

Çok Amaçlı Metasezgisel Optimizasyon Algoritmaları ile Hibrit Pan-Keskinleştirme Yöntemlerinden Üretilen Görüntülerin Sınıflandırma Performanslarının Arttırılmasına Yönelik Bir Araştırma

On the Use of Multi-Objective Metaheuristic Optimization Algorithms to Increase the Classification Performance of Images Produced from Hybrid Pansharpenting Methods

Volkan Yılmaz^{1*} 

¹Artvin Çoruh Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 08100, Artvin/Türkiye.

ARAŞTIRMA MAKALESİ

***Sorumlu yazar:**

Volkan Yılmaz
volkanyilmaz.jdz@gmail.com

doi: 10.48123/rsgis.838767

Yayın süreci

Geliş tarihi: 10.12.2020
Kabul tarihi: 11.01.2021
Basım tarihi: 13.03.2021

Özet

Görüntü sınıflandırma uygulamaları yüksek renk kalitesine sahip olan görüntülere ihtiyaç duymaktadır. Ancak, gerek algılayıcılardaki teknik kısıtlamalar, gerekse de maliyet problemlerinden dolayı bu tarz görüntüleri elde etmek her zaman mümkün olmamaktadır. Bu nedenle, bu çalışmada, literatürde ilk defa, çok amaçlı bir metasezgisel optimizasyon algoritması olan Non-Dominated Sorting Genetic Algorithm II (NSGA-II) algoritması, hibrit bir pan-keskinleştirme yöntemi olan Intensity-Hue-Saturation Discrete Wavelet Transform (IHS-DWT) yönteminin performansının iyileştirilmesi amacıyla kullanılmıştır. Önerilen yöntem ile renk kalitesi en iyiden en kötüye değişen beş farklı pan-keskinleştirilmiş görüntü üretilmiştir. Pan-keskinleştirmede kullanılan girdi Çok Bantlı (ÇB) görüntü ile üretilen bütün pan-keskinleştirilmiş görüntüler Yapay Sinir Ağları (YSA) yöntemine göre sınıflandırılmıştır. Sınıflandırma sonuçları, önerilen yöntem ile üretilen bütün pan-keskinleştirilmiş görüntülerin toplam sınıflandırma doğruluğunu belli oranda arttırdığını göstermektedir. Ayrıca, önerilen yöntem ile üretilen en iyi renk kalitesine sahip olan iki görüntünün toplam sınıflandırma doğruluğunu yaklaşık % 24 oranında arttırdığı tespit edilmiştir. Önerilen yöntem ile yüksek sınıflandırma doğruluğuna ihtiyaç duyulan uygulamalar için altlık üretilebileceği sonucuna varılmıştır.

Anahtar kelimeler: Pan-Keskinleştirme, Metasezgisel optimizasyon, Görüntü sınıflandırma

Abstract

Image classification applications require images of high colour quality. However, it is not always possible to obtain such images due to the technical constraints in the sensors and cost problems. Hence, this study, for the first time in the literature, used the multi-objective metaheuristic optimization algorithm Non-Dominated Sorting Genetic Algorithm II (NSGA-II) to improve the performance of the Intensity-Hue-Saturation Discrete Wavelet Transform (IHS-DWT) pansharpenting method. Five different pansharpented images with colour quality ranging from best to worst were produced with the proposed method. The input Multispectral (MS) image and all pansharpented images were classified with the Artificial Neural Network (ANN) classifier. The classification results revealed that all pansharpented images produced by the proposed method increased the overall classification accuracy to a certain extent. It was also concluded that the two images with the best colour qualities increased the overall classification accuracy by approximately 24 %. It can also be concluded that the proposed method is able to provide images for applications that require a high classification accuracy.

Keywords: Pansharpenting, Metaheuristic optimization, Image classification

1. Giriş

Günümüzde, uydu ve insanlı/insansız hava aracı teknolojilerindeki gelişmeler birçok uzaktan algılama uygulamasının ihtiyaç duyduğu yüksek uzamsal çözünürlüklü veya yüksek spektral çözünürlüklü görüntülerin elde edilebilmesine olanak sağlamaktadır. IKONOS, QuickBird, GeoEye-1, WorldView-2-3-4 vs. gibi uzaktan algılama uyduları, üzerlerinde barındırdıkları algılayıcılar sayesinde yüksek spektral çözünürlükte ve düşük uzamsal çözünürlükte çok bantlı (ÇB) görüntüler sağlarken, aynı zamanda da düşük spektral kaliteye sahip yüksek uzamsal çözünürlüklü pankromatik (PAN) görüntüler de üretebilmektedirler. Ayrıca, Earth Observation - 1 (EO-1) uydusuna entegre edilen Hyperion ve Chris uydusu üzerinde yer alan Proba gibi algılayıcılar sayesinde de daha yüksek spektral kaliteye sahip düşük uzamsal çözünürlüklü hiper bantlı uydu görüntüleri de elde etmek mümkündür. Görüldüğü üzere, uzaktan algılama uyduları tarafından görüntüler üretilirken ya spektral kaliteden ya da uzamsal kaliteden kayıplar yaşanmaktadır. Bunun nedeni uydu görüntülerini toplayan algılayıcılardaki birtakım teknik kısıtlamalardır (Yılmaz ve Gungor, 2016; Serifoglu Yılmaz vd., 2019). Sözü edilen teknik kısıtlamalar uzaktan algılama uygulamaları için ihtiyaç duyulan renk ve konum kalitesinde görüntüler elde edilebilmesini zorlaştırmaktadır. İhtiyaç duyulan kalitede görüntülerin elde edilebilmesini zorlaştıran bir diğer etmen ise yüksek kaliteli görüntülerin maliyetleridir. Uydu görüntülerinin spektral ve uzamsal kaliteleri arttıkça üretim ve pazarlama maliyetleri de artmaktadır. Bu gibi durumlar, araştırmacıları kendi uygulamaları için ihtiyaç duydukları spektral ve uzamsal kalitede görüntüler üretmek için motive etmektedir. Pan-keskinleştirme bu probleme etkin bir çözüm sunmaktadır (Yılmaz, 2020a).

Pan-keskinleştirme, yüksek uzamsal kalitedeki bir PAN görüntüdeki uzamsal detayları, aynı bölgeye ait daha düşük uzamsal kaliteye sahip yüksek spektral özellikli başka bir ÇB görüntüye aktararak, hem yüksek spektral kaliteye hem de yüksek uzamsal kaliteye sahip görüntüler üretilmesi işlemidir. Görüldüğü üzere, pan-keskinleştirme işleminin iki temel hedefi vardır; uzamsal kaliteyi girdi PAN görüntü kalitesine çıkarmak ve girdi ÇB görüntünün renk içeriğini başarıyla korumak. Ancak, bu iki hedefi aynı anda gerçekleştirmek çoğu durumda mümkün olmamaktadır. Bunun nedeni, pan-keskinleştirme yöntemlerinin hem renk yapısını hem de uzamsal detay kalitesini belli oranda bozmasıdır (Serifoglu Yılmaz vd., 2020).

1980'lerden günümüze kadar birçok pan-keskinleştirme yöntemi geliştirilmiştir. Dalgacık dönüşümü tabanlı pan-keskinleştirme yöntemleri literatürde en yaygın olarak kullanılan pan-keskinleştirme yöntemlerindedir. Çeşitli dalgacık dönüşümleri yardımıyla girdi PAN görüntüden çıkarttıkları uzamsal detayları girdi ÇB görüntüye aktaran bu yöntemler yüksek renk kalitesi vaat etmektedirler (Gogineni ve Chaturvedi, 2018; Yılmaz, 2020a). Bileşen değişimi tabanlı yaklaşımlar bir diğer yaygın olarak kullanılan pan-keskinleştirme yaklaşımlarındandır. Bu yaklaşımlar, girdi ÇB görüntünün renk ve uzamsal detay bilgilerini doğrusal bir dönüşüm aracılığıyla elde edilen farklı bir uzayda farklı bileşenlerde depolar. Bu yeni uzayda, uzamsal detay bilgilerini içeren bileşen girdi PAN görüntü ile yer değiştirir ve ters dönüşüm ile pan-keskinleştirilmiş görüntü üretilir (Ghassemian, 2016; Yılmaz, 2020a; Yılmaz vd., 2020). Bileşen değişimi tabanlı yöntemler, dalgacık dönüşümü tabanlı yöntemlerin aksine, uzamsal detay kalitesini arttırmakta oldukça başarılı olmalarına rağmen renk bozulmalarına yol açmaktadırlar (Serifoglu Yılmaz vd. 2019; Yılmaz, 2020a).


Optimum pan-keskinleştirme performansı elde etmek için metasezgisel optimizasyon algoritmalarından faydalanan yaklaşımlar son yıllarda dikkat çekmektedir. Garzelli ve Nencini (2006a) ve Garzelli ve Nencini (2006b) genetik algoritma kullanarak sırasıyla bileşen değişimi tabanlı Intensity-Hue-Saturation (IHS) yöntemini ve à-trous dalgacık dönüşümü tabanlı pan-keskinleştirme yöntemini optimize etmiştir. Yılmaz vd. (2019), bileşen değişimi tabanlı bir pan-keskinleştirme yöntemi olan Synthetic Variable Ratio (SVR) yönteminin performansını genetik algoritmadan yararlanarak iyileştirmiştir. Bir başka bileşen değişimi tabanlı pan-keskinleştirme yöntemi olan Gram-Schmidt (GS) (Laben ve Brower, 2000) yönteminin performansı Yılmaz vd. (2020) tarafından genetik algoritma yardımıyla iyileştirilmiştir. Serifoglu Yılmaz vd. (2019) metasezgisel Symbiotic Organisms Search (SOS) algoritmasından faydalanarak SVR yöntemini optimize ederken, Serifoglu Yılmaz vd. (2020) SOS algoritmasından yararlanarak hibrit bir pan-keskinleştirme yöntemi olan IHS - Discrete Wavelet Transform (IHS-DWT) (Abd El-Samie vd., 2012) yöntemini optimize etmiştir. Yılmaz (2020a) guguk kuşu arama algoritmasından faydalanan bir pan-keskinleştirme yöntemi geliştirmiştir. Yılmaz (2020b) çok amaçlı Non-Dominated Sorting Genetic Algorithm-II (NSGA-II) metasezgisel algoritmasını kullanarak SVR ve GS pan-keskinleştirme yöntemlerini iyileştirmiştir.

Bu çalışmanın amacı, bileşen değişimi tabanlı IHS yöntemi ile dalgacık dönüşümü tabanlı DWT yöntemini birleştiren IHS-DWT yönteminin performansını NSGA-II metasezgisel algoritmasıyla iyileştirmek ve önerilen yöntemle elde edilen farklı pan-keskinleştirilmiş görüntülerin renk kalitesini görüntü sınıflandırma yöntemiyle irdelemektir. Önerilen yöntemin görüntü sınıflandırma performansına etkileri görsel ve sayısal olarak irdelenecektir.

Makalenin geri kalanının ana hatları şu şekildedir; 2. bölüm çalışmanın uygulandığı test bölgesini ve çalışma kapsamında kullanılan uydu görüntülerini tanıtmaktadır. 3. bölüm önerilen NSGA-II tabanlı IHS-DWT pan-keskinleştirme yöntemini açıklamaktadır. 4. Bölüm çalışma kapsamında kullanılan görüntü sınıflandırma prosedürü hakkında bilgi vermektedir. 5. bölüm önerilen yöntemin görüntü sınıflandırma performansına etkilerini görsel ve sayısal olarak irdelemektedir. 6. bölüm ise çalışmadan elde edilen genel sonuçları özetlemektedir.

2. Materyal ve Çalışma Alanı

Çalışma kapsamında önerilen pan-keskinleştirme yöntemi Trabzon ilinin Sürmene ilçesinde kırsal bir bölgeye uygulanmıştır. 15 hektarlık bir alan kaplayan ve merkezinin coğrafi koordinatları $40^{\circ}53'37.04''K$ - $40^{\circ}06'03.15''D$ olan çalışma alanı, 2012 yılında WorldView-2 uydusu tarafından görüntülenmiştir. WorldView-2 uydusu uzamsal çözünürlüğü 2 m olan sekiz adet spektral bant (kıyı-coastal, mavi, yeşil, sarı, kırmızı, kırmızı kenarı-red edge, kızılötesi 1 ve kızılötesi 2) ve uzamsal çözünürlüğü 50 cm olan bir adet PAN görüntü üretmektedir. ÇB görüntü ve PAN görüntünün radyometrik çözünürlüğü 11 bit' tir. Şekil 1 çalışma alanını göstermektedir.



Şekil 1. Çalışma alanı

3. Önerilen Pan-keskinleştirme Yöntemi

Standart IHS-DWT pan-keskinleştirme yönteminde ilk aşama, girdi ÇB görüntünün boyutunu girdi PAN görüntünün boyutuna çıkartmaktır (Abd El-Samie vd., 2012). Elde edilen görüntü IHS dönüşümü yardımıyla RGB uzayından eksenleri yoğunluk, renk ve beyaza doygunluk olan başka bir uzaya dönüştürülür. RGB uzayından IHS uzayına dönüşüm aşağıda tanımlanmıştır (Gonzalez ve Woods, 2007):

$$\begin{pmatrix} I \\ V_1 \\ V_2 \end{pmatrix} = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ -\frac{\sqrt{2}}{6} & -\frac{\sqrt{2}}{6} & \frac{\sqrt{2}}{6} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} & 0 \end{pmatrix} \begin{pmatrix} K \\ Y \\ M \end{pmatrix} \quad (1)$$

$$H = \tan^{-1} \left(\frac{V_2}{V_1} \right) \quad (2)$$

$$S = \sqrt{V_1^2 + V_2^2} \quad (3)$$

Burada, I yoğunluk bileşenini, H renk bileşenini, S beyaza doygunluk bileşenini ifade etmektedir. K , Y ve M ise sırasıyla bir piksel konumundaki kırmızı, yeşil ve mavi bantlardaki gri değerleri temsil etmektedir.

Renk yapısındaki bozulmaları en aza indirmek için girdi PAN görüntünün histogramı elde edilen yoğunluk bileşeninin histogramına eşlenir. Daha sonra, girdi PAN görüntüye ve histogramı eşlenmiş yoğunluk bileşenine ayrık dalgacık dönüşümü (Discrete Wavelet Transform-DWT) uygulanır (Abd El-Samie vd., 2012). Herhangi bir görüntüye bir kademe ayrık dalgacık dönüşümü uygulandığında çözünürlüğü iki kat kötüşmüş dört adet alt bileşen oluşturulur.

Bu alt bileşenlerden bir tanesi olan ‘yaklaşım bileşeni’ görüntüdeki renk içeriğini barındırırken diğer üç alt bileşen görüntünün yatay, düşey ve çapraz yöndeki uzamsal detaylarını barındırır (Serifoglu Yılmaz vd., 2020). Girdi görüntüler arasındaki uzamsal çözünürlük oranı kaç kademe ayırık dalgacık dönüşümü uygulanacağını gösterir. Örneğin, girdi görüntüler arasındaki uzamsal çözünürlük oranı 4 ise iki kademe, 8 ise üç kademe ayırık dalgacık dönüşümü uygulanır. İlk kademe ayırık dalgacık dönüşümünden sonra uygulanacak olan her bir ayırık dalgacık dönüşümü elde edilen yaklaşım bileşenlerine uygulanır.

Daha sonra, histogramı eşlenmiş yoğunluk bileşeninden elde edilen yaklaşım bileşeni ile PAN görüntüden elde edilen yaklaşım bileşeninin ortalaması hesaplanır. Hesaplanan bu yeni görüntü, histogramı eşlenmiş yoğunluk bileşeninden elde edilen yaklaşım bileşeni ile yer değiştirir. Sonraki aşamada ters ayırık dalgacık dönüşümü uygulanarak yeni bir yoğunluk bileşeni elde edilir. Elde edilen bu yeni yoğunluk bileşeni ters IHS dönüşümünde kullanılarak pan-keskinleştirilmiş görüntü orijinal RGB uzayında elde edilir (Abd El-Samie vd., 2012). Ters IHS dönüşümü aşağıdaki gibi uygulanır (Gonzalez ve Woods, 2007):

$$\begin{pmatrix} K \\ Y \\ M \end{pmatrix} = \begin{pmatrix} 1 & -1 & 1 \\ \sqrt{2} & \sqrt{2} & \sqrt{2} \\ 1 & -1 & -1 \\ \sqrt{2} & \sqrt{2} & \sqrt{2} \\ 1 & \sqrt{2} & 0 \end{pmatrix} \begin{pmatrix} I \\ V_1 \\ V_2 \end{pmatrix} \quad (4)$$

Eşitlik (1)’ de görüldüğü üzere, IHS dönüşümü yoğunluk bileşenini girdi ÇB görüntünün bantlarının ortalaması şeklinde hesaplamaktadır. Girdi ÇB görüntünün her bir bandının yoğunluk bileşenine eşit oranda katkı vermesi gerektiği varsayımı renk kalitesinde bozulmalara neden olmaktadır. Bu durumu engellemek için, girdi ÇB görüntünün her bir bandı için en uygun bant ağırlığı belirlenmelidir. Bu çalışmada, optimum yoğunluk bileşenini elde etmede kullanılan bant ağırlıkları çok amaçlı metasezgisel bir optimizasyon algoritması olan NSGA-II’ den faydalanılarak belirlenmiştir. Daha önce de belirtildiği üzere pan-keskinleştirme işleminin iki hedefi vardır; girdi PAN görüntünün uzamsal detaylarının başarıyla aktarılması ve pan-keskinleştirme yaparken girdi ÇB görüntünün renk yapısının başarıyla korunması. Bu nedenle, pan-keskinleştirme iki amaçlı bir problem gibi düşünülebilir. Bu iki amacı da gerçekleştiren optimum bant ağırlıklarını belirlemek için NSGA-II algoritmasından yararlanılmıştır.

- NSGA-II algoritması ilk aşama olarak boyutu kullanıcı tarafından belirlenen rastgele bir popülasyon oluşturur (Deb vd., 2002).
- Üretilen popülasyon verilen iki amaca göre hızlı baskılanamayan sıralama (non-dominated sorting) yaklaşımına göre sıralanır ve her bir çözüme bir sıralama değeri (rank) verilir.
- Aynı sıralama değerine denk gelen çözümler arasında yığılma uzaklığı (crowding distance) sıralaması yapılır. Buna göre, aynı sıralama değerine sahip olan her bir çözümün, her iki amaç için diğer çözümlere olan uzaklıklarının toplamı yığılma uzaklığını verir. Yani, yığılma uzaklığı sıralaması her bir çözümü etrafındaki çözümlerin kalabalıklık derecesine göre sıralar. Yığılma değerinin küçük olması çözümün etrafının kalabalık olması anlamına gelmektedir. Bu durum tercih edilmediğinden dolayı yığılma uzaklığı değeri büyük olan çözümler seçilir (Deb vd., 2002).
- Aday çözümler hızlı baskılanamayan sıralama ve yığılma uzaklığı sıralamasına göre sıralandıktan sonra kalabalıklık karşılaştırma operatörü (crowded comparison operator) ve ikili turnuva seçimi (binary tournament selection) yöntemleri ile ebeveyn çözümler seçilir. Benzettirilmiş ikili çaprazlama (simulated binary crossover) ve polinom mutasyonu (polynomial mutation) yöntemleri seçilen ebeveynlerden yeni kromozomlar üretilmesinde kullanılır. Simüle edilmiş ikili çaprazlama yöntemi en iyi çözümler etrafında komşuluk araması yaparken, polinom mutasyonu yöntemi arama uzayının farklı bölgelerindeki çözümleri aramaya yarar.
- Elde edilen yeni kromozomlar orijinal popülasyona eklenerek yeni bir ara popülasyon oluşturulur.
- Ara popülasyon tekrar hızlı baskılanamayan sıralama ve yığılma uzaklığı sıralamasına göre sıralanarak orijinal popülasyon boyutunda yeni bir popülasyon elde edilir. Bu popülasyon sonraki iterasyonun girdi popülasyonu olarak kullanılır (Deb vd., 2002).
- İterasyonlar önceden belirlenen bir yakınsama değeri veya maksimum iterasyon sayısına ulaşılan kadar devam eder.

NSGA-II algoritması sonuç ürünü olarak Pareto optimal seti oluşturur. Bu set üzerindeki çözümler hiçbir çözüm tarafından baskılanamayan çözümleri içerir (Deb vd., 2002). Pareto optimal set üzerindeki çözümlerin hepsi eşit derecede önemlidir, dolayısıyla bu çözümlerden herhangi birinin bir diğerinden daha önemli olduğu düşünülemez. Kullanıcı, uygulamasının amacına en uygun olan çözümleri seçer (Yılmaz, 2020b). Bu çalışmada önerilen NSGA-II tabanlı IHS-DWT yönteminin iki amacından biri renk yapısını korumaktır. Bunu sağlamak için pan-keskinleştirilmiş görüntülerin renk yapılarının ne derece korunduğunu ölçmede kullanılan Erreur Relative Globale Adimensionnelle de Synthèse (ERGA) (Wald, 2000) metriğinden faydalanılmıştır. ERGA metriği aşağıdaki gibi hesaplanır (Wald, 2000):

$$ERGAS = 100 \frac{h}{l} \sqrt{\frac{1}{K} \sum_{k=1}^K \left(\frac{RMSE(k)}{\mu(\mathcal{C}B_k)} \right)^2} \quad (5)$$


Burada, h ve l sırasıyla girdi PAN ve ÇB görüntülerin uzamsal çözünürlüklerini göstermektedir. K toplam bant sayısını, $RMSE(k)$ girdi ÇB görüntünün k . bandı ile pan-keskinleştirilmiş görüntünün k . bandı arasındaki karesel ortalama hatayı (RMSE) ve $\mu(\mathcal{C}B_k)$ ise girdi ÇB görüntünün k . bandının ortalamasını göstermektedir.

NSGA-II tabanlı yöntemin bir diğer amacı ise girdi PAN görüntüdeki uzamsal detayları başarıyla aktarmaktır. Bu amacın sağlanması için pan-keskinleştirilmiş görüntülerin uzamsal kalitelerinin ölçülmesinde sıklıkla kullanılan uzamsal korelasyon katsayısı (UKK) (Zhou vd., 1998) metriğinden faydalanılmıştır. UKK metriği aşağıdaki gibi hesaplanır (Zhou vd., 1998):


$$UKK = \frac{\sum_{m,n} (LPAN_{mn} - \mu(LPAN))(LP_{mn} - \mu(LP))}{\sqrt{\left(\sum_{m,n} (LPAN_{mn} - \mu(LPAN))^2 \right) \left(\sum_{m,n} (LP_{mn} - \mu(LP))^2 \right)}} \quad (6)$$

Burada, $LPAN$ bir Laplacian filtre ile filtrelenmiş girdi PAN görüntüsünü, LP is bir Laplacian filtre ile filtrelenmiş pan-keskinleştirilmiş görüntüyü temsil etmektedir.


Çalışma kapsamında kullanılan IHS dönüşümü üç bantlı ÇB görüntüler ile çalışmaktadır. Ancak, çalışmada kullanılan girdi ÇB görüntü sekiz banda sahip olduğu için önerilen yöntem girdi ÇB görüntünün üçlü bant kombinasyonlarına uygulanmıştır. Dolayısıyla, önerilen yöntem kapsamında üretilen Pareto optimal çözüm değerlerini içeren Pareto cephesi (Pareto front) 1-2-3, 4-5-6 ve 6-7-8 bant kombinasyonları için üretilmiştir. 1-2-3 bant kombinasyonu için üretilen Pareto cephesi Şekil 2' de, 4-5-6 bant kombinasyonu için üretilen Pareto cephesi Şekil 3' de, 6-7-8 bant kombinasyonu için üretilen Pareto cephesi ise Şekil 4' de gösterilmiştir.



Şekil 2. 1-2-3 bant kombinasyonu için üretilen Pareto cephesi



Şekil 3. 4-5-6 bant kombinasyonu için üretilen Pareto cephesi



Şekil 4. 6-7-8 bant kombinasyonu için üretilen Pareto cephesi


Bu çalışma kapsamında, önerilen pan-keskinleştirme yöntemi ile beş farklı pan-keskinleştirilmiş görüntü üretilmiştir. Şekil 2, Şekil 3 ve Şekil 4' de gösterilen bütün Pareto optimal çözümler kullanılarak en iyi renk kalitesini sağlayan bant ağırlıkları, iyi bir renk kalitesi sağlayan bant ağırlıkları, optimum renk ve uzamsal kaliteyi sağlayan bant ağırlıkları, iyi bir uzamsal kalite sağlayan bant ağırlıkları ve en iyi uzamsal kaliteyi sağlayan bant ağırlıkları belirlenerek beş farklı pan-keskinleştirilmiş görüntü üretilmiştir.

4. Görüntü Sınıflandırma


Önerilen yöntemin görüntü sınıflandırma performansına etkilerini irdelemek için girdi ÇB görüntü ve üretilen bütün pan-keskinleştirilmiş görüntüler Yapay Sinir Ağları (YSA) ile sınıflandırılmıştır. YSA sınıflandırma yöntemi insan gözü ve beyin arasındaki kombinasyonu taklit eder. YSA sınıflandırma yönteminin temel amacı, eğitim verilerindeki düzenlilikleri öğrenmek ve bu düzenliliklere göre sınıflandırma kurallarını oluşturmaktır. Ağın mimarisi kullanıcı tarafından belirlenir (Tso ve Mather, 2009). Kullanıcı ağın eğitim oranını ve eğitim momentumunu tanımlamalıdır. Tipik bir sinir ağı üç katmandan oluşur. En soldaki katman (yani girdi katmanı) eğitim pikseli vektörlerini depolayan nöronları içerir. Girdi katmanında herhangi bir işlem yapılmaz. Sınıflandırmanın işlemi orta katman (yani gizli katman) tarafından gerçekleştirilir. En sağdaki katman (yani çıktı katmanı) sınıflandırma sonuçlarını üretir (Tso ve Mather, 2009). Aynı katmandaki nöronların hiçbiri birbirine bağlı değildir. Öte yandan, bir katmandaki her bir nöron, bir sonraki katmandaki nöronlara tam olarak bağlıdır. Bir ağdaki her ara bağlantı, öğrenme sırasında ayarlanan bir ağırlıkla ilişkilendirilir (Tso ve Mather, 2009). Geri yayılım algoritması, bu ağırlıkları güncellemek için kullanılan en yaygın algoritmalarından biridir. Geri yayılım algoritması, ileri ve geri yayılma olmak üzere iki adımdan oluşur. İleri yayılma aşamasında, girdi katmanı her bir eğitim piksel vektörü tarafından beslenir ve nöronların etkinliklerini girdi katmanından çıktı katmanına güncellemek için haritalama işlevleri kullanılır. Çıktı nöronlarının aktiviteleri beklenen aktivitelerle karşılaştırılır. Çıktı ile beklenen aktivite arasındaki fark ağ hatasıdır. Bu hata, çıktı katmanından geriye doğru yayılarak dağıtılır. İleri ve geri yayılımlar, tüm sınıfların özellikleri öğrenilene kadar art arda gerçekleştirilir (Tso ve Mather, 2009). Bu çalışmada geri yayılım algoritmasını benimseyen bir YSA kullanılmıştır. Eğitim oranı, eğitim momentumu, gizli katman sayısı ve eğitim momentumu parametreleri sırasıyla 0,3, 0,9, 1 ve 2000 olarak ayarlanmıştır. Bu parametre değerleri birçok farklı parametre denenerek belirlenmiştir. Oluşturulan YSA ile girdi ÇB görüntü ve pan-keskinleştirilmiş görüntüler gölge, bina, çay, orman, yol ve çıplak arazi olmak üzere altı arazi kullanım sınıfına ayrılmıştır. Bütün görüntülerin sınıflandırılmasında aynı eğitim piksellerinden yararlanılmıştır. Eğitim pikselleri arazi sınıflarının renk bakımından homojen kısımlarından toplanmıştır.

5. Bulgular

Önerilen yöntem ile üretilen pan-keskinleştirilmiş görüntüler Şekil 5' de gösterilmektedir. Şekilde de görüldüğü üzere, önerilen yöntem renk kalitesi girdi ÇB görüntünün renk kalitesine oldukça benzer görüntüler üretmeyi başarmıştır. Üretilen en iyi renk kalitesine sahip olan pan-keskinleştirilmiş görüntü (Şekil 5 (b)) neredeyse bütün yeryüzü nesnelere renklerin korumayı başarmıştır. Üretilen iyi renk kalitesine sahip görüntü (Şekil 5 (c)) ise genel olarak renk içeriğini korumakla beraber bazı yeşil alanlarda renk bozulmaları içermektedir. Önerilen yöntem optimum renk ve uzamsal kaliteye sahip pan-keskinleştirilmiş görüntüyü (Şekil 5(d)) üretirken renk yapısında da uzamsal detay kalitesinde de belli oranda bozulmalara yol açmıştır. Önerilen yöntem ile uzamsal detay kalitesini elde etmek üzere üretilen görüntülerdeki (Şekil 5 (e) ve (f)) renk bozulmaları açıkça görülmektedir. Bu görüntülerdeki uzamsal detay kalitesi ise dikkat çekicidir. Girdi ÇB görüntünün ve üretilen pan-keskinleştirilmiş görüntülerin YSA ile sınıflandırılması sonucu elde edilen görüntüler Şekil 6' da gösterilmiştir.



Şekil 5. Üretilen pan-keskinleştirilmiş görüntüler: (a) Girdi ÇB görüntü; (b) En iyi renk kalitesine sahip pan-keskinleştirilmiş görüntü; (c) İyi bir renk kalitesine sahip pan-keskinleştirilmiş görüntü; (d) Optimum renk ve uzamsal kaliteye sahip pan-keskinleştirilmiş görüntü; (e) İyi bir uzamsal kaliteye sahip pan-keskinleştirilmiş görüntü; (f) En iyi uzamsal kaliteye sahip pan-keskinleştirilmiş görüntü



Şekil 6. Üretilen sınıflandırılmış görüntüler: (a) Girdi ÇB görüntünün YSA sonucu; (b) En iyi renk kalitesine sahip pan-keskinleştirilmiş görüntünün YSA sonucu; (c) İyi bir renk kalitesine sahip pan-keskinleştirilmiş görüntünün YSA sonucu; (d) Optimum renk ve uzamsal kaliteye sahip pan-keskinleştirilmiş görüntünün YSA sonucu; (e) İyi bir uzamsal kaliteye sahip pan-keskinleştirilmiş görüntünün YSA sonucu; (f) En iyi uzamsal kaliteye sahip pan-keskinleştirilmiş görüntünün YSA sonucu

Elde edilen tematik görüntülerin sınıflandırma doğrulukları çalışma bölgesinde belirlenen 500 adet referans nokta ile irdelenmiştir. Girdi ÇB görüntü ile pan-keskinleştirilmiş görüntülerden elde edilen tematik görüntülerin kıyaslanabilmesi için girdi ÇB görüntünün boyutu girdi PAN görüntü boyutuna en yakın komşu yöntemine göre çıkartılmıştır. Referans noktaların sınıf değerlerinin tespit edilmesi için girdi PAN görüntüden ve çalışma bölgesine ait Google Earth görüntülerinden faydalanılmıştır. Referans noktalar ile sınıflandırılmış görüntülerden elde edilen hata matrisleri Tablo 1' de verilmiştir.

Tablo 1. Sınıflandırma doğrulukları

Görüntü	Arazi Sınıfı	Toplam Referans	Toplam Sınıflandırılmış	Doğru Sınıflandırılmış	Üretici Doğruluğu	Kullanıcı Doğruluğu
Orjinal ÇB Görüntü	Çay	187	291	168	% 89.84	% 57.73
	Bina	18	17	12	% 66.67	% 70.59
	Çıplak Arazi	32	48	23	% 71.88	% 47.92
	Yol	13	20	9	% 69.23	% 45.00
	Gölge	37	32	19	% 51.35	% 59.38
	Ağaç	213	92	78	% 36.62	% 84.78
	Toplam	500	500	309	Toplam Doğruluk = % 61.80	
En İyi Renk	Çay	187	200	148	% 79.14	% 74.00
	Bina	18	12	11	% 61.11	% 91.67
	Çıplak Arazi	32	29	22	% 68.75	% 75.86
	Yol	13	25	12	% 92.31	% 48.00
	Gölge	37	22	22	% 59.46	% 100.00
	Ağaç	213	212	165	% 77.46	% 77.83
	Toplam	500	500	380	Toplam Doğruluk = % 76.00	
İyi Bir Renk	Çay	187	201	150	% 80.21	% 74.63
	Bina	18	13	10	% 55.56	% 76.92
	Çıplak Arazi	32	42	28	% 87.50	% 66.67
	Yol	13	17	10	% 76.92	% 58.82
	Gölge	37	29	26	% 70.27	% 89.66
	Ağaç	213	198	160	% 75.12	% 80.81
	Toplam	500	500	384	Toplam Doğruluk = % 76.80	
Optimum	Çay	187	264	173	% 92.51	% 65.53
	Bina	18	12	9	% 50.00	% 75.00
	Çıplak Arazi	32	37	25	% 78.13	% 67.57
	Yol	13	18	11	% 84.62	% 61.11
	Gölge	37	25	22	% 59.46	% 88.00
	Ağaç	213	144	123	% 57.75	% 85.42
	Toplam	500	500	363	Toplam Doğruluk = % 72.60	
İyi Bir Konum	Çay	187	257	166	% 88.77	% 64.59
	Bina	18	9	8	% 44.44	% 88.89
	Çıplak Arazi	32	49	26	% 81.25	% 53.06
	Yol	13	20	12	% 92.31	% 60.00
	Gölge	37	24	22	% 59.46	% 91.67
	Ağaç	213	141	123	% 57.75	% 87.23
	Toplam	500	500	357	Toplam Doğruluk = % 71.40	
En İyi Konum	Çay	187	320	174	% 93.05	% 54.38
	Bina	18	9	9	% 50.00	% 100.00
	Çıplak Arazi	32	46	29	% 90.63	% 63.04
	Yol	13	20	13	% 100.00	% 65.00
	Gölge	37	29	27	% 72.97	% 93.10
	Ağaç	213	76	68	% 31.92	% 89.47
	Toplam	500	500	320	Toplam Doğruluk = % 64.00	

Tablo 1’de görüldüğü üzere bütün pan-keskinleştirilmiş görüntüler sınıflandırma doğruluğunu belli oranda arttırmışlardır. Girdi ÇB görüntünün sınıflandırma doğruluğu %61.80’dir. Bu görüntü için genel sınıflandırma doğruluğunun düşük çıkmasının en büyük nedeni çalışma bölgesinin büyük çoğunluğunun çay ve orman alanlarından oluşmasıdır. Çay ve orman alanları benzer spektral özelliklere sahip olduklarından dolayı bu sınıfların birbirine karışması sınıflandırma performansını olumsuz etkilemiştir. En iyi renk kalitesini sunan pan-keskinleştirilmiş görüntünün sınıflandırma doğruluğu %76 iken, iyi bir renk kalitesi sunan pan-keskinleştirilmiş görüntü ise %76.80’ lik bir doğrulukla sınıflandırılmıştır. Tablo 1’ de görüldüğü üzere, bu iki görüntü de çay ve orman alanlarının ayrılmasında belli oranda başarılı olmuşlardır. Optimum renk ve uzamsal kaliteye sahip pan-keskinleştirilmiş görüntü, iyi bir konum sağlayan pan-keskinleştirilmiş görüntü ve en iyi konum kalitesini sağlayan pan-keskinleştirilmiş görüntü ise sırasıyla %72.60, %71.40 ve %64’lük bir başarıyla sınıflandırılmıştır.

6. Sonuç

Çalışma kapsamına hibrit bir pan-keskinleştirme yöntemi olan IHS-DWT yönteminin performansı çok amaçlı bir metasezgisel algoritma olan NSGA-II ile iyileştirilmiştir. Bu çalışmada önerilen yöntem ile en iyi renk kalitesini sağlayan bant ağırlıkları, iyi bir renk kalitesi sağlayan bant ağırlıkları, optimum renk ve uzamsal kaliteyi sağlayan bant ağırlıkları, iyi bir uzamsal kalite sağlayan bant ağırlıkları ve en iyi uzamsal kaliteyi sağlayan bant ağırlıkları belirlenerek beş farklı pan-keskinleştirilmiş görüntü üretilmiştir. Üretilen pan-keskinleştirilmiş görüntülerin sınıflandırma doğrulukları hesaplandığında, üretilen iyi renk kalitesine sahip olan görüntülerin toplam sınıflandırma doğruluğunu yaklaşık %24 oranında arttırdığı görülmektedir. Üretilen iyi renk kalitesine sahip olan iki görüntü de birbirine karışması muhtemel olan çay ve orman alanlarının diğer görüntülere göre daha yüksek başarıyla sınıflandırılmasına olanak sağlamıştır. Optimum renk ve uzamsal kaliteyi sağlayan görüntü ve iyi bir konum kalitesi sağlayan diğer görüntüler de toplam sınıflandırma doğruluğunu belli oranda arttırmışlardır. Önerilen yönteminin kullanıcıya istediği renk veya uzamsal kalitede görüntü üretme imkânı sağlayabileceği sonucuna varılmıştır. Ayrıca, önerilen yöntem ile yüksek sınıflandırma doğruluğu gereken uygulamalara altlık görüntüler oluşturulabileceği ortaya konulmuştur.

Teşekkür

Çalışma kapsamında kullanılan uydu görüntülerinin sağlanmasında Karadeniz Teknik Üniversitesi, Harita Mühendisliği Bölümüne katkılarından dolayı teşekkürü borç bilirim.

Kaynaklar

- Abd El-Samie, F. E., Hadhoud, M. M., & El-Khamy, S. E. (2012). *Image Super-Resolution and Applications*. CRC press.
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. A. M. T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182-197. doi: 10.1109/4235.996017.
- Garzelli, A., & Nencini, F. (2006a). Fusion of Panchromatic and Multispectral Images by Genetic Algorithms. *IEEE International Conference on Geoscience and Remote Sensing Symposium (IGARSS 2006)* (3810-3813). Denver, CO, USA. doi: 10.1109/IGARSS.2006.976.
- Garzelli, A., & Nencini, F. (2006b). PAN-sharpening of Very High Resolution Multispectral Images Using Genetic Algorithms. *International Journal of Remote Sensing*, 27(15), 3273-3292. doi: 10.1080/01431160600554991.
- Ghassemian, H. (2016). A review of remote sensing image fusion methods. *Information Fusion*, 32, 75-89. doi: 10.1016/j.inffus.2016.03.003.
- Gogineni, R., & Chaturvedi, A. (2018). Sparsity inspired pan-sharpening technique using multi-scale learned dictionary. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 360-372. doi: 10.1016/j.isprsjprs.2018.10.009.
- Gonzalez, R. C., & Woods, R.E. 2007. *Digital Image Processing*. 3rd Edition, Pearson.
- Laben, C. A., & Brower, B. V. (2000). *U.S. Patent No. 6,011,875*. Washington, DC: U.S. Patent and Trademark Office.
- Serifoglu Yılmaz, C., Yılmaz, V., & Güngör, O. (2020). On the use of the SOS metaheuristic algorithm in hybrid image fusion methods to achieve optimum spectral fidelity. *International Journal of Remote Sensing*, 41(10), 3993-4021. doi: 10.1080/01431161.2019.1711244.
- Serifoglu Yılmaz, C., Yılmaz, V., Gungor, O., & Shan, J. (2019). Metaheuristic pansharpening based on symbiotic organisms search optimization. *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, 167-187. doi: 10.1016/j.isprsjprs.2019.10.014.
- Tso, B., & Mather, P. 2009. *Classification Methods for Remotely Sensed Data*. 2nd Edition, CRC Press.
- Wald, L. 2000. Quality of high resolution synthesized images: Is there a simple criterion? *3rd Conference: Fusion of Earth Data: Merging Point Measurements, Raster Maps and Remotely Sensed Images (99-103)*. Sophia Antipolis, France.

- Yılmaz, V. (2020a). Metasezgisel Guguk Kuşu Arama Algoritması ile Görüntü Kaynaştırma. *Türk Uzaktan Algılama ve CBS Dergisi*, 1(1), 1-12.
- Yılmaz, V. (2020b). A Non-Dominated Sorting Genetic Algorithm-II-based approach to optimize the spectral and spatial quality of component substitution-based pansharpened images. *Concurrency and Computation: Practice and Experience*, e6030.
- Yılmaz, V., & Gungor, O. (2016). Determining the optimum image fusion method for better interpretation of the surface of the Earth. *Norsk Geografisk Tidsskrift-Norwegian Journal of Geography*, 70(2), 69-81. doi: 10.1080/00291951.2015.1126761.
- Yılmaz, V., Serifoglu Yılmaz, C., Güngör, O., & Shan, J. (2020). A genetic algorithm solution to the gram-schmidt image fusion. *International Journal of Remote Sensing*, 41(4), 1458-1485. doi: 10.1080/01431161.2019.1667553.
- Zhou, J., Civco, D. L., & Silander, J. A. (1998). A wavelet transform method to merge Landsat TM and SPOT panchromatic data. *International Journal of Remote Sensing*, 19(4), 743-757. doi: 10.1080/014311698215973.