


ERDAS TA SINIFLANDIRMA

Dr. Oğuz Güngör

Karadeniz Teknik Üniversitesi
Jeodezi ve Fotogrametri Mühendisliği Bölümü
61080 Trabzon
ogungor@ktu.edu.tr

ERDAS ta Sınıflandırma Akış Şeması




Non-Parametrik Karar Kuralları

- **Parallelepiped**
- **Feature Space (Öznitelik Uzayı)**

Parallelepiped Karar Kuralı

- Aday piksellerin gri değerleri üst ve alt limitlerle kıyaslanır. Bu limitler;
 - Her bir bantta signaturelara ait minimum ve maksimum gri değerleri
 - Her bir bantta signaturelara ait ortalama değerleri $\pm$ belli bir miktar standart sapma
 - Veya sizin belirleyeceğiniz herhangi bir limit.

Parallelepiped Karar Kuralı



Piksel hangi dikdörtgenin içinde kalırsa o sınıfa atanır.

Bir pikselin birden fazla dikdörtgende kalması durumunda:

- Ya piksel ağırlığı en büyük sınıfa atanır
- Ya piksel parametrik bir kuralla göre sınıflandırılır
- Ya da piksel sınıfsız olarak bırakılır

Pikselin hiçbir dikdörtgenin içinde olmaması durumunda :

- Ya piksel parametrik bir kuralla sınıflandırılır
- Ya da piksel sınıfsız olarak bırakılır


Parallelepiped Karar Kuralı

■ Avantajları

- Hızlı ve basit
- Çok zaman gerektiren karmaşık sınıflandırma algoritmaları kullanmadan görüntüdeki muhtemel sınıf sayısını çabucak bulmada çok başarılı.

■ Dezavantajları

- Dikdörtgenler köşelere sahip olduklarından signature ın ortalamasından spektral mesafe olarak uzak piksellerinde sınıflandırılması ihtimali mevcut




Öznitelik Uzayı Karar Kuralı

■ Feature Space

- Öznitelik Uzayı Karar Kuralının Parallelepiped karar kuralından farkı aday piksellerin sınıflarının öznitelik uzayındaki dikdörtgenlerin içinde olup olmamasına değil de yine öznitelik uzayında kullanıcı tarafından oluşturulan poligonların içinde olup olmamasına göre belirlenmesidir.

Öznitelik Uzayı Karar Kuralı



Eğer aday piksele ait gri değer kullanıcı tarafından öznitelik uzayında çizilen poligonlardan birinin içindeyse piksel o signature in temsil ettiği sınıfa atanır.

Bir pikselin birden fazla poligonda kalması durumunda:

- Ya piksel ağırlığı en büyük sınıfa atanır
- Ya piksel parametrik bir kuralla göre sınıflandırılır
- Ya da piksel sınıfsız olarak bırakılır

Pikselin hiçbir geometrik şeklin içinde olmaması durumunda :

- Ya piksel parametrik bir kuralla sınıflandırılır
- Ya da piksel sınıfsız olarak bırakılır

■ Avantajları

- Çoğu zaman parametrik sınıflandırma öncesi kabaca ön bir sınıflandırma işlemi için kullanılabilir
- Normal dağılımda olmayan sınıfları sınıflandırmada başarılı
- Parametrik bilgi ile birbirinden ayrılmaları mümkün olmayan bazı arazi detaylarının birbirinden ayrılarak doğru sınıflandırılmasında başarılı olabilir
- Hızlı bir metot


■ Dezavantajları

- Bir piksel birden fazla signature ın içine düşebileceği için birden fazla sınıfa atanma riski var. Ayrıca bir pikselin sınıfsız kalma riski de mevcut.
- Öznitelik uzayı görüntüsü yorumlama açısından zor olabilir

Parametrik Karar Kuralları

■ Minimum Mesafe (Spektral Mesafe de denir)

- Aday piksel ile her bir signature a ait ortalama vektörü arasındaki spektral mesafeyi hesaplar
- Aday piksel spektral mesafesi en küçük olan signature ın temsil ettiği sınıfa atanır
- Spektral mesafe hesabı Öklit mesafesi hesabına dayanır



$$SD_{xyc} = \sqrt{\sum_{i=1}^n (\mu_{ci} - X_{xyi})^2}$$

Where:

- n = number of bands (dimensions)
- i = a particular band
- c = a particular class
- X_{xyi} = data file value of pixel x,y in band i
- μ_{ci} = mean of data file values in band i for the sample for class c
- SD_{xyc} = spectral distance from pixel x,y to the mean of class c

Source: [Swain and Davis, 1978](#)

Minimum Mesafe Karar Kuralı

■ Avantajları

- Her piksel mutlaka spektral olarak en az bir tane signature ortalamasına yakın olacağından sınıfsız piksel kalmaz
- Parallelepiped karar kuralı hariç en hızlı karar kuralıdır.

■ Dezavantajları

- Sınıfsız kalması daha mantıklı olan pikseller dahi bir sınıfa atanır.
- Sınıf içi çeşitliliği gözetmez. Örneğin, şehir merkezi sınıfında şehre ait bazı detaylara ait gri değerler büyük çeşitlilik gösterir. Bu durumda aslında şehre ait olaması gereken pikseller, gri değerler signature ortalamasına çok uzak olacağı için başka bir sınıf gibi sınıflandırılabilir.

Parametrik Karar Kuralları

■ Mahalanobis Mesafesi

- Minimum mesafe karar kuralına çok benzer. Tek fark kovaryans matrisi kullanılmasıdır.
- Aday piksel D si en düşük çıkan c sınıfına atanır.

$$D = (X - M_c)^T (Cov_c^{-1}) (X - M_c)$$

Where:

D	=	Mahalanobis distance
c	=	a particular class
X	=	the measurement vector of the candidate pixel
M_c	=	the mean vector of the signature of class c
Cov_c	=	the covariance matrix of the pixels in the signature of class c
Cov_c^{-1}	=	inverse of Cov_c
T	=	transposition function

The pixel is assigned to the class, c , for which D is the lowest.

Mahalanobis Mesafesi

■ Avantajları

- Minimum mesafe ve paralelepiped karar kurallarının aksine sınıf içi gri değer çeşitliliğini dikkate alır.

■ Dezavantajları

- Minimum mesafe ve paralelepiped karar kurallarına göre daha uzun zaman alır
- Parametrik bir kural olduğu için başarısı görüntünün normal dağılımda olup olmamasına bağlıdır.

Parametrik Karar Kuralları

■ Maximum Likelihood / Bayesian

- Her pikselin bir olasılıkla bir sınıfa ait olması gerektiği prensibine dayanır
- Temel eşitlik bütün sınıfların olasılıklarını eşit alır tüm bantların normal dağılımda olduğunu farz eder.
- Aday piksel D si endüşük çıkan c sınıfına atanır.

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

Where:

D	=	weighted distance (likelihood)
c	=	a particular class
X	=	the measurement vector of the candidate pixel
M_c	=	the mean vector of the sample of class c
a_c	=	percent probability that any candidate pixel is a member of class c (defaults to 1.0, or is entered from <i>a priori</i> knowledge)
Cov_c	=	the covariance matrix of the pixels in the sample of class c
$ Cov_c $	=	determinant of Cov_c (matrix algebra)
Cov_c^{-1}	=	inverse of Cov_c (matrix algebra)
$\ln$	=	natural logarithm function
T	=	transposition function (matrix algebra)

Maximum Likelihood / Bayesian

■ Avantajları

- Ders kapsamında anlatılan yöntemler arasında en başarılı ve doğru sonuç veren sınıflandırma karar kuralıdır.
- Mahalonobis mesafesi karar kuralında olduğu gibi sınıf içi gri değer çeşitliliğini dikkate alır.

■ Dezavantajları

- İşlem çok daha uzun zaman alır. İşlem süresi bant sayısı arttıkça daha da uzar.
- Parametrik bir kural olduğu için başarısı görüntünün normal dağılımda olup olmamasına bağlıdır.

İmzaların Kontrol Edilmesi

- İmzalar toplandıktan sonra
 - Kontrol edilebilir,
 - Silinebilir,
 - Yeniden adlandırılabilir,
 - ve diğer dosyalarda saklanmış olan imzalarla birleştirilebilir.

İmza Verisinin Kullanımı

- Erdas Imagine yazılımında her bir sınıf için toplanan imzaların sınıfları doğru olarak temsil edip etmediklerini anlamaya yardımcı olan testler vardır.
- Hem kontrollü hem de kontrolsüz eğitim sonucu toplanan imzaları kontrol etmek mümkündür.
- Erdas Imagine yazılımındaki kontrol yöntemleri
 - Alarm
 - Elips
 - Olasılık matrisi
 - Ayrılabilirlik
 - İstatistikler ve histogram
- İmzalar analiz edildikten sonra onları silmek veya birleştirmek, gereksiz görülen bantları atmak, gerekli görülürse yeni bantlar eklemek, veya sınıflandırma sonucunu olumlu yönde etkileyecek diğer bazı operasyonları yapmak daha faydalı olabilir.


- **Alarm**—parallelepiped karar kuralın kullanarak bir imza için tahmini sınıflandırılacak alanı orjinal görüntü üzerinde görebilirsiniz.
- **Elips**—her bant çifti için piksel değerlerine ait elips diyagramlarını ve piksel değerlerine ait dağılımları görebilirsiniz.
- **Olasılık matrisi** —eğitim veri kümesindeki piksellerin yüzde kaçının olması gerektiği gibi yüzde kaçının ise hatalı olarak sınıflandırıldığı görmek için hızlı bir sınıflandırma yapılır. Bu yüzde değerleri bir olasılık matrisinde sunulur. Bu yöntem sadece gerçek görüntü uzayında eğitim piksellerinin poligonlar kullanılarak toplandığı kontrollü eğitim için kullanılabilir.
- **Ayrılabilirlik**—imzalar arasında ayrılabilirlik (istatistiksel mesafe) ölçülür ve sınıflandırma performansını maksimuma çıkartan bant grupları tespit edilir.
- **İstatistikler ve Histogramlar**—İmzalara ait istatistik ve histogramlar kontrol ve kıyaslama yapmak için incelenebilir.

Alarm

- Alarm yöntemi bir ya da daha fazla imzanın tahmini olarak sınıflandırılmış halini orjinal görüntü üzerinde gösterir.
- parallelepiped karar kuralına göre, sınıflandırma kriterine uyan pikseller orjinal görüntüde farklı renklendirilerek görünecektir. Bu pikseller istediğiniz bir renkte gösterebilirsiniz.
- Bu test ile imzanın doğru toplanıp toplanmadığını test etmek için kendi örüntü tanıma yeteneklerinizden veya yer doğrulama bilgilerinden faydalanabilirsiniz.

Ellipse

- Bu yöntemde imza dosyalarında saklanan imzalara ait ortalama ve standart sapma değerleri kullanılarak elipsler hesaplanır
- Ayrıca dikdörtgenler, ortalamalar ve etiketler üretmek te mümkündür.
- Yöntemde her bir imzaya ait ortalama ve standart sapma değerleri elipsleri 2 boyutlu öznitelik uzayında çizmek için kullanılır.
- Her bant çifti için elips grafikleri incelenerek hangi imzalar hangi bant çiftlerinde daha iyi ayrıştırılabilir ve daha iyi bir sınıflandırma performansı sağlar anlaşılabilir.



Eğer öznitelik uzayında çizilen elipslerde büyük oranda üst üste örtüşme varsa, bu farklı sınıflar için toplanan imzaların sözkonusu bant çiftinde çok benzer spektral özellik gösterdiğini ve sınıflandırma sonucu bunların birbirine karışacağını gösterir. En ideal durum elipselerin hiç üst üste binmemesidir. Fakat, küçük bir miktar binme tolere edilebilir.

Olasılık Matrisi

- Bu yöntem seçilen AOI lardaki bütün pikselleri sınıflandırır ve sonuçları eğitim için toplanan piksellerle kıyaslar.
- Eğitim için toplanan pikseller her zaman homojen olmayabilir ve eğitim pikselleri içerisindeki bazı pikseller başka sınıflara gidebilir.
- Her örnek piksel aslında sadece her sınıfı belirleyen istatistik bilgilerine bir ağırlık olarak katkı sağlar. Eğer her eğitim örneğine ait imza istatistiği diğer örneklerden tamamen farklılık gösteriyorsa örnek eğitim piksellerinin tahmin edildiği sınıfa ait olacak şekilde sınıflandırılır.
- Bu yöntemde toplanan örnek eğitim pikselleri minimum mesafe, en çok benzerlik veya Mahalanobis mesafesi karar kuralları ile sınıflandırılır.
- Sonra bir olasılık matrisi üretilir. Bu matris hangi piksellerin olması gerektiği gibi hangilerinin ise hatalı sınıflandırıldığını gösterir.

Ayrılabilirlik

- İmzaların ayrılabilirliği iki imza arasındaki istatistiksel mesafedir.
- Ayrılabilirlik sınıflandırmada kullanılacak herhangi bir band kombinasyonu için hesaplanabilir ve sınıflandırmaya katkı sağlamayacak veya negatif yönde etkileyecek bantları tespit ederek dışarı atmanıza imkan sağlar.
- Ayrılabilirlik için kullanılan formüller en çok benzerlik karar kuralı ile ilişkilidir. Bu nedenle, aslında imzaların ayrılabilirliğinin test edilmesi bir nevi en çok benzerlik karar kuralının performanzsının önceden belirlenebilmesine de yardımcı olur.
- Ayrılabilirlik hesabı için üç seçenek vardır. Tüm üç formül de karşılaştırılan bantlarda imzalara ait kovaryans ve ortalama vektörleri kullanır.

Ayrılabilirlik

The formula for computing Divergence (D_{ij}) is as follows:

$$D_{ij} = \frac{1}{2} \text{tr}((C_i - C_j)(C_i^{-1} - C_j^{-1})) + \frac{1}{2} \text{tr}((C_i^{-1} - C_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T)$$

Where:

- D_i and D_j = the two signatures (classes) being compared
- C_i = the covariance matrix of signature i
- μ_i = the mean vector of signature i
- tr = the trace function (matrix algebra)
- T = the transposition function

Source: Swain and Davis, 1978

Dönüştürülmüş Ayrılabilirlik

The formula for computing Transformed Divergence (TD) is as follows:

$$D_{ij} = \frac{1}{2} \text{tr}((C_i - C_j)(C_i^{-1} - C_j^{-1})) + \frac{1}{2} \text{tr}((C_i^{-1} - C_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T)$$

$$TD_{ij} = 2000 \left(1 - \exp\left(\frac{-D_{ij}}{8}\right) \right)$$

Where:

- i and j = the two signatures (classes) being compared
- C_i = the covariance matrix of signature i
- μ_i = the mean vector of signature i
- tr = the trace function (matrix algebra)
- T = the transposition function

Source: Swain and Davis, 1978

Ayrılabilirlik değerleri 0 ila 2000 arasında çıkar.

Genel geçer kural olark eğer sonuç 1900 dan büyükse sınıflar sorunsuzca ayrılabilir denir. 1700 ila 1900 arası sonuç idare eder anlamındadır.

Sunuç 1700 den düşük çıkarsa sınıflar birbirinden ayırmıyor demektir. (Jensen, 1996)

Jeffries-Matusita Mesafesi

The formula for computing Jeffries-Matusita Distance (JM) is as follows:

$$\alpha = \frac{1}{8}(\mu_i - \mu_j)^T \left(\frac{C_i + C_j}{2} \right)^{-1} (\mu_i - \mu_j) + \frac{1}{2} \ln \left(\frac{|(C_i + C_j)/2|}{\sqrt{|C_i| \times |C_j|}} \right)$$

$$JM_{ij} = \sqrt{2(1 - e^{-\alpha})}$$

Where:

- D_i and D_j = the two signatures (classes) being compared
- C_i = the covariance matrix of signature i
- μ_i = the mean vector of signature i
- tr = the natural logarithm function
- T = the determinant of C_i (matrix algebra)

Source: Swain and Davis, 1978

***JM* mesafesi 0 ila 1414 arasındadır. Yani, Erdas yazılımının sunduğu değerler formülle üretilen değerin 1000 ile çarpılmış halidir.**

Signature Manipulation

- In many cases, training must be repeated several times before the desired signatures are produced. Signatures can be gathered from different sources—different training samples, feature space images, and different clustering programs—all using different techniques.
- After each signature file is evaluated, you may merge, delete, or create new signatures. The desired signatures can finally be moved to one signature file to be used in the classification.
- The following operations upon signatures and signature files are possible with ERDAS IMAGINE:
 - View the contents of the signature statistics
 - View histograms of the samples or clusters that were used to derive the signatures
 - Delete unwanted signatures
 - Merge signatures together, so that they form one larger class when classified
 - Append signatures from other files. You can combine signatures that are derived from different training methods for use in one classification.