

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**HİBRİT OPTİMİZASYON YÖNTEMLERİ
KULLANILARAK ULTRASON GÖRÜNTÜLERİNİN
YENİDEN YAPILANDIRILMASI**

YÜKSEK LİSANS TEZİ

Ali Can IŞIK

**Enstitü Anabilim Dalı : ELEKTRİK – ELEKTRONİK
MÜHENDİSLİĞİ**

Bilim Dalı : ELEKTRONİK

Tez Danışmanı : Dr. Öğretim Üyesi Gökçen ÇETİNEL

Ocak 2020

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**HİBRİT OPTİMİZASYON YÖNTEMLERİ
KULLANILARAK ULTRASON GÖRÜNTÜLERİNİN
YENİDEN YAPILANDIRILMASI**

YÜKSEK LİSANS TEZİ

Ali Can IŞIK

Enstitü Anabilim Dalı

**: ELEKTRİK – ELEKTRONİK
MÜHENDİSLİĞİ**

Bu tez 28.01.2020 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.


**Dr. Öğretim Üyesi
Gökçen ÇETİNEL
Jüri Başkanı**


**Dr. Öğretim Üyesi
Burhan BARAKLI
Üye**


**Dr. Öğretim Üyesi
Mustafa Zahid YILDIZ
Üye**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Ali Can Işık

28.01.2020

TEŞEKKÜR

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Dr. Öğretim Üyesi Gökçen ÇETİNEL'e ve her türlü manevi desteğini esirgemeyen eşime ve aileme teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	x
ÖZET	xii
SUMMARY	xiii

BÖLÜM 1.

GİRİŞ	1
1.1. Kanserde Kullanılan Biyomedikal Görüntüleme Çeşitleri	1
1.2. Bilgisayarlı Ultrason Tomografisi	2
1.3. Optimizasyon.....	5

BÖLÜM 2.

YAPILAN ÇALIŞMALAR	7
2.1. Modern Yeniden Yapılandırma Yöntemleri	7
2.2. Tezin Organizasyonu	11

BÖLÜM 3.

ULTRASON TOMOGRAFİSİNDE KULLANILAN PARAKSİYEL YAKLAŞIMA DAYALI İLETİM MODELLERİ	13
3.1. Ultrason İletim Tomografisi	13
3.1.1. İleri modelin paraksiyel yaklaşımda kullanılması	14
3.1.2. Ters problemin tam kareler formunda yazılması	16
3.2. Optimizasyon Metotları	16

3.2.1. Gradyant inişı	17
3.2.2. Gauss – Newton eşlenik gradyanti	17
3.2.3. Çizgi arama yöntemleri wolfe koşulları	20
3.2.4. Yarı – Newton yöntemi	27
3.2.5. Broyden, Fletcher, Goldfarb ve Shanno Yöntem	27
3.3. Optimizasyon Problemlerinde Test Fonksiyonlarının Uygulanması ...	30
3.3.1. Ackley fonksiyonu	31
3.3.2. Beale fonksiyonu	22
3.3.3. Rosenbrock fonksiyonu	33
3.3.4. Toplam Kareler fonksiyonu	34
3.3.5. Goldstein fonksiyonu	35
3.3.6. Rastrigin fonksiyonu	36
3.3.7. Döndürülmüş hiper elipsoid fonksiyonu	37
3.3.8. Griewank fonksiyonu	38
3.3.9. Altı kamburlu deve fonksiyonu	39
3.3.10. 3 Boyutlu hartmann fonksiyonu	40

BÖLÜM 4.

DENEYSEL SONUÇLAR	41
4.1. Fantom Görüntüsü Hazırlıkları	41
4.1.1. Fantom görüntüsü 1	42
4.1.2. Fantom görüntüsü 2	42
4.1.3. Fantom görüntüsü 3.....	43
4.1.4. Fantom görüntüsü 4	44
4.1.5. Fantom görüntüsü 5	45
4.1.6. Manyetik rezonans tarama fantom görüntüsü	46
4.1.7. Test fantom görüntüsü	47
4.2. Optimizasyon Yöntemlerinin Performanslarının Karşılaştırılması...	48
4.2.1. Görüntü fantomu 1	48
4.2.2. Görüntü fantomu 2	50
4.2.3. Görüntü fantomu 3	52
4.2.4. Görüntü fantomu 4	55

4.2.5. Görüntü fantomu 5	57
4.2.6. Görüntü fantomu 6	60
4.2.7. Görüntü fantomu 7	62
4.3. Benchmark Optimizasyon Test Fonksiyonları	65
4.4. Yeniden Yapılandırma Sonuçları	71

BÖLÜM 5.

TARTIŞMA VE SONUÇ	80
-------------------------	----

KAYNAKLAR	83
-----------------	----

ÖZGEÇMİŞ	87
----------------	----

SİMGELER VE KISALTMALAR LİSTESİ

BUT	: Bilgisayarlı Ultrason Tomografisi
BFGS	: Broyden, Fletcher, Goldfarb, and Shanno
LS	: Least Square
MG	: Mamografi
MHZ	: MegaHertz
MRG	: Manyetik Rezonans Görüntüleme
NMR	: Nükleer Manyetik Rezonans
RF	: Radyo Frekansı

ŞEKİLLER LİSTESİ

Şekil 1.1.	Üç boyutlu BUT sistemi	3
Şekil 1.2.	Üç boyutlu BUT' un ölçüm işleminin şematik gösterimi	4
Şekil 1.3.	Optimizasyon problemlerinin sınırlandırılması	5
Şekil 3.1.	Paraksiyel yaklaşımın ileri model	15
Şekil 3.2.	Amaç fonksiyonunun ıraksaması	20
Şekil 3.3.	Armijo koşulu	21
Şekil 3.4.	Eğrilik koşulu	22
Şekil 3.5.	Güçlü Wolfe koşuluna dayanan çizgi arama yöntemi akış şeması ..	23
Şekil 3.6.	Güçlü Wolfe koşuluna dayanan çizgi arama yöntemi yaklaşma fonksiyonunun akış şeması	24
Şekil 3.7.	Ackley fonksiyonu	31
Şekil 3.8.	Beale fonksiyonu	32
Şekil 3.9.	Rosenbrock fonksiyonu	33
Şekil 3.10.	Toplam kareler fonksiyonu	34
Şekil 3.11.	Goldstein Price fonksiyonu	35
Şekil 3.12.	Rastrigin fonksiyonu	36
Şekil 3.13.	Döndürülmüş hiper elipsoid fonksiyonu	37
Şekil 3.14.	Griewank fonksiyonu	38
Şekil 3.15.	Altı kamburlu deve fonksiyonu	39
Şekil 3.16.	3 Boyutlu hartmann fonksiyonu	40
Şekil 4.1.	Fantom görüntüsü 1 için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu	42
Şekil 4.2.	Fantom görüntüsü 2 için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu	43
Şekil 4.3.	Fantom görüntüsü 3 için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu	44

Şekil 4.4.	Fantom görüntüsü 4 için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu	45
Şekil 4.5.	Fantom görüntüsü 5 için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu	46
Şekil 4.6.	Meme MRI Taraması için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu	47
Şekil 4.7.	Test fantomu için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu	47
Şekil 4.8.	Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu	49
Şekil 4.9.	Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu	49
Şekil 4.10.	Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu	51
Şekil 4.11.	Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu	51
Şekil 4.12.	Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu	53
Şekil 4.13.	Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu	54
Şekil 4.14.	Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu	56
Şekil 4.15.	Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu	56
Şekil 4.16.	Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu	58
Şekil 4.17.	Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu	59
Şekil 4.18.	Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu	61
Şekil 4.19.	Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu	61

Şekil 4.20.	Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu	63
Şekil 4.21.	Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu	64
Şekil 4.22.	Görüntü fantomu 1 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması	72
Şekil 4.23.	Görüntü fantomu 1 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması	72
Şekil 4.24.	Görüntü fantomu 2 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması	73
Şekil 4.25.	Görüntü fantomu 2 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması	73
Şekil 4.26.	Görüntü fantomu 3 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması	74
Şekil 4.27.	Görüntü fantomu 3 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması	74
Şekil 4.28.	Görüntü fantomu 4 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması	75
Şekil 4.29.	Görüntü fantomu 4 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması	75
Şekil 4.30.	Görüntü fantomu 5 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması	76
Şekil 4.31.	Görüntü fantomu 5 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması	76
Şekil 4.32.	MRI taraması fantomu için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması	77
Şekil 4.33.	MRI taraması fantomu için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması	77
Şekil 4.34.	Test fantomu için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması	78

Şekil 4.35. Test fantomu için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması	79
---	----



TABLolar LİSTESİ

Tablo 3.1.	Gauss-Newton Eşlenik Gradyantı Algoritması	19
Tablo 3.2.	Güçlü Wolfe koşulu çizgi arama algoritması.....	25
Tablo 3.3.	Yakınlaştırma fonksiyonu algoritması.....	25
Tablo 3.4.	Gradyant inişi ve çizgi arama algoritması	26
Tablo 3.5.	Gradyant inişi ve BFGS algoritması	29
Tablo 3.6.	Gradyant inişi , çizgi arama ve BFGS algoritması	30
Tablo 4.1.	Meme dokusunda kullanılan parametreler	41
Tablo 4.2.	Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi..	50
Tablo 4.3.	Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi..	52
Tablo 4.4.	Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi..	54
Tablo 4.5.	Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi..	57
Tablo 4.6.	Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi..	59
Tablo 4.7.	Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi..	62
Tablo 4.8.	Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi..	64
Tablo 4.9.	Ackley test fonksiyonu için elde edilen global minimum değerleri	65
Tablo 4.10.	Beale test fonksiyonu için elde edilen global minimum değerleri ..	66
Tablo 4.11.	Rosenbrock test fonksiyonu için elde edilen global minimum değerleri	66
Tablo 4.12.	Toplam kareler test fonksiyonu için elde edilen global minimum değerleri	67
Tablo 4.13.	Goldstein Price test fonksiyonu için elde edilen global minimum değerleri	68
Tablo 4.14.	Rastrigin test fonksiyonu için elde edilen global minimum değerleri	68
Tablo 4.15.	Döndürülmüş hiper elipsoid test fonksiyonu için elde edilen global minimum değerleri	69

Tablo 4.16.	Griewank test fonksiyonu için elde edilen global minimum değerleri	70
Tablo 4.17.	Altı kamburlu deve test fonksiyonu için elde edilen global minimum değerleri	70
Tablo 4.18.	Hartman 3 boyutlu test fonksiyonu için elde edilen global minimum değerleri	71



ÖZET

Anahtar kelimeler: Gradyant inişi, Broyden-Fletcher-Goldfarb-Shanno, çizgi arama, ters problem, akustik görüntüleme, en küçük kareler yöntemi.

Bu tezde, paraksiyel yaklaşıma dayalı ultrason iletim tomografisi incelenmiş ve ileri problemi çözmek için akustik dalga yayılımı modellenmiştir. İteratif olarak yeniden yapılanma için, ileri modelden elde edilen kesin ve tahmini ölçümler arasında tanımlı bir amaç fonksiyonu oluşturulmuştur. Doğrusal olmayan en küçük kareler şeklinde ifade edilen bu amaç fonksiyonu çeşitli optimizasyon yöntemleri kullanılarak minimize edilmiştir. Optimizasyon yöntemleri olarak gradyant iniş ve Gauss-Newton eşlenik gradyant yöntemleri uygulanmış ve bu yöntemler hesaplama süreleri ve yakınsama oranları açısından karşılaştırılmıştır.

Güçlü Wolfe koşulu içeren çizgi arama yöntemi ile gradyant inişi yöntemi birleştirilerek amaç fonksiyonunun yakınsaması sağlanmıştır. Bu yakınsama oranını iyileştirmek için de BFGS (Broyden-Fletcher-Goldfarb-Shanno) yöntemi, gradyant inişi yöntemi ile birleştirilmiştir. İyileşen yakınsama hızının verimini daha da arttırmak için çizgi arama yöntemi ile BFGS yöntemi birleştirilmiştir. En hızlı iteratif algoritma olarak Gradyant inişi, çizgi arama ve BFGS optimizasyon yöntemi test edilen en hızlı iteratif algoritma olarak gözlemlenmiştir. Buna ek olarak optimizasyon yöntemlerine benchmark optimizasyon test fonksiyonları uygulanmış ve karşılaştırılma yapılmıştır. Gradyant inişi, çizgi arama ve BFGS yönteminin en modern Gauss – Newton eşlenik gradyantı yöntemine kıyasla daha az iterasyon sayısı ile çözümlenmesi nedeniyle ultrason tomografisindeki görüntü rekonstrüksiyonu için umut verici bir algoritma olduğu sonucuna varılmıştır.

RECONSTRUCTION OF THE ULTRASOUND IMAGE USING NESTEROV ACCELERATED GRADIENT DESCENT

SUMMARY

Keywords: Gradient descent, BFGS, line search, benchmark optimization functions, inverse problem, ultrasound imaging, least-squares problem.

In this thesis, ultrasound transmission tomography based on paraxial approximation has been investigated and acoustic wave propagation has been modeled to solve the forward problem. For iterative reconstruction, objective function was established between precise and predicted measurements obtained from the forward model. This objective function that is least square form, has been minimized by using various optimization methods. As optimization methods, gradient descent method and Gauss-Newton conjugate gradient has been compared in terms of computational time and convergence rate.

The objective function convergence was achieved by combining the line search method with strong Wolfe condition and the gradient descent method. To improve this convergence rate, the BFGS (Broyden-Fletcher-Goldfarb-Shanno) method is combined with the gradient descent method. Line search method and BFGS method have been combined to further improve the efficiency of the improved convergence rate. Gradient descent, line search and BFGS optimization method as the fastest iterative algorithm was observed as the fastest iterative algorithm tested. In addition, benchmark optimization test functions were applied to optimization methods and compared. It has been concluded that the gradient descent, line search and BFGS method is a promising algorithm for image reconstruction in ultrasound tomography since the most modern Gauss - Newton conjugate method is analyzed with less iteration number

BÖLÜM 1. GİRİŞ

Kanser dünya genelinde ve ülkemizde görülen önemli sağlık sorunları arasında yer almaktadır. Ölümcül ya da iyileştirilemeyen bir hastalık olarak kabul görmektedir (Canatan, 2009). Türkiye’de yıl bazında ortalama 62 bin kadın ve 97 bin erkek olmak üzere toplamda 159 bin insan kansere yakalanmaktadır (Türkiye Halk Sağlığı Kurumu Kanser Daire Başkanlığı, 2016: 1). Kanser vücut içinde yayıldıktan sonra teşhis edilmesinden dolayı, birçok insanın ölümüne sebebiyet vermiştir. Dolayısıyla kanserin erken teşhisi yayılmasını engellemek için önemli bir faktördür. Kanserlerin teşhisi için daha hassas tıbbi cihazlar gereklidir (Pérez-Liva ve ark., 2017). Ultrason (US), Mamografi (MG) ve Manyetik Rezonans Görüntüleme (MRG) kanser teşhislerinde kullanılan başlıca görüntüleme yöntemleridir.

1.1. Kanserde Kullanılan Biyomedikal Görüntüleme Çeşitleri

MRG, 1970'lerde mükemmel doku kontrastı ve uzamsal çözünürlük nedeniyle biyolojik dokudan görüntülerin invazif olmayan ve kesin bir şekilde elde edilmesini sağlayan tıbbi bir görüntüleme tekniği olarak geliştirilmiştir. MR, Radyo Frekans (RF) elektromanyetik dalgalar ve manyetik alan gradyanları ile kombinasyon halinde güçlü manyetik alanlar kullanan Nükleer Manyetik Rezonans (NMR) olarak bilinen bir olguya dayanır (P. C. Lauterbur, Nature 1973). MR’ın dezavantajlarından birisi pahalı bir görüntüleme yöntemi olmasıdır.


X-ray mamografisi kanser teşhisi için sık kullanılan bir tıbbi cihazdır ve daha ileri bir teşhis için MRG cihazı kullanılabilir. X-ray mamografisi yüksek çözünürlüklü olmasına rağmen iki boyutlu iz düşüm engelinden dolayı, küçük lezyonları algılamakta zorlanır. Ayrıca mamografi cihazının yaymış olduğu radyasyon hastaya zarar vermektedir.

Bilgisayarlı Ultrason Tomografisi (BUT), test altındaki yumuşak dokuların akustik özellikleri hakkında bilgi sağlar (Gemmeke ve ark., 2007). Kanserli dokularda ses hızı ve akustik zayıflama yayılımları sağlıklı dokulara göre farklıdır. Ayrıca, BUT'un radyasyon içermemesi ve daha ucuz olması sebebiyle MR ve mamografiye göre daha avantajlıdır. Bu özelliklere sahip olan BUT, özellikle meme kanseri hastalarında, iyi huylu ve kötü huylu kitleler arasında ayırım yapılmasını sağlar.

1.2. Bilgisayarlı Ultrason Tomografisi


BUT, kanserin erken teşhisinde yeni bir potansiyel görüntüleme yöntemi olarak görülmektedir. BUT cihazları, yansıma, zayıflama ve ses hızı görüntülerinin yeniden yapılandırılmasını ve hızlı veri elde edilmesini sağlar. İlk 2D ve 2.5D sistemleri, meme üzerindeki tüm halka boyunca döndürülebilen ve kaydırılabilen bir halka üzerinde bulunan transdüserler tarafından meme kanserini tespit etmek için kullanılmıştır. Bununla birlikte, sınırlı alan derinliği ve düzlem dışı yansımaların kaybı gibi bazı sorunlar ile karşılaşmıştır (Althaus, 2016).

Bu sorunların üstesinden gelmek için, Karlsruhe Teknoloji Enstitüsü'nde (KIT) bir üç boyutlu BUT sistemi geliştirilmiştir. Üç boyutlu BUT sistemi hasta yatağına yerleştirilen yarı eliptik bir araçtan meydana gelmektedir. Görüntü işleme, su ile dolu alana hasta göğsünü koyarak uzanırken, yarı eliptik alanın içine gömülü ve 4 verici, 9 alıcı ve 157 transdüser vasıtası ile gerçekleştirilir. Üç boyutlu BUT sistemi Şekil 1.1.'de gösterilmiştir.



Şekil 1.1. Üç boyutlu BUT sistemi (Althaus, 2016).

Ölçüm aşamasında bir verici, bir su banyosuna yerleştirilen memeye küresel dalga gönderir. Bu dalga çeşitli göğüs dokularından geçerek, basınç dağılımının tespit edildiği alıcılara ulaşır. Bu işlem tüm vericiler için tekrarlanır ve basınç dağılımı iki farklı sinyal darbesinden (pulse) oluşur. İletim darbesi, hiçbir yansımaya ve saçılmaya uğramadan alıcıya ulaşan ilk darbedir. Daha sonraki darbeler, memenin çeşitli dokularından saçılan yansıma darbeleridir. Bu iki darbe arasındaki fark, üç boyutlu BUT' un ana görüntüleme yöntemini oluşturur (yansıma ve iletim tomografisi). Yansıma tomografisi memenin yapısı hakkında bilgi sağlarken, iletim tomografisinde görüntülenen ses hızı ve zayıflama görüntüleri iyi ve kötü huylu hücrelerin birbirinden ayrılmasına olanak verir (Althaus, 2016). Ölçüm aşaması sırasındaki üç boyutlu BUT'un iki ana görüntüleme yöntemi sırasıyla Şekil 1.2.'de gösterilmektedir.



Şekil 1.2. Üç boyutlu BUT' un ölçüm işleminin şematik gösterimi (a) ve algılanan basıncın alıcıdaki dağılımı (b) (Althaus, 2016).


BUT ölçüm verilerinden ses hızı ve zayıflama profillerinin görüntüsünün yeniden oluşturulması hedeflenmektedir. Profiller ve ultrason sinyalleri arasındaki fiziksel etkileşimi taklit eden ileri bir model göz önüne alındığında, ölçümler profillere göre tahmin edilebilir. Yeniden yapılanma, elde edilen tahmini ölçümlerin mümkün olduğunca kesin ölçümlere yakın olacak şekilde elde edilmesine imkân sağlamaktadır. Dolayısıyla bu sapmayı minimize etmek için optimizasyon metotlarına ihtiyaç duyulmaktadır. Daha önceki çalışmalarda, görüntünün yeniden yapılandırılması Gauss-Newton eşlenik gradyantı kullanılarak yapılmıştır (Althaus, 2016). Althaus' un çalışmasından farklı olarak bu çalışmada iterasyon sayısı ve hesaplama süresi açısından daha iyi bir performans elde etmek için Gauss-Newton eşlenik gradyant kullanmak yerine gradyant inişi yöntemi kullanılmıştır. Bunun sebebi Gauss-Newton eşlenik gradyantının her iterasyonunda bir iç döngü içermesinden dolayı ve eşlenik gradyant için, Jacobian ve Hessian matrislerinin hesaplanması daha karmaşıktır. Diğer bir taraftan gradyant inişi metodu sadece gradyant hesaplaması gerektirdiğinden daha basittir. Daha iyi performans elde etmek için, uygun adım büyüklüğünün seçilmesine imkân sağlayan çizgi arama yöntemleri ve BFGS yöntemi, gradyant inişi yöntemine uyarlanmıştır. Ayrıca BFGS yöntemi ile gradyant inişi, Gauss-Newton eşlenik gradyantına göre daha az iterasyon sayısı gerektirir.

1.3. Optimizasyon

Optimizasyon, herhangi bir problem için mevcut alternatif çözümler kümesinden en iyi çözümün seçilmesi süreci olarak tanımlanabilir. Optimizasyon kelime karşılığı olarak “en iyileme” şeklinde ifade edilebilir.

Günümüzde; optimizasyonun başlıca kullanıldığı alanlar olarak elektronik, tıp, savunma sanayii, bilişim sistemleri ve ekonomi gelmektedir. Basit örnekler verilecek olursa yazılım alanında yapılan optimizasyonlarla işlem sürelerinin kısalması ve performansının artması sağlanmıştır. Tıbbi cihazların ise optimize edilerek daha iyi tahminleme ve teşhis yapabilme olanakları doğmuştur. Gün geçtikçe optimizasyon popülaritesini artırarak devam etmektedir.

Bir optimizasyon problemi genel olarak amaç fonksiyonu, tasarım değişkenleri ve kısıtlardan oluşmaktadır. Optimizasyon probleminin tanımlanması ve çözümünde kullanılacak yöntemin belirlenmesi amaç fonksiyonu, tasarım değişkenleri ve var ise kısıtların yapısına göre gerçekleştirilir.



Şekil 1.3. Optimizasyon problemlerinin sınıflandırılması

Yukarıda verilen Şekil 1.3.' e göre bu çalışmada fonksiyonu yer doğrusu olarak kullanarak (ground truth) deneme yanılma yöntemi vasıtasıyla gerçek görüntü ile tahmini görüntü arasındaki farkı azaltarak en iyi hala getirebilmeye çalışılmıştır.

Optimizasyon algoritmaları sayesinde karar değişkenlerimizin parametrelerini daha net şekilde belirlemeye çalışabiliriz. Karar değişkenlerinin kullanılmasıyla oluşacak birden fazla çözümlerin birbiriyle karşılaştırmasını sağlamak amacıyla amaç fonksiyonunun tanımlanması gerekir. Amaç fonksiyonları da problemin türüne göre değişiklik göstermektedir. Örneğin bir problemde amaç fonksiyonu zaman ise en kısa zaman gerektiren çözümlerin kıyaslanması gerekirken, amaç fonksiyonu maliyet fonksiyonu ise en düşük sonucu üreten çözüm en iyi çözümdür.

BÖLÜM 2. LİTERATÜR İNCELEMESİ

Bu bölümde tez kapsamında hedeflenen çalışma ile benzer yöntemler içeren çalışmalar kısaca özetlenerek tezin kapsamı hakkında bilgi verilmiştir.

2.1. Modern Yeniden Yapılandırma Yöntemleri

Yeniden yapılandırma yöntemlerinde birçok optimizasyon metodu kullanılmaktadır. Yeniden yapılandırma için yaygın kullanılan optimizasyon yöntemleri olarak gradyant inişi, lineer olmayan eşlenik gradyant ve Gauss Newton eşlenik gradyantıdır. Örnek olarak, Akçelik ve arkadaşları dalga yayılımının ters çevrilmesini paralel çok ölçekli Gauss – Newton – Krylov yöntemleri ile hesaplanmasıyla pelvis kemiğinin görüntüsünün oluşturulmasını sağlamışlardır. Kısmi diferansiyel denklemler tarafından yönetilen sistemlerin hesaplanmasının en büyük zorluklarından biri büyük ölçekli doğrusal olmayan parametre tahminidir. Bunlar, genellikle büyük ölçekli simülasyonu karakterize eden ileri problemlerin aksine, ters problemler olarak bilinir. Ters problemler, büyük yoğun kötü konumlandırılmış operatörler, çoklu minimum noktaları, uzay-zaman bağlamı ve ileri problemi tekrar tekrar çözme ihtiyacı nedeniyle ters problemlerin çözülmesi önemli ölçüde daha zordur. Zamana bağlı kısmi diferansiyel denklemlerin yönettiği ters problemler için paralel bir algoritma ve bir akustik ortamın malzeme alanını belirlemede ters dalga yayılma problemi için ölçeklenebilirlik sonuçları sunmuşlardır. Yukarıda belirtilen zorluklar, toplam değişkenlik düzenlenmesini, önceden şartlandırılmış matris içermeyen Gauss-Newton-Krylov yinelemesini, algoritmik kontrol noktası belirleme ve çok ölçekli sürdürme birleşimiyle ele alan bir çalışma yapmışlardır (Akçelik ve ark., 2002).

Virieux ve Operto jeofizik alanında tam dalga ters çevrimi ile ilgili araştırma yapmıştır. Tam dalga ters çevrimi sismogramlardan (sismografların grafik çıktısı) sayısal bilgileri çıkarmak için tam dalga alanı modellemesine dayanan zorlu bir veri

uyarlama prosedürüdür. Yayılan dalga boyunun yarısında yüksek çözünürlüklü görüntüleme beklenmektedir. Yüksek performanslı işlemler ve çok katlı / çok bileşenli geniş açıklıklı geniş Azimuth kazanımlarındaki son gelişmeler, bugün 3 boyutlu akustik tam dalga ters çevrimini mümkün kılmaktadır. Tam dalga ters çevriminin kilit bileşenleri verimli bir modelleme motorudur ve gradyan ile Hessian operatörlerinin verimli bir şekilde tahmin edildiği yerel bir diferansiyel yaklaşımdır. Bu noktada Virieux ve Operto optimizasyon metotlarına başvurmuşlardır. Yerel optimizasyon, başlangıç modelinin sınırlı doğruluğu, düşük frekans eksikliği, gürültünün varlığı ve dalga fiziği karmaşıklığının yaklaşık modellenmesi nedeniyle fonksiyonun yerel minimum noktasına yaklaşmasını engellemektedir. Bu nedenle farklı hiyerarşik çoklu ölçek stratejileri, tam dalga ters çevriminde doğrusal olmayan ve iyi konumlandırılmamış dalgaları azaltabilmek için parametre alanına aşamalı olarak daha kısa dalga boyları dahil ederek tasarlanmıştır. Yeniden yapılandırılma çalışmalarında sentetik ve gerçek veri kullanılırken yoğunluğa, anizotropi ve zayıflama faktörlerini kullanmışlardır. Optimizasyon yöntemleri olarak Newton, Gauss – Newton, gradyant inişi yöntemlerini kullanmışlardır. Başlıca karşılaştığı problemler ise ilk olarak doğru başlangıç modelleri oluşturmak, düşük frekansları kaydetmekte yaşadıkları zorluklardır. İkincil yaşadıkları problemler ise tam dalga ters çevriminin genlik hatalarına olan duyarlılığı azaltmak ve sağlamlaştırmak için yeni en aza indirme kriterleri tanımlamaktır (Virieux ve ark., 2009).

Sandhu ve arkadaşları (2015), frekans alanlı ultrason dalga formu tomografisinde meme görüntüleme çalışması yapmıştır. Frekans bölgesi akustik dalga denkleminin ultrason tomografi taramalarından elde edilen verilere uygulanmasının, en yüksek yeniden yapılandırılmış frekansın dalga boyunun sırasına göre yüksek çözünürlüklü ses hızı görüntüleri sağladığı gösterilmiştir. 0,4–1 MHz sinyal bant genişliği ve ortalama 1500 m/s ses hızı kullanarak, çözünürlük yaklaşık 1,5 mm 'dir. Nicel ses hızı değerleri ve bu görüntüler tarafından sağlanan morfoloji, meme hastalığının teşhisini ve sınıflandırılmasını bildirme potansiyeline sahiptir. Bu çalışmada, halka transdüserlerini kullanan iki farklı ultrason tomografi tarayıcısı tarafından toplanan meme verilerine uygulanan dalga formu tomografisinin formalizmi, pratik uygulaması ve vivo sonuçları sunulmaktadır. Formalizm, sonlu fark operatörleri kullanarak dalga

denkleminin frekans bölgesi modellemesinin bir incelemesini ve yinelemeli yeniden yapılanma şeması için gradyant iniş yönteminin bir incelemesini içerir. Dalga şekli tomografisinin pratik uygulamasının doğru bir başlangıç modeli, dikkatli veri işleme ve ses hızını yeniden yapılandırmaya kademeli olarak daha yüksek frekans bilgisini dahil etmek için bir yöntem gerektirdiği görülmüştür. Bu adımların ardından memenin yüksek çözünürlüklü nicel ses hızı görüntüleri elde etmişlerdir. Bu görüntüler yaygın olarak kullanılan ışın tomografisinin yeniden yapılandırma yöntemlerine göre belirgin bir iyileşme göstermektedir. Yöntemin sağlamlığı için iki farklı ultrason tomografi cihazından benzer sonuçlar elde edilerek gösterilmiştir (Sandhu ve ark.,2015).

Sandhu ve arkadaşları (2017) diğer bir çalışmada da tomografi prensiplerini bir halka dizisi ultrason dönüştürücü dizisi ile birleştirerek, araştırmacılar ultrason tomografisinin nispeten yeni bir yöntemini yaratmışlardır. Bu teknik ışının seyahat süresini temel alarak bir memenin ses hızını ve zayıflama özelliklerini ölçmenin yanı sıra tipik B modu yansıma görüntüleri üretme özelliğine de sahiptir. B-modu, probdan gelen ses dalgalarının dokular içinde yayılma ve yansıma ile geri dönerek iki boyutlu (2D) bir görüntü oluşturmaktadır. Bu görüntüler, dokuların sese tepkisine göre ekranda değişik parlaklıktaki gri tonlar şeklinde oluşmaktadır. Seyahat süresi tekniklerinin aksine, frekans bölgesi dalga formu tomografi teknikleri, dalga yayılımının fizikini daha doğru bir şekilde modellemektedir. Gradyant inişinin evrilmiş algoritmaları gerçek ve sentetik olarak üretilen akustik basınç alanları arasındaki fark olarak tanımlanan bir Amaç fonksiyonunu iteratif bir şekilde en aza indirerek, ultrason yöntemi ile incelenmiş bölgenin daha doğru ses hızı dağılımlarını yeniden oluşturmaya izin verir. Gradyant inişi algoritmaları ses hızının imajiner kısma sahip olmasını sağlayarak ortamın içsel zayıflamasının modellenmesine olanak sağlar. 2B varsayımı ayrıca düzlemden kaybedilen veya kazanılan enerjinin yeniden yapılandırılma algoritması tarafından düzgün bir şekilde hesaba katılmadığı durumlarda zayıflama görüntüleme için bir sorundur. Sandhu ve arkadaşları görüntünün yeniden yapılandırılmasında gradyant iniş yöntemi kullanmıştır. Sonuç olarak Sandhu ve arkadaşları görüntünün yeniden yapılandırılmasında daha az hassasiyet problemi ve zaman problemleriyle karşılaşmışlardır. Ayrıca kesit olarak

alınan görüntü ile görüntünün tamamı alındığında da süre olarak çok marjinal bir artış problemi gözlemlemişlerdir (Sandhu et ark., 2017).

Li ve arkadaşları dalga biçimi zayıflama tomografisini kullanarak meme görüntüsünü yeniden yapılandırmışlardır. Grandyant azalması metodunu kullanmışlardır. Dalga formu zayıflama görüntüsünün çok daha yüksek çözünürlüğe sahip olduğu ve meme lezyonu sınırlarına karşılık gelen ışın bazlı zayıflama görüntüsünden daha iyi tanımlayabildiğini göstermektedir. Bu çalışmada, bir halka dizisi ile elde edilen zaman alanı dalga formlarını önceden işlenmiştir ve elde edilen dalga alanlarına göre hesaplanan dalga alanlarını daha iyi eşleştirmek için yönlü dönüştürücü ışın düzenini kullanmışlardır. Dalga formu zayıflatmasını verilere uygulamışlar ve ortaya çıkan dalga şekli zayıflama görüntülerini, dalga biçimi zayıflatma rekonstrüksiyonunun çözünürlüğünü ve doğruluğunu değerlendirmek için ışın temelli kısımlarla karşılaştırmışlardır. Asimptotik bir yaklaşıma dayanan ışın tomografisine kıyasla, dalga formu tomografisi, algılanan dalga ile tam dalga denklemini modellemektedir. Her ne kadar ses hızı memedeki çeşitli dokuların ayırt edilmesine yardımcı olsada, kistler, fibroadenomlar ve kanserler gibi dokuların ses hızı değerlerinde örtüşme vardır. Zayıflama, bu lezyonları benzer ses hızlarında daha fazla karakterize etmeye yardımcı olmak için esastır. Toplam zayıflamayı yeniden yapılandıran ışın azaltma algoritmasından farklı olarak (yansıma, saçılma ve içsel zayıflamayı içeren toplam enerji kaybına dayanarak), dalga biçimi zayıflatma algoritması doku içsel zayıflamasını yeniden yapılandırabilir (Li ve ark., 2017).

Wiskin ve arkadaşları (2017) yeni bir 3D ultrason teknolojisi olan kantitatif iletim ultrason sistemi ve bir su banyosunda asılı bir göğsün görüntülenmesi için algoritma tanımlamışlardır. Nicel olarak doğruluğu fantom ile sağlamlarken, morfolojik doğruluk memenin vivo görüntüleriyle sağlamışlardır. Teşhis için kullanılan el tipi ultrasonlarda, göğüs görüntülerinin elde edilmesi ve belgelenmesi zaman alıcı ve operatöre bağımlıdır. Ayrıca bu el tipi ultrasonların görüş alanının küçük olması, dokudaki lezyonların görüntülenmesini zorlaştırmıştır. General elektriğin ve Siemens'in üretmiş olduğu bu otomatik göğüs tarama sistemleri, doğru 3 boyutlu veri elde edemezler ve dokunun sertliği ile ilgili niceliksel bilgi sağlamamaktadırlar. 2

boyutlu kuantatif ters saçılma metotlarında gelişmeler olmasının yanında, kırınımı hesaba katmayan ters problem yöntemleride kullanılmıştır. Tam dalga ters saçılma çözümü kullanmayan diğer yöntemler de araştırılmıştır. Wiskin ve arkadaşlarının (2017) ters saçılma yöntemi, göğüsün 3 boyutlu volumetrik yapısını ve dokular hakkında niceliksel bilgi sağlamıştır. Bu, radyologlara, doku elastikiyetiyle ilgili ek bilgiler ve meme dokusunun değerlendirilmesinde meme lezyonlarının karakterizasyonunda yardımcı olarak kullanılabilecek ve sonuçta özgüllüğü artıran biyobelirteçler sunar. Ayrıca, doğrusal olmayan eşlenik gradyantin Ribiere-Polak (RP) versiyonunu kullanarak ileri modelin paraksiyel yaklaşımını gerçekleştirmişlerdir. Fakat zayıflama görüntüsünün ses hızı görüntüsüne göre daha zor hesaplandığını keşfetmişlerdir (Wiskin ve ark., 2017).

Althouse (2016) aynı paraksiyel yaklaşıma dayanan Gauss – Newton eşlenik gradyanti kullanarak görüntünün yeniden yapılandırılması üzerinde çalışmalar yapmıştır. Ters problem yaklaşımı ile görüntünün yeniden yapılandırılması çok zaman aldığından, optimizasyon metodunu modifiye ederek daha az iterasyon sayısı ile bu teknolojiyi ileri taşınması amaçlanmıştır. Bu çalışmada, Althouse (2016)'un çalışmasından yola çıkılarak paraksiyel yaklaşıma dayanan ileri model ultrason dalga yayılımı araştırılmıştır. İteratif olarak yeniden yapılandırılma için gerçek ölçümler ileri modelden simule edilmiştir ve her iterasyonda yenilenen tahmini ölçümlerle karşılaştırılmıştır. Bu ters problem yaklaşımı lineer olmayan en küçük kareler (least square) yöntemi ile çözümlenmiştir. Gradyant inişi, Gauss Newton eşlenik gradyanti, gradyant inişi ve BFGS, gradyant inişi ve çizgi arama ve gradyant inişi , BFGS ve çizgi arama metotları karşılaştırılmıştır. Ek olarak çizgi arama yöntemi olan güçlü Wolfe koşulu (Nocedal ve Wright, 2000) her iterasyonda adım büyüklüğünü seçmek için bu optimizasyon yöntemleriyle birlikte kullanılmıştır.

2.2. Tezin Organizasyonu

Bu tezde gradyant inişi metodu ile BUT' da ki ses hızı ve zayıflama profillerinin yeniden yapılandırılması üzerinden çalışılmıştır. Materyal ve yöntemler kısmında ileri modelin paraksiyel yaklaşımına dayanan akustik dalga yayılımı gösterilmiştir. Amaç

fonksiyonu lineer olmayan en küçük kareler yöntemi ile oluşturulmuştur. Daha sonra optimizasyon yöntemleri tanıtılmış ve amaç fonksiyonunu minimize etmek için Gauss-Newton eşlenik gradyanı, gradyant inişi, çizgi arama ve BFGS metotları kullanılmıştır. Eşlenik metodu ile optimizasyon metotları için gerekli olan gradyanların nasıl hesaplanacağı açıklanmıştır. Sonuç bölümünde bütün optimizasyon yöntemleri, 7 farklı fantom üzerinde iterasyon sayıları ve hesaplama süreleri açısından karşılaştırılmıştır. Yeniden yapılandırılan ses hızı ve zayıflama profilleri gerçek yer doğrusuna göre analiz edilmiştir. Sonuç bölümünde ise en iyi optimizasyon yöntemi deneysel sonuçlara göre tartışılmıştır.



BÖLÜM 3. ULTRASON TOMOGRAFİSİNDE KULLANILAN PARAKSİYEL YAKLAŞIMA DAYALI İLETİM MODELLERİ

Bu bölümde, ultrason tomografisinde kullanılan paraksiyel yaklaşıma dayalı iletim modelleri anlatılmıştır. Gerçek ve tahmini ölçümler arasındaki sapma, en küçük kareler yöntemi ile oluşturulmuştur. İteratif olarak yeniden yapılandırma için gerekli olan optimizasyon yöntemleri araştırılmıştır. Bu yöntemler Gauss Newton eşlenik gradyant, gradyant inişi, Wolfe koşullarına dayalı çizgi arama yöntemleri ve BFGS dir.

3.1. Ultrason İletim Tomografisi

Ultrason iletim tomografisinin temel prensibi, yansıma ve saçılmadan oluşan ultrason dalga yayılımına dayanır (Suetens, 2009). Fakat dalga denklemlerinin tam çözümü çok zordur. Dalga denklemlerinin sayısal çözümü son zamanlarda mümkün hale gelmiştir (vanDongen ve Wright, 2007). Dalga denklemlerinin çözümü için birçok yaklaşım bulunmaktadır. Bunlardan bazıları doğrusal ışın, Born, Rytov ve paraksiyel yaklaşımdır. Doğrusal ışın tomografisi en kısıtlayıcı yaklaşımdır. Ultrasonun yayıcıdan alıcıya geçtiği yol, homojen kabul edilen bir ortamda ışının kırılması ihmal edilerek modellenir. Bu çok sık kullanılan metot olmasının yanında, sınırlı bir görüntü çözünürlüğüne sahiptir (Dapp, 2013). Born yaklaşımı, zayıf saçılma ve kırılmayı varsayarak aynı zamanda çoklu saçılmayı ihmal ederek, dalga denkleminin çözümünü basitleştirir. Bu yöntem, kırınım ile başa çıkarak ışın tabanlı yaklaşımlara kıyasla oldukça daha yüksek bir çözünürlük elde edebilmesine rağmen, düşük kontrast farkları olan görüntüleri yeniden oluşturmada başarısız olur (Duric ve ark., 2011). Dalga denklemlerinin yaklaşık çözümü için kullanılan Rytov yaklaşımı genellikle, sadece tek bir dalga boyunda faz değişiminin küçük olduğu durumda geçerlidir. Fakat hesaplama zorluğundan dolayı 2 boyutlu görüntüleme ve düşük frekanslarda sınırlandırılmıştır

(Simonetti, 2008). Paraksiyel yaklaşım, dalga yayılımını baskın olarak bir yönde hesaplayarak ve dalganın dilim-dilim iteratif aktarımıyla, hesaplama zorluğunu azaltmaktadır. BUT için, paraksiyel yaklaşım, sensörlerin sınırlı açılma açısı yönlülüğüne bağlı olarak uygun görünmektedir ve tüm akustik etkiler (kırılma, kırınım) dahil edildiğinden 3 boyutlu BUT için transmisyon tomografisini iyileştirme konusunda en umut verici adaydır.

3.1.1. İleri modelin paraksiyel yaklaşımda kullanılması

İletim tomografisinde elde edilen doku görüntülerinin ses ve zayıflama profilleri dokunun yapısı hakkında bize bilgi sağlar. İteratif olarak iletim tomografisinin yeniden yapılandırılması için, Helmholtz denklemleri, akustik ortamda yansıma, kırınım ve çoklu saçılma ile birlikte ultrasonun dalga yayılımı olarak tanımlanabilir (Althaus, 2016; Gemmeke ve ark., 2016).

$$\Delta p + k_0^2(1+\eta)^2 p = 0 \quad (3.1)$$

Burada (Denklem 3.1) ;

p : frekansa bağlı basınç alanı,

$k_0 = \frac{\omega}{c}$: akustik ortam için arka plan dalga numarası

$1+\eta$: yansıma indeksi, η homojensizliğin arka plan ortamından sapmasını ifade eder. Medikal görüntüleme için, Helmholtz denklemlerinin tam çözümü yüksek hesaplama maliyeti ve efor gerektirdiğinden, paraksiyel yaklaşım tercih edilmiştir (Althaus, 2016; Fichtner, 2011). Bu yaklaşım, transdüserlerin dairesel veya küresel bir geometrisini kullanırken, küresel dalgalar için Helmholtz denklemlerinin çözümü olarak tanımlanabilir. Basınç alanı denklemlerinin paraksiyel yaklaşımından ifade edilirse (Althaus, 2016; Gemmeke ve ark., 2016).

$$P = u e^{ik_0 z} \quad (3.2)$$

Burada (Denklem 3.2) ;


p : Frekansa bağılı basınç alanı,

$k_0 = \frac{\omega}{c}$: Akustik ortam için arka plan dalga numarası (akustik ortam tanımlanması için)

u : Karmaşık değerli genliği ve dalga vektörünü

z : Paraksiyel yönü yani z eksenini belirtir.

Meme su arka plan ortamına yerleştirilir. Akustik dalga alanı, emiterden alıcıya ilgilenilen bölge (İB) içerisinde heterojen ortamdan geçerek gönderilir. Paraksiyel yaklaşım ilgilenilen bölge (İB) içerisinde uygulanır ve dilim dilim yayımlanır. Paraksiyel yaklaşımın ileri modeli Şekil 3.1. 'de gösterilmiştir (Gemmeke ve ark., 2016).



Şekil 3.1. Paraksiyel yaklaşımın ileri modeli (Gemmeke ve ark., 2016).

Paraksiyel yaklaşım ayrıca basınç alanı p 'nin, Helmholtz denklemini çözen bir düzlem dalgadan sapması olarak da ifade edilir (homojen ortam için $\eta=0$). İleri model çözümü iki boyutlu problemler için aşağıdaki gibi hesaplanabilir (Gemmeke ve ark., 2016).

$$p_{k+1} = e^{ik_0 \eta_k \Delta z} \text{ifft} \left\{ e^{ik_0 \sqrt{\frac{\xi^2}{k_0^2} \Delta z}} \text{fft} \{p_k\} \right\} \quad (3.3)$$

Burada (Denklem 3.3) k indeksi p ve η değişkenleri için dikkate alınan z dilimini ifade ederken, ξ spektral değişken, fft ve $ifft$ sırasıyla ayırık Fourier dönüşümünü ve ters ayırık Fourier dönüşümünü ifade eder.

3.1.2. Ters problemin tam kareler toplamı formunda yazılması

BUT sisteminin birçok verici alıcı çiftinden alınan basınç dağılım ölçümlerinden, homojen olmama tahmini süreci η ters problemidir. Ses ve zayıflama profilleri η 'dan türetilir. Bu ters problemi çözmek için (Denklem 3.4) tahmini basınç alanları ile alıcılarda alınan kesin ölçümler arası sapma, doğrusal olmayan en küçük kareler toplamı formunda tanımlanır.

$$f(\eta) = \|p_r(\eta) - d\|^2 \quad (3.4)$$

Amaç fonksiyonumuz $f(\eta)$ 'i minimize etmek için çeşitli optimizasyon algoritmaları kullanılabilir. Daha önceki çalışmalarda Gauss Newton eşlenik inişi metodu uygulanmıştı. Bu projede gradyant inişi, çizgi arama ve BFGS metodu uygulanacak ve optimizasyon performansları karşılaştırılacaktır.

3.2. Optimizasyon Metotları

Optimizasyon yöntemlerinin amacı, belirli bir aralıkta giriş değerini sistematik olarak seçerek tanımlı bir amaç fonksiyonunun değerini maksimize etmek veya minimize etmektir. Bu tez çalışmasında, yeniden yapılanmanın gerçekleştirilmesi için amaç fonksiyonumuzun minimuma indirilmesi gereklidir. Daha kolay anlaşılması için, vadi üzerindeki bir topun yokuş aşağı adım adım düşmesi olarak düşünülebilir. Ancak, her adımda, farklı optimizasyon yöntemleri farklı adımlarla yokuş aşağıya doğru farklı “yönlerde” ilerler ve fonksiyonların en aza indirilmesi sırasında farklı davranışlar sergiler. Bu bölümde optimizasyon yöntemlerinin temel prensipleri araştırılacaktır.

3.2.1. Gradyant inişi

Gradyant inişi, mevcut amaç fonksiyonunun yerel minimuma yakınsaması için kullanılır. Minimum değere ulaşmak için her yinelemede alınan yön boyunca, adım boyutunu belirlemek için bir parametre gereklidir (Denklem 3.5). Diğer bir deyişle gradyant inişinin amacı amaç fonksiyonunun yarattığı yüzey üzerinde gradyant yönlerini izleyerek minimum noktayı bulmaktır (Ruder, 2016).

$$x_{k+1} = x_k - \alpha_k \nabla f(x_k) \quad (3.5)$$

Adım büyüklüğü $\alpha_k > 0$ yakınsama oranını kontrol etmek için önemli bir parametredir. Bir yandan çok küçük bir parametre değeri algoritmanın çok yavaş yakınsamasına neden olur. Öte yandan çok büyük bir parametre değeri algoritmanın yakınsaması yerine ıraksamasına neden olur. Dolayısıyla her iterasyonda azalan bir amaç fonksiyonu değeri elde etmek için adım büyüklüğü uygun olarak seçilmelidir (Ruder, 2016).

3.2.2. Gauss-Newton eşlenik gradyantı

Gauss-Newton eşlenik gradyantı, amaç fonksiyonu olarak verilen doğrusal olmayan en küçük kareler problemini en aza indirmek için kullanılır. İkinci mertebeden türevlerin hesaplanmasını gerektirmeyen bu yöntem Newton yönteminin modifikasyonu olarak da ifade edilir. Amaç fonksiyonu, doğrusal olmayan fonksiyonların karelerinin toplamı olarak yazılabilir (Siregar ve Ramli, 2018).

$$f(x) = \frac{1}{2} \sum_{j=1}^m r_j^2 \quad (3.6)$$

Burada (Denklem 3.6), r_j residual vektör olup, Denklem 3.4'deki gibi ifade edilebilir $r = p(\eta) - d$. Bu tezde, x yerine η olarak kabul edilmiştir. Yani tahmin etmek istediğimiz veya optimize etmek istediğimiz değerdir. Dolayısıyla r gerçek ölçüm ile tahmini ölçüm arasındaki farktır (Denklem 3.7).

$$r(x) = (r_1(x), r_2(x), \dots, r_m(x))^T \quad (3.7)$$

Residual gradyanı, tüm residuallerin $\nabla r_j(x)$, Jacobian matrisini kullanarak hesaplanabilir (Denklem 3.8). Jacobian matrisi ayrıca residuallerin parametrelere göre kısmi türevleri olarak bilinir.

$$J(x) = \left[\frac{\partial r_j}{\partial x_i} \right]_{j=1, \dots, m; i=1, \dots, n} = \begin{bmatrix} \nabla r_1(x)^T \\ \nabla r_2(x)^T \\ \vdots \\ \nabla r_m(x)^T \end{bmatrix} \quad (3.8)$$

Amaç fonksiyonunun $f(x)$ gradyanı ve Hessian matrisleri Denklem 3.9 ve Denklem 3.10' daki gibi hesaplanır (Siregar ve Ramli, 2018).

$$\nabla f(x) = \sum_{j=1}^m r_j(x) \nabla r_j(x) = J(x)^T r(x) \quad (3.9)$$

$$\begin{aligned} \nabla^2 f(x) &= \sum_{j=1}^m r_j(x) \nabla r_j(x)^T + \sum_{j=1}^m r_j(x) \nabla^2 r_j(x) = J(x)^T J(x) + \\ &\sum_{j=1}^m r_j(x) \nabla^2 r_j(x) \end{aligned} \quad (3.10)$$

Gauss-Newton arama yönünü bulmak için Denklem 3.11' deki yaklaşıma dayanır.

$$J(x_k)^T J(x_k) p_k^{GN} = J(x_k)^T r(x_k) \quad (3.11)$$

Tablo 3.1. Gauss-Newton Eşlenik Gradyantı Algoritması

Gauss-Newton Eşlenik Gradyantı
1. İterasyon sayacını ayarla $k = 0$, başlangıç tahminini yap x_0, 2. $(J(x_k)^T J(x_k) p_k^{GN} = J^T(x_k) r(x_k))$ Lineer eşlenik gradyantı kullanarak arama yönü p_k^{GN} bulmak için çöz 3. Hesapla $x_{k+1} = x_k + p_k^{GN}$ 4. İterasyon sayacını güncelle $k = k + 1$ 5. $f(x_k) < \epsilon$ olduğu sürece, adım 2 ye git

Algoritma 1’de ikinci adımda doğrusal olmayan en küçük kareler problemi (Denklem 3.12) çözümüne karşılık gelir (Nocedal ve Wright, 2000; Siregar ve Ramli, 2018).

$$\min \frac{1}{2} ||J(x_k)p - r(x_k)||^2 \quad (3.12)$$

Gauss Newton metodu için gerekli olan arama yönünü p_k^{GN} elde etmek için eşlenik gradyantı olarak bilinen $Ax = b$ problemini ele alalım.

Burada ;

$$A = J(x_k)^T J(x_k),$$

$$x = p_k^{GN},$$

$$b = J^T(x_k) r(x_k)$$


olarak tanımlanır ve çözümü Denklem 3.13’ ün minimizasyonuna karşılık gelir (Nocedal ve Wright, 2000).

$$\min f(x) = \frac{1}{2} x^T A x - b^T x \quad (3.13)$$

Gauss-Newton eşlenik gradyanti, Denklem 3.11' i çözmek için $\text{pcg}(A, b, \text{tol})$ gibi MATLAB'ta yer alan eşlenik gradyant işlevi gören fonksiyon kullanılarak uygulanabilir. Burada A amaç fonksiyonu, Hessian matrisine karşılık gelen $J(x_k)^T J(x_k)$ olmalıdır, diğer taraftan B matrisi de Amaç fonksiyonunun gradyantına $J^T(x_k)r(x_k)$ karşılık gelmelidir.

3.2.3. Çizgi arama yöntemleri ve wolfe koşulları

Çizgi arama yöntemleri her iterasyonda adım büyüklüklerini belirlemek için kullanılır. Verilen arama yönü boyunca ne kadar gideceğini hesaplar. Çok küçük adım büyüklüğü fonksiyonun yavaş yakınsamasına sebep olurken, çok büyük adım büyüklüğü ıraksamasına neden olur. Adım büyüklüğünü uygun bir şekilde seçilmesine ve aynı zamanda amaç fonksiyonunun yeterli miktarda azalmasına imkân verilmelidir. Çizgi arama yöntemleri de buna izin verir. Uygun adım büyüklüğünün eksikliğinden kaynaklı amaç fonksiyonunun yakınsaması yerine ıraksaması Şekil 3.2.' de gösterilmiştir.



Şekil 3.2. Amaç fonksiyonunun ıraksaması


Armijo koşulu amaç fonksiyonunun yeterli miktarda azalmasına imkân sağlamaktadır ve temel olarak Denklem 3.14' de verilmiştir. Amaç fonksiyonunun azalması hem adım büyüklüğüne hem de yönlü türeve bağlıdır (Nocedal ve Wright, 2000).

$$f(x_k + \alpha_k p_k) \leq f(x_k) + c_1 \alpha_k \nabla f(x_k)^T p_k \quad (3.14)$$


Eşitsizliğin sağ tarafını $l(\alpha)$ olarak, sol tarafını da $\varphi(\alpha)$ olarak kabul edelim. Adım büyüklüğü sadece $\varphi(\alpha) < l(\alpha)$ koşulu sağlarken azaltılabilir. Fakat çok küçük adım büyüklüğü amaç fonksiyonunun global minimum noktasına çok yavaş yakınsamasına sebep olabilir. Bu çok küçük adım büyüklüklerini dengede tutabilmek için ikinci bir koşul olan eğrilik koşuluna ihtiyaç duyulmaktadır (Nocedal ve Wright, 2000).

$$\nabla f(x_k + \alpha_k p_k)^T p_k \geq c_2 \nabla f(x_k)^T p_k \quad (3.15)$$

Eğrilik koşuluna göre, α_k 'da ki φ eğimi, başlangıç eğiminden $\varphi'(0)$ c_2 kat daha büyüktür. Bu koşul (Denklem 3.15) amaç fonksiyonunun optimum yakınsamasını sağlar. Armijo koşulu ve eğrilik koşulu sırasıyla Şekil 3.3. ve Şekil 3.4.'te gösterilmiştir.



Şekil 3.3. Armijo koşulu




Şekil 3.4. Eğrilik koşulu


Bu iki koşul birlikte Wolfe koşulları olarak adlandırılır (Denklem 3.15). Eğrilik koşulu yeniden tasarlanırsa daha gerçekçi adım büyüklükleri elde edilebilir ve bu da güçlü Wolfe koşulu olarak adlandırılır.

$$|\nabla f(x_k + \alpha_k p_k)^T p_k| \leq c_2 |\nabla f(x_k)^T p_k| \quad (3.15)$$

Burada (Denklem 3.15) ; $0 < c_1 < c_2 < 1$ olmalıdır. Bu tezde, güçlü Wolfe koşulu çizgi arama yöntemi uygulanmıştır. Bu algoritmaya göre, çizgi arama koşulu iki aşamadan oluşur. İlk aşamada küçük adım büyüklüğü ile başlanır ve kabul edilebilir uygun bir aralığa ulaşana kadar artırılır. İkinci aşamada, uygun adım büyüklüğünü bulana kadar, arama aralığını azaltan yakınlştırma fonksiyonu kullanılmıştır (Nocedal ve Wright, 2000). Algoritmanın detaylı açıklaması Şekil 3.5. ve 3.6.'da verilmiştir.



Şekil 3.5. Güçlü Wolfe koşuluna dayanan çizgi arama yöntemi akış şeması



Şekil 3.6. Güçlü Wolfe koşuluna dayanan çizgi arama yöntemi yaklaşma fonksiyonunun akış şeması

Tablo 3.2. Güçlü Wolfe koşulu çizgi arama algoritması
Güçlü Wolfe koşulu çizgi arama

1. Başlangıç adım büyüklüğünü ayarla $\alpha_0 = 0$;
2. Maksimum adım büyüklüğünü seç $\alpha_{max} > 0, \alpha_k \in (0, \alpha_{max})$
3. İtersayon sayacını ayarla $k = 1$;
4. Başlangıç amaç fonksiyonunu ayarla $of_0 = of, of_x = of$;
5. Bir sonraki iterasyonun amaç fonksiyonunu ayarla $of = f(x + \alpha_k p_0)$;
6. Eğer $of > f_0 + c_1 \alpha_k eğim0$ veya $of \geq of_x$
7. $\alpha * \leftarrow$ Yakınlaştır($x, p_0, Eğim0, \alpha_0, \alpha_k, of_0, of_x, c_1, c_2$); ve dur;
8. Hesapla $Eğimc = -\nabla|f(x + \alpha_k p_0)^T| p_0$;
9. Eğer $abs(Eğimc) < -c_2 Eğim0$
10. Ayarla $\alpha * = \alpha_k$ ve dur;
11. Eğer $Eğimc > 0$
12. $\alpha * \leftarrow$ Yakınlaştır($x, p_0, Eğim0, \alpha_k, \alpha_0, of_0, of, c_1, c_2$); ve dur;
13. Seç $\alpha_{k+1} \in (\alpha_k, \alpha_{max})$ ve $of_x = of; k = k + 1$;
14. Adım 5'e git

Tablo 3.3. Yakınlaştırma fonksiyonu algoritması
Yakınlaştırma fonksiyonu

Fonksiyon $\alpha * =$ Yakınlaştır($x, p_0, Eğim0, \alpha_{alt}, \alpha_{üst}, of_0, ofAlt, c_1, c_2$)

1. Ayarla $j = 1$; ve tanımla $Max_{iterasyon}$
2. $\alpha_j = (\alpha_{alt} + \alpha_{üst})/2$; // deneme adım büyüklüğü α_j, α_{alt} ve $\alpha_{üst}$ arasında;
3. Hesapla $of = f(x + \alpha_j p_0)$;
4. Eğer $of > of_0 + c_1 \alpha_j Eğim0$ veya $of \geq ofAlt$
5. Güncelle $\alpha_{üst} = \alpha_j$;
6. Değilse
7. Hesapla $Eğimc = -\nabla|f(x + \alpha_j p_0)^T| p_0$;

Tablo 3.3. (Devamı)
Yakınlaştırma fonksiyonu

8. Eğer $abs(eğimc) < -c_2eğim0$
9. Döndür $\alpha^* \leftarrow \alpha_j$;
10. Eğer $Eğimc(\alpha_{üst} - \alpha_{alt}) > 0$
11. $\alpha_{üst} \leftarrow \alpha_{alt}$;
12. $\alpha_{alt} \leftarrow \alpha_j$;
13. $ofAlt = of$;
14. Güncelle $j = j + 1$
15. $j < Max_{iterasyon}$ olduğu sürece, adım 2'ye git

Her iterasyonda adım büyüklüklerini belirlemek için gradyant inişi metoduna, güçlü Wolfe koşullarına dayanan çizgi arama yöntemi uyarlanmıştır. Gradyant inişi ve çizgi arama algoritması Tablo 3.4.' de verilmiştir.

Tablo 3.4. Gradyant inişi + çizgi arama algoritması
Gradyant inişi + çizgi arama

1. İterasyon sayacını ayarla $k = 0$. İlk tahmini yap x_0 ,
2. Arama yönünü hesapla $p_k = \nabla f(x_k)$,
3. Hesapla $Eğim = \nabla f(x_k)^T p_k$
4. Çağır $\alpha_k = \text{GüçlüWolfeKoşuluÇizgiArama}(x_k, f(x_k), p_k, -Eğim)$
5. $x_{k+1} = x_k + \alpha_k p_k$
6. $k = k + 1$;
7. $f(x_k) < \epsilon$ olduğu sürece, adım 2'ye git.

3.2.4. Yarı-Newton yöntemi

1950'lerin ortalarında, Argonne Ulusal Laboratuvarı'ndan Amerikalı fizikçi W.C Davidon, doğrusal olmayan optimizasyonda iterasyonu hızlandıran, Yarı-Newton algoritması fikrini öne sürdü. Yarı-Newton metodu, gradyanlardaki değişimleri ölçerek süper lineer yakınsama sağlayan Amaç fonksiyonu modeli oluşturur. Böylece, Davidon (1950) tarafından önerilen öneriyi takip eden Fletcher ve Powell, mevcut diğer yöntemlerden çok daha hızlı ve daha güvenilir yenilikçi yaklaşımlar geliştirmiştir. Günümüzde, sınırlandırılmamış, sınırlandırılmamış ve büyük ölçekli optimizasyon problemlerini çözmek için, Yarı-Newton algoritmalarının çeşitliliğini içeren optimizasyon yazılımı kütüphaneleri kullanılmaktadır.

3.2.5. Broyden, Fletcher, Goldfarb, and Shanno (BFGS) yöntemi

Broyden, Fletcher, Goldfarb ve Shanno tarafından icat edilen BFGS yöntemi, en popüler Yarı-Newton algoritması olarak bilinir. Kısıtsız optimizasyon sorunları genellikle Denklem 3.16'daki gibi tanımlanır;

$$\min f(x), x \in R^n \quad (3.16)$$

Burada, f , sürekli ikinci türevlere sahip genel bir dış bükey olmayan fonksiyon olarak bilinmektedir. Yarı-Newton metodu, Denklem 3.16 'daki denklemi çözmek için en çok kullanılan ve en verimli yöntemdir.

$$x_{k+1} = x_k + a_k H_k \nabla f(x_k) \quad (3.17)$$

Denklem 3.17' deki x_1 başlangıçtaki bir tahmin noktasını temsil ederken, H_k ters Hessian matrisini $[\nabla^2 f(x_k)]^{-1}$, $\nabla f(x_k)$ amaç fonksiyonunun gradyanını temsil eder. Adım büyüklüğü a_k , güçlü Wolfe koşullu çizgi arama yöntemler ile bulunabilir. Adım vektörü s_k ve g_k , BFGS'nin güncellenmiş formülü için tanımlanmıştır (Denklem 3.18 ve Denklem 3.19).

$$s_k = x_{k+1} - x_k \quad (3.18)$$

$$g_k = \nabla f(x_{k+1}) - \nabla f(x_k) \quad (3.19)$$

Yarı-Newton yöntemi, sonraki denklem matrisinin H_{k+1} sekant denklemini karşılamasını bekler.

$$H_{k+1}g_k = s_k \quad (3.20)$$

Ters Hessian güncellemesi, Denklem 3.20 'dekine benzer şekilde $[\nabla^2 f(x_{k+1})]^{-1}g_k = s_k$ ifade edilebilir. Bu nedenle, kuadratik durumda Yarı-Newton yönteminin superliner yakınsamasını ve pratik optimizasyonda çok etkili olmasını sağlar.

DFP adı verilen ilk Yarı-Newton yöntemi, Davidon ve Fletcher ve Powell tarafından önerildi. DFP metodu için, Hessian matrisinin H_k ile H_{k+1} yaklaşımına göre güncellenmesi Denklem 3.21' deki formülle hesaplanmıştır.

$$H_{k+1} = H_k - \frac{H_k g_k g_k^T H_k}{g_k^T H_k g_k} + \frac{s_k s_k^T}{g_k^T s_k} \quad (3.21)$$

DFP güncelleme formülü oldukça etkilidir. Bununla birlikte, bugünlerde Broyden, Fletcher, Goldfarb ve Shanno tarafından önerilen BFGS formülü ile değiştirildi. Ayrıca tüm Newton güncelleme formülleri arasında en etkili olduğu kabul edilmiştir. BFGS yönteminde, H_{k+1} matrisi bu yolla güncellenebilir (Denklem 3.22 ve Denklem 3.23).

$$H_{k+1} = (I - \rho_k s_k g_k^T) H_k (I - \rho_k g_k s_k^T) + \rho_k s_k s_k^T \quad (3.22)$$

$$\rho_k = \frac{1}{g_k^T s_k} \quad (3.23)$$

Komple BFGS algoritması gerçekleştirmek için, ilk yaklaşık H_0 uygun şekilde seçilmelidir. Her durumda iyi sonuç veren hiçbir sihirli formül olmadığı için, yaklaşık bir Hessian matrisinin tersinin x_0 'ta sonlu fark yöntemi (finite difference) kullanılarak hesaplanabileceği gibi, problem hakkında özel bilgiler kullanılabilir. Aksi takdirde, başka bir yol olarak, birim matrisi (I) seçilebilir veya değişkenlerin ölçeklendirmesini yansıtmak için birim matrisinin bir katı ($\mu * I$) olarak ayarlanabilir.

Bu bölümde, gradyant iniş yöntemi, gelişmiş yakınsama sonucu elde etmek için BFGS yöntemiyle birleştirilmiştir. BFGS metodu için gerekli olan adım büyüklüğü, Güçlü Wolfe koşulu kullanılarak elde edilmiştir.

Tablo 3.5. Gradyant inişi + BFGS algoritması
Gradyant İnişi + BFGS

1. İterasyon sayaçını ayarla $k = 0$, ilk tahmini yap x_0 ,
2. Yaklaşık hessian matrisinin tersini ayarla $H_0 = \mu * I$
3. Arama yönünü hesapla $p_k = -H_k \nabla f(x_k)$
4. Hesapla $x_{k+1} = x_k + \alpha_k * p_k$
5. Tanımla $s_k = x_{k+1} - x_k$, $g_k = \nabla f(x_{k+1}) - \nabla f(x_k)$ ve $\rho_k = \frac{1}{g_k^T s_k}$
6. Hessian güncellemesini yap $H_{k+1} = (I - \rho_k s_k g_k^T) H_k (I - \rho_k g_k s_k^T) + \rho_k s_k s_k^T$
7. Güncelle $k = k + 1$
8. $f(x_k) < \epsilon$ olduğu sürece adım adım 3'e git

Tablo 3.6. Gradyant inişi + çizgi arama + BFGS algoritması
Gradyant İnişi + çizgi arama + BFGS


1. İterasyon sayaçını ayarla $k = 0$, ilk tahmini yap x_0 ,
2. Yaklaşık hessian matrisinin tersini ayarla $H_0 = \mu * I$
3. Arama yönünü hesapla $p_k = -H_k \nabla f(x_k)$
4. Hesapla $Eğim = \nabla f(x_k)^T p_k$
5. Çağır $\alpha_k = \text{GüçlüWolfeKoşuluÇizgiArama}(x_k, f(x_k), p_k, -Eğim)$
6. Hesapla $x_{k+1} = x_k + \alpha_k * p_k$
7. Tanımla $s_k = x_{k+1} - x_k$, $g_k = \nabla f(x_{k+1}) - \nabla f(x_k)$ ve $\rho_k = \frac{1}{g_k^T s_k}$
8. Hessian güncellemesini yap $H_{k+1} = (I - \rho_k s_k g_k^T) H_k (I - \rho_k g_k s_k^T) + \rho_k s_k s_k^T$
9. Güncelle $k = k + 1$
10. $f(x_k) < \epsilon$ olduğu sürece adım adım 3'e git

3.3. Optimizasyon Problemlerinde Test Fonksiyonlarının Uygulama Alanları

Matematik uygulamalarında yapay görünümüler olarak bilinen test fonksiyonları hassasiyet, yakınsama oranı, gürbüzlük, genel performans gibi özellikleri değerlendirmede kullanılır. Bu tezde uygulanan optimizasyon yöntemlerinin test fonksiyonlarının yakınsama oranlarına göre kıyaslanması baz alınmaktadır.

BUT' da gerçekleştirilen yöntemleri kıyaslamakta kullanılacak olan test fonksiyonları fikir vermesi açısından sunulacaktır.

3.3.1. Ackley fonksiyonu




Şekil 3.7. Ackley Fonksiyonu (Adorio, E. P., ve Diliman, U. P., 2013).

$$f(x) = -a \exp\left(-b \sqrt{\frac{1}{d} \sum_{i=1}^d x_i^2}\right) - \exp\left(\frac{1}{d} \sum_{i=1}^d \cos(cx_i)\right) + a + \exp(1) \quad (3.24)$$

Ackley Fonksiyonu (Denklem 3.24), optimizasyon algoritmalarını test etmek için yaygın olarak kullanılır. Şekil 3.7’de gösterildiği gibi iki boyutlu formunda, neredeyse düz bir dış bölge ve merkezde büyük bir delik ile karakterize edilir. Bu fonksiyon, optimizasyon algoritmaları için, özellikle de tepe tırmanma algoritmaları, birçok yerel minimumundan birinde sıkışıp kalma riski taşımaktadır. Küresel minimum noktası $x^* = (0, \dots, 0)$ için $f(x^*) = 0$ ‘dır (Back, T. 1996, Molga, M., ve Smutnicki, 2013;).

3.3.2. Beale fonksiyonu




Şekil 3.8. Beale Fonksiyonu (Hedar A.R, 2013)

$$f(x) = (1.5 - x_1 + x_1x_2)^2 + (2.25 - x_1 + x_1x_2^2)^2 + (2.625 - x_1 + x_1x_2^3)^2 \quad (3.25)$$

Beale işlevi (Denklem 3.25), giriş alanının köşelerinde keskin tepe noktalarına sahip, çok yönlüdür. Küresel minimum noktası $x^* = (3, 0.5)$ için $f(x^*) = 0$ 'dır (Hedar A.R, 2013).

3.3.3. Rosenbrock fonksiyonu



Şekil 3.9. Rosenbrock Fonksiyonu Picheny ve ark. (2012)

$$f(x) = \sum_{i=0}^{d-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2] \quad (3.26)$$


Vadi veya muz fonksiyonu olarak da adlandırılan Rosenbrock fonksiyonu (Denklem 3.6), gradyant tabanlı optimizasyon algoritmaları için popüler bir test problemidir. Fonksiyon tek biçimlidir ve küresel dar, parabolik bir vadide konumlandırılmaktadır. Bununla birlikte, bu vadinin kolayca bulunmasına rağmen, minimum seviyeye yaklaşma zordur (Picheny ve ark., 2012). Küresel minimum noktası $x^* = (1, \dots, 1)$ için $f(x^*) = 0$ 'dır.

Picheny ve ark. (2012) fonksiyonu Denklem 3.27' deki gibi güncellemiştir:

$$f(x) = \frac{1}{3.755 * 10^5} [\sum_{i=1}^3 (100(\ddot{x}_{i+1} - \ddot{x}_i^2)^2 + (1 - \ddot{x}_i)^2 - 3.827 * 10^5)] m \quad (3.27)$$

Burada (Denklem 3.27); $\ddot{x}_i = 15x_i - 5$, tüm $i = 1,2,3,4$ için, fonksiyonun yeniden ölçeklendirilmiş formu sıfır ortalama ve bir varyansa sahiptir. Ayrıca çıktıya küçük bir Gauss hata terimi de eklenmiştir.

3.3.4. Toplam kareler fonksiyonu




Şekil 3.10. Toplam Kareler Fonksiyonu, Molga, M., & Smutnicki (2013)

$$f(x) = \sum_{i=1}^d ix_i^2 \quad (3.28)$$

Eksen Paralel Hiper-Elipsoid işlevi olarak da adlandırılan Toplama Kareleri fonksiyonu (Denklem 3.28), global minimumdan başka hiçbir yerel minimum sahip değildir. Sürekli, dışbükey ve tek biçimlidir. Burada iki boyutlu olarak gösterilmektedir.

Fonksiyon genellikle hiperküp üzerinde tüm $i=1, \dots, d$ için $x_i \in [-10,10]$ değerlendirilir. Bu fonksiyon hiperküp üzerinde tüm $i=1, \dots, d$ için $x_i \in [-5.12, 5.12]$ sınırlı olabilir. Küresel minimum noktası $x^* = (0, \dots, 0)$ için $f(x^*) = 0$ dır.

3.3.5. Goldstein Price fonksiyonu




Şekil 3.11. Goldstein Price Fonksiyonu, Dixon, L. C. W., & Szego, G. P. (1978)

$$f(x) = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] * [30 + (2x_1 - 3x_2)^2(18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)^2] \quad (3.29)$$

Goldstein fonksiyonu küresel bir optimizasyon test fonksiyonudur. Denklem 3.29’ da da görüleceği üzere iki adet değişkene sahiptir. Küresel minimum noktası $x^* = (0, -1)$ için $f(x^*) = 3$ ’ dır.

3.3.6. Rastrigin fonksiyonu




Şekil 3.12. Rastrigin Fonksiyonu, Pohlheim (2013)

$$f(x) = 10d + \sum_{i=1}^d [x_i^2 - 10 \cos(2\pi x_i)] \quad (3.30)$$

Rastrigin'in fonksiyonu (Denklem 3.30), sık yerel minimum noktaları üretmek için kosinüs modülasyonunun eklenmesiyle De Jong'un fonksiyonuna dayanır. Bu nedenle, test fonksiyonu oldukça çoklu biçimlidir. Bununla birlikte, minimum noktaların konumu düzenli olarak dağıtılmaktadır. Fonksiyon genellikle tüm $i=1, \dots, d$ için hiperküp $x_i \in [-5.12, 5.12]$ üzerinde değerlendirilir. Küresel minimum noktası $x^* = (0, 0)$ için $f(x^*) = 0$ 'dır.

3.3.7. Döndürülmüş hiper elipsoid fonksiyonu




Şekil 3.13. Döndürülmüş hiper elipsoid fonksiyonu, Molga, M., & Smutnicki (2013)

$$f(x) = \sum_{i=1}^d \sum_{j=1}^i x_j^2 \quad (3.31)$$

Döndürülmüş Hiper-Elipsoid fonksiyonu sürekli, dışbükey ve tek biçimlidir. Toplam Kareler fonksiyonu olarak da adlandırılan eksen paralel hiper-elipsoid fonksiyonunun bir uzantısıdır. Şekil 3.13., fonksiyonun iki boyutlu şeklini gösterir. Fonksiyon (Denklemler 3.31) genellikle tüm $i=1, \dots, d$ için hiperküp $x_j \in [-65.536, 65.536]$ üzerinde değerlendirilir. Küresel minimum noktası $x^* = (0, 0)$ için $f(x^*) = 0$ 'dır.

3.3.8. Griewank fonksiyonu




Şekil 3.14. Griewank Fonksiyonu, Molga, M., & Smutnicki, C. (2013)

$$f(x) = \sum_{i=1}^d \frac{x_i^2}{4000} - \prod_{i=1}^d \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \quad (3.32)$$

Griewank fonksiyonu Rastrigin fonksiyonuna benzer. Düzenli olarak dağıtılan çok sayıda yerel minimum noktasına sahiptir. Test alanı genellikle $i = 1, \dots, n$ için hiperküp $-600 \leq x_i \leq 600$ ile sınırlıdır. Küresel minimum noktası $x^* = (0, 0)$ için $f(x^*) = 0$ 'dır. Fonksiyon yorumu ölçeğe göre değişir; genel olarak dışbükey fonksiyonu, orta ölçekli görünüm yerel ekstremumun varlığını ve son olarak da ayrıntıların yakınlaştırılmasını önermektedir (Denklem 3.32).

3.3.9. Altı kamburlu deve fonksiyonu




Şekil 3.15. Altı Kamburlu Deve Fonksiyonu, Molga, M., & Smutnicki, C. (2013)

$$f(x) = \left(4 - 2.1 x_1^2 + \frac{x_1^4}{3}\right) x_1^2 + x_1 x_2 + (-4 + 4 x_2^2) x_2^2 \quad (3.33)$$

Altı kamburlu deve fonksiyonu, küresel bir optimizasyon test fonksiyonudur. Sınırlandırılmış bölgede altı tane yerel minimum noktasına sahiptir. İki tane de küresel minimum noktası bulunmaktadır. Denklem 3.33' de görüldüğü üzere iki adet değişkene sahiptir. Küresel minimum noktası $x^* = (0.0898, -0.7126)$ ve $x^* = (-0.0898, 0.7126)$ için $f(x^*) = 0$ 'dır.

3.3.10.3 boyutlu Hartmann fonksiyonu



Şekil 3.16. 3 boyutlu Hartmann fonksiyonu , Molga, M., & Smutnicki, C. (2013)

$$f(x) = -\sum_{i=0}^4 a_i \exp \left(-\sum_{j=1}^3 A_{ij} (x_j - p_{ij})^2 \right) \quad (3.34)$$

Burada (Denklem 3.34) ;

$$a = (1.0, 1.2, 3.0, 3.2)^T$$

$$A = \begin{bmatrix} 3.0 & 10 & 30 \\ 0.1 & 10 & 35 \\ 3.0 & 10 & 30 \\ 0.1 & 10 & 35 \end{bmatrix}$$

$$P = 10^{-4} \begin{bmatrix} 3689 & 1170 & 2673 \\ 4699 & 4387 & 7470 \\ 1091 & 8732 & 5547 \\ 381 & 5743 & 8828 \end{bmatrix}$$

Üç boyutlu hartmann fonksiyonu 4 yerel minimum noktasına sahiptir. Fonksiyon genellikle tüm $i = 1,2,3$ için hiperküp $x_j \in [0, 1]$ üzerinde değerlendirilir. Küresel minimum noktası $x^* = (0,114614, 0555649, 0.852547)$ için $f(x^*) = -3.86278$.

BÖLÜM 4. DENEYSEL SONUÇLAR

Bu bölümde, çeşitli dokular içeren dairesel yapı, meme MRI taramasını temsil eden yedi farklı sayısal fantom üzerinde çalışılmıştır. Bu fantomlar temel gerçek referansları elde etmek için hazırlanmıştır. Amacımız, optimizasyon algoritmaları kullanarak, ses hızı ve zayıflama profillerinin tam parametrelerini tahmin etmektir. Optimizasyon performansı bölümünde, uygulanan optimizasyon yöntemleri, yinleme sayısı ve hesaplama süresi açısından karşılaştırılır. Benchmark optimizasyon test sonuçları bölümünde, optimizasyon yöntemleri Benchmark test fonksiyonlarına göre karşılaştırılmıştır. Yeniden yapılanma sonuçları bölümünde hem ses hem de zayıflama profilleri için tahmini ve kesin ölçüm arasındaki standart sapmalar elde edilmiştir.

4.1. Fantom Görüntüsü Hazırlıkları


Yeniden yapılanmayı test etmek için, göğüs dokusunda ölçülen ses ve zayıflama parametrelerini içeren yedi farklı sayısal fantom kullandık. Meme dokusunda kullanılan parametreler Tablo 4.1.'de verilmiştir.

Tablo 4.1. Meme dokusunda kullanılan parametreler

Doku Tipi	Ses Hızı [m/s]	Renk	Zayıflama [dB/m/MHz]
Su	1485	Açık Mavi	0
Deri	1570	Sarı	70
Yağ	1450	Koyu Mavi	24
Bez	1490	Yeşil	20
Tümör	1560	Amber	45

4.1.1. Fantom görüntüsü 1


Şekil 4.1.' de, içinde su, cilt, yağ, bez ve tümör içeren 2 boyutlu simülasyon fantom görüntüsü gösterilmiştir. Üst satırda, sol kısım ses hızı görüntüsünü, sağ kısım zayıflama görüntüsünü temsil eder. Alt satırda, sol kısım ses için temel gerçek referans iken, sağ kısım ise zayıflama için temel gerçek referansıdır.



Şekil 4.1. Fantom görüntüsü 1 için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu.

4.1.2. Fantom görüntüsü 2


Yeniden yapılanma için gerçek referansı elde etmek amacıyla su, cilt, yağ, salgı bezi ve tümör bölgelerinden oluşan fantom için 2D simülasyonu yapılmıştır. Şekil 4.2.' de su (arka plan) açık mavi, cilt sarı, yağ koyu mavi, bez yeşil ve tümör amber renkte görünür, burada hem ses hem de zayıflama için fantom görüntüleri ve profilleri gösterilmiştir.



Şekil 4.2. Fantom görüntüsü 2 için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu.

4.1.3. Fantom görüntüsü 3


Dairesel yapılı su, deri, yağ, bez ve tümör içeren fantom görüntüsü profillerinin 2 boyutlu simülasyonu Şekil 4.3.' de gösterilmiştir. Üst satırda, sol kısım ses hızı görüntüsünü, sağ kısım zayıflama görüntüsünü temsil eder. Alt satırlarda, ses ve zayıflama profilleri için temel gerçek referansları (η_{kesin} olarak bilinen parametreler) elde edilir.



Şekil 4.3. Fantom görüntüsü 3 için ses hızı ve zayıflama görüntüleri ve profillerinin iki boyutlu simülasyonu.

4.1.4. Fantom görüntüsü 4


Yeniden yapılanma için gerçek referansı elde etmek amacıyla su, cilt, yağ, salgı bezi ve tümör bölgelerinden oluşan fantom için 2D simülasyonu yapılmıştır. Su (arka plan) açık mavi, cilt sarı, yağ koyu mavi, bez yeşil ve tümör amber renkte ifade edilirken, Şekil 4.4.'te hem ses hızı hem de zayıflama için fantom görüntüleri ve profilleri gösterilmiştir.



Şekil 4.4. Fantom görüntüsü 4 için ses hızı ve zayıflama görüntüleri ve profillerinin 2 boyutlu simülasyonu.

4.1.5. Fantom görüntüsü 5


Şekil 4.5.' te, içinde su, cilt, yağ, bez ve tümör içeren 2 boyutlu simülasyon fantom görüntüsü gösterilmiştir. Üst satırda, sol kısım ses hızı görüntüsünü, sağ kısım zayıflama görüntüsünü temsil eder. Alt satırda, sol kısım ses için temel gerçek referans iken, sağ kısım ise zayıflama için temel gerçek referansıdır.



Şekil 4.5. Fantom görüntüsü 5 için ses hızı ve zayıflama görüntüleri ve profillerinin 2 boyutlu simülasyonu.

4.1.6. Manyetik rezonans tarama fantom görüntüsü


Şekil 4.6.' da manyetik rezonans (MRI) tarama fantom görüntüsünün 2D simülasyonu hem ses hem de zayıflama profilleri için verilmiştir. Gerçek memenin yapısını içeren bu özel fantom, klinik bir MRI görüntüsünden elde edilmiştir. Alttaki satırlar hem ses hızı hem de zayıflama için temel gerçek referansını (η_{kesin} olarak bilinen parametreler) gösterir.



Şekil 4.6. Meme MRI Taraması için ses hızı ve zayıflama görüntüleri ve profillerinin 2 boyutlu simülasyonu.

4.1.7. Test fantom görüntüsü

Şekil 4.7.' de, içinde farklı kontrast-çözünürlük lezyonları olan bir test fantomu için ses ve zayıflama görüntülerinin 2D simülasyonu verilmiştir. Üst satırda, sol kısım ses görüntüsünü, sağ kısım ise zayıflama görüntüsünü temsil eder.




Şekil 4.7. Test fantomu için ses hızı ve zayıflama görüntüleri ve profillerinin 2 boyutlu simülasyonu.

4.2. Görüntü Üzerine Uygulanan Optimizasyon Yöntemlerinin Performanslarının Karşılaştırılması


Denklem 3.4’ de verilen amaç fonksiyonu $f(\eta)$ ‘i minimize etmek için çeşitli optimizasyon metotları uygulanmıştır. Gerçek ölçümler Denklem 3.3’ de verilen ileri model probleminden fantomun gerçek yer doğrusu parametrelerinden bulunmuştur. Bu fantom parametrelerini yeniden yapılandırmak için ilk tahmin olarak su fantom parametreleri ile başlatılmıştır. Daha sonra, tahmini ölçümde, ileri model probleminden bulunarak gerçek ölçüm ile her iterasyonda karşılaştırılmış ve fonksiyon değerimiz minimize edilmiştir. Bu Amaç fonksiyonumuz belirlediğimiz tolerans değerine ϵ kadar azalmaya devam etmiştir. Optimizasyon metotları olarak Gauss Newton Eşlenik Gradyantı (GNEG), gradyant inişi, gradyant inişi ve çizgi arama, gradyant inişi ve BFGS ve gradyant inişi, BFGS ve çizgi arama yöntemleri küresel minimuma yakınsama oranları ve hesaplama süreleri açısından test edilmiştir. Bütün deneyler MATLAB ortamında, Intel (R) core (TM) i7-4700 HQ (2.40 GHZ) işlemci ile yapılmıştır.

4.2.1. Görüntü fantomu 1

Bu deneyde, su, deri, yağ, salgı bezi ve tümörü içeren doku fantom parametreleri yeniden yapılandırılmıştır. BFGS ve çizgi arama yöntemlerinin yakınsama oranlarına nasıl bir iyileştirme etkisi olduğu gösterilmiştir. Gauss Newton eşlenik gradyant iç döngü tolerans değeri 0,05 olarak seçilirken, gradyant inişi sabit adım büyüklüğü, Amaç fonksiyonunun ıraksamasını önlemek için $4e-8$ olarak ayarlandı. BFGS için ölçeklendirme faktörleri, gradyant inişi için uygun şekilde seçilmiştir. Seçilen adım boyutları ve deneylerin sonuçları Tablo 4.2., Şekil 4.8. ve Şekil 4.9.’ da gösterilmektedir.



Şekil 4.8. Yeniden yapılandırma metodlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu



Şekil 4.9. Yeniden yapılandırma metodlarının karşılaştırılması hesaplama süresi


Tablo 4.2. Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi

Optimizasyon yöntemleri	Adım büyüklüğü	İterasyon sayısı	Hesaplama süresi (sn)
Gauss Newton	$\alpha_{sabit}=1$, iç tolerans GNEG=0.075	İç döngü	65
Eşlenik Gradyantı		Dış döngü	12
Gradyant inişi	$\alpha_{sabit}=4e-8$		133
			30,087
Gradyant inişi + çizgi arama	$\alpha_{başlangıç}=5e-8$, $c_1=1e-4$, $c_2=0.9$		107
			70,369
Gradyant inişi + BFGS	$\alpha_{sabit}=4e-8$, $H_{başlangıç}=1.2*I$		112
			332,904
Gradyant inişi + çizgi arama + BFGS	$\alpha_{başlangıç}=5e-8$, $c_1=1e-4$, $c_2=0.9$, $H_{başlangıç}=1.2*I$		90
			356,832


Tablo 4.2.'e göre, test edilen beş algoritma arasında, gradyant inişi, çizgi arama ve BFGS en küçük yineleme sayısından (90 iterasyon) en hızlı yöntemdi. Öte yandan, her döngüde, Hessian matrisinin güncellenmesi BFGS yönteminde ve adım büyüklüğü bulunmasının çizgi arama yönteminde fazladan hesaplama süresine neden olmaktadır. Bu nedenle, Gauss Newton eşlenik gradyantı en az zaman alan yöntem (24,387 sn) olarak görülmüştür.

4.2.2. Görüntü fantomu 2

Gauss-Newton eşlenik gradyantı, gradyant inişi, gradyant inişi ve çizgi arama, gradyant inişi ve BFGS ve gradyant inişi, çizgi arama ve BFGS metotları tek tek yakınsama hızı ve hesaplama süresi açısından çeşitli su, deri, yağ, beze ve tümör dokularını içeren fantom görüntüsü üzerinde test edilmiştir. Gradyant inişi güçlü Wolfe koşulu çizgi arama yönteminde adım büyüklüğü başlangıçta ($\alpha_{başlangıç}$) $4e-8$ ile başlatılıp, güçlü Wolfe koşullarına bağlı olarak her iterasyonda güncellenmiştir. Gradyant inişi için en uygun adım büyüklüğü Amaç fonksiyonunun ıraksamasını engellemek için $3e-8$ seçilmiştir. Her bir algoritmanın sonuçları ve seçilen parametreler Tablo 4.3., Şekil 4.10. ve Şekil 4.11.'de verilmiştir.



Şekil 4.10. Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu



Şekil 4.11. Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu

Tablo 4.3. Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi


Optimizasyon yöntemleri	Adım büyüklüğü	İterasyon sayısı	Hesaplama süresi (sn)
Gauss Newton	$\alpha_{\text{sabit}}=1$, iç tolerans GNEG=0,068	İç döngü	86
Eşlenik Gradyantı		Dış döngü	15
Gradyant inişi	$\alpha_{\text{sabit}}=3\text{e-}8$	362	86,403
Gradyant inişi + çizgi arama	$\alpha_{\text{başlangıç}}=4\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$	271	223,412
Gradyant inişi + BFGS	$\alpha_{\text{sabit}}=3\text{e-}8$, $H_{\text{başlangıç}}=1,2*I$	317	954,766
Gradyant inişi + çizgi arama + BFGS	$\alpha_{\text{başlangıç}}=4\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$ $H_{\text{başlangıç}}=1,2*I$	228	1001,852

Tablo 4.3.' e göre, BFGS (317 iterasyon) ile Gradyant inişi için sabit adım büyüklüğüne sahip gradyant inişi metoduna göre (362 iterasyon) yakınsama oranı açısından geliştirilmiştir. Öte yandan, iterasyon sayısı, gradyant inişi ve çizgi arama metodunda 271 iken, gradyant inişi, çizgi arama ve BFGS için 228'e düşürülmüştür. Tablo 4.3.' de görüldüğü gibi, BFGS yöntemine sahip olan yöntemlerde her bir iterasyonda, Hessian matrisi güncellemesinden dolayı çok daha fazla hesaplama süresiyle sonuçlandığı görülmüştür. Sonuç olarak en iyi yakınsama oranına sahip olan gradyant inişi, çizgi arama ve BFGS için gözlemlenirken (228 iterasyon), hesaplama süresi açısından en iyi yöntem Gauss Newton eşlenik gradyantında gözlemlenmiştir (28,494 sn).


4.2.3. Görüntü fantomu 3

Birkaç yumuşak doku içeren sayısal fantom parametreleri yeniden yapılanmayı test etmek için yüklenmiştir. Kesin ölçüm d, 110 x 86 boyutundaki bilinen fantom piksel parametreleri (η_{kesin}) kullanılarak ileri problem algoritmasından simüle edilmiştir. 110 x 86 boyutlu bilinmeyen piksel parametrelerin (η) tahmini su fantom parametreleri ile başlatılıp tahmini basıncı p ileri problem algoritmasından elde edildi. Amaç fonksiyonu olarak bilinen p ve d arasındaki sapmayı en aza indirmek için, her bir

iterasyonda tahmin basıncı p güncellenip ve tolerans değeri ϵ ulaşana kadar kesin d ölçümü ile karşılaştırılmıştır. Bu süreç ters problem olarak adlandırılır. Gauss Newton eşlenik gradyant metodu, gradyant inişi, gradyant inişi ve çizgi arama, gradyant inişi ve BFGS ve gradyant inişi, çizgi arama ve BFGS metotları yakınsama hızı ve hesaplama süresi açısından ayrı ayrı test edilmiştir. Gauss Newton için eşlenik gradyant iç döngü tolerans değeri, $1e-4$ 'in dış döngü tolerans değeri ϵ ile en iyi yakınsama nedeniyle ampirik yerine deneysel olarak 0,0075 olarak seçildi. Gradyant inişi için sabit adım büyüklüğü, ıraksama ve yavaş yakınsamayı önlemek için ampirik olarak $3e-8$ 'e ayarlandı. BGFS yönteminde en iyi yakınsama oranını elde etmek için ölçeklendirme faktörleri 1,2 olarak seçilmiştir. Her bir algoritma için karşılık gelen sonuçlar Tablo 4.4., Şekil 4.12. ve Şekil 4.13. ' de verilmiştir.



Şekil 4.12. Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu



Şekil 4.13. Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu


Tablo 4.4. Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi

Optimizasyon yöntemleri	Adım büyüklüğü	İterasyon sayısı	Hesaplama süresi (sn)
Gauss Newton Eşlenik Gradyantı	$\alpha_{\text{sabit}}=1$, iç tolerans GNEG=0,075	İç döngü 69 Dış döngü 11	21,619
Gradyant inişi	$\alpha_{\text{sabit}}=3\text{e-}8$	276	62,0163
Gradyant inişi + çizgi arama	$\alpha_{\text{başlangıç}}=3\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$	230	156,271
Gradyant inişi + BFGS	$\alpha_{\text{sabit}}=3\text{e-}8$, $H_{\text{başlangıç}}=1,2*I$	237	703,228
Gradyant inişi + çizgi arama + BFGS	$\alpha_{\text{başlangıç}}=3\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$, $H_{\text{başlangıç}}=1,2*I$	201	699,5716


Tablo 4.4.'teki veriler doğrultusunda, en iyi yakınsama hızı gradyant inişi, çizgi arama ve BFGS metodunda gözlemlenmiştir (201 iterasyon). Gradyant inişi metoduna (276 iterasyon) kıyasla çizgi arama yöntemi ile uyarlanmış gradyant inişi metodunda (230 iterasyon) yakınsama oranlarının daha da iyileştiği gözlemlenmiştir. Hesaplama süresi açısından Gauss Newton eşlenik gradyantı en kısa sürede yeniden yapılandırmayı tamamlamıştır (21,619 sn).

4.2.4. Görüntü fantomu 4

Gauss Newton eşlenik gradyantı, gradyant inişi, gradyant inişi ve çizgi arama ve bunların BFGS ile uyarlanmış olan gradyant inişi ve BFGS ve gradyant inişi, çizgi arama ve BFGS metotlarının yakınsama sonuçları Şekil 4.14., 4.15. ve Tablo 4.5.' de gösterilmiştir. Gradyant inişi metodunda, amaç fonksiyonunun ıraksamasını ve yavaş yakınsamayı engellemek için en uygun adım büyüklüğü olarak $3e-08$ olarak seçilmiştir. Aynı şekilde BFGS metotları için ölçekleme faktörü dış tolerans değerine ($1e-4$) ıraksamadan en hızlı şekilde yakınsaması sebebi ile 1,2 olarak seçilmiştir. Ayrıca Wolfe koşullu çizgi arama yönteminin aralığından dolayı, parametreler $0 < c_1 < c_2 < 1$ aralığında seçilmiştir. Genellikle literatürlerde $c_1=10^{-4}$, $c_2=0.9$ olarak tavsiye edilir ve uygulamamızda da bu değerler kullanılmıştır. İlk aşamada küçük bir adım büyüklüğü ile başlatılır ve kabul edilebilir bir adım büyüklüğü bulunana kadar artırılmaya devam eder. İkinci aşamada ise yakınlaştırma fonksiyonu ile uygun bir adım büyüklüğü bulunana kadar arama aralığı azaltılmaya devam eder.



Şekil 4.14. Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu



Şekil 4.15. Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu

Tablo 4.5. Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi


Optimizasyon yöntemleri	Adım büyüklüğü	İterasyon sayısı	Hesaplama süresi (sn)
Gauss Newton	$\alpha_{\text{sabit}}=1$, iç tolerans	İç döngü	64
Eşlenik Gradyantı	GNEG=0,075	Dış döngü	11
Gradyant inişi	$\alpha_{\text{sabit}}=3\text{e-}8$	274	63,51
Gradyant inişi + çizgi arama	$\alpha_{\text{başlangıç}}=3\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$	228	165,60
Gradyant inişi + BFGS	$\alpha_{\text{sabit}}=3\text{e-}8$, $H_{\text{başlangıç}}=1,2*I$	235	716,47
Gradyant inişi + çizgi arama + BFGS	$\alpha_{\text{başlangıç}}=3\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$, $H_{\text{başlangıç}}=1,2*I$	204	722,00

Tablo 4.5.' teki sonuçlara göre, Gauss Newton eşlenik gradyantı iç ve dış döngü olmak üzere 704 iterasyonda tolerans değerine ulaşmaktadır. Gradyant inişi metodunda sabit adım büyüklüğü sebebi ile 274 iterasyonda tamamlanırken, gradyant inişi ve çizgi arama yönteminde adım büyüklüğünün değişmesi yakınsama oranını 228 iterasyona düşürmüştür. Aynı şekilde BFGS metodu ile uyarlanan gradyant inişi metodunda (235 iterasyon), gradyant inişi metoduna (274 iterasyon) göre yakınsama oranında iyileşme olduğu gözlemlenmiştir. En iyi yakınsama oranı olarak, 204 iterasyon ile, gradyant inişi, çizgi arama ve BFGS metotunda görülürken zaman açısından en iyi metodun Gauss Newton eşlenik gradyant metotunda olduğu görülmüştür (20,85 sn).


4.2.5. Görüntü fantomu 5

Gauss Newton eşlenik gradyant için dış tolerans değeri $1\text{e-}04$ 'e ϵ en iyi şekilde yakınsamasından dolayı, iç tolerans değeri 0,07 olarak seçilmiştir. Gradyant inişi için adım büyüklüğü $3\text{e-}08$ olarak seçilmiştir. Bunun nedeni $3\text{e-}08$ ten büyük olan adım büyüklükleri için Amaç fonksiyonu değerinin yakınsaması yerine ıraksamasına neden olmasıdır. Diğer bir taraftan, $3\text{e-}08$ 'den küçük olan adım büyüklükleri için de Amaç fonksiyonunun yavaş bir şekilde yakınsamasına neden olduğundan dolayı en iyi adım büyüklüğü olarak $3\text{e-}08$ seçilmiştir. Daha iyi yakınsama oranı elde etmek için BFGS

metodu gradyant inişi metodu ile birleştirilmiştir. Birim matrisi katsayı ile çarparak $(\mu * I)$, ilk Hessian matrisinin tersi şeklinde tanımlanmıştır. Her iterasyonda, Hessian matrisi BFGS formülüne göre güncellenmiştir. Amaç fonksiyonunun dış tolerans değerine ulaşamayıp ıraksamasını önlemek için, ölçekleme faktörü 1,2 seçilmiştir.



Şekil 4.16. Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu



Şekil 4.17. Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu


Tablo 4.6. Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi

Optimizasyon yöntemleri	Adım büyüklüğü	İterasyon sayısı	Hesaplama süresi (sn)
Gauss Newton Eşlenik Gradyantı	$\alpha_{\text{sabit}}=1$ iç tolerans GNEG=0,07	İç döngü 32 Dış döngü 6	12,882
Gradyant inişi	$\alpha_{\text{sabit}}=3\text{e-}8$	147	34,340
Gradyant inişi + çizgi arama	$\alpha_{\text{başlangıç}}=4\text{e-}8, c_1=1\text{e-}4, c_2=0,9$	101	128,0781
Gradyant inişi + BFGS	$\alpha_{\text{sabit}}=3\text{e-}8,$ $H_{\text{başlangıç}}=1,2*I$	132	395,192
Gradyant inişi + çizgi arama + BFGS	$\alpha_{\text{başlangıç}}=4\text{e-}8, c_1=1\text{e-}4, c_2=0,9,$ $H_{\text{başlangıç}}=1,2*I$	82	466,767


Tablo 4.6.'e göre iterasyon sayıları açısından Gauss Newton eşlenik gradyanti için, eşlenik gradyanti iç döngüsünde 32 iterasyon ile sonuçlanırken, dış döngüde 6 iterasyon ile sonuçlanmıştır. Eşlenik gradyantının MATLAB PCG fonksiyonunun iç döngüsünde her iterasyonda fonksiyon değerine ulaşamadığından Şekil 4.16.' da 32 iterasyon olarak gösterilmiştir. Yani toplamda 192 iterasyon ile tolerans değerine ulaşmıştır. Gradyant inişi metodu için 147 iterasyon ile tolerans değerine ulaşırken, Amaç fonksiyonunun ıraksamasını ve yavaş yakınsamasını engelleyen gradyanti inişi ve çizgi arama yöntemi, 101 iterasyon ile sonuçlanmıştır. Yani her iterasyonda adım büyüklüğünün değişmesi sebebi ile iterasyon sayısında iyileşme gözlemlenmiştir. Diğer bir yandan gradyanti inişi metoduna göre (147 iterasyon), gradyanti inişi ve BFGS metodunda (132 iterasyon) yakınsama oranları açısından iyileşme gözlemlenmiştir. Ayrıca, gradyanti inişi, çizgi arama ve BFGS metotları birlikte kullanıldığında 82 iterasyona düştüğü gözlemlenmiştir. Tolerans değerine ulaşmak için, en iyi yakınsama oranı gradyanti inişi, çizgi arama ve BFGS (82 iterasyon) gözlemlenirken, hesap karmaşıklığı sebebi ile zaman açısından (466,767 sn) uzamaya sebep olmuştur. Zaman açısından en iyi metot Gauss Newton eşlenik gradyantında (12 sn) gözlemlenmiştir.

4.2.6. Görüntü fantomu 6

Bu deneyde, manyetik rezonans tarama fantomu beş farklı yöntem kullanılarak yeniden yapılandırılmak üzere yüklenmiştir. Kesin ölçüm d , $110 * 86$ bilinen piksel parametrelerine (η_{Kesin}) göre ileri problem algoritmasından simüle edilmiştir. Bu $110 * 86$ bilinen piksel parametrelerini yeniden yapılandırmak için, ilk tahmin olarak 110×86 su piksel parametreleri ile başlatılmış olup (η), her iterasyonda ileri problemi algoritmasından tahmini basıncı p elde edildi. Bu kesin ölçüm ile tahmini basınç arasındaki sapma her iterasyonda belirlediğimiz tolerans değerine kadar minimize edilmiştir. Tolerans değerine en iyi yakınsama nedeniyle ($1e-4$), Gauss Newton eşlenik gradyantının iç tolerans değeri 0,0075 olarak seçilmiştir. BFGS yönteminin adım boyutu ve ölçeklendirme faktörü, Amaç fonksiyonunun ıraksamasını önlemek için uygun şekilde seçildi. Her bir algoritma için karşılık gelen sonuçlar Tablo 4.7., Şekil 4.18. ve 4.19.'da verilmiştir.



Şekil 4.18. Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu



Şekil 4.19. Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu

Tablo 4.7. Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi


Optimizasyon yöntemleri	Adım büyüklüğü	İterasyon sayısı	Hesaplama süresi (sn)
Gauss Newton	$\alpha_{\text{sabit}}=1$, iç tolerans	İç döngü	56
Eşlenik Gradyantı	GNEG=0,075	Dış döngü	8
Gradyant inişi	$\alpha_{\text{sabit}}=4\text{e-}8$	203	51,0513
Gradyant inişi + çizgi arama	$\alpha_{\text{başlangıç}}=5\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$	147	297,127
Gradyant inişi + BFGS	$\alpha_{\text{sabit}}=4\text{e-}8$, $H_{\text{başlangıç}}=1.2*I$	175	546,5264
Gradyant inişi + çizgi arama + BFGS	$\alpha_{\text{başlangıç}}=5\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$, $H_{\text{başlangıç}}=1,2*I$	106	681,1273

Tablo 4.7.'ya göre sabit adım büyüklüğüne sahip gradyant iniş metotunda, 203 iterasyondan sonra tolerans değerine ulaşırken, gradyant inişi ve çizgi arama yöntemiyle 147 iterasyondan sonra ulaştığı görülmüştür. Benzer şekilde, Hessian güncellemesine sahip olan gradyant inişi, çizgi arama ve BFGS metotunda (106 iterasyon), gradyant inişi ve BFGS metoduna (175 iterasyon) kıyasla, iterasyon sayısında önemli bir azalma gözlenmiştir. Öte yandan, Gauss Newton eşlenik gradyant yöntemi iç ve dış iterasyon olarak toplamda 448 iterasyon ile sonuçlanmıştır. Şekil 4.19.'a göre, en kısa sürede tolerans değerine ulaşan yöntem, Gauss Newton eşlenik gradyantı iken (21,946 s), yakınsama oranı açısından en iyi metot gradyant inişi, çizgi arama ve BFGS' dir (106 iterasyon).


4.2.7. Görüntü fantomu 7

Uygulanan optimizasyon metotlarımızın performanslarını karşılaştırmak için numerik test fantomu görüntüsü üzerinde, sırasıyla Gauss Newton eşlenik gradyantı, gradyant inişi, gradyant inişi ve çizgi arama, gradyant inişi ve BFGS, gradyant inişi, çizgi arama ve BFGS uygulanmıştır. Tolerans değerine en iyi yakınsama nedeniyle ($1\text{e-}4$), Gauss Newton eşlenik gradyantının iç tolerans değeri 0,0075 olarak seçilmiştir. BFGS yönteminin adım boyutu ve ölçeklendirme faktörü, Amaç fonksiyonunun iraksamasını

önlemek için uygun şekilde seçildi. Her bir algoritma için karşılık gelen sonuçlar Tablo 4.8., Şekil 4.20. ve 4.21.'de verilmiştir.



Şekil 4.20. Yeniden yapılandırma metotlarının karşılaştırılması iterasyon sayısı ve amaç fonksiyonu



Şekil 4.21. Yeniden yapılandırma metotlarının karşılaştırılması hesaplama süresi ve amaç fonksiyonu

Tablo 4.8. Seçilen adım büyüklükleri, iterasyon sayıları ve hesaplama süresi

Optimizasyon yöntemleri	Adım büyüklüğü	İterasyon sayısı	Hesaplama süresi (sn)
Gauss Newton	$\alpha_{\text{sabit}}=1$, iç tolerans	İç döngü	33
Eşlenik Gradyantı	GNEG=0,09	Dış döngü	6
Gradyant inişi	$\alpha_{\text{sabit}}=3\text{e-}8$	127	31,1956
Gradyant inişi + çizgi arama	$\alpha_{\text{başlangıç}}=4\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$	81	250,1322
Gradyant inişi + BFGS	$\alpha_{\text{sabit}}=3\text{e-}8$, $H_{\text{başlangıç}}=2*I$	112	342,5133
Gradyant inişi + çizgi arama + BFGS	$\alpha_{\text{başlangıç}}=4\text{e-}8$, $c_1=1\text{e-}4$, $c_2=0,9$, $H_{\text{başlangıç}}=2*I$	72	444,4838

Tablo 4.8. ve Şekil 4.20.'ye göre, çizgi arama ile güncellenen adım büyüklüğüne sahip olan gradyant inişi ile sabit adım büyüklüğüne sahip olan gradyant inişi (127 iterasyon)

karşılaştırıldığında çizgi arama yönteminin yakınsama oranını iyileştirdiği gözlemlenmiştir. En hızlı yakınsama hızı, en az yinleme sayısına bağlı olarak, gradyant inişi, çizgi arama ve BFGS metotunda (72 iterasyon) gözlemlenmiştir.

4.3. Benchmark Optimizasyon Test Fonksiyonları

Uygulanan optimizasyon algoritmaları, Benchmark test fonksiyonları ile test edilmiştir. Ackley test fonksiyonu, Gauss Newton eşlenik gradyantı, gradyant inişi, gradyant inişi ve çizgi arama, gradyant inişi ve BFGS ve gradyant inişi, çizgi arama ve BFGS optimizasyon algoritmaları için girdi değerleri $x^* = \eta$ olarak verilmiştir. Elde edilen sonuçlar Tablo 4.9.'de gösterilmiştir. Tablo 4.9.'e göre belirlenen aynı tolerans değerleri için (1e-04) global minimuma en iyi yakınsayan optimizasyon algoritması gradyant inişi ve BFGS olarak gözlemlenmiştir. Diğer yandan Gauss Newton eşlenik gradyantı algoritması, global minimum değeri için en yüksek değerde kalmıştır.

Tablo 4.9. Ackley test fonksiyonu için elde edilen global minimum değerleri

Ackley test fonksiyonu	$x^* = (0, \dots, 0)$	Global minimum $f(x^*) = 0$
Gauss Newton Eşlenik Gradyantı	$x^* = \eta$	$f(x^*) = 0,0016795 - 0,0000299i$
Gradyant inişi	$x^* = \eta$	$f(x^*) = 0,0015956 - 0,0000141i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = 0,0015994 - 0,0000136i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = 0,0015727 - 0,0000117i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = 0,0015899 - 0,0000131i$

Her bir optimizasyon algoritması için Beale test fonksiyonu uygulanmıştır. Normalde Beale fonksiyonu için global minimum değerine $x^* = (3,0.5)$ girdi değerlerinde ulaşırken, optimizasyon algoritmalarının performans değerlendirmesi için $x^* = \eta$ olarak tercih edilmiştir. Beale test fonksiyonu için, her bir optimizasyon algoritmasının performans sonuçları Tablo 4.10.'da verilmiştir. Tablo 4.10.'da verilen sonuçlara göre, global minimuma en iyi yakınsayan algoritma gradyant inişinde görülmüştür. Bunun

sebebi belirlenen sabit adım büyüklüğünün her iterasyonda daha stabil bir şekilde yakınsaması olmuştur. Buna karşın global minimum değerine en uzakta algoritma, Gauss Newton eşlenik gradyantında gözlemlenmiştir.

Tablo 4.10. Beale test fonksiyonu için elde edilen global minimum değerleri

Beale test fonksiyonu	$x^* = (3,0.5)$	Global minimum $f(x^*) = 0$
Gauss Newton Eşlenik Gradyantı	$x^* = \eta$	$f(x^*) = 14.2031403 - 0.0000051i$
Gradyant inişi	$x^* = \eta$	$f(x^*) = 14.2031307 - 0.0000024i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = 14.2031307 - 0.0000025i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = 14.2031317 - 0.0000027i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = 14.2031307 - 0.0000025i$

Her bir optimizasyon algoritması için Rosenbrock test fonksiyonu uygulanmıştır. Rosenbrock fonksiyonu için global minimum değerine $x^* = (1, \dots, 1)$ girdi değerlerinde ulaşır. Rosenbrock test fonksiyonu için, her bir optimizasyon algoritmasının performans sonuçları Tablo 4.11.'de verilmiştir. Tablo 4.11.'de verilen sonuçlara göre, global minimuma en iyi yakınsama oranı, güçlü Wolfe koşullarına göre belirlenen ve farklı adım büyüklüklerine olanak sağlayan gradyant inişi ve çizgi arama yönteminde görülmüştür. Buna karşın global minimum değerine en uzakta algoritma, Gauss Newton eşlenik gradyantında gözlemlenmiştir.

Tablo 4.11. Rosenbrock test fonksiyonu için elde edilen global minimum değerleri

Rosenbrock test fonksiyonu	$x^* = (1, \dots, 1)$	Global minimum $f(x^*) = 0$
Gauss Newton Eşlenik Gradyantı	$x^* = \eta$	$f(x^*) = -0.3002772 - 0.0000001i$
Gradyant inişi	$x^* = \eta$	$f(x^*) = -0.3000736 - 0.0001786i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = -0.3000732 - 0.0001789i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = -0.3000846 - 0.0001566i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = -0.3000755 - 0.0001778i$

Her bir optimizasyon algoritması için Toplam kareler test fonksiyonu uygulanmıştır. Toplam kareler test fonksiyonu için global minimum değerine $x^* = (0,0)$ girdi değerlerinde ulaşır. Toplam kareler test fonksiyonu için, her bir optimizasyon algoritmasının performans sonuçları Tablo 4.12.' de verilmiştir. Tablo 4.12.' de verilen sonuçlara göre, gradyant inişi yöntemine kıyasla gradyant inişi ve çizgi arama yöntemi global minimuma daha uzakta kaldığı görülmüştür. Öte yandan, gradyant inişi ve BFGS yöntemi ile gradyant inişi, BFGS ve çizgi karşılaştırıldığında, gradyant inişi ve BFGS yöntemi global minimuma daha iyi yakınsadığı görülmüştür. Global minimum değerine en uzakta algoritma, Gauss Newton eşlenik gradyantında olduğu görülmüştür.

Tablo 4.12. Toplam kareler test fonksiyonu için elde edilen global minimum değerleri

Toplam kareler test fonksiyonu	$x^* = (0,0)$	Global minimum $f(x^*) = 0$
Gauss Newton Eşlenik Gradyantı	$x^* = \eta$	$f(x^*) = -0.0011399 - 0.0000466i$
Gradyant inişi	$x^* = \eta$	$f(x^*) = 8.5212750e - 04 - 2.3192471e - 05i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = 8.5756672e - 04 - 2.2281672e - 05i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = 8.2455535e - 04 - 2.0687708e - 05i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = 8.4688794e - 04 - 2.1400829e - 05i$

Goldstein Price test fonksiyonu, Gauss Newton eşlenik gradyantı, gradyant inişi, gradyant inişi ve çizgi arama, gradyant inişi ve BFGS ve gradyant inişi, çizgi arama ve BFGS performans testleri yapılmıştır. Goldstein Price test fonksiyonunda, $x^* = (0, -1)$ girdi değerleri için global minimum noktası $f(x^*) = 3$ tür. Elde edilen sonuçlar 3 'e göre referans alınmış olup, Tablo 4.13.' de gösterilmiştir. Sonuçlara göre, gradyant inişi yöntemine kıyasla gradyant inişi ve çizgi arama yöntemi global minimuma daha uzakta kaldığı görülmüştür. Öte yandan, gradyant inişi ve BFGS yöntemi ile gradyant inişi, BFGS ve çizgi arama yöntemi karşılaştırıldığında, gradyant inişi, BFGS ve çizgi arama yöntemi global minimuma daha iyi yakınsadığı görülmüştür. Global minimum değerine, en iyi yakınsayan algoritmanın gradyant inişi

ve çizgi arama olduğu gözlemlenirken, en uzaktan kalan algoritmanın Gauss Newton eşlenik gradyantı olduğu görülmüştür.

Tablo 4.13. Goldstein Price test fonksiyonu için elde edilen global minimum değerleri

Goldstein Price test fonksiyonu	$x^* = (0, -1)$	Global minimum $f(x^*) = 3$
Gauss Newton Eşlenik Gradyantı	$x^* = \eta$	$f(x^*) = 6.0000909e + 02 + 1.0946718e - 02i$
Gradyant inişi	$x^* = \eta$	$f(x^*) = 6.000e + 02 + 4.003e - 02i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = 6.000e + 02 + 3.999e - 02i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = 6.000e + 02 + 4.005e - 02i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = 6.000e + 02 + 4.004e - 02i$

Rastrigin test fonksiyonu, Gauss Newton eşlenik gradyantı, gradyant inişi, gradyant inişi ve çizgi arama, gradyant inişi ve BFGS ve gradyant inişi, çizgi arama ve BFGS optimizasyon algoritmaları için girdi değerleri $x^* = \eta$ olarak verilmiştir. Elde edilen sonuçlar Tablo 4.14.'de gösterilmiştir. Tablo 4.14.'te verilen sonuçlara göre, gradyant inişi yöntemine kıyasla gradyant inişi ve BFGS yöntemi global minimuma yakınsaması açısından daha iyi performans göstermiştir. Benzer şekilde, gradyant inişi ve çizgi arama yöntemi ile gradyant inişi, BFGS ve çizgi arama yöntemi karşılaştırıldığında, gradyant inişi, BFGS ve çizgi arama yöntemi global minimuma daha iyi yakınsadığı görülmüştür. Global minimum değerine en uzakta algoritma, Gauss Newton eşlenik gradyantında olduğu görülmüştür.

Tablo 4.14. Rastrigin test fonksiyonu için elde edilen global minimum değerleri

Rastrigin test fonksiyonu	$x^* = (0,0)$	Global minimum $f(x^*) = 0$
Gauss Newton Eşlenik Gradyantı	$x^* = \eta$	$f(x^*) = 0.0035400 - 0.0001346i$
Gradyant inişi	$x^* = \eta$	$f(x^*) = 0.0030518 - 0.0000603i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = 0.0029297 - 0.0000584i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = 0.0029297 - 0.0000495i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = 0.0029297 - 0.0000560i$

Her bir optimizasyon algortiması için global minimum değerine $x^* = (0,0)$ girdi değerlerinde ulaşan döndürülmüş hiper ellipsoid test fonksiyonu test fonksiyonu uygulanmıştır. Döndürülmüş hiper elipsoid test fonksiyonu için, her bir optimizasyon algoritmasının performans sonuçları Tablo 4.15.' de verilmiştir. Elde edilen sonuçlara göre, gradyant inişi yöntemi ile gradyant inişi ve çizgi arama yöntemi karşılaştırıldığında, gradyant inişi yöntemi daha iyi yakınsamıştır. Benzer şekilde, gradyant inişi ve BFGS yöntemi ile gradyant inişi, BFGS ve çizgi karşılaştırıldığında, gradyant inişi ve BFGS yöntemi global minimuma daha iyi yakınsadığı görülmüştür. Global minimum değerine, en iyi yakınsayan algoritmanın gradyant inişi ve BFGS olduğu gözlemlenirken, en uzaktan kalan algoritmanın Gauss Newton eşlenik gradyantı olduğu görülmüştür.

Tablo 4.15. Döndürülmüş hiper elipsoid test fonksiyonu için elde edilen global minimum değerleri

Döndürülmüş hiper elipsoid test fonksiyonu	$x^* = (0,0)$	Global minimum $f(x^*) = 0$
Gauss Newton Eşlenik	$x^* = \eta$	$f(x^*) = 0.0012983 - 0.0000272i$
Gradyantı		
Gradyant inişi	$x^* = \eta$	$f(x^*) = 0.0010691 - 0.0000105i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = 0.0010774 - 0.0000104i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = 0.0010463 - 0.0000070i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = 0.0010670 - 0.0000099i$

Griewank test fonksiyonu her bir optimizasyon algoritması üzerinde test edilmiş olup sonuçlar Tablo 4.16.' da verilmiştir. gradyant inişi yöntemine global minimum değerine en iyi yakınsayan algoritmanın gradyant inişi ve BFGS olduğu gözlemlenirken, en uzaktan kalan algoritmanın Gauss Newton eşlenik gradyantı olduğu görülmüştür.

Tablo 4.16. Griewank test fonksiyonu için elde edilen global minimum değerleri

Griewank test fonksiyonu	$x^* = (0,0)$	Global minimum $f(x^*) = 0$
Gauss Newton Eşlenik	$x^* = \eta$	$f(x^*) = 5.9604645e - 08$
Gradyantı		$- 8.8982119e - 09i$
Gradyant inişi	$x^* = \eta$	$f(x^*) = 5.9604645e - 08$
		$- 6.8929054e - 09i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = 5.9604645e - 08$
		$- 6.8557449e - 09i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = 5.9604645e - 08$
		$- 5.7322147e - 09i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = 5.9604645e - 08$
		$- 6.6710157e - 09i$

Global minimum değerine $x^* = (0,0)$ girdi değerlerinde ulaşan altı kamburlu test fonksiyonu her bir optimizasyon algoritması için uygulanmıştır. Tablo 4.17.'de verilen deneysel sonuçlar doğrultusunda, Global minimum değerine en iyi yakınsayan algoritmanın gradyant inişi olduğu gözlemlenirken, en uzaktan kalan algoritmanın Gauss Newton eşlenik gradyantı olduğu görülmüştür.

Tablo 4.17. Altı kamburlu deve test fonksiyonu için elde edilen global minimum değerleri

Altı kamburlu deve test fonksiyonu	$x^* = (0,0)$	Global minimum $f(x^*) = 0$
Gauss Newton Eşlenik	$x^* = \eta$	$f(x^*) = 7.6454629e - 09 - 1.4650421e - 08i$
Gradyantı		
Gradyant inişi	$x^* = \eta$	$f(x^*) = 7.0205268e - 09 - 1.3036177e - 08i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = 7.0220625e - 09 - 1.3981854e - 08i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = 7.2077437e - 09 - 1.3759358e - 08i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = 7.0556458e - 09 - 1.3994807e - 08i$

Her bir optimizasyon algoritması için Hartman 3 boyutlu test fonksiyonu uygulanmıştır ve global minimum noktası olan $f(x^*) = -3.86278$ değerine göre referans alınmıştır. Tablo 4.18.'de verilen sonuçlara göre, global minimum değerine en iyi


yakınsayan algoritmanın gradyant inişi ve BFGS olduğu gözlemlenirken, en uzaktan kalan algoritmanın gradyant inişi olduğu görülmüştür.

Tablo 4.18. Hartman 3 boyutlu test fonksiyonu için elde edilen global minimum değerleri


Hartman 3 boyutlu test fonksiyonu	x^* $= (0.114614, 0.555649, 0.852547)$	Global minimum $f(x^*) = -3.86278$
Gauss Newton	$x^* = \eta$	$f(x^*) = -0.0680446 - 0.0000235i$
Eşlenik Gradyantı		
Gradyant inişi	$x^* = \eta$	$f(x^*) = -0.0680412 - 0.0000175i$
Gradyant inişi + çizgi arama	$x^* = \eta$	$f(x^*) = -0.0680412 - 0.0000177i$
Gradyant inişi + BFGS	$x^* = \eta$	$f(x^*) = -0.0680457 - 0.0000087i$
Gradyant inişi + çizgi arama + BFGS	$x^* = \eta$	$f(x^*) = -0.0680420 - 0.0000172i$

4.4. Yeniden Yapılandırma Sonuçları

Ses hızı ve zayıflama profil görüntülerinin yeniden yapılandırılması, Gauss-Newton eşlenik gradyantı ve gradyant inişi optimizasyon metotları görüntü nitelikleri bakımından Şekil 4.22. ve 4.23.' de verilmiştir. Daha iyi yeniden yapılandırma sonucu elde etmek için, fantom görüntüleri tolerans değeri $1e-08$ 'e ulaşana kadar optimize edilmiştir. Yeniden oluşturulan görüntüler üst sıralarda hem ses hızı hem de zayıflama için görülebilir. Alt kısımdaki profiller, görüntüdeki pembe noktalı çizgilerdeki parametrelere yani piksellere odaklanır; burada kırmızı daireler yeniden oluşturulan profilleri temsil ederken, mavi çizgiler simüle edilmiş referanslarını temsil eder. Simülasyondan Gauss-Newton eşlenik gradyantı kullanılarak, standart sapma ses hızı görüntüsü için $0,00 \text{ m / s}$ olarak elde edilirken, zayıflama görüntüsü için $\%0,000$ olarak elde edilmiştir. Öte yandan, gradyant inişi kullanarak yapılan simülasyondan, standart sapma ses hızı görüntüsü için $0,00 \text{ m / s}$, zayıflama görüntüsü için $\%0,000$ olarak elde edilmiştir.




Şekil 4.22. Görüntü fantomu 1 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması




Şekil 4.23. Görüntü fantomu 1 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması

Su, deri, yağ, salgı bezi, tümör içeren farklı tipteki dokulardan oluşan fantom görüntüsü 2 için yeniden yapılandırma sonuçları Şekil 4.24. ve Şekil 4.25.'de gösterilmiştir. Gauss-Newton eşlenik gradyantı kullanılarak, standart sapma ses hızı için 0,00 m / s ve zayıflama için %0,001 olarak elde edilmiştir. Öte yandan, gradyant

inişi kullanarak, standart sapma ses hızı için $0,01 \text{ m/s}$ ve zayıflama için $0,001$ olarak elde edilmiştir.




Şekil 4.24. Görüntü fantomu 2 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması.




Şekil 4.25. Görüntü fantomu 2 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması

Fantom görüntüsü 3 için ses hızı ve zayıflama görüntülerinin yeniden yapılandırma sonuçları hem Gauss-Newton eşlenik gradyantı hem de gradyant inişi için sırasıyla Şekil 4.26. ve Şekil 4.27.'de gösterilmektedir. Yeniden oluşturulan görüntüler hem ses

hızı hem de zayıflama için görülebilir. Gauss-Newton eşlenik gradyanı ile elde edilen standart sapma ses hızı için 0,01 m/s iken, zayıflama için %0,001 olmuştur. Öte yandan, gradyant inişi için simülasyondan elde edilen standart sapma, ses hızı için 0,01 m / s ve zayıflama için %0,002'dir.




Şekil 4.26. Görüntü fantomu 3 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması.




Şekil 4.27. Görüntü fantomu 3 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması

Gauss-Newton eşlenik gradyanı ve gradyant inişi kullanılarak fantom görüntüsü 4 için hem ses hızı hem de zayıflama görüntüleri ve profillerinin yeniden yapılandırma

sonuçları sırasıyla Şekil 4.28. ve Şekil 4.29.'da gösterilmiştir. Gauss-Newton eşlenik gradyanti kullanılarak, simülasyondan standart sapma ses hızı için 0,01 m / s ve zayıflama için %0,001 olarak elde edilmiştir. Öte yandan, gradyant inişi metotunu kullanarak, simülasyondan standart sapma ses hızı için 0,01 m / s, zayıflama için %0,002 olarak elde edilmiştir.




Şekil 4.28. Görüntü fantomu 4 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması.




Şekil 4.29. Görüntü fantomu 4 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması

Gauss-Newton eşlenik gradyanı ve gradyant inişi kullanılarak fantom görüntüsü 5 için hem ses hızı hem de zayıflama görüntüleri ve profillerinin yeniden yapılandırma sonuçları sırasıyla Şekil 4.30. ve Şekil 4.31.'de gösterilmiştir. Gauss-Newton eşlenik gradyanı kullanılarak, simülasyondan standart sapma ses hızı için 0,01 m / s ve zayıflama için %0,001 olarak elde edilmiştir. Öte yandan, gradyant inişi metotunu kullanarak, simülasyondan standart sapma ses hızı için 0,02 m / s, zayıflama için %0,002 olarak elde edilmiştir.




Şekil 4.30. Görüntü fantomu 5 için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması.




Şekil 4.31. Görüntü fantomu 5 için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması

Su, deri, yağ, salgı bezi, tümör içeren farklı tipteki dokulardan oluşan meme yapısının MRI taraması görüntüsü üzerinde yeniden yapılandırma sonuçları Şekil 4.32. ve Şekil 4.33.'te gösterilmektedir. Gauss-Newton eşlenik gradyantu kullanılarak, standart sapma ses hızı için 0.01 m / s ve zayıflama için % 0.001 olarak elde edilirken, gradyant inişi kullanarak, standart sapma ses hızı için 0.01 m / s ve zayıflama için % 0.002 olarak elde edilmiştir.




Şekil 4.32. MRI taraması fantomu için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması.




Şekil 4.33. MRI taraması fantomu için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması

İçerisinde farklı kontrast-çözünürlük lezyonları içeren test fantomu görüntüsü üzerinde yeniden yapılandırma sonuçları Şekil 4.34. ve Şekil 4.35.' de gösterilmektedir. Gauss-Newton eşlenik gradyanti kullanılarak, standart sapma ses hızı için 0,01 m / s ve zayıflama için %0,001 olarak elde edilirken, gradyant inişi kullanarak, standart sapma ses hızı için 0,02 m / s ve zayıflama için % 0,002 olarak elde edilmiştir. Bununla birlikte gradyant inişinden elde edilen zayıflama görüntüleri Gauss Newton eşlenik gradyantında elde edilen zayıflama görüntüleri kadar iyi değildir. Bunun sebebi Gauss Newton eşlenik gradyantını metodunun verimli bir düzenleme yöntemine sahip olmasıdır. Altta yatan doğrusal olmayan problem kötü durumdaysa (ill posed), doğrusallaştırılmış problemler kötüleşir ve düzenleme (regularization) yöntemlerine ihtiyaç duyulur. Düzenleme, eşlenik gradyanti doğrusallaştırılmış problemlerin normal denklemlere uygulanarak yapılmıştır (Althaus, 2016).



Şekil 4.34. Test fantomu için ses hızı ve zayıflama görüntülerinin Gauss Newton eşlenik gradyant kullanarak yeniden yapılandırılması.



Şekil 4.35. Test fantomu için ses hızı ve zayıflama görüntülerinin gradyant inişi kullanarak yeniden yapılandırılması

BÖLÜM 5. TARTIŞMA VE SONUÇ

Bu çalışmada BUT'da kullanılan ses hızı ve zayıflama görüntülerinin yeniden yapılandırılması için gradyant inişi optimizasyon metodu uygulanmıştır. Güçlü Wolfe koşullarına dayanan çizgi arama yöntemleri gradyant inişi metotuna eklenmiştir. Böylece her iterasyonda adım büyüklüğü bu koşullara göre güncellenmiştir. BFGS metodu incelenmiş ve gradyant inişi metoduna adapte edilmiştir. Optimizasyon performanslarını karşılaştırmak için yedi farklı fantom görüntüsü tasarlanmıştır. Gradyant inişinin yakınsama davranışları ve optimizasyon performansları Gauss Newton eşlenik gradyantı, gradyant inişi ve çizgi arama, gradyant inişi ve BFGS ve gradyant inişi, çizgi arama ve BFGS metotları ile karşılaştırılmıştır. Benchmark test fonksiyonları incelenmiş bu optimizasyon yöntemleri üzerinde test edilmiştir. Son olarak gradyant inişi ile yeniden yapılandırılan görüntü ile Gauss Newton eşlenik gradyant metodu ile yeniden yapılandırılan görüntü kaliteleri ses hızı ve zayıflama profillerinin standart sapmalarına göre değerlendirilmiştir.

Genel bir kural olarak, araştırmada uygulanan tüm algoritmalarda, uygun adım büyüklüğünün kullanımı yakınsama hızında büyük bir etkiye sahiptir. Normalde adım büyüklüğü arttırıldığında, yakınsama oranı daha hızlı olmakla birlikte daha az iterasyon sayısı gerektirir. Bununla birlikte, adım büyüklüğü çok büyük olduğunda, yakınsama yerine ıraksama eğilimi vardır, bu da açıkça artan bir Amaç fonksiyonuna neden olur. Güçlü Wolfe koşullarına dayanan çizgi arama yöntemi, uygun adım boyutunu bulma konusunda umut vericidir. Gradyan inişi ile adapte edilmiş çizgi arama yöntemi daha az iterasyonda minimuma yakınsamasına rağmen, her iterasyon için ekstra hesaplama süresi gerektirir. Bunun sebebi uygun adım büyüklüğünün bulunması için harcanan ekstra hesaplama süresidir. Aynı şekilde BFGS yöntemi ile adapte edilen gradyant inişi yöntemi iterasyon sayısında azalma gözlemlenirken hesaplama süresinde artış gözlemlenmiştir. Sonuçlar, gradyant inişi, çizgi arama ve

BFGS yöntemi iterasyon sayıları açısından, test edilen tüm yöntemler arasında en iyi yöntem olduğunu gösterirken, Gauss Newton eşlenik gradyanlı hesaplama süresi açısından en hızlı yöntemdir.

Uygulanan birçok yerel minimum noktalarına sahip çeşitli Benchmark test fonksiyonları ile optimizasyon algoritmaları test edilmiştir. Sonuçlar, Benchmark fonksiyonlarında, Gauss Newton eşlenik gradyan optimizasyon metodu yerel minimuma en uzakta kalan algoritma olduğu gözlemlendi.

Yeniden yapılandırma sonuçlarında hem ses hızı hem de zayıflama görüntü profillerinin standart sapmaları simülasyondan karşılaştırılmıştır. Zayıflama görüntülerinin ses hızı görüntüleri kadar iyi olmadığı gözlemlenmiştir. Bunun asıl sebebi kompleks değer parametrelerinin yeniden yapılandırmamızdır. Zayıflama görüntülerini hesaplanması, ses hızı görüntülerinin hesaplanmasından (ill-posed) problemin daha ciddi bir şekilde ortaya çıkan kısmıdır. Diğer bir deyişle, zayıflama görüntülerin fark aralığı ses hızı görüntülerine göre çok daha küçüktür (0,9998 -1). Daha iyi zayıflama görüntüleri elde edebilmek için, Amaç fonksiyonu için tolerans değeri küçük seçilmiştir ($1e-08$). Gauss Newton eşlenik gradyandaki gibi iç döngü gerektirmeyen gradyant inişi yöntemindeki zayıflama görüntülerinin düzenleştirme teriminin olmamasından dolayı, Gauss Newton eşlenik gradyantında elde edilen zayıflama görüntüsüne göre daha dağınık kalmıştır.

Sonuç olarak çalışmamızdan elde edilen önemli bulgular şu şekilde özetlenebilir:

- a. İç döngü gerektirmeyen gradyant inişi metodu araştırıldı ve ses hızı ve zayıflama görüntüleri yeniden yapılandırıldı.
- b. Çizgi arama yöntemleri gradyant inişi metoduna uygun adım büyüklüğü sağlayarak iterasyon sayısında önemli bir düşüş gösterdi. Aynı şekilde Hessian matrisi güncellemeli BFGS metodu da iterasyon sayısında düşüş gösterdi. Fakat hesaplama süreleri açısından ekstra süre gerektirmiştir.
- c. Benchmark optimizasyon test fonksiyonları için, gradyant inişi metodu, Gauss Newton metoduna göre daha fazla global minimuma yakınsamıştır.

- d. Zayıflama görüntülerinin yeniden yapılandırılması ses hızı görüntülerine göre daha zor olduğu gözlemlenmiştir. Buna ek olarak Gauss Newton eşlenik gradyant metodunda düzenleştirme teriminin olması gradyant inişi metoduna göre daha iyi performans göstermiştir.



KAYNAKLAR

- Akcelik V., Biros G., & Ghattas O. 2002. Parallel Multiscale Gauss-Newton-Krylov Methods for inverse wave propagation Pittsburgh Supercomputing Center under awards ASC-010025P and ASC-010036Ps.
- Althaus L. 2016. On acoustic tomography using paraxial approximations, M.Sc. dissertation, Darmstadt University of Technology, Department of Mathematics, Darmstadt, Germany, pp.7-11.
- André M.P., Jones J.P. & Lee H. 2011. Inverse Scattering Theory, in: Acoustical Imaging, vol. 30, Springer Science, Cham, Switzerland, pp. 53-59.
- Ashfaq M. & Ermert H. 2004. A new approach towards ultrasonic transmission tomography with a standard ultrasound system. In: Proceedings of the IEEE International Ultrasonics, Ferroelectrics, and Frequency Control Joint 50th Anniversary Conference, pp. 1848–1851.
- Bubeck S. 2015. Convex Optimization: Algorithms and Complexity. In: Foundations and Trends in Machine Learning, 8(3-4), 231-358. Available from: doi: 10.1561/22000000050
- Calderon C., Vilkomerson D., Mezrich R., Etzold K.F., Kingsley B. & Haskin M. 1976. Differences in the attenuation of ultrasound by normal, benign, and malignant breast tissue. Journal of Clinical Ultrasound, 4(4), 249-254.
- Dapp R. 2013. Abbildungsmethoden für die Brust mit einem 3D-Ultraschall-Computertomographen. PhD dissertation, Karlsruhe Institute of Technology, Karlsruhe, Germany.
- Duric N., Li C., Roy O. & Schmidt S. 2011. Acoustic Tomography: Promise versus Reality. International Ultrasonics Symposium Proceedings, Orlando, Florida, USA, pp. 2031-2043.
- Ferlay J., Soerjomataram I., Ervik M., Dikshit R., Eser S., Mathers C., Rebelo M., Parkin D.M., Forman D. & Bray F. 2015. Cancer incidence and mortality worldwide: sources, methods and major patterns in GLOBOCAN 2012. Int J Cancer. 136(5), 359-386. doi: 10.1002/ijc.29210. Available from: <http://globocan.iarc.fr>
- Fichtner A. 2011. Full seismic waveform modelling and inversion, Springer, pp. 86-123. Available from: doi: 10.1007/978-3-642-15807-0
- Gemmeke H. & Ruiter N.V. 2007. 3D Ultrasound Computer Tomography for medical imaging. In: Nuclear Instruments and Methods in Physics Research Section A.

- Accelerators Spectrometers Detectors and Associated Equipment, 580 (2), 1057-1065. Available from: <https://doi.org/10.1016/j.nima.2007.06.116>
- Gemmeke H., Althaus L., van Dongen K.W.A., Egger H., Hesser J., Mayer J., Ruiter N.V., Zapf M. & Hopp T. 2016. Wave Equation Based Transmission Tomography. Proc. in IEEE International Ultrasonics Symposium (IUS), Tours, France. Available from: doi: 10.1109/ULTSYM.2016.7728829
- Greenleaf J. 1995. 3D and tomographi cultrasound, in: L.W. Goldman (Ed.), Medical CT & Ultrasound: Current Technology and Applications, Advanced Medical Publ., Madison, WI, pp. 267–284.
- Greenleaf J.F. 2012. Clinical imaging with transmissive ultrasonic computerized tomography. IEEE Trans. Biomed. Eng. 28(2), 177-185.
- Haynes M.S. 2012. Full- wave Nonlinear Inverse Scattering for Acoustic and Electromagnetic Breast Imaging, P.H.D. dissertation, The University of Michigan, pp.18-19.
- H. Gemmeke N.V. & Ruiter. 2007. 3D ultrasound computer tomography for medical imaging. Nuclear Instruments and Methods in Physics Research. 580, 1057–1065. doi: 10.1016/j.nima.2007.06.116.
- Johnson S.A., Borup D.T., Berggren M.J., Wiskin J.W. & Eidens R. 1992. Modeling of inverse scattering and other tomographic algorithms in conjunction with wide bandwidth acoustic transducer arrays for towed or autonomous sub-bottom imaging systems. IEEE Oceans, 4(4), 294-299. Available from: doi: 10.1109/OCEANS.1992.612705
- Li C., Sandhu G.Y., Boone M. & Duric N. 2017. Breast Imaging Using Waveform Attenuation Tomography, Medical Imaging 2017: Ultrasonic Imaging and Tomography, edited by Neb Duric, Brecht Heyde, Proc. of SPIE Vol. 10139, 101390A · © 2017 SPIE · CCC code: 1605-7422/17/\$18 · doi: 10.1117/12.2255569
- McGough R.J., Samulsk, T.V. & Kelly J.F. 2004. An efficient grid sectoring method for calculations of the near-field pressure generated by a circular piston, *J. Acoustical Soc. Am.*, 115, pp. 1942. Available from: doi: 10.1121/1.1687835
- Nguyen M., Bressmer H. et al. 1993. Improvements in ultrasound transmission computed tomography, in: Proceedings of the European Conference on Engineering and Medicine, pp. 189–190.
- Nocedal J. & Wright S.J. 2006. Numerical Optimization, Mathematics Subject Classification. Springer Series in Operations Research and Financial Engineering, USA, pp.30-33. ISBN-10: 0-387-30303-0.
- Norton S.J. & Linzer M. 1979. Ultrasonic reflectivity to mography: reconstruction with circular transducer arrays. Ultrason Imaging. 1(2),154-84. doi:10.1177/016173467900100205

- Nounou M., ElAmrawy F., Ahmed N., Abdelrauf K., Goda S. & Qhattal H. 2015. Breast Cancer: Conventional Diagnosis and Treatment Modalities and Recent Patents and Technologies. *Breast Cancer (Auckl)*, 27(9suppl 2), 17-34. doi: 10.4137/BCBCR.S29420.
- Pérez-Liva M., Herraiz J.L., Udías J.M., Miller E., Cox B.T. & Treeby B.E. 2017. Time domain reconstruction of sound speed and attenuation in ultrasound computed tomography using fullwave inversion. *J Acoust Soc Am.* 141(3), 1595. doi: 10.1121/1.4976688.
- Ruder S. 2016. An overview of gradient descent optimization algorithms. arXiv:1609.04747. Available from: <http://ruder.io/optimizing-gradient-descent/>
- Ruiter N.V., Zapf M., Hopp T., Dapp R., Kretzek E., Birk M., Kohout B. & Gemmeke H. 2012. 3D ultrasound computer tomography of the breast: a new era? *Eur J Radiol.* 81(Suppl1), S133-4. doi: 10.1016/S0720-048X(12)70055-4.
- Sandhu G.Y., West E., Roy O. & Duric J. 2017. 3D Frequency-Domain Ultrasound Waveform Tomography breast imaging. Conference: Medical Imaging 2017: Ultrasonic Imaging and Tomography. Orlando, Florida, United States. 10139, pp 1013909. Available from: <https://doi.org/10.1117/12.2254399>
- Sandhu G.Y., Li C., Roy O. Schmidt S & Duric N. 2015. Frequency-Domain Ultrasound Waveform Tomography: breast imaging using a ring transducer. *IOP Publishing Institute of Physics and Engineering in Medicine Phys. Med. Biol.* (60) (2015) 5381-5398. Available from: <https://doi.org/10.1088/0031-9155/60/14/5381>.
- Simonetti F.L., Huang L. & Duric, N. 2008. A multiscale approach to diffraction tomography of complex three-dimensional objects. 2008. International Conference on BioMedical Engineering and Informatics, pp. 723-727.
- Siregar R.W. & Ramli M. 2018. Analysis Local Convergence of Gauss-Newton Method. *IOP Conference Series: Materials Science and Engineering*, 300, 1-6. Available from: doi:10.1088/1757-899X/300/1/012044
- Suetens P. 2009. Fundamentals of medical imaging. Cambridge University Press, Cambridge, UK. Available from: <https://doi.org/10.1017/CBO9780511596803>
- vanDongen K.W.A. & Wright W.M.D. 2007. A full vectorial contrast source inversion scheme for three-dimensional acoustic imaging of both compressibility and density profiles. *The Journal of the Acoustical Society of America* 121(3), 1538-1549. Available from: <https://doi.org/10.1121/1.2431333>
- Virieux J., Opetro S. 2009. An Overview of full-waveform inversion in exploration geophysics. *Geophysics*, VOL. 74, NO 6 (November-December 2009); P.WCC152, 15 FIGS., 1 TABLE. 10.1190/1.3238367.
- Wiskin J., Borup D., Iuanow E., Klock J. & Lenox M. 2017. 3-D Nonlinear Acoustic Inverse Scattering: Algorithm and Quantitative Results. *IEEE Trans. Ultrason., Ferroelectr., Control* 64(8), pp.1161-1174.

Wiskin J., Borup D., Johnson S., Berggren M., Robinson D., Smith J., Chen J., Parisky Y. & Klock J. 2010. Inverse Scattering and Refraction Corrected Reflection or Breast Cancer Imaging. In: SPIE Proceedings, pp. 7629. Available from: doi: 10.1117/12.844910.

Wiskin J.W., Borup D.T., Iuanow E., Klock J. & Lenox M.W. 2017. 3-D Nonlinear Acoustic Inverse Scattering: Algorithm and Quantitative Results. IEEE Trans Ultrason Ferroelectr Freq Control. 68(8), 1161-1174. doi:10.1109/TUFFC.2017.2706189



ÖZGEÇMİŞ

Ali Can IŞIK, 08.04.1992’de Ankara’da doğdu. İlk, orta ve lise eğitimini Gümüşhane’de tamamladı. 2010 yılında Ali Fuat Kadirbeyoğlu Anadolu Lisesi’nden mezun oldu. 2010 yılında başladığı Başkent Üniversitesinde İngilizce hazırlık ve Elektrik – Elektronik Mühendisliği eğitimini tamamladı. 2017 yılında Sakarya Üniversitesinde Elektrik – Elektronik Mühendisliği Bölümünde yüksek lisans eğitimine başladı. Aynı zamanda savunma sanayine yönelik su altı akustiği ile ilgili çalışmalarına özel bir şirkette devam etmektedir.