

Grup Seyreklik ve Düşük Dereceli Modellerin Uzlaştırılmasıyla Çarpımsal Gürültünün Giderilmesi

Removal of Multiplicative Noise via Reconciliation of Group Sparsity and Low-Rank Models

Mehmet Demir¹

 0000-0002-3710-9515

¹Elektrik-Elektronik Mühendisliği Bölümü
Gaziantep Üniversitesi, Gaziantep Türkiye
mehmetdemir@gantep.edu.tr

Özet

Çarpımsal gürültü (benek gürültüsü olarak da bilinir) modelleri, sentetik açıklıklı radar ve sonar sistemleri ile ultrason ve lazer görüntüleme gibi koherent görüntüleme sistemlerinin analizinde merkezi bir role sahiptir. Bu gürültü türü, görüntü üzerinde bölümlere (segmentasyon) veya hedef tanıma gibi algoritmaların uygulanmasını önemli ölçüde zorlaştırır. Söz konusu algoritmaların etkili bir şekilde çalışabilmesi için öncelikle benek gürültüsünün giderilmesi gerekmektedir. Bu çalışmada, ilk aşamada homomorfik dönüşüm kullanılarak çarpımsal gürültü, toplamsal gürültüye dönüştürülmüştür. Ardından, çarpımsal gürültüye uygun istatistiksel yöntemlerle seçilen benzer yamalar üzerinde grup seyreklilik ve düşük dereceli modellerin entegrasyonuna dayalı yeni bir yaklaşım önerilmiştir. Önerilen yöntemde, benzer yamalar; uyarlanabilir sözlük seçimi, seyrek katsayıların öğrenilmesi ve düşük ranklı modellerin eğitimi amacıyla kullanılmıştır. Sentetik ve gerçek görüntülerle gerçekleştirilen deneysel çalışmalar ve karşılaştırmalar, önerilen benek gürültüsü giderme yönteminin etkinliğini kanıtlamıştır.

Anahtar kelimeler: Benek gürültü, grup seyreklilik, düşük-dereceli model.

Abstract

Multiplicative noise (also known as speckle noise) models play a central role in the analysis of coherent imaging systems such as synthetic aperture radar and sonar, as well as ultrasound and laser imaging. This type of noise significantly complicates the application of algorithms like image segmentation or target recognition on images. For these algorithms to work effectively, the speckle noise must first be removed. In this study, we first used homomorphic transformation to convert multiplicative noise into additive noise. Then, we proposed a novel approach based on the integration of group sparsity and low-rank models, using similar patches selected through statistical methods appropriate for multiplicative noise. In the proposed method, similar patches were utilized for adaptive dictionary selection, learning sparse coefficients, and training low-rank models. Experimental results and comparisons on synthetic and real images demonstrate the effectiveness of our proposed speckle noise reduction method.

Keywords: Speckle noise, group sparsity, low-rank model.

1. Giriş

Sentetik açıklıklı radar ve sonar, ultrason ve lazer görüntüleme sistemleri, doğaları gereği tutarlı (coherent) saçılma olayları nedeniyle oluşan görüntülerde benek gürültüsü meydana gelmektedir. Bu gürültü türü, görüntü analizi ve bilgi çıkarma algoritmalarının uygulanmasını zorlaştırmakta ve istenen sonuçların elde edilmesini engellemektedir [1,2]. Sentetik Açıklıklı Radar (SAR) sistemlerinde benek gürültüsünü azaltmak için, azimut spektral bant genişliğinin bir kısmından elde edilen birden fazla görüntünün uyumsuz ortalaması alınarak gürültü varyansı azaltılır. Çok bakışlı SAR işleme, bu yöntemle örnek olarak verilebilir. Bu, kullanılan ilk yöntemlerden biridir ve SAR görüntüsü oluşturulurken çarpımsal gürültünün giderilmesi hedeflenir. Ancak bu yöntem, gürültüyü azaltırken görüntünün bulanıklaşmasına neden olmaktadır. Diğer bir klasik yöntem ise, görüntüler oluşturulduktan sonra istatistiksel teknikler kullanılarak beneklerin uzamsal alanda filtrelenmesine dayanır. Lee filtresi gibi yöntemler, bu istatistiksel yaklaşımlar kapsamında değerlendirilmiştir [3]. Benek giderme işlemi, yerel görüntü istatistiklerine göre minimum-ortalama-kare-hatası (MMSE) veya maksimum a posteriori (MAP) kriterleri temel alınarak gerçekleştirilir. Bu süreçteki performans büyük ölçüde yerel pencere parametrelerinin seçimine bağlıdır [1,4].

Öncü çalışmalarda, kısmi diferansiyel denklemlere dayanan toplam varyasyon (TV) tabanlı yöntemler ve bunların geliştirilmiş versiyonları, çarpımsal gürültünün neden olduğu gürültüleri gidermede ve keskin kenarları korumada başarılı sonuçlar vermiştir [5,6]. TV tabanlı yaklaşımlarla çözülen benek gürültü problemlerinde, çarpımsal Gama gürültüsü içeren görüntüleri iyileştirmek için I-divergence veri uyumu terimi ve TV veya lokal olmayan ortalamalar (NL-means) gibi kenar koruyucu düzenleştiriciler kullanılmıştır. Bu yöntem, genellikle Poisson gürültüsü için kullanılan I-divergence teriminin Gama gürültüsü için de uygun olduğunu savunarak TV veya NL-means gibi tekniklerle birleştirir [6]. Ayrıca, TV'nin kullanıldığı başka bir çalışmada [5], çarpımsal gürültüyü gidermek için logaritmik dönüşümle toplamsal modele dönüştürülen bir yaklaşım önerilmiştir. Değişken ayırma ve artırılmış Lagrangian kullanılarak geliştirilen MIDAL (Multiplicative Image Denoising by Augmented Lagrangian) algoritması, TV düzenlestirmesiyle hızlı ve etkili sonuçlar sunmuştur.

Benek gürültüsü, sinyal kaynaklı dalgalanmalardan oluşan ve doğası gereği çarpımsal karaktere sahip bir gürültü türüdür. Daha önceki çalışmalar, bu tür gürültünün bastırılmasında yerel olmayan (Nonlocal-NL) ortalamalar yaklaşımının etkili olduğunu göstermiştir [7]. NL-means yönteminin kullanıldığı araştırmalarda, yerel olmayan tekniklerin genişletilmesinin, görüntü çözünürlüğünü korurken benek gürültüsünü baskılamada esnek bir yöntem sunduğu vurgulanmaktadır. Bu yöntem, gürültüyü azaltmak için piksel benzerliğini temel alan genişletilmiş komşuluk bölgeleri oluşturur ve bu bölgelerdeki pikselleri ağırlıklı maksimum olabilirlik (weighted maximum-likelihood) tahminiyle işler [7]. Geleneksel NL-means algoritması, piksel benzerliğini ilgili piksellerin etrafındaki yamaların Öklid mesafesi üzerinden tanımlar. NL-means temelli bir başka çalışmada ise gürültünün istatistiksel dağılım modeline dayanan daha genel bir benzerlik ölçütü önerilmiştir. Bu yaklaşım, gürültü giderme sürecini ağırlıklı maksimum olabilirlik tahmini (Weighted Maximum Likelihood Estimation-WMLE) problemine dönüştürerek ağırlıkların veriye uygun şekilde belirlenmesini sağlar. Böylece yöntem, yalnızca toplamsal Gauss gürültüsüne değil, ultrason, lazer veya SAR görüntülerindeki çarpımsal benek gürültüsü gibi farklı gürültü türlerine de uyarlanabilmektedir [8]. Bunun yanı sıra, bir diğer çalışmada SAR-BM3-D adı verilen yeni bir algoritma önerilmiştir. Bu algoritma, toplamsal Gauss gürültüsü için oldukça başarılı olan BM3-D yöntemini temel almakla birlikte, SAR gürültüsünün çarpımsal yapısına uyum sağlamak için temel adımlarını önemli ölçüde değiştirmektedir. Standart BM3-D'de kullanılan Öklid mesafesi yerine, [8]'de olduğu gibi SAR verilerinin istatistiksel özelliklerine daha uygun olasılık temelli bir benzerlik ölçüsü kullanılarak görüntü blokları gruplandırılmıştır. Bu sayede blok eşleştirme işlemi daha doğru bir şekilde gerçekleştirilebilmektedir [9]. Bu çalışmada, daha önce bahsedilen yöntemlere paralel olarak, benek gürültüsünün istatistiksel dağılım modeline dayalı bir benzerlik kriteri kullanılarak yamalar seçilmiştir.

Literatürde ayrıca, SAR ve ultrason gibi görüntülerdeki benek gürültüsünü azaltmak amacıyla makine öğrenmesine dayalı çeşitli yöntemler geliştirilmiş ve bu yöntemler umut vaat eden sonuçlar sunmuştur. Öne çıkan yaklaşımlar arasında düşük rank temsili yöntemler [10-13], seyrek kodlama teknikleri [14,15] ve derin evrişimli sinir ağları (CNN) [16-20] yer almaktadır.

Örneğin, [10]'de benzer görüntü yamalarının gruplanmasıyla düşük rank kısıtlaması uygulanmış ve performansı artırmak için özyinelemeli bir süreç kullanılmıştır. Güncel olan başka bir çalışmada, SAR görüntülerindeki benek gürültüsünü azaltmak için Fisher-Tippett dağılımından türetilen bir veri uyum terimini ve düşük ranklı yaklaşımları iyileştiren nükleer normdan Frobenius normun çıkarılmasıyla elde edilen regülerizasyon terimini kullanan yeni bir yöntem önermişlerdir [12]. [13]'de ise geleneksel düşük ranklı yöntemlerin aksine, Xu ve arkadaşları, bu modellerin gürültü olarak ele alıp attığı artık kısımdan değerli kenar bilgilerini çıkarmaya odaklanan yenilikçi bir SAR benek giderme yaklaşımı sunmuşlardır. Seyrek temsile (sparse representation) dayalı POTDF yönteminde [15] ise, görüntü yamalarının sıralanmasıyla iki aşamalı bir filtreleme gerçekleştirilmiştir. İlk aşamada KSVD [21] algoritmasıyla aşırı tam bir sözlük öğrenilmiş, ardından 2-B dalgacık dönüşümüyle detaylı filtreleme yapılmıştır. Ancak bu yöntem, tüm görüntü için optimal olmayan kodlamalara yol açabilmekte ve aşırı yumuşatılmış sonuçlar üretebilmektedir.

Derin öğrenme tabanlı çözümlerden SAR-CNN [16], 17 katmanlı bir mimariyle artık gürültüyü logaritmik dönüşüm kullanarak bastırmayı hedeflemektedir. [17]'de homomorfik dönüşüm yerine, Öklid mesafesi ve toplam varyasyon kısıtlamalarıyla eğitilmiş uçtan uca bir CNN modeli önerilmiştir. [18]'de ise CNN'ye entegre edilen kılavuz filtreleme mekanizması sayesinde benek gürültüsünün etkili şekilde giderilmesi sağlanmıştır. Bu alandaki daha güncel yaklaşımlar, özellik çıkarımını zenginleştirmeye odaklanmıştır. Örneğin, Liu ve arkadaşları tarafından geliştirilen MFAENet [19], çok ölçekli bir mimari ve deformasyon olabilir evrişim kullanarak görüntü özelliklerine esnek bir adaptasyon sağlamıştır. Aynı araştırma ekibinin bir diğer çalışması olan LG-DBNet ise, CNN'lerin yerel ve öz-dikkat mekanizmalarının küresel modelleme yeteneklerini çift dallı bir ağ yapısında birleştirerek detay koruma performansını artırmayı hedeflemiştir [20]. Bu yöntemler, sentetik verilerde geleneksel tekniklere kıyasla üstün performans sergilemekle birlikte, denetimli öğrenmeyle eğitildikleri ve gerçek uygulamalardaki bilinmeyen gürültü dağılımlarına tam uyum sağlayamadıkları için bazen ideal olmayan sonuçlar verebilmektedir.

Yapılan çalışmalarda, yerel olmayan öz-benzerlik (Nonlocal self-similarity) özelliği, ortak seyreklik ve grup seyrek kodlama gibi farklı seyreklik modelleriyle sıklıkla kullanılmaktadır. Ancak, mevcut yerel olmayan öz-benzerlik temelli seyreklik modelleri ya aşırı kısıtlayıcıdır (örneğin, tüm seyrek kodların aynı desteği paylaşmasını şart koşar) ya da fazla genel bir yaklaşım benimser (örneğin, yalnızca grup katsayıları üzerinde düz seyreklik uygular) [22]. Literatürdeki mevcut yöntemler, gürültü bastırma ve detay koruma arasındaki dengeyi kurmakta yetersiz kaldığı anlaşılmıştır. Bu durum, gerçek görüntülerin modellenmesinde bu yöntemlerin etkinliğini sınırlandırmaktadır [22]. Bu çalışmada, grup seyrek kodlama ile ortak seyreklik arasındaki boşluğu kapatmak amacıyla, [22] numaralı kaynakta önerilen yerel olmayan öz-benzerlik tabanlı seyreklik modeli, benek gürültüsünün giderilmesi için kritik bazı değişiklikler yapılarak uyarlanmıştır. Önerilen model, benzer yama gruplarının her biri için sözlük-alanı katsayılarının hem seyreklik hem de düşük ranklılık özelliklerini eş zamanlı olarak kullanmaktadır.

2. Problem Formülasyonu

SAR, ultrason ve lazer görüntüleme sistemlerinde karşılaşılan temel problemlerden biri olan benek gürültüsünün giderilmesi, bozulmuş gözlem verisi y 'den orijinal gürültüsüz görüntü x 'in elde edilmesi sürecini ifade etmektedir. Bu sistemlerde, benek gürültüsü n 'nin istatistiksel karakteristiği genellikle çarpımsal gürültü modeliyle tanımlanmaktadır. Bozulmuş görüntü y ile arzu edilen görüntü x arasındaki matematiksel ilişki, temel olarak şu şekilde modellenebilir:

$$y = x \odot n \quad (1)$$

buradaki $\odot$ işareti Hadamard çarpımını simgeler. Benek gürültüsünün şiddeti Gamma dağılımını takip eder. Böylece, gürültü matrisindeki her bir elemanın olasılık yoğunluk fonksiyonu şu şekilde tanımlanır:

$$p(n) = \frac{L^L n^{L-1}}{\Gamma(L)} \exp(-nL), \quad n \geq 0 \quad (2)$$

bu denklemden, L ve $\Gamma(\cdot)$ parametreleri sırasıyla eşdeğer bakış sayısını ve Gamma dağılım fonksiyonunu ifade etmektedir. L

parametresinin belirlenmesinde, [23] numaralı referansta önerilen denetimsiz yöntem kullanılabilir. L değerinin doğrudan tespiti, gerçek SAR veya ultrason görüntülerinde oldukça zordur. Çarpımsal gürültü modelini toplamsal gürültü formuna dönüştürebilmek amacıyla, öncelikle (1) numaralı denklemin logaritmik dönüşüme tabi tutulması, diğer bir ifadeyle homomorfik dönüşüm uygulanması gerekmektedir. Dönüşüm sonrası (1) numaralı denklem aşağıdaki duruma gelir:

$$\ln(y) = \ln(x) + \ln(n) \quad (3)$$

burada $\ln(n)$ beklenen değeri sıfırdan farklı olduğu için, (3) numaralı denklemde bir sapma düzeltme yapılması gerekmektedir.

$$y_c = \ln(y) - \psi^0(L) + \ln(L) = x_c + n_c \quad (4)$$

belirtilen denklemde $\psi^r(\cdot)$, r mertebeli polygamma fonksiyonunu ifade etmektedir. Logaritmik dönüşüm sonrası x_c ve n_c , (sırasıyla $\ln(x)$ ve $\ln(n)$ 'nin sapma düzeltmeli değerleri) homomorfik filtrelemede kullanılır. Burada $\psi^{(0)}$ digama fonksiyonudur ve gürültünün logaritmik uzaydaki ortalamasını sıfıra yaklaştırır. Düzeltilmiş gürültü n_c 'nin varyansı $\sigma_n^2 = \psi^{(1)}(L)$ trigama fonksiyonu olur. Sapma düzeltmeli gürültünün dağılımı L değerinin artması durumunda Gauss dağılımına yakınsamaktadır. Böylece, n_c elimine edilebilecek Gauss dağılımına sahip bir toplam gürültü olarak alınabilir.

3. Yama Gruplama

Önerilen yöntemde, daha önce de bahsettiğimiz gibi çarpımsal gürültülü görüntüler için uygun olan istatistiksel bir metotla benzer yamalar seçilir [8]. Görüntü, birbiriyle kesişen küçük yamalara bölünür. Görüntülerdeki doğal "kendine benzerlik" özelliğinden faydalananarak, her bir referans yama için ona en çok benzeyen diğer yamalar bulunur ve bir grup oluşturulur. İki yama (x_i ve x_j) arasındaki benzerlik, standart Öklid mesafesi yerine, doğası gereği SAR ve ultrason gibi benek gürültülü görüntülerin istatistiksel özelliklerine daha uygun olan şu mesafe ölçütü ile hesaplanır [8]:

$$d(x_i, x_j) = \sum_{k=1}^{p^2} \ln \left[\sqrt{\frac{x_i(k)}{x_j(k)}} + \sqrt{\frac{x_j(k)}{x_i(k)}} \right] \quad (5)$$

burada p^2 , yamanın piksel sayısıdır. Bu ölçüt, logaritmik dönüşüm uygulanmış görüntünün üssü alınarak (yani orijinal yoğunluk uzayında) hesaplanır.

4. Düşük-Rank Düzenileştirmeli Grup Seyrek Kodlama Optimizasyon Modeli

Benek gürültü giderilmesi için önerilen yeni yaklaşımda her bir yama grubu X_i için temel amaç, çarpımsal gürültüyü temizlemektir. Grup seyrekleştirme ile düşük-ranklı modellerin uzlaştırılmasıyla önerilen yaklaşım, bunu her grup için hem seyrekliliği hem de düşük-ranklılığı aynı anda kullanarak yapar. Modelin genel optimizasyon modeli aşağıdaki şekildedir [22]:

$$(\hat{A}_i, \{\hat{B}_i\}) = \arg \min_{x_i, \{A_i\}, \{B_i\}} \frac{1}{2\sigma_n^2} \|y_c - Hx\|_2^2 + \lambda \sum_i \|A_i\|_1 + \tau \sum_i \|B_i\|_* \quad (6)$$

bizim yaklaşımımızda bu problem, her yama grubu için ayrı ayrı ve daha basit bir formda çözülür. H matrisi gürültü giderme problemlerinde birim matris olarak alınır. Bir yama grubu X_i için hedef, onu bir sözlük D_i ve seyrekleştirme katsayıları matrisi A_i cinsinden ifade etmektir: $X_i \approx D_i A_i$. Önerdiğimiz yöntem, bu ifadeye iki ceza terimi daha ekler:

1. Seyreklik: Katsayı matrisi A_i 'nin elemanlarının çoğunun sıfır olması istenir. Bu $\lambda \sum_i \|A_i\|_1$ terimi ile sağlanır.
2. Düşük ranklılık: A_i matrisinin kendisinin düşük ranklı olması istenir. Yani, A_i 'nin sütunları (her bir yamanın seyrekleştirme katsayıları) birbiriyle yüksek oranda ilişkili olmalıdır. Bu $\tau \sum_i \|B_i\|_*$ terimi ile sağlanır, burada B_i , A_i 'nin düşük ranklı bir yaklaşımıdır ve $\|\cdot\|_*$ nükleer normu ifade eder.

Bu iki hedefi birleştiren ve çözümü kolaylaştıran optimizasyon problemi şöyledir:

$$\{\hat{A}_i, \hat{B}_i\} = \arg \min_{A_i, B_i} \frac{1}{2} \|X_i - D_i A_i\|_F^2 + \lambda \sum_i \|A_i\|_1 + \frac{1}{2\eta} \|A_i - B_i\|_F^2 + \tau \sum_i \|B_i\|_* \quad (7)$$

burada X_i matrisi grup yamaları göstermektedir ve görüntüden benzer yamaların çıkarılıp grup oluşturulmasını $X_i = R_i y_c$ denklemiyle formalize edebiliriz. Ayrıca, $\|\cdot\|_F$ Frobenius normu ifade eder.

5. Problemin Çözümü

Ortaya çıkan bu karmaşık problem, değişkenleri ayrı ayrı optimize eden sıralı minimizasyon ("alternating minimization") yöntemiyle çözülebilir.

- a) Sözlük Öğrenme (D_i): İstatistiksel yöntemle oluşturulan her yama grubu için Temel Bileşenler Analizi (PCA) uygulanarak adaptif bir sözlük (yani D_i) öğrenilir. Bu, oluşturulan yama grubunun kovaryans matrisinin özvektörlerini bulmakla eşdeğerdir.
- b) Düşük Ranklı Yakınsama (B_i): A_i sabitken, B_i için problem basitleşir. Bu alt problemin çözümü, A_i 'nin Tekil Değer Ayrışımı (SVD) ve ardından tekil değerlere yumuşak eşikleme (soft-thresholding) uygulanmasıyla bulunur.
 - $A_0 = U_S \Sigma V^T$ (SVD ayrışımı)
 - Eşiklenmiş tekil değerler: $\hat{\Sigma} = \text{soft}(\Sigma, \text{threshold})$
 - $\hat{B}_i = U_S \hat{\Sigma} V^T$

- c) Seyrek Katsayıları Bulma (A_i): D_i ve B_i sabitken, A_i için problem çözülür. Bu standart bir "soft-thresholding" işlemiyle yapılır. Ayrıca, daha kaliteli gürültüden arındırabilmek için seyrekleştirme teriminin önüne ağırlık katsayısı eklenir [1]. Bu çalışmada, iyi sonuçlar elde edebilmek için ağırlık katsayısı seyrekleştirme terimine eklenmiştir. Oluşan yeni terim şu şekildedir: $\sum_i \|W_i \odot A_i\|_1$. Ağırlık değişkeni hem gürültü seviyesine hem de katsayıların varyansına göre adaptif bir şekilde ayarlanır.

$$W_i(k) = \frac{c \cdot 2\sqrt{2}\sigma_i^2}{\lambda_k}, \quad \lambda_k = \text{eigenvalues}$$

Tüm yamalar için bu işlemler yapıldıktan sonra gürültüsü azaltılmış yamalar elde edilmiş olur.

- Her bir yamanın nihai gürültüsüz hali, ait olduğu farklı gruplarda elde edilen sonuçların ortalaması alınarak bulunur:

$$x_c = (\sum_{i=1}^K R_i^T R_i)^{-1} (\sum_{i=1}^K R_i^T D_i A_i) \quad (8)$$

burada R_i matrisi benzer yamaların bulunarak düşük ranklı matris oluşturma işlemini tanımlar. R_i^T matrisi elde edilmiş temiz düşük ranklı matrsten yamaların tekrar yerine yerleştirilme işlemini formülüz eder.

- Bu ortalaması alınmış yamalar, üst üste bindikleri bölgelerde tekrar ortalamaları alınarak tam bir görüntü oluşturulur.
- Son olarak, ilk adımdaki logaritmik dönüşümü tersine çevirmek için üstel dönüşüm (exponential transform) uygulanır ve nihai gürültüsüz görüntü elde edilir.

$$x = \exp(x_c) \quad (9)$$

Bu adımlar neticesinde grup seyrekliğin ve düşük ranklılığın güçlü yönleri birleştirilip uzlaştırılarak yeni bir çarpımsal gürültü giderme yaklaşımı ortaya çıkarılmıştır. Grup seyreklik ve düşük ranklılık doğal görüntülerin yapısında bulunan özelliklerdir. Grup seyrek kodlama tarafından uygulanan düz seyrekliğin yanı sıra, grup benzerliğinden daha fazla yararlanmak için her bir grup seyrek katsayısı A_i üzerinde grup bazında düşük ranklılık önerilerek benek gürültü giderme için önemli bir algoritma geliştirilmiştir.

Grup seyreklik ortak seyrekliğe kıyasla daha esnektir; çünkü her bir yama seyrek kodunun destek kümesi, grup içindeki güçlü korelasyona rağmen bağımsızdır [22]. Önerilen benek gürültü giderme modeli grup içi yama korelasyonundan daha fazla yararlanmak için grup seyrek kodlamanın standart seyrekliğine ek olarak bir düşük rank ceza terimi getirir. Hafif bir varsayım altında, çarpımsal gürültü için uyarlanan yöntem [22], daha kısıtlayıcı, ama yine de ortak seyreklikten daha geneldir.

Özetle, bu yöntem homomorfik dönüşüm ile SAR görüntülerinde ortaya çıkan benek gürültüsünün doğru bir şekilde işlenebilir hale getirmekte, ardından ağırlıklı seyreklik ile özellikleri koruyarak gürültüyü temizlemekte ve düşük ranklılık ile de yapısal bütünlüğü güvence altına almaktadır. Bu üç unsurun birleşimi, modelin SAR gibi koherent görüntü restorasyonunda üstün bir performans sergilemesini sağlar.

Grup seyreklik ile düşük ranklılığın uzlaştırıldığı önerilen yöntemin algoritması Tablo 1’de verilmiştir.

6. DeneySEL Sonuçlar

Bu bölümde, önerilen yöntemin performansını ve etkinliğini kapsamlı bir şekilde değerlendirmek amacıyla, kontrollü bir ortamda sentetik olarak oluşturulmuş benek gürültüsü ile bozulmuş test görüntüleri ve gerçek SAR görüntüsü kullanılarak deneysel çalışmalar gerçekleştirilmiştir.

İlk olarak sentetik olarak oluşturulan çarpımsal gürültülü görüntülerden elde edilen sonuçlar, önerilen yöntemin öncü yöntemlerle kıyaslandığında daha iyi sonuç verdiğini Tablo 2 ve Tablo 3’te elde edilen PSNR/SSIM sonuçlarıyla ortaya

Tablo 1: Önerilen yöntemin kodu

Başlangıç: Girdi: Gürültülü görüntü y, Tahmini Eşdeğer Bakış Sayısı ENL, L Adım 1: Ön İşleme ve Gürültü Dönüşümü - Giriş görüntüsüne logaritmik dönüşüm uygula. - Sapma (bias) düzeltmesi yaparak y_c görüntüsünü elde et. - Başlangıç tahmini olarak $x_c^{(0)} = y_c$ ata. Adım 2: Ana İteratif Döngü ($k=1, 2, \dots, \text{MaxIter}$) Görüntü Güncelleme (x Alt-Problemi): $\hat{x}_c^{(k)} \leftarrow \hat{x}_c^{(k-1)} + \gamma(y_c - \hat{x}_c^{(k-1)})$ Gürültü Seviyesi Tahmini: - Güncel görüntü ile gürültülü görüntü arasındaki farka bakarak gürültünün standart sapmasını (σ_n) yeniden tahmin et. Benzer Yama Gruplarını Oluşturma: - Güncel görüntü $\hat{x}_c^{(k)}$ üzerinde referans yamaları seç. - Her referans yama denklem (5)’i kullanarak en benzer m adet yamayı bul ve bir X_i grubu oluştur. Her Grup için Çarpımsal Gürültü Giderme: - Oluşturulan her bir X_i yama grubu için Sıralı Minimizasyon (Alternating Minimization) ile aşağıdaki adımları uygula: Adaptif Sözlük Öğrenme (D_i): PCA ile gruba özel D_i sözlüğünü öğren. Düşük Ranklı Yakınsama (B_i): Tekil Değer Eşikleme (SVD) ile B_i’yi hesapla. Ağırlıklı Seyrek Kodlama (A_i): Adaptif ağırlıklı yumuşak eşikleme ile A_i’yi hesapla. Yamaları Yeniden Oluştur: $\hat{X}_i = D_i \hat{A}_i$ ile temizlenmiş yama grubunu oluştur. Görüntü Birleştirme (Aggregation): - Tüm gruplardan elde edilen temizlenmiş yamaların ($\hat{X}_i$) ortalamasını alarak bir sonraki iterasyonun gürültüsüz görüntü tahmini olan $\hat{x}_c^{(k)}$’yi oluştur. Adım 3: Son İşleme - İterasyonlar bittiğinde elde edilen son logaritmik görüntü $\hat{x}_c^{(final)}$’e üstel (exponential) dönüşüm uygula. Çıktı: Nihai gürültüsüz görüntü $\hat{x}_{final}$.

koyulmaktadır. Çalışmada sentetik benek gürültüsü içeren test görüntülerinin oluşturulması amacıyla, literatürde yaygın olarak kullanılan iki farklı referans görüntüsü (House, Monarch) seçilmiştir. Bu görüntülerin seçilmesindeki temel kriter, farklı yapısal özellikler (düzgün bölgeler, keskin kenarlar, ince dokular ve karmaşık detaylar) içermeleri ve böylece önerilen yöntemin çeşitli senaryolardaki performansının kapsamlı bir şekilde değerlendirilebilmesidir.

Sentetik benek gürültülü görüntüler, orijinal optik görüntülerin yoğunluk formatında simüle edilmiş benek gürültüsü ile çarpılması yoluyla üretilmiştir. Bu simülasyon işlemi, [5] numaralı referansta detaylı olarak açıklanan matematiksel modele uygun şekilde gerçekleştirilmiş olup, süreçte L parametresi sırasıyla 1, 4, 8, 16 ve 32 değerlerine ayarlanarak farklı gürültü seviyelerindeki davranışın analiz edilmesi sağlanmıştır. Bu çeşitli L değerleri, yöntemin güçlü ($L = 1$) ile zayıf ($L = 32$) gürültü koşulları altındaki performansını sistematik olarak test etmeye olanak tanımaktadır.



Şekil 1: Test olarak kullanılacak referans House ve Monarch görüntüleri.

Önerilen yöntemin performansını değerlendirmek amacıyla, Şekil 1'deki referans görüntüler simüle edilerek, literatürde benek gürültüsü bastırma problemine yönelik olarak geliştirilmiş iki farklı yöntemle karşılaştırmalı bir analiz gerçekleştirilmiştir.

Birinci yöntem olarak, adaptif yerel istatistiklere dayalı Lee filtre seçilmiştir. Bu filtre, temel prensip olarak görüntüdeki her bir pikselin değerini, merkezinde bulunduğu yerel pencere (komşuluk bölgesi) içindeki piksellerin ortalaması ve varyansına bağlı olarak adaptif bir şekilde günceller. Bu sayede, gürültü baskılama işlemi sırasında kenar ve detay bilgilerinin korunması hedeflenir. İkinci karşılaştırma yöntemi ise,

çarpımsal gürültü azaltmada yaygın olarak kullanılan MIDAL algoritmasıdır. Bu yöntem, toplam varyasyon (TV-total variation) tabanlı bir optimizasyon yaklaşımı benimseyerek, görüntünün yapısal bilgilerini korurken gürültüyü etkili bir şekilde bastırmayı amaçlar. Bu iki referans yöntemle yapılan karşılaştırmalar, önerilen algoritmanın gürültü giderme kapasitesi, detay koruma yeteneği ve hesaplama verimliliği açısından kapsamlı bir şekilde incelenmiştir. Deneyisel sonuçlar, önerilen yaklaşımın karşılaştırılan yöntemlere kıyasla daha iyi sonuçlar ürettiği gözlemlenmiştir.

Deneyisel Çalışmalar ve Parametre Optimizasyonu

Lee filtresinin implementasyonunda yerel istatistiklerin hesaplanması amacıyla 7×7 boyutunda kare pencere yapısı tercih edilmiştir. Söz konusu pencere boyutunun seçiminde, gürültü bastırma performansı ile görüntüdeki detay bilgisinin korunması arasındaki kritik denge göz önünde bulundurulmuştur. MIDAL algoritmasının parametreleştirilmesi aşamasında ise, düzenleştirme katsayısı λ değeri en iyi sonuç verecek şekilde optimize edilmiştir. Önerilen yönteme ait λ ve τ parametreleri de benzer şekilde en iyi sonuçları verecek şekilde ayarlanarak belirlenmiştir.


Şekil 2'de, önerilen yöntemin benek gürültüsü giderme performansı, literatürde yaygın olarak kullanılan diğer algoritmaların sonuçlarıyla karşılaştırmalı olarak sunulmuştur. Çalışmada test görüntüsü olarak standart House görüntüsü kullanılmış ve bu görüntüye farklı seviyelerde benek gürültüsü eklenerek yöntemlerin performansı değerlendirilmiştir. Deneyisel sonuçlarda, görsel karşılaştırma için L parametresinin 4 ve 16 değerlerine karşılık gelen sonuçlar Şekil 2'de gösterilmiştir. Bu seçim, düşük ve yüksek gürültü seviyelerinde yöntemlerin davranışını net bir şekilde ortaya koymak amacıyla yapılmıştır. Ayrıca, L değerinin 1'den 32'ye kadar değiştiği tüm aralık için nicel performans ölçümleri (PSNR, SSIM) Tablo 2'de detaylı olarak raporlanmıştır.

Tablo 2: House test görüntüsüne farklı L değerleri ile eklenen benek gürültünün Lee filtre, MIDAL ve önerilen yöntemle gürültüsü giderilmiş görüntülerin PSNR, SSIM sonuçları

	Lee Filtresi		MIDAL		Önerilen Yöntem	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
L=1	23.6700	0.5069	23.8578	0.7352	24.2113	0.6591
L=4	26.5305	0.6697	28.5094	0.8087	29.2610	0.7985
L=8	28.1209	0.7412	29.4219	0.8250	31.2908	0.8302
L=16	29.8364	0.7983	31.7444	0.8534	33.1701	0.8689
L=32	31.7635	0.8511	33.5091	0.8706	34.9693	0.9074

Tablo 3: Monarch test görüntüsüne farklı L değerleri ile eklenen benek gürültünün Lee filtre, MIDAL ve önerilen yöntemle gürültüsü giderilmiş görüntülerin PSNR, SSIM sonuçları

	Lee Filtresi		MIDAL		Önerilen Yöntem	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
L=1	21.1600	0.6169	20.3153	0.6730	22.4749	0.7083
L=4	24.2953	0.7634	26.1420	0.8478	27.2401	0.8717
L=8	26.2623	0.8221	28.4683	0.8783	29.3066	0.9057
L=16	28.3394	0.8689	30.1623	0.9171	31.1663	0.9300
L=32	30.6602	0.9062	32.6551	0.9385	33.4023	0.9527



Şekil 2: House test görüntüsünün 4 ve 16 L değerli farklı benek gürültü seviyeleri için Lee filtre, MIDAL ve önerilen yöntem sonuçları gösterilmiştir.

Şekil 2 ve Tablo 2’de sunulan benzetim sonuçlarının karşılaştırmalı analizi, farklı gürültü seviyelerinde yöntemlerin performans farklılıklarını ortaya koymaktadır. Yapılan değerlendirmelerde, önerilen yöntemin PSNR ve SSIM metrikleri açısından referans alınan yöntemlere göre daha iyi performans sergilediği gözlemlenmiştir. Lee filtresinin benek gürültüyü tam bir şekilde filtreleyemediği MIDAL algoritmasında ise basamaklanma artefaktı olduğu gözlemlenmektedir.

Şekil 3 ve Tablo 3’te, Monarch (Kral kelebeği) test görüntüsü üzerinde gerçekleştirilen deneysel çalışmanın sonuçları, farklı gürültü seviyelerine bağlı olarak yöntemlerin performanslarının karşılaştırmalı analizini sunmaktadır. Elde edilen bulgular, önerilen yöntemin hem PSNR hem de SSIM metrikleri açısından literatürde referans kabul edilen yöntemlerden ölçülebilir üstünlükler sergilediğini ortaya koymaktadır.

Önerilen yöntemin pratik uygulamalardaki etkinliğini göstermek amacıyla gerçek SAR görüntüleri kullanılarak da

deneyler yapılmıştır. British DRA SAR tarafından elde edilmiş Bedfordshire’den bir kırsal manzara sunan gerçek 256×256 “Field” SAR görüntüsü kullanılmıştır. Bu görüntüyle yapılan deneysel çalışmalardan elde edilen görüntüler Şekil 4’te verilmiştir. Önceki benzetim çalışmalarında olduğu gibi bu görüntü için de önerilen yöntem Lee filtresi ve MIDAL yöntemleriyle karşılaştırılmıştır. Ayrıca, gerçek SAR görüntülerinde gürültüsüz referans görüntünün bulunmaması sebebiyle farklı gürültü giderme yöntemlerinin performansını değerlendirmek için ENL (Eşdeğer Görüntü Sayısı) ve orijinal ile gürültüsüzleştirilmiş SAR görüntüleri arasındaki oran görüntüsü kullanılmıştır. ENL görüntünün homojen bölgesi referans alınarak benek gürültünün gerçek SAR görüntülerinde ne kadar giderildiğini tespit edebilmek amacıyla yaygın olarak kullanılan bir indekstir. ENL hesaplaması için seçilen homojen bölge görüntülerde kırmızı çerçeve içerisine alınmıştır. ENL indeksi aşağıdaki denklemle hesaplanır:

$$ENL = \left(\frac{4}{\pi} - 1\right) \left(\frac{\mu_{HR}}{\sigma_{HR}}\right) \quad (10)$$

μ_{HR} seçilen homojen bölgenin ortalama değeri ve σ_{HR} ise varyansdır. Gürültülü gerçek SAR görüntünün gürültüden temizlenmiş haliyle bölümünden elde edilen oran görüntüleri ise Şekil 5’te gösterilmektedir. Oran görüntüsünde ise ideal durumda tamamen benek gürültüyü gösterir bir görüntü elde etmek gerekir. Oran görüntüsünde görüntü içerisindeki kenarların belli olma derecesi yöntemin benek gürültü giderme performansını görsel olarak ortaya çıkarmaktadır. Bu yüzden biz de bu görsel karşılaştırmayı sunmak istedik. Şekil 5’te oran görüntüsü karşılaştırmaları sunulmaktadır.

Field görüntüsünde kırmızı çerçeve içerisine alınan homojen bölge için ENL değerleri: Lee filtresi için 87.0384, MIDAL için 182.2541 ve önerilen yöntem için 441.7678 olarak hesaplanmıştır. Buradaki ENL sonuçları önerdiğimiz yöntemin daha iyi sonuç verdiğini göstermektedir. Şekil 5’te verilen oran görüntüsü karşılaştırmalarından da önerilen yöntemin karşılaştırılan yöntemlere göre daha iyi sonuçlar verdiği gözlemlenmiştir. Önerilen yöntemin oran görüntüsünde kenar detayları hemen hemen belli olmamaktadır. Ayrıca, Şekil 4’te elde edilen sonuçlara bakıldığında önerilen yöntemin görüntü detaylarını daha iyi koruduğu görülmektedir.


Yapılan bu deneysel çalışmaların çalışma süresi karşılaştırmaları da hesaplanmıştır. House, Monarch ve Field görüntülerinin boyutları birbiriyle aynıdır. House, Monarch ve Field görüntülerinin tümü 256×256 boyutunda olduğundan, her bir yöntemin işlem süresi test edilen görüntüye göre değişiklik göstermemiştir. Bu nedenle, belirli bir yöntemin her üç görüntü için hesaplanan çalışma süresi de aynıdır. Karşılaştırılan yöntemlerin algoritmaları Intel® Core™ i7-4700HQ (2.4 GHz) ve 16 GB RAM içeren bir bilgisayarda çalıştırılmıştır. Çalışma süreleri: Lee filtresi için 3.5250 sec, MIDAL için 51.4120 sec ve önerilen yöntem için 647.5913 sec olarak belirlenmiştir. Çalışma süreleri karşılaştırmalarına baktığımızda önerilen yöntemin diğer yöntemlere kıyasla daha yavaş olduğu ve hesaplama verimliliğinin daha düşük olduğu çıkarımı yapılabilir. Önerdiğimiz yöntemin bir GPU (Grafik İşlemci Birimi) üzerinde çalıştırılması hesaplama verimliliği dezavantajını elemine etmek için iyi bir yaklaşım olabilir.

7. Sonuç


Bu çalışmada, çarpımsal benek gürültüsünün toplamsal forma dönüştürülmesi amacıyla homomorfik dönüşüm yaklaşımı benimsenmiştir. Geliştirilen yeni nesil çarpımsal gürültü giderme modeli, grup katsayılarının hem seyrek temsil hem de düşük rank özelliklerini sinerjistik olarak kullanmaktadır. Önerilen bu hibrit model, geleneksel grup seyrek kodlama (Group Sparse Coding) ve birleşik seyreklik (Joint Sparsity) modelleri arasında köprü oluşturan yenilikçi bir çerçeve sunmaktadır.

Modelin optimizasyonu için, adaptif parametre ayarlama mekanizmasına sahip bir sıralı minimizasyon algoritması tasarlanmıştır. Yerel-olmayan benzerlik prizması altında, küresel aşırı tam sözlükler yerine, benzer yama gruplarından türetilen adaptif kompakt sözlükler ve seyrek katsayı matrisleri öğrenilmektedir. Performans iyileştirmesi amacıyla uygulanan ağırlıklı düzenleme ve üstel geri dönüşüm adımları, yöntemin etkinliğini artıran kritik bileşenler olarak öne çıkmaktadır. Diğer taraftan, önerilen yöntemin iyi performans gösterebilmesi için algoritmada bulunan parametrelerin optimum değerlerinin seçilmesi gerekmektedir. Bu parametreler düzgün seçilmediği takdirde yöntem istenilen performansı göstermeyebilir.


Önerilen yaklaşımın performans analizleri incelendiğinde sentetik ve gerçek SAR görüntüleriyle yapılan karşılaştırmalarda PSNR, SSIM ve ENL gibi görüntü karşılaştırma metrikleri açısından daha iyi sonuçlar verdiği gözlemlenmiştir. Ancak, Lee filtresi ve MIDAL algoritmalarının çalışma süreleri önerilen yöntemden daha kısadır. Önerdiğimiz yöntemin çalışma süresini kısaltıp daha hızlı sonuçlar elde etmek için GPU üzerinde çalıştırılmasını daha sonraki çalışma olarak planlamaktayız.



Şekil 3: Monarch test görüntüsünün 4 ve 16 L değerli farklı benek gürültü seviyeleri için Lee filtre, MIDAL ve önerilen yöntem sonuçları gösterilmiştir.



Şekil 4: L değeri 2 olan Field SAR görüntüsünün karşılaştırılan üç yöntemle benek gürültüden temizlenmiş sonuçları (a) Gerçek SAR görüntüsü (b) Lee filtre, (c) MIDAL (d) Önerilen yöntem.



Şekil 5: Field SAR görüntüsünün oran görüntüsü karşılaştırmaları (a) Lee filtre, (b) MIDAL (c) Önerilen yöntem.

8. Kaynaklar

- [1] Zhang J., Chen J., Yu H., Yang D., Xu X. ve Xing M., "Learning an SAR Image Despeckling Model Via Weighted Sparse Representation," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 14., 7148-7158, 2021.
- [2] Huang S., Liu D., Gao G., Guo X., "A Novel Method for Speckle Noise Reduction and Ship Target Detection in SAR Images," *Pattern Recognition*, Vol. 42., 1533-1542, 2009.
- [3] Lee J.S., Jurkevich L., Dewaele P., Wambach P., Oosterlinck A., "Speckle Filtering of Synthetic Aperture Radar Images: A Review," *Remote Sensing Reviews*, Vol.8., 313-340, 1994.
- [4] Lee J-S., Grunes M.R., Grandi G., "Polarimetric SAR Speckle Filtering and Its Implication for Classification," *IEEE Transactions on Geoscience and Remote Sensing*, Vol.37., 2363-2373, 1999.
- [5] Bioucas-Dias J. M., Figueiredo M. A. T., "Multiplicative Noise Removal Using Variable Splitting and Constrained Optimization," *IEEE Transactions on Image Processing*, Vol. 19., 1720-1730, 2010.
- [6] Steidl G., Teuber T., "Removing Multiplicative Noise by Douglas-Rachford Splitting Methods," *Journal of Mathematical Imaging and Vision*, Vol. 36., 168-184, 2009.
- [7] Deledalle C-A., Denis L., Tupin F., Reigber A., Jäger M., "NL-SAR: A Unified Nonlocal Framework for Resolution-Preserving (Pol)(In)SAR Denoising," *IEEE Transactions On Geoscience And Remote Sensing*, Vol. 53., 2021-2038, 2015.
- [8] Deledalle C-A., Denis L., Tupin F., "Iterative Weighted Maximum Likelihood Denoising With Probabilistic Patch-Based Weights," *IEEE Transactions On Image Processing*, Vol. 18., 2661-2672, 2009.
- [9] Parrilli S., Poderico M., Angelino C.S., Verdoliva L., "A Nonlocal SAR Image Denoising Algorithm Based on LLMSE Wavelet Shrinkage," *IEEE Transactions on Geoscience and Remote Sensing*, Vol.50., 606-616, 2012.
- [10] Fang J., Hu S., Ma X., "A Boosting SAR Image Despeckling Method Based on Non-Local Weighted Group Low-Rank Representation," *Sensors*, Vol.18., 2018, Art. no. 3448.
- [11] Chen G., Li G., Liu Y., Zhang X., Zhang L., "SAR Image Despeckling Based on Combination of Fractional-Order Total Variation and Nonlocal Low Rank Regularization," *IEEE Trans. Geosci. Remote Sens.*, Vol.58., 2056-2070, 2020.
- [12] F. Bo, X. Ma, Y. Cen and S. Hu, "SAR Image Speckle Reduction Based on Nuclear Norm Minus Frobenius Norm Regularization," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 62., 1-15, 2024.
- [13] Z. Xu, X. Feng, S. Tian, X.-J. Shen, H. Zhang and C. Wang, "Edge Preserved Low-Rank SAR Image Despeckling via Hierarchical Prior Knowledge Regulation," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 61., 1-17, 2023.
- [14] Xu B., Cui Y., Li Z., Yang J., "An Iterative SAR Image Filtering Method Using Nonlocal Sparse Model", *IEEE Geosci. Remote Sens. Lett.*, Vol.12., 1635-1639, 2015.
- [15] Xu B., Cui Y., Li Z., Zuo B., Yang J., Song J., "Patch Ordering-Based SAR Image Despeckling via Transform-Domain Filtering", *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, Vol.8., 1682-1695, 2015.
- [16] Chierchia G., Cozzolino D., Poggi G., Verdoliva L., "SAR Image Despeckling through Convolutional Neural Networks", in *Proc. IEEE Int. Geosci. Remote Sens. Symp.*, 2017, 5438-5441.
- [17] Wang P., Zhang H., Patel V.M., "SAR Image Despeckling using a Convolutional Neural Network", *IEEE Signal Process. Lett.*, Vol.24., 1763-1767, 2017.
- [18] Liu S. et al., "Convolutional Neural Network and Guided Filtering for SAR Image Denoising", *Remote Sens.*, Vol.11., 2019, Art. no. 702.
- [19] S. Liu, L. Zhang, S. Tian, Q. Hu, B. Li and Y. Zhang, "MFAENet: A Multiscale Feature Adaptive Enhancement Network for SAR Image Despeckling," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 16., 10420-10433, 2023.
- [20] S. Liu, S. Tian, Y. Zhao, Q. Hu, B. Li and Y. -D. Zhang, "LG-DBNet: Local and Global Dual-Branch Network for SAR Image Denoising," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 62., 1-15, 2024.
- [21] Aharon M., Elad M., Bruckstein A., "K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation", *IEEE Trans. Signal Process.*, Vol.54., 4311-4322, 2006.
- [22] Zha Z., Wen B., Yuan X., Zhou J., Zhu C., "Image Restoration via Reconciliation of Group Sparsity and Low-Rank Models", *IEEE Transactions on Image Processing*, Vol. 30., 5223-5238, 2021.
- [23] Cui Y., Zhou G., Yang J., Yamaguchi Y., "Unsupervised Estimation of the Equivalent Number of Looks in SAR Images", *IEEE Geosci. Remote Sens. Lett.*, Vol.8., 710-714, 2011.

Özgeçmiş



Dr. Mehmet DEMİR, Gaziantep Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden lisans derecesini 2009, yüksek lisans derecesini 2012 ve doktora derecesini 2019 yıllarında almıştır. Şu anda Gaziantep Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde doktor öğretim üyesi olarak çalışmaktadır. Araştırma alanları arasında sinyal işleme, görüntü işleme, sentetik açıklıklı radar görüntüleme ve makine öğrenmesi yer almaktadır.