

# Uzaktan Algılama Görüntülerinde Şerit Gürültüsü Giderimi için ADOM Algoritmasının Sezgiseller ile Geliştirilmesi

İrem Nur EROĞLU<sup>1</sup>  Hasan Ali AKYÜREK<sup>2\*</sup> 

<sup>1</sup> Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Adli Bilişim Mühendisliği, Konya, Türkiye

<sup>2</sup> Necmettin Erbakan Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Havacılık Elektrik ve Elektronik, Konya, Türkiye

## Makale Bilgisi

## ÖZET

Geliş Tarihi: 23.05.2024  
Kabul Tarihi: 31.08.2024  
Yayın Tarihi: 31.12.2024

### Anahtar Kelimeler:

ADOM,  
Ağaç-Tohum Algoritması,  
Parçacık-Sürü Optimizasyonu,  
ADOM-PSO,  
ADOM-TSA,  
Gürültü Giderimi.

Uzaktan algılama sistemleri, Dünya yüzeyindeki değişikliklerin izlenmesi ve analizi açısından kritik öneme sahiptir. Ancak, bu sistemlerden elde edilen görüntülerde çeşitli gürültüler oluşabilir ve bu durum ölçümlerin doğruluğunu olumsuz etkileyebilir. Bu çalışmada, uzaktan algılama görüntülerindeki şerit gürültüsünü gidermek amacıyla ADOM (Alternating Direction Method of Multipliers) algoritmasının performansı optimize edilmiştir. Bu amaçla, iki sezgisel optimizasyon algoritması olan Ağaç-Tohum (TSA) ve Parçacık-Sürü Optimizasyonu (PSO) kullanılarak ADOM algoritmasının performansı artırılmıştır. ADOM algoritması, şerit gürültüsünü gidermek için geliştirilmiş bir optimizasyon modelidir ve bu modelin parametreleri TSA ve PSO algoritmaları ile optimize edilmiştir. Her iki algoritma da ADOM algoritmasının parametrelerini optimize ederek, şerit gürültüsünün giderilmesi sürecini iyileştirmeyi amaçlamaktadır. ADOM algoritmasının performansı, TSA ve PSO algoritmaları ile optimize edildikten sonra, şerit gürültüsünü giderme yetenekleri karşılaştırılmıştır. Sonuçlar, TSA ve PSO algoritmasının ADOM algoritmasını optimize etmede başarılı olduğunu göstermiştir. Benzer hesaplama maliyetinde ADOM-TSA ve ADOM-PSO algoritmalarının yalnız ADOM algoritması ve şerit gürültüsünü giderme ve görüntü kalitesini artırma konusunda istatistiksel olarak daha iyi sonuçlar ürettiğini gözlenmiştir. ADOM-TSA, ADOM-PSO'ya kıyasla şerit gürültüsünü gidermede daha yüksek bir performans sergilemiştir. Gelecekteki çalışmalar, farklı sezgisel algoritmaların denenmesi ve işlem maliyeti azaltılırken daha yüksek başarımın elde edilmesi üzerine odaklanmalıdır.

## Improving ADOM Algorithm with Heuristics for Stripe Noise Removal in Remote Sensing Images

### Article Info

### ABSTRACT

Received: 23.05.2024  
Accepted: 31.08.2024  
Published: 31.12.2024

### Keywords:

ADOM,  
Tree-Seed Algorithm,  
Particle Swarm Optimization,  
ADOM-PSO,  
ADOM-TSA,  
Noise Removal.

Remote sensing systems are critically important for monitoring and analyzing changes on the Earth's surface. However, the images obtained from these systems can contain various types of noise, which can adversely affect the accuracy of measurements. This study aims to optimize the performance of the ADOM (Alternating Direction Method of Multipliers) algorithm to remove stripe noise in remote sensing images. To this end, the performance of the ADOM algorithm has been enhanced using two heuristic optimization algorithms: Tree-Seed Algorithm (TSA) and Particle Swarm Optimization (PSO). The ADOM algorithm is an optimization model developed to remove stripe noise, and the parameters have been optimized using TSA and PSO algorithms. Both algorithms aim to improve the stripe noise removal process by optimizing the parameters of the ADOM algorithm. After optimizing the performance of the ADOM algorithm with TSA and PSO algorithms, their abilities to remove stripe noise were compared. The results showed that TSA and PSO algorithm were successful in optimizing the ADOM algorithm. It has been observed that, at similar computational costs, ADOM-TSA and ADOM-PSO algorithms produce statistically better results than the plain ADOM algorithm in removing stripe noise and improving image quality. ADOM-TSA showed a higher performance in strip noise removal compared to ADOM-PSO. Future work should focus on testing different heuristic algorithms and achieving higher performance while reducing the processing cost.

### To cite this article:

Eroğlu, İ.N. & Akyürek, H.A. (2024). Uzaktan algılama görüntülerinde şerit gürültüsü giderimi için ADOM algoritmasının sezgiseller ile geliştirilmesi. *Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 6(3), XX- XX. <https://doi.org/10.47112/neufmbd.2024.56>

\*Sorumlu Yazar: Hasan Ali Akyürek, [hakyurek@erbakan.edu.tr](mailto:hakyurek@erbakan.edu.tr)



This article is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

## GİRİŞ (INTRODUCTION)

İnsan faaliyetlerinin hız kazanmasıyla birlikte, Dünya'nın yüzeyi son yıllarda çeşitli arazi örtüsü değişiklikleriyle önemli ölçüde değişime uğramıştır [1]. Yer bilimi çalışmaları, birden fazla zaman ölçeğinde iklim değişikliği, mahsul üretiminin tahmin edilmesi, arazi kaynaklarının izlenmesi ve insan faaliyetinin ekosistem üzerindeki etkisinin anlaşılması gibi konuları ele almaktadır [2]. Bu tür problemlerin çözümünde ise uzaktan algılama sistemleri büyük önem taşımaktadır. Söz konusu sistemler, Dünya'yı uzaktan gözlemleyerek çeşitli ölçümler yapılmasına olanak sağlamaktadır. Uzaktan algılama sistemleri, yeryüzündeki ve gökyüzündeki sensörleri kullanarak bu ölçümleri desteklemektedir.

Uzaktan algılama, belirli durumları sensörler aracılığıyla tespit etme ve analiz etme sürecini kapsamaktadır. Bu teknoloji, elektromanyetik radyasyonun uzaktaki nesnelere etkileşerek yansması ve bu yansımanın algılanmasıyla nesnenin özelliklerini belirleme amacını taşımaktadır [3]. Uzaktan algılama görüntüleri (RSI), görüntüleme ve dijitalleştirme işlemleriyle elde edilmektedir ve bu veriler, Dünya'yı gözlemleme ve iklim değişikliği gibi farklı amaçlar için kullanılmaktadır [4]. Uzaktan algılama teknolojisinin hızla gelişmesi ve Dünya gözlem uydularının çeşitlenmesiyle birlikte, bu görüntüler yer bilimi çalışmalarında önemli bir veri kaynağı haline gelmiştir [1]. Uzaktan algılama görüntülerinde sensör özelliklerinden, sinyal iletiminden ve çevresel koşullardan kaynaklı çeşitli gürültüler oluşmaktadır ve bu gürültüler yer bilimi çalışmalarındaki ölçümleri etkilemektedir. Bu nedenle, bu gürültülerin giderilmesi için çeşitli algoritmalar geliştirilmiştir.

Song vd. [5] uzaktan algılama görüntülerindeki şerit gürültüsünü azaltmak için bir ağırlıklı çift seyreklikli tek yönlü varyasyon (WDSUV) modeli oluşturmuştur. Bu modelde, iki varyasyon terimi ve iki seyreklik terimi kullanarak yoğun şerit alanını, aşırı alanı ve düzenli gürültüyle bozulmuş alanların işlenmesi sağlanmıştır. Ardından, optimizasyon modelini alternatif bir minimizasyon çözümünde kullanmak için alternatif yönlü çarpanlar yöntemi (ADMM) kullanılmıştır.

Zhang vd. [6] yaptıkları çalışmada uzaktan algılama görüntülerindeki Gauss gürültüsünü gidermek amacıyla, kenar algılama ve diferansiyel gelişim (DE) yöntemlerine dayanan çoklu-optimizasyonlu ikili filtreleme (MOBF) algoritması önermişlerdir. Önerdikleri algoritmada, DE algoritmasını kullanarak, gri değer alanının standart sapmasına dayanan popülasyondaki bireyler, gizli çözüm vektörlerini iyileştirmek ve standart sapmayı optimize etmek için en uygun renk alanını belirlemek için yinelemeli mutasyon, çarpazlama ve seçim işlemlerine tabi tutulmuştur [6].

Han vd. [7] uzaktan algılama görüntülerindeki gürültüler için derin öğrenme yaklaşımı temelli bir gürültü giderici ağ modeli (RSIDNet) geliştirmişlerdir. Bu ağ temel olarak çok ölçekli öznetelik çıkarma modülü (MFE), birden fazla yerel bağlantılı gelişmiş dikkat bloğu (ECA), global özellik birleştirme bloğu (GFF) ve gürültülü görüntü yeniden oluşturma bloğu (NR) içerir. Bu modüllerin birleştirilmesi, çıkarılan özneteliklerin model tarafından daha iyi kullanılmasını sağlamaktadır ve modelin gürültü giderme yeteneğini artırmaktadır.

Zhou vd. [8] geliştirdikleri modelde uzaktan algılama görüntülerinden daha fazla öznetelik çıkarabilmek amacıyla, ağırlıklı alanını artırmak için DnCNN (denoising evrişimli sinir ağı) ağ çerçevesine genişletilmiş evrişim dahil etmiştir. Algoritmanın uygulanabilirliğini doğrulamak için yaptıkları çalışmada uzaktan algılama görüntüsünde Gauss ve tuz-biber gürültüsü giderme deneyleri ve gürültüsüz görüntüde kenar algılama analizleri gerçekleştirilmiştir. Objektif değerlendirme açısından, farklı gürültü giderme algoritmalarının performansı, ortalama kare hatası (MSE), tepe sinyal-gürültü oranı (PSNR) ve ortalama yapısal benzerlik indeksi (MSSIM) gibi ölçümler kullanılarak karşılaştırılmıştır.

Yan vd. [9] çalışmalarında uzaktan algılama görüntülerinde yatay şerit gürültüsünü ortadan

kaldırmak için yeni bir tek yönlü varyasyon modeli önermişlerdir. Şerit gürültüsünün küresel seyrekliğini ve dikey görüntü gradyanlarının yerel seyrekliğini karakterize etmek için quasinorm değerini kullanmaktadır. Bu değer doku desenlerini tamamen ayrılmış bir şekilde yakalamak için kullanılmaktadır. Ayrıca önerilen dışbükey olmayan modeli çözmek için ADMM tabanlı bir model geliştirmişlerdir.

Wang vd. [10] çalışmalarında hiperspektral uzaktan algılama görüntülerinde çoklu-detektör çizgisel tarama görüntüleme sistemlerinde oluşan şerit gürültüsünün giderimi için çok-ölçekli genişletilmiş tek yönlü evrişim ağı (MsDUC) yöntemini önermişlerdir. Bu yöntem, uzamsal-spektral korelasyonu korurken 3 boyutlu hiperspektral görüntülerde şerit gürültüsü giderimi için evrişim ağlarını kullanmaktadır.

Uzaktan algılama görüntülerindeki şerit gürültüsünü gidermede metot geliştiren başka bir çalışmada, doğrusal çizgi gürültü tespit algoritması (LSND) tabanlı bir model önerilmiştir. Li vd. [11] önerdikleri modelde doğrusal dönüşüm yoluyla şerit gürültüsü içeren çok sayıda uzaktan algılama görüntüsünü simüle ettikten sonra, eğitim süreci için yeni bir kayıp fonksiyonu ve algılama sürecinde kullanılan doğrusal nesnelere bastırılmasını tasarlayarak LSND adı verilen yeni bir doğrusal şerit gürültüsü algılama algoritması geliştirmişlerdir.


Bu çalışmada kullanılan ve Kim vd. [4] tarafından geliştirilen ADOM algoritması ise gözlemlenen görüntüden şerit gürültüsü bileşenlerini bulmaya yönelik bir optimizasyon fonksiyonu önermektedir. Ardından şerit gürültüsü bileşenini çıkarmak amacıyla optimizasyon fonksiyonunu çözmek için bir optimizasyon işlemi uygulanmaktadır. Optimizasyon sürecinde, verimli şerit gürültüsü bileşeni yakalama için ağırlığa dayalı bir algılama stratejisi ve şerit gürültüsünü hızlı bir şekilde ortadan kaldırmak için ADMM kullanılmaktadır.

Sezgisel optimizasyon algoritmaları, çeşitli optimizasyon problemlerini verimli bir şekilde çözmek için yaygın olarak kullanılan bir yöntem sınıfıdır. Bu algoritmalar, hesaplama açısından pahalı veya kesin optimizasyon yöntemleri kullanılarak çözülmesi mümkün olmayan karmaşık problemler için yaklaşık optimal çözümler bulmak üzere özel olarak tasarlanmıştır[12-15]. Sezgisel optimizasyon algoritmaları, yerel optimizasyonun ötesine geçen ve geniş bir problem yelpazesine uygulanabilen meta-sezgisel teknikleri de kapsamaktadır ve bu teknikler kümeleme problemleri [16], matematiksel problemler [17], görüntü işleme problemleri [18], eğri uydurma problemleri [19], nesne tespit problemleri[20] ve yapay sinir ağlarının eğitimi[21] gibi farklı alanlarda çeşitli problemlerin çözümü için uygulanmıştır.

Bu çalışmada RSI görüntülerindeki dikey şerit gürültüsünün giderilmesi amacıyla geliştirilen ADMM tabanlı ADOM algoritmasının, gürültü gidermedeki sürecini optimize edebilmek için sezgisel algoritmalar kullanılmıştır. Bu algoritmalarından iki tanesi kullanılmış olup gürültü gidermedeki iyileştirme performansı karşılaştırılmıştır. ADOM algoritmasında kullanılan parametreler sezgisel algoritmalarından Ağaç-Tohum (TSA)[12] ve Parçacık-Sürü Optimizasyonu (PSO)[13, 15] algoritmaları ile optimize edilerek RSI görüntülerinde mevcut olan şerit gürültüsünü gidermedeki işlevselliğin artırılması hedeflenmiştir.

ADOM algoritmasında bulunan lambda parametreleri TSA ve PSO algoritmaları ile optimize edilmiş ve ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının çıktıları piksel bazlı ölçüm kalitesi (PSNR) değeri, yapısal benzerlik endeksi (SSIM) değeri ve orijinal görüntü ile gürültülü görüntü arasındaki ortalama mutlak fark olan D değerleri kıyaslanmıştır. Şerit gürültüsü giderilmiş görüntü ile gözlenen görüntü arasında karşılaştırmalar yapılmıştır. Şekil 1.'de örnek şerit gürültülü görüntü, temiz orijinal görüntü ve bu görüntülerden temiz görüntü çıkarıldığında artakalan gürültü örneği verilmiştir. Bu görüntülerde kırmızı çevrelenmiş bölge büyütülerek gürültü ve gürültü giderimi başarısının

gözlemlenebilirliği artırılmıştır. Bu çalışmada sonuçlar karşılaştırılırken, şerit gürültüsünün ne kadar giderildiği ve temiz orijinal görüntüye olan benzerliği incelenmiştir.



### Şekil 1

(a) Orijinal temiz görüntü ve gürültü kalıntısı örneği, (b) orijinal şerit gürültüsü görüntüsü ve gürültü kalıntısı örneği

## MATERYAL VE METOD (MATERIALS AND METHOD)

Bu çalışmada kullanılan materyaller ve metotlar ile ilgili detaylı bilgi bu başlık altında toplanmıştır. Öncelikle uzaktan algılama görüntülerinde şerit gürültüsünü giderme amacıyla geliştirilen ADOM algoritması ve parametreleri optimize etmek için kullanılan TSA ve PSO ayrıntılı bir biçimde açıklanmıştır. Deneysel araştırmalar [4, 10] çalışmalarında ve [22] de paylaşılan verisetleri üzerine yürütülmüştür.

### ADOM Algoritması (ADOM Algorithm)

ADOM, uzaktan algılama görüntüsünde şerit gürültüsünün giderilmesi için ADMM tabanlı optimizasyon modelidir. Gözlemlenen görüntüden şerit gürültüsü bileşenlerini bulmak için bir optimizasyon fonksiyonu ve ardından şerit gürültüsü bileşenini çıkarmak için optimizasyon fonksiyonunu çözmek için optimizasyon işlemi formüle edilir. Optimizasyon sürecinde, şerit gürültüsü bileşeninin verimli bir şekilde yakalanması için ağırlığa dayalı bir algılama çözümü ve şerit gürültüsünün hızlı bir şekilde giderilmesi için ADMM tabanlı bir hızlandırma stratejisi işlenir. Çarpanların alternatif yön yöntemi (ADMM), amaç fonksiyonu için en uygun çözümü verimli bir şekilde üretmek için optimizasyon problemini daha küçük alt problemlere ayrıştırarak görüntü yok etmede yaygın olarak kullanılmaktadır. Ayrıca görüntü restorasyonunda kısıtlı optimizasyon problemlerini çözmek için yaygın olarak kullanılır [23]. ADMM algoritmasının kritik bir özelliği, bir alt problem için herhangi bir hazır görüntüdeki gürültü giderme algoritmasının takılmasına izin veren modüler yapısıdır.

Ağırlığa dayalı algılama stratejisinde, norm ve grup norm ağırlıklarının ayarlanmasıyla oluşturulan ağırlıklı normu kullanarak şerit gürültüsünü etkili bir şekilde tespit eder. Yani oluşturulan ağırlıklı normu kullanarak görüntü ayrıntılarına benzer şerit gürültüsünü ortaya çıkarır. İki kontrol stratejisi kullanarak optimizasyon sürecini hızlandırılır: kanıt tabanlı başlangıç noktası kontrolü ve momentum tabanlı adım boyutu kontrolü. İlki, şerit gürültü bileşenini daha doğru bir şekilde bulmak için eşik parametresini uygun şekilde ayarlayarak bir başlangıç noktası sağlarken, ikincisi momentum katsayısını kullanarak yakınsamayı hızlandırır ve sönümlenme katsayısından yararlanarak optimizasyon kararlılığı sağlar [4].

ADOM algoritmasının problem formülasyonunda şeritleme faktörünün eklemeli gürültü olduğu varsayılarak, RSI görüntülerindeki bozulma süreci şu şekilde ifade edilmektedir [4]:

$$O = D + S \quad (1)$$

Buradaki ifade sırasıyla  $O$  gözlenen görüntü,  $D$  istenen net görüntü ve  $S$  şerit gürültüsü bileşenini ifade eder. Denklem (1),  $O$ 'yu;  $D$  ve  $S$ 'nin toplamı olarak temsil eder.

Şerit gürültüsünü etkili bir şekilde gidermek için, şerit gürültüsünü  $O$ 'dan direkt olarak gidermek yerine  $S$ 'i bulmaya odaklanılır. Böylece, şerit gürültüsü giderme işlemi Denklem (2)'deki gibi gösterilebilir [4]:

$$D = O - S \quad (2)$$

Amaç yüksek kaliteli bir  $D$  elde etmek için görüntü ayrıntılarını korurken şerit gürültüsünün ön bilgisini kullanarak  $S$ 'i  $O$ 'dan ayırmaktır. Denklem (3)'te ADOM algoritmasının amaç fonksiyonu gösterilmiştir [4].

$$\operatorname{argmin}_S \left\{ \nabla_y S_1 + \lambda_1 \nabla_y (O - S)_{w_n,1} + \lambda_2 S_{w_g,2,1} \right\} \quad (3)$$

Burada  $\lambda_1$  ve  $\lambda_2$ , farklı terimler arasındaki kısıtlamaları dengelemek için iki pozitif düzenleme parametresidir. Bu değerler, bu çalışmada TSA ve PSO ile optimize edilen parametrelerdir.

$$\nabla_y S_1 \quad (4)$$

$$\lambda_1 \nabla_y (O - S)_{w_n,1} \quad (5)$$

$$\lambda_2 S_{w_g,2,1} \quad (6)$$

Denklem (4),  $S$ 'in dikey gradyanı için  $L_1$ -normunu temsil eder.  $O$ 'nun dikey gradyanında görünmediğinden,  $S$ 'nin dikey gradyanını en aza indirerek  $S$  bulunabilir [4].

Denklem (5),  $O$  ve  $S$  arasındaki farkın yatay gradyanı için ağırlıklı  $L_1$ -normunu gösterir. Geleneksel  $L_1$ -normunu kullanan yöntemler, şerit gürültüsüne benzer özelliklere yapışma eğilimi gösterdiğinden bazı bilgilerin kaybına neden olabilir. Bunu çözmek için,  $S$ 'i daha doğru bir şekilde tespit etmek amacıyla geleneksel  $L_1$ -normunu eşit yoğunlukta bir ' $w_n$ ' norm ağırlığı ile birleştiren ağırlıklı  $L_1$ -normunu kullanılır [4].

Denklem (6),  $S$ 'nin ağırlıklı  $L_{2,1}$  normunu gösterir. Geleneksel  $L_{2,1}$ -normu, şerit gürültüsünü bulma konusunda sınırlamalara sahiptir. Bu sorunu çözmek için, geleneksel  $L_{2,1}$  normunu bir grup normu ağırlığı ' $w_g$ ' ile birleştiren ağırlıklı bir  $L_{2,1}$  normu kullanılır. Ağırlıklı  $L_{2,1}$ -normu geleneksel  $L_{2,1}$ -normu ile her iterasyon adımında farklı yoğunluklara sahip her grupta ' $w_g$ ' kullanarak  $S$  daha etkili bir şekilde tespit edebilir [4].

$$\begin{aligned} & \underset{A,B,C,S}{\operatorname{argmin}} \left\{ A_1 + \lambda_1 B_{w_n,1} + \lambda_2 C_{w_g,2,1} \right\} \\ & \text{s. t. } A = \nabla_y S, B = \nabla_x (O - S), C = S \end{aligned} \quad (7)$$

Denklem (7), hesaplama verimliliği için  $A$ ,  $B$  ve  $C$  yardımcı değişkenlerini tanıtarak amaç fonksiyonu kısıtlı amaç fonksiyonuna dönüştürülmesini göstermektedir [4].

### Ağaç-Tohum Algoritması (Tree-Seed Algorithm)

Sürekli optimizasyon problemlerini çözmek için önerilen popülasyon tabanlı bir sezgisel arama algoritması olan TSA, 2015 yılında geliştirilmiştir [12]. TSA, ağaçlar ve tohumlardan oluşan bir yapı kullanarak olası çözümleri temsil etmektedir. Algoritmanın başlangıç aşamasında, ağaçlar arama uzayında rastgele olarak oluşturulur.

TSA algoritmasında iki özel kontrol parametresi bulunmaktadır: arama eğilimi ( $ST$ ) ve her ağaç için üretilecek tohum sayısı ( $NS$ ). TSA'da iki güncelleme denklemi kullanılır ve  $ST$ , güncelleme denkleminin seçimini kontrol ederken,  $NS$  üretilecek tohum sayısını belirler. İlgili çalışmada yapılan analizler,  $ST$ 'nin 0,1 için uygun olduğunu ve  $NS$ 'nin topluluğun %10 ile %25'i arasında değişebileceğini göstermiştir. Bu parametreler, optimizasyon probleminin özelliklerine bağlı olarak ayarlanmalıdır [12].

Arama uzayında iki denklem bulunmaktadır. Denklem (8), ağaç popülasyonunun en iyi konumu için tohumların üretilmesini ifade eder [12].

$$S_{i,j} = T_{i,j} + \alpha_{i,j}(B_j - T_{r,j}) \quad (8)$$

Burada  $S_{i,j}$ , ağaçla üretilecek tohumun  $j$ 'inci boyutunu,  $T_{i,j}$  ise  $i$ 'inci ağacın  $j$ 'inci boyutunu temsil eder.  $B_j$ , en iyi ağacın  $j$ 'inci boyutunu ifade etmektedir.  $\alpha_{i,j}$ ,  $[-1, 1]$  aralığında rastgele üretilen ölçeklendirme faktörünü ifade etmektedir.

Denklem (9) ise yeni bir tohum üretimi için popülasyon içinde iki farklı ağaç konumu kullanılır [24].

$$S_{i,j} = T_{i,j} + \alpha_{i,j}(T_{i,j} - T_{r,j}) \quad (9)$$

Burada  $S_{i,j}$ , ağaçla üretilecek tohumun  $j$ 'inci boyutunu,  $T_{i,j}$  ise  $i$ 'inci ağacın  $j$ 'inci boyutunu temsil eder.  $T_{r,j}$ , ise  $i$ 'inci ağacın  $j$ 'inci boyutunu ifade etmektedir.  $\alpha_{i,j}$ ,  $[-1, 1]$  aralığında rastgele üretilen ölçeklendirme faktörünü ifade etmektedir.

Başlangıç ağaç konumları şu denklem (10) kullanılarak üretilir:

$$T_{i,j} = L_{j,min} + r_{i,j}(H_{j,max} - L_{j,min}) \quad (10)$$

Burada  $L_{j,min}$ , arama uzayının alt sınırını,  $H_{j,max}$ , arama uzayının üst sınırını temsil eder ve  $r_{i,j}$ , her bir boyut ve konum için  $[0, 1]$  aralığında rastgele üretilen bir sayıdır. Optimizasyon problemine olası çözümler olan başlangıç ağaç konumları bu denkleme göre belirlenir [12].

Minimizasyon için popülasyondan en iyi çözüm denklem (11) kullanılarak seçilir:

$$B = \min\{f(\vec{T}_i)\} \quad i = 1, 2, \dots, N \quad (11)$$

Burada  $N$ , popülasyondaki ağaç sayısını ifade eder.

Başlangıç kümesi rastgele belirlenen bir miktarda oluşturulur. Problemdaki amaç fonksiyonu değerinin hesaplanabilmesi için oluşturulan  $N$  tane popülasyondaki her bir ağaç modellenir. Bu hesaplamadan sonra, çözüm için her bir ağaç için tohumlar üretilir. Tohumların amaç fonksiyonu değerleri hesaplanır ve kendi ana ağaçları ile kıyaslanır. Başarılı olan tohum, mevcut popülasyonun en

yeni ağacı olur. Popülasyondaki ağaç ve tohumların karşılaştırılmasından sonra oluşan yeni popülasyon arasından en optimize ağaç tespit edilir. Süreç boyunca ağaçlar ve tohumlar arama uzayı boyunca yinelemeli olarak güncellenir ve küresel ve yerel aramayı tamamlamak için sürekli olarak yeni tohumlar üretilir [25]. En başta belirlenen maksimum değere ulaşana kadar tohum üretimi ve karşılaştırma işlemi devam eder. Maksimum sayıya ulaşıldığında, elde edilen sonuç en uygun çözüm olarak kabul edilir [12].

TSA algoritmasında amaç fonksiyonu çalıştırılma sayısı popülasyon boyutuna ve tohum sayısı rassallığına (%10-%25 arasında) bağlı olarak değişeceği için popülasyon sayısı  $N$ , 40 olarak belirlenmiş,  $ST$  parametresi literatürde yer aldığı gibi 0,1 olarak bırakılmıştır. Böylece çalıştırılan toplam ADOM adımı diğer algoritmalarla doğru bir kıyaslama yapılabilmesi için eşit tutulmaya çalışılmıştır.

### **Parçacık-Sürü Optimizasyonu Algoritması (Particle-Swarm Optimization Algorithm)**

PSO algoritması, popülasyon tabanlı sezgisel algoritmalar arasında popüler bir yöntemdir. 1995 yılında tanıtılmasından bu yana geniş çapta araştırılmış ve yüzlerce PSO versiyonu geliştirilmiştir. Bu araştırmalar, algoritmanın yakınsaması ve parametreleştirilmesine ilişkin çok sayıda teorik ve ampirik bulguya yol açmıştır [26].

Çoğu uygulamada, PSO algoritmasını kullananlar, 1995'teki ilk öneriyi takip ederek popülasyon boyutunu 20-50 parçacıkla sınırlandırmaktadır [26]. Bu algortmada, tamamen bağlantılı bir sürü bulunmaktadır; bu, tüm parçacıkların bilgiyi paylaştığı anlamına gelmektedir. Her parçacık, sürüdeki herhangi bir parçacığın şimdiye kadar bulunduğu en iyi konumu bilir [13, 15]. PSO'nun ilk aşamasında, tüm parçacıkların konumları ve hızları rastgele olarak başlatılır. Sonraki adımda, her parçacık kendi geçmişindeki en iyi konumu yerel optimum, tüm parçacıklar arasındaki en iyi konumu ise global optimum olarak kaydeder [27].

Her parçacığın konumu denklem (12) ve hızı denklem (13) ile hesaplanmaktadır.

$$x_{i,d}(it + 1) = x_{i,d}(it) + v_{i,d}(it + 1) \quad (12)$$

$$v_{i,d}(it + 1) = wv_{i,d}(it) + C_1 Rnd(0,1)[pb_{i,d}(it) - x_{i,d}(it)] + C_2 Rnd(0,1)[gb_d(it) - x_{i,d}(it)] \quad (13)$$

Hız denkleminde, hız güncellemesi, her biri özel bir anlama sahip olan farklı bileşenlerin toplamından oluşur [13, 15]. İlk terim, önceki hızı ifade eden momentum bileşenidir. İkinci terim, parçacığın şimdiye kadar bulunduğu en iyi konuma olan mesafesine dayanan bilişsel bileşendir. Üçüncü terim ise, sürüdeki herhangi bir parçacığın bulunduğu en iyi konuma olan mesafesine dayanan sosyal bileşendir.

Konum açısından, sürüdeki tüm parçacıklar arama uzayında istenilen şekilde dağıtılarak  $n$  boyutlu uzayda konumlandırılır. Bunu yapmanın iki yaygın yolu, parçacıkları rastgele veya düzgün bir şekilde konumlandırmaktır. Hız genellikle rastgele bir değere ayarlanır, ancak büyük başlangıç sapmalarını önlemek için daha düşük hızlar genellikle daha uygundur. Sosyal ve bilişsel bileşenlerin ölçek değerleri, optimizasyon süreci boyunca sabit tutulur ve başlangıç aşamasında belirlenir [13, 15].

PSO algoritmasının parametrelerinin belirlenmesi ile ilgili literatürde birçok yöntem önerilmiştir [28]. Literatürde yer alan çalışmalarda ve önerilen yöntemler referans alınarak  $w$ ,  $C_1$  ve  $C_2$  parametreleri sırasıyla 0,5, 1,5 ve 1,5 olarak belirlenmiştir. Parçacık sayısı ve toplam iterasyon sayısı ise toplam ADOM adımı eşit olacak şekilde sırasıyla 10 ve 30 olarak belirlenmiştir.

### **ADOM-PSO & ADOM-TSA Algoritmaları (ADOM-PSO & ADOM-TSA Algorithms)**

ADOM algoritmasının başarılı sonuçlar üretebilmesi için çözmeye çalıştığı alt problemlerin parametrelerinin tayini oldukça önemlidir. Bu parametreler özellikle yakınsama süreçlerine ciddi etki etmektedir. Bu nedenle optimum yakınsamayı sağlamak için optimum parametrelerin tespit edilmesi

gerekmektedir. Önerilen yöntemde ADOM algoritmasının yakınsama değerini belirlenen iterasyon sayısında minimize eden parametreleri PSO ve TSA algoritmaları ile tespit edilerek, ADOM algoritması bu tespit edilen parametreler ile çalıştırılması sağlanmaktadır. ADOM, PSO ve TSA algoritmaları için seçilen parametreler Tablo 1’de verilmiştir.

**Tablo 1**

*Algoritmaların Parametreleri.*

Parametre\Algoritma	ADOM	ADOM-PSO	ADOM-TSA
$\lambda_1$	0,01	[0,001 – 0,02]	[0,001 – 0,02]
$\lambda_2$	0,01	[0,001 – 0,02]	[0,001 – 0,02]
$N$	-	10	40
$ST$	-	-	0,1
$w$	-	0,5	-
$C_1$	-	1,5	-
$C_2$	-	1,5	-

Yapay şerit gürültüleri [4] de önerilen periyodik olmayan şeritler referans alınarak üretilmiş ve -40 ile 40 arasında yoğunlukta rastgele oluşturulan şerit gürültüleri referans görüntüde %40 gürültü oluşturacak şekilde rastgele dağıtılmıştır.

Önerilen yöntemin sözde-kodu Şekil 2’de verilmiştir.

```
{
  Görüntüyü yükle
  Yapay şerit gürültüsü ekle
  Optimum parametreleri bul (PSO/TSA ve Amaç Fonksiyonu=ADOM(max_iter=20)Hata oranı)
  return ADOM(max_iter=2000,params=optimal)
}
```

**Şekil 2**

*Önerilen yöntemin sözde-kodu.*

Üretilen yapay şerit gürültülü görüntünün gürültüsünün giderimi için optimal parametrelerin tayini için PSA/TSO optimizasyon algoritmaları kullanılmaktadır. Bu algoritmalarının optimum parametre tespiti yaparken ihtiyacı olan amaç fonksiyonu olarak ADOM algoritmasını 20 iterasyon çalıştırılarak duraklatılmış elde edilen hata oranının minimize edilmesi hedeflenmiştir. Böylece hızlı bir şekilde yakınsama başarımı yüksek olan parametreler tespit edilerek ADOM algoritması bu parametreler ile nihai olarak çalıştırılmaktadır.

## BULGULAR (RESULTS)

Çalışma literatürde yaygın bir şekilde kullanılan 9 farklı RSI görüntüsü ile yapılmıştır. Görüntüler sırasıyla Cuprite1, Botswana, Cuprite2, KSC, MUUFL Gulfport, PaviaC, PaviaU, Salinas ve Urban görüntüleridir [4, 22, 29]. Çalışma i9-14900 işlemci üzerinde Matlab 2024a kullanılarak gerçekleştirilmiştir. Algoritma performansları çalışma süresi, Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM), piksel başına hata (D error/px) ve toplam ADOM adımı (ADOM STEP) metrikleri kullanılarak karşılaştırılmıştır. Ayrıca, elde edilen sonuçlar arasındaki farklılığı istatistiksel olarak anlamlılığını ölçmek için Wilcoxon Signed-Rank testi ile algoritmaların istatistiksel olarak anlamlı performans farklılıkları belirlenmiştir. Test sonuçları P-değerlerine göre değerlendirilmiş ve anlamlı farklar "+" ile gösterilmiştir. Her üç yöntem de 15 farklı tur çalıştırılmış ve sonuçların ortalamaları ve standart sapmaları uzaktan algılama görüntüleri için Tablo 2. de verilmiştir.



**Tablo 2**  
Çıktı Değerleri ve Değerlerin Karşılaştırılması.

VERİ SETİ	ALGORİTMA	ÇALIŞMA SÜRESİ(sn)	PSNR	SSIM	D (error/px)	ADOM STEP
RSI-1	ADOM	29±1	46,23±1,59	99,7762%±0,00	0,84±0,12	4000±0
	ADOM-PSO	30±1	45,25±1,52	99,6864%±0,00	0,93±0,12	4000±0
	ADOM-TSA	31±2	45,31±1,63	99,6909%±0,13	0,92±0,13	4234±112
RSI-2	ADOM	28±1	57,57±2,13	99,9863%±0,00	0,23±0,05	4000±0
	ADOM-PSO	28±1	58,09±3,96	99,9738%±0,00	0,22±0,16	4000±0
	ADOM-TSA	31±1	58,77±1,46	99,9895%±0,04	0,19±0,04	4385±70
RSI-3	ADOM	28±1	54,30±2,36	99,9783%±0,00	0,35±0,08	4000±0
	ADOM-PSO	29±1	40,04±1,81	98,2342%±0,01	1,40±0,29	4000±0
	ADOM-TSA	31±1	40,40±5,48	97,5303%±0,78	1,57±0,78	4230±75
RSI-4	ADOM	28±1	61,48±2,79	99,9771%±0,00	0,16±0,04	4000±0
	ADOM-PSO	28±0	63,32±11,14	99,9879%±0,01	0,32±0,55	4000±0
	ADOM-TSA	31±1	62,10±6,99	99,9856%±0,16	0,23±0,16	4422±110
RSI-5	ADOM	29±1	43,37±2,27	99,6961%±0,00	1,16±0,29	4000±0
	ADOM-PSO	29±1	43,33±2,25	99,6914%±0,00	1,16±0,29	4000±0
	ADOM-TSA	31±1	43,57±2,19	99,7829%±0,29	1,15±0,29	4200±127
RSI-6	ADOM	29±1	42,47±1,33	99,8322%±0,00	1,33±0,19	4000±0
	ADOM-PSO	30±1	42,60±1,28	99,8328%±0,00	1,33±0,16	4000±0
	ADOM-TSA	31±2	42,63±1,27	99,8342%±0,16	1,33±0,16	4252±111
RSI-7	ADOM	28±1	47,36±1,28	99,8876%±0,00	0,72±0,09	4000±0
	ADOM-PSO	29±1	47,42±1,36	99,8890%±0,00	0,71±0,09	4000±0
	ADOM-TSA	31±1	47,29±1,32	99,8806%±0,10	0,73±0,10	4264±129
RSI-8	ADOM	28±1	47,29±2,73	99,9614%±0,00	0,55±0,11	4000±0
	ADOM-PSO	29±1	43,34±5,26	99,2876%±0,01	1,08±0,48	4000±0
	ADOM-TSA	31±1	45,09±4,08	99,6275%±0,39	0,87±0,39	4268±68
RSI-9	ADOM	28±1	44,67±1,45	99,7263%±0,00	0,99±0,16	4000±0
	ADOM-PSO	29±1	44,54±1,25	99,7187%±0,00	1,00±0,14	4000±0
	ADOM-TSA	31±1	44,71±1,35	99,7298%±0,14	0,99±0,14	4222±90

Elde edilen sonuçlar arasındaki farklılığı istatistiksel olarak anlamlılığını ölçmek için yapılan Wilcoxon Signed-Rank testi sonuçları ise Tablo 3'te verilmiştir.


**Tablo 3**  
Wilcoxon Signed-Rank Testi Sonuçları.

ALGORİTMA\VERİ SETİ	RSI-1	RSI-2	RSI-3	RSI-4	RSI-5	RSI-6	RSI-7	RSI-8	RSI-9
ADOM-PSO	-	+	-	+	-	+	+	-	-
ADOM-TSA	-	+	-	+	+	+	-	-	+

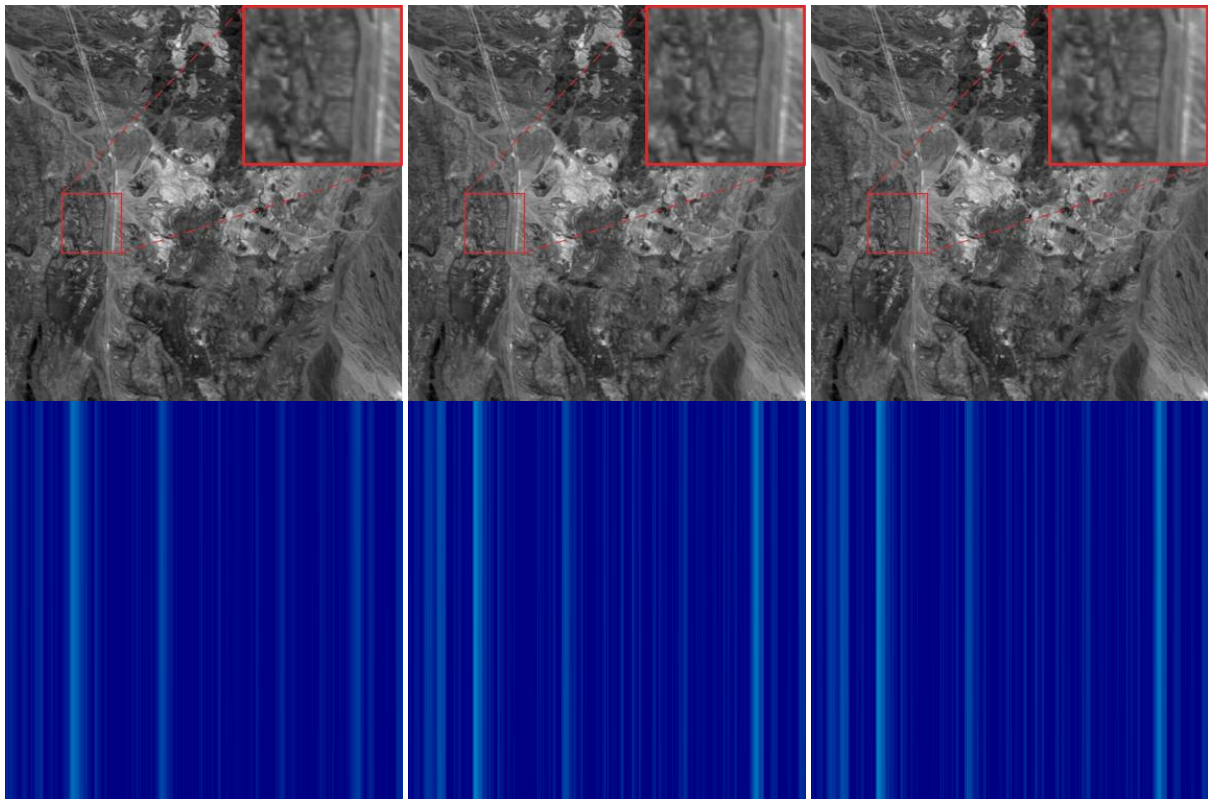
\*  $p < 0,05$  olan değerler (+) olarak, diğer değerleri ise (-) olarak gösterilmiştir.

Elde edilen sonuçlar PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her bir veriseti için ayrı ayrı değerlendirilmiş ve sırayla verilmiştir.

RSI-1 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntılarını Şekil 3'te verilmiştir.



(a)



(b)

(c)

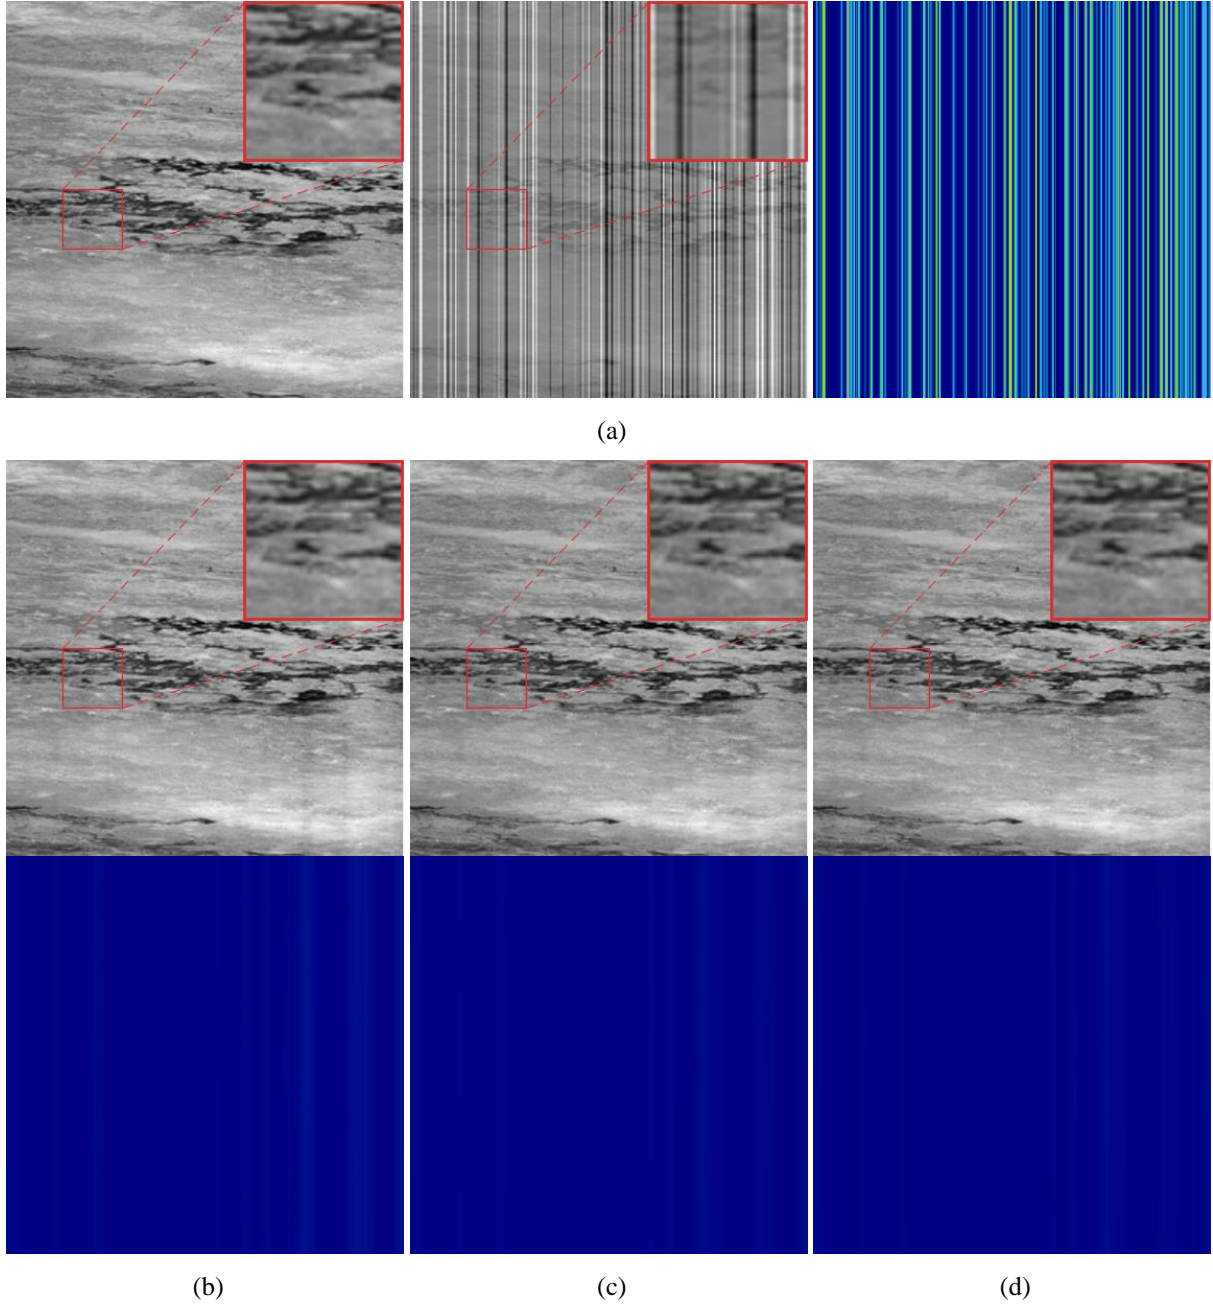
(d)

### Şekil 3

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

RSI-1 veriseti ile yapılan denemelerde ADOM algoritması  $29 \pm 1$  saniyede  $46,23 \pm 1,59$  PSNR ve  $\%99,7762 \pm 0,00$  SSIM ile temel performansı göstermiştir. ADOM-PSO  $45,25 \pm 1,52$  PSNR ve  $\%99,6864 \pm 0,00$  SSIM ile yakın performans sergilemiştir. ADOM-TSA ise  $45,31 \pm 1,63$  PSNR ve  $\%99,6909 \pm 0,13$  SSIM ile yakın sonuçlar vermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da ADOM algoritmasına göre istatistiksel olarak anlamlı bir fark göstermemektedir ( $P\text{-Value} \geq 0,05$ ).

RSI-2 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 4'te verilmiştir.




#### Şekil 4


(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

RSI-2 veriseti ile yapılan denemelerde ADOM  $57,57 \pm 2,13$  PSNR ve  $\%99,9863 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO kombinasyonu  $58,09 \pm 3,96$  PSNR ve  $\%99,9738 \pm 0,00$  SSIM ile benzer performans göstermiştir. ADOM-TSA ise  $58,77 \pm 1,46$  PSNR ve  $\%99,9895 \pm 0,04$  SSIM ile daha yüksek performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da ADOM algoritmasına göre istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir (P-Value < 0,05).

RSI-3 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 5'te verilmiştir.



(a)



(b)

(c)

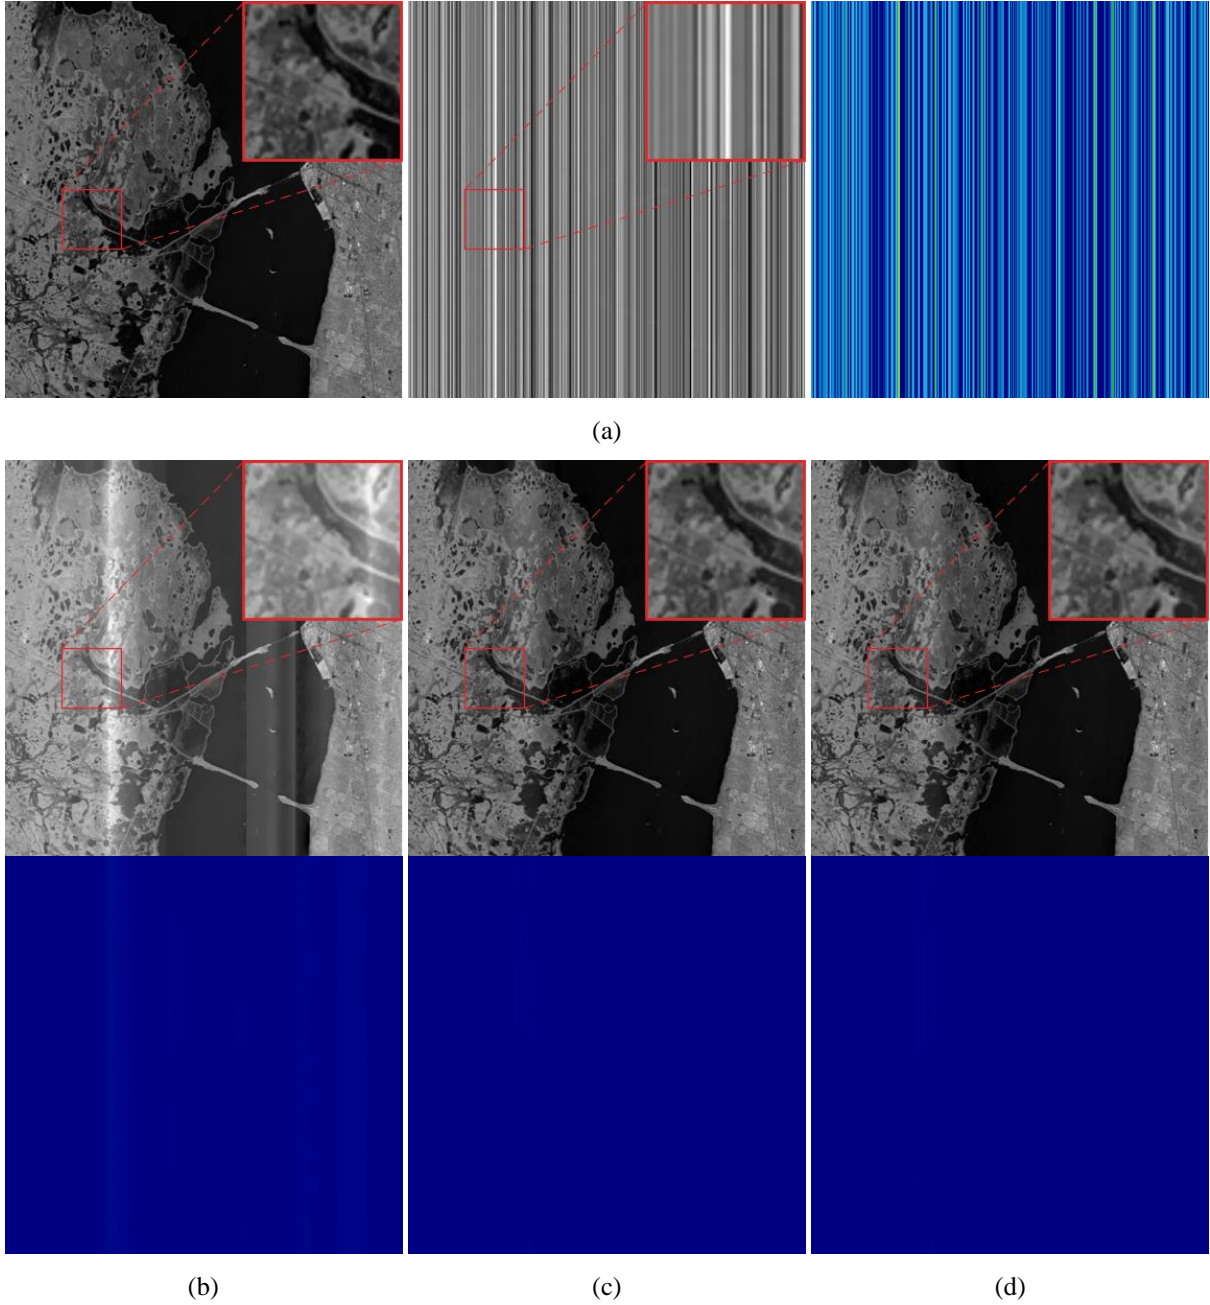
(d)

### Şekil 5

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

RSI-3 veriseti ile yapılan denemelerde ADOM algoritması  $54,30 \pm 2,36$  PSNR ve  $\%99,9783 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $40,04 \pm 1,81$  PSNR ve  $\%98,2342 \pm 0,01$  SSIM ile düşük performans göstermiştir. ADOM-TSA ise  $40,40 \pm 5,48$  PSNR ve  $\%97,5303 \pm 0,78$  SSIM ile benzer şekilde düşük performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da ADOM algoritmasına göre istatistiksel olarak anlamlı bir fark göstermemektedir ( $P\text{-Value} \geq 0,05$ ).

RSI-4 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 6'da verilmiştir.




**Şekil 6**


(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

RSI-4 veriseti ile yapılan denemelerde ADOM algoritması  $61,48 \pm 2,79$  PSNR ve  $\%99,9771 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO kombinasyonu  $63,32 \pm 11,14$  PSNR ve  $\%99,9879 \pm 0,01$  SSIM ile daha yüksek performans göstermiştir. ADOM-TSA ise  $62,10 \pm 6,99$  PSNR ve  $\%99,9856 \pm 0,16$  SSIM ile benzer performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da ADOM algoritmasına göre istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir (P-Value  $< 0,05$ ).

RSI-5 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 7'de verilmiştir.



(a)



(b)

(c)

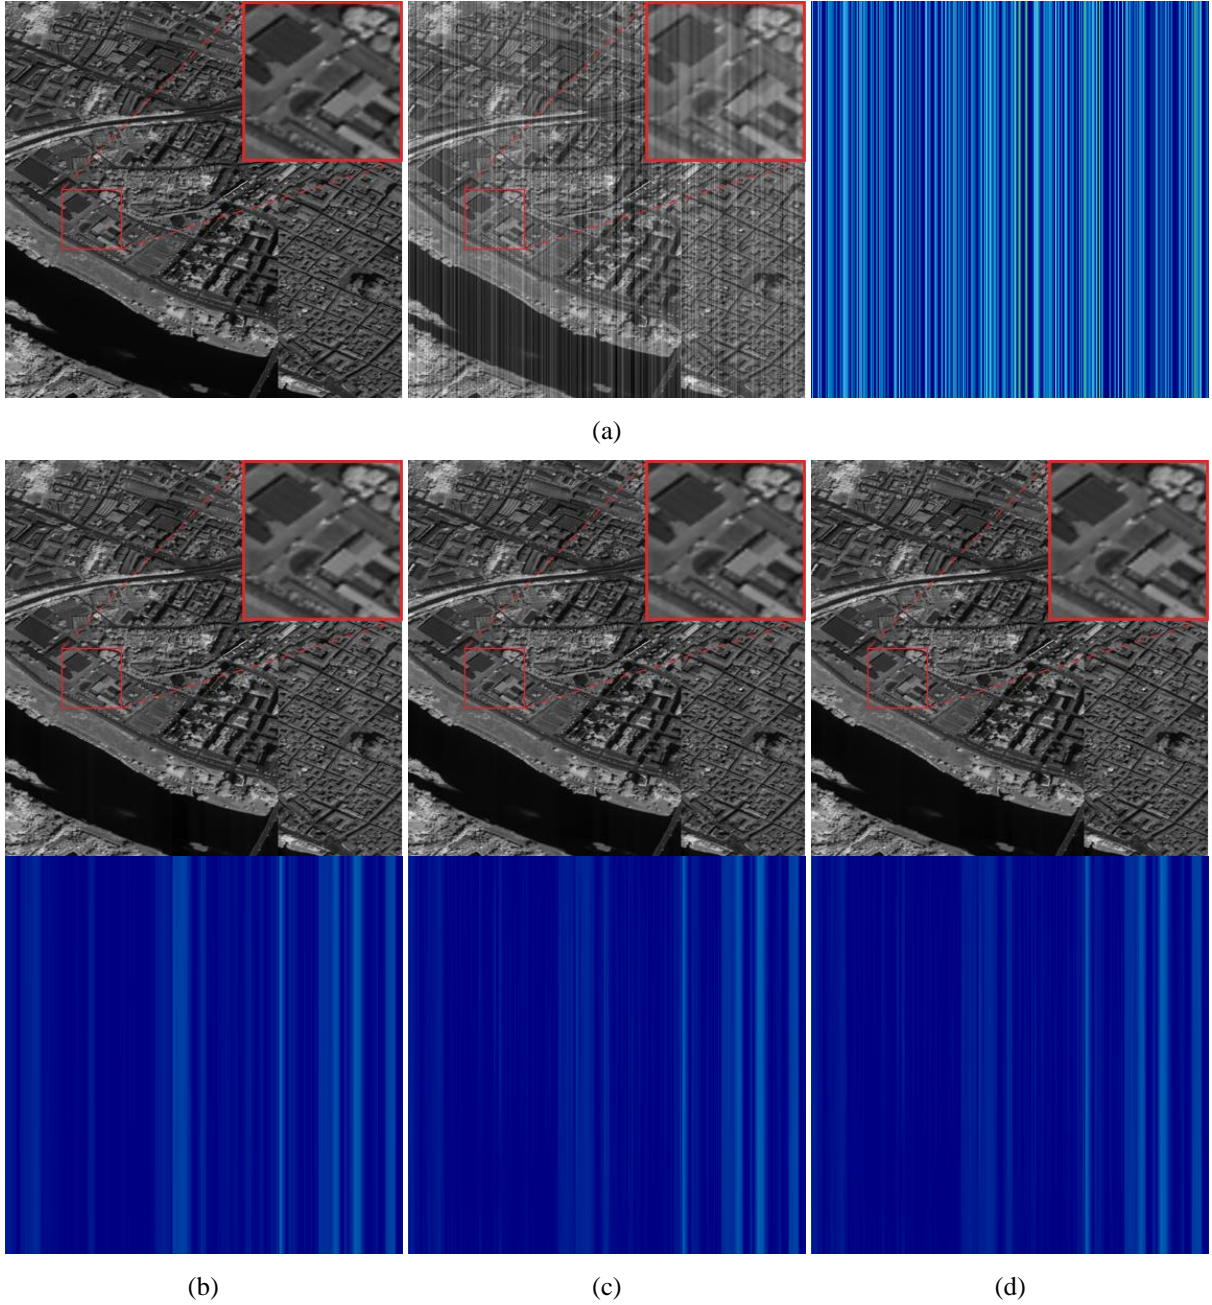
(d)

### Şekil 7

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

RSI-5 veriseti ile yapılan denemelerde ADOM algoritması  $43,37 \pm 2,27$  PSNR ve  $\%99,6961 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO kombinasyonu  $43,33 \pm 2,25$  PSNR ve  $\%99,6914 \pm 0,00$  SSIM ile benzer performans göstermiştir. ADOM-TSA ise  $43,57 \pm 2,19$  PSNR ve  $\%99,7829 \pm 0,29$  SSIM ile daha iyi sonuçlar vermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre ADOM-TSA algoritması istatistiksel olarak anlamlı bir fark göstermektedir (P-Value  $< 0,05$ ), ancak ADOM-PSO algoritması için istatistiksel olarak anlamlı bir fark bulunmamaktadır (P-Value  $\geq 0,05$ ).

RSI-6 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 8'de verilmiştir.




**Şekil 8**


(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

RSI-6 veriseti ile yapılan denemelerde ADOM algoritması  $42,47 \pm 1,33$  PSNR ve  $\%99,8322 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $42,60 \pm 1,28$  PSNR ve  $\%99,8328 \pm 0,00$  SSIM ile daha iyi performans göstermiştir. ADOM-TSA ise  $42,63 \pm 1,27$  PSNR ve  $\%99,8342 \pm 0,16$  SSIM ile daha iyi performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir (P-Value  $< 0,05$ ).

RSI-7 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 9'da verilmiştir.



(a)



(b)

(c)

(d)


### Şekil 9

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı


RSI-7 veriseti ile yapılan denemelerde ADOM algoritması  $47,36 \pm 1,28$  PSNR ve  $\%99,8876 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $47,42 \pm 1,36$  PSNR ve  $\%99,8890 \pm 0,00$  SSIM ile daha iyi performans göstermiştir. ADOM-TSA ise  $47,29 \pm 1,32$  PSNR ve  $\%99,8806 \pm 0,10$  SSIM ile benzer sonuçlar vermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre ADOM-TSA istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir (P-Value  $< 0,05$ ).

RSI-8 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 10'da verilmiştir.





(a)



(b)

(c)


(d)

### Şekil 10


(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

RSI-8 veriseti ile yapılan denemelerde ADOM algoritması  $47,29 \pm 2,73$  PSNR ve  $\%99,9614 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $43,34 \pm 5,26$  PSNR ve  $\%99,2876 \pm 0,01$  SSIM ile düşük performans göstermiştir. ADOM-TSA ise  $45,09 \pm 4,08$  PSNR ve  $\%99,6275 \pm 0,39$  SSIM ile benzer şekilde düşük performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da ADOM algoritmasına göre anlamlı bir fark göstermemektedir ( $P\text{-Value} \geq 0,05$ ).

RSI-9 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 11'de verilmiştir.



(a)



(b)

(c)

(d)

### Şekil 11

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

RSI-9 veriseti ile yapılan denemelerde ADOM algoritması  $44,71 \pm 1,45$  PSNR ve  $\%99,7263 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $44,54 \pm 1,25$  PSNR ve  $\%99,7187 \pm 0,00$  SSIM ile benzer performans göstermiştir. ADOM-TSA ise  $44,67 \pm 1,35$  PSNR ve  $\%99,7298 \pm 0,14$  SSIM ile daha iyi sonuçlar vermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre ADOM-TSA algoritması istatistiksel olarak anlamlı bir fark göstermektedir (P-Value  $< 0,05$ ), ancak ADOM-PSO algoritması için istatistiksel olarak anlamlı bir fark bulunmamaktadır (P-Value  $\geq 0,05$ ).

Yukarıda incelenen bulgular doğrultusunda ADOM algoritmasının genel olarak iyi performans gösterdiğini ancak ADOM-PSO ve ADOM-TSA algoritmalarının belirli veri setlerinde anlamlı şekilde daha iyi sonuçlar verdiğini göstermektedir. Özellikle RSI-2, RSI-4 ve RSI-6 veri setlerinde, her iki

algoritma da ADOM algoritmasına göre istatistiksel olarak anlamlı derecede daha iyi performans sergilemiştir. RSI-5 ve RSI-9 veri setlerinde yalnızca ADOM-TSA algoritması istatistiksel olarak anlamlı bir fark oluştururken, RSI-7 veri setinde ise yalnızca ADOM-PSO algoritması istatistiksel olarak anlamlı bir fark oluşturmuştur. RSI-1, RSI-3 ve RSI-8 veri setlerinde ilgili algoritmalar istatistiksel olarak anlamlı bir fark göstermemiştir. Bu sonuçlar, algoritma seçiminin veri setinin özelliklerine ve uygulama gereksinimlerine bağlı olarak yapılması gerektiğini ortaya koymaktadır.

Bu verisetlerine ek olarak şerit hatasının çizgisel tarama nedeniyle sıkça rastlandığı hiperspektral görüntüleme sistemlerinden elde edilen farklı hiperspektral görüntü (HSI) veri setleri üzerinde ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının performansları incelenmiştir. Algoritma performansları çalışma süresi, Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM), piksel başına hata (D error/px) ve toplam ADOM adımı (ADOM STEP) metrikleri kullanılarak karşılaştırılmıştır. Ayrıca, Wilcoxon Signed-Rank testi ile algoritmaların istatistiksel olarak anlamlı performans farklılıkları belirlenmiştir. Test sonuçları P-değerlerine göre değerlendirilmiş ve anlamlı farklar "+" ile gösterilmiştir. Her üç yöntem de 15 farklı tur çalıştırılmış ve sonuçların ortalamaları ve standart sapmaları uzaktan algılama görüntüleri için Tablo 4. de verilmiştir.

**Tablo 4**  
Çıktı Değerleri ve Değerlerin Karşılaştırılması


VERİ SETİ	ALGORİTMA	ÇALIŞMA SÜRESİ(sn)	PSNR	SSIM	D (error/px)	ADOM STEP
HSI-1	ADOM	29±1	39,83±1,04	99,7155%±0,00	0,73±0,07	4000±0
	ADOM-PSO	29±1	47,07±3,91	99,8905%±0,00	0,35±0,10	4000±0
	ADOM-TSA	31±1	47,05±3,61	99,8873%±0,09	0,35±0,09	4256±109
HSI-2	ADOM	29±1	50,13±4,52	99,9587%±0,00	0,23±0,08	4000±0
	ADOM-PSO	29±1	54,76±4,17	99,9710%±0,00	0,14±0,03	4000±0
	ADOM-TSA	31±1	54,68±4,07	99,9708%±0,03	0,14±0,03	4292±70
HSI-3	ADOM	29±1	48,39±2,31	99,9766%±0,00	0,18±0,06	4000±0
	ADOM-PSO	29±1	51,38±3,29	99,9834%±0,00	0,13±0,06	4000±0
	ADOM-TSA	31±1	51,47±3,60	99,9833%±0,06	0,13±0,06	4238±69
HSI-4	ADOM	29±1	61,99±3,93	99,9808%±0,00	0,08±0,03	4000±0
	ADOM-PSO	29±1	61,69±3,01	99,9725%±0,00	0,08±0,02	4000±0
	ADOM-TSA	30±1	62,25±2,94	99,9765%±0,02	0,08±0,02	4190±91
HSI-5	ADOM	29±1	66,21±2,31	99,9919%±0,00	0,04±0,01	4000±0
	ADOM-PSO	29±1	68,74±2,76	99,9939%±0,00	0,04±0,01	4000±0
	ADOM-TSA	31±1	67,68±5,62	99,9924%±0,03	0,05±0,03	4220±90
HSI-6	ADOM	29±1	61,40±2,17	99,9755%±0,00	0,10±0,02	4000±0
	ADOM-PSO	29±1	59,81±1,28	99,9578%±0,00	0,12±0,01	4000±0
	ADOM-TSA	31±1	59,54±0,96	99,9556%±0,01	0,12±0,01	4290±86
HSI-7	ADOM	29±1	47,33±1,60	99,9395%±0,00	0,21±0,05	4000±0
	ADOM-PSO	29±1	58,53±4,58	99,9774%±0,00	0,10±0,02	4000±0
	ADOM-TSA	31±1	59,00±4,55	99,9801%±0,03	0,09±0,03	4228±94
HSI-8	ADOM	29±1	66,46±2,36	99,9950%±0,00	0,05±0,01	4000±0
	ADOM-PSO	29±1	65,28±1,63	99,9905%±0,00	0,06±0,01	4000±0
	ADOM-TSA	31±1	64,94±1,77	99,9892%±0,01	0,06±0,01	4244±100
HSI-9	ADOM	29±0	53,76±1,87	99,9391%±0,00	0,23±0,04	4000±0
	ADOM-PSO	29±1	53,52±1,07	99,9244%±0,00	0,24±0,03	4000±0
	ADOM-TSA	32±1	53,13±1,55	99,9181%±0,05	0,26±0,05	4316±77

Elde edilen sonuçlar arasındaki farklılığı istatistiksel olarak anlamlılığını ölçmek için yapılan Wilcoxon Signed-Rank testi sonuçları ise Tablo 5. te verilmiştir.

**Tablo 5**  
Wilcoxon Signed-Rank Testi Sonuçları

ALGORİTMA\VERİSETİ	HSI-1	HSI-2	HSI-3	HSI-4	HSI-5	HSI-6	HSI-7	HSI-8	HSI-9
ADOM-PSO	+	+	+	-	+	-	+	-	-
ADOM-TSA	+	+	+	+	+	-	+	-	-

Elde edilen sonuçlar PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her bir veri seti için ayrı ayrı değerlendirilmiş ve sırayla verilmiştir. HSI-1 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 12’de verilmiştir.




**Şekil 12**

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-1 veriseti ile yapılan denemelerde ADOM algoritması  $29 \pm 1$  saniyede  $39,83 \pm 1,04$  PSNR ve  $99,7155 \pm 0,00$  SSIM ile temel performansı göstermiştir. ADOM-PSO  $47,07 \pm 3,91$  PSNR ve  $99,8905 \pm 0,00$  SSIM ile daha yüksek performans sergilemiştir. ADOM-TSA ise  $47,05 \pm 3,61$  PSNR ve  $99,8873 \pm 0,09$  SSIM ile daha yüksek performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da ADOM algoritmasına göre istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir ( $P\text{-Value} < 0,05$ ).

HSI-2 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 13'de verilmiştir.




**Şekil 13**

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-2 veriseti ile yapılan denemelerde ADOM  $50,13 \pm 4,52$  PSNR ve  $\%99,9587 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO kombinasyonu  $54,76 \pm 4,17$  PSNR ve  $\%99,9710 \pm 0,00$  SSIM ile daha iyi sonuçlar vermiştir. ADOM-TSA ise  $54,68 \pm 4,07$  PSNR ve  $\%99,9708 \pm 0,03$  SSIM ile benzer performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da ADOM algoritmasına göre istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir ( $P\text{-Value} < 0,05$ ).

HSI-3 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 14'te verilmiştir.




**Şekil 14**

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-3 veriseti ile yapılan denemelerde ADOM algoritması  $48,39 \pm 2,31$  PSNR ve  $\%99,9766 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $51,38 \pm 3,29$  PSNR ve  $\%99,9834 \pm 0,00$  SSIM ile daha yüksek performans göstermiştir. ADOM-TSA ise  $51,47 \pm 3,60$  PSNR ve  $\%99,9833 \pm 0,06$  SSIM ile benzer sonuçlar vermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir (P-Value < 0,05).

HSI-4 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 15'te verilmiştir.




**Şekil 15**

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-4 veriseti ile yapılan denemelerde ADOM algoritması  $61,99 \pm 3,93$  PSNR ve  $\%99,9808 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO kombinasyonu  $61,69 \pm 3,01$  PSNR ve  $\%99,9725 \pm 0,00$  SSIM ile benzer performans göstermiştir. ADOM-TSA ise  $62,25 \pm 2,94$  PSNR ve  $\%99,9765 \pm 0,02$  SSIM ile daha iyi performans göstermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre ADOM-TSA algoritması ADOM algoritmasına göre istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir ( $P\text{-Value} < 0,05$ ).

HSI-5 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 16'da verilmiştir.




**Şekil 16**

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı



HSI-5 veriseti ile yapılan denemelerde ADOM algoritması  $66,21 \pm 2,31$  PSNR ve  $\%99,9919 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO kombinasyonu  $68,74 \pm 2,76$  PSNR ve  $\%99,9939 \pm 0,00$  SSIM ile daha iyi sonuçlar vermiştir. ADOM-TSA ise  $67,68 \pm 5,62$  PSNR ve  $\%99,9924 \pm 0,03$  SSIM ile benzer performans göstermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir (P-Value < 0,05).

HSI-6 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmaların ürettiği sonuçlar ile gürültü kalıntıları Şekil 17’de verilmiştir.




Şekil 17

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-6 veriseti ile yapılan denemelerde ADOM algoritması  $61,40 \pm 2,17$  PSNR ve  $\%99,9755 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $59,81 \pm 1,28$  PSNR ve  $\%99,9578 \pm 0,00$  SSIM ile benzer performans göstermiştir. ADOM-TSA ise  $59,54 \pm 0,96$  PSNR ve  $\%99,9556 \pm 0,01$  SSIM ile benzer performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre önerilen algoritmalar istatistiksel olarak anlamlı bir fark göstermemektedir ( $P\text{-Value} \geq 0,05$ ).

HSI-7 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 18'de verilmiştir.




**Şekil 18**

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-7 veriseti ile yapılan denemelerde ADOM algoritması  $47,33 \pm 1,60$  PSNR ve  $\%99,9395 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $58,53 \pm 4,58$  PSNR ve  $\%99,9774 \pm 0,00$  SSIM ile daha yüksek performans göstermiştir. ADOM-TSA ise  $59,00 \pm 4,55$  PSNR ve  $\%99,9801 \pm 0,03$  SSIM ile benzer sonuçlar vermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir (P-Value < 0,05).

HSI-8 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 19'da verilmiştir.




Şekil 19

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-8 veriseti ile yapılan denemelerde ADOM algoritması  $66,46 \pm 2,36$  PSNR ve  $\%99,9950 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $65,28 \pm 1,63$  PSNR ve  $\%99,9905 \pm 0,00$  SSIM ile benzer performans göstermiştir. ADOM-TSA ise  $64,94 \pm 1,77$  PSNR ve  $\%99,9892 \pm 0,01$  SSIM ile benzer performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre önerilen algoritmalar istatistiksel olarak anlamlı bir fark göstermemektedir ( $P\text{-Value} \geq 0,05$ ).

HSI-9 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 20'de verilmiştir.

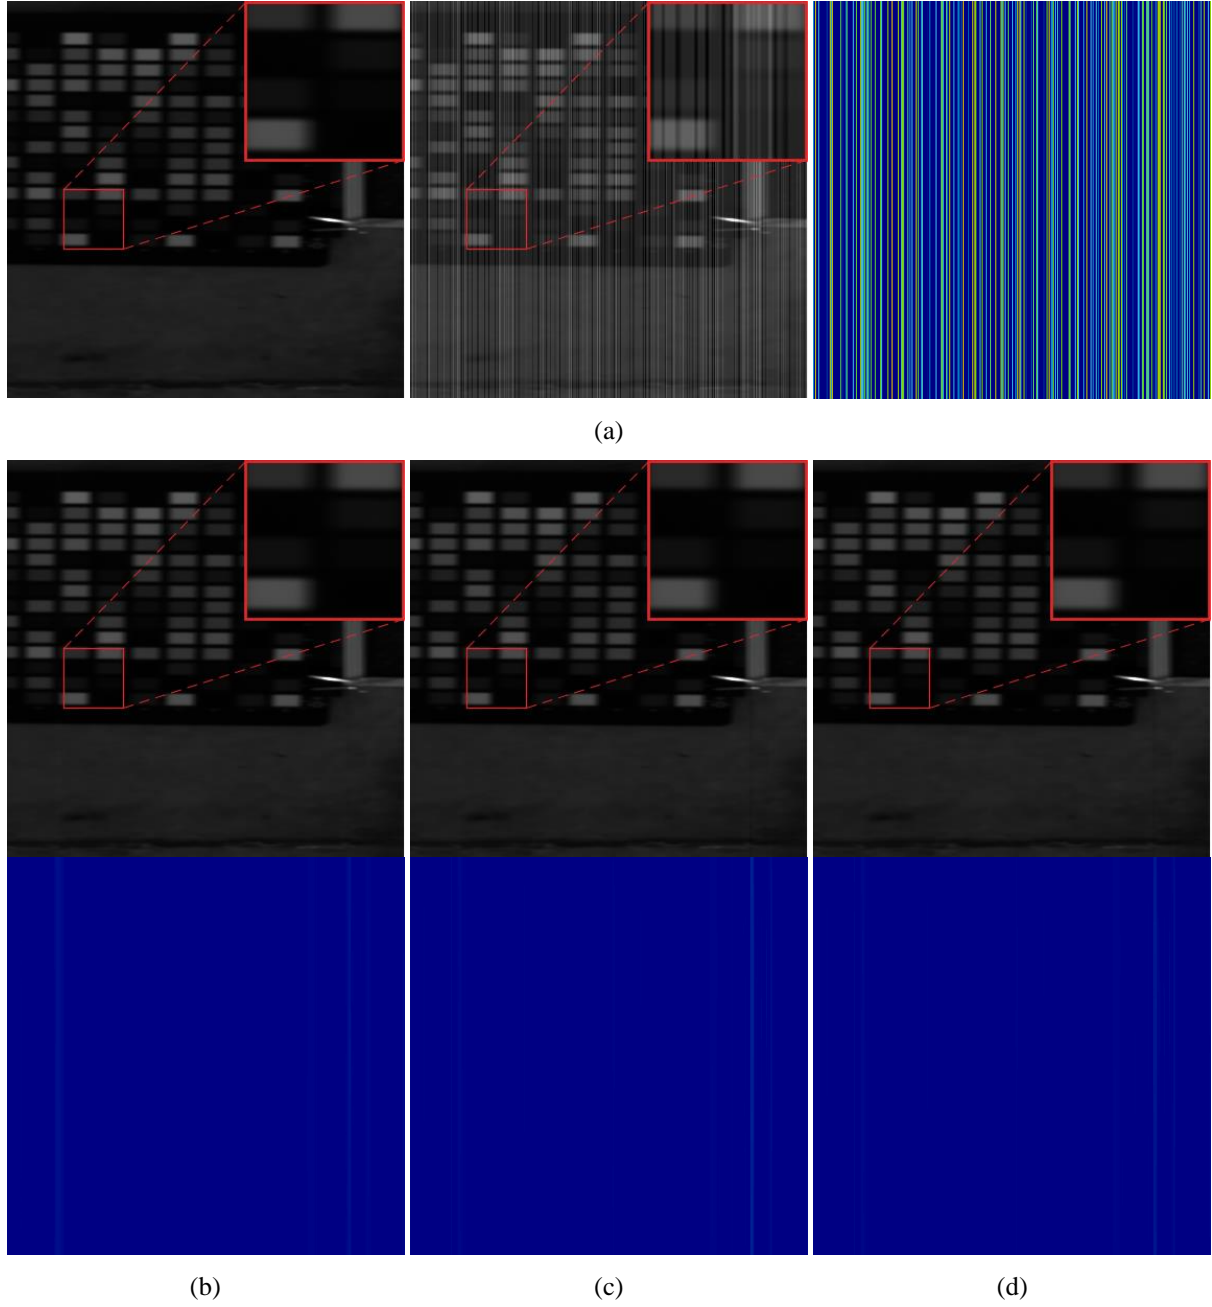


**Şekil 20**

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-9 veriseti ile yapılan denemelerde ADOM algoritması  $53,76 \pm 1,87$  PSNR ve  $\%99,9391 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $53,52 \pm 1,07$  PSNR ve  $\%99,9244 \pm 0,00$  SSIM ile benzer performans göstermiştir. ADOM-TSA ise  $53,13 \pm 1,55$  PSNR ve  $\%99,9181 \pm 0,05$  SSIM ile benzer performans sergilemiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre önerilen algoritmalar istatistiksel olarak anlamlı bir fark göstermemektedir ( $P\text{-Value} \geq 0,05$ ).

HSI-10 veri seti için orijinal temiz görüntü, gürültü eklenmiş görüntü, gürültü kalıntısı ve sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının ürettiği sonuçlar ile gürültü kalıntıları Şekil 21’de verilmiştir.



**Şekil 21**

(a) Orijinal temiz görüntü, gürültülü görüntü ve gürültü kalıntısı örneği, (b), (c) ve (d) sırasıyla ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının sonucu gürültü giderilmiş görüntü ve gürültü kalıntısı

HSI-10 veriseti ile yapılan denemelerde ADOM algoritması  $39,36 \pm 0,96$  PSNR ve  $\%98,3010 \pm 0,00$  SSIM değerlerine ulaşmıştır. ADOM-PSO  $43,02 \pm 1,87$  PSNR ve  $\%99,0975 \pm 0,00$  SSIM ile daha iyi sonuçlar vermiştir. ADOM-TSA ise  $43,21 \pm 2,42$  PSNR ve  $\%99,0911 \pm 0,22$  SSIM ile benzer performans göstermiştir. PSNR, SSIM ve mutlak hata değerleri ile birlikte Wilcoxon Signed-Rank testi sonuçlarına göre her iki algoritma da istatistiksel olarak anlamlı şekilde daha iyi performans göstermektedir (P-Value < 0,05).

Bu çalışma, ADOM algoritmasının genel olarak iyi performans gösterdiğini ancak ADOM-PSO ve ADOM-TSA kombinasyonlarının belirli veri setlerinde anlamlı şekilde daha iyi sonuçlar verdiğini göstermektedir. Özellikle HSI-1, HSI-2, HSI-3, HSI-5, HSI-7 ve HSI-10 veri setlerinde, önerilen algoritmalar ADOM algoritmasına göre istatistiksel olarak anlamlı derecede daha iyi performans sergilemiştir. HSI-4 veri setinde yalnızca ADOM-TSA algoritması istatistiksel olarak anlamlı bir fark oluştururken, HSI-6, HSI-8 ve HSI-9 veri setlerinde önerilen algoritmalar anlamlı bir fark göstermemiştir.

### TARTIŞMA VE SONUÇLAR (DISCUSSION AND CONCLUSIONS)

ADOM algoritmasının alt problemlerinde kullanılan  $\lambda_1$  ve  $\lambda_2$  parametreleri, orijinal çalışmada deneme yanılma ile tespit edilmiş ve sabit değerler olarak kullanılmıştır. Bu parametrelerin şerit gürültüsü gideriminde önemli bir etkisi vardır. Bu sebeple parametrelerin hassas ayarlanmasının önemli olduğu gözlenmiştir. Bu nedenle yapılan bu çalışmada verisetleri üzerinde  $\lambda_1$  ve  $\lambda_2$  parametrelerinin optimum değerleri ADOM-TSA ve ADOM-PSO algoritmaları ile elde edilmiştir.

ADOM, ADOM-PSO ve ADOM-TSA algoritmalarının performansları üzerine yapılan değerlendirmede bu algoritmalar; işlem süresi, Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM), piksel hatası (D error/px) ve toplam ADOM adımları gibi performans metriklerine göre karşılaştırılma yapılmıştır. Ayrıca, algoritmalar arasındaki performans farklılıklarının istatistiksel anlamlılığını belirlemek için Wilcoxon Signed-Rank testi kullanılmış ve p-değerleri  $p < 0,05$  olan farklılıklar istatistiksel olarak önemli kabul edilmiştir.

RSI veri setleri üzerine yapılan analizde, ADOM-PSO ve ADOM-TSA algoritmalarının genellikle ADOM algoritmasından daha iyi sonuçlar elde ettiğini göstermiştir. RSI-2, RSI-4 ve RSI-6 veri setlerinde her iki algoritma da ADOM'a göre istatistiksel olarak önemli ( $p < 0,05$ ) derecede daha iyi performans sergilemiştir. Buna karşılık, RSI-5 ve RSI-9 veri setlerinde sadece ADOM-TSA algoritması istatistiksel olarak önemli ( $p < 0,05$ ) iyileşmeler göstermiştir. RSI-7 veri setinde ise sadece ADOM-PSO algoritması istatistiksel olarak önemli ( $p < 0,05$ ) iyileşmeler göstermiştir. RSI-1, RSI-3 ve RSI-8 veri setlerinde ise önerilen algoritmalar arasında istatistiksel olarak anlamlı bir fark bulunamamıştır.

HSI veri setlerinde yapılan analizde de ADOM-PSO ve ADOM-TSA algoritmalarının genellikle ADOM algoritmasından daha iyi performans göstermiştir. Özellikle, HSI-1, HSI-2, HSI-3, HSI-5, HSI-7 ve HSI-10 veri setleri için her iki algoritma da ADOM'a göre istatistiksel olarak önemli ( $p < 0,05$ ) derecede daha iyi performans sergilemiştir. HSI-4 veri setinde sadece ADOM-TSA algoritması istatistiksel olarak önemli ( $p < 0,05$ ) derecede bir iyileşme gösterirken, HSI-6, HSI-8 ve HSI-9 veri setlerinde algoritmalar arasında istatistiksel olarak anlamlı bir fark gözlenmemiştir.

Benzer hesaplama maliyetlerinde daha optimum sonuç bulmak bilgi işlem teknolojilerinin gelişiminde çok önem arz etmektedir. Yapılan bu çalışma ile ADOM algoritmasının farklı veri setlerinde tutarlı bir performans gösterdiğini, bununla birlikte ADOM-PSO ve ADOM-TSA algoritmalarının yaklaşık aynı hesaplama maliyeti ile birçok durumda performansı önemli ölçüde artırabileceğini göstermektedir. PSO ve TSA ile ADOM'un entegrasyonu, uzaktan algılama ve hiperspektral görüntülerde şerit gürültüsü giderimi görevi sonuçlarda performansın arttığını göstermektedir. Bu

verisetlerinin dışında farklı verisetlerinde yapılacak olan araştırmalar ile bu kombinasyonların daha da rafine edilmesine ve bağlam yelpazesinde uygulanabilirliklerinin araştırılmasına odaklanılabileceği düşünülmüştür. Gelecekteki çalışmalar, farklı sezgisel algoritmaların denenmesi ve işlem maliyeti azaltılırken daha yüksek başarımın elde edilmesi üzerine odaklanmalıdır.

**Etik Kurul Onayı (Ethical Declaration)**

Bu çalışma için etik kurul onayı gerekmemektedir.

**Yazar Katkıları (Authors Credit)**

Araştırma Tasarımı (CRediT 1) İ.N.E (%50) – H.A.A. (%50)

Veri Toplama (CRediT 2) İ.N.E (%50) – H.A.A. (%50)

Araştırma - Veri Analizi - Doğrulama (CRediT 3-4-6-11) İ.N.E (%40) – H.A.A. (%60)

Makalenin Yazımı (CRediT 12-13) İ.N.E (%50) – H.A.A. (%50)

Metnin Tashihi ve Geliştirilmesi (CRediT 14) İ.N.E (%40) – H.A.A. (%60)

**Finansman (Funding)**

Bu çalışma herhangi bir kurum tarafından destek alınmadan geliştirilip yapılmıştır.

**Çıkar Çatışması (Conflict of Interest)**

Yazarların bu çalışma için beyan ettikleri herhangi bir çıkar çatışması yoktur.

**Sürdürülebilir Kalkınma Amaçları (SDG)**

Sürdürülebilir Kalkınma Amaçları: Desteklemiyor

## KAYNAKÇA (REFERENCES)

- [1] C. Ma, W. Xia, F. Chen, J. Liu, Q. Dai, L. Jiang, J. Duan, W. Liu, A content-based remote sensing image change information retrieval model, *ISPRS International Journal of Geo-Information*. 6 (10) (2017). doi: 10.3390/ijgi6100310
- [2] J. Le Moigne, Introduction to Remote Sensing Image Registration, içinde: *IEEE International Symposium on Geoscience and Remote Sensing IGARSS, IEEE*, Fort Worth, TX, USA, 2017: 2565-2568. doi: 10.1109/IGARSS.2017.8127519
- [3] K. Ş. Kavak, Uzaktan algılamanın temel kavramları ve jeolojideki uygulama alanları, *Jeoloji Mühendisliği Dergisi*. 21 (1) (1998), 63-74.
- [4] N. Kim, S.-S. Han, C.-S. Jeong, ADOM: ADMM-Based Optimization Model for Stripe Noise Removal in Remote Sensing Image, *IEEE Access*. 11 (2023), 106587-106606. doi: 10.1109/ACCESS.2023.3319268
- [5] Q. Song, Y. Wang, X. Yan, H. Gu, Remote sensing images stripe noise removal by double sparse regulation and region separation, *Remote Sensing*. 10 (7) (2018), 998. doi: 10.3390/rs10070998
- [6] X. Zhang, Y. Li, X. Feng, J. Hua, D. Yue, J. Wang, Application of multiple-optimization filtering algorithm in remote sensing image denoising, *Sensors (Basel)*. 23 (18) (2023), 7813. doi: 10.3390/s23187813
- [7] L. Han, Y. Zhao, H. Lv, Y. Zhang, H. Liu, G. Bi, Remote sensing image denoising based on deep and shallow feature fusion and attention mechanism, *Remote Sensing*. 14 (5) (2022), 1243. doi: 10.3390/rs14051243
- [8] Y. Zhou, C. Ren, S. Zhang, X. Xue, Y. Liu, J. Lu, C. Ding, A second-order method for removing mixed noise from remote sensing images, *Sensors (Basel)*. 23 (17) (2023), 7543. doi: 10.3390/s23177543
- [9] F. Yan, S. Wu, Q. Zhang, Y. Liu, H. Sun, Destriping of remote sensing images by an optimized variational model, *Sensors*. 23 (17) (2023). doi: 10.3390/s23177529
- [10] Z. Wang, G. Wang, Z. Pan, J. Zhang, G. Zhai, Fast stripe noise removal from hyperspectral image via multi-scale dilated unidirectional convolution, *Multimedia Tools and Applications*. 79 (31) (2020), 23007-23022. doi: 10.1007/s11042-020-09065-4
- [11] B. Li, Y. Zhou, D. Xie, L. Zheng, Y. Wu, J. Yue, S. Jiang, Stripe noise detection of high-resolution remote sensing images using deep learning method, *Remote Sensing*. 14 (4) (2022). doi: 10.3390/rs14040873
- [12] M. S. Kiran, TSA: Tree-seed algorithm for continuous optimization, *Expert Systems with Applications*. 42 (19) (2015), 6686-6698. doi: 10.1016/j.eswa.2015.04.055
- [13] G. Pereira, Particle Swarm Optimization, (2011).
- [14] H. A. Akyürek, Ö. K. Baykan, B. Koçer, Improving gravitational search algorithm performance with artificial bee colony algorithm for constrained numerical optimization, *The Journal of MacroTrends in Applied Science*. 4 (1) (2016), 55-68.
- [15] J. Kennedy, R. Eberhart, Particle swarm optimization, içinde: *IEEE*, 1995: 1942-1948.
- [16] A. Pektaş, O. İnan, Application of tree seed algorithm on clustering problems, *Necmettin Erbakan University Journal of Science and Engineering*. 4 (1) (2022), 1-10. doi: 10.47112/neufmbd.2022.8
- [17] G. Orucova Büyüköz, H. Haklı, Implementation of grey wolf optimization algorithm to p-median problems, *Necmettin Erbakan University Journal of Science and Engineering*. 6 (1) (2024), 166-177. doi: 10.47112/neufmbd.2024.40
- [18] İ. İlhan, A. Ünlü, A novel hybrid gray wolf optimization algorithm with harmony search to solve multi-level image thresholding problem, *Necmettin Erbakan University Journal of Science and Engineering*. 5 (2) (2023), 230-245. doi: 10.47112/neufmbd.2023.21



- [19] H. A. Akyürek, E. Ülker, B. Koçer, Automatic Knot adjustment using dolphin echolocation algorithm for b-spline curve approximation, *The Journal of MacroTrends in Technology and Innovation*. 4 (1) (2016), 100-109.
- [20] Q. B. Phan, T. T. Nguyen, A Novel Approach for PV Cell Fault Detection Using YOLOv8 and Particle Swarm Optimization, içinde: *2023 IEEE 66th International Midwest Symposium on Circuits and Systems (MWSCAS)*, 2023: 634-638. doi: 10.1109/MWSCAS57524.2023.10406139
- [21] C. Sudheer, S. Mathur, Particle swarm optimization trained neural network for aquifer parameter estimation, *Ksce Journal of Civil Engineering*. 16 (3) (2012), 298-307. doi: 10.1007/s12205-012-1452-5
- [22] G. d. I. C. (GIC), Hyperspectral Remote Sensing Scenes. [https://www.ehu.es/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](https://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes) (erişim 2024).
- [23] S. H. Chan, X. Wang, O. A. Elgendy, Plug-and-play ADMM for image restoration: fixed-point convergence and applications, *IEEE Transactions on Computational Imaging*. 3 (1) (2017), 84-98. doi: 10.1109/TCI.2016.2629286
- [24] F. Chen, Z. Ye, C. Wang, L. Yan, R. Wang, A Feature Selection Approach for Network Intrusion Detection Based on Tree-Seed Algorithm and K-Nearest Neighbor, içinde: *IEEE*, 2018: 68-72. doi: 10.1109/IDAACS-SWS.2018.8525522
- [25] J. Jiang, X. Meng, L. Qian, H. Wang, Enhance tree-seed algorithm using hierarchy mechanism for constrained optimization problems, *Expert Systems with Applications*. 209 (2022), 118311. doi: 10.1016/j.eswa.2022.118311
- [26] A. P. Piotrowski, J. J. Napiorkowski, A. E. Piotrowska, Population size in particle swarm optimization, *Swarm and Evolutionary Computation*. 58 (2020), 100718. doi: 10.1016/j.swevo.2020.100718
- [27] A. Rashnoa, S. Fadaeib, Image restoration by projection onto convex sets with particle swarm parameter optimization, *International Journal of Engineering*. 36 (2) (2023), 398-407. doi: 10.5829/ije.2023.36.02b.18
- [28] A. P. Engelbrecht, "Particle Swarm Optimization," in *Computational Intelligence*, 2007, pp. 289-358.
- [29] H. A. Akyürek, B. Koçer, Semi-supervised fuzzy neighborhood preserving analysis for feature extraction in hyperspectral remote sensing images, *Neural Computing and Applications*. 31 (8) (2019), 3385-3415. doi: 10.1007/s00521-017-3279-y