bölgesinden bağımsız olarak, modellerin birbirine benzer (paralel) performans eğrileri sergilemeleri ve aralarındaki korelasyonun yüksekliği (ki çoğu durumda 1.0 değerine oldukça yakın) yerel eğitim ile ağın performansı arasında bir ilişki olmadığını gözler önüne sermiştir. Buna karşın her bölgeden rastgele alınan karma örnek görüntüler ile genel eğitim yapmanın daha iyi sonuç verdiği gözlenmiştir. Kimi durumda yerel bölgeye ait eğitim setindeki imge sayısı ile yaklaşık aynı sayıda ve her bölgeden rastgele seçilen görüntülerden oluşan bir eğitim seti ile genel eğitim yapmak o bölgede daha başarılı sonuçların alınmasını sağlamıştır. İlave olarak, eğitim verisi miktarının artırılmasının derin ağın performansına doğrudan katkı sağladığı da açıkça görülmüştür. Eğitim verisinin miktarının artmasıyla birlikte DÖ ağının başarımı da artmıştır.

7. B-MOD ULTRASON GÖRÜNTÜSÜNE KARŞIN RF SİNYALİ SEVİYESİNDE SÜPER ÇÖZÜNÜRLÜK

Bölüm 5’de derin öğrenme (DÖ) algoritmaları ile nihai B-mod ultrason görüntüleri üzerinde süper çözünürlük (SÇ) uygulaması gerçekleştirilmiş ve Bölüm 6’da yerel eğitim, genel eğitim ve eğitim görüntüsü sayısının DÖ ağlarına etkisi üzerine kapsamlı bir çalışma yapılmıştır. Bölüm 5’de yapılan çalışma neticesinde, DÖ algoritmalarının geleneksel tekniklerden daha başarılı olduğu sonucuna varılmıştır.

Bu bölümde nihai B-mod ultrason görüntüleri üzerinde elde edilen SÇ’nin, nihai B-mod ultrason görüntüsüne dönüştürülmeden evvelki bir ara aşamada radyo frekans (RF) sinyali formatında bulunan ultrason verisi üzerinde elde edilen SÇ ile karşılaştırılmıştır. Karşılaştırmanın amacı, söz konusu iki safhanın hangisinde yapılan SÇ’nin daha başarılı sonuçlar verdiğini ortaya koymaktır. Karşılaştırmanın yapıldığı her iki aşama da Şekil 7.1’de gösterilmiştir. Ultrason görüntüleme RF sinyalinin elde edildiği aşama yeşil renk ile; nihai B-mod imgenin edinildiği safha ise kırmızı renk ile belirtilmiştir.




Şekil 7.1. B-mod görüntü safhası ve RF sinyali safhasındaki süper çözünürlük

Her iki safhada da gerçekleştirilen SÇ test amacıyla, Illionis üniversitesi İnsana Lab [103] web sitesinden alınan RF sinyali formatındaki 909 adet RF sinyali verisinden 829 tanesi eğitim kümesi için ve rastgele seçilen 80 adet RF verisi de test için kullanılmıştır. Oluşturulan RF sinyali formatındaki eğitim ve test setlerinin muadili olacak B-mod formatındaki eğitim ve test setleri, RF formatındaki eğitim ve test setlerindeki görüntülere tipik ultrason ardıl işleme süreçlerinin (Bkz. Şekil 7.1) uygulanması ile elde edilmiştir. Bu işlem vasıtası ile aynı orijinal veriden üretilen ve aynı verinin RF sinyali ve B-mod imge formatındaki eğitim ve test setleri hazır hale getirilmiştir.

Her iki görüntüleme aşamasında da SÇ elde etmek için, Bölüm 5’de tasarlanan temel model olan 3 YB’li DECUSR modeli (Bkz. Şekil 5.6) ve ayrıca diğer DÖ modeli olan SRCNN, 2, 3, 4 ve 8 kat büyütme için 300’er devir (epoch) eğitime tabi tutulmuştur. Tüm testler bahsi geçen iki DÖ modeline ilave olarak ÇDE, ÇKE, EYKE ve Lanczos tekniği ve RWRUSR yöntemi üzerinde, Bölüm 5’de uygulandığı gibi uygulanmıştır.

Hem eğitim hem de test için SÇ’nin her iki aşamada da nasıl gerçekleştirildiğine dair kavramsal şema Şekil 7.2’de verilmiştir. RF sinyali seviyesinde SÇ elde etmek adına, mevcut RF sinyali SÇ problem tanımına uygun olarak DÇ sinyale dönüştürülmüş ve mevcut sinyalin YÇ sinyal olarak kabul edilmesi ve her sinyalin de DÖ modeline verilmesi ile derin ağın DÇ sinyal ile YÇ sinyal arasındaki dönüşüm fonksiyonunu öğrenmesi istenmiştir. B-mod görüntüler üzerinde yapılan eğitim de, daha önce Bölüm 5’de izah edildiği gibi gerçekleştirilmiştir.



Şekil 7.2. RF sinyali safhasında ve Nihai B-mod görüntü üzerinde süper çözünürlüğün elde edilmesine dair kavramsal şema

Her iki DÖ modelinin her iki safhada da bütün büyütme ölçekleri (2, 3, 4 ve 8 kat) için eğitiminin tamamlanmasının ardından, tüm modellerin başarımları hem RF safhası hem de B-mod safhasına ait test setleri üzerinde karşılaştırılmıştır. Bahsi geçen bütün yöntemlerin RF sinyali safhasında ürettiği görüntüler ultrason görüntülemeye normalde yapıldığı şekliyle B-mod görüntü formatına dönüştürülmüş ve performans ölçümleri B-mod görüntüye

dönüştürülmüş imgeler üzerinde yapılmıştır. Böylece, her iki safhadan elde edilen görüntüler B-mod görüntü formatında kıyaslamaya tabi tutulmuştur.

Karşılaştırmada, önceki bölümde olduğu gibi ERGAS, GMSD, PAMSE, PSNR, SAM, SCC, SSIM ve VIF metrikleri kullanılmıştır. Düşük değerler ERGAS, GMSD, PAMSE ve SAM metriklerinde başarı anlamına gelirken, diğer metriklerde yüksek değerler başarı anlamına gelmektedir. RF sinyali safhasında elde edilen sonuçlar Çizelge 7.1’de; B-mod görüntü safhasında elde edilen sonuçlar ise Çizelge 7.2’de verilmiştir.

Çizelge 7.1’de verilen sonuçlara göre, DECUSR ağı RF sinyali üzerinde SÇ elde etmede tüm ölçeklerde, neredeyse tüm metriklere göre en iyi performansı göstermiştir. Sadece iki istisna 8 kat büyütmede iki metrikte meydana gelmiştir. ERGAS metriği Lanczos yöntemini; SSIM metriği ise EYKE yöntemini çok ufak sayısal farkla daha başarılı bulmuştur. Bunların dışındaki altı metrik yine DECUSR modelini 8 kat büyültmede de en başarılı yöntem olarak göstermiştir.

B-mod safhası üzerinde yapılan SÇ uygulamasında DECUSR ağı tüm metrikler tarafından tüm ölçeklerde, istisnasız en başarılı yöntem olarak bulunmuştur.


Metotların B-mod safhası ve RF sinyali safhalarında elde ettiği SÇ sonuçlarının PSNR metriği üzerindeki görsel karşılaştırması Şekil 7.3’de verilmiştir. Diğer metriklerdeki görsel karşılaştırmalar EK-7’de verilmiştir. Mavi renkli barlar RF sinyali seviyesine ait sonuçları temsil ederken, turuncu renkli barlar B-mod imge safhasında elde edilen sonuçları temsil etmektedir.

Çizelge 7.1. RF sinyali safhasında süper çözünürlüğün gerçekleştirilmesiyle elde edilen nicel sonuçlar

ÖLÇEK	METOT	ERGAS	GMSD	PAMSE	PSNR	SAM	SCC	SSIM	VIF
2	ÇKE	2103,0778	0,1033	77,0206	24,8873	0,0801	0,5903	0,7037	0,2530
	ÇDE	2283,7240	0,1115	97,5381	24,2122	0,0863	0,5488	0,6721	0,2174
	LANCZOS	1932,2373	0,0926	63,3583	25,5874	0,0742	0,6345	0,7468	0,2996
	EYKE	2596,5363	0,1308	105,0330	23,0530	0,0993	0,3413	0,5112	0,1544
	RWRUSR	2589,8532	0,1305	104,0881	23,0775	0,0991	0,3415	0,5113	0,1545
	SRCNN	1557,1459	0,0744	29,9593	27,3665	0,0622	0,7204	0,8060	0,3826
	DECUSR	1501,2657	0,0720	27,6888	27,6510	0,0605	0,7340	0,8161	0,4018
3	ÇKE	3281,9148	0,1562	266,3552	20,8858	0,1247	0,1689	0,3849	0,0933
	ÇDE	3773,3181	0,1642	398,7068	19,6456	0,1376	0,1318	0,3313	0,0810
	LANCZOS	3130,8249	0,1505	223,5718	21,3422	0,1199	0,2094	0,4130	0,1022
	EYKE	3272,5133	0,1765	262,3876	20,9770	0,1250	0,0559	0,3516	0,0699
	RWRUSR	3281,9300	0,1562	266,3549	20,8858	0,1247	0,1689	0,3849	0,0933
	SRCNN	2978,8974	0,1512	183,7503	21,7427	0,1147	0,2230	0,4144	0,1079
	DECUSR	2921,8300	0,1445	182,2573	21,8830	0,1138	0,2311	0,4353	0,1216
4	ÇKE	3903,2923	0,1716	426,3586	19,4000	0,1486	0,0307	0,2247	0,0415
	ÇDE	4081,0825	0,1752	484,5826	18,9901	0,1538	0,0296	0,2114	0,0378
	LANCZOS	3764,4924	0,1691	379,9731	19,7446	0,1444	0,0409	0,2370	0,0424
	EYKE	3787,5033	0,1799	450,4426	19,6026	0,1453	-0,0137	0,2644	0,0389
	RWRUSR	3770,7891	0,1795	448,6670	19,6112	0,1451	-0,0137	0,2645	0,0389
	SRCNN	3544,6034	0,1625	282,6297	20,2889	0,1342	0,1036	0,2745	0,0499
	DECUSR	3365,6030	0,1598	234,7710	20,7274	0,1297	0,1285	0,2991	0,0542
8	ÇKE	4218,8261	0,2017	692,4452	18,6084	0,1649	0,0003	0,2270	0,0139
	ÇDE	4255,4710	0,2068	715,8965	18,5385	0,1652	0,0006	0,2324	0,0133
	LANCZOS	4216,3156	0,1983	687,4980	18,6122	0,1648	0,0002	0,2239	0,0141
	EYKE	4244,4000	0,2122	716,8886	18,4080	0,1694	0,0015	0,2336	0,0133
	RWRUSR	4277,1659	0,2117	752,2464	18,3079	0,1703	0,0014	0,2334	0,0133
	SRCNN	4283,9070	0,2079	702,2617	18,5830	0,1606	0,0012	0,1992	0,0132
	DECUSR	4257,3911	0,1947	649,2707	18,5460	0,1597	0,0029	0,1844	0,0143

Çizelge 7.2. Nihai B-mod görüntü safhasında süper çözünürlüğün gerçekleştirilmesiyle elde edilen nicel sonuçlar

ÖLÇEK		ERGAS	GMSD	PAMSE	PSNR	SAM	SCC	SSIM	VIF
2	ÇKE	1851,2632	0,0672	11,4667	26,0166	0,0721	0,3349	0,5415	0,2928
	ÇDE	1914,5595	0,0744	15,1290	25,7406	0,0744	0,3232	0,5092	0,2676
	LANCZOS	1842,6157	0,0648	10,6486	26,0468	0,0718	0,3138	0,5442	0,2989
	EYKE	1860,9330	0,0743	10,6254	25,9980	0,0722	0,2638	0,5595	0,2925
	RWRUSR	1864,4635	0,0743	11,1687	25,9835	0,0722	0,2638	0,5595	0,2924
	SRCNN	1717,4309	0,0594	8,2212	26,6575	0,0669	0,4234	0,6262	0,3331
	DECUSR	1539,9427	0,0496	5,9421	27,5502	0,0605	0,5481	0,6995	0,3823
3	ÇKE	2070,5468	0,0854	23,6715	25,0838	0,0803	0,1154	0,4363	0,2112
	ÇDE	2098,0692	0,0956	26,8183	24,9767	0,0813	0,0889	0,4234	0,1962
	LANCZOS	2061,1835	0,0805	22,4361	25,1199	0,0800	0,1131	0,4414	0,2187
	EYKE	2127,4505	0,0863	24,3418	24,8630	0,0824	0,0471	0,4263	0,2005
	RWRUSR	5673,5281	0,0992	1418,6434	16,2628	0,1540	0,1185	0,4472	0,2451
	SRCNN	2022,6115	0,0734	19,8815	25,2789	0,0785	0,1488	0,4667	0,2356
	DECUSR	1991,1480	0,0704	18,4183	25,4063	0,0773	0,1872	0,4832	0,2461
4	ÇKE	2175,4265	0,1231	35,3283	24,6798	0,0842	0,0552	0,3937	0,1586
	ÇDE	2210,6880	0,1389	40,6461	24,5468	0,0855	0,0469	0,3782	0,1413
	LANCZOS	2162,8175	0,1149	33,4635	24,7279	0,0837	0,0577	0,4007	0,1666
	EYKE	2238,7001	0,1330	37,6136	24,4394	0,0865	0,0155	0,3792	0,1458
	RWRUSR	2241,6385	0,1330	38,1528	24,4294	0,0865	0,0155	0,3792	0,1458
	SRCNN	2136,6639	0,1037	30,4189	24,8271	0,0827	0,0699	0,4184	0,1830
	DECUSR	2122,8766	0,1010	29,4777	24,8751	0,0822	0,0910	0,4260	0,1886
8	ÇKE	2399,0582	0,1997	72,8567	23,8501	0,0926	0,0049	0,3160	0,0581
	ÇDE	2425,9076	0,2073	78,2576	23,7554	0,0937	0,0040	0,3097	0,0509
	LANCZOS	2389,1815	0,1949	70,8764	23,8850	0,0922	0,0048	0,3188	0,0614
	EYKE	2451,6356	0,2193	78,1548	23,6603	0,0947	0,0010	0,3046	0,0472
	RWRUSR	2485,3697	0,2244	277,8373	20,9838	0,1288	0,0009	0,3016	0,0468
	SRCNN	2379,2299	0,1858	68,9735	23,9197	0,0919	0,0073	0,3245	0,0659
	DECUSR	2366,1499	0,1780	66,9434	23,9654	0,0914	0,0142	0,3313	0,0711



Şekil 7.3. RF sinyali safhasında ve Nihai B-mod görüntü safhasında elde edilen süper çözünürlük sonuçlarının PSNR (dB) metriği üzerinde görsel olarak karşılaştırılması

Şekilden açıkça görüldüğü üzere, B-mod imge formatındaki görüntüler üzerinde SÇ yapılması RF sinyali üzerinde SÇ yapılmasından daha başarılı sonuçlar vermiştir. Sadece üç istisna durum 2 kat büyültmede SRCNN ve DECUSR modellerinde; 3 kat büyültmede ise RWRUSR yönteminde meydana gelmiştir. 2 kat büyültmede SRCNN ve DECUSR modelleri RF sinyali safhasında B-mod safhasına göre çok az bir miktar daha iyi sonuç vermiştir. Benzer şekilde, RWRUSR yöntemi ise üç kat büyültmede RF sinyali safhasında daha iyi performans sergilemiştir. Bunların dışında B-mod safhasında yapılan SÇ, RF safhasındaki SÇ göre, özellikle ölçek arttıkça daha başarılı olmuştur. Genellikle, yöntemlerin başarılarındaki düşüşün büyültme ölçeği arttıkça RF sinyali seviyesinde B-mod seviyesine göre daha fazla olduğu gözlenmektedir.

ERGAS (Ek-6 Şekil 6.1) ve PAMSE (Ek-6 Şekil 6.3) metriğindeki görsel sonuçlara göre, tek istisna 3 kat büyültme ölçeği için RWRUSR yönteminde gerçekleşmiş. Bu istisna dışında tüm metriklerde B-mod safhasındaki SÇ daha başarılı olmuştur. GMSD metriğinde (Ek-6 Şekil 6.2) tek bir istisna 8 kat büyültme için ÇDE yönteminde görülmüştür. SAM metriğinde (Ek-6 Şekil 6.4) iki istisna iki kat büyültme ölçeği için SRCNN ve DECUSR modellerinde; 3 kat büyültme ölçeği için RWRUSR tekniğinde meydana gelmiştir. SCC metriğine göre (Ek-6 Şekil 6.5), 2 ve 3 kat büyültme ölçeklerinde RF safhasında elde edilen SÇ daha başarılı

iken, 4 ve 8 kat büyültme ölçeklerinde B-mod görüntü safhası daha başarılı çıkmıştır. SSIM (Ek-6 Şekil 6.6) metriğine göre de, 2 kat büyültmede RF sahası; 3, 4 ve 8 kat büyültmede ise B-mod görüntü safhası daha iyi sonuç vermiştir. VIF (Ek-6 Şekil 6.6) metriğine göre, 2 kat büyültme ölçeğinde Lanczos, SRCNN ve DECUSR modellerinin RF safhasında daha başarılı oluşu dışında diğer tüm ölçeklerde ve yöntemlerde B-mod görüntü safhasındaki sonuçlar kayda değer miktarda yüksek çıkmıştır.

Yukarıda bahsi geçen birkaç istisna dışında, B-mod görüntü safhasında yapılan SÇ RF sinyali formatında bulunan ultrason görüntüsü verisinde yapılan SÇ'ye göre gözle görülür başarılı sonuç vermiştir.





8. SONUÇ VE ÖNERİLER

Geleneksel yapay sinir ağlarının (YSA) çok sayıda katmana ve çok daha gelişkin ve başarımı yüksek farklı tipte ağ mimarilerine sahip olan derin öğrenme (DÖ) algoritmaları günümüzde sınıflandırma, nesne tanıma, örüntü tanıma, doğal dil işleme, bilgisayarla görmede, medikal görüntülerin işlenmesinde ve daha birçok sayısız alanda başarısını kanıtlamıştır. DÖ algoritmaları diğer pek çok alanda olduğu gibi, mevcut olan görüntünün belirli bir ölçekte büyütülmesini sağlarken görüntüdeki aktif çözünürlüğü iyileştirmeyi amaçlayan süper çözünürlük (SÇ) uygulamalarında da devam etmiş, diğer metotlardan çok daha iyi sonuçlar elde etmiştir. Özellikle, son yıllardaki başarılı SÇ çalışmalarının büyük çoğunluğu DÖ algoritmaları ile gerçekleştirilmiştir.

Ultrason görüntüleme (UG) jinekolojide, kalp, karaciğer, böbrek, pankreas, prostat gibi organların hızlı ve dinamik görüntülerin ediniminde yaygın bir biçimde kullanılmaktadır. Diğer tıbbi görüntüleme teknikleriyle kıyaslandığında hem hasta hem de uygulayıcı (radyolog, doktor vb.) açısından zararsız, güvenilir, maliyeti düşük olmakla birlikte, mobil kullanıma uygundur ve anlık görüntü alınmasına imkân verir. Fakat UG'nin en büyük sorunu görüntü çözünürlüğünün düşük oluşudur. Düşük çözünürlüklü (DÇ) ultrason görüntülerinin daha yüksek çözünürlüğe (YÇ) sahip görüntülere dönüştürülmesi tıbbi uygulamalarda teşhis ve tanı adına büyük önem arz etmektedir. Görüntü kalitesinin düşüklüğü tıbbi görüntüleme uzmanının veya doktorların görüntüyü yorumlamasını güçleştirmekte, bazı durumlarda yanlış teşhis yapmalarına neden olabilmektedir. Ayrıca DÇ sorunu nedeniyle görüntülerin analizi, yorumlanması vb. süreçlerin tamamlanması uzun zaman almaktadır. Bu manada, UG'de çok daha YÇ ve iyi kalitede görüntülerin elde edilmesi sayesinde tıbbi tanı ve teşhisin doğruluğu artacak ve analiz, yorumlama gibi süreçler hız kazanacaktır.

Bu doktora tezinde, ultrason görüntülerindeki DÇ sorununun çözümü için DÖ algoritmaları kullanılmıştır. Çoğu diğer çalışmalarda yapıldığı gibi UG'nin ön işleme safhasında veya ardıl işleme safhasının ara aşamalarında bir yerlerde farklı formatlarda bulunan ultrason verisi üzerinde SÇ elde etmek yerine, UG'nin en son safhası olan nihai B-mod ultrason görüntüleri üzerinde SÇ uygulanmıştır.

Çalışma dâhilinde dört farklı büyültme ölçeğinde (2, 3, 4 ve 8 kat) SÇ gerçekleştirilmiştir. Oldukça yüksek miktarda (yaklaşık 28 bin) B-mod ultrason görüntüsü ile çoğunluğu

konvolüsyon katmanlarından oluşan bir derin ağ eğitilmiş ve performansının en iyi olması için optimize edilmiştir. Eğitim sonucunda başarıyı yüksek bir DÖ ağı meydana getirilmiştir. Tasarlanan DÖ ağı 4 adet enterpolasyon yöntemi, bir adet ağırlıklı regresyon yöntemi ve iki adet diğer başarılı DÖ modeli ile kıyaslanmıştır. Kıyaslamalar neticesinde eğitilen DÖ ağı ile elde edilen SÇ'nin diğer metotlarla elde edilen SÇ'ye nazaran kayda değer oranda iyi olduğu gözler önüne serilmiştir. İlave olarak, tasarlanan modelin diğer yöntem ve tekniklerden açık ara üstün olduğu tek yönlü varyans analizi (ANOVA) ve Welch t-testi ile istatistiksel olarak da kanıtlanmıştır. Tasarlanan DÖ ağı ile üretilen ultrason görüntüleri hem niceliksel hem de insan görme sistemi açısından da başarılı bulunmuştur. Bu nedenle, B-mod ultrason görüntüleri üzerinde DÖ algoritmaları ile edilen SÇ, DÇ sorununun üstesinden gelmede umut vaat etmektedir.

Nihai B-mod ultrason görüntüleri üzerinde SÇ elde etmenin çeşitli avantajları vardır. Şöyle ki; sadece yeni elde edilecek olan UG'de SÇ elde etmek değil, mevcut olan ultrason görüntüleri üzerinde de SÇ elde etmek mümkündür. Ayrıca, bir donanım değişikliğine gerek kalmadan ve ilave bir maliyet oluşturmada, görüntüleme cihazı üzerine bir yazılım olarak bütünleştirilebilir. Veya, ultrason görüntüleri üzerinde çeşitli analiz ve işleme yapan tekniklere bir ön işlem safhası olarak uyarlanabilir.

Yukarıda bahsi geçen çalışmalara ilave olarak, DÖ ağlarının ultrason görüntüleri üzerinde en başarılı SÇ'yi elde etmesini sağlayacak en iyi eğitim yöntem deneysel olarak araştırılmıştır. Bu bağlamda DÖ ağlarının başarıyı belirli bir organ veya bölge görüntüleriyle yerel eğitim ve her bölgeden rastgele alınan karma görüntüler ile genel eğitim açısından kıyaslanmıştır. Ultrasonun tıbbi görüntülemeye genellikle insan vücudunun belirli bir organı veya bölgesi üzerinde uygulanması nedeniyle DÖ ağlarının insan vücudunun belirli bir organı veya bölgesi ile yerel eğitilmesinin DÖ ağlarının daha iyi SÇ elde etmesine imkân verip vermediği konusu da ilginç bir araştırma konusudur. Bu soruya cevap bulmak adına kapsamlı bir deney yapılmış ve sonuçlar detaylı bir şekilde analiz edilmiştir. Deneyin icrasında ayrıca yerel eğitim haricinde, her bölgeden alınan rastgele görüntüler ile bir DÖ ağının genel eğitilmesinin nasıl bir etkide bulunduğu da araştırılmıştır. Yerel eğitim ve genel eğitim karşılaştırılarak en iyi eğitimi verecek olan yönteme dair cevap aranmıştır. İlave olarak, eğitim görüntüsü miktarının derin ağın SÇ performansına nasıl etki ettiği de detaylı bir şekilde incelenmiştir.

Yapılan deneyler ve analizler neticesinde, yerel eğitimin, beklenenin aksine, DÖ algoritmalarının SÇ'deki başarısını artırmadığı; kimi zaman yerel eğitim kümesindeki görüntü miktarı ile yaklaşık aynı sayıda ve her bölgeden rastgele karma görüntüler ile genel eğitim yapmanın daha başarılı sonuç alınmasına imkân sağladığı görülmüştür. Eğitildikleri bölgeden bağımsız olarak, her bir DÖ ağının belirli bir bölgeye ait test setinde benzeri performans sergilemesi ve ağlar arasındaki korelasyonun çok yüksek oluşu, DÖ ağlarının eğitim sürecinde öğrendikleri şeyin eğitim bölgesinden bağımsız bir bilgi olduğunu göstermiştir. Esasen, DÖ katmanlarındaki konvolüsyon filtreleri belirli bir en ve boy değerine sahip bir penceredir (matris). Dolayısı ile eğitim esnasında yapılan konvolüsyon işlemi neticesinde bölgeden bağımsız olarak belirli bir mesafedeki yerel özelliklerin ağ tarafından öğrenildiği düşünülmektedir. Bu nedenle, bir organ veya bölgenin tamamına dair bir nitelik veya özellikten ziyade görüntü içerisindeki kısmi bir yerel ilişkinin öğrenilmesi söz konusudur. İlave olarak, eğitim görüntüsü adedinin artırılmasının DÖ ağlarının SÇ'deki başarısına gözle görülür katkı sağladığı da bu tez çalışmasında açıkça ortaya konulan sonuçlardandır. Eğitim verisi miktarı arttıkça DÖ ağının performansı da artmıştır.

Yukarıda bahsedilen çalışmalar haricinde, UG'nin son safhası olan B-mod görüntüler üzerinde elde edilen SÇ, ardıl işleme safhasının ilk aşamalarında radyo frekans (RF) sinyali formatında bulunan ultrason verisi üzerinde elde edilen SÇ ile de karşılaştırılmıştır. Karşılaştırmanın amacı iki aşamanın hangisinde elde edilen SÇ'nin başarıyı artırdığını bulmaktır. Bu bağlamda, bir DÖ modeli aynı RF verisi üzerinden elde edilen hem RF hem de B-mod formatındaki iki eğitim kümesi ile ayrı ayrı eğitilmiş ve eğitim sonucunda elde edilen iki farklı modelin başarı düzeyleri ölçülmüştür. Ölçüm için sekiz farklı GKM kullanılmıştır. Ölçüm sonuçları, B-mod görüntüler üzerinde yapılan SÇ'nin RF sinyalinden elde edilen SC'den açık ara daha başarılı olduğunu ortaya koymuştur.

Özetle, bu çalışma ile B-mod ultrason görüntülerinde DÖ algoritmaları ile SÇ yapmanın diğer UG safhalarında ve diğer yöntemlerle yapılan SÇ'ye göre daha başarılı sonuçlar verdiği ve UG'deki DÇ sorununun çözümünde umut vaat edici olduğu gözler önüne serilmiştir. İlave olarak, bir bölge ile eğitim yapmanın o bölgede daha başarılı SÇ elde edilmesini sağlamadığı, hatta her bölgeden alınan karma örnek ultrason görüntüleri ile eğitim yapmanın zaman zaman daha iyi sonuç verdiği de gösterilmiştir. Eğitim verisinin artırılmasının SÇ'deki başarıyı artırdığı da yine bu çalışma kapsamında elde edilen sonuçlar arasındadır.

Bu doktora çalışmasında SÇ elde etmek adına konvolüsyonel sinir ağlarından yararlanılmıştır. Bununla beraber, son zamanlarda çekişmeli üretici ağların (GAN) da çok iyi performans sergilediği optik görüntüler üzerinde yapılan çalışmalarda gösterilmiştir. Bu nedenle, GAN ile ultrason görüntülerinde SÇ elde etmek ilginç bir araştırma konusu olarak durmaktadır. Ayrıca, bu çalışmada ardıl işleme safhasına odaklanılmıştır. Ön işleme safhasında da SÇ uygulamak adına GAN'ların veya daha farklı DÖ algoritmalarının SÇ problemine nasıl bir çözüm getirdiğinin incelenmesi ilave bir araştırma konusudur.



KAYNAKLAR

1. Ortiz, S. H. C., Chiu, T., and Fox, M. D. (2012). Ultrasound image enhancement: A review. *Biomedical Signal Processing and Control*, 7(5), 419-428.
2. Krizhevsky, A., et al. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems Foundation Conference*, Nevada, United States of America, 22(1), 1097–1105.
3. Nasrollahi, K., and Moeslund, T. B. (2014). Super-resolution: a comprehensive survey, *Machine vision and applications*, 25(6), 1423-1468.
4. Dong, C., Loy, C. C., He, K., and Tang, X. (2015). Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence*, 38(2), 295-307.
5. Keys, R. G. (1981). Cubic Convolution Interpolation for Digital Image Processing *IEEE Transactions on Acoustics, Speech, and Signal Processing*.
6. Yang, J., Wright, J., Huang, T. and Ma, Y. (2008). Image super-resolution as sparse representation of raw image patches. *26th IEEE Conference on Computer Vision and Pattern Recognition*, Portland, Oregon, United States of America, 1-8.
7. Chang, H., Yeung, D. Y., and Xiong, Y. (2004). Super-resolution through neighbor embedding. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Washington, United States of America, 1, 1-1.
8. Romano, Y., Isidoro, J., and Milanfar, P. (2016). RAISR: Rapid and Accurate Image Super Resolution. *IEEE Transactions on Computational Imaging*, 3(1), 1–31.
9. Tang, Y., Yan, P., Yuan, Y., and Li, X. (2011). Single-image super-resolution via local learning. *International Journal of Machine Learning and Cybernetics*, 2(1), 15-23.
10. Dong, C., Loy, C. C., and Tang, X. (2016, October). Accelerating the super-resolution convolutional neural network. *European conference on computer vision*, Amsterdam, The Netherlands, pp. 391-407.
11. Yamanaka, J., Kuwashima, S., and Kurita, T. (2017, November). Fast and accurate image super resolution by deep CNN with skip connection and network in network. *International Conference on Neural Information Processing*, Guangzhou, China, pp. 217-225.
12. Shi, W., Caballero, J., Huszár, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D., and Wang, Z. (2016). Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Nevada, United States of America, pp. 1874-1883.
13. Lim, B., Son, S., Kim, H., Nah, S., and Mu Lee, K. (2017). Enhanced deep residual networks for single image super-resolution. *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, Hawaii, United States of

America, pp. 136-144.

14. Li, Z., Li, S., Wang, J., and Wang, H. (2016, November). A Novel Multi-Frame Color Images Super-Resolution Framework based on Deep Convolutional Neural Network. *5th International Conference on Measurement, Instrumentation and Automation (ICMIA 2016)*, Shenzhen, China.
15. Zhong, X., Mei, L., Wang, J., Shao, J., and He, Y. (2016). A Robust Image Super-resolution Algorithm Using Deep Convolution Networks. *DEStech Transactions on Engineering and Technology Research*, (iceta).
16. Kim, J., Kwon Lee, J., and Mu Lee, K. (2016). Deeply-recursive convolutional network for image super-resolution. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, United States of America, pp. 1637-1645.
17. Kim, J., Kwon Lee, J., and Mu Lee, K. (2016). Accurate image super-resolution using very deep convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, United States of America, pp. 1646-1654.
18. Tai, Y., Yang, J., and Liu, X. (2017). Image super-resolution via deep recursive residual network. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Honolulu, United States of America, pp. 3147-3155.
19. Yang, F., Xu, W., and Tian, Y. (2017, August). Image super resolution using deep convolutional network based on topology aggregation structure. *AIP Conference Proceedings*, 1864(1), 020185.
20. He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, United States of America, pp. 770-778.
21. Mao, X., Shen, C., and Yang, Y. B. (2016). Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections. *Advances in neural information processing systems*, pp. 2802-2810.
22. Wang, Z., Liu, D., Yang, J., Han, W., and Huang, T. (2015). Deep networks for image super-resolution with sparse prior. *Proceedings of the IEEE international conference on computer vision*, Santiago, Chile, pp. 370-378.
23. Wang, L., Huang, Z., Gong, Y., and Pan, C. (2017). Ensemble based deep networks for image super-resolution. *Pattern Recognition*, 68, 191-198.
24. Liu, D., Wang, Z., Nasrabadi, N., and Huang, T. (2016, November). Learning a mixture of deep networks for single image super-resolution. *Asian Conference on Computer Vision*, Taipei, Taiwan, pp. 145-156. Springer, Cham.
25. Zhang, K., Zuo, W., Gu, S., and Zhang, L. (2017). Learning deep CNN denoiser prior for image restoration. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Honolulu, United States of America, pp. 3929-3938.
26. Lai, W. S., Huang, J. B., Ahuja, N., and Yang, M. H. (2017). Deep laplacian pyramid networks for fast and accurate super-resolution. *Proceedings of the IEEE conference*

- on computer vision and pattern recognition, Honolulu, United States of America, pp. 624-632.
27. Sajjadi, M. S., Scholkopf, B., and Hirsch, M. (2017). Enhancenet: Single image super-resolution through automated texture synthesis. *Proceedings of the IEEE International Conference on Computer Vision*, Venice, Italy, pp. 4491-4500.
 28. Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Honolulu, United States of America, pp. 4700-4708.
 29. Zhang, Y., Tian, Y., Kong, Y., Zhong, B., and Fu, Y. (2018). Residual dense network for image super-resolution. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Salt Lake City, United States of America, pp. 2472-2481.
 30. Tai, Y., Yang, J., Liu, X., and Xu, C. (2017). Memnet: A persistent memory network for image restoration. *Proceedings of the IEEE international conference on computer vision*, Venice, Italy, pp. 4539-4547.
 31. Liu, B., and Ait-Boudaoud, D. (2020). Effective image super resolution via hierarchical convolutional neural network. *Neurocomputing*, 374, 109-116.
 32. Tang, J., Huang, C., Liu, J., and Zhu, H. (2020). Image Super-Resolution Based on CNN Using Multilabel Gene Expression Programming, *Applied Sciences*, 10(3), 854.
 33. Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z., and Shi, W. (2017). Photo-realistic single image super-resolution using a generative adversarial network. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Honolulu, United States of America, pp. 4681-4690.
 34. Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Qiao, Y. and Loy, C. C. (2018). Esrgan: Enhanced super-resolution generative adversarial networks. *Proceedings of the European Conference on Computer Vision (ECCV)*, Munich, Germany, pp. 0-0.
 35. Hu, X., Liu, X., Wang, Z., Li, X., Peng, W., and Cheng, G. (2019, September). RTSRGAN: Real-Time Super-Resolution Generative Adversarial Networks. *Seventh International Conference on Advanced Cloud and Big Data (CBD)*, Suzhou, China, pp. 321-326.
 36. Zhu, X., Zhang, L., Zhang, L., Liu, X., Shen, Y., and Zhao, S. (2019, December). Generative Adversarial Network-based Image Super-Resolution with a Novel Quality Loss. *2019 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)*, Beitou, Taipei, pp. 1-2.
 37. Zhang, Z., Wang, Z., Lin, Z., and Qi, H. (2019). Image super-resolution by neural texture transfer. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Long Beach, United States of America, pp. 7982-7991.
 38. Zareapoor, M., Celebi, M. E., and Yang, J. (2019). Diverse adversarial network for image super-resolution. *Signal Processing: Image Communication*, 74, 191-200.

39. Zhang, Y., Liu, S., Dong, C., Zhang, X., and Yuan, Y. (2019). Multiple cycle-in-cycle generative adversarial networks for unsupervised image super-resolution. *IEEE transactions on Image Processing*, 29, 1101-1112.
40. Zhang, X., Song, H., Zhang, K., Qiao, J., and Liu, Q. (in press). Single image super-resolution with enhanced Laplacian pyramid network via conditional generative adversarial learning. *Neurocomputing*.
41. Wu, F., Wang, B., Cui, D., and Li, L. (2018, July). Single Image Super-Resolution Based on Wasserstein GANs. *2018 37th Chinese Control Conference (CCC)*, Wuhan, China, pp. 9649-9653.
42. Lian, S., Zhou, H., and Sun, Y. (2019, July). FG-SRGAN: A Feature-Guided Super-Resolution Generative Adversarial Network for Unpaired Image Super-Resolution. *International Symposium on Neural Networks*, Moscow, Russia, pp. 151-161.
43. Seddik, M. E. A., Tamaazousti, M., and Lin, J. (in press). Generative collaborative networks for single image super-resolution. *Neurocomputing*.
44. Wang, Z., Chen, B., Zhang, H., and Liu, H. (2019). Variational probabilistic generative framework for single image super-resolution. *Signal Processing*, 156, 92-105.
45. Shamsolmoali, P., Zareapoor, M., Wang, R., Jain, D. K., and Yang, J. (2019). G-GANISR: Gradual generative adversarial network for image super resolution. *Neurocomputing*, 366, 140-153.
46. Labyed, Y., and Huang, L. (2012). Ultrasound time-reversal MUSIC imaging with diffraction and attenuation compensation. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 59(10), 2186-2200.
47. Taxt, T., and Strand, J. (2001). Two-dimensional noise-robust blind deconvolution of ultrasound images. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 48(4), 861-866.
48. Abeyratne, U. R., Petropulu, A. P., and Reid, J. M. (1995). Higher order spectra based deconvolution of ultrasound images. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 42(6), 1064-1075.
49. Abeyratne, U. R., Petropulu, A. P., Reid, J. M., Golas, T., Conant, E., and Forsberg, F. (1997). Higher order versus second order statistics in ultrasound image deconvolution. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 44(6), 1409-1416.
50. Parker, K. J. (2012). Superresolution imaging of scatterers in ultrasound B-scan imaging. *The Journal of the Acoustical Society of America*, 131(6), 4680-4689.
51. Chen, S., and Parker, K. J. (2016). Enhanced resolution pulse-echo imaging with stabilized pulses. *Journal of Medical Imaging*, 3(2), 027003.
52. Chen, S., and Parker, K. J. (2017). Enhanced axial and lateral resolution using stabilized pulses. *Journal of Medical Imaging*, 4(2), 027001.

53. Michailovich, O. V., and Adam, D. (2005). A novel approach to the 2-D blind deconvolution problem in medical ultrasound, *IEEE transactions on medical imaging*, 24(1), 86-104.
54. Michailovich, O., and Tannenbaum, A. (2007). Blind deconvolution of medical ultrasound images: A parametric inverse filtering approach, *IEEE Transactions on Image Processing*, 16(12), 3005-3019.
55. Kouame, D., and Ploquin, M. (2009, June). Super-resolution in medical imaging: An illustrative approach through ultrasound. *2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, Boston, United States of America, pp. 249-252.
56. Ploquin, M., and Kouamé, D. (2010, September). Improvement of medical image resolution using an extended 2d factorized form complex number parametric model. *2010 IEEE International Conference on Image Processing*, Hong Kong, China, pp. 601-604.
57. Morin, R., Basarab, A., and Kouamé, D. (2012, May). Alternating direction method of multipliers framework for super-resolution in ultrasound imaging. *2012 9th IEEE International Symposium on Biomedical Imaging (ISBI)*, Barcelona, Spain, pp. 1595-1598.
58. Ploquin, M., Basarab, A., and Kouamé, D. (2015). Resolution enhancement in medical ultrasound imaging. *Journal of Medical Imaging*, 2(1), 017001.
59. Zhao, N., Wei, Q., Basarab, A., Kouamé, D., and Tourneret, J. Y. (2016, April). Single image super-resolution of medical ultrasound images using a fast algorithm. *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, Prague, Czech Republic, pp. 473-476.
60. Yu, C., Zhang, C., and Xie, L. (2012). A blind deconvolution approach to ultrasound imaging. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 59(2), 271-280.
61. Jensen, J. A. (2013, July). Real time deconvolution of in-vivo ultrasound images. *2013 IEEE International Ultrasonics Symposium (IUS)*, Prague, Czech Republic, pp. 29-32.
62. Yang, Z., Tuthill, T. A., Raunig, D. L., Fox, M. D., and Analoui, M. (2007). Pixel compounding: resolution-enhanced ultrasound imaging for quantitative analysis. *Ultrasound in medicine & biology*, 33(8), 1309-1319.
63. Dai, Y., Wang, B., and Liu, D. (2009, June). A fast and robust super resolution method for intima reconstruction in medical ultrasound. *2009 3rd International Conference on Bioinformatics and Biomedical Engineering*, Beijing, China, pp. 1-4.
64. Wang, B., Cao, T., Dai, Y., and Liu, D. C. (2009, September). Ultrasound speckle reduction via super resolution and nonlinear diffusion. *Asian Conference on Computer Vision*, Berlin, Heidelberg, pp. 130-139.
65. Morin, R., Basarab, A., Bidon, S., and Kouamé, D. (2015). Motion estimation-based image enhancement in ultrasound imaging. *Ultrasonics*, 60, 19-26.

66. Morin, R., Basarab, A., Ploquin, M., and Kouamé, D. (2012, February). Post-processing multiple-frame super-resolution in ultrasound imaging. *International Society for Optics and Photonics. In Medical Imaging 2012: Ultrasonic Imaging, Tomography, and Therapy*, 8320, 83201G.
67. Sharabati, W., and Bowei, X. (2018, July). Robust Weighted Regression for Ultrasound Image Super-Resolution. *2018 IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*, San Diego, United States of America, pp. 1-6).
68. Cüneyitoğlu Özkul, M., Mumcuoğlu, Ü. E., ve Sancak, İ. T. (2019). Single-image Bayesian Restoration and Multi-image Super-resolution Restoration for B-mode Ultrasound Using an Accurate System Model Involving Correlated Nature of the Speckle Noise. *Ultrasonic imaging*, 41(6), 368-386.
69. Abdel-Nasser, M., Melendez, J., Moreno, A., Omer, O. A., and Puig, D. (2017). Breast tumor classification in ultrasound images using texture analysis and super-resolution methods, *Engineering Applications of Artificial Intelligence*, 59, 84-92.
70. Yang, S., Sun, Y., Chen, Y., and Jiao, L. (2012). Structural similarity regularized and sparse coding based super-resolution for medical images, *Biomedical Signal Processing and Control*, 7(6), 579-590.
71. Zhang, Q., Li, B., Shen, M., & Yang, J. (2016, November). A novel ultrasonic image zooming algorithm based on sparse representation. *2016 3rd International Conference on Systems and Informatics (ICSAI)*, Shanghai, China, pp. 861-865.
72. Gonzalez, J., Alvarez, M., Orozco, A. (2016, November). Spatial resolution enhancement in ultrasound images from multiple annotators knowledge. *21st Iberoamerican Congress on Pattern Recognition*, CIARP, Lima, Peru, pp. 502-510.
73. Abdel-Nasser, M., and Omer, O. A. (2016, October). Ultrasound image enhancement using a deep learning architecture. *International Conference on Advanced Intelligent Systems and Informatics*, Cairo, Egypt, pp. 639-649.
74. Choi, W., Kim, M., HakLee, J., Kim, J., and BeomRa, J. (2018, October). Deep CNN-Based Ultrasound Super-Resolution for High-Speed High-Resolution B-Mode Imaging. *2018 IEEE International Ultrasonics Symposium (IUS)*, Kobe, Japan, pp. 1-4.
75. Wu, Y., Yang, F., Huang, J., and Liu, Y. (2019). Super-resolution construction of intravascular ultrasound images using generative adversarial networks. *Nan Fang yi ke da xue xue bao= Journal of Southern Medical University*, 39(1), 82-87.
76. Lu, J., and Liu, W. (2018, June). Unsupervised super-resolution framework for medical ultrasound images using dilated convolutional neural networks. *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)*, Chongqing, China, pp. 739-744.
77. Zhou, Z., Wang, Y., Yu, J., Guo, W., and Fang, Z. (2017, October). Super-resolution reconstruction of plane-wave ultrasound imaging based on the improved CNN method. *European Congress on Computational Methods in Applied Sciences and Engineering*,

Duisburg, Germany, pp. 111-120.


78. Patterson, J., and Gibson, A. (2017). Deep learning: A Practitioner's Approach. Sebastopol, CA, United States of America: O'Reilly Media, Inc.
79. İnternet: Güventürk, F. (2020). Fettah GÜVENTÜRK. Web: <https://www.fettahguventurk.com>, Son Erişim Tarihi: 01.05.2020.
80. İnternet: GeForce GTX TITAN Z. Web: <http://geforce-gtx-titan-z.blogspot.com/2014/06/geforce-gtx-titan-z-ultimate-graphical.html>, Son Erişim Tarihi: 02.05.2020.
81. İnternet: Cloud Tensor Processing Units. Web: <https://cloud.google.com/tpu/docs/tpus>, Son Erişim Tarihi: 02.05.2020.
82. Temiz, H., Bilge, H. Ş., ve Uyğur, S. (2019). Colaboratory: Makine Öğrenmesi ve Derin Öğrenme Çalışmalarında Donanım Gereksinimini Karşılama Alternatif Bir Çözüm. *3rd International Symposium on Innovative Approaches in Scientific Studies (ISAS 2019)*, Ankara, Türkiye, 568–571.
83. Szabo, T. L. (2004). Diagnostic ultrasound imaging: inside out. Boston, MA, United States of America: Academic Press, 25.
84. Abd Elsalam Alsultan, N. (2017). Development of A New Speckle Reduction Algorithm For Medical Ultrasound Images, Yayınlanmamış Yüksek Lisans Tezi, Gaziantep Üniversitesi Fen Bilimleri Enstitüsü, Gaziantep, 2.
85. Bushberg, J. T., Siebert, J. A., Leidholdt JR, E. M., and Boone, J. M. (2012). The essential physics of medical imaging (3). Philadelphia, United States of America: Lippincott Williams & Wilkins, 500-571.
86. Mikaeili, M. (2015). Doppler Ultrason Görüntüleme Sistemlerinde Yeni Bir Uyarlamalı Spektral Güç Yoğunluk Tahmin Yöntemi Kullanarak Çözünürlüğün İyileştirilmesi, Yayınlanmamış Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 3-8 .
87. Kartal, M. K., (2011). Tanısal Ultrason İçin Adaptif Güvenlik Parametresi Modelinin Oluşturulması ve Görüntü Kalitesinin Arttırılması, Yayınlanmamış Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
88. İnternet: Keras. Web: <https://www.keras.io>, Son Erişim Tarihi: 02.04.2020.
89. İnternet: TensorFlow. Web: <https://www.tensorflow.org>, Son Erişim Tarihi: 02.04.2020.
90. Temiz, H. and Bilge, H. Ş. (2020). Super Resolution of B-mode Ultrasound Images with Deep Learning. *IEEE Access*, 8, 78808 – 78820.
91. İnternet: Kingma D. P., and Ba, J. (2014). Adam: A method for stochastic optimization. Web: <https://arxiv.org/abs/1412.6980>, Son Erişim Tarihi: 02.05.2020.
92. İnternet: Geertsma T. Browse free ultrasound cases | Ultrasound Cases. Web:

<http://www.ultrasoundcases.info>, Son Erişim Tarihi:25.12.2018.


93. İnternet: Joe, A. A Gallery of High-Resolution, Ultrasound, Color Doppler & 3D Images. Web: <https://www.ultrasound-images.com>, Son Erişim Tarihi:25.12.2018.
94. Wang, Z., Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, 13(4), 600-612.
95. Wang, Z., Simoncelli, E. P., and Bovik, A. C. (2003, November). Multiscale structural similarity for image quality assessment. *The Thrity-Seventh Asilomar Conference on Signals, Systems & Computers*, Pacific Grove, CA, United States of America, 2, pp. 1398-1402.
96. Zhang, L., Zhang, L., Mou, X., and Zhang, D. (2011). FSIM: A feature similarity index for image quality assessment. *IEEE transactions on Image Processing*, 20(8), 2378-2386.
97. Reisenhofer, R., Bosse, S., Kutyniok, G., and Wiegand, T. (2018). A Haar wavelet-based perceptual similarity index for image quality assessment. *Signal Processing: Image Communication*, 61, 33-43.
98. Xue, W., Zhang, L., Mou, X., and Bovik, A. C. (2013). Gradient magnitude similarity deviation: A highly efficient perceptual image quality index. *IEEE Transactions on Image Processing*, 23(2), 684-695.
99. Sheikh, H. R., and Bovik, A. C. (2005, January). A visual information fidelity approach to video quality assessment. *The First International Workshop on Video Processing and Quality Metrics for Consumer Electronics*, Scottsdale, Arizona, 7, 2.
100. Sharabati, W., and Bowei, X. (2018, July). Robust Weighted Regression for Ultrasound Image Super-Resolution. *2018 IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*, San Diego, United States of America, pp. 1-6.
101. Xue, W., Mou, X., Zhang, L., and Feng, X. (2013). Perceptual fidelity aware mean squared error. *Proceedings of the IEEE International Conference on Computer Vision*, Sydney, Australia, pp. 705-712.
102. İnternet: Yuhas, R. H., Goetz, A. F., & Boardman, J. W. (1992). Discrimination among semi-arid landscape endmembers using the spectral angle mapper (SAM) algorithm. Web: <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19940012238.pdf>, Son Erişim Tarihi: 08.05.2020.
103. İnternet: Insana Lab: Ultrasonic Imaging - The University of Illionis at Urbana Champaign, Web: http://ultrasonics.bioengineering.illinois.edu/data_phantom.asp, Son Erişim Tarihi: 06.02.2020.



EK-1. Metotların tüm büyültme ölçeklerindeki performans grafikleri




Şekil 1.1. Metotların TestSet-I'deki performanslarının görsel sunumu.




Şekil 1.2. Metotların TestSet-II'deki performanslarının görsel sunumu.

EK-3. Test bölgelerine göre gruplanmış ortalama GKM skor grafikleri




Şekil 3.1. Eğitilen modellerin 12 yerel bölgeye ait test setlerinde elde ettikleri ortalama ERGAS skorları




Şekil 3.2. Eğitilen modellerin 12 yerel bölgeye ait test setlerinde elde ettikleri ortalama GMSD skorları

EK-3. (devam) Test bölgelerine göre gruplanmış ortalama GKM skor grafikleri




Şekil 3.3. Eğitilen modellerin 12 yerel bölgeye ait test setlerinde elde ettikleri ortalama PAMSE skorları




Şekil 3.4. Eğitilen modellerin 12 yerel bölgeye ait test setlerinde elde ettikleri ortalama SAM skorları

EK-3. (devam) Test bölgelerine göre gruplanmış ortalama GKM skor grafikleri




Şekil 3.5. Eğitilen modellerin 12 yerel bölgeye ait test setlerinde elde ettikleri ortalama SCC skorları




Şekil 3.6. Eğitilen modellerin 12 yerel bölgeye ait test setlerinde elde ettikleri ortalama SSIM skorları

EK-4. Modellere göre gruplanmış ortalama GKM skor grafikleri




Şekil 4.1. 12 yerel test setinden elde edilen modellere göre gruplanmış ortalama ERGAS skorları

EK-4. (devam) Modellere göre gruplanmış ortalama GKM skor grafikleri




Şekil 4.2. 12 yerel test setinden elde edilen modellere göre gruplanmış ortalama GMSD skorları

EK-4. (devam) Modellere göre gruplanmış ortalama GKM skor grafikleri




Şekil 4.3. 12 yerel test setinden elde edilen modellere göre gruplanmış ortalama PAMSE skorları

EK-4. (devam) Modellere göre gruplanmış ortalama GKM skor grafikleri




Şekil 4.4. 12 yerel test setinden elde edilen modellere göre gruplanmış ortalama SAM skorları

EK-4. (devam) Modellere göre gruplanmış ortalama GKM skor grafikleri




Şekil 4.5. 12 yerel test setinden elde edilen modellere göre gruplanmış ortalama SCC skorları

EK-4. (devam) Modellere göre gruplanmış ortalama GKM skor grafikleri




Şekil 4.6. 12 yerel test setinden elde edilen modellere göre gruplanmış ortalama SSIM skorları

EK-4. (devam) Modellere göre gruplanmış ortalama GKM skor grafikleri




Şekil 4.7. 12 yerel test setinden elde edilen modellere göre gruplanmış ortalama VIF skorları

EK-5. Korelasyon analizi




Şekil 5.1. ERGAS metriği üzerinde ölçülen modeller arasındaki korelasyon değerleri

EK-5. (devam) Korelasyon analizi




Şekil 5.2. GMSD metriği üzerinde ölçülen modeller arasındaki korelasyon değerleri

EK-5. (devam) Korelasyon analizi




Şekil 5.3. PAMSE metriği üzerinde ölçülen modeller arasındaki korelasyon değerleri

EK-5. (devam) Korelasyon analizi




Şekil 5.4. SAM metriği üzerinde ölçülen modeller arasındaki korelasyon değerleri

EK-5. (devam) Korelasyon analizi




Şekil 5.5. SCC metriği üzerinde ölçülen modeller arasındaki korelasyon değerleri

EK-5. (devam) Korelasyon analizi




Şekil 5.6. SSIM metriği üzerinde ölçülen modeller arasındaki korelasyon değerleri

EK-5. (devam) Korelasyon analizi




Şekil 5.7. VIF metriği üzerinde ölçülen modeller arasındaki korelasyon değerleri

EK-6. B-mod görüntüde ve RF sinyalinde elde edilen süper çözünürlüğün karşılaştırılması




Şekil 6.1. B-mod görüntü safhasında ve RF sinyali safhasında elde edilen süper çözünürlüğe dair ERGAS metriği sonuçları




Şekil 6.2. B-mod görüntü safhasında ve RF sinyali safhasında elde edilen süper çözünürlüğe dair GMSD metriği sonuçları

EK-6. (devam) B-mod görüntüde ve RF sinyalinde elde edilen süper çözünürlüğün karşılaştırılması




Şekil 6.3. B-mod görüntü safhasında ve RF sinyali safhasında elde edilen süper çözünürlüğe dair PAMSE metriği sonuçları




Şekil 6.4. B-mod görüntü safhasında ve RF sinyali safhasında elde edilen süper çözünürlüğe dair SAM metriği sonuçları

EK-6. (devam) B-mod görüntüde ve RF sinyalinde elde edilen süper çözünürlüğün karşılaştırılması




Şekil 6.5. B-mod görüntü safhasında ve RF sinyali safhasında elde edilen süper çözünürlüğe dair SCC metriği sonuçları



Şekil 6.6. B-mod görüntü safhasında ve RF sinyali safhasında elde edilen süper çözünürlüğe dair SSIM metriği sonuçları

EK-6. (devam) B-mod görüntüde ve RF sinyalinde elde edilen süper çözünürlüğün karşılaştırılması



Şekil 6.7. B-mod görüntü safhasında ve RF sinyali safhasında elde edilen süper çözünürlüğe dair VIF metriği sonuçları

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : TEMİZ, Hakan
 Uyruğu : T.C.
 Doğum tarihi ve yeri :
 Medeni hali :
 Telefon :
 Faks :
 e-mail :

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Doktora	Gazi Üniversitesi / Bilgisayar Bilimleri	Devam ediyor
Yüksek lisans	Ahmet Yesevi Üniversitesi/Bilgisayar Mühendisliği	2010
Lisans	Ahmet Yesevi Üniversitesi/Bilgisayar Mühendisliği	2014
Lisans	Anadolu Üniversitesi/ İşletme	2012
Lisans	Marmara Üniversitesi/Makine Öğretmenliği	1998
Lise	Artvin Teknik Lise ve End Mes. Lisesi, Teknik Lise	1994

İş Deneyimi

Yıl	Yer	Görev
2015-Halen	Artvin Çoruh Üniversitesi	Öğretim Görevlisi
2013-2015	Dolsar Mühendislik A.Ş.	Bilgi İşlem Koordinatörü
2009-2013	DECON Ltd.	IT Specialist
2008-2009	STUCKY Ltd.	IT Specialist
2004-2007	STUCKY Consulting Engineers	IT Support Specialist
2000-2003	ERG İnşaat Tic. San. Tur. A.Ş.	Teknik Öğretmen

Yabancı Dil

İngilizce, Çok iyi

Yayınlar

1. Temiz, H. and Bilge, H. Ş. (2020). Super Resolution of B-mode Ultrasound Images with Deep Learning, *IEEE Access*, 8, 78808-78820.
2. Temiz, H., Bilge, H. Ş., ve Uyğur, S. (2019). Colaboratory: Makine Öğrenmesi ve Derin Öğrenme Çalışmalarında Donanım Gereksinimini Karşılamada Alternatif Bir Çözüm. 3rd International Symposium on Innovative Approaches in Scientific Studies (ISAS 2019), Ankara, Türkiye, 568–571.
3. Temiz, H., Tüfekci, A., ve Bilge, H. Ş. (2018, Mayıs). Derin Öğrenme ile Süper Çözünürlük Üzerine Karşılaştırmalı Bir Çalışma. 26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, İzmir, Türkiye, pp. 1-4.



GAZİLİ OLMAK AYRICALIKTIR...