

SENTINEL-2 VE SENTINEL-3 GÖRÜNTÜLERİNİN KONUM-ZAMANSAL KAYNAŞTIRILMASINDA FARKLI ALGORİTMALARIN PERFORMANS ANALİZİ

Fırat ERDEM¹, Uğur AVDAN²

¹Doktora öğrencisi, Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, firaterdem@eskisehir.edu.tr

²Doç. Dr., Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, uavdan@eskisehir.edu.tr

ÖZET

Günümüzde uzaktan algılama sistemleri ile üretilen sık zaman serisi verileri yeryüzü dinamiklerinin izlenmesinde önemli rol oynamaktadır. Ancak mevcut uydu sensörlerinin konumsal çözünürlükleri ve zamansal çözünürlükleri arasındaki ilişki incelendiğinde çoğu uydu sensörü için bu iki çözünürlük tipi arasında ters orantı olduğu görülmektedir. Örneğin Sentinel-2 uydusu aynı alanı her beş günde bir görüntüleyebilmektedir. Ancak belirli bölgelerde bulut ve gölge etmenleri sebebiyle uygun bir görüntü elde etmek genellikle beş günden daha fazla zaman alabilir. Sentinel-3 programı ise çok yüksek zamansal çözünürlüklü (1.4 gün) görüntüler sağlamaktadır. Sentinel-3 görüntüleri daha yüksek zamansal çözünürlüğe sahip olmasına rağmen 300 m konumsal çözünürlüğü sebebiyle birçok yerel ölçekli uygulama için yeterli değildir. Sentinel-2 ve Sentinel-3 görüntülerinin konum-zamansal kaynaştırılması ile en fazla 1.4 gün zamansal çözünürlüğe ve 10 m konumsal çözünürlüğe sahip görüntüler üretilmektedir. Bu çalışmada Sentinel-2 ve Sentinel-3 görüntülerinin konum-zamansal kaynaştırılması için DMNet, Flexible Spatiotemporal Data Fusion (FSDAF) 2.0 ve Reliable and Adaptive Spatiotemporal Data Fusion (RASDF) yöntemlerinin performansları karşılaştırılmıştır. Sonuçlar, güçlü zamansal değişiklikler olması durumunda derin öğrenme tabanlı DMNet modelinin diğer yöntemlere göre daha yüksek başarı ile tahmin sonuçları ürettiğini göstermiştir. Zamansal değişimin az olduğu durumlarda ise RASDF yöntemi diğer yöntemlere göre daha başarılı olmuştur.

Anahtar Sözcükler: derin öğrenme, konum-zamansal kaynaştırma, Sentinel-2, Sentinel-3, uzaktan algılama

ABSTRACT

PERFORMANCE ANALYSIS OF DIFFERENT ALGORITHMS IN SPATIOTEMPORAL FUSION OF SENTINEL-2 AND SENTINEL-3 IMAGES

Today, frequent time series data produced by remote sensing systems play an important role in monitoring the dynamics of the earth. When the relationship between the spatial resolutions and temporal resolutions of existing satellite sensors is examined, it is seen that there is an inverse proportion between these two resolution types for most satellite sensors. For example, Sentinel-2 satellites can revisit the same region every five days. However, due to cloud and shadow pollution, it often takes more than five days to achieve a cloud-free Sentinel-2 image for certain areas. Sentinel-3 program provides very high temporal resolution (1.4 days) satellite imagery. Compared to Sentinel-2, Sentinel-3 provides more frequent data, but they are not sufficient for many local scale applications due to their low spatial resolution of 300 m. Images with a temporal resolution of up to 1.4 days and a spatial resolution of 10 m can be generated by spatiotemporal fusion of Sentinel-2 and Sentinel-3 images. In this study, the performances of DMNet, Flexible Spatiotemporal Data Fusion (FSDAF) 2.0, and Reliable and Adaptive Spatiotemporal Data Fusion (RASDF) methods for spatio-temporal fusion of Sentinel-2 and Sentinel-3 images were compared. The results demonstrated that the deep learning-based DMNet model generates better prediction results than other approaches in case of significant temporal changes. The RASDF method performed better than other methods in situations when there was less temporal variance.

Keywords: deep learning, spatiotemporal fusion, Sentinel-2, Sentinel-3, remote sensing


1. GİRİŞ

Günümüzde uzaktan algılama sistemleri ile üretilen sık zaman serisi verileri yeryüzü dinamiklerinin izlenmesinde önemli rol oynamaktadır. Örneğin; bitki örtüsü mevsimselliğinin izlenmesi (Shen vd., 2011), karbon akısının modellenmesi (Lees vd., 2018), ürün veriminin tahmin edilmesi (Johnson vd., 2016), insan-doğa etkileşimlerinin izlenmesi (Li vd., 2017) gibi çeşitli uygulama alanları için sık zaman serisi verilerine ihtiyaç vardır. Landsat, Sentinel-2, MODIS gibi ücretsiz olarak temin edilebilen uydu görüntülerinin yaygınlaşması ile uzaktan algılamada zaman serisi ve değişim analizi çalışmaları popülerite kazanmıştır.

Değişim analizini amaçlayan pek çok uygulama alanında zamansal çözünürlüğün yüksek olmasının yanında konumsal çözünürlüğün de yüksek olması önemlidir. Mevcut uydu sensörlerinin konumsal çözünürlükleri ve zamansal çözünürlükleri arasındaki ilişki incelendiğinde çoğu uydu sensörü için bu iki çözünürlük tipi arasında ters orantı olduğu görülmektedir. Genellikle konumsal çözünürlüğü yüksek olan uydu sensörlerinin zamansal çözünürlüğü düşük iken zamansal çözünürlüğü yüksek olan sensörlerin konumsal çözünürlüğü düşüktür (Ghamisi vd., 2019). Örneğin MODIS uydusunun aynı alanı tekrar görüntüleme süresi 1 gün ve konumsal çözünürlüğü 250 m,

500 m ve 1 km iken Landsat-8 uydusunun aynı alanı tekrar görüntüleme süresi 16 gün ve multispektral bantlarının konumsal çözünürlüğü 30 m'dir.

Sentinel-2 uyduları aynı alanı her beş günde bir ziyaret edebilir. Ancak belirli bölgelerde bulut ve gölge etmenleri sebebiyle uygun bir görüntü elde etmek genellikle beş günden daha fazla bir zaman alabilir. Özellikle bulutlu alanlar için Sentinel-2 gözlemleri bitkilerin büyüme döngüsü gibi hızlı değişimleri izlemek için yeterli değildir. Avrupa Uzay Ajansı'nın bir diğer programı olan Sentinel-3 çok yüksek zamansal çözünürlüklü (1.4 gün) uydu görüntüleri sağlamaktadır. Sentinel-2 ile kıyaslandığında Sentinel-3 uydusu daha sık görüntüler sağlar ancak bu görüntüler 300 m konumsal çözünürlüğü sebebiyle birçok büyük ölçekli uygulama için yeterli değildir. Konum-zamansal görüntü kaynaştırma (Şekil-1) ile 1.4 gün zamansal çözünürlüğe ve 10 m konumsal çözünürlüğe sahip görüntüler üretilebilir.




Şekil 1. Konum-zamansal görüntü kaynaştırmanın şematik gösterimi (Zhu, vd., 2018)

Konum-zamansal görüntü kaynaştırma, yüksek konumsal ve zamansal çözünürlüklü görüntülerin üretilmesi için ekonomik ve efektif bir çözümdür. Konum-zamansal görüntü kaynaştırma, MODIS ve AVHRR gibi yüksek zamansal çözünürlüklü görüntüler ile LANDSAT, Sentinel-2 gibi yüksek konumsal çözünürlüğe sahip görüntüleri kaynaştırmaya yönelik metodolojilerdir (Zhu vd., 2018). Bu işlem sonucunda hem konumsal çözünürlüğü hem de zamansal çözünürlüğü yüksek, sentezlenmiş görüntüler üretilir. Böylelikle, mevcut uydu sistemlerinin konumsal ve zamansal çözünürlük sınırlamaları elimine edilir ve daha fazla sayıda bulutsuz görüntü elde edilebilir.

Konum-zamansal görüntü kaynaştırma yöntemleri; karışım temelli (Zhang vd., 2013; Wu vd., 2012), ağırlık fonksiyonu temelli (Gao vd., 2006; Zhu vd., 2010), Bayes temelli (Shen vd., 2016), öğrenme temelli (Ke vd., 2016; Boyte vd., 2018) ve hibrit yöntemler (Zhu vd., 2016) olmak üzere beş kategoride değerlendirilir (Zhu vd., 2018). Bu yöntemlerin çeşitli durumlarda birbirlerine göre avantaj ve dezavantajları bulunmaktadır. Sunulan çalışmanın amacı Sentinel-2 ve Sentinel-3 görüntülerinin konum-zamansal kaynaştırılması için DMNet (Li vd., 2020), Flexible spatiotemporal data fusion (FSDAF) 2.0 (Guo vd., 2020) ve Reliable and adaptive spatiotemporal data fusion (RASDF) (Shi vd., 2022) algoritmalarının performansını karşılaştırmaktır.

2. MATERYAL VE YÖNTEM

Konum-zamansal görüntü kaynaştırma algoritmalarının başarılarının test edilmesi için Kansas veri seti (Erdem ve Avdan, 2022) oluşturulmuştur. Kansas veri seti, ABD'nin Kansas eyaletinden bir tarım alanını kapsamaktadır. Kansas, 2015 itibarıyla en verimli tarım eyaletlerinden birisidir. Bölgede yüksek verimde buğday, mısır ve soya fasulyesi üretilmektedir. Kansas 213,100 kilometre kare alanı ile A.B.D.'nin en büyük 15. eyaletidir. Ayrıca 2020 nüfus sayımına göre nüfusu 2,940,865 olup en fazla nüfusa sahip 34. eyalettir (Britannica, 2022). Kansas eyaletindeki önemli tarım ürünü sert kırmızı kışlık buğdaydır. Eyaletin doğu bölgesi A.B.D.'nin en önemli tahıl üretim merkezlerinden biri olan Tahıl Kuşağı'nın (Grain Belt) bir parçasıdır. Kansas, yılda 3 Mha'dan fazla ekilen ~9 Mt üretim miktarıyla ABD'deki en büyük kışlık buğday üreten eyalettir (Service, 2017). Kışlık buğday ekimi, eylül ortasından kasım ortasına kadar yapılırken hasat işlemi ise yere ve mahsul durumuna bağlı olarak haziran ayının başından temmuz ayının başlarına kadar gerçekleştirilir (Munaro vd., 2020). Şekil 2.'de çalışma alanının konumu verilmiştir. Çalışma alanı 48 km x 48 km'lik bir alanı kapsamaktadır.



Şekil 2. Kansas veri setinin konumu


Veri setinde yüksek konumsal çözünürlüklü görüntü olarak Sentinel-2 MSI, yüksek zamansal çözünürlüklü görüntü olarak Sentinel-3 OLCI uydu görüntüleri yer almaktadır. Sentinel-2 MSI uydu görüntülerinin 10 m konumsal çözünürlüğe sahip 2. (mavi), 3. (yeşil), 4. (kırmızı) ve 8. (yakın kızılötesi) bantları ve Sentinel-3 OLCI uydu görüntülerinin 300 m konumsal çözünürlüğe sahip 4., 6., 8. ve 17. bantları kullanılmıştır. Sentinel-3 verilerine yüzey yansımalarını elde etmek için SNAP yazılımında iCor aracı ile atmosferik düzeltme uygulanmıştır. Ardından, Sentinel-2 ve Sentinel-3 görüntüleri üzerinde kontrol noktaları belirlenerek Sentinel-3 yüzey yansıması verilerine rektifikasyon işlemi uygulanmıştır. Son ön işleme adımında Sentinel-3 görüntüleri, görüntülerin Sentinel-2 görüntüleri ile tam olarak aynı boyutta olması için 10 m piksel boyutunda yeniden örneklenmiştir.

Konum-zamansal görüntü kaynaştırma çalışmalarında görüntülerin tarihlerine göre gruplandırılması gerekmektedir (Tan vd., 2018). Sunulan çalışmada kullanılan algoritmalar, referans tarihindeki düşük ve yüksek konumsal çözünürlüklü görüntüyü ve tahmin tarihindeki düşük konumsal çözünürlüklü görüntüyü kullanarak tahmin tarihindeki yüksek konumsal çözünürlüklü görüntüyü tahmin etmektedir (Li vd., 2020). Bu nedenle, görüntüler her grupta referans ve tahmin tarihleri için birer Sentinel-2 ve Sentinel-3 görüntüsü olacak şekilde gruplandırılmıştır. Uydu görüntülerinin tarihleri ve gruplandırılması Çizelge 1.'de verilmiştir.

Çizelge 1. Kansas veri setindeki Sentinel-2 ve Sentinel-3 uydu görüntülerinin gruplandırılması

Kullanım	Tarih-1 (Referans)	Tarih-2 (Tahmin)
Eğitim	07.06.2019	12.07.2019
	12.07.2019	06.08.2019
	06.08.2019	26.08.2019
	29.06.2020	09.07.2020
	05.08.2021	20.08.2021
Test	11.06.2021	16.07.2021
	11.07.2021	16.07.2021
	16.07.2021	05.08.2021

Çalışmada DMNet (Li vd., 2020), Flexible spatiotemporal data fusion (FSDAF) 2.0 (Guo vd., 2020) ve Reliable and adaptive spatiotemporal data fusion (RASDF) (Shi vd., 2022) algoritmalarının performansı karşılaştırılmıştır. DMNet modeli Li vd. (2020) tarafından Landsat ve MODIS görüntülerinin konum-zamansal kaynaştırılması için geliştirilmiş Konvolüsyonel Sinir Ağı tabanlı bir modeldir. Modelin öne çıkan özellikleri çok ölçekli konvolüsyonları, genişleme özellikli konvolüsyonları ve kısa yol bağlantılarını kullanmasıdır. Şekil 3.'te DMNet modeli gösterilmiştir.



Şekil 3. DMNet modeli

FSDAF 2.0 algoritması, FSDAF algoritmasının performansını iyileştirmek, özellikle konumsal detayların kaybolmasını önlemek ve arazi örtüsü değişim alanlarını optimize etmek için geliştirilmiştir (Guo vd., 2020). RASDF algoritması ise konum-zamansal görüntü kaynaştırmanın sensör farklılıklarından kaynaklanan belirsizliğini azaltmak ve güçlü zamansal değişimlerin modellenmesini sağlamak için geliştirilmiş bir konum-zamansal görüntü kaynaştırma yöntemidir (Shi vd., 2022). Konum-zamansal görüntü kaynaştırma algoritmalarının doğruluk analizi için tahmin tarihindeki Sentinel-2 görüntüsü yer gerçeği olarak kullanılarak RMSE (1), PSNR (2), SSIM (3), SAM (4) ve UIQI (5) metrikleri hesaplanmıştır. RMSE, PSNR, SSIM ve UIQI metriklerinin optimum değerleri sırasıyla 0, $+\infty$, 1 ve 1'dir. SAM değeri sıfıra yaklaştıkça kaynaştırma sonucunun belirsizliği azalır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^H \sum_{j=1}^W (y(i,j) - x(i,j))^2}{H \times W}} \quad (1)$$

$$PSNR = 10 \times \log_{10} \left(\frac{peakval^2}{MSE} \right) \quad (2)$$

$$SSIM = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (3)$$

$$SAM = \frac{1}{P} \sum_{i=1}^P \arccos \frac{\sum_{j=1}^B ((x_j(i) - y_j(i)))}{\sqrt{\sum_{j=1}^B ((x_j(i))^2) \sum_{j=1}^B ((y_j(i))^2)}} \quad (4)$$

$$UIQI = \frac{4\mu_x\mu_y\mu_{xy}}{(\mu_x^2 + \mu_y^2)(\sigma_x^2 + \sigma_y^2)} \quad (5)$$

Burada H, görüntüdeki toplam satır sayısını, W, görüntüdeki toplam sütun sayısını, x, tahmin edilen görüntüyü, y, referans görüntüyü, μ_x tahmin edilen görüntünün ortalamasını, μ_y , referans görüntünün ortalamasını, σ_{xy} , tahmin edilen ve referans görüntü arasındaki kovaryansı, σ_x^2 , tahmin edilen görüntünün varyansını, σ_y^2 , referans görüntünün varyansını, peakval olası maksimum piksel değerini, c_1 ve c_2 sabitleri ve p, toplam piksel sayısını ifade etmektedir.


3. BULGULAR

Derin öğrenme modellerinin eğitilmesi çok fazla işlem gücü gerektirmesi sebebiyle birçok derin öğrenme çalışmasında uydu görüntülerine kesme işi uygulanır ve daha küçük görüntüler üzerinden eğitim ve test işlemleri gerçekleştirilir (Tan vd., 2018; Liu vd., 2019; Wang ve Wang, 2020). Sunulan çalışmada Kansas veri setindeki uydu görüntülerinden 128 piksel kaydırma ile 256 x 256 piksel boyutlarında görüntü parçaları oluşturulmuştur. Bu işlem sonucunda eğitim için toplam 4500 adet görüntü parçası elde edilmiştir. Elde edilen görüntü parçalarının %10'u doğrulama için kullanılmıştır. DMNet modelinin eğitilmesinde 0.0001 öğrenme oranı ile birlikte Adam optimizasyon algoritması (Kingma ve Ba, 2014) kullanılmıştır. Modelin eğitim işlemi için kayıp fonksiyonu olarak ortalama karesel hata (Mean Square Error – MSE) fonksiyonu kullanılmıştır. Epok sayısı ise 100 olarak belirlenmiştir.

FSDAF 2.0 algoritması GitHub - Andy-cumt/ FSDAF2_GUI kodu kullanılarak uygulanmıştır. RASDF algoritması ise GitHub - Andy-cumt/ RASDF_GUI kodu kullanılarak uygulanmıştır. RASDF'nin kayar pencere parametresinin maksimum ve minimum boyutları 80 ve 20 olarak belirlenmiştir. Global karışmama adımında kullanılan minimum ve maksimum sınıflandırma sayısı parametreleri ise sırasıyla 3 ve 7 olarak seçilmiştir. Yerel karışmama adımında

kullanılan minimum ve maksimum sınıflandırma sayısı parametreleri sırasıyla 2 ve 4 olarak seçilmiştir. FSDAF 2.0 ve RASDF algoritmalarının uygulanmasındaki tüm parametreler ampirik olarak seçilmiştir.


Birinci test grubunun çalışma alanı içerisinde bir örnek alan için tahmin sonuçları Şekil 4.'te gösterilmektedir. Görsel değerlendirme için çalışma alanının tarımsal içeriğinin yoğun olması nedeniyle kırmızı-yeşil-yakın kızılötesi bant kombinasyonu kullanılmıştır. FSDAF 2.0 ve RASDF yöntemlerinin derin öğrenme tabanlı DMNet yöntemine göre zamansal değişime daha duyarlı olduğu görülmektedir. Özellikle spektral benzerlik açısından derin öğrenme tabanlı yöntemlerin tahmin sonuçları referans görüntüye daha yakındır. Sarı dikdörtgende görülebileceği gibi tarım alanları DMNet ve STFRDN modellerinin üretmiş olduğu tahmin görüntülerinde gerçeğe daha yakınken, bu tür alanlar FSDAF 2.0 ve RASDF tahminlerinde daha belirsizdir. Bununla birlikte yeşil dikdörtgende gözlemlenebileceği gibi özellikle ekili tarım alanlarını içermeyen arka plan alanlarında DMNet modeli gürültü üretme eğilimindedir.



Şekil 4. Birinci test grubu için yöntemlerin karşılaştırması. A) 11.06.2021 Sentinel-3, B) 16.07.2021 Sentinel-3, C) 11.06.2021 Sentinel-2, D) 16.07.2021 Sentinel-2 (yer gerçeği), E) FSDAF 2.0, F) RASDF, G) DMNet


İkinci test grubunda, birinci test grubunda tahmin edilmesi hedeflenen görüntü daha yakın tarihli bir referans görüntü kullanarak tahmin edilmiştir. Bu grup, birinci test grubu ile aynı tarihin (16.07.2021) tahminini içerir, ancak referans tarihi 11.06.2021 yerine 11.07.2021'dir. Dolayısıyla bu test grubunda konum-zamansal görüntü kaynaştırma için kısa zaman aralığının (5 gün) önemi araştırılmıştır. İkinci test grubunun çalışma alanı içindeki bir örnek alan için tahmin sonuçları Şekil 5.'te gösterilmektedir. Test edilen üç algoritma da ilk test grubuna kıyasla yer gerçeğine daha yakın tahmin sonuçları sağlamıştır. Tarihler arasında çok fazla arazi örtüsü ve arazi kullanımı değişimi olmamasına rağmen tahmin tarihinin Sentinel-2 görüntüsü spektral özellikler açısından referans tarihteki (11.07.2021) görüntüden

farklıdır. FSDAF 2.0 ve RASDF algoritmaları referans tarihindeki görüntüye daha yakın bir görüntü üretirken, derin öğrenme tabanlı DMNet modelinin spektral içeriği hedeflenen görüntüye daha yakındır.



Şekil 5. İkinci test grubu için yöntemlerin karşılaştırması. A) 11.07.2021 Sentinel-3, B) 16.07.2021 Sentinel-3, C) 11.07.2021 Sentinel-2, D) 16.07.2021 Sentinel-2 (yer gerçeği), E) FSDAF 2.0, F) RASDF, G) DMNet

Üçüncü test grubu ise 16.07.2021 ve 05.08.2021 tarihli görüntü çiftlerinden oluşmaktadır. Bu tarihlerde hasat işlemlerinin tamamlanması nedeniyle ikinci test grubuna benzer şekilde arazi örtüsü ve arazi kullanımı değişimi azdır. Ancak diğer test gruplarından farklı olarak hasat işlemlerinin tamamlanması sebebiyle çalışma alanının birçok yerinde ekili tarım alanları daha fazladır. Şekil 6., örnek bir bölge için üçüncü test grubunun görsel karşılaştırmasını göstermektedir. FSDAF 2.0 ve RASDF algoritmaları, önceki test gruplarına kıyasla daha doğru görüntüler tahmin etmiştir. Öte yandan, DMNet modeli bu test grubunda bir miktar gürültü üretmiştir. Model, siyah dikdörtgende da görülebileceği gibi bazı ekili alanları arka plan olarak tahmin etmiştir.



Şekil 6. Üçüncü test grubu için yöntemlerin karşılaştırması. A) 16.07.2021 Sentinel-3, B) 05.08.2021 Sentinel-3, C) 16.07.2021 Sentinel-2, D) 05.08.2021 Sentinel-2 (yer gerçeği), E) FSDAF 2.0, F) RASDF, G) DMNet

Birinci test grubunun doğruluk analizi sonuçları Çizelge 2.'de verilmiştir. Tüm doğruluk analizi metriklerinde FSDAF 2.0 ve RASDF algoritmaları DMNet modeline kıyasla test görüntüsünü daha az doğrulukla tahmin etmiştir. Bunun temel nedeni, görsel değerlendirmede de gözlenebilen spektral farklılıklardır (Şekil 3.).

Çizelge 2. Birinci test grubuna ait doğruluk analizi sonuçları

Metrik	Bant	FSDAF 2.0	RASDF	DMNet
RMSE	Kırmızı	0.05535	0.05428	0.05196
	Yeşil	0.03472	0.03354	0.02961
	Mavi	0.03160	0.03080	0.02824
	Yakın kızılötesi	0.08143	0.07941	0.07814
	Ortalama	0.05078	0.04951	0.04699

PSNR	Kırmızı	25.1382	25.3073	25.6872
	Yeşil	29.1879	29.4893	30.5710
	Mavi	30.0056	30.2277	30.9838
	Yakın kızılötesi	21.7839	22.0027	22.1420
	Ortalama	26.5289	26.7568	27.3460
SSIM	Kırmızı	0.7359	0.7306	0.7806
	Yeşil	0.8574	0.8642	0.8835
	Mavi	0.8805	0.8859	0.9024
	Yakın kızılötesi	0.6563	0.6710	0.7085
	Ortalama	0.7825	0.7879	0.8188
UIQI	Kırmızı	0.7925	0.8014	0.8343
	Yeşil	0.9033	0.9126	0.9344
	Mavi	0.8603	0.8686	0.8636
	Yakın kızılötesi	0.9550	0.9576	0.9591
	Ortalama	0.8777	0.8851	0.8978
SAM		0.3347	0.3259	0.3028

İkinci test grubunun doğruluk analizi sonuçları Çizelge 3.'de verilmiştir. Referans ve tahmin tarihi arasında arazi kullanımı ve arazi örtüsü değişiminin az olması nedeniyle bu test grubunda daha yüksek doğruluk metriklerine ulaşılmıştır. RMSE, PSNR ve UIQI metrikleri baz alındığında ilk test grubuna yakın sonuçlar elde edilse de FSDAF 2.0 ve RASDF algoritmaları, SSIM ve SAM metrikleri baz alındığında DMNet modeline kıyasla daha yüksek doğruluk metriklerine sahip görüntüler tahmin etmiştir.

Çizelge 3. İkinci test grubuna ait doğruluk analizi sonuçları

Metrik	Bant	FSDAF 2.0	RASDF	DMNet
RMSE	Kırmızı	0.05371	0.05271	0.05001
	Yeşil	0.04140	0.04100	0.03401
	Mavi	0.03125	0.03073	0.02618
	Yakın kızılötesi	0.13180	0.13075	0.07072
	Ortalama	0.06454	0.06380	0.04523
PSNR	Kırmızı	25.3992	25.5630	26.0190
	Yeşil	27.6593	27.7453	29.3674
	Mavi	30.1021	30.2482	31.6412
	Yakın kızılötesi	17.6019	17.6711	23.0089
	Ortalama	25.1906	25.3069	27.5091
SSIM	Kırmızı	0.9021	0.9185	0.8265
	Yeşil	0.9383	0.9463	0.8978
	Mavi	0.9445	0.9505	0.9208
	Yakın kızılötesi	0.8338	0.8707	0.7614
	Ortalama	0.9047	0.9215	0.8516
UIQI	Kırmızı	0.8727	0.8731	0.8705
	Yeşil	0.9233	0.9231	0.9316
	Mavi	0.9408	0.9409	0.9116
	Yakın kızılötesi	0.8998	0.9001	0.9597
	Ortalama	0.9092	0.9093	0.9184
SAM		0.2232	0.2175	0.2589

Üçüncü test grubunun doğruluk analizi sonuçları Çizelge 4.'te verilmiştir. FSDAF 2.0 ve RASDF algoritmaları, özellikle yakın kızılötesi bantının tahmini için DMNet modeline kıyasla daha yüksek başarıda tahmin sonuçları üretmiştir. PSNR ve UIQI dışındaki tüm metriklerde FSDAF 2.0 ve RASDF algoritmaları, DMNet modelinden daha iyi performans göstermiştir. RASDF ve FSDAF 2.0 yöntemleri karşılaştırıldığında, RASDF yöntemi, tüm metriklerde FSDAF 2.0'dan daha başarılı olmuştur.

Çizelge 4. Üçüncü test grubuna ait doğruluk analizi sonuçları

Metrik	Bant	FSDAF 2.0	RASDF	DMNet
RMSE	Kırmızı	0.03420	0.03367	0.03850
	Yeşil	0.02282	0.02269	0.02156
	Mavi	0.02486	0.02479	0.01930
	Yakın kızılötesi	0.07318	0.07103	0.08357
	Ortalama	0.03877	0.03804	0.04073
PSNR	Kırmızı	29.3183	29.4543	28.2907
	Yeşil	32.8325	32.8847	33.3261

	Mavi	32.0905	32.1160	34.2911
	Yakın kızılötesi	22.7120	22.9712	21.5585
	Ortalama	29.2383	29.3565	29.3666
SSIM	Kırmızı	0.8951	0.9042	0.8743
	Yeşil	0.9486	0.9523	0.9380
	Mavi	0.9585	0.9611	0.9494
	Yakın kızılötesi	0.7956	0.8268	0.7727
	Ortalama	0.8994	0.9111	0.8836
UIQI	Kırmızı	0.8607	0.8647	0.8906
	Yeşil	0.9467	0.9481	0.9591
	Mavi	0.8675	0.8668	0.9319
	Yakın kızılötesi	0.9611	0.9631	0.9588
	Ortalama	0.9090	0.9107	0.9351
SAM		0.2387	0.2352	0.2552

4. SONUÇLAR

Sentinel-2 görüntülerinin zamansal çözünürlüğü ve Sentinel-3 görüntülerinin konumsal çözünürlüğü birçok yerel ölçekli uygulama için yeterli olmayabilir. Sentinel-2 ve Sentinel-3 görüntülerinin konum-zamansal kaynaştırılması ile en fazla 1.4 gün zamansal çözünürlüğe ve 10 m konumsal çözünürlüğe sahip görüntüler üretilebilmektedir. Ancak Sentinel-2 ve Sentinel-3 görüntülerinin konum-zamansal kaynaştırılması için sınırlı sayıda çalışma mevcuttur. Bu çalışmada DMNet, FSDAF 2.0 ve RASDF algoritmalarının Sentinel-2 ve Sentinel-3 görüntüleri üzerindeki konum-zamansal kaynaştırma performansı karşılaştırılmıştır. Araştırmanın sonuçları, güçlü zamansal değişim durumunda, derin öğrenme tabanlı DMNet modelinin FSDAF 2.0 ve RASDF yöntemlerinden daha iyi performans gösterdiğini göstermektedir. Öte yandan daha az zamansal değişim olması durumunda FSDAF 2.0 ve RASDF yöntemleri DMNet modeline göre daha yüksek bir başarı elde etmiştir.

5. TEŞEKKÜR

Bu çalışma, Fırat Erdem'in Doç. Dr. Uğur Avdan'ın danışmanlığında yürüttüğü doktora tezinden üretilmiştir.

KAYNAKLAR

- Boyte, S. P., Wylie, B. K., Rigge, M. B. ve Dahal, D.** 2018. Fusing MODIS with Landsat 8 data to downscale weekly normalized difference vegetation index estimates for central Great Basin rangelands, USA. *GIScience & Remote Sensing*, 55(3), 376-399.
- Britannica.**, 2022. Kansas. <https://www.britannica.com/place/Kansas> [Erişim tarihi: 18.10.2022].
- Erdem, F. ve Avdan, U.** 2022. Comparative study on spatiotemporal fusion of Sentinel-2 and Sentinel-3 images over strong temporal changes. *Journal of Applied Remote Sensing*, 16(3), 036508. <https://doi.org/10.1117/1.JRS.16.036508>.
- Gao, F., Masek, J., Schwaller, M. ve Hall, F.** 2006. On the blending of the Landsat and MODIS surface reflectance: Predicting daily Landsat surface reflectance. *IEEE Transactions on Geoscience and Remote sensing*, 44(8), 2207-2218.
- Ghamisi, P., Rasti, B., Yokoya, N., Wang, Q., Hofle, B., Bruzzone, L., Bovolo, F., Chi, M., Anders, K. Gloaguen, R., Atkinson, P. M. ve Benediktsson, J. A.** 2019. Multisource and multitemporal data fusion in remote sensing: A comprehensive review of the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 7(1), 6-39.
- Guo, D., Shi, W., Hao, M. ve Zhu, X.** 2020. FSDAF 2.0: Improving the performance of retrieving land cover changes and preserving spatial details. *Remote Sensing of Environment*, 248, 111973.
- Johnson, M. D., Hsieh, W. W., Cannon, A. J., Davidson, A. ve Bédard, F.** 2016. Crop yield forecasting on the Canadian Prairies by remotely sensed vegetation indices and machine learning methods. *Agricultural and forest meteorology*, 218, 74-84.
- Ke, Y., Im, J., Park, S. ve Gong, H.** 2016. Downscaling of MODIS One kilometer evapotranspiration using Landsat-8 data and machine learning approaches. *Remote Sensing*, 8(3), 215.

- Kingma, D. P. ve Ba, J.** 2014. Adam: A method for stochastic optimization. *arXiv*, 1412.6980.
- Lees, K., Quaife, T., Artz, R., Khomik, M. ve Clark, J.** 2018. Potential for using remote sensing to estimate carbon fluxes across northern peatlands—A review. *Science of the Total Environment*, 615, 857-874.
- Li, W., Zhang, X., Peng, Y. ve Dong, M.** 2020. DMNet: A network architecture using dilated convolution and multiscale mechanisms for spatiotemporal fusion of remote sensing images. *IEEE Sensors Journal*, 20(20), 12190-12202.
- Li, X., Zhou, Y., Asrar, G. R., Mao, J., Li, X. ve Li, W.** 2017. Response of vegetation phenology to urbanization in the conterminous United States. *Global change biology*, 23(7), 2818-2830.
- Liu, X., Deng, C., Chanussot, J., Hong, D. ve Zhao, B.** 2019. StfNet: A two-stream convolutional neural network for spatiotemporal image fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6552-6564.
- Munaro, L., Hefley, T., DeWolf, E., Haley, S., Fritz, A., Zhang, G., Haag, L. A., Schlegal, A. J., Edwards, J. T., Marburger, D., Alderman, P., Jones-Diamond, S. M., Johnson, J., Lingenfelser, J. E., Uneda-Trevisoli, S. H. Ve Lollato, R. P.** 2020. Exploring long-term variety performance trials to improve environment-specific genotype× management recommendations: A case-study for winter wheat. *Field Crops Research*, 255, 107848.
- Service, N. A.** 2017. *2017 Census of Agriculture*. Washington, DC: United States Department of Agriculture.
- Shen, H., Meng, X. ve Zhang, L.** 2016. An integrated framework for the spatio-temporal-spectral fusion of remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(12), 7135-7148.
- Shen, M., Tang, Y., Chen, J., Zhu, X. ve Zheng, Y.** 2011. Influences of temperature and precipitation before the growing season on spring phenology in grasslands of the central and eastern Qinghai-Tibetan Plateau. *Agricultural and Forest Meteorology*, 151(12), 1711-1722.
- Shi, W., Guo, D. ve Zhang, H.** 2022. A reliable and adaptive spatiotemporal data fusion method for blending multi-spatiotemporal-resolution satellite images. *Remote Sensing of Environment*, 268, 112770.
- Tan, Z., Yue, P., Di, L. ve Tang, J.** 2018. Deriving high spatiotemporal remote sensing images using deep convolutional network. *Remote Sensing*, 10(7), 1066.
- Wang, X. ve Wang, X.** 2020. Spatiotemporal fusion of remote sensing image based on deep learning. *Journal of Sensors*, 2020, 8873079.
- Wu, M., Niu, Z., Wang, C., Wu, C. ve Wang, L.** 2012. Use of MODIS and Landsat time series data to generate high-resolution temporal synthetic Landsat data using a spatial and temporal reflectance fusion model. *Journal of Applied Remote Sensing*, 6(1), 063507.
- Zhang, W., Li, A., Jin, H., Bian, J., Zhang, Z., Lei, G., Qin, Z. ve Huang, C.** 2013. An enhanced spatial and temporal data fusion model for fusing Landsat and MODIS surface reflectance to generate high temporal Landsat-like data. *Remote Sensing*, 5(10), 5346-5368.
- Zhu, X., Cai, F., Tian, J. ve Williams, T. K.-A.** 2018. Spatiotemporal fusion of multisource remote sensing data: Literature survey, taxonomy, principles, applications, and future directions. *Remote Sensing*, 10(4), 527.
- Zhu, X., Chen, J., Gao, F., Chen, X. ve Masek, J. G.** 2010. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. *Remote Sensing of Environment*, 114(11), 2610-2623.
- Zhu, X., Helmer, E. H., Gao, F., Liu, D., Chen, J. ve Lefsky, M. A.** 2016. A flexible spatiotemporal method for fusing satellite images with different resolutions. *Remote Sensing of Environment*, 172, 165-177.