

DAĞLIK BÖLGELERDE KAR ÖRTÜSÜ SINIFLANDIRMASINDA RANDOM FOREST ALGORİTMASININ DEĞERLENDİRİLMESİ

Cansu AKSU¹, Semih KUTER², Zuhale AKYÜREK³

¹ Orta Doğu Teknik Üniversitesi, Jeodezi ve Coğrafi Bilgi Teknolojileri, 06800, Ankara, cansu.aksu@metu.edu.tr

² Dr. Öğr. Üyesi, Çankırı Karatekin Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü, Çankırı, semihkuter@karatekin.edu.tr

³ Prof. Dr., Orta Doğu Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 06800, Ankara, zakyurek@metu.edu.tr

ÖZET

Kar örtüsü, çoğu ülke için yıl boyunca kullanılabilir su miktarını kabaca belirler. İklim değişikliğinin yanı sıra içme ve sanayi suyunun talebin sürekli artmasına sebep olan küresel nüfus artışı, kar örtüsünü izlemeyi geçmişte olduğundan daha önemli hale getirmektedir. Günümüzde kar örtüsünü gözlemlemek için, yersel ölçüm tekniklerinin yanı sıra, kar sınıflandırması için uzaktan algılama verileri üzerinde farklı makine öğrenme algoritmaları kullanılmaktadır. Bu çalışmanın amacı, seçilen üç dağlık bölgede (Alpler, Tatra Dağları ve Kaçkar Dağları) Sentinel-2 görüntüleri üzerinde kar örtüsü sınıflandırması için Random Forest algoritmasının bağımsız değişkenlerin farklı girdi kombinasyonları ile performansını değerlendirmektir. Girdi kombinasyonları, daha iyi bir değerlendirme için kar örtüsünün farklı morfolojik yapısını göz önünde bulunduracak şekilde yılın üç farklı zamanından alınmıştır: i) kar örtüsünün oluşmaya başladığı zaman (Kasım-Aralık), ii) kar örtüsünün bütünüyle oluşmuş olarak gözlemlendiği zaman (Ocak-Mart), ve iii) karın erimeye başladığı zaman (Nisan- Haziran). Değerlendirme sonuçları için hata matrisleri ile genel doğruluk (GD) ve Kappa katsayısı kullanılmıştır. En iyi sonuçlar, herhangi bir düzeltme yapılmayan atmosfer üstü refleksans değerlerini veren bantlar ile normalleştirilmiş fark kar (NDSI), normalleştirilmiş fark bitki örtüsü (NDVI) ve normalleştirilmiş fark su (NDWI) indislerini içeren değişkenlerin oluşturduğu kombinasyon (Sc_only) ile %94 GD, %89 Kappa katsayısı ile Alp Bölgesi'nde elde edilmesine rağmen, genel olarak, temel bileşenler kombinasyonunun en doğru, sayısal yükseklik modeli ve buradan elde edilen yükseklik değişkeninin oluşturduğu kombinasyonunun ise en kötü sonuçları verdiği gözlemlenmiştir. Temel bileşenler yönteminin ayrıca, temel bileşenleri elde etme süreci hariç, tüm kombinasyonlar arasında en kısa hesaplama süresine sahip olduğu gözlemlenmiştir. Bu kombinasyon aynı zamanda Random Forest modelinde diğer kombinasyonlara kıyasla en az miktarda girdi değişkenine sahiptir. Elde edilen bu sonuçlar, Random Forest metodunun dağlık bölgeler üzerinde kar sınıflandırması söz konusu olduğunda, NDSI, NDVI ve NDWI ile uygun sayıda temel bileşen girdisi ile en iyi sonucu verdiğini göstermektedir.

Anahtar Sözcükler: Sentinel-2, karın uzaktan algılanması, sınıflandırma, makine öğrenmesi, kar hidrolojisi

ABSTRACT

ASSESSMENT OF RANDOM FOREST METHOD IN PIXEL-BASED SNOW COVER CLASSIFICATION OVER MOUNTAINOUS REGIONS

The snow cover determines the amount of usable water throughout the year for most countries. An ever-increasing global population that grows the demand on drinking and industrial water, as well as climate change, makes monitoring of snow cover even more crucial than it was in the past. Today, to observe the amount of snow cover, different machine learning algorithms are being used on remote sensing data for classification of snow, aside from in-situ data collection techniques. The aim of this study is to assess the performance of Random Forest algorithm for snow cover classification on Sentinel-2 imagery on three selected mountainous regions: Alpine Region, Tatra Mountains, and Kaçkar Mountains, with different input combinations as independent variables (predictors). The combinations have been evaluated for three different times of the year by considering different morphological stages of snow for a much better assessment: i) the time that snow cover starts to form (November to December), ii) the time that snow cover is fully formed (January to March), and iii) the time when snow starts to melt (April to June). The error matrices, overall accuracy and Kappa coefficient were used for accuracy assessment. Although the best results were achieved with the model input combination composed of Sentinel-2 bands without atmospheric and topographic correction together with the following normalized band indices: Normalized Difference Snow Index (NDSI), Normalized Difference Vegetation Index (NDVI) and Normalized Difference Water Index (NDWI) in Alpine Region, principle component bands combination yielded the most accurate results, and digital elevation and its derivatives (i.e., slope and aspect) combination produced the worst results in general. Principle components method also gave the shortest computation time out of all combinations, excluding the process of obtaining principal components, as the combination has the least amount of inputs to the Random Forest model, as compared to the other combinations. The overall results indicated that Random Forest works best with an appropriate number of principal component inputs together with NDSI, NDVI and NDWI in snow cover classification over rough and complex mountainous regions.

Keywords: Sentinel-2, remote sensing of snow, classification, machine learning, snow hydrology

1. GİRİŞ

Kar örtüsü, uzaktan algılama teknikleri ile, yaklaşık 60 yıldır gözlemlenebilmektedir (Akyürek ve Şorman, 2002; Tekeli vd., 2005). Kar örtüsünün algılanması için birçok farklı uydu kullanılmaktadır. Avrupa Uzay Ajansı'nın (ESA – European Space Agency) Copernicus programının geliştirdiği, multispektral Sentinel-2 uydusu bu araçlardan biri olup Haziran 2015'te veri sunmaya başlamıştır (Phiri vd., 2020). Hem zamansal ve mekânsal çözünürlük açısından, hem de veriye ulaşılabilirlik açısından oldukça avantajlı bir uzaktan algılama veri kaynağıdır.

Kar örtüsünün uzaktan algılama yardımı ile sınıflandırılmasında birçok farklı yöntem kullanılmaktadır. NDSI (Hall vd., 2011), spektral karışım analizi (Painter vd., 1998; Hao vd., 2019) ve eşikleme yöntemlerinden (Luo vd., 2008) sıklıkla faydalanılmaktadır. Bir diğer sıkça kullanılan metot makine öğrenmesi algoritmaları olup, kar örtüsü için diğer yöntemlerden daha iyi yüksek sınıflandırma doğruluğu sağladığı çeşitli çalışmalarda vurgulanmıştır (Hou vd., 2020; Liu vd., 2020; Hou vd., 2021; Baba vd., 2020; Tsai vd., 2019).


Dağlık bölgelerde, kar kaplı alanların optik uydu verisinden sınıflandırılmasında kompleks topoğrafya, gölge, bulut ve bulut gölgesi, karmaşık hücre problemi gibi problemler halen çözülmesi gereken problemler olarak karşımıza çıkmaktadır. Bu problemlerin giderilmesi amacıyla, bu çalışmada, Random Forest (RF) Sentinel-2 görüntüleri 6 farklı kombinasyonda model girdi verisi oluşturacak şekilde biçimlendirilmiştir. Bu çalışma ile, kar örtüsü sınıflandırılmasında en sık karşılaşılan sorunların çözülmesini sağlayacak bir girdi kombinasyonunun oluşturulması amaçlanmıştır.

1.1 Test Alanları ve Kullanılan Yöntemler

Bu çalışmada üç farklı dağlık alandan seçilmiş test bölgelerinden, üç farklı periyotta alınan Sentinel-2 görüntüleri kullanılmıştır. Bu dağlık alanlar; Alp Bölgesi, Tatra Dağları ve Kaçkar Dağları olarak belirlenmiştir. Bu çalışmada kullanılan dokuz adet Sentinel-2 görüntüsüne ait temel bilgiler **Çizelge 1**'de verilmekte olup, karoların lokasyonları **Şekil 1**'de gösterilmektedir.

Çizelge 1. Çalışmada kullanılan Sentinel-2 görüntülerinin yerleri, karo numaraları ve gözlem tarihleri.


Yer	Karo numarası	Görüntü tarihi
Alp Bölgesi	T32TPS	05.12.2018
		24.01.2019
		13.06.2019
Tatra Dağları	T34UCV	29.11.2018
		23.01.2020
		08.04.2019
Kaçkar Dağları	T37TFE	19.12.2019
		19.03.2018
		08.04.2018



Şekil 1. Sentinel 2 karolarının lokasyonları

Bu üç dağlık alan, farklı iklim koşulları; ortalama sıcaklık, yağış, kar derinliklerinde ve farklı arazi örtüsüne sahip olduğu için RF algoritmasını test etmek adına belirlenmiştir.

9 adet Sentinel-2 karosundan, **Şekil 2**'de gösterildiği gibi $20 \times 20 \text{ km}^2$ 'lik kesitler alınmış olup, **Çizelge 2**'deki dört girdi kombinasyonu ile RF algoritması kullanılarak sınıflandırma yapılmış ve dört adet sınıf elde edilmiştir: Bulut, Yer (Kar Olmayan), Kar, Su, Eğitim alanları Sen2COR işlemi yapılan görüntülerden görsel kontrol yapılarak belirlenmiştir. Oluşturulan kombinasyonlar (Bkz. **Çizelge 2**), 1) herhangi bir düzeltme yapılmayan atmosfer üstü reflektans değerlerini veren bantlar ile NDSI, NDVI ve NDWI değişkenlerinin oluşturduğu kombinasyon (sc_only); 2) atmosferik ve topografik düzeltme yapılan bantlar ile NDSI, NDVI ve NDWI değişkenlerinin oluşturduğu kombinasyon (atmo_topo); 3) sayısal yükseklik verisinden elde edilen yükseklik, eğim ve bakı değişkenleri ile atmosferik ve topografik düzeltme yapılan bantların ve NDSI, NDVI ve NDWI değişkenlerinin oluşturduğu kombinasyon (dem); ve 4) atmosferik ve topografik düzeltme yapılan bantlardan elde edilen ilk üç temel bileşen ile NDSI, NDVI ve NDWI değişkenlerinin oluşturduğu kombinasyon (pca) olarak belirlenmiştir. Doğruluk analizinde en iyi ve en kötü sonuç veren görüntüler, **Çizelge 3**'teki girdi kombinasyonları ile sınıflandırılmıştır; bu kombinasyonlar, temel bileşenler, NDSI, NDVI ve NDWI değişkenleri ile sayısal yükseklik verisinden elde edilen eğim ve bakı verilerinin oluşturduğu kombinasyon (pca_plus) ve *pca_plus*'a ek olarak yükseklik verisini de içeren kombinasyondur (pca_plus2). **Çizelge 3**'teki girdi kombinasyonları kullanılarak yapılan sınıflandırmaların doğruluk analizi ile **Çizelge 2**'deki girdi kombinasyonu ile sınıflandırılan görüntülerin doğruluk analizi sonuçları karşılaştırılıp, elde edilen en iyi sonuçlara ait girdi kombinasyonu, Sentinel-2 karolarının tamamına ($100 \times 100 \text{ km}^2$ 'lik alanlar) uygulanmıştır.



Şekil 2. Kullanılan Sentinel-2 karoları ve altı farklı girdi kombinasyonunun Random Forest sınıflandırma algoritması ile test edildiği, seçilen $20 \times 20 \text{ km}^2$ 'lik kesitler (bant kombinasyonu: Bant 3, Bant 8a ve Bant 11)

Çizelge 2. RF sınıflandırmasında kullanılan model girdi değişkenlerine ait kombinasyonlar.

Girdi kombinasyonu ismi	Girdi kombinasyonu içeriği
sc_only	Atmosfer üstü Bant 2-7, Bant 8a, Bant 11, Bant 12 reflektansları, NDSI, NDVI, NDWI
atmo_topo	Atmosferik/topografik düzeltme uygulanan Bant 2-7, Bant 8a, Bant 11, Bant 12 reflektansları, NDSI, NDVI, NDWI
dem	Atmosferik/topografik düzeltme uygulanan Bant 2-7, Bant 8a, Bant 11, Bant 12 reflektansları, NDSI, NDVI, NDWI, yükseklik, eğim, bakı
pca	İlk üç temel bileşen (Atmosferik/topografik düzeltme uygulanan Bant 2-7, Bant 8a, Bant 11 ve Bant 12 reflektansları kullanılarak elde edilmiş), NDSI, NDVI, NDWI

Çizelge 3. Sınıflandırmada en iyi ve en kötü sonuçları veren model girdi kombinasyonları.

Girdi kombinasyonu ismi	Girdi kombinasyonu içeriği
pca_plus	İlk üç temel bileşen (Atmosferik/topografik düzeltme uygulanan Bant 2-7, Bant 8a, Bant 11 ve Bant 12 reflektansları kullanılarak elde edilmiş), NDSI, NDVI, NDWI, eğim, bakı
pca_plus2	İlk üç temel bileşen (Atmosferik/topografik düzeltme uygulanan Bant 2-7, Bant 8a, Bant 11 ve Bant 12 reflektansları kullanılarak elde edilmiş), NDSI, NDVI, NDWI, yükseklik verisi, eğim, bakı

Bu çalışmada, farklı girdi kombinasyonlarının yanı sıra, her sınıf için 300 adet ve 1000 adet eğitim verisinin olduğu durumlar tüm kombinasyonlar için değerlendirilmiştir.

Doğruluk analizi sonuçları, rastgele elde edilen test verileri ve çok terimli dağılım formülü (*multinomial distribution formula*) (Ozdarici Ok ve Akyurek, 2012; Jensen, 2006) ile yapılmıştır. Çok terimli dağılım formülü (1)'de verilmiştir.


$$N = \frac{B! \prod_i (1 - \pi_i)}{b_i^2} \quad (1)$$

Formüldeki (1) N, numune veri sayısının büyüklüğüne, i, k tane sınıftan verisi toplamın %50'sine en yakın olan sınıf, b istenen presesyonu, B, bir serbestlik dereceli dağılımın (güven seviyesi) chi-kare (χ^2) üst (α/k) $\times 100$. yüzdelik dilimini, k ise sınıf sayısını ifade eder (Ozdarici Ok ve Akyurek, 2012).

2. ANALİZLER


Bu çalışmada doğruluk analizi, sınıflandırılan görüntülerin hata matrisleri ve bu matrislerden elde edilen GD değerleri ile Kappa katsayıları kullanılarak yapılmıştır. Hata matrisleri, daha çok sınıflandırmada elde edilen dört adet sınıfın birbirleri ile karıştığı durumların tespiti için kullanılmıştır. GD değerleri ve Kappa katsayıları ise, girdi kombinasyonları arasından en yüksek sınıflandırma doğruluğunu verenlerin değerlendirilmesi amacı ile sınıflandırılmış görüntülerden hesaplanmıştır.

Şekil 3'te, çalışmada kullanılan 9 adet Sentinel-2 görüntülerinden bir örnek, hem $20 \times 20 \text{ km}^2$ 'lik kesitlerinin hem de karoların tamamının ($100 \times 100 \text{ km}^2$ 'lik alanlar) sınıflandırılmış olarak verilmiştir. “_1000” ibaresi, her sınıf için 1000 adet eğitim verisi, “_300” ise her sınıf için 300 adet eğitim verisinin model girdisi olarak kullanıldığına işaret etmektedir.



Şekil 3. Sınıflandırılan Sentinel-2 görüntüleri (Kaçkar Dağları, 19 Aralık 2019) (sahte RGB görüntülerdeki Sentinel 2 bant kombinasyonu sırasıyla Bant 3, Bant 8a ve Bant 11)


Sınıflandırılmış $20 \times 20 \text{ km}^2$ 'lik kesitlerin hata matrislerinden bir örnek (Alp Bölgesi'ne ait 24 Ocak 2019 tarihli kesit) **Şekil 4**'te incelenebilmektedir. Tüm sınıflandırılmış kesitlerin GD değerleri ve Kappa katsayıları **Çizelge 4**'te verilmiştir.



Şekil 4. Alp Bölgesi'ne ait karışıklık matrisleri (24 Ocak 2019) (cloud:bulut, snow: kar, land: yer (kar olmayan), water:su)

Çizelge 4. Sınıflandırılmış kesitlerin GD değerleri ve Kappa katsayıları														
Lokasyon	Tarih	Katsayı	Atmo_Topo_1000	Atmo_Topo_300	SC_1000	SC_300	DEM_1000	DEM_300	PCA_1000	PCA_300	PCA_PLUS_1000	PCA_PLUS_300	PCA_PLUS2_1000	PCA_PLUS2_300
Alp Bölgesi	5 Aralık 2018	GD	0.93	0.90	0.94	0.94	0.86	0.84	0.90	0.90	-	-	-	-
		Kappa	0.87	0.83	0.89	0.89	0.75	0.70	0.83	0.83	-	-	-	-
	24 Ocak 2019	GD	0.81	0.80	0.78	0.79	0.80	0.80	0.79	0.78	-	-	-	-
		Kappa	0.70	0.69	0.65	0.66	0.70	0.70	0.68	0.67	-	-	-	-
	13 Haziran 2019	GD	0.82	0.83	0.82	0.82	0.82	0.82	0.84	0.84	-	-	-	-
		Kappa	0.72	0.73	0.72	0.73	0.72	0.72	0.76	0.75	-	-	-	-
Tatra Dağları	29 Kasım 2018	GD	0.74	0.69	0.73	0.75	0.74	0.74	0.78	0.78	-	-	-	-
		Kappa	0.66	0.59	0.64	0.66	0.65	0.66	0.71	0.70	-	-	-	-
	23 Ocak 2020	GD	0.80	0.79	0.77	0.78	0.73	0.72	0.71	0.72	0.75	0.77	0.76	0.74
		GD	0.72	0.70	0.67	0.69	0.63	0.62	0.59	0.60	0.64	0.67	0.67	0.63
	8 Nisan 2019	GD	0.91	0.91	0.90	0.91	0.92	0.91	0.93	0.92	0.92	0.88	0.93	0.89
		Kappa	0.83	0.83	0.82	0.85	0.85	0.84	0.87	0.86	0.86	0.79	0.88	0.80
Kaçkar Dağları	19 Aralık 2019	GD	0.79	0.78	0.87	0.81	0.77	0.66	0.78	0.70	-	-	-	-
		Kappa	0.68	0.67	0.80	0.71	0.66	0.50	0.66	0.54	-	-	-	-
	19 Mart 2019	GD	0.84	0.84	0.83	0.84	0.83	0.81	0.84	0.81	-	-	-	-
		Kappa	0.70	0.69	0.66	0.70	0.67	0.62	0.69	0.64	-	-	-	-
	8 Nisan 2018	GD	0.75	0.75	0.72	0.74	0.75	0.74	0.75	0.77	-	-	-	-
		Kappa	0.64	0.63	0.60	0.62	0.64	0.62	0.64	0.68	-	-	-	-

Çizelge 2 ile **Çizelge 3**'teki girdi kombinasyonları ile sınıflandırılan kesitlerin doğruluk analizi neticesinde, genel anlamda en iyi sonuçları veren kombinasyon *pca* olarak değerlendirilmiştir. Bu nedenle, *pca* girdi kombinasyonu, Sentinel-2 karolarının tamamına ($100 \times 100 \text{ km}^2$ 'lik alanlar) uygulanmıştır. Karoların tamamına uygulanan sınıflandırmanın sonucunda elde edilen GD değerleri ve Kappa katsayıları **Şekil 6**'da gösterilmiştir.



Şekil 6. Sınıflandırılan Sentinel-2 karolarının GD değerleri ve Kappa katsayıları (*pca*)

3. SONUÇLAR VE TARTIŞMA

Bu bildiride, üç farklı dağlık bölgede, kar sezonunun üç farklı zaman diliminde ve 6 farklı girdi kombinasyonu ile, RF algoritmasının kar örtüsü sınıflandırmasının sonuçları sunulmaktadır. Bu sonuçlara göre, atmosferik ve topografik olarak düzeltilmiş Sentinel-2 bantlarından elde edilen temel bileşenler ile NDSI, NDVI ve NDWI (*pca* girdi kombinasyonu), diğer girdi kombinasyonlarına kıyasla hem doğruluk analizi açısından hem de kar örtüsü sınıflandırmada sıkça karşılaşılan sorunlardan birçoğunu çözmede başarılı olmuştur. Kar sezonu dikkate alındığında Alp Bölgesi'nde seçilen 3 farklı dönem için de sınıflandırma başarısı yüksektir ve farklılık göstermemektedir. Alp Bölgesinden seçilen alanın ortalama yüksekliği 1750 m'dir ve bu bölgedeki kar kalıcıdır. Tatra ve Kaçkar Dağlarından seçilen çalışma alanlarının ortalama yükseklikleri 690 m ve 2100 m'dir. Bu iki çalışma alanında kar, sezon içinde eriyip yeniden görülebilmektedir.

Eğitim veri seti büyüklüğünün, doğruluk analizi sonuçlarına etki ettiği gözlemlenmiştir. 1000 adet eğitim verisinin genel olarak tüm girdi kombinasyonları için 300 adet eğitim veri setinden çok daha iyi GD değerleri ve Kappa katsayıları elde ettiği belirlenmiştir. Bunun sebebi, RF algoritmasının, diğer makine öğrenmesi yöntemlerine kıyasla, eğitim veri seti büyüklüğüne daha duyarlı olmasıdır (Li vd.; 2014).

Sınıflar arasındaki karışıklıklar, genel olarak Kar – Yer (kar olmayan), Bulut – Yer (kar olmayan) ve Su -Yer (Kar olmayan) arasında ortaya çıkmıştır. Bulutun kar dışındaki diğer arazi örtüleri ile karışmasının sebebinin, her ne kadar RF algoritması bulutları diğer arazi örtülerinden ayırt etmekte diğer yöntemlerden daha başarılı olsa da, bulutun dokusunun dikkate alındığı bir metotla çok daha iyi sınıflandırma yapılabileceği düşünülmektedir (Ghasemian ve Akhoondzadeh; 2018). Su ve kar olmayan diğer arazi örtülerinin karışmasının sebebinin, her üç bölgedeki kompleks topografik yapı sebebiyle gölgelerin oluşması olarak belirlenmiştir (Ko vd., 2015). Her iki karışıklığı, *pca* girdi kombinasyonunun oldukça azalttığı gözlemlenmiştir.

Diğer arazi örtülerinin kar yerine sınıflandırılmasının sebebinin, özellikle Alp Bölgesi ve Tatra Dağları'nda büyük bir alanı kaplayan ağaçlık ve orman alanları sebebiyle olduğu belirlenmiştir. Sınıflandırma sırasında, ağaçlık alanlar kar örtüsü boyutunu olduğundan daha az gösterebilir (Luo vd., 2022; Robinson vd., 1993; Bitner vd., 2002). Bunun yol açtığı bir başka durum, sadece Kaçkar Dağları'ndaki doğruluk analizi sonuçlarından en yüksek değerlerin gözlemlenebildiği zamanın kar örtüsünün bütünüyle oluşmuş olarak gözlemlendiği periyot olmasıdır. Alp Bölgesi'nde en iyi sonuçların kar sezonu başlangıcında, Tatra Dağları'nda ise sezonun sonunda olduğu belirlenmiştir. Kar örtüsü sınıflandırma konusundaki genel beklenti ise, doğruluk analizi yapıldığında, kar örtüsünün bütünüyle oluşmuş olarak gözlemlendiği zamanda daha iyi sonuçlar gözlemlenebiliyor olmasıdır (Romanov vd., 2002; Parajka ve Blöschl, 2006). *pca* girdi kombinasyonunun, her ne kadar diğer girdi kombinasyonlarından daha çok bu problemi azalttığı gözlemlense de, bu sorunu çözmek için tam olarak yeterli olmadığı anlaşılmıştır. Bu sorunun çözümü için, RF algoritmasının yanında, bazı çalışmaların da önerdiği üzere, başka bir metodun da kullanılması gerektiği

belirlenmiştir. Bu metotlardan bazıları, doğrusal karışım (linear mixture - LM) ve doğrusal olmayan karışım (nonlinear mixture - NLM) analizi (Painter vd., 2003; Rosenthal ve Dozier, 1996), ve uç eleman tespiti (endmember extraction) (Hao et al., 2019) olarak sıralanabilir. Kuter vd. (2018) tarafından bu problemin çözümü için önerilen bir teknik olan *Çok Değişkenli Uyarlanabilir Regresyon Eğrileri* (Multivariate Adaptive Regression Splines - MARS), yaprak dökmeyen ormanlık alanlar dışındaki ağaçlık alanlarda kar örtüsü sınıflandırması için güzel sonuç vermektedir. Yaprak dökmeyen ağaçlık alanlar içinse, Wang vd. (2015) normalleştirilmiş fark orman kar indisini (NDSFI) önermiş olup, kar örtüsü sınıflandırması için NDSI ve NDSFI'yi beraber kullandığı bir yaklaşım geliştirmiştir.

Optik sensörler ile kar örtüsünün algınmasında en problemli konulardan biri (aslında bir problemten ziyade teknik bir sınırlama olarak da kabul edilebilir), yoğun orman meşcerelerinin yerdeki kar örtüsünü, optik sensörlerin görüş alanından gizlemesidir. İleride yapılması düşünülen çalışmalarda bu sorunun çözümüne yönelik olarak, LM, NLM, veya MARS yöntemlerinin NDSFI ile NDSI'nin temel bileşen bantlarıyla beraber kullanıldığı bir girdi kombinasyonu ile kullanılması da düşünülmektedir.

KAYNAKLAR

- Akyürek, Z., & Şorman, Ü. (2002). Monitoring snow-covered areas using NOAA-AVHRR data in the eastern part of Turkey. *Hydrological Sciences Journal*, 47, 243–252. <https://doi.org/10.1080/02626660209492927>
- Baba, M. W., Gascoin, S., Hagolle, O., Bourgeois, E., Desjardins, C., & Dedieu, G. (2020). Evaluation of Methods for Mapping the Snow Cover Area at High Spatio-Temporal Resolution with VENµS. *Remote Sensing*, 12, 3058. <https://doi.org/10.3390/rs12183058>
- Bitner, D., Carroll, T., Cline, D. and Romanov, P. (2002), An assessment of the differences between three satellite snow cover mapping techniques. *Hydrol. Process.*, 16: 3723-3733. <https://doi.org/10.1002/hyp.1231>
- Ghasemian, N., & Akhoondzadeh, M. (2018). Introducing two Random Forest based methods for cloud detection in remote sensing images. *Advances in Space Research*, 62(2), 288–303. <https://doi.org/10.1016/j.asr.2018.04.030>
- Hall, D.K., Riggs, G.A. (2011). Normalized-Difference Snow Index (NDSI). In V.P. Singh, P. Singh, & U.K. Haritashya (Eds.), *Encyclopedia of Snow, Ice and Glaciers* (pp. 779-780). Dordrecht: Springer Netherlands.
- Hao, S., Jiang, L., Shi, J., Wang, G., & Liu, X. (2019). Assessment of MODIS-Based Fractional Snow Cover Products Over the Tibetan Plateau. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(2), 533–548. <https://doi.org/10.1109/JSTARS.2018.2879666>
- Hou, J., Huang, C., Chen, W., & Zhang, Y. (2021). Improving Snow Estimates Through Assimilation of MODIS Fractional Snow Cover Data Using Machine Learning Algorithms and the Common Land Model. *Water Resources Research*, 57(7), e2020WR029010. <https://doi.org/https://doi.org/10.1029/2020WR029010>
- Hou, J., Huang, C., Zhang, Y., & Guo, J. (2020). On the Value of Available MODIS and Landsat8 OLI Image Pairs for MODIS Fractional Snow Cover Mapping Based on an Artificial Neural Network. *IEEE Transactions on Geoscience and Remote Sensing*, 58(6), 4319–4334. <https://doi.org/10.1109/TGRS.2019.2963075>
- Jensen, J. R. (2006). *Introductory digital image processing: A remote sensing perspective*. Prentice-Hall.
- Ko, B. C., Kim, H. H., & Nam, J. Y. (2015). Classification of Potential Water Bodies Using Landsat 8 OLI and a Combination of Two Boosted Random Forest Classifiers. *Sensors*, 15(6), 13763–13777. <https://doi.org/10.3390/s150613763>
- Kuter, S., Akyurek, Z., & Weber, G. W. (2018). Retrieval of fractional snow covered area from MODIS data by multivariate adaptive regression splines. *Remote Sensing of Environment*, 205, 236–252. <https://doi.org/10.1016/J.RSE.2017.11.021>
- Li, C., Wang, J., Wang, L., Hu, L., & Gong, P. (2014). Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery. *Remote Sensing*, 6(2), 964–983. <https://doi.org/10.3390/rs6020964>
- Liu, Y., Chen, X., Hao, J.-S., & Li, L. (2020). Snow cover estimation from MODIS and Sentinel-1 SAR data using machine learning algorithms in the western part of the Tianshan Mountains. *Journal of Mountain Science*, 17(4), 884–897. <https://doi.org/10.1007/s11629-019-5723-1>

- Luo, J., Dong, C., Lin, K., Chen, X., Zhao, L., & Menzel, L.** (2022). Mapping snow cover in forests using optical remote sensing, machine learning and time-lapse photography. *Remote Sensing of Environment*, 275, 113017. <https://doi.org/10.1016/j.rse.2022.113017>
- Luo, Y., Trishchenko, A., & Khlopenkov, K.** (2008). Developing clear-sky, cloud and cloud shadow mask for producing clear-sky composites at 250-meter spatial resolution for the seven MODIS land bands over Canada and North America. *Remote Sensing of Environment - REMOTE SENS ENVIRON*, 112, 4167–4185. <https://doi.org/10.1016/j.rse.2008.06.010>
- Ozdarici Ok, A., & Akyurek, Z.** (2012). A segment-based approach to classify agricultural lands by using multi-temporal optical and Microwave Data. *International Journal of Remote Sensing*, 33(22), 7184–7204. <https://doi.org/10.1080/01431161.2012.700423>
- Painter, T. H., Dozier, J., Roberts, D. A., Davis, R. E., & Green, R. O.** (2003). Retrieval of subpixel snow-covered area and grain size from imaging spectrometer data. *Remote Sensing of Environment*, 85(1), 64–77. [https://doi.org/10.1016/S0034-4257\(02\)00187-6](https://doi.org/10.1016/S0034-4257(02)00187-6)
- Painter, T. H., Roberts, D. A., Green, R. O., & Dozier, J.** (1998). The Effect of Grain Size on Spectral Mixture Analysis of Snow-Covered Area from AVIRIS Data. *Remote Sensing of Environment*, 65(3), 320–332. [https://doi.org/https://doi.org/10.1016/S0034-4257\(98\)00041-8](https://doi.org/https://doi.org/10.1016/S0034-4257(98)00041-8)
- Parajka, J. & Blöschl, G.** (2006). Validation of MODIS snow cover images over Austria, *Hydrol. Earth Syst. Sci.*, 10, 679–689, <https://doi.org/10.5194/hess-10-679-2006>, 2006.
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M.** (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14). <https://doi.org/10.3390/rs12142291>
- Robinson, D. A., Dewey, K. F., & Heim, R. R.** (1993). Global snow cover monitoring: an update. *Bulletin - American Meteorological Society*, 74(9), 1689–1696. [https://doi.org/10.1175/1520-0477\(1993\)074<1689:GSCMAU>2.0.CO;2](https://doi.org/10.1175/1520-0477(1993)074<1689:GSCMAU>2.0.CO;2)
- Romanov, P., Gutman, G., & Csiszar, I.** (2002). Satellite-derived snow cover maps for north America: Accuracy assessment. *Advances in Space Research*, 30(11), 2455–2460. [https://doi.org/10.1016/S0273-1177\(02\)80304-0](https://doi.org/10.1016/S0273-1177(02)80304-0)
- Rosenthal, W., & Dozier, J.** (1996). Automated Mapping of Montane Snow Cover at Subpixel Resolution from the Landsat Thematic Mapper. *Water Resources Research*, 32(1), 115–130. <https://doi.org/https://doi.org/10.1029/95WR02718>
- Tekeli, A., Akyürek, Z., Sorman, A., Sensoy, A., & Şorman, Ü.** (2005). Using MODIS snow cover maps in modeling snowmelt runoff process in the Eastern part of Turkey. *Remote Sensing of Environment*, 97, 216–230. <https://doi.org/10.1016/j.rse.2005.03.013>
- Tsai, Y.-L. S., Dietz, A., Oppelt, N., & Kuenzer, C.** (2019). Wet and Dry Snow Detection Using Sentinel-1 SAR Data for Mountainous Areas with a Machine Learning Technique. *Remote Sensing*, 11(8). <https://doi.org/10.3390/rs11080895>
- Wang, Y., Su, J., Zhai, X., Meng, F., & Liu, C.** (2022). Snow Coverage Mapping by Learning from Sentinel-2 Satellite Multispectral Images via Machine Learning Algorithms. *Remote Sensing*, 14(3). <https://doi.org/10.3390/rs14030782>
- Wang, X.-Y., Wang, J., Jiang, Z.-Y., Li, H.-Y., & Hao, X.-H.** (2015). An Effective Method for Snow-Cover Mapping of Dense Coniferous Forests in the Upper Heihe River Basin Using Landsat Operational Land Imager Data. *Remote Sensing*, 7(12), 17246–17257. <https://doi.org/10.3390/rs71215882>