

DESTEK VEKTÖR MAKİNELERİNDE KODLAMA TASARIMININ SINIFLANDIRMA PERFORMANSINA ETKİSİ: HİPERSPEKTRAL GÖRÜNTÜLER İLE UYGULAMA

Sena URFALI¹, Ümit Haluk ATASEVER²,

¹Sena URFALI, Erciyes Üniversitesi, Harita Mühendisliği A.B.D, Kayseri, senaahi97@gmail.com

²Doç. Dr. Ümit Haluk ATASEVER, Erciyes Üniversitesi, Harita Mühendisliği Bölümü, Kayseri, uhatasever@erciyes.edu.tr

ÖZET

Uzaktan algılama teknolojilerindeki baş döndürücü gelişmeler, haritacılık, ziraat, çevresel uygulamalar, madencilik gibi gözlem gerektiren birçok bilim dalında görece daha kapsamlı çalışmalar yapılabilmesinin önünü açmıştır. Geçmişte Sputnik 1 uydusu ile başlayan yeryüzü gözlem misyonu günümüzde, multispektral, Sentetik Açıklıklı Radar ve hiperspektral algılayıcılar ile devam etmektedir. Hiperspektral görüntüler, spektral çözünürlüklerinin multispektral görüntülere göre oldukça yüksek olması nedeniyle nesnelerin yansım karakterlerini daha hassas biçimde tanımlayabilmektedir. Hiperspektral görüntülerin sahip olduğu bu kabiliyet, arazi kullanımının görece daha başarılı sınıflandırılabilmesi için olanak sağlamaktadır. Ancak yüksek band sayısına sahip hiperspektral görüntülerin yüksek başarıyla sınıflandırılabilmesi için hem uygun sınıflandırma tekniğini seçmek hem de doğru parametre ayarı yapabilmek önemli bir aşamadır. Detaylı bir literatür çalışması yapıldığında, Destek Vektör Makineleri tekniğinin hem multispektral hem de hiperspektral görüntülerin sınıflandırılmasında en çok tercih edilen yöntemlerden olduğu anlaşılmaktadır. DVM tekniğinin performansı kontrol parametrelerine göre değişkenlik gösterebilmektedir. Penaltı parametresi, çekirdek fonksiyonu, çekirdek ölçeği ve kodlama tasarımı en önemli kontrol parametreleridir. Temelde ikili sınıflandırma için geliştirilen DVM, kodlama tasarımları sayesinde çok sınıflı karmaşık problemlerde de kullanılabilir hale gelmiştir. Bire-Karşı-Bir (onevsone), Bire-Karşı-Hepsi(onevsall) en çok bilinen kodlama yaklaşımlarına ek olarak Seyrek Rastgele (sparserandom), Sıralı (ordinal) ve İkili Tamamlama (binarycomplete) yaklaşımları da kullanılmaktadır. Bu çalışmada kodlama tasarımlarının etkileri deneysel olarak incelenmiştir. Bu amaçla temel karşılaştırma veri setlerinden biri olarak tercih edilen Salinas-A verisi kullanılmıştır. Kodlama tasarımlarını objektif değerlendirebilmesi için, sırasıyla tüm kodlama parametreleri diğer temel DVM kontrol parametreleri sabit tutularak elde ettikleri performans değerleri incelenmiştir. Kutu kısıtlama (penaltı) parametresi için 1, 5, 10 ve 50 değerleri; çekirdek fonksiyonları için 'Linear' ve 'Gaussian' fonksiyonları kullanılarak uygulamalar Matlab dilinde yazılan kod ile tamamlanmıştır. Ayrıca bu çalışmada, klasik kıyaslama işlemlerinden farklı olarak görüntünün tamamına kıyaslama metrikleri (Genel doğruluk, Kappa katsayısı, F-skoru) uygulanmıştır. Gerçekleştirilen simülasyonun sonunda Bire-Karşı-Bir (onevsone) kodlama tasarımının Kutu Kısıtlama parametresinin 50; Kernel fonksiyonun 'Linear' olması halinde en yüksek genel doğruluk ve kappa katsayısı değerlerini elde ettiği görülmüştür.

Anahtar Sözcükler: DVM, Hiperspektral Görüntü, Kodlama Tasarımı

ABSTRACT

EFFECT OF CODING DESIGN ON CLASSIFICATION PERFORMANCE ON SUPPORT VECTOR MACHINES: APPLICATION WITH HYPERSPECTRAL IMAGES

The astonishing developments in remote sensing technologies have paved the way for relatively more comprehensive studies in many branches of science that require monitoring, such as cartography, agriculture, environmental applications, and mining. The earth observation mission, which started with the Sputnik 1 satellite in the past, continues today with multispectral, synthetic aperture radar and hyperspectral sensors. Hyperspectral images can define the reflectance characteristics of objects more precisely because their spectral resolution is much higher than multispectral images. This capability of hyperspectral images allows for a relatively successful classification of land use/cover. However, in order to classify hyperspectral images with high band numbers with high success, it is important to choose the appropriate classification technique and to set the correct parameters. When a detailed literature study is made, it is understood that the Support Vector Machines technique is one of the most preferred methods for the classification of both multispectral and hyperspectral images. The performance of the SVM technique may vary according to the control parameters. Boxconstraint parameter, kernel function, kernel scale and coding design are the most important control parameters. Developed mainly for binary classification, SVM has become usable in complex multi-class problems thanks to its coding designs. In addition to the most well-known coding approaches onevsone, onevsall; sparserandom, ordinal and binarycomplete approaches are also used. In this study, the effects of coding designs were investigated experimentally. For this purpose, Salinas-A data, which is preferred as one of the basic comparison data sets, was used. In order to evaluate the coding designs objectively, the performance values obtained by keeping all the coding parameters and other basic SVM control parameters constant, respectively, were examined. Values of 1, 5, 10 and 50 for the boxconstraint parameter; By using the 'Linear' and 'Gaussian' functions for the kernel functions, the applications were completed with the code written in Matlab. In addition, in this study, comparison metrics (Overall accuracy, Kappa coefficient, F-score) were applied to the entire image, unlike the classical comparison processes. At the end of the simulation, it was seen that in the one-against-one (onevsone) coding design, if the Box Constraint parameter is 50 and the Kernel function is 'Linear', it has obtained the highest overall accuracy and kappa coefficient.

Keywords: SVM, Hyperspectral Image, Coding Design


1. GİRİŞ

Uzaktan Algılama ile elde edilen hiperspektral görüntüler analiz ve karşılaştırma işlemlerinin yapılmasında oldukça sık tercih edilen görüntüler arasındadır. Hiperspektral görüntü, disiplinlerarası farklı çalışmalarda kullanılan çok sayıda banttan oluşan 3 boyutlu bir görüntü verisidir (Güven vd., 2018). 3 boyutlu hiperspektral görüntüdeki ilk iki boyut ayrıştırılabilen piksel sayısına karşılık gelirken üçüncü boyut spektral bant sayısına karşılık gelmektedir (Yiğit, 2019). Hiperspektral görüntüler üzerinde yapılan çalışmalarda yer-gerçeği görüntüsüne de sahip olması nedeniyle çoğunlukla Salinas veri seti kullanılmaktadır. Salinas verisi ABD'nin Kaliforniya eyaletinde yer alan Salinas Vadisinde AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) sensörü ile elde edilmiştir (Yiğit, 2019; Seyrek, 2021). Diğer sensörler aracılığıyla elde edilen verilere göre dar band aralıklı, spektral çözünürlüğü yüksek olan hiperspektral görüntüler; yansıtım karakterini daha iyi tanımlayarak sınıflandırma performansının daha yüksek olması için tercih edilen görüntü veri setlerinden biridir (Li vd., 2018; Seyrek, 2021). Hiperspektral görüntüler, farklı sınıflandırma teknikleriyle sınıflandırılıp analizler yapılarak yorumlanabilmektedir (Güven vd., 2018). Destek Vektör Makineleri tekniği istatistiksel öğrenme temelli, birçok alanda başarılı sonuçlar ortaya çıkaran, kontrollü makine öğrenmesi tekniğidir (Kavzoğlu ve Çölkesen, 2010; Atasever, 2011; Metlek ve Kayaalp, 2020). DVM tekniğinin ana çalışma prensibi, iki sınıfı ayrıştırabilen en uygun karar fonksiyonunu tahmin etmektir (Tercan ve Atasever, 2021). Makine öğrenmesi teknikleri kullanılırken parametre ayarlarının yapılması büyük önem taşımaktadır. Uygun ve doğru parametre ayarı seçimi, çalışma performansı için son derece önemli olmaktadır. Sınıflandırma algoritmalarının hangisi kullanılırsa kullanılsın, modelin doğruluğunu etkileyen en önemli unsurlardan biri, parametre ayarlamasının doğru yapılmasıdır. DVM tekniğinin başarısını etkileyen en önemli parametreler, kutu kısıtlaması, çekirdek fonksiyonu ve kodlama tasarımıdır. Bu çalışmada, Destek Vektör Makineleri tekniğiyle hiperspektral görüntüleri sınıflandırma işleminde kodlama tasarımının sınıflandırma performansına etkisi belirlenirken Salinas-A hiperspektral görüntü veri seti kullanılmıştır. Görüntü veri seti üzerinde sınıflandırma işlemi kernel fonksiyonları, kodlama tasarımları ve kutu kısıtlama parametreleri değiştirilerek yapılmıştır. Lineer kernel ve Gaussian kernel fonksiyonları her parametre ayarı için ayrı bir şekilde uygulanarak elde edilen sonuçlar, genel doğruluk, kappa katsayısı, F-skoru yönünden karşılaştırılmıştır. Ayrıca elde edilen modellerin yer gerçeği verisi kullanılarak test edilmesi, değerlendirme sürecinin da nesnel değerlendirmesini mümkün kılmıştır. Böylelikle DVM ile sınıflandırma işleminde hangi kodlama tasarımının hiperspektral görüntüleri sınıflandırırken daha uygun olduğu kıyas yapılarak analiz edilmiştir.

2. MATERYAL VE METOD

2.1 Çalışma Verisi

Bu çalışmada, destek vektör makineleri tekniğinde kodlama tasarımının sınıflandırma performansına etkisini ortaya koymak için Salinas-A görüntü verisi kullanılmıştır. Salinas-A görüntü verisinde hangi pikselin hangi sınıfta olduğu bilinmektedir. Salinas-A görüntüsü, sınıflandırma algoritmalarının performanslarını belirlemede oldukça sık tercih edilen bir görüntü verisidir. Sınıflandırma performansını belirlemede kullanılan Salinas-A verisi, 83*86 boyutunda ve 224 banttan oluşmaktadır. Salinas-A hiperspektral görüntüsü üzerinde yapılan sınıflandırma işleminde Matlab programı kullanılmıştır. Kullanılan veri seti ve veri setinin sınıf özellikleri Şekil 1 ve Çizelge 1 olarak sunulmuştur.



Şekil 1. Salinas-A veri seti

Çizelge 1. Salinas-A veri seti özellikleri (Url-1)

Sınıf	Piksel Sayısı
Brokoli (Yeşil Ot)	391
Mısır (Yeşil Ot)	1343
Romaine Cinsi Marul (4 Hafta)	616
Romaine Cinsi Marul (5 Hafta)	1525
Romaine Cinsi Marul (6 Hafta)	674
Romaine Cinsi Marul (7 Hafta)	799

2.2 Sınıflandırma

Uzaktan algılama yoluyla elde edilen ham veriler üzerinde yorum yapmak oldukça zor bir işlemdir. Bu yüzden ham halde bulunan verilerden anlamlı bilgiler çıkarmak için sınıflandırma işlemi kullanılmaktadır. Sınıflandırma işlemiyle benzer özellik gösteren pikseller aynı gruba atanmaktadır (Jehnsen, 1996; Yiğit, 2019). Sınıflandırma işlemi kontrolsüz sınıflandırma ve kontrollü sınıflandırma olarak iki şekilde yapılabilmektedir. Kontrolsüz sınıflandırma, pikselleri belirli bir sınıflandırma kuralına bağlı olarak etiketlemeden, kümeleme yöntemleri yardımıyla yapılan sınıflandırma türüdür (Kesikoğlu, 2013). Kontrollü sınıflandırma tekniğinde ise pikseller belirli bir sınıflandırma kuralına bağlı olarak, eğitim alanları seçilerek sınıflandırılmaktadır. Kontrollü sınıflandırma tekniğinde; Minimum Mesafe, Maksimum Olabilirlik, Yapay Sinir Ağları, Destek Vektör Makineleri gibi yüksek doğruluk içeren metotlar kullanılmaktadır (Richards, 2005; Siewe, 2007; Kesikoğlu, 2013). Destek Vektör Makineleri, özellikle karmaşık verilerin sınıflandırılmasında oldukça etkilidir. Bu avantajın temelinde, kullanılan çekirdek fonksiyonlar sayesinde yüksek boyutlu uzaylarda (yüksek sayıda band) oldukça verimli çalışabilmektedir.

2.3 Parametre Tanımlamaları

2.3.1 Lineer Çekirdek Fonksiyonu

Kernel fonksiyonun varsayılan değeri, lineer kerneli olarak bilinmektedir (Metlek ve Kayaalp, 2020). Lineer kernelinin matematiksel ifadesi; $K(x, y) = (x \cdot y)$ olarak bilinmektedir. Burada K çekirdek fonksiyonu olarak nitelendirilmektedir (Atasever, 2011).

2.3.2 Gaussian Çekirdek Fonksiyonu

Literatürde gaussian kerneli, radyal tabanlı fonksiyon kerneli olarak da bilinmektedir. Gaussian kernelinin matematiksel ifadesi; $K(x, y) = e^{-\gamma ||x-x_i||^2}$ olarak ifade edilmektedir (Atasever, 2011). Bu ifade içerisinde yer alan, K çekirdek fonksiyonu, γ kernel boyutu olarak verilmiştir.

2.3.3 Kodlama Tasarımları

Destek Vektör Makineleri ile bilim dünyasına sunulduğunda ikili sınıflandırmalar için kullanılmaktaydı. Ancak daha sonraları, özellikle görüntü işleme gibi disiplinlerde çok daha fazla sınıfa ihtiyaç duyulması nedeniyle farklı stratejiler geliştirilmiştir. Bunlardan en fazla kullanılanlar kodlama tasarımlarıdır. Bu çalışmanın temel motivasyonunu da kodlama tasarımlarının hiperspektral görüntülerin sınıflandırma performansına etkisinin deneysel olarak incelenmesi olarak tanımlayabiliriz. Bu çalışma kapsamında, Bire-Karşı-Bir, Bire-Karşı-Hepsi, Sıralı, İkili Tamamlama, Seyrek Rastgele kodlama tasarımlarının sınıflandırma performansına etkileri hem eğitim verisinden elde edilen eğitim doğruluğuyla hem de yer-gerçeğinden elde edilen doğruluk değerleri ile incelenmiştir.

Bire-Karşı-Bir (onevsone) kodlama tasarımı matlab programında onevsone olarak bilinmektedir. Bu tasarımda örnek olarak alınan her veri seti, diğer örnek veri setleriyle ayrı bir şekilde eğitilir. Yani Bire-Karşı-Bir kodlama tasarımında $k(k-1)/2$ eğitim işlemi gerçekleştirilmektedir. Burada k sınıf sayısına karşılık gelmektedir (Atasever, 2011).

Bire-Karşı-Hepsi (onevsall) kodlama tasarımı matlab programında onevsall olarak kullanılmaktadır. Bu kodlama tasarımında örnek olarak alınan her veri seti bir sınıf, geride kalan diğer veri setlerinin hepsi bir sınıf olarak kabul edilmektedir. Yani k adet sınıf varsa k adet eğitim işlemi gerçekleştirilmektedir (Atasever, 2011).

Sıralı (ordinal) kodlama tasarımında ilk ikili öğrenen için, birinci sınıf negatif alınırken geri kalanı pozitif olarak alınmaktadır. İkinci ikili öğrenen için, ilk iki sınıf negatif iken geri kalanı pozitifdir. İşlem bu mantıkla devam eder. Yani sıralı kodlama tasarımında k adet sınıf varsa $k-1$ adet eğitim işlemi yapılmaktadır (Url-2).

İkili Tamamlama (binarycomplete) kodlama tasarımı, sınıfları tüm ikili kombinasyonlara bölerek işlem yapar ve hiçbir sınıfı yok saymaz. Her ikili öğrenen için, tüm sınıflara -1 ve 1 ataması yapar ve atama işleminde en az bir pozitif sınıf ve bir negatif sınıf atanmaktadır. Yani bu tasarımda k adet sınıf varsa $2^{(k-1)} - 1$ eğitim işlemi gerçekleşir (Url-2).


Seyrek Rastgele (sparsandom) kodlama tasarımında, her bir ikili öğrenen için yazılım, her biri için 0.25 olasılıkla pozitif veya negatif olarak rastgele sınıflar atar ve 0.5 olasılıkla sınıfları yok sayarak işlem gerçekleştirilmektedir (Url-2).

3. BULGULAR

Destek Vektör Makineleri tekniği ile sınıflandırma işlemi yapılırken sınıflandırma doğruluğunu etkileyen parametrelerden önemli olan adımlardan biri, uygun çekirdek fonksiyonun seçimidir (Metlek ve Kayaalp, 2020). Bu çalışmada Destek Vektör Makineleriyle sınıflandırma işleminde Lineer fonksiyon ve Gaussian fonksiyon kullanılmıştır. Destek Vektör Makineleri ile sınıflandırmada kullanılan bir diğer parametrede kodlama tasarımıdır. Bu çalışmada, Bire-Karşı-Bir (onevsone), Bire-Karşı-Hepsi (onevsall), Sıralı (ordinal), İkili Tamamlama (binarycomplete), Seyrek Rastgele (sparserandom) kodlama tasarımları kullanılmıştır. Tüm çekirdek fonksiyonları ve kodlama tasarımları için 1, 5, 10 ve 50 kutu kısıtlaması (penalty değeri) uygulanmıştır.

3.1. Salinas-A Görüntüsü Lineer Kernel Parametresi ile Sınıflandırma

Salinas-A görüntüsü, lineer fonksiyonu ve Bire-Karşı-Bir kodlama tasarımıyla 1, 5, 10, 50 kutu kısıtlaması kullanılarak sınıflandırılmıştır. Uygulama sonucu elde edilen sınıflandırma görüntüleri Şekil 2’de sunulmuştur.




Şekil 2. Lineer fonksiyonu ve Bire-Karşı-Bir parametresi ile elde edilen sınıflandırma görüntüleri

Lineer fonksiyon ve Bire-Karşı-Bir kodlama tasarımıyla kutu kısıtlaması değiştirilerek elde edilen sınıflandırılmış görüntülerin genel doğruluk, kappa katsayısı ve F-skoru değerlerine ilişkin bilgiler Çizelge 2’de sunulmuştur. Uygulamaya göre hem eğitim verisi hem de görüntünün tamamı için en yüksek başarı kutu kısıtlama değeri 50 olarak seçildiğinde elde edilmiştir.

Çizelge 2. Lineer fonksiyonu ve Bire-Karşı-Bir parametresi ile elde edilen doğruluk değerleri

Bire-Karşı-Bir					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	119.3522	0.8867	0.8649	0.8594	0.8775
5	115.6698	0.8993	0.8762	0.8693	0.8821
10	116.1144	0.8575	0.8372	0.8310	0.8487
50	110.7239	0.8819	0.9059	0.8868	0.9206

Salinas-A görüntüsü, lineer fonksiyon ve Bire-Karşı-Hepsi (onevsall) kodlama tasarımıyla 1, 5, 10, 50 kutu kısıtlaması kullanılarak sınıflandırılmıştır. Uygulama sonucu elde edilen sınıflandırma görüntüleri Şekil 3’de sunulmuştur.




Şekil 3. Lineer fonksiyonu ve Bire-Karşı-Hepsi parametresi ile elde edilen sınıflandırma görüntüleri

Şekil 3 dikkatli incelenirse kutu kısıtlama değerinin 1, 5 ve 10 olduğu durumlarda görece daha düşük doğruluk değerleri elde edilmiştir. Lineer fonksiyonu ve Bire-Karşı-Hepsi kodlama tasarımıyla kutu kısıtlaması değiştirildiğinde elde edilen genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 3 olarak sunulmuştur. Görüntüler arasındaki farkların, doğruluk değerlerine de yansıdığı görülmüştür. Bu parametrelerle en yüksek doğruluk değerleri kutu kısıtlaması 50 olduğunda elde edilmiştir.

Çizelge 3. Lineer fonksiyonu ve Bire-Karşı-Hepsi parametresi ile elde edilen doğruluk değerleri

Bire-Karşı-Hepsi					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	280.1242	0.5960	0.5843	0.5770	0.5718
5	261.5405	0.4577	0.4545	0.4517	NaN
10	260.4889	0.6270	0.6196	0.6057	0.6106
50	266.1255	0.7212	0.7020	0.6859	0.7574

Bir sonraki uygulamada Salinas-A görüntüsünün lineer fonksiyonu ve Sıralı kodlama tasarımıyla gerçekleştirilmiş ve sonuç görüntüler Şekil 4'te sunulmuştur. Sınıflandırılmış görüntüler incelendiğinde bu parametrelerle doğru bir sınıflandırma yapılmadığı görülmektedir.




Şekil 4. Lineer fonksiyonu ve Sıralı parametresi ile elde edilen sınıflandırma görüntüleri

Lineer fonksiyonu ve Sıralı kodlama tasarımıyla kutu kısıtlama değeri değiştirilerek yapılan sınıflandırmanın genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 4'te sunulmuştur. Doğruluk değerlerinde görüldüğü üzere sınıflandırma işlemi güvenilir seviyelerde olmamıştır. Sonuçlara bakıldığında Lineer fonksiyon ve Sıralı kodlama tasarımının birlikte kullanımının hiperspektral görüntü sınıflandırma için uygun olmadığı görülmüştür.

Çizelge 4. Lineer fonksiyonu ve Sıralı parametresi ile elde edilen doğruluk değerleri

Sıralı					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	348.1926	0.2588	0.2567	0.2369	NaN
5	342.7411	0.3222	0.3183	0.3039	NaN
10	330.9409	0.2616	0.2634	0.2594	NaN
50	327.7868	0.2431	0.3073	0.2958	NaN

İkili Tamamlama kodlama kullanılarak gerçekleştirilen sınıflandırılma sonucu elde edilen görüntüler Şekil 5'te verilmiştir. İkili Tamamlama ile elde edilen sonuçlar Sıralı kodlama tasarımına göre daha başarılı olsa da istenen sonuca ulaşamadığı görülmektedir.




Şekil 5. Lineer fonksiyonu ve İkili Tamamlama parametresi ile elde edilen sınıflandırma görüntüleri

Lineer fonksiyonu ve İkili Tamamlama kodlama tasarımıyla kutu kısıtlama değeri değiştirilerek yapılan sınıflandırmanın genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 5'te sunulmuştur. İkili Tamamlama tasarımı ile elde edilen hata değerleri her ne kadar Sıralı kodlama tasarımından daha yüksek olsa da ne eğitim doğruluğu için ne de görüntünün tamamından elde edilen metriklerde istenen seviyelere ulaşamadığı görülmüştür.

Çizelge 5. Lineer fonksiyonu ve İkili Tamamlama parametresi ile elde edilen doğruluk değerleri

İkili Tamamlama					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	3121.5152	0.5219	0.5139	0.5100	0.5707
5	3115.7111	0.6696	0.6603	0.6407	0.6788
10	3097.7088	0.6748	0.6671	0.6648	0.6433
50	3137.0835	0.3488	0.3425	0.3279	0.2932

Lineer fonksiyonu ve Seyrek Rastgele kodlama tasarımıyla gerçekleştirilen sınıflandırma işlemleri ile elde edilen sınıflandırılmış görüntüler Şekil 6'da sunulmuştur. Bu kodlama tasarımının belirlenen parametrelere göre etkin sonuçlar üretmediği görülmüştür.



Şekil 6. Lineer fonksiyonu ve Seyrek Rastgele parametresi ile elde edilen sınıflandırma görüntüleri


Lineer fonksiyonu ve Seyrek Rastgele kodlama tasarımıyla kutu kısıtlama değeri değiştirilerek yapılan sınıflandırmanın genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 6'da sunulmuştur. Kutu kısıtlaması 5 olarak alındığında diğerlerine göre daha etkin sonuç üretildiği görülmüştür.

Çizelge 6. Lineer fonksiyonu ve Seyrek Rastgele parametresi ile elde edilen doğruluk değerleri

Seyrek Rastgele					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	800.6134	0.4032	0.4011	0.3966	0.3920
5	666.5522	0.7687	0.7571	0.7483	0.7858
10	809.5267	0.6708	0.6621	0.6562	0.6884
50	687.4705	0.5621	0.5604	0.5506	0.5816

3.2. Salinas-A Görüntüsünün Gaussian Fonksiyonu ile Sınıflandırma

Salinas-A görüntüsü, gaussian fonksiyonu ve Bire-Karşı-Bir kodlama tasarımıyla 1, 5, 10, 50 kutu kısıtlaması kullanılarak sınıflandırılmıştır. Uygulama sonucu elde edilen sınıflandırma görüntüleri Şekil 7'de sunulmuştur.



Şekil 7. Gaussian fonksiyonu ve Bire-Karşı-Bir parametresi ile elde edilen sınıflandırma görüntüleri


Şekil 7 incelendiğinde her ne kadar sonuç görüntülerde hatalı sınıflandırılan pikseller olsa da genel olarak sınıflandırmanın görece kabul edilebilir doğrulukta olduğu görülmektedir.

Gaussian fonksiyonu ve Bire-Karşı-Bir kodlama tasarımıyla kutu kısıtlama değeri değiştirilerek yapılan sınıflandırmanın genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 7’de sunulmuştur. Gerçekleştiren uygulamalarda eğitim doğruluğu çok yüksek hesaplanmasına karşın, görüntünün tamamı için hesaplanan metriklerin görece daha düşük olduğu görülmektedir. Bu adımdaki kutu kısıtlaması değerlerinin sınıflandırma metriklerine ciddi etkisi olmadığı görülmüştür.

Çizelge 7. Gaussian fonksiyonu ve Bire-Karşı-Bir parametresi ile elde edilen doğruluk değerleri

Bire-Karşı-Bir					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	12.6937	0.9806	0.8511	0.8477	0.8749
5	11.7672	0.9806	0.8511	0.8489	0.8749
10	11.8692	0.9806	0.8511	0.8447	0.8749
50	11.8323	0.9806	0.8511	0.8395	0.8749

Salinas-A hiperspektral görüntüsü Gaussian fonksiyonu ve Bire-Karşı-Hepsi kodlama tasarımıyla 1,5,10,50 kutu kısıtlaması kullanılarak sınıflandırılmıştır. Elde edilen sınıflandırma görüntüleri Şekil 8’de sunulmuştur.




Şekil 8. Gaussian fonksiyonu ve Bire-Karşı-Hepsi parametresi ile elde edilen sınıflandırma görüntüleri

Gaussian fonksiyonu ve Bire-Karşı-Hepsi kodlama tasarımıyla kutu kısıtlama değeri değiştirilerek yapılan sınıflandırmanın genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 8’de gösterilmiştir. Doğruluk değerlerinin güvenilir seviyelerde olduğu görülmüştür. Ayrıca tüm kutu kısıtlama değerlerinde birbirine çok yakın değerler elde edilmiştir.

Çizelge 8. Gaussian fonksiyonu ve Bire-Karşı-Hepsi parametresi ile elde edilen doğruluk değerleri

Bire-Karşı-Hepsi					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	25.7018	0.9806	0.8511	0.8465	0.8749
5	25.8618	0.9806	0.8511	0.8459	0.8749
10	25.8579	0.9806	0.8511	0.8426	0.8749
50	25.3480	0.9806	0.8511	0.8463	0.8749

Gaussian fonksiyonu ve Sıralı kodlama tasarımıyla elde edilen sonuçlar Şekil 9’da görselleştirilmiştir. Sonuç görüntülerin birbirine çok yakın olduğu gözlemlenmiştir.




Şekil 9. Gaussian fonksiyonu ve Sıralı parametresi ile elde edilen sınıflandırma görüntüleri

Gaussian fonksiyonu ve Sıralı Kodlama tasarımıyla kutu kısıtlama değeri değiştirilerek yapılan sınıflandırmanın genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 9’da sunulmuştur. Çizelge dikkatli incelenirse eğitim doğruluğu ve görüntünün tamamından hesaplanan genel doğruluk değeri arasında ciddi fark olduğu gözlemlenmiştir.

Çizelge 9. Gaussian fonksiyonu ve Sıralı parametresi ile elde edilen doğruluk değerleri

Sıralı					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	22.4859	0.9694	0.8138	0.8051	0.8293
5	23.0687	0.9694	0.8138	0.8056	0.8293
10	22.3283	0.9694	0.8138	0.8037	0.8293
50	23.1104	0.9694	0.8138	0.8046	0.8293

Salinas-A hiperspektral görüntüsü Gaussian fonksiyonu ve İkili Tamamlama kodlama tasarımıyla elde edilen çıktı görüntüler Şekil 10’da sunulmuştur. Sonuç görüntülerin birbirine çok yakın olduğu görülmektedir.




Şekil 10. Gaussian fonksiyonu ve İkili Tamamlama parametresi ile elde edilen sınıflandırma görüntüleri

Gaussian fonksiyonu ve İkili Tamamlama kodlama tasarımıyla kutu kısıtlama değeri değiştirilerek yapılan sınıflandırmanın genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 10’da gösterilmektedir. Çizelge incelendiğinde Salinas-A görüntüsünün doğruluk değerlerinin güvenilir seviyelerde olduğu görülmüştür. Ayrıca tüm kutu kısıtlama değerlerinde birbirine çok yakın doğruluk değerleri elde edilmiştir. Yani kutu kısıtlama değerinin bu parametrelerle sınıflandırmada doğruluklara ciddi etkisinin olmadığı anlaşılmaktadır.

Çizelge 10. Gaussian fonksiyonu ve İkili Tamamlama parametresi ile elde edilen doğruluk değerleri

İkili Tamamlama					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	260.3181	0.9806	0.8511	0.8449	0.8749
5	228.0131	0.9806	0.8511	0.8392	0.8749
10	240.9428	0.9806	0.8511	0.8494	0.8749
50	243.2882	0.9806	0.8511	0.8318	0.8749

Son uygulamada Gaussian fonksiyonu ve Seyrek Rastgele kodlama tasarımıyla sınıflandırma işlemleri yapılmış ve elde edilen sonuç görüntüler Şekil 11’ verilmiştir. Seyrek Rastgele kodlamasının farklı kutu kısıtlama değerlerinde bazı sınıfların çok daha başarılı sınıflandırdığı görülmüştür.



Şekil 11. Gaussian fonksiyonu ve Seyrek Rastgele parametresi ile elde edilen sınıflandırma görüntüleri

Gaussian fonksiyonu ve Seyrek Rastgele kodlama tasarımıyla kutu kısıtlama değeri değiştirilerek yapılan sınıflandırmanın genel doğruluk, kappa katsayısı ve F-skoru değerleri Çizelge 11’de gösterilmiştir. Gaussian fonksiyonu ile yapılan diğer tüm uygulamalarda olduğu gibi bu uygulamada da eğitim doğruluğu ile genel doğruluk değerleri arasında ciddi fark olduğu gözlemlenmiştir.

Çizelge 11. Gaussian fonksiyonu ve Seyrek Rastgele parametresi ile elde edilen doğruluk değerleri

Seyrek Rastgele					
Eğitim Verisi			Görüntünün Tamamı		
Kutu Kısıtlama	Süre (saniye)	Eğitim Doğruluğu	Genel Doğruluk	Kappa Katsayısı	F-Skoru
1	65.7586	0.9806	0.8511	0.8326	0.8749
5	61.1576	0.9806	0.8469	0.8416	0.8692
10	66.2962	0.9806	0.8413	0.8360	0.8641
50	60.6248	0.9806	0.8511	0.8401	0.8749

4. SONUÇ

Hiperspektral görüntüler yüksek band kapasitesi sayesinde sınıfların belirlenebilmesinde ciddi avantajlar getirmektedir. Ancak, çok fazla sayıda band içermesi sınıflandırma algoritmalarının kontrol parametre ayarlamalarını çok daha dikkatli biçimde yapılmasını gerektirmektedir. Hem multispektral hem de hiperspektral görüntüler ile yapılan sınıflandırma uygulamalarının çok büyük bir kısmında Destek Vektör Makineleri yönteminin kullanıldığı görülmektedir. Her ne kadar DVM tekniği yüksek boyutlu (öznitelik/band) verilerin sınıflandırmasında etkili olsa da; doğru parametrelerin seçimi kritik öneme sahiptir. Bu çalışma ile Destek Vektör Makineleri tekniği ile hiperspektral görüntülerde kodlama tasarımının sınıflandırma performansına etkisi araştırılmıştır. Uygulama için Salinas veri setinin bir parçası olan Salinas-A veri seti kullanılmıştır. Lineer ve Gaussian fonksiyonların kullanıldığı çalışmalarda, her ne kadar Gaussian fonksiyon genel olarak tüm kodlama tasarımlarında birbirine yakın ve başarılı sonuçlar üretse de kodlama tasarımının Bire-Karşı-Bir; kutu kısıtlama parametresinin 50; çekirdek fonksiyonun ‘Lineer’ olması halinde en yüksek genel doğruluk, kappa katsayısı ve F-Skor değerlerini elde ettiği görülmüştür.

KAYNAKLAR

- Atasever, Ü. H., 2011. Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rasgele Orman (Random Forest) ve Regresyon Ağaçları Yöntemlerinin Kullanılması. *Yüksek Lisans Tezi*. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri. 86 sayfa.
- Günen, M.A., Atasever, Ü.H., Beşdok, E., 2018. Hiperspektral Görüntülerin Oto-Kodlayıcı Derin Öğrenme ile Sınıflandırılması. *VII. Uzaktan Algılama-Cbs Sempozyumu*, Eskişehir, 18-21 Eylül 2018.
- Jehnsen, J.R., 1996. *Introductory digital image processing: A remote sensing perspective*, Prentice Hall, New Jersey, 315 sayfa.
- Kavzoğlu, T., Çölkesen, İ., 2010. Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, Sayı 144.
- Kesikoğlu, M. H., 2013. Sultan Sazlığı Milli Parkı ve Ramsar Alanı Kıyı Değişiminin Uydu Görüntü Analizleriyle İncelenmesi. *Yüksek Lisans Tezi*. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri. 89 sayfa.
- Li Y, Zhang H, Xue X, Jiang Y, Shen Q., 2018. Deep learning for remote sensing image classification: a survey. *WIRES Data Mining- and Knowledge Discovery*, 8(6):e1264.
- Metlek, S., Kayaalp, K., 2020. *Makine Öğrenmesinde, Teoriden Örnek Matlab Uygulamalarına Kadar Destek Vektör Makineleri*, İksad, Aralık 2020.
- Richards, J. A., Jia, X., 2005. *Remote Sensing Dijital Image Analysis*, 4th edition, Springer, Germany.
- Seyrek, E.C., 2021. Hiperspektral Görüntü Sınıflandırma Uygulamalarında Makine ve Derin Öğrenme Kullanımı. *Yüksek Lisans Tezi*. Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Afyonkarahisar. 154 sayfa.

Siewe, S. S., 2007. Change Detection Analysis Of The Landuse and Landcover of The Fort Cobb Reservoir Watershed. *Master of Science*. Oklahoma State University, USA, 86 sayfa.

Tercan, E., Atasever, U.H., 2021. Effectiveness of autoencoder for lake area extraction from high-resolution RGB imagery: an experimental study. *Environmental Science and Pollution Research* 28, 31084–31096.

Url-1 (Web sayfası: http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes), [Erişim Tarihi: 10.05.2022].

Url-2 (Web sayfası: <https://www.mathworks.com/help/stats/fitcecoc.html>), [Erişim Tarihi: 28.06.2022].

Yiğit, M., 2019. Hiperspektral uydu görüntülerinin ileri tekniklerle sınıflandırılması. *Yüksek Lisans Tezi*. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri. 137 sayfa.