

# UZAKTAN ALGILAMADA SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Eminnur Ayhan<sup>1</sup>, Oğuz Kansu<sup>2</sup>

<sup>1</sup> Karadeniz Teknik Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Bölümü, Fotogrametri Anabilim Dalı, Trabzon. [eyhan@ktu.edu.tr](mailto:eyhan@ktu.edu.tr)

<sup>2</sup> İstanbul Teknik Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Bölümü, İstanbul. [oguzkansu@hotmail.com](mailto:oguzkansu@hotmail.com)

## ÖZET

Modern uydu algılama teknolojilerinin en önemli uygulamalarından biri, arazi örtüsü kullanımının uzaktan algılama ile haritalanması ve harita bilgilerinin üretilmesidir. Görüntü sınıflandırma, uzaktan algılanmış görüntülerde aynı özelliğe sahip olan bölgelerin benzer şekilde gösterildiği tematik haritaların hazırlanması işlemidir. Literatürde yoğun olarak kullanılan klasik istatistiksel sınıflandırma yöntemlerine (Maksimum Olabilirlik, Mahalanobis uzaklığı vb.) ek olarak son yıllarda Yapay Zekâ yaklaşımları sınıflandırma problemlerinin çözümünde kullanılmaya başlanmıştır. Temelde insan zekâsı davranışlarını makineye aktarmaya çalışan yapay zekâ uygulamaları genel olarak; Bulanık (Fuzzy) Mantık, Uzman Sistemler, Genetik ve Tabu Arama ve Yapay Sinir Ağları (YSA) olarak alt başlıklara ayrılmaktadır.

Bu çalışmada, çok spektrumlu ikonos II ve Landsat görüntü verilerinin sınıflandırılması için klasik Maksimum Olabilirlik yöntemi, YSA sınıflandırma yöntemi ve Bulanık Mantığa Dayalı sınıflandırma yöntemlerinin karşılaştırılması amaçlanmıştır. Yapay Sinir Ağları ile görüntü sınıflandırma uygulaması için, geri yayımlı öğrenme algoritması, Bulanık Mantık ile yapılan uygulama için, Sugeno tipi bulanık model kullanılmıştır.

Görüntü sınıflandırma işleminin denetleme aracı olan; sınıflandırma doğruluğu açısından yapılan karşılaştırmalarda, yapay sinir ağları sınıflandırması, bulanık mantığa dayalı sınıflandırma yöntemi ve maksimum olasılık sınıflandırmasından daha iyi sonuçlar vermiştir.

**Anahtar Sözcükler:** Uzaktan algılama, sınıflandırma, Yapay Sinir Ağları, Bulanık Mantık, Maksimum olabilirlik yöntemi.

# COMPARISON OF IMAGE CLASSIFICATION METHODS FOR REMOTE SENSING

Eminnur Ayhan<sup>1</sup>, Oğuz Kansu<sup>2</sup>

<sup>1</sup> Blacksea Technical University Faculty of Engineering Department Geodesy and Photogrammetry, Trabzon. [eyhan@ktu.edu.tr](mailto:eyhan@ktu.edu.tr)

<sup>2</sup> Istanbul Technical University Department of Geodesy and Photogrammetry, Istanbul. [oguzkansu@hotmail.com](mailto:oguzkansu@hotmail.com)

## ABSTRACT

One of the most important applications in the technology of remote sensing is to map land cover with remote sensing and to produce mapping information. Image classification is a process on remotely sensed images for preparing the thematic maps that show the similar areas with the same features. Besides the common methods used intensely in literature (Maximum likelihood, Mahalanobis distance etc.), the artificial intelligence approaches have been used to solve the problems based on the classification recently. The artificial intelligence which basically aims to mimic the intelligence of human beings onto the machines is generally divided into Fuzzy Logic, Expert Systems, Genetic and Tabu Search and Artificial Neural Networks (ANN).

In this study for classification of multispectral IKONOS II imagery and LANDSAT imagery data, it was aimed to compare ANN classification with the standard maximum likelihood method and image classification based on fuzzy logic method. Back propagating learning algorithm is used for Artificial Neural Network image classification and Sugeno type fuzzy model is used for the application of Fuzzy Logic.

Comparisons are made in terms of classification accuracy that is the control tool of the process of image classification. Artificial Neural Network classification is more robust than the standard maximum likelihood method and fuzzy logic method.

**Key Words:** Remote Sensing, Classification, Artificial Neural Networks, Fuzzy Logic, Maximum Likelihood Method.

## 1. GİRİŞ

Arazi kullanımının değişen biçimleri ekonomik, sosyal ve çevresel koşulların da değişimini yansıtır. Arazi kullanımının belirlenebilmesi görüntü sınıflandırılmasıyla mümkündür. Uzaktan algılamada sınıflandırma, bir görüntüdeki her bir piksel değerinin ait olduğu özellik grubunu belirleme işlemidir. Sınıflandırma, tematik bilgi çıkarmak için kullanılan çok önemli bir yöntemdir. Bu işlemde orijinal algılanmış görüntü, karar fonksiyonlarıyla ayrılmış özellik uzayı ile sonuç haritaya dönüştürülür. Dijital tematik harita haline getirilmiş sınıflandırılmış görüntü, bir harita projeksiyonuna dönüştürüldüğü durumda, coğrafi bilgi sistemlerinde kullanılabilir (Jehnsen, 1996).

Sınıflandırma işleminde, başlangıçta var olan veri ve bilgilerin tür ve miktarına göre problem yaklaşım ve çözüm yolları farklı olmaktadır. Sınıflandırmada kullanılacak bant kombinasyonlarını belirlemek amacıyla çalışma alanına ait çok spektrumlu veri dizisindeki korelasyon irdelenmelidir. Bunun için korelasyon matrisi oluşturulmalı, ve korelasyon katsayıları incelenerek minimum korelasyona sahip bantlar sınıflandırmada kullanılmalıdır (Ayhan vd., 2003).

Uzaktan algılamada sınıflandırma, birçok faktörün düşünülmesini gerektiren karmaşık bir işlemdir. Görüntü sınıflandırma adımları, uygun bir sınıflandırma sisteminin belirlenmesini, eğitim örneklerinin seçimini, görüntü işleme, özellik çıkarma, uygun sınıflandırma yaklaşımlarını seçme, sınıflandırma sonrası işlemleri ve doğruluk değerlendirmesini içerir. Kullanıcının ihtiyacı, çalışma alanının ölçeği, ekonomik şartlar ve analistin becerisi sınıflandırma sonuçlarının kalitesini, sınıflandırma işleminin dizaynını, uzaktan algılanmış verinin seçimini etkileyen önemli faktörlerdir. Genel anlamda görüntü sınıflandırma yaklaşımları kontrollü ve kontrolsüz, parametrik ve parametrik olmayan olarak gruplandırılabilir (Lu and Weng, 2007).

Kontrollü sınıflandırmada, elde edilecek kategorileri temsil eden görüntü pikselleri toplanır ve ayırt edici karar fonksiyonları bu eğitim örneklerinden hesaplanır. Kontrolsüz sınıflandırmada ise kategorileri temsil eden örnekler bilinmeyen spektral olarak ayrılabilen kümeler oluşturulur. Kümelerin hangi kategorileri temsil ettikleri sınıflandırmadan sonra arazi incelemeleri ve harita ve hava fotoğraflarından yararlanılarak belirlenir (URL- 2, 2006).

## 2. SINIFLANDIRMA YÖNTEMLERİ

Literatürde yoğun olarak kullanılan klasik istatistiksel sınıflandırma yöntemleri; Maksimum Olabilirlik, Mahalanobis uzaklığı vb. yöntemlerdir. Son yıllarda Yapay Zekâ yaklaşımları sınıflandırma problemlerinin çözümünde kullanılmaya başlanmıştır. Temelde insan zekâsı davranışlarını makineye aktarmaya çalışan yapay zekâ uygulamaları genel olarak; Bulanık (Fuzzy) Mantık, Uzman Sistemler, Genetik ve Tabu Arama ve Yapay Sinir Ağları (YSA) olarak alt başlıklara ayrılmaktadır.

Maksimum Olabilirlik karar kuralında, verilerin bant histogramlarının normal dağılımı olduğu varsayılır. Maksimum Olabilirlik karar kuralı, bir pikselin belirli bir sınıfa ait olma olasılığına dayanır. Belirli bir patern, ortalama vektör ve kovaryans matrisiyle tanımlanır. Bu parametrelerle, bir pikselin belli bir sınıfa ait olma olasılığı hesaplanır. Olasılık düzeyi eksende gösterilir, yataydaki iki eksende farklı bantlar yer alır. Bu değerlerle oluşan çan şeklindeki yüzey olasılık yoğunluk fonksiyonu olarak adlandırılır ve her bir spektral kategori için bir fonksiyon vardır.

Olasılık yoğunluk fonksiyonları, bilinmeyen piksellerin olasılıklarının hesaplanarak belirli bir sınıfa atanması için kullanılır. Aday piksel olasılık değerine göre en çok benzediği sınıfa atanır. Eğer aday pikselin olasılığı tüm sınıfların sınır değerlerinin altındaysa piksel 'bilinmeyen' olarak etiketlenir (Lillesand and Kiefer, 2000).

### 2.1 Yapay Sinir Ağları

Yapay sinir ağları, katmanlar biçiminde düzenlenen basit işlem elemanı gruplarından oluşmaktadır. Her bir katman, farklı ağırlık değerlerine sahip olan bağlantılar aracılığıyla iletişimde bulunduğu belli sayıda işlem elemanını içermektedir. YSA'nın oluşturulmasında, hücrelerin karşılıklı bağlantı biçimleri ya da işlem elemanlarının düzenlenmesi, bilgiyi öğrenme ve bilgiyi kullanma yöntemi olarak üç temel elemana gereksinim vardır. YSA, ilgilenilen nesne hakkında hemen hemen hiçbir bilgi olmaması ya da çok az bilgi olması, bu nesnenin parametrelerinin ve durumunun matematiksel olarak ya da kurala dayalı olarak tanımlanamaması ya da alışılmış işlemcilerle çözilemeyen problemlerin var olması durumlarında etkin olarak kullanılabilir bir yaklaşımdır (Sağiroğlu vd., 2003).

YSA' ları, yapılarına ve öğrenme algoritmalarına göre sınıflandırılabilir (URL- 5, 2006). Yapay sinir ağları, yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki sınıfa ayrılmaktadır. İleri beslemeli bir ağda işlemci elemanlar genellikle katmanlara ayrılmıştır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. Geri beslemeli YSA' larda, bazı nöronların çıkışları, aynı nörona veya önceki katmanlardaki nöronlara geri beslenir.

Öğrenme algoritmalarına göre YSA' ları kontrollü öğrenme, kontrolsüz öğrenme olarak ayrılmaktadır. Bir kontrollü öğrenme algoritması nöronlar arası bağlantı ağırlıklarını, verilen giriş veri kümesine karşılık gelen gerçek değerlerle ağ çıkışı arasındaki farka göre güncellemektedir. Böylece kontrollü öğrenme algoritması istenen çıkış sinyalini sağlamak için bir danışmana ihtiyaç duymaktadır. Kontrolsüz öğrenme algoritmasında, istenilen çıkış değerinin bilinmesine gerek yoktur. Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ, sınıflandırma kurallarını kendi kendine geliştirmektedir.

Günümüzde en çok bilinen ve yaygın biçimde kullanılan yapay sinir ağı sınıflandırma yöntemi "çok-tabakalı algılayıcı sinir ağı"dır. Bu çalışmada, kontrollü öğrenme algoritmalarından geri yayılma algoritması, çalışma bölgesine ait çok spektrumlu dijital uydu görüntüsünün sınıflandırılmasında kullanılmıştır. Geri yayılım, çok katmanlı algılayıcı ağların eğitiminde en çok kullanılan temel bir algoritmadır. Giriş veri vektörü ağı öğrettiği veri kümesi olup çıkış vektörü, ağın üretmesi beklenen gerçek çıkış değerleridir.

Eğitimin amacı da istenen çıkış değerleriyle ağız ürettiği çıkış değerleri arasındaki farktan kaynaklanan hatanın minimize edilmesidir.

Aktivasyon fonksiyonu (karar fonksiyonu), YSA' na lineer olmayan bir yapı kazandırmak için ara ve çıkış katmanlarında kullanılan matematiksel bir fonksiyondur. Genellikle çok katmanlı algılayıcı (Multi-Layer Perseptron) yapılarında logaritmik sigmoidal veya tanjant hiperbolik ve Radyal Tabanlı Fonksiyon (Radial Basis Function) yapılarında ise Gauss fonksiyonları kullanılmaktadır.

YSA larında öğrenme oranı, Bağlantıların ağırlık değerlerindeki değişimin miktarını tanımlar. Bu oranı yüksek alma, değişimin miktarını artıracaktır. Düşük alınır ise, değişim miktarı azalacaktır. Öğrenme oranının ağız yakınsama süresine önemli bir etkisi vardır. Momentum katsayısı ise toparlanma oranını hızlandırmak için en çok kullanılan sezgisel yöntemlerden biri, momentum faktörünün kullanımınıdır. Bu faktör, ağız daha hızlı toparlanmasına yardım eder.

YSA yapılarında giriş ve çıkış katmanlarındaki işlemci eleman sayıları, veri boyutu ve istenen sınıf sayısı gibi dış etkenlere göre belirlenirken, ara katmanlardaki elemanlar deneme yanılma yoluyla belirlenmektedir.

## 2.2 Bulanık Mantık Kavramı

Modelleme, sonuç çıkarma, hesaplama için kullanılan geleneksel yöntemlerin çoğu kesindir, sayısaldir ve tam doğrudur. Buna karşın gerçek durumlar birçok bakımdan

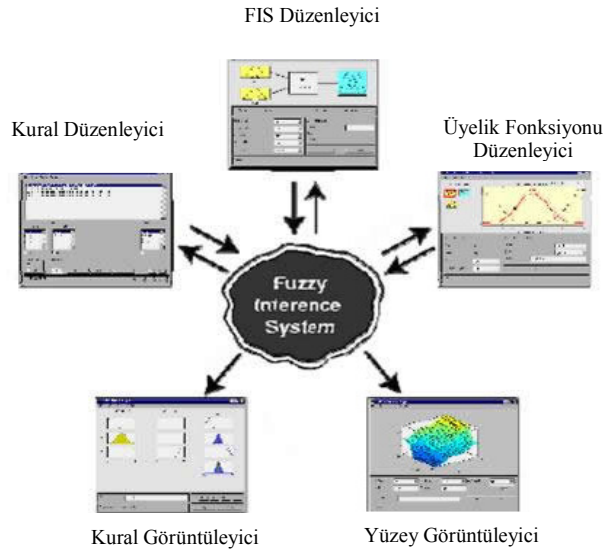
belirsizdir ve bulanıktır. Bulanık mantık bir tür makine zekâsıdır. Esas olarak, bulanık mantık doğru/yanlış, evet/hayır, yüksek/alçak gibi geleneksel değerler arasında tanım yapabilmek için geçiş değerlerine izin veren çok değerli bir mantıktır. Oldukça uzun ya da çok hızlı gibi sözel terimler matematiksel olarak formüle edilebilir ve bilgisayarlar tarafından işlenebilir (Hellman, 2004).

Bulanık mantık ile yaygın olarak kullanılan başlıca modellemeler; Mamdani ve Takagi – Sugeno tipi bulanık modellemelerdir. İki yöntem arasındaki fark çıktı üyelik fonksiyonlarındadır. Sugeno tipi bulanık modellemede çıktı üyelik fonksiyonları sadece lineer ya da sabittir. Çıktı üyelik fonksiyonları sabit olduğu zaman, 0. derece, 1. derece doğru denklemi şeklinde olduğu zaman ise birinci derece Sugeno bulanık model olarak adlandırılırlar (URL- 4, 2006). Böylece Sugeno tipi bulanık model, Mamdani tipi bulanık modelden daha karmaşık ve gösterim açısından daha elverişlidir.

Bulanık Mantık Modülü, Matlab'ın nümerik hesaplama ortamı üzerine kurulu fonksiyonların bütünüdür ve MATLAB iskeletinde Bulanık Çıkarım Sistemi (FIS) düzenlemeyi ve oluşturmayı sağlar. Bulanık Mantık Modülünde, bulanık çıkarım sistemi oluşturma, düzenleme ve inceleme için başlıca beş grafiksel kullanıcı ara yüzü vardır. Bunlar;

1. Bulanık Çıkarım Sistemi Düzenleyicisi,
2. Üyelik Fonksiyonu Düzenleyicisi,
3. Kural Düzenleyicisi,
4. Kural Görüntüleyicisi,
5. Yüzey görüntüleyici dir.

Bu grafiksel kullanıcı ara yüzleri birbirlerine dinamik olarak bağlıdır, FIS içerisinde birisinde yapılan değişiklikler diğer grafiksel kullanıcı ara yüzlerini de etkilemektedir (Mathworks Inc., 1998).



Şekil 1. Bulanık Mantık Modülü Grafiksel Kullanıcı Ara yüzü.

*Bulanık Çıkarım Sistem Düzenleyicisi:* sistem için gerekli olan üst seviyede işleri yönetir. Kaç tane girdi ve çıktı değişkeni var? İsimleri neler? Bulanık Mantık Modülü girdi sayısını kısıtlamaz.

*Üyelik Fonksiyon Düzenleyicisi:* her değişkenle ilgili üyelik fonksiyonlarını tanımlamak için kullanılır.


*Kural Düzenleyicisi:* sistem davranışını tanımlayan kuralların listesini düzenlemek için kullanılır.

*Kural Görüntüleyicisi ve Yüzey Görüntüleyicisi:* Hangi kuralların aktif olduğunu ya da özel üyelik fonksiyon şekillerinin sonuçları nasıl etkilediğini gösterir. Başlıca beş grafiksel kullanıcı ara yüzü birbirini tümüyle etkilemekte, bilgi değişimini sağlamakta ve aynı zamanda açılabilir.

### 3- UYGULAMA

Uygulamada, çalışma alanı olarak Ikonos uydu görüntüsü için yaklaşık 3,6 km x 3,6 km genişliğinde bir alan seçilmiştir. Sınıflandırma işlemlerinde maksimum olabilirlik karar kuralı, Yapay Sinir Ağları ve Bulanık Mantık sınıflandırma yöntemleri

kullanılmıştır. Klasik Maksimum Olabilirlik sınıflandırma yöntemi için Erdas Imagine 8.7 ve PCI Geomatica 9.0 yazılımı kullanılmıştır. Bulanık Mantığa dayalı görüntü sınıflandırma uygulaması Matlab programı ortamında programlanmıştır. Yapay Sinir Ağlarına dayalı görüntü sınıflandırma uygulaması, Stuttgart Üniversitesi tarafından geliştirilen Stuttgart Neural Network Simulator (SNNS) programı ile gerçekleştirilmiştir. Erdas Imagine yazılımı ortamında uydu görüntü verisi üzerinden eğitim alanları Şekil 2.' deki gibi çevrilerek vektör veri formatında kaydedilmiş ve sınıflandırma uygulamalarının hepsinde aynı eğitim alanları kullanılmıştır.



Şekil 2. Çalışma alanındaki eğitim alanları.

Tüm yöntemlerde veri, sınıflandırıcıya tek tek piksel bazında verilmiş ve sonuçta 7 sınıftan birisine girmeye zorlanmıştır. Maksimum Olabilirlik yönteminde piksel paterni, en yakın olasılığa sahip olduğu (en yüksek Gauss olasılık yoğunluk değerini aldığı) sınıfa atanırken YSA ve Bulanık Mantık yapısında kazanan hepsini alır yöntemine uygun olarak en yüksek değer alınmış çıkış katmanı temsil ettiği sınıfa atanmıştır.

sınıflara ait eğitim alanlarının seçimi uydu görüntüsü üzerinden çıplak gözle yapılmıştır. Hedef sınıfları en iyi derecede temsil edecek ve olabildiğince homojen yapıda seçilen eğitim veri kümesi 7 sınıftan ve toplam 15168 paternden oluşmaktadır. Tablo 1' de seçilen sınıfların özellikleri, Tablo 2' de arazi sınıflarının toplam poligon ve patern sayıları verilmektedir.

Bu çalışma kapsamında yapılan eğitim alanı tespitinde, uydu görüntü verisinin yüksek çözünürlüklü olması sebebiyle tüm

Tablo 1. Çalışmada seçilen sınıflar ve özellikleri.

Sınıf Adı	Sınıf Kodu	Açıklama
Su	1	Deniz ve Dereler
Yeşil 1	2	Bitki örtüsü yoğunluğunun az olduğu çayır tipi alanlar
Yeşil 2	3	Bitki örtüsünün yoğun olduğu orman bölgeleri
Parlak	4	Deformasyona uğramış parlak renkli alanlar
Toprak	5	Tarla tipi çıplak toprak
Yol	6	Ana ve ara yollar
Yerleşim	7	Düzenli ve düzensiz yerleşim alanları

Tablo 2. Eğitim alanlarının poligon ve piksel sayıları.

Arazi Sınıfı	Eğitim Alanı Poligon Sayısı	Patern Sayısı
Su	8	5149
Yeşil 1	3	1721
Yeşil 2	2	2004
Parlak	4	1666
Toprak	11	2069
Yol	10	1452
Yerleşim	19	1107

Tespit edilen eğitim alanlarının irdelemesi sonucu bazı sınıflarda parlaklığın etkili olduğu görülmüştür. Bu nedenle parlaklıklardan etkilenen sınıflar parlak alanlar olarak ayrılarak yeni bir arazi sınıfı altında toplanmıştır.

Seçilen bu örnek alanların dağılım ve birbirinden ayrılabilirlikleri hem grafik hem de sayısal olarak analiz edilmiştir. Bu grafiklerin analizinde, iki boyutlu tüm özellik uzaylarında özellikle 2. ve 3. sınıfların arasındaki örtüşme dikkat çekicidir. 7. sınıftaki ayırt edilebilirlik derecesi düşük seviyede olduğu için, bu sınıfın sınıflandırma performansının zayıf çıkması beklenmektedir. Oluşturulan sınıf alıştırma örneklerinin 4 boyutlu özellik uzayındaki ayrılabilirlik analizi, PCI Geomatica yazılımında kantitatif olarak da incelenmiştir. Bu amaçla sınıf örnek alanlarının 4 kanal için Bhattacharyya uzaklığı ve dönüştürülmüş diverjans değerleri hesaplanmıştır. Bu derecelendirmeye göre; zayıf ayrılabilirlik derecesine toprak ve yerleşim alanları sınıfları girmektedir.

### 3.1. Maksimum olasılık yöntemi Uygulaması

İkonos uydu görüntüsünün kontrollü sınıflandırmaya tabi tutulması ile elde edilen sonuçlar, alana ilişkin pankromatik uydu görüntüsü kullanılarak kontrol edilmiştir. Sınıflandırmanın başarısı, Erdas Imagine 8.6 programında 210 deneme alanından oluşan piksel bazında test verisi kullanılarak kontrol edilmiştir. Yapılan kontrollü sınıflandırmada toplam sınıflandırma doğruluğu %67,62, Kappa istatistik değeri 0,6020 olarak başarısız bulunmuştur.

Bu yöntemde su olarak nitelendirilen sınıfın üretici doğruluğu %96,43, kullanıcı doğruluğu %100 ve kappa istatistiği 1 olup yüksek başarı oranı ile ayrılabilirliktedir. Yerleşim alanları %66,67 kullanıcı doğruluğu ile düşük değere sahiptir. Kappa istatistik değeri 0,6392 olduğundan ilgili sınıfın ayrılmasında istenilen başarı sağlanamamıştır. Çünkü kappa istatistiği değeri, 0-1 aralığında değişmekte ve 0,8 oranından büyük değerler başarılı sayılmaktadır. Trabzon ilindeki yerleşim alanlarındaki yapılaşmanın dağınık olmasından dolayı iskan alanlarının ayrımında başarı oranı düşük çıkmıştır. Sınıf dağılımlarının normal dağılıma uymaması ve bunun sonucunda dağılımların birbirine girmesinden dolayı diğer sınıfların ayrımında da başarı sağlanamamıştır.

### 3.2. Yapay Sinir Ağları Uygulaması

Kullanılan YSA geri yayılım algoritmasında giriş katmanı, kullanılan her bir kanala karşılık bir yapay nöron gelecek şekilde 4 nöron tesis edilmiştir. Çıkış katmanı hedeflenen 7 sınıfın her birine bir nöron gelecek şekilde tesis edilmiştir. YSA

hedef değerleri, ilgili sınıfa ait olması beklenen nöron için 1, ait olmayan diğerleri için 0 olarak belirlenmiştir. YSA ara katman sayısı, ilk ağırlık parametresi, öğrenme parametresi ve momentum oranı uzaktan algılanmış görüntülerin sınıflandırma problemine en iyi yakınsamayı getirecek en iyi değerleri deneme yanılma yöntemiyle belirlenmeye çalışılmıştır ve tüm bu ağırlık parametreleri ve öğrenmesini etkileyen parametreler tek tek ele alınarak optimum ağırlık yapısı tasarlanmıştır. Yapılan doğruluk analizleri sonucunda en iyi doğruluğu veren ağırlık tasarımı belirlenmiş ve uydu görüntüsü optimum ağırlık tasarımı göre sınıflandırılmıştır. Optimum ağırlık tasarımı için en iyi değerler Tablo 3 de gösterilmiştir. Yapay sinir ağlarının sınıflandırılması sonucunda toplam doğruluk %98,76 ve Kappa istatistik değeri 0,9855 bulunmuştur.

Tablo 3. Yapay sinir ağları uygulaması için Optimum ağırlık tasarımı ve sınıflandırma sonucu.

Parametreler	Seçim / Sonuç
Girdi katman sayısı	4
Çıktı katman sayısı	7
Ara katman sayısı	14
İlk ağırlık aralığı	[-0.1, 0.1]
Öğrenme oranı ve Momentum	0.15 – 0.075
Çıktı kodlaması	[ 0 1 0 ]
İterasyon	5000
Toplam doğruluk	98.76
Kappa İstatistiği	0.9855

### 3-3. Bulanık Mantığa Dayalı Görüntü Sınıflandırma Uygulaması

Bulanık mantığa dayalı sınıflandırma için girdi verisi olarak, tüm sınıflandırma uygulamalarında kullanılan aynı eğitim paternleri kullanılmıştır. Uygulama için Matlab yazılımının bulanık mantık modülü ve Pci Geomatica yazılımı kullanılmıştır. Pci Geomatica programından alınan üyelik fonksiyon parametreleri kullanılarak bulanık çıkarım sistemi (FIS) oluşturulmuştur. Sınıflandırmadan elde edilen sonuçlar, alana ilişkin pankromatik uydu görüntüsü kullanılarak kontrol edilmiştir. Sınıflandırmanın başarısı, Erdas Imagine 8.6 programında 210 deneme alanından oluşan nokta bazında test verisi kullanılarak kontrol edilmiştir. Yapılan kontrollü sınıflandırmanın başarısını özetleyecek olursak; toplam sınıflandırma doğruluğu %63,81, Kappa istatistik değeri 0,5560 olarak başarısız bulunmuştur. Sınıflandırma sonuçlarında görüldüğü gibi bulanık mantıkla yapılan sınıflandırmada başarı sağlanamamıştır. Yerleşim alanları sınıfı ile su sınıfı birbirine girmiştir. Sınıflandırmanın toplam doğruluğu çok düşük elde edilmiştir.


### 3.4. Genel Karşılaştırma

İkonos görüntü verileri için genel doğruluk, kappa ve üretici doğruluk değerleri, Yapay Sinir Ağları, Bulanık Mantık ve Maksimum Olabilirlik sınıflandırma uygulamaları için karşılaştırmalı olarak Tablo 4’de verilmiştir.


Tablo 4. İkonos uydu görüntü verisi için bütün sınıflandırma yöntemlerinin GD, Kapa ve üretici doğruluk değerleri.

	Genel Doğruluk	Kappa Değerleri	Sınıflar / Üretici Doğrulukları						
			1	2	3	4	5	6	7
YSA	98.76	98.55	100.00	98.67	99.46	100.00	96.75	98.92	97.00
Max. Likelihood	67.62	60.20	96.43	77.46	65.22	80.00	63.89	46.15	12.50
Bulanık Mantık	63.81	55.60	96.88	79.03	65.52	9.09	48.57	58.62	0.00

İkonos görüntü verisi için sınıflandırılmış görüntüler Şekil 3, Şekil 4, Şekil 5 de verilmiştir.



Şekil 3. Maksimum olasılık yöntemine göre sınıflandırılmış görüntü.



Şekil 4. Bulanık Mantık yöntemi ile sınıflandırılmış görüntü.



Şekil 5. Yapay Sinir Ağı yöntemi ile sınıflandırılmış görüntü.

#### 4. SONUÇLAR

Bu çalışmada, sınıflandırma problemi için gerçekleştirilen uygulamalar sonucunda, YSA yapısından elde edilen sınıflandırma genel doğruluk (GD) ve Kappa değerlerinin, maksimum olabilirlik ve bulanık mantık yöntemlerinden elde edilen değerlerden daha yüksek çıktığı görülmüştür.

Maksimum olabilirlik yönteminde elde edilen sınıflandırma doğruluk değerinin YSA doğruluk değerlerinden düşük olması, bu yöntemin eğitim verisi dışında karşılaştığı diğer veriler için rölatif olarak daha az bir genelleme yeteneğine sahip olduğunu göstermektedir. Burada Maksimum olabilirlik yönteminin en büyük özelliği sınıflandırma verisi için istatistiksel dağılım (Gauss) kabulü yapmasıdır. Verinin bu dağılıma uymaması, bu dağılımdan sapması ölçüsünde sınıflandırma performansı düşecektir.

Bulanık mantık yöntemiyle yapılan sınıflandırma uygulaması, Ikonos uydu görüntü verisi için çalışmada en kötü sonucu vermiştir. Bu durum görüntü ve ilgili sınıfların karmaşıklık düzeyine bağlı olarak Bulanık mantık için yazılacak koşul denklemlerinin sayısının artırılması gerektiğini göstermektedir.

Bu çalışmada gerçekleştirilen uygulamalar, YSA sınıflandırma algoritmasının çok spektrumlu uydu görüntü verilerinin sınıflandırılması için bulanık mantık ve klasik yöntemlere göre kıyaslanabilir ve daha iyi performans gösteren etkin sınıflandırma araçları olduklarını göstermiştir. Buna karşın sinir ağları ile sınıflandırma işlemi, standart yöntemlere oranla hem zaman alıcı hem de daha çok uğraş gerektiren bir araç durumundadır.

#### Kaynaklar

Jehnsen, J.R., 1996. Introductory Digital Image Processing, A Remote Sensing Perspective, Prentice Hall, New Jersey.

Ayhan, E., Karslı, F., Tunç E., 2003. Uzaktan Algılanmış Görüntülerde Sınıflandırma ve Analiz, Harita Dergisi.

Lu, D. and Weng, Q., 2007. A survey of image classification methods and techniques for improving classification performance, International Journal of Remote Sensing. Vol. 28, No. 5, 10 March 2007, 823–870.

URL- 2, www.berkeley.edu, 24 Ocak 2006.

Lillesand, T.M., Kiefer, R.W., 2000. Remote Sensing and Image Interpretation, John Wiley&Sons Inc., New York.

Sağiroğlu, Ş., Beşdok, E., Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları, Ufuk Kitabevi, İstanbul.

URL- 5, [http://www.dacs.dtic.mil/techs/neural/neural\\_ToC.html](http://www.dacs.dtic.mil/techs/neural/neural_ToC.html), 13 Nisan 2006

Hellman, M., Fuzzy Logic Introduction, www.fpk.tu.berlin.de/~anderl/epsilon/fuzzyintro4.pdf, 03 Ocak 2004.

URL-4,

<http://www.cems.uwe.ac.uk/~xzhang/PDF/MSc/Fuzzy%20Logic.pdf>, 29 Mart 2006

Mathworks Inc., 1998. Matlab Fuzzy Logic Toolbox, Users Guide.