

AKÜ FEMÜBİD 17 (2017) 035101 (914-921)
DOI: 10.5578/fmbd.64079

AKU J. Sci. Eng.17 (2017) 035101 (914-921)

Yumurtaların Çevrimiçi bir Destek Vektör Makinesi Kullanılarak Sınıflandırılması

Engin Taş¹, Barış Gökçe²

¹Afyon Kocatepe Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü, Afyonkarahisar.

²Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, Afyonkarahisar

eposta: engintas@aku.edu.tr

Geliş Tarihi: 07.06.2017 ; Kabul Tarihi: 21.11.2017

Özet

Yumurta, beslenmedeki en önemli protein kaynakları arasında yer alır ve bu nedenle yumurta üretim endüstrisi birçok ülkedeki en büyük endüstrilerden biridir. Yumurtaların otomatik olarak sınıflandırılması yumurta üretim sürecini geliştirmek ve hızlandırmak için önemlidir. Bu hijyenik üretim ortamı açısından da önemlidir. Bu çalışma, yumurtaların derecelerine göre sınıflandırılması için farklı bir yaklaşım önermektedir. Bir çevrimiçi destek vektör makinesi yumurta çiftleriyle çalışacak şekilde uyarlanmıştır. Bu eşli model, bir çiftin pozitif bir çift olup olmadığını belirleyebilir; burada, aynı sınıftaki iki yumurta tarafından oluşturulan çift pozitif bir çift ve farklı sınıflardan gelen iki yumurta tarafından oluşturulan çift ise negatif bir çifttir. Bu yaklaşımın ve klasik DVM'nin sınıflandırma performansları karşılaştırılmış ve sonuçlar eşli yaklaşımın klasik DVM'den anlamlı ölçüde daha iyi olduğunu göstermektedir.

Anahtar kelimeler

Çevrimiçi öğrenme; Eşli öğrenme; Destek vektör makineleri; Çekirdek yöntemleri; Çok sınıflı sınıflandırma

Eggs' Grade Classification using an Online Pairwise Support Vector Machine

Abstract

Egg is among the most important sources of protein in nutrition, thus egg production industry is one of the largest industries in many countries. Accurate automatic grading of eggs from poultry is critical for improving and speeding up the egg production process. This is also important in terms of hygienic production environment. This paper proposes a different approach for classification of eggs into grades. An online support vector machine is adapted to work with pairs of eggs. This pairwise model is able to identify whether a pair is a positive pair or not, where a positive pair formed by two eggs from the same grade and a negative pair formed by two eggs from different grades. Classification performances of this approach and classical SVM are compared and results indicate that the pairwise setting outperforms the classical SVM significantly.

Keywords

Online learning; Pairwise learning; Support vector machines; Kernel methods; Multi-class classification

© Afyon Kocatepe Üniversitesi

1. Giriş

Eski yumurta işleme tesislerinde, yumurta genellikle yumurta işleme ünitelerini gözlemleyen insanlar tarafından elle derecelendirilir. Bir üretim bandından akan yumurtalar insanlar tarafından elektro-mekanik kayıt tutucular kullanılarak etiketlenir ve daha sonra tasnif makineleri

tarafından ayrılır. Yumurta ayırma süreci kayıt tutucularda çalışan gözlemciler nedeniyle yavaşlar. Bunun yanında, bir çiftlikte tüm kümeslerden gelen yumurtalar, yumurta tasnif makineleri ile toplu bir şekilde sınıflandırılır.

Bu durum, kümeslerin performanslarının ölçümüne imkân vermemektedir. Bu nedenle, kümeslerin üretim performanslarının ölçülmesi için yumurtaların kalite bakımından boyutlarına göre önceden derecelendirilmesine ihtiyaç duyulmaktadır. Bu çalışmada, banttan akan yumurtalar, özelliklerine göre, yumurta sınıflandırma makinesinden önce gerçek zamanlı olarak, görüntü işleme teknikleri ve çevrimiçi bir destek vektör makinesi kullanılarak sınıflandırılacaktır. Bu şekilde, kümeslerin verimliliğini ve kalite oranlarını eşzamanlı olarak belirlemek de mümkündür.

Literatürdeki farklı çalışmalarda görüntü işleme teknikleri ve çeşitli sınıflandırma yöntemleri kullanılmıştır. Patel vd. (1998) gerçekleştirdikleri çalışmada gri (gray) renk uzayı yerine (RGB) kırmızı, yeşil ve mavi renk uzayının renk histogramını çıkararak (YSA) yapay sinir ağlarını eğitmek amacı ile veriler girilmiştir. Yaptıkları çalışmada 180 - 255 renk değer aralığına sahip yumurtaların farklı renk piksellerine sahip olmadığı ve bu sebeple sağlam yumurta olarak belirlendiği görülmüştür. Yine başka bir çalışmada kahverengi yumurtalardaki kirlerin ve lekelerin belirlenmesi için RGB renk uzayında imge çıkarma işlemi yapılmış ve daha sonra imgeyi (binary) ikili resim formatına dönüştürerek kirli bölgelerdeki görüntünün piksel değerleri farklı olduğundan belirlenen eşik değere göre yumurtanın kirli olup olmadığına karar verilmiştir. Bunun yanında kırık ve çatlak yumurtalar için farklı bir uygulama yapılmadığı görülmüştür (Mertens et al. 2005). Lin vd. (2009) gerçekleştirdikleri bir çalışmada dijital görüntü işleme yöntemlerinden farklı bir yaklaşım geliştirerek ses dalgalarının akustik rezonans frekans yöntemi ile bir sistem geliştirmişlerdir. Ses dalgalarının yumurta kabuğu üzerinde sadece kabuk çatlak ve kırıkların tespiti amacı ile kullanılabilirdiği görülmüş ancak kirli ve lekeli yumurtaların tespit edilmesinin mümkün olmadığı görülmüştür.

Dehrouyeh vd. (2010) gerçekleştirdikleri bir çalışmada yumurtalarda oluşan kan lekelerinin belirlenmesi için halojen lamba kullanmıştır. Halojen lambanın yaymış olduğu sarı ışığın kanda oluşturduğu renk farklılığının HSV renk uzayındaki değeri kullanılarak bir sınıflandırma yapılmıştır. Elde edilen görüntü önce gri renk uzayına dönüştürülmüş ve Canny kenar çıkarma algoritması kullanılarak imge arka plandan çıkarılmış ve ikili (binary) görüntüye dönüştürülerek kabuk üzerindeki kir ve lekelerin tespiti yapılmıştır. Mansoor vd. (2011) gerçekleştirdikleri bir çalışmada Susan kenar

yakalama yöntemi ve yerel bulanık eşik belirleme metodu kullanarak yumurta kabuğunda oluşan kırık ve çatlakları tespit eden bir algoritma geliştirmişlerdir.

Lunadei vd. (2011) gerçekleştirdikleri bir çalışmada tek renkli (monochrome) kamera ile yumurta görüntülerini almışları ve daha sonra bu görüntüler referans görüntüler ile karşılaştırarak arka plan çıkarma işlemi yapmışlardır. Arka plan çıkarmadan elde edilen görüntüler üzerinde kir ve lekeleri belirlemek için bir algoritma geliştirilmiştir. Lekeler tespit edildikten sonra lekelerin boyutsal ve geometrik şekilsel sınıflandırılması yapılmış ve lekelerin türlerinin tespiti yapılmıştır.

Ibrahim vd. (2012) gerçekleştirdikleri bir çalışmada yumurtaları belirlenen büyüklük durumlarına göre sınıflandırma yapmışlardır. Sınıflandırma sonrasında yumurta üzerinde leke ve kirlerin tespiti içinde bir çalışma yapılmıştır. Yumurtaların büyüklük durumlarına göre sınıflandırması için yumurta görüntüsü içerisindeki piksellerin alan yoğunluğu (piksel sayısı) kullanılmıştır. Yumurtadan elde edilen görüntüler gri seviyeye dönüştürüp belirli eşik değerler kullanılarak ikili (binary) görüntüye dönüştürülmüştür. Bu ikili görüntü üzerinde kir ve leke tespit çalışmaları yapılmıştır.

Arivazhagan vd. (2013) gerçekleştirdikleri bir çalışmada çatlak ve kırık yumurtaları tespit etmek amacı ile elde edilen görüntü görüntüyü RGB renk uzayından YIQ renk uzayına dönüştürülmüştür. Bu dönüşüm sonrasında Bottomhat dönüşümü uygulanmış ve yumurta üzerindeki çatlak ve kırıkların tespiti yapılmış. Yumurtalardaki kir ve lekelerin tespiti için ise elde edilen görüntü HSV renk uzayına dönüştürülmüş ve bileşenlerine ayrılmıştır. H katmanındaki renk değerini kullanarak kir ve lekelerin tespiti yapılmıştır. Daha yumurta içinde oluşan kan lekelerinin tespiti için ise halojen lamba kullanılmış ve Candling metodu kullanılmıştır. Elde edilen ikili (binary) görüntü işleme tekniği ile leke tespiti yapılmıştır. Yapılan çalışmada üç farklı leke veya kusur için farklı yöntemler uygulanmış ancak çalışma sınıflandırma konusunda başarılı olmuştur.

Destek Vektör Makinesi'nin (DVM) temel fikri, doğrusal olarak ayrılabilen veriler üzerinden optimal bir ayırma hiperdüzlemi oluşturmaktır. Aynı zamanda çekirdekleri ve yumuşak marj formülasyonlarını kullanarak doğrusal olarak ayrılmayan verilerde geniş marjlı bir hiperdüzlemi de öğrenebilir. Bununla birlikte, DVM başlangıçta ikili sınıflandırma için tasarlanmıştır ve DVM'yi çok

sınıflı senaryoya genişletmek için iki ana yaklaşım vardır. Bir yaklaşım ikili algoritmayı çok sınıfa genelleştirmektir, başka bir yaklaşım ise çok sınıflı sınıflandırma problemini bir dizi ikili problem haline dönüştürmektir. En eski ve en yaygın kullanılan uygulamalardan biri, her biri her sınıfı diğerlerinden ayıran M ikili DVM sınıflandırıcılarını oluşturan, tümüne karşı tek yaklaşımıdır. i.DVM, i sınıfının tüm örneklerini pozitif etiketlerle ve diğer tüm örnekleri negatif etiketlerle ele alarak eğitilir. Eşli sınıflandırma ise, iki sınıflı problemlerin her birinden elde edilen eşli karşılaştırmalar göz önüne alınarak, çok sınıflı problemleri çözmek için alternatif bir tekniktir. Test kümesinden bir örnek sınıflandırılırken, en çok eşli karşılaştırmayı kazanan sınıfa atanır. Bu çalışmada, çiftleri sınıflandırmada kullanılmak üzere her bir sınıf için eşli bir DVM modeli oluşturduk. Burada aynı sınıftan gelen iki yumurta pozitif bir çifti, farklı sınıftan gelen iki yumurta negatif bir çifti oluşturur. Bu eşli DVM modeli, herhangi bir çiftin pozitif bir çift olup olmadığını belirleyebilir. Diğer taraftan, eşli bir düzenlemede n örnek n^2 eşli örneğe karşılık gelir ve büyük ölçekli bir veri kümesi ile birlikte bir destek vektör makinesinin eğitilmesi çoğu durumda ciddi hesaplama maliyetleri getirir. Veriler toplu olarak işlendiğinde, DVM'ler her adımda amaç fonksiyonun hesaplanmasını gerektirir, ve bu temel olarak önceden tanımlanmış bir kayıp fonksiyonunun eğitilecek bir veri seti üzerinden hesaplanmasını gerektirir. Gradyana dayalı yöntemler, amaç fonksiyonunun her bir değerlendirmesinde sırasıyla gradyanı hesaplarken, Newton yöntemi ve eşlenik gradyan algoritması gibi standart sayısal optimizasyon teknikleri, amaç fonksiyonunun ikinci dereceden bilgisine ihtiyaç duyar. Mevcut veri setleri gittikçe büyüdükçe, bu tür klasik ikinci dereceden yöntemler neredeyse tüm durumlarda uygulaması pratik değildir.

Buna karşın, algılayıcı (perceptron) ve varyantları gibi çevrimiçi gradyan tabanlı yöntemler, büyük ve tekrarlı veri kümelerinde büyük bir avantaja sahiptir. Aslında, basit çevrimiçi gradyan düşümü yöntemleri genelde sofistike ikinci derece toplu algoritmalarından daha iyi performans sergiler, çünkü çevrimiçi yöntemlerin hesaplama gereksinimleri, eğitim verilerini tek tek örnekler veya küçük alt örnekler şeklinde işledikleri için oldukça düşüktür. Dolayısıyla bu çalışma, problemi farklı tanımlayarak ve buna uygun bir yöntemin seçimi ile ilgili iki temel fikre dayanır. İlk olarak, herhangi bir ikili veya çok sınıflı sınıflandırma probleminin eşli sınıflandırma problemine dönüştürülebileceğini biliyoruz. Bu, daha zengin bir veri kümesinden öğrenmenin

avantajını getirir ve eşli model, örneklerden öğrendiğimizden daha fazla öğrenebilir. Geleneksel öğrenme algoritmaları bu kapsamda daha verimsiz hale geldiğinden ve bazı durumlarda uygulanamadığı için (ör. Toplu yöntemler), çevrimiçi DVM algoritmasını örnek çiftlerle çalışacak şekilde değiştirilmesini öneriyoruz. Bu yaklaşım, çiftleri tek tek işleme avantajını getirir ve daha büyük boyutlara sahip büyük ölçekli verilerden kaynaklanan zorlukların üstesinden gelir.

2. Materyal ve Metot

$\mathcal{X} = (x_1, x_2, \dots, x_m), \forall x_i \in \mathbb{R}^n$ şeklinde bir örnek kümemiz olsun. İki örneğin herhangi bir kombinasyonu $p = (x_i, x_j) \in \mathcal{P} \subseteq \mathcal{X}^2$ çifti olarak düşünülebilir. Bu çiftlerden oluşan $T = \{(p, y_p) : p \in \mathcal{P}\}$ dizisini $\mathbb{Z} = \mathcal{P} \times \{+1, -1\}$ olasılık dağılımına sahip bir kitleden çekilmiş bir eğitim örneklemini olduğunu düşünelim. T 'den gelen bir örnek, n -boyutlu bir sütun vektörü çifti ve bu iki örneğin aynı sınıftan gelip gelmediğini belirleyen bir $y_p(+1, -1)$ etiketinden oluşan bir üçlüdür. Amaç eğitim örnekleminde uygun bir $f: \mathcal{P} \rightarrow \{+1, -1\}$ fonksiyonunu öğrenmektir. Karar fonksiyonunun, $f(p) = \langle w, \Phi(p) \rangle$ şeklinde temsil edildiği doğrusal durumu ele alalım, burada $w \in \mathbb{R}^n$ eğitim örneklemini T 'ye dayanarak tahmin edilmesi gereken parametre vektörüdür ve Φ ise çiftleri daha büyük bir uzaya gönderen bir özellik fonksiyonudur.

Optimal bir karar fonksiyonu (en büyük marja sahip optimal hiperdüzlem) özellik uzayında aşağıdaki amaç fonksiyonunu minimize ederek bulunur:

$$\min_w \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (1)$$

$$\text{with } \begin{cases} \forall i y_i \hat{y}(p_i) \geq 1 - \xi_i \\ \forall i \xi_i \geq 0 \end{cases}$$

$\xi = \xi_1, \xi_2, \dots, \xi_n$ gevşek değişkenleri bazı çiftlerin marjının yanlış tarafında yer almasına izin verir. Düzeltme parametresi C 'nin büyük değerleri için, ayrılamayan çiftlere büyük bir ceza verilir ve daha fazla sayıda destek çifti oluşur. C 'nin küçük değerleri bu cezanın etkisini yumuşatır ve gürültülü problemlerde daha iyi sonuçlar elde etmemizi sağlar ama yetersiz uyuma sahip bir destek çifti modeli oluşturabilir.

Bu konveks optimizasyon probleminin eşini (dual) maksimize etmek esas problemden daha basit bir konveks kuadratik programlama problemidir. DVM çekirdek genişlemesinin α_i katsayıları aşağıdaki eş amaç fonksiyonunu

$$W(\alpha) = \sum_i \alpha_i y_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j K(p_i, p_j) \quad (2)$$

tanımlayarak ve

$$\max_{\alpha} W(\alpha) \text{ with } \begin{cases} \sum_i \alpha_i = 0 \\ A_i \leq \alpha_i \leq B_i \\ A_i = \min(0, C y_i) \\ B_i = \max(0, C y_i). \end{cases} \quad (3)$$

DVM kuadratik programlama problemini çözerek bulunabilir.

Orta büyüklükteki veri kümelerinde bile eşli öğrenme gerçekleştirdiğimizde çok büyük sayıda örnek çiftlerini işlememiz gerekir, bu nedenle etkin ve hızlı bir DVM sınıflandırıcısına ihtiyaç duyarız. Bu zorlukların üstesinden gelebilmek için çevrimiçi ve aktif öğrenme özellikleriyle çekirdeklerle çalışan hızlı bir sınıflandırıcı olan LASVM algoritması kullanılmıştır (Bottou and LeCun 2004). Çevrimiçi yapısından dolayı eşli öğrenme kapsamında bu algoritma çeşitli avantajlara sahiptir. LASVM örnekleri tek tek işleyerek ve en çok bilgilendirici olan destek vektörlerini açılımında tutarak hesaplama karmaşıklığı ve maliyetiyle başa çıkabilir. Bu gerekli olan hesaplama miktarını ciddi anlamda düşürür. LASVM algoritmasının başka bir avantajı da seyrek veri kümelerinde kullanılmasına uygun olmasıdır zira veri boyutunun büyük olduğu çoğu veri kümesinde örnekler önemli derecede seyrek bir yapıya sahiptir yani örnek vektörünün bazı elemanları değer almaz. LASVM bu problemi bu örnekler için uygun hızlı seyrek vektör çarpımları kullanarak bir avantaja dönüştürür. Bu sayede örneklerin ikili kombinasyonlarından oluşan çiftler tek tek işlenerek daha zengin bir veri kümesinden öğrenmenin avantajları değerlendirilmiş olur. LASVM ayrıca herhangi bir zamanda çekirdek açılımında toplanan vektörlerin çevrimiçi süreçte açılımdan çıkarıldığı bir destek vektörü çıkarma

adımına da sahiptir. Bu da o anda çekirdek açılımındaki etkinliğini yitirmiş olan destek vektörlerinin temizlenmesi anlamına gelir. Bu sayede çekirdek açılımı en etkin ve kompakt şekilde süreç boyunca korunmuş olur. LASVM algoritması aynı zamanda sıralı minimal optimizasyon (SMO) algoritmasıyla ilişkilidir ve SVM kuadratik programlama probleminin çözümüne yakınsar (Platt 1999).

Diğer yandan, LASVM eşli öğrenme için uygun değildir. Çünkü, bu haliyle, çekirdek belleği eşler için hesaplanan çekirdek değerlerini tutar ve bu da hem bellek kapasitesi hem de hesaplama yükü olarak oldukça ciddi maliyetler oluşturur. Bu durum, algoritmayı büyük veri kümeleri için elverişsiz hale getirir. Ayrıca eşler için çekirdek değerlerini saklamak anlamsızdır, zira örnekler için çekirdek değerleri bir kez hesaplandığında herhangi bir çift için çekirdek değerleri hesaplamak daha sonra göreceğimiz üzere 3 basit aritmetik işlemden oluşur. Bu nedenle, bu çalışmada LASVM algoritmasını eşli öğrenme durumunda çalıştırabilmek için algoritmanın yapısında ciddi değişiklikler yapılmıştır. Oluşan algoritma Eşli-DVM olarak adlandırılmıştır. Bu çalışmanın birinci ana katkısı, aşağıda maddeler halinde özetlenen, Eşli-DVM algoritmasını oluşturabilmek için LASVM algoritmasında gerçekleştirilen temel değişikliklerdir.

- Destek çiftlerinin indislerini ve karşılık gelen örneklerin indislerini tutmak için sırasıyla P ve S kümeleri tanımlanmıştır. Eşli-DVM çekirdek açılımına bir çift eklediğinde (işleme), çiftin indisi P kümesine eklenir ve aynı zamanda bu çifti oluşturan iki örneğin indisleri de S kümesine eklenir. P kümesi sadece çiftlerin indislerini tutmak için kullanılır, herhangi bir çekirdek önbelleği kullanılmaz. Çekirdek değerleri sadece ilgili çifti oluşturan örnekler için hesaplanır ve çekirdek önbelleğinde tutulur. Dolayısıyla, S kümesiyle beraber örneklerin çekirdek değerlerini tutan bir çekirdek önbelleği kullanılır.
- LASVM algoritmasında bir örneği işlemek için gerekli olan tüm yordamlar, bir çifti işleyecek şekilde yeniden düzenlenmiştir. Bu bir çift için ilgili gradyanın hesaplanması,

maksimum gradyana sahip τ -bozan dördlünün (iki çift tarafında oluşturulan) belirlenmesi ve uygun adım yönlerinin belirlenmesini içerir.

- Yeniden işleme bazı çiftleri P 'den çıkartır. Buna karşılık S kümesinden bu çiftle ilgili olarak iki örnek çıkartılır. Sonuç olarak sapma terimi b ve P kümesindeki en çok τ -bozan dördlünün gradyanı δ değerlerinin tümü hesaplanır.

LASVM öncelikle çekirdek açılımına en az bir çift ekleyerek sürece başlar ve daha sonra o anki çekirdek açılımındaki var olan gereksiz destek çiftlerini arar. Çevrimiçi durumda bu, t anında yeni bir çifti işlemek için kullanılabilir. Çekirdek açılımında herhangi bir t anında $\alpha_i \neq 0$ katsayısına sahip çiftler destek çiftleri olarak tanımlanır. Destek çiftlerine karşılık gelen çiftlerin indisleri P kümesinde tutulurken, bu çiftlere karşılık gelen örneklerin indisleri S kümesinde tutulur. Eğer $i \notin S$ ise karşılık gelen α_i 'lerin değer almadığı varsayılır.

Eşlerden öğrenme durumunda, Eşli-DVM'in yapısı daha fazla önem arzeder, çünkü (işleme) ve (yeniden işleme) adımları daha fazla bilgiye sahip eşleri elinde tutarken, gerek duyulmayan önemini yitmiş çiftleri de çekirdek açılımında çıkartarak bunlardan kurtulur. Bu çiftlerin sayısının kuadratik olarak büyüdüğü eşli öğrenme durumunda en kullanışlı durumdur. Diğer taraftan, çiftlerden bir model öğrenmek için, ortak bir özellik alanında bir çifti temsil edecek ek bir yapı türüne ihtiyaç duyarız. Basilio ve Hofmann (2004), kullanıcı derecelendirmelerini ve öğe özelliklerini ortak bir öğrenme mimarisinde birleştirmiş, farklı örnek çiftleri için uygun çekirdeklerin tasarımında iyi örnekler vermiştir ve çekirdeklerin tek bir çekirdeğe birleştirilmesinin birkaç yolunu göstermiştir. Birbirinden farklı özellik haritalarını basitçe birleştirmek için tensör çarpımlarını kullanmışlardır. Oyama ve Manning (2004) eşli sınıflandırıcıları öğrenmede örnek çiftleri arasındaki özelliklerin kombinasyonlarını kullanmak için bir çekirdek önermiştir. Bu kapsamda, Ben-Hur ve Noble (2005) tek proteinler arasındaki bir çekirdeği protein çiftleri arasındaki bir çekirdeğe çeviren tensör çarpım eşli çekirdeğini (TÇEÇ) önermiştir. Vert vd. (2007) biyolojik ağların yeniden inşası için metrik öğrenme

eşli çekirdeğini (MÖEÇ) geliştirmiştir. Kashima vd. (2009) çevrimiçi öğrenme sürecini hızlandırmak için Kartezyen çekirdeğini kullanarak bu genel çerçevenin özel bir durumunu önermiştir. Kartezyen çekirdek TÇEÇ ve MÖEÇ' den daha seyrek bir yapıya sahiptir. Ayrıca çekirdek matrislerinin özdeğer analizine dayanarak iki farklı eşli çekirdek için genelleştirme sınırları verilmiştir.

Bu çalışmada, eşleri temsil etmek için TÇEÇ kullanılmıştır. $p_1 = (x_1, x_2)$ ve $p_2 = (x_3, x_4)$ şeklinde 2 çift için TÇEÇ

$$\begin{aligned} K_{T\text{PPK}}((x_1, x_2), (x_3, x_4)) \\ = K(x_1, x_3)K(x_2, x_4) \\ + K(x_1, x_4)K(x_2, x_3). \end{aligned} \quad (4)$$

şeklinde verilir. Bunun yanında örnekler arası RBF çekirdeği gibi bir çekirdek kullanarak, TÇEÇ çekirdeği çiftler arasındaki herhangi bir ilişkiyi öğrenen, evrensel olarak yaklaşan bir fonksiyonlar sınıfı \mathcal{H} üretir. Tüm denemelerimizde MÖEÇ' nin de performansını değerlendirmemize rağmen TÇEÇ' den anlamlı bir farklılık görülmemiştir. Bu nedenle, esas amaçtan uzaklaşmamak için uygulamada sadece TÇEÇ kullanılmıştır.

3. Bulgular ve Tartışma

Çok büyük (XL), Büyük (L), Orta (M) ve Küçük (S) olmak üzere 4 ağırlık sınıfından toplanmış 200 yumurtadan oluşan bir veri kümesi kullanılmıştır. Bu sınıflar, Türk Gıda Kodeksi (TGK) tarafından belirlenmiş yumurta ağırlığı aralıkları kullanılarak oluşturulmuştur (Çizelge 1).

Çizelge 1. TGK'ya göre yumurtaların ağırlık sınıfları

Ağırlık sınıfı	Ağırlık aralığı (gr.) (a)
XL	$a \geq 73$
L	$63 \geq a < 73$
M	$53 \geq a < 63$
S	$a < 53$

Bu çalışmada, sınıflandırma sadece yumurtaların çeşitli oryantasyonlardaki dikey ve yatay görüntüleri kullanılarak gerçekleştirilmeye çalışılmıştır. Bu görüntüler yumurta işleme ünitelerine uygun basit bir kurulumun üzerine yerleştirilmiş bir Microsoft Kinect kamera ile elde edilmiştir (Şekil 1).



Şekil 1. Microsoft Kinect sensor ile görüntü alma sistemi.

Görüntü toplama sürecinin ardından elde edilmiş olan görüntüler önce belirli bir eşik değerine göre ikili bir görüntüye dönüştürülmüş, daha sonra yumurtaların öbek görüntüsü (blob) elde edilerek bu öbeklere ait ana istatistiksel özellikleri görüntü işleme teknikleri kullanılarak çıkartılmıştır. Sonuç olarak, bir yumurta öbek görüntüsünden alan, derinlik, majör eksen büyüklüğü, minör eksen büyüklüğü, dış merkezlilik, oryantasyon, eşit-çap, katılık, kapsam ve çevre ölçümü olarak toplamda 10 özellik elde edilmiştir.

Burada amaç daha önce görülmemiş bir yumurtanın hangi sınıfa ait olduğunu yine kamera görüntüsüne dayanarak belirlemektir. Tüm süreci eğitim ve test olmak üzere düşünebiliriz. Eğitim aşamasında ilk adım veriyi işleyerek eşli öğrenmeye uygun hale getirmektir. Bu nedenle, veri eğitim (%60), geçerlilik(%20) ve test (%20) şeklinde 3 kümeye bölünmüştür. Belirli bir hedeflenmiş sınıf için eşli bir eğitim kümesi oluşturmak için, eğitim kümesinden rassal olarak 2 örnek seçilir. Bunlardan bir tanesi hedef sınıftan seçilir diğeri ise eğitim kümesinde bulunan herhangi bir sınıftan herhangi bir örnek olabilir. Eğer bu 2 örnek aynı sınıftan (hedef sınıf) geliyorsa pozitif bir eğitim çiftine, aksi halde negatif bir eğitim çiftine sahip oluruz. Bu arada, dengeli bir eşli eğitim kümesi oluşturmak için bu süreç boyunca pozitif ve negatif çiftlerin sayısını kontrol ederiz. Bu

durum bu süreç boyunca dikkat edilmesi gereken önemli bir noktadır, çünkü pozitif ve negatif çiftlerin dengeli dağılmadığı bir eğitim kümesi oluşursa eşli modelin tahminleri baskın sınıf yönünde bir sapma gösterir. Başka bir ifadeyle, belirli bir hedef sınıf için pozitif ve negatif çiftler oluşturma sürecinde adil davranmaya çalışırız.

Diğer taraftan, eşli geçerlilik veri kümesi bu şekilde oluşturulmaz. Eşli geçerlilik verisi için, geçerlilik veri kümesinde bulunan her bir örnek için eğitim veri kümesinden rassal bir örnek seçilir. Benzer şekilde bu iki örnek aynı sınıftan geliyorsa pozitif bir çifte, aksi halde negatif bir çifte sahip oluruz. Önceki süreçten farklı olarak bu sefer pozitif veya negatif çiftlerin sayısını takip etmeyiz. Böylece, eşli geçerlilik kümesini oluştururken belirli bir önsel bilgiyi kullanmış oluruz. Yani, veri kümesindeki baskın sınıfların örneklerine daha yüksek seçilme şansı vermiş oluruz.

Sonuçta, yumurta sınıflandırma problemdeki her bir sınıf için toplamda 4 farklı eşli eğitim ve geçerlilik kümeleri elde edilir. Eşli-DVM algoritması kullanılarak her bir sınıf için eşli DVM modelleri bu eşli eğitim veri kümeleri üzerinde eğitilir. Modellerin hiper-parametreleri eşli geçerlilik veri kümeleri üzerindeki eşli sınıflandırma performansları değerlendirilerek ayarlanır. Optimal hiper-parametreler bir kez belirlendiğinde her bir sınıf için optimal bir ikili sınıflandırıcı elde edilmiş olur ve test aşamasına geçilir.

Test aşamasında, daha önce hiç görmediğimiz bir test örneği düşünelim, yine bu test örneği önceden belirlenmiş sayıda eğitim örneği ile rassal olarak eşleştirilir. Bu şekilde devam ederek eşli bir test kümesi oluşturulur. Daha sonra bu eşli test kümesinde bulunan eşler bir önceki aşamada belirlenmiş olan optimal eşli DVM modellerine girer ve her bir test örneği için tüm eşli tahminler toplanır. Bu tahminlere sahip olduğumuzda ilgili test örneği için belirli sayıda eğitim örneğinin oylarını almış oluruz. Bu bize test örneğinin karşılık gelen eğitim örneğiyle aynı sınıftan olup olmadığına dair olasılıksal bilgiyi sağlar. Diğer bir ifadeyle, herhangi bir test örneğiyle eşleştirilmiş eğitim örneklerinin tümü test örneğinin kendi sınıfından gelip gelmediğine dair bir oy verir. Bu sürecin sonunda, ilgili test örneğini kazana sınıfa atamak için çoğunluk oyunu kullanırız, yani test örneğini en fazla pozitif oy aldığı sınıfa atarız. Örnekler arası çekirdek olarak ilk önce doğrusal ve Gausyan RBF çekirdekler kullanılmıştır ve RBF çekirdekleri bu problemde çok daha iyi performans gösterdiği görülmüştür. Bu nedenle eşli çekirdeklerin içinde RBF çekirdekler kullanılmıştır.

Eşli-DVM algoritmasında çekirdek önbelleği 256MB olarak ayarlanmıştır. Tüm deneylerde Eşli-DVM yumuşak marjlı bir kayıp fonksiyonuyla ve gradyanlar üzerinde küçük bir tolerans $\epsilon = 0.001$ ile çalıştırılmıştır. Cezalandırma parametresi C için $[1e - 5, 1e + 5]$ aralığında ve RBF çekirdeğinin σ parametresi için de $[1e - 6, 1]$ aralığında grid-araması gerçekleştirilmiştir. Her bir eşli-DVM modeli için grid-araması sonucu elde edilen hiper-parametre değerleri Çizelge 2'de verilmiştir. Bu hiper-parametre değerleri tüm tekrarlı denemelerde kullanılmıştır. Klasik DVM modeli için, R programındaki *kernelab* paketindeki *ksvm* yordamı kullanılmıştır. DVM için hiper-parametreler bu pakette otomatik olarak belirlenir. Her bir tekrar için, *ksvm* eğitim ve geçerlilik kümelerine göre farklı hiper-parametreler seçebilir. (daha fazla ayrıntı için okuyucular R dokümanlarına başvurabilir).

Çizelge 2. Grid-araması sonucu her bir sınıf için elde edilen en iyi hiper-parametre değerleri

Sınıf	Cezalandırma parametresi (C)	RBF çekirdek parametresi (σ)
S	1000	1e-5
M	1000	1e-5
L	1000	5e-6
XL	1000	1e-6

Orijinal veri kümesi daha önce normalleştirilmediği için, örnekler arasındaki çekirdek değerleri eşli çekirdeğin hesaplanması sırasında çevrimiçi olarak normalleştirilir. Her bir sınıf için 1000 adet eğitim çifti ve bir test örneğinin çoğunluk oyu ile sınıflandırılması için de 10 adet oy veren oluşturulmuştur.

İlk olarak, her bir sınıf için eşli modellerin doğru sınıflandırma oranlarının ortalamaları ve standart sapmaları Çizelge 3'de verilmiştir. Bu eşli modeller çiftleri pozitif veya negatif olarak sınıflandırmada üstün bir performans gerçekleştirmiştir. Bu sonuçlar gösterir ki yumurta görüntülerinin eşler halinde işlenmesi yumurtaların sınıflandırılması için çok uygun bir model oluşturur.

Çizelge 3. 10 tekrar sonucu her sınıf için eşli modellerin sınıflandırma doğruluk oranı ortalamaları

Sınıf	Eşli sınıflandırma doğruluğu ortalaması (std.dev.)
S	100 (0.00)
M	98.58 (2.00)
L	99.18 (0.84)
XL	98.55 (1.91)

İkincil olarak, en son sınıflandırma doğruluk oranlarına göre eşli durum ile klasik durumun sınıflandırma performansları karşılaştırılmıştır. Sonuçlar Çizelge 4'de özetlenmiştir, her bir sınıflandırma 10 kez tekrar edilerek sınıflandırma doğruluk oranları ve standart sapmaları hesaplanmıştır. Eşli-DVM algoritmasının önerilen sınıflandırma şemasıyla birlikte klasik sınıflandırma algoritmasında istatistiksel olarak anlamlı derecede daha iyi sonuçlar verdiği görülmüştür. Bir kez daha vurgulamak gerekirse, bu sınıflandırma gücünü önerilen çok sınıflı sınıflandırma yaklaşımından ve eşli sınıflandırma için geliştirilen iyi bir şekilde ayarlanmış çevrimiçi DVM' den almaktadır.

Çizelge 4. Eşli-DVM ve klasik DVM'nin 10 tekrar sonucu elde edilen en son sınıflandırma doğruluk oranı ortalamaları

Algoritma	En son sınıflandırma doğruluk oranı ortalaması (std.sap.)
Klasik DVM	85.88 (3.34)
Eşli-DVM	96.57 (0.02)

*Koyu değerler klasik DVM sonuçlarından istatistiksel olarak anlamlı farklılığı göstermektedir (anlamlılık düzeyi: 0.01).

4. Sonuç

Yumurta üretim endüstrisinde yumurtaların sınıflandırılması ve çatlak ve(ya) kirli olarak belirlenmesi üzerine birçok çalışma bulunmaktadır. Bu çalışmalar genel olarak altta yatan sınıflandırma veya tespit etme metodunda ziyade görüntü işleme tekniklerine dayanır. Ama, iyi bir şekilde tasarlanmış ve ayarlanmış bir sınıflandırma algoritması belirli bir görev için daha iyi performans gösterebilir. Bu nedenle, bu çalışmada bu alandaki önceki çalışmalardan farklı olarak çok-sınıflı bir sınıflandırma problemini ikili eşli sınıflandırma problemlerine çeviren bir genel sınıflandırma çerçevesi önerilmiştir. Çok-sınıflı sınıflandırma problemindeki her bir sınıf için eşli bir model oluşturulmuştur. Bir çift verildiğinde, bu eşli model bu çifti oluşturan öğelerin aynı sınıftan gelip gelmediğini belirleme yeteneğine sahiptir. Dolayısıyla, eşli modellerden elde edilen eşli tahminler birleştirilerek, çok-sınıflı sınıflandırma problemi etkin bir şekilde çözülmüş olur. Önerilen sınıflandırma sürecinde girdi olarak sadece yumurtaların dikey ve yatay görüntülerinin basit görüntü işleme teknikleriyle işlenerek elde edildiği

ana özellikler kullanılmıştır. Yumurta görüntü örneği çiftiyle çalışacak şekilde bir çevrimiçi destek vektör makinesi geliştirilmiştir (Eşli-DVM). Önerilen ve standart yaklaşımın performansları yumurtaların sınıflandırması probleminde karşılaştırılmıştır. En son sınıflandırma doğruluk oran oranlarına göre, önerilen yaklaşım klasik yaklaşımdan daha üstün bir performans göstermiştir. Son olarak, bu yaklaşım aynı zamanda daha büyük boyutsallığa ve daha geniş çaplı veri kümesine sahip herhangi bir çok-sınıflı sınıflandırma problemlerine uyarlanabilir.

Kaynaklar

Arivazhagan, S., Shebiah, R.N., Sudharsan, H., Kannan, R.R., Ramesh, R., 2013. External and internal defect detection of egg using machine vision. *Journal of Emerging Trends in Computing and Information Sciences*, 4(3), 257-262.

Basilico, J., Hofmann, T., 2004. Unifying collaborative and content-based filtering. In: Proceedings of the twenty-first international conference on Machine learning, ICML '04, pp. 9-. ACM, New York, NY, USA.

Ben-Hur, A., Noble, W., 2005. Kernel methods for predicting protein-protein interactions. *Bioinformatics* 21(suppl 1), i38-i46.

Bottou, L., LeCun, Y., 2004. Large scale online learning. In: S. Thrun, L. Saul, B. Schölkopf (eds.) *Advances in Neural Information Processing Systems*, 16. MIT Press, Cambridge, MA.

Dehrouyeh, M., Omid, M., Ahmadi, H., Mohtasebi, S., Jamzad, M., 2010. Grading and quality inspection of defected eggs using machine vision. *International Journal of Advanced Science and Technology*, 17, 23-31.

Ibrahim, R., Zin, Z.M., Nadzri, N., Shamsudin, M., Zaunudin, M., 2012. Egg's grade classification and dirt inspection using image processing techniques. In: Proceedings of the World Congress on Engineering, 2.

Kashima, H., Oyama, S., Yamanishi, Y., Tsuda, K., 2009. On Pairwise Kernels: An Efficient Alternative and Generalization Analysis. In: Proceedings of the 13th Pacific-Asia Conference on Advances in Knowledge Discovery and Data Mining, PAKDD '09, pp. 1030-1037. Springer-Verlag, Berlin, Heidelberg.

Lin, H., Zhao, J.W., Chen, Q.S., Cai, J.R., Zhou, P., 2009. Eggshell crack detection based on acoustic impulse response and supervised pattern recognition. *Czech Journal Food Science*, 27(6), 393-402.

Lunadei, L., Ruiz-Garcia, L., Bodria, L., Guidetti, R., 2012. Automatic identification of defects on eggshell through a multispectral vision system. *Food and Bioprocess Technology*, 5(8), 3042-3050.

Mansoor, M.S., Ashtiyani, M., Sarabadani, H., 2011. Automatic crack detection in eggshell based on susan edge detector using fuzzy thresholding. *Modern Applied Science*, 5(6), 117.

Mertens, K., De Ketelaere, B., Kamers, B., Bamelis, F., Kemps, B., Verhoelst, E., De Baerdemaeker, J., Decuypere, E., 2005. Dirt detection on brown eggs by means of color computer vision. *Poultry science*, 84(10), 1653-1659.

Oyama, S., Manning, C.D., 2004. Using feature conjunctions across examples for learning pairwise classifiers. In: 15th European Conference on Machine Learning (ECML2004).

Patel, V., McClendon, R., Goodrum, J., 1998. Color computer vision and artificial neural networks for the detection of defects in poultry eggs. In: *Artificial Intelligence for Biology and Agriculture*, pp. 163-176. Springer.

Platt, J.C., 1999. 12 fast training of support vector machines using sequential minimal optimization.

Vert, J.P., Qiu, J., Noble, W., 2007. A new pairwise kernel for biological network inference with support vector machines. *BMC Bioinformatics*, 8(Suppl 10), S8.