

YAPAY SİNİR AĞI VE GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANARAK DURUM BUĞDAYININ CAMSILIĞININ BELİRLENMESİ

Ahmet BABALIK ^{a*}, Fatih M. BOTSALI ^b

^a Selçuk Üniversitesi Mühendislik – Mimarlık Fakültesi Bilgisayar Müh. Böl., Konya

^b Selçuk Üniversitesi Mühendislik – Mimarlık Fakültesi Makina Müh. Böl., Konya

Özet

Hububat denetiminde bilgisayar destekli kalite denetim sistemlerinin kullanıldığı değişik uygulamalar bulunmaktadır. Bu çalışmada Çeşit-1252 türü durum buğdayının camsı ve camsı olmayan danelerinin görüntü işleme teknikleri ve yapay sinir ağı yardımıyla sınıflandırılması amaçlanmıştır. Masaüstü tarayıcı yardımıyla elde edilen resimlerden her bir daneye ait histogram bilgileri elde edilmiştir. Bu histogram bilgileri kullanılarak farklı yapay sinir ağı modellerinin (Öz düzenlemeli harita – ÖDH, Çok katmanlı algılayıcı – ÇKA) sınıflandırma başarıları irdelenmiştir.

Anahtar Kelimeler: Yapay sinir ağları, görüntü işleme, buğday camsılığı.

DETERMINATION OF DURUM WHEAT VITREOUSNESS USING ARTIFICIAL NEURAL NETWORKS AND IMAGE PROCESSING TECHNIQUES

* Corresponding author. Tel: +90-332-223 37 21 Fax: +90-332-241 06 35
E-mail address: ababalik@selcuk.edu.tr

Abstract

At grain inspection, different applications of computer aided quality control systems are used. In this study, it is aimed to classify vitreousness and non-vitreousness wheat kernels in Çeşit-1252 type durum wheat using image processing techniques and artificial neural networks. Digital images of wheat kernels obtained using desktop scanner and histogram of each kernel calculated. Using this histogram data, different artificial neural networks architecture (Self organizing map – SOM, Multi Layer Perceptron – MLP) classification performance examined.

Keywords: Artificial neural networks, image processing, wheat vitreousness.

1. Giriş

Makarna, ekmek, pasta gibi son ürünlerin kalitesi, büyük ölçüde bu ürünlerin yapımında kullanılan un ve irmiğin hammaddesi olan buğdayın kalitesine bağlıdır. Buğday kalitesi ise, buğdayın türüne, yetiştirme koşullarına, hasat ve depolama şartlarına ve mikroorganizmalar ile haşerelerin daneler üzerinde yaptığı tahribata bağlıdır.

Durum buğdayı genel olarak irmik, makarna üretiminde kullanılmaktadır. Durum buğdayında dane camsılığı; dane sertliği ve protein içeriği hakkında bilgi veren önemli bir kalite kriteridir. Yüksek kaliteli durum buğdayı sert, camsı, yarı saydam görünümündedir ve protein içerikleri yüksektir. Camsı olmayan daneler ise yumuşak ve mat görünümündedir [1]. Satın alma ve işleme aşamalarında buğday yığını içerisindeki camsı danelerin oranının belirlenmesi gerekmektedir.

Günümüzde hububat kalitesinin denetiminde, bilgisayar destekli kalite denetim sistemleri geliştirilmektedir. Görsel denetime alternatif olarak sunulan bu sistemler, genel olarak buğday yığını ve/veya danelere ait sayısal resimlerin bilgisayar ortamına aktarılarak görüntü işleme teknikleri yardımıyla tanımlayıcı bilgilerin elde edilmesi ve bu bilgilerin sınıflandırılması prensibine dayanmaktadır.

Bilgisayar destekli kalite denetim sistemlerinin avantajları şu şekilde sıralanabilir [2];

- Tanımlayıcı bilgileri doğru üretebilmeleri,
- Hızlı ve objektif olmaları,
- Kişiyeye bağımlılığı azaltması,
- Tutarlı, verimli ve düşük maliyetli olmaları,
- Yoğun iş gücü gerektiren işlemlerde otomasyona imkan tanınmaları,
- Tahribatsız muayeneye uygun olmaları,
- İlerleyen çalışmalarda ve değerlendirmelerde kullanılmak üzere kayıtları saklama ve arşivleme özelliklerinin olmaları.

Camsılık durum buğdayı için önemli bir kalite ölçütüdür. Uygulamada, durum buğdayının camsılığının belirlenmesinde farklı yöntemler kullanılmaktadır. Klasik yöntemde, Grobecker kesit aletinin içerisine 50 buğday danesi yerleştirilerek enine kesilir. Cam gibi parlak görünen camsı (züccaci) olanlar sert, unsu beyaz görünüme sahip olanlar yumuşak, yüzeyde kısmi unlu bölgeler var ise dönmeli olarak etiketlenir. Sert, yumuşak, dönmeli daneler sayılarak oranları hesaplanır [3].

Görsel olarak yapılan camsılık denetimi kişiden kişiye değişiklik gösterebilmektedir. Araştırmacılar bu tür olumsuzlukları giderebilmek ve insan faktörünü en aza indirebilmek amacıyla infrared spektrum ölçümlerinin kullanıldığı (NIR yöntemi), farklı ışıklandırma ortamlarındaki resimlemelere dayalı görüntü işleme tekniklerinin kullanıldığı bilgisayar destekli sistemler önermektedirler. Dowel (2000), buğday camsılığını değerlendirmek amacıyla NIR spektrum analizi yöntemini kullanmıştır. Buğday danelerinin 400-1700 nm aralığında ışık yutma oranlarını istatistiksel yöntemlerle değerlendirmiştir [4]. Wang ve ark. (2002), CCD kamera yardımıyla elde ettikleri resimleri kullanarak camsı ve camsı olmayan buğday danelerini tespit etmeyi amaçlamışlardır. Sınıflandırma işleminde yapay sinir ağları kullanılmıştır [5]. Wang ve ark. (2003), durum buğdayındaki camsı ve camsı olmayan daneleri tespit edebilmek amacıyla yaptıkları diğer bir çalışmada üç farklı ışıklandırma ortamında (ön aydınlatma – yansıma, yan aydınlatma, arkadan aydınlatma – geçirgenlik) danelere ait resimleri kullanmışlardır. Elde edilen resimlerden histogram hesaplaması yapılmış ve yapay sinir ağı yardımıyla sınıflandırılmıştır [1]. Goretta ve ark. (2006), durum

buğdayının camsılığını belirlemede hiperspektral görüntüleme tekniklerini kullanmışlardır. Farklı dalga boylarında (650-1100 nm) elde ettikleri resimlerden tanımlayıcı bilgiler çıkarılmış ve bu tanımlayıcı bilgiler istatistiksel yöntemlerle sınıflandırılmıştır [6]. Neethirajan ve ark. (2006), camsı ve camsı olmayan buğday tanelerini tespit edebilmek amacıyla soft X-ray ve geçen ışık görüntüleme sistemlerini kullanmışlardır. Resimlerden elde ettikleri özellikleri istatistiksel yöntemler yardımıyla değerlendirmişlerdir [7].


Bu çalışmada, masaüstü tarayıcı aracılığı ile elde edilen resimlerden durum buğdayı partisi içerisindeki camsı ve camsı olmayan daneleri tespit edilmesi amaçlanmıştır.

2. Materyal ve Metot

Çalışmada, Çeşit-1252 türü durum buğdayı ele alınmıştır. Uzman kişiler tarafından belirlenen 100 camsı ve 100 camsı olmayan dane kullanılmıştır. Çok küçük daneler, kırık daneler ve ot tohumu gibi yabancı maddeler değerlendirilmeye alınmamıştır. Uygulama Matlab ortamında geliştirilmiştir.

2.1 Resmin elde edilmesi ve özellik çıkarımı

Danelere ait resimler masaüstü tarayıcı kullanılarak elde edilmiştir. Resim işleme aşamasında işlemlerin daha hızlı ve hatasız yapılabilmesi amacıyla siyah arka plan kullanılmıştır. Tarayıcıdan elde edilen örnek resimler Şekil 1’de sunulmuştur.



a) Camsı daneler

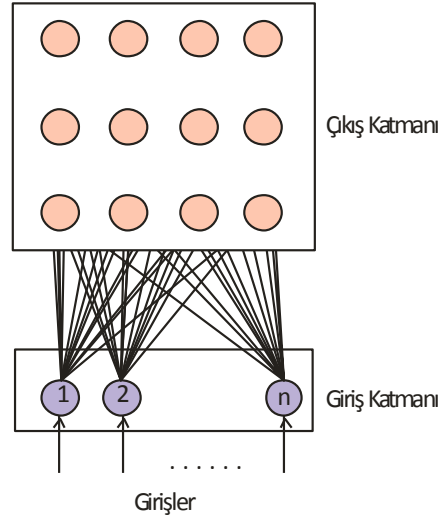
b) Camsı olmayan daneler

Şekil 1. Buğday danelerine ait örnek resimler

Sayısal görüntü işleme teknikleri kullanılarak her bir daneye ait renk bilgileri elde edilmiştir. Bu amaçla, öncelikle elde edilen sayısal görüntüler gri seviye resimlere dönüştürülmüştür. Resimdeki gürültülerin ve çok küçük objelerin (toz vb.) giderilmesi amacıyla resim filtrelenmiştir. Gürültüsü giderilmiş gri seviye resimler Otsu metodu kullanılarak siyah beyaz resme dönüştürülmüş ve ardından bölütleme işlemi gerçekleştirilmiştir. Bölütlenmiş resimdeki her bir nesne etiketlenerek, her bir daneye ait gri seviye histogramı hesaplanmıştır. Histogram verileri, 0-255 aralığındaki gri seviye bilgi 15 eşit aralığa bölünerek her aralıkta bulunan eleman sayısının belirlenmesi şeklinde elde edilmiştir. Yapılan görüntü analizi işlemi sonucunda her bir daneye ait 15 gri seviye renk bilgisi elde edilmiştir. Böylece 100 camsı, 100 camsı olmayan daneye ait toplam 15x200'lik veri seti oluşturulmuştur. Veriler [0-1] aralığına normalize edilmiştir.

2.2 Öz düzenlemeli harita

Öz düzenlemeli harita (ÖDH) danışmansız eğitim yönteminin kullanıldığı ileri beslemeli bir ağ modelidir. ÖDH ağı, bir giriş ve bir çıkış katmanından oluşur. Giriş katmanında bulunan her bir nöron çıkış katmanındaki tüm nöronlara ağırlıklarla bağlıdır. Çıkış katmanı iki boyutlu düzlem şeklindedir. ÖDH ağının yapısı Şekil 2'de görülmektedir [8].



Şekil 2. Öz düzenlemeli harita ağının yapısı

ÖDH ağının en temel özelliği eğitim işleminde bir öğretmene veya üretmesi gereken çıktıların ağa sunulması zorunluluğunun olmamasıdır. Öğrenme işlemi kazanan nöronun ve komşu nöronların ağırlıklarının güncellenmesi temeline dayanır. Başlangıçta nöronların ağırlıkları rassal olarak belirlenir. Eğitim verisi ağ girişlerine uygulanarak kazanan nöron belirlenir ve kazanan nöron ile komşu nöronların ağırlıkları güncellenir. Ağırlıkların güncellenmesi Eşitlik 1'e göre yapılır:

$$w(t+1) = w(t) + \alpha \phi(x(t) - w(t)) \quad (1)$$

Burada α öğrenme katsayısı ($\alpha > 0$), ϕ komşuluk fonksiyonu ve $x(t)$ giriş vektörüdür. Komşuluk fonksiyonu Eşitlik 2'ye göre hesaplanır.

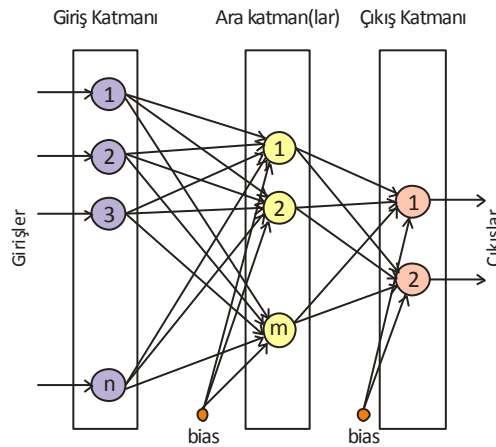
$$\phi(k) = \exp(-\|d_i - d_k\|^2 / (2\sigma^2)) \quad (2)$$

Eşitlik 2'de d_i ve d_k , i . ve k . nöronların pozisyonları gösteren vektörler, σ ise komşuluk alanının genişliğini göstermektedir [8, 9].

2.3 Çok katmanlı algılayıcılar

Yapay sinir ağlarında nöronların dizilişleri ve aralarındaki bağlantı durumlarına göre değişik yapılarda yapay sinir ağı modelleri oluşturulmaktadır. Çok katmanlı algılayıcı (ÇKA) ağlar farklı nöron sayılarına sahip giriş katmanı, bir veya daha fazla

katmandan oluşan ara katman(lar) ve çıkış katmanından oluşan ileri beslemeli bir yapay sinir ağı modelidir. ÇKA sinir ağının yapısı Şekil 3’de gösterilmektedir. ÇKA sinir ağlarında bir katmandaki nöronların çıkışları kendinden bir sonraki katmanda bulunan tüm nöronların girişlerine ağırlıklarla bağlıdır. Giriş ve çıkış katmanında bulunan nöron sayıları uygulama problemine göre belirlenir. Ara katman sayısı, ara katmanda bulunan nöronların sayısı ve aktivasyon fonksiyonları tasarımcı tarafından deneme yanılma yöntemiyle belirlenir [8].



Şekil 3. Çok katmanlı algılayıcı sinir ağının yapısı

ÇKA’ların eğitiminde danışmanlı eğitim yöntemi kullanılır. Uygulanan bir giriş değerine göre üretilmesi istenen çıkış değeri ağa gösterilir. ÇKA’ın eğitiminde hatanın geri yayılım algoritması kullanılır. Hatanın geri yayılım algoritmasında ağın üretmesi beklenen değer ile o anda üretilen değer arasındaki farkı hesaplanarak hata hesabı yapılır. Çıkış katmanındaki j. nöron için hata hesabı Eşitlik 3 kullanılarak hesaplanır [8].

$$e_j = d_j - o_j \quad (3)$$

Burada e_j hata, d_j nöronun beklenen çıkışı ve o_j nöronun o anda ürettiği çıkış değeridir. Çıkış katmanında oluşan toplam hatayı hesaplamak için en küçük kareler yöntemi kullanılır. Toplam hata Eşitlik 4’e göre hesaplanır.

$$E = \frac{1}{2} \sum_j e_j^2 \quad (4)$$

Elde edilen hata değerine göre hatayı en aza indirecek şekilde katmanlar arası ağırlıklar güncellenir. Ağ ağırlıklarının güncellenmesi kabul edilebilir bir hata seviyesine ulaşınca kadar veya belirlenen işlem sayısına ulaşınca kadar sürdürülür.

3. Sonuçlar ve Tartışma

Masaüstü tarayıcı yardımıyla elde edilen buğday resimlerinden camsı ve camsı olmayan buğday danelerinin belirlenmesi amacıyla danışmanlı ve danışmansız eğitim algoritmalarının kullanıldığı iki YSA modelinin başarı performansları irdelenmiştir. Kullanılan YSA modellerinin 15 girişi ve 2 çıkışı bulunmaktadır.

Yapay sinir ağı modellerinin ürettiği sonuçların geçerliliğini ve güvenilirliğini belirlemek amacıyla 2 kat çapraz geçerlilik testi uygulanmıştır. Bu amaçla veri seti rassal olarak eşit iki parçaya bölünmüş, ilk aşamada birinci set eğitim ikinci set ise test için kullanılarak başarı oranları hesaplanmıştır. İkinci aşamada ise eğitim ve test setleri yer değiştirilerek yapay sinir ağının sınıflandırma başarıları hesaplanmıştır. Her iki aşamada elde edilen test başarılarının ortalaması hesaplanarak o ağ modelinin başarıları tespit edilmiştir. Her bir sette 50 camsı, 50 camsı olmayan (unsu) olmak üzere 100 buğday danesine ait bilgiler bulunmaktadır.

Çalışmada ilk olarak danışmansız eğitim stratejisinin kullanıldığı ÖDH ağ modeli ile daha sonra da danışmanlı eğitim stratejisinin kullanıldığı ÇKA ağ modeli ile sınıflandırma yapılmıştır.

ÖDH modeli ile yapılan sınıflandırma işleminde ortalama test başarıları % 97,5 olarak tespit edilmiştir. 15 giriş ve 2 çıkıştan oluşan ÖDH modeli 500 adım eğitilmiştir. ÖDH kullanılarak yapılan sınıflandırmada elde edilen sonuçlar Tablo 1’de sunulmuştur.

Tablo 1. ÖDH kullanılarak yapılan sınıflandırma sonuçları

Doğru Sınıflanan Dane Sayısı

	Camsı Dane	Unsu Dane
Birinci Set	50	48
İkinci Set	49	49

ÇKA modeli ile yapılan sınıflandırma işleminde ortalama test başarıları gizli katmanda 10 nöronun kullanıldığı yapıda % 100 olarak tespit edilmiştir. ÇKA yapıları kurulurken gizli katman ve çıkış katmanındaki nöronların aktivasyon fonksiyonları logaritmik sigmoid olarak kullanılmıştır. YSA modellerinin eğitiminde hatanın geriye yayılım algoritması kullanılmış ve ağ 500 adım eğitilmiştir. Çıkışların değerlendirilmesinde değeri diğerinden büyük olan çıkış o sınıfa ait veri olarak sınıflandırılmıştır. ÇKA kullanılarak yapılan sınıflandırma işleminde elde edilen sonuçlar Tablo 2’de sunulmuştur.

Tablo 2. ÇKA kullanılarak yapılan sınıflandırma sonuçları

Gizli Katmandaki Nöron Sayısı		Doğru Sınıflanan Dane Sayısı	
		Camsı Dane	Unsu Dane
5	Birinci Set	50	50
	İkinci Set	49	49
10	Birinci Set	50	50
	İkinci Set	50	50

ÖDH ve ÇKA kullanılarak elde edilen ortalama başarı oranları değerlendirildiğinde en iyi sınıflandırma başarısı gizli katmanda 10 nöronun kullanıldığı ÇKA yapısında elde edilmiştir. Başarı ortalamaları Tablo 3’de sunulmuştur.

Tablo 3. ÖDH ve ÇKP kullanılarak yapılan sınıflandırma başarısı ortalamaları

YSA Modeli	Sınıflandırma Başarısı (%)		
	Camsı Dane	Unsu Dane	Ortalama Başarı
ÖDH	99	96	97,5
ÇKA – 1	99	99	99
(Gizli katmanda 5 nöron)			
ÇKA – 2	100	100	100
(Gizli katmanda 10 nöron)			

Bu çalışmada durum buğdayı yığınındaki camsı ve camsı olmayan danelerin tespitinde kullanılacak hızlı ve başarılı sonuçlar üreten bir sistem önerilmiştir. Önerilen sistem buğday yığınlarının satın alma aşamasında kalite ve fiyat belirleme işlemlerinde kullanılabilir. Hareket halindeki banttardan akan buğday örneklerinin fotoğrafları sayısal kamera ile çekilerek gerçek zamanlı değerlendirme işlemi yapılabilir. Ayrıca bant çıkışına monte edilecek ağırlık sensörleri yardımıyla 1000 dane

ağırlığı gibi kalite belirleyici değerler tespit edilerek sadece camsılık değil farklı kalite kriterlerinin belirlenmesi de sağlanabilir. Ayrıca işleme aşamasında yığın içerisindeki camsı danelerin oranlarına göre proses parametrelerinin otomatik olarak belirlenmesi sağlanabilir ya da yığın içerisindeki camsı olmayan danelerin tespit edilerek yığından çıkarılması sağlanabilir. Böylece düşük kaliteli buğday yığınının kalitesinin artması sağlanabilir.

Kaynaklar

- [1] Wang N, Zhang N, Dowell F, Pearson T. Determination of durum wheat vitreousness using transmissive and reflective images. 2003 ASAE Annual International Meeting, Nevada, USA, 27 – 30 July 2003.
- [2] Brosnan T, Sun D.W. Inspection and grading of agricultural and food products by computer vision systems – a review. *Computers and Electronics in Agriculture* 2002; 36: 193-213.
- [3] Elgün A, Türker S, Bilgiçli N. Tahıl ve Tahıl Ürünlerinde Analitik Kalite Kontrolü. Konya: Konya Ticaret Borsası Yayınları; 2001.
- [4] Dowell F.E. Differentiating vitreous and non vitreous durum wheat kernels by using near infrared spectroscopy. *Cereal Chemistry*, 2000; 72: 155-158.
- [5] Wang N, Dowell F, Zhang N. Determining wheat vitreousness using image processing and a neural network. 2002 ASAE Annual International Meeting, Illinois, 28-31 July 2002.
- [6] Goretta N, Roger JM, Aubert M, Bellon-Maurel V. Determining vitreousness of durum wheat kernels using near infrared hyperspectral imaging. *Journal of Near Infrared Spectroscopy*, 2006; 14; 231-239.
- [7] Neethirajan S, Karunakaran C, Symons S, Jayas DS. Classification of vitreousness in durum wheat using soft X-rays and transmitted light images. *Computer and Electronics in Agriculture*, 2006; 53: 71-78.

- [8] Öztemel E. Yapay Sinir Ağları. İstanbul: Papatya Yayıncılık; 2003.
- [9] Kohonen T. The self-organizing map. Neurocomputing, 1998; 21: 1-6.