

GÖRÜNTÜ İŞLEMENE DAYALI TARIMSAL ÜRÜN SINIFLANDIRMA

Ender BUL¹

Gökhan GELEN²

Halis ALTUN³

^{1,2,3}Elektrik Elektronik Mühendisliği Bölümü

Mühendislik Mimarlık Fakültesi

Niğde Üniversitesi, 51200 NİĞDE

¹e-posta:enderbul@hotmail.com

²e-posta: ggelen@nigde.edu.tr

³e-posta: haltun@nigde.edu.tr

Anahtar sözcükler:Yapay Zeka, Görüntü İşleme,Nesne tanıma, Yapay Sinir Ağı, Tarımsal Ürün Sınıflandırma

ÖZET

Bu bildiriye, görüntü işlemeye dayalı yöntemler kullanılarak, tarımsal ürün olarak seçilen fasulyelerin iyi kalite veya kötü kalite olarak sınıflandırılması amaçlanmaktadır. Görüntü işleme teknikleri kullanılarak çeşitli parametreler elde edilmiş ve bu parametreler yardımıyla fasulyeler ilk önce parametre karşılaştırma yoluyla daha sonra ise Yapay Sinir Ağı (YSA) kullanılarak sınıflandırılmıştır. Elde edilen sonuçlar bu problemin çözümünde YSA yapısının daha yüksek performans sergilediğini göstermektedir.

1. GİRİŞ

Video kamera ve tarayıcı gibi görüntü yakalayıcı cihazlarla alınarak sayısallaştırılan cisim görüntülerinin uygun bilgisayar yazılımlarıyla işlenmesi ve/veya analizi görüntü işleme olarak tanımlanır. Birçok yazar tarafından farklı tanımlamalar yapılmakla birlikte, görüntü yakalama ve analizini gerçekleştirmek için kullanılan yazılım ve donanım birimleri kombinasyonu görüntü işleme sistemi (GIS) olarak adlandırılmaktadır [1,2,3].

GIS, ilgilenilen bir objenin veya oluşumun tanımlanmasını sağlayacak lineer ve kuadratik geometrik özellikler, göreceli ve mutlak konum gibi yerleşim özellikleri, renklilik veya yoğunluk gibi optik özelliklerinin saptanması ve analizinde kullanılabilir. Bu durum, GIS'lere hemen her alanda kullanım potansiyeli sağlayabilmektedir. Son yıllarda bilgisayar ve elektronik endüstrisinde görülen hızlı gelişme sonucu, GIS'lerinin ekonomik ve yaygın kullanımını mümkün kılacak yazılım ve donanım gelişiminin de söz konusu olduğu bildirilmektedir [1]. Son on yıldan beri tarımda da GIS kullanım olanakları yoğun ilgi görmüş ve yüzlerce uygulama ile realize edilmiştir.

Bu çalışmada tarımsal ürün olarak fasulye seçilmiştir. Fasulye, Dünya'da ekim alanı ve üretim yönünden yemeklik tane baklagiller içerisinde ilk sırada yer almakta ve taze sebze yanında kuru tane olarak da yaygın bir şekilde tüketilmektedir. Ülkelere göre ekim alanı ve üretim durumlarına bakıldığında; Hindistan'ın

ilk sırada yer aldığı izlenilmektedir. Kuru fasulye tarımı, gelişmekte olan ülkelerde yaygın olmasına karşın, verimi gelişmiş ülkelerde daha yüksektir. En önemli kuru fasulye ihracatçı ülkeler ise sırasıyla; ABD, Çin ve Myanmar'dır. Ülkemizde fasulye, ekim alanı ve üretim yönünden nohut ve mercimekten sonra üçüncü sırada yer almaktadır. İstatistiklerine göre Fasulyenin, Türkiye'deki ekim alanı 172.500 ha, üretimi 230.000 ton, birim alandan alınan tane verimi ise 133.3 kg/da'dır[4].

Üretim sırasında karşılaşılan çeşitli sebepler (zararlı bitkiler, yetersiz gübreleme, yanlış ilaçlama vb.) nedeniyle elde edilen fasulyelerin belirli bir standardı mevcut değildir. Üretim işlemi bittikten sonra elde edilen mahsul çeşitli özellikleri göz önünde bulundurularak farklı sınıflara ayırt edilmektedir. Bu işlem için genellikle insan gücü kullanılmaktadır. Son yıllardaki teknolojik gelişmelere paralel olarak bu işlem cihazlar tarafından da yapılabilmektedir. Bu çalışmada böyle bir cihaz için gerekli olacak yazılım için etkin bir çözüm aranmaktadır.

2. VERİ KÜMESİ

Tarımsal ürün olarak ele alınan fasulyeler için iki sınıfın mevcut olduğu kabul edilmiştir. Bunlar iyi kalite fasulyeler ve kötü kalite fasulyeler. Bu çalışmada 50'si iyi kalite 50'si kötü kalite olmak üzere toplam 100 tane fasulye kullanılmıştır. Bu fasulyelerin görüntüleri dijital kamera ile alınarak 302x200 piksel boyutunda *.jpeg formatında kaydedilmiştir. Bu veri tabanına ait bazı fasulyelerin görüntüsü Şekil 1 ve Şekil 2'de verilmiştir. Şekil 1'de iyi kalite olarak adlandırılan renginde ve şeklinde bir bozukluk olmayan fasulyelerin bir miktarı görülmektedir. Şekil 2'de ise kötü kalite olarak adlandırılan sınıfa mensup örnek görüntüleri sunulmuştur.

MATLAB Görüntü işleme araç kutusu (Image Processing Toolbox) ile oluşturulmuş bir yazılım tarafından bir klasör içerisinde bulunan resimler sırayla alınıp işlenmiştir.Yazılım resimleri öncelikle 256 renk gri tonlara dönüştürüp, daha sonra resimleri oluşturan piksellerin ortalama değerleri hesaplan-

mıdır. Böylelikle elde edilen parametre aşağıda belirtilen denklem yardımı ile hesaplanmıştır

$$\mu_i = \frac{1}{nm} \sum_{x=1}^m \sum_{y=1}^m I_{xy} \quad (1)$$

Burrada μ_i ; herbir resimdeki piksellerin ortalaması
 n ; bir satırda bulunan piksel sayısı (320 piksel)
 m ; bir sütunda bulunan piksel sayısı (200 piksel)
 I_{xy} ; x. satır ve y. sütundaki pikselin gri ton değeri

İkinci parametre olarak ise resmi oluşturan sütunlardaki piksellerin gri ton değerlerinin ortalamasının standart sapması kullanılmıştır. Bu parametre aşağıda verilen formüllerle elde edilmiştir.

Her bir sütunun ortalama değeri χ_i olmak üzere

$$\chi_i = \frac{1}{m} \sum_{y=1}^m I_{xy} \quad (2)$$

$$\sigma = \sqrt{\frac{(\mu_i - \chi_i)^2}{n}} \quad (3)$$

σ ; her resime ait standart sapma parametresidir.




Şekil 1 İyi olarak adlandırılan sınıfa ait fasulye örneği görüntüleri



Şekil 2 Kötü kalite olarak adlandırılan sınıfa ait fasulye örneği görüntüleri

Bu iki parametreye ek olarak görüntülerdeki fasulye objelerinin en ve boy uzunlukları yazılan algoritma tarafından hesaplanmış ve bu parametreler de sınıflandırma işleminde kullanılmıştır. Bu iki parametre Şekil 3'te tanımlanmıştır.



Şekil 3 Bir fasulye için en ve boy parametreleri

3.PARAMETRE KARŞILAŞTIRMA

Bu yöntemde, fasulye görüntülerinden algoritma tarafından işlenerek elde edilen iki parametre, ortalama değer ve standart sapma, kullanılarak bu iki değer aynı sınıfa mensup örnekleri kapsayacak şekilde birer eşik noktası belirlenmiştir. Sınıflandırılacak olan örneğe ait parametreler bu iki eşik değere karşılaştırılarak sınıfı hakkında karar verilmektedir. Eğer ilgili parametre eşik değere eşit veya bu değer üzerinde ise bu örnek iyi kalite fasulye olarak sınıflandırılmakta eğer değilse kötü kalite fasulye olarak sınıflandırılmaktadır.

Bu algoritma kullanılarak yapılan sınıflandırma işleminin başarımları Tablo 1'de verilmiştir.

Tablo 1 Parametre karşılaştırma yöntemi başarımları oranları

	İyi Kalite Fasulye	Kötü Kalite Fasulye	Toplam
Doğru Sınıf.	49	38	87
Yanlış Sınıf.	1	12	13
Başarımlar	%98	%76	%87
Toplam	50	50	100

Tablodanda görülebileceği gibi algoritmanın İyi fasulye olarak adlandırılan veri için performansı %98 dir yani veri kümesindeki 50 tane verinin 49 tanesini doğru bir tanesinide yanlış olarak sınıflandırmıştır. Kötü kalite fasulye olarak adlandırılan verinin ise 38 tanesini doğru; 12 tanesini yanlış sınıflandırmıştır. Bu algoritmanın bu problem için toplam başarımları %87 olarak hesaplanmıştır.

4. YAPAY SİNİR AĞI KULLANARAK SINIFLANDIRMA

Son yıllarda, sınıflandırma problemlerinin çözümünde sınıflandırıcı olarak Yapay Sinir Ağı (YSA) yapıları oldukça fazla kullanılmaya başlanmıştır. Bu problemlerde, sınıflara ait ayırt edici özelliklerden elde edilen veriler ağına girişini, sınıfları belirleyen ikili düzendeki sayılar da ağına çıkışı oluşturur [5-7]. Bu çalışmada Çok katmanlı algılayıcı (MLP tipi) YSA yapısı kullanılmıştır.

MLP ağı bir giriş katmanı, bir veya daha fazla saklı katman ve bir çıkış katmanından oluşur. Her katman bünyesinde bir çok nöron hücresi bulundurulur. Bu hücreler birbirlerine ağırlıklı bağlantılarla bağlıdır. MLP ağı n giriş vektörünü, üzerinde doğrusal olmayan işlemler yaparak l çıkış vektörüne dönüştürür. Ağına çıkışı aşağıda tanımlanan etkinlik (aktivasyon) fonksiyonuna sahip çıkış katmanı tarafından belirlenir.

$$x_o = f\left(\sum_h x_h w_{ho}\right) \quad (4)$$

Burada $f()$ etkinlik fonksiyonu, x_h h. saklı katman nöronunun aktivasyonu, ve w_{ho} h. saklı katman nöronu ile o. çıkış katmanı arasındaki bağlantının ağırlığıdır. En çok kullanılan etkinlik fonksiyonu Denklem 5'de verilen Sigmoid fonksiyonudur.

$$x_o = \frac{1}{1 + \exp\left(-\sum_h x_h w_{ho}\right)} \quad (5)$$

Saklı katmanın aktivasyon seviyesi de çıkış katmanın aktivasyonu gibi bulunur. Hesaplanan çıkış değeri ile hedef değer arasındaki farka dayanan bir hata değeri aşağıdaki gibi tanımlanabilir.

$$E = \frac{1}{2} \sum_s \sum_o \left(t_o^{(s)} - x_o^{(s)}\right)^2 \quad (6)$$

Burada N veri kümesindeki örnek sayısı L ise çıkış nöronu sayısını göstermektedir. MLP ağı eğitiminin amacı katmanlar arasındaki bağlantıların ağırlıklarını değiştirerek hata (E)'yi en aza indirmektir. Ağırlıklar Eğim Düşümü (Gradient Descent) ve Geri Yayılım (Backpropagation) algoritmaları ile ayarlanmaktadır. Bu algoritmalar birbiriyle ilişkilendirilmiş giriş ve hedef t_o verilerini eğitim kümesi olarak kullanmaktadır. MLP yapısının eğitimi sırasında, eğitime rasgele seçilmiş bir başlangıç ağırlık kümesi ile başlanır ve eğitim w_{ih} ve w_{ho} optimize edilene kadar devam ettirilir.

Hataı geriye yayma algoritmasına göre; her nöron arasındaki bağlantının ağırlığı aşağıda belirtildiği gibi değiştirilerek hata (E) küçültülmeye çalışılır. Bu işlem

ağırlıkların en uygun değeri bulunana kadar devam ettirilir.

$$\Delta w_{ho} = -\eta \frac{\partial E}{\partial w_{ho}} = -\eta \delta_o x_h \quad (7)$$

$$\Delta w_{ih} = -\eta \frac{\partial E}{\partial w_{ih}} = -\eta \delta_h x_i \quad (8)$$

Bu denklemlerdeki E, Denklem 3'te tanımlanan hata fonksiyonudur.

$$\delta_o = x'_o (t_o - x_o) \quad \text{ve}$$

$$\delta_h = x'_h \sum_o \delta_o w_{ho} \quad \text{dır.} \quad \text{Eğer aktivasyon fonksiyonu}$$

sigmoid fonksiyon ise $x'_o = x_o(1 - x_o)$ ve

$$x'_h = x_h(1 - x_h) \quad \text{olacaktır.}$$

Bu uygulamada, toplam 100 adet fasulye görüntüsünden elde edilen 100x4 boyutlu veri kullanılmıştır. Her resimden en, boy, ortalama değer ve standart sapma olmak üzere dörder tane parametre elde edilmiştir. Bu verilerin yarısı iyi kalite olarak adlandırılan sınıfa ait fasulyelerden elde edilen verilerdir. Diğer yarısı ise yani 50x4 boyutlu veri ise kötü kalite olarak adlandırılan sınıfın verileridir. İyi ve kötü kalite fasulyeler sınıfına ait veriler rastgele karıştırılarak toplam veri kümesi olan 100x4 boyutlu veri elde edilmiştir. Karıştırma işleminin ardından ise toplam veri eğitim ve test verisi olmak üzere tekrar ikiye bölünmüştür. Bu verilerden eğitim verisi için oluşturulan ağ eğitilerek test verisi için test edilmiştir.

Bu uygulama Matlab 6.5 ortamında Neural Network Toolbox kullanılarak gerçekleştirilmiştir. *Newff* komutu ile 4 giriş nöronu 3 saklı katman nöronu ve iki çıkış katmanı nöronuna sahip ileri beslemeli ağ yapısı oluşturulmuştur. *traingda* komutu kullanılarak adaptif öğrenme oranı ile eğitim yapılmıştır. Eğitim ve test verileri için elde edilen başarımlar Tablo 2 'de verilmiştir.


Tablo 2 YSA için başarımlar oranları

	Eğitim Verisi	Test Verisi	Toplam
Doğru Sınıf.	50	43	93
Yanlış Sınıf.	0	7	7
Başarımlar	%100	%86	%93
Toplam	50	50	100

Tablodanda görülebileceği gibi YSA'nın eğitim verisi için performansı %100 dür yani veri kümesindeki 50 tane verinin tamamını doğru olarak sınıflandırabilmiştir. Test verisi için ise 50 tane verinin 43 tanesini doğru 7 tanesini yanlış sınıflandırmaktadır. YSA'nın bu problem için toplam başarımları %93 olmuştur.

5.GÖRÜNTÜLERİN GERÇEK ZAMANLI OLARAK İŞLENMESİ

Yukarıda açıklanan yöntemlerde hareketli görüntü kullanılmamıştır. Hareketli görüntü kullanılarak ta ayırt etme işlemi yapılabilir. Bu işlemi yapabilmek için gerekli olan sistemin blok şeması Şekil 4'te verilmiştir. Şekilden de görüldüğü gibi iki DC motor tarafından hareket ettirilen bant üzerindeki fasulyelerin görüntüsü bir dijital kamera yardımıyla bilgisayar ortamına aktarılmakta ve ilgili sınıflandırma işleminin ardından kontrol kartı ile fasulyeler iyi kalite ve kötü kalite diye ayırd edilmektedir.



Şekil 4 fasulyelerin online ayırd edilmesi

MATLAB programlama dilinin diğer bir araç kutusu olan Hareketli Görüntü İşleme araç kutusu (image acquisition toolbox) kullanılarak oluşturulan yazılımla bu işlem gerçekleştirilebilir. Bu işlemim ardından yine resimleri oluşturan piksellerin ortalama değer ve standart sapmaları kullanılarak fasulyelerin iyi kalite veya kötü kalite şeklinde ayrıştırılması gerçekleştirilebilir.

SONUÇLAR

Bu çalışmada tarımsal ürünleri sınıflandırılması için etkin bir yöntem olan görüntü işleme ve bunu temel alan bir ayrıştırma sistemi sunulmuştur. Bu ayrıştırma sistemi için gerekli olan yazılımı sağlayacak iki algoritma karşılaştırılmıştır. Bunlardan ilki parametre karşılaştırma yöntemidir. Bu yöntemde algoritmanın toplam başarımı %87 civarında olmaktadır. İkinci algoritma olarak ise YSA kullanılmıştır. YSA'da başarım ise %93 civarlarındadır.

KAYNAKLAR

- [1] Bek, Y., Cebeci, Z., 1993. Tarımsal üretim ve araştırmalarda görüntü işleme sistemleri. T.K.B. Tarım ve Köy Dergisi, 84: 18-20.
- [2] Cebeci,Z., Bek,Y. Pekel,E., 1992a. Görüntü işleme sistemlerinin hayvansal üretim ve kalite kontrolünde kullanım olanakları. Trakya

Bölgesi 1. Hayvancılık Sempozyumu, 8-9 Ocak 1992, Tekirdağ. Hasad

Yayınçılık: Hayvancılık Serisi 2, s. 153-164.

- [3] Cebeci,Z., Cengizler,I., Gökçe, M.A., 1992b. Su ürünleri mühendisliğinde sayısal görüntü işleme sistemlerinden yararlanma olanakları. VII. Mühendislik Haftası, Su Ürünleri Mühendisliği Oturumu, 25-29 Mayıs 1992, Eğirdir,Isparta
- [4] Türkiye'nin Kuru Fasulye Raporu [http://www.bilgiturkiye.com/join/?ID=News&d=288,\(14.04.2005](http://www.bilgiturkiye.com/join/?ID=News&d=288,(14.04.2005)
- [5] M. Y. Rafiq, G. Bugmann D. J. Easterbrook., Neural Network Design for Engineering Applications, COMPUTER AND STRUCTURES, Vol 79, pp 1541-1552 2002.
- [6] W. Loh, L. Tim, "A Comparison of Prediction Accuracy, Complexity, and Training Time of Thirty Three old and New Classification Algorithm", MACHINE LEARNING 40(3) ., pp 203-238, 2000.
- [7] A Ribert, A Ennaji, Y Lecourtier, Generalisation Capabilities of a Distributed Neural Classifier, ESANN'1999 - European Symposium on Artificial Neural Networks Bruges (Belgium), pp. 269-268, 1999.