

ARAZİ ÖRTÜSÜNÜN BELİRLENMESİNDE TORBALAMA-KARAR AĞAÇLARI YÖNTEMİNİN KULLANIMI

Ümit Haluk ATASEVER¹, Coşkun ÖZKAN¹

¹ Erciyes Üniversitesi, Harita Mühendisliği Bölümü, 38039, Melikgazi, Kayseri, {uhatasever@erciyes.edu.tr, cozkan@erciyes.edu.tr}

ÖZET

Günümüzde birçok uygulama, güncel ve yüksek doğruluklu, mekansal bilgiye ihtiyaç duymaktadır. Bu bilgiler çevresel değişimlerin izlenmesi, arazi kullanımının belirlenmesi ve farklı tematik haritalama amaçları için kullanılmaktadır. Uzaktan algılama sistemleri sinoptik görüş kabiliyeti, farklı konumsal, zamansal ve spektral çözünürlüğe sahip olmaları nedeniyle tematik bilgi çıkartımı için en önemli araçlardan biri olmuştur. Uydu görüntülerinden tematik bilgi çıkarımındaki en önemli aşama şüphesiz sınıflandırma işlemidir. Sınıflandırma işleminin doğruluğu, kullanılan yöntem ve yonteme ait parametreler ile doğrudan ilişkilidir. Bu sebepten ötürü problemin ve kullanılan görüntünün niteliğine göre uygun sınıflandırma yönteminin seçilmesi büyük önem arz etmektedir. Literatürde en yaygın kullanılan sınıflandırma yöntemleri parametrik bir yöntem olan En Çok Olabilirlik ve herhangi bir istatistiksel dağılım bilgisi gerektirmeyen Yapay Sinir Ağları'dır. Bu çalışmada bu yöntemlere ek olarak çok hızlı bir sınıflandırma yöntemi olan Karar Ağaçları ve sınıflandırma yöntemlerinin doğruluğunu arttırmakta kullanılan torbalama (Bagging) metodu kullanılarak çok kanallı Landsat verisinin sınıflandırılmasındaki başarıları araştırılmış ve temel sınıflandırma yöntemleri ile başarıları kıyaslanmıştır.

Anahtar Sözcükler: Görüntü Sınıflandırma, Torbalama(Bagging), Karar Ağaçları.

ABSTRACT

THE USE OF BAGGED-DECISION TREE METHOD FOR DETERMINATION OF LAND COVER

In many applications around the world, high-accuracy, precision terrestrial data and information is needed. This information is used for monitoring of environmental changes, determination of land use and purpose of different thematic mapping. Remote sensing systems have been one of the important tools due to their synoptic visibility, different spatial, temporal and spectral resolution. Classification is the most important phase in the process of thematic information extraction. Accuracy of the classification process is directly related with method and parameters of the method. For this reason, selecting the appropriate method of classification is of great importance. Many studies around the world, Maximum Likelihood which is a parametric method and Artificial Neural Network which do not require any statistical information are used. In this study, in addition to these methods, decision tree method which is very fast and Bagging approach which is used for increasing accuracy of classification method are used and the success of multi-channel classification of Landsat data were investigated and compared with basic classification methods.

Keywords: Image Classification, Bagging Approach, Decision Trees.

1. GİRİŞ

Yeryüzü ile ilgili birçok çalışmada uzaktan algılama disiplininin sağladığı bilgilere gereksinim duyulmaktadır. Uydular tarafından elde edilen görüntüler yardımıyla çok geniş alanlara ait detaylı bilgilere doğru ve hassas analizler yapılarak ulaşabilmek mümkündür. Bu analizlerin başında uydu görüntülerinin sınıflandırılması gelmektedir. Dolayısı ile sınıflandırma doğruluğunu mümkün olduğu kadar arttırmak gerekmektedir. Sınıflandırma doğruluğunu arttıran en önemli bileşenlerden bir tercih edilecek sınıflandırma yöntemidir. Son 20 yıl içinde yapay zeka ve istatistiksel öğrenme alanındaki gelişmelerden en çok etkilenen alanlardan biri uzaktan algılama disiplini olmuştur. Özellikle uydu görüntülerinin sınıflandırılmasında En Çok Olabilirlik Yöntemi'ne ek olarak, Yapay Sinir Ağları, Karar Ağaçları ve Rastgele Orman gibi Karar Ağaçları temelli yöntemler ve sınıflandırma doğruluğunu arttıran grup(ensemble) yaklaşımlarda tercih edilmeye başlanmıştır.

Literatürde robust yöntemlerin başında gelen En Çok Olabilirlik Yöntemi görüntünün normal dağılıma uyduğunu varsaydığı için parametrik bir yöntemdir. Ek olarak, bu yöntemde sınıflandırma yapılırken sadece parlaklık değerleri değil; ortalama, varyans ve kovaryans hesaplamaları da dahil edilir. Yapay Sinir Ağları ise gürültülü veriler ile kullanılabilmesi, eğitim için büyük verisetlerine ihtiyaç duymaması, doğrusal olmayan ilişkileri modelleyebilmesi gibi yetenekleri nedeniyle farklı branş ve mühendislik dallarında kullanıldığı gibi uydu görüntülerinin sınıflandırılmasında da yoğun olarak kullanılmakta ve başarılı sonuçlar vermektedir(Kavzoglu, T., 2001).

Sık olarak kullanılan sınıflandırma yöntemlerinden biri de Karar Ağaçlarıdır. Bu yöntem oldukça kullanışlı, basit ve yapısı gereği oldukça hızlı bir yöntemdir. Basit olarak "eğer-ise" gibi karşılaştırmalar yapılarak oluşturulan Karar


Ağaçları, istatistiksel öğrenme grup(ensemble) algoritmaları ile desteklenerek doğrulukları arttırılmaya çalışılır. Bu algoritmaların başında Torbalama(Bagging) gelmektedir(Breiman, L.,1996).

Bu çalışmada Landsat verisi kullanılarak Torbalama (Bagging) yönteminin sınıflandırma doğruluğu üzerindeki etkisi incelenmiş ve en sık kullanılan algoritmalar ile karşılaştırılmıştır.

2. KULLANILAN YÖNTEMLER

2.1. Yapay Sinir Ağları

Yapay Sinir Ağları biyolojik sinir ağlarının fonksiyonel yönlerinden esinlenilerek geliştirilmiş matematiksel bir modeldir. Çoğu durumda bir YSA öğrenme aşamasında ağ üzerinde geçen iç ve dış bilgilere göre yapısını değiştirebilen adaptif bir sistemdir. Buna ek olarak verilerin karmaşık ve gürültülü olduğu durumlarda veriler arasındaki doğrusal olmayan ilişkilerin öğrenilmesinde oldukça başarılıdır(Kavzoğlu, T.,2001).Yapay Sinir Ağları'ndaki işlem adımları Şekil 1.de gösterildiği gibi modellenilebilir.



Şekil 1. Yapay Sinir Ağları'nın temel adımları

Eşitlikte görüldüğü gibi ;

$$n = x_1 \cdot w_1 + x_2 \cdot w_2 + \dots + x_n \cdot w_n + b \quad (1)$$

şeklinde ifade edilir. Burada w_n , n inci numaralı ağırlık, x_n ise n inci veri değerini temsil etmektedir. İşlem birim çıktısı ise 2 nolu eşitlik ile hesaplanır(İnternet-1):

$$o = f(w \cdot x + b) \quad (2)$$

Burada kullanılan karar fonksiyonu(f) sistemin doğruluğunu etkileyen en önemli faktörlerden biridir. Çok kanallı uydu görüntülerinin sınıflandırılmasında en çok kullanılan fonksiyon Log-Sigmoid olmasına rağmen bazı çalışmalarda Hiperbolik Tanjant(Tan-Sigmoid) fonksiyonunun daha başarılı sonuçlar verdiği gözlemlenmiştir(Özkan C., ve Sunar F.,2003). Görüntü sınıflandırma en çok kullanılan iki aktivasyon fonksiyonu Çizelge 1.de verilmiştir.

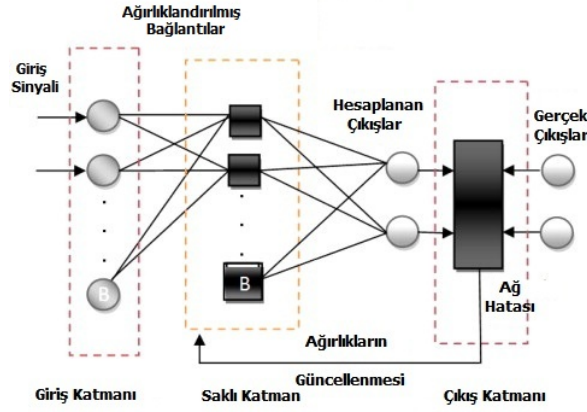
Çizelge 1. Görüntü sınıflandırmada en sık kullanılan aktivasyon fonksiyonları

Aktivasyon Fonksiyonu	Matematiksel Eşitliği	Grafiksel Gösterim
Log-Sigmoid	$y = \frac{1}{1 + e^{-x}}$	
Hiperbolik Tanjant	$y = \frac{1 - e^{-2x}}{1 + e^{2x}}$	

Çok katmanlı ileri beslemeli sinir ağları, giriş değerleri ve çıkış değerleri arasındaki fonksiyonel ilişkileri başarılı biçimde temsil edebildiği için uzaktan algılamada kullanılması uygundur. Bu ağ yapısı giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç kısımdan oluşmaktadır. Ek olarak veri akışı giriş katmanından çıkış katmanına

doğrudur ve arada herhangi bir döngü bulunmamaktadır. Giriş katmanı kendisine gelen sinyali(bilgiyi) saklı katmana iletirler. Saklı katmanda, giriş katmanından gelen bilgiler öncelikle ağırlıklandırılarak toplanır ve çıkış katmanına iletir. Çıkış katmanında ise çıkış değerleri üretilir(Amasyalı, S., 2011).

Sınıflandırma amacıyla Yapay Sinir Ağları kullanımının en önemli aşamalarından biri eğitim aşamasıdır. Eğitim aşamasında eğitim verisine ait değerlendirme fonksiyonunun optimizasyonu için bağlantı ağırlıkları güncellenerek durdurma kriterine ulaşana kadar hesaplanır. Ağların eğitimi için farklı arama yöntemleri kullanılmasına rağmen en çok tercih edilenlerden biri geri yayımlı öğrenme yöntemidir (Rocach, L., 2011). Bu yaklaşımda hatalar çıkıştan girişe doğru azaltılmaya çalışıldığı için bu şekilde isimlendirilmiştir. Çok katmanlı ileri beslemeli geri yayımlı yapay sinir ağı Şekil 2.de gösterilmiştir.



Şekil 2. Çok katmanlı ileri beslemeli geri yayımlı yapay sinir ağı

2.2. En Çok Olabilirlik Yöntemi

Parametrik bir yöntem olan En Çok Olabilirlik Yöntemi literatürde en fazla kullanılan sınıflandırma yöntemlerinden biridir. Bu yöntemde varyans, kovaryans ve ortalama değer gibi istatistikî değerler kullanılarak piksellerin sınıflara ait olma olasılıkları hesaplanır ve olasılığın en yüksek olduğu sınıfa atanmaları sağlanır. Ek olarak bu yaklaşımda uydu görüntülerinin her bir bandının normal dağılıma uyduğu kabulü yapılır.

En Çok Olabilirlik Yöntemi'nde sınıfların ilk olasılık değerleri ile ilgili bilgi yoksa olasılıkların hepsi eşit kabul edilir ve herhangi bir pikselin belirlenen sınıflar dışında bir sınıfa ait olup olmadığı belirlenmeye çalışılır. Pikselin olasılık değerinin eşik değerin altında olması durumunda ise piksel bilinmeyen etiketini alır. Ayrıca hesaplanan olasılıklar düzey ekseninde gösterilmesi sayesinde varyans ve kovaryans değerleri de hesaba katılarak uzaysal dağılımları da sınıflandırma işlemine dahil edilmiş olur. Yöntemin eşitliği şu şekildedir.

$$D = \ln(a_c - [0.5 \cdot \ln(|cov_c)|]) - 0.5 \cdot (X - M_c)^T \cdot (cov_c)^{-1} \cdot (X - M_c) \quad (3)$$

Bu eşitlikte:

D : Olasılık değerini

c : Örnek bir sınıfı

X : Aday pikselin ölçüm vektörünü

M_c : c örnek sınıfının ortalama vektörünü

a_c : Aday pikselin C sınıfına ait olma yüzdesini

cov_c : c örnek sınıfındaki piksellerin varyans-kovaryans matrisini göstermektedir (Mather, P. M., 1987; Çölkesen, İ., 2009).

2.3. Karar Ağaçları

Karar Ağaçları Yöntemi son yıllarda uydu görüntülerinin sınıflandırılması, karakter tanıma, radar sinyallerinin sınıflandırılması gibi birçok farklı alanda başarılı biçimde kullanılmaktadır. Bu yöntemin bu kadar tercih edilmesinin temel nedeni ise, başarılı sonuçlar verebilmesine rağmen kolay yorumlanabilir ve sade olmasıdır(Safavian, S., R., vd. 1991). Bir karar ağacı düğüm, dal ve yaprak olarak adlandırılan üç temel kısımdan oluşur. Her bir nitelik düğüm tarafından temsil edilir. Karar Ağaçları'nda en önemli problem ise dallanmanın hangi kıstasa göre yapılacağını belirlenmesidir. Kullanılabilecek her farklı kriter ise bir karar ağacı algoritmasına karşılık gelir. Bu algoritmalar temelde üç gruba ayrılır (Özkan, Y., 2008):

- Bellek tabanlı sınıflandırma algoritmaları
- Sınıflandırma ve regresyon ağaçları
- Entropiye dayalı algoritmalar

Bellek tabanlı sınıflandırma algoritmalarından en çok bilinen k- en yakın komşuluk algoritmasıdır. Entropiye dayalı dallanma kistasını kullanan algoritmalara örnek olarak ID3 ve C4.5 verilebilir (Özkan, Y., 2008). Sınıflandırma ve regresyon ağaçlarında ise dallanma kriteri olarak Gini İndeksi ve Twoing Algoritması en çok kullanılan yöntemlerdir. Bu çalışmada sınıflandırma ağaçları(CART) tercih edilmiştir.

2.3.1. Sınıflandırma ve Regresyon Ağaçları(CART)

Breiman tarafından önerilen bu yöntem veri sınıflandırmada sık olarak kullanılan yöntemlerden biridir(Breiman, L., vd. 1984). Bu yaklaşımda eğitim verisindeki hedef değerinin kategorik olması durumunda sınıflandırma ağacı(classification tree), sürekli olması durumunda regresyon ağacı(regressio ntree) olarak adlandırılır. Ancak çalışmaların çoğunda Classification and Regression Trees (CART) olarak isimlendirilerek kullanılır (Atasever, Ü., H., 2011;Chang, L.,Y., and Wang, H.,W., 2006).

Karar Ağaçları temelli bir yöntem olan CART, çok büyük veri gruplarını basit kurallar kullanarak hızlı sınıflandırabilme yeteneği nedeniyle başta mühendislik bilimleri olmak üzere birçok farklı disiplinde tercih edilmektedir. Bu yöntemin diğer Karar Ağaçları'ndan en önemli farkı ise sadece ikili dallanmalara izin vermesidir. Dallanmanın belirlenmesi için genelde ise Gini İndeksi Algoritması ve Twoing Algoritması olmak üzere iki kistas kullanılır.

2.3.2. Gini Algoritması

Gini bölünme kuralı(yada Gini İndeks) en çok kullanılan kuraldır. Her bit T düğümü için Gini indeksi şu şekilde hesaplanır:

$$Gini(T) = 1 - \sum_j [p(j | T)]^2 \quad (4)$$

Eşitlikte $p(j | T)$, T düğümündeki j sınıfına ait bağıl olasılığı göstermektedir. Ek olarak Gini İndeksi gürültülü verilerde de oldukça başarılı sonuçlar verir(İnternet-2).

2.3.3. Twoing Algoritması

Bu yöntem Gini indeksine göre daha dengeli ağaçlar olmasına rağmen daha yavaş çalışır. Twoing indeksi 5 nolu eşitlikle hesaplanır:

$$Twoing(T) = \frac{P_L \cdot P_R}{4} \cdot \left[\sum_i (|p(i | T_L) - p(i | T_R)|) \right]^2 \quad (5)$$


Eşitlikte R sağ dal, L sol dal anlamına gelmektedir. $p(i | T_L)$, T_L düğümündeki i sınıfına ait bağıl olasılık, $p(i | T_R)$, T_R düğümüne ait bağıl olasılık; P_L , aday verinin sola bölünme olasılığı; P_R , aday verinin sağa bölünme olasılığıdır(Timofeev, R., 2004).

2.4. Torbalama(Bagging)

Bagging, 1994 yılında Breiman tarafından ortaya atılan, istatistiksel sınıflandırma yöntemlerinin doğruluğunu arttıran makine öğrenmesi temelli bir grup(ensemble) algoritmasıdır(Breiman, L., 1996). Bu yöntem varyansı düşürdüğü için aşırı öğrenmenin engellenmesine yardımcı olur. Temelde, bir eğitim verisinin farklı kombinasyonlarının üretilerek birden fazla eğitim örneğinin oluşturulması amaçlanır. Eğitim verisinin N adetten oluştuğunu varsayarsak, yine N örneğe sahip bir eğitim verisi rastgele seçimle yerine koymalı olarak üretilir. Bu durumda ise bazı eğitim verisindeki bazı örnekler yer almazken, bazıları birden fazla yer alır. Her bir karar ağacı bu şekilde üretilmiş birbirinden farklı örnekler içeren eğitim verileri ile eğitilirler ve sonuç çoğunluk oylaması ile belirlenir. Bagging(Torbalama) Algoritması şu şekilde özetlenebilir:

- 1) Orjinal eğitim verisi D olsun
İşlem N kere tekrarlanır
- 2) D kümesinden yeni bir D_k bootstrap örneği üretilir
- 3) Sınıflandırıcı D_k eğitim verisi kullanılarak eğitilir
 N adet sınıflandırıcı birleştirilir

Ek olarak, Bagging(Torbalama) Tekniği Şekil 3.de görselleştirilmiştir.



Şekil 3. Bagging(Torbalama) Yöntemi

3. UYGULAMA

2009 tarihli Kayseri il merkezine ait Landsat TM uydu görüntüsünün sınıflandırılması için ilk olarak dokuz arazi örtüsünü temsil eden eğitim alanları seçilmiştir. Sınıflandırma işlemi için kullanılacak olan teknikler MATLAB ortamında kodlanmıştır. Kullanılan yöntemlerden Yapay Sinir Ağları ve Torbalama-Karar Ağaçları parametre değişimine çok hassastır. Yapay Sinir Ağları'nda kullanılacak ağ modeli, öğrenme fonksiyonu ve epok sayısı modelin doğruluğunu ciddi oranda etkilemektedir. Bu çalışma kapsamında Yapay Sinir Ağları, ileri beslemeli geri yayımlı çok katmanlı ağ modeli, hiperbolik tanjant aktivasyon fonksiyonu, Levenberg-Marquardt optimizasyon algoritması kullanılarak 100 epokta eğitilmiştir. Torbalama-Karar Ağaçları'nda ise zayıf öğrenici(weak learner) sayısı ve dallanma kriteri sınıflandırma doğruluğu üzerinde farklı değişimler gösterebilmektedir. Bu çalışma kapsamında Torbalama-Karar Ağaçları yöntemi 5, 10, 50 ve 100 zayıf öğrenici ve farklı dallanma kriterleri kullanılarak eğitilmiştir. Elde edilen bulgular karşılaştırmalı olarak Çizelge 2. de sunulmuştur.


Çizelge 2. Farklı yöntemlerden elde edilen sonuçların karşılaştırılması

	Karar Ağaçları (CART)		Yapay Sinir Ağları ¹	En Çok Olabilirlik	Torbalama-Karar Ağaçları ² (CART)			
	Gini	Twoing			5	10	50	100
Genel Doğruluk(%)	87.3	86.9	91.1	88.1	88	89.4	92.3	92.5
Kappa Katsayısı	0.85	0.84	0.89	0.87	0.86	0.88	0.90	0.91

¹30 koşturma sonucu elde edilen sonuçların ortalamasıdır.

² Torbalama-Karar Ağaçları'nda kullanılan zayıf öğrenici sayısıdır.

Çizelge 2. de görüldüğü gibi Torbalama yönteminin Karar Ağaçları'na eklenmesi ile bu yöntemin doğruluğu yaklaşık %5 oranında artmıştır. Zayıf öğrenici sayısı arttıkça sınıflandırma doğruluğu da belli bir düzeye kadar artmış olmasına rağmen belli bir sayıdan sonra başarı artışı gözlemlenememiştir. Zayıf öğrenici sayısının artması öğrenme sürecinde başarı düzeyini belli bir düzeye kadar arttırmasına rağmen hesap maliyetini ciddi oranda arttırmaktadır. Torbalama-Karar Ağaçları Yöntemi kullanılarak üretilen tematik harita Şekil 4. de gösterilmiştir.



Şekil 4. Torbalama-Karar Ağaçları yöntemi kullanılarak üretilen tematik harita

4. SONUÇLAR

Uzaktan algılama sinoptik görüş ve düzenli veri üretebilme gibi kabiliyetlerinden dolayı birçok farklı bilim dalı tarafından tercih edilen veri kaynaklarından biridir. Uydu görüntülerinden anlamlı veya tematik bilgi üretebilmenin temel adımlarından biri kuşkusuz sınıflandırmadır. Yapılan birçok çalışma hassas ve doğru bilgilere ihtiyaç duyduğundan, tercih edilecek sınıflandırma yöntemi önemli bir bileşendir. Günümüzde bilişim ve istatistiksel öğrenme alanındaki gelişmeler farklı sınıflandırma yöntemlerinin veya sınıflandırma yönteminin doğruluğunu arttıran meta-algoritmaların geliştirilmesine neden olmuştur. Özellikle uydu görüntülerinin sınıflandırılmasında Yapay Sinir Ağları, En Çok Olabilirlik ve Karar Ağaçları temelli yöntemler oldukça sık kullanılmaktadır. Son dönemlerde ise mevcut yöntemlerin doğruluğunu arttırabilen, meta-algoritma olarak adlandırılan yöntemlerde sınıflandırma işlemine dahil edilmektedir. Genelde istatistiksel öğrenme tabanlı olan bu yöntemlerin başında basit ama etkili bir yaklaşım olan Torbalama(Bagging) gelmektedir. Çoğunlukla Karar Ağaçları'na uygulanan bu meta algoritma özellikle karmaşık verilerin sınıflandırılması sırasında, eğitim verisinde değişiklikler yaparak(yerine koyma) sınıflandırma doğruluğunu arttırmaktadır.

Bu çalışma ile Kayseri merkezine ait Landsat TM görüntüsünün sınıflandırma işlemi için Karar Ağaçları ile Torbalama yöntemi birlikte kullanılmış, diğer yöntemlerle karşılaştırılarak, klasik yöntemlere göre daha başarılı sonuçlar verdiği gözlemlenmiş ve Bagging(Torbalama) meta-algoritmasının uydu görüntülerinin sınıflandırılmasında Karar Ağaçları(CART) yönteminin doğruluğunda artış sağladığı ortaya konmuştur.

KAYNAKLAR

Amasyalı, S., 2011, Operasyon İşlemlerinin Hızlandırılmasında Veri Madenciliğinin Kullanılması, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul

Atasever, Ü., H., 2011,Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rastgele Orman (RandomForest) ve Regresyon Ağaçları Yöntemlerinin Kullanılması, *Yüksek Lisans Tezi*, Erciyes Üniversitesi, Kayseri

Breiman, L., 1996, Bagging predictors, *Machine Learning*, 24 (2): 123–140

Breiman, L., Friedman, J., H., Olshen, R., A., Stone, C., J., 1984, Classification and regression trees. Monterey, CA: Wadsworth & Brooks/Cole Advanced Books

Chang, L., Y., and Wang, H., W., 2006, Analysis of trafficinjuryseverity: An application of non-parametric classification tree techniques, *Accident Analysis & Prevention*, 38(5), 1019-1027.

Çölkesen, İ.,Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi, *Yüksek Lisans Tezi*, Gebze, 2009.

İnternet1:http://www.acikders.org.tr/pluginfile.php/645/mod_resource/content/0/Ek_Kaynaklar/siniflandirma.pdf
12.09.2012

İnternet-2:

http://www.hypertextbookshop.com/dataminingbook/working_version/contents/chapters/chapter001/section003/blue/page002.html ,26.06.2012

Kavzoglu, T., 2001, An Investigation Of The Design And Use Of Feed-Forward Artificial Neural Networks In The Classification Of Remotely Sensed Images, *Doktora Tezi*, Nottingham University, UK.

Kavzoğlu, T., Çölkesen, İ., 2010, Karar Ağaçları İle Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneği, *Harita Teknolojileri Dergisi*, 36-45, Cilt:2, No:1

Mather, P., M., 1987, Computer Processing Of Remote-Sensed Images. John Wiley And Sons Ltd.

Özkan, C., and Sunar ,F., 2003, The Comparison of Activation Functionsfor Multispectral Landsat TM Image Classification, *Photogrammetric Engineering & Remote Sensing*, Vol. 69, No. 11, pp. 1225–1234.

Özkan, Y., 2008, Veri Madenciliği Yöntemleri,S.187-188, Papatya Yayıncılık, İstanbul

Rocach, L., 2010, Pattern Classification Using Ensemble Methods, World Scientific Publishing Co,

Safavian, S., R., Landgrebe D., 1991, A Survey Of Decision Tree Classifier Methodology, IEEE Transactions On Systems Man And Cybernetics, 21, 660-674.

Timofeev, R., 2004, Classification and Regression Trees (CART) Theory and Applications, *Yüksek Lisans Tezi*, Humboldt University, Berlin