

Ampirik Kip Ayırışımı ve Dalgacık Dönüşümü Kullanarak Hiperspektral Görüntülerin Boyutlarının Azaltılması

Esra Tunç Görmüş^{a*}, Nishan.Canagarajah^b, Alin Achim^b

^a KTU Harita Mühendisliği Bölümü, Kanuni Kampüs, Trabzon, Türkiye (etunc@ktu.edu.tr)

^b Visual Information Laboratory, Department of Electrical and Electronic Engineering, University of Bristol, Bristol BS8 1UB, U.K. (Nishan.Canagarajah@bristol.ac.uk, Alin.Achim@bristol.ac.uk)

ANAHTAR KELİMELER: Hiperspektral Görüntüler, Ampirik Kip Ayırışımı, Ayrık Dalgacık Dönüşümü, Boyut Azaltımı

ÖZET:

Bu çalışmada, hiperspektral görüntülerin boyutlarını azaltmak için yeni bir metot sunulmaktadır. En iyi sınıflandırma doğruluğunu verecek olan en küçük öznelik kümesini oluşturmak için Ampirik Kip Ayırışımı (AKA) ve Ayrık Dalgacık Dönüşümü (DWT) birleştirilmiştir. Geliştirilen bu yöntem ile görüntüye ait konumsal ve spektral bilgi birlikte kullanıldığı için daha iyi sınıflandırma doğruluğu elde edilmiştir. Kısaca, iki boyutlu AKA'nın hiperspektral görüntünün tüm bantlarına uygulanması ile konumsal bilgi zenginleştirilmiş, daha sonra AKA öznelik imzalarına uygulanan bir boyutlu DWT ile spektral bilginin iyileştirilmesi sağlanmıştır. Boyutu azaltılmış hiperspektral görüntüler, dalgacık dönüşümü sonrası katsayıların seçilmesi ile elde edilmiştir. Bu yöntem AVIRIS Pine ve ROSIS Pavia University adındaki iki farklı hiperspektral görüntüye uygulanmış ve sonuçta elde edilen yeni görüntüler Destek Vektör Makinaları ile sınıflandırılarak, geliştirilen yöntem diğer boyut indirgeme yöntemleri ile karşılaştırılmıştır.

Dimensionality Reduction of Hyperspectral Images Exploiting Empirical Mode Decomposition and Discrete Wavelet Transform

KEY WORDS: Hyperspectral Images, Empirical Mode Decomposition, Discrete Wavelet Transform, Dimensionality Reduction

ABSTRACT:

A new dimensionality reduction method for hyperspectral images is proposed in this study. In order to find the most discriminative subset of features which gives the best classification accuracy, two important methods namely two dimensional Empirical Mode Decomposition (2D-EMD) and one dimensional Discrete Wavelet Transform are combined. High classification accuracy is obtained because of exploiting both spatial and spectral information of the image via these decomposition methods. Proposed method composed of applying 2D-EMD on each band of the hyperspectral image to get the components that specifies spatial information details by intrinsic mod functions (IMFs) and then, 1D-DWT is applied on these IMFs to get wavelet based IMFs (WIMF) which reveal the spectral information. Finally the new features of dimensionally reduced hyperspectral images are generated by summing up the lower scale of WIMF features. Proposed method is tested on two well known hyperspectral images called AVIRIS Pine and ROSIS Pavia University. Generated new features are classified by Support Vector Machine (SVM) and compared with other dimensionality reduction methods in order to show the effectiveness of the proposed method.

1. GİRİŞ

Yüksek spektral çözünürlüklü algılayıcıları, multispektral (MS) algılayıcılardan ayıran en önemli özellikleri yeryüzündeki nesnelere birbirinden daha iyi ayırt edebilme kapasitesidir. Uydulardan ya da uçaklardan çekilen yüksek çözünürlüklü görüntüler yardımıyla tarım, jeoloji, coğrafya veya savunma gibi farklı disiplinlerdeki yeryüzü nesnelere tespit edilebilme kapasiteleri geliştirilmiştir (Chang, 2000). Hiperspektral görüntülerin çok sayıda komşu ve dar bantlardan oluşması, MS görüntülerde ayırt edilemeyen nesnelere daha yüksek doğrulukta ayırt edilmesine ve sınıflandırılmasına izin vermektedir. Bu tür uygulamaların çoğunda “boyut azaltma” gerekli olan ön işlem aşamalarından biridir. Boyut azaltma işlemi ile hiperspektral küp içerisindeki bilgileri özetleyen daha az bantlı yeni öznelikler (fetaures) oluşturulmaktadır. Literatürde görüntü boyutunu azaltmak için 2 ayrı yaklaşım

kullanılmaktadır. Birincisi sınıflandırma kriterine ya da sınıfların ayrılabilirliğine olan katkılarına göre, doğrudan orijinal öznelik uzayından alt özneliklerin seçilmesine dayanır ve buna ‘öznelik seçme’ denilmektedir (Backer, 2005). İkinci yaklaşım ise orijinal öznelik uzayındaki tüm veriyi kullanarak daha az boyutlu alt uzaya taşınmasına dayanmaktadır. Buna da ‘öznelik çıkartma’ denilmektedir. Temel bileşen analizi (PCA), hızlı Fourier dönüşümü (FFT) veya dalgacık dönüşümü (WT) bu tür yaklaşımlara verilebilecek örneklerdendir (Hsu, 2006). Bu çalışmada, ikinci yaklaşım ele alınmıştır ve lokal enerjiyi daha iyi bulma yeteneğinden dolayı dalgacık dönüşümü hiperspektral görüntülerin (HSG) boyutlarının azaltılmasında kullanılmıştır.

Son yıllarda yapılan çeşitli çalışmalarda dalgacık tabanlı boyut azaltma yöntemlerinden yararlanılmıştır (Bruce, 2002) ve (Kempeneers, 2004). Dalgacıkların zaman-frekans yerleştirme

* Corresponding author. This is useful to know for communication with the appropriate person in cases with more than one author.

özelliğinden dolayı, ayrık dalgacık dönüşümü (Discrete Wavelet Transformation-DWT) en iyi ayırt edici özneliklerin çıkartılmasında kullanılmıştır (Bruce, 2002). Bir diğer çalışmada ise (Kempeneers, 2004). HSG'lere DWT uygulandıktan sonra, dalgacık katsayıları, dalgacık enerjileri ve dalgacık detay histogramları elde edilmiş ve bu değerler sınıflandırmada öznelik olarak kullanılmıştır. Bir diğer çalışmada ise (Hsu, 2006), WT HSG'lere uygulanmış ve belli bir sırada dalgacık katsayıları elde edilmiştir. Daha sonra sınıflandırmada kullanılmak üzere en iyi öznelikler, öznelik seçme işlemi ile elde edilmiştir.

Dalgacık dönüşümüne alternatif olarak Ampirik Kip Ayırıştırma (AKA) (Empirical Mode Decomposition- EMD), Huang vd. tarafından (Huang,1998) bir boyutlu (1B) sinyaller için, Linderhed tarafından ise (Linderhed,2004) iki boyutlu (2B) görüntüler için önerilmiştir. AKA dönüşümü daha sonra başka çalışmalarda görüntü sınıflandırma ve boyut azaltma işlemleri için kullanılmıştır (Demir, 2010) ve (Wu,2005).

Bu çalışmanın amacı, 2B-AKA dönüşümünün hiperspektral görüntülerin boyut azaltımı alanında kullanılması ve daha az veri ile sınıflandırma başarımının artırılmasıdır. Yapılan çalışmada 2D AKA konumsal ilişkiyi çıkartabilmek için her banda ayrı ayrı uygulanmış, daha sonra görüntüdeki spektral bilgiyi çıkartabilmek için, bir boyutlu ayrık dalgacık dönüşümü (1B-DWT), AKA dönüşümü sonucu elde edilen 'içkin kip fonksiyonları (İKF) (intrinsic mode function-IMF)'na uygulanmıştır. Elde edilen öznelikler ardı sıra tolanarak, dalgacık tabanlı İKF'leri (WIKF) oluşturmuştur. Son olarak boyutu azaltılmış dalgacık tabanlı AKA öznelikleri 'destek vektör makinaları (DVM)' ile sınıflandırılmış ve değerlendirilmeleri yapılmıştır.

Bu çalışmada ikinci bölümde dalgacık dönüşüm tabanlı boyut azaltma yöntemleri, üçüncü bölümde AKA dönüşümü ve dördüncü bölümde önerilen çalışmanın detayları ile deney sonuçları incelenmiştir. Son bölümde ise elde edilen sonuçlar irdelenmiştir.

2. DÖNÜŞÜM TABANLI BOYUT AZALTMA YÖNTEMLERİ

Hiperspektral görüntüler 3B küp şeklinde düşünülmektedirler. Üst yüzü konumsal değişimi gösterirken, kenar yüzleri spektral değişimi göstermektedir. Dalgacık dönüşümleri uzaktan algılamada kullanılan birçok uygulama için alt yapı oluşturan çok güçlü bir araçtır. Sıkıştırma, birleştirme veya sınıflandırma gibi uygulamalarda dalgacık dönüşümünden yararlanılmaktadır.

Bu çalışmada dalgacık dönüşümü hiperspektral veri küpünde spektral uzayda piksellere ait değişkenlik, benzerlik ve farklılıklar gibi özelliklerini çıkartmak için kullanılacaktır. HSG'lerde bir nesne spektral değerlerinin büyüklüklerindense, spektral imzalarının şekillerine göre daha kolay belirlenebilmektedir. Bu yüzden dalgacık tabanlı yaklaşımlar daha çok 1B-DWT spektral uzayda piksellere uygulanmaktadır. Böylece boyut azaltımını sağlayan birkaç dalgacık katsayılarının seçimi de yapılmış olur. Dalgacık tabanlı boyut azaltma yöntemleri sonucu elde edilen yeni görüntü küpünün sınıflandırma performansları PCA veya FFT gibi diğer frekans tabanlı yöntemlerden daha iyi sonuç vermektedir. Bu, her bir ölçekte farklı spektral bantlardaki hiperspektral sinyallerin lokal enerji değişimlerini iyi bulabilme özelliklerinden kaynaklanmaktadır.

Uzaktan Algılamada (UA) PCA en çok kullanılan boyut azaltma yöntemlerindedir. Verideki gereksiz bilgilerden kurtularak sadece yüksek varyanslı bantların kullanımını sağlamaktadır. Ancak lokal spektral imzaları koruyamadığı için, iyi bir sınıflandırma performansı yakalayamamaktadır (Kaewpjit, 2003). Diğer taraftan FFT tabanlı metotlarda, her bir imzaya FFT uygulanır ve ilk birkaç ve son birkaç katsayıların mutlak değerleri sınıflandırma için öznelikleri oluşturur. Dalgacık dönüşümü daha önceki çalışmalarda sınıflandırma uygulamaları için ön işlem adımı olarak boyut azaltımında kullanılmıştır (Chen, 2009) ve (Hsu, 2002). Dalgacık dönüşümü bir sinyali alçak (a-approximation) ve yüksek frekans (d-detail) bileşenleri olmak üzere ikiye ayırır. Bu dönüşüm matematiksel olarak aşağıdaki gibi ifade edilmektedir.

$$a_{j+1}[p] = \sum_{n=-\infty}^{\infty} h[n-2p]a_j[n] \quad (1)$$

$$d_{j+1}[p] = \sum_{n=-\infty}^{\infty} g[n-2p]a_j[n]$$

Burada 'h' ve 'g' dönüşümde kullanılan çıktıyı örnekleyen filtreler, a_j , 2^j seviyesindeki düşük frekans bileşen katsayıları, a_{j+1} ve d_{j+1} ise sırasıyla 2^{j+1} seviyesindeki alçak ve yüksek frekans bileşen katsayılarıdır.

DWT'yi hesaplarken iki farklı girdiye ihtiyaç vardır ana dalgacık seçimi ve indirgeme seviyesi. Bu çalışmada deneylerden sonra 3 seviye indirgemenin yapılması uygun görülmüştür. Dalgacık dönüşümünden sonraki sinyalin uzunluğu dalgacık filtresinin ve orijinal sinyalin uzunluğuna bağlıdır.

Ana dalgacığın seçimi için literatürde en çok kullanılan Daubechies 3 (db3) kullanılmıştır (Chen,2009). Dalgacık dönüşümü tabanlı boyut azaltımı hangi bileşenlere ait katsayıları (alçak frekans, yüksek frekans ya da her ikisi) seçecekse, ona göre değişmektedir. Dalgacık dönüşümü yapıldıktan sonra boyut azaltım amaçlı katsayılar seçimi iki yöntem ile yapılmaktadır. Bunlar 'doğrusal dalgacık öznelik çıkartımı', diğeri ise 'doğrusal olmayan dalgacık öznelik çıkartımı'dır.

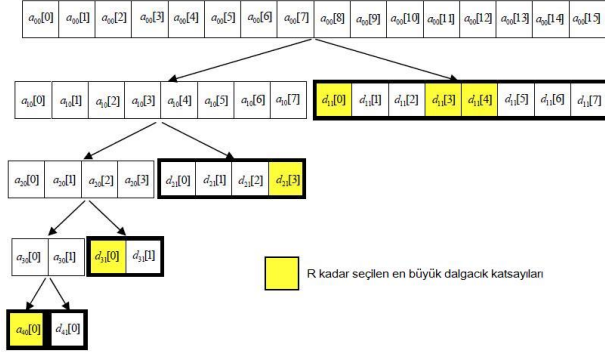
2.1 Doğrusal Dalgacık Öznelik Çıkartımı (Linear WFE)

Hiperspektral imzayı 1B-DWT kullanarak indirgedikten sonra R kadar dalgacık katsayısı seçilir (Şekil 1). Daha sonra sınıflandırma için alçak ya da yüksek frekans katsayıları kullanılır. Bir çalışmada (Hsu, 2006), düşük frekanslı değerlerin orijinal spektrumun trendi ile ilgili bilgileri gösterdiği, detayların ise en çok değişimin olduğu yerleri gösterdiği belirtilmiştir.

2.2 Doğrusal Olmayan Dalgacık Öznelik Çıkartımı (Non-Linear WFE)

Doğrusal-DWT yöntemine benzer olarak boyut azaltımı dalgacık katsayılarının seçimi ile gerçekleştirilmektedir. Bu yöntemde imzayı indirgedikten sonra, dalgacık katsayıları azalan sırada sıralanır ve en yüksek R katsayıları sınıflandırılmak için en önemli öznelikler olarak seçilir. Ancak Doğrusal-DWT'e göre daha düşük sınıflandırma performansına sahiptir.

Şekil 1'de 16 birim uzunluğundaki bir sinyale 4 seviye 1B-DWT yapılmıştır. Kalın sınır ile gösterilen katsayılar aynı sırada alınıp istenilen ilk R katsayı seçilince Lineer WFE yöntemine, sarı renkteki en büyük R kadar katsayı ise Non-Linear WFE yöntemine örnek olarak verilmiştir.



Şekil 1. Kalın sınırları olan katsayılar Doğrusal Öznitelik Çıkartımı için ve sarı renkli en büyük katsayılar Doğrusal Olamayan Öznitelik Çıkartımı için kullanılmıştır.

3. AMPİRİK KİP AYRIŞTIRMA YÖNTEMİ (AKA)

Dalgacık dönüşümünde filtrelerin seçimindeki sınırlamalardan dolayı, Fourier dönüşümünde ise verinin doğrusal ve durağan sayılmasından dolayı bazı zorluklarla karşılaşmaktadır. Bu zorluklar, veri hakkında hiç bir varsayımda bulunmayan ve veriyi içkin kip fonksiyonlarına (İKF) ayırtıran AKA dönüşümü (Huang, 1998) ile elimine edilmektedir. Bu nedenle, AKA'nın özellikle doğrusal ve durağan olmayan zaman serilerinde Fourier ve Dalgacık dönüşümlerinden daha başarılı olduğu çeşitli çalışmalarda gösterilmiştir (Demir, 2008). Karmaşık sinyal AKA dönüşümü ile İKF'lere ve bir kalana (residue) ayrılır. Daha sonra elde edilen İKF'leri, kalan ile birlikte toplayarak bilgi kaybı ve hata olmadan orijinal işaret elde edilmektedir.

AKA, sinyalin konumsal frekansını İKF'ler ile ifade eder. 2B görüntülerde de aynı şekildedir. İlk İKF görüntünün en yüksek lokal konumsal frekanslarını göstermektedir. İkinci İKF ikinci en yüksek konumsal frekansları göstermektedir ve bu böyle devam eder. İKF olabilmek için 2 şart vardır. Birincisi, sıfır geçişlerinin sayısının, uç noktasının (extreme) sayısına eşit olması ya da aralarındaki farkın 1 olmasıdır. Diğeri ise, lokal maksimum ve lokal minimum değerlerinin belirlediği zarfların ortalama değerlerinin herhangi bir noktada sıfır olmasıdır. Üst zarf, işaretin yerel maksimum noktalarının ara değerlemesi ile, alt zarf yerel minimum noktalarının ara değerlemesi ile bulunmaktadır. AKA, sinyalin istatistiklerine bağlı değildir ve sadece sinyalin lokal özelliklerine dayanmaktadır. Frekanslar içi ve frekanslar arası birçok öznitelik oluşturmaktadır.

Bir bandın İKF'lerini bulan iteratif işlemlere 'eleme işlemi' (sifting process) adı verilmektedir. Bu işlem bandın kendisi ($B_l(i, j)$) ile başlamaktadır. $I_{l,1}^{(1)} = B_l(i, j)$. $I_{l,m}^{(n)}$ 'de (n) iterasyon sayısını, $l=1,2,...,L$ band sayısını, L hiperspektral görüntüdeki toplam görüntü sayısını, (i,j) uzamsal boyutu, $m=1:M$, M İKF sayısını temsil etmektedir.

Buna göre 2D-AKA'nın nasıl çalıştığı, hiperspektral görüntünün l numaralı bandı $B_l(i, j)$ için, birinci İKF'nin ($İKF_{l,m}$) nasıl bulunduğu aşağıdaki gibi açıklanmıştır;

- 1) Girdi görüntüde tüm yerel maksimum ve yerel minimum noktalarının 2B genlik ve pozisyonlarının elde edilmesi.
- 2) Eğri aradeğerlenmesi (spline enterpolation) ile yerel maksimum noktalarından 2B üst zarf $E_{\max}(i, j)$ ve yerel minimum noktalarından 2B alt zarf $E_{\min}(i, j)$ oluşturulması.

3) Her (i,j) uzamsal pozisyon için üst zarf ve alt zarfın ortalamasının hesaplanması

$$EM_m^n(i, j) = (E_{\max}(i, j) + E_{\min}(i, j)) / 2 \quad (1)$$

4) Ortalama zarf işaretinin, giriş işaretinden çıkarılması

$$S_m^n(i, j) = I_{l,m}^n(i, j) - EM_m^n(i, j) \quad (2)$$

Buraya kadar ki adımlar eleme işleminin bir iterasyonunu göstermektedir.

5) Bu adımda yapılacak olan, 4. adımda elde edilen görüntünün İKF olup olmadığını test etmektir. İKF olma şartı zarf ortalama işaretinin sıfıra yeterince yakın olup olmamasına bağlıdır (Demir, 2010).

$$\sum_{i=1}^P \sum_{j=1}^R |EM_m^n(i, j)| / (PxR) < \tau \quad (5)$$

Burada P ve R ortalama zarfın boyutları, τ ise sıfıra yakın bir değerdir. Eğer durdurma kriteri N. İterasyonda sağlandıysa ($n=N$), ilk İKF elde edilmiş olur, $İKF_{l,m}(i, j) = S_m^N(i, j)$.

Eğer bu kriter sağlanmadı ise, ilk İKF bulunana kadar, adım 4'te elde edilen görüntü adım 1'de girdi görüntü olarak ele alınıp işlemler tekrar edilir, $I_{l,m}^{n+1}(i, j) = S_m^n(i, j)$.

6) Eğer İKF başarılı bir şekilde elde edildiyse, kalan sinyal hesaplanır $R_m(i, j) = I_{l,m}^n(i, j) - İKF_{l,m}(i, j)$. Eğer kalan sinyal daha fazla uç nokta (extrema) içermiyorsa AKA işlemi sona erer. Eğer içeriyorsa, bir sonraki İKF'nin hesaplanmasına, bu kalan görüntünün birinci adımda girdi görüntü olarak ele alınması ile devam edilir, $I_{l,m}^{n+1}(i, j) = R_m(i, j)$.

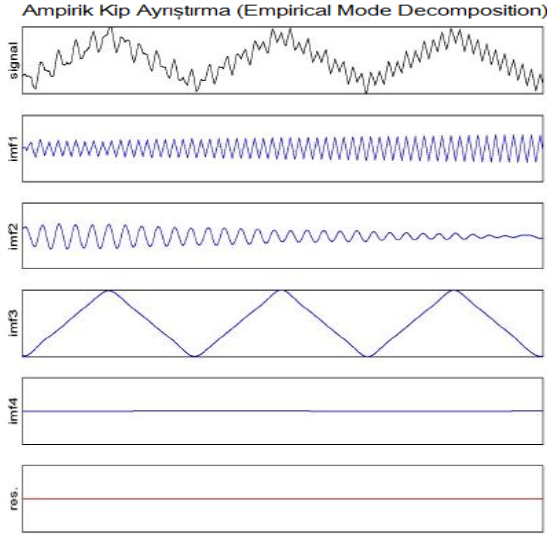
Orijinal bant $B_l(i, j)$, tüm İKF'lerin ve en son kalanın toplanması ile tam olarak geri elde edilir.

$$B_l(i, j) = \sum_{m=1}^M İKF_{l,m}(i, j) + R_M(i, j) \quad (6)$$


AKA dönüşümünün etkili bir şekilde bir sinyalin karakteristiğini ve değişimini nasıl yakaladığı Şekil 2'de gösterilmektedir. Bu şekilde, orijinal sinyal genliği yavaşça büyüyen yüksek frekanslı üçgenel dalgalardan, genliği hızlıca azalan orta frekanslı sinüs dalgalarından ve düşük frekanslı üçgenel dalgalardan oluşmaktadır. Dolayısı ile AKA dönüşümü sonucunda, orijinal görüntülerin, kendisini oluşturan sinyallere başarılı bir şekilde ayrıştığı ve kalanın sıfıra çok yakın olduğu gösterilmiştir.

Şekil3'te ise, 2D-AKA bir görüntüye uygulandıktan sonra elde edilen İKF'ler gösterilmiştir.

Bu çalışmada hem 2D AKA dönüşümünden hem de 1D-DWT'den yararlanarak daha etkin bir şekilde hiperspektral görüntülerin boyutları azaltılmış ve sınıflandırma başarımları diğer boyut indirgeme yöntemleri ile karşılaştırılarak, önerilen metodun üstünlükleri gösterilmiştir.



Şekil 2. 1B-Sinyalin 1B-AKA dönüşümü



Şekil 3. Bir görüntünün 2B-AKA dönüşümü. Sırasıyla orijinal girdi bant, birinci, ikinci, üçüncü ve dördüncü İKF'ler (İKF1, İKF2, İKF3, İKF4)

4. ÖNERİLEN YÖNTEM

Demir ve Ertürk çalışmalarında (Demir, 2010) ilk olarak 2B-AKA ile hiperspektral görüntülerin İKF'lerini bulmuş, daha sonra tüm bantların alt sıradaki İKF'lerini toplayarak yeni öznelikler oluşturmuştur. Son olarak bu öznelikler, hiperspektral görüntülerin sınıflandırma başarımlarını artırmak için kullanılmıştır. Yazarların elde ettikleri sonuçlara göre düşük seviyeli İKF'lerin toplamı, sınıflar arası mesafeyi

arttırdığı için konumsal uzayda daha iyi sınıflandırma başarımı sağlamaktadır.

Önerilen bu çalışmada ise, 2B-AKA dönüşümü kullanarak konumsal bilgiden, 1B-DWT kullanarak spektral bilgiden yararlanılmış ve hiperspektral görüntüler için yeni bir boyut azaltma yöntemi önerilmiştir.

Daha önceki çalışmalarda spektral ve uzamsal bilginin birlikte kullanımının hiperspektral görüntülerde daha yüksek sınıflandırma başarımı verdiği gösterilmiştir (Licciardi, 2009). Bu nedenden dolayı, dalgacık tabanlı İKF özneliklerinin sınıflandırılması diğer yöntemlerden daha yüksek sınıflandırma başarımı vermiştir.

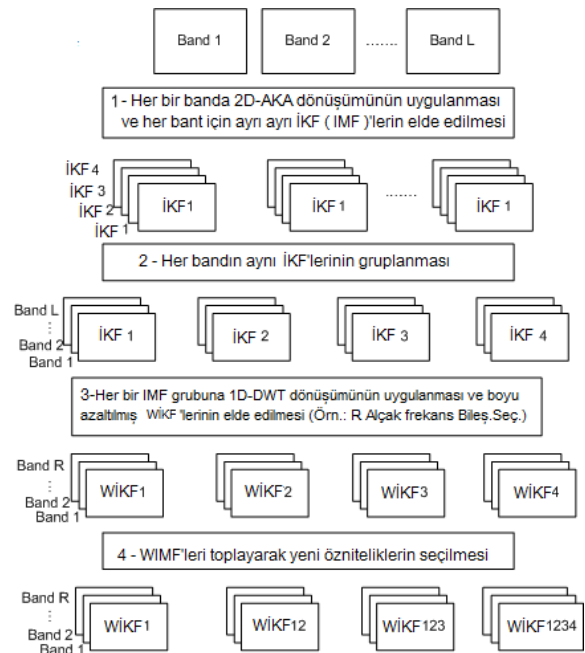
Önerilen metod şu şekilde özetlenmiştir.

- 1.2B-AKA'nın her bir spektral bantta uygulanması ve M derece İKF özneliklerinin oluşturulması
- 2.Elde edilen her bir İKF özneliklerindeki piksellere spektral uzayda 1B-DWT uygulanması, WİKF'lerin elde edilmesi.
- 3.Düşük seviye WİKF'leri toplayarak yeni dalgacık tabanlı İKF'lerin oluşturulması. Örneğin WİKF1 ve WİKF2 toplayarak WİKF12 elde edilmesi.

$$WİKF(1...M)(i, j) = \sum_{m=1}^M WİKF_m(i, j) \quad (7)$$

- 4.Son olarak, dalgacık dönüşümünün tipine göre R kadar öznelik seçilerek sınıflandırmaya girecek WİMF özneliklerinin belirlenmesi.

Önerilen yöntem Şekil 4'te gösterilmiştir. Daha ayrıntılı bilgi (Görmüş, 2012)'de bulunabilir. Bu yöntemin bir dezavantajı işlem zamanının uzun olması ve bunun aynı zamanda sinyalin yapısına bağlı olmasıdır. Diğer taraftan DWT de zaman sinyalinin uzunluğuna ve dönüşüm seviyesine bağlıdır.



Şekil 4. Önerilen yöntemin işlem adımları

4.1 Deneysel Veriler

Bu çalışmada iki farklı hiperspektral görüntü kullanılmıştır. Birincisi çok iyi bilinen AVIRIS Indiana Pine verisidir. Bu görüntü AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) Alıcısı tarafından Kuzey batı Indiana'da çekilmiştir. 145x145 piksel boyutunda ve $0.4-2.5 \cdot 10^{-6}$ metre dalga boyu aralığında 224 tane spektral banda sahiptir. Görüntünün 2/3'ü orman veya diğer doğal bitki örtüsü ile kaplıdır. İki tane duble yol, bir demir yolu ve çok az miktarda evler, küçük yapılar ve küçük yollar içermektedir. Görüntü Haziran ayında çekildiği için mısır, soya fasülyesi gibi tahılların daha yeni yeni yetiştiği görülmektedir. Yer kontrol görüntüsünde 16 sınıf vardır. Çok az elemanı olan bazı sınıflar çıkartılmış ve geriye kalan 9 sınıf bu çalışmada kullanılmıştır. [104-108], [150-163], 220 numaralı bantlar su buharı emme alanlarında oldukları için çıkartılarak geriye kullanılmak üzere 200 kalmıştır.

Kullanılan ikinci hiperspektral veri ise Pavia görüntüsüdür. Bu görüntüler Kuzey İtalya'da Pavia üzerinde ROSIS 03 alıcısı tarafından çekilmiştir. Pavia Üniversitesi görüntüsünün 103 spektral bandı ve 9 sınıfı vardır. Konumsal çözünürlükleri 1.3m dir. Her iki görüntüde de eğitim kümeleri beraberlerinde temin edilen referans görüntülerden elde edilmiştir.

Tablo 1 ve Tablo 2'de sırasıyla İndiana Pine ve Pavia görüntülerine ait sınıflar ve eleman sayıları gösterilmiştir.

Sınıf	Sınıf İsmi	Örnek sayısı
2	Corn no till	1434
3	Corn-min till	834
5	Grass / Pasture	497
6	Grass / Trees	747
8	Hay - windrowed	489
10	Soybean - no till	968
11	Soybean - min till	2468
12	Soybean - clean till	614
14	Woods	1294
	Toplam	9345

Tablo 1. AVIRIS Indiana Pine Görüntüsü için her bir sınıfa ait örnek sayısı

Sınıf	Sınıf İsmi	Örnek sayısı
1	Asphalt	6631
2	Meadows	18649
3	Gravel	2099
4	Trees	3064
5	Bare Soil	1345
6	Metal Sheets	5029
7	Bitumen	1330
8	Bricks	3682
9	Shadow	947
	Toplam	42776

Tablo 2. ROSIS Pavia niversitesi Görüntüsü için her bir sınıfa ait örnek sayısı

4.2 Dalgacık Tabanlı İKF Özniteliklerinin Elde Edilmesi

Bu çalışmada hiperspektral görüntüdeki her bir banda ait İKF'ler 2B-AKA dönüşümü ile elde edilmiştir. Deneylerde kullanılan Pine ve Pavia görüntülerinin her bir bandına 2B-AKA uygulandıktan sonra elde edilen İKF sayıları Tablo 3'te gösterilmiştir.

Görüldüğü gibi İKF öznitelikleri görüntünün bantlarındaki konumsal bilgiye bağlı olduğu için, her iki görüntü için elde edilen İKF sayıları farklıdır. Pine görüntüsünde 3 İKF varken, Pavia görüntüsünde 4 İKF ve 2 adet İKF 5 bulunmaktadır. Bu yüzden Pavia görüntüsünün bantlarının, Pine görüntüsünün bantlarından daha heterojen olduğu anlaşılmaktadır.

İKF öznitelikleri elde edildikten sonra, dalgacık tabanlı İKF'leri elde etmek için İKF'lere 1B-DWT uygulanmıştır. Daha sonra düşük seviyeli WİKF'ler toplanarak sınıflandırılacak yeni öznitelikler bulunmuştur.

AKA dönüşümünde, düşük seviyeli İKF'ler konumsal değişimin hızlı olduğu durumları, yüksek seviyeli İKF'ler ise konumsal değişimin az olduğu durumları göstermektedirler. Dolayısı ile düşük seviyeli İKF'leri toplayarak değişimin en çok olduğu durumlar sınıflandırmaya yeni öznitelik olarak katılmış ve yüksek başarımlar sağlanmıştır.

	İKF1	İKF2	İKF3	İKF4	İKF5
Pine Data	4	170	26	-	-
Pavia Data	-	-	-	101	2

Tablo 3. Görüntü verilerinden 2B-AKA dönüşümü sonucu elde edilen İKF sayıları.

5. DENEYSEL SONUÇLAR

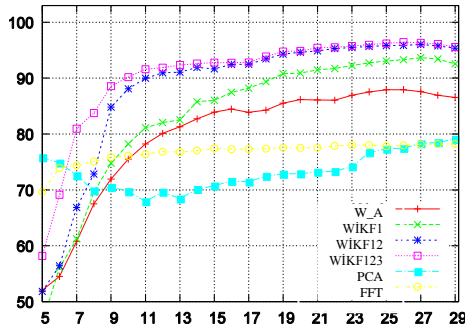
Önerilen yöntemin etkinliği, Destek Vektör Makinaları (DVM) kullanılarak gösterilmiştir. Doğrusal ayrılabilir sınıfları birbirinden ayıran pek çok karar düzlemini bulmak mümkündür. DVM bu karar düzlemlerinden her iki sınıfa uzak olanı, yani iki sınıf arasındaki sınır uzaklığını büyüleyen en uygun ayırt etme yüzeyini belirlemektedir (Demir, 2008). Bu düzleme en yakın vektörler de *destek vektörleri* olarak isimlendirilmektedir. Eğitim örneklerinden elde edilen destek vektörleri sınıflandırma için kullanılmaktadır. Karar (test) aşamasında destek vektörleri kullanılarak test verilerinin hangi sınıfta olduğu ile ilgili kestirim yapılmaktadır. Doğrusal olarak ayrılamayan durumlarda, sınıflardaki her bir vektör, kernel fonksiyonları yardımıyla daha yüksek boyutlu bir uzaya taşır ve elde edilen yeni verinin doğrusal ayrılabilir hale getirilmesini sağlar (Demir, 2008). DVM sadece sınıfların sınırlarına yakın olan örnekleri değerlendirdiği için, eğitim verisi küçük olduğunda da, yada yüksek boyutlu bir veri kümesi kullandığında da yüksek başarımlar vermektedir. Bu çalışmada Radyal Tabanlı Kernel (RTK) kullanılarak DVM sınıflandırması gerçekleştirilmiştir. Sınıflandırma doğruluğu hem eğitim verisi, hem de test verisi için Genel Doğruluk (OA) ve Kappa (k) değerleri ile gösterilmiştir. Çoklu sınıflandırma stratejisi olarak kısa eğitim süresine sahip olan birebir (one against one) metodu kullanılmıştır. Referans görüntüsünden sınıfların %10 eğitim verisi, kalan kısımları ise test verisi oluşturulmuştur.

Bu çalışma içerisinde, deneyler boyunca RTK için γ parametresi, [0.1:0.1:2] aralığında 5 katlı doğrulama kullanılarak en uygun değer seçilmiştir. 2B-AKA dönüşümü için 17x17 'lik bir pencere ve $p=0.006$ durma kriteri olarak seçilmiştir. 1B-DWT dönüşümünde ise, dönüşüm seviyesi $L=3$, ve ana dalgacık olarak db3 seçilmiştir. Sınıflandırmaya girecek R öznitelik sayısı ise, DWT'den sonra elde edilen alçak frekans katsayıları kadar seçilmiştir. Önerilen metotta doğrusal dalgacık öznitelik çıkartma yöntemi kullanılmıştır.


Çalışmada iki grup deney gerçekleştirilmiştir. Birinci grup deneylerde önerilen yöntem, PCA, FFT ve W_T (Dalgacık

dönüşümü) gibi frekans tabanlı boyut azaltma yöntemleri ile karşılaştırılmıştır. İkinci grup deneylerde ise, önerilen metod sadece AKA tabanlı (Demir, 2010) ve W_T (Hsu, 2003) ve (Kewpijit, 2003) yöntemler ile karşılaştırılmıştır. AKA tabanlı yöntemde, 2B-AKA orijinal görüntüye uygulanmış, her bandın İKF'leri bulunmuş ve yeni öznitelikler elde edilen İKF'lerin toplanması ile elde edilerek sınıflandırılmıştır. 1B-DWT tabanlı yöntemde ise, DWT orijinal görüntüye uygulanmış ve daha sonra sadece düşük frekanslı katsayılar yeni öznitelikler olarak seçilmiş (W_A) ve sınıflandırılmıştır. Bu iki yöntemin dışında, orijinal görüntü de hiçbir işleme tabi tutulmadan sınıflandırılmış ve tablolarda gösterilmiştir.

İlk deneyin sonuçları Pine verisi için Şekil 5'de, Pavia verisi için Şekil 6'da gösterilmiştir. Tablolarda, her iki görüntü için önerilen WIKF özniteliklerinin, W_A, FFT ve PCA yöntemlerinden daha iyi sonuç verdiği görülmüştür. Pine görüntüsü için ilk 3 WIKF'nin toplanması sonucu oluşan WIKF123 en yüksek genel doğruluk (GD) (overall accuracy) sınıflandırma başarımı verirken, Pavia için birinci WIKF (WIKF1) en yüksek sınıflandırma başarımı vermiştir. Diğer taraftan Şekil 5'de W_A yöntemi önerilen yöntemden sonra, en iyi sınıflandırma sonucunu veren yöntem olmuştur. W_A ile elde edilen maksimum başarımlar 29 öznitelik ile sağlanırken, aynı başarımlar önerilen yöntem ile sadece 8 WIKF123 ile sağlanmıştır. Şekil 6'da ise, PCA yöntemi sonucu seçilen 17 bandın sınıflandırılması W_A ve FFT yöntemlerinden daha iyi sonuç vermiştir. PCA ile maksimum başarımlar 17 öznitelik ile sağlanırken, aynı başarımlar önerilen yöntemde 8 WIKF1 özniteliklerinin sınıflandırılması ile sağlanmıştır.



Şekil 5: %10 Pine Eğitim verisi kullanarak frekans tabanlı boyut azaltma yöntemleri ile önerilen yöntemin özniteliklerinin DVM ile sınıflandırılması sonucu 29 banda kadar elde edilen GD.



Şekil 6: %10 Pavia Eğitim verisi kullanarak frekans tabanlı boyut azaltma yöntemleri ile önerilen yöntemin özniteliklerinin DVM ile sınıflandırılması sonucu 17 banda kadar elde edilen GD.

İkinci deney sonuçları Pine ve Pavia görüntüleri için sırasıyla Tablo 4 ve Tablo 5'te gösterilmiştir. Önerilen yöntem 2B-AKA, 1B-DWT ve Orijinal görüntü yöntemleri ile boyut indirgemesi yapıldıktan sonraki sınıflandırma başarımları gösterilmiştir. Her iki veride de en düşük başarımlar orijinal görüntünün sınıflandırılması sonucu elde edilmiştir. Tablo 4'te, Pine görüntüsü için en yüksek başarımlar, WIKF123 nolu özniteliklerin sınıflandırılması sonucu elde edilmiştir. Tablo 6'da Pavia görüntüsüne boyut azaltımı yöntemleri uygulandıktan sonra 17 özniteliklerin sınıflandırılması sonucu en yüksek sınıflandırma başarımı önerilen yöntem ile elde edilmiştir. %10 eğitim verisi için WIKF1'nin sınıflandırma sonucu maksimum GD ve k değerlerini vermiştir.


Metotlar		%10 Test		%10 Eğitim	
		GD	k	GD	k
Orijinal Görüntü	Im1	57.98	0.5513	99.89	0.9991
2B-AKA	IKF1	88.08	0.8639	100.00	1.000
	IKF12	91.65	0.9081	100.00	1.000
	IKF123	93.98	0.9347	99.79	0.9979
1B-DWT	w_A	86.54	0.8615	100.00	1.000
2B-AKA + 1B-DWT	WIKF1	92.55	0.9160	100.00	1.000
	WIKF12	95.36	0.9519	100.00	1.000
	WIKF123	95.57	0.9539	100.00	1.000

Tablo 4: Pine görüntüsüne ait sadece alçak frekans katsayılarını ve o sayı kadar (29) öznitelikleri elde eden boyut indirgeme yöntemlerinin önerilen yöntem ile karşılaştırılması.


Metotlar		%10 Test		%10 Eğitim	
		GD	k	GD	k
Orijinal Görüntü	Im1	66.39	0.4432	69.26	0.4931
2B-AKA	IKF1	87.81	0.7833	92.55	0.8830
	IKF12	95.84	0.9313	97.83	0.9707
	IKF123	97.51	0.9584	98.69	0.9835
	WIKF1234	97.47	0.9493	98.22	0.9678
1B-DWT	w_A	91.68	0.8839	92.24	0.8943
2B-AKA + 1B-DWT	WIKF1	98.29	0.9464	98.86	0.9601
	WIKF12	97.12	0.9344	98.74	0.9656
	WIKF123	97.62	0.9370	98.65	0.9584
	WIKF1234	97.78	0.9435	98.83	0.9647

Tablo 5: Pavia görüntüsüne ait sadece alçak frekans katsayılarını ve o sayı kadar (17) öznitelikleri elde eden boyut indirgeme yöntemlerinin önerilen yöntem ile karşılaştırılması.

Görsel değerlendirme için, Pine ve Pavia görüntüleri için sırasıyla Şekil 7'de ve Şekil 9'da önerilen yöntem ve W_A yöntemi ile elde edilen özniteliklerin DVM ile sınıflandırma sonuçları gösterilmiştir. Açıkça görülebileceği gibi, her iki görüntüde de önerilen yöntem ile boyut azaltımı yapılan görüntüler daha yüksek doğruluk ile sınıflandırılmıştır.



Şekil 7. Sırasıyla orijinal Pine görüntüsü, ona ait referans görüntü, aynı sayıda özneliğe sahip olan W_A ve WIKF12 verilerinin sınıflandırma sonuçları.



Şekil 8. Sırasıyla orijinal Pavia görüntüsü, ona ait referans görüntü, aynı sayıda özneliğe sahip olan W_A ve WIKF1 verilerinin sınıflandırma sonuçları.

Deneylerden ve görsel sonuçlardan da anlaşılacağı üzere, önerilen yöntem hem 2B-Aka hem de 1B-DWT avantajlarını birleştirerek elde ettiği özneliklerin oluşumunda hem konumsal hem de spektral bilgiyi aynı anda kullandığı için, diğer yöntemlerden daha fazla sınıflandırma başarımı elde etmiştir.

6. SONUÇLAR

Bu çalışmada 2B-AKA ve 1B-DWT kullanılarak hiperspektral görüntülerin boyutlarının azaltımı için bir yöntem önerilmiştir. Önerilen yöntemin etkinliğini göstermek için RBF kernelini kullanarak DVM sınıflandırması yapılmıştır. Çalışmada Aviris

Pine ve Rosis Pavia University hiperspektral görüntüleri kullanılmıştır. Önerilen yöntem ilk önce sadece 1D_DWT, PCA ve FFT gibi frekans tabanlı dönüşümler ile karşılaştırılmıştır ve %10 eğitim verisi kullanılarak yapılan sınıflandırmada bu yöntemlerin sağladığı maksimum başarı, önerilen yöntemle çok daha az öznelik sayısı ile gerçekleştirildiği görülmüştür. Önerilen yöntemde İKF'ler konumsal uzayda her bir banda 2B-AKA dönüşümü uygulayarak ve daha sonra tüm bantların İKF'lerine spektral uzayda 1B-DWT uygulayarak WIKF'ler elde edilmiştir. Bu şekilde görüntülerin karakteristik özelliklerini taşıyan öznelikleri oluşturmak için hem konumsal hem de spektral bilgilerden yararlanılmıştır. DVM sınıflandırıcısında sınıflandırılan öznelikler ise WIKF'lerin toplanması ile elde edilmiştir. Elde edilen WIKF öznelikleri sadece 2D-AKA, yada sadece orijinal görüntüdeki öznelikler ile karşılaştırıldığında da en yüksek sınıflandırma başarımı verdiği yapılan deneyler sonucu ortaya konulmuştur.

TEŞEKKÜR

Bu çalışma, İngiltere'de bulunan 'Institute of Materials, Minerals and Mining'in verdiği burslar ile (Bosworth Smith Trust, Edgar Pam Fellowship, and the G. Vernon Hobson Bequest) kısmen desteklenmiştir.

KAYNAKLAR

- Backer, S., 2005. Band selection for hyperspectral remote sensing. *IEEE Geosci. Remote Sens. Lett.*, vol. 2, no. 3, pp. 319–323.
- Bruce, L., Koger, C. ve Li, J., 2002. Dimensionality reduction of hyperspectral data using discrete wavelet transform feature extraction. *IEEE Trans. Geosci. Remote Sens.*, vol. 40, no. 10, pp. 2331–2338.
- Chang, C.-I., 2000. An information-theoretic approach to spectral variability, similarity, and discrimination for hyperspectral image analysis, *IEEE Trans. Inf. Theory*, vol. 46, no. 5, pp. 1927–1932.
- Chang, C.-I., Wang, S., Liu, K.-H., Chang, M.-L. ve Lin, C., 2011. Progressive band dimensionality expansion and reduction via band prioritization for hyperspectral imagery. *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens. (JSTARS)*, vol. 4, no. 3, pp. 591–614.
- Chen, J., Wang, C., ve Wang, R., 2009. Fusion of svms in wavelet domain for hyperspectral data classification. *IEEE Int. Conf. Robotics and Biomimetics (ROBIO)*, pp. 1372–1375.
- Demir, B. ve Erturk, S., 2008. Hyperspectral image classification based on Empirical Mode Decomposition, *IEEE 16th Signal Processing, Communication and Applications Conference*, pp. 1-4.
- Demir, B., ve Erturk, S., 2010. Empirical mode decomposition of hyperspectral images for support vector machine classification. *IEEE Trans. Geosci. Remote Sens.*, vol. 48, no. 11, pp. 4071–4084.

Gormus, E.T., Canagarajah,N. ve Achim,A.,2012. Dimensionality Reduction of Hyperspectral Images Using Empirical Mode Decompositions and Wavelets. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, no. 6, pp. 1821-1830.

Hsu, P. H., HsingTseng, Y., ve Gong, P., 2006. Spectral feature extraction of hyperspectral images using wavelet transform. *J. Photogramm. Remote Sens.*, vol. 11, no. 1, pp. 93–109.

Hsu, P.-H., Tseng, Y.-H. ve Gong,P.,2002. Dimension reduction of hyperspectral images for classification applications. *Annals of GIS*, vol. 8, no. 1, pp. 1–8.

Huang, N. E., Shen,Z., Long, S. R. , Wu, M. C., Shih, H. H., Zheng, Q., Yen, N.-C., Tung, C. C. ve Liu, H. H., 1998. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proc. R. Soc. Math. Phys. Sci*, vol. 454, no. 1971, pp. 903–995.

Kaewpijit,S., Le moigne, J. ve El-Ghazawi,V.,2003. Automatic reduction of hyperspectral imagery using wavelet spectral analysis. *IEEE Trans. Geosci. Remote Sens.*, vol. 41, no. 4, pp. 863–871.

Kempeneers, P., De Backer, S. B., Debruyn,W., ve Scheunders,p., 2004. Wavelet based feature extraction for hyperspectral vegetation monitoring. In: *Image and Signal Processing for Remote Sensing IX*, vol. 5238, pp. 297–305, 586, 2004.

Licciardi, G., Pacifici, F., Tuia, D., Prasad, S., West, T., Giacco, F., Thiel, C., Inglada, J., Christophe, E., Chanussot, J. ve Gamba, P., 2009. Decision fusion for the classification of hyperspectral data: Outcome of the 2008 GRS-S data fusion contest. *IEEE Trans. Geosci. Remote Sens.*, vol. 47, no. 11, pp. 3857–3865.

Linderhed, A., 2004. Adaptive Image Compression With Wavelet Packets and Empirical Mode Decomposition. Ph.D. dissertation, Linköping Stud. Sci. Technol., Linköping, Sweden.

Wu, K. and Hsieh, P., 2005. Empirical mode decomposition for dimensionality reduction of hyperspectral data. *Proc. IGARSS'2005*, pp. 1241–1244.

Yang, H. ve Du, Q., 2011. Particle swarm optimization-based dimensionality reduction for hyperspectral image classification. In: *Proc. IEEE IGARSS'11*, pp. 2357–2360.