

RASTER GÖRÜNTÜLERDEN ŞEKİL (PATERN) TANIMAYA İLİŞKİN TEMEL MATEMATİKSEL YAKLAŞIMLAR

Sedat DOĞAN
Sebahattin BEKTAŞ

ÖZET

Raster görüntülerden, kartografik nesnelerin ve insan yapımı yapay tesislerin bilgisayar kullanılarak otomatik olarak belirlenmesi sayesinde, kartografya, planlama, CBS analizleri vb. birçok konuda zaman, hız ve maliyet kazancı sağlanabilir ve farklı amaçlar için yeni modeller geliştirilebilir. Raster görüntüler, harita, yazılı doküman, fotoğraf gibi grafiksel bilgilerin tarayıcılarla taranması ile ya da dijital formatta resim çekebilen kameralarla elde edilir ve raster dosya formatında bilgisayara aktarılırlar. Raster görüntülerden yapay tesislerin otomatik olarak çıkarılmasını sağlamak amacıyla geliştirilecek bir sistemle, haritaların otomatik olarak vektöre dönüştürülmesi, elyazısı ya da kitap puntolarıyla yazılmış dokümanların otomatik olarak metin formatına dönüştürülmesi, hava veya yer fotoğraflarından üzerindeki yapay tesislerin otomatik olarak çıkarılması ve bu tesislerin üç-boyutlu modellerinin kurulması vb. gibi daha akla gelebilecek bir çok işlem yapılabilir.

Bu makalede, raster görüntülerden kartografik ve fotogrametrik nesnelerin otomatik olarak çıkarılması amacıyla kullanılabilecek matematiksel yaklaşımlar genel hatlarıyla tanıtılacaktır.

ABSTRACT

With the recognition of cartographic and man-made objects from raster images automatically, on the subjects such as cartography, planning, GIS analysis etc., speed and costal benefits can be provided and new models can also be developed for various purposes. Raster images are achieved and transferred to computer media either from scanned materials such as maps, printed documents and photographs etc., or directly from the cameras, taking digital pictures in the raster format. With a system to be developed to serve for extracting man-made objects from the raster images, automatic vectorisation of maps, conversion of the scanned handwriting or printed documents to text format, recognition of man made objects from aerial or terrestrial photographs and reconstruction of 3-D models of these recognized objects and still many other processes might come in mind will able to be performed.

In this paper, the mathematical approaches which can be used for extraction of cartographic and photogrammetric objects from raster images, will be introduced with their general views.

1. GİRİŞ

Raster görüntülerden farklı amaçlar için gerek geometrik gerekse istatistiksel bilgilerin otomatik olarak çıkarılması için yapılan işlemler genel olarak **“görüntü tetkiki” (visual inspection)** ya da **“görüntü anlama” (image understanding)** olarak adlandırılmaktadır. Görüntülerin yorumlanması için kullanılan teorik modeller ise temelde **“patern tanıma”(pattern recognition)** teorilerine dayanmaktadır. Buradaki **“patern tanıma”** kavramı

yerine “*şekil tanıma, şekil anlama ya da cisim algılama*” gibi kavramlar da kullanılabilir. Buradaki şekil ya da cisimler, raster görüntüdeki binalar yollar vs. olabileceği gibi, alfabetik karakterler ya da özel tanıtıcı semboller de olabilir. Gerçekleştirilmek istenen bir uygulamadan elde edilmek istenen sonuçlara göre bu kavram, yukarıda sayılan ve daha da sayılabilecek özel kavramlarla isimlendirilip ifade edilebilir. Bu makalede, görüntülerden kartografik nesnelere ve yapay tesislerin geometrik yapılarının otomatik olarak anlaşılması hedeflenmektedir. Bu nedenle, bu makalede, hedeflenen bu amacı ifade etmek için “*şekil anlama, şekil algılama ya da şekil çıkarma*” terimleri kullanılacaktır.

Bir raster görüntüden şekillerin çıkarılmasından önce, görüntü üzerinde hataya neden olabilecek istenmeden oluşan ve görüntü adı verilen bozucu verilerin (etkilerin) giderilmesi gerekir. Yine, net olmayan bir görüntünün, şekil çıkarma işlemlerinden önce netleştirilmesi gerekir. Bu tür görüntü iyileştirme amacıyla yapılan işlemlere de genel olarak “*görüntü işleme*” (*image processing*) adı verilir. Görüntü işleme uygulamaları, hem şekil tanıma yöntemleri hem de bazı özel dönüşümler kullanılarak gerçekleştirilir.

Görüldüğü gibi, raster görüntülerden şekillerin çıkarılması için kullanılan teorilerin çoğu, şekil tanıma (*şekil anlama:pattern recognition*) teorilerinin özel hallerinden ibarettirler. Bu nedenle bundan sonraki bölümde, şekil tanıma işlemleri ile ilgili genel olarak tanıtıcı bilgiler verilecek daha sonra da, şekil tanıma yöntemlerine değinilecektir.


2. ŞEKİL TANIMA NEDİR?

Şekil tanıma kavramı genel olarak, bir dizi olay veya işlemler kümesinin tanımı ve/veya sınıflandırılmasını ifade eder. Tanımlanması istenen işlem ya da olaylar dizisi fiziksel nesnelere ya da mantığın açıklayabileceği olaylar olmalıdır. Bu nesne ve olaylara da genel olarak “*patern (şekil ya da cisim)*” adı verilir. Yazılı bir kağıt üzerindeki harfler, sayılar veya bir fotoğraftaki binalar, insanlar vs. tanınması istenen şekillere örnek olarak verilebilir.

Bir insan, çevresindeki olayların ve nesnelere ne olduğunu ve bunların karşısında nasıl davranması gerektiğini duyu organlarıyla topladığı verileri beyinde yorumlayarak anlar ve yorumun sonucuna göre bir davranış sergileyerek tepkisini ortaya koyar. Bilgisayarın şekilleri otomatik olarak tanıyabilmesi için de benzer süreçlerin var olması gerekir. Yani, önce tanınması istenen varlıklara ait bilgilerin toplanması ve bu bilgilerin bellekte depolanması, daha sonra da bu bilgilerin yorumlanması ve sonuçta varlıkların ne olduğuna karar verilmesi gerekir. Bir insan; görerek, işiterek, tadarak, koklayarak ve dokunarak çevresinden veri toplar. Kimi varlıkları tanımak için sadece görme yetebileceği gibi kimileri için görülen varlığın kokusunun, tadının veya dokusunun yapısının bilinmesine ya da çıkardığı seslere gerek duyulabilir. İnsan, topladığı bu verileri daha önceden kazandığı bilgi ya da deneyimlerle işler ve varlığın ne olduğunu anlar. Bazı durumlarda ise insan daha önce hiç rastlamadığı ya da bilmediği bir varlık ya da olayla ilk kez karşılaşabilir. Bu durumda insan yine de akıl yürüterek, var olan bilgileriyle karşılaştırarak, deneyerek vb. yöntemler kullanarak bu durumu anlamaya çalışır. Eğer bu durumun ilk kez meydana geldiğine ikna olursa, yeni bir bilgi olarak bunu da belleğine yerleştirir ve ileride aynı tür olayların çıkması halinde bu bilgisini de diğerleriyle aynı şartlarda kullanır. İnsan her şeyi tek başına öğrenemez. Çoğumuz edindiğimiz bilgilerin büyük bölümünü okullarda öğretmenlerimizin yardımıyla öğrenmişizdir. Bir matematik problemini derste çözerken takıldığımız bir yerde öğretmenimiz ne yapmamız gerektiğini çoğumuza söylemiştir. Elbetteki kitaplar da en zengin bilgi

kaynaklarındandır. Canlı bir kangruyu hiç görmemiş olsak bile, en azından bir kitapta resmini görmüşüzdür ve eminim hepimiz bir gün Avustralya'ya gitmiş olsak, bu resim sayesinde canlısını gördüğümüz an hemen tanırız. Bilgisayarlarla otomatik şekil tanıma işlemleri de aynen yukarıda anlatılan insan beyni örneğindeki gibi gerçekleştirilir.


Şekil tanıma işleminde yapılması gereken ilk iş, tanınması istenen şekillere ait detay (özellik) noktalarının belirlenmesidir. Şekil-1'de, şekil tanıma sisteminin genel yapısı görülmektedir /3/.



Şekil-1: Şekil Tanıma Sisteminin Genel Yapısı

Şekil-1'de görüldüğü gibi, öncelikle tanınması istenen nesnelere ilgili alıcılarla veri toplanır. Daha sonra toplanan verilerden, tanınması istenen şekilleri en iyi temsil eden detay (özellik) ölçüleri belirlenerek detay vektörleri oluşturulur. Daha sonra da ayırma fonksiyonlarını kullanarak sınıflandırma yapılır ve karar verilir.

Bilgisayarda şekil tanıma için öncelikle, görüntüde var olabilecek olası farklı şekilleri en iyi temsil edebilecek bilgilerin seçilmesi ve bu bilgilerin vektörlerle ifade edilmesi gerekir. Bu amaçla nesnelere tanınması için gerekli olan öznelik bilgilerinin çıkarılması işine **özellik, öznelik ya da detay çıkarma (feature extraction)** adı verilir. Özellik bilgilerinden oluşan vektörlere ise **özellik ya da detay vektörleri** adı verilir. Eğer bir şekle ait n tür detay ölçüsü yapılmışsa, oluşan detay vektörü n boyutlu olacaktır. Örneğin, bir A harfini oluşturan şeklin gri düzey değerleri $X(1), X(2), \dots, X(n)$ şeklinde örneklenebilir. Bu n tane ölçü X detay vektörünü oluşturur. Normal şartlar altında bile olsa, her gözlemede ölçülen değerler farklı değişkenlerdir. Bir A harfi için ölçülen değerler, başka bir A harfi için ölçülen değerlerle aynı olmayacaktır. Bu nedenle, bu ölçüler rastgele değişkenler olur, X vektörü de rastgele vektör olarak adlandırılır. Böylece görüntü üzerindeki her gri-düzye rastgele değişkenli bir X rastgele vektörü ile ifade edilebilir. Bilgisayarda daha hızlı yorumlama olanakları sağlaması bakımından, bu ölçü değerlerinin periyodik bir fonksiyonla ifade edilmesi de mümkündür. Bu durumda hızın yanısıra renk veya gri düzeylerin değişimlerinin yorumlanması olanağı da doğar. Bunun için örneğin bir Fourier dönüşümü kullanılabilir. Dönüşümden sonra pikseller periyodik bir fonksiyonla temsil edilir. Bu periyodik fonksiyonun genliği piksellerin genliği olur. Bu şekilde elde edilen piksel genlikleri de detay ölçüsü olarak kullanılabilir ve X rastgele vektörü ile ifade edilebilir. Farklı özelliklere sahip iki sınıfın olduğu düşünülürse, ve bu iki sınıfa ait ölçü değerleri sırasıyla X_1 ve X_2 rastgele vektörleriyle gösterilirse; bu durumda bu iki vektöre ait ölçülerin dağılımlarının bilinmesi halinde, iki sınıfı ayıran bir sınır belirlenebilir ve bu sınır $g(x_1, x_2)$ gibi bir fonksiyonla ifade edilebilir. Belirlenecek bu sınır birinci, ikinci ya da n . dereceden bir fonksiyon olabilir. Tam bu sınır üzerinde $g(x_1, x_2)=0$ olur ve bu sınır fonksiyonu örnek uzayını iki ayrı bölgeye ayırır. Bu g fonksiyonuna **“diskriminant (ayırma) fonksiyonu”** adı verilir. Bir ölçünün hangi sınıfa ait olduğuna, $g(x_1, x_2) > 0$ ya da $g(x_1, x_2) < 0$ olup olmadığına bakılarak karar verilir. diskriminant fonksiyonunun işaretini belirleyen bir ağ kurulur. Bu ağa “sınıflandırıcı ağ” adı verilir (Şekil-2) /1/.



Şekil-2: Bir Sınıflandırıcının Blok Diyagramı

Şekil tanıma işlemlerinde hangi yöntemler kullanılırsa kullanılsın, sınıflandırmanın yapılabilmesi için bir karşılaştırma kriterinin mutlaka belirlenmesi gerekir. Bu kriteri ifade etmek için ayırma fonksiyonları kullanılır. Ayırma fonksiyonu yukarıda gösterilen $g(x,y)$ fonksiyonu gibi sürekli bir fonksiyon olabileceği gibi, ayrık bir fonksiyon da olabilir. Bu fonksiyon tamamen geometrik şartlarla yazılabileceği gibi, istatistiksel parametrelerle de ifade edilebilir. Örneğin, bir görüntüden farklı bitki örtülerini belirleyen alanları ayırmak için tamamen piksel geometrisine bağlı ayırma fonksiyonları yazılabilir ve bu durumda sınıflandırma, her bir yeni pikselin konumunun bu fonksiyonlarla karşılaştırılması yoluyla yapılır. Yine ileriki bölümlerde anlatılacak şablon karşılaştırma yönteminde de, sınıflandırma için ayırma fonksiyonları kullanılmaktadır. Bu durumda ise ayırma fonksiyonu, örnek şablonlarla sınıflandırılması istenen yeni bir giriş şablonu arasındaki çapraz korelasyon (cross correlation) fonksiyonu olacaktır. Örneğin çapraz korelasyon katsayısı ρ_i ise, bu durumda ayırma fonksiyonu $f = \begin{cases} W_1, & x \leq \rho_i \\ W_2, & x > \rho_i \end{cases}$ (W_1 birinci sınıf, W_2 ikinci sınıf) gibi bir ayrık fonksiyon olacaktır.

Eğer, ayırma fonksiyonlarının tanımlanması için şekil tanıma işleminden önce, hangi sınıfa ait oldukları önceden bilinen veriler kullanılıyorsa, bu veriler ayırma fonksiyonunu öğrenmek için (tanımlamak için) kullanıldıklarından, bu tür şekil tanıma işlemlerine *öğretmenli (supervised) şekil tanıma* denir. Eğer, ayırma fonksiyonlarının tanımlanması için önceden ait olduğu sınıfları bilinen veriler yoksa, bu durumda ayırma fonksiyonu görüntüde var olan verilerden otomatik olarak ya da manuel olarak (elle) seçilen uygun veriler kullanılarak tanımlanır. Bu işleme ise *alıştırma ya da eğitime (learning/training)* adı verilir. Öyleyse bir şekil tanıma işlemi, ya öğretmenli ya da öğretmensiz olarak yapılır. Yine, bir şekil tanıma uygulamasında ayırma fonksiyonları ya geometrik, ya istatistik ya da algoritmik bağıntılarla tanımlanır. Bazı problemlerde ise hem geometrik, hem istatistik ve hatta hem de algoritmik bağıntıların birlikte ya da ikişer ikişer kullanılmasıyla da ayırma fonksiyonları tanımlanabilir, ama ayırma fonksiyonu tanımlanmadan asla sınıflandırma yapılamaz. Başka bir ifadeyle, bütün sınıflandırma işlemleri ayırma fonksiyonlarıyla yapılır.

3. ŞEKİL TANIMA YAKLAŞIMLARI

Pratikte çok farklı şekil tanıma yaklaşımları vardır. Ama temelde çoğu bu bölümde anlatılacak temel yaklaşımları esas almaktadır. Farklılıklar ise, detay ölçülerinin yapılması ve ayırma fonksiyonlarının yorumlanmasında ortaya çıkar. En önemli asıl problem ayırma fonksiyonlarının belirlenmesi yani sınıflandırma için gereken karşılaştırma kriterinin

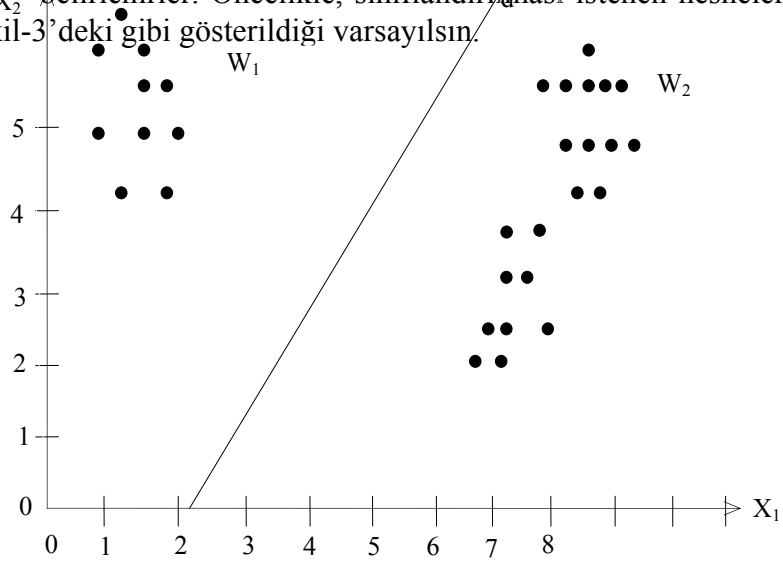
belirlenmesidir. Ayırma fonksiyonlarının belirlenmesinden sonra zaten verilerin sınıflandırılması için bir çok analiz yöntemi kullanılabilir. Ayırma fonksiyonlarını belirleyebilmek için başlangıçta eldeki verilerle hangi yapıda bir fonksiyonun işe yarayacağını bilmesi yararlı olacaktır. Çünkü bu durumda, izlenecek yaklaşımlar belirlenmiş olur. Bu bölümde, şekil tanıma için kullanılacak temel matematiksel yaklaşımlar anlatılacaktır. Bu yaklaşımlar;

- Polinomal ayırma fonksiyonlarıyla şekil tanıma,
- Gruplandırma (clustering) ile şekil tanıma,
- Şablona uydurma (şablona oturtma) ile şekil tanıma,
- İstatistiksel şekil tanıma

olarak ele alınacaktır.

a. Polinomal Ayırma Fonksiyonlarıyla Şekil Tanıma

Bu yaklaşımlar daha çok, uydu ya da hava fotoğraflarından ürün sınıflandırması, bitki örtüsünün belirlenmesi, rekolte tahmini gibi uygulamalarda kullanılmaktadır. Görüntü üzerinde farklı özelliklere sahip alanların belirlenmesi ve bu alanların birbirinden ayırılması için polinomal yapıda ayırma fonksiyonları kullanılır. Bu fonksiyonlar geometrik olarak X_2 belirlenirler. Öncelikle, sınıflandırılması istenen nesnelere yapılan detay ölçülerinin Şekil-3'deki gibi gösterildiği varsayalım.



Şekil-3: Doğrusal Ayırma Fonksiyonu

Şekil-3'de, d doğrusunun solunda kalan bölge W_1 , sağında kalan bölge ise W_2 olmak üzere iki farklı sınıfa karşılık gelmektedir. Öyle bir fonksiyon tanımlanmalı ki, şekilde görülen her bir nokta bu fonksiyonda yerine konduğunda elde edilen değer eğer sıfırdan küçükse bu nokta W_1 sınıfına, eğer sıfırdan büyükse W_2 sınıfına ait olsun. Böyle bir fonksiyonun $1.5 X_1 -$

$1.0 X_2 - 3.5 = 0$ şeklinde tanımlandığını kabul edelim. Yukarıdaki şekle göre, koordinatları (8,4) olan noktanın W_2 sınıfına ait olduğu görülmektedir. Öyleyse bu nokta fonksiyonda yerine konduğunda elde edilen sonuç değerinin sıfırdan büyük olması gerekir. Gerçekten de, $1.5 \times 8 - 1.0 \times 4 - 3.5 = 4.5 > 0$ elde edilir ve bu $X(8,4)$ noktasının W_2 grubuna ait olduğu söylenebilir. Benzer şekilde (4,4) noktası aynı fonksiyonda yerine konursa, $1.5 \times 4 - 1.0 \times 4 - 3.5 = -1.5 < 0$ elde edilir. O halde bu noktanın W_1 sınıfına ait olması gerekir ve gerçekten de öyledir. Görüldüğü gibi, sınıflandırma için uygun bir ayırma fonksiyonunun tanımlanması gerekmektedir. Bunun için yapılabilecek en kolay yol, noktaların birbirinden belirgin bir şekilde ayrıldığı bölgeden bir doğrunun geçirilmesidir. Bunun için dengeleyici doğru belirleme teknikleri kullanılabilir. Ancak bu şekilde ya da farklı bir yöntemle belirlenen ayırma fonksiyonlarının, gerçekten de doğru sınıflandırmayı yapıp yapmadığı kontrol edilmelidir. Bunun için öğretme amaçlı kullanılan ve hangi sınıfa ait olduğu bilinen örnek model noktalar kullanılır. Yapılan kontrolde, eğer fonksiyon yanlış sınıflandırma yapıyorsa, doğru sınıflandırma yapabilmesi için fonksiyonun katsayıları değiştirilir. Kontrole devam edilir. Bütün örneklerin doğru sınıflandırılmasını sağlayan katsayılar bulununcaya kadar bu işlemler bir döngü içerisinde devam eder. Bu işlem eğitime, alıştırmaya ya da öğrenme sürecine karşılık gelir. Yani, bilgisayar ayırma fonksiyonunu öğrenmek için çalışmaktadır /3/. Dikkat edilirse, buradaki ayırma fonksiyonu doğrusaldır. Benzer yöntemle doğrusal olmayan ikinci dereceden ya da daha yüksek dereceden polinomal fonksiyonlar da belirlenebilir. Ancak bunun için sınıfların birbirine çok yakın olmaması ve birbirini de örtmemesi gerekir. Pratikte ise bu durumla çok nadiren karşılaşılır. Ayrıca sınıf sayısının çok fazla olduğu durumlarda da hem hesaplama yönünden hem de bilgisayarda yorumlama açısından büyük problemler ortaya çıkar.

b. Gruplandırma ile Şekil Tanıma (Clustering)

Tanınması istenen nesnelere ait şekil noktalarının (detay noktaları / detay vektörleri) hangi sınıfa ait olduklarının bulunması için, bu noktaların bilinen sınıf kümelerinin herbirinin ağırlık merkezine olan uzaklıkları teker teker hesaplanır. Eğer bu detay noktalarının (detay vektörü) en yakınında hangi sınıf varsa, bunlar o sınıfa dahil edilir.

Örnek olarak; W_1 ve W_2 gibi iki tane sınıfın verildiği varsayalım. W_1 sınıfına ait olduğu

bilinen detay vektörleri $\begin{bmatrix} 3 \\ 4 \\ 8 \\ 2 \end{bmatrix}$, $\begin{bmatrix} 2 \\ 9 \\ 5 \\ 1 \end{bmatrix}$, $\begin{bmatrix} 5 \\ 7 \\ 7 \\ 1 \end{bmatrix}$; W_2 sınıfına ait olduğu bilinen vektörler ise

$\begin{bmatrix} 3 \\ 5 \\ 8 \\ 1 \end{bmatrix}$, $\begin{bmatrix} 7 \\ 2 \\ 6 \\ 6 \end{bmatrix}$, $\begin{bmatrix} 5 \\ 6 \\ 3 \\ 2 \end{bmatrix}$ olsun. Hangi sınıfa ait olduğu bilinmeyen yani sınıflandırılması istenen detay

vektörü ise $\begin{bmatrix} 3 \\ 5 \\ 7 \\ 0 \end{bmatrix}$ olsun ve X ile gösterilsin.

Şimdi, X'in W_1 'e mi yoksa W_2 'ye mi ait olduğunun bulunabilmesi için önce, W_1 ve W_2 sınıflarının (kümelerinin / gruplarının) ağırlık merkezlerinin bulunması gerekir. Bu sınıfların ağırlık merkezleri sırasıyla W_{1g} ve W_{2g} ile gösterilirse;

$$W_{1g} = \begin{bmatrix} 3.33 \\ 6.67 \\ 6.67 \\ 1.33 \end{bmatrix}, \quad W_{2g} = \begin{bmatrix} 5.00 \\ 4.33 \\ 5.66 \\ 3.00 \end{bmatrix} \quad \text{şeklinde elde edilir.}$$

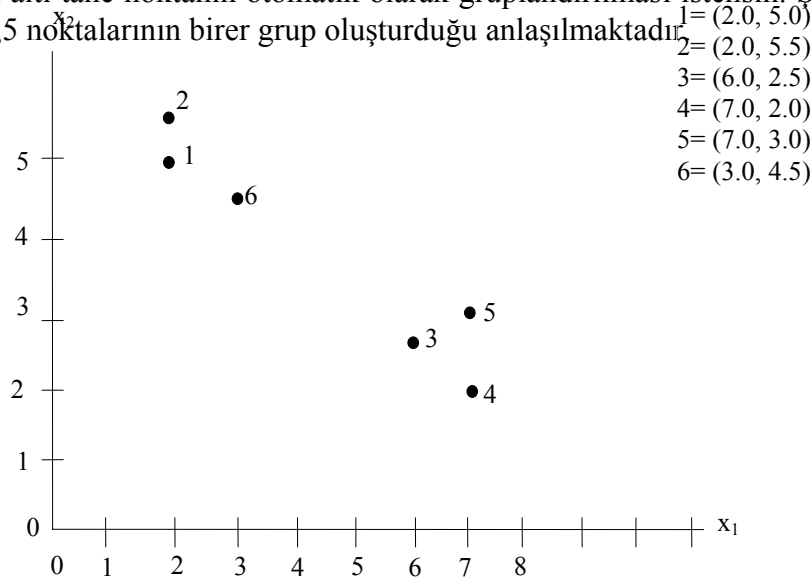
Şimdi de X'in bu iki ağırlık merkezine olan Euklidean uzaklıkları teker teker hesaplanır. Bu uzaklıklara S_1 ve S_2 denirse,

$$S_1 = (3-3.33)^2 + (5-6.67)^2 + (7-6.67)^2 + (0-1.33)^2 = 2.19 \text{ bulunur.}$$

$$S_2 = (3-5)^2 + (5-4.33)^2 + (7-5.66)^2 + (0-3)^2 = 4.07 \text{ bulunur.}$$

$S_1 < S_2$ olduğundan, X vektörünün W_1 sınıfına daha yakın olduğu ve bu yüzden mantıksal muhakeme ile, W_1 sınıfına dahil olma ihtimalinin W_2 sınıfına dahil olma ihtimalinden daha fazla olduğu söylenebilir ve X'in sınıfı W_1 'dir denir. Böylece en kısa uzaklıkla sınıflandırma yapılmış olur.

Gruplandırma işleminin otomatik olarak yapılabilmesi için farklı yöntemler vardır. Şekil-4'de görülen altı tane noktanın otomatik olarak gruplandırılması istensin. Şekle bakıldığında, 1,2,6 ve 3,4,5 noktalarının birer grup oluşturduğu anlaşılmaktadır.



Şekil-4: Otomatik Gruplandırma İçin Örnek Veriler

Detay vektörleri X_1, \dots, X_n olsun. Başlangıç olarak, bu vektörlerden rastgele ikisi, iki farklı grubun ortalaması kabul edilir. Şekil-4'deki 1 ve 2 numaralı noktalar iki grubun orta noktası olsun. Ortalamalar M_i ile gösterilirse, $M_1 = (2.0, 5.0)$, $M_2 = (2.0, 5.5)$ olur. Diğer bütün noktaların bunlara olan uzaklıkları Tablo-1'de verilmiştir.

Tablo-1: Uzaklıkların Hesabı

Nokta No	X_1 'e uzaklığı (S_1)	X_2 'ye uzaklığı (S_2)	Grubu
1	0.00	0.50	1 ($S_1 < S_2$)
2	0.50	0.00	2 ($S_2 < S_1$)
3	4.72	5.00	1 ($S_1 < S_2$)
4	5.83	6.10	1 ($S_1 < S_2$)
5	5.39	5.59	1 ($S_1 < S_2$)
6	1.12	1.41	1 ($S_1 < S_2$)

Yukarıdaki tabloda gösterilen hesaplara göre, birinci grup 1,3,4,5,6 vektörlerinden, ikinci grup ise 2 vektöründen oluşur. Şimdi, yeni oluşan grupların ortalaması hesaplanırsa $M_1 = (5.0, 3.4)$, $M_2 = (2.0, 5.5)$ elde edilir. Aynen yukarıdaki tabloda yapılan hesap gibi, bütün vektörlerin yeni hesaplanan orta noktalara olan uzaklıkları hesaplanırsa, 1,2,6 noktaları ikinci gruba, 3,4,5 noktaları ise birinci gruba girer. Tekrar bu yeni oluşan grupların ortalaması hesaplanırsa, $M_1 = (6.67, 2.5)$ ve $M_2 = (2.33, 5.0)$ elde edilir. Tekrar uzaklıklar hesaplandığında yine birinci grup 3,4,5 ve ikinci grup ise 1,2,6 noktalarından oluşur. Bundan sonra işleme devam etmeye gerek kalmaz. Çünkü her seferde artık aynı gruplandırma elde edilecektir. Dolayısıyla en uygun grup elde edilmiştir artık. Bu yöntemle gruplandırma basit bir bilgisayar programıyla kolayca yapılabilir. Ancak bu yöntem de, eğer sınıflar birbirine bitişik veya birbirini örtüyorsa, kullanılamaz.

c. Şablon Karşılaştırma Tekniği ile Şekil Tanıma (Template Matching)


Bu yaklaşım, tanınması istenen şekillerin belli bir şablona uyması durumunda kullanılır. Örnek olarak raster görüntülerden, Times New Roman gibi bilinen bir yazı fontuyla yazılmış harflerin tanınması ve tanınan harflerin metin formatında bir dosyaya kaydedilmesi verilebilir. Bunun için örneğin Times New Roman fontuyla Türkçe yazılmış bir metnin scannerla taranmasıyla oluşturulmuş bir raster görüntünün metin formatına dönüştürülmesi amacıyla harflerin tanınması istendiğinde, Tüçe'deki 29 tane harfin bu fontta nasıl oluşturulduğunun bilgisayara önceden yüklenmesi gerekir. Yani, 29 tane harfin şablonu hazırlanıp önceden bilgisayarın belleğine yüklenmelidir. Eğer görüntüde farklı fontlarda yazılmış harfler varsa, onlar için de şablonlar hazırlanıp belleğe yüklenmelidir, aksi halde bu farklı fontların tanınması mümkün olmayacaktır. Aynı fontta olup da farklı punto büyüklüğünde olan

harlerin tanınmasında her punto için yeni bir şablon oluşturmaya gerek yoktur. Çünkü tanıma işlemi aynı fonttaki bir şablonun farklı boyutlarda ölçeklendirilmesi yoluyla gerçekleştirilebilir. Şekil tanıma için belleğe önceden yüklenen bu örnek şablonların hepsine birden “*şekil sözlüğü*” adı verilir.

Şablon karşılaştırma tekniği sadece alfabetik veya matematiksel karakterleri tanımak için değil, belli bir şekli olan nesnelere tanıması için de kullanılır. Örneğin, bir fabrikanın ürettiği farklı dört tür el aletinin (makas, tornavida, İngiliz anahtarı, çekiç) beyaz bir bant üzerinde karışık bir sırayla bir robotun önünden geçtiğini, robotun bir kamera aracılığıyla elde ettiği resimleri işleyerek, bu aletleri tanıyıp her birini farklı kutulara koymasına gerektiğini varsayalım. Bu örnekte sınıf sayısının dört olduğu bilinmektedir. Fabrikada hangi aletlerin üretildiği de bilindiğinden ve bu aletlerin şekli de bu fabrikada standart olarak üretildiğinden, bu dört tane aletin şekli, değişik açılardan görüntüsünü içeren birer ya da daha fazla sayıda şablonla ifade edilebilir. Bu durumda robot, o anda önünden geçen aletin görüntüsünü, bellekte her bir alete ait olan şablon ya da şablonlarla teker teker karşılaştırır. Bu karşılaştırmada gördüğü şekil hangi örnek grubuna benziyorsa, onu o grubun konulması gereken kutuya koyar. Tabii burada, robotun kamerası, tanınması istenen cisimleri örnek şablonlarda tanımlandığı şekilde göreceği bir konuma ve açıya monte edilmelidir.

Bu iki örnekte yapılan tanıma ve sınıflandırma işi genel olarak şöyle gerçekleştirilir: Hangi sınıfa ait olduğu bilinmeyen bir şekil, şekil sözlüğündeki sınıflarla teker teker karşılaştırılır. Karşılaştırma sonucu, bilinmeyen şeklin şekil sözlüğündeki hangi sınıfa ait olabileceğine, seçilen bir benzerlik kriterine göre karar verilir. Başka bir deyişle, eğer bilinmeyen şekil, i. sınıfa diğerlerine göre daha iyi uyuyorsa, bu durumda paternin sınıfı i’dir denir. Bu işlemin en kritik yönü, patern sözlüğü ile giriş paterninin karşılaştırılması için kullanılacak ölçütün seçimidir. Bu ölçütler tamamen geometrik ya da topolojik yapıda olabileceği gibi (piksellerin birbirine göre bağlantıları), istatistiksel ölçütler de olabilir (çapraz korelasyon gibi). Bu yöntem hesap açısından oldukça kolaydır ve gürültü verilerinden de pek fazla etkilenmez. Şekil-5’de bir A harfi için belleğe yüklenmek üzere oluşturulan bir şablon örneği görülmektedir.

Şekil-5’deki şablon, bir matris şeklinde belleğe yüklenir. Şekildeki kareler pikselleri temsil etmektedir. Dikkat edilirse, yandaki şablon 15 piksel x 13 piksel’lik bir alandan oluşturulmuştur. Görüntü üzerinde aynı boyutlu alanlar taranır ve her pozisyonda taranan alanlar bellekteki örneklerle karşılaştırılır. Eğer alanla bellekteki şablon tıpkı aynı ise ya da verilen bir tolerans sınırı içinde kalacak şekilde şablonla benzeşiyorsa, o zaman bu alanın bu şablonun sınıfına ait olduğuna karar verilir.



Şekil-5: 'A' harfi için tasarlanmış bir şablon

d. İstatistiksel Şekil Tanıma Yaklaşımı

İstatistiksel şekil tanıma yaklaşımında, eğer rastgele vektörlerin kendi sınıflarına ait şartlı olasılık yoğunluk fonksiyonları ya da şartlı dağılım fonksiyonları bilinirse, bu durumda şekil tanıma problemi istatistiksel hipotez testine dönüşür. W_1 , W_2 gibi iki tane sınıfın verildiği ve şartlı olasılık yoğunluk fonksiyonlarıyla öncül (*a priori*) olasılıkların bilindiği varsayalım. X , detay ölçülerinden oluşan vektör olmak üzere, X 'in W_1 ve W_2 sınıflarından hangisine ait olduğunu bulabilmek için olasılıklara dayalı basit bir karar kuralı,

$$q_1(X) < q_2(X) \text{ ise } X \in W_1 \text{ ya da } q_1(X) > q_2(X) \text{ ise } X \in W_2 \quad (1)$$

şeklinde yazılabilir. Burada $q_i(X)$ verilen X 'in W_i soncul (*a posteriori*) olasılığıdır. Bu (1) bağıntısının anlamı şudur: Eğer X 'in W_1 sınıfına ait olma olasılığı, W_2 sınıfına ait olma olasılığından daha büyükse, bu durumda X , W_1 sınıfına aittir, aksi halde W_2 sınıfına ait olacaktır. $q_i(X)$ soncul olasılıkları, Bayes teoremi ile, öncül P_i olasılıkları ve $P_i(X)$ şartlı yoğunluk fonksiyonları ile şu şekilde hesaplanabilir:

$$q_i(X) = P_i P_i(X) / P(X) \quad (2)$$

Burada $P(X)$, karışık (*mixture*) yoğunluk fonksiyonu olup;

$$P(X) = \sum_{i=1}^L P_i P_i(X) \quad (L: \text{sınıf sayısı}) \quad (3)$$

şeklinde hesaplanır. Bu durumda (1) bağıntısı,

$$P_1 P_1(X) < P_2 P_2(X) \text{ ise } X \in W_1 \text{ ya da } P_1 P_1(X) > P_2 P_2(X) \text{ ise } X \in W_2 \quad (4)$$

halini alır. Ya da aynı eşitlik,

$$L(X) = P_1(X) / P_2(X) < P_2 / P_1 \text{ ise } X \in W_1 \text{ ya da}$$

$$L(X) = P_1(X) / P_2(X) > P_2 / P_1 \text{ ise } X \in W_2 \quad (5)$$

şeklinde ifade edilebilir. Buradaki $L(X)$ ifadesine ise benzerlik oranı (*likelihood ratio*) adı verilir. Bu oran, hipotez testlerinin temel büyüklüğüdür. P_2 / P_1 oranına ise eşik değeri (*threshold value*) adı verilir, $1/1$. Bilgisayarda yorumlanması daha kolay olduğu için yukarıdaki $L(X)$ oranı logaritmik bir fonksiyon olarak da yorumlanabilir. Yani,

$$D(X) = -\ln L(X) = -\ln P_1(X) + \ln P_2(X) > \ln P_1 / P_2 \text{ ise } X \in W_1 \text{ ya da}$$

$$D(X) = -\ln P_1(X) + \ln P_2(X) < \ln P_1 / P_2 \text{ ise } X \in W_2 \quad (6)$$

şeklinde de ifade edilebilir. Negatif logaritma alındığı için eşitsizliklerin yönü değiştirilmiştir. Bu şekilde ifade edilen $D(X)$ fonksiyonu artık bu haliyle sınıflandırma için kullanılan ayırma

fonksiyonu olur. Bu şekilde ayırma fonksiyonunun belirlenmesine *minimum hatalı Bayes karar kuralı* adı verilir /1/, /6/, /2/.

Bayes Hatası: Genelde, gerek (6) bağıntısıyla verilen karar kuralıyla, gerekse başka bir kuralla yapılan sınıflandırma işlemlerinde mutlaka hatalar oluşur. Yani yapılan sınıflandırmanın %100 doğru olduğu söylenemez. Bunun yerine, yapılan sınıflandırmanın ne ölçüde doğru yapıldığını söylemek mümkündür. Bunun için sınıflandırmada yapılabilecek hata olasılığının hesaplanması gerekir. Bu hata aslında, bir detay vektörünün yanlış bir sınıfa dahil edilmesi hatasıdır. Bir X vektörünün şartlı hatasına $r(X)$ denirse, bu hata (1) bağıntısında kullanılan soncul $q_1(X)$ ya da $q_2(X)$ olasılıklarından küçük olanına eşittir. Yani,

$$r(X) = \min \{ q_1(X), q_2(X) \} \text{ olur.} \quad (7)$$

Toplam hataya karşılık gelen Bayes hatası ise, $r(X)$ ' in $E\{r(X)\}$ ümit değerine eşit olur /1/. Daha açık ifade edilirse;

$$\begin{aligned} \varepsilon &= E\{r(X)\} = \int r(X) P(X) dX \\ &= P_1 \int_{L_2} P_1(X) dX + P_2 \int_{L_1} P_2(X) dX \\ &= P_1 \varepsilon_1 + P_2 \varepsilon_2 \end{aligned} \quad (8)$$

olur. Burada $\varepsilon_1 = \int_{L_2} P_1(X) dX$ ve $\varepsilon_2 = \int_{L_1} P_2(X) dX$ 'e eşittir. (8) eşitliğinde, L_1 ve L_2 bölgeleri, X 'in bu karar kuralı ile W_1 ve W_2 sınıflarına atandıkları bölgelerdir. L_1 bölgesinde, $P_1 P_1(X) > P_2 P_2(X)$ olur ve bu yüzden de, $r(X) = P_2 P_2(X) / P(X)$ olur. Benzer şekilde, L_2 bölgesinde de, $P_1 P_1(X) < P_2 P_2(X)$ olur ve $r(X) = P_1 P_1(X) / P(X)$ olur. Dikkat edilirse, W_1 ve W_2 sınıflarına yanlış atamadan dolayı iki tür hata ortaya çıkmaktadır. ε_1 ve ε_2 hataları. Toplam hata ise, bunların ağırlıklı toplamına eşittir.

İstatistiksel şekil tanımada, yoğunluk fonksiyonlarının tanımlanması için bu fonksiyonu oluşturan parametrelerin belirlenmesi gerekir. Bir dağılımı en iyi tanımlayan parametreler ortalama değerler ile otokorelasyon değerleridir. Bunların özel bir ifade şekli de varyans-kovaryans matrisleridir. Pratikte, bu parametrelerin belirlenmesi için eldeki deneysel veriler kullanılır. Bu parametreler, olasılık teorisi kullanılarak belirlenir. Ayırma fonksiyonunun, ortalama vektör ($E\{X\}$) ve kovaryans matrisleriyle ifade edilmesi yaklaşımına "*parametrik yaklaşım*" adı verilir. Ayırma fonksiyonunun doğrudan bu parametrelerle ifade edilememesi durumunda ise, yoğunluk fonksiyonunun yapısal olmayan yollarla elde edilmesine çalışılır. Bunun için bütün örnek kümesi değil de, amaca göre uygun seçilen komşu örnek kümelerinden yoğunluk fonksiyonunun elde edilmesine çalışılır. Bu yaklaşıma da "*nonparametrik (parametrik olmayan) yaklaşım*" adı verilir.

Bayes sınıflandırmasını basit bir örnekle açıklayalım. Bir raster görüntüde; çimenlik bir alanın ortasından bir yolun geçtiği ve bu yolun üzerinde de bir arabanın yol aldığı varsayalım. Oluşturulacak bir sistemle, bu görüntüden çimenlik, yol ve arabanın tanınması istensin. Bu işlemin, Bayes yöntemiyle gerçekleştirileceği kabul edilsin:

Önce, görüntü üzerinden her sınıfa ait alıştırma bölgeleri seçilir. Daha sonra, bu alanlara ait piksellerin renklerine göre sayıları (frekansları) belirlenir. Bir bölgedeki (sınıftaki) farklı renklere sahip piksellerin sayısı, sırayla bölgedeki toplam piksellerin sayısına bölünürse, bu bölgedeki koşullu olasılıklar elde edilmiş olur. Tabii ki piksellerin renkleri ya da gri düzey değerleri de detay ölçülerine karşılık gelir. Örnek olarak Tablo-2'deki değerlerin belirlendiği varsayalım.

Tablo-2: Piksel Frekansları (sayıları)

	0	1	2	3	TOPLAM
YOL	50	12	0	0	62
ARABA	14	30	28	2	74
ÇİMEN	0	10	34	20	64

Yukarıdaki her bir sınıfa ait farklı renkteki piksellerin sayısı, ait olduğu sınıftaki toplam piksel sayısına bölünürse, her bir renge ait koşullu olasılıkları elde edilir. Bu değerler ise Tablo-3'de gösterilmiştir.

Tablo-3: Sınıfların Koşullu Olasılıkları

	0	1	2	3	TOPLAM
YOL	0.81	0.19	0.00	0.00	1.00
ARABA	0.19	0.41	0.38	0.03	1.00
ÇİMEN	0.00	0.16	0.53	0.31	1.00

Yukarıdaki olasılıklarla şöyle bir yorum yapılabilir. Araba sınıfı içinde seçilen herhangi bir pikselin gri düzey değerinin 1 olma olasılığı 0.41'dir. Yani $P(1 / araba) = 0.41$ 'dir. Görüntüden seçilen rastgele bir pikselin hangi sınıfa ait olabileceğine karar verebilmek için de, görüntüyü oluşturan toplam piksel sayısının bilinmesi gerekir. Bu sayı gerçek uygulamalarda elbetteki bilinir. Çünkü raster görüntülerin piksel olarak boyutları her zaman bellidir. Bu örnekte, toplam görüntü piksel sayısı 200 kabul edilsin. Şimdi herhangi bir pikselin sırasıyla, yol, araba ve çimen sınıfına ait olma olasılığı hesaplanırsa;

$$P(\text{bir pikselin yol olma olasılığı}) = 62/200=0.31,$$

$$P(\text{bir pikselin araba olma olasılığı})=74/200=0.37,$$

$$P(\text{bir pikselin çimen olma olasılığı})=64/200=0.32 \text{ olarak elde edilirler.}$$

Bu hesaplamadaki 62, 74, 64 sayıları sırasıyla her bir sınıftaki toplam piksel sayısına eşittir. Bu hesaplanan olasılıklar sırasıyla Tablo-3'deki olasılık değerleriyle çarpılırsa, her bir sınıfın en iyi hangi gri düzey değeri ile temsil edildiği olasılığı ortaya çıkar. Bu olasılık değerleri de Tablo-4'de verilmiştir.

Tablo-4: Soncul Olasılıklar

	0	1	2	3
YOL	0.25	0.06	0.00	0.00
ARABA	0.07	0.15	0.14	0.01
ÇİMEN	0.00	0.05	0.17	0.10

Bu aşamada artık, hangi sınıfın hangi gri düzey değerlerinden oluştuğuna karar verilebilir. Yol sınıfının gri düzey değerinin 0(sıfır) olma olasılığı en yüksek olduğundan, görüntüdeki 0 değerli gri düzeye sahip pikseller yol sınıfına dahil edilir. Benzer şekilde, gri düzey değeri 1 olan pikseller araba sınıfına 2 ve 3 olan pikseller de çimen sınıfına dahil edilir. Böylece sınıflandırma işlemi tamamlanmış olur. Elbetteki sadece bu verilerle doğruluğu çok yüksek bir sınıflandırma yapılamaz. Gerçek uygulamalarda, gri düzey değerlerinin yanısıra başka bilgiler de dikkate alınır. Örneğin gri düzey değerlerinin farklı gri düzey değerleriyle yanyana geldiğinde oluşturduğu parlaklık oranı, rengin yoğunluğu vs. gibi bilgiler de sınıflandırma için aynı anda kullanılabilir. Bunlardan başka, sınıfların morfolojik yapısı, topolojik ilişkileri gibi ek bilgiler de sınıflandırma için kullanılırlar.

4. ŞEKİL TANIMA SİSTEMLERİNİN HARİTACILIKTA KULLANIM ALANLARI

Raster görüntülerden şekil tanıma sistemleri, haritacılıkla ilgili pek çok konuda önemli kolaylıklar ve yenilikler sağlayacaktır. Bilinen klasik yöntemlerin yerini bu tür otomatik sistemlerin alması sayesinde, zaman, hız ve ekonomi yönünden büyük kazançlar elde edilebilecektir. Aşağıda, böyle bir sistemin haritacılıkta nerelerde kullanılabileceği kısaca özetlenmiştir.

- a. Fotogrametride; resim çiftlerinin yöneltilmesi, 3 boyutlu model oluşturma,*
- b. Kentlerin imar durumundaki değişikliklerin ve çevre kirliliğinin raster veri yapısındaki hava, yer ya da uydu fotoğraflarından / görüntülerinden izlenmesi,*
- c. Kent planlama ve yönetimi,*
- d. Coğrafi Bilgi Sistemi (CBS) için otomatik veri toplama ve raster görüntülerle konumsal analizler,*
- e. Haritaların otomatik olarak genelleştirilmesi,*

f. Tarayıcılarla (scanner) taranarak raster veri yapısına dönüştürülmüş haritaların otomatik olarak vektör veri yapısına dönüştürülmesi,

g. Zirai alanlarda ürün tesbiti ve rekolte tahmini.

Bütün bu işlemlerin kurulacak bir CBS sistemi içinde bütünleştirildiği de düşünülecek olursa, bu sistemlerle hayal gücünün sınırlarını zorlayacak ölçüde gelişmelerin ortaya çıkacağı açıkça görülebilmektedir. Ancak, yukarıda sayılan işlemlerin tam otomatik ve de yüksek doğrulukta gerçekleştirilmesini engelleyen zorluklar tam anlamıyla aşılamamıştır. Son bir kaç yıl içinde bu konuda çalışmalar oldukça hız kazanmaya başlamıştır.

5. SONUÇ

Yakın gelecekte, sayısal sistemlerdeki en önemli gelişmelerin, otomatik detay verisi toplama (çok belirgin detaylar, yollar, binalar, ormanlar gibi) ve sayısal görüntü işleme tekniklerinin geliştirilmesi yönünde olacağı beklenmektedir /5/. Bu tür sistemlerin gerçekleştirilmesi için gereken teknikler üzerine çalışmaları ve hedefleri belirleyen tartışmalar, dünyada son birkaç yıl içinde yoğunluk kazanmaya başlamıştır. Bir taraftan bu tür tekniklerle ilgili stratejiler belirlenmeye çalışılırken, diğer bir taraftan da yavaş yavaş eksikliklerine rağmen bu tür sistemlerin ilk adımları fiilen atılmaya devam etmektedir. Bu konuda, yarı otomatik detay verisi çıkaran sistemlerde epeyce ilerleme sağlanmıştır. Ancak bu verilerin tam otomatik olarak çıkarılmasını sağlayacak sistemlerin tasarımı için gereken matematiksel modeller (teknikler) tam anlamıyla ortaya konulamamıştır. Bu makalede, bu tür sistemlerin geliştirilmesi için kullanılan temel matematik yaklaşımlarının tanıtılması amaçlanmıştır. Dünyada, bu tür sistemlerin geliştirilmesi için elektronik mühendisleri, bilgisayar mühendisleri, jeodezi ve fotogrametri mühendisleri müşterek olarak çalışmaktadırlar. Ülkemizde de böyle bir sistemin, jeodezi ve fotogrametri alanında çok büyük yararlar sağlayacağına hiç kuşku yoktur. Ülkemizdeki elektronikçilerin çoğunun, sayısal görüntülerin iletimi üzerinde uğraştıkları gözönüne alınırsa, raster görüntülerden detay verilerinin çıkarılması işlemleriyle uğraşmak ağırlıklı olarak biz jeodezi ve fotogrametri mühendislerine düşmektedir.

K A Y N A K L A R

- /1/ Fukunaga, K., : Introduction to Statistical Pattern Recognition, Academic Press Inc., San Diego, CA 92101, 1990.
- /2/ Low, A., : Introductory Computer Vision and Image Processing, McGraw-Hill Book Co., UK., 1991.
- /3/ Maktav, D., : Uzaktan Algılama (Çeviri), Hürriyet Ofset A.Ş., 1991.
Sunar F.,
- /4/ Murthy, G., : Modified Neocognitron for Improved 2-D Pattern Recognition, IEE
Venkatesh, Y.V., Proc. Image Signal Process, Vol. 143, No 1, S.31-40, 1996.

/5/ Özbalmumcu, M., : Sayısal Fotogrametri ve Sayısal Fotogrametrik Stereo Çalışma İstasyonları, Harita Dergisi, Sayı 116, S. 62-72, Ankara, 1996.

/6/ Papoulis, A., : Probability, Random Variables, and Stochastic Processes, McGraw Hill Inc., Singapore, 1991.