

Fıstık sınıflandırma sistemi için Siirt fıstığı imgelerinden gürbüz özneliklerin çıkarılması

Musa ATAŞ^{*1}

¹ Siirt Üniversitesi, Bilgisayar Mühendisliği Bölümü, Siirt

Makale Gönderme Tarihi: 07.02.2016

Makale Kabul Tarihi: 12.04.2016

Öz

Siirt fıstığı diğer fıstık çeşitlerine göre daha iri taneli oluşu, aroma ve tadındaki farklılıklarından dolayı Antep fıstığı çeşidine göre piyasada çoğunlukla taze çerez olarak tüketilmektedir. Yıllık ortalama 25 bin ton üretim kapasitesi olan Siirt fıstık çeşidinin yurtiçi ve dışında pazarlanabilmesi ve müşteri memnuniyetini kazanabilmesi için kalite standartlarına göre bir sınıflandırma ve derecelendirme işlemine tabi tutulması gerekmektedir. Hâlihazırda sınıflandırma işlemi manuel olarak işçiler ve mekanik araçlar kullanılarak yapılmaktadır. İnsan gücü ile sınıflandırma işlemi uzun zaman alan, sıkıcı ve verimi düşük bir süreçtir. Bununla birlikte söz konusu işlem gıda hijyeni açısından da riskler taşımaktadır. Diğer taraftan mekanik araçlar (titreşim temelli elekler ve iğneli sınıflandırıcılar) istenilen doğrulukta sınıflandırma yapamamaktadırlar. Sonuç olarak bilgisayar görüşü tabanlı tam otomatik bir fıstık sınıflandırıcı sistemine gereksinim duyulmaktadır. Bu çalışmamızda, Siirt fıstığının kalite standartlarına göre sınıflandırılması işleminde kullanılmak üzere görüntüleri alınan Siirt fıstığı numunelerinden ayrımsallık gücü yüksek özneliklerin çıkarılması için çeşitli imge işleme yöntemlerinin geliştirilmesi hedeflenmiştir. İmgelerden çapların oranı, fıstık alanı ve kenar alan oranı öznelikleri çıkarılmıştır. Elde edilen gürbüz öznelik vektörü çevrim dışı (offline) sınıflandırma işlemine girdi parametresi olarak verilmiştir. TSE standartlarına göre fıstıklar, alan uzmanı tarafından danişmalı öğrenme maksadıyla ekstra iri, iri, orta, küçük, kabuk ve çatlamamış sınıflarına ayrılmışlardır. Her bir fıstık grubunda 100 adet fıstık olacak şekilde toplam 600 adet fıstık numunesinden örüntüler çıkarılmıştır. Çevrimdışı (Offline) sınıflandırmada Naive Bayes, Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) algoritmaları kullanılmıştır. Sınıflandırma algoritmaları kendi aralarında genel sınıflandırma başarımları ve 2.tip hata (Type II error, severe error, false negative) ölçütlerine göre karşılaştırılmıştır. Genel sınıflandırma başarısına göre %83.33 doğruluk oranı ile YSA en iyi sınıflandırıcı olarak tespit edilmiştir. 2.tip hata ölçütünde yine YSA ve Naive Bayes sınıflandırıcıları seçilmiştir. Sonuç olarak sunulan gürbüz öznelik vektörü çerçevesinde YSA ve Naive Bayes sınıflandırıcılarının fıstık sınıflandırma sistemi için kullanılması önerilmektedir. Yapılan gerçek zamanlı testlerde bir fıstık numunesi için öznelik çıkarımı ve sınıflandırma işlemlerinin süresi toplamda yaklaşık 314 ms olarak hesaplanmıştır.

Anahtar Kelimeler: Görüntü İşleme; Öznelik çıkarımı; Fıstık sınıflandırma sistemi; Sınıflandırma;

*Yazışmaların yapılacağı yazar: Musa ATAŞ. hakmesyo@gmail.com; Tel: +90 (484) 223 12 24 (3019)

Giriş

Bilgisayarlı görü sistemleri günümüzde birçok alanda (üretim, medikal, askeri, robotik, tarım) başarılı ve etkin bir şekilde kullanılmaktadır. Tarımsal gıdaların tahribatsız muayene kapsamında, paketlenmeden önce incelenerek kalite standartları çerçevesinde son kullanıcıya ulaştırılması, üretici firmaların rekabet gücünü arttırmaktadır. Türkiye, fıstık üretiminde dünyada üçüncü sırada yer almaktadır. 2015 verilerine göre yıllık 15 bin ton üretim ile en çok fıstık üretilen üçüncü il olan Siirt ilimiz, Türkiye’de üretilen fıstığın %18 ini karşılamıştır (Tarımsal rehber, 2015). Siirt fıstığı daha iri taneli yapısı, düşük yağ oranı ve daha zengin besleyici özellikleriyle Antep fıstığına göre piyasada taze çerez olarak rağbet görmektedir. Dolayısıyla ekonomik kazancı daha iyi olmaktadır.

Dicle Kalkınma Ajansı (DIKA) verilerine göre, Siirt ilinde yıllık 15 bin ton Siirt fıstığı işleyebilecek modern bir tesisin yapımı IPA (Katılım Öncesi Yardım Aracı) tarafından desteklenmiştir. Önümüzdeki üç yıl içerisinde bu tesisin aktif olacağı düşünülmektedir. Fıstık işleme sürecinde önemli olabilecek üç basamak vardır. Bunlar; çatlamamış fıstıkların tespiti, içi boş fıstıkların dolu olanlardan ayrıştırılması ve fıstıkların boyut, şekil, sağlıklı oluşu, morfolojik ve estetik özelliklerine göre sınıflandırılmasıdır. Hâlihazırda boş fıstıkların ayırımı için suyun kaldırma kuvveti prensibi kullanılmaktadır. Fakat su içerisine atılan fıstıkların nem oranı artmakta bu da aflatoksine sebep olan küfün üremesine sebep olmaktadır. Yabancı madde ve iç fıstık içeren, kabuk veya parçacıkları ihtiva eden, değişik türde kusuru olan, küf, böcek zararı ve çürümüş fıstıkları sınıflandıracak komple bir sistem henüz geliştirilmemiştir. Siirt fıstığında çatlak tespiti ve sınıflandırma, hâlihazırda işçiler tarafından ilkel yöntemlerle elle yapılmaktadır. Gıda hijyeni göz önüne alındığında bu yöntemin sağlık açısından sakıncaları vardır. Buna ek olarak, büyük tonajlı ürünlerin sınıflandırılması hem uzun zaman almakta, hem de etkin olamamaktadır. Tüketici açısından

düşünüldüğünde çatlak olmayan ve kötü kalitedeki fıstıkların miktarı doğrudan müşteri memnuniyetini etkileyeceğinden, başarıyı yüksek bir sınıflandırıcı sisteminin geliştirilmesi kaçınılmaz olmaktadır.

Son yıllarda tarımsal ürünlerin sınıflandırılmasında mekanik, akustik ve optik yöntemler sıkça kullanılmaktadır. Mekanik sınıflandırıcılara örnek olarak titreşimli elekler ve iğneli seçiciler verilebilir. Titreşimli elekler sadece fıstığın boyut bilgisi gözetilerek derecelendirilmesini amaçlar. Elde edilen ürün kalite standartları düşünüldüğünde tatmin edici olmaktan uzaktır. Çünkü boyutları aynı olup kabuk, içi boş, çatlamamış, hastalıklı veya yabancı madde gruplarının kaliteli fıstık gruplarına karışmış olması muhtemeldir. İğneli seçiciler (needle sorter) ise fıstıklarda çatlak ve çatlak olmayan ayırımını yapmak için geliştirilmiş mekanik sistemlerdir. Söz konusu sistemde yaklaşık 1.5 metre çapında ve 3 metre uzunluğunda bir tamburun içerisine belirli bir desende yerleştirilmiş on binlerce ucu kancalı çelik iğne kullanılmıştır. Tambura gönderilen işlenmemiş fıstıklar belirli bir hızda dönen tamburun dış kenarına merkez kaç ile dağıtılarak fıstıkların çatlak kısmının iğnelerin başındaki kancalar tarafından yakalanarak tahliye edilmesi amaçlanır. Bu işlemin neticesinde fıstıklar çatlak veya kapalı sınıflarına ayrılırlar. %8 civarında çok az çatlağı olan fıstıkları da çatlamış sınıfına dâhil eden söz konusu sistem ürüne fiziksel olarak ta zarar verdiğinden işletmeler tarafında tercih edilmemektedir (Ghazanfari vd. 1997, Pearson 2001).

Son yıllarda, ABD’de ve İran’da yapılan çalışmalarda, çarpma ses verisine dayanarak çatlak fıstıklar çatlak olmayanlardan, içi boş olanlar da içi dolu olanlardan yüksek bir sınıflandırma başarıyı ile ayrılmaya çalışılmıştır (Pearson 2001, Çetin vd. 2004, Omid vd. 2009, Omid 2011). Laboratuvar şartlarında tek kanal olarak çalışan söz konusu sistemler, gerçek fabrika ortamında daha düşük performans sunmaktadırlar. Bunun da en büyük nedeni, çarpma sesi temelli sistemin çevresel

görüntülerden çok fazla etkilenmesidir. Diğer bir neden ise genellikle yapılan çalışmalarda laboratuvar ortamında ortalama aynı büyüklükte ve tipte fıstığın kullanılmasıdır.

Görüntü tabanlı çalışmalara gelindiğinde ilk olarak Pearson (1996), bilgisayarlı görü sistemi kullanarak kabuğu hastalıklı fıstıkları sağlıklı fıstıklardan %85 doğrulukla ayırabilmiştir. Bu bağlamda Ghazanfari vd. (1997) ile Ghazanfari vd. (1998) çalışmalarında da görüntü tabanlı sınıflandırma kullanıldığını görmekteyiz. Söz konusu çalışmalarda, gri seviye histogram ve fourier betimleyicileri öznelik vektörü olarak kullanılarak sırasıyla %92.4 ve %94.8 genel sınıflandırma başarımı elde edilmiştir. Ayrıca Pearson ve Toyofoku (2010) çalışmalarında Digital Signal Processor (DSP) kullanarak üç farklı açıdan çekilmiş çizgi-taramalı (line-scan) görüntülerden fıstığın açık ya da kapalı olduğu bilgisine %95 sınıflandırma başarısı ile ulaşabilmişlerdir. Burada dikkat edilmesi gereken nokta, bu çalışmalarda fıstık numunelerine belirli bir oryantasyon (dikey yön) verildiğidir ve sistem tam olarak gerçek zamanlı çalışmamaktadır. Ayrıca, genellikle o zamandaki kullanılan teknoloji düşünüldüğünde 2 ya da 3 sınıf hedeflenmiştir. 3 sınıf ve üzerinde bir çalışmaya literatürde rastlanılmamıştır.

Bu çalışmada, fıstık sınıflandırma sisteminde kullanılması için, dikey olarak serbest düşme hareketi ile bırakılan fıstık örneklerinden elde edilen görüntülerden ayrımsallık güçleri yüksek özneliklerin çıkarılması hedeflenmektedir. Elde edilen gürbüz öznelik vektörü çevrim dışı (offline) sınıflandırma işlemine girdi parametresi olarak verilmiştir. Sunulan gürbüz öznelik yöntemleri kendi aralarında; sınıflandırma performansı ve çalışma hızı ölçütlerine göre irdelenmiştir. Sistemin gerçek zamanlı işleme hızı test edilmiştir. Çıkarılan özneliklerin grup halinde sınıflandırma başarımları ayrıca araştırılmıştır.


Materyal ve Yöntem

Veri Toplama

Siirt fıstığı örneklerinin görüntülerinin alınması için Şekil 1 ve Şekil 2 deki fıstık besleme ve görüntü alımı bileşenleri geliştirilmiştir.




Şekil 1. Birim zamanda bir fıstık beslemeye olan tanıyan krank-biyel ve hava üfleme düzeneği



Şekil 2. Görüntü alımı kamera düzeneği

Şekil 1’de görüldüğü gibi, imgeleri alınacak fıstık örnekleri besleme ünitesine tepeden insan gücü ile doldurulmaktadır. Huni şeklindeki ünitenin üzerinde fıstıkların kendi aralarında tutunmasını engellemek için titreşim motoru çalışmaktadır. Huninin merkezinde yukarıya doğru krank-biyel mekanizması ile dairesel

hareketi doğrusal harekete çeviren bir düzenek yardımıyla fıstıklar tek tek alınarak belirli bir yüksekliğe gelindiğinde solenoid valfin çalışması sağlanmış ve ilgili fıstık hava yardımıyla yerinden alınarak besleme işlemi gerçekleştirilmiştir. Serbest düşme hareketi yapan fıstık iç çapı 16 mm olan pleksi glass borudan akmaya zorlanarak dikey konuma yakın bir yön kazandırılmıştır. Ancak küçük boyutlu fıstıklar için dikey olarak düşme garantisi bulunmamaktadır. İlgili fıstık şeffaf borudan geçerken kızılötesi sensör tarafından algılanması sağlanmıştır. Bu iş için MZ80 cisimden yansımali kızılötesi sensör kullanılmıştır. Kızılötesi sensör harici tetikleyicileri bulunan Şekil 2 deki üç adet GigE endüstriyel kamerayı tetikleyerek anlık görüntü alımı gerçekleştirmiştir. Görüntüler gigabit yerel ağ üzerinden iş istasyonunda çalışan yazılıma aktarılmıştır. Görüntü alımı için GigE IC Imaging DFK23618 endüstriyel kameralar kullanılmıştır. Söz konusu kameralar 120 fps video çekim ve ağ üzerinde çalışabilme yeteneğine sahiptirler. Serbest düşen fıstık örneğinin hareketten kaynaklanan görüntü bozukluğunu (motion blur) engellemek için kameranın pozlama (exposure) süresi 1/10000sn olacak şekilde ayarlanarak kapalı kutunun içerisi yoğun ve homojen bir şekilde aydınlatılmıştır. Aydınlatmada kararlı ışık verebilmesi için doğru akımda çalışabilen led'ler kullanılmıştır. Şekil 3 yazılım tarafından yakalanan 640x480 çözünürlüğündeki bir fıstık örneğinin 120 derecelik açılarla çekilmiş imgelerini göstermektedir. Şekil 3 teki görüntüler orijinal imgelerden (640x480) ilgi alanı algoritması (region of interest, ROI) kullanılarak kesilmiştir (cropping).





Şekil 3. Değişik açılardan (120°) alınmış aynı fıstık örneğine ait ROI imgeleri.

Söz konusu algoritma bir sonraki bölüm olan önışlemede ayrıntılı olarak ele alınmıştır.

Önışlem

Çalışmada kullanılan endüstriyel kameralar varsayılan olarak 640x480 çözünürlüğünde renkli görüntü üretmektedirler. İlk olarak renkli görüntüler gri parlaklık (0-255) seviyesine dönüştürülmüştür. Şekil 4 renkli görüntü (üst) ve gri seviye görüntüsü (alt) göstermektedir.



Şekil 4. Orijinal 640x480 çözünürlüğündeki renkli (üst) ve gri seviye (alt) görüntü

Gri seviye görüntü incelendiğinde imgede yüksek seviyede arka plan gürültüsünün olduğu görülmektedir. 3x3 ortanca (median) filtre uygulanarak gürültüler giderilmeye çalışılmıştır. Arka plandaki pikselleri tamamen siyah (gri parlaklık değeri=0) yapmak için eşik değeri (threshold value) 13 olacak şekilde ayrıca bir yüksek geçer filtre (ygf) yani high-pass filter

uygulanmıştır. Orijinal görüntülerde fıstığın kapladığı alan tüm alanın (640x480) yaklaşık 5 veya 6 da biri kadardır. Hesaplama süresini azaltmak için fıstık nesnesini imgeden çıkarmak gerekir (cropping). Bu iş için Java programlama dilinde fıstık nesnesinin sol-üst ve sağ-alt koordinatlarını bulan bir ilgi alanı (ia) algoritması geliştirilmiştir. Aşağıda, orijinal imgeden fıstık nesnesini çıkaran kod bloğu yazılmıştır.

```
public int[][] getROI(int[][] img) {
    int[] px = getProjectedX(img);
    int[] py = getProjectedY(img);
    int[] x = getObjectPos(px);
    int[] y = getObjectPos(py);
    return getSubMatrix(img, x, y);
}
```

Yukarıdaki kod incelendiğinde, img matrisinin (orijinal imge) x ve y eksenleri üzerinde izdüşümleri alındıktan sonra getObjectPos fonksiyonu ile olası bölgenin başlangıç ve bitiş koordinatlarının tespit edildiği ve dikdörtgen bölgenin getSubMatrix komutu ile çıkarıldığı anlaşılmaktadır.

Öznitelik Çıkartma

Öznitelikler çıkarılacağı zaman sınıflandırma işlemine katkı sağlayacak güçlü ve gürbüz özneliklerin çıkarılması hedeflenmiştir. Fıstık görüntüleri incelendiğinde fıstık nesnesinin yaklaşık bir elips şeklinde olduğu görülmektedir. Elipste bulunan küçük (r1) ve büyük (r2) yarıçap (birbirine dik eksenler) kavramları bu benzetim ile fıstık nesnesinde de bulunacaktır. Normal fıstık ile kabuk, iç ve yabancı madde (ağaç dalı veya yaprak) ayrımı için eksenler oranı (r1/r2) güçlü bir ayrımsallık verebilir. Diğer taraftan fıstık nesnesinin alan bilgisi de kabuk ve normal ayırımının yanında kalite standartlarına göre sınıflandırma işlemi için kullanılabilir. Son olarak ta çatlamamış ve çatlak fıstıkları ayırabilmek için toplam kenar uzunluğunun alanın kareköküne oranından faydalanabiliriz. İlerleyen alt başlıklarda her bir özneliğin nasıl bulunduğu dair detaylı bilgiler verilecektir.


a) Çapların Oranı (ÇO)

Fıstık görüntüleri incelendiğinde yaklaşık %70'ine yakın oranda fıstıkların düşey olmadığı görülmektedir. Şayet bütün görüntülerde fıstığın düşey olması garantilenmiş olsaydı, çıkartılmış ia görüntüsünün genişliği ve uzunluğu bize r1 ve r2 değerlerini verecekti. Dolayısıyla zor hesaplamalara girilmeden kısa yoldan sonuca ulaşmamız mümkün olurdu. Ancak belirttiğimiz gibi %70 oranında dik düşmeyen fıstık söz konusudur.

Çap bilgileri hesaplanırken fıstık geometrisi göz önüne alınarak genel olarak fıstık kontürünün bir elipse benzediği varsayımından yola çıkılmıştır. Buna göre, her bir fıstık görüntüsünde birbirine dik (orthogonal) olacak şekilde iki temel eksen bulunmaktadır. Birinci eksen fıstığın merkezinden uzunlamasına geçen eksendir. Bu eksene dik diğer eksen ise çaptır. Çapı hesaplayan algoritma ilk etapta birinci yani uzun olan ekseni bulmaya çalışır. Bunun için crop edilmiş fıstık imgesinin parlaklık değeri matrisinde birbirinden uzamsal (spatial) olarak en uzak (euclidean distance) piksellerin koordinatları tespit edilir. Sonra bu koordinatlar arasında sanal bir doğru oturtulur. Bu sanal doğruyu dik kesen eksen belirlenir. Bunun için Denklem 1'deki formülden faydalanılır.

$$m1 * m2 = -1 \quad (1)$$

Bu formüle göre birbirine dik iki doğrunun eğimlerinin çarpımı -1'e eşittir. Birinci eksenin merkezinden, ikinci eksen doğrultusunda hareket edilerek pikseller tek tek kontrol edilir. İmgelere ygf uygulandığı için, sıfır parlaklık değerine ulaşınca kadar matris içinde çap doğrultusunda ilerlenir. Fıstık dışına çıktığında sıfır gri değerine ulaşılacağından işlem o noktada sonlandırılarak toplam kaç piksel hareket edildiği hesaplanıp çap değeri belirlenir. Şekil 5, değişik fıstık numuneleri için tespit edilen temel eksenlerin görüntü üzerine eklenmiş (overlay) durumlarını göstermektedir. Şekil 5 incelendiğinde tespit edilen temel eksenlerde herhangi bir hatanın olmadığı anlaşılmaktadır.



Şekil 5. Değişik fıstık imgelerinde tespit edilen temel eksenler

b) Fıstık Alanı (FA)

İmgelerden fıstık alanını bulmak nispeten kolay bir işlemdir. Daha önceden imgeye yüksek-geçer filtre uyguladığımız için değeri sıfırdan büyük olan tüm piksellerin teorik olarak fıstık nesnesine ait olduğu varsayılır. Bu piksellerin toplam sayısı bize fıstık alan değerini verir. Denklem 2 ve 3, FA değerinin hesaplanma işlemini özetlemektedir.

$$FA = \sum_{i=1}^M \sum_{j=1}^N f(i, j) \quad (2)$$

$$f(i, j) = \begin{cases} 1 & \text{eğer } P(i, j) > 0 \\ 0 & \text{eğer } P(i, j) = 0 \end{cases} \quad (3)$$

Denklem 2'deki M ve N değerleri imgedeki satır ve sütun sayılarını ifade eder. $f(i, j)$ ise Denklem 3'te görüldüğü gibi parçalı bir fonksiyondur. P yani piksel parlaklık değeri 0'dan büyük ise 1 değilse 0 değerini üretir.

c) Kenar Alan Oranı (KAO)

Kenar alan oranını bulunması için fıstık nesnesinin toplam kenar uzunluğunun bulunması gerekmektedir. Toplam kenar uzunluğu (TKU) hesaplanmasında bilinen kenar bulma algoritmalarından Sobel, Prewitt ve Canny (1986) algoritmaları denenmiştir. En iyi çıktı Canny'den elde edildiği için bu çalışmada Canny kenar bulma algoritması kullanılmıştır.

Şekil 6, Çatlak ve çatlamamış fıstıklar için Canny kenar tespiti çıktılarını göstermektedir.



Şekil 6. Çatlak (üstte) ve çatlamamış (altta) fıstıkların, orijinal (sol) ve Canny (sağ) kenar tespit çıktıları

Toplam kenar uzunluğu (TKU), kenar bulma algoritması uygulanmış bir görüntüdeki beyaz (255 parlaklık değeri) piksellerin toplam adedidir. TKU'nun fıstık alanına oranı bize fıstığın çatlak veya çatlamamış olduğu hakkında bilgi verir. Çatlak fıstıklarda Şekil 6'dan da anlaşılacağı gibi, çatlama kenarları da pixel dağılımın hızlı değiştiği yerlerden olacağından kenar çizgisi olarak algılanacaklardır. Bu durum TKU değerini dolayısıyla da oranı artıracaktır. Benzer şekilde üzerinde çatlak olmayan fıstık görüntülerinde ise sadece fıstığın dış kenarları kenar çizgisi olarak algılandığından düşük TKU değeri elde edilecektir. Burada dikkat edilmesi gereken bir husus; sadece TKU bilgisi çatlak/çatlamamış ayrımsallığını sağlamayabilir. Çünkü fıstıklar boyut olarak birbirinden farklıdır dolayısıyla küçük çatlaklı olan bir fıstığın TKU'su çatlak olmayan büyük bir fıstığınkine yakın olma ihtimali söz konusudur. Bunun için TKU'nun fıstık alanının kareköküne olan oranına bakmak daha yerinde olur. Böylece fıstık büyüklüğünden bağımsız bir şekilde çatlak tespiti yapmamız mümkün olabilir. Fıstık alanının karekökünü almamızın diğer bir nedeni

de pay ile paydayı aynı boyut uzayına taşıyarak daha sağlıklı değerler üretebilmemizdir. Söz konusu öznelik, Kenar Alan Oranı (KAO) olarak isimlendirilmiştir. Denklem 3. KAO formülünü göstermektedir.

$$KAO = \frac{TKU}{\sqrt{\text{fıstık alanı}}} \quad (3)$$

Bir fikir vermesi açısından, Şekil 29'daki üst satırda bulunan çatlak fıstığın KAO değeri 2521.81 iken, alt satırdaki çatlamaş fıstık için bu değer 1068.68 çıkmaktadır. Yaptığımız deneylerde bu farklılığın fıstık boyutundan bağımsız olduğu anlaşılmıştır.

Sınıflandırma ve Başarı Ölçütü

Fıstık imgelerinden çapların oranı (ÇO), fıstık alanı (FA) ve kenar alan oranı (KAO) öznelikleri çıkarılmıştır. Söz konusu geometrik özneliklerle elde edilmiş veri kümesi Naive Bayes, Yapay Sinir Ağları (YSA) ve Destek Vektör Makinaları (DVM) algoritmaları kullanılarak sınıflandırma yapılmıştır.

Başarı ölçütü olarak sınıflandırma doğruluk performansı (P) değeri doğru saptanan örüntü sayısının, toplam test örüntü sayısına oranı ile elde edilmiştir.

$$P = \frac{\text{Doğru saptanan örüntü sayısı}}{\text{Toplam örüntü sayısı}} \times 100$$

Uygulama ve Başarımlar

Bu çalışmada, Siirt fıstığını kalite standartlarına göre bilgisayarlı görü sistemi kullanılarak sınıflandırılması amaçlanmıştır. Hedef sınıflar ve ölçütleri Tablo 1'de listelenmiştir. Ölçütlerin belirlenmesinde TSE standartları referans olarak alınmıştır.

Tablo 1. Çalışmada hedeflenen nihai sınıflar

Sınıf	Açıklama	Ölçüt
1	Ekstra İri	Ağırlığı >1.41 gr
2	İri	Ağırlığı [1.13-1.40] gr
3	Orta	Ağırlığı [1.09-1.12] gr
4	Küçük	Ağırlığı < 1.09 gr
5	Kabuk	
6	Çatlamaş	

Her bir sınıfa ait 100 adet fıstık numunesinin görüntüleri alınarak öznelikler çıkarılmış ve Weka arff formatında veri kümesi elde edilmiştir. Toplamda 6 sınıf için 600 örüntüden meydana gelen bu veri setinin sınıf etiketleri danişmalı öğrenme için eklenmiştir. Sınıflandırma işlemleri Weka 3.6 veri madenciliği yazılım ara yüzü kullanılarak gerçekleştirilmiştir (Hall vd, 2009).

Sınıflandırma algoritmalarının serbest değişkenleri (free parameters) üzerinde bir eniyileme (optimization) gerçekleştirilmediği için veri seti öğrenme-doğrulama-test gruplarına bölünmemiştir. Bunun yerine doğrudan veri seti 10 parçaya bölünmüş 9 parçası eğitim geriye kalan bir parçası da test için kullanılmıştır. Literatürde buna 10 kat çapraz doğrulama da denmektedir. Her bir çapraz doğrulamada elde edilen performans değeri kaydedilerek 10 çapraz doğrulamayı müteakip tümünün ortalaması alınarak sistemin genel sınıflandırma başarımı belirlenmiştir. Weka'daki varsayılan parametreler değiştirilmeden 10 kat çaprazlama yapıldığından sınıflandırma algoritmasının veri kümesine meyilli (biased) olmasının önüne geçilmiştir. Tablo 2, Tablo 3 ve Tablo 4 üç sınıflandırıcının karmaşıklık matrisi ve sınıflandırma performansını göstermektedir.

Tablo 2. Naive Bayes sınıflandırıcısı karmaşıklık matrisi

Naive Bayes		Performans % = 82.51					
1	2	3	4	5	6	← classified as	
90	10	0	0	0	0	1 (ekstra iri)	
12	58	25	0	1	4	2 (iri)	
0	0	77	0	1	5	3 (orta)	
0	0	1	86	1	12	4 (küçük)	
1	0	3	4	87	5	5 (kabuk)	
0	1	0	1	1	97	6 (çatlamaş)	

Tablo 3. YSA sınıflandırıcısı karmaşıklık matrisi

YSA		Performans % = 83.33					
1	2	3	4	5	6	← classified as	
95	5	0	0	0	0	1 (ekstra iri)	
17	53	26	0	1	4	2 (iri)	
0	17	79	0	1	4	3 (orta)	
0	0	1	90	3	6	4 (küçük)	
1	0	3	4	88	4	5 (kabuk)	
0	1	0	4	1	95	6 (çatlamaş)	

Tablo 4. DVM sınıflandırıcısı karmaşıklık matrisi

DVM		Performans % = 81.83					← classified as
1	2	3	4	5	6		
93	7	0	0	0	0	1 (ekstra iri)	
15	57	21	0	0	7	2 (iri)	
0	21	72	0	0	7	3 (orta)	
0	0	1	95	0	4	4 (küçük)	
1	2	4	4	82	7	5 (kabuk)	
0	1	0	7	0	92	6 (çatlamamış)	

Sonuçlar ve Tartışma

Siirt fıstıklarının kalite standartlarına göre sınıflandırılmasını amaçlayan sistem için serbest düşme hareketi ile bırakılan fıstık örneklerinden görüntüler elde edilmiştir. Söz konusu imgelerden güçlü ve gürbüz öznitelikler (çapların oranı, fıstık alanı ve kenar alan oranı) çıkarılmaya çalışılmıştır. Fıstık örüntüleri alan uzmanı tarafından TSE standartları gözetilerek danışmalı öğrenmede kullanılmak için hedef sınıf gruplarına etiketlenmiştir. Hedef sınıflar sırasıyla; ekstra iri, iri, orta, küçük, kabuk ve çatlamamış gruplarıdır. Sınıflar arasında dengeli dağılımı sağlamak adına her bir sınıf için 100 fıstık örneği kullanılmıştır. Toplamda 600 adet örüntüden oluşan veri seti üzerinde 10 kat çapraz doğrulama testi yapılarak kullanılan makine öğrenmesi algoritmalarının sınıflandırma performansları belirlenmiştir. Çalışmada doğrusal ve basit sınıflandırıcı olarak Naive Bayes, doğrusal olmayan ve karmaşık sınıflandırıcı olarak ta YSA ve DVM algoritmaları kullanılmıştır.

Yapılan uygulamalarda Tablo 2, 3 ve 4'te görüldüğü gibi en iyi sınıflandırma performansı %83.33 lük başarımla YSA algoritmasında gözlemlenmiştir. YSA algoritmasını %82.51 ve %81.83 ile Naive Bayes ve DVM takip etmiştir. Sınıflandırma algoritmalarının karmaşıklık matrisleri incelendiğinde genellikle sınıflandırıcıların komşu sınıflarla daha çok hata yaptığı anlaşılmaktadır. Aslında 1, 2, 3 ve 4.kalite fıstıklarda bu tarz hatalar son kullanıcı düşünüldüğünde belirli bir ölçüde tolere edilebilirler. Çünkü örneğin 1.kalite fıstık satın alan bir son kullanıcı tükettiği fıstıkların içerisinde az miktarda 2. kalite fıstık görmesi

çok sorun çıkarmayabilir. Ancak 1.kalite fıstık grubunun içerisinde 4.kalite fıstık, kabuk veya çatlamamış fıstıklara en az miktarda rastlaması gerekir. Dolayısıyla 4, 5 ve 6. Sınıflar riskli grupları (2.tip hata yani yanlış-negatif) temsil etmektedirler. 2.tip hata bağlamında en iyi sınıflandırıcılığı seçmek için çatlamamış, kabuk ve küçük sınıflarının doğruluk performanslarını karmaşıklık matrislerinden elde etmemiz gerekir. Tablo 5, karmaşıklık matrisleri verilerinden elde edilen riskli grupların doğruluk performanslarını listelemektedir.

Tablo 5. Riskli sınıfların doğruluk performansları

Sınıf	Naive Bayes	YSA	DVM
4	86	90	95
5	87	88	82
6	97	95	92

Tablo 5 incelendiğinde Naive Bayes sınıflandırıcısının en az ölümcül hata (severe error) yaptığı ve ondan sonra da YSA'nın geldiği görülür. Naive Bayes sadece 3 adet çatlamamış sınıfta hata yapmasına rağmen bu miktar YSA ve DVM de sırasıyla 5 ve 8 olarak ölçülmüştür. Diğer taraftan yanlış kabuk sınıflandırma işleminde YSA Naive Bayes'ten daha az hata yapmıştır (YSA 12 hata, Naive Bayes 13 hata). 4.sınıfa gelindiğinde DVM 5 hatayla en iyi sınıflandırıcı çıkmıştır. 4.sınıf için YSA ve Naive Bayes 10 ve 14 hata yapmıştır. Burada dikkat edilmesi gereken önemli bir nokta en ölümcül hatanın kabuk ve çatlamamış sınıflarında olduğu gerçeğidir. Bu bağlamda en çok riskli sınıflandırma DVM tarafından yapıldığı için fıstık sınıflandırma sisteminde kullanılmak üzere Naive Bayes ve YSA sınıflandırıcıları önerilmektedir. Ortalama %83.33 sınıflandırma başarımla bu çalışmada sunulan geometrik özniteliklerin ayrımsallık güçlerini göstermektedir.

Bu çalışmada önerilen fıstık sınıflandırma sisteminin gerçek zamanlı performansı ayrıca test edilmiştir. Tablo 6, söz konusu testte araştırılan her bir işlem için geçen ortalama süreyi listelemektedir. Ortalama geçen süre 100 adet fıstık baz alınarak, Windows 8 işletim sistemi ve i5 işlemci ile 8GB belleği olan bir masaüstü bilgisayarda hesaplanmıştır.

Tablo 6. Fıstık sınıflandırma sürecindeki önemli işlemler ve milisaniye cinsinden zamansal maliyetleri

İşlem (üç görüntü için)	Zaman (ms)
Görüntü Alımı	15
Sabit diske kaydedilmesi	123
Gri dönüşümü	12
ROI matrisinin çıkarılması	6
Canny kenar bulma	130
Eksenlerin tespiti	17
Fıstık alanı hesaplanması	5
Sınıflandırma ve karar verme	5
Üfleme solenoid valflerin tetiklenmesi	1
TOPLAM SÜRE	314

Tablo 6 incelendiğinde bir fıstık için gerçek zamanlı hız performansı ortalama 314ms olarak ölçüldüğü görülecektir. Bu bilgiler ışığında önerilen fıstık sınıflandırma sisteminin ortalama yaklaşık hızı 3 fıstık/sn olarak kabul edilebilir. Tablo 6'dan da anlaşılacağı üzere en yüksek maliyet Canny kenar bulma algoritmasındadır. Canny ve diğer algoritmalar hız performansı açısından sürekli optimize edilmektedir. İleride yapılacak çalışmalarda fıstık nesnesini en iyi temsil edebilecek başka geometrik ve istatistiksel öznelikler ve düşük hızda çalışabilen kenar bulma algoritmaları araştırılacaktır.

Teşekkür

Bu çalışma, Tübitak-1005, 113E620 numaralı proje kapsamında desteklenmiştir.

Kaynaklar

- Cetin, A.E., Pearson, T.C., Tewfik, A.H., (2004). "Classification of closed-and open-shell pistachio nuts using voice- ecognition technology". *Transactions-American Society of Agricultural Engineers*, 47, 2, 659-664.
- Ghazanfari, A., Irudayaraj, J., Kusalik, A., Romaniuk, M., (1997). "Machine vision grading of pistachio nuts using Fourier descriptors", *Journal of agricultural engineering research*, 68, 3, 247-252.
- Ghazanfari, A., Wulfsch, D., Irudayaraj, J., (1998). "Machine vision grading of pistachio nuts using gray-level histogram", *Canadian Agriculture Engineering*, 40(1): 61-66.
- Hall, M., Frank E., Holmes G., Pfahringer B., Reutemann P., Witten I., (2009). "The WEKA data mining software: an update", *ACM SIGKDD explorations newsletter*, 11,1, 10-18.
- Omid, M., Mahmoudi, A., Omid, M. H., (2009). "An intelligent system for sorting pistachio nut varieties", *Expert Systems with Applications*, 36, 9, 11528-11535.
- Omid, M., (2011). "Design of an expert system for sorting pistachio nuts through decision tree and fuzzy logic classifier", *Expert Systems with Applications*, 38, 4, 4339-4347.
- Pearson, T., (1996). "Machine vision system for automated detection of stained pistachio nuts", *LWT-Food Science and Technology*, 29 3, 203-209.
- Pearson, T.C., (2001). "Detection of pistachio nuts with closed shells using impact acoustics", *Applied Engineering in Agriculture*, 17, 2, 249-253.
- Pearson, T., Toyofuku, N., (2000). "Automated sorting of pistachio nuts with closed shells", *Applied Engineering in Agriculture*, 16, 1, 91-94.
- T.C. Gıda Tarım Ve Hayvancılık Bakanlığı, "Siirt ili tarımsal yatırım rehberi", https://www.tarim.gov.tr/SGB/TARYAT/Belgeler/il_yatirim_rehber_leri/siirt.pdf, Son erişim tarihi: 28 Eylül 2015.

Extraction of robust features from Siirt pistachio images for pistachio sorting system

Extended abstract

Siirt pistachio is mostly consumed as fresh cookies in the market because it consists of more coarse-grained than other types of pistachio varieties and differs according to the aromas and taste. In order to gain customer satisfaction, Siirt pistachio having annual production capacity of 25 thousand tons should be subjected to the fully automatic sorting and grading processes based on the quality standards. Currently classification process is carried out via manual labor and mechanical tools. Man powered classification is a time consuming, boring and inefficient process. In addition to this, such a process carries several risks in terms of food hygiene. On the other hand, mechanical sorting systems (vibration based and pin pickers) cannot achieved desired classification accuracies anymore. Consequently a fully automated system based on machine vision is required.

In this study it is aimed to develop various image processing methods for extracting robust features from the acquired images of Siirt pistachio samples for using pistachio sorting and grading system. Thus diameter ratio, pistachio area and edge length over area features are extracted from the acquired images. Extracted proposed features are provided as input parameters for offline classification. Pistachios are grouped into colossal, big, medium, small, shell and uncracked classes by domain expert based on Turkish quality standards. Dataset is constructed from the totally 600 pistachios (each group has 100 samples). Naïve Bayes, Artificial Neural Network (ANN) and Support Vector Machine (SVM) are used as classifiers. Classifiers are evaluated based on generalization accuracies and Type II error (false negative or severe error) criterion. ANN having 83.33% accuracy outperforms others. ANN and Naïve Bayes are also selected as winner classifiers based on severe error (Type II error or false negative) constraint.

In addition to these, proposed pistachio sorting and grading systems is subjected to the real time performance testing with respect the computational cost criteria. Experiments revealed that considering three images, total processing speed of one pistachio sample is approximately 314ms which indicates that average processing speed of the proposed pistachio grading system is 3nuts per second. Another significant fact is related to the computational cost of the Canny edge detector algorithm. It holds about 230ms for three images and therefore Canny edge process is the most expensive part that should be addressed in the future. It should be noted that the processing performance of the proposed system is for the single channel. Therefore customers can purchase several channels in order to establish parallel processing mechanism according to their needs and factory processing potentials.

Consequently, ANN and Naïve Bayes classifiers along with proposed robust features are recommended to be using in pistachio sorting and grading system.

Keywords: Image processing; feature extraction; pistachio sorting system; classification.