

Görüntü İşleme Tekniklerine Dayalı Sinirsel-Bulanık Sistem Modeli Kullanarak Buğday Danelerinin Sınıflandırılması

Classification Of Wheat Grains Using Image Processing Techniques Based Neuro-Fuzzy System Model

Ahmet Kayabasi¹, Kadir Sabanci¹, Abdurrahim Toktas¹

¹Elektrik-Elektronik Mühendisliği Bölümü, Karamanoğlu Mehmetbey Üniversitesi, Karaman, Türkiye
ahmetkayabasi@kmu.edu.tr, kadirsabanci@kmu.edu.tr, atoktas@kmu.edu.tr

Özetçe—Bu çalışmada, görüntü işleme tekniklerine (GİT) dayalı Sugeno tip sinirsel-bulanık sistem (SBS) modeli kullanarak buğday danelerinin, ekmeklik ve makarnalık olarak sınıflandırılması işlemi sunuldu. SBS modelinin eğitim ve test sürecinde kullanılacak veri setini elde etmek için 200 buğday danesinin görüntüleri yüksek çözünürlüklü kamera ile alınmıştır. Uzunluk, genişlik, alan, çevre ve doluluk olmak üzere 5 adet boyut özelliği, GIT kullanılarak elde edilmiştir. Sonra, SBS modeli, 180 buğday danesinin boyut özelliği giriş olacak şekilde kullanılarak eğitilmiş ve modelin doğruluğu da geriye kalan 20 buğday danesi ile test edilmiştir. Önerilen SBS modeli, test sürecinde sayısal olarak 0.0312 ortalama mutlak hata (OMH) ve % 100'lük bir doğruluk ile buğday danelerini ekmeklik ve makarnalık olarak sınıflandırmıştır. Bu sonuçlar GİT ve SBS modelinin buğday danelerinin ekmeklik ve makarnalık olarak sınıflandırılmasında başarılı bir şekilde kullanılabileceğini göstermektedir.

Anahtar Kelimeler—sınıflandırma; buğday daneleri; görüntü işleme teknikleri; sinirsel-bulanık sistem.

Abstract—In this study, an image processing techniques (IPTs) and a Sugeno-typed neuro-fuzzy system (NFS) model is presented for classifying the wheat grains into bread and durum. Images of 200 wheat grains are taken by a high resolution camera in order to generate the data set for training and testing processes of the NFS model. The features of 5 dimensions which are length, width, area, perimeter and fullness are acquired through using IPT. Then NFS model input with the dimension parameters are trained through 180 wheat grain data and their accuracies are tested via 20 data. The proposed NFS model numerically calculate the outputs with mean absolute error (MAE) of 0.0312 and classify the grains with accuracy of 100% for the testing process. These results show that the IPT based NFS model can be successfully applied to classification of wheat grains.

Keywords—classification; wheat grains; image processing technique; neuro-fuzzy system (NFS).

I. GİRİŞ

Ekmek, makarna, kek gibi ürünler için kullanılan unun standardı buğdayın kalitesine bağlıdır. Buğdayın kalitesini belirleyen en önemli faktör içerisindeki protein miktarıdır. Ekmek ve makarna yapımında kullanılan buğday çeşitlerinin içerisinde barındırdıkları protein miktarları farklıdır. Makarnalık buğday ekmeklik buğdaya göre daha çok protein içerir. Ekmeklik buğdayın makarnalık buğdayın içerisine karışması protein miktarının azalmasına sebep olacaktır. Bu yüzden, kalitenin artması ve maliyetin düşmesi açısından buğday danelerinin sınıflandırılması önemlidir. Son yıllarda bilgisayar teknolojileri sayesinde görsel özelliklerin kullanılması ile tarım ürünlerinin değerlendirilmesi önemli bir çalışma alanı haline gelmiştir. Görüntü işleme teknikleri (GİT) görsel özellikler ile ürünlerin sınıflandırılmasında kullanılabilir. Ayrıca yapılan sınıflandırmalardaki başarıyı artırmak için yapay zeka teknikleri GİT'ler ile entegre hale getirilmektedir [1-2]. Yapay sinir ağları (YSA), destek vektör makinaları (DVM), sinirsel-bulanık sistem (SBS), karar ağaçları (KA), k-en yakın komşuluk (KEYK), bayes ağlar (BA) ve diskriminant analiz (DA) tarım ürünlerinin sınıflandırılmasında en çok kullanılan yapay zekâ teknikleridir [3-7].


Literatürde farklı tarım ürünlerinin sınıflandırılması için birçok çalışma sunulmuştur. Berman ve ark. (2007) buğday danelerinin sınıflandırılmasında yakın kızılötesi görüntü analizini kullanmışlardır [8]. Jamuna ve ark. (2010), KA ve çok katmanlı algılayıcılara (ÇKA) bağlı sınıflandırıcılar ile pamuk tohumlarının sınıflandırmışlardır [9]. DA ve KEYK yapay zekâ teknikleri Guevara ve ark. (2011) tarafından buğday ve arpa sınıflandırmada kullanılmıştır [10]. Zapotoczny (2011) tarafından buğday sınıflandırmada, aşamalı analiz ve meta-çok katmanlı teknikler tercih edilmiştir [11]. Baharatları KEYK yoluyla sınıflandırmak için ultraviyole görünür spektrofotometri kullanan bir sınıflandırıcı Dİ Anibal ve ark. (2012) tarafından önerilmiştir [12]. Prakash ve ark. (2012) KEYK ve BA

sınıflandırma algoritmaları ile görüntü temelli sınıflandırma çalışmışlardır [13]. Pazoki ve ark. (2014) pirinç danelerinin morfolojik özellikleri ile ilgili 5 özelliğe bağlı YSA ve SBS kullanarak sınıflandırma yapmışlardır [14]. Mineral içeriklerine bağlı olarak kahve danelerinin sınıflandırılması için Muñiz-Valencia ve ark. (2014) ÇKA temelli YSA modellemiştir [15]. De Oliveira ve ark. (2016) tarafından yeşil kahve çekirdeklerini 4 gruba ayıran YSA ve BA modelleri tasarlanmıştır [16]. Literatürde, önerilen sınıflandırıcıların, dikkate alınan ürünlerin özelliklerine büyük oranda bağlı oldukları ve sınıflandırma doğruluklarının farklılık gösterdiği görülmektedir.

Bu çalışmada, buğday danelerinin 5 adet boyut özelliği kullanılarak ekmeklik ve makarnalık olarak sınıflandırılması için GİT temelli bir SBS modeli tasarlanmıştır. Bu çalışmada, Sugeno tip [17] SBS modeli kullanılmıştır. 200 adet buğday danesinin 5 boyut özelliği GİT vasıtasıyla elde edilmiş ve SBS modeline giriş olarak sunulmuştur. 200 buğday danesinden 180'i modeli eğitmek ve geriye kalan 20 adedi ise test işlemi için kullanılmıştır. Önerilen model eğitim ve test sürecinde buğday danelerini, ekmeklik ve makarnalık olarak %100 doğrulukta sınıflandırmıştır.

II. GÖRÜNTÜ İŞLEME TEKNİĞİ VE VERİLERİN ELDE EDİLMESİ

Konya bölgesinde yetiştirilen buğday danelerinin çekilen fotoğraflarından GİT kullanılarak, boyut özellikleri Şekil 1'de görülen blok diyagrama göre elde edilmiştir. Görüntülerin elde edilmesi için Şekil 2'de görüldüğü gibi bilgisayar, kamera, şerit LED aydınlatmalı ve kamera tutuculu kapalı bir kutudan oluşan bir düzenek kullanılmıştır. Kullanılan kameranın modeli ve teknik özellikleri şu şekildedir: Logitech C920, Full HD 1080p, Carl Zeiss Lens, 15 MP. Kamera ile görüntüler alınırken buğday ile aralarında 35 cm olacak şekilde yerleştirilmiş ve kutunun içinde siyah bir arka plan kullanılmıştır.




Şekil 1. Boyut özelliklerinin çıkarılmasına ait blok diyagram




Şekil 2. Görüntülerin alınması için kurulan düzenek

Kamera ile alınan birer adet ekmeklik ve makarnalık buğday görüntüleri Şekil 3'de görülmektedir. Fotoğraflardan da görüldüğü üzere 2 buğday danesi arasındaki ana fark, makarnalık buğdayın ekmeklik buğdaya göre daha büyük olmasıdır. Bu sebeple GİT temelli SBS modeli tasarlanırken buğday danelerinin boyut özellikleri kullanılmıştır. 100'er adet ekmeklik ve makarnalık buğday danelerinin yüksek çözünürlüklü kamera ile çekilen fotoğrafları Şekil 4'de görülmektedir.




Şekil 3. Buğday danelerinin görüntüleri a)Ekmeklik buğday b)Makarnalık buğday



Şekil 4. 100 buğday danesinin RGB görüntüleri a)Ekmeklik buğday b)Makarnalık buğday

GİT yazılımı, özellik verilerini elde etmek için MATLAB® programı aracılığıyla yürütülmüştür. İlk olarak, renkli buğday resimleri gri seviye resim bilgisine çevrilir. Gri seviye çevrilmiş ekmeklik ve makarnalık buğday resimleri Şekil 5a ve 5b'de görülmektedir. İkinci olarak gri seviye ekmeklik ve makarnalık resimler, Otsu metodu [18] kullanılarak Şekil 5c ve Şekil 5d'de görüldüğü gibi binary (siyah/beyaz) resime çevrilir. Morfolofik işlemler kullanılarak binary resimdeki görüntüler filtrelenmiştir. Üçüncü olarak, binary resimde segmentasyon işlemi ile her bir danenin konumu belirlenerek etiketlenir.



Şekil 5. 100 buğdayın görüntüleri a) Ekmeklik buğdayın gri seviyesi b) makarnalık buğdayın gri seviyesi c) Ekmeklik buğdayın binary görüntüleri d) Makarnalık buğdayın binary görüntüleri

Her bir danenin boyutlarına ait, uzunluk (U), genişlik (G), alan (A) ve çevre (Ç) özellikleri ikili görüntülerden çıkarılır. Boyutla ilgili doluluk (D) özelliği bu parametreler kullanılarak Eşitlik 1’de verilen formüle göre elde edilir.

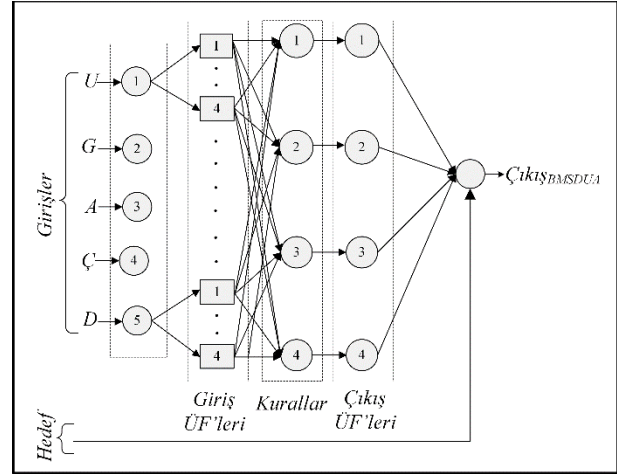
$$D = \frac{4\pi A}{\text{Ç}^2} \quad (1)$$

III. SİNİRSEL-BULANIK SİSTEM MODELİ

Bulanık mantık ve sinir ağları yapısı birbirini doğal olarak tamamlayan birinde eksik olanın diğerinde bulunduğu yapay zekâ sistemleridir. Sinir ağları düşük seviyeli hesaplama yapılarında iyi performans verirken, ham verilerde bulanık mantık dilsel yorumlarla daha yüksek seviyeli yorumlar yapabilir. Ancak bulanık mantık sistemi yeni çevre şartları için kendini yenileyemez ve öğrenme yetisi de yoktur. Diğer taraftan sinir ağlarının öğrenme kabiliyeti vardır. Bu iki yapının birleştirilmesi bulanık mantık çıkarım sistemine öğrenme kabiliyeti eklemiş ve bulanık mantık çıkarım sistemini daha etkili hale getirmiştir. Ortaya çıkan yapı sadece öğrenme kabiliyeti olarak açıklamak yetersiz kalır. Buna ilaveten bu birleşme sonucu, bulanık mantık parametrelerinin optimizasyonunda da gelişme olmuş, en küçük kareler metodu ve eğitim metodlarının kazanımı ile bulanık mantık, sinir ağları metodundan daha hızlı yakınsayan bir metot haline dönüşmüştür [19].

A. Sinirsel-Bulanık Sistem Modeli Eğitim Süreci

SBS modeline, buğday danelerinin boyut parametreleri giriş olarak, sınıflandırma sonuçları da hedef olarak sunulmuştur. Eğitim sürecinde 200 buğday danesi veri setinin 180’i kullanılmıştır. Sugeno tip bulanık çıkarım sistemi kullanan SBS modeline ait blok diyagramı Şekil 6’da görülmektedir. SBS eğitim sürecinde, üyelik fonksiyonlarının (ÜF) farklı tipleri ön çalışmalarda denenmiş ve girişler için Gaussian ÜF, çıkış içinde lineer ÜF seçilmiştir. Bu çalışmada, model parametrelerinin belirlenmesinde “eğitim düşümü” yöntemi ve “en küçük kareler” yöntemlerinin birleşiminden oluşan Hybrid öğrenme algoritması kullanılmıştır. Eğitim düşümü yöntemi, lineer olmayan giriş parametrelerinin düzenlenmesinde, en küçük kareler yöntemi ise lineer çıkış parametrelerinin düzenlenmesinde kullanılmaktadır. Eğitim düşümü yöntemi, modellemede ağ hatasını en küçük yapacak şekilde ağırlık katsayılarının değiştirilmesi ve güncelleştirilmesi için kullanılmaktadır. Hybrid öğrenme algoritması yardımıyla, giriş üyelik fonksiyonu parametreleri, çıkış üyelik fonksiyon parametreleri güncellenmekte ve en uygun değerler elde edilmektedir. Bu çalışmada kullanılan SBS modeline ait parametreler Tablo I’de verilmiştir. SBS modelinin yazılımı MATLAB araç kutusu kullanılarak oluşturulmuştur.



Şekil 6. SBS modelinin blok diyagramı

Parametreler	Tip/değer
Giriş ÜF tipi	Gaussian
Çıkış ÜF tipi	Lineer
Giriş sayısı	5
Çıkış sayısı	1
Bulanık kurallar sayısı	4
ÜF sayısı	4
Seed değeri	1915847970
Epok	200
Etki aralığı	0.5
Sıkıştırma faktörü	1.25
Kabul oranı	0.5
Geri çevirme oranı	0.15

Tablo I. SBS modelinin parametreleri

B. Sinirsel-Bulanık Sistem Modeli Test Süreci

Eğitim sürecinde kullanılan verilerin dışında kalan 20 adet buğday danesi verisi önerilen modeli test etmek için kullanılmıştır. 10 ekmeclik ve 10 makarnalık türden oluşan 20 buğday danesinin uzunluk, genişlik, alan, çevre ve doluluk olmak üzere 5 adet boyut özelliğini kapsayan test verileri ve mutlak hata değerleri ile beraber SBS modeli test sonuçları Tablo II’de verilmiştir. Tablo II’den görüldüğü üzere, önerilen SBS modeli, test sürecinde sayısal olarak 0.0312 OMH ve % 100’lük bir sınıflandırma doğruluğu ile sonuçları belirlemiştir. Önerilen modelin test aşamasında, 18 adet sınıflandırma işleminin çok küçük hata ile gerçekleştirildiği Tablo II’den görülmektedir. Bu sonuçlar GIT’e dayalı SBS modelinin buğday danelerinin sınıflandırmasında başarılı bir şekilde kullanılabileceğini göstermiştir.

Dane #	Giriş parametreleri					Hedef	Sonuçlar		
	Uzunluk (pxl)	Genişlik (pxl)	Alan (pxl ²)	Çevre (pxl)	Doluluk		ÇıkışSBS	Mutlak hata	Sınıflandırma
1	80.5652	35.8292	2256.0000	202.7523	0.6896	1.000	1.1114	0.1114	Makarnalık
2	85.4882	33.8357	2256.0000	208.3675	0.6530	1.000	0.9967	0.0033	Makarnalık
3	87.0308	28.6928	1938.0000	206.4092	0.5716	1.000	1.0072	0.0072	Makarnalık
4	90.6658	29.1766	2066.0000	212.3675	0.5757	1.000	1.0051	0.0051	Makarnalık
5	73.6011	28.3721	1630.0000	177.5391	0.6498	1.000	0.9904	0.0096	Makarnalık
6	76.5508	29.1798	1745.0000	183.4386	0.6517	1.000	0.9925	0.0075	Makarnalık
7	87.2399	35.4049	2415.0000	214.0660	0.6623	1.000	0.9944	0.0056	Makarnalık
8	81.1672	35.0524	2214.0000	203.9655	0.6688	1.000	0.9996	0.0004	Makarnalık
9	82.8189	33.0887	2140.0000	205.1371	0.6391	1.000	0.9930	0.0070	Makarnalık
10	73.6011	28.3721	1630.0000	177.5391	0.6498	1.000	0.9904	0.0096	Makarnalık
11	69.5679	37.3539	2014.0000	188.6518	0.7111	2.000	1.8930	0.1070	Ekmeçlik
12	63.6663	35.1940	1757.0000	166.2670	0.7987	2.000	2.0019	0.0019	Ekmeçlik
13	69.3322	33.8972	1841.0000	175.9239	0.7475	2.000	2.0146	0.0146	Ekmeçlik
14	73.5171	31.9743	1835.0000	186.1665	0.6653	2.000	1.6980	0.3020	Ekmeçlik
15	66.2957	37.9450	1967.0000	177.6812	0.7829	2.000	2.0013	0.0013	Ekmeçlik
16	66.6693	41.0286	2140.0000	180.8528	0.8222	2.000	1.9904	0.0096	Ekmeçlik
17	65.1759	34.7517	1772.0000	171.6812	0.7555	2.000	2.0078	0.0078	Ekmeçlik
18	63.0120	34.5241	1702.0000	165.2965	0.7828	2.000	2.0026	0.0026	Ekmeçlik
19	68.0608	40.1471	2138.0000	187.8234	0.7616	2.000	2.0023	0.0023	Ekmeçlik
20	65.8371	35.9484	1851.0000	176.3087	0.7483	2.000	2.0084	0.0084	Ekmeçlik
Ortalama Mutlak Hata (OMH)								0.0312	

Tablo II. SBS modeli ile test verileri için sınıflandırma sonuçları

IV. SONUÇ

Bu bildiriye, GİT temelli sugeno tip SBS modeli ekmeçlik ve makarnalık olarak buğday danelerinin sınıflandırılması için önerilmiştir. Türkiye'nin Konya bölgesinde yetiştirilen 100 ekmeçlik ve 100 makarnalık buğday danesi için 5 boyut özelliği GİT kullanılarak elde edilmiştir. Sugeno tip SBS modeli 180 buğday danesi ile eğitilmiş, geriye kalan 20'si ile de test edilmiştir. Önerilen modelin sınıflandırma işlemi %100 doğrulukla yaptığı belirlenmiştir. Önerilen yapay zeka metodu, tarım ürünlerinin sınıflandırılması için endüstriye entegre edilerek başarılı bir şekilde kullanılacaktır.

YAZAR KATKILARI

Birinci yazar çalışmanın sorumlu yazarı olup bulanık mantık sistemine dayalı uyarlanabilir ağ modeli için kullanılan yazılımları yazmış ve uygun modelin bulunmasını sağlamıştır. *İkinci yazar* buğday danelerini görüntü işleme tekniği ile işleyerek modelin eğitimi ve testi için kullanılan veri setini elde etmiştir. *Üçüncü yazar* görüntü işleme sürecine yardım etmiş, bildirisinin yazımı ve bildiri içerisindeki şekil ve tabloların çizimini gerçekleştirmiştir.

KAYNAKÇA

- [1] Mollazade K, Omid M and Arefi A, "Comparing data mining classifiers for grading raisins based on visual features," *Comput Electron Agr*, 84, 124–131, 2012.
- [2] Sungur C and Ozkan H, "A real time quality control application for animal production by image processing," *J Sci Food Agr*, 95, 2850–2857, 2015.
- [3] Yu X, Liu K, Wu D and He Y, "Raisin quality classification using least squares support vector machine (LSSVM) based on combined color and texture features," *Food Bioprocess Tech*, 5, 1552–1563, 2012.
- [4] Hu BG, Gosine RG, Cao LX and de Silva CW, "Application of a fuzzy classification technique in computer grading of fish products," *IEEE T Fuzzy Syst*, 6, 144–152, 1998.
- [5] Al Ohali Y, "Computer vision based date fruit grading system: Design and implementation," *Journal of King Saud University-Computer and Information Sciences*, 23, 29–36, 2001.
- [6] Gálvez RP, Carpio FJE, Guadix EM and Guadix A, "Artificial neural networks to model the production of blood protein hydrolysates for plant fertilisation," *J Sci Food Agr*, 96, 207–214, 2016.
- [7] Pet'ka J, Mocak J, Farkaš P, Balla B and Kováč M, "Classification of Slovak varietal white wines by volatile compounds," *J Sci Food Agr*, 81, 1533–1539, 2001.

- [8] Berman M, Connor PM, Whitbourn LB, Coward DA, Osborne BG and Southan MD, "Classification of sound and stained wheat grains using visible and near infrared hyperspectral image analysis," *J Near Infrared Spec*, 15, 351–358, 2007.
- [9] Jamuna KS, Karpagavalli S, Revathi P, Gokilavani S and Madhiya E, "Classification of Seed Cotton Yield Based on the Growth Stages of Cotton Crop Using Machine Learning Techniques," *International Conference on Advances in Computer Engineering*, 20-21, June, 2010; Bangalore, Karnataka, India, 312–315, 2010.
- [10] Guevara-Hernandez F and Gomez-Gil J, "A machine vision system for classification of wheat and barley grain kernels," *Span J Agric, Res*, 9, 672–680, 2011.
- [11] Zapotoczny P, "Discrimination of wheat grain varieties using image analysis: morphological features," *Eur Food Res Technol*, 233, 769–779, 2011.
- [12] Di Anibal CV, Ruisánchez I, Fernández M, Forteza R, Cerdà V and Callao MP, "Standardization of UV-visible data in a food adulteration classification problem," *Food Chem*, 134, 2326–2331, 2012.
- [13] Prakash JS, Vignesh KA, Ashok C and Adithyan R, "Multi class Support Vector Machines classifier for machine vision application," *In Machine Vision and Image Processing (MVIP)*, 14-15, Dec, 2012; Taipei, Taiwan, 197–199, 2012.
- [14] Pazoki AR, Farokhi F and Pazoki Z, "Classification of rice grain varieties using two Artificial Neural Networks (MLP and Neuro-Fuzzy)" *J Anim and Plant Sci*, 24, 336–343, 2014.
- [15] Muñoz-Valencia R, Jurado JM, Ceballos-Magaña SG, Alcázar Á and Hernández-Díaz J, "Characterization of Mexican coffee according to mineral contents by means of multilayer perceptrons artificial neural networks," *Journal of Food Composition and Analysis*, 34, 7–11, 2014.
- [16] De Oliveira EM, Leme DS, Barbosa BHG, Rodarte MP and Pereira RGFA, "A computer vision system for coffee beans classification based on computational intelligence techniques," *J Food Eng*, 171, 22–27, 2016.
- [17] Shleeg, Alshalaa A., and Issmail M. Ellabib, "Comparison of mamdani and sugeno fuzzy inference systems for the breast cancer risk," *International Journal of Computer, Information Science and Engineering*, 7(10), 387-391, 2013.
- [18] Otsu N, "A Threshold Selection Method from Gray-Level Histograms," *IEEE T Syst Man Cyb*, 9, 62–66, 1979.
- [19] Jang JSR, "ANFIS: adaptive-network-based fuzzy inference system," *IEEE Trans SystMan Cybern*, 23, 665–685, 1993.