İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

2-BOYUTLU SEYREK ÖZBAĞLANIMLI MODELLEME İLE RADAR HEDEF SINIFLANDIRMA

YÜKSEK LİSANS TEZİ

Koray SARIKAYA

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Telekomünikasyon Mühendisliği Programı

MAYIS 2014

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

2-BOYUTLU SEYREK ÖZBAĞLANIMLI MODELLEME İLE RADAR HEDEF SINIFLANDIRMA

YÜKSEK LİSANS TEZİ

Koray SARIKAYA
504111351

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Telekomünikasyon Mühendisliği Programı

Tez Danışmanı: Doç. Dr. Işın YAZGAN ERER

MAYIS 2014

İTÜ, Fen Bilimleri Enstitüsü'nün 504111351 numaralı Yüksek Lisans Öğrencisi **Koray SARIKAYA**, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı **"2-BOYUTLU SEYREK ÖZBAĞLANIMLI MODELLEME İLE RADAR HEDEF SINIFLANDIRMA"** başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı :	**Doç. Dr. Işın YAZGAN ERER** İstanbul Teknik Üniversitesi	.....
Jüri Üyeleri :	**Prof. Dr. Sedef KENT PINAR** İstanbul Teknik Üniversitesi	.....
	Doç. Dr. Lütfiye DURAK ATA Yıldız Teknik Üniversitesi	.....

Teslim Tarihi : 05.05.2014
Savunma Tarihi : 26.05.2014

Eşime ve biricik oğluma,

ÖNSÖZ

Öncelikle tez çalışmaları sırasında benden desteğini esirgemeyen hocam Sn. Doç. Dr. Işın YAZGAN ERER'e teşekkürü bir borç bilirim.
Diğer yandan bu zorlu dönemde kendilerinden çaldığım vakte rağmen desteklerini eksik etmeyen eşim Dr. Zeynep YAKŞİ SARIKAYA'ya ve küçük oğlum Kerem Oktay SARIKAYA'ya, eğitim sürecim ile ilgili desteklerini zor koşullara rağmen esirgemeyen annem Belgin SARIKAYA ve babam Adnan SARIKAYA'ya teşekkür ederim.
Ayrıca zorlu dönemeçlerde desteğini esirgemeyen arkadaşım Haldun BOZKURT'a teşekkür ederim.
Yüksek lisans çalışmaları döneminde gerekli desteği sağlayarak süreci kolaylaştıran kurumum ASELSAN A.Ş.'deki yöneticilerime akademik hayata verdikleri destek için ayrıca teşekkür ederim.

Mayıs 2014

Koray SARIKAYA
Telekomünikasyon Mühendisi

İÇİNDEKİLER

Sayfa

ÖNSÖZ ..... **vii**
İÇİNDEKİLER ..... **ix**
KISALTMALAR ..... **xi**
ÇİZELGE LİSTESİ ..... **xiii**
ŞEKİL LİSTESİ ..... **xv**
ÖZET ..... **xxi**
SUMMARY ..... **xxv**
1. GİRİŞ **1**
2. SENTETİK AÇIKLIKLI RADAR İLE HEDEF GÖRÜNTÜLEME **5**
2.1. Amaç 5
2.2. SAR ile İlgili Genel Bilgiler 5
2.3. SAR Görüntüleme Teknikleri 6
2.3.1. 2-B Fourier dönüşümüne dayalı radar hedef görüntüleme 6
2.3.2. Yüksek çözünürlüklü SAR görüntüleme teknikleri 11
2.3.2.1. MUSIC algoritması 13
Uzamsal yumuşatma işleminde kullanılan alt matris boyutunun etkisi 17
Kestirilen saçıcı sayısının etkisi 24
2.3.2.2. Özbağlanımlı (AR) modelleme algoritması 35
Tekil değer ayrışımı (SVD- singular value decomposition) yöntemi ile radar görüntüleme 49
Seyrek özbağlanımlı (AR) modelleme ile radar görüntüleme 57
2.3.3. Farklı yöntemlerle bulunan görüntülerin karşılaştırılması 68
3. RADAR HEDEF SINIFLANDIRMA YÖNTEMİ **75**
3.1. İlk Hazırlık İşlemleri 75
3.2. Polar Eşleme İşlemi 76
3.3. Temel Bileşenler Analizi 82
3.4. Eğitim Veri Setinin Oluşturulması İşlemi 84
3.5. K-Means Algoritması 86
3.6. Sınıflandırma Tasarımı 88
3.7. Sınıflandırma Sonuçları ve Değerlendirmeler 90
3.7.1. Geniş bantlı veri için sınıflandırma sonuçları 91
3.7.2. Dar bantlı veri için sınıflandırma sonuçları 92
4. SONUÇ VE ÖNERİLER **97**
KAYNAKLAR **99**
EK: Radar Hedef Görüntülerinin Dinamik Alan Değerleri (BMP-2 Hedefi için) **101**
ÖZGEÇMİŞ **102**

KISALTMALAR

AR : Auto-Regressive
FFT : Fast Fourier Transform
SAR : Synthetic Aparture Radar (Yapay Açıklıklı Radar)
ISAR : Inverse Synthetic Aparture Radar (Ters Yapay Açıklıklı Radar)
RCS : Radar Cross Section (Radar Kesit Alanı)
SNR : Signal to Noise Ratio (Sinyal Gürültü Oranı)
IFFT : Inverse Fast Fourier Transform (Ters Hızlı Fourier Dönüşümü)
MSTAR : Movingand Stationary Target Acquisition and Recognation
MUSIC : Multiple Signal Classification
PCA : Principal Compenent Analysis (Temel Bileşenler Analizi)
SVD : Singular Value Decomposition (Tekil Değer Ayrışımı)
UD : Uygulanabilir Değil

ÇİZELGE LİSTESİ

Çizelge 1: Farklı radar hedef görüntüleme algoritmaları için sınıflandırma sonuçları (%) (geniş bantlı verilere sahip olunduğu durumda)..... 92
Çizelge 2: Farklı yöntemlere göre ve değişken parametre setlerine göre en iyi radar hedef sınıflandırma sonuçları (%)..... 92
Çizelge 3: Hedef sınıflandırma başarıları karmaşıklık matrisi (geniş bantlı verilere sahip olunduğu durumda)..... 93
Çizelge 4: AR modelleme algoritması için sınıflandırma sonuçları (%) (dar bantlı verilere sahip olunduğu durumda) 93
Çizelge 5: Farklı Yöntemlere Göre ve değişken parametre setlerine göre en iyi radar hedef sınıflandırma sonuçları (%) (dar bantlı veriler için)..... 94
Çizelge 6: Hedef sınıflandırma başarıları karmaşıklık matrisi (dar bantlı verilere sahip olunduğu durumda)..... 94
Çizelge 7: Farklı radar görüntüleme algoritmaları için dinamik alan sonuçları (dB) (64x64 boyutunda geniş bantlı veriler için) 101
Çizelge 8: Farklı radar görüntüleme algoritmaları için dinamik alan sonuçları (dB) (32x32 boyutunda daraltılmış bantlı veriler için)..... 101

ŞEKİL LİSTESİ

Şekil 2.1: Yapay açıklıklı radar sistemi [7]. 6
Şekil 2.2: M saçılma merkezine sahip hedef [3]..... 7
Şekil 2.3: Model Bir Uçağın Menzil Profili [7]..... 8
Şekil 2.4: Model Bir Uçağın Çapraz Menzil Profili [2]. 9
Şekil 2.5: Polar Format Algoritması ile $(\boldsymbol{f}, \boldsymbol{\theta})$ uzayından $(\boldsymbol{fx}, \boldsymbol{fy})$ uzayına geçiş . 10
Şekil 2.6: Uzamsal Yumuşatma (Spatial Smoothing) Yöntemi [2]..... 15
Şekil 2.7: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 12, c) 16, d) 20, e) 24, f) 30 18
Şekil 2.8: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=10 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 12, c) 16, d) 20, e) 24, f) 30 19
Şekil 2.9: 32 x 32 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 6, c) 8, d) 10, e) 12, f) 15 20
Şekil 2.10: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 6, c) 8, d) 10, e) 12, f) 15 21
Şekil 2.11: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 6, c) 8, d) 10, e) 12, f) 15 22
Şekil 2.12: 16 x 16 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 4, c) 5, d) 6, e) 7, f) 8 23
Şekil 2.13: 64x64 boyutunda veri matrisine sahip Mig-25 için, 24x24 boyutunda alt matris kullanıldığında hesaplanan özdeğerlerin sıralanmış görünümü 24
Şekil 2.14: 64x64 boyutunda veri matrisine sahip Mig-25 için, 24x24 boyutunda alt matris kullanıldığında hesaplanan özdeğerlerin sıralanmış görünümü (0-100 arasında normalize edilmiştir)..... 25
Şekil 2.15: Normalize özdeğerlerin 0.25 genişliğindeki hücrelere göre histogramlanması 25
Şekil 2.16: Özdeğerlerin 0.25 genişliğindeki hücrelere göre histogramlanması..... 25
Şekil 2.17: 64 x 64 veri boyutundaki Mig 25 hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:24) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 15, c) 55, d) 95 (kestirilen saçıcı sayısı değeri), e) 135, f) 175 29

Şekil 2.18: 64 x 64 veri boyutundaki Mig 25 hedefinin (SNR=10 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:24) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 14, c) 44, d) 74 (kestirilen saçıcı sayısı değeri), e) 104, f) 134 30
Şekil 2.19: 32x32 veri boyutundaki Mig 25 hedefinin(SNR=30 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:12) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 17, c) 27, d) 37 (kestirilen saçıcı sayısı değeri), e) 47, f) 57 31
Şekil 2.20: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:12) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 7, c) 14, d) 21 (kestirilen saçıcı sayısı değeri), e) 28, f) 35 32
Şekil 2.21: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:12) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 5, c) 11, d) saçıcı sayısı:17 (kestirilen saçıcı sayısı değeri), e) 23, f) 29 33
Şekil 2.22: 16 x 16 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:7) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 4, c) 8, d) 12 (kestirilen saçıcı sayısı değeri), e) 16, f) 20 34
Şekil 2.23: Koordinat sistemi ve M saçılma merkezli hedef 36
Şekil 2.24: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 12, c) 16, d) 20, e) 24, f) 30 43
Şekil 2.25: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=10 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 12, c) 16, d) 20, e) 24, f) 30 44
Şekil 2.26: 32 x 32 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 6, c) 8, d) 10, e) 12, f) 15 45
Şekil 2.27: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 6, c) 8, d) 10, e) 12, f) 15 46
Şekil 2.28: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 6, c) 8, d) 10, e) 12, f) 15 47
Şekil 2.29: 16 x 16 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 4, c) 5, d) 6, e) 7, f) 8 48

Şekil 2.30: 64 x 64 veri boyutundaki Mig 25 hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 24) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 20, c) 60, d) 100 (kestirilen saçıcı sayısı değeri), e) 140, f) 180 51
Şekil 2.31: 64 x 64 veri boyutundaki Mig 25 hedefinin (SNR=10 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 20) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 16, c) 46, d) 76 (kestirilen saçıcı sayısı değeri), e) 106, f) 136 52
Şekil 2.32: Mig 25 hedefinin (SNR=30 dB, 32x32'lik veri) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 22, c) 32, d) 42 (kestirilen saçıcı sayısı değeri), e) 52, f) 62 53
Şekil 2.33: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 7, c) 14, d) 21 (kestirilen saçıcı sayısı değeri), e) 28, f) 35 54
Şekil 2.34: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 5, c) 14, d) 23 (kestirilen saçıcı sayısı değeri), e) 32, f) 41 55
Şekil 2.35: Airbus hedefinin (SNR=30 dB, 16x16'lik veri) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 7) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 4, c) 8, d) 13 (kestirilen saçıcı sayısı değeri), e): 17, f) 21 56
Şekil 2.36: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 24) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4 61
Şekil 2.37: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=10 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4 62
Şekil 2.38: Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının daraltılmış veriler (32 x 32) ile ve seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4 63

Şekil 2.39: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4 64
Şekil 2.40: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4 65
Şekil 2.41: Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının daraltılmış veriler (16 x 16) ile ve seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 7) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4 66
Şekil 2.42: Özbağlanımlı (AR) katsayıları a) En küçük kareler çözümü için, b) Tekil Değer Ayrışımı (SVD) çözümü için, c) Seyrek (sparse) çözümü için 67
Şekil 2.43: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:24): a) Fourier dönüşümü yöntemi, b) MUSIC algoritması, c) özbağlanımlı (AR) modelleme yöntemi, d) özbağlanımlı modelleme yöntemi-SVD çözümü, e) seyrek özbağlanımlı modelleme yöntemi 69
Şekil 2.44: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=10 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:24): a) Fourier dönüşümü yöntemi, b) MUSIC algoritması, c) özbağlanımlı (AR) modelleme yöntemi, d) özbağlanımlı modelleme yöntemi-SVD çözümü, e) seyrek özbağlanımlı modelleme yöntemi (λ=4) 70
Şekil 2.45: 32 x 32 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:12): a) Fourier dönüşümü yöntemi (64x64 boyutundaki veri ile), b) Fourier dönüşümü yöntemi (32x32 boyutundaki daraltılmış veri ile), c) MUSIC algoritması, d) özbağlanımlı (AR) modelleme yöntemi, e) özbağlanımlı modelleme yöntemi-SVD çözümü, f) seyrek özbağlanımlı modelleme yöntemi (λ: 0,5) 71
Şekil 2.46: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:12): a) Fourier dönüşümü yöntemi, b) MUSIC algoritması, c) özbağlanımlı (AR) modelleme yöntemi, d) özbağlanımlı modelleme yöntemi-SVD çözümü, e) seyrek özbağlanımlı modelleme yöntemi 72
Şekil 2.47: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:12): a) Fourier dönüşümü yöntemi, b) MUSIC algoritması, c) özbağlanımlı (AR) modelleme yöntemi, d) özbağlanımlı modelleme yöntemi-SVD çözümü, e) seyrek özbağlanımlı modelleme yöntemi 73
Şekil 2.48: 16 x 16 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:7): a) Fourier dönüşümü yöntemi (32x32 boyutundaki veri ile), b) Fourier dönüşümü yöntemi (16x16 boyutundaki daraltılmış veri ile), c) MUSIC algoritması, d) özbağlanımlı (AR) modelleme yöntemi, e) özbağlanımlı

modelleme yöntemi-SVD çözümü, f) seyrek özbağlanımlı modelleme yöntemi (λ:0,5) 74
Şekil 3.1: Log-Polar Izgara (üstte) , Polar Izgara (altta) [23]. 77
Şekil 3.2: Polar Görüntü Geometrisi [23]. 78
Şekil 3.3: F16 uçak ISAR görüntüsü ve polar ızgarası [23]. 80
Şekil 3.4: F16 uçak ISAR görüntüsü ve polar ızgarası, döndürülmüş ve açısı 80
Şekil 3.5: Şekil 3.3 e karşı gelen Polar görüntü $Ir(r)$ ve $I\theta(\theta)$: $Nr = N\theta = 50$ [23]. 81
Şekil 3.6: Şekil 3.4 e karşı gelen Polar görüntü $Ir(r)$ ve $I\theta(\theta)$: $Nr = N\theta = 50$ [23]. 81
Şekil 3.7: Temel bileşenler analizi için grafiksel gösterim [26]. 83
Şekil 3.8: Bir hedefin önerilen deneme veri setinin mimarisi [23]..... 86
Şekil 3.9: Sınıflandırma performansının deneysel sonucunu elde etme şeması [7] .. 89
Şekil 3.10: Hedeflerin Fourier dönüşümü yöntemine göre elde edilmiş radar hedef görüntüleri a) BMP2, b) BTR70, c) T72 90

2-BOYUTLU SEYREK ÖZBAĞLANIMLI MODELLEME İLE RADAR HEDEF SINIFLANDIRMA

ÖZET

Radarlar günümüzde sivil-askeri bir çok alanda yaygın olarak farklı uygulamalar için kullanılmaktadır. Radarlar askeri alanlarda hedef tespiti, takibi vb amaçlarla kullanılırken sivil alanlarda hava trafiği kontrolü, denizde seyir güvenliği, trafikte hız kontrolü, meterolojik uygulamalar, yer yüzü görüntüleme vb. bir çok alanda kullanılmaktadır.

Radarlarda görüntüleme son yıllarda ilgi çeken bir alandır. Görüntülemede yüksek çözünürlüğü sağlamak önemli bir problemdir. Geleneksel radarlar ile yüksek çözünürlük hedeflendiğinde çok zorlu fiziksel kısıtlar ortaya çıkmaktadır (çok geniş anten açıklığı gibi). Bu noktada hedefin hareketinden faydalanarak yapay bir açıklık oluşturan SAR (Sentetik Açıklıklı Radar) sistemleri ortaya çıkmaktadır. SAR sistemleri yapay bir açıklık oluşturarak ve fiziksel geniş anten açıklığı gereğini ortadan kaldırarak yüksek çözünürlükle görüntüleme sağlayan yapılardır.

Sentetik açıklı radar görüntülemede kullanılan geleneksel yöntem hızlı ve işlem maliyetinin düşük olması nedeniyle 2 boyutlu Fourier dönüşümüdür. Radar görüntülemede menzil çözünürlüğü frekans bant genişliğine, çapraz menzil çözünürlüğü ise gözlem açı aralığına bağlı olduğundan 2 boyutlu Fourier dönüşümüyle yüksek çözünürlüklü görüntü elde edebilmek için geniş bant-geniş gözlem açı aralığında veri toplamak gerekmektedir. Ancak gerçek hayatta gerçekleştirilen uygulamalarda bu koşulları sağlamak oldukça zordur. Dar bant-dar açı koşullarında 2 boyutlu Fourier dönüşümü istenen çözünürlüğü sağlayamamaktadır. Literatürde bu problemin çözümü için yüksek çözünürlüklü spektral kestirim yöntemleri kullanılmaktadır. Bu çalışmada spektral kestirim yöntemlerinden MUSIC (Multiple Signal Classification) ve özbağlanımlı (Auto-Regressive) modelleme metodlarına değinilecektir. MUSIC metodu verinin özilişki (otokorelasyon) matrisinin sinyal ve gürültü özvektörlerinin dikliğine dayanmaktadır [2]. Özbağlanımlı modelleme ise 2-boyutlu kartezyen frekans spektrumunun 2-boyutlu lineer kestirimine (linear prediction) dayanmaktadır [3].

MUSIC algoritması ile radar hedef görüntülemede gürültü saçıcıları başarılı bir şekilde bastırılmasına rağmen veri toplanan frekans bandı ve açı sektörü daraldıkça radar hedef görüntüsünde bozulmalar önemli ölçüde artmaktadır. Özbağlanımlı (AR) modellemede ise dar frekans bandı ve açısal sektörde hedef radar görüntüsü korunsa da çok sayıda sahte saçıcılar oluştuğundan görüntüde hedef ile arka plan ayrımı zorlaşmaktadır. Özbağlanımlı modellemede sahte saçıcıların bastırılması amacıyla tekil değer ayrışımı (singular value decomposition-SVD) kullanılır. Bu yöntem özbağlanımlı modelleme ile elde edilen radar hedef görüntüsünde sahte saçıcıları bastırmayı başarsa da radar hedef görüntüsünde veri kaybını engelleyememektedir. Bu çalışma kapsamında önerdiğimiz seyrek özbağlanımlı

(sparse AR) modelleme yönteminde ise veriler dar frekans bandı ve açısal sektörde toplansa dahi sahte saçıcılar başarılı bir şekilde bastırılmaktadır. Ayrıca bu işlemi yaparken görüntülenmesi amaçlanan hedefin görüntüsünde oluşabilecek bozulmayı önemli ölçüde engellemektedir.

MUSIC yönteminde ve özbağlanımlı modelleme yönteminin tekil değer ayrışımı (SVD) çözümünde görüntüleme başarısı saçıcı sayısı kestirimine önemli ölçüde bağlıdır. Bu çalışma kapsamında özgün bir saçıcı sayısı kestirim algoritması da sunulmaktadır. Diğer yandan yeni önerdiğimiz seyrek özbağlanımlı modelleme yönteminde saçıcı sayısı kestirimine ihtiyaç bulunmamaktadır.

Regülarizasyon yöntemleri kötü koşullanmış (ill-posed) problemlerde ek olarak yumuşatma ve seyreklik (sparsity) bilgilerini probleme katarak alternatif çözümler sağlamaktadır. En eski yöntemlerden biri olan Tickhonov regülarizasyonunda ceza terimi olarak bilinmeyen vektörünün 2-normu kullanılmaktadır. 2-norm ceza terimi dahil edilmesi ile geniş değerli bileşenleri kısıtlamakta ve daha yumuşak geçişler sunan çözümler elde edilmektedir. Sonuç direkt (kapalı form) veya konjuge gradyan gibi iteratif yöntemlerle elde edilebilir. Son zamanlarda 0-norm ceza fonksiyonu (penalty function) kullanan seyreklik önceli (sparsity prior) regülarizayon yöntemleri bir çok uygulamada kullanılmaktadır. 0-norm minimizasyonu NP zor problem (NP hard problem) olduğundan cezalandırma fonksiyonu olarak 1-norm kullanılır ve bu yöntemle 0-normunun çözümüne yaklaşılır. Ceza terimi olarak kullanılan 1-norm ile az sayıda sıfırdan farklı katsayı içeren sonuçlar üretilmektedir. 1-norm ceza terimi içeren regülarizasyon problemleri türevlenebilir (differentiable) değildir ve 2-norm durumundan farklı olarak bir kapalı form çözümüne sahip değildir. Diğer yandan bu problemler konveks kuadratik problemlere dönüştürülebilir ve konveks optimizasyon yöntemleriyle çözülebilirler. [1]'de konuşma işaretlerinin lineer kestirimi için regularizasyon tabanlı özbağlanımlı (AR) modelleme kullanılmıştır. [1]'de yazarlar 1-norm ceza terimi içeren özbağlanımlı (AR) model katsayıları ya da kalıntı teriminin (residual) 1-norm minimizasyonunu içeren seyrek kalıntı terimi tanımlamışlardır. Bu çalışmada yazarların sonuçları 2-B özbağlanımlı modellemeye uyarlanmış ve ISAR görüntü iyileştirme problemine uygulanmıştır.

Son yıllarda özellikle askeri alanlarda kritik bir öneme sahip olan SAR sistemlerinde sınıflandırma hedef tespiti ve hedef kimliklendirmesi açısından önem arz etmektedir. SAR'da sınıflandırma ile tespit edilen hedeflerin dost-düşman ayrımı yapılabilmektedir. Bu çalışmada günümüzde önemi her geçen gün artan SAR sistemlerinin farklı metodlara göre sınıflandırma performansının değişimi üzerinde durulmuştur.

Çalışma kapsamında radar hedef görüntülerinin ve sınıflandırma performansının iyileştirilmesi amacıyla özbağlanımlı (AR) katsayılarının kestirimi özgün bir regülarizasyon yöntemi olan seyrek (sparse) yöntemi yapılmaktadır. Sahte saçıcıları bastırmayı ve bu işlemi yaparken de hedef görüntüsünü başarılı bir şekilde korumayı hedefleyen bu yöntemle görüntülemenin yanında sınıflandırma performansının da iyileştiği görülmektedir.

Bu çalışmada SAR sınıflandırma algoritmasında doğrudan görüntüleri kullanmak yerine bu görüntülere özel dönüşümler uygulanarak öznitelik vektörleri çıkartılmış ve elde edilen öznitelik vektör boyutları PCA yöntemi ile indirgenerek yöntemin daha verimli çalışması sağlanmıştır. Sınıflama benzetimleri MATLAB ortamında ve MSTAR veri seti kullanılarak gerçekleştirilmiştir.

Çalışma kapsamında görüntüleme yöntemlerinin başarılarının örneklenmesi için mig-25 simule verileri ve airbus uçağını görüntüleyen radarın gerçek verileri kullanılmıştır.

Çalışmada MSTAR veri seti içerisinde yer alan T72, BMP2 ve BTR70 hedeflerinin verileri kullanılarak farklı spektral kestirim yöntemlerine göre sınıflandırma performansı incelenmiştir.

RADAR TARGET IDENTIFICATION WITH 2-D SPARSE AR MODELLING

SUMMARY

Radars are used for a lot of different military-civilian applications contemporarily. Military applications such as target searching, detecting, surveillance, tracking etc. and civilian applications such as air traffic control, sea navigation, speed control in traffic, meteorology, imaging surface etc. are several samples of applications of radars.

Radar images present a spatial distribution of scattering centers corresponding to an object. In order to characterize an object properly, a radar image must provide a quantitative description of the object's scattering properties, for instance the locations and intensities of the different scattering centers [2].

Radar imaging has been an attractive field for researchers in recent years. To provide high resolution is an important problem in radar imaging. There are hard physical constraints to get high resolution with conventional radars, too wide antenna aperture is required. At this point, importance of SAR (Synthetic Aperture Radars) systems, which uses motion of radar platforms and provides synthetic aperture, appears. SAR systems provides high resolution radar images by forming synthetic aperture and removing the requirement of wide antenna aperture.

Traditional SAR imaging method is 2-D Fourier transform, because of its speed and simplicity. In SAR imaging range resolution depends on frequency bandwidth and cross-range resolution depends on angular width. Because of this condition, wide frequency bandwidth and wide angular width is needed for high resolution SAR images. However it is hard to meet this conditions in real life applications. As a result, 2-D Fourier Transform can not provide high resolution SAR images under narrow bandwidth and narrow angular width circumstances. In the literature, there are some high resolution spectral estimation techniques to get high resolution SAR images in the narrow frequency bandwidth - angular width. MUSIC (Multiple Signal Classification) [2] and AR (Auto-Regressive) Modelling algorithm [3] are the most popular high resolution spectral estimation techniques.

The MUSIC algorithm is based on the orthogonality relationship that exists between the signal and noise eigenvectors of the data correlation matrix.

AR Modelling algorithm is described which improves resolution in both down-range and cross-range. The algorithm is based on two-dimensional forward-backward linear prediction**.** It uses 2-D Cartesian frequency spectra to find the locations of dominant scattering centers associated with a target. Thus, it is assumed that the target can be described by individual nondispersive scattering centers, i.e., the apparent locations of the scattering centers do not change with frequency or aspect angle. It is shown that the algorithm can be used effectively to generate high-quality

radar images using RCS data over small bandwidth and aspect angle sectors [3]. On the other hand, there may be more scattering centers than target has and one can also use singular value decomposition (SVD) to suppress the spurious scattering centers [3].

MUSIC algorithm is a successful method to suppress the spurious scatterers. Nevertheless, when frequency bandwidth and angular sector is narrow, deteriorations affect the radar target image highly. AR modelling method works well in case of narrow frequency band and angular sector; but there are too many spurious scattering centers that prevent to distinguish the radar target image and background. SVD can be used to suppress spurious scattering centers; but it also causes to suppress scattering centers of target. On the other hand, in this study, we present sparsity regularized AR models and apply them to the problem of high resolution radar imaging. We constraint AR coefficient vector to be sparse. By using the sparsity prior we constrain AR coefficient vector to be sparse. The use of resulting coefficient vector yields radar images with reduced side lobes improving the discrimination of the target from the background. This method also works successfully in case of narrow frequency band and angular sector.

Success of MUSIC method and SVD solution of AR modeling is related with prediction of number of target scattering centers. In this study a novel algorithm is offered to predict number of target scattering centers. However, the proposed sparse AR modeling method does not need the prediction of number of target scattering centers.

Regularization methods provide another alternative to the solution of ill-posed problems by introducing additional information such as smoothness or sparsity priors. The Tickhonov regularization is essentially a trade-off between fitting the data and reducing the norm of the solution. The inclusion of 2-norm penalty function restricts large value components and produces smoother solutions. It can be computed directly or by iterative methods such as conjuge gradient method. Recently regularization methods with sparsity prior using 0-norm penalty fuctions have found many applications . Since 0-norm minimization is a NP hard problem, it can be approximated by the use of 1-norm as penalty functions which produces sparse results with few number of non-zero coefficients. Regularization problems which involve 1-norm penalty functions are not differentiable, thus unlike 2-norm case they do not have a closed form solution, but they can be transformed into convex quadratic problems and solved by convex optimization methods. In [1] the sparsity based regularization of AR models is used in the framework of linear prediction of speech signals. The authors defined sparse AR models by including 1-norm penalty or sparse residuals by 1-norm minimization of the residual. In this work we extend their results to the 2D AR modeling and apply to ISAR image formation problem.

SAR imaging based on the 2D linear prediction uses the 2-norm minimization of the prediction error to obtain 2D autoregressive (AR) model coefficients. However, this approach causes many spurious peaks in the resulting image . In this study, a new SAR imaging method based on the 2D sparse AR modeling of backscattered data is proposed. The 2D model coefficients are obtained by the 2-norm minimization of the prediction error penalized by the 1-norm of the prediction coefficient vector. The resulting 2D prediction coefficient vector is sparse, and its use yields radar images with reduced sidelobes compared to the classical 2-norm minization.

This study is mainly about improving performance of classification of targets via SAR. In recent years, especially in military applications, classification of targets is a critical matter for detecting the character of targets. Detected targets can be discriminated as hostile or friend after classification with SAR datas.

Classification section of this study have mainly two parts. Firstly, classification success of the conventional methods, which are FFT, MUSIC (Multiple Signal Classification) and AR (Auto-Regressive) modeling, is investigated with different parameter values. For next step, classification success of the novel method, which is called sparse AR modelling, is obtained.

Instead of using images directly in the SAR classification algorithm, feature vectors have been extracted by applying special transforms and the method performance has become more effective by reducing feature vectors dimensions with PCA method. Classification simulations will be run in MATLAB and by using MSTAR data set.

For presentation success of radar imaging of different methods, simulated data of mig-25 plane's and real imaging, collected from airbus plane, are used.

T72, BMP2 and BTR70, targets of MSTAR data sets, are used to test the performance of classification.

1. GİRİŞ

Yapay açıklıklı radar (SAR) görüntüleri, bir cismin yüksek enerji saçılma merkezlerinin iki boyutlu (2-B) dağılımını gösterir. Bu çalışmada bilinmeyen bir cismin SAR görüntüsünün tanımlanması ve sınıflandırılması amaçlanmıştır. Bunun için yapılması gereken ilk işlem farklı açılardan bir bölge üzerinde çeşitli hedeflerin SAR görüntülerini içeren bir veri tabanı oluşturmaktır. Sonraki adımda, elde edilen sınıfı bilinmeyen SAR görüntüleri saklanan veri tabanı ile karşılaştırılır. Bilinmeyen SAR görüntülerini başarılı bir şekilde tanımlamak için ihtiyaç duyulan karşılaştırma sayısı genellikle çok fazla olmalıdır. Böylece yeterli bir sınıflama performansı garantilenebilir.

Çalışmada radar hedef görüntülerini elde etmek için 2 boyutlu FFT, MUSIC [2] ve özbağlanımlı (AR) modellemenin [3] yanında bu çalışma kapsamında önerilen seyrek özbağlanımlı (sparse AR) modelleme yöntemi kullanılmış ve yöntemlerin sınıflandırma performansları karşılaştırılmıştır.

Görüntülemede geleneksel olarak kullanılan 2-B Fourier dönüşümüne dayalı radar görüntülemenin avantajları ve dezavantajları mevcuttur. 2-boyutlu SAR görüntüsü görüntülenmek istenen hedefin menzil ve çapraz menzil profilinin işlenmesi sonucu elde edilmektedir. 2-boyutlu FFT yöntemi frekans uzayında toplanan verileri ters Fourier dönüşümü ile konum uzayına çevirerek görüntünün elde edilmesini sağlar. Fourier dönüşümü Hızlı Fourier Dönüşümü (FFT – Fast Fourier Transform) ile gerçekleştirildiğinde hem işlem zamanı hem de bu işlemin hesaplama yükü açısından önemli ölçüde tasarruf sağlanır. Diğer yandan bu yöntem frekans bant genişliği ve hedefin izlendiği açı aralığı yeterince geniş olduğunda yeterli çözünürlüğü sağlayabilmektedir. Burada görüntü çözünürlüğü frekans bant genişliği ve izlenen açı aralığıyla doğru orantılı olarak artar. Pratikte yüksek bant genişliğini ve geniş açı aralığını sağlamak çoğu zaman mümkün olmadığından bu yöntemin kullanım alanı daralmaktadır [2, 3].

MUSIC algoritması ile radar hedef görüntüleme gerçekleştirilirken uzamsal yumuşatma işlemi sırasında verinin boyutu düşeceğinden efektif bant genişliği de azalır ve elde edilen görüntünün çözünürlüğü de kısmen azalır. Bu dezavantajına rağmen MUSIC algoritması geleneksel Fourier dönüşümüne dayalı radar görüntüleme yöntemine göre daha iyi sonuç vermektedir [2]. Uzamsal yumuşatma işleminde kullanılacak alt matris boyutunun seçimi MUSIC algoritmasının performansı için önemlidir. Alt matris boyutu arttıkça MUSIC algoritması daha yüksek çözünürlük sunar ancak dekorelasyon performansı düşerek bazı baskın saçıcı noktaları tespit edilemez duruma gelebilir. Bunun yanında MUSIC yönteminde saçıcı sayısının doğru bir şekilde kestirimi önemlidir. Saçıcı sayısının bilinmemesi ya da yanlış kestirilmesi elde edilen sonuçları önemli oranda etkilemektedir [2].

Özbağlanımlı (AR) modelleme algoritması ile menzilde ve çarpraz menzilde yüksek çözünürlüklü radar hedef görüntüsü elde edilebilir. Algoritma 2 boyutlu lineer kestirim (ileriye doğru [forward] ve geriye doğru [backward] lineer kestirim) tabanlı çalışan bir algoritmadır. Hedefin baskın saçıcı merkezlerinin konumlarını bulabilmek için 2-boyutlu kartezyen frekans spektrumu kullanılır. Hedefin birbirlerinden ayrı, dağınıklaşmamış (nondispersive) saçıcı merkezlerinden oluştuğu varsayılmaktadır. Bu varsayım hedef saçıcı merkezlerinin frekans ve bakış açısı ile değişmediğini ifade etmektedir. Bu yöntemle dar frekans bandı ve dar açı sektöründe toplanan RCS verilerinden yüksek kalitede radar görüntüleri elde edilebildiği gösterilmiştir. Özbağlanımlı (AR) (Auto-Regressive) modelleme yöntemi özellikle dar bant genişliğinde ve dar açı aralığında veri toplandığı durumlarda 2 boyutlu Fourier dönüşümüne dayalı radar hedef görüntüleme yöntemine göre daha iyi çözünürlük sağlamaktadır [3]. Özbağlanımlı modelleme ile radar hedef görüntüleme yönteminde sahte saçıcıların sayısı hedefin arkaplandan ayırt edilmesini zorlaştırabilir. Bu durumda sahte saçıcıların bastırılması için en küçük kareler çözümlerinde "tekil değer ayrışımı (SVD)" kullanılabilir [3]. Tekil değer ayrışımı sahte saçıcıları bastırırken bir miktar radar hedefi görüntüsü üzerinde de bozulmaya sebep olur. Bu çalışma kapsamında önerilen seyrek özbağlanımlı (sparse AR) modelleme yönteminde ise veriler dar frekans bandı ve açısal sektörde toplansa dahi radar görüntüsündeki sahte saçıcıların başarılı bir şekilde bastırıldığı ve hedefin görüntüsünde oluşabilecek bozulmaların önemli ölçüde engellendiği gösterilmektedir. [1]'de konuşma işaretlerinin lineer kestirimi için regularizasyon

tabanlı özbağlanımlı (AR) modelleme kullanılmıştır. Yazarlar 1-norm ceza terimi içeren özbağlanımlı (AR) model katsayıları ya da kalıntı teriminin (residual) 1-norm minimizasyonunu içeren seyrek kalıntı terimi tanımlamışlardır. Bu çalışmada yazarların sonuçları 2-B özbağlanımlı modellemeye uyarlanmış ve ISAR görüntü iyileştirme problemine uygulanmıştır.

Bu çalışmada sınıflandırma başarısının ölçümü için BMP2 ve T72 tankları ve BTR70 askeri nakliye aracının saçıcı alanlarından elde edilen ham verileri kullanılmıştır. Bu veriler "Movingand Stationary Target Acquisition and Recognition (MSTAR)" programı kapsamında toplanmıştır. İlk aşamada farklı radar hedef görüntüleme yöntemleri ile SAR sınıflandırma başarıları incelenmiştir. İkinci aşamada ise frekans bant genişliği ve açısal sektör azaltılarak verinin (dokümanda "dar bantlı veri" şeklinde ifade edilmektedir) çözünürlüğü düşürülmüştür. Bu durumda geleneksel olarak kullanılan FFT, MUSIC ve özbağlanımlı (AR) modelleme algoritmalarının yanı sıra yeni önerdiğimiz seyrek özbağlanımlı (sparse AR) modelleme yönteminin sınıflandırmadaki başarısı incelenmiştir.

Bu çalışma sırasında kullanılan yüksek çözünürlüklü spektral kestirim yöntemleri kendi içlerinde de farklı sınıflandırma başarıları sergilemektedir. MUSIC'te alt matris boyutu; özbağlanımlı (AR) modellemede modelleme seviyesi ve seyrek özbağlanımlı modelleme yöntemi için modelleme seviyesi ve λ parametrelerine bağlı olarak sınıflandırma başarısı değişmektedir.

Bu çalışmada kullanılan sınıflandırma yaklaşımında öznitelik vektörleri SAR hedef görüntüsünün içerdiği özellikleri en etkin şekilde kullanmak üzere tasarlanmıştır. Bu sebeple her türlü SAR görüntüsüne uygulanabilir. Yöntemde elde edilen öznitelik vektöreri k-ortalamalar algoritması kullanılarak sınıflandırma işlemine tabi tutulur. Ayırt edici özelliklerin kaybı SAR görüntülerinin özellikleri göz önünde bulundurularak en az seviyede tutulur [4]. Farklı sıkıştırma yöntemleri ile SAR görüntüsünden kullanılacak öznitelikler elde edilir.

Çalışmanın ilk bölümünde çalışma ile ilgili genel bilgiler yer almaktadır.

İkinci bölümde SAR sistemleri ile ilgili temel bilgiler verilmiştir. Ayrıca FFT, MUSIC, özbağlanımlı (AR) modelleme ve seyrek özbağlanımlı (sparse AR) modelleme algoritmalarına dayalı radar görüntüleme yöntemleri ile ilgili teorik bilgiler ve görüntüleme uygulamaları yer almaktadır.

Üçüncü bölümde radar hedef sınıfladırma yöntemine, sınıflandırma uygulamalarına, sonuçlarına ve değerlendirmelere yer verilmiştir.

Son bölümde ise çalışma sonuçlarıyla ilgili değerlendirmeler ve ileri çalışmalar için öneriler yer almaktadır.

2. SENTETİK AÇIKLIKLI RADAR İLE HEDEF GÖRÜNTÜLEME

2.1. Amaç

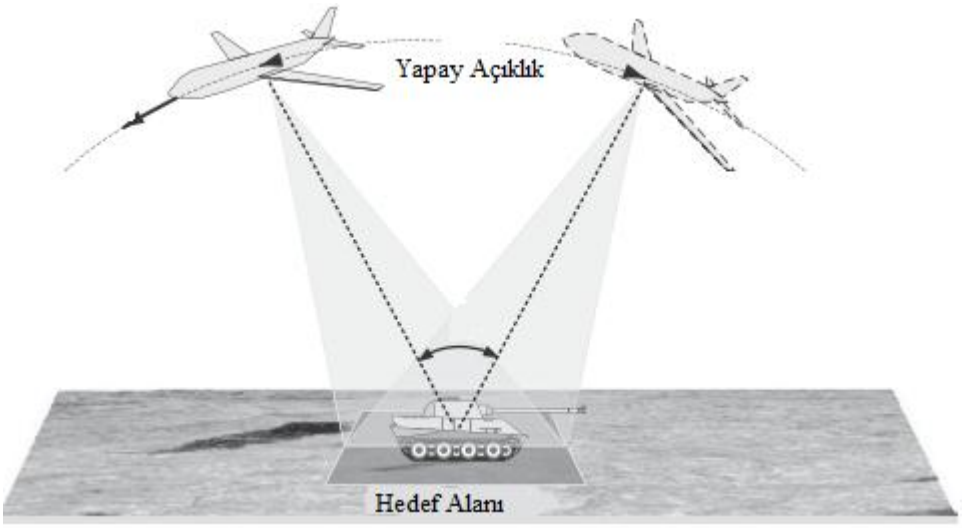
Bu bölümde SAR ile ilgili genel bilgiler sunulacaktır.

2.2. SAR ile İlgili Genel Bilgiler

Geleneksel radar sistemlerinin çözünürlük kısıtları önemli boyutlardadır. Bu radarlarda menzil çözünürlüğünü (range resolution) arttırmak için darbe süresini kısaltmak gerekmektedir. Ancak darbe süresinin kısalması işaret-gürültü oranını azaltmaktadır. Geleneksel radar sistemlerinde arzu edilen çözünürlüğü yakalamak için pratikte gerçekleştirilemeyecek anten boyutları gerekmektedir.

Yapay açıklıklı radar (synthetic aperture radar-SAR), geleneksel radar sisteminin kısıtlarını fiziksel gerçeklenebilirlik açısıdan makul düzeye çekmek için geliştirilmiştir. Yapay açıklıklı radar sistemlerinde, bir uydu veya bir uçak ile taşınan radar, mümkün olduğunca sabit bir hızla belirli bir yönde hareket ettirilmektedir. Radar, ileri yönlü hareketi esnasında belirli bir süre boyunca belirli sayıda darbe göndermektedir. Radar tarafından toplanan yansıyan işaretler uygun bir biçimde kaydedilmekte ve birleştirilmektedir. Bu sayede yapay açıklık oluşturulmaktadır. Platformun hızı ve toplam darbe gönderme süresi yapay açıklığın boyunu belirlemektedir. Yapay açıklıklı radar yönteminde her nokta daha uzun süre gözlenmektedir. Bu sayede platformun ilerleme yönüne paralel olan yanca açı (azimuth) doğrultusunda aynı boydaki gerçek açıklıklı bir antene göre daha yüksek çözünürlük elde edilir [6].

Ters yapay açıklıklı radarlarda (ISAR-Inverse Seynthetic Aperture Radar) ise SAR sistemlerinden farklı olarak radar sabit durmakta, hedef hareket etmektedir. Bu durumda da hedeften farklı açılarda veri toplanabilmektedir. Radarın ISAR ya da SAR olması yapay açıklık oluşturma mantığında bir değişiklik oluşturmamaktadır. Bu noktada önemli olan, hedef ve radarın birbirlerine göre göreceli hareketlerinden faydalanarak, farklı açılardan veri toplayabilmektir.



Şekil 2.1: Yapay açıklıklı radar sistemi [7].

SAR görüntüsü oluşturmak için kullanılan geleneksel yöntem hesaplama kolaylıkları ve hızı nedeniyle 2 boyutlu Fourier dönüşümüdür. Menzil ve çapraz menzil çözünürlükleri ölçüm yapılan frekans bant genişliği ve açı gözlem aralığı ile doğru orantılı olduğundan bu değerlerin kısıtlı olduğu durumlarda 2 boyutlu Fourier dönüşümü düşük çözünürlük sunar. Bu koşullarda Fourier dönüşümü yerine yüksek çözünürlüklü spektral kestirim yöntemlerinin kullanılması SAR görüntüsünün çözünürlüğünü arttırmaktadır. Özbağlanımlı (AR) Modelleme, MUSIC (Multiple Signal Classification) [2-3] bu yöntemlerden ikisidir. Bu yöntemlerin Fourier dönüşümü yöntemine göre en büyük avantajları dar bant koşullarında bir birine yakın saçılma noktalarını ayırt edebilmesidir [8]. MUSIC (Multiple Signal Classification) metodu elde edilen verinin özilişki matrisinin sinyal ve gürültü özvektörlerinin dikliğine dayanmaktadır [2]. Özbağlanımlı (AR) modelleme ise 2-boyutlu kartezyen frekans spektrumunun 2-boyutlu lineer kestirimine (linear prediction) dayanmaktadır [3].

2.3. SAR Görüntüleme Teknikleri

2.3.1. 2-B Fourier dönüşümüne dayalı radar hedef görüntüleme

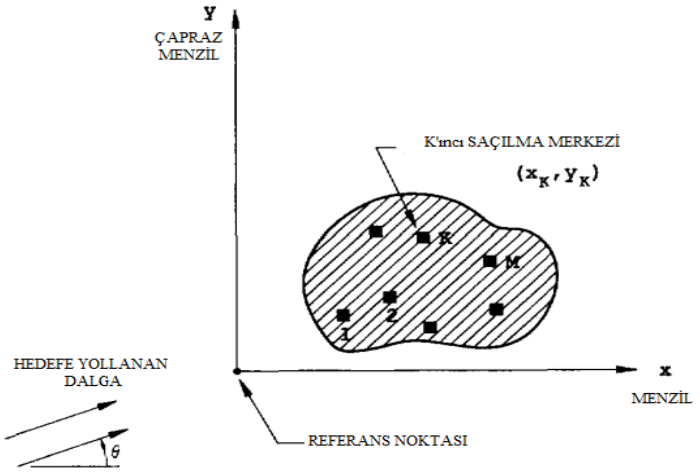
2-boyutlu SAR görüntüsü görüntülenmek istenen hedefin menzil ve çapraz menzil profilinin işlenmesi sonucu elde edilmektedir. 2-boyutlu FFT yöntemi frekans uzayında toplanan verileri ters Fourier dönüşümü ile konum uzayına çevirerek

görüntünün elde edilmesini sağlar. Frekans bant genişliği ve hedefin izlendiği açı aralığı yeterince geniş olduğunda bu yöntem yeterli çözünürlüğü sağlayabilmektedir. Burada görüntü çözünürlüğü frekans bant genişliği ve izlenen açı aralığıyla doğru orantılı olarak artar. Pratikte yüksek bant genişliğini ve geniş açı aralığını sağlamak çoğu zaman mümkün olmadığından bu yöntemin kullanım alanı daralmaktadır.

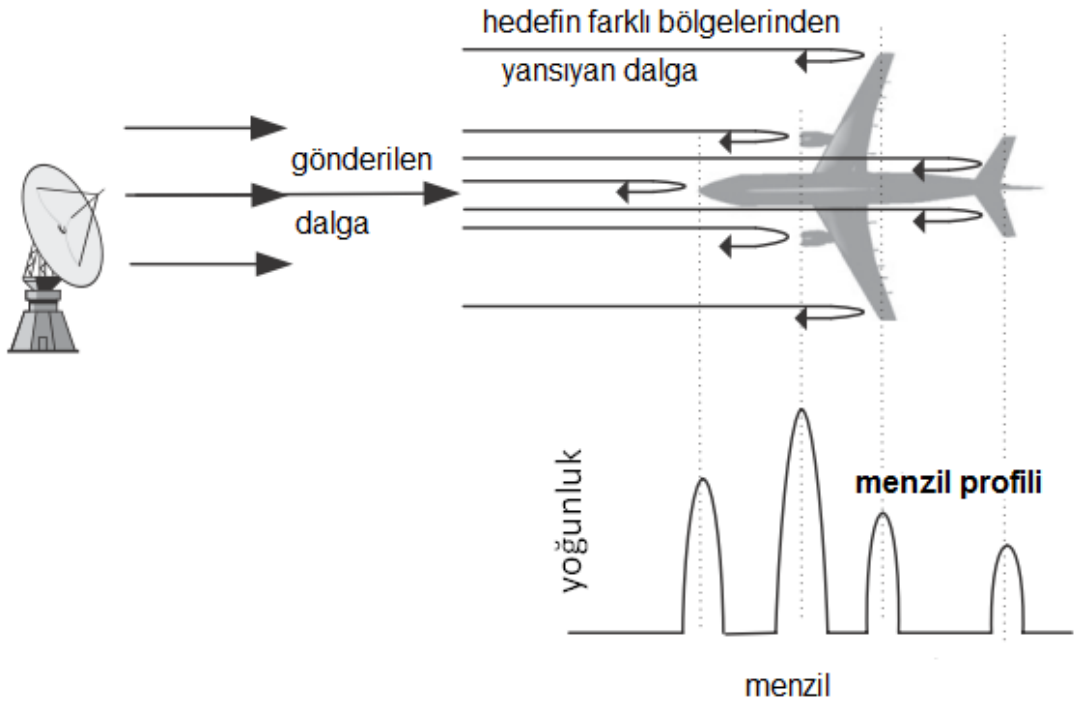
SAR görüntülerini elde etmek için genellikle frekans uzayındaki veriden 2-boyutlu Fourier dönüşümü ile konum uzayına geçilir. Bu dönüşüm işlemini sağlıklı bir şekilde yapabilmek için hedefin ya da SAR platformunun doğrusal olmayan hareketinden kaynaklı problemlerin giderilmesi, faz ayarlamalarının, menzil hizalama (range alignment) işlemlerinin ön işlem olarak yapılması gerekmektedir. Bu çalışmada bu problemlerin giderildiği, elde olan ham datanın bu işlemlerden geçirildiği varsayılmıştır.

SAR görüntüsü elde etmek en sık kullanılan yöntem 2 Boyutlu Fourier dönüşümüdür. Fourier dönüşümü Hızlı Fourier Dönüşümü (FFT – Fast Fourier Transform) ile gerçekleştirildiğinde hem işlem zamanı hem de bu işlemin hesaplama yükü açısından büyük bir tasarruf sağlanmış olunur [5].

SAR sistemlerinde menzil ve çapraz menzil profilinin elde edilip görüntünün gerçek zamanlı oluşturulabilmesi için genelde frekans atlamalı (chirp) darbeler kullanılmaktadır. Görüntü elde edilmesinde kullanılacak iki boyutlu veri, hedefe farklı frekans ve açı aralıklarıyla yollanan elektromanyetik dalganın hedefin saçılma noktalarından yansıyıp saçılması sonrasında radar tarafından toplanmasıyla oluşur.



Şekil 2.2: M saçılma merkezine sahip hedef [3].



Şekil 2.3: Model Bir Uçağın Menzil Profili [7].

Şekil 2.3'de görüldüğü üzere radar anteninden gönderilen dalgalar, hedefin saçılma merkezlerinden saçılıma uğrar. Eğer saçılma merkezleri radara göre farklı konumlarda olurlarsa bu merkezlerden saçılan dalgalar radara farklı zaman dilimlerinde ulaşacağından hedefin menzil profili oluşturulmuş olur. Ancak aynı uzaklık üzerindeki birden fazla saçılma merkezi tek bir saçılma merkezi olarak görüleceğinden menzil profiline de bu şekilde yansıyacaktır. Bu durum sadece menzil profili kullanılarak hedef hakkında ayrıntılı bir bilgi edinmemin mümkün olmadığını göstermektedir [7].

Gönderilen dalganın bant genişliği B, ışık hızı c ile ifade edildiğinde menzil çözünürlüğü Δx aşağıdaki bağıntıyla hesaplanır.

$$\Delta x = \frac{c}{2B} \tag{2.1}$$

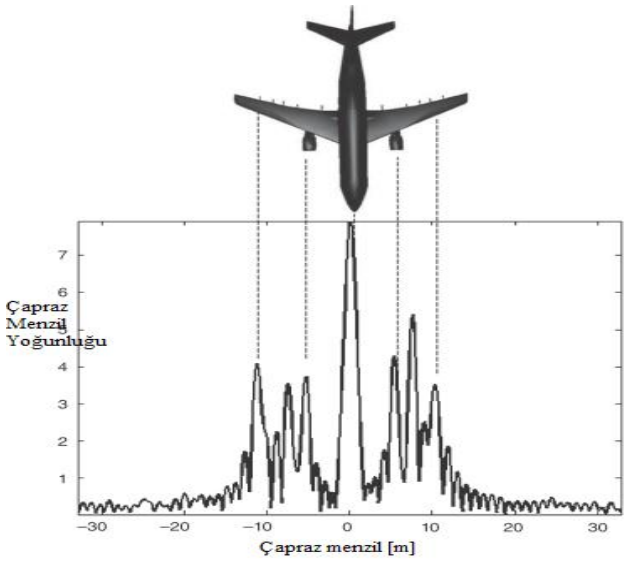
(2.1) bağıntısından da görüldüğü üzere menzil çözünürlüğü sinyalin bant genişliğine bağlıdır ve dalganın şeklinden bağımsızdır [9]. Bunun yanında menzil örnekleme

sayısı *N* olmak üzere radarın gözlemleyeceği alan $X_{\max}$ aşağıda belirtilen bağıntıyla bulunur.

$$X_{\max} = N.\Delta x \tag{2.2}$$

(2.2) bağıntısına göre hedefin tamamının gözlemlenebilmesi için $X_{\max}$ değerinin en az hedefin boyu kadar olması gerekmektedir [7].

Çapraz menzil profili radar tarafından farklı açı aralıklarında gönderilen ve hedefin saçılma merkezlerinden saçılan elektromanyetik dalgaların toplanması sonucu elde edilmektedir.



Şekil 2.4: Model Bir Uçağın Çapraz Menzil Profili [2].

f_c merkez frekansı, Ω gözlem açı genişliği olmak üzere çapraz menzil çözünürlüğü Δy aşağıdaki gibi ifade edilir.

$$\Delta y = \frac{c}{2 f_c \Omega} \tag{2.3}$$

(2.3) bağıntısında görüldüğü üzere çapraz menzil çözünürlüğünün iyileşmesi için gözlem açısı genişliğinin artması gerekmektedir. Çapraz menzil örnekleme sayısı *M* olmak üzere radarın çapraz menzilde gözlemleyebileceği alan $Y_{\max}$ da;

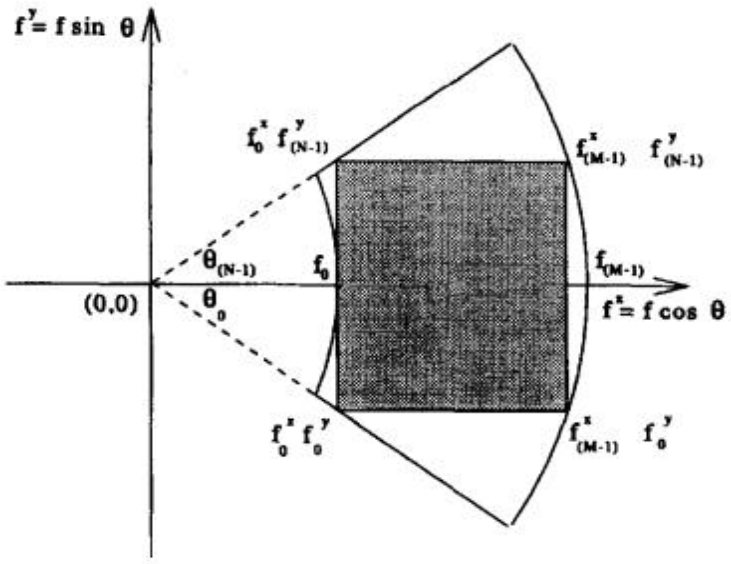
$$Y_{\max} = M.\Delta y \tag{2.4}$$

bağıntısıyla gösterilir. Menzil profilinde olduğu gibi hedefin çapraz menzilde tamamının görüntülenebilmesi için $Y_{\max}$ yeteri kadar büyük seçilmelidir [7].

Radar görüntüsü, hedefin sınırlı sayıdaki saçılma merkezi ve bu saçılma merkezlerinin etkileşimi sonucu toplanan veriler toplamı olarak tanımlanabilir. Hedeften yansıyan sinyaller hedefin her saçılma merkezinden saçılan kompleks yapıdaki saçılma sinyalleri olarak temsil edilir. d saçılma merkezinden oluşan ve M adet frekans f_m ($m = 0,1,...,M-1$) ve N adet açı θ_n ($n = 0,1,...,N-1$) değerinde ölçülen radar hedefinden saçılan sinyal aşağıdaki gibi ifade edilir.

$$x'(m,n) = \sum_{k=1}^{d} s_k . e^{j4\pi \frac{f_m}{c}(x_k \cos\theta_n - y_k \sin\theta_n)} + u(m,n) \tag{2.5}$$

Bu ifadede s_k k'ıncı saçılma merkezinin kompleks saçılma yoğunluğunu, x_k ve y_k k'ıncı saçılma merkezinin alınan referans noktasına göre iki boyutlu konumunu, c ışık hızını ve $u(m,n)$ ek gürültüyü ifade eder. Bu gürültünün genellikle sıfır ortalamalı ve σ^2 varyanslı beyaz Gaussian gürültüsü olduğu varsayılmaktadır [2].



Şekil 2.5: Polar Format Algoritması ile (f, θ) uzayından (f^x, f^y) uzayına geçiş [1].

Şekil 2.5'de görüldüğü üzere frekans – açı (f,θ) uzayına eşit aralıklarla dağılmış radar verisi kartezyen uzayında eşit aralıklarla dağılmış veriyi tam olarak karşılayamaz [5]. Bilindiği üzere iki boyutlu radar görüntüleme işleminde frekans uzayı menzil profilini, açı uzayı ise çapraz menzil profilini oluşturmaktadır. (2.5) bağıntısından da açıkça görüleceği üzere iki Fourier dönüşüm çifti
($f\cos\theta \Leftrightarrow x; f\sin\theta \Leftrightarrow y$) f ve θ'ye göre birbirinden ayrılabilir durumda değildir. Ölçülen veri dar açı ölçüm aralığında aralığında olduğunda küçük açılar yaklaşımından ($\cos\theta \approx 1$ ve $\sin\theta \approx \theta$) faydalanılarak veri ayrılabilir Fourier çiftlerine dönüştürülebilir. Ancak bu yaklaşım sonucu elde edilen görüntüde odaklama sorunu oluşur. Odaklanmış görüntü Şekil 2.5'te gösterildiği üzere frekans-açı uzayındaki verinin ayrılabilir değişkenleri $f^x = f\cos\theta$ ve $f^y = f\sin\theta$ kullanılarak polar format algoritması ile kartezyen koordinatlara (rectangular grid) interpole edilmesiyle elde edilir. Bu işlemler sonucunda denklem aşağıdaki şekilde yeniden yazılabilir.

$$x'(m,n) = \sum_{k=1}^{d} s_k . e^{j\frac{4\pi}{c}(f_m^x x_k - f_n^y y_k)} + u(m,n) \qquad \textbf{(2.6)}$$

Şekil 2.5'te görüldüğü üzere polar format algoritması ile interpolasyon yapılmış veri artık f^x ve f^y doğrultusunda eşit artım aralıklarıyla kartezyen koordinata yayılmıştır. Bu veriye Fourier dönüşümü uygulandığında klasik radar görüntüsü elde edilebilir [2].

Görüntü iyileştirme için "sıfır ekleme", "pencereleme" gibi yöntemler kullanılabilir [7].

2.3.2. Yüksek çözünürlüklü SAR görüntüleme teknikleri

Fourier dönüşümüne dayanan geleneksel radar görüntüleme teknikleri hesaplama kolaylıkları ve işlemci gücünü minimum seviyede kullanmaları nedeniyle sıkça kullanılmaktadır [10]. Ancak bu teknikler kısıtlı bir çözünürlük sunmaktadır. Menzil çözünürlüğü bant genişliğine, çapraz menzil çözünürlüğü ise gözlem açı genişliğine bağlı olduğundan yüksek çözünürlüklü radar görüntüsü elde edebilmek için bant

genişliği ve açı gözlem aralığının yeterince büyük olması gerekmektedir. Ancak pek çok durumda böyle bir imkan sağlanamamaktadır. Özellikle hedefin saçılma noktalarının çok farklı frekans ve açı aralıklarında gözlemlenebildiği SAR görüntülemede istenen görüntüler elde edilememektedir [3]. Kısıtlı verilerin bulunduğu bu durumlarda spektral kestrim yöntemleri sıkça kullanılmaktadır [10].

Yüksek çözünürlüklü modern spektral kestirim yöntemleri Fourier yöntemiyle gerçekleştirilen SAR görüntüleme tekniklerine güçlü alternatifler sunar. Bu teknikler klasik yöntemlere göre daha iyi çözünürlük ve kontrast sunmaktadır [11].

Yüksek çözünürlüklü spektral kestirim yöntemleri veri genişletme ve kovaryans temelli metodlardır. Veri genişletme yönteminde dar bant genişliği - gözlem açı aralığında elde edilen veriler frekans-açı uzayında genişletilir. Bu genişletme için özbağlanımlı (auto-regressive) modelleme kullanılır. Kovaryans temelli spektral kestrim tekniklerinde ise amaç korelasyon matrisinin kestirimidir.

İşlem yükünün artmasına rağmen yüksek çözünürlüklü spektral kestirim yöntemleri FFT'ye göre daha iyi çözünürlük sunmaktadır. İşlem yükünün artması alınan sinyallerin kovaryans matrislerinin özdeğer ayrıştırma (eigenvalue decomposition) işleminden kaynaklanmaktadır. MUSIC algoritmasında çözünürlük korelasyon matrisinin alt matris boyutuna, özbağlanımlı (AR) modelleme algoritmasında ise modelleme seviyesine önemli oranda bağlıdır.

MUSIC algoritmasında artan alt matris boyutuyla, artan spektral bant genişliğine bağlı olarak, çözünürlük artar. Diğer yandan alt matris sayısı azaldıkça ya da diğer bir tabirle alt matris boyutu arttıkça kovaryans matrisi kestirimindeki doğruluk azalmaktadır. Kovaryans matrisinin kestirimi ise dinamik alanı doğrudan etkilemektedir. Dinamik alan, piksel genliklerinin hangi değer aralıklarında olduklarını ifade etmektedir ve genellikle çözünürlükle birlikte görüntü kalite göstergesi olarak kullanılır [5]. Dinamik alan şu şekilde ifade edilir:

$$Dinamik\ Alan = 20\log(P_{maks}) - 20\log(P_{min}) = 20\log\left(\frac{P_{maks}}{P_{min}}\right) \qquad \textbf{(2.7)}$$

Burada P_{maks}ve P_{min}, sırasıyla, lineer ölçütlerde maksimum ve minimum genlik değerlerini ifade etmektedir.

Ortalama örtüşen alt matris sayısı azaldıkça SAR görüntülerinin dinamik alanı azalmaktadır. Buradan hedef ile arka plan ayrımının zorlaştığı anlaşılabilir. Genel olarak daha düşük hesaplama süreleri gerçek-zamanlı sistemlerde daha çok tercih edilir. Küçük alt matris boyutları düşük çözünürlüğe rağmen bu zaman gereğini iyileştirilmiş dinamik alan ile birlikte karşılayabilir. Sonuç olarak radar hedef sınıflandırma başarısı için çözünürlük ve dinamik alan iki etkin parametredir ve bu parametreler alt matris boyutunun artması/azalması ile birbirleri ile çelişkili değerler alırlar [5].

AR modellemede ise modelleme seviyesi arttıkça çözünürlük artmakta; fakat hedef ile arka plan ayrımının zorlaştığı görülmektedir. Konunun ayrıntılarına 2.3.2.2 *Özbağlanımlı (AR) modelleme algoritması* başlığında değinilmektedir.

2.3.2.1. MUSIC algoritması

Yüksek çözünürlüklü radar görüntüleme teknikleri hedefi daha iyi ayırt etme özelliği dışında radarın istenen verileri elde etmek için çok fazla açı aralığında çalışmasını da engelleyerek radar sistemlerinin veritabanları için daha az hafıza kullanmalarını sağlar[8]. Uygulamadaki zorluklardan ötürü geniş bant genişliği ve geniş açı aralıklarında ölçüm yapmak zor olduğundan dar bant – dar açı durumlarında Fourier yöntemi kısıtlı çözünürlük sunmaktadır. Bunun yanında MUSIC (Multiple Signal Classification) algoritması aynı bant genişliklerinde Fourier yöntemine göre daha iyi çözünürlük sunmaktadır. MUSIC algoritması Fourier yöntemine göre daha kompleks bir yapıda olduğu için daha fazla hesaplama gücü kullanmasına rağmen günümüz işlemci teknolojileriyle bu algoritmayla gerçek zamanlı görüntüler elde edilebilmektedir [12].

Fourier dönüşümünde olduğu gibi MUSIC dahil tüm yüksek çözünürlüklü spektral kestrim yöntemlerinde frekans-açı uzayında elde edilen görüntünün odaklanma probleminin giderilmesi için kartezyen düzleme eşit aralıklarla yayılması gerekmektedir [9]. Bunun için polar format algoritmasında da kullanılan interpolasyon adımı (polar koordinatlardan kartezyen frekans koordinatlarına geçiş) gerçekleştirilir.

(2.6) bağıntısında ifade edilen interpole edilmiş yapıdaki sinyal vektör notasyonu kullanılarak aşağıdaki gibi yazılabilir.

$$\mathrm{x} = \mathrm{As} + \mathrm{u} \tag{2.8}$$

(2.8) bağıntısındaki değişkenler sütunlarına göre dizilmiş vektörler olarak aşağıdaki gibi yazılırsa,

$$\mathrm{x} = [x_{00} x_{10} \ldots x_{M-10} x_{01} \ldots x_{M-1N-1}]^T \tag{2.9}$$

$$\mathrm{s} = [s_1 s_2 \ldots s_d]^T \tag{2.10}$$

$$\mathrm{u} = [u_{00} u_{10} \ldots u_{M-10} u_{01} \ldots u_{M-1N-1}]^T \tag{2.11}$$

$$\mathrm{A} = [\mathrm{a}(x_1, y_1)\, \mathrm{a}(x_2, y_2) \ldots \mathrm{a}(x_d, y_d)] \tag{2.12}$$

$$\mathrm{a}(x_k, y_k) = [e^{j\frac{4\pi}{c}(f_0^x x_k - f_0^y y_k)}\ e^{j\frac{4\pi}{c}(f_1^x x_k - f_0^y y_k)} \ldots e^{j\frac{4\pi}{c}(f_{M-1}^x x_k - f_0^y y_k)}\ e^{j\frac{4\pi}{c}(f_0^x x_k - f_1^y y_k)} \ldots e^{j\frac{4\pi}{c}(f_{M-1}^x x_k - f_{N-1}^y y_k)}]^T \tag{2.13}$$

Yukarıdaki denklemlerde d saçıcı sayısını, T matris devriğini (transpose), A $MN \times d$ boyutlarındaki matrisi ve $\mathrm{a}(x_k, y_k)$ ise her sinyalin mod vektörünü ifade eder.

MUSIC algoritmasında ilk olarak radar verisi kullanılarak özilişki (otokorelasyon) matrisi elde edilir. Özilişki matrisi aşağıdaki gibi tanımlanır:

$$R_{xx} = E[\mathrm{x}\mathrm{x}^H] \tag{2.14}$$

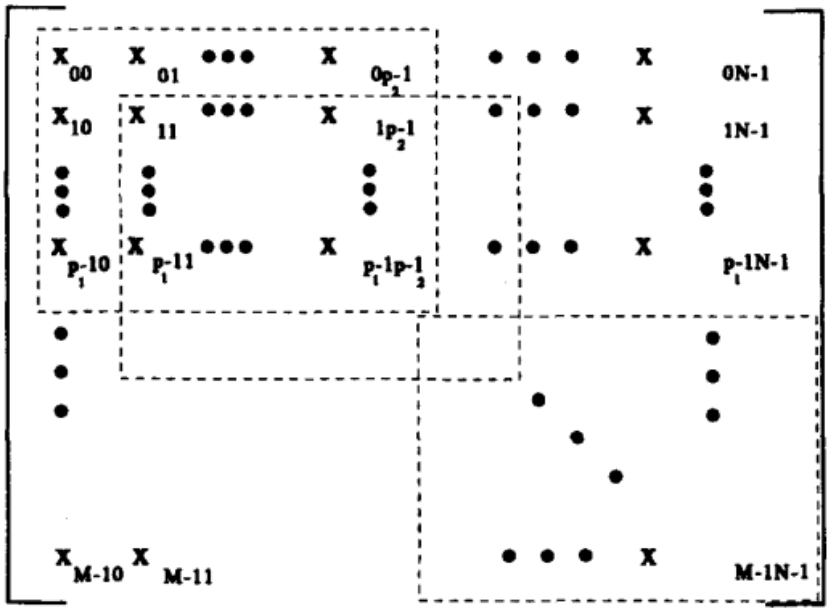
(2.14) bağıntısında E beklenen değeri, x ise radar verisinin sütun olarak dizilmiş halini ifade eder. H ise kompleks eşlenik hermisyen işaretidir.

İkinci aşamada özilişki matrisinin özvektörleri hesaplanır. Özilişki matrisinin özvektörleri sinyal ve gürültü olmak üzere iki alt uzaya ayrılır. MUSIC algoritması da verininin özilişki matrisinin sinyal ve gürültü özvektörlerinin dikliğine dayanmaktadır. **E**, sütunları $(MN - d)$ R_{xx} özilişki matrisinin gürültü özvektörlerinden oluşan $MN \times (MN - d)$ boyutunda bir matris olmak üzere her bir saçılma merkezinin yeri (2.13) bağıntısında belirtilen mod vektörü $\mathrm{a}(x, y)$ kullanılarak ve (2.10) bağıntısının maksimum noktaları araştırılarak kestirilir [12].

$$P_{\text{MUSIC}}(x,y) = \frac{\text{a}(x,y)^H \, \text{a}(x,y)}{\text{a}(x,y)^H \, \text{EE}^H \text{a}(x,y)} \qquad \textbf{(2.15)}$$

(2.15) bağıntısının uzamsal uzayındaki tepe noktaları farklı saçılma merkezlerinin yerlerini gösterir. Görüntüdeki spektral tepe noktaları saçılma merkezlerinin saçılma yoğunlukları hakkında bilgi vermez. MUSIC algoritmasında saçılma merkezlerinin genliklerinin kestirimi yapılmamaktadır. Bu işlem için en küçük kareler yöntemi kullanılabilir [2].

Normal şartlarda özilişki matrisinin kestirimi birden çok gözlem sonucu elde edilen verilerin ortalaması hesaplanarak gerçekleştirilir. Eğer farklı saçıcı merkezlerinden gelen katkılar ilişkisiz ise bu ortalama alma işlemi sonucunda full rank özilişki matrisi elde edilir. Ancak radar uygulamalarında genellikle sadece bir tane veri vektörü mevcuttur.



Şekil 2.6: Uzamsal Yumuşatma (Spatial Smoothing) Yöntemi [2].

Sadece bir adet veri vektörünün bulunduğu durumda, özilişki matrisini full rank matris haline getirmek için 1 boyutlu işlemlerde başarılı sonuçlar veren uzamsal yumuşatma işlemi 2 boyutlu işlemlere uyarlanabilir [13]. 2 boyutlu uzamsal yumuşatma işlemi Şekil 2.6'da gösterilmiştir.

Şekil 2.6'da görüldüğü üzere interpole edilmiş veri üzerinde $L = (M+1-p_1)\,\text{x}\,(N+1-p_2)$ sayıda alt matris tanımlanır. Her bir alt matrisin boyutu

$p_1 \text{ x } p_2$ olacaktır. x_l'yi l'nci alt matrisin sütun bazlı dizilen vektörü olarak alırsak l 'nci alt matrise göre kestirilen özilişki matrisi aşağıdaki gibi olacaktır.

$$\hat{\text{R}}_l = \text{x}_l \text{x}_l^H \tag{2.16}$$

(2.16) bağıntısından yola çıkarak toplam özilişki matrisi R_{xx} de aşağıdaki gibi hesaplanır:

$$\text{R}_{xx} = \frac{1}{2L} \sum_{l=1}^{L} (\hat{\text{R}}_l + J\, \hat{\text{R}}_l^{*}\, J) \tag{2.17}$$

'*' işareti matrisin kompleks eşleniğini ifade ederken J ise $p_1 p_2 \text{x}\, p_1 p_2$ boyutlarındaki exchange matrisidir [2].

$$J = \begin{pmatrix} 0 & \dots & 0 & 1 \\ 0 & \dots & 1 & 0 \\ \vdots & \ddots & \vdots & \vdots \\ 1 & 0 & \dots & 0 \end{pmatrix} \tag{2.18}$$

Şekil 2.6'dan da açıkça görülebileceği üzere uzamsal yumuşatma (spatial smoothing) işlemi sırasında verinin boyutu $M\text{x}N$'den $p_1 \text{x} p_2$' ye düşeceğinden efektif bant genişliği de azalır ve elde edilen görüntünün çözünürlüğü de kısmen azalır. Bu dezavantajına rağmen uzamsal yumuşatma ile gerçekleştirilen MUSIC algoritması geleneksel Fourier yöntemine göre daha iyi sonuç vermektedir. Uzamsal yumuşatma işleminde dekorelasyon etkisini elde edebilmek için bant genişliğinin bir kısmı harcanır. Eğer p_1 ve p_2 değerleri arttırılırsa MUSIC algoritmasının çözünürlüğü artar ancak farklı saçıcı merkezlerinden gelen sinyallerin dekorelasyon etkisi azalır. Tam tersi şekilde p_1 ve p_2 değerleri azaltılırsa da dekorelasyon performansı artar ancak çözünürlük azalır. Bu nedenle p_1 ve p_2 değerinin seçimi MUSIC algoritmasının performansı için önemlidir. Sonuç olarak eğer p_1 ve p_2 artarsa MUSIC algoritması daha yüksek çözünürlük sunar ancak dekorelasyon performansı düşerek bazı baskın saçıcı noktaları tespit edilemez duruma gelebilir [14].

Bunun yanında MUSIC yönteminde de saçıcı sayısının doğru bir şekilde kestirimi büyük önem taşımaktadır. Saçıcı sayısının bilinmemesi ya da yanlış kestirilmesi elde edilen sonuçları önemli oranda etkilemektedir.

Uzamsal yumuşatma işleminde kullanılan alt matris boyutunun etkisi

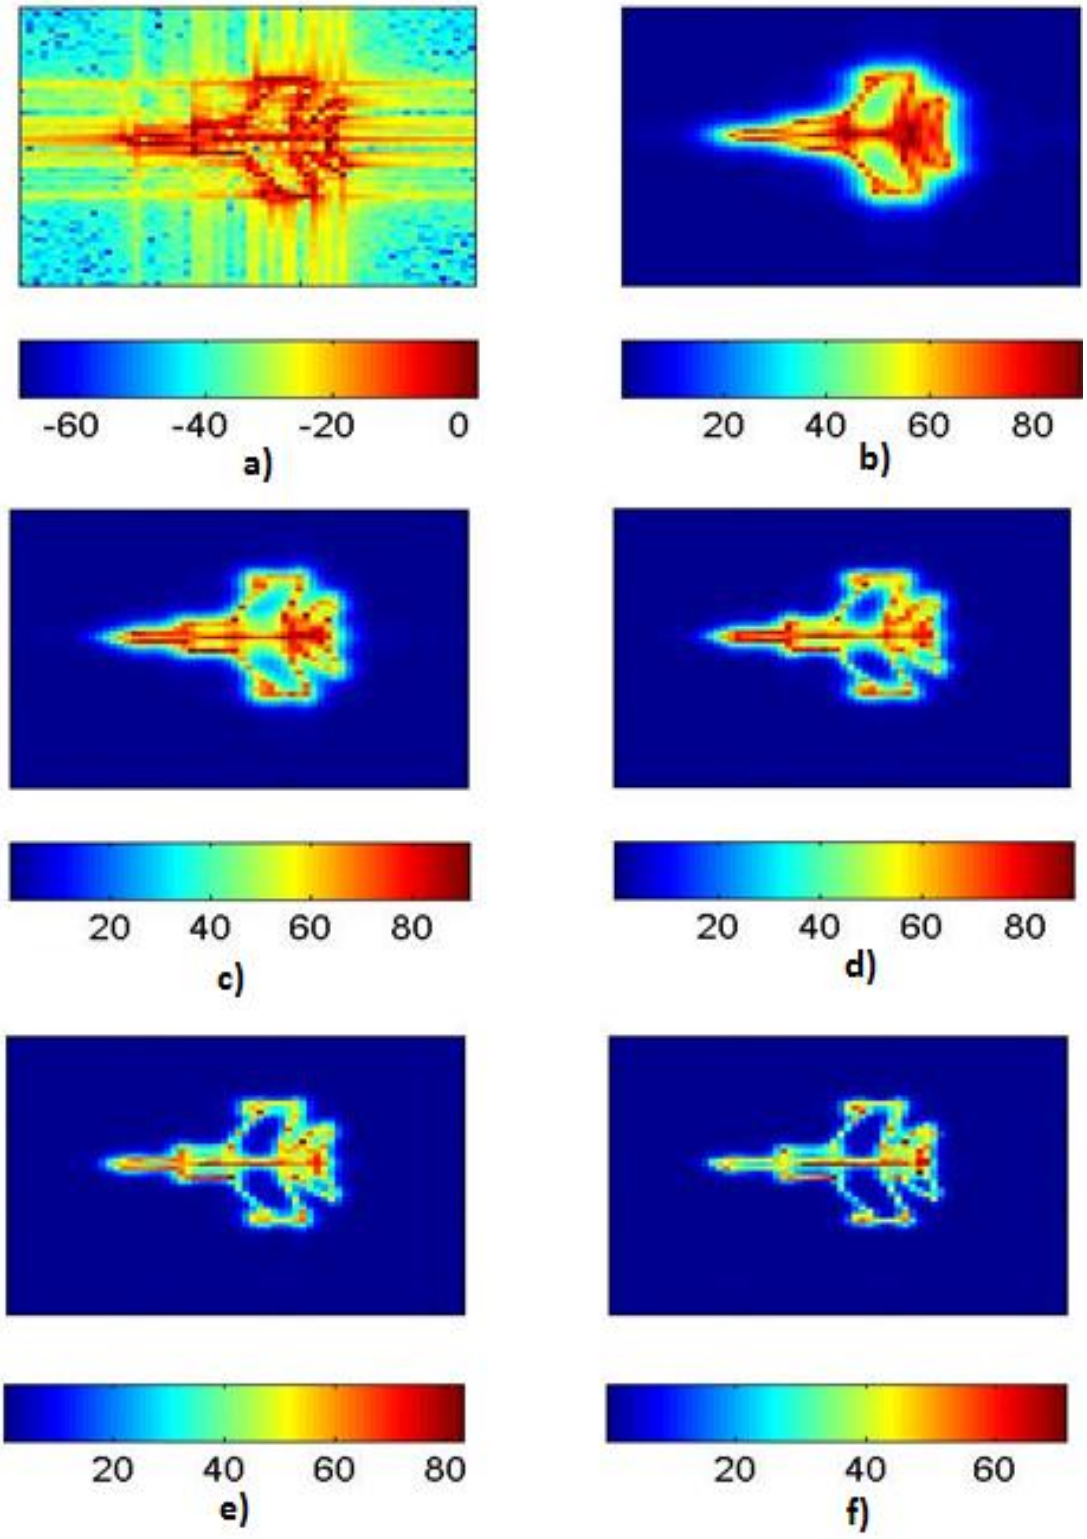
Bu bölümde değişen alt matris boyutlarından radar görüntülerinin nasıl etkilendiği incelenecektir. Değişen alt matris boyutuna göre radar görüntüleri aşağıdaki 6 farklı şekilde gösterilmektedir.

Şekillerde farklı alt matris boyutları için görüntüler elde edilmiştir. İlgili şekiller incelendiğinde alt matris boyutu arttıkça çözünürlükte iyileşme olduğu; fakat bunun yanında genellikle dinamik alanın daraldığı görülmektedir. 2 boyutlu Fourier dönüşümü yöntemi ile karşılaştırıldığında görüntünün çok daha net bir şekilde elde edildiği, baskın saçıcıların belirgin bir şekilde göründüğü söylenebilir. Şekil 2.7 ve Şekil 2.8 incelendiğinde mig25 hedefi için (64x64 boyutundaki veri için) görüntü çözünürlüğü ve daha az sahte hedef içermesi hususlarında en iyi sonuçların alt matris boyutunun 24 olduğu durumlarda elde edildiği söylenebilir. Şekil 2.9'da ise mig-25 verisinin band genişliği daraltıldığında MUSIC algoritması tarafından elde edilen görüntüler görünmektedir. Bu şekil 64x64'lük frekans uzayındaki mig-25 verisinin 32x32'lik kısmı alınarak elde edilen veriden oluşturulmuş görüntülerdir. Bant genişliği daraltıldığında MUSIC algoritması ile elde edilen verilerde önemli ölçüde bozulma olduğu görülmektedir. İlgili şekil incelendiğinde en iyi görüntünün alt matris boyutunun 12 olduğu durumda elde edildiği söylenebilir.

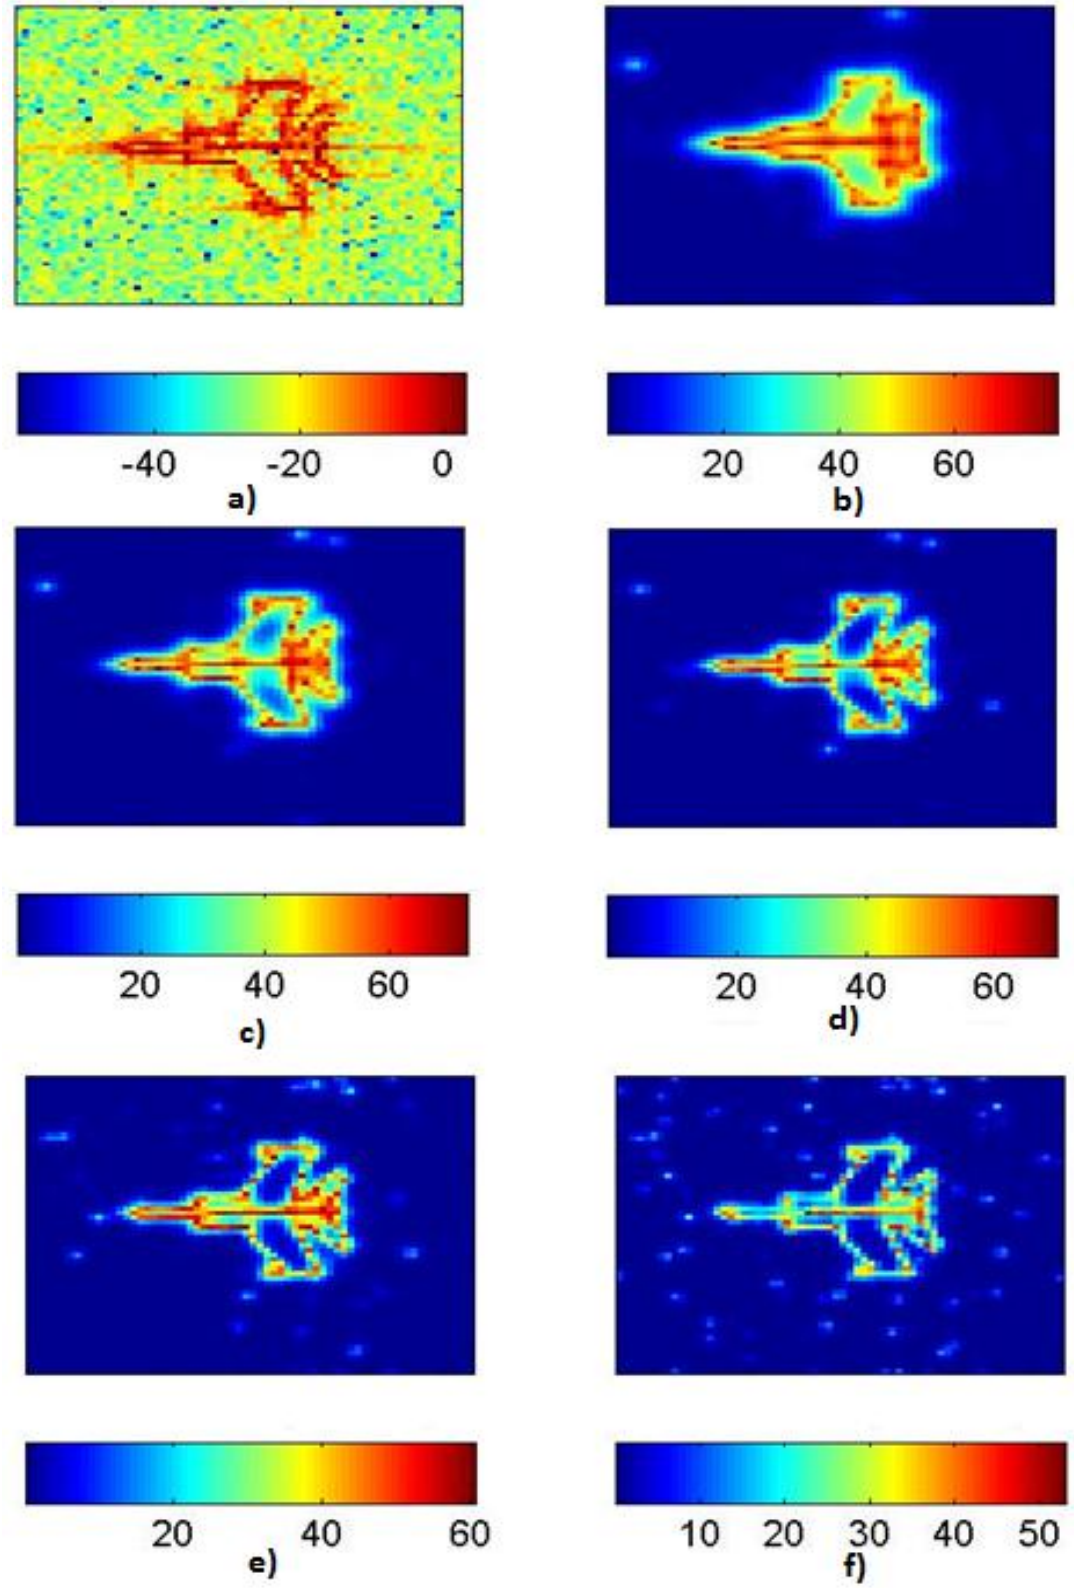
MUSIC algoritmasında alt matris boyutunun radar hedef görüntülerine etkisinin görülebilmesi için ek olarak Airbus hedefinden alınan verilerden elde edilen görüntüler (Şekil 2.10, Şekil 2.11, Şekil 2.12) incelenebilir.

MUSIC algoritması ve sonraki bölümlerde anlatılacak algoritmalar için radar hedef görüntüleri elde edilecektir. Radar hedef görüntülemede kullanılacak hedefler için elde edilen verilerin parametreleri şu şekildedir:

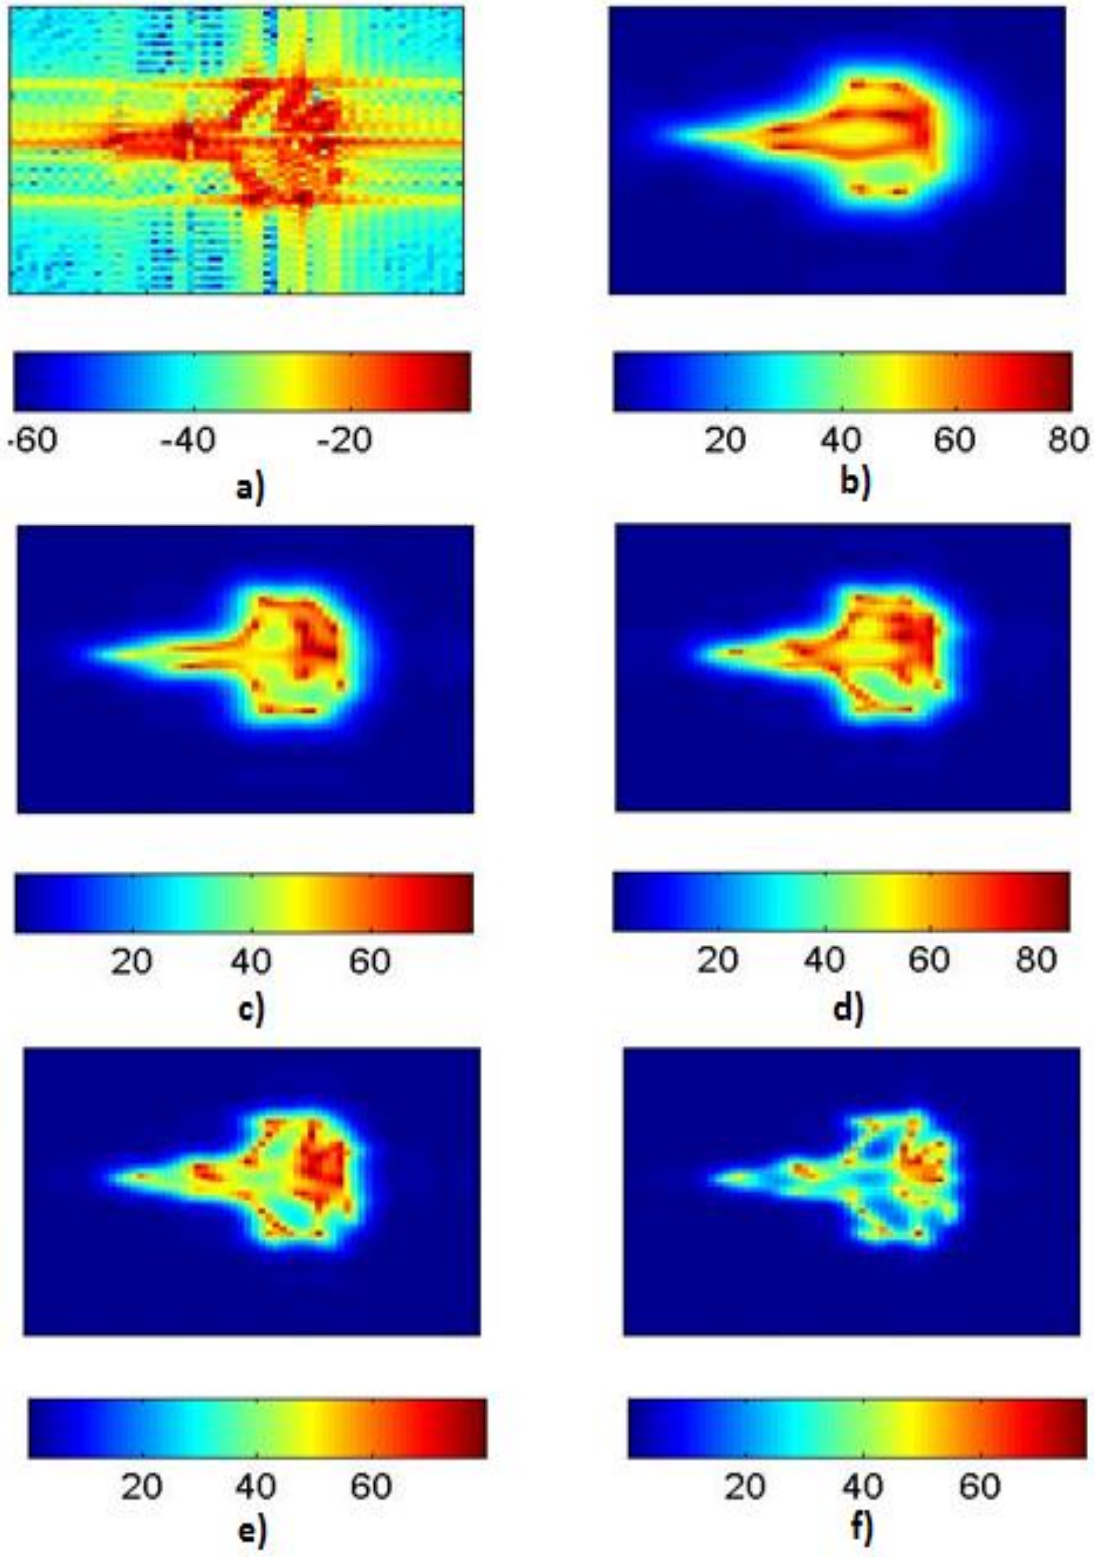
- Merkez frekansı f_c = 9GHz, band genişliği B = 531 MHz, gözlem açı aralığı Ω=3.67 olan 64x64'lük "mig25" simule verisi
- Merkez frekansı f_c = 4 GHz, bant genişliği B=122 MHz, gözlem açı aralığı $\Omega = 2.08^\circ$ olan 32x32'lik "Airbus" verisi.



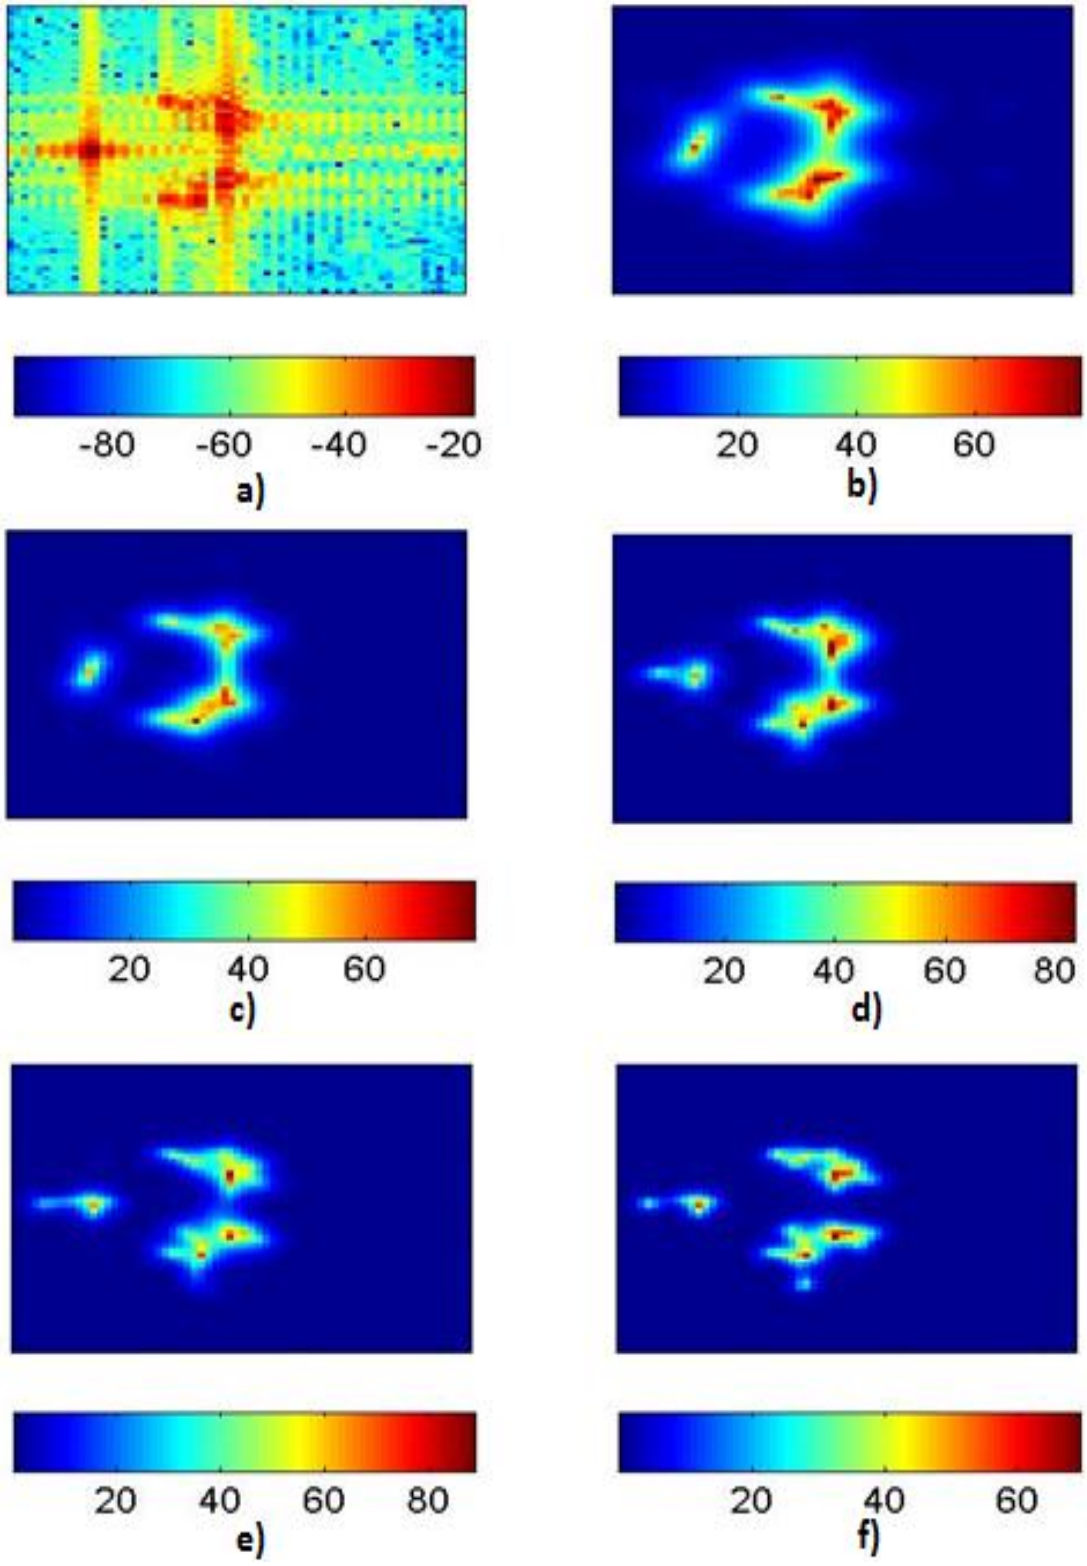
Şekil 2.7: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 12, c) 16, d) 20, e) 24, f) 30



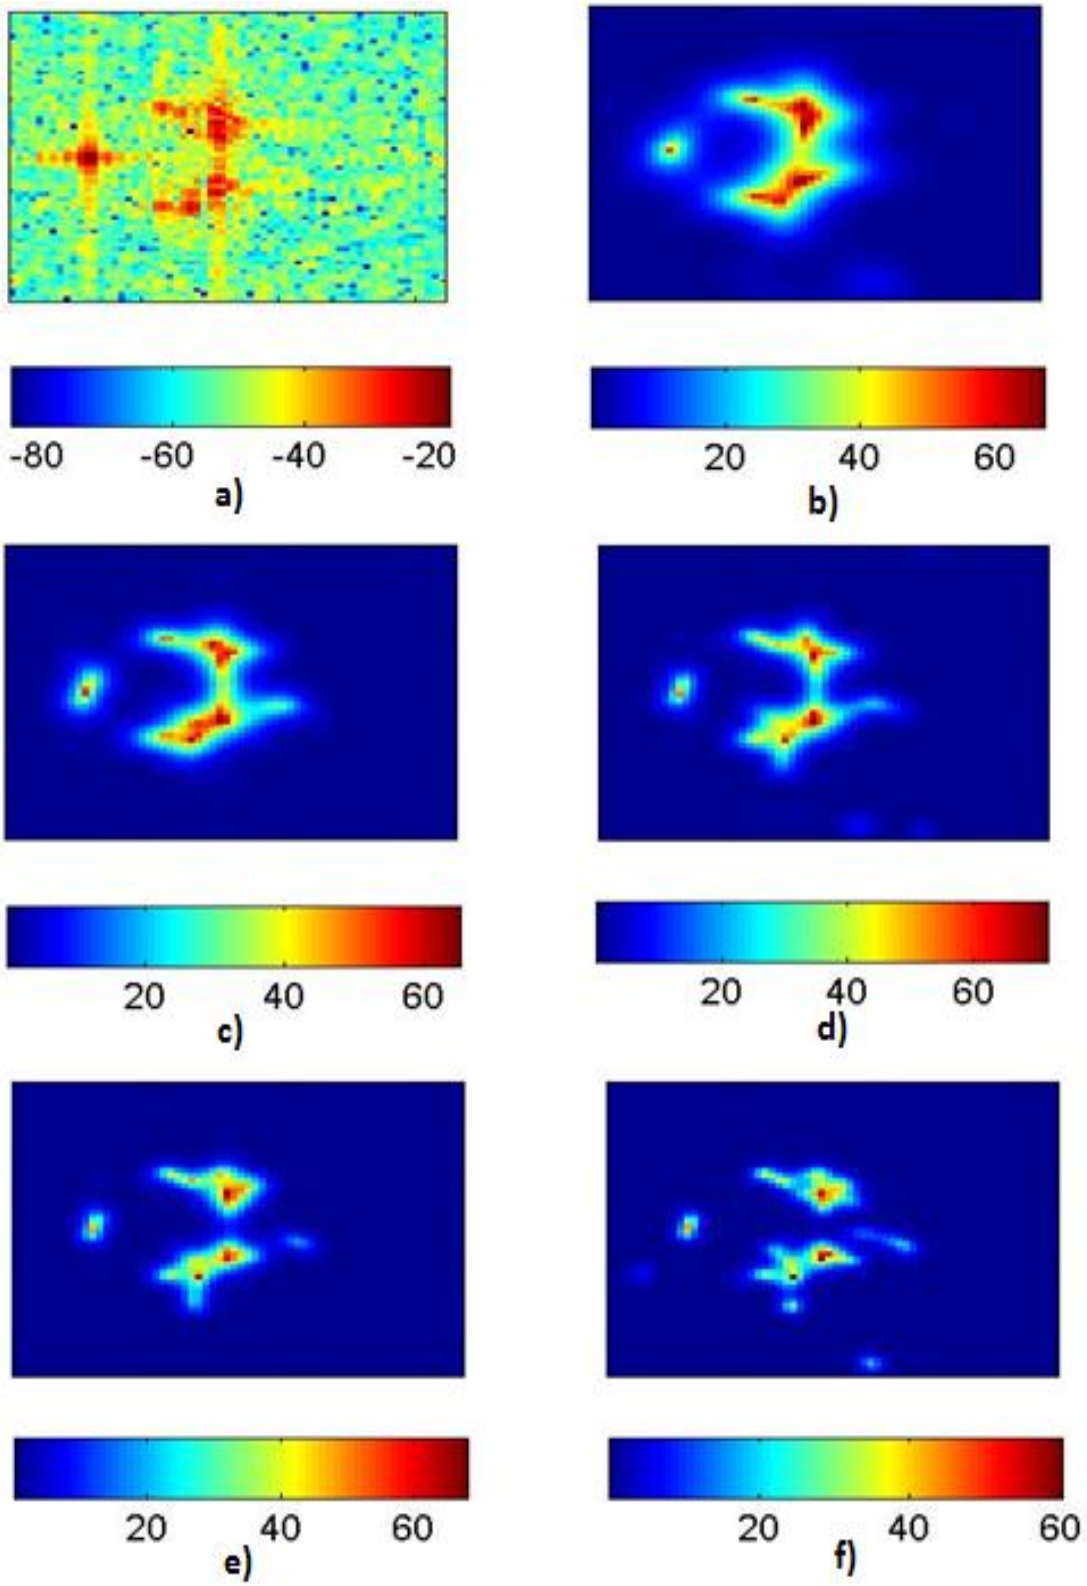
Şekil 2.8: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=10 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 12, c) 16, d) 20, e) 24, f) 30



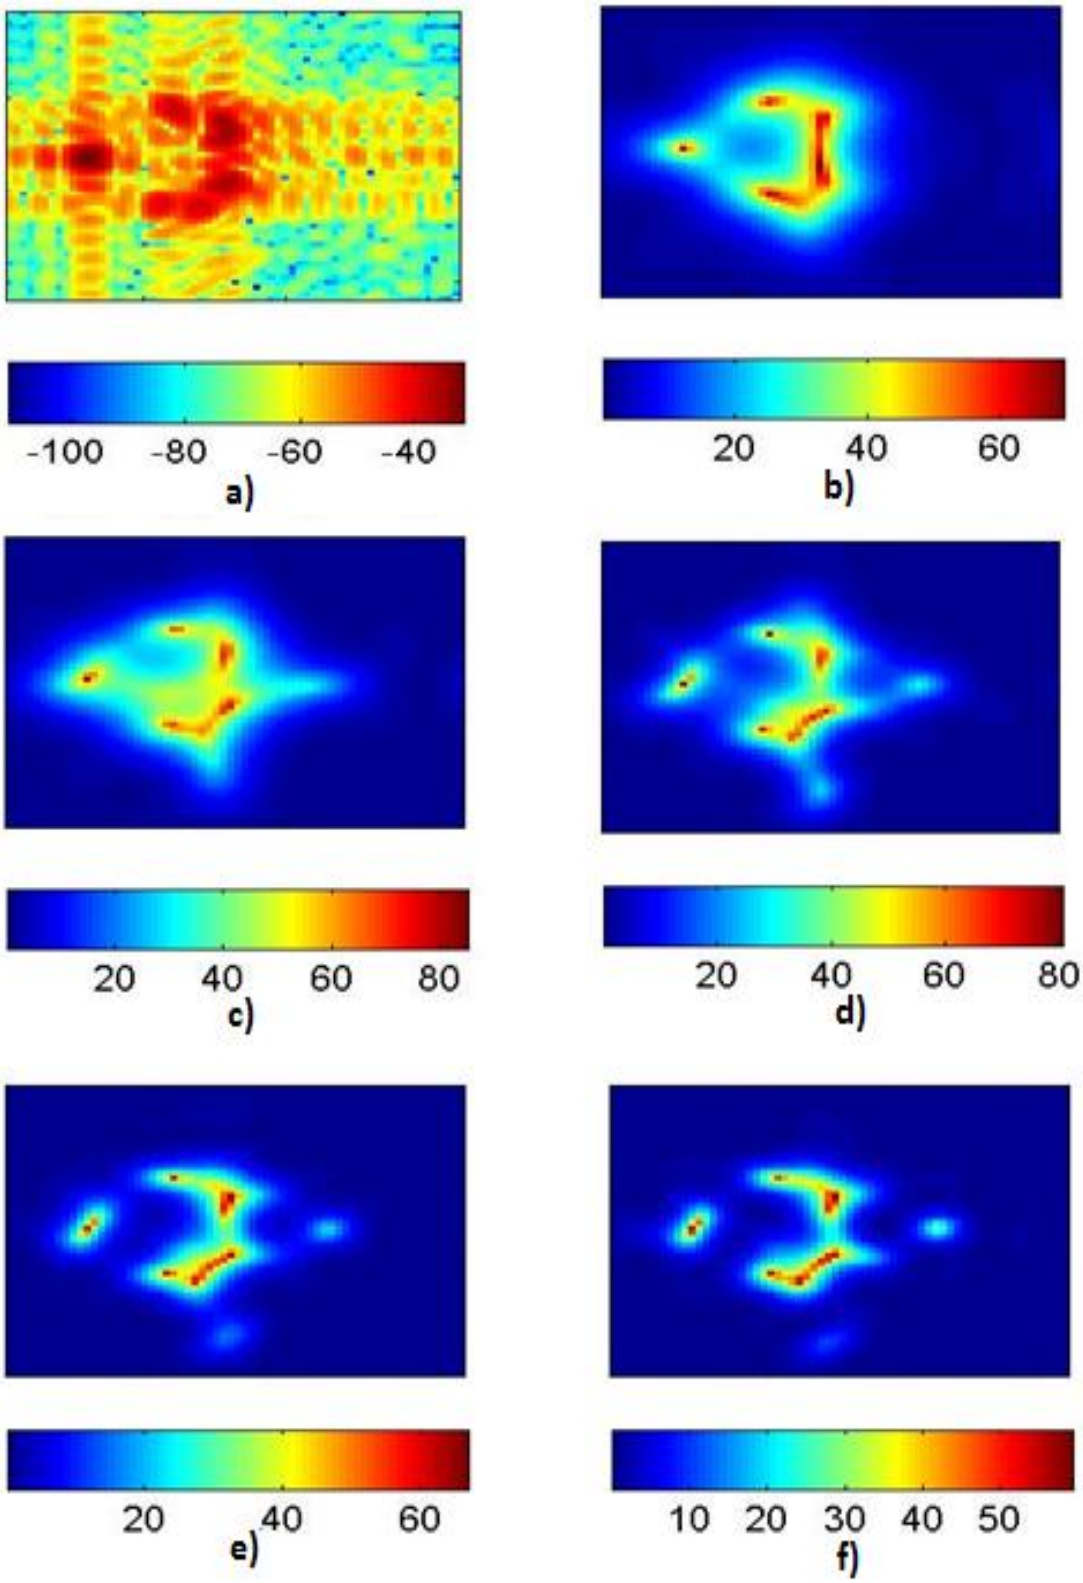
Şekil 2.9: 32 x 32 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 6, c) 8, d) 10, e) 12, f) 15



Şekil 2.10: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 6, c) 8, d) 10, e) 12, f) 15



Şekil 2.11: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 6, c) 8, d) 10, e) 12, f) 15



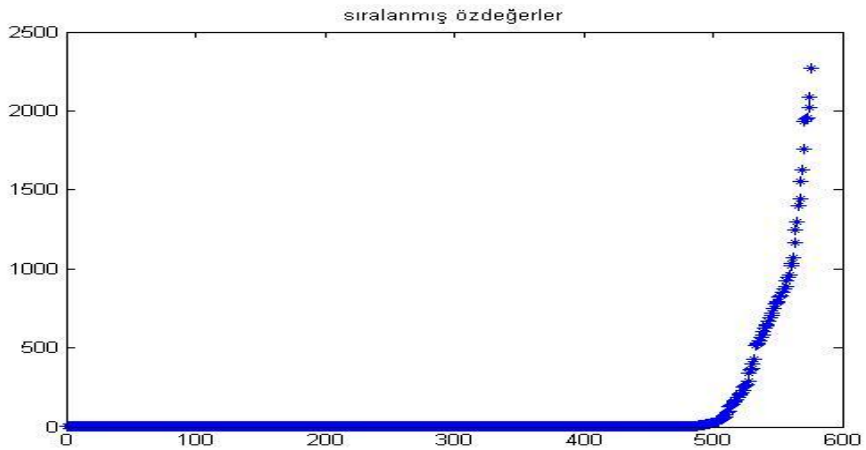
Şekil 2.12: 16 x 16 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritması uzamsal yumuşatma işleminde kullanılan alt matris boyutları b) 4, c) 5, d) 6, e) 7, f) 8

Kestirilen saçıcı sayısının etkisi

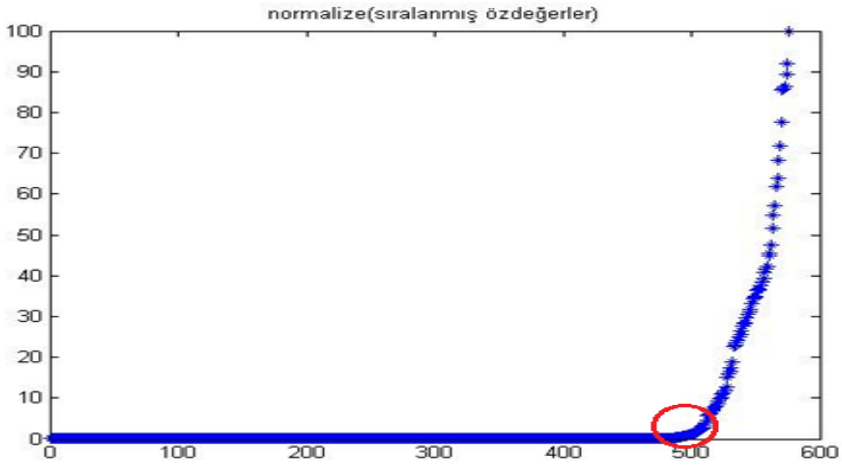
Alt matris boyutunun radar hedef görüntülerinin dinamik alan ve çözünürlüğüne etkisi önceki bölümde incelenmiştir. Bu bölümde ise kestirilen saçıcı sayısının görüntüler üzerindeki etkisi incelenecektir.

MUSIC algoritmasında geri saçılan alanlardan oluşturulmuş kovaryans matrisinin özdeğerleri saçılan alanın niteliğine göre belirli değerler almaktadır. Bu değerler incelendiğinde baskın saçıcıları ifade eden özdeğerlerin gürültüyü ifade eden özdeğerlere göre nispeten yüksek olduğu görülmektedir; ayrıca düşük değerli özdeğerler yaklaşık olarak birbirine eşit olmaktadır [3]. Bu sonuç göz önünde bulundurularak, bu çalışma kapsamında, hedefe ait saçıcı sayısının kestirimini sağlayan algoritma şu şekilde tasarlanmıştır:

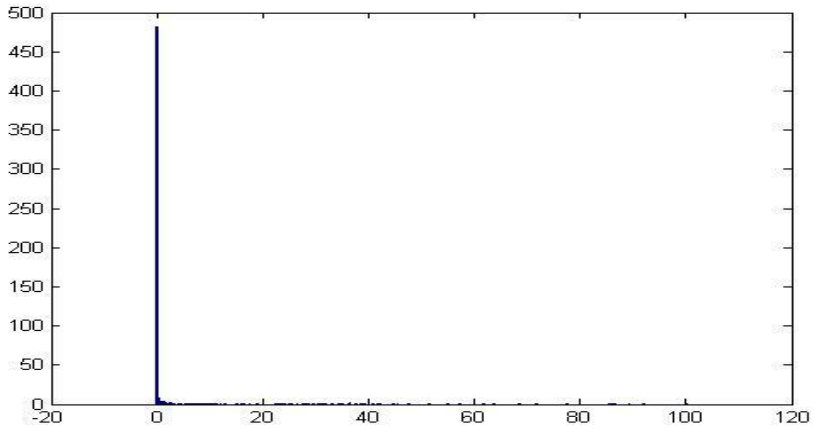
1. Kovaryans matrisinin özdeğerleri tekil değer ayrışımı (SVD) yöntemiyle elde edilir. (bknz. Şekil 2.13).
2. Hesaplanan özdeğerler, maksimum 100 değeri alacak şekilde, normalize edilir (bknz. Şekil 2.14).
3. Normalize edilmiş özdeğerler belirli aralıklar ile histogramlanır. Burada histogramlamadan kasıt yaklaşık olarak aynı değerde olan özdeğerlerin gruplanmasıdır. Bu işlem birbirine benzer olan özdeğerlerin tespit edilmesine yardımcı olmaktadır (bknz. Şekil 2.15 ve Şekil 2.16).
4. En çok eleman içeren histogram hücresi tespit edilir (p. histogram hücresi). İlk histogram hücresinden p. histogram hücresine kadarki kısımda yer alan özdeğerler gürültüyü ifade eden özdeğerlerdir (küçük özdeğer içeren elemanlar bu grupta yer alır).



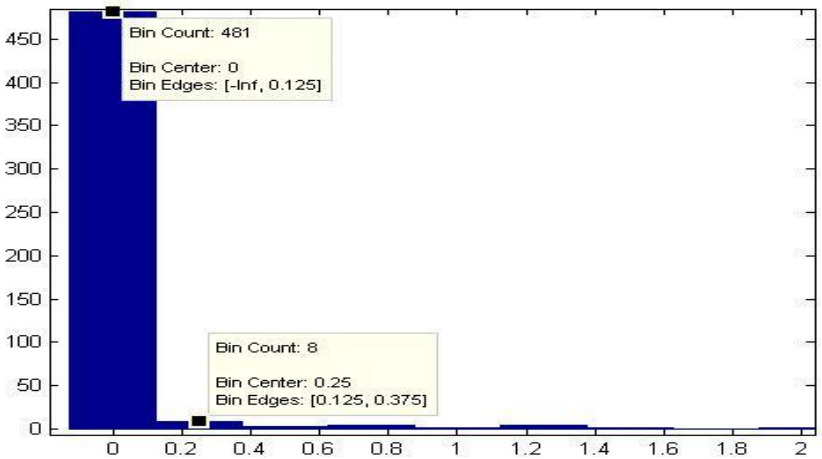
Şekil 2.13: 64x64 boyutunda veri matrisine sahip Mig-25 için, 24x24 boyutunda alt matris kullanıldığında hesaplanan özdeğerlerin sıralanmış görünümü



Şekil 2.14: 64x64 boyutunda veri matrisine sahip Mig-25 için, 24x24 boyutunda alt matris kullanıldığında hesaplanan özdeğerlerin sıralanmış görünümü (0-100 arasında normalize edilmiştir)



Şekil 2.15: Normalize özdeğerlerin 0.25 genişliğindeki hücrelere göre histogramlanması



Şekil 2.16: Özdeğerlerin 0.25 genişliğindeki hücrelere göre histogramlanması (yakınlaştırılmış görünüm)

5. Bu aşamada özdeğerlerde kopmanın yaşandığı hücrenin belirlenmesi işlemine geçilir (Şekil 2.14'te kopmanın yaşanmaya başladığı özdeğerler kırmızı yuvarlak içerisinde gösterilmektedir). Gupta'nın ifade ettiği üzere baskın saçıcıları ifade eden özdeğerler gürültüyü ifade eden özdeğerlere göre nispeten yüksektir; ayrıca düşük değerli özdeğerler yaklaşık olarak birbirine eşit olmaktadır [3]. Bu adımda belirtilen işlemler ile yaklaşık olarak birbirine eşit olan özdeğerler diğer özdeğerlerden ayrılacaktır, sonuç olarak saçıcı sayısı kestirilecektir. Bu işlem şu şekilde yapılır:
   5.1. İlk histogram hücresinden (p+1). histogram hücresine kadarki histogram hücrelerindeki özdeğerler için standart sapma (σ) ve ortalama (μ) hesaplanır.
   5.2. (p+1). histogram hücresindeki tüm özdeğerler "μ+2σ" değerinden büyükse (p+1). histogram hücresinde yer alan özdeğerler önceki histogram hücrelerinde yer alan özdeğerlerden değer bakımında farklılaşmış kabul edilir ve kopma sağlanmış olur. Bu durumda saçıcı sayısı şu şekilde kestirilir;

      Saçıcı Sayısı=(Tüm özdeğerlerin sayısı)–(1'den p. histogram hücresine kadarki hücrelerde yer alan özdeğer sayısı)

   5.3. (p+1). histogram hücresindeki tüm özdeğerler "μ+2σ" değerinden büyük değilse 5. adımda belirtilen işlemler 1. histogram hücresinden (p+2). histogram hücresine kadar olan kısım için yeniden yapılır. (5.2)'de belirtilen durum oluşup saçıcı sayısı kestirilene kadar işlemlere katılan histogram hücresi sayısı bir arttırılarak işlemler devam ettirilir.

Saçıcı sayısı kestirim algoritmasının daha net bir şekilde açıklanması için algoritma bir örnek ile anlatılacaktır. Mig-25 hedefinin 64x64 boyutundaki veri matrisi için uzamsal yumuşatma işleminde kullanılan alt matris boyutu 30x30 seçilerek algoritmanın işleyişi örneklendirilecektir.

- Öncelikle özdeğerler hesaplanır. Toplam özdeğer sayısı 900 (alt matris boyutunda yer alan veri sayısı kadar: 30 x 30)'dür.
- Maksimum özdeğer 100 olacak şekilde normalizasyon işlemi yapılır. Normalizasyon işleminin ardından histogramlama işlemi yapılır ve histogram hücre genişliği 0.25 alınır. Özdeğer 0-100 aralığında olduğundan ve

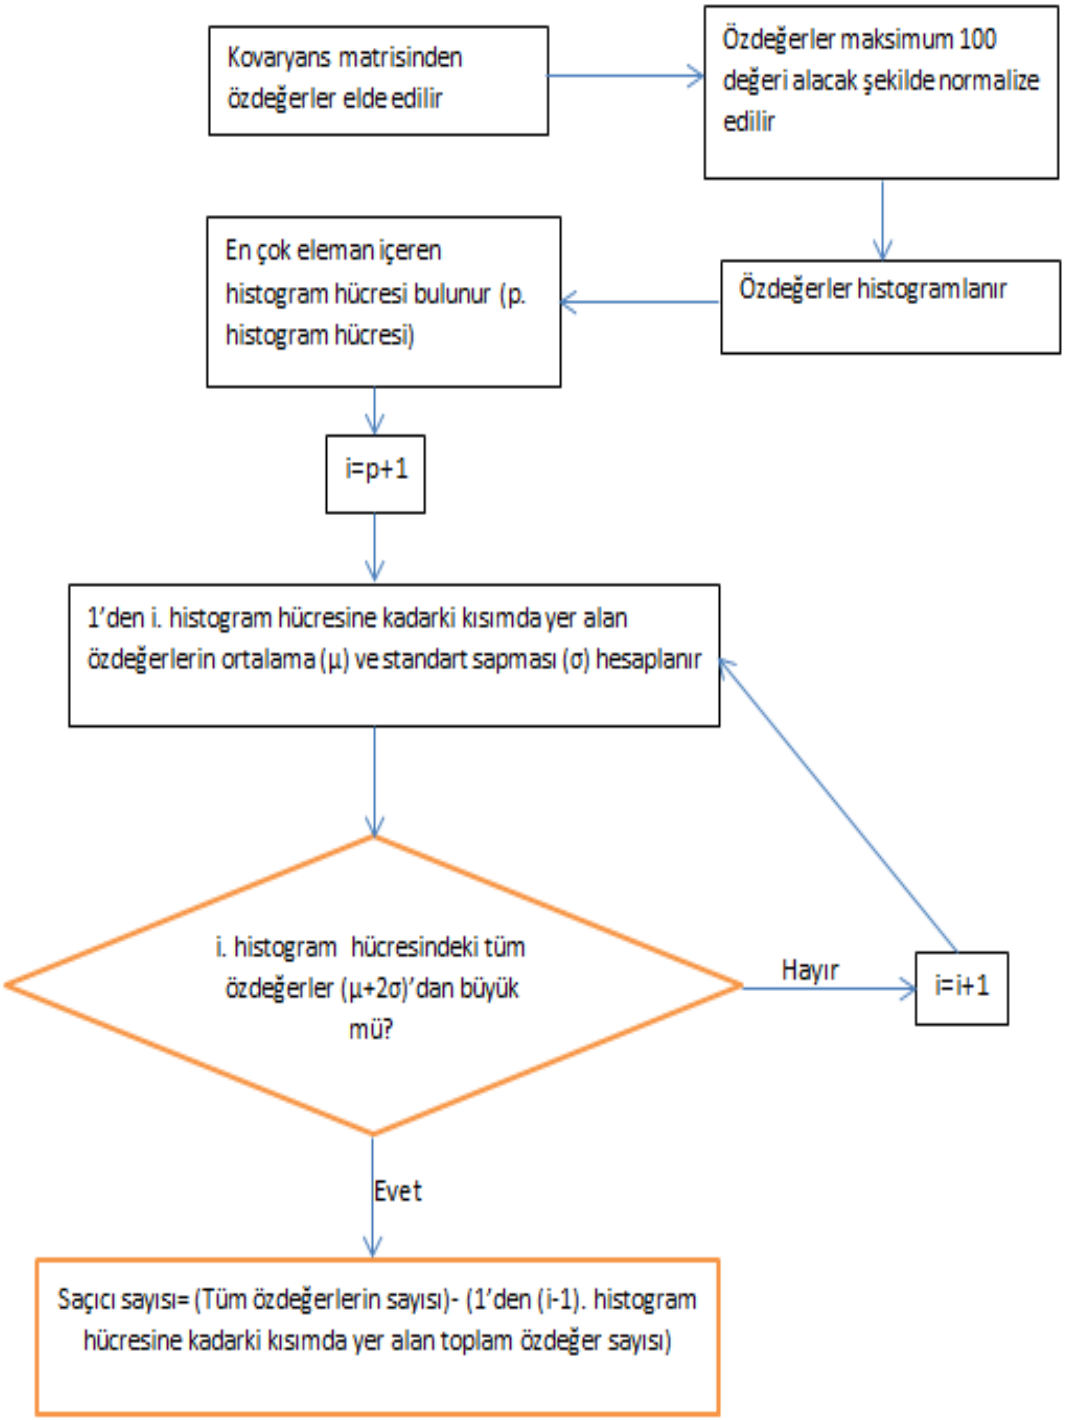
histogram hücre genişliği 0.25 alındığı için histogram hücresi sayısı 401 olmuştur. Histogram hücre genişliği olan 0.25 değeri deneysel belirlenmiştir.

En çok eleman içeren histogram hücresi tespit edilir. İlk 5 histogram hücresinin içerdiği özdeğer sayısı şu şekildedir: 781, 10, 8, 6, 3. Histogram hücrelerin içerdiği özdeğer sayılarına bakıldığında en çok özdeğer 1. histogram hücresinde olduğu görülmektedir. Genellikle en küçük değerli özdeğerleri içeren ilk hücre en çok elemanı içerir. Gürültünün çok fazla olduğu ve hedefin zorlukla arkaplandan ayrılabildiği durumlarda maksimum eleman içeren histogram hücresi değişebilmektedir.

- Bu aşamadan sonra özdeğerler arasında kopmanın oluştuğu histogram hücresi belirlenecektir. Algoritmaya göre 1. ve 2. (p+1. değer) histogram hücresindeki tüm özdeğerler için ortalama (μ) ve standart sapma (σ) hesaplanır. Hesaplamanın ardından 791 adet özdeğer için ortalama değerinin 0,0083; standart sapmanın ise 0,0265 olduğu görülmüştür.
- 2. hücrede yer alan özdeğerlerin şu şekilde sıralandığı görülmüştür: 0,1352; 0,1505; 0,1587; 0,1733; 0,1880; 0,2280; 0,2323; 0,2591; 0,2894; 0,3334.
- μ+2σ işleminin değeri 0,0614 hesaplanmaktadır. Görüldüğü üzere 2. hücrede yer alan tüm özdeğerler bu değerin üzerindedir. 2. hücreden itibaren özdeğerler farklılaşmaya başlamıştır. Gupta'nın belirttiği üzere gürültüye ait özdeğerler düşük değerlidir, ayrıca düşük değerli özdeğerler yaklaşık olarak birbirine eşit olmaktadır [3]. Dolayısıyla 1. hücrenin gürültü özdeğerlerini içerdiği diğer özdeğerlerin ise baskın saçıcıya ait olduğu söylenebilir. Eğer özdeğerlerden bir tanesi dahi μ+2σ değerinin altında kalsaydı o zaman işlemler 3. histogram hücresinin dahil edilmesi ile yeniden yapılacaktı ve işlemler bu şekilde hesaplamalara en son eklenen histogram hücresindeki tüm özdeğerler μ+2σ değerinden büyük olana kadar devam ettirilecekti.
- Sonuç olarak;

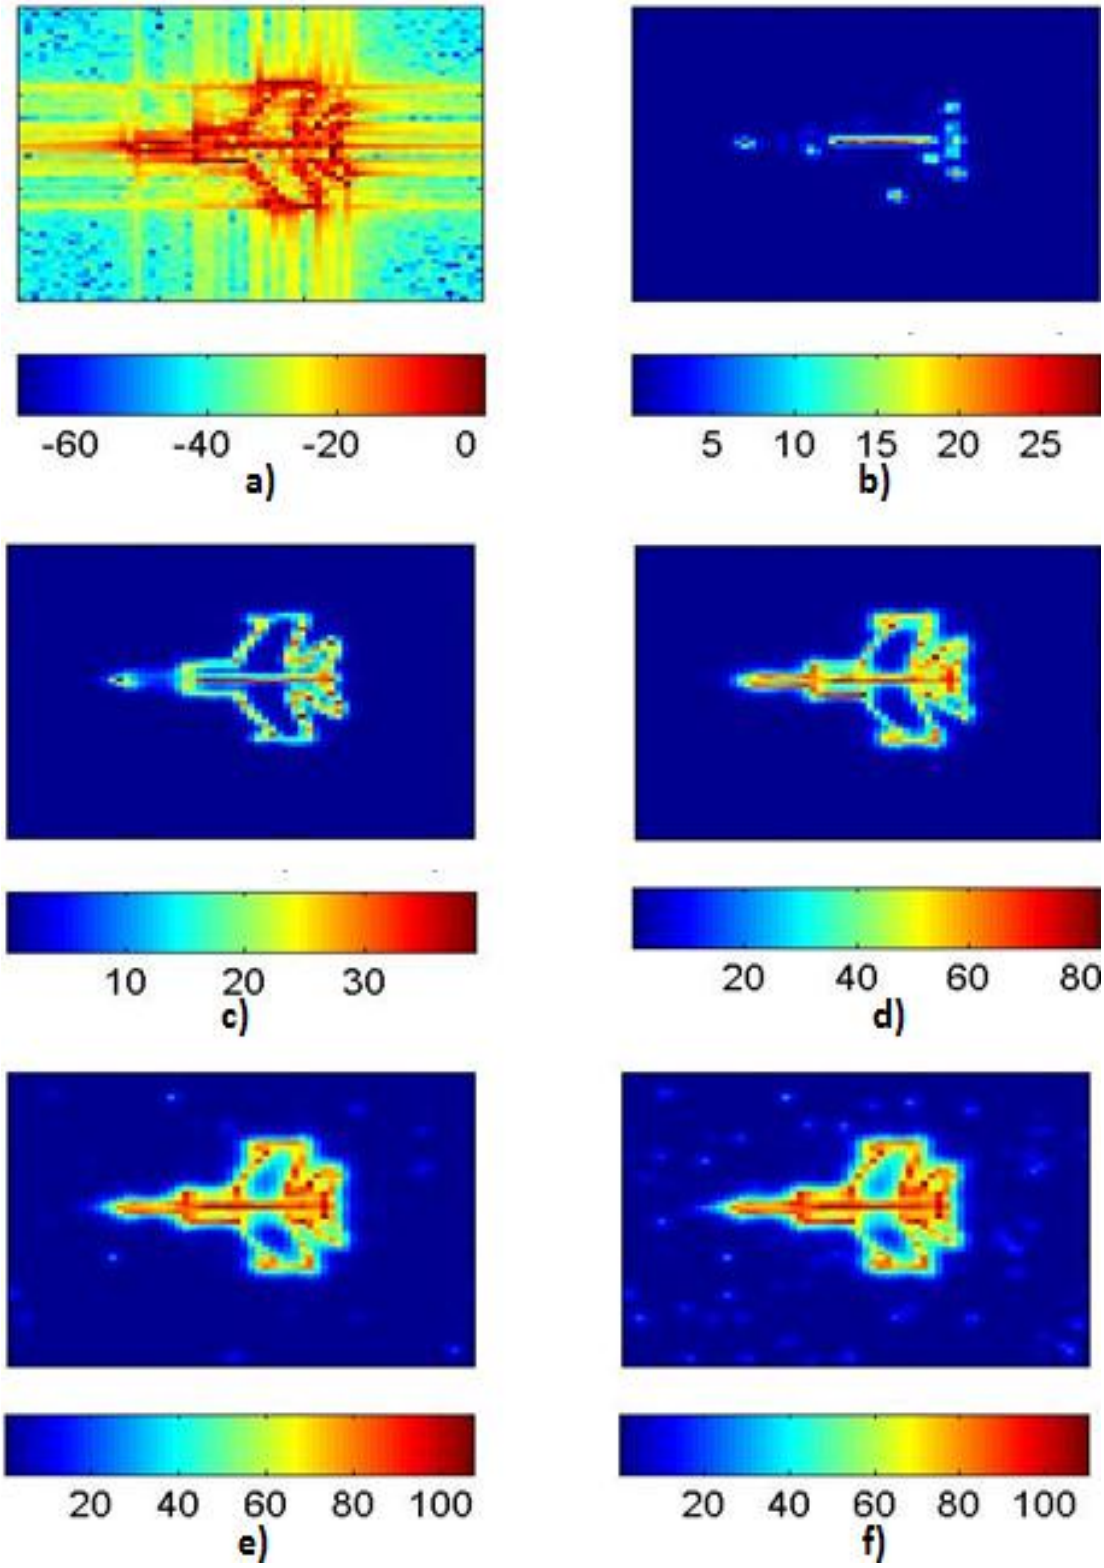
  Saçıcı Sayısı=(Tüm özdeğerlerin sayısı)–(1'den p. histogram hücresine kadarki hücrelerde yer alan özdeğer sayisi)

  ifadesi ile saçıcı sayısının 900-781=119 bulunduğu görülmektedir. Mig-25'in, tam çözünürlük ile görüntülendiğinde, saçıcı sayısının 120 olduğu bilindiğinden sonucun oldukça iyi olduğu söylenebilir.

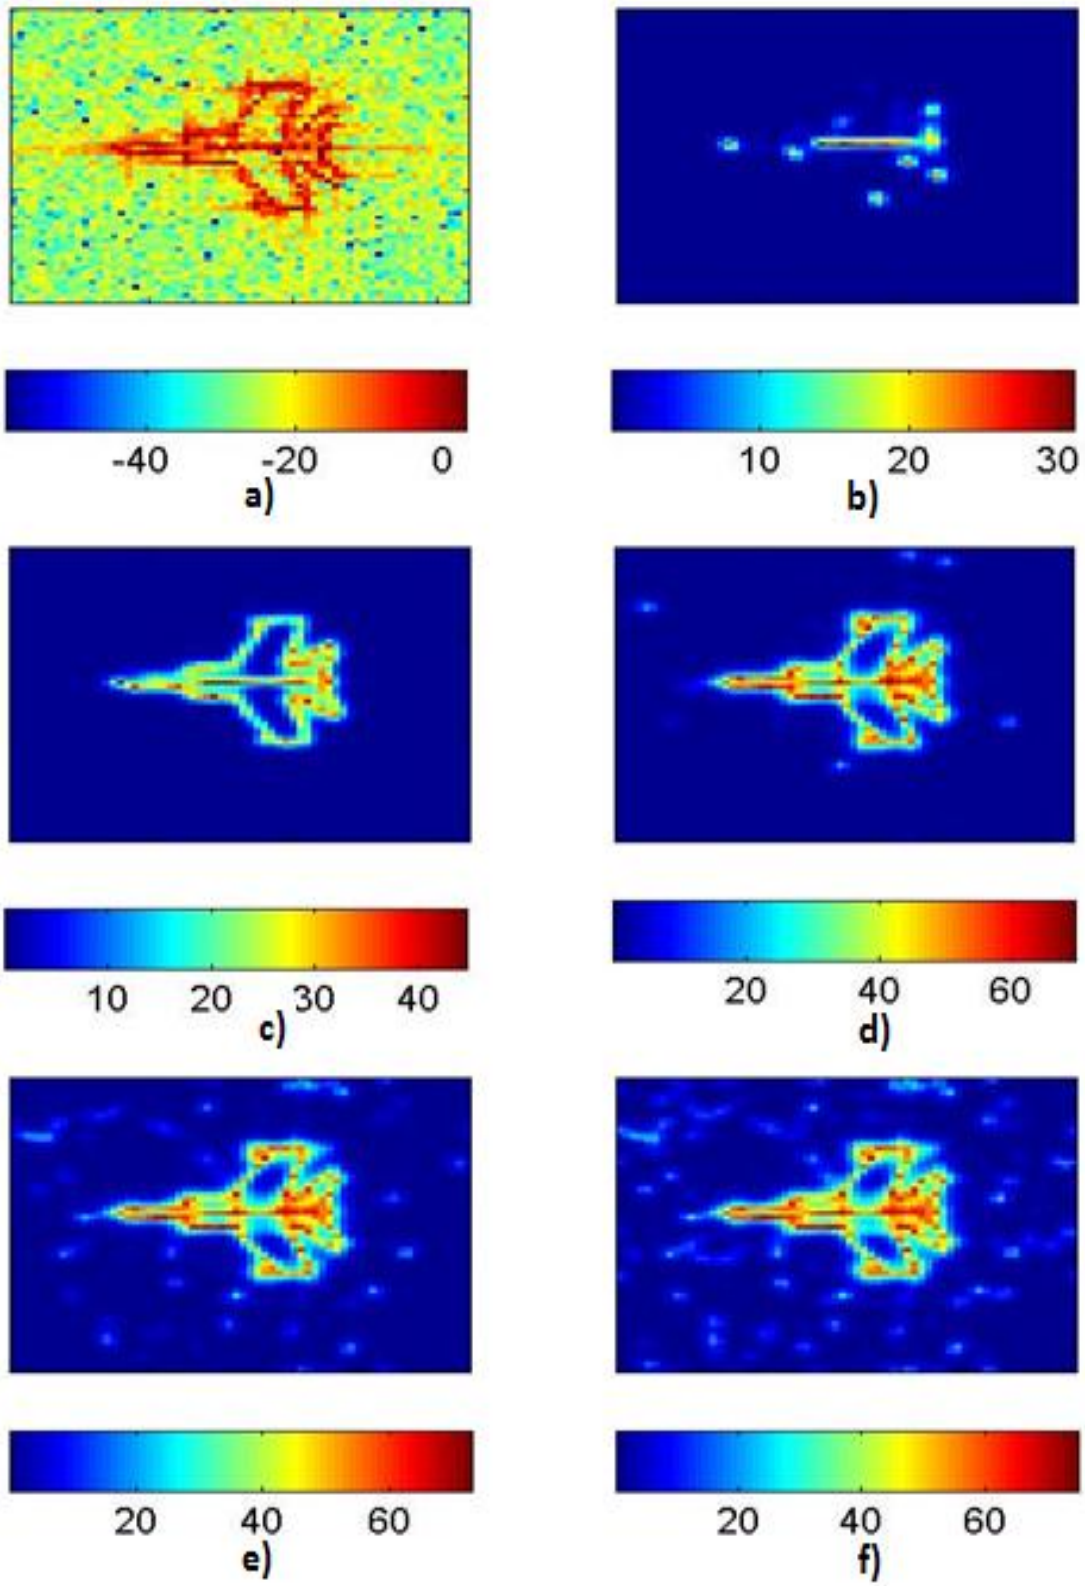


Akış Diyagramı 1: Saçıcı sayısı kestirim algoritması

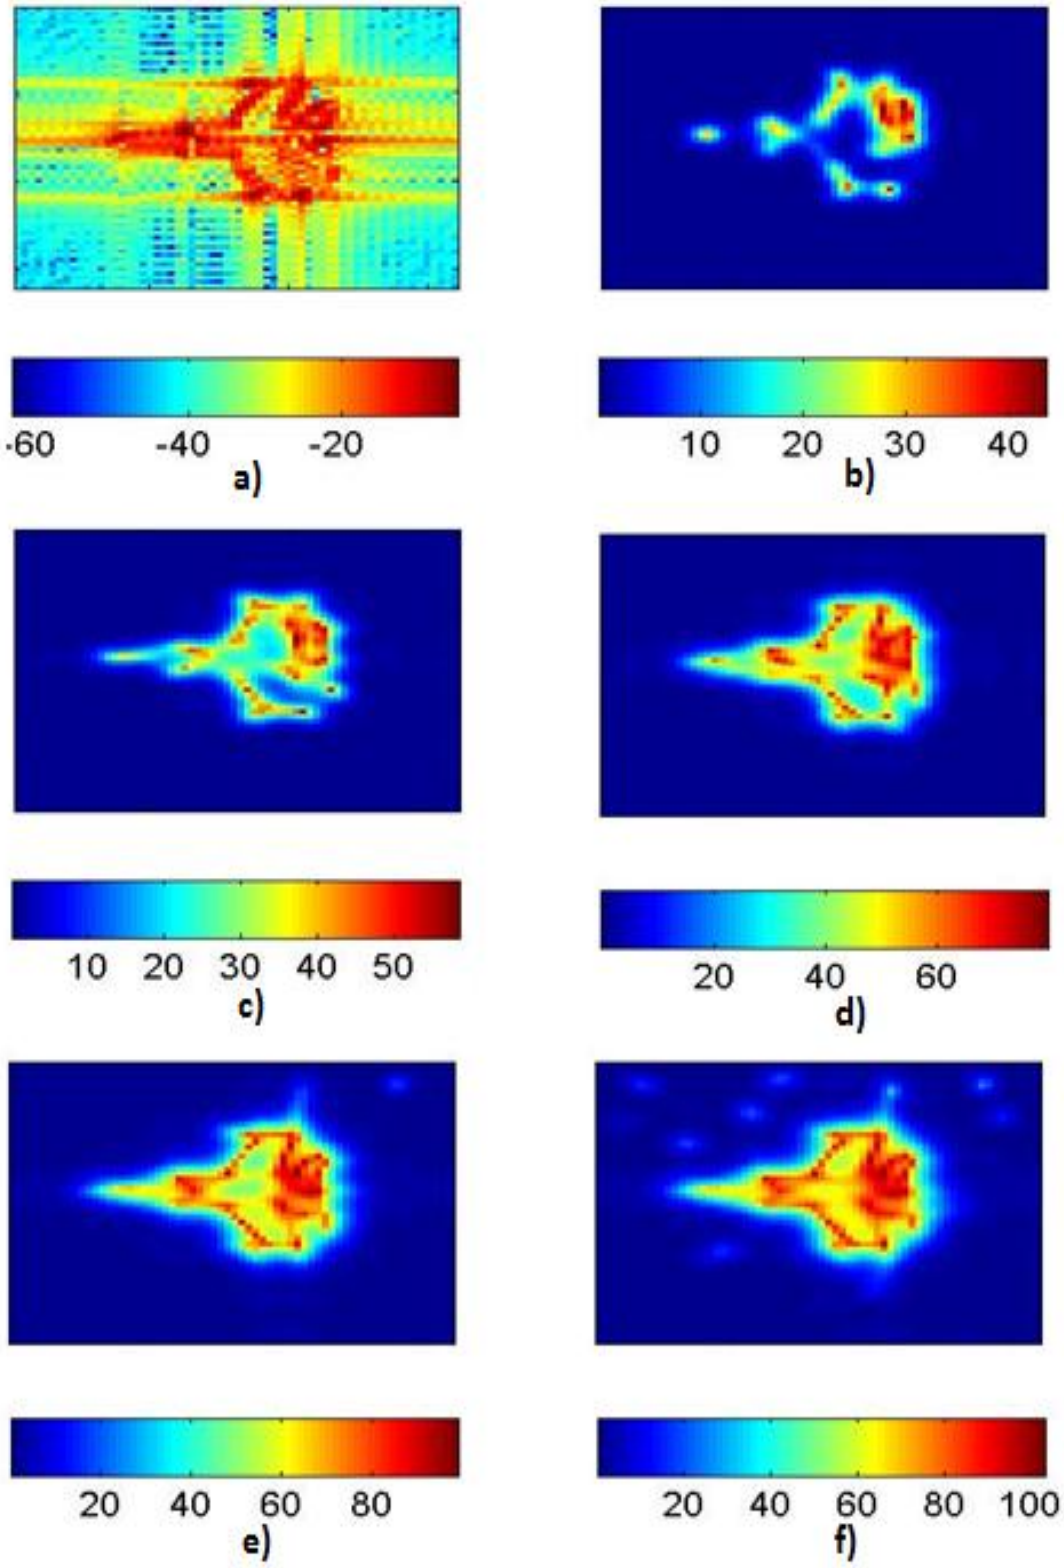
Aşağıdaki yer alan altı şekilde kestirilen saçıcı sayısı değiştikçe görüntülerde meydana gelen değişiklik görünmektedir. İlgili şekiller incelendiğinde saçıcı sayısının düşük kestirildiği durumlarda hedef üzerindeki saçıcılar görünmez kılınmaktadır. Saçıcı sayısının yüksek kestirildiği durumlarda ise sahte saçıcılar oluşmaktadır. Diğer yandan tahmin edilen saçıcı sayısı arttıkça dinamik alan değerinin yükseldiği görülmektedir.



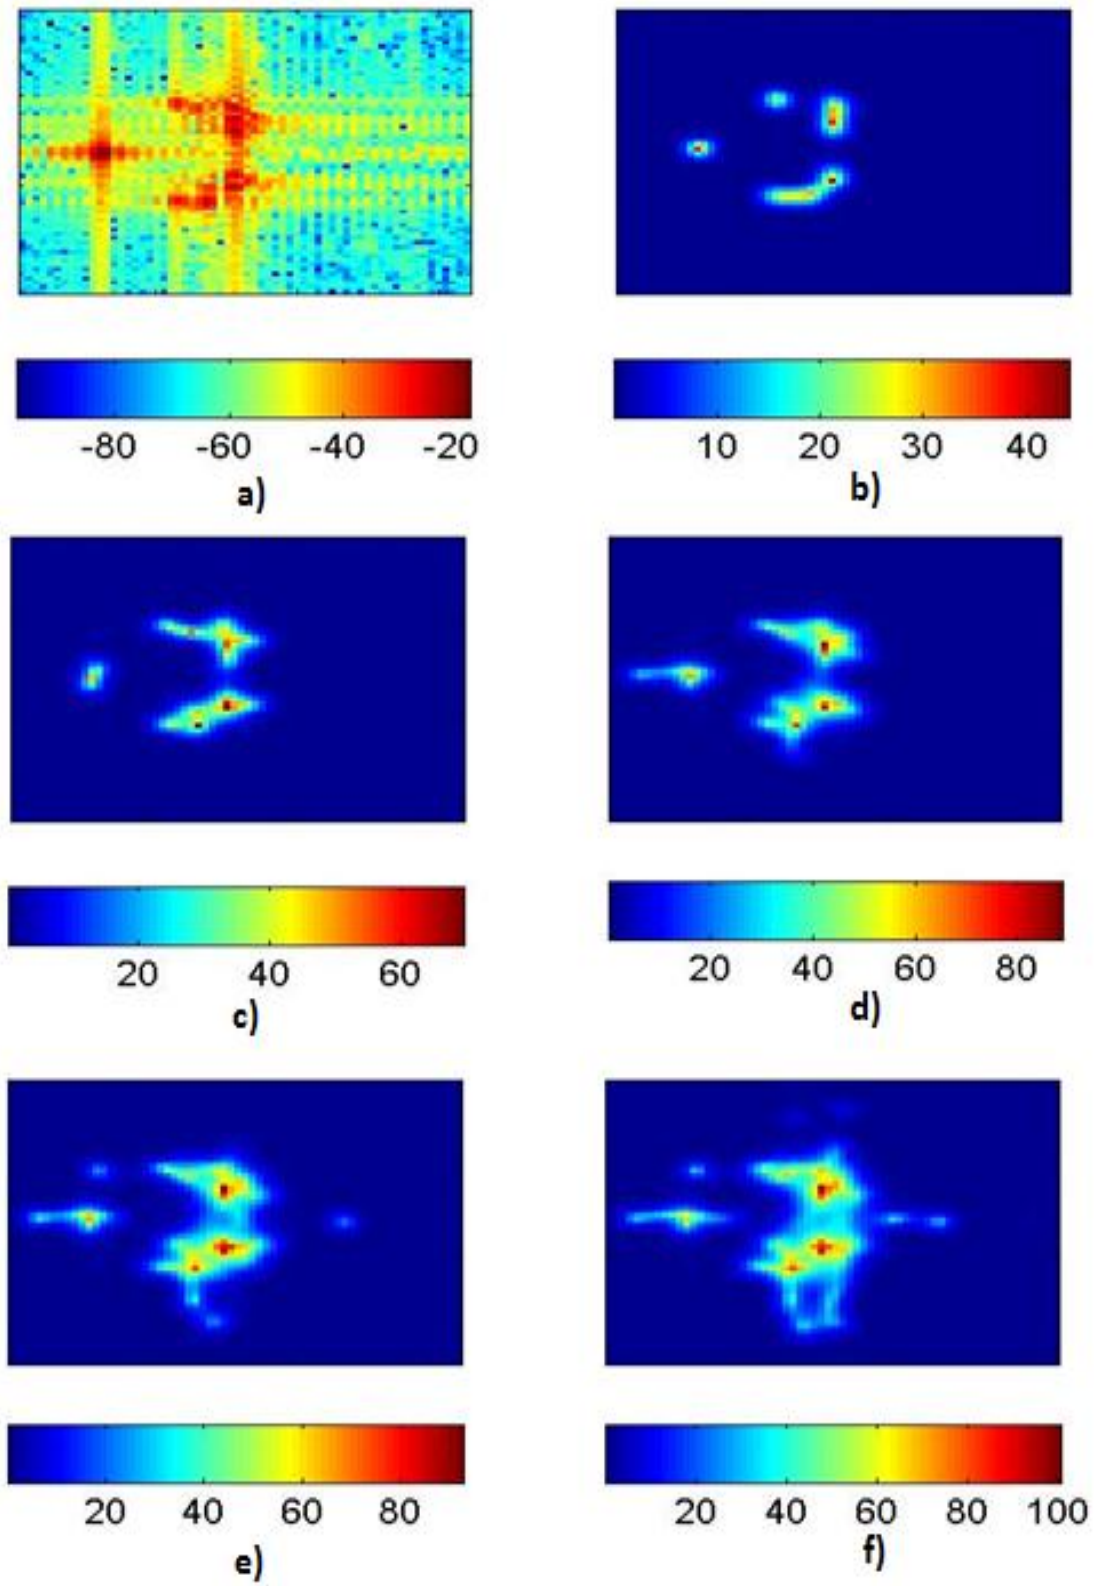
Şekil 2.17: 64 x 64 veri boyutundaki Mig 25 hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:24) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 15, c) 55, d) 95 (kestirilen saçıcı sayısı değeri), e) 135, f) 175



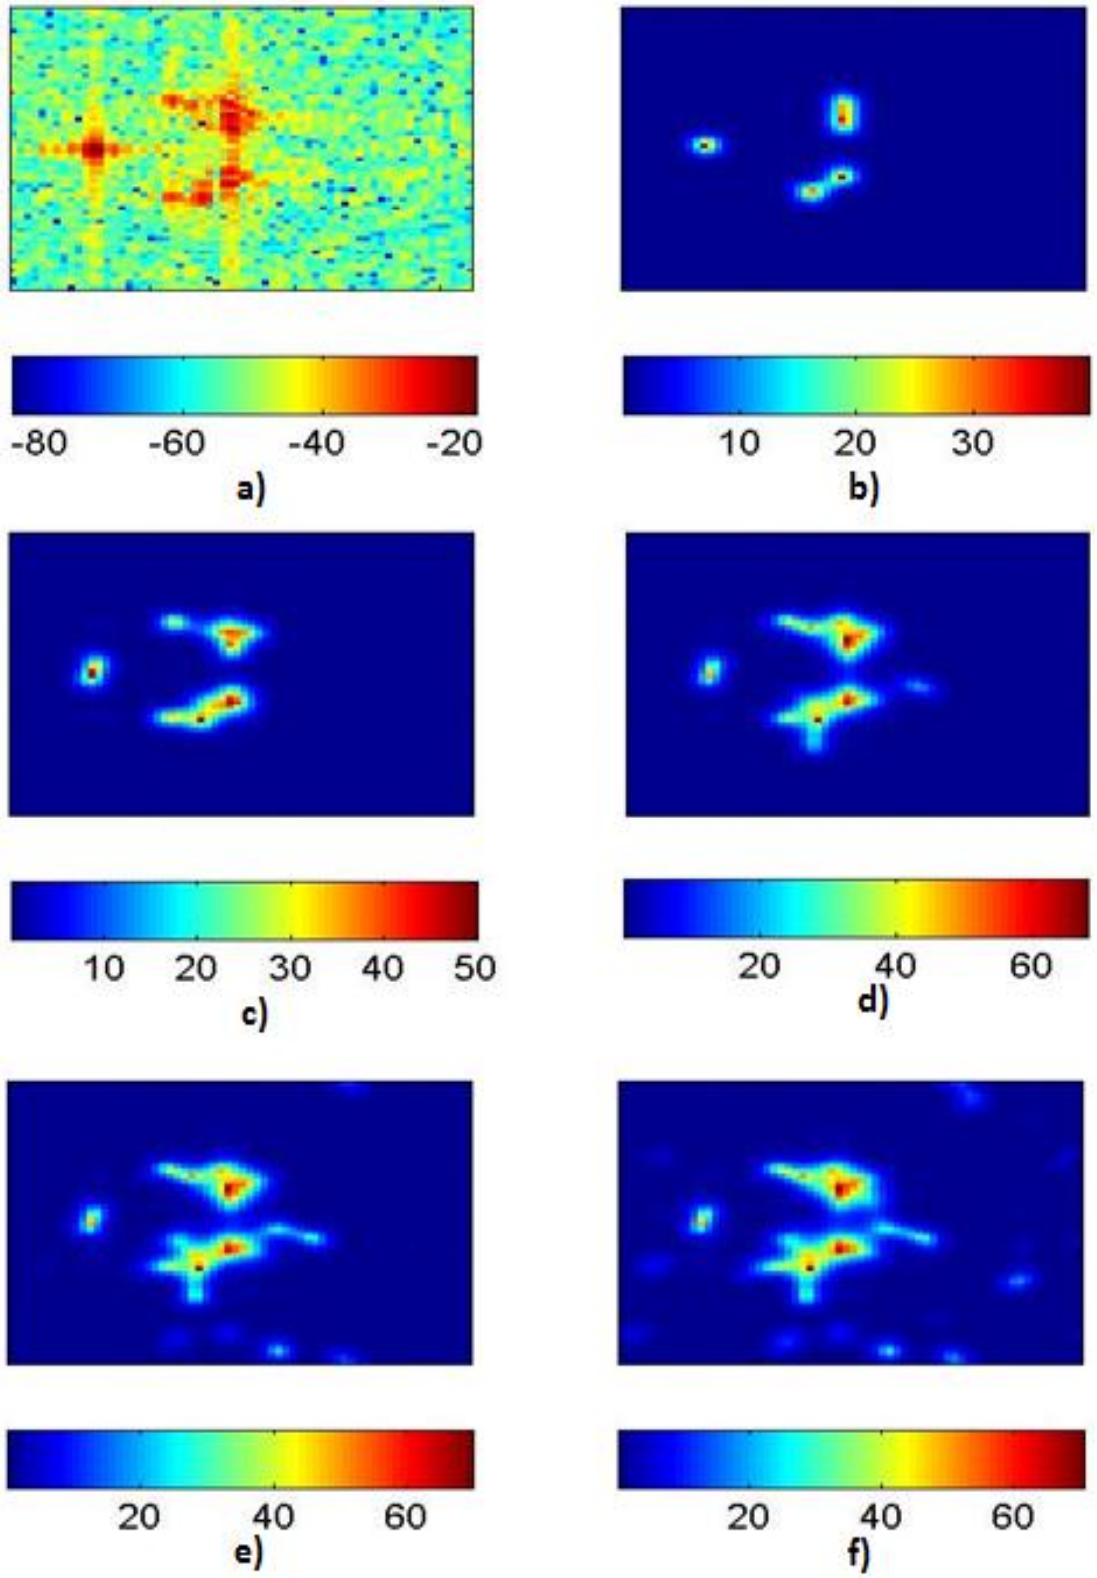
Şekil 2.18: 64 x 64 veri boyutundaki Mig 25 hedefinin (SNR=10 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:24) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 14, c) 44, d) 74 (kestirilen saçıcı sayısı değeri), e) 104, f) 134



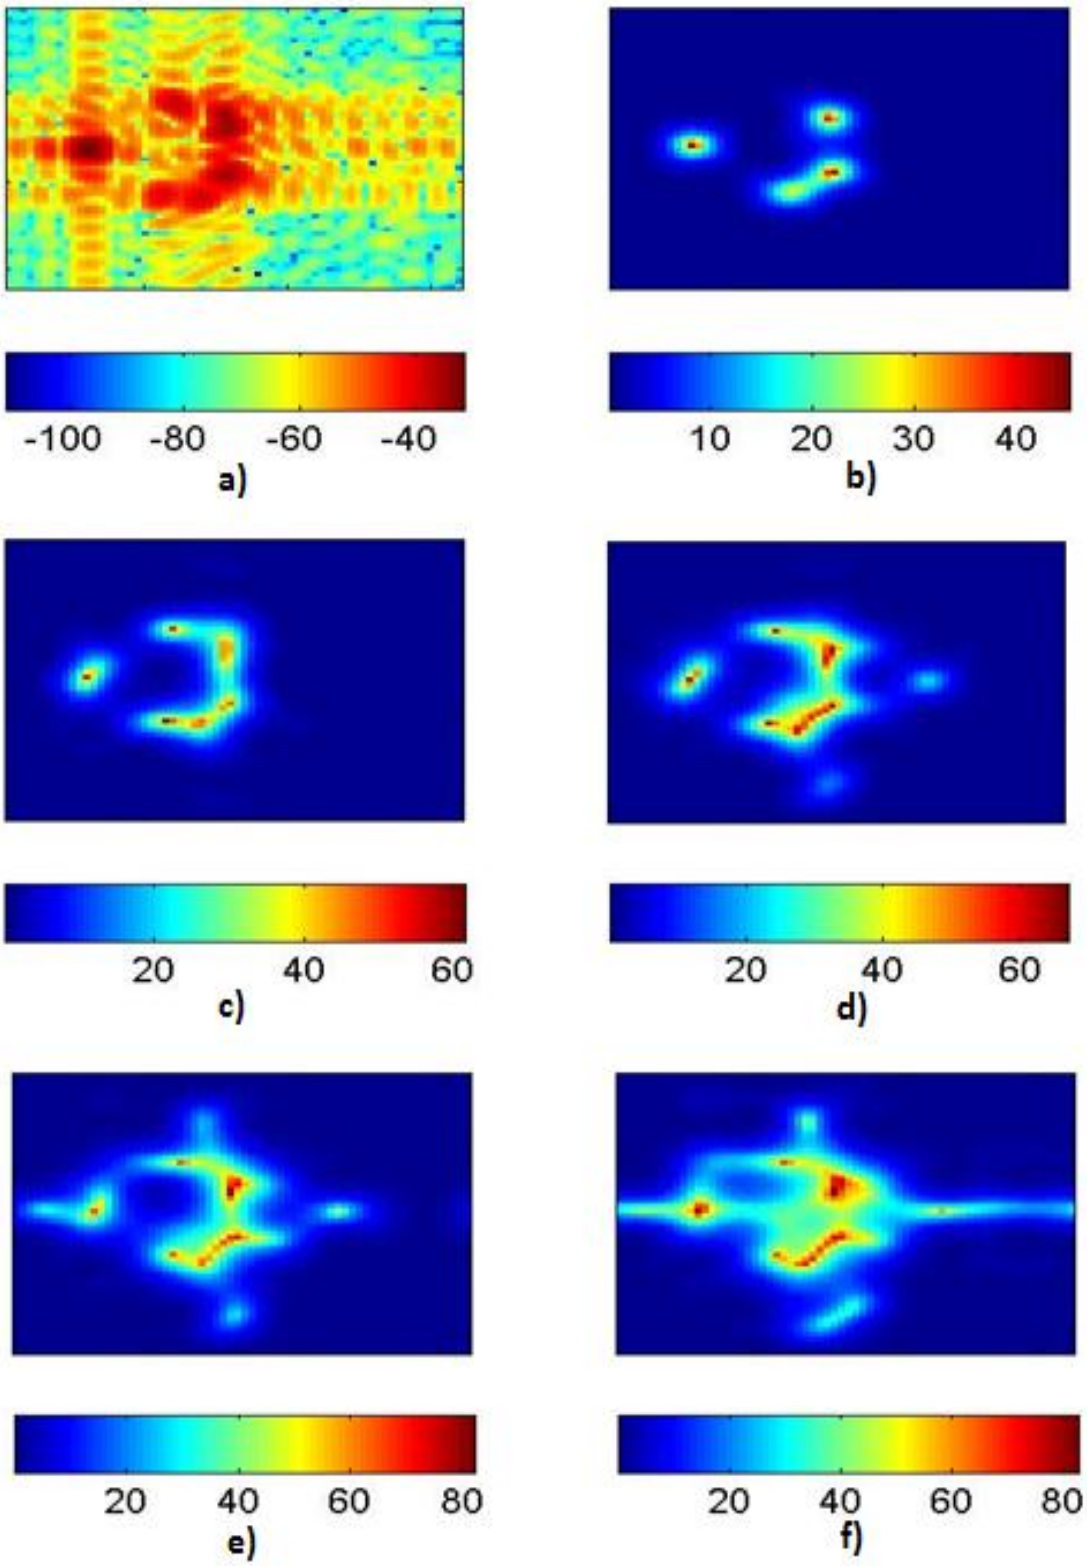
Şekil 2.19: 32x32 veri boyutundaki Mig 25 hedefinin(SNR=30 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:12) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 17, c) 27, d) 37 (kestirilen saçıcı sayısı değeri), e) 47, f) 57



Şekil 2.20: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:12) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 7, c) 14, d) 21 (kestirilen saçıcı sayısı değeri), e) 28, f) 35



Şekil 2.21: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:12) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 5, c) 11, d) saçıcı sayısı:17 (kestirilen saçıcı sayısı değeri), e) 23, f) 29



Şekil 2.22: 16 x 16 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi a) Fourier dönüşümü yöntemi; MUSIC algoritmasında (alt matris boyutu:7) kullanılan farklı saçıcı sayısı değerleri için elde edilen görüntüler, saçıcı sayıları: b) 4, c) 8, d) 12 (kestirilen saçıcı sayısı değeri), e) 16, f) 20

2.3.2.2. Özbağlanımlı (AR) modelleme algoritması

AR modelleme algoritması ile menzilde ve çarpraz menzilde yüksek çözünürlüklü radar hedef görüntüsü elde edilebilir. Algoritma 2 boyutlu lineer kestirim (ileriye doğru [forward] ve geriye doğru [backward] lineer kestirim) tabanlı çalışan bir algoritmadır. Hedefin baskın saçıcı merkezlerinin konumlarını bulabilmek için 2-boyutlu kartezyen frekans spektrumunu kullanır. Hedefin birbirlerinden ayrı dağınıklaşmamış (nondispersive) saçıcı merkezlerinden oluştuğu varsayılmaktadır. Bu varsayım hedef saçıcı merkezlerinin frekans ve bakış açısı ile değişmediğini ifade etmektedir. Bu yöntemle dar frekans bandı ve dar açı sektöründe toplanan RCS verilerinden yüksek kalitede radar görüntüleri elde edilebildiği gösterilmiştir. Özbağlanımlı (AR) (Auto-Regressive) modelleme yöntemi özellikle dar bant genişliğinde ve dar açı aralığında veri toplandığı durumlarda 2-B ters FFT'ye göre daha iyi çözünürlük sağlamaktadır [3].

Şekil 2.23'de görülen M adet ayrık saçıcı bulunduran bir hedefi ele alalım. f frekansında θ açısındaki k. saçıcı merkezinin oluşturduğu geri saçılma alanı şu şekilde hesaplanabilir:

$$E_k(f,\theta) = A_k\,(f,\theta)e^{j2\pi f t_k} \qquad \textbf{(2.19)}$$

$A_k\,(f,\theta)$, k. saçıcı merkezin geri saçılma alanı (referans noktasında yer aldığı düşünülürse); t_k, saçıcı merkezinin yerine (x_k, y_k) göre gecikme zamanıdır (time delay). Gecikme zamanı t_k şu şekilde ifade edilebilir:

$$t_k = \frac{2\,(x_k \cos\theta + y_k\ \sin\theta)}{\mathrm{c}} \qquad \textbf{(2.20)}$$

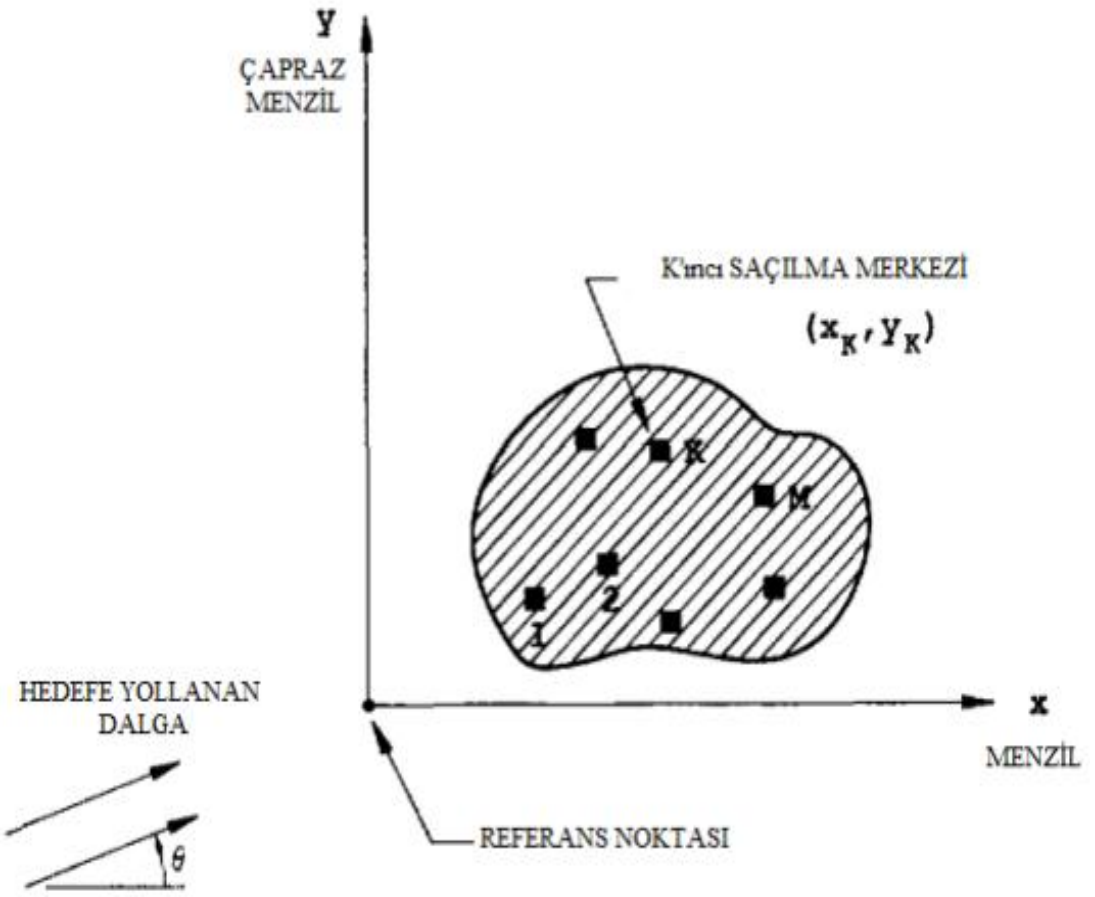
c, ışık hızıdır. (2.20)'yi (2.19)'da yerine koyduğumuzda; şu ifade elde edilmektedir:

$$E_k\left(f_x, f_y\right) = A_k\,(f_x, f_y)e^{j4\pi/c\,(f_x\,x_k + f_y\,y_k)} \qquad \textbf{(2.21)}$$

Burada,

$$f_x = f\cos\theta\ ;\ f_y = f\sin\theta \qquad \textbf{(2.22)}$$

şeklinde ifade edilir.



Şekil 2.23: Koordinat sistemi ve M saçılma merkezli hedef

Ayrıca;

$$f = \sqrt{f_x^2 + f_y^2} \tag{2.23}$$

ve

$$\theta = \tan^{-1}(f_y / f_x) \tag{2.24}$$

ifadeleri yazılabilir.

Hedef saçılma alanının küçük f ve θ artım aralıkları ile hesaplandığını varsaydığımızda, kartezyen koordinatta eşit aralıklı f_x ve f_y değerleri elde etmek için interpolasyon kullanılabilir. Sonrasında f_x ve f_y uzayında saçılan alanlar hesaplanabilir. Bu durumda f_x ve f_y şu şekilde hesaplanabilir:

$$f_x(l) = f_x(0) + l\Delta f_x; \quad l = 0,1,2 \dots N-1 \tag{2.25}$$

ve

$$f_y(l) = f_y(0) + n\Delta f_y \quad n = 0,1,2 \dots N-1 \tag{2.26}$$

Burada $f_x(0)$ ve $f_y(0)$ değerleri f_x ve f_y'nin başlangıç, ya da diğer bir tabirle ilk değerleridir. Δf kartezyen düzlemdeki frekansın artım aralığıdır. (2.25) ve (2.26)'yı (2.21)'de yerine koyduğumuzda, aşağıdaki formul elde edilir:

$$E_k(l,n) = A_k\,(l,n) e^{j4\pi/c\,(f_x(0)\,x_k + f_y(0)\,y_k)} z_{x_k}^{l} z_{y_k}^{n} \tag{2.27}$$

Burada,

$$z_{x_k} = e^{j4\pi/c\Delta f_x x_k} \tag{2.28}$$

ve

$$z_{y_k} = e^{j4\pi/c\Delta f_y y_k} \tag{2.29}$$

Hedefin saçılan alanları küçük bir bant genişliği ve açısal bölgede yapıldığından $A_k\,(f,\theta)$ frekansa ve açısal bölgeye göre değişmeyen, sabit kabul edilebilir [3].

Bu varsayım sonrasında (2.27) bağıntısı şu şekilde yazılabilir.

$$E_k(l,n) = E_k(0,0) z_{x_k}^{l} z_{y_k}^{n} \tag{2.30}$$

Burada,

$$E_k(0,0) = A_k\,(f_x(0), f_y(0)) e^{j4\pi/c\,(f_x(0)\,x_k + f_y(0)\,y_k)} \tag{2.31}$$

ifadesi k. saçıcı merkezinin kartezyen frekanslardaki $(f_x(0), f_y(0))$ geri saçılma alanını ifade etmektedir. ((2.30)'dan kartezyen frekanslardaki toplam geri saçılan alan şu şekilde ifade edilebilir:

$$E(l,n) = \sum_{k=1}^{M} E_k(0,0) z_{x_k}^{l} z_{y_k}^{n} + v(l,n) \tag{2.32}$$

$v(l,n)$ ölçülen gürültü değeridir. (2.32)'den görüldüğü üzere hedefin saçıcı alanlarını kestirebilmek için 2 boyutlu lineer kestirim (linear prediction) kullanılabilir [3].

f_x ve f_y üzerindeki L adet veri noktası belirli bir kartezyen frekanstaki $(f_x(l), f_y(l))$ saçılan alanları kestirmek için kullanılabilir. Eğer önceki L adet verinin lineer kombinasyonu kullanılırsa, öngörülen saçılan alan $\hat{E}(l,n)$ şu şekilde yazılabilir:

$$\hat{E}(l,n) = -\sum_{i=0}^{L}\sum_{j=0}^{L} a_{ij}\, E(l-i, n-j) \qquad i = j \neq 0 \qquad l,n = L, L+1, \dots, N-1 \tag{2.33}$$

Buradaki a_{ij} bilinmeyen katsayıları ifade etmektedir. Denklem (2.33) kestirilen değeri kendinden önceki değerlerin lineer kombinasyonu şeklinde ifade etmektedir. Denklem ayrıca L modelleme seviyeli özbağlanımlı (AR - autoregressive) modellemeyi ifade etmektedir. Eğer kestirilen değer kendinden sonraki L adet verinin lineer kombinasyonu kullanılarak bulunuyorsa bu yöntem geriye doğru kestirim (backward prediction) şeklinde ifade edilebilir. Bu durumda kestirilen değer $\hat{E}(l,n)$ şu şekilde yazılabilir:

$$\hat{E}(l,n) = -\sum_{i=0}^{L}\sum_{j=0}^{L} \tilde{a}_{ij}\, E(l+i, n+j) \qquad i = j \neq 0 \qquad l,n = 0, 1, \dots, N-L-1 \tag{2.34}$$

Burada $\tilde{a}_{ij}$ bilinmeyen katsayılardır. [15]'de gösterildiği üzere $\tilde{a}_{ij} = a^*{}_{ij}$. Dolayısıyla (2.34) şu şekilde yazılabilir:

$$\hat{E}^*(l,n) = -\sum_{i=0}^{L}\sum_{j=0}^{L} a_{ij}\, E^*(l+i, n+j) \qquad \textbf{(2.35)}$$

$$i = j \neq 0$$

Eğer [3]'de bahsedilen bu kestirim doğru ise $\hat{E}(l,n) = E(l,n)$ olacaktır. (2.33) ve (2.35) kullanılarak bilinmeyen katsayı değerleri a_{ij} bulunabilir. Burada $(L+1)^2 - 1$ bilinmeyen ve $2(N-L)^2$ lineer denklem bulunmaktadır. Normal olarak $N > 2L$ olacak şekilde seçilir. Sonuç olarak en küçük kareler (least square) çözümüyle ya da toplam en küçük kareler çözümüyle a_{ij}'ler bulunabilir. Denklem (2.33) ve (2.35) matris notasyonu ile şu şekilde sunulabilir:

$$\boldsymbol{Ea} = -\boldsymbol{e} \qquad \textbf{(2.36)}$$

Burada $\boldsymbol{E}$, $2(N-L)^2$'e $(L+1)^2 - 1$'lik bir matristir. $\boldsymbol{a}$, $(L+1)^2 - 1$ uzunluğunda bir vektördür. $\boldsymbol{e}$, $2(N-L)^2$ uzunluğunda bir vektördür. (2.35)'in en küçük kareler çözümü şu şekildedir:

$$\boldsymbol{a} = -(\boldsymbol{E^H E})^{-1}\boldsymbol{E^H e} \qquad \textbf{(2.37)}$$

Buradaki H kompleks konjuge transpoze'yi göstermektedir.

Yukarıdaki bahislerde iki boyut için de f_x ve f_y ileriye doğru ya da geriye doğru kestirim yöntemleri anlatılmıştır. Alternatif olarak ileriye doğru kestirim yöntemi değerlerden biri için geriye doğru kestirim yöntemi değerlerden diğeri için kullanılabilir. Bu durumda yine $2(N-L)^2$ kadar denklem ve a_{ij}'den farklı olarak $(L+1)^2 - 1$ kadar bilinmeyen olacaktır. Bu bilinmeyen katsayılar b_{ij} şeklinde ifade edilmiştir. Eğer ileriye doğru kestirim f_x üzerinde ve geriye doğru kestirim f_y üzerinde kullanılırsa kestirilen değer şu şekilde yazılabilir:

$$\hat{E}(l,n) = -\sum_{i=0}^{L}\sum_{j=0}^{L} b_{ij}\, E(l-i, n+j) \qquad \textbf{(2.38)}$$

$$i = j \neq 0$$

$$l = L, L+1, \ldots, N-1$$

$$n = 0, 1, \ldots, N-L-1$$

Diğer taraftan eğer geriye doğru kestirim f_x üzerinde ve ileriye doğru kestirim f_y üzerine kullanılırsa kestirilen değer şu şekilde yazılır:

$$\hat{E}^*(l,n) = -\sum_{\substack{i=0 \\ i=j\neq 0}}^{L} b_{ij}\, E^*(l+i, n-j) \qquad \textbf{(2.39)}$$

$$l = 0, 1, \dots, N-L-1$$

$$n = L, L+1, \dots, N-1$$

(2.38) ve (2.39) kullanılarak denklemler çözülebilir ve b_{ij} katsayıları tespit edilebilir. Matris formunda formuller şu şekilde düzenlenebilir:

$$\widetilde{\boldsymbol{E}}\boldsymbol{b} = -\tilde{\boldsymbol{e}} \qquad \textbf{(2.40)}$$

Burada $\widetilde{\boldsymbol{E}}$, $2(N-L)^2$'e $(L+1)^2-1$'lik bir matristir. $\boldsymbol{b}$, $(L+1)^2-1$ uzunluğunda bir vektördür. $\tilde{\boldsymbol{e}}$ ise $2(N-L)^2$ uzunluğunda bir vektördür.

Daha sonra a_{ij} ve b_{ij} katsayıları hedefin saçıcılarının yerlerini bulmak için kullanılırlar. (2.33)'den kestirilen geri saçılan ile ölçülen geri saçılan alan arasındaki hata $e(l,n)$, şu şekilde bulunur:

$$e(l,n) = E(l,n) - \hat{E}(l,n)$$

$$= E(l,n) + \sum_{\substack{i=0 \\ i=j\neq 0}}^{L}\sum_{j=0}^{L} a_{ij}\, E(l-i, n-j) \qquad \textbf{(2.41)}$$

Yukarıda ifade edilen denklem 2-boyutlu hata kestirim filtresinin (error prediction filter) çıktısıdır. Bu hata kestirim filtresinin sıfırlarının saçıcı merkez yerleri ile ilişkili olduğu gösterilebilir. (2.41)'in 2-boyutlu z-dönüşümü şu şekilde ifade edilebilir.

$$Z\big(e(l,n)\big) = \left(1 + \sum_{\substack{i=0 \\ i=j\neq 0}}^{L}\sum_{j=0}^{L} a_{ij}\, z_1^{-i} z_2^{-j}\right) Z\big(E(l,n)\big) \qquad \textbf{(2.42)}$$

Bu filtrenin transfer fonksiyonu şu şekilde ifade edilebilir:

$$1 + \sum_{i=0}^{L} \sum_{j=0}^{L} a_{ij}\, z_1^{-i} z_2^{-j} \qquad \textbf{(2.43)}$$

$$i = j \neq 0$$

Benzer şekilde (2.38) kullanılarak, filtrenin transfer fonksiyonu şu şekilde verilebilir:

$$1 + \sum_{i=0}^{L} \sum_{j=0}^{L} b_{ij}\, z_1^{-i} z_2^{-j} \qquad \textbf{(2.44)}$$

$$i = j \neq 0$$

(2.43) ve (2.44) hata kestirim filtresinin sıfırlarını bulabilmek için çözülebilir. z_{1k} ve z_{2k} filtrenin k. sıfırı olsun, şu şekilde ifade edilebilirler:

$$\begin{aligned} z_{1k} &= c_k e^{j\alpha_k} \\ z_{2k} &= d_k e^{j\beta_k} \end{aligned} \qquad \textbf{(2.45)}$$

(2.28) ve (2.29)'dan,

$$\begin{aligned} \alpha_k &= \frac{4\pi}{c} \Delta f_x . x_k \\ \beta_k &= \frac{4\pi}{c} \Delta f_y . y_k \end{aligned} \qquad \textbf{(2.46)}$$

Ya da diğer bir şekilde,

$$\begin{aligned} x_k &= \frac{\alpha_k}{4\pi} \frac{c}{\Delta f_x} \\ y_k &= \frac{\beta_k}{4\pi} \frac{c}{\Delta f_y} \end{aligned} \qquad \textbf{(2.47)}$$

Sonuç olarak hata kestirim filtrelerinin sıfırları ile saçıcı merkezleri tespit edilebilir. Genel olarak, (2.43) ve (2.44)'ün sıfırları saçıcı merkezleri sayısından daha çok olacaktır. Genlikleri yaklaşık aynı olan sıfırlar gerçek saçıcı merkezlerini gösterir. Aşağıda açıklandığı şekilde, kestirilen saçıcı merkezleri ile ilişkili olan sinyallerin genlikleri gerçek saçıcı merkezlerini hesaplamak için kullanılabilir. Pratikte gerçek

saçıcı merkezlerinden üretilen sinyallerin genlikleri sahte hedeflerin genliklerinden çok daha yüksek olmaktadır. Bu nedenle, küçük genlikli saçıcıların sahte hedef olduğu düşünülebilir [16].

(2.43) ve (2.44)'ün sıfırlarını ya da köklerini bulmak kolay bir problem değildir. Alternatif olarak (2.43) ve (2.44) kullanılarak P(x,y) şu şekilde tanımlanabilir:

$$P(x,y) = \frac{1}{\left|1 + \sum_{i=0}^{L}\sum_{j=0}^{L} a_{ij}\, z_1^{-i} z_2^{-j}\right|^2 + \left|1 + \sum_{i=0}^{L}\sum_{j=0}^{L} b_{ij}\, z_1^{-i} z_2^{-j}\right|^2} \qquad \textbf{(2.48)}$$

$$i = j \neq 0$$

Burada,

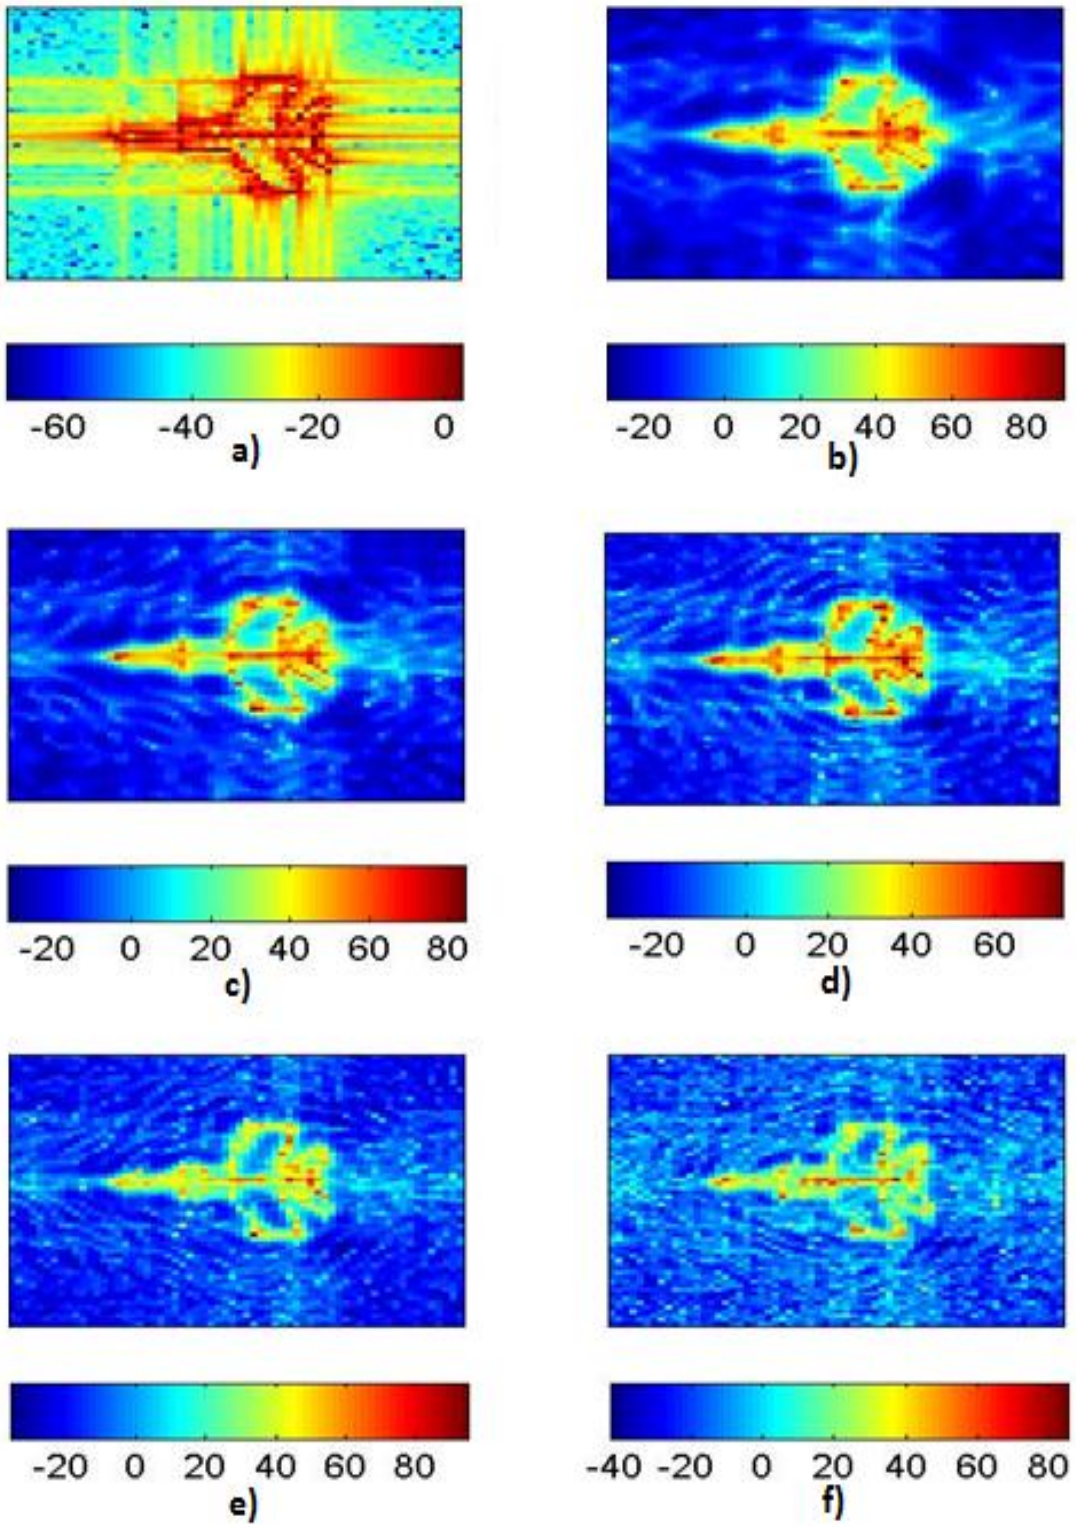
$$z_1 = e^{j4\pi/c\Delta f_x x} \qquad \textbf{(2.49)}$$

ve

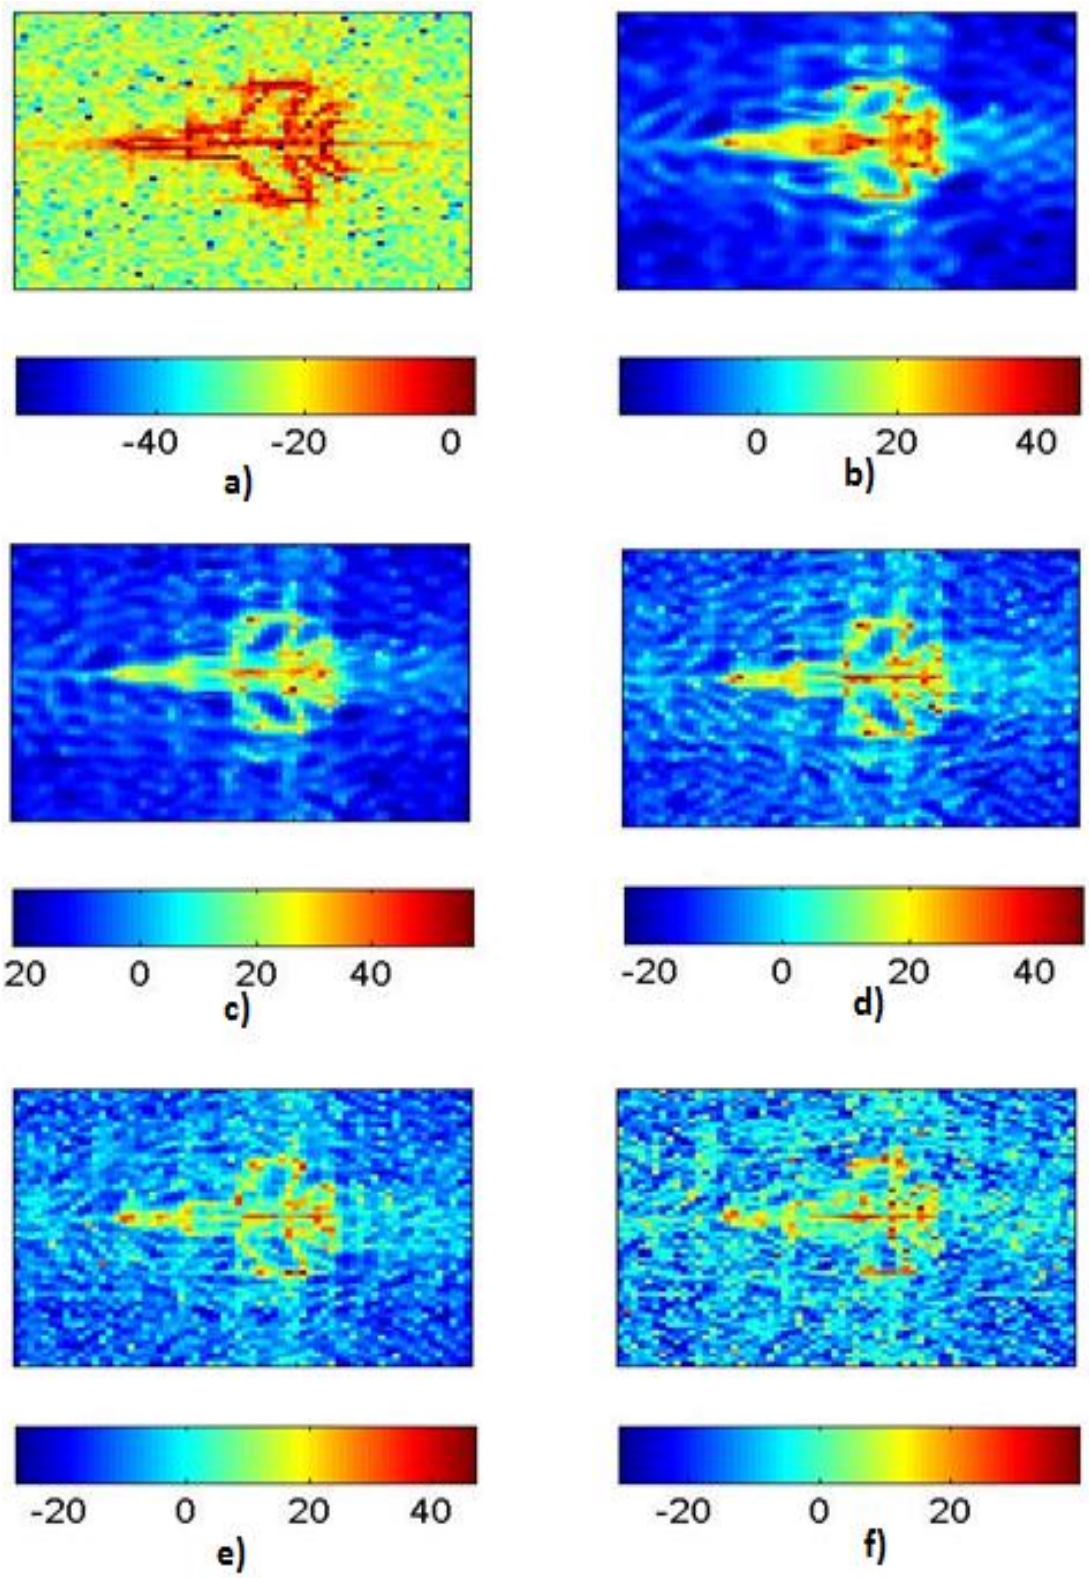
$$z_2 = e^{j4\pi/c\Delta f_y y} \qquad \textbf{(2.50)}$$

Bu noktada şuna dikkate etmek gerekir ki (2.48)'de (x, y) hedefin saçıcı merkezi ile çakışırsa (2.48)'in payda kısmı küçülecek ve fonksiyon bir tepe noktasına sahip olacaktır. Bu noktada $P(x, y)$ değerleri çizdirildiğinde $P(x, y)$'nin tepe noktaları saçıcı merkezlerinin yerlerini gösterecektir [3].

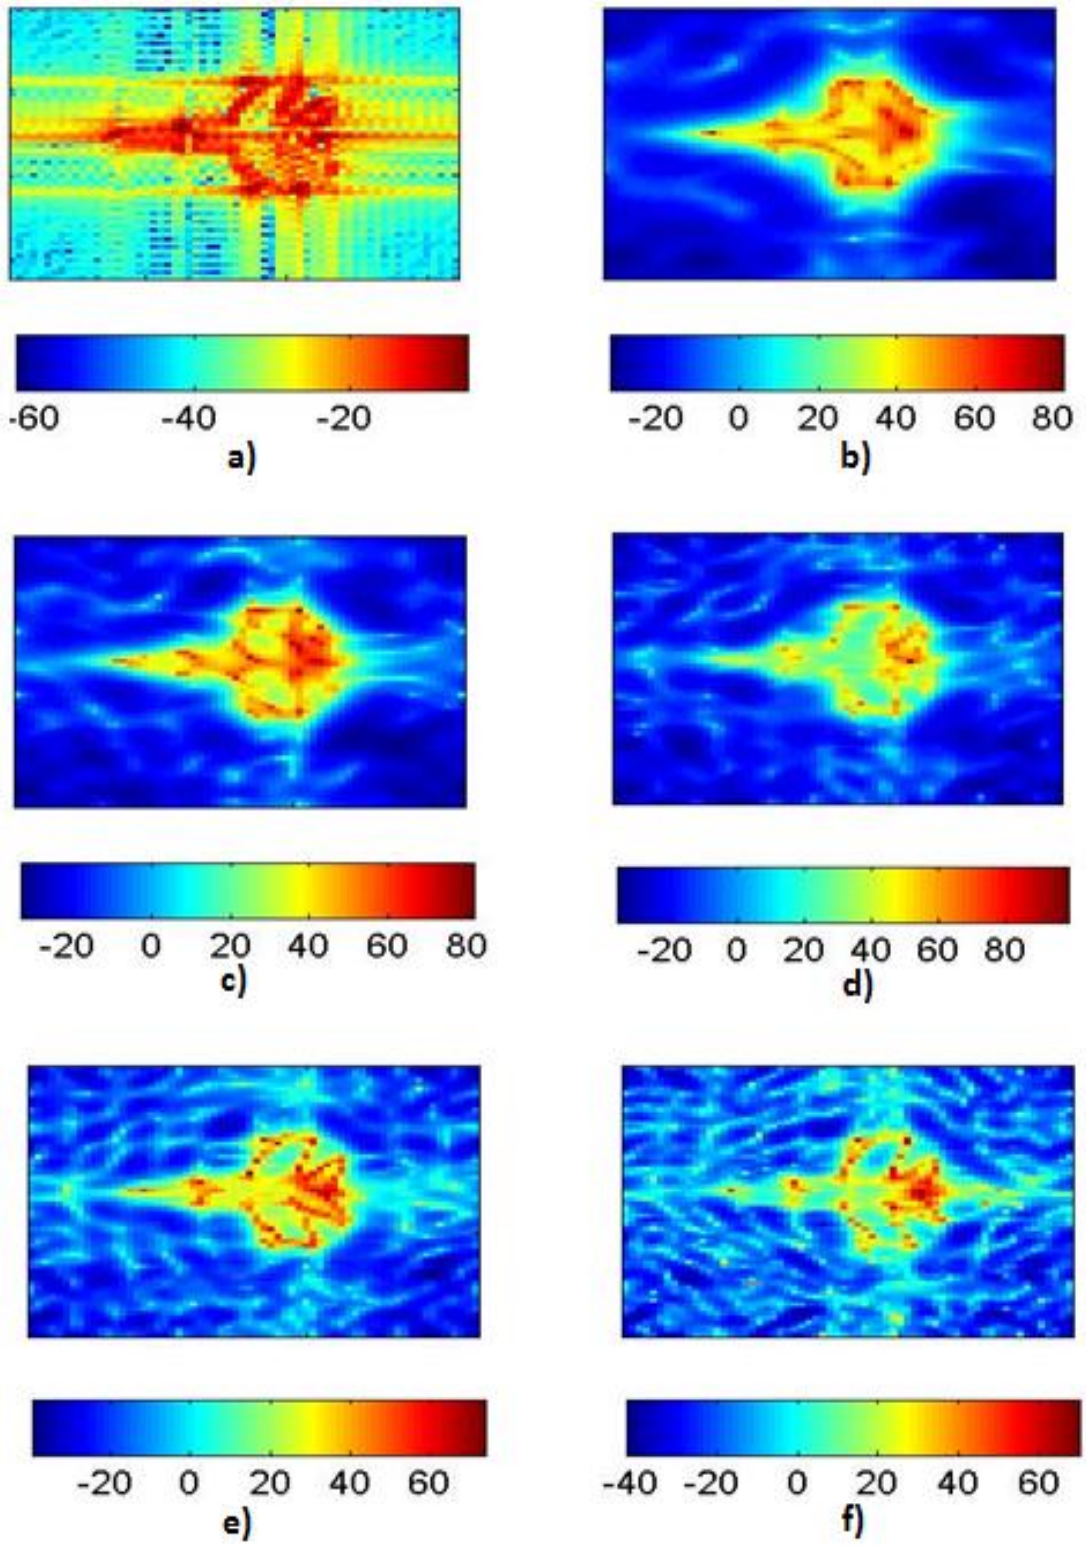
Aşağıdaki altı şekilde değişen özbağlanımlı (AR) modelleme seviyelerine göre radar hedef görüntüleri görünmektedir. Görüntüler incelendiğinde modelleme seviyesi arttıkça çözünürlüğün arttığı görülmektedir. Bir seviyeden sonra çözünürlük arttsa da radar hedef görüntüsünün belirginliği kaybolmakta ve radar hedef görüntüsü arka plan görüntüsünden ayırt edilemez hale gelmektedir (örn. 64x64 boyutundaki veri için modelleme seviyesi 30 iken). Modelleme seviyesi düştükçe çözünürlük kötüleşmekte, diğer yandan hedef saçıcıları gürültüye sebep olan diğer saçıcılardan çok daha belirgin halde görünmektedir. Dinamik alanda ise MUSIC algoritmasındaki gibi belirli bir düzende artış veya azalma görünmemektedir.



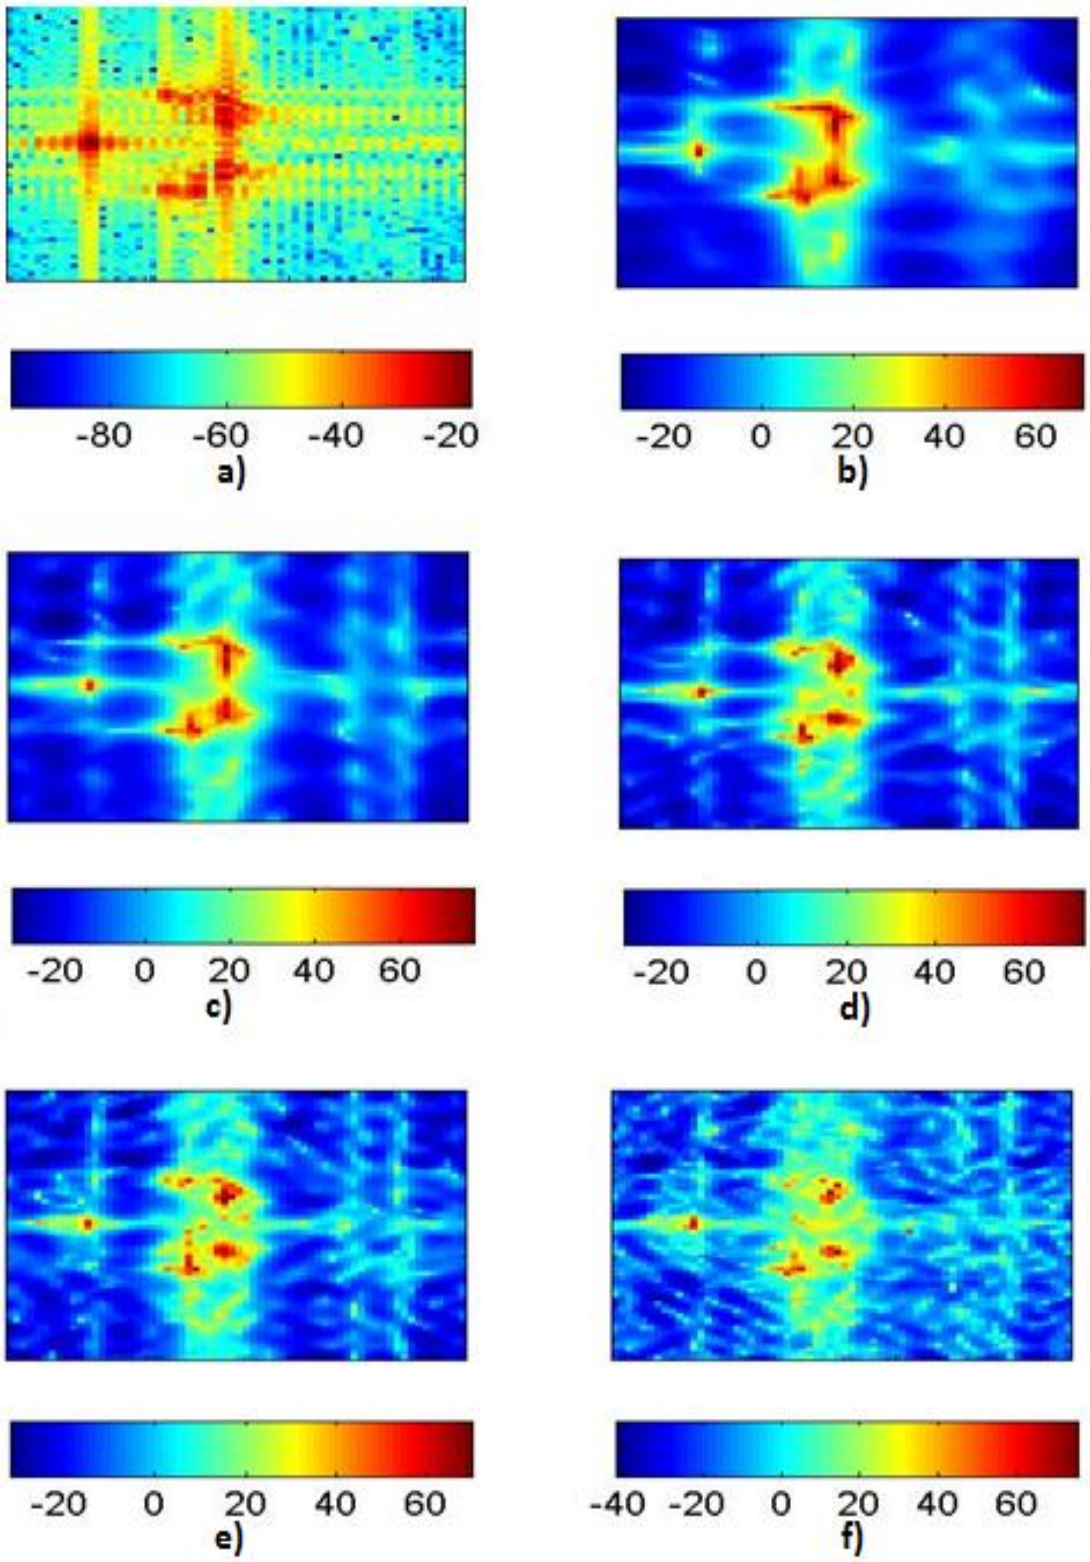
Şekil 2.24: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 12, c) 16, d) 20, e) 24, f) 30



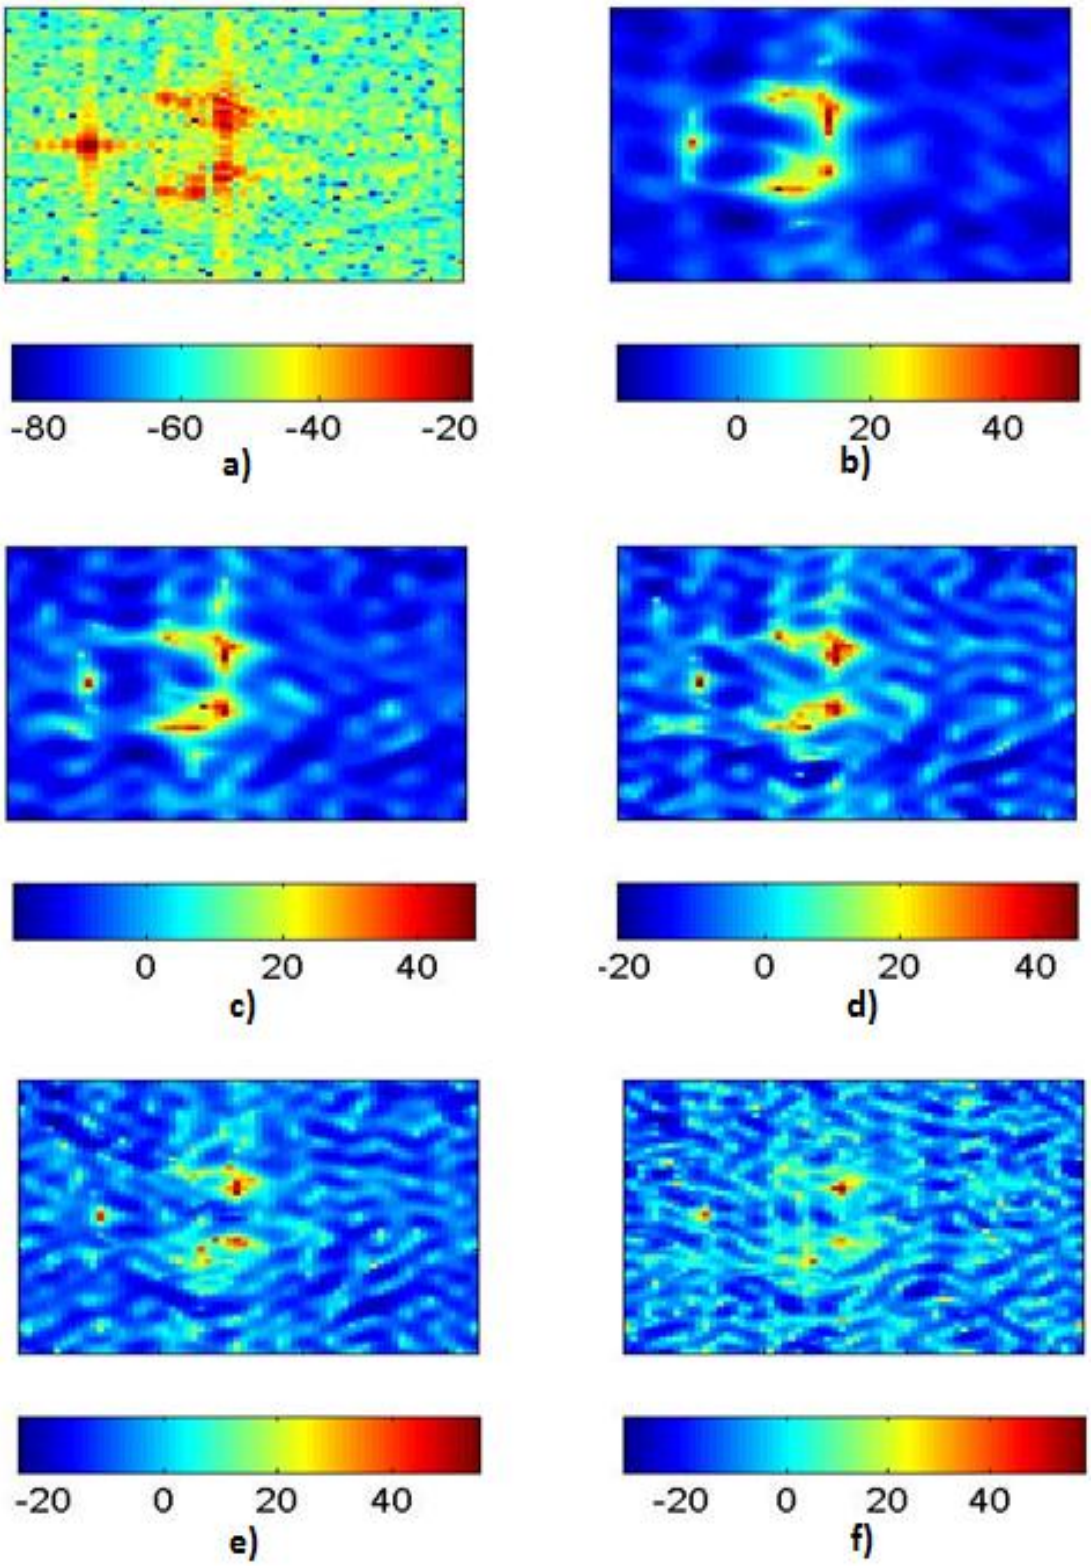
Şekil 2.25: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=10 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 12, c) 16, d) 20, e) 24, f) 30



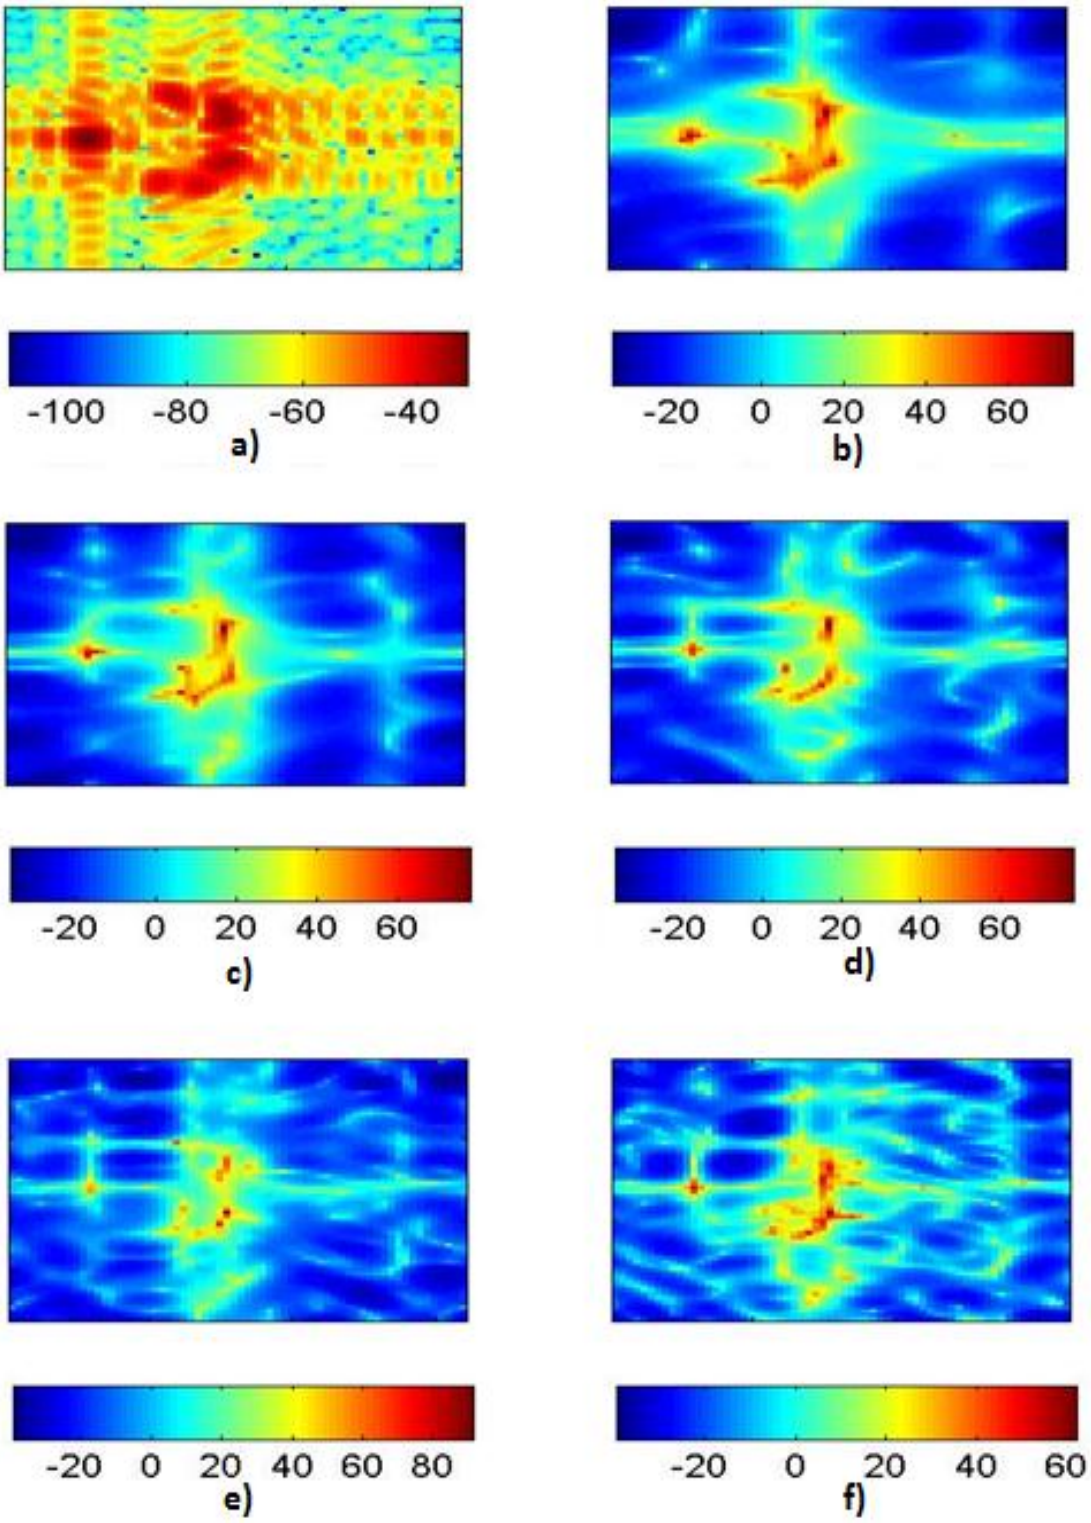
Şekil 2.26: 32 x 32 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 6, c) 8, d) 10, e) 12, f) 15



Şekil 2.27: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 6, c) 8, d) 10, e) 12, f) 15



Şekil 2.28: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 6, c) 8, d) 10, e) 12, f) 15



Şekil 2.29: 16 x 16 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntülerinin elde edilmesi a) Fourier dönüşümü yöntemi; farklı özbağlanımlı (AR) modelleme seviyelerine göre elde edilmesi, özbağlanımlı modelleme seviyesi: b) 4, c) 5, d) 6, e) 7, f) 8

Tekil değer ayrışımı (SVD- singular value decomposition) yöntemi ile radar görüntüleme

(2.48)'deki $P(x,y)$ saçıcı sayısından daha fazla tepe noktasına sahip olabilir. Bu noktada yine gerçek saçıcı merkezlerini bulabilmek için tepe noktalarının genlik değerleri üzerinden hareket edilebilir. Ayrıca sahte tepe noktalarını bastırmak için en küçük kareler çözümlerinde "tekil değer ayrışımı" kullanılabilir [17] .

(2.37)'den bilinmeyen a_{ij} katsayıları için en küçük kareler çözümü şu şekilde verilir:

$$\boldsymbol{a} = -\boldsymbol{R}^{-1}\boldsymbol{r} \tag{2.51}$$

Burada

$$\boldsymbol{R} = \boldsymbol{E}^{\boldsymbol{H}}\boldsymbol{E} \tag{2.52}$$

$$\boldsymbol{r} = \boldsymbol{E}^{\boldsymbol{H}}\boldsymbol{e} \tag{2.53}$$

Yukarıdaki denklemde $\boldsymbol{R}$ ölçülen geri saçılma alanlarının kovaryans matrisidir. M adet ayrık saçıcı merkezi olduğunda $\boldsymbol{R}$'nin M adet geniş özdeğere sahip olduğu ve kalan $(L+1)^2 - 1 - M$ özdeğerin ise göreceli olarak düşük değerli ve yaklaşık olarak birbirlerine eşit olduğu gösterilebilir. Daha da ötesi, en geniş M adet özdeğerin özvektörleri geri saçılan alanları ifade eder. Kalan özvektörler ise ölçülen verinin içindeki gürültüyü ifade eder. Sonuç olarak, (2.51)'deki çözümdeki gürültü özvektörleri çıkarılırsa model parametreleri (a_{ij}) iyileştirilebilir [3]. Bu durumda;

$$\boldsymbol{a} = -\sum_{\boldsymbol{i=1}}^{\boldsymbol{M'}} \frac{(\boldsymbol{U_i^H r})}{\boldsymbol{\lambda_i}} \boldsymbol{U_i} \tag{2.54}$$

Burada M' kestirilen saçıcı sayısı, λ_i , i=1, 2, …, M', R'nin en büyük M' özdeğeridir. U_i , λ_i özdeğerleri ile ilgili özvektörlerdir. Fonksiyon P'yi bulabilmek için bu katsayılar kullanıldığı takdirde, çizimde saçıcı merkezlerin bulundukları noktalarda keskin tepe noktaları görülecektir ve bu M' adet tepe noktası hedefi tanımlamak için kullanılabilecektir. Pratikte büyük ve küçük özdeğer ayrımı aşikar olmayabilir. Bu durumda M' adet saçıcı merkezini kestirebilmek için bilgi-temelli kriter (information-based criterion) [18], [19] kullanılabilir. Sonrasında en küçük kareler çözümünde ((2.36) ve (2.40)'da) en geniş M' özdeğer kullanılabilir. Aşağıda farklı saçıcı merkezleri ile ilgili sinyal genliklerinin nasıl kestirilebileceği anlatılmaktadır.

(2.32)'nin en küçük kareler çözümünde farklı saçıcı merkezleri ile ilgili olan sinyal genliklerinin nasıl elde edileceği ele alınır. M', yukarıda bahsedilen prosedür kullanılarak kestirilmiş saçıcı merkezlerinin sayısı olsun. Sonrasında denklem (2.32)'den,

$$E(l,n) \simeq \sum_{k=1}^{M'} E_k\,(0,0) e^{j4\pi/c(\Delta f_x.\hat{x}_k.l+\Delta f_y.\hat{y}_k.n)} \qquad \textbf{(2.55)}$$

$$l,n = 0,1,\dots,N-L-1$$

Burada $(\hat{x}_k,\ \hat{y}_k)\,k.$ saçıcı merkezin kestirilen konumudur. Denklem ((**2.55**), N^2 denklem ve M' adet bilinmeyen sunmaktadır ($E_k(0,0)$). Genelde N^2>>M' olduğundan ((**2.55**)'in en küçük kareler çözümü $E_k(0,0)$'ı kestirmek için kullanılabilir, k= 1,2, …M'. Denklem ((**2.55**) matris formunda şu şekilde yazılabilir:

$$\boldsymbol{Vq = f} \qquad \textbf{(2.56)}$$

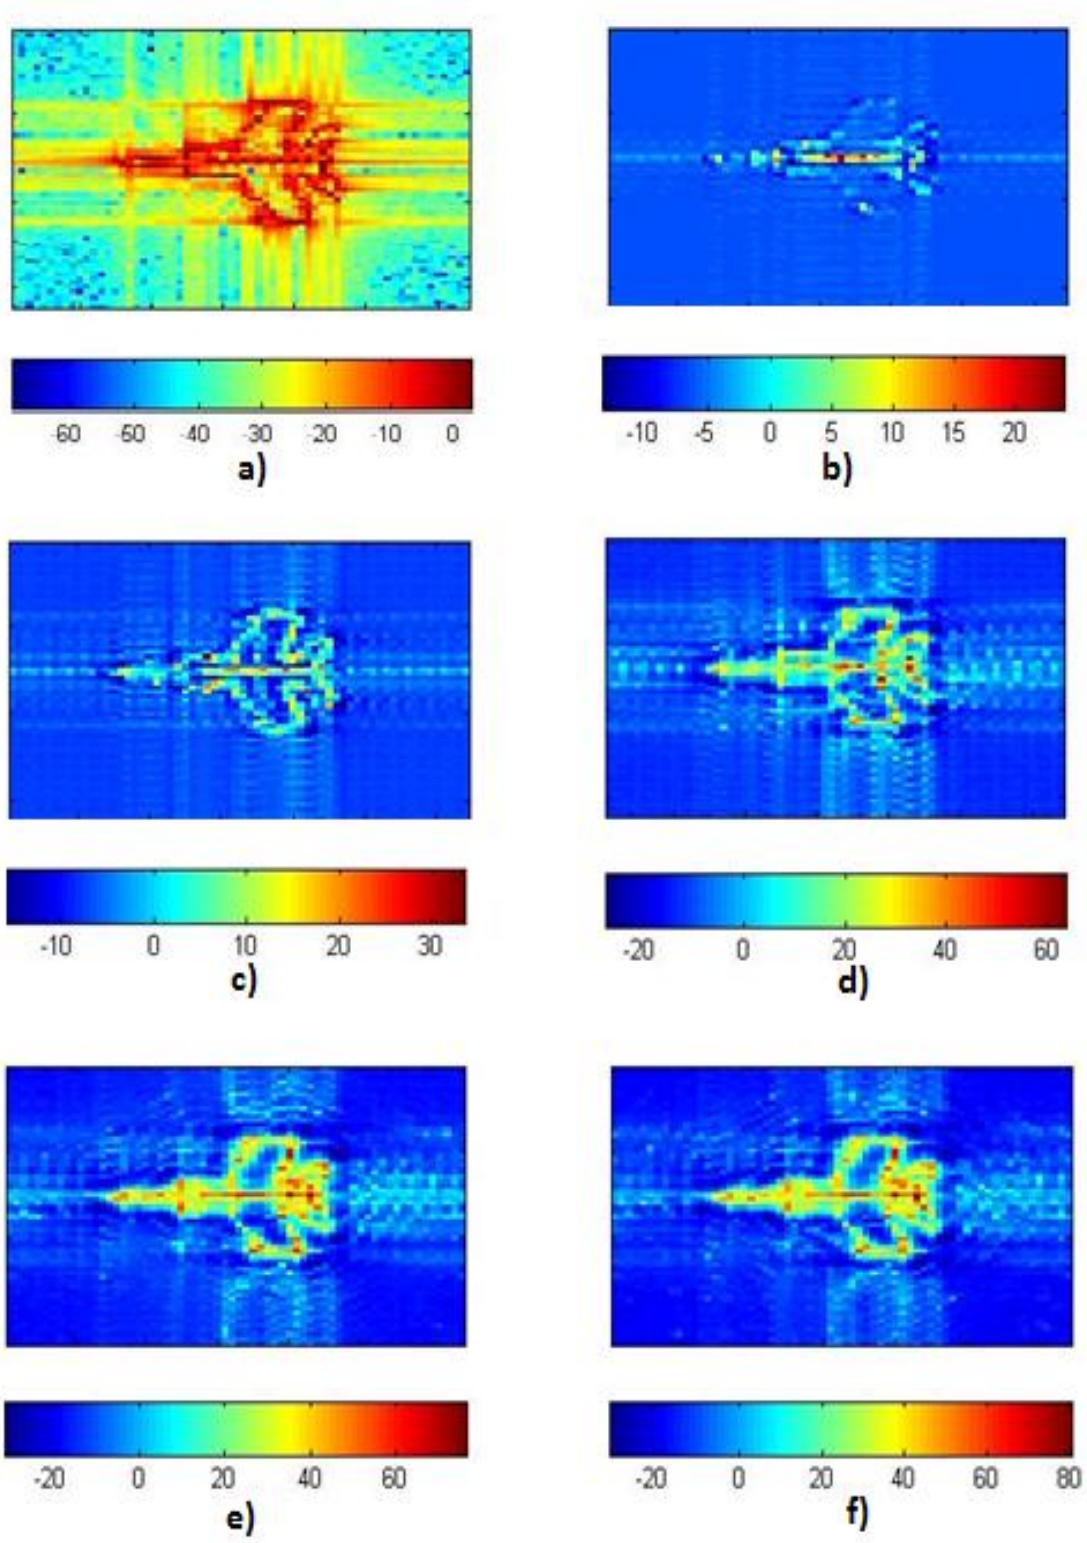
Burada $\boldsymbol{V}$, N^2xM' boyutunda bir matris; $\boldsymbol{q}$, M' uzunluğunda $\boldsymbol{f}$ ise N^2 uzunluğunda bir vektördür. $\boldsymbol{q}$ için en küçük kareler çözümü:

$$\boldsymbol{q} = (\boldsymbol{V^H V})^{-1}\boldsymbol{V^H f} \qquad \textbf{(2.57)}$$

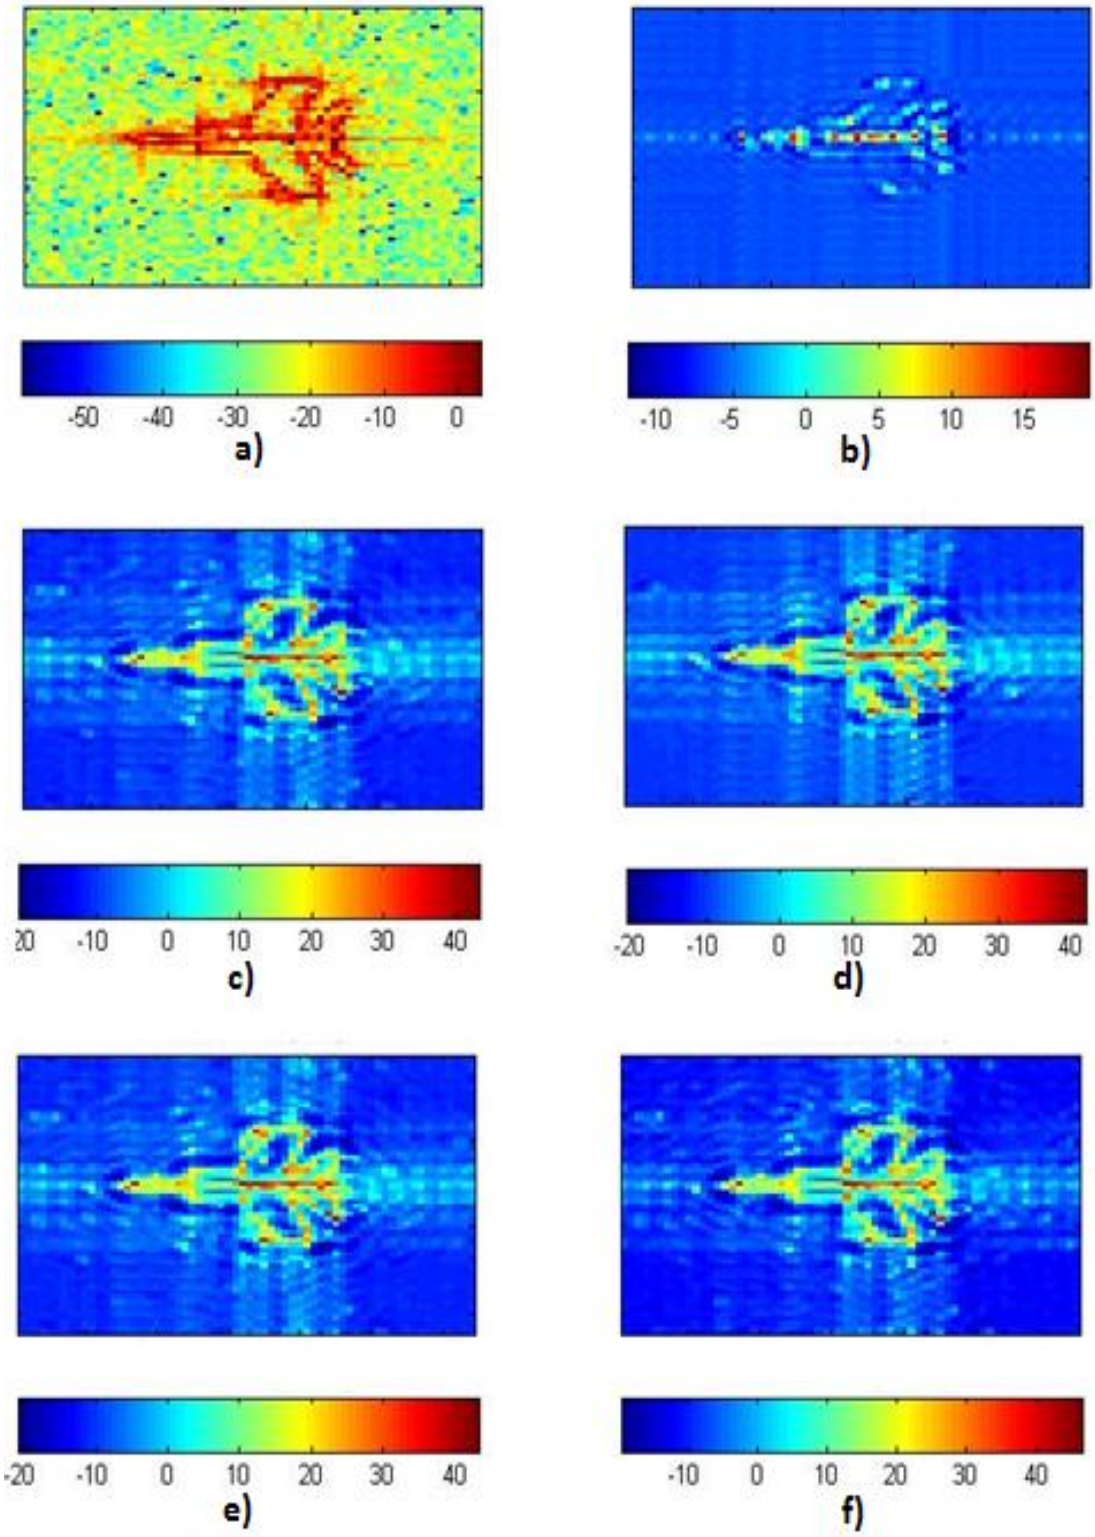
Sonuç olarak, farklı saçılma merkezleri ile ilgili olan sinyallerin genlikleri elde edilebilir.

Tekil değer ayrışımı (SVD) yöntemi ile özbağlanımlı katsayısı kestirildiğinde radar hedef görüntüsündeki yan lobların (sahte saçıcıların) başarılı bir şekilde bastırıldığı görülebilir. Bu durum radar hedefinin arka plan görüntüsüne oranla daha net görünmesini sağlamaktadır.

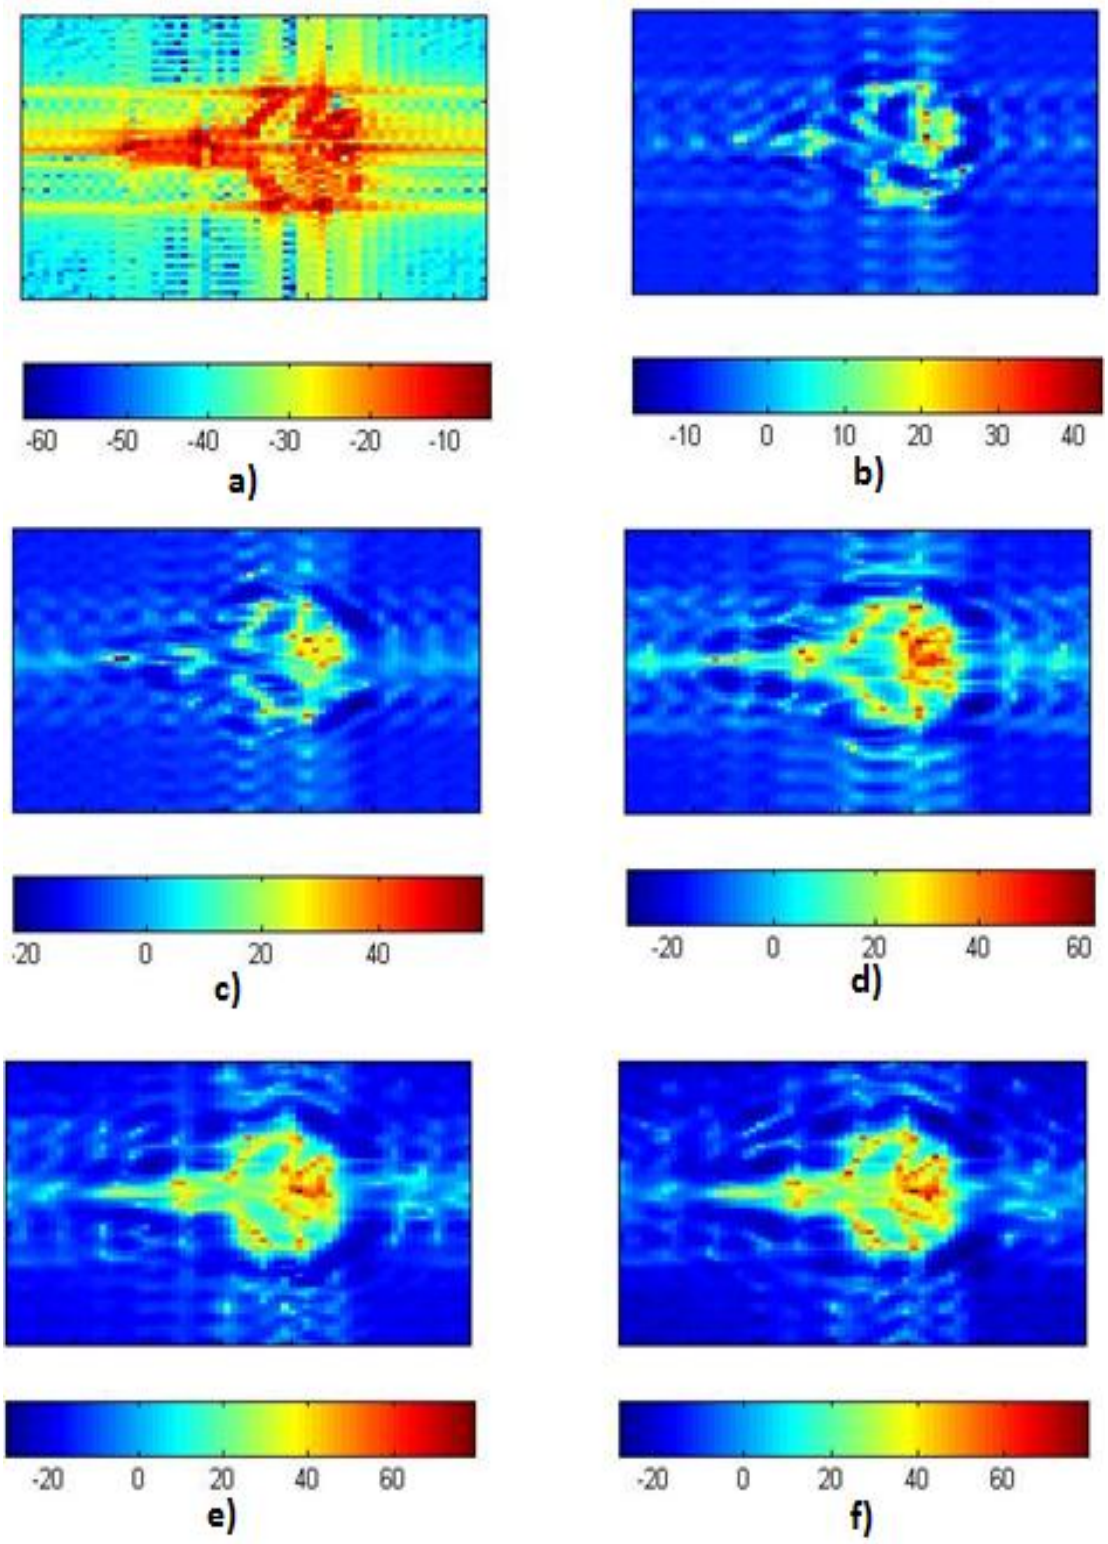
Aşağıda yer alan 6 şekilde kestirilen saçıcı sayısının tekil değer ayrışımı (SVD) çözümünde radar hedef görüntüsüne etkisi izlenebilir. Tahmin edilen saçıcı sayısı değiştikçe görüntülerde meydana gelen değişiklik görünmektedir. İlgili şekiller incelendiğinde tahmini saçıcı sayısının çok düşmesi hedef üzerindeki saçıcıları da görünmez kılmaktadır. Tahmini saçıcı sayısının yüksek seçilmesi ise sahte saçıcılar oluşturmaktadır. Diğer yandan tahmin edilen saçıcı sayısı arttıkça dinamik alan değerinin yükseldiği görülmektedir.



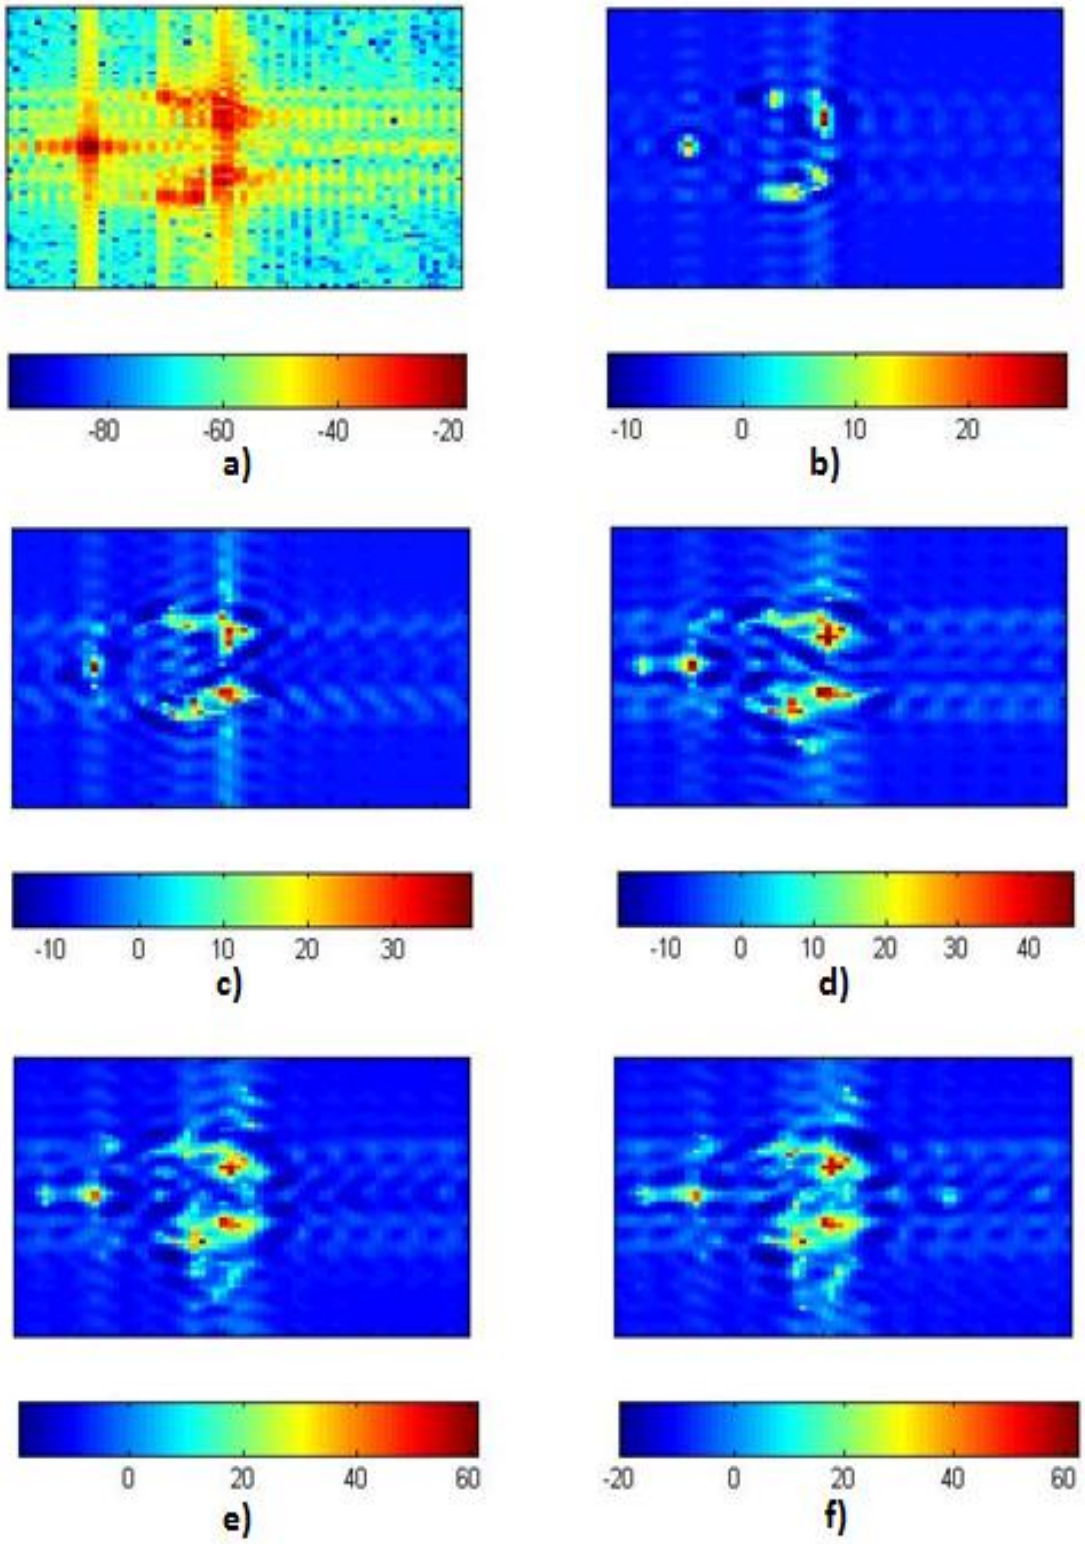
Şekil 2.30: 64 x 64 veri boyutundaki Mig 25 hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 24) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 20, c) 60, d) 100 (kestirilen saçıcı sayısı değeri), e) 140, f) 180



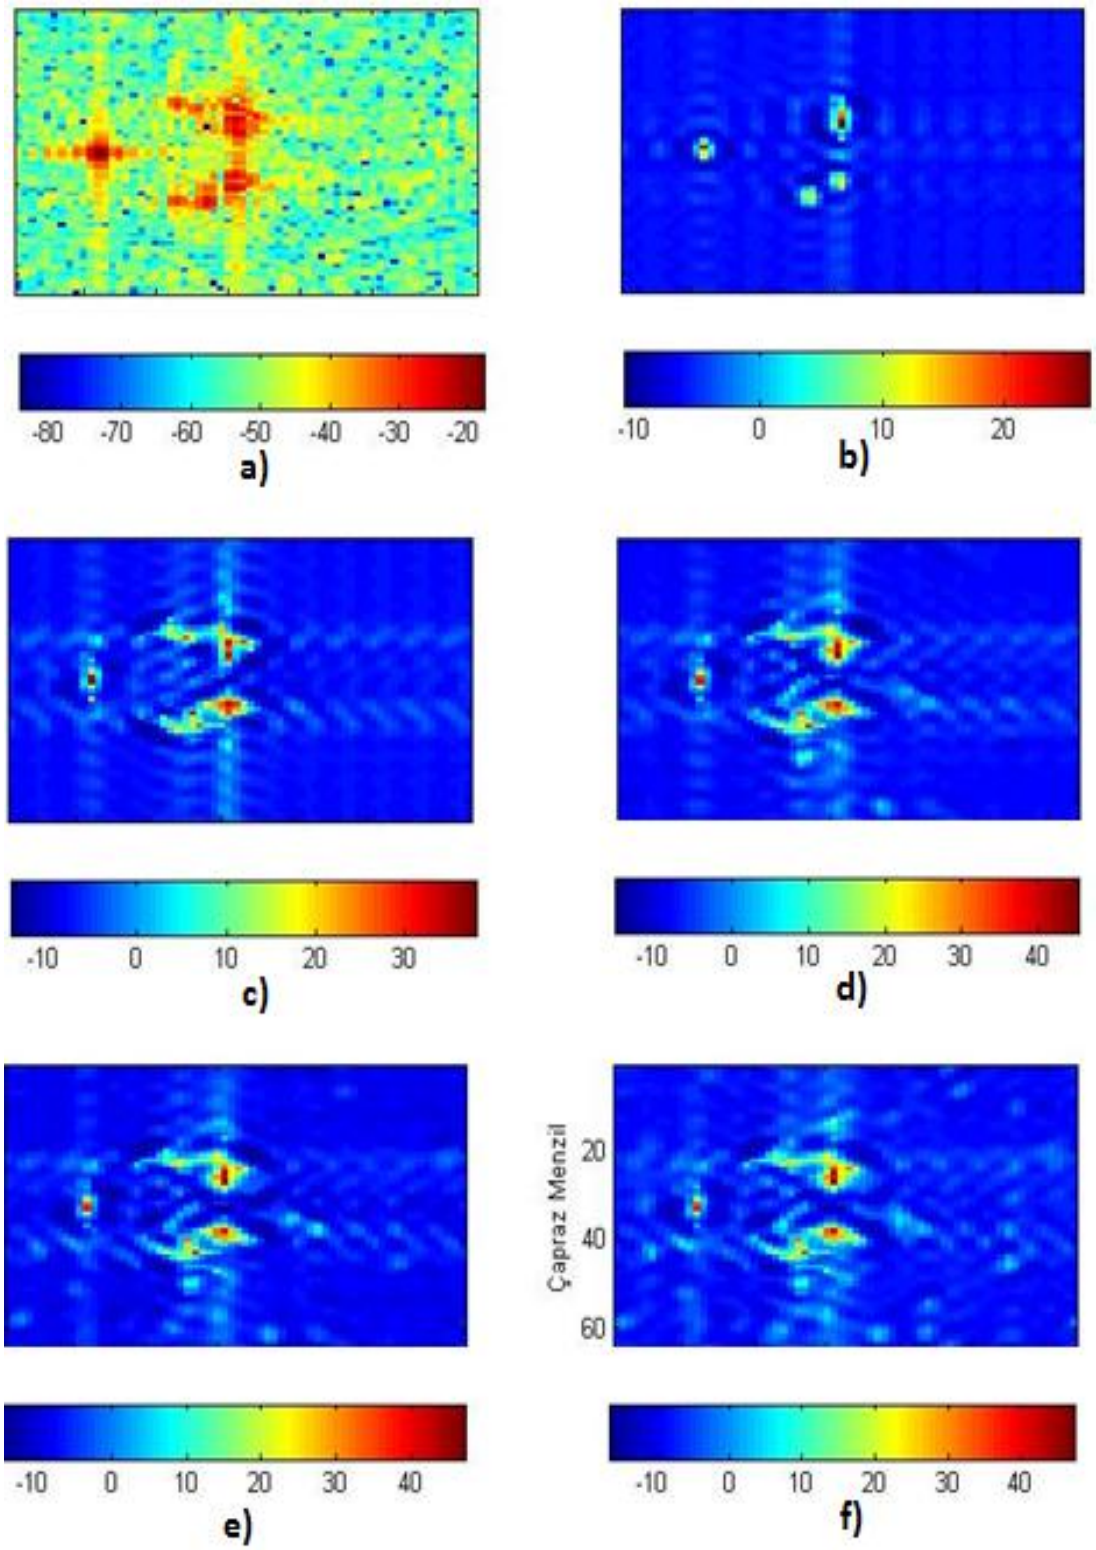
Şekil 2.31: 64 x 64 veri boyutundaki Mig 25 hedefinin (SNR=10 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 20) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 16, c) 46, d) 76 (kestirilen saçıcı sayısı değeri), e) 106, f) 136



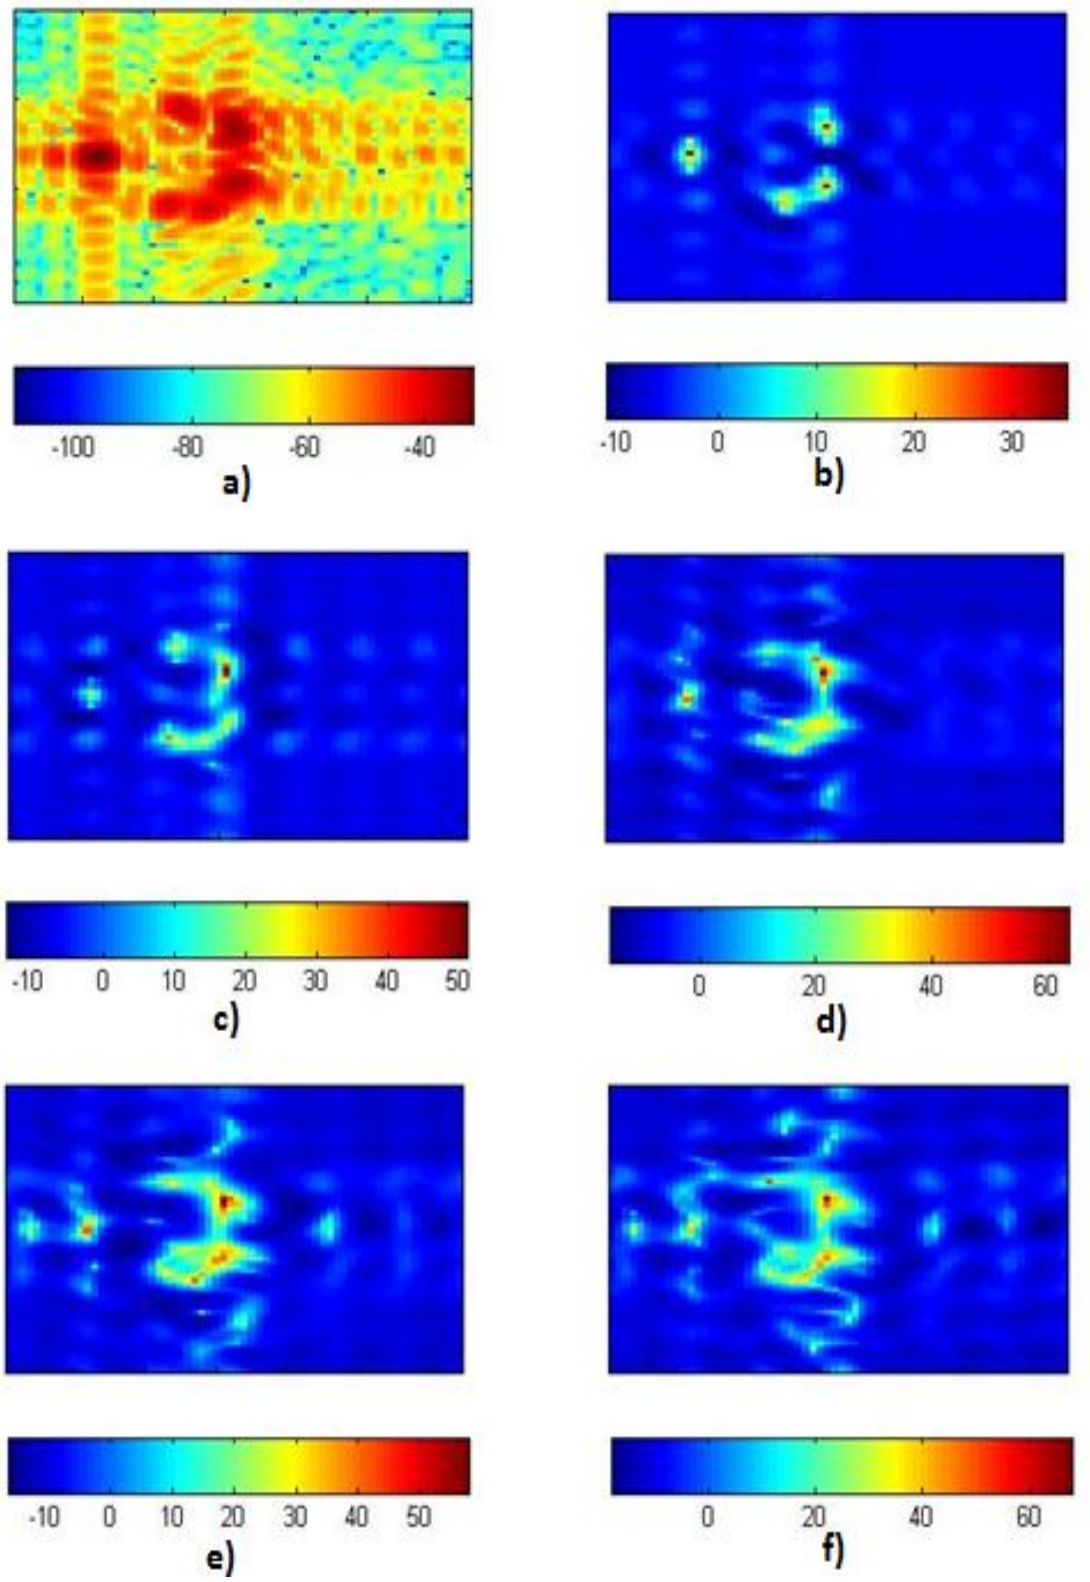
Şekil 2.32: Mig 25 hedefinin (SNR=30 dB, 32x32'lik veri) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 22, c) 32, d) 42 (kestirilen saçıcı sayısı değeri), e) 52, f) 62



Şekil 2.33: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 7, c) 14, d) 21 (kestirilen saçıcı sayısı değeri), e) 28, f) 35



Şekil 2.34: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 5, c) 14, d) 23 (kestirilen saçıcı sayısı değeri), e) 32, f) 41



Şekil 2.35: Airbus hedefinin (SNR=30 dB, 16x16'lik veri) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının SVD yöntemi ile elde edildiği durumda, kullanılan farklı saçıcı sayısı değerleri için (modelleme seviyesi: 7) elde edilen görüntüleri a) Fourier dönüşümü yöntemi; SVD için saçıcı sayıları: b) 4, c) 8, d) 13 (kestirilen saçıcı sayısı değeri), e): 17, f) 21

Seyrek özbağlanımlı (AR) modelleme ile radar görüntüleme

Regülarizasyon yöntemleri kötü koşullanmış (ill-posed) problemlerde ek olarak yumuşatma ve seyreklik (sparsity) bilgilerini probleme katarak alternatif çözümler sağlamaktadır. En eski yöntemlerden biri olan Tickhonov regülarizasyonunda ceza terimi olarak bilinmeyen vektörünün 2-normu kullanılmaktadır. 2-norm ceza terimi dahil edilmesi ile geniş değerli bileşenleri kısıtlamakta ve daha yumuşak geçişler sunan çözümler elde edilmektedir. Sonuç direkt (kapalı form) veya konjuge gradyan gibi iteratif yöntemlerle elde edilebilir. Son zamanlarda 0-norm ceza fonksiyonu (penalty function) kullanan seyreklik önceliği (sparsity prior) regülarizayon yöntemleri bir çok uygulamada kullanılmaktadır. 0-norm minimizasyonu NP zor problem (NP hard problem) olduğundan cezalandırma fonksiyonu olarak 1-norm kullanılır ve bu yöntemle 0-normunun çözümüne yaklaşılır. Ceza terimi olarak kullanılan 1-norm ile az sayıda sıfırdan farklı katsayı içeren sonuçlar üretilmektedir. 1-norm ceza terimi içeren regülarizasyon problemleri türevlenebilir (differentiable) değildir ve 2-norm durumundan farklı olarak bir kapalı form çözümüne sahip değildir. Diğer yandan bu problemler konveks kuadratik problemlere dönüştürülebilir ve konveks optimizasyon yöntemleriyle çözülebilirler. [1]'de konuşma işaretlerinin lineer kestirimi için regularizasyon tabanlı özbağlanımlı (AR) modelleme kullanılmıştır. [1]'de yazarlar 1-norm ceza terimi içeren özbağlanımlı (AR) model katsayıları ya da kalıntı teriminin (residual) 1-norm minimizasyonunu içeren seyrek kalıntı terimi tanımlamışlardır. Bu çalışmada yazarların sonuçları 2-B özbağlanımlı modellemeye uyarlanmış ve ISAR görüntü iyileştirme problemine uygulanmıştır.

1-B özbağlanımlı (AR) modellemede yazarlar bir konuşma örneğini (sample) geçmiş örneklerin lineer kombinasyonu şeklinde tanımlamışlardır [1].

$$x(n) = \sum_{k=1}^{K} a_k \, x(n-k) + e(n) \qquad \textbf{(2.58)}$$

Burada $\{a_k\}$ kestirilen katsayılar, $e(n)$ ise uyarı sinyalidir (excitation). Farklı kestiriciler farklı uyarı sinyallerine ve farklı uygulamalara kullanılabilirler. Yazarlar yöntemlerinde problemi, gözlemlenen gerçek $x(n)$ örnekleri kümesinden, n=1, 2, …

N olacak şekilde, katsayı vektörlerini hatayı minimize edecek şekilde kestirebilecek bir optimizasyon problemi olarak ele almaktadırlar. $\hat{\boldsymbol{e}} = \boldsymbol{x} - \boldsymbol{X}\hat{\boldsymbol{a}}$ vektörü genel olarak $\boldsymbol{e}$'nin kestirimi olan kalıntıyı (residual) ifade eder. Bu kalıntı vektörü aşağıdaki minimizasyon probleminin sonucu olan $\hat{\boldsymbol{a}}$'nın kestiriminden elde edilir [1].

$$\min_{\boldsymbol{a}} \|\boldsymbol{x} - \boldsymbol{X}\boldsymbol{a}\|_p^p + \lambda \|\boldsymbol{a}\|_k^k \qquad \textbf{(2.59)}$$

Burada,

$$\boldsymbol{x} = \begin{bmatrix} x(N_1) \\ \vdots \\ x(N_2) \end{bmatrix}, \boldsymbol{X} = \begin{bmatrix} x(N_1 - 1) & \cdots & x(N_1 - K) \\ \vdots & & \vdots \\ x(N_2 - 1) & \cdots & x(N_2 - K) \end{bmatrix}$$

ve $\|.\|_p$ p-normu ifade etmektedir. p-normu $\|\boldsymbol{x}\|_p$=$(\sum_{n=1}^{N} |x(n)|^p)^{1/p}$, $p \geq 1$ için, şeklinde ifade edilmektedir. N_1 ve N_2 başlangıç ve bitiş değerleri, $n < 1$ ve $n > N$ için $x(n) = 0$ varsayılacak şekilde, birçok şekilde seçilebilir. Örneğin, $p = 2$ ve $\lambda = 0$, $N_1 = 1$ ve $N_2 = N + K$ olacak şekilde seçilirse bu durum bizi Yule-Walker denklemlerinin çözümüne denk olan özilişki yöntemine (auto-correlation method) götürecektir; $N_1 = K + 1$ ve $N_2 = N$ seçimi ise kovaryans metoduna götürmektedir.

Bu çalışmada yazarların sonuçları 2-B özbağlanımlı (AR) modellemeye uyarlanmış ve ISAR görüntü iyileştirme problemine uygulanmıştır.

(2.36) ve (2.40) denklemleri kullanılarak iki kestirim hatası şu şekilde tanımlanabilir.

$$\boldsymbol{e_{1-3}} = \boldsymbol{E}\boldsymbol{a} + \boldsymbol{e} \qquad \textbf{(2.60)}$$

$$\boldsymbol{e_{2-4}} = \tilde{\boldsymbol{E}}\boldsymbol{b} + \tilde{\boldsymbol{e}} \qquad \textbf{(2.61)}$$

Kestirim katsayılarının hesabı bir optimizasyon problemi olarak düşünülebilir. Bu optimizasyon problemi bir grup gözlemlenen kompleks işaretleri kullanarak katsayı

kestirimi yapılmasını sağlar ve böylece kestirim hatasını minimuma indirir. Minimizasyon probleminin sonucu şu şekilde belirtilebilir,

$$\boldsymbol{a} = \min_{\boldsymbol{a}} \|\boldsymbol{e_{1-3}}\|_2^2 + \lambda \|\boldsymbol{a}\|_k^k = \min_{a} \|\boldsymbol{E a} + \boldsymbol{e}\|_2^2 + \lambda \|\boldsymbol{a}\|_k^k \tag{2.62}$$

ve

$$\boldsymbol{b} = \min_{\boldsymbol{b}} \|\boldsymbol{e_{2-4}}\|_2^2 + \lambda \|\boldsymbol{b}\|_k^k = \min_{\boldsymbol{b}} \left\|\tilde{\boldsymbol{E}}\boldsymbol{b} + \tilde{\boldsymbol{e}}\right\|_2^2 + \lambda \|\boldsymbol{b}\|_k^k \tag{2.63}$$

Burada $\| \ \|_p$, p-norm, şu şekilde ifade edilebilir,

$$\|\boldsymbol{x}\|_p = \left(\sum_{n=1}^{N} |x(n)|^p\right)^{1/p}, \ p > 1 \tag{2.64}$$

λ , regülarizasyon parametresidir. $p = 2$ ve $\lambda = 0$ olarak seçildiğinde sonuç klasik en küçük kareler çözümü olmaktadır [1]. l_2 minimizasyon yaklaşımının bazı sıkıntıları vardır, özellikle yüksek mertebelerde SVD kullanımını gerektiren bir çok istenmeyen tepe noktalarının görünmesine sebep olur. Farklı bir çözüm olarak, $p = 2$ ve $k = 2$ seçilerek Tykhonov tipi regülarizasyon çözümü kullanılabilir,

$$\boldsymbol{a} = \min_{\boldsymbol{a}} \|\boldsymbol{E a} + \boldsymbol{e}\|_2^2 + \lambda \|\boldsymbol{a}\|_2^2 \tag{2.65}$$

ve

$$\boldsymbol{b} = \min_{\boldsymbol{b}} \left\|\tilde{\boldsymbol{E}}\boldsymbol{b} + \tilde{\boldsymbol{e}}\right\|_2^2 + \lambda \|\boldsymbol{b}\|_2^2 \tag{2.66}$$

Bu ifadeler kapalı formda şu şekilde ifade edilebilir,

$$\boldsymbol{a} = -(\boldsymbol{E}^H \boldsymbol{E} + \lambda I)^{-1} \boldsymbol{E}^H \boldsymbol{e} \tag{2.67}$$

Farklı bir çözüm olarak 1-norm içeren ceza terimi kullanılarak aşağıda verilen ve katsayıların seyrek olarak elde edildiği bir çözüm bulunabilir,

$$\boldsymbol{a} = \min_{\boldsymbol{a}} \|\boldsymbol{E}\boldsymbol{a} + \boldsymbol{e}\|_2^2 + \lambda\|\boldsymbol{a}\|_1^1 \quad \textbf{(2.68)}$$

ve

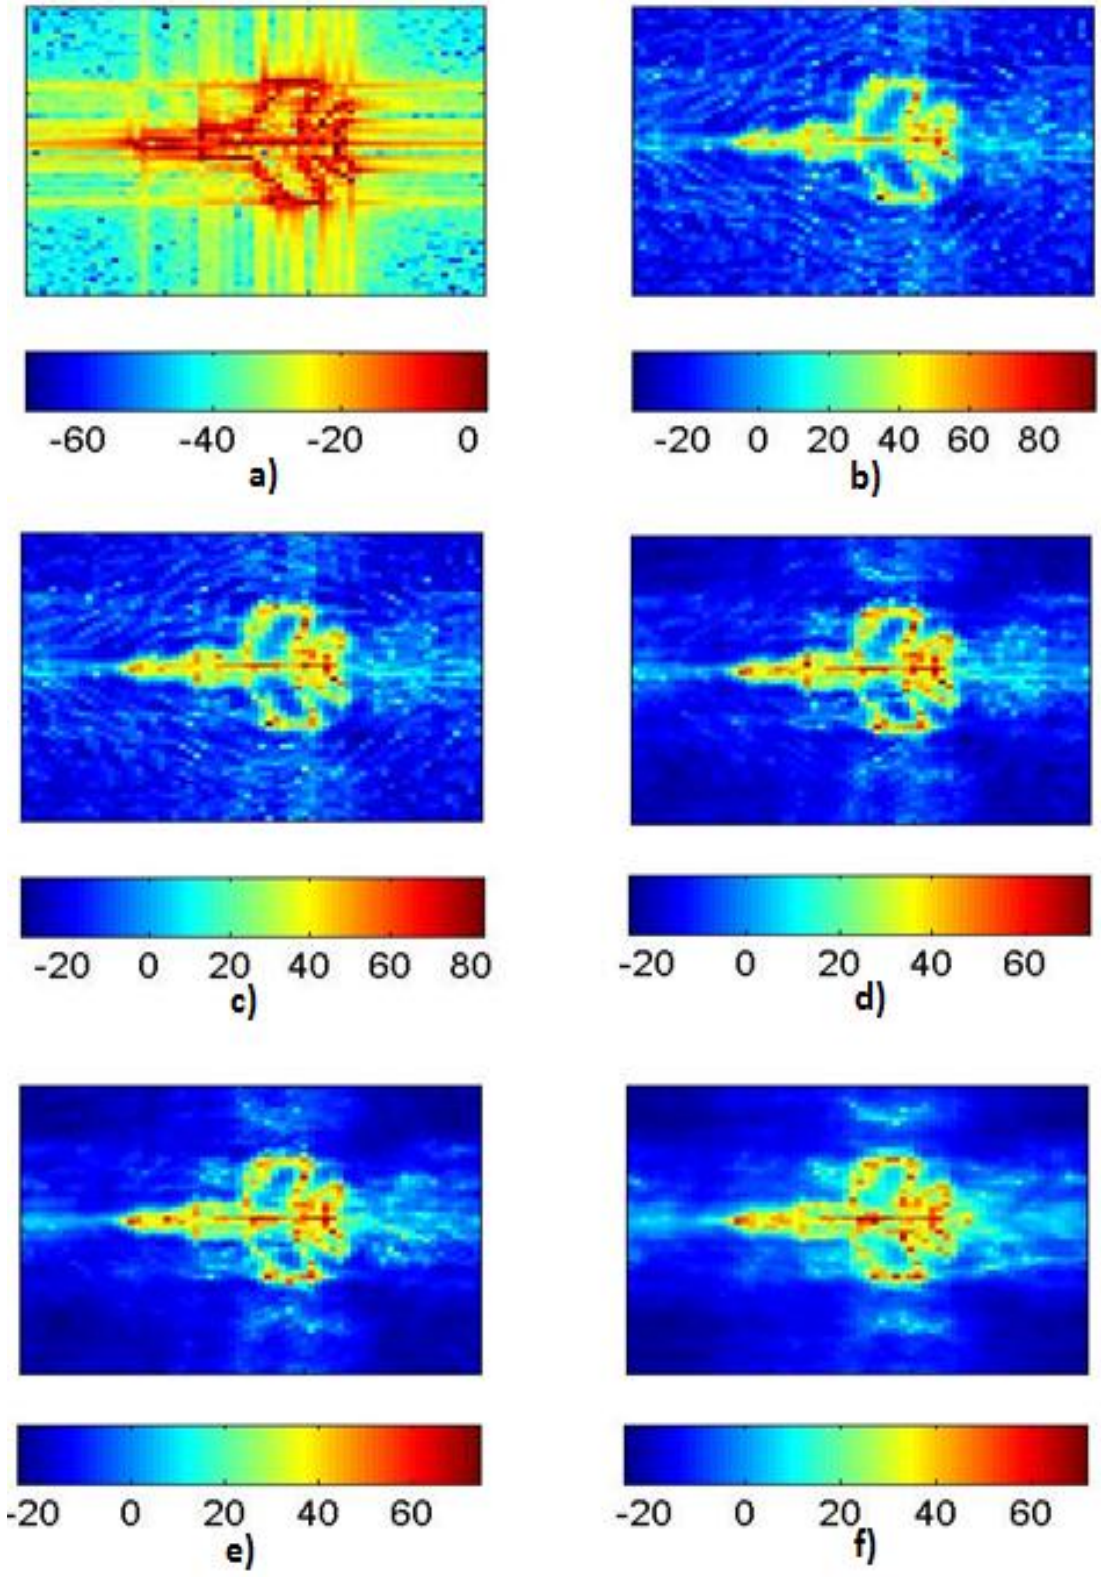
$$\boldsymbol{b} = \min_{\boldsymbol{b}} \left\|\tilde{\boldsymbol{E}}\boldsymbol{b} + \tilde{\boldsymbol{e}}\right\|_2^2 + \lambda\|\boldsymbol{b}\|_1^1 \quad \textbf{(2.69)}$$

Cvx optimizasyon paketi kullanılarak denklem (2.65), (2.66), (2.68) ve (2.69)'da tanımlanan minimizasyon problemleri efektif bir şekilde çözülebilir.

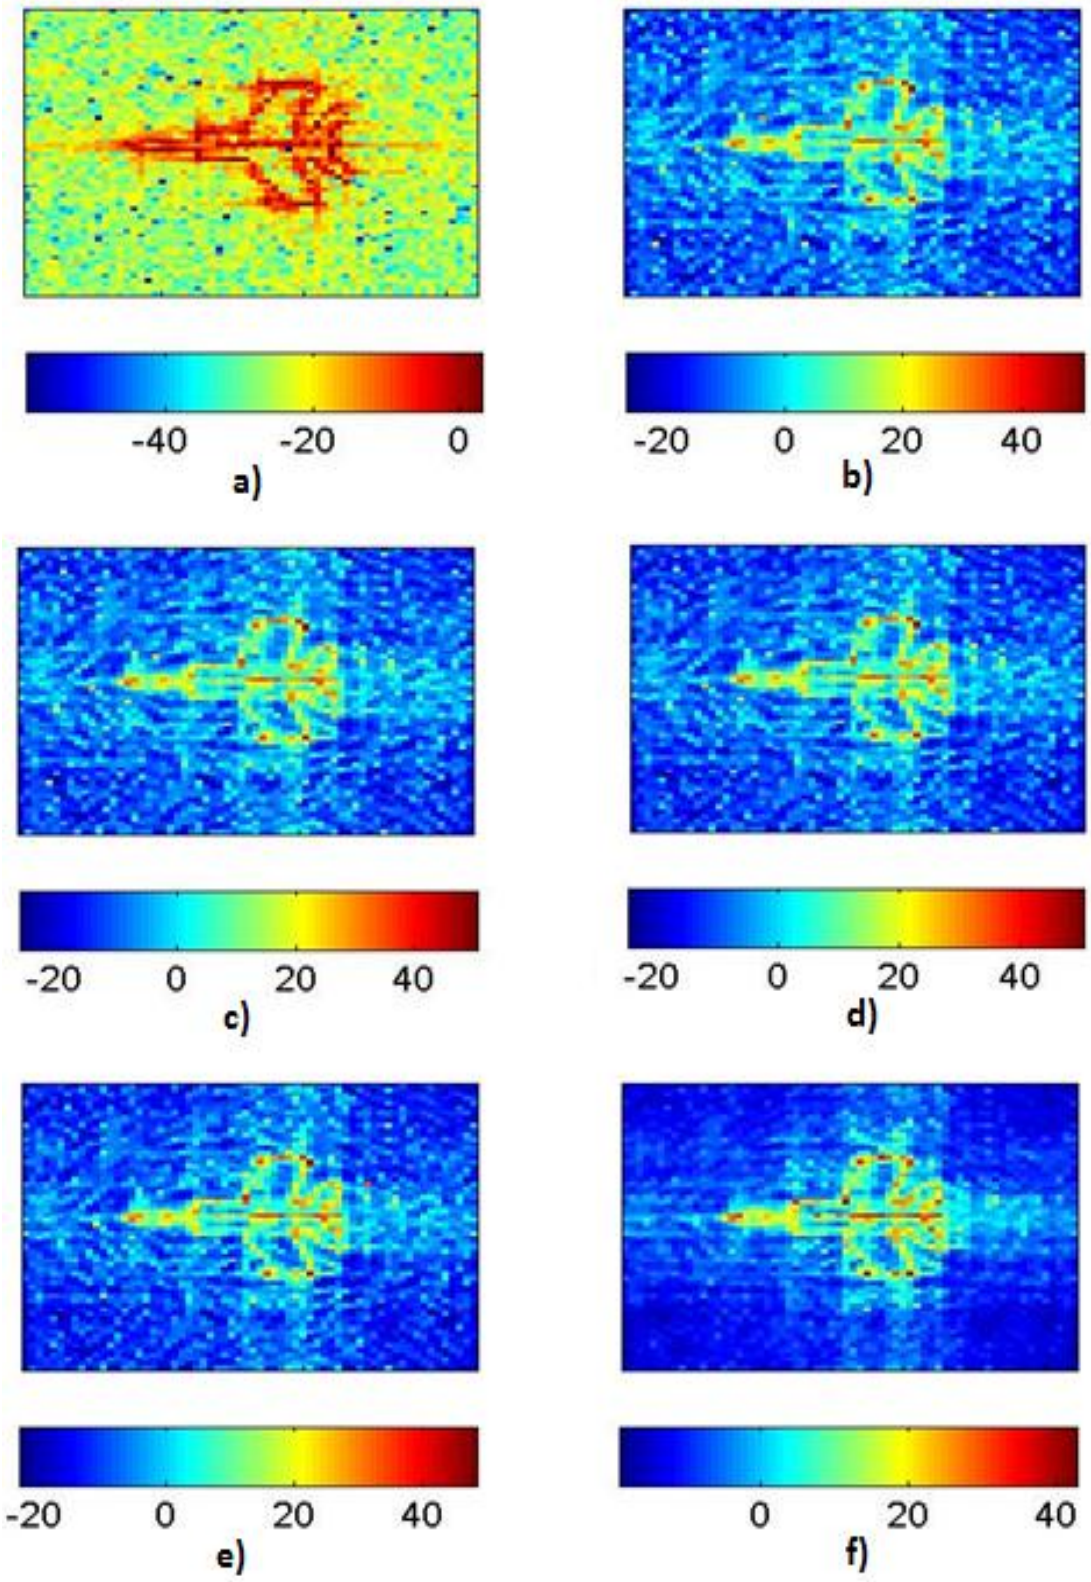
Regülarizasyon parametresi olan λ, kestirimcinin (AR katsayı vektörü) seyrekliği ile kalıntı teriminin 2-normunun minimizasyonunun arasındaki ödünleşimi (trade-off) kontrol etmektedir. λ ceza terimi parametresinin sonuçlar üzerine etkisi önemli boyuttadır. Parametrenin düşük seçilmesi durumunda sonuç 2-norma yakınsamakta, geri plandaki bozucu etkiler yeterince temizlenememektedir. Büyük değerlerin seçilmesi durumunda ise çözünürlük kötüleşmektedir. Literatürde λ parametresinin çözümü için L-curve yöntemi kullanılmaktadır [20]. L-curve yönteminde farklı λ parametreleri için elde edilen çözümlerin normlarının, $\|\boldsymbol{a}\|_k^k$, logaritmaları kalıntı işaretinin normunun, $\|\boldsymbol{E}\boldsymbol{a} + \boldsymbol{e}\|_p^p$, logaritmasına bağlı olarak çizilir. Elde edilen eğri L harfine benzediği için bu yönteme L-curve yöntemi denmektedir. Optimum λ parametresi L'nin dirseğinde yer alan noktadaki değer olarak tespit edilir [20].

Bu çalışmada en iyi λ parametresi, sınıflandırmada L-curve yöntemi kullanımı işlem yükü fazlalığı nedeniyle uygun olmadığından, deneysel olarak belirlenmiştir. Diğer yandan SVD yönteminden farklı olarak seyrek özbağlanımlı (AR) modelleme yönteminde saçıcı sayısı kestirimi gereği bulunmamaktadır.

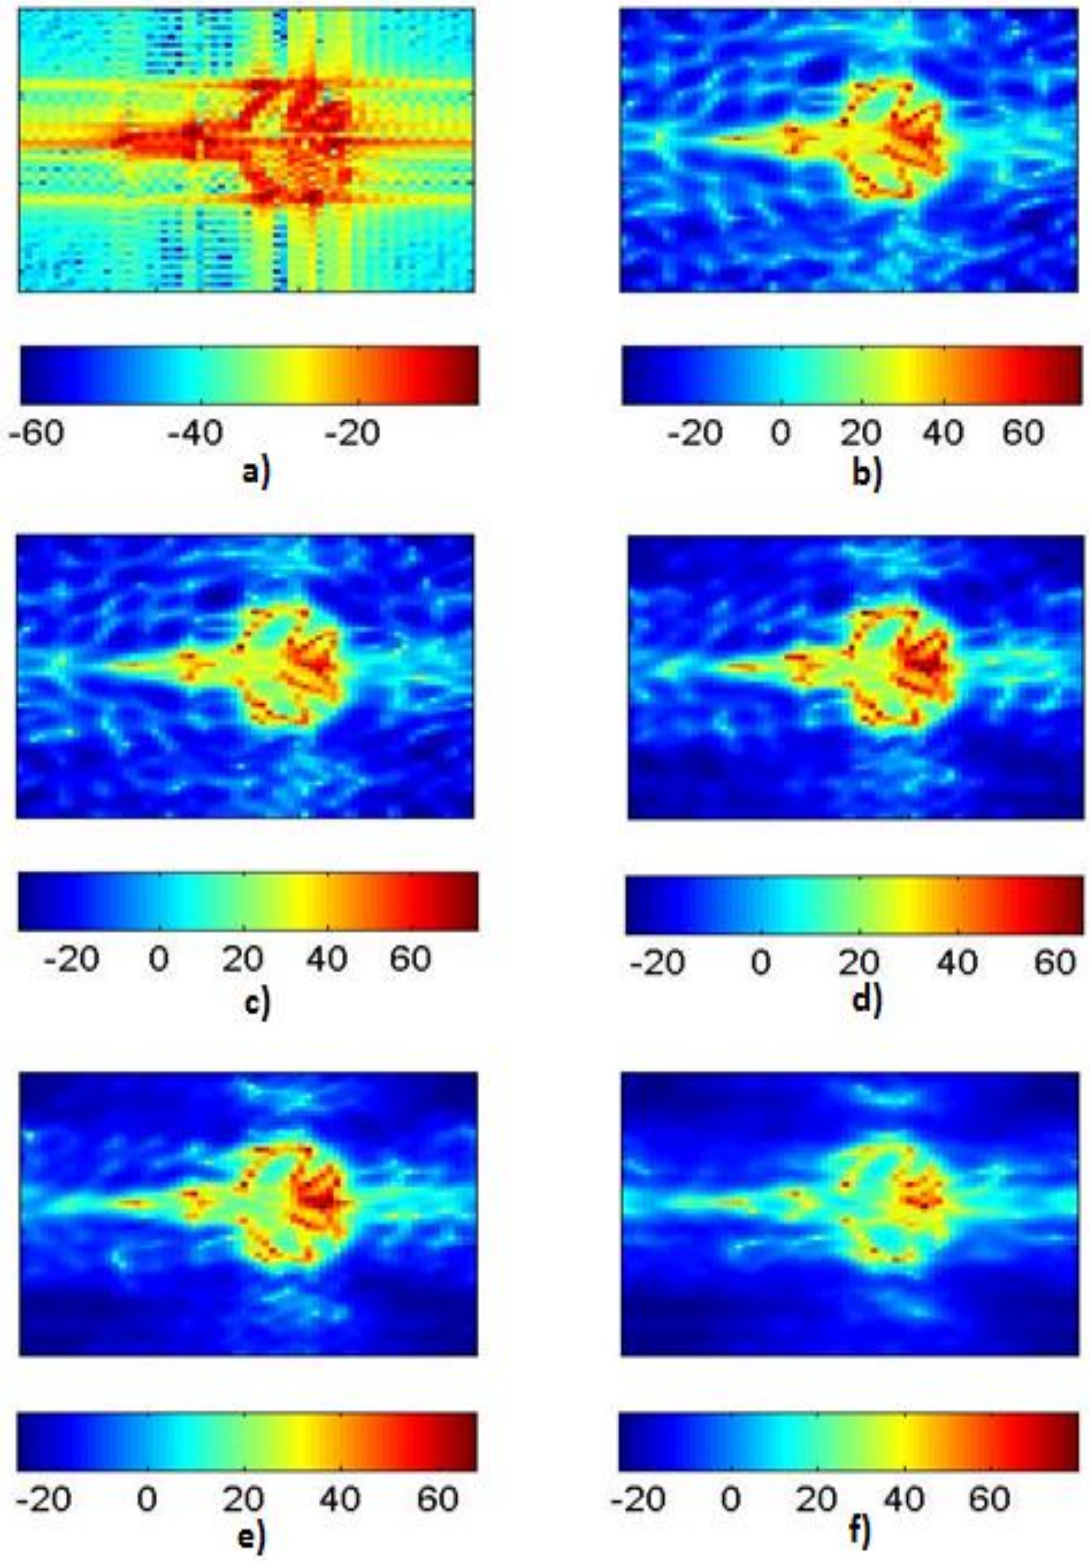
Aşağıda yer alan altı şekil incelendiğinde artan λ değerleri ile birlikte seyrek özbağlanımlı modelleme yönteminin radar hedef görüntüleme üzerindeki etkisi görülmektedir. Şekillerden de açıkça görüleceği üzere λ arttıkça hedef dışındaki saçıcılar (yan loblar) bastırılmakta, fakat diğer yandan bu bastırılma işlemi ile birlikte radar hedef görüntüsünün kontrastında azalma görünmektedir. Bu durumun radar hedef sınıflandırmaya etkisi 3.7.2 *Dar bantlı veri için sınıflandırma sonuçları* başlığı altında ele alınmıştır.



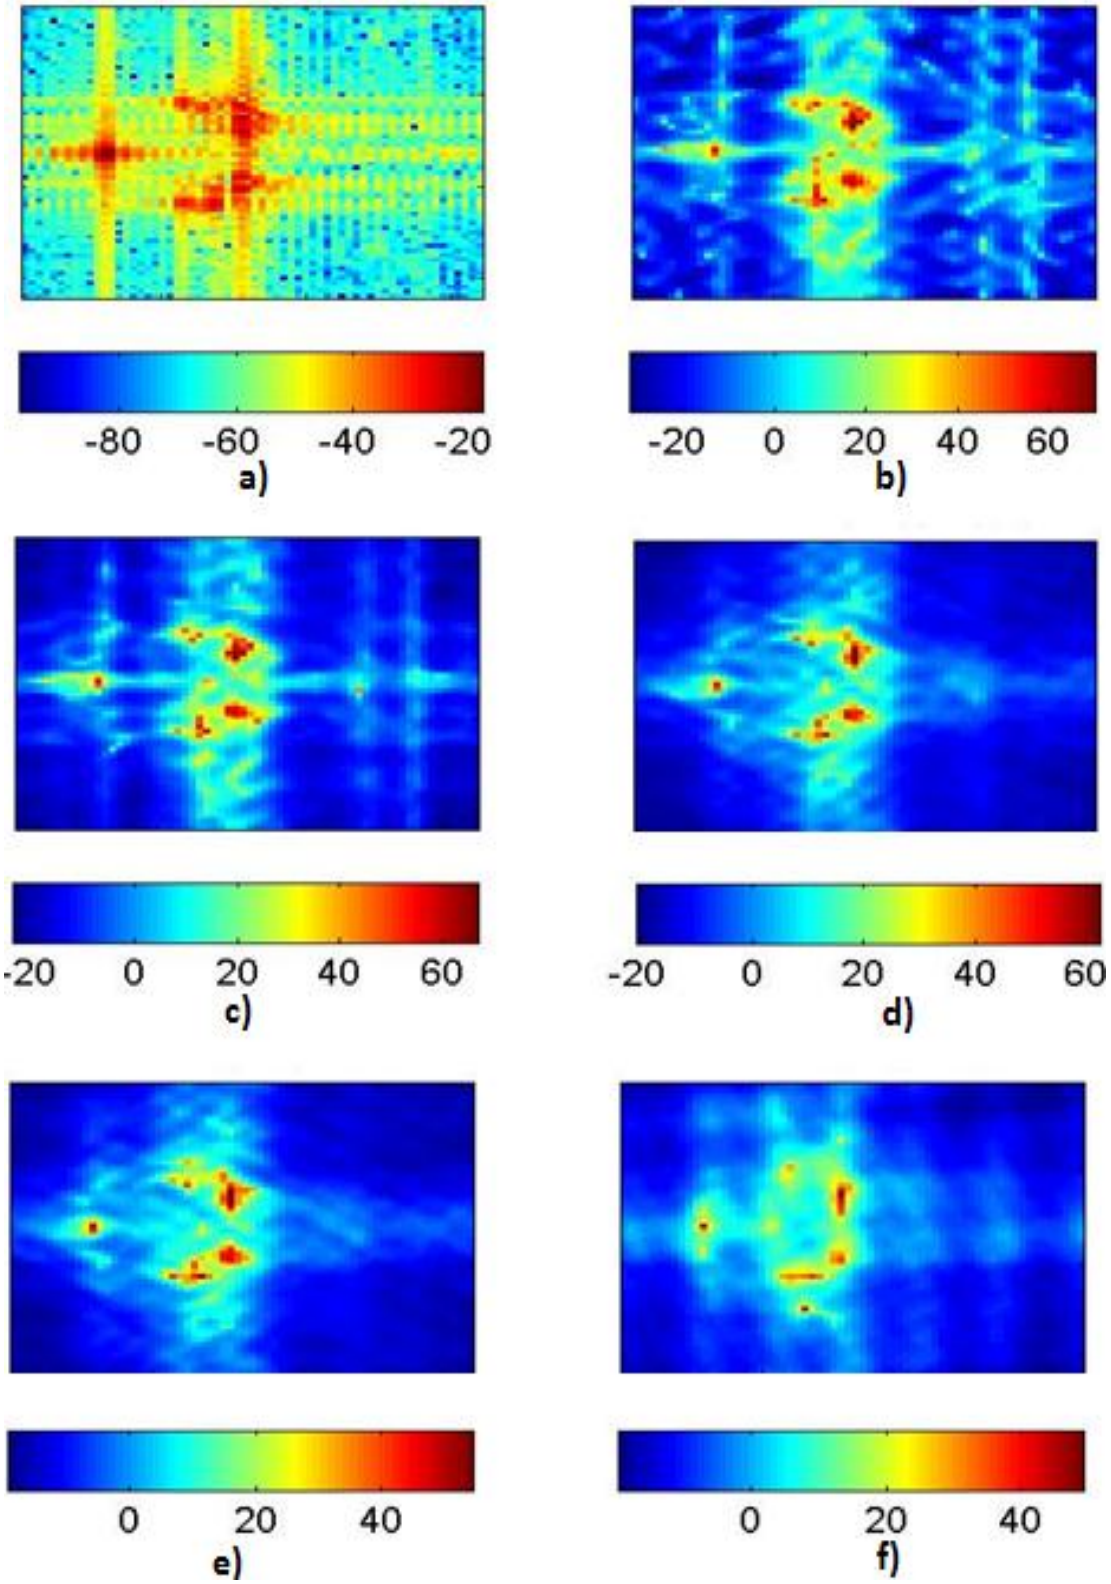
Şekil 2.36: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 24) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4



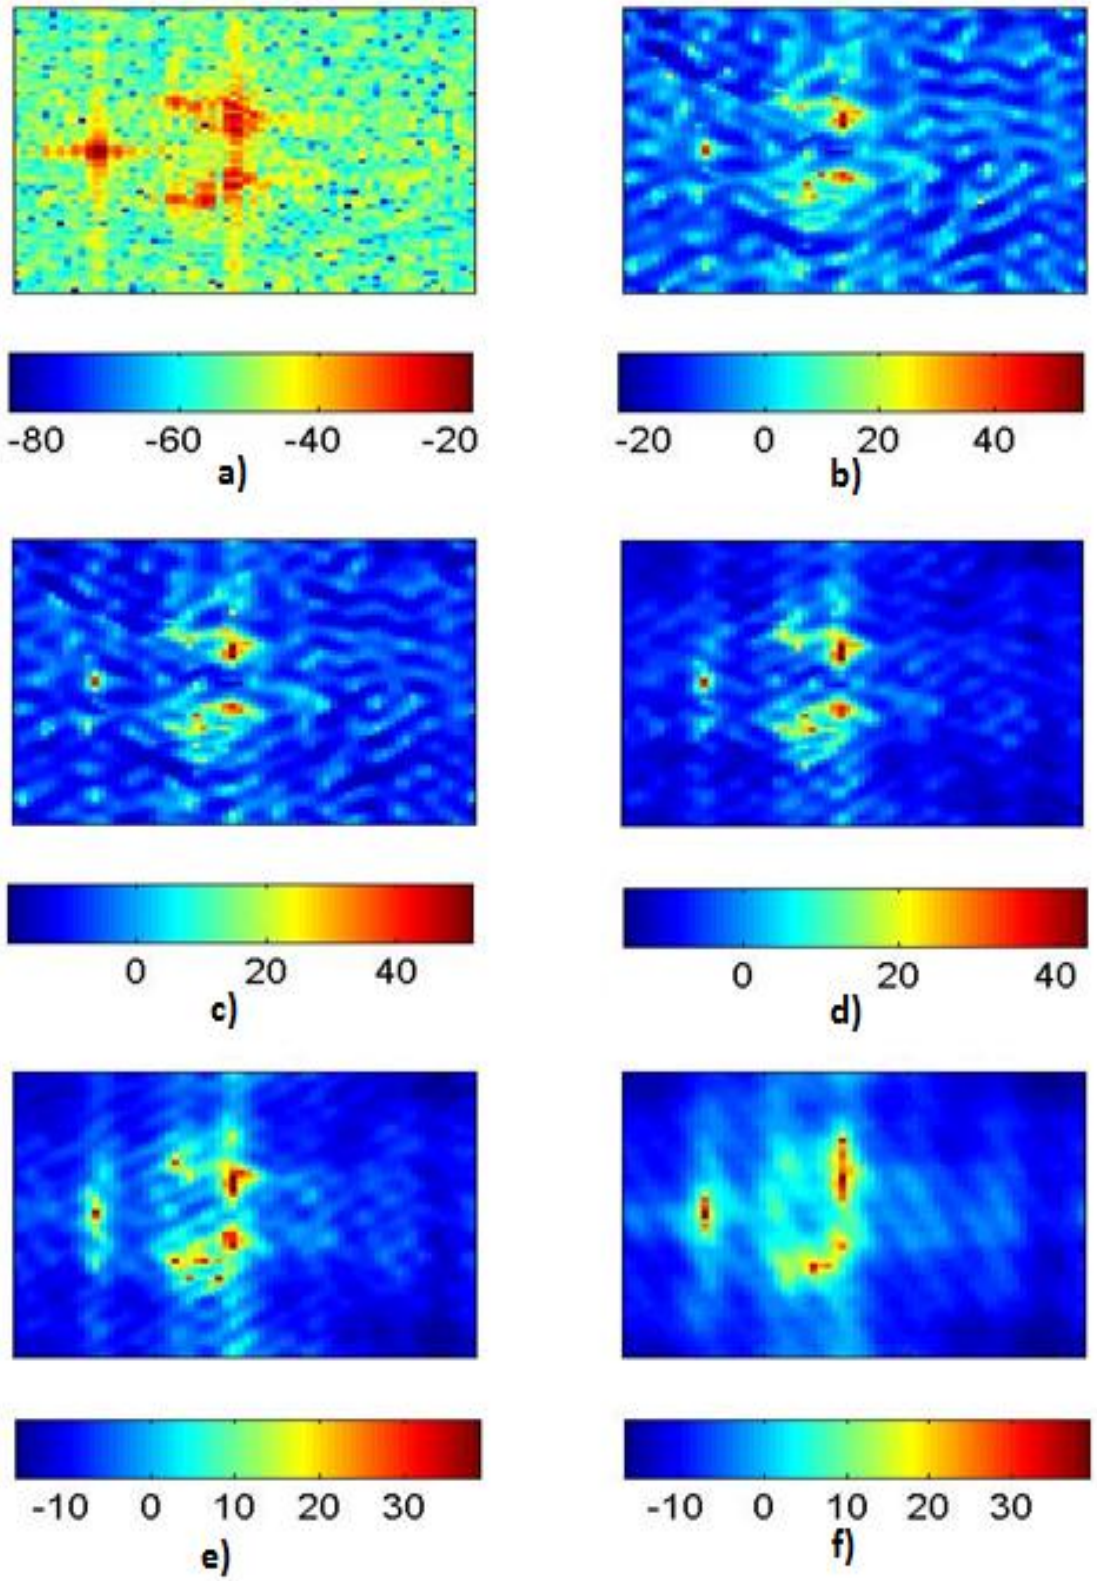
Şekil 2.37: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=10 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4



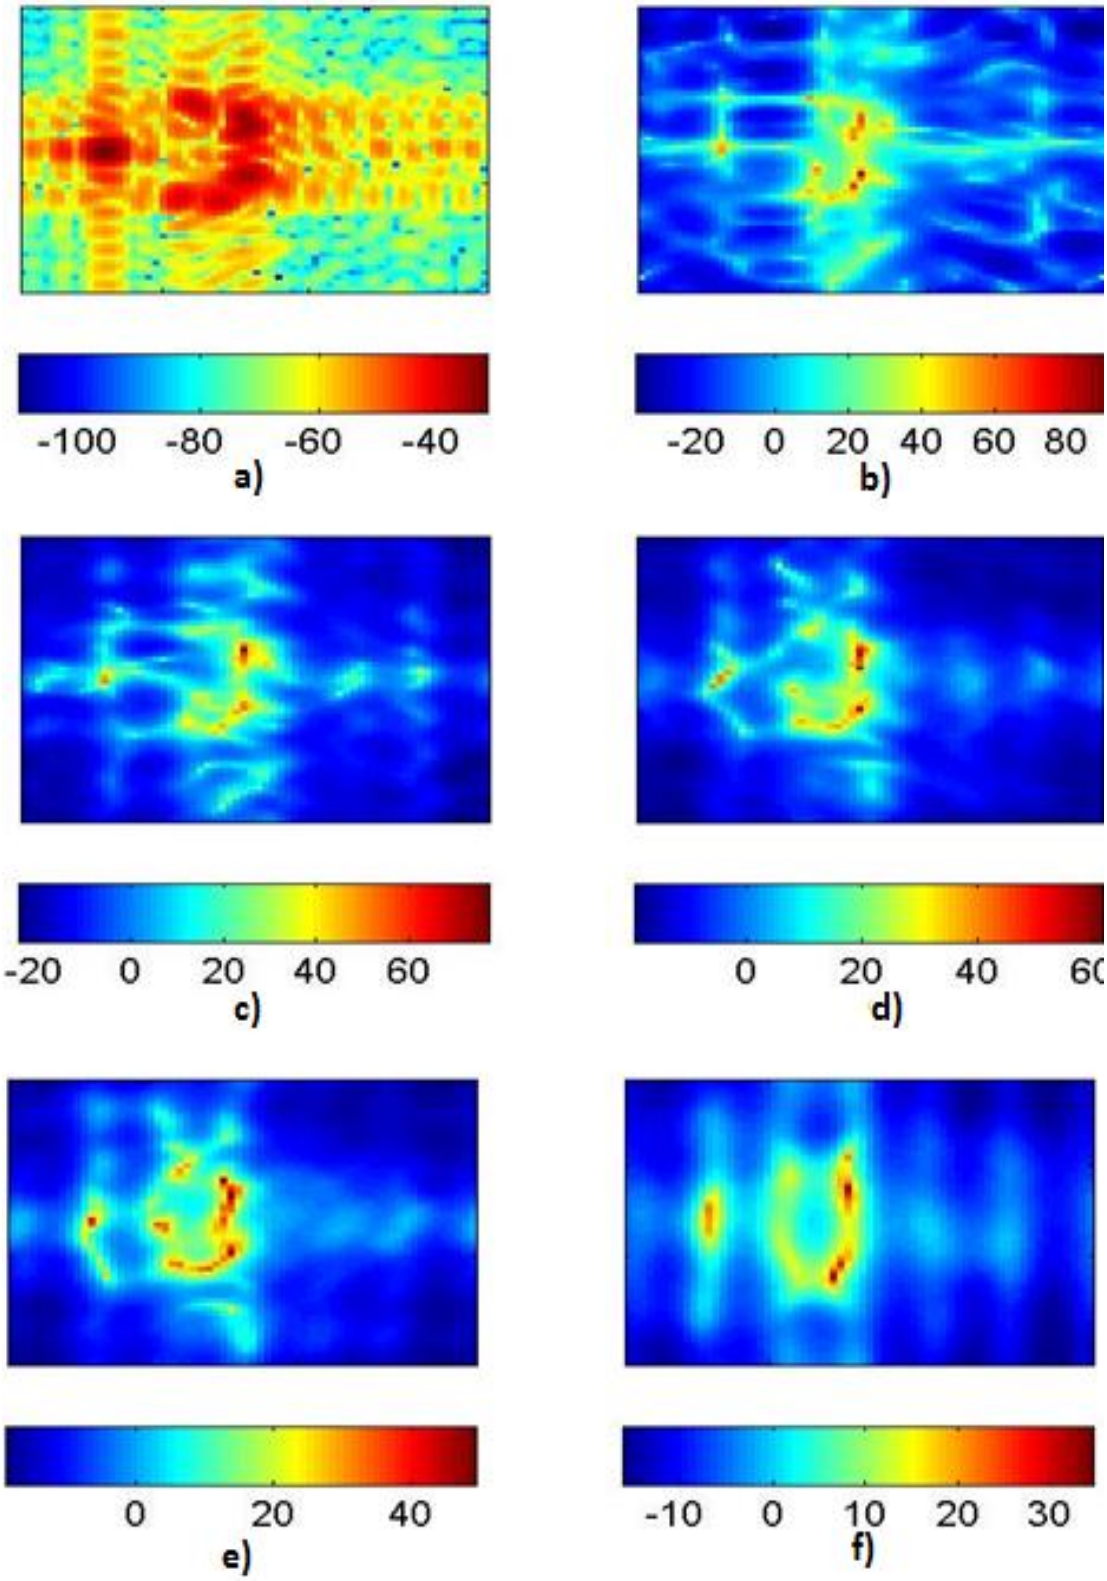
Şekil 2.38: Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının daraltılmış veriler (32 x 32) ile ve seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4



Şekil 2.39: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4



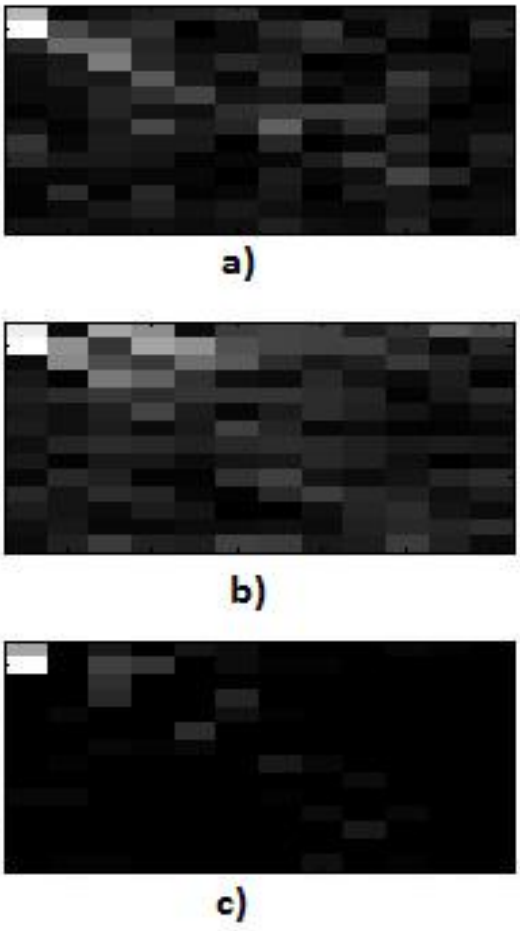
Şekil 2.40: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 12) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4



Şekil 2.41: Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün, özbağlanımlı (AR) katsayılarının daraltılmış veriler (16 x 16) ile ve seyrek (sparse) yöntemi ile elde edildiği durumda, kullanılan farklı λ değerleri için (modelleme seviyesi: 7) elde edilen görüntüleri a) Fourier dönüşümü yöntemi, b) λ:0.001, c) λ: 0.1, d) λ:0.5, e) λ: 1, f) λ: 4

Özbağlanımlı modelleme ile radar hedef görüntüleme işleminde özbağlanımlı (AR) katsayıları "en küçük kareler yöntemi", "tekil değer ayrışımı (SVD) ile birlikte en küçük kareler yöntemi" ve "seyrek (sparse) yöntemi" olmak üzere üç farklı şekilde kestirilmiştir. Seyrek özbağlanımlı (sparse AR) yöntemi ile kestirilen özbağlanımlı katsayıları seyreklik özelliği gösterir. Bu durum elde edilen görüntülerde yan lobların (gürültü seviyeleri) bastırılmasını ve hedefin daha belirgin bir şekilde görüntülenmesini sağlamaktadır.

Şekil 2.42'de özbağlanımlı (AR) katsayılarının gri skalada görüntüleri mevcuttur. Bu katsayıların çizimi için airbus verileri kullanılmıştır. Katsayılar hesaplanırken 32x32 boyutundaki veri için özbağlanımlı modelleme seviyesi 12, λ ise 0.5 alınmıştır. İlgili şekilden görüleceği üzere özbağlanımlı seyrek metodu ile kestirilen katsayıların seyreklik (sparse) özelliği, beklendiği üzere, diğer iki yönteme göre daha belirgindir.



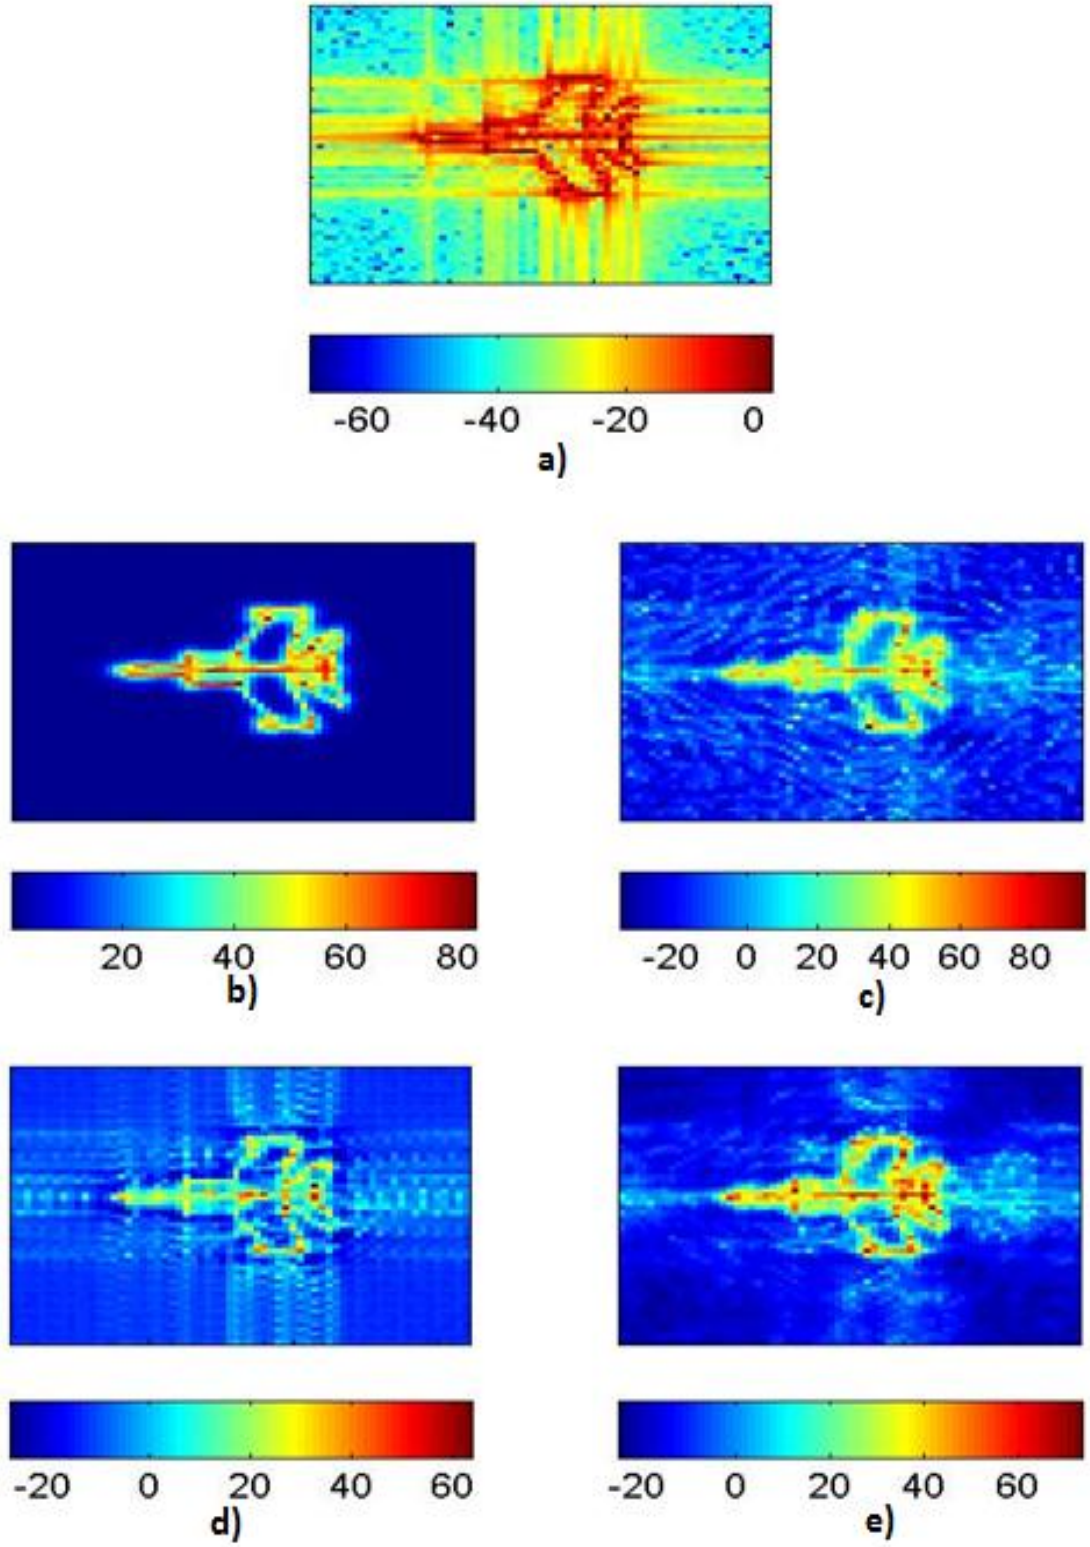
Şekil 2.42: Özbağlanımlı (AR) katsayıları a) En küçük kareler çözümü için, b) Tekil Değer Ayrışımı (SVD) çözümü için, c) Seyrek (sparse) çözümü için

Bu parametreler ile elde edilen airbus görüntüsü Şekil 2.46'da görünmektedir.

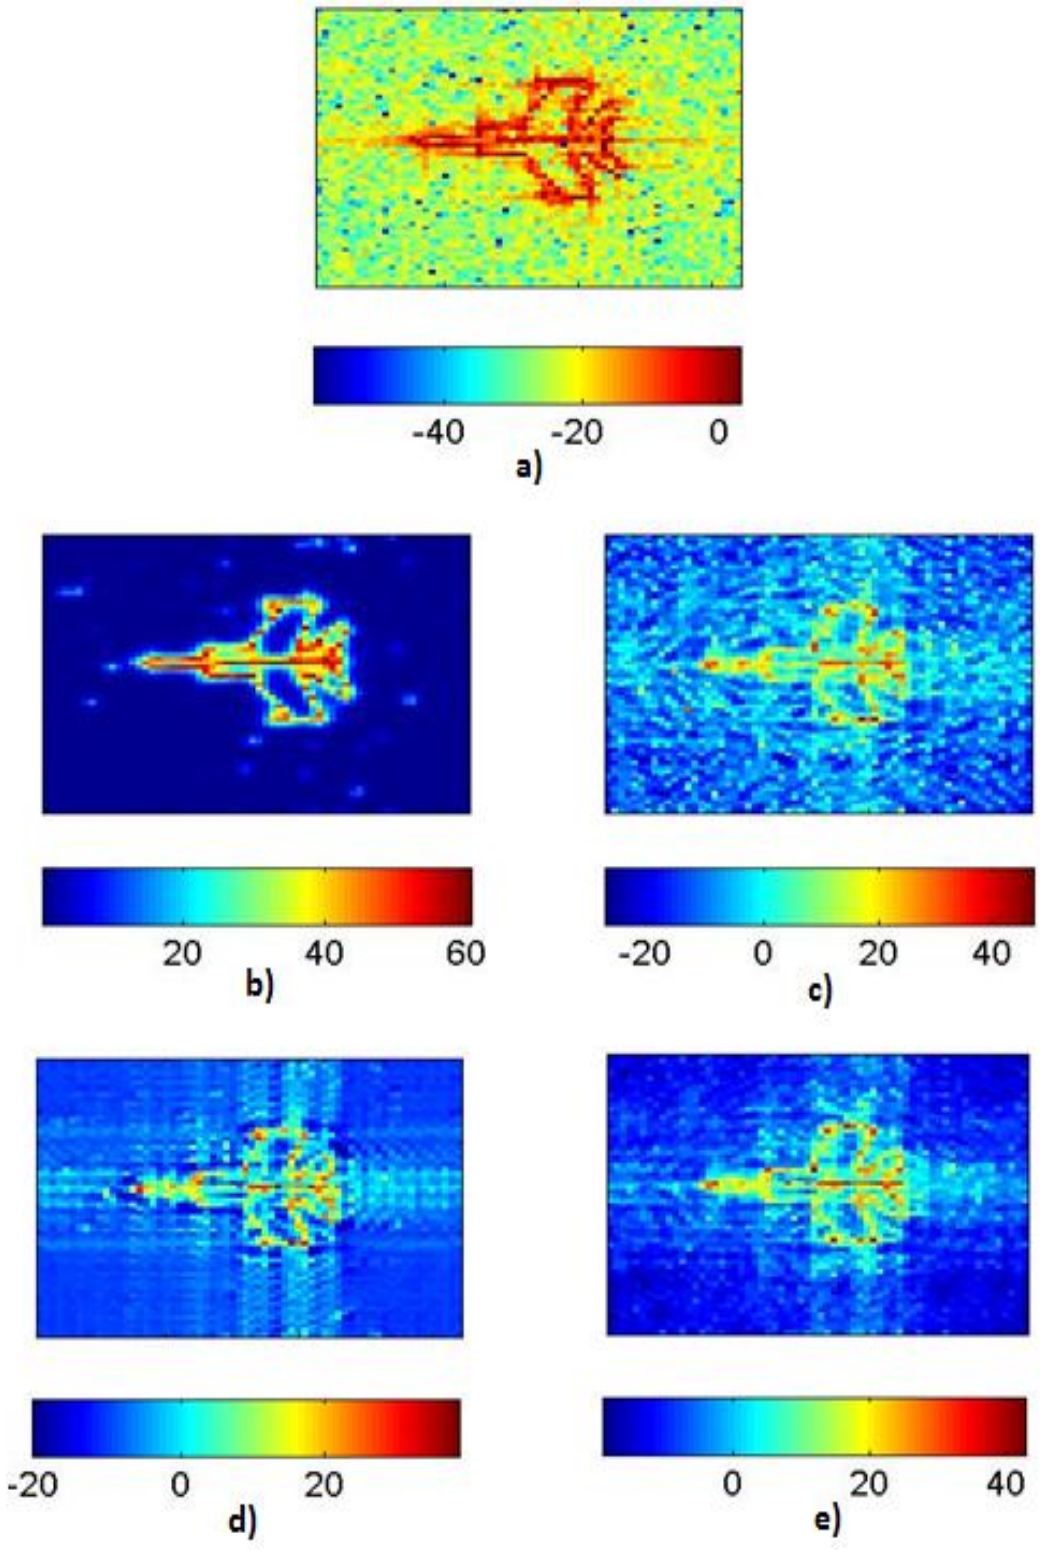
2.3.3. Farklı yöntemlerle bulunan görüntülerin karşılaştırılması

SAR görüntüleme teknikleri başlığı altında son olarak farklı yöntemler ile elde edilen radar hedef görüntülerin karşılaştırılmalı değerlendirilmesi yapılacaktır. Aşağıda yer alan altı şekilde farklı yöntemlere göre elde edilen radar hedef görüntülerinden örnekler sunulmaktadır. Örnekler incelendiğinde, geniş frekans-açı bandındaki veriler kullanıldığında en iyi radar hedef görüntüsünün MUSIC algoritması ile elde edildiği görülmektedir. Diğer yandan daha dar frekans-açı bandında veriler kullanıldığında MUSIC algoritması hedef dışındaki saçıcıları (gürültü) başarılı bir şekilde bastırabiliyor iken hedef görüntüsünde önemli bozulmalar meydana gelmektedir. Örneğin Şekil 2.9 incelendiğinde radar hedefinin kuyruk bilgisi başta olmak üzere önemli ayrıntılarının kaybolduğu görünmektedir. Seyrek özbağlanımlı (sparse AR) modellemede ise hedef dışındaki saçıcılar (gürültü) MUSIC algoritması kadar iyi bastırılamasa da hedef görüntüsünde ayrıntıların daha iyi korunduğu görülmektedir (bknz. Şekil 2.38) (karşılaştırmalı sonuç için bknz. **Şekil 2.45**). Bu durumun sınıflandırma başarısına etkisi 3.7.2 *Dar bantlı veri için sınıflandırma sonuçları* başlığında incelenmiştir.

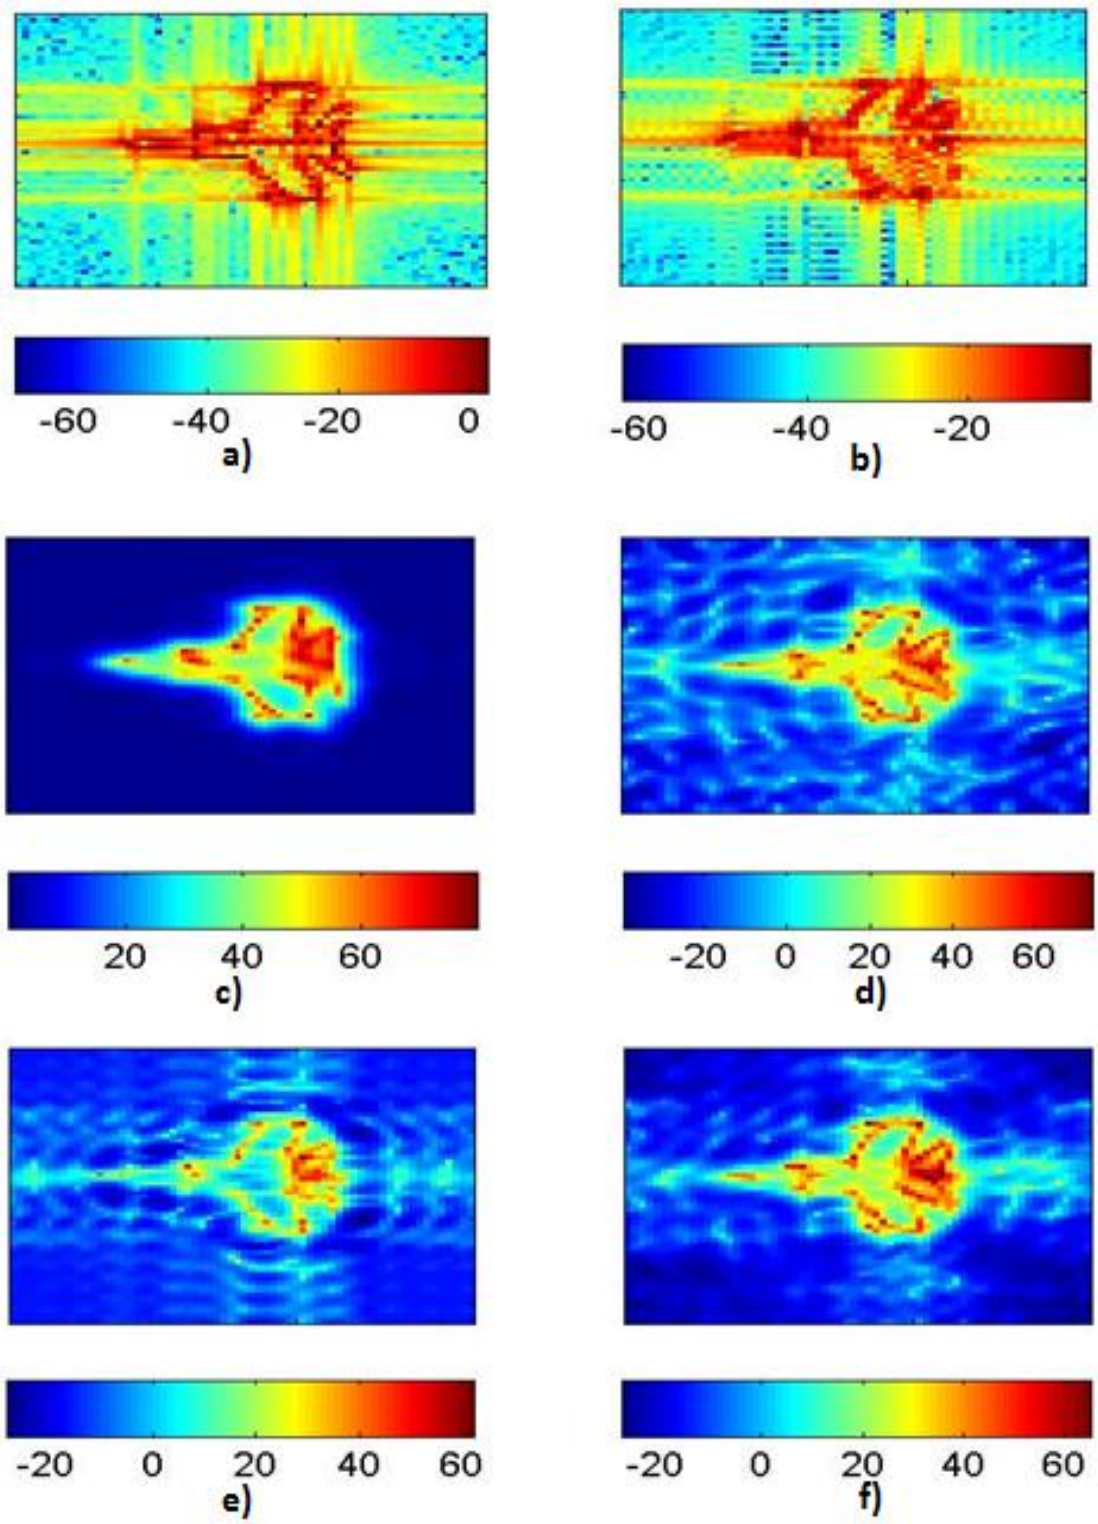
Aşağıda yer alan altı adet şekilde seyrek özbağlanımlı modellemenin diğer özbağlanımlı modelleme çözümlerine göre daha başarılı olduğu görülmektedir. Tekil değer ayrışımı çözümünde (AR-SVD) gürültü bastırılırken radar hedef görüntüsünde de ayrıntıların kaybedildiği görülebilmektedir. Seyrek özbağlanımlı yönteminin gürültüyü bastırırken radar hedef görüntüsündeki ayrıntıları kaybetmemesi görüntüleme ve sınıflandırma açısından avantaj sağlamaktadır.



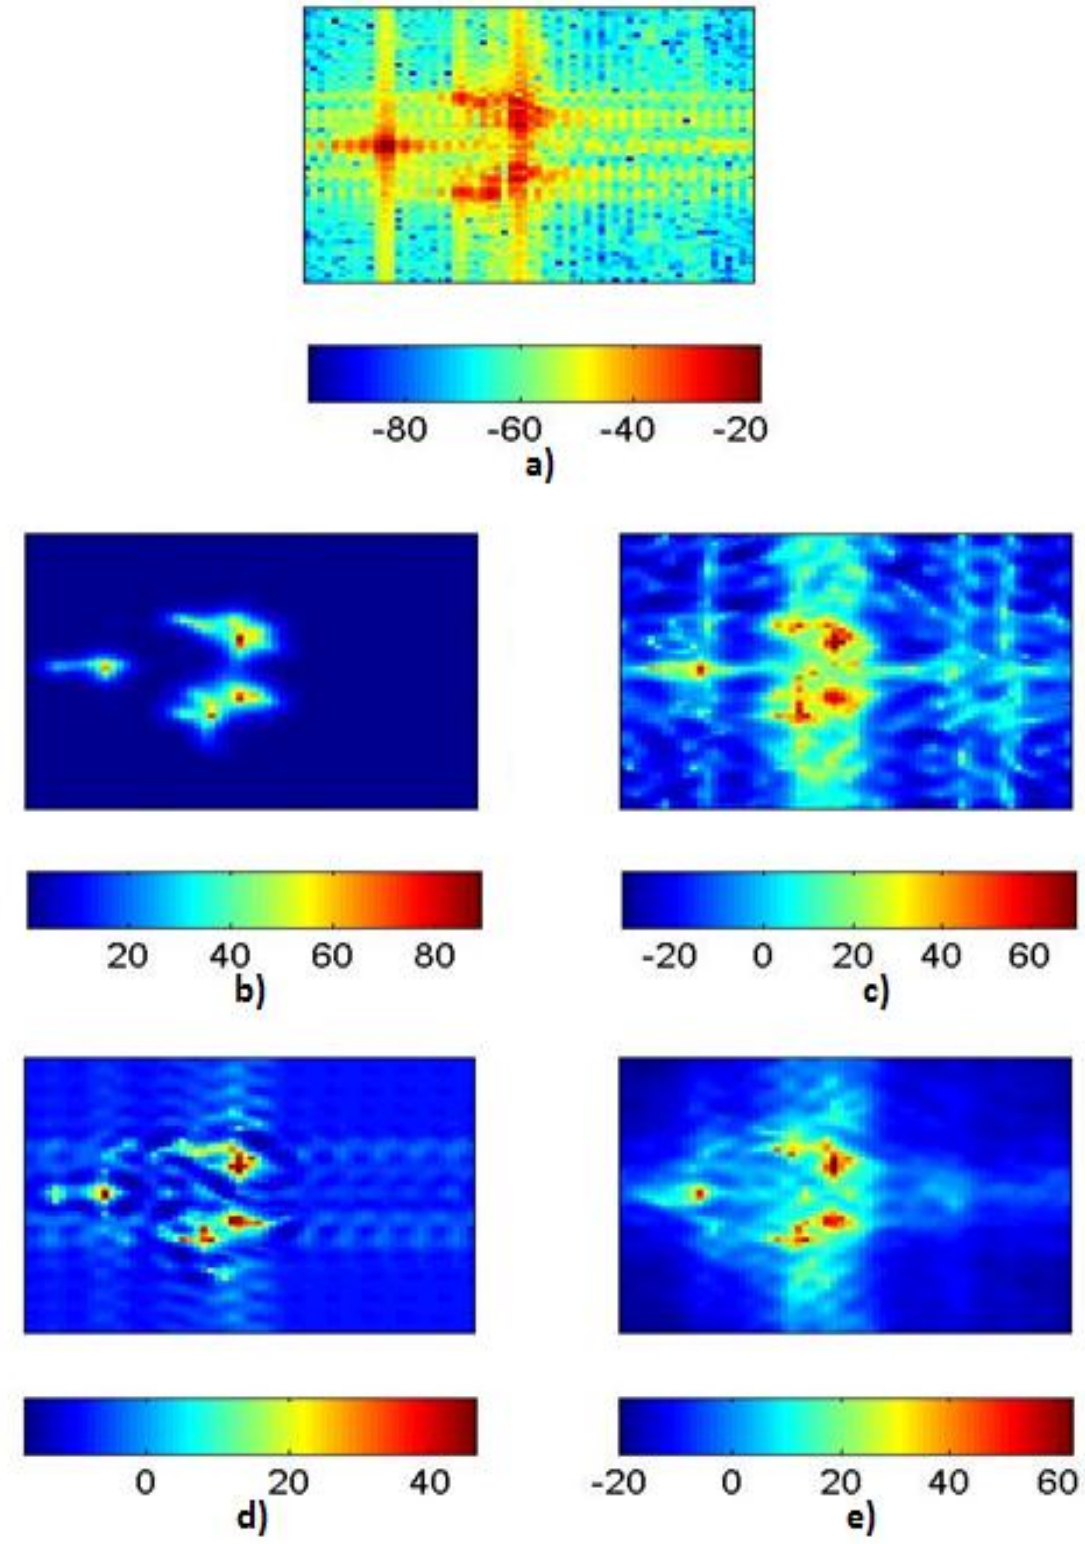
Şekil 2.43: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:24): a) Fourier dönüşümü yöntemi, b) MUSIC algoritması, c) özbağlanımlı (AR) modelleme yöntemi, d) özbağlanımlı modelleme yöntemi-SVD çözümü, e) seyrek özbağlanımlı modelleme yöntemi (λ: 0,5)



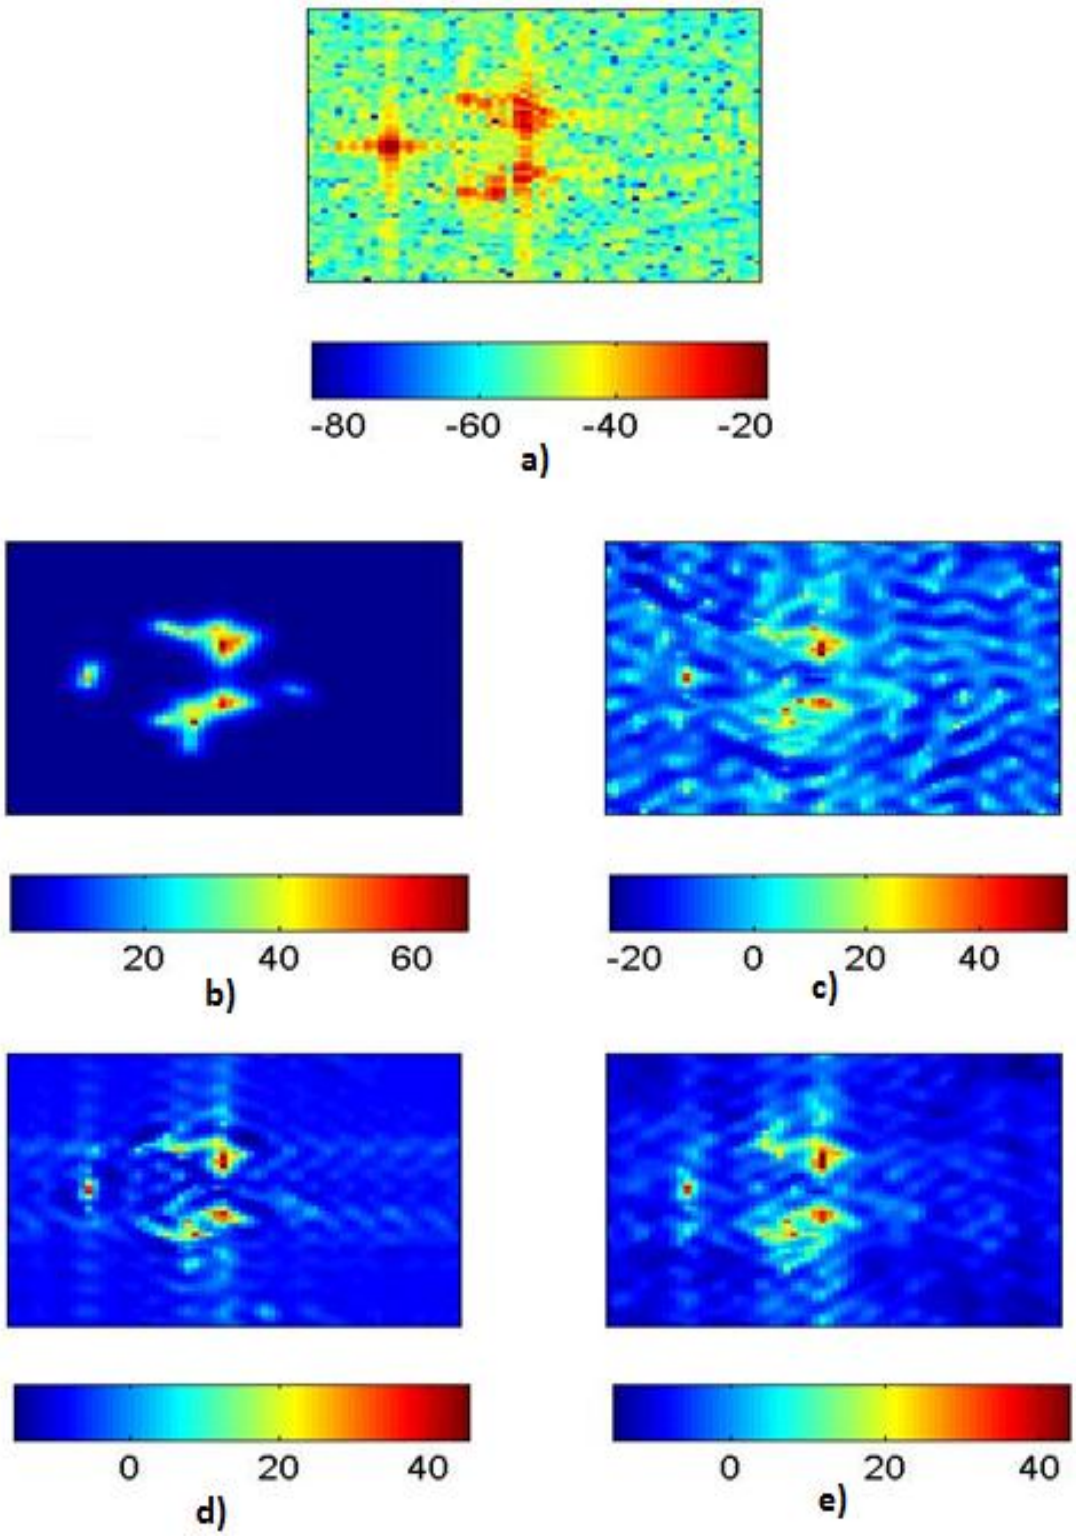
Şekil 2.44: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=10 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:24): a) Fourier dönüşümü yöntemi, b) MUSIC algoritması, c) özbağlanımlı (AR) modelleme yöntemi, d) özbağlanımlı modelleme yöntemi-SVD çözümü, e) seyrek özbağlanımlı modelleme yöntemi (λ=4)



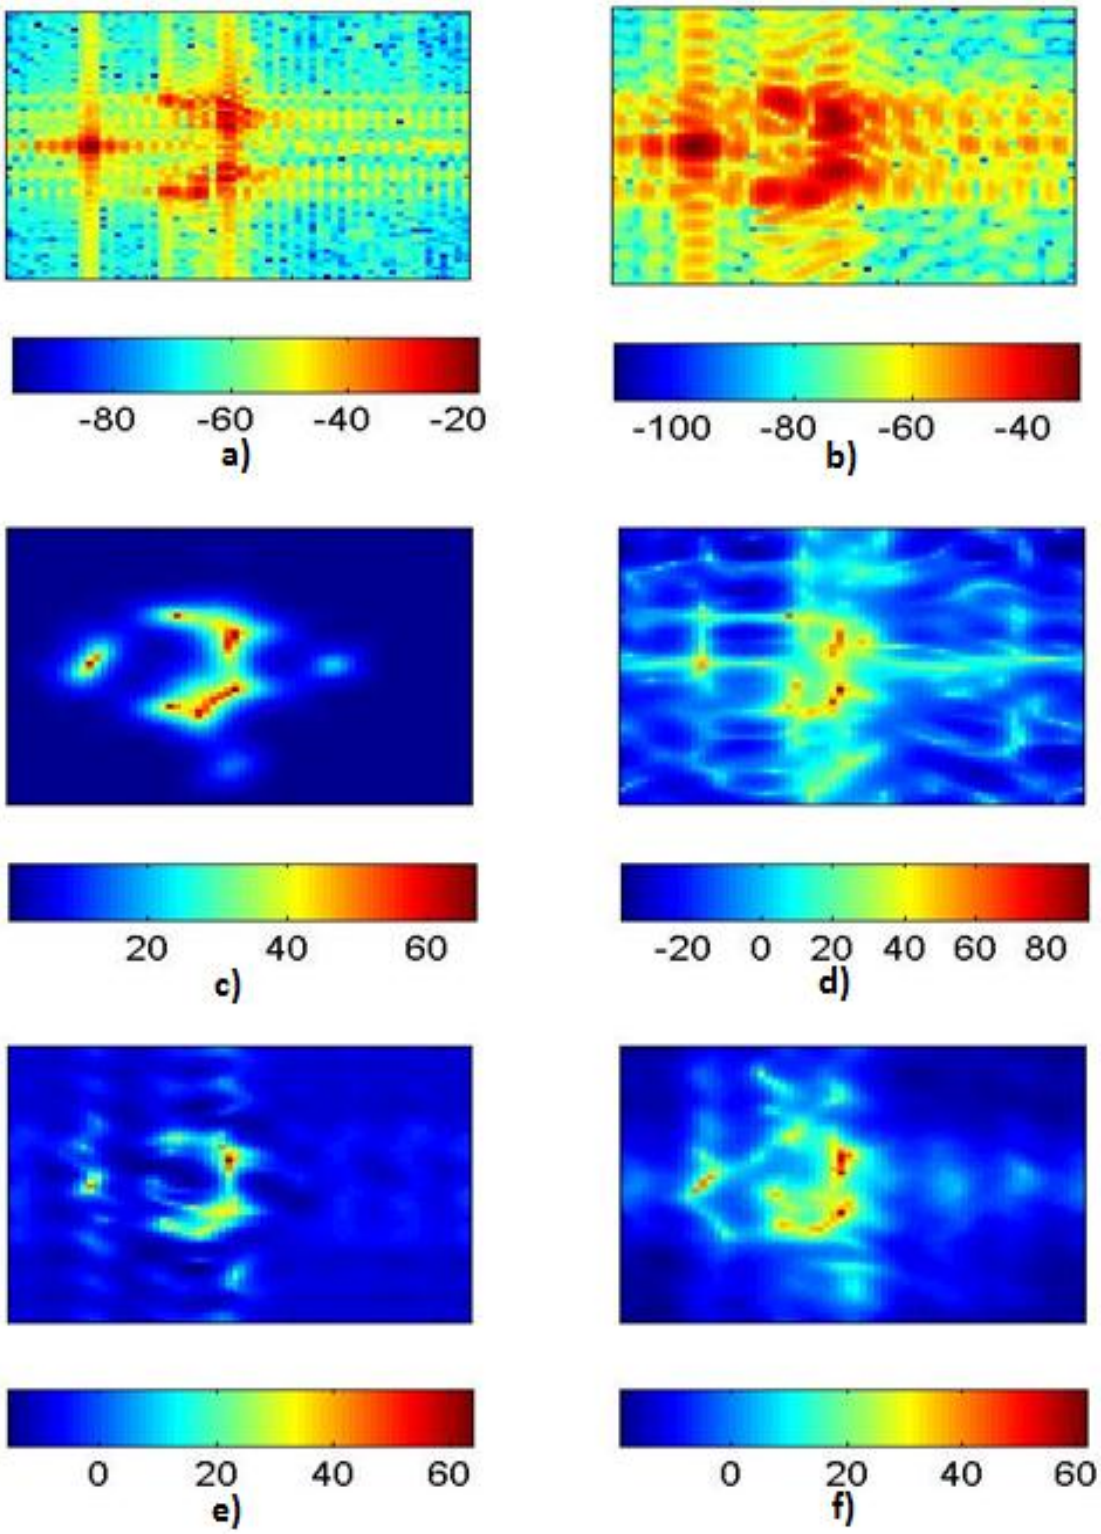
Şekil 2.45: 32 x 32 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:12): a) Fourier dönüşümü yöntemi (64x64 boyutundaki veri ile), b) Fourier dönüşümü yöntemi (32x32 boyutundaki daraltılmış veri ile), c) MUSIC algoritması, d) özbağlanımlı (AR) modelleme yöntemi, e) özbağlanımlı modelleme yöntemi-SVD çözümü, f) seyrek özbağlanımlı modelleme yöntemi (λ: 0,5)



Şekil 2.46: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:12): a) Fourier dönüşümü yöntemi, b) MUSIC algoritması, c) özbağlanımlı (AR) modelleme yöntemi, d) özbağlanımlı modelleme yöntemi-SVD çözümü, e) seyrek özbağlanımlı modelleme yöntemi (λ: 0,5)



Şekil 2.47: 32 x 32 veri boyutundaki Airbus hedefinin (SNR=10 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:12): a) Fourier dönüşümü yöntemi, b) MUSIC algoritması, c) özbağlanımlı (AR) modelleme yöntemi, d) özbağlanımlı modelleme yöntemi-SVD çözümü, e) seyrek özbağlanımlı modelleme yöntemi (λ: 0,5)



Şekil 2.48: 16 x 16 veri boyutundaki Airbus hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi:7): a) Fourier dönüşümü yöntemi (32x32 boyutundaki veri ile), b) Fourier dönüşümü yöntemi (16x16 boyutundaki daraltılmış veri ile), c) MUSIC algoritması, d) özbağlanımlı (AR) modelleme yöntemi, e) özbağlanımlı modelleme yöntemi-SVD çözümü, f) seyrek özbağlanımlı modelleme yöntemi (λ:0,5)

3. RADAR HEDEF SINIFLANDIRMA YÖNTEMİ

Bu bölümde ISAR görüntüleri üzerinden radar hedef sınıflandırma yöntemi anlatılmaktadır. SAR ve ISAR görüntüleme teorisi aynı formullerle ifade edildiğinden ISAR için tanımlanan radar hedef sınıflandırma yöntemi SAR sistemleri için de geçerlidir.

3.1. İlk Hazırlık İşlemleri

2-B ISAR görüntüsü şu şekilde tanımlanır:

$$I_0(x_i, y_i) \qquad i = 1,2, \dots \dots N \qquad j = 1,2, \dots \dots M \tag{3.1}$$

Denklem (3.1)'de bahsi geçen *(x, y)* orijinal ISAR görüntü düzleminde alt menzil ve çapraz menzili ifade eder. *M* ve *N* ilgili boyutun piksel sayısıdır [5]. Ön hazırlık aşamasında görüntünün bölütleme (segmentation) ve normalizasyon işlemleri yapılır. Bölütleme sürecinde hedefin cevabı, gürültü içeren görüntünün geri kalanından ve saçılma cevabından elde edilir. Bu çalışmada Sinyal-Gürültü Oranı (SNR) ve Sinyal-Parazit Oranı (SCR) nispeten yüksek kabul edilmektedir. Böylece radar görüntüsü içerisinde yer alan hedefi arka plandan ayırmak kolay olacaktır. Bu amaçla ortalama eşik değeri ISAR görüntü düzleminin orijinal alt menzil ve çapraz menzil boyutuna uygun olarak basit bir şekilde ifade edilebilir:

$$I_0' = \frac{1}{MN} \sum_{i=0}^{M} \sum_{j=0}^{N} I_0(x_i, y_i) \tag{3.2}$$

Böylece eşik değerinin üstünde kalan sinyal seviyeleri hedef pikseller olarak belirlenir. Geri kalan pikseller atılır (değerleri sıfır kabul edilir).

Yukarıdaki bölütleme (segmentation) adımları ISAR görüntülerinde cismin bazı bölgelerinde ayrıca uygulanabilir ve görüntünün pikselleri azaltılabilir. Giriş koşullarına bağlı olarak Jet Motoru Modülasyonu (JEM), çoklu yansımalar ve

rezonans saçılma bölütlemeleri uygulanabilir. Ancak hedefin ana gövdesinden gelen ayırıcı piksellerin zarar görmeden alınmasına dikkat edilmelidir. Diğer gelişmiş bölütleme yöntemleri kenar algılamalı ve histogram tabanlı bölütlemedir. Bu metotlardan da yararlanılabilir [21].

Sonuç olarak verimli bir bölütleme (segmentation) geliştirmek için gürbüz (robust) bir algoritma kurulması gerekmektedir. Bu algoritma sayesinde gürültü ve dağınıklık yanıtlarının yanı sıra cismin kusursuzca çıkarılması sonucuna ulaşılabilir. Bu nedenle daha ileri bir araştırma gereklidir. ISAR görüntülerin sinyal seviyesi değerleri radar ve hedef arasında farklı mesafelere göre değişmektedir [22]. ISAR görüntüsünü normalleştirmek için bütün enerjisi kullanılır. Bu durum için oluşturulan denklem şu şekildedir:

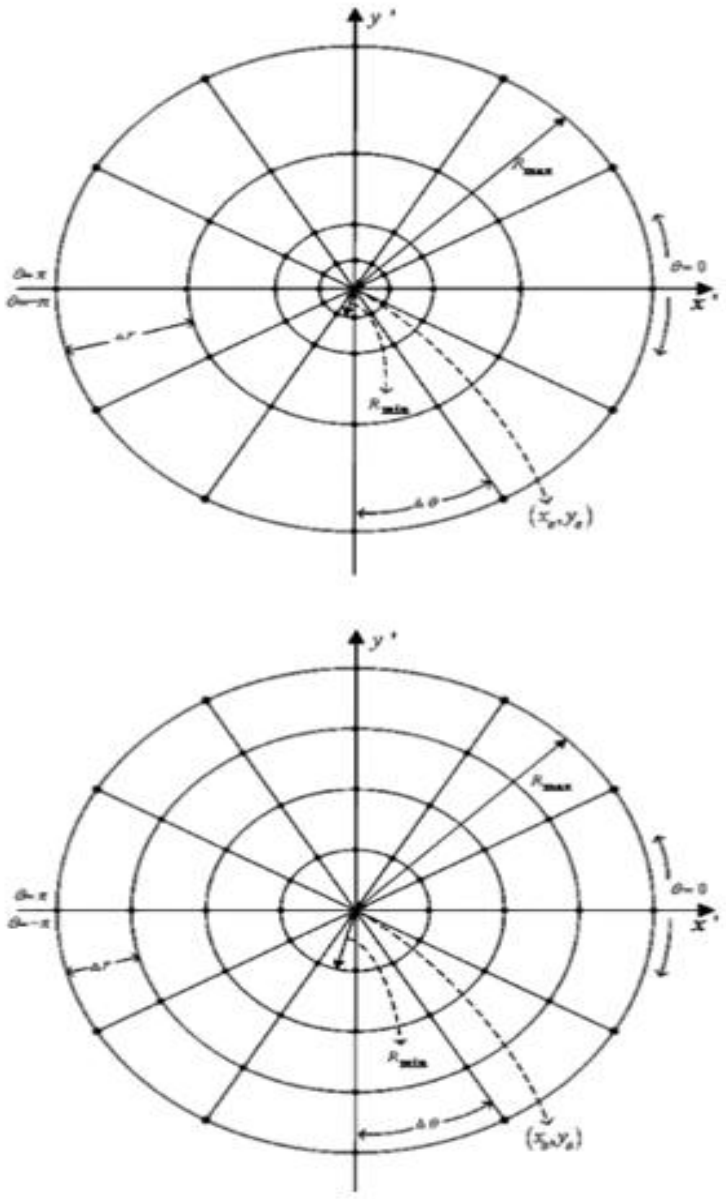
$$I_n(x_i, y_i) = \frac{I_0(x_i, y_i)}{\sum_{i=1}^{M} \sum_{j=1}^{N} I_0(x_i, y_j)} \quad \textbf{(3.3)}$$

Formüldeki $I_0(x_i, y_i)$ bölütleme sonrası ISAR görüntüsüdür. Sonuç olarak ISAR görüntünün kendi sinyal seviyelerinden ziyade sınıflandırma için göreceli şeklinden yararlanılır [23].

3.2. Polar Eşleme İşlemi

Farklı yönelim ve ölçeklemelerle doku görüntülerinin sınıflandırılması örüntü tanıma topluluklarında ve bilgisayarlı görüntü işlemede dikkatleri üzerine çekmiş bir konudur. İşleyebilir yönelimler ve ölçek değişiklikleri için bir dizi teoriler önerilmiştir. Log-kutup eşleme (LPM) bunlardan bir tanesidir [23, 24, 25]. Yeniden örnekleme sürecini içinde barındıran bir görüntünün LPM'si uzay içinde değişen log-kutup ızgarası kullanır ve log-kutup görüntü elde edilir (LPI). LPI koordinat, dönme ve orijinal koordinatlarda ölçek sapmaları, çeviri varyantı gibi basit değişimler ile gözlemlenir. ISAR görüntü sınıflandırmada LPM uygulamak için LPI'nın dönüşme invaryantı bir başka işlem olarak sağlanmalıdır. Ayrıca ızgara çevresi etrafında daha az önem verilen çevrenin merkezinden örnekleme noktalarına doğru doğrusal olmayan radyal düzenlemeler bilgi kaybına yol açabilir. ISAR görüntülerinde görüntü merkezinden uzak saçılma merkezleri genellikle kenar yapılarından kırılımlı saçılma mekanizmalarıyla alakalı olabilir. Bu merkezler sınıflandırma için faydalı bilgiler muhafaza eder. Bu nedenle LPM başarılı bir sınıflandırma performansı

ihtiyacını karşılamak için yeterli bilgi miktarını vermeyebilir. Bunun için polar eşleme işlemi LPM yerine görüntüyü yeniden örneklemek için kullanılır. LPM ve polar eşleme ızgarası Şekil 3.1'de gösterilmiştir.

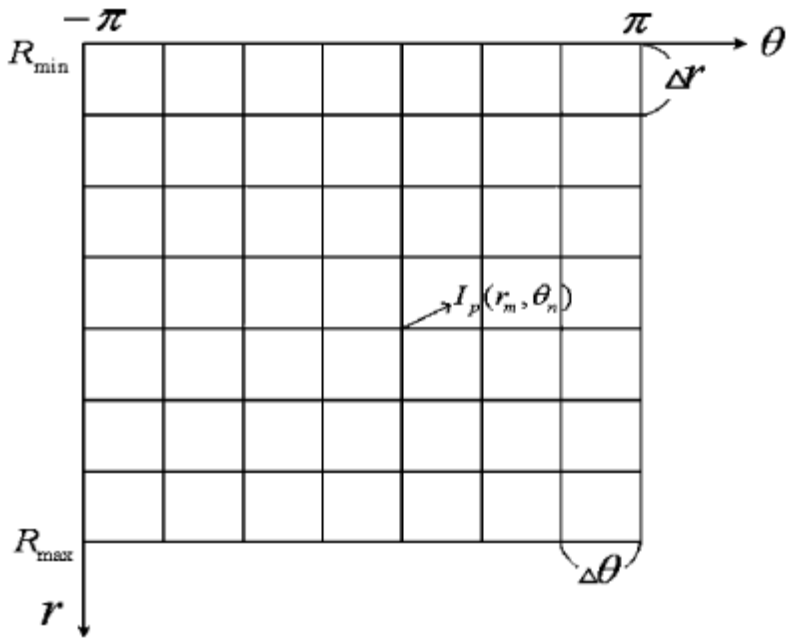


Şekil 3.1: Log-Polar Izgara (üstte) , Polar Izgara (altta) [23].

Şekilden de anlaşılacağı üzere yarıçap çevre kenarı yönünde hareket eder. Kutup haritalama LPM'den daha iyi bir ızgaraya sahiptir. Çünkü *r* yönündeki örnekleme aralığı yarıçapın bağımsızlığıyla alakalıdır. Polar eşleme kullanılarak görüntü ile alakalı I*(x,y)* değeri yeniden elde edilir. Buna göre:

$$I_p(r_m, \theta_n) \quad m = 1,2, \dots \dots, N_r \qquad n = 1,2, \dots \dots, N_\theta \tag{3.4}$$

ifadesi belirlenir. (3.4) ifadesinde görülen N_r şekilde r yönünde N_θ ise θ yönünde bulunan örneklemelerin sayısıdır. Polar görüntüye karşı gelen geometri Şekil 3.2'de gösterilmiştir.



Şekil 3.2: Polar Görüntü Geometrisi [23].

r_m ve θn ise ISAR görüntünün koordinatı *(x,y)* ile ilgilidir:

$$(x_k, y_k) = (x_c, y_c) + (r_m Cos\theta_n,\ r_m Sin\theta_n)$$
$$m = 1,2,\ldots\ldots N_r$$
$$n = 1,2,\ldots\ldots N_\theta \quad \textbf{(3.5)}$$
$$k = 1,2,\ldots\ldots N_r N_\theta$$

$$r_m = R_{min} + (m-1)\Delta r \quad \textbf{(3.6)}$$

$$\theta_n = -\pi + (n-1)\Delta\theta \quad \textbf{(3.7)}$$

$$\Delta r = \frac{R_{max} - R_{min}}{N_r - 1} \quad \textbf{(3.8)}$$

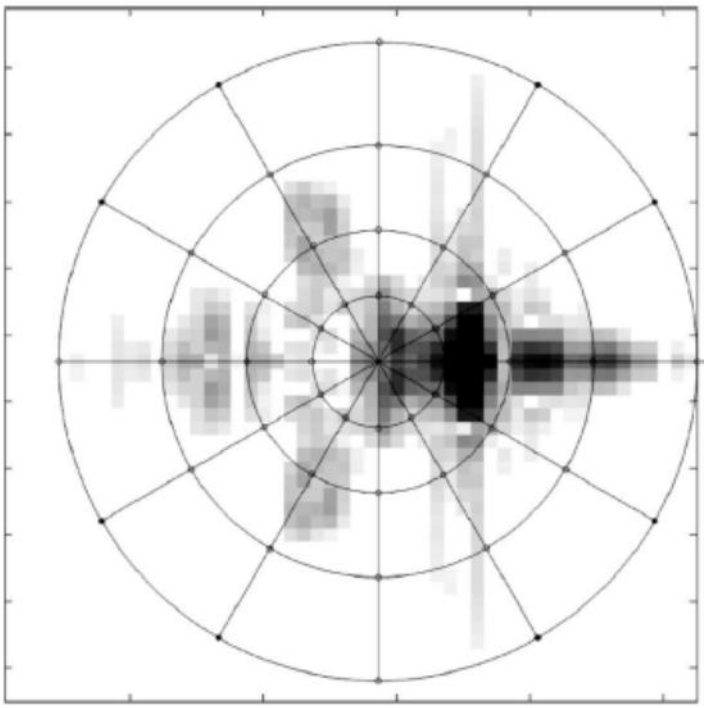
$$\Delta\theta = \frac{2\pi}{N_Q - 1} \quad \textbf{(3.9)}$$

Yukarıdaki denklem (3.5)'de, kutup eşlemenin orta noktası gösterilir. Bu nokta önceden işlenmiş bir ağırlık merkezi olarak seçilmiştir. Δr ve $\Delta\theta$ sırasıyla r ve θ ya

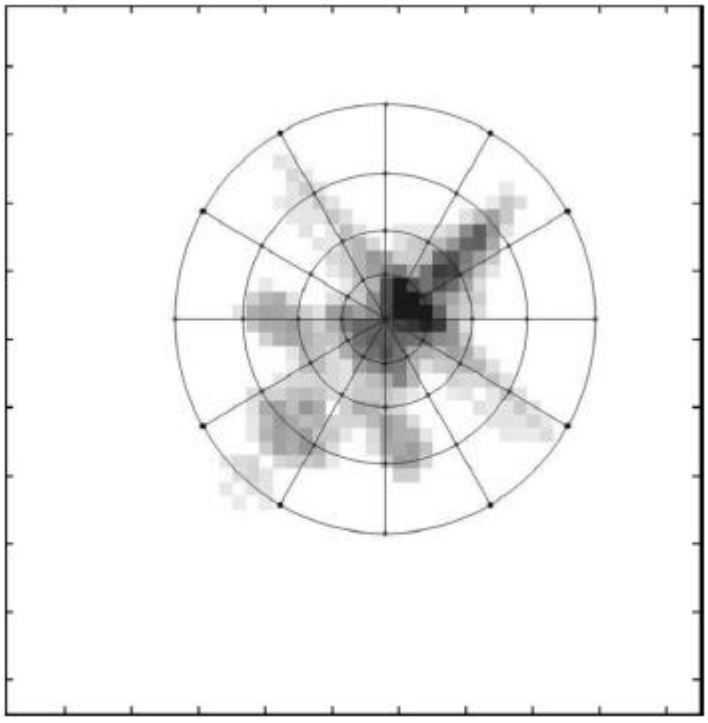
doğru örnekleme aralıklarıdır. R_{max} en büyük örnekleme çerçevesinin yarıçapıdır. Bu yarıçap hedeften alınan cevaba göre çok dikkatli seçilmiş olmalıdır. R_{max} , (x_c, y_c) ve $(x_c, y_c)'$ nin dış hedef pikseli arasında hesaplanabilir. Çünkü piksele karşılık gelen hedef yanıtı ön işleme aşamasında belirlenmiştir. R_{min} en küçük örnekleme çemberinin yarıçapıdır ve rasgele küçük bir değer seçilebilir. $R_{min} = 0$ seçmek yaygın ve kullanışlı bir yoldur. Eğer örnekleme çözümlemeleri Δr ve $\Delta\theta$ geniş olursa, alt örnekleme meydana gelir. Böylece, hedef sınıflama için çok fazla faydalı bilgi içeren, polar görüntü sonuçlandırmada orijinal görüntü kaybedilmiş olabilir. Buna karşılık aşırı örnekleme durumunda polar görüntünün boyutluluğu önemli ölçüde artırılır [25].

Şekil 3.2'de (r_m, θ_n) olarak belirtilen polar bir görüntünün piksel değerini elde etmek için belirtilen değerler, orijinal ISAR görüntüsünden denklem (3.5)'deki (x_k, y_k) piksel değeri referans alınarak belirlenmiştir. Ancak (3.5)'deki (x_k, y_k)'da orijinal ISAR görüntüsünün pikselleri konumlandırılmamıştır. Bu yüzden (x_k, y_k) den daha doğru piksel değerleri hesaplanarak uygun bir interpolasyon düzeni oluşturulması arzu edilir. Literatürde birçok interpolasyon yöntemi mevcuttur. Ancak bu çalışmada daha basit doğrusal bir interpolasyon yöntemi uygulanmıştır. Yüksek dereceden polinomlara dayalı interpolasyon yöntemleri de uygulanabilir [23, 25].

Şekil 3.3 ve Şekil 3.4'te bir F16 uçak modelinin ISAR görüntüleri ilgili yuvarlak ızgaralar üzerine bindirilmiş şekilde gösterilmektedir. Şekil 3.3 ve Şekil 3.4'deki görüntüyü elde etmek için -15 ve 15 derecelik açıları kapsayan 8.4 – 12.4 GHz arasında küçük aralıklarla elde edilmiş RCS verileri ölçülmüştür. Ölçülen frekans yönü etki alanı verileri kartezyen frekans spektrumuna interpole edilmiştir. Daha sonra ISAR görüntüleri oluşturmak için 2-B ters hızlı Fourier (IFFT) uygulanmıştır. Daha önce belirtilen ön işleme algoritması bu şekilleri elde etmek için kullanılmıştır. Şekil 3.4'deki görüntüde dikkat edilmesi gereken nokta Şekil 3.3'ün alt ölçeklenmiş ve döndürülmüş olmasıdır. Bu döndürülme açısı 45 derece ve ölçek oranı $1/\sqrt{2}$ dir. Etkin bir ISAR sınıflandırma şeması Şekil 3.3 ve Şekil 3.4'deki hedefleri aynı sınıfa alarak sınıflandırmaktadır. Bu hedefi gerçekleştirmek için polar eşleme yöntemi Şekil 3.3 ve Şekil 3.4'deki gibi polar ızgaralar eklenerek uygulanmıştır. Elde edilen görüntüler Şekil 3.5 ve Şekil 3.6'da gösterilmektedir.



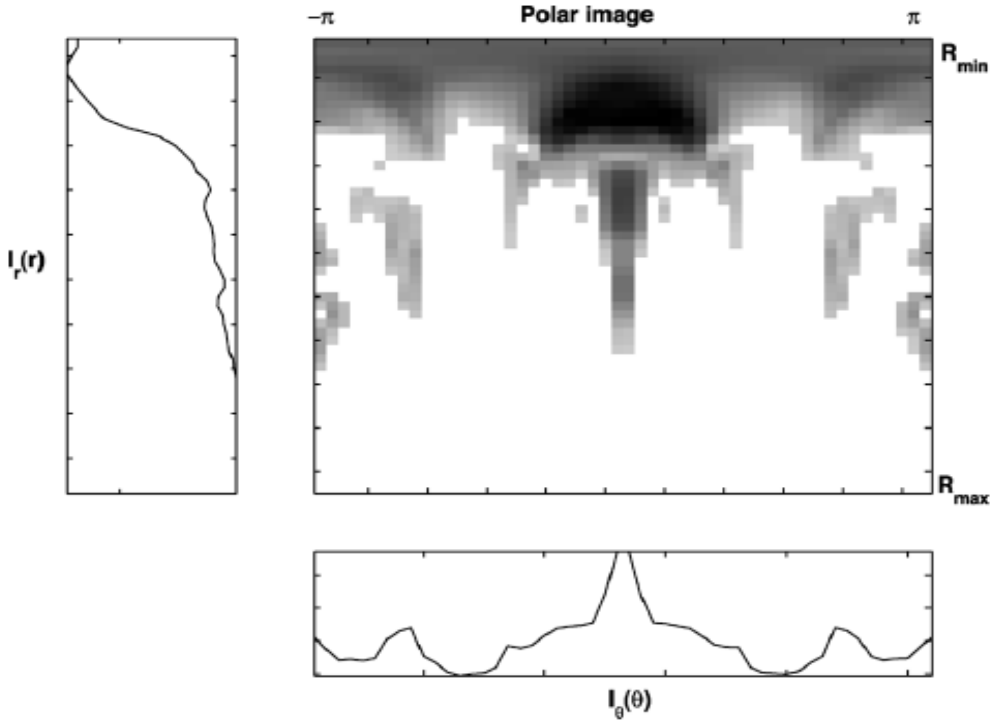
Şekil 3.3: F16 uçak ISAR görüntüsü ve polar ızgarası [23].



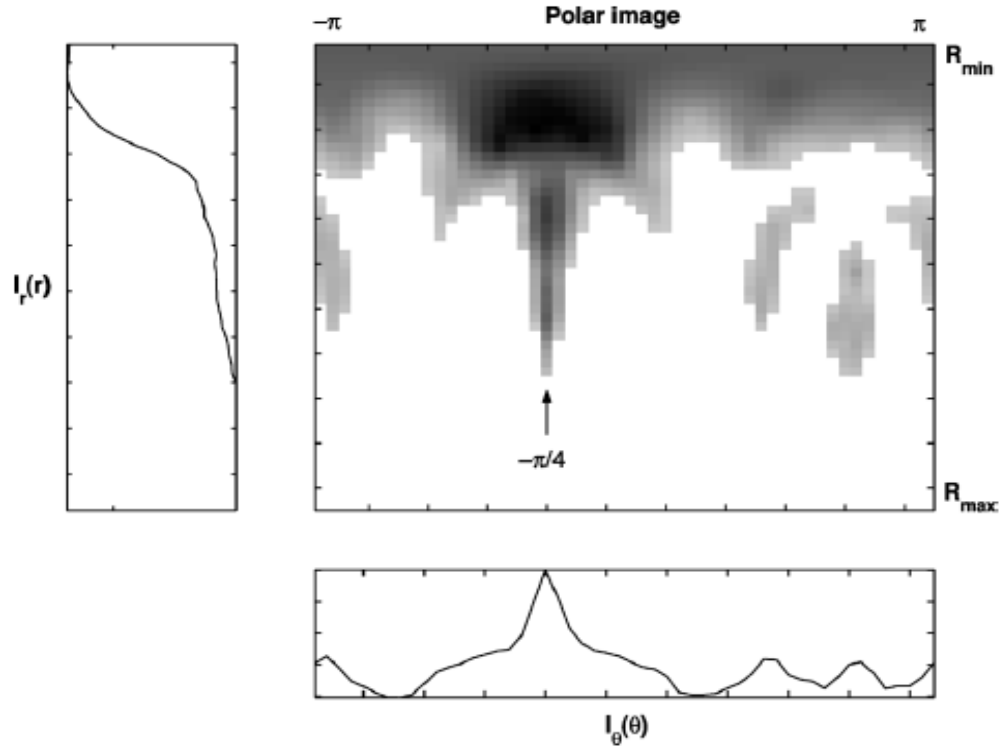
Şekil 3.4: F16 uçak ISAR görüntüsü ve polar ızgarası, döndürülmüş ve açısı küçültülmüş hali [23].

Şekil 3.5 ve Şekil 3.6'yı karşılaştırılırsa iki kutup görüntüsü θ yönüne doğru kaymalar hariç benzerdir. Beklendiği gibi iki görüntü arasında θ yönündeki yer değiştirme miktarı $\pi/4$ e eşittir. Bunun aksine bu iki görüntü arasında r yönünde

hemen hemen hiç fark yoktur. Bu sonuç kutup eşleme işlemi sonucunda ölçek değişmezliğinin elde edildiğini ve dönme varyantının θ yönünde dönüşme varyantına dönüştüğünü göstermektedir. Pratikte ölçek değişmezliği polar eşlemede R_{max} ın uygulanabilir bir şekilde belirlenmesine atfedilir [23, 25].



Şekil 3.5: Şekil 3.3 e karşı gelen Polar görüntü $I_r(r)$ ve $I_\theta(\theta)$: N_r= N_θ = 50 [23].



Şekil 3.6: Şekil 3.4 e karşı gelen Polar görüntü $I_r(r)$ ve $I_\theta(\theta)$: N_r= N_θ = 50 [23].

3.3. Temel Bileşenler Analizi

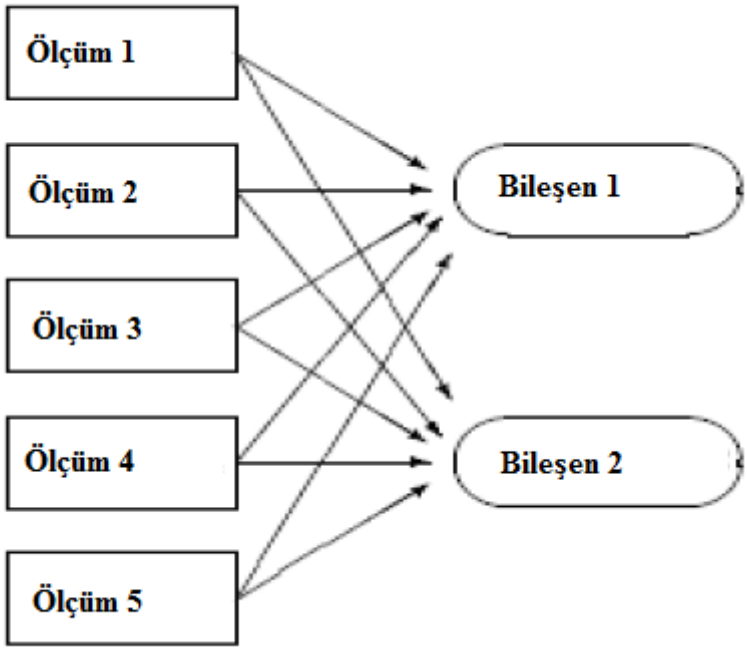
Temel bileşenler analizi (Principal Components Analyses), çok değişkenli analizin en eski ve en çok bilinen tekniğidir. İlk kez Pearson tarafından kullanılan teknik daha sonra bağımsız olarak Hotelling tarafından geliştirilmiştir. Temel bileşenler analizi ile değişkenlerin bileşkeleri diye tabir edilebilecek daha az sayıda yeni değişkenler ya da temel bileşenler oluşturulur. Temel bileşenler birbirinden bağımsızdırlar. Böylece değişkenler arası bağımlılık yapısı da ortadan kaldırılmaktadır. Ayrıca temel bileşenler analizi çoklu doğrusal bağlantı problemine literatürde önerilen çözümlerden biridir.

Çok değişkenli görüntü sınıflandırma algoritmalarında p tane hedefe ilişkin q tane değişken (özellik) incelenmektedir. Bu değişkenlerden birçoğunun birbiriyle ilişkili ve değişken sayısının (q) çok büyük olması, çeşitli değerlendirmeler yapılmasını güçleştirmektedir. Böyle durumlarda temel bileşenler analizi başvurulan önemli tekniklerden biridir. Değişkenler setinin varyant kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri vasıtasıyla açıklayarak, veri indirgenmesi ve yorumlanmasını sağlayan, çok değişkenli bir istatistik yöntemidir. Genel olarak değişkenler arasındaki bağımlılık yapısının yok edilmesi ve boyut indirgeme amacıyla kullanılan bu teknik başlı başına bir analiz olduğu gibi başka analizler için veri hazırlama tekniği olarak da kullanılmaktadır. Yöntemde karşılıklı bağımlılık yapısı gösteren, ölçüm sayısı p olan q adet değişken; doğrusal, ortagonal ve birbirinden bağımsız olma özelliklerini taşıyan k ($k \leq q$) tane yeni değişkene dönüştürülür [26].

Her biri p ölçümünde q değişkenin oluşturduğu bir sistem düşünüldüğünde, sistemin toplam değişkenliği q, değişkenin tümü tarafından açıklanır. Toplam değişkenliğin önemli bir kısmı k ($k \leq q$) bileşen tarafından açıklandığı durumlarda, k bileşen orijinal q değişkeni temsil edebilir. Bu durumda p ölçümdeki q değişken, önemli bir bilgi (varyant) kaybına neden olunmaksızın, p ölçümündeki k değişkene indirgenmiş olur. Söz konusu k adet yeni değişken, orijinal değişkenlerin bazı kısıtlamalara bağlı kalınarak oluşturulmuş çeşitli doğrusal birleşimleridir.

Temel bileşenler analizi ile ulaşılması istenilen ilk sonuç; $X_1, X_2, \ldots\ldots, X_q$ gibi q tane değişkeni, önemli bir bilgi kaybına neden olmaksızın, bu değişkenleri temsil edebilen daha az sayıda değişkene indirgemek ve değişkenlere etki eden genel nedensel faktörleri elde etmektir. Bunun için kurulan düzen basitçe Şekil 3.7'deki gibi

gösterilebilir. Daha sonra indirgenmiş yeni değişkenler ile çalışmanın amacı doğrultusunda çeşitli sonuçlara ulaşılacaktır [26].



Şekil 3.7: Temel bileşenler analizi için grafiksel gösterim [26].

Temel bileşenler analizi ile asıl amaç görüntü matrisinin sıkıştırılmış halini elde etmektir. Orijinal değişkenlerden nispeten daha az sayıda mümkün olduğunca temel bileşen elde etmek için şöyle bir yaklaşım kullanılır:

$$\boldsymbol{y} = \boldsymbol{A^T x} \tag{3.10}$$

Denklem (3.10)'da görülen $y = [y_1, y_2, \dots, y_N]^T$ ifadesi temel bileşenler analizi ile bileşen sayısı azaltılmış özellik vektörüdür. $\boldsymbol{A}$ MxN boyutunda $\boldsymbol{x}$ öznitelik matrisini $\boldsymbol{y}$'ye dönüştürme matrisidir. Temel bileşenler analizinin temel amacı ${y_1}^T, {y_2}^T, \dots, {y_N}^T$ dizisini oluşturmaktır. PCA $\boldsymbol{A}$'nın ortonormal bir matris ($\boldsymbol{{A_i}^T . A_j} = \boldsymbol{\delta_{ij}}$) olduğunu varsayarsak $\mathbf{Y}$ (C_y)'nin kovaryans matrisi diyagonal hale getirilmiştir. Pratikte $\boldsymbol{A}$ matrisinin bileşenleri basitçe kovaryans matrisleri kullanılarak hesaplanır. Kovaryans matrisi $\boldsymbol{C_x}$ şu şekilde gösterilir:

$$C_x = \frac{1}{K}\sum_{k=1}^{K} x\,(k)x^T(k) \tag{3.11}$$

C matrisinin öz değer ve öz vektörleri Φ ve Λ şu şekilde hesaplanır:

$$C_x \Phi = \Phi \Lambda \quad \textbf{(3.12)}$$

Denklem (3.12)'de verilen $\Lambda = diag(\lambda_1, \lambda_2, \dots, \lambda_N)$ ve $\lambda_1, \lambda_2, \dots, \lambda_N$ özdeğerlerdir. Bu değerler azalan sırada sıralandığı durumda yani $\lambda_1 \geq \lambda_2 \geq, \dots, \geq \lambda_N$ olduğunda N boyutlu öz vektör matrisi A aşağıdaki gibidir:

$$A = [\Phi_1, \Phi_2, \dots, \Phi_N] \quad \textbf{(3.13)}$$

Bu işlemler neticesinde PCA normalize edilmiş ve veri miktarı sıkıştırılmış görüntüyü ve gürültüsü azaltılmış bir öz nitelik vektörü sağlamış olur. Temel bileşen yükleri, temel bileşenlerin değişkenlere varyant katkısını gösteren ağırlıklardır ve temel bileşenleri değişkenlerin hangi ağırlıklarla tanımladıklarını göstermektedir. Temel bileşenler ortogonal seçileceğinden δ_{ij} ağırlıkları değişkenler ile temel bileşenler arasındaki korelasyon katsayısıyla orantılıdır. δ_{ij}= i. değişkenin j. temel bileşendeki ağırlığıdır.

Uygulamalarda birkaç temel bileşen, toplam değişkenliğin %80'inden büyük bir oranını açıklayabiliyorsa, bu bileşenler büyük bir bilgi kaybına neden olmaksızın orijinal q değişkenin yerini alabilir. Ayrıca, değeri 1'den küçük olan öz değerlere karşılık gelen temel bileşenler, istatistiksel olarak önemsiz bilgi taşıdıklarından değerlendirme dışı bırakılır [26].

3.4. Eğitim Veri Setinin Oluşturulması İşlemi

Çalışma kapsamında kullanılan algoritma yardımıyla sınıflandırılan hedefin öznitelik vektörü üç kısımdan oluşmaktadır: *r-çalışılan görüntü, θ-çalışılan görüntü ve* PCA ile elde edilmiş *sıkıştırılmış kutupsal görüntü.* Polar görüntünün *r* ekseninde oluşturulan öznitelik vektörüne $I_r(r)$ denirse:

$$I_r(r) = \int_{-\pi}^{\pi} I_p(r, \theta) = \sum_{n=1}^{N_\theta} I_p(r_m, \theta_n) \quad \textbf{(3.14)}$$

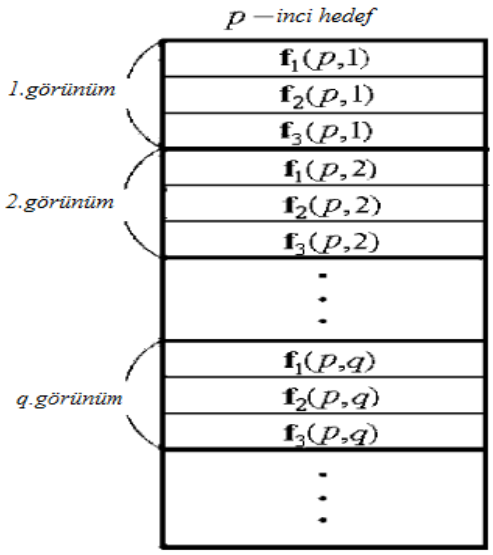
şeklinde elde edilir. Görüntünün θ yönündeki 1 boyutlu görüntüsünün öznitelik vektörüne $I_\theta(\theta)$ denirse:

$$I_\theta(\theta) = \int_{R_{min}}^{R_{max}} I_p(r,\theta) = \sum_{m=1}^{N_r} I_p(r_m, \theta_n) \quad \textbf{(3.15)}$$

Denklem (3.14) ve (3.15)'te görülen $I_r(r)$ ve $I_\theta(\theta)$ ifadeleri N_r ve N_θ ile aynı boyuttadırlar. Bu boyutlar N_rxN_θ şeklindedir ve polar görüntüden daha küçüktür. $I_r(r)$ ve $I_\theta(\theta)$ ifadelerinin tipik görüntüleri Şekil 3.5 ve Şekil 3.6'da bir F16 uçak modeli için gösterilmiştir. $I_r(r)$ ve $I_\theta(\theta)$ sınıflandırma adımlarında fayda sağlayacaktır. Bu fayda sadece polar görüntünün dönüşüm sabitlerini sağlamada değil, aynı zamanda bilinmeyen cisimlerin sınıflarını belirlemede kullanılacak olan öznitelik uzayını azaltma işleminde kullanılacaktır.

Daha önce tartışıldığı gibi, ayrıştırıcı bilgilerin kaybını azaltmak; polar görüntüde orijinal piksel değerinin tamamının kullanılmasına karşı arzu edilen bir durumdur [27]. Ancak bu işlem öznitelik vektörünün çok geniş boyutlarda olmasına neden olabilir. Çünkü N_r ve N_θ orjinal ISAR görüntüde saçılma mekanizmasını içeren çoğu durum için küçük olamaz. Bu yüzden , N_rxN_θ boyutlu polar görüntünün $I_p(r_m, \theta_n)$ değerini elde etmek için sıkıştırılması gerekir. Sıkıştırma işlemi sonucunda boyut azaltılabilir. Bu işlem temel bileşenler analizi yardımıyla sağlanır [28, 29]. Genel olarak 2-B bir görüntü sınıflandırma için faydalı bilgiler içerir. PCA bu faydalı bilgilerin daha düşük boyutta elde edilmesini sağlar. Böylelikle gereğinden fazla olan öznitelik vektörleri daha küçük boyuta indirgenir. Ayrıca, sıkıştırılmış görüntü ile orijinal görüntü arasındaki bilgi kaybı küçük temel-alan hatasının hassasiyeti sayesinde en aza indirilir.

Temel bileşenler analizi ve polar format algoritması sayesinde eğitim veri setinin çıkarılması Şekil 3.8'de gösterilmiştir. Şekilde gördüğümüz üzere p. hedefe ait q. gözlem açısına kadar olan her görüntü üç adet alt özellik bileşeni içermektedir: $f_1(p,q)$, $f_2(p,q)$, $f_3(p,q)$. Bu alt özellik fonksiyonlarından $f_1(p,q)$ r ekseninde oluşturulan öznitelik vektörüne, $I_r(r)$' ye, karşılık gelir. $f_2(p,q)$ θ yönündeki 1-boyutlu görüntüsünün öznitelik vektörüne $I_\theta(\theta)$ iken, $f_3(p,q)$ da temel bileşenler analizi yardımıyla sıkıştırılmış görüntünün öznitelik vektörünü ifade eder. Böylece bütün öznitelik boyutları saklanmış olur. Bunların sayıları (N_r + $N_\theta + l$)' ye eşittir. l burada PCA ile azaltılmış öznitelik vektörünün boyutudur [23].



Şekil 3.8: Bir hedefin önerilen deneme veri setinin mimarisi [23].

3.5. K-Means Algoritması

En iyi bilinen ve yaygın kullanılan algoritmalardan biri olan k-means, verileri sınıflandıran bir kümeleme algoritmasıdır. Verilen nesneleri nitelik veya özelliklerine göre k adet sınıfa ayırmak amacıyla kullanılır. Sınıflandırma, verilerin en yakın veya benzer oldukları küme merkezleri etrafına yerleştirilmesi ile gerçekleştirilir. Bu çalışmada kullanılan k-means algoritması, J. MacQueen [30] tarafından 1967 yılında tanıtılmıştır. Çalışma yönteminde, Öklit uzaklığı temel alınarak kümeleme yapılmaktadır. Algoritmaya k-means adı verilmesinin nedeni, algoritmanın çalışmasından önce sabit bir küme sayısına ihtiyaç duyulmasıdır. Küme sayısı k ile gösterilir ve elemanlarının birbirlerine olan yakınlıklarına göre oluşacak grup sayısını ifade eder. Buna göre k önceden bilinen ve kümeleme işlemi bitene kadar değeri değişmeyen sabit bir pozitif tamsayıdır.

Çok yaygın kullanımı olan bu algoritmanın birtakım zayıf yönleri de bulunmaktadır. Algoritmanın başında giriş parametresi olarak bir k sayısına ihtiyacı vardır. Elde edilecek olan sonuçlar k sayısına göre değişkenlik gösterebilir. Eğer küme sayısı belirli değil ise deneme yoluyla en uygun sayı bulunur. Algoritma çakışan kümelerde iyi sonuç vermeyebilir [31].

Algoritmanın ilk adımında öncelikle küme merkezlerini veya diğer bir deyişle küme ortalamasını temsil edecek k adet eleman belirlenir. MacQueen algoritmasında küme merkezleri ilk k adet elemandan seçilir. Ancak elemanların değerleri birbirine çok

yakın ise, seçim rastgele yapılır veya birbirinden uzak elemanlar seçilir. Bu noktaların her biri prototip olarak adlandırılır. Belirlenen bu elemanlar tek elemanlı başlangıç kümeleridir ve ilk küme merkezlerini oluştururlar. Kümenin ağırlıklı ortalama değerine sahip olan ya da bu değere en yakın olan elemanı küme merkezi olarak adlandırılır.

İkinci adımda, okunan elemanlar kendilerine en yakın k adet küme merkezinden birine dahil edilir. Elemanların küme merkezine olan yakınlık derecesini bulmak amacıyla çeşitli geometrik yöntemler kullanılır. Bunlardan bir tanesi, kümeler arasındaki sınırları belirleyerek, elemanların hangi küme merkezine daha yakın olduklarını tespit eder. Bunun için önce iki küme merkezi bir doğruyla birleştirilir. Bu doğrunun orta noktasından geçen ve doğruyu dik kesen başka bir doğru daha geçirildiğinde, bu doğru iki kümenin sınırı olarak kabul edilir. Bulunan sınır çizgisi dikkate alınarak, elemanların hangi kümeye dahil edileceği ortaya çıkar.

Noktalar arası uzaklığın hesaplanmasında en çok kullanılan yöntem Öklit bağıntısıdır. İki boyutlu bilgilerde, iki küme merkezinin birleştirilmesinde doğru kullanılırken, boyut sayısı arttığında doğru yerine düzlem kullanılır. Çok boyutlu bilgilerde çok boyutlu düzlemler kullanılır. Algoritmanın geometrik gösteriminde küme sınırları yukarıda anlatıldığı şekilde belirlenmektedir. Bilgisayar programları ile geliştirilen k-means algoritmalarında ise, düzlemler yerine noktalar arasındaki uzaklıklar hesaplanarak, noktaların merkeze yakınlığı dikkate alınmaktadır.

Üçüncü adımda her bir kümeye eklenen yeni eleman ile küme elemanlarının ağırlıklı ortalaması tekrar hesaplanarak yeni bir küme merkezi bulunur. Ağırlıklı ortalama kümenin her bir boyutundaki bütün elemanların ortalama değerlerinin alınması ile hesaplanır. Algoritmanın başında seçilen elemanlar küme merkezini oluştururken, ikinci döngü sonucunda bulunan yeni küme merkezleri artık bir küme elemanı değil, sadece bir ortalama değerdir. Bundan sonraki seçim işlemlerinde küme merkezini bu yeni eleman temsil eder. Her bir döngüde elemanlar farklı bir kümeye dahil edilebilirler.

Kümeleme işlemi, tüm elemanların tekrar aynı veya farklı bir kümeye dahil edilmesiyle devam eder. Elemanların bir kümeye dahil edilmesi ve küme merkezlerinin tekrar hesaplanması işlemlerine ait döngü, küme sınırlarının değişimi

bitene kadar devam eder. K-means algoritması ile uygulamalarda genellikle birkaç düzine döngü sonrası kararlı bir küme grubu ortaya çıkar [30].

Kümeleme algoritmalarında, elemanların birbirlerine olan yakınlıklarına göre oluşturulan kümelerin sayısı k ile gösterilir. "k" işlem öncesinde bilinen ve kümeleme işlemi bitene kadar değeri değişmeyen sabit bir pozitif tamsayıdır. K-means algoritması ile verileri kümelere ayırmak için geometrik veya aritmetik hesaplama yöntemleri kullanılmaktadır.

3.6. Sınıflandırma Tasarımı

Daha önceki varsayımlarımızdan elde ettiğimiz sonuçlara dayanarak bilinmeyen bir SAR görüntünün $I_p(r,\theta)$ değeri $I_r(r)\ ve\ I_\theta(\theta)$ değerlerini elde etmek için işlenir. Şekil 3.5 ve Şekil 3.6'da gördüğümüz gibi iki kutup görüntüsü r yönüne doğru benzerlikler gösterirken θ yününe doğru farklılıklar göstermektedir. Bu değişiklikler öteleme değişikliklerinden kaynaklanmaktadır. Buna rağmen bu iki cismin de şekillerdeki yansıtılan görüntüleri aynı şekilde gösterilmiştir. Verimli bir sınıflandırma algoritması kullandığımız zaman iki cisimde aynı sınıfa dahil olacaktır. Teoride orijinal SAR görüntüsü ve onun alt ölçeklenmiş hali aynı $I_r(r)$ değerini paylaşmak zorundadır. Bu zorunluluk aynı doğrultu ve hedef sınıfında olduğu sürece devam eder. Daha sonra bilinmeyen bir hedefe karşılık gelen sıkıştırılmış polar görüntüden PCA yöntemiyle yansıyan matris elde edilir. Buradan elde edilen tüm vektörler tek bir vektörü haline gelecek şekilde $I_c = I_r(r)\ I_\theta(\theta)\ I_{PCA}$ öznitelik vektörü oluşturulur.

Test kümesi için elimizde bulunan her bir hedeften elde edilen vektörlerin bir kısmı ortalamaları alınarak S_t test kümesine dahil edilir. Burada S_t kümesi K-means sınıflayıcımız için referans kütüphane işlevini görecektir. Sınıflayıcı girişine gelen her bir vektörün burada bulunan referans kütüphane ile olan uzaklığına bakılarak ait olduğu sınıfa karar verilecektir.

K-means'de bilinmeyen hedefin başlangıç sınıfı p_0 olarak tanımlanır. Standart işlem sırasında eğer;

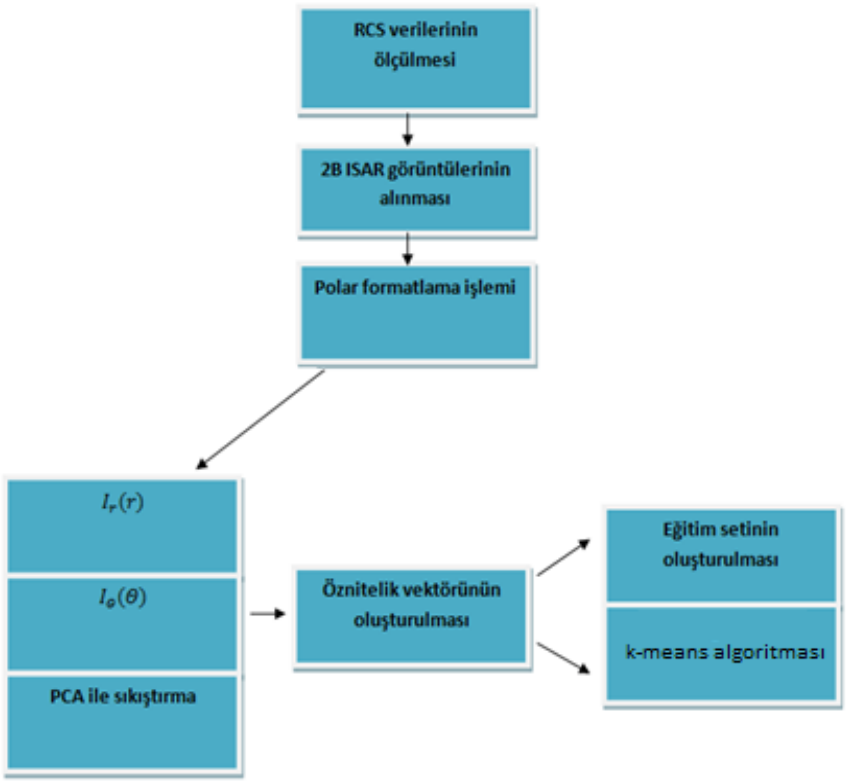
$$d(p_0, q_0) \leq d(p, q) \qquad \textbf{(3.17)}$$

ise;

$$d(p,q) = \left|\left|I_h(p,q) - I_r(p_u,q_u)\right|\right| \qquad (p,q) \in S_t \tag{3.18}$$

şeklinde uzaklıklar hesaplanarak, karar verme işlemi gerçekleştirilir.

Bir sınıflandırma algoritmasının performansı, doğru tanıma oranı ile ölçülür. Bu oran bütün veri kümesinin doğru sınıflandırma oranıdır. Doğru sınıflandırma oranına ulaşmak için Şekil 3.9'da bir algoritma oluşturulmuştur. Algoritmanın ilk kısmında ISAR görüntülerin RCS verileri tek tek elde edilmiştir. Eğitim aşamasında ikinci adım ve test aşamasında üçüncü adım kısımlarında kutupsal görüntüyü elde etmek için N_r ve N_θ değerleri N_r =50 ve N_θ=50 olacak şekilde belirlenmiştir.



Şekil 3.9 Sınıflandırma performansının deneysel sonucunu elde etme şeması [7]

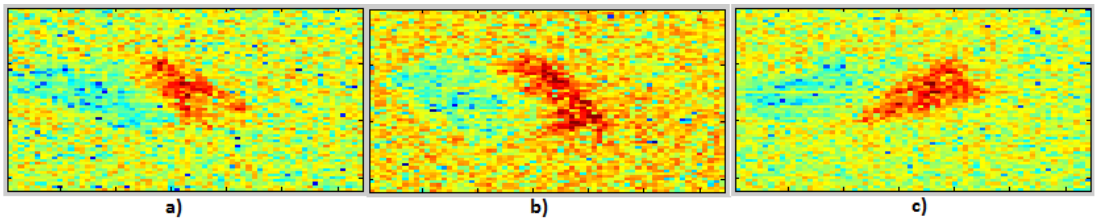
Yine aynı adımlarda polar gerçekleme çemberinin en küçük ve en büyük yarıçapları da R_{max}=50, R_{min}=1 olacak şekilde seçilmiştir. Eğitim aşamasının üçüncü adımında PCA yönteminin uygulanması için l=20 seçilir. Test aşamasının beşinci ve altıncı adımlarında η ve γ değerleri seçilir. Eğitim aşamasının dördüncü adımında üç alt bileşik özelliği olan $I_r(r), I_\theta(\theta)$ ve sıkıştırılmış görüntüden oluşan tek bir şablon bulunmaktadır. Bu şablon PCA yöntemiyle elde edilmiştir. Bu şablonun boyutları N_r =50 ve N_θ=50 ve PCA dan elde edilen l=20'nin boyutlarını içermektedir.

Test evresinin birinci adımında eğitim görüntülerinden farklı bir test görüntüsü rastgele döndürülür ve ölçeklenmesi yapılır. 0º ile 360º arasında alınmış SAR görüntüleri kullanılır. Verimli bir SAR sınıflandırma yapabilmek için farklı açılarla ölçeklenmiş görüntülerin aynı gruba alınması gerekir [23].

3.7. Sınıflandırma Sonuçları ve Değerlendirmeler

Çalışmada kullanılan veriler Sandia National Laboratory (SNL) tarafından 1995 yılında kaydedilmiştir. Bu veriler hareketli ve sabit hedef elde etme ve tanıma (Movingand Stationary Target Acquisition and Recognition - MSTAR) programı kapsamında toplanmıştır. Veriler 9.6 GHz merkez frekansında ve 591 MHz frekans bant genişliğinde SAR sisteminin spotlight modunda toplanmıştır. Radarın menzil ve çapraz menzil çözünürlükleri 0,304 metredir. Bu çalışmada sınıflandırma başarısının ölçümü için BMP2 ve T72 tankları ve BTR70 askeri nakliye aracının saçıcı alanlarından elde edilen ham verileri kullanılmıştır. Herbir hedef için 232 adet olmak üzere farklı açılarda elde edilmiş görüntüler ile toplamda 696 görüntüden veri tabanı oluşturulmuştur. Her bir hedef için 196 adet olmak üzere toplamda 588 adet görüntünün her biri için veri tabanı ile karşılaştırılma yapılmış ve hedefler sınıflandırılmıştır.

Radar hedef sınıflandırmada 591 MHz frekans bant genişliğine sahip ham veriler kullanılmıştır (dokümanda “geniş bantlı veri” şeklinde ifade edilmektedir). FFT, MUSIC, özbağlanımlı (AR) modelleme ve çalışma kapsamında önerdiğimiz seyrek özbağlanımlı (sparse-AR) modelleme algoritmalarının sınıflandırma başarıları incelenmiştir. İkinci aşamada ise frekans bant genişliği ve açısal sektör daraltılarak verinin (dokümanda “dar bantlı veri” şeklinde ifade edilmektedir) çözünürlüğü düşürülmüş ve bu durumda FFT, MUSIC, özbağlanımlı modelleme ve seyrek özbağlanımlı modelleme algoritmalarının sınıflandırmadaki başarısı incelenmiştir.



Şekil 3.10 Hedeflerin Fourier dönüşümü yöntemine göre elde edilmiş radar hedef görüntüleri a) BMP2, b) BTR70, c) T72

3.7.1. Geniş bantlı veri için sınıflandırma sonuçları

Farklı görüntüleme yöntemleri kullanılarak ve görüntüleme teknikleri içerisinde yer alan farklı değişken değerleri için sınıflandırma sonuçları elde edilmiştir. Geleneksel 2 boyutlu FFT yöntemiyle %90.3 başarı sağlanmıştır. Yüksek çözünürlüklü spektral kestirim yöntemleriyle elde edilen görüntülerin sınıflandırma başarıları Çizelge 1'de sunulmaktadır.

Özbağlanımlı (AR) modellemede SVD yöntemini kullanmanın, radar hedef görüntüsünü sahte saçıcılardan arındırmasına (yan lobları bastırmasına) rağmen, radar hedef sınıflandırmaya katkı sağlamadığı görülmektedir. Bunun en önemli sebebi SVD yan lobları bastırken radar hedefinin de kontrastını daraltmasıdır (SVD, radar hedef görüntüsünü yumuşatmaktadır). Bu da sınıflandırmada istenen iyileştirmeyi sağlamasını engellemektedir (bknz. Şekil 2.30). Diğer yandan geniş bantlı veri kullanıldığı durumda seyrek özbağlanımlı modellemenin sınıflandırma başarısına önemli bir katkı sağlamadığı söylenebilir.

MUSIC algoritmasının aksine, özbağlanımlı modelleme yönteminde dinamik alanın etkili olduğuna dair bir bulgu ile karşılaşılmamıştır. Özbağlanımlı modelleme seviyesinin artması veya azalması dinamik alanda düzenli bir artış veya azalmaya sebep olmamaktadır. Modelleme seviyesindeki artışa/azalışa dinamik alan düzensiz tepki vermektedir (bknz. Çizelge 7 ve Çizelge 8).

Özbağlanımlı modelleme yönteminde modelleme seviyesi arttıkça çözünürlük artmasına rağmen sınıflandırma başarısı düşmektedir. Bunun sebebi modelleme seviyesi düşük iken hedef saçıcılarının ortamdaki diğer saçıcılardan daha belirgin görünmesidir, diğer bir ifadeyle hedefin arka plandan daha kolay ayırt edilebilmesidir (bknz. Şekil 2.24, Şekil 2.25, Şekil 2.27, Şekil 2.28).

Çizelgeler incelendiğinde geniş bantlı veriler için, yöntemler arasında sınıflandırma başarısı açısından ciddi bir fark olmadığı, değerlerin birbirine yakın düzeyde olduğu görünmektedir.

Çizelge 3'de BMP2, BTR70 ve T72 hedeflerinin görüntüleri için sınıflandırma başarıları sergilenmektedir. Çizelgeden en başarılı sınıflandırma sonucunun T72 hedefi için elde edildiği görülmektedir. En kötü sınıflandırma sonucu ise BMP2 hedefine aittir. BMP2 hedefi yanlış sınıflandırıldığında büyük oranda T72 olarak

sınıflandırılmıştır. Şekil 3.10'da bakılırsa bu hatalı sınıflandırmanın iki hedefin birbirine nispeten daha çok benzemesinden kaynaklandığı söylenebilir.

Çizelge 1: Farklı radar hedef görüntüleme algoritmaları için sınıflandırma sonuçları (%) (geniş bantlı verilere sahip olunduğu durumda)

Modelleme Seviyesi / Alt Matris Boyutu	**MUSIC**	**Özbağlanımlı (AR)**	**Özbağlanımlı-SVD Çözümü**	**Özbağlanımlı-Seyrek Çözümü**	
				λ: 0.5	**λ: 4**
8	90.3	92.3	91.3	92.7	90.6
12	91.3	90.5	88.8	91	90.1
16	90.5	87.1	85.2	87.1	86.4

Çizelge 2: Farklı yöntemlere göre ve değişken parametre setlerine göre en iyi radar hedef sınıflandırma sonuçları (%)

Yöntem	**Parametreler**	**Sonuç (%)**
FFT	-	90.3
MUSIC	Alt Matris Boyut: 12	91.3
AR	Modelleme Seviyesi: 8	92.3
AR-SVD	Modelleme Seviyesi: 8	91.3
Seyrek AR	Modelleme Seviyesi: 8; λ: 0.5	92.7

3.7.2. Dar bantlı veri için sınıflandırma sonuçları

Dar bantlı veri, 64x64'lük frekans-açı uzayındaki MSTAR verilerinin 32x32'lik kısmının alınması ile oluşturulmuş veri bloğudur. Bu noktada daha dar frekans bandında ve/veya daha dar açı sektöründe çalışma durumunda sınıflandırma başarısının farklı yöntemlere göre nasıl değiştiği incelenecektir. Farklı görüntüleme yöntemleri kullanılarak ve görüntüleme teknikleri içerisinde yer alan farklı değişken değerleri için sınıflandırma sonuçları elde edilmiştir. Geleneksel 2 boyutlu FFT yöntemiyle %72.1 başarı sağlanmıştır. Yüksek çözünürlüklü spektral kestirim yöntemleriyle elde edilen görüntülerin sınıflandırma başarıları Çizelge 4'te sunulmaktadır. Yöntemlerin kendi içinde sınıflandırma başarısının hangi etkenlere

göre değiştiğine 3.7.1 *Geniş bantlı veri için sınıflandırma sonuçları* başlığından bakılabilir.

Çizelge 3: Hedef sınıflandırma başarıları karmaşıklık matrisi (geniş bantlı verilere sahip olunduğu durumda)

		BMP2	**BTR70**	**T72**
FFT	**BMP2**	168	13	5
	BTR70	6	174	2
	T72	22	9	189
MUSIC	**BMP2**	168	8	6
	BTR70	9	182	3
	T72	19	6	187
AR	**BMP2**	169	7	1
	BTR70	3	179	0
	T72	24	10	195
AR-SVD	**BMP2**	166	8	6
	BTR70	3	181	0
	T72	27	7	190
Seyrek-AR	**BMP2**	170	7	1
	BTR70	2	180	0
	T72	24	9	195

Çizelge 4: AR modelleme algoritması için sınıflandırma sonuçları (%) (dar bantlı verilere sahip olunduğu durumda)

Modelleme Seviyesi / Alt Matris Boyutu	**MUSIC**	**Özbağlanımlı (AR)**	**Özbağlanımlı-SVD Çözümü**	**Özbağlanımlı-Seyrek Çözümü**	
				λ: 0.5	**λ: 4**
8	73.8	72.1	70.7	72.6	76.5
10	71.3	72.6	70.7	73.1	72.1
12	69.4	70.6	68.4	70.8	70.2

Çizelge 5: Farklı Yöntemlere Göre ve değişken parametre setlerine göre en iyi radar hedef sınıflandırma sonuçları (%) (dar bantlı veriler için)

Yöntem	Parametreler	Sonuç (%)
FFT	-	72.1
MUSIC	Alt Matris Boyut: 8	73.8
AR	Modelleme Seviyesi: 10	72.6
AR-SVD	Modelleme Seviyesi: 8 ve 10	70.7
Seyrek AR	Modelleme Seviyesi: 8; λ=4	76.5

Çizelge 6: Hedef sınıflandırma başarıları karmaşıklık matrisi (dar bantlı verilere sahip olunduğu durumda)

		BMP2	**BTR70**	**T72**
FFT	**BMP2**	121	28	33
	BTR70	20	142	2
	T72	55	26	161
MUSIC	**BMP2**	134	33	31
	BTR70	31	142	7
	T72	31	21	158
AR	**BMP2**	128	36	28
	BTR70	22	136	5
	T72	46	24	163
AR-SVD	**BMP2**	117	41	28
	BTR70	30	135	4
	T72	49	20	164
Seyrek-AR	**BMP2**	138	30	23
	BTR70	22	143	4
	T72	36	23	169

Burada dikkat edilmesi gereken önemli bir nokta ise bu çalışmada önerilen özbağlanımlı katsayılarının kestirilmesini sağlayan yöntem olan seyrek özbağlanımlı

modellemenin sınıflandırmaya nasıl etki ettiği konusudur. Dar bantlı verilerde, diğer spektral kestirim yöntemleri ile elde edilen görüntülerde sahte saçıcı problemi ve/veya radar hedef görüntüsünde önemli bozulmalar görünmektedir; seyrek özbağlanımlı yöntemde ise sahte saçıcılar (gürültü saçıcıları) bastırılırken radar hedef görüntüsü de önemli oranda korunmaktadır (bknz. **Şekil 2.45**). Seyrek özbağlanımlı modelleme yönteminin başarısı sınıflandırma açısından da deneysel olarak test edilmiştir. Önerilen yöntemin Çizelge 4'de gösterilen tüm modelleme seviyelerinde diğer yöntemlere göre daha başarılı olduğu görülmektedir.

Çizelge 6'da BMP2, BTR70 ve T72 hedeflerinin dar bantlı veriler ile elde edilen görüntüleri için sınıflandırma başarıları sergilenmektedir. Yine en başarılı sınıflandırma sonucu T72 hedefi, en kötü sınıflandırma sonucu ise BMP2 hedefi için elde edilmiştir.

4. SONUÇ VE ÖNERİLER

Sentetik açıklıklı radarlar ile yeterince geniş frekans aralığında ve açısal sektörde veri toplanabildiği durumlarda Fourier dönüşümüne dayalı radar hedef görüntüleme yönteminin önemli bir dezavantajı yoktur; hatta FFT kullanımı ile işlem yükü açısından avantaj sağlanmaktadır. Fakat pratikte bu çok mümkün olmamakta, dar frekans bantlarında ve açısal sektörlerde çalışmak gerekmektedir. Bu probleme çözüm getirmek amacıyla radar hedef görüntüleme için yüksek çözünürlüklü spektral kestirim yöntemleri kullanılmıştır. MUSIC algoritması ile radar hedef görüntülemede gürültü saçıcıları başarılı bir şekilde bastırılmasına rağmen veri toplanan frekans bandı ve açı sektörü daraldıkça radar hedef görüntüsünde bozulmaların önemli ölçüde arttığı görülmüştür. Özbağlanımlı (AR) modellemede ise dar frekans bandı ve açısal sektörde hedef radar görüntüsü korunsa da çok sayıda sahte saçıcılar oluştuğundan görüntüde hedef ile arka plan ayrımı zorlaşmaktadır. Özbağlanımlı modellemede sahte saçıcıların bastırılması amacıyla tekil değer ayrışımı (singular value decomposition-SVD) kullanılmıştır. Bu yöntem özbağlanımlı modelleme ile elde edilen radar hedef görüntüsünde sahte saçıcıları bastırmayı başarsa da radar hedef görüntüsünde veri kaybını engelleyememiştir. Bu çalışma kapsamında önerdiğimiz seyrek özbağlanımlı (sparse AR) modelleme yönteminde ise veriler dar frekans bandı ve açısal sektörde toplansa dahi sahte saçıcıların başarılı bir şekilde bastırıldığı ve ayrıca bu işlemi yaparken görüntülenmesi amaçlanan hedefin görüntüsünde oluşabilecek bozulmayı önemli ölçüde engellediği görülmüştür.

MUSIC yönteminde ve özbağlanımlı modelleme yönteminin tekil değer ayrışımı (SVD) çözümünde görüntüleme başarısı saçıcı sayısı kestirimine önemli ölçüde bağlıdır. Bu çalışma kapsamında özgün bir saçıcı sayısı kestirim algoritması da sunulmuştur. İlgili algoritma ile radar hedef görüntülerinin başarılı bir şekilde elde edildiği gösterilmiştir. Diğer yandan yeni önerdiğimiz seyrek özbağlanımlı (sparse-AR) yönteminde saçıcı sayısı kestirimine ihtiyaç bulunmamaktadır.

Bu çalışmada sınıflandırma başarısının ölçümü için BMP2 ve T72 tankları ve BTR70 askeri nakliye aracının saçıcı alanlarından elde edilen ham verileri

kullanılmıştır. Bu veriler "Movingand Stationary Target Acquisition and Recognition (MSTAR)" programı kapsamında toplanmıştır. FFT, MUSIC ve özbağlanımlı (AR) modelleme algoritmalarının sınıflandırma başarıları incelenmiştir. Geniş frekans bant genişliğinde ve açısal sektörde yöntemler arasında sınıflandırma başarısı açısından önemli bir fark oluşmadığı görülmüştür. İkinci aşamada ise frekans bant genişliği ve açısal sektör daraltılarak verinin (dokümanda "dar bantlı veri" şeklinde ifade edilmektedir) çözünürlüğü düşürülmüştür. Bu durumda yeni önerdiğimiz seyrek özbağlanımlı (sparse AR) modelleme yönteminin geleneksel olarak kullanılan FFT, MUSIC ve özbağlanımlı (AR) modelleme algoritmalarına göre daha başarılı olduğu görülmüştür.

Bu çalışma sırasında kullanılan yüksek çözünürlüklü spektral kestirim yöntemleri kendi içlerinde de farklı sınıflandırma başarıları sergilediği görülmüştür. MUSIC'te alt matris boyutu; özbağlanımlı (AR) modellemede modelleme seviyesi ve seyrek özbağlanımlı modelleme yöntemi için λ parametreleri değiştikçe sınıflandırma başarısı değişmektedir.

Bu çalışmada kullanılan sınıflandırma yaklaşımında öznitelik vektörleri SAR hedef görüntüsünün içerdiği özellikleri en etkin şekilde kullanmak üzere tasarlanmıştır. Bu sebeple her türlü SAR görüntüsüne uygulanabilir. Yöntemde elde edilen öznitelik vektörleri k-means algoritması kullanılarak sınıflandırma işlemine tabi tutulmuştur.

Bu çalışma kapsamında 2-B seyrek özbağlanımlı (sparse AR) modelleme yöntemi ile radar hedef görüntüleme ve sınıflandırmada iyileştirmeler sağlanmıştır. Seyrekleştirme işlemleri ciddi işlem yüküne sahiptir. İşlem yükünü azaltılması için ileri çalışma olarak bu işlemlerin bir boyutta yapılması hedeflenebilir. Ayrıca seyrek özbağlanımlı yönteminde λ parametresinin otomatik belirlenebilmesi yöntemi daha pratik hale getirecektir.

KAYNAKLAR

[1] Gracobello, D., Christensen, M. G., Murthi, M.N., Jensen, S.H., Moonene, M., (2012). *Sparse linear prediction and its applications to speech processing*, IEEE Trans on Audio Speech and LanguageProcessing, Vol. 20, No.5.

[2] Odendaal, J. W., Bernard, E. ve Pistorius, C. W. I. (1994). *Two-Dimensional superresolution radar imaging using the MUSIC algorithm*, IEEE Transactions on Antennas and Propagation, Vol. 42, No. 10.

[3] Gupta, I. J. (1994). *High resolution radar imaging using 2-D linear prediction,* IEEE transactions on antennas and proragation, Vol. 42.

[4] Resenbach, K. and Schiller, J., (1995). *Identification of aircraft on the basis of 2-D radar images*, IEEE Int. Radar Conf. Record, 405–409.

[5] Park, J. I. ve Kim, K. T. (2010). *A comparative study on ISAR imaging algorithms for radar target identification*, Progress in Electromagnetics Research, Vol. 108, 155-175.

[6] Deliormanlı, S. (2009). *Yapay açıklık radar ham verilerinden görüntü oluşturulması*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.

[7] Özdemir, C. (2012). *Inverse synthetic aperture radar imaging with Matlab algorithms*, Wiley, pp. 107

[8] Walton E. ve Moghaddar A. (1991). *High resolution imaging of radar targets using narrow band data,* IEEE AP Soc. Int. Symp., Londra.

[9] Mensa, D.L. (1991). *High resolution radar cross section imaging,* Artech House

[10] Erer, I., Kent, S. and Kartal M. (2008). *High resolution radar imaging from incomplete data*, RADAR ’08. IEEE Radar Conference.

[11] Degraff, S. R., (1998). *SAR imaging via modern 2-D spectral estimation methods,* IEEE Transactions on Image Procesing , Vol. 7, No. 5.

[12] Yamada, H., Ohmiya, M., Ogawa, Y. ve Itoh, K. (1991). *Superresolution techniques for time-domain measurements with a network analyzer,* IEEE Trans. Antennas Propagat., vol. 39, pp. 177–183.

[13] Radoi, E., Quinquis, F. T., Pellen, F. (2004). *Automatic radar target recognition using superresolution MUSIC 2D images and self-organizing neural network,* matrix, 2 (1).

[14] Kim, K. T., Seo, D. K., Kim H. T. (2002). *Efficient radar target recognition using MUSIC algorithm and invariant features,* IEEE Transaction on antennas and propagation, vol.50, no.3

[15] Ulrych, T.J. and Clayton R.W. (1976). *Time series modelling and maximum entropy.* Phys. Earth Planet Int., vol. 12, pp.188-200

[16] Carriere, R. and Moses, R. L. (1992). *High resolution target modelling using a modified Pony estimator,* IEEE Trans. Antennas Propagat., vol. 40, pp. 13-18.

[17] Tufts, D. W. and Kumaresan, R. (1982). *Estimation of frequencies of multiple sinusoids: Making linear prediction perform like maximum likelihood,* Proc. IEEE, vol. 70, pp. 975-989.

[18] Wax, M. ve Kailath, T. (1985). *Detection of signals by information theoretical criteria,* IEEE Trans. Acoust., Speech, Signal Processing, vol. ASSP-33, pp. 387-392.

[19] Wax, M. and Ziskind I. (1989). *Detection of the number of the coherent signals by the MDL Principle,* IEEE Trans. Acoust., Speech, Signal Processing, vol. 37, pp. 1190-1196.

[20] Hansen, P. C., O'leary, D. P. (1993). *The use of the L-curve in the regularization of discrete ill-posed problems,* SIAM on Sci. Comp., Vol. 14, No. 6, 1478-1503.

[21] Reed, T. R. and Buf, J. M. H., (1993). *A review of recent texture segmentation and feature extraction techniques,* CVGIP: Image Understanding, 57, 359-372.

[22] Park, S.H., and Kim, K.T., (2010). *Segmantation of ISAR images of targets moving in formation,* IEEE Trans.Antennas and Propag., 48, 2099- 2108.

[23] Kim, K. T., Seo, D. K., and Kim, H. T., (2005). *Efficient classification of ISAR images,* IEEE Trans. Antennas Propag., 53, 1611-1621.

[24] Park, S.H., Kim, H.T., and Kim, K. T., (2011)**.** *Cross-Range scaling algorithm for ISAR images using 2-D Fourier transform and polar mapping,* IEEE Trans. Antennas and Propag., 49, 868 – 877.

[25] Li, H. J., and Yang, S. H., (1993). *Using range profiles as feature vectors to identify aerospace objects,* IEEE Trans. Antennas Propag., 41,261–268.

[26] Abujarad, F., G. Nadim, and A. Omar, (2007). *Ground penetrating radar signal processing for landmine detection,* Diss. Otto-von-Guericke-Universität Magdeburg, Universitätsbibliothek.

[27] Petersen, M. E., de Ridder, D., and Handels, H., (2002). *Image processing with neural networks—a review,* Pattern Recognition, 35, 2279–2301.

[28] Fukunaga, K., (1990). *Introduction to statistical pattern recognition,* Academic, New York.

[29] Duda, R. O., Hart, P. E., and Stork, D. G., (2001). *Pattern classification,* 2nd ed. Wiley, New York.

[30] MacQueen, J., (1967). *Some methods for classification and analysis of multi-variate observations.*, Proc. of the Fifth Berkeley Symp. on Math., Statistics and Probability, Berkeley, 281.

[31] Berkhin, P., (2002). *Survey of clustering data mining techniques,* Accrue Software Inc., San Jose, California, USA

EK: Radar Hedef Görüntülerinin Dinamik Alan Değerleri (BMP-2 Hedefi için)

Çizelge 7: Farklı radar görüntüleme algoritmaları için dinamik alan sonuçları (dB) (64x64 boyutunda geniş bantlı veriler için)

Modelleme Seviyesi	MUSIC	Özbağlanımlı (AR)	Özbağlanımlı-SVD
5	59.6	55.9	39.9
8	58.3	68.1	49.2
10	58.3	62.3	40.2
15	57.2	61.3	44.1
20	56.5	74.9	39.8

Çizelge 8: Farklı radar görüntüleme algoritmaları için dinamik alan sonuçları (dB) (32x32 boyutunda daraltılmış bantlı veriler için)

Modelleme Seviyesi	MUSIC	Özbağlanımlı (AR)	Özbağlanımlı-SVD
5	56.0	57.2	52.1
8	58.5	50.7	39.4
10	56.3	51.2	54.2
12	53.5	59.2	44.3

ÖZGEÇMİŞ

Ad Soyad: Koray SARIKAYA

Doğum Yeri ve Tarihi: POLATLI, 17.10.1987

E-Posta: sarikaya_koray@hotmail.com; ksarikaya@aselsan.com.tr

Lisans: İTÜ (2005-2009)

Mesleki Deneyim ve Ödüller: 4,5 yıldır ASELSAN A.Ş. firmasında çalışmaktadır.