

Seyreklik GÜdümlü Doğrusal Öngörü ile Yüksek Çözünürlüklü Radar Görüntüleme

High Resolution Radar Imaging with Sparsity Driven Linear Prediction

Koray Sarıkaya¹, Haldun Bozkurt², Işın Erer²

¹ASELSAN A.Ş. Radar Elektronik Harp ve İstihbarat Sistemleri, Ankara
ksarikaya@aselsan.com.tr

²Elektronik ve Haberleşme Mühendisliği Bölümü, İstanbul Teknik Üniversitesi, İstanbul
ierer@itu.edu.tr, bozkurtha@itu.edu.tr

Öz

2B doğrusal öngörü temelli ISAR görüntüleme 2B AR katsayıların eldesi için l_2 norm minimizasyonunu kullanır. Fakat bu yöntem sonuç görüntüde yalancı tepelerin oluşmasına neden olur. AR katsayılarına TDA kesmesinin uygulanmasının başarımlı saçıcı sayısının kestirimine bağlıdır. Saçıcı sayısının yanlış kestirimi bazı saçıcıların kestirilememesine ya da yan lobların etkin şekilde indirgenememesine neden olur. Bu çalışmada, seyreklik regülarizasyonlu AR modeller sunulmuş ve yüksek çözünürlüklü radar görüntüleme problemine uygulanmıştır. Seyreklik öncelinin kullanılmasıyla AR katsayı vektörü seyrek olmaya zorlanmıştır. Elde edilen seyrek katsayı vektörünün kullanılmasıyla hedefin geri plandan daha kolay ayırt edilmesine olanak veren yan lobları indirgenmiş radar görüntüleri elde edilmiştir. Önerilen yöntem dar band-dar açı durumunda da başarıyla çalışmaktadır. Önerilen seyrek AR modeller radar görüntüleme nin yanısıra ISAR görüntülerin sınıflandırılmasına da uygulanmıştır. Sonuçlar önerilen yöntemin diğer AR temelli yöntemlere göre daha yüksek başarımlıya sahip olduğunu göstermektedir.

Anahtar Kelimeler: Radar görüntüleme, doğrusal öngörü, özbağlanımlı modelleme, seyrek gösterimler, regularization.

Abstract

ISAR imaging based on the 2D linear prediction uses the l_2 norm minimization of the prediction error to obtain 2D AR model coefficients. However, this approach causes many spurious peaks in the resulting image. SVD truncation of AR coefficients depends on the choice of scattering coefficients and a wrong choice may cause underestimation of scattering centers or inefficient suppression of sidelobes. In this study, we present sparsity regularized AR models and apply them to the problem of high resolution radar imaging. 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. The proposed sparse AR models have been applied to the ISAR imaging problem as well as classification of ISAR images. The results show that the proposed method has higher performance compared to the other AR based methods.

Keywords: Radar imaging, linear prediction, autoregressive modeling, sparse representations, regularizasyon.

1. Giriş

Ters yapay açıklıklı radar (ISAR) görüntüleme kullanılan geleneksel yöntem hızlı ve işlem maliyetinin düşük olması nedeniyle 2 boyutlu Fourier dönüşümüne dayanan polar format algoritmasıdır [1]. Radar görüntüleme 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 yöntemlerinden Multiple Signal Classification (MUSIC) ve özbağlanımlı (autoregressive, AR) modelleme metodları kullanılmıştır [2-6]. MUSIC metodu verinin özilişki matrisinin sinyale ve gürültü özvektörlerinin dikliğine dayanmaktadır [4]. AR modelleme ise 2-boyutlu kartezyen frekans spektrumunun 2-boyutlu doğrusal kestirimine dayanmaktadır [2].

MUSIC algoritması ile yüksek çözünürlüklü radar görüntüleri elde edilebilmesine rağmen, veri toplanan frekans bandı ve açı sektörü daraldıkça radar hedef görüntüsünde bozulmalar önemli ölçüde artmaktadır. AR modellemede ise dar frekans bandı ve açılal sektörde hedef radar görüntüsü korunsun da çok sayıda sahte saçıcılar olduğundan görüntüde hedef ile arka plan ayrımı zorlaşmaktadır. AR modellemede sahte saçıcıların bastırılması amacıyla tekil değer ayrışımı (TDA) kullanılır. Bu yöntem özbağlanımlı modelleme ile elde edilen radar hedef görüntüsünde sahte saçıcıları bastırmayı başarsa da radar hedef görüntüsünde veri kaybını engelleyememektedir [2].

MUSIC yönteminde ve AR-TDA ile çözümünde görüntüleme başarımlı saçıcı sayısı kestirimine önemli ölçüde bağlıdır [2].

Bu çalışmada regularizasyon yöntemleri AR modelleme ile gerçekleştirilerek seyrek AR modeller oluşturularak, ISAR görüntülemeye uygulanacak ve varolan AR model temelli yöntemlere göre arka planı daha temiz olan yüksek çözünürlüklü görüntüleri elde edilecektir. Regularizasyon yöntemleri kötü koşullanmış (ill-posed) problemlerde ek olarak yumuşatma ya da seyrek-

lik (sparsity) bilgilerini probleme katarak alternatif çözümler sağlamaktadır [7]. En eski yöntemlerden biri olan Tichonov regülarizasyonunda ceza terimi olarak bilinmeyen vektörünün l_2 normu kullanılmaktadır. l_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 l_0 norm ceza fonksiyonu (penalty function) kullanan seyreklik önceli (sparsity prior) regülarizasyon yöntemleri bir çok uygulamada kullanılmaktadır. l_0 norm minimizasyonu NP zor problem (NP hard problem) olduğundan cezalandırma fonksiyonu olarak l_1 norm kullanılır ve bu yöntemle l_0 normunun çözümüne yaklaşılr. Ceza terimi olarak kullanılan l_1 normu ile az sayıda sıfırdan farklı katsayı içeren sonuçlar üretilmektedir. l_1 norm ceza terimi içeren regülarizasyon problemleri türevlenebilir (differentiable) değildir ve l_2 norm durumundan farklı olarak bir kapalı form çözümüne sahip değildir. Diğer yandan bu problemler konveks kuadratik problemlere dönüştürülebilir ve konveks optimizasyon yöntemleriyle çözülebilirler [7].

Çalışmanın ikinci bölümünde doğrusal öngörü ile ISAR görüntüleme problemi ana hatlarıyla tanıtmış, üçüncü bölümde önerilen seyreklik güdümlü ISAR görüntüleme yöntemi verilmiş, 4. bölümde ise radar görüntüleri ve sınıflama sonuçları sunulmuştur. Son bölümde ise çalışma sonuçlarıyla ilgili değerlendirmeler yer almaktadır.

2. Doğrusal Öngörü ile ISAR Görüntüleme

d adet saçıcıdan oluşan bir hedeften geri yansıyan işaret f_m frekans ve θ_n ($n = 0, 1, \dots, N - 1$, $m = 0, 1, \dots, M - 1$) bakış açısı olmak üzere,

$$E(f_m, \theta_n) = u(f_m, \theta_n) + \sum_{k=1}^d a_k \exp\left(-j \frac{4\pi f_m}{c} (x_k \cos \theta_n + y_k \sin \theta_n)\right) \quad (1)$$

şeklinde verilir [2]. Burada a_k, x_k, y_k sırasıyla k . saçıcı merkezin şiddetine ve koordinatlarına karşı gelmektedir.

$u(f_m, \theta_n)$ 0 ortalamalı ve σ^2 varyanslı beyaz Gauss gürültüsüdür ve c ışık hızıdır. Odaklanmış bir ISAR görüntüsü elde etmek için, (1) ile verilen frekans-açı verisi $y(f_m, \theta_n)$

$$f_x = \frac{2f}{c} \cos \theta \quad (2)$$

Ve

$$f_y = \frac{2f}{c} \sin \theta \quad (3)$$

dönüşümleri kullanılarak konumsal frekans uzayına geçirilir ve aşağıdaki gibi gösterilebilir:

$$E(m, n) = \sum_{k=1}^d a_k \exp\left(-j2\pi (x_k f_x(m) + y_k f_y(n))\right) + u(m, n) \quad (4)$$

$$\begin{aligned} f_x(m) &= f_x(0) + m\Delta f_x & m &= 1, 2, \dots, M \\ f_y(n) &= f_y(0) + n\Delta f_y & n &= 1, 2, \dots, N \end{aligned}$$

Burada $f_x(0)$ ve $f_y(0)$ sırasıyla f_x ve f_y nin başlangıç değerlerine karşılık gelmektedir. M ve N değerleri konumsal frekans uzayındaki örnek değerleridir, $M = N$ alınarak (4) ile verilen konumsal frekans uzayındaki geri saçılan alan verisi 2B doğrusal öngörü kullanılarak aşağıdaki gibi modellenilebilir:

$$\hat{E}(l, n) = - \sum_{i=0}^L \sum_{j=0}^L a_{ij} E(l - i, n - j) \quad (5)$$

$$i = j \neq 0$$

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

Buradaki a_{ij} bilinmeyen katsayıları ifade etmektedir. Denklem (5) 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:

$$\hat{E}(l, n) = - \sum_{i=0}^L \sum_{j=0}^L \tilde{a}_{ij} E(l + i, n + j) \quad (6)$$

$$i = j \neq 0$$

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

Burada \tilde{a}_{ij} bilinmeyen katsayılarıdır. [2]'de gösterildiği üzere $\tilde{a}_{ij} = a^*_{ij}$. Dolayısıyla (6) şu şekilde yazılabilir:

$$\hat{E}^*(l, n) = - \sum_{i=0}^L \sum_{j=0}^L a_{ij} E^*(l + i, n + j) \quad (7)$$

$$i = j \neq 0$$

Eğer [2]'de bahsedilen bu kestirim doğru ise $\hat{E}(l, n) = E(l, n)$ olacaktır. (5) ve (7) 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 (5) ve (7) matris notasyonu ile şu şekilde sunulabilir:

$$\mathbf{E}\mathbf{a} = -\mathbf{e} \quad (8)$$

Burada \mathbf{E} , $2(N - L)^2$ 'e $(L + 1)^2 - 1$ 'lik bir matristir. \mathbf{a} , $(L + 1)^2 - 1$ uzunluğunda bir vektördür. \mathbf{e} , $2(N - L)^2$ uzunluğunda bir vektördür. (7)'nin en küçük kareler çözümü şu şekildedir:

$$\mathbf{a} = -(\mathbf{E}^H\mathbf{E})^{-1}\mathbf{E}^H\mathbf{e} \quad (9)$$

Buradaki H eşlenik evrik alma işlemini 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 de 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:

$$\hat{E}(l, n) = - \sum_{i=0}^L \sum_{j=0}^L b_{ij} E(l - i, n + j) \quad (10)$$

$i = j \neq 0$

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

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

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

$$\hat{E}^*(l, n) = - \sum_{i=0}^L b_{ij} E^*(l + i, n - j) \quad (11)$$

$i = j \neq 0$

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

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

(10) ve (11) kullanılarak denklemler çözülebilir ve b_{ij} katsayıları tespit edilebilir. Matris formunda formüller şu şekilde düzenlenebilir:

$$\tilde{\mathbf{E}}\mathbf{b} = -\tilde{\mathbf{e}} \quad (12)$$

Burada $\tilde{\mathbf{E}}$, $2(N - L)^2$ 'e $(L + 1)^2 - 1$ 'lik bir matristir. \mathbf{b} , $(L + 1)^2 - 1$ uzunluğunda bir vektördür. $\tilde{\mathbf{e}}$ ise $2(N - L)^2$ uzunluğunda bir vektördür. \mathbf{b} katsayıları (9) da verildiği gibi en küçük kareler çözümünden bulunur.

Saçıcı merkezlerin konumlarına karşı gelen radar görüntüsü $P(x, y)$ tepe noktalarından bulunur.

$$P(x, y) = \frac{1}{|1 + \sum_{i=0}^L \sum_{j=0}^L a_{ij} z_1^{-i} z_2^{-j}|^2 + |1 + \sum_{i=0}^L \sum_{j=0}^L b_{ij} z_1^{-i} z_2^{-j}|^2} \quad (13)$$

$$i = j \neq 0$$

Burada $z_1 = \exp(j \frac{4\pi}{c} \Delta f_x x)$, $z_2 = \exp(j \frac{4\pi}{c} \Delta f_y y)$ şeklinde seçilir ve görüntülenecek bölgenin genişliği $-\frac{c}{4\Delta f} < x, y < \frac{c}{4\Delta f}$ ile verilir.

3. Önerilen Seyreklik GÜdümlü Görüntüleme Algoritması

1-B özbağlanımlı (AR) modelleme kullanılarak 1B işaret örnekleri geçmiş örneklerin lineer kombinasyonu şeklinde tanımlanabilir [7].

$$x(n) = \sum_{k=1}^K a_k x(n - k) + e(n) \quad (14)$$

Burada $\{a_k\}$ özbağlanımlı model katsayılarına, $e(n)$ ise beyaz Gauss gürültüsüne karşı gelmektedir. [7]'de model katsayılarının kestirimi problemi, gözlemlenen gerçek $x(n)$ örnekleri kümesinden, $n=1, 2, \dots, N$ olacak şekilde, katsayı vektörlerini hatayı minimize edecek şekilde kestirebilecek bir optimizasyon problemi olarak ele almaktadırlar.

$\hat{\mathbf{e}} = \mathbf{x} - \mathbf{X}\hat{\mathbf{a}}$ vektörü genel olarak \mathbf{e} 'nin kestirimi olan kalıntıyı (residual) ifade eder. Bu kalıntı vektörü aşağıdaki minimizasyon probleminin sonucu olan $\hat{\mathbf{a}}$ 'nın kestiriminden elde edilir [4].

$$\min_{\mathbf{a}} \|\mathbf{x} - \mathbf{X}\mathbf{a}\|_p^p + \lambda \|\mathbf{a}\|_k^k \quad (15)$$

Burada,

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

ve $\|\cdot\|_p$ l_p normunu ifade etmektedir. l_p

$$\|\mathbf{x}\|_p = (\sum_{n=1}^N |x(n)|^p)^{1/p}, p \geq 1 \text{ için,}$$

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 götürecektir.

Benzer şekilde 2-B seyrek özbağlanımlı modelleri oluşturmak için (8) ve (12) denklemleri aşağıdaki gibi modellenerek,

$$\mathbf{e}_{1-3} = \mathbf{E}\mathbf{a} + \mathbf{e} \quad (16)$$

$$(17)$$

$$\mathbf{e}_{2-4} = \tilde{\mathbf{E}}\mathbf{b} + \tilde{\mathbf{e}}$$

kestirim hata vektörleri oluşturulur.

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:

$$\mathbf{a} = \min_{\mathbf{a}} \|\mathbf{e}_{1-3}\|_2^2 + \lambda \|\mathbf{a}\|_k^k = \min_{\mathbf{a}} \|\mathbf{E}\mathbf{a} + \mathbf{e}\|_2^2 + \lambda \|\mathbf{a}\|_k^k \quad (18)$$

$$\begin{aligned} \mathbf{b} &= \min_{\mathbf{b}} \|\mathbf{e}_{2-4}\|_2^2 + \lambda \|\mathbf{b}\|_k^k \\ &= \min_{\mathbf{b}} \|\tilde{\mathbf{E}}\mathbf{b} + \tilde{\mathbf{e}}\|_2^2 + \lambda \|\mathbf{b}\|_k^k \end{aligned} \quad (19)$$

$p = 2$ ve $\lambda = 0$ olarak seçildiğinde sonuç klasik en küçük kareler çözümü olmaktadır ve (9) ile elde edilen sonucu vermektedir. l_2 minimizasyon yaklaşımının bazı sıkıntıları vardır, özellikle yüksek mertebelerde TDA kullanımını gerektiren birçok istenmeyen tepelerinin görünmesine sebep olur. Bunun yerine, $p = 2$ ve $k = 2$ seçilerek Tykhonov tipi regülarizasyon çözümü kullanılabilir,

$$\mathbf{a} = \min_{\mathbf{a}} \|\mathbf{E}\mathbf{a} + \mathbf{e}\|_2^2 + \lambda \|\mathbf{a}\|_2^2 \quad (20)$$

$$\mathbf{b} = \min_{\mathbf{b}} \|\tilde{\mathbf{E}}\mathbf{b} + \tilde{\mathbf{e}}\|_2^2 + \lambda \|\mathbf{b}\|_2^2 \quad (21)$$

Bu ifadeler kapalı formda şu şekilde ifade edilebilir:

$$\mathbf{a} = -(\mathbf{E}^H \mathbf{E} + \lambda \mathbf{I})^{-1} \mathbf{E}^H \mathbf{e} \quad (22)$$

Farklı bir çözüm olarak l_1 norm içeren ceza terimi kullanılarak aşağıda verilen ve katsayıların seyrek olarak elde edildiği bir çözüm bulunabilir,

$$\mathbf{a} = \min_{\mathbf{a}} \|\mathbf{E}\mathbf{a} + \mathbf{e}\|_2^2 + \lambda \|\mathbf{a}\|_1 \quad (23)$$

$$(24)$$

$$\mathbf{b} = \min_{\mathbf{b}} \|\tilde{\mathbf{E}}\mathbf{b} + \tilde{\mathbf{e}}\|_2^2 + \lambda \|\mathbf{b}\|_1$$

Cvx optimizasyon paketi [8] kullanılarak denklem (20), (21), (23) ve (24)'de tanımlanan minimizasyon problemleri efektif bir şekilde çözülebilir.

Regülarizasyon parametresi olan λ , kestirimcinin (AR katsayı vektörü) seyrekliği ile kalıntı teriminin l_2 normunun minimizasyonunun arasındaki ödünleşimi (trade-off) kontrol etmektedir. λ ceza terimi parametresinin sonuçlar üzerine etkisi önemli boyuttadır. Parametrenin düşük seçilmesi durumunda sonuç l_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 [9]. L-curve yönteminde farklı λ parametreleri için elde edilen çözümlerin normlarının, $\|\mathbf{a}\|_k^k$, logaritmaları kalıntı işaretinin normunun, $\|\mathbf{E}\mathbf{a} + \mathbf{e}\|_p^p$, logaritmasına bağlı olarak çizilir. Elde edilen eğri L harfine benzediği için bu yöntem L-curve yöntemi denmektedir. Optimum λ parametresi L'nin dirseğinde yer alan noktadaki değer olarak tespit edilir [9].

4. Deneysel Sonuçlar

Önerilen seyreklik güdümlü yöntem, mig25 verisine [10] uygulanarak radar görüntüleri elde edilmiştir.


Şekil 4.1'de gösterilen Mig-25 hedefi için elde edilen polar format algoritması, MUSIC, AR modelleme, AR-SVD, önerilen seyreklik güdümlü özbağlanımlı (seyrek AR) modelleme sonuçları sırasıyla gösterilmektedir. Verinin boyutları 64×64 , merkez frekansı $f_c = 9 \text{ GHz}$, band genişliği $B = 531 \text{ MHz}$ ve gözlem açısı aralığı $\Omega = 3.67^\circ$ dir. İşaret gürültü oranı $\text{SNR} = 30 \text{ dB}$ olacak şekilde toplamsal beyaz Gauss gürültüsü eklenmiştir.

Şekil 4.1-a'da gösterilen "Polar Format" algoritması sonucu beklendiği gibi yüksek genlikli yan loblar içermektedir.


MUSIC algoritması sonucunda yan lobların azaldığı, çözünürlüğün de yükseldiği görülmektedir. AR modelleme sonuçlarında ise arka plandaki yan lobların bozucu etkisi gözlemlenmektedir. AR-TDA yönteminin performansı sadece saçıcı sayısının kestirimine bağlıdır. Saçıcı sayısının gereğinden düşük seçilmesi durumunda arka plandaki yan loblar yeterince temizlenememekte, büyük seçilmesi durumunda ise varolan saçıcıların tamamının kestirilememesine sebep olmaktadır. Önerilen yöntemin klasik AR modelleme yöntemine göre daha temiz arka plana sahip görüntüler oluşturduğu Şekil 4.1-e'den görülmektedir. l_1 norm ceza teriminin kullanılması yalancı saçıcı sayısını azaltmış, daha temiz bir arka plan oluşturmuştur ve saçıcıların belirginliğini arttırmıştır. Ancak yöntemin performansı MUSIC yönteminin arkasında kalmaktadır. (22) ile verilen l_2 ceza teriminin kullanılması ise yan lobları yeterince indirgeyemediğinden sonuçlara dahil edilmemiştir.

Regülerizasyon parametresinin etkisi Şekil 4.2'de verilmektedir. Parametrenin küçük seçimi durumunda radar görüntüleri l_2 norm çözümüne, büyük seçimi ise düşük çözünürlüklü görüntüler elde edilmesine neden olmaktadır.


Dar bantlı data kullanımını etkisini gözlemleyebilmek için veri boyutları 32×32 'ye indirilmiş ve beklendiği gibi tüm yöntemlerin çözünürlüğünün azaldığı Şekil 4.3'de gözlemlenmiştir. 64×64 (geniş band) veri için en iyi sonucu veren MUSIC yöntemi, 32×32 (dar band) veri için Şekil 4.3-c'de görüldüğü gibi özellikle uçağın kuyruk bölgesinde ayrıntıları tamamen kaybetmektedir. AR modelleme temelli yöntemler kendi aralarında karşılaştırıldıklarında en iyi sonucun önerilen yöntemle elde edildiği görülmektedir. Arka plandaki yan loblar l_2 norm çözümüne göre azalmıştır. AR-TDA sonucunda ise seçilen sayısı için yan lobların yeterince temizlenemediği, buna karşın hedefin de yeterince modellenemediği görülmektedir.



Şekil 4.1: 64 x 64 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi: 24): a) Polar format algoritması, b) MUSIC algoritması, c) AR modelleme yöntemi, d) AR-TDA çözümü, e) seyrek AR modelleme yöntemi ($\lambda=0,5$)



Şekil 4.2: 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) $\lambda:0.001$, c) $\lambda: 0.1$, d) $\lambda:0.5$, e) $\lambda: 1$, f) $\lambda: 4$



Şekil 4.3: 32 x 32 veri boyutundaki Mig-25 hedefinin (SNR=30 dB) ISAR görüntüsünün elde edilmesi (alt matris boyutu ve modelleme seviyesi=12): a) Polar format algoritması (64x64 boyutundaki veri ile), b) Polar format algoritması (32x32 boyutundaki daraltılmış veri ile), c) MUSIC algoritması, d) AR modelleme yöntemi, e) AR-TDA çözümü, f) seyrek AR modelleme yöntemi ($\lambda=0,5$)


Tüm benzetimler Intel(R) Core(TM) i7 işlemci, 8 GB RAM, Windows 8 64 bit işletim sistemli bilgisayarda MATLAB 2012a ortamında gerçekleştirilmiştir. Sırasıyla polar format algoritması, MUSIC, AR modelleme, AR-TDA ve seyrek AR modelleme yöntemi 1.3 sn, 3.02 sn, 2.3 sn, 2.15 sn ve 48.23 sn sürmektedir. Her ne kadar seyrek AR modelleme yöntemi diğerlerine göre uzun sürüyor olsa da CVX yerine karmaşıklığı daha az olan OMP (Dikgen Eşleştirme Takibi) [11] gibi yöntemler kullanılarak süre MUSIC ve AR modelleme gibi bilinen spektral kestirim temelli radar görüntüleme yöntemleri mertebesine çekilebilmektedir.

Yöntemlerin performanslarını daha iyi karşılaştırmak amacıyla tüm yöntemler [12]'de verilen sınıflama algoritmasıyla MSTAR verilerinin [13] sınıflandırılmasında kullanılmıştır. MSTAR verileri Sandia National Laboratory (SNL) tarafından 1995 yılında, hareketli ve sabit hedef elde etme ve tanıma (Moving and 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. Her bir 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). Polar format, MUSIC, AR modelleme ve çalışma kapsamında önerdiğimiz seyrek AR modelleme algoritmalarının sınıflandırma başarıları incelenmiştir. İkinci aşamada ise frekans bant genişliği ve açılal sektör daraltılarak verinin (dokümanda "dar bantlı veri" şeklinde ifade edilmektedir) çözünürlüğü düşürülmüş ve bu durumda polar format, MUSIC, AR modelleme ve seyrek AR modelleme algoritmalarının sınıflandırmadaki başarısı incelenmiştir.



Şekil 4.4: MSTAR hedeflerinin gerçek görüntüleri [14]



Şekil 4.5: MSTAR hedeflerinin ISAR görüntüleri a) BMP2, b) BTR70, c) T72


4.1.2 Boyutlu ISAR Sınıflama Algoritması

Şekil 4.6'da aşamaları verilen sınıflama algoritması aşağıdaki gibi özetlenebilir [12]:

1. ISAR görüntü uzayından kutupsal koordinatlara (r, θ) geçilerek, kutupsal görüntü $I_p(r, \theta)$ oluşturulur.
2. PCA kullanılarak kutupsal görüntülerin boyutu düşürülür.
3. Ek olarak, kutupsal görüntünün r ve θ eksenlerine ayrı ayrı izdüşümleri $I_p(r)$ ve $I_p(\theta)$ bulunarak öznelik seti oluşturulur.
4. K-en yakın komşu (k-NN) algoritması kullanılarak görüntüler sınıflandırılır.

4.1.1. Geniş Bantlı Veri İçin Sınıflandırma Sonuçları

Farklı görüntüleme yöntemleri kullanılarak ve görüntüleme teknikleri içerisinde yer alan farklı değişken değerleri için sınıflandırma sonuçları elde edilmiştir. Geleneksel polar-format algoritması ile %90.3 başarı sağlanmıştır. Yüksek çözünürlüklü spektral kestirim yöntemleriyle elde edilen görüntülerin sınıflandırma başarıları Tablo 1'de sunulmaktadır.



Şekil 4.6: Kullanılan sınıflama algoritmasının akış diagramı

Tablo 1: Farklı yöntemlere göre ve değişken parametre setlerine göre en iyi radar hedef sınıflandırma sonuçları (%)

Yöntem	Parametreler	Sonuç (%)
Polar Format	-	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

AR modellemede TDA yöntemini kullanmanın, radar hedef görüntüsünü sahte saçıcılardan arındırmasına (yan lobları bastırmasına) rağmen, radar hedef sınıflandırmaya katkı sağlamadığı

görülmektedir. Bunun en önemli sebebi TDA yan lobları bastırırken radar hedefinin de kontrastını daraltmasıdır. Bu da sınıflandırmada istenen iyileştirmeyi sağlamasını engellemektedir. Diğer yandan geniş bantlı veri kullanıldığı durumda seyrek AR modellemenin sınıflandırma başarısına önemli bir katkı sağlamadığı söylenebilir.

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

Tablo 2’de BMP2, BTR70 ve T72 hedeflerinin görüntüleri için sınıflandırma başarıları sergilenmektedir. Tablodan 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 4.5’e bakılırsa bu hatalı sınıflandırmanın iki hedefin birbirine nispeten daha çok benzemesinden kaynaklandığı söylenebilir.

Tablo 2: Hedef sınıflandırma başarıları karmaşıklık matrisi (geniş bantlı verilere sahip olduğu durumda)

Polar Format		BMP2	BTR70	T72
	BMP2		168	13
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

4.1.2. Dar Bantlı Veri İçin 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. Yöntemlerden elde edilen görüntülerin sınıflandırma başarımları

Tablo 3’te sunulmaktadır. Dar bantlı verilerde, diğer spektral kestirim yöntemleri ile elde edilen görüntülerde sahte saçıcı problemi ve/veya radar hedef görüntüsünde önemli bozulmalar görülmektedir; seyrek özbağlanımlı yöntemde ise sahte saçıcılar bastırılırken radar hedef görüntüsü de önemli oranda korunmaktadır. Önerilen yöntemin Tablo 3’de gösterilen tüm modelleme seviyelerinde diğer yöntemlere göre daha başarılı olduğu görülmektedir.

Tablo 4’de 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.

Tablo 3: Farklı Yöntemlere ve değişken parametre setlerine göre en iyi radar hedef sınıflandırma sonuçları (%) (dar bantlı veriler için)

Yöntem	Parametreler	Sonuç (%)
Polar format	-	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; $\lambda=4$	76.5

Tablo 4 : Hedef sınıflandırma başarıları karmaşıklık matrisi (dar bantlı verilere sahip olduğu durumda)

Polar format		BMP2	BTR70	T72
	BMP2		121	28
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

5. Sonuçlar

Bu çalışma kapsamında 2B seyrek AR modeller oluşturularak ISAR görüntüleme probleminde uygulanmıştır. Önerilen yöntem yaygın olarak kullanılan AR temelli yöntemler ve MUSIC yöntemiyle karşılaştırılmış, veriler dar frekans bandı ve açılal sektörde toplansa dahi radar görüntüsündeki sahte saçıcıların başarılı bir şekilde bastırıldığı ve hedefin görüntüsünde oluşabilecek bozulmaların önemli ölçüde engellendiği gösterilmiştir. Ayrıca tüm yöntemlerden elde edilen ISAR görüntüler sınıflandırılarak dar band durumunda en yüksek başarımın önerilen yöntemle elde edildiği ortaya konmuştur. Önümüzdeki dönemde 1B menzil profilleri seyrek AR modellenerek daha az işlem yükü gerektiren radar sınıflama yöntemleri üzerinde çalışılması planlanmaktadır.

6. Kaynakça

[1] Özdemir, C., *Inverse Synthetic Aperture Radar Imaging with MATLAB Algorithms*. New Jersey: Wiley, 2012.

[2] Gupta I.J., “High resolution radar imaging using 2-D linear prediction”, *IEEE Transactions on Antennas and Propagation*, Vol. 22, 31-37, Jan. 1994.

[3] Kim K.T., S.W. Kim, H.T. Kim, “Two dimensional ISAR imaging using full polarization and superresolution processing techniques”, *IEE Proceedings Radar, Sonar and Navigation*, Vol. 145, 240-246, Aug. 1998.

[4] Erer I. and A.H. Kayran, “Superresolution ISAR Imaging Using 2-D Autoregressive Lattice Filters”, *Microwave and Optical Technology Letters*, 32, 81-85, (2002).

[5] 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.

[6] Park J. I., Kim K.T., “A Comparative study on ISAR imaging algorithms for radar target identification”, *Progress in Electromagnetic Research*, Vol. 108, 155-175, 2010.

[7] Gracobello D., Christensen M. G., Murthi M.N., Jensen S.H., Moonene M., “Sparse Linear prediction and its applications to speech processing”, *IEEE Trans on Audio Speech and Language Processing*, Vol. 20, No.5, 2012 .

[8] Grant M., Boyd S., CVX: Matlab software for Disciplined Convex Programming (web page and software) 2008 [online]. Available : <http://Stanford.edu/boyd/cvx>.

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

[10] Chen V. C., Ling H., *Time-frequency transforms for radar imaging and signal analysis*, Boston: Artech House, 2002.

[11] Tropp J., Gilbert AC. *Signal recovery from random measurements via orthogonal matching pursuit*. *IEEE Trans Inf Theory* 53(12):4655–4666,2007.

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

[13] Moving and Stationary Target Acquisition and Recognition (MSTAR) Public Dataset website: <https://www.sdms.afrl.af.mil/datasets/mstar/>

[14] Na G. D., Wang G.K. Zhang Y., *Kernel linear representation: application to target recognition in synthetic aperture radar images* *Journal of Applied Remote Sensing*, Vol.8,No.1,2014.



Koray Sarıkaya

1987 Ankara doęumludur. İlk ve orta oęretimi Bursa'da tamamlamıřtır. 2009 yılında İstanbul Teknik niversitesi Telekomnikasyon Mhendislięi blmnden mezun olmuřtur. 2014 yılında İT Telekomnikasyon blmnde yksek lisans eęitimini tamamlamıřtır. 2009'dan beri Aselsan A.ř'de elektronik harp sistem mhendislięi grevine devam etmektedir. Evli ve bir çocuk babasıdır.



Haldun Bozkurt

1988 Zonguldak doęumludur, ilk ve orta oęretimini burada tamamlamıřtır. 2012 yılında İstanbul Teknik niversitesi Elektronik Mhendislięi blmnden mezun olmuřtur. zel sektrde arařtırma geliřtirme mhendisi olarak alıřmakta olup, İT Telekomnikasyon Mhendislięi blmnde yksek lisans eęitimine devam etmektedir.



Iřın Erer

1991 yılında İstanbul Teknik niversitesi, Elektrik-Elektronik Fakltesi, Elektronik ve Haberleřme Mhendislięi Blm'nden mezun oldu. Aynı yıl İstanbul Teknik niversitesi, Elektrik-Elektronik Fakltesi'nde Arařtırma Grevlisi olarak alıřmaya bařladı. Elektronik ve Haberleřme Mhendislięi alanında 1993'de Yksek Lisans, 2001'da Doktora derecelerini aldı. Aynı niversitede 2002'de Yardımcı Doęent, 2006'da Doęent oldu. Iřın Yazgan Erer iřaret ve grnt iřleme, radar iřaret iřleme, uzaktan algılama konularında yksek lisans/lisans seviyesinde ders vermekte, arařtırma yapmaktadır ve bu alanda ulusal/uluslararası bilimsel dergi yayını ve konferans bildirimleri bulunmaktadır.