

# Agregaların Temel Şekil Özellikleri Kullanılarak Yapay Sinir Ağları Yardımıyla Sınıflandırılması

## Classification of Aggregates Using Basic Shape Parameters Through Neural Networks

**Mahmut SİNECEN ve Metehan MAKİNACI\***

Dokuz Eylül Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Müh. Bölümü, 35160, Buca, İzmir

Geliş Tarihi/Received : 16.07.2009, Kabul Tarihi/Accepted : 08.03.2010

### ÖZET

Bu çalışmada, asfalt ve beton karışımlarında kullanılan doğal ve kırma taş agregaların görüntü işleme teknikleri kullanılarak elde edilen tanımlayıcı vektörlerinin yapay sinir ağları yardımıyla sınıflandırılması amaçlanmaktadır. Farklı şekil özelliklerine sahip (yassı, uzun, yuvarlak, köşeli, küre) 5 iri agrega türünün 45° ve 90° lik açılardaki 7.1 Mp (Canon EOS 350D) ve 10 Mp (Sony DSC-R1) çözünürlüğe sahip 2 farklı dijital fotoğraf makinesinden elde edilen görüntüleri, MATLAB programının Görüntü İşleme Araç kutusu kullanılarak ön işlemlerden geçirilmiştir. Agregalara ait her iki açı için ayrı ayrı 9 ve toplam da 18 öznitelik vektörü bulunarak yapay sinir ağları yardımıyla sınıflandırma işlemi gerçekleştirilmiştir. Sonuçlar, görüntü işleme ve yapay sinir ağlarının agrega özelliklerinin tespiti ve ayırımı için etkili yöntemler olduğunu göstermiş ve agrega ocaklarındaki otomasyon sistemlerin bu tarz yaklaşımlar ile verim, maliyet ve zaman faktörlerini etkileyeceğini ortaya koymuştur.

**Anahtar Kelimeler :** *Agrega, Görüntü işleme, Yapay sinir ağları.*

### ABSTRACT

In this paper, the aim is to classify natural or crushed aggregates by using concrete and asphalt mixes through Artificial Neural Networks. For classification, it was used the feature vector which was calculated by using digital image processing techniques. Of the five different type coarse aggregates images were taken with 45° and 90° by a 10 Mp (Sony DSC-R1) and 7.1 Mp (Canon EOS 350D) camera. Aggregates images were processed and analyzed by using MATLAB Image Processing and Neural Network Toolbox. Classification process was made with totally 18 feature vectors, which is 9 vectors each angles, by neural network. Results showed image processing and neural networks which are important methods for founding shape parameters and classification of aggregates, and performance, cost and time consuming factors of automation systems in aggregate sources will be effective with these methods.

**Keywords :** *Aggregate, Digital image processing, Artificial neural networks.*

### 1. GİRİŞ

Agregalara ait morfolojik özellikler (şekil, köşelilik, boyut, yüzey pürüzlülüğü, v.b.) agrega tanelerinin kullanıldıkları karışımların dayanımı, kalıcılığı ve hizmet kalitesi üzerinde önemli etkisi olmaktadır (Ahlrich, 1996).

Agregaların morfolojik özelliklerinin mevcut standart deney yöntemleri ile tespiti, laboratuvar koşullarına bağlı, zaman alıcı ve insan hatalarına açıktır. Disiplinlerarası etkileşimin ve bilgi teknolojilerindeki gelişmelerin artması, hızlı ve etkili yeni yöntemlerin geliştirilmesine olanak sağlamaktadır (İsa v.d., 2008).

Sayısal görüntüleme aygıtlarındaki ilerlemeler ve aynı anda birçok verinin hesaplanarak depolanmasını sağlayan bilgisayarlar yardımıyla modern görsel analiz sistemleri oluşturulmaktadır. Bu sayede agrega tanelerinin fiziksel özelliklerinin (çap, boy, en, çevre, vb.) bulunması ve sınıflandırılması çok daha kısa sürede gerçekleştirilebilmektedir (Quiroga, 2003).

Çalışmanın ikinci bölümünde kullanılacak öznitelik vektörleri hakkında bilgi verilmiş, üçüncü bölümünde görüntü işleme ve analizi için kullanılacak araçlar ve yöntem belirtilmiş, dördüncü bölümünde sınıflandırıcı tanıtılmış ve son bölümde elde edilen sonuçlar gösterilmiş ve çalışmanın öneminden bahsedilmiştir.

\* Yazışılan yazar/Corresponding author. E-posta adresi/E-mail address : mahmut@pau.edu.tr (M. Sincen)

## 2. ÖZNETELİK VEKTÖRLERİ

Agregaları karakterize edilmesinde, şekil özellikleri önemli bir etken oluşturmaktadır. Ancak laboratuvar ortamında çok sayıda agreganın manüel olarak ölçülmesi mümkün değildir. Fakat son zamanlardaki veri toplama ve işleme sistemleri bu ölçüm değerlerinin otomatikleştirilmesini ve daha hızlı yapılmasına olanak sağlamaktadır. Bu çalışmada, agregaların sınıflandırılması için kullanılacak temel şekil özellikleri şöyledir;

- Rugosity (tane çevresinin, taneyi içine alan en küçük dikdörtgen çevresine olan oranı), agregaya ait yüzey pürüzlülüğünü veya doku bilgisini elde etmek için kullanılmaktadır (Şekil 1) (Dilek, 2000).

$$R_g = \frac{C}{2(a+b)} \quad (1)$$

- Roundness (taneye ait yuvarlaklık oranıdır), tane 0-1 arasında aldığı değere göre yuvarlaklık özelliği incelenmektedir. 1 değerini alan agregaya tanesi tam yuvarlak olarak nitelendirilmektedir,


$$\text{Yuvarlaklık} = \frac{C^2}{4\pi A} \quad (2)$$

- Yarıçaplar Oranı (tanenin merkezinden çevresine çizilen en büyük ve en küçük yarıçaplar oranı) düzensiz yüzeyler çok küçük yarıçap oranına sahiptir bu da yarıçaplar oranının artmasına yol açmaktadır,

$$R_y = \frac{R_{\max}}{R_{\min}} \quad (3)$$

- % Dikdörtgen Alanı (tane alanının, taneyi çevreleyen en küçük dikdörtgen alanına olan oranı),


$$\%DA = \frac{A}{a \times b} \quad (4)$$



Şekil 1. Köşellilik ölçüleri (Dilek, 2000).

- Konkavlık (Tane alanının, taneyi çevreleyen konkav alanına oranı) (Şekil 2) (Garboczi, 2001),

$$K = \frac{A}{KA} \quad (5)$$



Şekil 2. Konkavlık (Jaakkola ve Haussler, 1999).

- Ortalama Uzaklık (tane kontur merkezinden kontur piksellerine olan oranı),

$$d_{ort} = \frac{1}{n} \sum_{i=1}^n d_i \quad (6)$$

- Uzaklık Standart Sapması (Ortalama Uzaklık değerinin standart sapması) (Şekil 3),

$$S_{std} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_i - d_{ort})^2} \quad (7)$$

- Daire Çevresi Oranı,

$$C = \frac{2\pi d_{ort}}{\text{kenar piksellerinin sayısı}} \quad (8)$$


- Gri Seviye Oranı (piksellerin gri seviyelerinin ortalama değeri).

$$GSO_{ort} = \frac{1}{n} \sum_{i=1}^n \text{ piksellerin gri seviye değeri} \quad (9)$$


## 3. GÖRÜNTÜ İŞLEME VE ANALİZ

Bu çalışmada, 7.1 Mp ve 10 Mp çözünürlüğe sahip Canon EOS350D ve Pentax 10D modeli dijital fotoğraf makineleri kullanılarak görüntüler alınmıştır. Yapılan çalışmanın kullanılacak donanımsal araçlardan bağımsız olduğunu göstermek için iki farklı fotoğraf makinesi kullanılmıştır. Görüntü alımı için Şekil 4'de gösterilen düzenek oluşturulmuştur. Yassı, yuvarlak ve küre agregaların tek bakış noktasından bakıldığında birbirlerine çok fazla benzemeleri nedeniyle görüntüler 45° ve 90° olmak üzere iki farklı açıdan çekilmiştir. Bu sayede, agregalardan çıkarılan öznetelik vektörlerinin analiz performansının artması düşünülmüştür. Agregalara ait şekil özellikleri, görüntüler ön işlemlerden geçirilerek hesaplanmıştır. Her iki açıdan çekilen fotoğraflar, dijital ortamda depolandıktan sonra Matlab programının Image Processing Toolbox'ı kullanılarak ön işlemlerden geçirilmiştir. Öncelikle çekilen görüntüler fotoğraf makinelerinin yüksek çözünürlüğünden kaynaklanan fazla alanlar kesilip atılmış ve görüntü boyutları 800x600 çözünürlüğüne düşürülmüştür. Elde edilen düşük boyutlu bu yeni fotoğraflar işlem hızını doğrudan etkilemiştir. Daha sonra görüntüler


RGB modundan gri seviyeye çevrilmiş ve bu yeni görüntüler belirlenen bir eşik değerinden geçirilerek binary (0-1) moda çevrilmiştir. Işık aydınlatmasından ve çekim yüzeyinden oluşan gürültü piksellerini elimine etmek için toplam alan 100 pikselden az olan noktacıklar kümesi, etiketlenme işleminden sonra görüntüden çıkartılmıştır. Bu aşamadan sonra elde ettiğimiz binary moddaki agrega görüntüsünün Canny metodu yardımıyla kenar hatları bulunmuştur. Bu ön işlemler sonucunda agregalarımıza ait koordinat bilgileri elde edilmiş ve ana görüntüden agreganın yeri tespit edilip öznitelik vektörlerinin çıkartılma işlemi adımına geçilmiştir. Şekil 5'de agregalara ait örnek görüntüler ve Şekil 6'da yapılan işlemlere ait akış diyagramı verilmektedir.



Şekil 3. Ortalama uzaklık (Janoo, 1998).

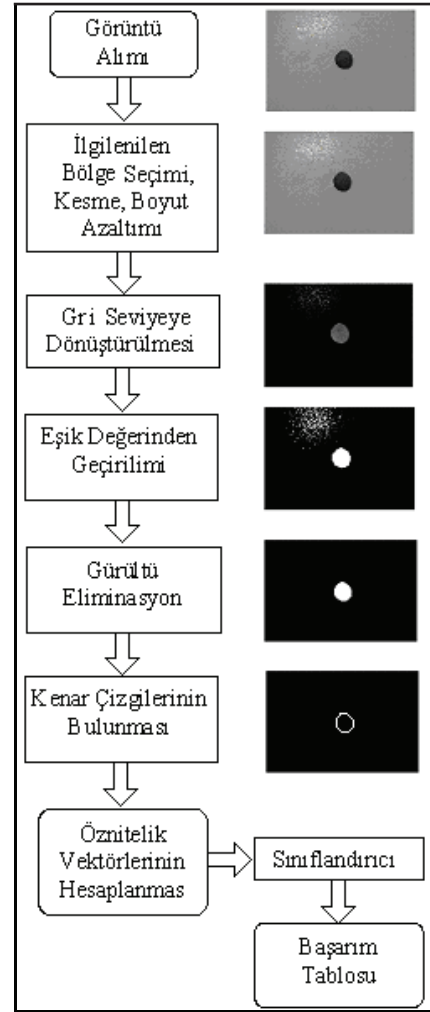


Şekil 4. Görüntü alma düzeneği.



(a) Köşeli, (b) Uzun, (c) Yassı, (d) Yuvarlak, (e) Küre.

Şekil 5. Agrega tiplerine ait görüntü.



Şekil 6. Agrega sınıflandırma için görüntü işleme ve analiz diyagramı.

#### 4. SINIFLANDIRMA

Sınıflandırma işlemindeki amacımız, görüntü işleme teknikleri yardımıyla elde edilen öznitelik vektörlerini kullanarak agregaların birbirinden ayırımını sağlamaktır. Bu amaçla, en iyi ayırımı yapabilmek için yapay sinir ağı modellerinden bazı yöntemler seçilmiştir. Bu yöntemler; Çok Katmanlı Algılayıcı, Radyal Temel Fonksiyon ve Öğrenen Vektör Nicemlemedir (Bishop, 1995; Haykin, 1998). Bu sınıflandırıcılardan sadece çok katmanlı algılayıcı için iki ayrı model denenmiştir. Bu modellerden birinde; 2 arakatman kullanılmış ve bu arakatmanlara ait düğümler 3 ile 15 arasında değiştirilmiştir. İkinci modelde ise bir arakatman kullanılmış ve düğüm sayısı yine 3 ile 15 arasında değiştirilmiştir.

Sınıflandırmada 5 farklı agrega tipi kullanılarak 45° ve 90°'lik açıların her birinden 9 farklı öznitelik vektörü çıkartılmıştır. Tablo 1'de 45°'lik açıya ait örnek öznitelik vektörü gösterilmektedir. Çalışmanın ön aşamasında, toplam 231 agrega tanesine ait öznitelik vektörlerinden 200 tanesi sınıflandırıcıların eğitimleri

için kullanılmış ve 31 tanesi de sınıflandırıcıların testi için kullanılmıştır. Test sonuçlarına göre en yüksek başarıyı sağlayan yapay sinir ağ modeli belirlenmiştir.

45° ve 90°'lik açılardan elde edilen öznitelik vektörleri ayrı ayrı ve birleştirilerek her sınıflandırıcı modelinde değerlendirilmiştir. Her sınıflandırıcının istatistiki olarak kesin sonucu verebildiğini anlamak için eğitim sırasında elde edilen eşik ve düğüm ağırlıkları kaydedilmiştir. Sınıflandırıcıların eşik ve

düğüm ağırlık değerleri kaydedilmiş verilere göre sabitlenmiş ve her defasında farklı test vektörleri kullanılarak toplam 30 defa ayrı ayrı başarı oranları hesaplanmıştır. Bu değerlerin ortalamaları alınarak sınıflandırıcı sonuç başarı oranı bulunmuştur. Tablo 2'de de gösterildiği gibi ilk arakatmanda 11 düğümlü ve ikinci arakatmanda 4 düğümlü FF2, 45° ve 90° derecelik açılardan elde edilmiş öznitelik vektörlerinin tümünü kullanarak % 98,9'luk başarı oranı ile en yüksek doğruluk değerini vermiştir.

**Tablo 1. Sınıflandırıcı için kullanılan 45°'ye ait öznitelik vektörleri örnek veriler öznitelikler.**

Sınıf	Rugosity	Yarıçaplar Oranı	Dikdörtgen Alanı	Konkavlık	Yuvarlaklık	Ortalama Uzaklık	Uzaklık Standart Sapması	Daire Çevresi Oranı	Gri Seviye Oranı
Uzun	0,68	1,11	0,74	0,99	0,44	0,18	0,01	1,13	173,44
Yuvarlak	0,77	1,34	0,78	0,97	0,66	0,16	0,02	1,01	162,62
Küre	0,80	2,67	0,80	0,99	0,93	0,15	0,05	0,94	156,04
Yassı	0,71	1,14	0,79	0,99	0,48	0,17	0,01	1,09	191,35
Köşeli	0,71	1,16	0,76	0,99	0,50	0,17	0,01	1,09	189,24

**Tablo 2. Sınıflandırıcıların başarıları.**

Ağ Türü	DS	45/90° Başarı (%)	DS	45° Başarı (%)	DS	90° Başarı (%)
FF1	15	90.7	14	76.7	10	84.5
FF2	11-4	98.9	8-13	86.5	13-4	91.9
RBF	-	75.3	-	75.6	-	77.5
LVQ	15	71.1	10	60.1	12	63.5

FF1: Tek ara katmanlı algılayıcı; FF2: Çift ara katmanlı algılayıcı; RBF: Radyal tabanlı fonksiyon; LVQ: Öğrenmeli vektör nicemleme; DS: Düğüm sayıları.

## 6. SONUÇ

Agrega şeklinin ve yüzey pürüzlülüğünün ölçüsü olan mekanik deney yöntemlerinin (TS EN 933-6, ASTM C1252) en önemli problemi agrega şekli, köşeliliği ve yüzey pürüzlülüğünü tek tek ifade edememeleri ve bu özellikler arasında doğrudan bir ilişki kuramamalarıdır. Sayısal görüntü işleme yöntemleri kullanılarak yapılan ayırım, mekanik yöntemlere kıyasla çok daha kısa sürelerde daha yüksek doğrulukla yapılabilmektedir. Bunun sonucu olarak da agrega ayırımı sırasında oluşabilecek zaman, iş gücü ve performans kayıpları en aza indirilmiş olacaktır.

Bu çalışmada, görüntü işleme metotları aracılığıyla agregaların sayısal bir yaklaşımı sağlanmıştır. Elde edilen sayısal veriler, oluşturulan sınıflandırma modellerinde test edilerek, agrega analizinde en iyi sonucu verebilen sınıflandırıcı belirlenmiştir. Bu sayede insan hatasından bağımsız, daha az maliyetli ve yüksek performanslı sonuçlar elde edilmiştir.

Ayrıca, başarıyı yüksek olan sınıflandırıcı ve öznitelik vektörlerini bulmak için 45° ve 90°'lik farklı açılardan elde edilen veriler, ayrı ayrı ve birleştirilerek test edilmiştir. Test sonuçları göstermiştir ki analiz sırasında tek açıdan çekilen görüntülere ait öznitelikler yetersiz bir ayırım gücüne sahiptir. Yuvarlak, küre ve yassı agrega türlerinin tek bakış açısında birbirlerine benzerliğinden dolayı her iki açı türüne ait özniteliklerin kullanılması hem yüksek performans sağlamakta hem de daha doğru sonuç vermektedir. İki açıya ait özniteliklerin birleştirilerek kullanılması ile maksimum başarıyı Çift Ara Katmanlı Algılayıcı elde etmiştir.

---

**KAYNAKLAR**

---

- Ahlich, R. C. 1996. Influence of aggregate properties on performance of heavy-duty hot-mix asphalt pavements, Transportation Research Record 1547, TRB, National Research Council. 7-14.
- Bishop, C. M. 1995. Neural Networks for Pattern Recognition, Oxford University Press, USA; 1 edition.
- Dilek, U. 2000. Effects of Manufactured Sand Characteristics on Properties of Concrete, Ph.D. Thesis, North Carolina State University.
- Garboczi, E. 2001. Three-dimensional mathematical analysis of particle shape using X-ray tomography and spherical harmonics: Application to aggregates used in concrete, Cement and Concrete Research, pp. 1621-1638.
- Haykin, S. 1998. Neural Networks: A Comprehensive Foundation (2nd Edition) (Hardcover), Prentice Hall, 2nd edition.
- Isa, N. A. M., Al-Batah, M. S., Zamli, K. Z., Azizli, K. A., Joret, A. and Noor, N. R. M. 2008. Suitable features selection for the HMLP and MLP networks to identify the shape of aggregate, Construction and Building Materials, Volume: 22, Issue 3, March 2008, Pages: 402-410.
- Jaakkola, T. and Haussler, D. 1999. Probabilistic kernel regression models, in Proceedings of the 1999 Conference on AI and Statistics.
- Janoo, V.C. 1998 "Quantification of shape, angularity, and surface texture of base course materials", CRREL Special Report No. 98-1, Cold Regions Research and Engineering Laboratory, USA, 1998.
- Quiroga, P.N. 2003. The effect of the aggregate characteristics on the performance of Portland cement concrete, Ph.D. Thesis, The University of Texas at Austin.