



Clutter removal techniques in ground penetrating radar by using non-local means approach

Deniz Kumlu*¹ , Işın Erer² 

¹Electrical and Electronic Department, National Defense University-Turkish Naval University, Istanbul, 34942, Turkey

²Electronics and Communication Engineering Department, Istanbul Technical University, Maslak-Istanbul, 34469, Turkey

Highlights:

- Non-local means image decomposition
- Image decomposition with directional filter banks
- Construction of 2D simulated dataset by gprMax

Keywords:

- Clutter removal
- Image analysis
- Directional filter bank
- Smoothing filter
- Ground-penetrating radar
- gprMax

Article Info:

Research Article
Received: 05.03.2019
Accepted: 14.01.2020

DOI:

10.17341/gazimmfd.535892

Correspondence:

Author: Deniz Kumlu
e-mail: dkumlu@dho.edu.tr
phone: +90 216 395 2630 / 3564

Graphical/Tabular Abstract

A novel clutter removal method based on non-local means (NLM) filtering for ground-penetrating radar (GPR) is presented. NLM filter which can be considered as a generalization of bilateral filter diverges from other local averaging filters since it determines the pixel weights by investigating the self-similarities in the image. NLM filter is extended to a multiscale-multidirectional version called multiscale directional non-local means (MDNLM) filter. Then, it is used to decompose the GPR image into approximation and detail subbands to capture the intrinsic geometrical structures of GPR image that contain both target and clutter information. After directional decomposition, the clutter is eliminated by keeping the diagonal information as target component. Finally, the inverse transform of the remaining subbands provides the reconstructed clutter-free GPR image.

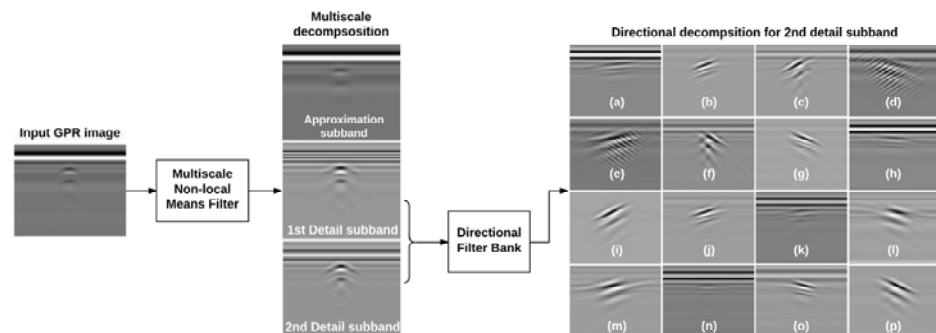


Figure A: The output images for detail and directional subbands of MDNLM method

Purpose: The clutter removal methods in GPR images are as important as the GPR radar itself. Since, the detection rate is reported according to these results. Therefore, improvement in the ROC curves mean increase in the detection rate. The constructed gprMax simulated data results show that NLM filter based method outperforms other state-of-the-art methods.

Theory and Methods:

The NLM method is extended as multi-scale form using “a trous wavelet transform” and multi-directional form using “directional filter banks” for GPR clutter removal implementation and the formulation is given in simple and concise way.

Results:


Both visual results and quantitative results are presented for simulated dataset and discussed in detail. In addition, visual results of the real dataset is provided for further analysis. The obtained results proved the superiority of our proposed method.

Conclusion:

A new GPR clutter removal method based on a multi-scale and multi-directional extension of NLM filter is proposed. NLM has better performance to extract details and it is more robust to clutter hence outperform the other state of the art algorithms.



Yerel olmayan ortalamalar yaklaşımı ile yere nüfuz eden radar görüntülerinde kargaşa giderme

Deniz Kumlu*¹ , Işın Erer² 

¹Milli Savunma Üniversitesi, Deniz Harp Okulu, Elektrik-Elektronik Mühendisliği Bölümü, 34942, İstanbul, Türkiye

²İstanbul Teknik Üniversitesi, Elektrik Elektronik Mühendisliği Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, 34469, Maslak İstanbul, Türkiye

Ö N E Ç İ K A N L A R

- Yerel olmayan ortalamalar yöntemi ile görüntünün ayrıştırılması
- Yönlü süzgeçler bankası ile görüntünün ayrıştırılması
- 2 boyutlu benzetim veri setinin gprMax ile üretilmesi

Makale Bilgileri

Araştırma Makalesi
Geliş: 05.03.2019
Kabul: 14.01.2020

DOI:

10.17341/gazimmfd.535892

Anahtar Kelimeler:

Kargaşa giderme,
görüntü analizi,
yönlü süzgeç bankası,
yumuşatma süzgeçleri,
yere nüfuz eden radar,
gprMax.

ÖZET

Bu makalede, yere nüfuz eden radar (YNR) görüntülerinde mevcut olan kargaşayı gidermek için yerel olmayan ortalamalar (YOO) süzgeci tabanlı yöntemin kullanılması önerilmiştir. YOO süzgeci diğer yerel ortalama alan süzgeçlerden farklı olan bilateral süzgecin genellemesi olarak düşünülebilir, çünkü YOO süzgeci ilgili pikselin ağırlığını bulurken görüntüde benzer komşu piksellerin değerlerine bakarak karar verir. Bu çalışmada, YOO süzgeci çoklu ölçekli-yönlü olacak şekilde genişletilmiş ve bu yeni yöntem çok-ölçekli yönlü yerel olmayan ortalamalar (ÇYYOO) süzgeci ismi verilmiştir. Daha sonra, bu yöntem YNR görüntüleri içinde bulunan hedef ve kargaşaya ait doğal geometrik bilgileri yakalamak amacıyla görüntüleri yaklaşım ve detay alt uzaylara ayırtmak için kullanılmıştır. Ayırıştırma yapıldıktan sonra, kargaşa sadece diyagonal bilgi içeren alt uzay görüntülerini koruyarak giderilmiştir. Daha sonra, kargaşası giderilmiş YNR görüntüsü elde etmek için geriye kalan alt uzaylara ters dönüşüm uygulanır. Önerilen yöntem benzetim ve gerçek YNR veri seti kullanılarak literatürde var olan mevcut yöntemler ve yeni önerilen komşuluk filtresi tabanlı yöntem ile alıcı işletim karakteristik (AİK) eğrileri üzerinden karşılaştırılmış, üstünlüğü kanıtlanmıştır.

Clutter removal techniques in ground penetrating radar by using non-local means approach

H I G H L I G H T S

- Non-local means image decomposition
- Image decomposition with directional filter banks
- Construction of 2D simulated dataset by gprMax

Article Info

Research Article
Received: 05.03.2019
Accepted: 14.01.2020

DOI:

10.17341/gazimmfd.535892

Keywords:

Clutter removal,
image analysis,
directional filter bank,
smoothing filter,
ground-penetrating radar,
gprMax

ABSTRACT

In this paper, a novel clutter removal method based on non-local means (NLM) filtering for ground-penetrating radar (GPR) is presented. NLM filter which can be considered as a generalization of bilateral filter diverges from other local averaging filters since it determines the pixel weights by investigating the self-similarities in the image. NLM filter is extended to a multiscale-multidirectional version called multiscale directional non-local means (MDNLM) filter. Then, it is used to decompose the GPR image into approximation and detail subbands to capture the intrinsic geometrical structures of GPR image that contain both target and clutter information. After directional decomposition, the clutter is eliminated by keeping the diagonal information as target component. Finally, the inverse transform of the remaining subbands provides the reconstructed clutter-free GPR image. Results for both simulated and real datasets are presented to validate the superiority of the proposed method over widely used clutter reduction methods, as well as the recently proposed neighborhood filter based one, in terms of receiving operator characteristic (ROC) curves, thus improving detection performance.

*Sorumlu Yazar/Corresponding Author: dkumlu@dho.edu.tr, icerer@itu.edu.tr / Tel: +90 216 395 2630 / 3564

1. GİRİŞ (INTRODUCTION)

Yere Nüfuz Eden Radar (YNR) engel arkasındaki cisimleri görüntülemek için kullanılan önemli bir uzaktan algılama teknolojisidir ve bu teknoloji günümüzde pek çok sivil ve askeri alanda kullanılmaktadır [1, 2]. Özellikle askeri alanda mayın tespiti konusunda büyük bir başarımla sağlamıştır. Çünkü günümüzde mevcut mayınlar metal dedektörleri tarafından algılanmaması için minimum metal içerecek şekilde plastik materyalden üretilmektedir ve bu gelişme metal dedektörleri yerine YNR kullanılmasını mecbur kılmaktadır. YNR sistemlerinin çalışma prensibi engel arkasına elektromanyetik işaret gönderip yansıyan işaretlerin toplanması şeklindedir. Bu işaretin bir kere gönderilip alınması sonucu elde edilen işarete A-tarama denir ve A-taramaların yan yana konulması ile oluşturulan görüntüye B-tarama veya YNR görüntüsü denir. Elde edilen YNR görüntüsü çeşitli sebeplerden dolayı kargaşa içerir ve bu kargaşa hedefe göre çok daha baskındır. Dolayısıyla hedef kargaşa tarafından maskelenir. Kargaşaya sebep olan kaynakları verici anten tarafından gönderilen elektromanyetik dalganın direk alıcı anten tarafından alınması (alıcı-verici anten arasında kuplaj), yerin yüzeyinden direk yansıyan elektromanyetik dalga, yer yüzeyindeki çeşitli düzensizlikler, toprak ve hedef materyalin cinsi, çevresel faktörler vb. şeklinde sıralayabiliriz.1].

Ortamda bulunan kargaşa kaynaklarını yok etmek mümkün olmadığı için mevcut kargaşayı giderecek yöntemler literatürde önerilmiştir. Bunlardan en temeli engel arkası görüntülerde kargaşanın veya arka planın modellenmesidir. Bu yaklaşım için önerilen metod Ortalama Çıkarma (OÇ) yöntemidir. OÇ yönteminde hedef cismin olmadığı bir bölgede belirli bir uzunluktaki pencere içerisinde bulunan A-tarama işaretlerinin ortalaması hesaplanarak arka plan (kargaşa) bilgisi kestirilir. Daha sonra kestirilen arka plan işareti diğer tüm A-tarama işaretlerinden çıkartılarak kargaşa giderme işlemi gerçekleştirilir. Bu yöntem, alıcı ve verici antenler arası kuplaj ve engelden geri gelen yansımalarından dolayı oluşan kargaşanın giderilmesinde etkili olmasına rağmen hedef cismin olmadığı bölgenin bilgisine ihtiyaç duymaktadır ve yöntemin başarısı engel yüzeyinin şekline, anten yüksekliğine ve engel yapısındaki değişimlere bağlıdır. Medyan Çıkarma (MÇ) yöntemi de OÇ yöntemine benzerdir ve arasındaki tek fark OÇ yönteminde pencere içerisinde yer alan A-tarama işaretlerinin ortalaması alınırken, MÇ yönteminde pencere içerisinde bulunan işaretlerin medyanı alınarak diğer tüm A-tarama işaretlerinden çıkarılır [3]. Yürüyen ortalama çıkarma (YOÇ) ve Yürüyen Medyan Çıkarma (YMÇ) yöntemleri, OÇ ve MÇ yöntemlerinin düşük performans gösterdiği engebeli engel yüzeylerinde, anten yüksekliğinin ve engel yapısındaki değişimlere dayanıklı yöntemler olarak önerilmiştir [4]. Fakat, kullandığımız benzetim veri setinde referans görüntü yani sadece kargaşaya ait görüntü olmadığı için bu yöntemler karşılaştırma için kullanılmamıştır. Kargaşa gidermek için literatürde kullanılan yaygın

yöntemlerden bir diğeri ise veriyi alt uzaylara ayırıştırarak istatistiksel yöntemlerdir. Bu yöntemler tekil değer ayrışımı (TDA), temel bileşen analizi (TBA) ve bağımsız bileşen analizi (BBA) [5-8] yöntemi olarak adlandırılır. Alt uzaya ayırıştırma tabanlı yöntemler, kargaşa ve hedef cismin basit bir şekilde ayırıştırılmadığı durumda görüntülerini YNR görüntülerinin hedef ve kargaşa şeklinde alt uzaylara ayırabilmektedir. Bu ayırıştırma esnasında her yöntem farklı bir kısıt altında ayırıştırma yapar. Genel olarak elde edilen alt uzaylarda, en baskın altuzay kargaşaya karşılık gelmektedir ve geriye kalanlar ise hedef bilgisi içermektedir. Literatürde, bu yöntemlerin hem kendi aralarında hemde başka yöntemler ile karşılaştırıldığı çok sayıda yayım bulunmaktadır [5-9]. Fakat bu yöntemler seyrek tabanlı bir ayırıştırma yapmadığı için YNR görüntülerinde istenen sonucu vermeyebilir. Yine bu gruba giren ve yeni önerilmiş olan morfolojik bileşen analizi (MBA)'de benzer alt uzay ayrışımını yapmaktadır [9]. Fakat bu ayrışım esnasında kargaşa ve hedef için ayrı ayrı eğittiği önceden öğrenilmiş sözlükleri kullanmaktadır ve işlem süresi oldukça uzundur. Ayrıca yapılan ayırıştırma işlemi sırasında hedefin sinyal kuvvetini önemli ölçüde azalttığı gözlemlenmiştir.

Geçtiğimiz yıllarda, görüntülerin çoklu ölçeklerde ve yönlerde incelenmesi için çeşitli dönüşüm yöntemleri önerilmiştir. Bu dönüşümler, görüntüyü çoklu çözünürlükte inceleyerek, kenar ve çizgi detayları hakkında bilgiler vermektedir. YNR görüntülerinde kargaşa yatay bir geometriye sahip iken, hedef cisim ise hiperbolik bir geometriye sahiptir. Bu bilgiden yola çıkarak, literatürdeki bazı dönüşümler YNR görüntülerine uygulanmıştır [10]. Bunlar eğricik dönüşümü (ED) [11, 12], çoklu-çözünürlüklü yönlü bilateral süzgeç (ÇYBS) yöntemi ve bu yöntemden benzer fakat süre ve performans olarak daha iyi sonuç veren çoklu-çözünürlüklü yönlü komşuluk süzgeci (ÇYKS) dönüşümüdür [13]. Bu dönüşümler, resmi farklı ölçeklerde alt uzaylara böler ve bu alt uzaylara yaklaşım ve detay alt uzayları denir. Daha sonra detay alt uzaylar, yönlü süzgeçler bankası (YSB) ile her ölçek için farklı yönlerde ayırıştırılır. Bu yönler katsayı matrisleri ile ifade edilir. Her katsayı matrisi farklı ölçekteki yön bilgisini tutar ve bu bilgiler hedefe mi yoksa kargaşaya mı ait olduğunun analizi yapılır. Hedef cisim ve kargaşaya ait olan uzaylar tespit edildikten sonra (yatay ve hiperbolik bileşenler) iki ayrı grup oluşturulur ve bu alt uzay gruplarına ters dönüşüm uygulanarak hedef cisim ve kargaşaya ait görüntüler tekrardan ayrı ayrı oluşturularak birbirinden ayırt edilmiş olur. Burada ED dönüşümünde bir parametre seçimi olmadığı için YNR görüntüleri için uyarlanamamaktadır. ÇYBS ve ÇYKS dönüşümlerinde parametre seçimi ile süzgeçler değiştirilebilmektedir ve YNR görüntüsü için bu parametreler optimize edilmiştir [13]. Bu metodların iyi sonuç verebilmesi için detay alt uzayların elde edilmesi önemlidir ve literatürde bu metodların uyguladığı yerel ortalamalardan daha iyi performans veren yerel olmayan ortalamalar (YOO) önerilmiştir. Literatürde önerilen ve YNR görüntülerinde kullanılan bu yöntemler yerel ortalama alan süzgeçler vasıtasıyla görüntüyü çeşitli ölçeklerde alt uzaylara

ayrıştırmaktadır. Fakat alınan yerel ortalama detay bantları oluştururken kayıplara sebep olmaktadır. Özellikle toplamsal bir kargaşaya mevcut olduğunda bu yöntemlerin performansları önemli ölçüde azalmaktadır. Bu süzgeçlere alternatif olarak literatürde yerel olmayan ortalamalar süzgeci önerilmiş, ve kargaşa giderme açısından büyük bir başarımlı sağlamıştır. Bu sebeple, yapılan çalışmada YOO süzgeci çoklu ölçekli ve yönlü yapıda tekrar tasarlanarak YNR görüntüleri için uyarlanmıştır. Elde edilen çoklu-çözünürlüklü yönlü yerel olmayan ortalamalar (ÇYYOO) süzgeci benzetim veri setine uygulanmış ve sonuçlar literatürde var olan diğer yöntemler ile alıcı işletim karakteristik (AİK) eğrileri üzerinden karşılaştırılmıştır ve üstünlüğü ispatlanmıştır. Ayrıca sonuçları daha iyi analiz edebilmek amacıyla deneysel veri setleri üzerinde de kıyaslamalar yapılmış, hem gerçek hem benzetim veri setleri için görsel ve sayısal sonuçlar sunulmuştur.

2. YEREL OLMAYAN ORTALAMALAR SÜZGEÇİ (NON-LOCAL MEANS FILTER)

Klasik YOO süzgeci görüntü I 'ya ait her pikseli çeşitli komşuluklardaki piksellerin ortalamasını alarak değiştirir. Görüntüde p pozisyonundaki piksel için YOO süzgecinin çıkışı Eş. 1'de verilir [14]

$$I_p = \sum_{q \in S} w(p, q) I_q \quad (1)$$

$w(p, q)$ ağırlıklandırma fonksiyonudur, p ve q piksellerinin benzerliğine göre bir değer oluşturur ve bu değer $0 \leq w(p, q) \leq 1$ arasında yer alır. Ayrıca $\sum_{q \in S} w(p, q) = 1$ şartını sağlar ve "1" tam benzerlik durumunu göstermektedir (Eş. 2) [14].

$$w(p, q) = \frac{1}{C(p)} \exp\left(-\frac{d(p, q)}{\sigma^2}\right) \quad (2)$$

$C(p)$ normalizasyon parametresidir; (Eş. 3, Eş. 4)

$$C(p) = \sum_{w \in S} \exp\left(-\frac{d(p, q)}{\sigma^2}\right) \quad (3)$$

$$d(p, q) = \|V(N_p) - V(N_q)\|_2^2 \quad (4)$$


burada σ azalım parametresidir ve üssel fonksiyonun azalım hızını kontrol eder, N_p ve N_q ise $N \times N$ boyutunda ve merkezi (p, q) olan bir komşuluk bölgesi S 'i ifade eder. V genlik değeri ve d ise iki genlik arasındaki mesafeyi gösterir [14].

3. ÖNERİLEN KARGAŞA GİDERME METODU (PROPOSED CLUTTER REMOVAL METHOD)

Kargaşa giderme metodlarının asıl amacı sadece hedef bilgisine sahip temiz YNR görüntüsünü elde etmektir. YNR

görüntüsü $I \in \mathbb{R}^{M \times N}$ matrisi ile temsil edilir ve burada $M \times N$ sırasıyla YNR görüntüsündeki derinlik ve A-tarama sayısını gösterir. Bu kapsamda YNR görüntüsü aşağıdaki formülasyona göre bileşenlerine ayrılabilir (Eş. 5) [13].

$$I = I_T + I_C \quad (5)$$



Şekil 1. YNR görüntüsünün geometrik özellikleri (Geometrical features of the GPR image)

burada I_T ve I_C YNR görüntüsünün hedef (target) ve kargaşa (clutter) bileşenini temsil eder.

Önerilen metodun amacı görüntüyü Eş. 5'te olduğu gibi hedef ve kargaşa bileşenlerine ayırmaktır. Bu amaçla, önerilen metod YNR görüntüsünde var olan hedef ve kargaşanın geometrik özelliklerinden faydalanır. Şekil 1'de gösterildiği gibi hedef bileşeni hiperbolik bir geometrik yapıya sahipken, kargaşa bileşeni ise yatay bir geometrik yapıya sahiptir. Bu geometrik özellikleri bulabilmek için, YNR görüntüsü önce farklı ölçeklerde alt uzaylara ayrılmakta ve daha sonra her ölçekteki görüntü YSB vasıtasıyla farklı yönlerde alt uzaylara ayrılmaktadır [15]. Elde edilen her ölçekteki yönlü görüntülerden geometrik özellikler kullanılarak YNR görüntüsünde hedef ve kargaşa bileşenlerine ayrılmaktadır.

Klasik YOO süzgecinin temel prensibi bölüm 2'de açıklanmıştır. YOO süzgecinin çıkışını kullanarak, farklı detay alt uzaylara ulaşmak mümkündür [16].

$$D^1 = I^0 - I^1 \quad (6)$$

Burada I^1 , I^0 ve D^1 sırasıyla süzgeç çıkışı, süzgeçlenmiş YNR görüntüsü ve detay alt uzaylarını ifade etmektedir (Eş. 6).

Eş. 6 ölçeklere ayırmada bir seviye ayrıştırma olarak düşünülebilir. Fakat, bizim problemimizde YNR görüntüsünü bir seviye ayrıştırma yetersiz kalmaktadır çünkü hedef bilgisi farklı ölçeklere yayılmış olabilir. Bu sebeple, Eş. 6'daki bir seviye ayrıştırma çok seviye ayrıştırma olarak genişletilmiştir ve buna çok ölçekli

ayırıştırma adı verilmektedir [15]. YNR görüntüsünün ayrıştırılması esnasında, YNR görüntüsü ile aynı boyutta alt uzay görüntülerine sahip olabilmek için (shift-invariant) alt uzay görüntüleri YNR görüntüleri ile aynı boyutta seçilmiştir.

Çoklu ölçekli ayrıştırma, her detay alt uzay görüntüye ayırdığımızda Eş. 2’de belirtilen sigma parametresini iki katına çıkararak elde edilir ve buna göre Eş. 6 Eş. 7’deki gibi genişletilebilir [15].

$$I_p^j = \sum_{w \in S} \frac{1}{C_j(p)} \exp\left(-\frac{d(p,q)}{(2^j \sigma)^2}\right) I_q^{j-1} \quad (7)$$

I^{j-1} bir önceki süzgeçleme adımının çıkışıdır ve ağırlıklandırma parametresi $C_j(p)$ Eş. 8’de verilir

$$C_j(p) = \sum_{w \in S} \exp\left(-\frac{d(p,q)}{(2^j \sigma)^2}\right) \quad (8)$$

j ölçeğine ait detay alt uzay ise

$$D^j = I^{j-1} - I^j \quad (9)$$

Eş. 9’un sonucu olarak, YNR görüntüsü çoklu ölçekli ayrıştırma ile yaklaşım ve j detay alt uzaylarına ayrıştırılmıştır. Bir sonraki adım, Şekil 1’de verilen hedefin ve kargaşanın geometrik özelliklerini kullanarak detay alt uzaylarda hedef bilgisini bulmaktır. Çoklu ölçekli - çok yönlü altuzaylar $D^{j,l}$ her bir detay alt uzaya süzgeçler YSB uygulanarak elde edilir (Eş. 10) [15].

$$D^{j,l} = dfb(D^j, l) \quad (10)$$

burada $dfb(.)$ ve 2^j yönlü filtrelere ayrıştırma fonksiyonu ve bu işlemin sonucunda elde edilecek yönlü alt uzay görüntülerin sayısını vermektedir.

Şekil 2 ÇYYOO metodunun adımlarını göstermektedir. Bu metoda ait görsel ayrıştırma sonuçları Şekil 3’te sunulmuştur. Bu görsel sonuçlar açıkça göstermektedir ki detay alt uzaylara inildiğinde hedefin farklı ölçeklerde daha da belirginleştiği ve yönlü ayrıştırmadan sonra bazı görüntülerde yatay bilginin toplandığı, bazı görüntülerde hiperbolik (diyagonal ve karşı-diyagonal) bilginin toplandığı ve bazı görüntülerde ise karışık bilgiler olduğu görülmektedir.


Burada hedef bilgisine ait görüntüleri seçebilmek için bir eşikleme fonksiyonu $S_D(D^{j,l})$ tanımlanmıştır.(Eş. 11)

$$S_D(D^{j,l}) = \begin{cases} D^{j,l}, & "l" \text{ hedefe ait alt uzaylar} \\ 0, & \text{diğerleri} \end{cases} \quad (11)$$

Bu eşikleme fonksiyonu $D^{j,l}$ görüntülerini alıyor ve bu görüntüler içinde hiperbolik bilgi içerenleri tutarak diğerlerini “0” değerine eşitliyor. Eş. 10’daki ayrıştırma adımına benzer şekilde, ters yönlü süzgeç bankası (TYSB) Eş. 11’de elde edilen eşiklenmiş görüntülere uygulanmıştır,

$$D_T^j = idfb(S_D(D^{j,l})) \quad (12)$$

burada $idfb(.)$ ve D_T^j sırasıyla TYBS ve sadece hedef bilgisine ait detay alt uzayları ifade etmektedir(Eş. 12). Sadece hedef bilgisine sahip YNR görüntüsünü tekrar oluşturmak için Eş. 13 kullanılır.



Şekil 2. ÇYYOO dönüşümü a) YOO ve YSB dönüşümlerinin blok diyagramları b) ilgili frekans ayrışmaları c) 2 boyutlu frekans düzleminde yönlü alt uzaylar (MDNLM transform (a) Block diagram of multiscale NLM and DFB transform (b) corresponding frequency decomposition (c) Directional subbands on the 2D frequency plane)

$$I_T = \sum_{j=1}^J D_T^j \quad (13)$$

4. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

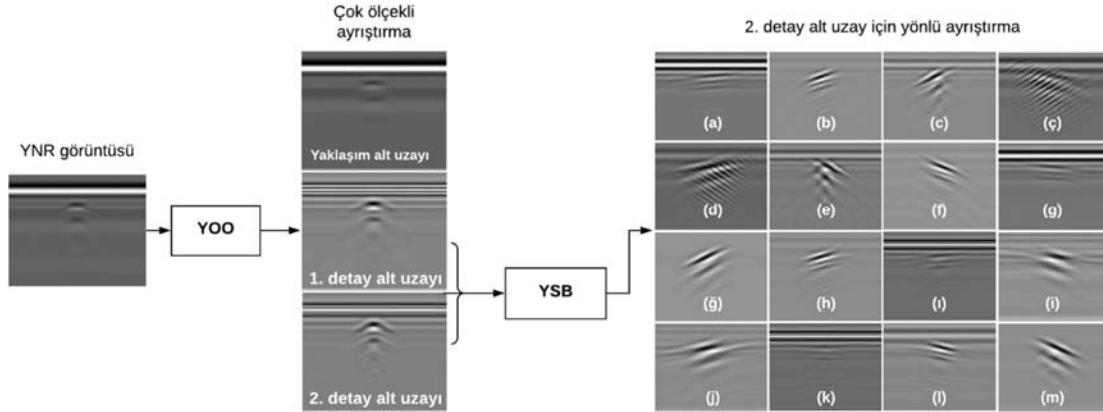
Önerilen yöntem literatürde var olan alt uzay tabanlı metodlar (TDA [5], TBA [5], BBA [5], MBA [9]) ve çoklu çözünürlük tabanlı metodlar (ED [11], ÇYKS [13]) ile benzetim veri seti ve deneysel veri setleri olmak üzere farklı senaryolar üzerinden karşılaştırılmıştır. Karşılaştırma sonuçları olarak AİK eğrileri ve görsel sonuçlar verilmiştir. AİK eğrileri YNR hedef tespit problemlerinde sıklıkla sayısal analiz tekniği olarak kullanılmaktadır ve bu eğrilerin hesaplanması kargaşası giderilmiş YNR görüntülerinde hedefin enerjisi kullanılarak bulunur. Bir YNR görüntüsünün enerji çizimi sadece o görüntü için sonuç verir ve sadece tek sonuç objektif karşılaştırma için yeterli değildir. Bu sebeple, benzetim veri seti üretilmiş ve bu veri setindeki tüm YNR görüntüleri kullanarak elde edilen AİK sonuçları raporlanmıştır. Böylece performans karşılaştırmaları daha detaylı olarak analiz edilmiştir. YNR görüntüsünde enerji kavramı Şekil 4'de gösterilmiştir. Şekil 4a'da kargaşası giderilmiş YNR görüntüsünde hedefin merkezi (kırmızı çizgi) ve hedef tespit başlangıç-bitiş yerleri (mavi çizgi) gösterilmektedir.

Şekil 4b ise kargaşası giderilmiş YNR görüntüsündeki piksel değerlerine dayanan enerji değerlerini göstermektedir. Burada normalize edilmiş enerji (mavi çizgi) ve süzgeçlenmiş enerji (kırmızı çizgi) ile çizilmiştir. Normalize edilmiş enerji E_N Eş. 14'e göre piksel değerlerini kullanarak hesaplanabilir.

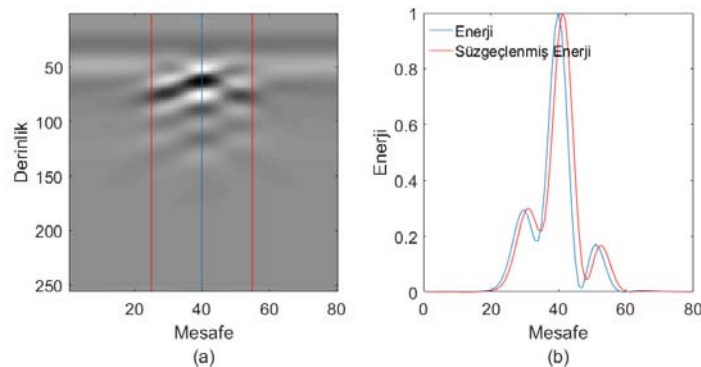
$$E_N = \frac{\sum_{q=1}^Q I_T^2(p, q) - \min\left(\sum_{q=1}^Q I_T^2(p, q)\right)}{\max\left(\left(\sum_{q=1}^Q I_T^2(p, q) - \min\left(\sum_{q=1}^Q I_T^2(p, q)\right)\right)\right)} \quad (14)$$

Burada I_T Eş. 13 ile elde edilmiş kargaşası giderilmiş YNR görüntüsüdür. $\min(\cdot)$ ve $\max(\cdot)$ ise bir dizinin minimum ve maksimum değerini bulan operatörlerdir. Eş. 14 sonucu elden edilen normalize edilmiş enerji E_N , kısa süreli dalgalanmaları engellemek ve enerji değerlerinin uzun dönem yönelimini bulmak amacıyla bir alçak geçiren süzgeç tarafından süzgeçlenir.

Veri setinde mevcut her bir YNR görüntüsü için kargaşası giderilmiş görüntülerin süzgeçlenmiş enerji değerleri bulunduktan sonra, Şekil 4a ve Şekil 4b'de gösterildiği gibi



Şekil 3. ÇYYOO metodunun detay ve yönlü alt uzay görüntüleri
(The output images for detail and directional subbands of MDNLM method)



Şekil 4. YNR görüntüsünde enerjinin tanımı a) Kargaşası giderilmiş YNR görüntüsünde enerji hesaplanması b) Kargaşası giderilmiş YNR görüntüsü için enerji ve süzgeçlenmiş çizimleri (The definition of the energy in GPR image (a) The clutter-free GPR image for energy calculation (b) The energy and smoothed energy plot of the clutter-free GPR image)

tespit ve yanlış tespit bölgelerine bakılarak tespit olasılığı (TO) ve yanlış alarm oranı (YAO) AİK eğrilerini oluşturabilmek amacıyla hesaplanır.

4.1. Benzetim veri seti için elde edilen sonuçları (Obtained results for simulated dataset results)

Benzetim veri seti gprMax benzetim programı kullanılarak üretilmiştir. Bu program Maxwell'in denklemlerinden faydalanarak ikinci dereceden sonlu fark zaman uzayı algoritmasını kullanır. Bu program vasıtasıyla YNR görüntüleri oluşturulabilir fakat bunun için belirli parametrelerin seçilmesi gerekmektedir. Biz benzetim süresince anten olarak gprMax'ın kütüphanesinde hazır olan ve aynı zamanda ticari ürün olarak kullanılan GSSI (geophysical survey system inc.) model 5100'ü tercih ettik. Kütüphane de bulunan ticari anten mevcut kullanılan YNR'lerin performansını göstermek için bilinçli olarak tercih edilmiştir [17]. Genel olarak YNR performansına etki eden iki kritik parametre bulunmaktadır ve bunlar dielektrik sabiti (DS) ve elektriksel iletkenlik (Eİ)'tir. Farklı ortamlar için YNR görüntülerini oluştururken her toprak tipi ve gömülü cisim materyali için bu iki parametrenin bilinmesi gerekmektedir [17].


YNR ile tespit için aynı deney ortamı kurulsa dahi DS ve Eİ parametrelerinden dolayı değişik toprak tipleri ve değişik hedef materyalleri için farklı tespit sonuçları çıkabilir. Yani burada toprak ve hedef materyali tipi hedef tespiti için önemli bir parametredir diyebiliriz. Şöyle ki daha iletken olan toprak (nemli olanlar), iletken olmayan toprağa (kuru olanlar) göre fazla enerji harcar ve bu daha derin mesafelere nüfuz etmesini engeller ve tespit performansını düşürebilir. Ayrıca hedef materyalide aynı şekilde daha iletken ise geri yansıyan sinyali zayıflatacağı için tespit oranını düşürür. Yani metal olmayan hedefleri tespit etmek daha zorlaşır. Yine diğer önemli bir parametre hedefin gömülü olduğu derinliktir. Hedef daha derine gömüldükçe elektromanyetik dalganın nüfuz etmesi zorlaşacağından tespit oranı azalır fakat yüzeye çok yakın gömüldüğünde ise hedef sinyali ile kargaşa sinyali birbirini maskeler. Bu sebeple gömülme derinliği YNR ile hedef tespitinde önemli bir parametredir.

Bu bahsettiğimiz üç parametre (toprak çeşidi, hedef materyali ve derinlik) kontrol edebileceğimiz ve YNR sisteminin performansını etkileyecek değişkenler olduğundan oluşturulan görüntülerde sistematik olarak değiştirilmiş ve farklı benzetim YNR görüntüleri elde edilmiştir.

Tablo 1. Materyallerin elektromanyetik özellikleri
(Electromagnetic properties of materials)

Materyal	DS (F/m)	Eİ (S/m)
Kuru kum toprak	3,0	0,001
Nemli kum toprak	8,0	0,01
Islak kum toprak	20,0	0,1
Kuru kil toprak	10,0	0,01
Islak kil toprak	12,0	0,01
Kuru kum-kil toprak	10,0	0,001
Aluminyum	3,1	2,3e7
Plastik	3,0	0,01

Üretilen benzetim veri seti toplamda 112 YNR görüntüsünden oluşmaktadır [18] ve bu veri setinde 7 farklı toprak tipi, 2 farklı hedef materyali, 2 farklı gömülme derinliği ve 4 farklı senaryo kullanılmıştır. Deneyin nasıl dizayn edildiği Şekil 5'te gösterilmiştir. Toprak ve hedef tipine ait materyallerin elektriksel özellikleri Tablo 1'de verilmiştir. 7. toprak tipi su kümbetleri içeren heterojen toprak tipidir. Bu toprağın özellikleri, 0,5 kil oranı, 0,5 kum oranı, kitle yoğunluğu $2g/cm^3$, parçacık yoğunluğu $2.66g/cm^3$ ve hacimsel su oranı 0.001–0.25 aralığındadır. Şekil 5'te gösterildiği gibi silindirik hedefler problemi daha zorlaştırmak amacıyla yüzeye yakın olacak şekilde 2 cm ve 3 cm derinliklere gömülmüştür. Hedefin çapı ve yüksekliği 2,8 cm ve 4 cm'dir. Bu benzetimde kullanılan hedeflerin boyutları M14 plastik kaplı antipersonel mayınına uygun seçilmiştir çünkü bu mayın günümüzde sıklıkla kullanılan bir mayın tipidir. Modelin ayrıklaştırması $\Delta x = \Delta y = \Delta z = 1mm$ olarak seçilmiş ve benzetim uzayı $1000 \times 120 \times 400mm$ olarak tanımlanmıştır. Alıcı ve verici antenler yüzeyden 5 cm yüksekliğe yerleştirilmiş ve her defasında 1 cm hareket ettirilerek A-tarama bilgisi




Şekil 5. Benzetim veri setinin gprMax benzetim programında deney düzeneği
(Experimental setup of the simulated dataset in gprMax simulation program.)


toplanmıştır. Her benzetim verisinin senaryosu için antenler 80 kere hareket ettirilmiş ve sonuç olarak 80 adet 256 tane katsayı içeren A-tarama verisi toplanmış ve bunlar yanyana birleştirilerek B-tarama görüntüsü oluşturulmuştur. Bu sebeple, Şekil 5'te gösterildiği gibi tarama yapılan bölge 80 cm'dir, 10 cm'den başlar ve 90 cm'de son bulmaktadır. Daha önce söylendiği gibi benzetim veri setinde toplamda 112 YNR görüntüsü mevcuttur ve toplamda 4 senaryo için 28 YNR görüntüsü vardır. Her senaryo da 28 görüntü elde etmek için toprak tipi, hedef materyali ve derinlik aynı sistematik ile değiştirilmektedir ve senaryolar arasındaki fark değişik yüzey tiplerinden kaynaklanmaktadır [18].

İlk senaryo en basit olanıdır ve burada yüzey tipi düzdür [18]. Bu senaryo için algoritmaların tespit performansları Şekil 6'da AİK eğrileri ile gösterilmiştir. Elde edilen

sonuçlar göstermektedir ki ÇYYOO, ÇYKS [13] ve MBA [9] yaklaşık olarak aynı performansı sergilemektedir, ikinci en iyi performans ise TDA [5] tarafından elde edilmiştir ve ED [11] ise onu takip etmektedir. Fakat TBA [5] ve BBA [5] algoritmaları ise kötü bir performans sergilemiştir. Bu algoritmaların görsel sonuçları Şekil 7b-Şekil 7h'ta verilmiştir. Şekil 7a, ilk senaryodan seçilmiş bir örnek YNR görüntüsüdür ve özellikleri ise sırasıyla; nemli kum toprak, plastik hedef ve 3 cm gömülme derinliğidir. Burada toprak tipi ve hedef materyali YNR için iyi sonuç verecek şekilde seçilmediğinden, hedef bilgisi ham YNR görüntüsünde güçlülükte seçilmektedir. Fakat, senaryo basit bir senaryo olduğundan bütün algoritmalar kargaşa giderme açısından tatmin edici görsel sonuçlar sunmuştur. Görsel sonuçları analiz ettiğimizde, MBA'nın en iyi performansı sergilediği görülmektedir bunun başlıca nedeni önceden oluşturulmuş



Şekil 6. Senaryo I için hesaplanmış AİK eğrileri (Calculated ROC curves for scenario I)




Şekil 7. Senaryo I için bir B-tarama verisinin görsel sonuçları a) Ham veri, hedef bilgisinin bulunması b) TBA [5] c) BBA [5] d) TDA [5] e) MBA [9] f) ED [11] g) ÇYKS [13] h) ÇYYOO (Visual results for one B-scan data of Scenario I a) Raw data, target components obtained by b) PCA [5] c) ICA [5] d) SVD [5] e) MCA [9] f) CT [11] g) MDNF [13] h) MDNLM)

sözlüklerin bu senaryo için uygun olmasıdır. Şekil 7e’de görüldüğü gibi yüzeyde hiç kargaşa bulunmamaktadır ve arka plan oldukça temizdir. En iyi ikinci performans ÇYYOO ve ÇYKS algoritmaları tarafından elde edilmiş ve Şekil 7g ve Şekil 7h’ta gösterilmiştir.


Fakat sonuç görüntüleri daha detaylı incelendiğinde ÇYYOO’nun hedefi daha belirgin bir şekilde kargaşadan temizlediği söylenebilir ve hedefe ait sinyal daha kuvvetlidir. TBA, BBA ve TDA algoritmalarının hemen hemen aynı sonuçları elde ettiği görülmektedir. Şekil 7b-Şekil 7d’de görüldüğü gibi yüzeyde hala yatay bir çizgi halinde kargaşa bileşeni bulunmaktadır ve bu tespit oranına etki eder. Şekil 7f’de görüldüğü üzere ED bu senaryo için kötü sonuç vermiştir ve hedef bilgisini dağıtmıştır. Ayrıca kargaşa temizlemede de çok başarılı bir sonuç ortaya koymamıştır. İkinci senaryo düz yüzey ve üzerinde çim bulundurmaktadır

[18]. Bu senaryo da toprak üzerinde var olabilecek bitkilerin YNR performansına etkisi gözlemlenmeye çalışılmıştır. Düz olan yüzeye 10000 adet çim ekilmiş ve çimlerin boyu 2 cm ve kökü de 2 cm olarak ayarlanmıştır. Bu senaryonun ilk senaryoya göre biraz daha karmaşık olduğu söylenebilir ve bunun da AİK eğrilerindeki performansın düşmesinden gözlemleyebiliriz. Şekil 8’de gösterilen AİK eğrileri incelendiğinde, ÇYYOO ve ÇYKS [13]’nin en iyi performansı sergilediği ve ÇYYOO’nun çok az ÇYKS’nin üzerinde olduğu, bu iki algoritmayı da MBA [9]’nin takip ettiği görülmektedir. TDA [5]’nin performansı MBA’nın altındadır ve bunu ED [11] takip etmektedir. TBA [5] ve BBA [5] ise yine kötü sonuç vermiştir.

Bu senaryoya ilişkin görsel sonuçlar Şekil 9b-Şekil 9h’ta verilmiştir. Şekil 9a bu senaryodan seçilmiş ham YNR görüntüsüdür ve bu görüntünün özellikleri ise sırasıyla;



Şekil 8. Senaryo II için hesaplanmış AİK eğrileri (Calculated ROC curves for scenario II)



Şekil 9. Senaryo II için bir B-tarama verisinin görsel sonuçları a) Ham veri, hedef bilgisinin bulunması b) TBA [5] c) BBA [5] d) TDA [5] e) MBA [9] f) ED [11] g) ÇYKS [13] h) ÇYYOO (Visual results for one B-scan data of Scenario II a) Raw data, target components obtained by b) PCA [5] c) ICA [5] d) SVD [5] e) MCA [9] f) CT [11] g) MDNF [13] h) MDNLM)

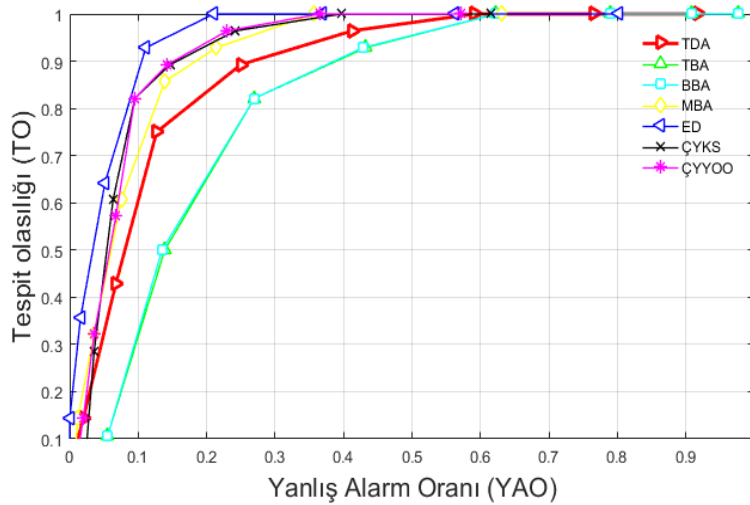
nemli kum toprak, alüminyum hedef ve 2 cm gömülme derinliğidir. Burada alüminyum hedef kullanıldığı için YNR görüntüsünde hedef daha belirgin çıkmıştır ve nemli kum ortamı hedefin tespit edilmesi açısından ıslak kum ortamına göre daha iyi sonuç vermektedir. Görsel sonuçlar incelendiğinde, ÇYYOO ve ÇYKS [13] algoritmalarının diğerlerine kıyasla daha iyi sonuç verdiği, kargaşayı neredeyse tamamen yok ettiği ve hedef sinyalini zayıflatmadığı gözlemlenmektedir. İkinci en iyi performans MBA [9] algoritması tarafından sergilenmiştir ama yüzeyde çimlerin etkisi gözükmemektedir ve MBA ayrıcı hedef sinyalini zayıflatarak enerji hesabında AİK eğri sonuçlarını kötüleştirilmektedir. Yani kargaşa bilgisini yok ederken biraz hedef bilgisinden de fedakarlık etmektedir. TDA [5] algoritması da tatmin edici bir sonuç sunmaktadır ama çim etkisi yüzeyde bariz bir şekilde gözlenmektedir ve hedef sinyalinde bozulma meydana gelmiştir. TBA [5] ve BBA [5] algoritmaları ise görsel olarak ta kötü sonuç vermiş, hedefi maskeleyen yatay ve dikey bir sürü çizgi içermektedir ve bunlar hedef tespit performansını etkilemektedir. ED [11] görsel olarak diğerlerine göre oldukça kötü bir sonuç vermiştir. Yüzey kargaşasını tam olarak bastıramadığı gibi ayrıca hedef sinyalinde bozulmalar meydana getirmiştir.

Üçüncü senaryo pürüzlü yüzeydir ve yüzeydeki dalgalanma yaklaşık 2 cm civarındadır [18]. Bu senaryo ilk senaryoya göre daha gerçekçi bir senaryodur. Çünkü günlük hayatta gömülü hedef tespiti için dümdüz bir zemin bulmak neredeyse imkansızdır. Fakat mevcut pürüzler senaryoyu zorlaştırmaktadır ve bu Şekil 10'daki AİK eğrileri sonuçlarının kötüleşmesinden gözlemlenebilir. AİK eğrileri analizinde ED'nin en iyi performansı sergilediği görülmektedir. ÇYYOO ve ÇYKS [13] algoritmaları ise ED [11]'yi takip etmektedir. MBA [9]'nin performansı ise bunların çok az altında yer almaktadır ve TDA [5] ise MBA'nın bariz olarak gerisindedir. TBA [5] ve BBA [5]'nin sonuçları ise oldukça kötüdür diyebiliriz. Bu senaryoya ilişkin görsel sonuçlar Şekil 11b-Şekil 11h'ta verilmiştir. Şekil 11a bu senaryodan seçilmiş ham YNR görüntüsüdür ve


bu görüntünün özellikleri ise sırasıyla; kuru kum toprak, alüminyum hedef ve 3 cm gömülme derinliğidir. Bu senaryo diğerlerine göre çok daha karmaşık olduğu için, ortam parametreleri kasıtlı olarak iyi sonuç verecek şekilde seçilmiştir. Aksi takdirde hedefi görsel olarak analiz etmek zor olacaktır. Bu YNR görüntüsü için En iyi görsel sonuç ÇYOO ve ÇYKS [13] tarafından elde edilmiştir fakat ÇYOO'da hedef bilgisinin daha belirgin olduğu görülmektedir. İkinci en iyi sonuç MBA [9] tarafından elde edilmiştir fakat yüzeyde kargaşa etkisi görülmektedir ve hedef bilgisi de oldukça zayıftır. TDA [5] algoritması görsel performans olarak MBA'yı takip etmektedir fakat yüzeydeki kargaşa bariz olarak giderilememiştir. Bu senaryo için ED [11], TBA [5] ve BBA [5]'nin görsel sonuçlarının tatmini edici olmadığını söyleyebiliriz. Çünkü ED için hedef bilgisi neredeyse tamamen kaybolmuşken, TBA ve BBA'da hedef sinyali düşey ve yatay çizgiler tarafından maskelenmiştir.

Dördüncü senaryo, pürüzlü yüzey ve üzerinde su kümbetleri içermektedir [18]. Yüzeydeki pürüzlülük oranı üçüncü senaryoya benzerdir ve su kümbetleri 0,5 cm derinliğindedir. Pürüzlü yüzey üzerine yerleştirilen su kümbetleri elektromanyetik dalganın yayılım performansını etkilemekte ve bu da YNR performansına etki etmektedir. Bu yüzden Şekil 12'de verilen AİK eğrilerinde kötüleşme gözlenmektedir. AİK eğrileri incelendiğinde ÇYYOO ve ÇYKS [13] algoritmalarının en iyi performansı sergilediği fakat ÇYYOO'nun biraz daha üstün olduğu gözlemlenmektedir. En iyi ikinci performans MBA [9] ve TDA [5] tarafından elde edilmiştir ama MBA'nın daha iyi olduğu söylenebilir. ED [11]'nin performansı TDA'ya yakındır ama küçük TO değerleri için tatmin edici değildir. TBA [5] ve BBA [5] yaklaşık olarak aynı performansa sahiptir ve diğer algoritmalarından bariz bir şekilde kötüdür.


Bu senaryoya ilişkin görsel sonuçlar Şekil 13b-Şekil 13h'ta verilmiştir. Şekil 13a bu senaryodan seçilmiş ham YNR görüntüsüdür ve bu görüntünün özellikleri ise sırasıyla; nemli kum toprak, plastik hedef ve 3 cm gömülme



Şekil 10. Senaryo III için hesaplanmış AİK eğrileri (Calculated ROC curves for scenario III)




Şekil 11. Senaryo III için bir B-tarama verisinin görsel sonuçları a) Ham veri, hedef bilgisinin bulunması b) TBA [5] c) BBA [5] d) TDA [5] e) MBA [9] f) ED [11] g) ÇYKS [13] h) ÇYYOO (Visual results for one B-scan data of Scenario III a) Raw data, target components obtained by b) PCA [5] c) ICA [5] d) SVD [5] e) MCA [9] f) CT [11] g) MDNF [13] h) MDNLM)




Şekil 12. Senaryo IV için hesaplanmış AİK eğrileri (Calculated ROC curves for scenario IV)

derinliğidir. Burada kum ve hedef tipi YNR sistemi için kasıtlı olarak uygun seçilmediğinden gömülü hedef gözle bile güçlükle seçilebilmektedir. Buna ek olarak, ham görüntüde yüzey üzerindeki pürüzler net olarak seçilebilmektedir. Bu YNR görüntüsü için en iyi sonuçlar MBA [9], ÇYYOO ve ÇYKS [13] algoritmaları tarafından elde edilmiştir fakat ÇYYOO'da hedef bilgisi daha baskındır ve MBA hedef bilgisi oldukça zayıftır. TDA [5] ise onlardan sonra en iyi ikinci performansa sahiptir fakat yüzey kargaşası bariz olarak görülebilmektedir. TBA [5] ve BBA [5] sonuçları ise tatmin edici değildir, yüzey kargaşası iyi temizlenememiş ve elde edilen görüntü birçok yatay dikey bileşen içermektedir bunun doğal sonucu olarak hedef tespiti güçleşmektedir. Şekil 14 tüm benzetim veri seti (112 YNR görüntüsü) için AİK eğrisi sonuçlarını göstermektedir. Böylece en basit yüzey durumundan en karmaşık yüzey

durumuna kadar algoritmaların performansları tek bir grafikte gösterilmiştir. Bu sonuçlar göstermektedir ki ÇYYOO algoritması literatürde varolan algoritmalara göre üstün bir performans sergilemektedir. MBA [9] ve ÇYKS [13] yaklaşık olarak aynı performansı vermekte fakat MBA algoritması sözlüklerini oluşturmak için bir ön işlem gerektirmektedir fakat ÇYKS direkt olarak ham YNR görüntüsüne uygulanabilir. ED [11] ve TDA [5] benzer performanslar sergilemiş ve maksimum tespit noktasına ÇYYOO, MBA ve ÇYKS'den sonra ulaşmıştır. TBA [5] ve BBA [5]'nin performansları ise diğerlerine nazaran oldukça kötüdür. Daha önce verilen görsel sonuçlar da değerlendirildiğinde AİK eğrileri ile benzer sonuçlara ulaşıldığı görülmektedir. Bu yüzden AİK eğrilerinin sayısal olarak karşılaştırmada iyi bir yöntem olduğunu değerlendirilmektedir.




Şekil 13. Senaryo IV için bir B-tarama verisinin görsel sonuçları a) Ham veri, hedef bilgisinin bulunması b) TBA [5] c) BBA [5] d) TDA [5] e) MBA [9] f) ED [11] g) ÇYKS [13] h) ÇYYOO (Visual results for one B-scan data of Scenario IV a) Raw data, target components obtained by b) PCA [5] c) ICA [5] d) SVD [5] e) MCA [9] f) CT [11] g) MDNF [13] h) MDNLM)



Şekil 14. Tüm benzetim veri seti için hesaplanmış AİK eğrileri (Calculated ROC curves for overall simulated dataset)

4.2. Deneysel veri setleri için elde edilen sonuçlar (Obtained results for experimental dataset results)


Bu çalışmada önerilen algoritmanın etkinliğini göstermek amacıyla benzetim veri setine ek olarak iki adet deneysel veri setlerinde görsel ve sayısal sonuçlar raporlanmıştır. Bu deneysel verilerden ilki saha ölçümlerine, diğeri laboratuvar ölçümleri sonucu elde edilmiştir. İlk kullandığımız veri seti, literatür de sıklıkla kullanılan ve Vrije Universiteit Brussel tarafından sağlanan veri setidir[19]. Deneyin düzeneği Şekil 15'te ve elde edilen ham YNR görüntüsü Şekil 16a'da gösterilmiştir. Bu senaryoda, PMA-3 mayın, PMA-1 mayın, taş ve bakır tel hedef olarak kullanılmış ve 5 cm derinliğe gömülmüştür. Hedeflere ait detaylı özellikler Tablo 2'de sunulmuştur. Bu senaryoda kullanılan toprak çeşidi kuru kil toprak, küçük taşlar içeren karışık bir yüzey yapısı ve maksimum 10 cm'ye kadar pürüzler içermektedir.



Şekil 15. Deneysel veri seti için deney düzeneği
(Experimental setup for real dataset)

Tablo 2. Gerçek veri setinde gömülü objelere ait bilgiler (The specifications of buried objects in real dataset)

Hedef	Hedef ölçüleri	Derinlik (cm)	X Merkezi(cm)	Y Merkezi (cm)
PMA-3 mayın	Yük. 5 cm, Çap 10 cm	5 cm	25 cm	25 cm
PMA-1 mayın	14x7x3 cm	5 cm	25 cm	125 cm
Büyük taş	6x7x10 cm	5 cm	25 cm	75 cm
Bakır tel	Boy 30 cm, En 2x0,5 cm	5 cm	25cm	175 cm



Şekil 16. Deneysel veri seti için görsel sonuçlar a) Ham veri, hedef bilgisinin bulunması b) TBA [5] c) BBA [5] d) TDA [5] e) MBA [9] f) ED [11] g) ÇYKS [13] h) ÇYYOO (Visual results for the real dataset a) Raw data, target components obtained by b) PCA [5] c) ICA [5] d) SVD [5] e) MCA [9] f) CT [11] g) MDNF [13] h) MDNLM)

Anten yüzeyden 5 cm yukarıya konumlandırılmıştır ve frekansı 1 GHz olan bir anten kullanılmıştır. Taranan alan 50x196 cm boyutlarındadır, anten her seferinde 1 cm kaydırılmış ve toplamda 512 katsayı içeren bir 196 adet A-tarama verisi elde edilmiştir [19]. Burada farklı hedeflerin oluşu ve birbirleriyle etkileşimleri problemi zorlaştırmaktadır.

Şekil 16b-Şekil 16h algoritmaların görsel performanslarını göstermektedir. Literatürde gerçek veriler çok sınırlı olduğu için AİK eğrileri kullanılmamakta sadece görsel sonuçlar verilmektedir (AİK eğrilerinin sağlıklı sonuç verebilmesi için veri setinin yeterli büyüklükte olması gerekmektedir). Şekil 16b-Şekil 16h'ta verilen gerçek veri sonuçları incelendiğinde, en iyi sonuçlar MBA [9] ve ED [11] tarafından verildiği gözlemlenmekle beraber hedef bilgisi oldukça zayıflamıştır. ÇYYOO ve ÇYKS [13] sonuçlarında yüzey kargaşasının giderildiği görülmektedir ve hedef bilgileri MBA ve ED'ye kıyasla daha güçlüdür. Hedefin lokasyonu doğru olmakla beraber sadece biraz yayılma gözlemlenmektedir. TBA [5], BBA [5] ve TDA [5] benzer sonuçlar vermiştir ve aralarında TDA daha iyi performans göstermiştir. TBA ve BBA algoritmaları yakında incelendiğinde hedeflerin altın dikey çizgiler mevcuttur ve her üç algoritmada da yüzey kargaşası halen gözlemlenmektedir. Ayrıca bu veri üzerinde sayısal analiz yapabilmek için Eş. 14'e göre enerji seviyeleri çizdirilmiştir. Deneysel veri seti için AİK eğrilerinin çizdirilmesinde kullanılan enerji çizimleri deneysel veri içinde hesaplanarak

Şekil 16'da gösterilmiştir (enerji çizimi kırmızı renk kesikli çizgi ile çizdirilmiştir). Bu enerji seviyeleri, hedef sinyallerinin giderilmiş kargaşa karşısında ne kadar güçlü olduğunu göstermektedir. Algoritmaların performansları incelendiğinde, TBA ve BBA'nın hemen hemen aynı performansı verdiği ve 1. ve 3. hedefi yakalamakta zorlandığı görülmektedir ayrıca 4. Hedefi çok fazla dağıtmıştır. TDA algoritması ise 3. hedefi yakalayamamıştır 1. ve 3. hedefin ise sinyal kuvveti nispeten daha düşüktür. MBA metodu görsel olarak temiz bir görüntü vermiştir fakat hedef kuvvetlerini oldukça azaltmıştır. Bu enerji çizimlerinde gözlemlenebilmektedir ve burada 3. hedef neredeyse kaybolmuş 1. ve 3. Hedefin kuvveti ise oldukça azalmıştır bu durum tespit performansını etkilemektedir. ED dönüşümüne bakıldığında gerçek veri de TBA ve BBA ile beraber en kötü sonuç olarak gösterilebilir. Sadece son hedef hariç enerji çizimi bakımından oldukça zayıftır. ÇYKS ve önerilen ÇYYOO algoritmalarına bakıldığında enerji seviyelerinin oldukça yüksek olduğu görülmektedir. Burada ÇYKS algoritması başlangıçta oluşturduğu tepe sinyali ile 1. hedefin tespit edilmesini güçleştirmekte ve yanlış alarm yol açmaktadır. Bu durum ÇYYOO yönteminde gözlenmemektedir çünkü 1. hedefin sinyali oldukça kuvvetlidir ve çevresindeki gürültülerden rahatlıkla ayrıştırılabilmektedir. 2. hedefte yine bir tepe gözlenmektedir ve diğerlerine metotlara göre yüksek olsa da tespit performansı açısından tatmin edici değildir. 3. hedef için bakıldığında tüm metotlar arasında en iyi sinyal kuvvetine sahip olduğunu görmekteyiz. Sonuncu hedef için

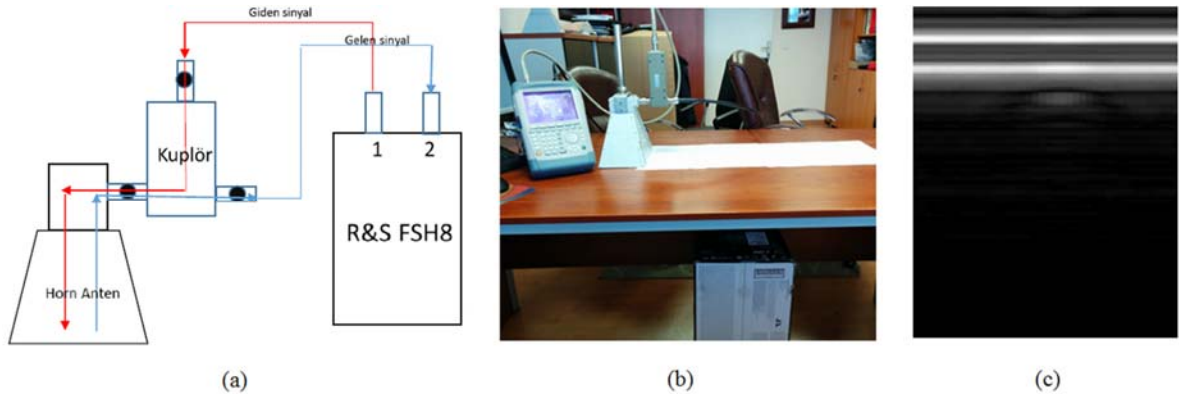
ise dar bir hüzmeye sahip olup hedefi yaymamıştır. Genel olarak bakıldığında gerçek hedef üzerindeki sayısal analizlere göre önerilen ÇYYOO metodunun gerçek veri üzerinde oldukça iyi sonuç verdiği gözlemlenmiştir.

Bu bölümün ikinci kısmında, laboratuvar ölçümlerinde elde edilen veri seti önerilen ve mevcut yöntemlerin performanslarının karşılaştırılması amacıyla kullanılmıştır. Bu veri setini oluşturmak için horn anten, kuplör ve vektör ağ analizörü (Vector Network Analyzer) (R&S FSH8) kullanılarak masa altında bulunan nesne için görüntüleme yapılmıştır. Şekil 17a'da deneysel veri seti hazırlamak için oluşturulan laboratuvar deney düzeneği gösterilmiştir. Bu deney düzeneğinde kullanılacak YNR dizaynı için kullanılan horn anten, kuplör ve vektör ağ analizörünün bağlantıları şekilde görüldüğü gibidir. Fiziksel deney ortamı ve deneyin tasarlanış biçimi Şekil 17b'de gösterilmiştir. Taranan bölge 80 cm uzunluğunda ve 2 cm aralıklarla sağa doğru taranarak, toplamda 40 adet ölçüm alınmıştır. Her lokasyonda 631 farklı genlik ve faz değerleri ölçülmüştür. Bu yüzden, YNR görüntüsünün anten konum sayısı 40 ve derinliği 631'dir. Vektör ağ analizörü, 1 GHz frekans bandından 4 GHz frekans bandına kadar olan aralıkta eşit aralıklı (Δf) olmak üzere toplam 631 ayrı frekans noktasında geri saçılma elektrik alan verisi (farklı genlik ve faz) toplanmıştır. Daha sonra 631x40 boyutlarındaki YNR görüntüsü tarama inceliğinin artırılması ve kırpmaya işlemlerinden sonra 150x40 boyutlarında indirgenmiştir.


Şekil 17b'de görüldüğü gibi masanın altına bir 5 cm'lik bağlantı ile bir 5 cm çapında ve 13 cm yüksekliğinde kola kutusu yerleştirilmiştir. Yerleştirilen kola kutusu alınan 40 ölçümün tam ortasında kalmaktadır. Dolayısıyla, bu senaryodan elde edilecek olan YNR görüntüsünde, kola kutusu 20. ölçümün olduğu hizadan itibaren gözlenmelidir ve ölçümler sonucunda elden edilen ham YNR görüntüsü Şekil 17c'de gösterilmiştir. Elde edilen ve Şekil 18a'da gösterilen YNR görünüşüne literatürde mevcut olan yöntemler ve tarafımızdan önerilen ÇYYOO yöntemi uygulanmıştır ve sonuçlar Şekil 18b-Şekil 18h'da gösterilmiştir. Görüntü laboratuvar ölçümleri sonucu elde edildiği için üretilen simüle verilere göre daha zor bir

görüntüdür ve yöntemlerin performansları bu sebeple azalmıştır. Şekil 18'de verilen görsel sonuçlar incelendiğinde; TBA, BBA ve TDA yöntemlerinin sonuçlarının birbirine oldukça benzer olduğu ve yüzey kargaşasını belirli ölçüde azalttıkları fakat belirgin yatay çizgilerin olduğu gözlemlenmektedir. MBA yöntemine bakıldığında, yüzey kargaşasının azaldığı fakat hedef üstünde bazı ekoların görüldüğü gözlenmektedir. Ayrıca tespit için kullanılan hedef sinyali kuvveti zayıflamıştır ve bu durum MBA'nın genel bir problemi. Sonuç olarak, bu faktörler MBA'nın tespit performansının azalmasına sebep olmaktadır. ÇYKS ve ÇYYOO yöntemleri karşılaştırıldığında, ikisinin benzer görseli ürettiği fakat ÇYYOO'nun hedef sinyalini yükselttiği görülmektedir. Bu önerilen ÇYYOO yönteminde var olan YOO süzgecinin doğal bir sonucudur. Hedef sinyalinin yükselmesi hedef tespitini istenen bir durumdur ve hedef tespit performansını arttırmaktadır. Bütün yöntemler incelendiğinde, ÇYYOO'nun tatmin edici bir görsel sonuç verdiğini söyleyebiliriz, hedef oldukça belirgin ve kargaşa büyük ölçüde giderilmiştir. ÇYKS ve MBA yöntemi ÇYYOO'yu takip etmektedir ve görsel olarak iyi sonuç vermektedir fakat hedef sinyalini zayıflatmışlardır ve bu istenmeyen bir durumdur. TBA, BBA ve TDA yöntemleri kargaşayı tam giderememiştir ama hedef sinyalinin yeri doğrudur.

Deneysel veri seti için AİK eğrilerinin çizdirilmesinde kullanılan enerji çizimleri hesaplanıp Şekil 18'de gösterilmiştir (enerji çizimi kırmızı renk kesikli çizgi ile çizdirilmiştir) ve bu enerji çizimleri sayesinde sonuçlar sayısal verilerle yorumlanabilmektedir. Bu sonuçlara göre, TBA, BBA, TDA ve MBA sonuçları birbirine benzerdir. Burada kargaşadan kaynaklı bir taban gürültüsünün olduğu görülmektedir (enerji çizimleri belirli bir seviyeden başlamaktadır.) Bu durum ÇYKS ve ÇYYOO yöntemlerinde mevcut değildir yani gürültü tabanı tam olarak bastırılmıştır. Her iki yöntemde de yönlü süzgeçlerden kaynaklanan yan loplara oluşmuştur ama bu yan loplara hedef tespit bölgesinde yer aldığı için sonucu etkilememektedir. ÇYKS ve ÇYYOO metodları karşılaştırıldığında, bu yan loplara etkisinin ÇYYOO'da daha az olduğu görülmektedir ve hedefin sinyal kuvveti ÇYYOO yönteminde daha kuvvetlidir.



Şekil 17. Deneysel veri setinin oluşturulması a) YNR sisteminin blok diyagramı b) Fiziksel Deney ortamı c) Elde edilen ham YNR görüntüsü (Construction of the experimental scenario a) Block diagram of the GPR b) Physical environment for the experiment c) Obtained raw GPR image)



Şekil 18. Deneysel veri seti için görsel sonuçlar a) Ham veri, hedef bilgisinin bulunması b) TBA [5] c) BBA [5] d) TDA [5] e) MBA [9] f) ED [11] g) ÇYKS [13] h) ÇYYOO (Visual results for the experimental dataset a) Raw data, target components obtained by b) PCA [5] c) ICA [5] d) SVD [5] e) MCA [9] f) CT [11] g) MDNF [13] h) MDNLM)

5. SONUÇLAR (CONCLUSIONS)

Bu makalede, çoklu çözünürlüklü ve çok yönlü yeni bir YNR kargaşa giderme algoritması önerilmiştir. YNR görüntüsü standart YOO süzgeci kullanılarak “a trous” dalgacık dönüşümü prosedürü ile alt bantlara ayrıştırılmış daha sonra bunlar YSB’den geçirilmiştir. Ters dönüşüm ise hedef bilgilerini saklayıp kargaşa bilgilerini yok ettikten sonra uygulanmış ve ham YNR görüntüsünün hedef bilgisi çıkarılmıştır. YOO süzgeci literatürde bilateral süzgeç ve komşuluk süzgecinden sonra ortaya çıkmış olup onlara karşı üstün bir performans sergilediği ortaya konmuştur. Özellikle kargaşalı durumlarda YOO süzgeci daha iyi sonuç vermektedir ve bu özellik YNR görüntüsünü detay bantlara ayırmamızda avantaj sağlamaktadır. Bu sayede daha çok detay görüntüden elde edilmektedir ve toplamsal kargaşaya karşı daha gürbüzdür. Yapılan sayısal ve görsel analizlerde önerilen ÇYYOO algoritmasının performansının literatürde mevcut yöntemlerden daha iyi olduğu hem benzetim veri setinde hem gerçek veri setlerinde gösterilmiştir. Önerilen metod kargaşayı giderirken hedef bilgisini zayıflatmamakta ve bu sayede AİK metriği üzerinden yüksek tespit imkanı vermektedir.

TEŞEKKÜR (ACKNOWLEDGEMENT)

YNR ölçümleri için Prof.Dr. Selçuk Pakler’e teşekkür ederiz.

KAYNAKLAR (REFERENCES)

1. Daniels, D. J., Surface-Penetrating Radar, 2nd edition, IEEE Press, 2004.
2. Akkaya, A.E. and Talu, M.F., Extended Kalman Filter Based IMU Sensor Fusion Application for Leakage Position Detection in Water Pipelines. Journal of the

Faculty of Engineering and Architecture of Gazi University, 32 (4), 1393-1404, 2017.

3. Abujarad, F., A. Jostingmeier, and A. S. Omar, Clutter Removal for Landmine Using different Signal Processing Techniques, Proc. of the Tenth IEEE International Conference Ground Penetrating Radar, Delft- The Netherlands, 697-700, Haziran 2004.
4. Brunzell, H., Detection of shallowly buried objects using impulse radar. IEEE Transactions on Geoscience and Remote sensing, 37(2), 875-886, 1999.
5. Verma, P. K, A. N. Gaikwad, D. Singh and, M. J. Nigam, Analysis of Clutter Reduction Techniques for Through Wall Imaging in UWB range, Progress In Electromagnetics Research B, 17, 29-48, 2009.
6. Abujarad, F., G. Nadim, and A. Omar, Clutter Reduction and Detection of Landmine Objects in Ground Penetrating Radar Data Using Singular Value Decomposition (SVD), Proc. of the 3rd International Workshop on Advanced Ground Penetrating Radar, Delft- The Netherlands, 37-42, Mayıs 2005.
7. Tuncer, T., A novel image authentication method based on singular value decomposition. Journal of the Faculty of Engineering and Architecture of Gazi University, 32(3), 877-886, 2017.
8. Kumlu, D., and I. Erer, A Comparative Study on Clutter Reduction Techniques in GPR Images, International Conference on Electrical and Electronics Engineering, Ankara-Türkiye, 323-328, Nisan 2017.
9. Temlioglu, E., and I. Erer, Clutter Removal in Ground-Penetrating Radar Images Using Morphological Component Analysis, IEEE Geoscience and Remote Sensing Letters, 13 (12), 1802-1806, 2016.
10. Kumlu, D. and Erer, I., Clutter removal techniques in ground penetrating radar for landmine detection: A

- Survey, Operations Research for Military Organizations, IGI global, 375-399, 2019.
11. Bao, Q. Z., Q. C. Li, and W. C. Chen, GPR Data Noise Attenuation on The Curvelet Transform, Applied Geophysics, 11 (3), 301-310, 2014.
 12. Terrasse, G., N. Jean-Marie, T. Emmanuel, and D. Emeline, Application of the Curvelet Transform for Clutter and Noise Removal in GPR Data, IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing, 10 (10), 4280-4294, 2017.
 13. Kumlu, D. and Erer, I., The multiscale Directional Neighborhood Filter and Its Application To Clutter Removal in GPR Data, Signal, Image and Video Processing, 12 (7), 1237-1244, 2018.
 14. Buades, A., B. Coll, and J.-M. Morel, A Non-Local Algorithm for Image Denoising, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego-USA 60-65, Haziran 2005.
 15. Hu, J., and S. Li, The Multiscale Directional Bilateral filter and Its Application To Multisensor Image Fusion, Information Fusion, 13 (3), 196-206, 2012.
 16. Yin, H., and S. Li, Pansharpening with Multiscale Normalized Nonlocal Means Filter: A Two-step Approach," IEEE Transaction on Geoscience and Remote Sensing, 53 (10), 5734-5745, 2015.
 17. Warren, C., G. Antonios, and G. Iraklis, gprMax: Open Source Software To Simulate Electromagnetic Wave Propagation for Ground Penetrating Radar, Computer Physics Communications, 209, 163-170, 2016.
 18. Temliolu, E., I. Erer, and D. Kumlu, A Least Mean Square Approach To Buried Object Detection for Ground Penetrating Radar, IEEE International Geoscience and Remote Sensing Symposium, Forth Worth-USA, 4833-4836, Temmuz 2017.
 19. Vrije Univ. Brussel (VUB). Real GPR data. <http://www.minedet.etro.vub.ac.be>. Erişim tarihi Eylül 01, 2011.