

# UZAKTAN ALGILANMIŞ GÖRÜNTÜLERDE SINIFLANDIRMA VE ANALİZ

## (CLASSIFICATION OF REMOTE SENSING IMAGES AND ANALYSIS)

**Eminnur AYHAN**  
**Fevzi KARSLI**  
**Esra TUNÇ**

### ÖZET

Sınıflandırma; birçok bilim dalında kullanılan bir karar verme işlemidir. Görüntü sınıflandırma işleminde amaç, bir görüntüdeki bütün pikselleri arazide karşılık geldikleri sınıflar veya temalar içine otomatik olarak atamak, yerleştirmektir.

Bu çalışmada, uzaktan algılanmış görüntülerin sınıflandırmasında kullanılan iki genel yaklaşım, denetimsiz ve denetimli sınıflandırmada kullanılan yöntemler tanıtılmıştır. Denetimli sınıflandırma yöntemleri istatistiksel kavramlara dayalı yöntemleri ve yapay sinir ağlarına dayalı yöntemleri içerir. Ayrıca fuzzy sınıflandırıcılar ve sınıflandırmada doğruluk analizi konusu ele alınmıştır.

### ABSTRACT

Classification is a decision process used in several subdivision sciences. The overall objective of image classification procedures is to automatically categorize all pixels in an image into land cover classes or themes

In this study, two general approaches used in classification of remote sensed images are presented; methods used in the supervised and unsupervised classification were introduced. Supervised methods include those based on statistical concepts and those based on artificial neural-networks. Besides, fuzzy classifiers and classification accuracy subject were described.

### 1. GİRİŞ

Sınıflandırma işleminde iki aşama söz konusudur. Birincisi yeryüzündeki gerçek nesne sınıflarının tanımlanması. Bu aşamada tanımlanacak arazinin veya nesnenin yapısı ve sınıf sayısı için bir öncül değer belirlenir. İkinci aşamada, genelde sınıflandırma kuralı veya karar kuralı olarak bilinen karar verme işlemi kullanılarak piksellere özellikleri doğrultusunda sayısal etiket verilir. Uzaktan algılamada sınıflandırma, genel olarak nesnelerin farklı spektral yansımalarına dayandırılır. Her piksel için değişik bantlardaki değerler esas alınarak, belirlenen bir matematiksel işlem sonucu o pikselin ait olduğu sınıf bulunur.

Kümeleme (clustering) işleminde ise tanımlanacak arazi yüzeyi için sınıflar grubunun belirlenmesi gerekmez. Kümeleme; görüntü alanında başlangıçta belli olmayan farklı arazi sınıflarının sayısını belirlemeyi amaçlayan ve pikselleri bu sınıflara tahsis eden bir araştırma işlemidir.

Piksel etiketlemede kullanılan bu iki yaklaşım, uzaktan algılamada eğitilmiş (supervised) ve eğitimsiz (unsupervised) sınıflandırma işlemi olarak bilinir. Ancak bütün durumlarda

sınıflandırılacak pikselin özellikleri, bu pikseli etiketlemek için kullanılır. Bu yöntemlerde genellikle spektral veri kullanılır. En basit şekilde bir piksel, elemanları onun her bir spektral banttaki gri seviyeleri olan bir vektör tarafından tanımlanır. Bu vektör pikselin spektral özelliklerini gösterir. Birçok spektral bantta ölçülmüş tek bir piksel için gri-skala değerleri grubu, desen (pattern) olarak adlandırılır. Deseni tanımlayan spektral bantlar veya içerik (context) ve doku (texture) gibi pikselin diğer nitelikleri, özellikler (features) olarak adlandırılır. Desen, sınıflandırılacak eleman için seçilen özellikler üzerindeki ölçüler grubudur. Bu yüzden sınıflandırma işlemi bir desen tanıma şekli olarak değerlendirilebilir. Görüntü verisinden çıkartılan ilave özellikler, çoğu durumda sınıflandırma işlemi daha da geliştirmek için kullanılır. Bir fotoğrafik görüntünün görsel analizi, tonu ve dokusuna ilave olarak objenin içeriğinin değerlendirilmesini de kapsar. İçerik bir objenin yakınındaki objelerle ilişkisidir.

## 2. UZAKTAN ALGILANMIŞ GÖRÜNTÜLERDE SINIFLANDIRMA YÖNTEMLERİ

### a. Eğitimsiz Sınıflandırma

Sınıfı bilinen yeterince örnek piksel, ya da bunlarla ilgili olasılık dağılım bilgisinin bulunmadığı durumlarda, kümeleme denen yöntemler kullanılarak yapılan sınıflandırmalara eğitimsiz sınıflandırma adı verilir. Bu sınıflandırmada, her spektral sınıftan gelen verilerin özellik uzayında kümeler oluşturacağı varsayımı ile veriler incelenerek kümelenecekler aranır ve her küme bir sınıf olarak tanımlanır. Eğitimsiz sınıflandırma genel olarak iki adımdan oluşur.

Birinci adımda veri kümelere ayrılır. Benzer yeryüzü nesnelere yansıyan spektral değerler yakın bir gruplaşma gösterir. Eğitimsiz sınıflandırma sonucu oluşan sınıflar spektral sınıflardır. İkinci adımda, daha büyük ölçekli görüntü veya harita gibi referans verileri ile bu spektral sınıflar karşılaştırılarak hangi yeryüzü gerçeğine karşılık geldikleri belirlenir.

Verilen bir veri grubundaki doğal spektral grupları belirlemek için kullanılacak çok sayıda kümeleme algoritması vardır. En genel kümeleme şekillerinden biri “K-means” K-ortalama yöntemidir. Algoritmada, çok boyutlu ölçü uzayındaki küme merkezleri keyfi olarak konumlandırılır ve görüntüdeki her bir piksel daha sonra keyfi ortalama vektörüne en yakın olan kümeyle atanır. Bütün pikseller bu tarzda sınıflandırıldıktan sonra, kümelerin her biri için ortalama vektörler tekrar hesaplanır. Hesaplanmış ortalama görüntü verisini tekrar sınıflandırmak için kullanılır. İşlem, iterasyonlar arasındaki ortalama sınıf vektörleri konumlarındaki değişim önemsiz olana kadar devam eder. Bu aşamaya ulaşıldığında, her bir spektral sınıfın arazi karşılığı tanımlanır.

Bu yaklaşım iteratif olduğundan hesaplar zaman alıcıdır. Bu yüzden yöntem tüm görüntü yerine, görüntü alt alanlarına uygulanır. Böylece alt alanlar eğitimsiz araştırma alanları olarak ifade edilir ve bu araştırma alanları eğitilmiş yaklaşımdan farklıdır. Eğitilmiş sınıflandırmada bu alanlar homojen bölgelerde seçilirken, eğitimsiz araştırma alanları farklı yeryüzü şekillerini bulduracak şekilde heterojen bir yapıda belirlenir. Bu, bütün spektral sınıfların değişik alt alanlarda belirlenmesini sağlar. Bu alanlar bağımsız bir şekilde kümelendirilir ve değişik alanlardaki spektral sınıfları tanımlamak için istatistiksel analiz uygulanır. Benzer arazi tiplerini gösteren benzer kümeler birleştirilir. İstatistiksel araştırma, birleştirilmiş sınıflar ve tüm görüntü sınıflandırması için kullanılır (Bir minimum uzaklık veya en yüksek olasılık

algoritması). Bu yaklaşım eğitilmiş ve eğitimsiz analiz elemanlarının her ikisini de içerdiği için melez (hybrid) sınıflandırma olarak adlandırılır /3/.

## b. Eğitilmiş Sınıflandırma

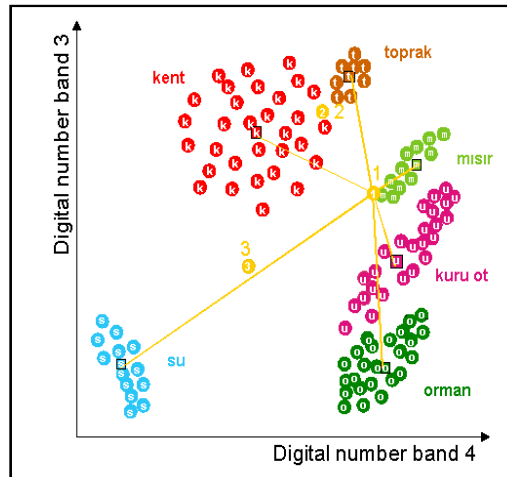
Eğitilmiş yaklaşımda önce yararlı bilgi sınıfları (eğitim alanları) belirlenir, daha sonra onların spektral ayırt edilebilirliği incelenir. Eğitimsiz yaklaşımda ise spektral olarak ayrılabilen sınıflar belirlenir ve daha sonra bu spektral sınıflara ait bilgi tespit edilir. Eğitilmiş sınıflandırma; eğitim aşaması, sınıflandırma aşaması ve çıktı aşaması şeklinde üç adımdan oluşur.

Eğitim aşaması (training stage); bu aşamada incelenecek alanda bilinen sınıfları temsil edecek eğitim alanları seçilir. Bu alanlar, sınıflandırmada kullanılacak her bilgi sınıfı için yeterli düzeyde homojen ve temsil edici şekilde belirlenir. Eğitim alanları her özellik tipi ile ilgili spektral özellikleri tanımlayan bir sayısal yorumlama anahtarı (interpretation key) düzenlemek için kullanılır.

Sınıflandırma aşaması (classification stage); görüntüdeki her piksel sayısal olarak yorumlama anahtarı içindeki her bir sınıf ile karşılaştırılarak, sınıflardan en çok hangisine benzediği saptanır ve ilgili sınıfın adı ile etiketlenir. Bilinmeyen pikseller ve araştırma seti pikselleri arasındaki bu karşılaştırmayı yapmak için kullanılacak çok sayıda sayısal yöntem vardır. Bu çalışmada istatistiksel kavramlara dayalı sınıflandırma yöntemleri olarak; Ortalamaya En Az Uzaklık Yöntemi, Paralel kenar Yöntemi, En Yüksek Olasılık Yöntemi ve ayrıca Yapay Sinir Ağlarına dayalı yöntemler sunulmuştur.

Çıktı aşaması (output stage); çıktı ürünleri sınırsız sayıda üretilebilir. En yaygın kullanılan çıktı formları; grafik ürünler, çizelge çıktı ürünler ve sayısal bilgi dosyaları şeklindedir.


### (1) Ortalamaya En Az Uzaklık Yöntemi



Şekil-1: Ortalamaya En Az Uzaklık Yöntemi /7/

Yöntemde, öncelikle her bir sınıfın tüm bantlardaki ortalama parlaklık değeri hesaplanır. Bu değerler her bir sınıfa ait ortalama vektörü oluşturur. Sınıflara ait bu ortalama değerler Şekil-1 üzerinde siyah çerçeveli kareler ile gösterilmiştir. sınıfların kovaryans matrislerinin eşit olduğu varsayımı ile sınıfı bilinmeyen bir piksel sınıf ortalamaları ve bilinmeyen pikselin değeri arasındaki uzaklık hesaplanarak sınıflandırılabilir. Bu işlem sonucu her piksel n boyutlu uzayda, kendisine en yakın ortalama vektöre sahip sınıfa atanır. Şekil-1’de 1 numaralı bilinmeyen pikselin her bir sınıf ortalama değerine olan uzaklığı çizgilerle gösterilmiştir. Bu yöntemde göre 1 numaralı piksel mısır sınıfına aittir. Eğer piksel herhangi bir sınıf ortalamasından önceden belirlenmiş bir uzaklık, eşik (threshold) değerinden daha uzaksa bu piksel bilinmeyen olarak sınıflandırılır /3/.

## (2) Paralel Kenar Yöntemi



Şekil-2 :(a) Paralel Kenar Yöntemi (b) Basamaklandırılmış Paralel Kenar Yöntemi /7/

Bu yöntemde, her sınıf için eğitim alanlarındaki sınıf varyanslarına dayalı parlaklık değerlerinin sınırları belirlenir. Bu sınırlar her bir bant için en yüksek ve en düşük parlaklık değerleri ile tanımlanır. Bu sınır değerleri iki boyutlu özellik uzayında paralel kenarlarla ifade edilen bir alan olarak ortaya çıkar. Bilinmeyen bir piksel bu sınır değerleri kullanılarak oluşturulan karar bölgelerine göre sınıflandırılır. Eğer piksel bütün karar bölgelerinin dışında kalıyorsa bilinmeyen olarak sınıflandırılır. Paralel kenarlı bölgelerin çok boyutlu olanları paralel yüzler (paralelepeds) olarak adlandırılır.

Kovaryans ifadesi spektral sınıfların eğilimini ifade eder. Örnekteki mısır ve kuru ot sınıfları pozitif kovaryansa sahip, bunlar sağa eğilimlidirler. Su sınıfı negatif kovaryansı gösterir, bu da sola eğilimlidir. Kent sınıfı özellik uzayı üzerinde yaklaşık dairesel dağılımdadır. Bu da kent sınıfındaki değerler arasında kovaryansın bulunmadığını gösterir. Kovaryansın varlığı durumunda eğitim aşamasında elde edilen verilerden oluşturulan karar bölgelerini paralel kenarlar ile ifade etmek yetersiz kalabilir. Üst üste binmeler ile sıkça karşılaşılır.


Şekil-2' de çok tekrarlanan toprak sınıfı, daha değişken kent sınıfı için tanımlanandan daha küçük karar bölgeleri ile gösterilir. Bundan dolayı 2 numaralı piksel kent olarak sınıflandırılır. Bununla beraber, tanımlanmış sınıf sınırları üst üste bindiğinde zorluklarla karşılaşılır. Üst üste binen kısımlarda meydana gelen bilinmeyen piksel gözlemleri şüpheli olarak sınıflandırılır yada iki üst üste binen sınıflardan birine (yada her ikisine) keyfi olarak atanır.

Spektral desenler çoğu kez yüksek korelasyona sahiptir. Ortaya çıkan bu problem farklı karar bölgeleri için tanımlanmış bir tek paralel kenarı, bir dizi basamaklandırılmış sınırlara sahip paralel kenarlar ile değiştirmek suretiyle bir ölçüde azaltılabilir. Bu yaklaşım Şekil-2 (b)'de gösterilmiştir /3/. Daha karmaşık bir çözüm şeklinde ise, üst üste çakışma bölgesinde kalan piksellerin paralel kenar merkezlerine olan öklit uzaklıkları hesaplanır ve piksel en yakın paralel kenara atanır /4/.

### (3) En Yüksek Olasılık Yöntemi

En yüksek olasılık yönteminde, bilinmeyen bir pikselin sınıflandırılmasında sınıflandırılacak spektral desenlerin hem varyansı hem de kovaryansı değerlendirilir. Bu değerlendirme sırasında, nokta kümelerinin normal dağılımda olduğu varsayılır. Bu varsayım altında sınıf deseninin dağılımı, ortalama vektör ve kovaryans matrisi yardımı ile tanımlanabilir. Herhangi bir pikselin, örnek sınıflardan herhangi birisinde yer alma olasılığı istatistiksel olarak hesaplanabilir /2/.

Şekil-3 özellik uzayı üzerinde çizilmiş 3 boyutlu olasılık değerleri değişim grafiğini göstermektedir. Burada düşey eksen, herhangi bir pikselin herhangi bir sınıfa dahil olma olasılığını göstermektedir. Bu şekilde elde edilen eğriler olasılık yoğunluk fonksiyonları (probability density functions) olarak adlandırılır /3/.

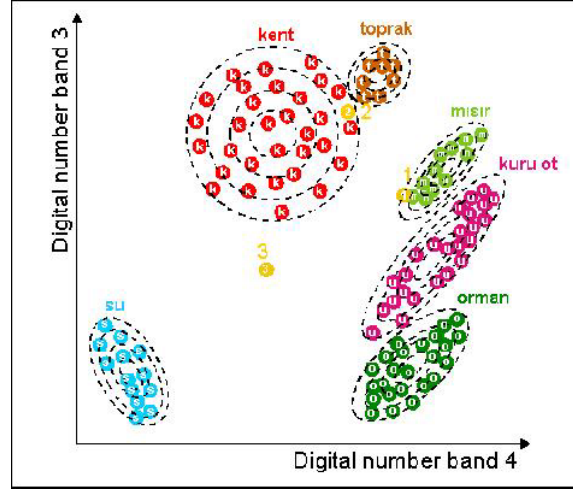


Şekil-3 : En Yüksek Olasılık Yöntemi İle Tanımlanan Olasılık Yoğunluk Fonksiyonları

Olasılık yoğunluk fonksiyonları, her piksel değerinin, herhangi bir sınıfa dahil olma olasılığını hesaplamak için kullanılır. Her bir sınıf için olasılıkların değerlendirilmesinden

sonra, piksel bunlardan en olası sınıfa atanır. Eğer pikselin herhangi bir sınıfa ait olma olasılığı, belirlenen bir eşliğin altında ise bilinmeyen olarak sınıflandırılır.

Esas olarak en yüksek olasılık sınıflandırması yöntemi, dağılım diyagramı üzerinde elipsoid eş olasılık konturlarını belirler. Bu karar bölgeleri Şekil-4'de gösterilmiştir. Eş olasılık konturlarının şekli en yüksek olasılık sınıflandırması yönteminin korelasyona duyarlılığını göstermektedir. Bu duyarlılık nedeni ile 1 numaralı piksel doğru olarak mısır sınıfında yer almıştır /2/.



Şekil-4: En Yüksek Olasılık Sınıflandırması /7/

En yüksek olasılık sınıflandırma yönteminin gelişmiş bir şekli Bayesian sınıflandırıcısıdır. Bu teknik, olasılık tahminleri için iki ağırlık faktörü kullanır. İlk olarak, bir ön olasılık belirlenir ve bu değer verilen görüntüdeki her sınıf için beklenen meydana gelme olasılığıdır. İkincisi yanlış sınıflandırma değeri ile ilişkili bir ağırlık her sınıfa uygulanır. Bu iki faktör birlikte optimum sınıflandırmayı oluşturur /3/.

En yüksek olasılık yöntemi sınıflandırmasında kullanılan eşitlikler aşağıda özetlenmiştir.  $w_i$  i.inci sınıfı,  $j=1,2,\dots,M$  görüntü üzerindeki sınıf sayısını gösterdiğinde,

$$g_i(x) \geq g_j(x) \text{ ise } j \neq i \text{ için } x \in w_i \quad (1)$$

(1) eşitliğinde verilen sınıflandırma kuralına göre,  $x$ 'in  $i$  sınıfına ait olduğuna karar verilir /5/. Olasılık yoğunluk fonksiyonu, ortalama vektör ve kovaryans matrisini ifade eden eşitlikler;

$$p(x|w_i) = (2\pi)^{-n/2} * |S_x|^{-0.5} * \exp \left[ -0.5 \left( (x - m_i)^T S_x^{-1} (x - m_i) \right) \right] \quad (2)$$

$$m_i = \frac{1}{K} * \sum_{k=1}^K x_k \quad ; \quad S_x = \frac{1}{K-1} * \sum_{k=1}^K \left( (x - m_i)^T * (x - m_i) \right)$$

şeklinde verilir.

$p(x|w_i)$  = Sınıf-koşullu olasılık dağılım fonksiyonu (olasılık yoğunluk fonksiyonu)

$x$  = Piksel vektörü

$| |$  = Determinant

$m_i$  = Sınıf ortalaması

$n$  = Kullanılan bant sayısı (pikselin boyutu)

$S_x$  = Varyans - kovaryans matrisi

$(x - m)^T S_x^{-1} (x - m)$  = Mahalanobis uzaklığı

$K$  = Bir sınıfta bulunan toplam piksel sayısı

Bayes teoremi sınıflandırma kuralına göre düzenlendiğinde;

$$\frac{p(x | w_i) * p(w_i)}{p(x)} > \frac{p(x | w_j) * p(w_j)}{p(x)} \quad j \neq i \quad \text{için} \quad x \in w_i \quad (3)$$

(3) formülü elde edilir. Formülde exponansiyel terimden kaçınmak için her iki tarafın doğal logaritması alınır.

$$g_i(x) = \ln \{ p(x | w_i) * p(w_i) \} = \ln p(x | w_i) + \ln p(w_i) \quad (4)$$

(4) eşitliğinde, olasılık yoğunluk fonksiyonu yerine yazılır ve bir takım kısaltmalar yapıldığında sınıflandırma için kullanılacak eşitlik elde edilir.

$$g_i(x) = - \ln | S_x | - (x - m_i)^T S_x^{-1} (x - m_i) \quad (5)$$


Elde edilen (5) eşitliği her bir piksel için hesaplanır. (1) ifadesinde yerine konularak sınıflandırma yapılır.

### c. Yapay sinirsel ağ sınıflandırıcıları (Neural Classifiers)

Yapay sinirsel ağlar (Artificial Neural Network) insan beynindeki sinir hücrelerinin (neronların) çalışma prensiplerine benzer bir yapı sergiler. Bu ağlar, her biri diğer birçok birim ile ağırlıklı bağlantılar kullanan tekli birimden oluşur. Bu birimlerin çıktısı ağda bir ilerdeki birime aktarılır.

Her bir işlem birimi (sinir hücresi), diğer birimlerden gelen ağırlıklı verileri alan, bu ağırlıklı verileri toplayan, bu toplam üzerinde karar verme, kıyaslama (thresholding) işlemi şeklinde basit bir hesaplama oluşturan ve daha sonra bu sonucu diğer birimlere çıktı olarak gönderen basit bir bilgisayardır /4/.

Yapay ağlardaki her bir işlem birimi Şekil-5'de gösterildiği gibi modellenenir. Yapay işlem birimlerinin iki fonksiyonu; ağırlıklı girdileri, verileri toplamak ve bu toplama bir karar fonksiyonu uygulamaktır.



Şekil-5 : Bir işlem biriminin(neron) gösterimi

Toplama işlemi;

$$n = w_{1,1} * i_1 + w_{1,2} * i_2 + \dots + w_{1,R} * i_R + b = \underline{w} * \underline{i} + b \quad (6)$$


şeklinde ifade edilir. Burada  $w_R$  R inci veri ile ilgili ağırlık,  $i_R$  R inci verinin değerini, b ilave olarak ayarlanabilir bir öngörü değeri, n toplam çıktı, f ağ verisini işlem birimi çıktısına çeviren bir karar fonksiyonunu ifade eder. Burada  $\underline{w}$  ve  $\underline{i}$  vektör yapıdadır.

İşlem birimi çıktısı,

$$o = f(\underline{w} * \underline{i} + b) \quad (7)$$

şeklinde hesaplanır.

Karar işlemi en basit şekli ile (n) ve bir ön-koşul değer (T) arasındaki bir karşılaştırmadır. Eğer n T den büyük ise o zaman işlem birimi ileri yönde, önünde bağlantılı olduğu diğer işlem birimlerine bir çıktı göndererek cevap verir. Bilgi başlangıç girdilerinden final çıktılara ilerletildiği için bu tür yapay sinirsel ağ modelini tanımlamada öne, ileri beslemeli (feed-forward) terimi kullanılır. Karar fonksiyonu, çıktıyı şekillendirmek için birçok şekilde olabilir. En yaygın fonksiyonlar; lineer (doğrusal), logsigmoid ve binary (ikili birim) fonksiyonlarıdır.



Şekil-5 : Üç yaygın karar fonksiyonu




Doğrusal karar fonksiyonunda çıktılar, girdinin basit lineer fonksiyonudur. İkili birim karar fonksiyonu negatif girdiler için  $-1$  ve pozitif girdiler için  $+1$  çıktıları iken, log sigmoid fonksiyon 0 ile 1 arasında çıktı değerleri ile girdinin doğrusal olmayan bir fonksiyonudur /1/.

Yaygın olarak bir işlem birimi birçok girdi verisi olsa bile yeterli olmayabilir. Tabaka yapılı Yapay Sinirsel Ağlar (YSA) gerekir. İşlem birimlerinin ilişkili bağlantı grupları, yararlı bir iş oluşturulmadan önce bazı araştırmalar (training) gerekir. Öğrenme, araştırma(eğitim) örnekleri sağlanarak ve beklenen çıktı ile yapay sinirsel ağın gerçek çıktısı karşılaştırılarak gerçekleştirilir. İkisi arasında fark varsa o zaman YSA'ı oluşturan işlem birimleri arasındaki bağlantılarla ilgili ağırlıklar, doğru bir karar şansını artırmak ve yanlış seçim şansını düşürmek için dengelenir, ayarlanır. Ağırlıklara başlangıçta rasgele değerler verilir. Bu eğitilmiş öğrenme işlemine YSA için doğru cevap elde edilinceye kadar devam edilir. Bu basit model, tek tabaka (single layer perceptron) algılayıcı olarak adlandırılır ve o sadece basit örnekleri tanıma yeteneğine sahiptir.

Bugün en çok bilinen ve yaygın olarak kullanılan, birçok öğrenme algoritmasının geliştirildiği ve geniş bir şekilde analiz yeteneğine sahip (Multilayer Perceptron) çoklu tabaka algılama ağlarıdır. Bu ağlar çoklu tabakalar içinde organize edilmiş çok sayıda birimi içeren genel amaçlı, esnek, doğrusal olmayan modellerdir. Çoklu tabaka algılama ağları girdi vektörleri ve onların çıktıları arasındaki ilişki şekilleri hakkında çok az veya hiç bilgi olmadığı problemlerde değerli araçlardır.

Çoklu tabaka yönteminde sıklıkla bir sigmoid fonksiyon kullanılır ve işlem birimi çıktı değerleri 0 ile 1 arasında bir değerdir. Ayrıca YSA'ları oluşturan işlem birimleri Şekil-6'da gösterildiği gibi tabakalar şeklinde düzenlenir.



Şekil-6 : Çoklu-tabaka algılama. Girdi tabakası, çıktı tabakasına aradaki gizli(merkez) tabaka ile bağlantılıdır.

Bu ağlar, tipik olarak üç veya daha çok işlem birimli tabakalar gerektirir. Sınıflandırma işleminde kullanılmış değişik girdileri (uydu kanal değerleri) kabul eden bir girdi tabakası bir veya daha çok gizli tabaka ve her sınıf için işlem birimli bir çıktı tabakasından oluşur /4/.

Bu tür ağlarda, bir girdi örneğinden veri sunulduğu zaman, çıktı işlem birimlerinin her birinde bir çıktı değeri hesaplanıncaya kadar, ağın girdi tabakasındaki işlem birimleri ardışık tabakalarda hesaplamalar oluşturur. Bu ağların araştırması normal olarak eğitilmiş tarzda

oluşturulur. Araştırma örneği olarak adlandırılan belirli bir araştırma veri piksel vektörü ağ içerisinde oluşturulur ve bu araştırma örneği  $i$  sınıfının üyesi olduğu bilinir. Ağ çıkışı, çıktı tabakasındaki her bir işlem birimi için bir değer içerir. Olası  $k$  sınıf varsa o zaman beklenen çıktı vektörü  $(o)$ ,  $1$ 'e eşit olması gereken  $i$  inci elemanı hariç sıfıra eşit elemanlara sahip olmalıdır. Gerçek çıktı vektörü  $(a)$  beklenen çıktı vektörü  $(o)$ 'dan hata  $(e)$  olarak adlandırılan bir miktar kadar farklıdır.

$$e = \frac{1}{2} \sum_{j=1}^k (o_j - a_j)^2 \quad (8)$$

Çoklu tabaka ağlar geri yayımlı (backpropagation) araştırma algoritması ile araştırılabilir. Bu algortmada, arzu edilmiş ve ağın gerçek çıktıları arasındaki farkın, karesel ortalamasına eşit bir değer fonksiyonunu minimum yapmak için bir (gradient) eğim araştırma tekniği kullanılır /1/. Hata, ağırlık değerlerine karşılık gelen hata dağılımı yardımı ile ağırlıkları dengelemek, ayarlamak için kullanılır. Bu fikir en dik iniş (steepest descent) yöntemi olarak bilinir. Bu yöntem, eğim yönü ve alınması gereken adımın uzunluğunu gerektirir. Eğim, ağırlıklar açısından hatanın ilk türevi yardımı ile ölçülür. Türev, eğimin yönünü ve miktarını verir. Adım uzunluğu bellidir ve YSA terminolojisinde öğrenme oranı olarak adlandırılır. Hata, ağ içerisinde çıktı tabakasından girdi verisine geriye doğru iletilir. Bu yüzden geri iletim, yayılım terimi kullanılır /4/.

#### **d. Fuzzy Sınıflandırıcılar**

Kesin sınıflandırma işleminde, her bir veri sadece bir kümeyle atanır. Ancak pratik uygulamalarda sınıflar tümüyle ayrı değildir ve karşılıklı olarak tek gruba ait değildir. Belirsizlik derecesine ve kesin olmama derecesine bağlı olarak bazı örtüşmeye sahiptir. Böyle belirsizlikler fuzzy olarak ifade edilir ve bu belirsizlikler iki sınıf arasındaki sınır boyunca kolayca izlenebilir. Gerçek veri gruplarının gösterimi, fuzzy kümeleme yöntemleri yardımı ile daha doğru bir şekilde ele alınabilir /6/.

Esnek (soft) veya fuzzy sınıflandırıcı her görüntü pikselini tek bir sınıfa kesin bir şekilde atamaz. Bunun yerine, her bir piksele, her bir sınıf için "üyelik derecesi" verilir. Üyelik derecesi 0 ile 1 arasında değişir ve pikselin belirli sınıfa ait olma veya benzerlik derecesinin bir ölçüsünü verir. Burada üyelik derecesinin olasılığa karşılık geldiği söylenebilir. Fuzzy kelimesi bir yaklaşıklık ifade eder. Üyelik derecesi 1 olan bir obje şüphesiz olarak gruba aittir ve üyelik dereceleri 0 olanlar tam olarak gruba ait değildir. Ancak 1 ile 0 arasında üyelik derecesine sahip objeler kısmen aynı gruba aittir. Üyelik derecesi ne kadar büyükse objenin gruba ait olması da o kadar fazladır.

En çok kullanılan eğitimsiz (denetimsiz) fuzzy sınıflandırmalarından biri, ortalama fuzzy-c kümeleme algoritmasıdır. Ortalama fuzzy-c sınıflandırma, değişik örtüşmeli sınıflar içindeki verinin sınıflandırması için geniş bir şekilde kullanılır. Gerçekte bu kesin sınıflandırmanın genişletilmiş şeklidir. Tek fark aynı sınıf içinde olsa bile farklı verinin bu sınıfa ait olması, farklı üyelik dereceleri ile ifade edilir.

Ortalama fuzzy-c sınıflandırma algoritmasının temel fikri, aşağıdaki gibi belirtilebilir.  $U$ ,  $n$  kolonlu (her piksel için bir tane) ve  $p$  satırlı (her küme için bir tane) üyelik derecesi matrisidir.

$$U = \begin{bmatrix} u_{11} & \dots & u_{1n} \\ \dots & & \dots \\ \dots & & \dots \\ u_{p1} & \dots & u_{pn} \end{bmatrix} \quad (9)$$

U matrisinin her bir elemanı  $u_{ij}$ , 0-1 aralığında olmalıdır. P küme sayısı kullanıcı tarafından belirlenir ve küme merkezinin başlangıç konumu, ya rasgele yada kullanıcının önerileriyle oluşturulur.  $i$  pikselinden  $j$  küme merkezine olan öklit uzaklığı aşağıdaki gibi belirlenebilir.

$$d_{ij} = \sqrt{\sum_{l=1}^k (x_{il} - c_{jl})^2} \quad (10)$$

$$c_{jl} = \frac{\sum_{i=1}^n u_{ji}^m x_{il}}{\sum_{i=1}^n u_{ji}^m} \quad (11)$$

$c$  (küme) merkezleri (11) eşitliğinden hesaplanır. Bu  $j$  merkeziyle ilgili olan tüm piksellerin basit bir ağırlıklı ortalamasıdır ( $1 \leq j \leq p$ ).  $x_{il}$  terimi  $i$  inci pikselin ( $1 \leq i \leq n$ )  $l$  inci spektral bandı veya özelliği üzerindeki ölçümüdür.  $m$  üstel bir terimdir.

$u_{ij}$  üyelik derecelerinden her biri, her bir küme merkezinden olan öklit uzaklığına göre geliştirilir.

$$u_{ij} = \frac{1}{\sum_{c=1}^p \left( \frac{d_{ij}}{d_{cj}} \right)^{2/(m-1)}} \quad (12)$$

U'nun kolonları fuzzy kümeleri (U satırları) üzerindeki pikseller için üyelik derecelerini gösterir. Defuzzyfication işlemi, en büyük değeri içeren U'nun  $i$  kolonundaki elemanı seçilerek  $i$  pikselinin küme üyeliğini belirlemek için kullanılabilir. Alternatif olarak ve belki daha aydınlatıcı olarak, sınıf başına 0-1 'den 0-255 'e kadar üyelik derecesi ölçeklendirilerek bir grup sınıflandırılmış görüntü üretilebilirdi. Eğer bu yapılırsa üyelik derecesi 1'e yakın olanlar beyaz, 0'a yakın olanlar siyah görünür. Sınıflandırılmış görüntünün renk bileşimleri sınıf üyeliklerine göre yorumlanabilir. Böylece, eğer 1 sınıfı kırmızı ile, 2 sınıfı yeşil ile, gösterilirse sarı piksel sınıf 1'e ait olduğu kadar, sınıf 2'ye de ait olacaktır /4/.

### 3. SINIFLANDIRMADA DOĞRULUK ANALİZİ

Doğruluk analizi, eğitim alanı olarak ayrılan bölgeler dışında kalan test alanlarına ilişkin piksel değerlerinin, referans kabul edilen, haritalar yada arazi hakkında kesin bilgi veren bir kaynakla istatistiksel olarak karşılaştırma ilkesine dayalı bir kontrol yöntemidir /2/.

Hatalar, piksellerin yanlış sınıflandırılmasından dolayı oluşmaktadır. Analizde hata derecesi yerine doğruluk derecesi de araştırılabilir. Eğer çok sayıda sınıflandırılmamış piksel varsa, eğitim veri setlerinin gerçeği temsil etme oranları düşer. Sınıflandırmada doğruluk derecesinin gösterilmesinde en yaygın kullanılan metot k\*k düzensizlik, hata (confusion) matrisinin oluşturulmasıdır. Matris referans verileri, yani yer gerçeği kullanılarak oluşturulur /4/.

Tablo 1: Test Alanlarına İlişkin Sınıflandırma Performansı, Hata Matrisi

		Sınıflara Ayrılmış Piksel Sayısı										
		Sınıflar	1	2	3	4	5	6	I	II	III	IV
Bilinen Sınıf Tipi Referans Verisi	1	50	3	0	0	2	5	60	83.3	10	21	
	2	4	62	3	0	0	1	70	88.5	8	10	
	3	4	4	70	0	8	3	89	78.6	19	6	
	4	0	0	0	64	0	0	64	100.0	0	3	
	5	3	0	2	0	71	1	77	92.2	6	10	
	6	10	3	1	3	0	33	50	66.0	17	10	
V		71	72	76	67	81	43	410		60	60	
		1-Su	2- Toprak	3-Orman	4-Kent	5-Mısır	6-Kuru ot					

Tablo 1’de;

- I = Satır toplamı ; II = Her bir sınıfın yüzde olarak sınıflandırma doğruluğu,
- III = Referans verisinde i sınıfına ait olan, fakat sınıflandırma sonucu i sınıfına atanmamış piksel sayısı,
- IV = Sınıflandırma sonucu i sınıfına atanmış olan, fakat referans verisinde i sınıfında olmayan piksel sayısı
- V = Sütun toplamını ifade eder.

Matrisin i satırının i. elemanı (i. köşegen eleman) sınıflandırıcı tarafından doğru etiketlenmiş olan ve operatör tarafından i sınıfına dahil edilen piksellerin sayısını içermektedir, aynı satırın diğer sütunlarındaki elemanlar yanlış olarak sınıflandırılmış piksellerin sayısını ve dağılımını göstermektedir. i sınıfının doğruluk derecesi, köşegen elemanın aynı satıra ait referans veri toplamına bölünmesinden elde edilir. Genel sınıflandırma doğruluğu (yüzde olarak) her bir sınıf doğruluğunun ortalamasıdır. Tablo 1 için genel sınıflandırma doğruluğu  $(350/410)*100 = \%85.4$  tür /4/.

Bir başka yaklaşımda, olasılık matrisiyle sağlanmış bilgiyi özetleyen kappa ( $\kappa$ ) katsayısı sınıflandırmanın doğruluğunu ağırlıklı olarak hesaplayan bir istatistiksel ölçü olarak kullanılır.

$$\kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} * x_{+i}}{N^2 - \sum_{i=1}^r x_{i+} * x_{+i}} \quad (13)$$

Burada;

$r$  = Sınıf sayısı ;  $x_{ii}$  = Hata matrisinin köşegen elemanları

$x_{i+}$  = Satır toplamı ;  $x_{+i}$  = Sütun toplamı

$N$  = Hata matrisindeki toplam piksel sayısıdır.

Tablo 1'deki değerler için  $\kappa$  değeri;  $\kappa = \frac{410 \times 350 - 28739}{168100 - 28739} = \frac{114761}{139361} = 0.82$

bulunur. Sonuçta bulunan ( $\kappa$ ) değeri;

0.00 ise sınıflandırılmış ve referans verileri arasında uyumun olmadığını,

1.00 ise tam uyum olduğunu ,

0.75 ve fazlası sınıflandırma performansının çok iyi olduğunu,

0.40'ın aşağısı ise performansın yetersiz olduğunu gösterir.

Burada dikkat edilecek iki nokta, test alanları olabildiğince büyük olmalı ve homojen dağılmalıdır. Ham veriden alınmış test pikselleri, uzaktan algılanmış görüntü ile aynı tarihte alınmamış ise yersel yapının değişiminden dolayı sonuçların yorumlanmasını etkileyebilir. Ayrıca test verileri ve sınıflandırılmakta olan görüntü pikselleri arasındaki ölçek farkından dolayı problemler ortaya çıkabilir. Mümkün olabildiği kadar, test pikselleri gerçeği yansıtmalıdır. Hata matrisinden alınan doğruluk derecelerinin direk yorumlanması hatalara yol açabilir. Verilen spektrum sınıfı için çok sayıda test varyasyonu söz konusudur ve hepside farklı doğruluk derecesi verebilir /4/.

#### 4. SONUÇ

Çalışmada uzaktan algılanmış verilerin sınıflandırılması ile ilgili eğitilmiş, eğitimsiz sınıflandırma ve fuzzy sınıflandırma yöntemleri ele alınmıştır. Uzaktan algılanmış görüntülerde sınıflarla ilgili olasılık dağılımları bilinmiyor, sınıfı bilinen eğitim alanları mevcut değil yada çok yetersiz miktarda ise verilerin sınıflandırılmasında eğitimsiz sınıflandırma kullanılır.

Analizci kontrolünün azalması nedeniyle eğitimsiz sınıflandırma, bilgi içeren sınıfları belirlemede genel olarak eğitilmiş sınıflandırma kadar etkin bir yöntem değildir. Bu nedenle tamamen eğitimsiz sınıflandırmaya dayanan analizin, ancak bilgi içeren sınıfların çok spektrumlu verilerde kolaylıkla ayırt edilebilir olması halinde güvenilir sonuçlar vermesi beklenebilir.

İlgilenilen sınıfların sayısı biliniyor, her sınıftan alınmış eğitim alanları mevcut ise bu veriler kullanılarak eğitilmiş sınıflandırma yapılabilir. Eğitilmiş sınıflandırma yöntemleri istatistiksel kavramlara dayalı yöntemleri ve yapay sinir ağlarına dayalı yöntemleri kapsar. istatistiksel yöntemler olarak, ortalamaya en az uzaklık yöntemi, paralel kenar yöntemi ve en yüksek olasılık yöntemi incelenmiştir.

En az uzaklık sınıflandırması bu yöntemlerin en basitidir. Burada her sınıfın yalnız ortalama vektörü belirlenir, sınıfların kovaryans matrislerinin eşit olduğu varsayılır. Her piksel  $n$  boyutlu uzayda kendisine en yakın ortalama vektöre sahip sınıfa atanır. Yöntem görüntü verisindeki farklı derecelerdeki varyanslara duyarlıdır. En yüksek olasılık yöntemi ile karşılaştırıldığında hata oranı yükselmesine rağmen, işlem basitliği nedeniyle önemli ölçüde zaman tasarrufu sağlar.

Paralel kenar yönteminde eğitim alanlarındaki piksellerin parlaklık değer sınırları göz önünde bulundurularak sınıf dağılımlarının duyarlılıkları ortaya çıkarılabilir. Bu yöntemde kovaryans matrisi ve sınıfların olasılık dağılımları kullanılmaz. Kovaryansın varlığı durumunda eğitim aşamasında elde edilen verilerden oluşturulan karar bölgelerini paralel kenarlar ile ifade etmek yetersiz kalır. Çünkü karar bölgeleri üst üste biner ve pikselin hangi sınıfa ait olduğu anlaşılabilir. Karar bölgeleri basamaklara ayrılarak, bu problem bir miktar azaltılabilir.

En yüksek olasılık yönteminde sınıfların olasılık dağılımları kullanılır. Her sınıf için ortalama vektör ve kovaryans matrisi hesaplanır. Böylece sınıfların dağılımları ve ağırlıkları göz önüne alınmış olur. Sınıflandırılmak istenen piksel, olasılığı en fazla olan sınıfa atanır. En az uzaklık ve paralel kenar yöntemi ile karşılaştırıldığında, en yüksek olasılık sınıflandırma yöntemi en az hata oranını verir. Ancak bu, olasılıkların doğru bilinmesine ve hesaplanmasına bağlıdır. Bu yöntemin en önemli dezavantajı, her pikselin sınıflandırılması için çok sayıda hesaba gerek göstermesidir. Genel bir kural olarak, bu yöntemde sınıflandırmada kullanılan bant sayısı arttıkça sınıflandırmanın doğruluğu da artmaktadır. Ancak kullanılan bant sayısının çok fazla olması, bazı durumlarda bazı bantların diğer bantların duyarlılıklarını azaltmasına neden olabilir. Bundan dolayı sınıflandırmada kullanılacak en uygun bantların seçimi önemlidir.

Çoklu tabaka yapay sinir ağlarının (YSA) avantajları; Bu tür ağlar bir istatistiksel dağılım ile uyumlu veya uyumsuz olan bütün sayısal girdi türlerini kabul eder. Bu yüzden uzaktan alınmamış verilerde ilave girdiler olarak işleme dahil edilebilir. YSA'lar geliştirilebilir. Yani onları araştırmak için kullanılmış olanlara benzer girdileri tanıyabilir. Bilinmeyen örnekler, iki bilinen örnek arasında olduğu zaman çok daha başarılı bir şekilde geliştirilebilir, ancak araştırma örneklerinin uzağında olan yeni örneklerle ulaşma yeteneği daha az iyidir. Daha büyük ağlar (daha çok işlem birimli), küçük ağlardan daha zayıf geliştirme kapasitesine sahip olma eğilimi gösterirler. YSA'lar ağırlıklı bağlantılar yardımı ile ilişkili çok sayıda işlem birimli tabakaları içerdiğinden, araştırma örneklerindeki mevcut gürültüyü tolere edebilirler /4/.

Örnek, model tanımada YSA'ların kullanımı ile ilgili dezavantajlar; Bu tür ağlarda problemler ağı dizaynında, yapılandırılması sırasında olur. Genellikle 1 veya 2 gizli tabaka çoğu problem için uygundur. Ancak verilen bir durumda kaç tane gizli tabaka kullanılmalı, kaç tane işlem birimi her bir gizli tabakada gereklidir? İç işlem birimlerinin hepsinin bağlantısı gereklidir? Parametre oranını öğrenmek için en iyi değer nedir? Gibi soruların cevaplanması gereklidir. Bu tür ağlarda araştırma, eğitim zamanı uzun sürebilir. 486 tabanlı bir PC üzerinde 512x512 lik bir görüntü, aynı düzeyde doğruluğu başarmak için bir YSA'da birkaç saatlik bir araştırmayı gerektirirken, en yüksek olasılık algoritması ile 1 dakikadan daha kısa bir surede sınıflandırılabilir. YSA da kullanılan en dik iniş algoritması ile genel bir minimumdan ziyade lokal bir minimuma ulaşılabilir. Bir YSA yardımı ile ulaşılmış sonuçlar;

genellikle küçük rasgele değerler olan, işlem birimi iç ağırlıklarının başlangıç değerlerine bağlıdır. Başlangıç ağırlıklarındaki farklar, ağırlıkların farklı lokal minimumlara yakınsamasına neden olabilir ve böylece farklı sınıflandırma doğrulukları beklenebilir. YSA'ların genelleme yeteneği, araştırma sırasında yapılmış iterasyonların sayısına ve gizli tabakaların içerdiği işlem birimlerinin sayısına kompleks bir tarzda bağlıdır /4/.

## KAYNAKLAR

- /1/ ARSLAN, O., : "Neural Networks for Images Classification", International Symposium on Remote Sensing and Integrated Technologies, 29-40, October 1999, Istanbul
- /2/ EVSAHİBİOĞLU, N.A., : Tübitak Marmara Araştırma Merkezi Uzay Bilimleri Teknolojisi Bölümü Uzaktan Algılama Temel Eğitimi Kurs Notları, 3-7 Mayıs, Gebze1993
- /3/ LILLESAND, T.M., KIEFER, R. W., : Remote Sensing And Image Interpretation, Canada, (2000).
- /4/ MATHER, Paul M., : Computer Processing of Remotely Sensed Images, England, (1999).
- /5/ MAKTAV, D., SUNAR, F., : Uzaktan Algılama Kantitatif Yaklaşım, Türkiye, (1991).
- /6/ ŞEN, Z., ÜSTÜNTAŞ, T., : "Fuzzy c-Means Classification in Discriminant Analysis", International Symposium on Remote Sensing and Integrated Technologies, 81-86, October 1999, Istanbul
- /7/ : <http://www.gis.wau.nl/girs/projects/rsbasics/overview.html> (2002)