

Yapay Sinir Ağları Tabanlı Yumurta Ağırlık ve Sınıflandırma Tahmini

Muhammed Furkan Taşdemir¹, Mehmet Şamil Akçay¹, İsmail Koyuncu²

¹Afyon Kocatepe University, Institute of Natural and Applied Sciences, Afyonkarahisar.

²Afyon Kocatepe University, Faculty of Technology, Department of Electrical Electronics Engineering, Afyonkarahisar.

e-mail: mftasdemir@usr.aku.edu.tr, 0000-0002-3401-2929, msakcay@usr.aku.edu.tr ORCID ID: 0000-0003-1603-8903, ismailkoyuncu@aku.edu.tr ORCID ID 0000-0003-4725-4879.

Geliş/Received : 06.09.2024 ; Kabul/Accepted : 04.12.2024 ; Revize/Revised : 09.12.2024

Öz

Yumurta, besleyici özelliği ve ekonomik açıdan düşük maliyete sahip olması nedeni ile dünyada yaygın bir şekilde tüketilmektedir. Bununla birlikte yumurta ağırlığının hassas bir şekilde ölçülmesi ve buna göre ağırlık sınıfının doğru olarak belirlenmesi önemli bir aşamadır. Sunulan bu çalışmada, yumurta görüntüleri kullanılarak YSA tabanlı ağırlık tahmini yapılmış ve bu sonuçlara göre yumurta sınıflandırma işlemi gerçekleştirilmiştir. Çalışmada öncelikle S, M, L ve XL sınıflarında olmak üzere 4 farklı paketlenmiş 120 adet yumurtanın ağırlıkları hassas terazi ile tartılmıştır. Ardından ikinci aşamada, ilgili yumurtalara ait 120 adet yumurta veri seti, saatin tersi yönünde 30°, 100° ve 200° döndürülerek toplam 480 adet yumurta görüntüsüne sahip daha geniş bir veri seti oluşturulmuştur. YSA tabanlı tahmin işleminin gerçekleştirilebilmesi amacı ile ilgili veri setine ait 336 yumurta görüntüsü eğitim, 72 adet yumurta görüntüsü doğrulama ve 72 adet yumurta görüntüsü test için üç bölüme ayrılmıştır. Çalışmadan elde edilen sonuçlara göre, YSA-tabanlı tahmin sistemi YSA-tabanlı ağırlık tahmin sistemine ait eğitim sonucu %98.2, doğrulama (validation) sonucu %98.1 ve test işleminden %97.9 oranında başarı sağlanmıştır. Sunulan bu çalışma ile, tasarımı yapılan ileri beslemeli YSA yapısının yumurta ağırlığına göre sınıflandırma uygulamalarında başarılı bir şekilde kullanılabileceği gösterilmiştir.

Anahtar Kelimeler

Yumurta ağırlığı;
Ağırlık tahmini; Yapay
sinir ağları; Yumurta
ağırlık tahmini

Artificial Neural Networks Based Egg Weight and Classification Estimation

Abstract

Eggs have consumed both nutritional properties and lower prices all over the world. Thus, precise measurement of egg weight and accurate weight class determination is an important stage. In this study, ANN-based weight estimation has been performed using egg images, after egg classification has been performed according to these results. With this study, the weights of 120 eggs packed in 4 different packages as S, M, L, and XL classes have been weighed with an assay balance. In the second section, a huge 480 egg images dataset have been generated with applying 30°, 100°, and 200° counterclockwise image rotations to related 120 egg images. In order to perform ANN-based prediction, the dataset have been divided into three parts to 336 egg images for training, 72 egg images for validation and 72 egg images for testing. According to the results obtained from the study, the ANN-based weight estimation system achieved 98.2% success in training, 98.1% success in validation and 97.9% success in testing. In this study, it has been shown the study that the feed-forward ANN structure designed can be successfully used in egg weight classification applications.

Keywords

Egg Weight; Weight
estimation; Artificial
neural networks; Egg
weight estimation.

1. Giriş

Son yıllarda yoğun çalışma alanlarından birisi olan yapay zekâ, genel olarak derin öğrenme (Türkoğlu 2021), bulanık mantık (fuzzy logic) (Karatas vd. 2020), makine öğrenmesi (Jiang vd. 2024), doğal dil işleme (Tanguy vd. 2015), genetik algoritma (Zorlu ve Sunca 2017) ve yapay sinir ağları (YSA-Artificial Neural Network) (Koyuncu vd. 2019) olmak üzere farklı alt dallara ayrılmaktadır. Bu alanlardan birisi olan YSA, sinyal ve görüntü işleme (Abbaspour-Gilandeh vd. 2020), robotik (Du 2011), optimizasyon (Lin ve Tsai 2008), medikal (Avcı 2014) ve kontrol (Fei ve Ding 2012) olmak üzere birçok uygulamada kullanılmaktadır. Genel olarak görüntü işleme, bölütleme (Tombul vd. 2018), eşikleme (Demirci vd. 2019), morfolojik işlemler (Yıldız vd. 2018), kenar bulma (Yiğitbaşı 2014), köşe bulma algoritmaları (Tasdemir vd. 2020) ve filtreleme (Altuntaş vd. 2011) vb. süreçleri içermektedir. Bu işlemler kriptoloji (Barakat vd. 2014), yer bilimlari (Lu vd. 2013), sağlık (Prakash vd. 2014, Hao vd. 2014), ölçme-enstrümantasyon (Rana vd. 2014, Li vd. 2014), kontrol (Xiao vd. 2015) ve gıda (Türkoğlu 2021) gibi pek çok alanda kullanılmaktadır. Olumsuz fiziksel şartlardan çok fazla etkilenmeme, düşük maliyetli olma ve yüksek başarımla nedeni ile görüntü işleme tabanlı uygulamalar gıda endüstrisinde önemli bir yer teşkil eden yumurta sektöründe çok sık tercih edilmektedir. Dünya nüfusunun artması, unlu mamuller ve işlenmiş gıdalar gibi çok farklı sektörlerde geniş bir alanda kullanılması nedeni ile yumurta tüketim oranı gün geçtikçe artmaktadır. Ayrıca Türkiye 2022 yılında Dünya'nın en büyük 4. yumurta ihracatçısı olarak sektörde önemli bir oyuncu konumundadır (Bahtiyar vd. 2023). Yumurta, insanların faydalanması için yaratılmış çok önemli bir besin kaynağıdır. Yumurta, besleyici özelliği ile uygun fiyatlı olması bakımından dünya çapında ve ülkemizde yaygın şekilde tüketilmektedir. Her geçen gün artan bu tüketim gereksinimi tavuk çiftliklerinde yumurtaların toplanması, kusurlu (kırık, çatlak vb.) olanların sağlamlardan ayrılması, ağırlık sınıflandırılması ve paketleme gibi işlemler için otomasyon tabanlı sistemlere geçişi hızlandırmıştır (Balcı vd. 2021).

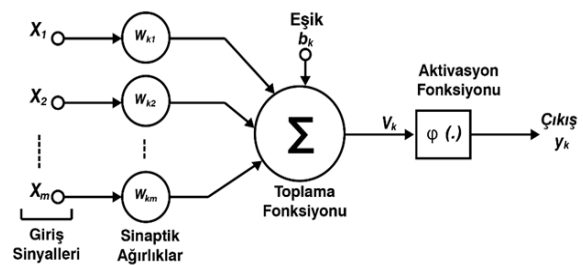
Tavuk çiftliklerinde ağırlık sınıfına uygun olarak paketlenen yumurtalar son aşamada tüketiciye sunulmaktadır. Bu noktada rekabet, maliyet, pazara çıkış hızı ve müşteri memnuniyeti için ağırlığının hassas ve hızlı bir şekilde ölçülüp ağırlık sınıfının doğru olarak belirlenmesi gerekmektedir. Yapılan araştırmalarda yumurta ağırlık sınıfına, geleneksel tüketiciler tarafından dikkat edildiği gözlemlenmiştir (Şalvarcı ve Ayten 2019). Günümüzde yumurta üzerine yapılan çalışmalar genel olarak yumurtaya ait çatlak, kırık, kirli, kanlı ve ağırlık tespiti gibi farklı alanlara ayrılmaktadır (Türkoğlu 2021). Literatürde yumurta ağırlıklarının tespit edilebilmesi konusu ve alanı üzerine yapılmış oldukça fazla çalışmaya rastlanılmıştır. Bu çalışmalar doğrudan ölçüm ve belirli parametrelere göre tahmin olmak üzere iki bölüme ayrılmaktadır. Sunulan çalışma tahmine dayalı bir yumurta ağırlık ölçüm sistemi olduğundan dolayı literatür bölümünde genel olarak bu çalışmalara yer verilmiştir. Regresyon analizi, görüntü işleme teknikleri, makine görüşü ve YSA, yumurta ağırlığının tespiti için kullanılan tahmin-tabanlı alanlara örnek olarak verilebilir. Dangphonhong ve arkadaşları tarafından yapılan çalışmada, görüntü işleme yöntemleri kullanılarak yumurta boyutları belirlenmiş ve bu değerlere göre yumurta ağırlığının tespiti gerçekleştirilmiştir. Sunulan çalışmada, önerilen yöntemin doğruluğu %97.67 olarak belirtilmiştir (Dangphonhong vd. 2016). Arı ve Berberler tarafından yapılan diğer bir çalışmada, yapay sinir ağlarında yaygın olarak kullanılan geri yayılım algoritması ile yumurta ağırlık ve sınıflandırma işlemi gerçekleştirilmiştir. İlgili çalışmada, rastgele ağırlıklarla eğitilip test seti ile test edilen sınıflandırma örnekleri için %93.02 ve eğitim seti ile test edilen sınıflandırma örneklerinde ise %96.02 başarı elde edilmiştir (Arı ve Berberler 2017). Alikhanov ve arkadaşları tarafından yapılan regresyon analizi tabanlı yumurta ağırlıklarının ölçülmesi çalışmasında, Matlab kullanılarak görüntü işleme yöntemleri ile yumurtanın çevresel uzunluğu ve hacmi gibi öznitelik vektörleri ile ağırlık tahmini yapılmıştır. Yapılan çalışma sonucunda önerilen yöntemin başarı oranı %94.39 olarak sunulmuştur (Alikhanov vd. 2015). Raoufat ve arkadaşları tarafından yapılan YSA-tabanlı

çalışmada, görüntü işleme kullanılarak yumurta ağırlıkları tahmin edilmiştir. Yumurta ağırlıklarının tespiti için 9 farklı Multi Layer Perceptron ağ yapısı kullanılmıştır. Çalışmada YSA-tabanlı yumurta ağırlık tahmini sisteminin başarısı %96 olarak elde edilmiştir (Raoufat ve Asadi 2010). Çanga ve arkadaşları yaptıkları çalışmada, yumurta ağırlığı tahmini için MARS (Multivariate Adaptive Regression Splines) yöntemini kullanmışlardır. Çalışmada Lohmann LSL Classic beyaz hibrit sürü tavuk cinsine ait 60 adet yumurta örnek alınmıştır. Ağırlık tahmini R Studio programında MARS algoritması kullanılarak yapılmıştır. Sonuçta, geliştirilen MARS tabanlı model ile daha kolay ve daha yüksek doğrulukta yumurta ağırlık tahmini yapılabileceğini ifade etmişlerdir (Çanga vd. 2021). Asadi ve arkadaşları çalışmalarında yumurta ağırlık tahmini için makine görüşü tabanlı bir sistem geliştirmişlerdir. Çalışmada yumurtaları yerleştirmek için ayna ile donatılmış bir tutucu çerçeve kullanılmıştır. Böylece her yumurtadan iki görüntü elde edilebilmektedir. Ardından bu görüntüler Matlab ortamında işlenmektedir. Her yumurta görüntüsünden çevre, ön yüzey, minimum, maksimum ve etkili çap gibi yumurta özelliklerini çıkarmak için altı algoritma geliştirilmiştir. Sonuçta makine görüşü tabanlı sistemden yaklaşık %95 doğruluk elde edilmiştir (Asadi vd. 2012).

Sunulan bu çalışmada literatürde yapılmış yukarıdaki çalışmalardan farklı olarak, çok katmanlı ileri beslemeli bir YSA yapısı ile yumurta görüntüleri kullanılarak ağırlık tahmini yapılmıştır. Yapılan çalışmada, yumurtaların piksel boyutlarındaki değişimler hacimle doğru orantılanmış ve bu değerler yapay sinir ağlarında eğitilerek yumurta ağırlık ve sınıflandırma işlemi gerçekleştirilmiştir. Bu tasarım ile literatürdeki YSA-tabanlı yumurta ağırlık tahmini yapılarına göre başarı oranı daha yüksek sonuçlar elde edilmiştir. Çalışmanın ikinci bölümünde, yapay sinir ağları ile ilgili genel bilgiler verilmiştir. Üçüncü bölümde, YSA tabanlı yumurta ağırlık tahmini sistemi tanıtılmıştır. Son bölümde ise YSA-tabanlı yumurta ağırlık tahmini sisteminden elde edilen sonuçlar yorumlanmıştır.

2. Yapay Sinir Ağları

Günlük hayatımızda yoğun şekilde uygulama sahası bulunan YSA'lar yapay zekânın alt çalışma alanlarından birisidir. YSA, insan beyninde mevcut olan öğrenme, karar verme, tahmin etme ve sınıflandırma gibi yetenekler referans alınıp geliştirilmiş bir yapay zekâ çalışma alanıdır. Bu özellikleri sayesinde YSA, optimizasyon, tıp, kontrol, hata tespiti, sinyal ve görüntü işleme, güvenli haberleşme, uzay teknolojisi, tahmin, karar verme, sınıflandırma ve kaos uygulamaları olmak üzere çok farklı alanlarda kullanılmaktadır. Şekil 1'de YSA nöron modeli verilmiştir. Bir YSA nöronunda çıkış bilgisinin üretilmesi denklem (1) ve denklem (2) kullanılarak ifade edilmiştir. Transfer fonksiyonu nöron çıkışındaki değeri doğrudan etkilemektedir (Akçay vd. 2022). Aktivasyon fonksiyonları doğrusal ve doğrusal olmayan biçimlerde yaygın olarak kullanılmaktadır. Doğrusal olan aktivasyon fonksiyonlarına PosLin, PureLin, HardLim, HardLims, SatLin, SatLins fonksiyonları ve doğrusal olmayan aktivasyon fonksiyonlarına LogSig, TanSig ve RadBas fonksiyonlarını örnek olarak verilebilmektedir (Akçay vd. 2020). LogSig, TanSig ve RadBas fonksiyonları karmaşık problem çözümlerinde oldukça başarılı olarak sıklıkla tercih edilmektedir (Tuna 2020).




Şekil 1. YSA nöron modeli.

$$v_k = \sum_{j=1}^m w_{kj} \cdot x_j$$

$$y_k = \phi(v_k + b_k)$$

Çok katmanlı ileri beslemeli bir YSA yapısı giriş katmanı (input layer), gizli katman(lar) (hidden layer) ve çıkış katmanından (output layer) oluşmaktadır. YSA yapısında önemli bir bölüm olan gizli katman sayısı ile bu katmandaki nöron sayısı gerçekleştirilen uygulamaya göre değişiklik göstermektedir (Ersoy ve Karal 2012). YSA yapıları

genel olarak tek katmanlı ileri beslemeli, çok katmanlı ileri beslemeli ve geri beslemeli olarak üç temel sınıfta incelenebilmektedir (Vaidyanathan vd. 2020). Şekil 2’de örnek çok katmanlı ileri beslemeli bir YSA yapısı gösterilmiştir.



Şekil 2. Çok katmanlı ileri beslemeli bir YSA yapısı.

3. YSA-Tabanlı Yumurta Ağırlık Tahmini Sistemi


Çalışmanın bu bölümünde yumurta görüntüleri kullanılarak YSA-tabanlı yumurta ağırlıklarının tespit edilmesi için görüntü işleme yöntemleri ve YSA yapısı anlatılmıştır. Sunulan bu çalışmada, 3 ayrı yumurta markasının 4 farklı S, M, L ve XL sınıfı ile paketlenmiş oldukları ürünleri incelenmiştir. Çalışmada kullanılan yumurtalara ait sınıflandırma işlemi için 2014 yılında Resmî Gazete’de yayınlanan Gıda, Tarım ve Hayvancılık Bakanlığı, Türk Gıda Kodeksi Yumurta Tebliğine göre aşağıda verilen A sınıfı yumurtaların ağırlık sınıfları Tablosu dikkate alınmıştır [Resmî Gazete, 2014].

Tablo 1. A Sınıfı Yumurtanın Ağırlık Sınıfları


Ağırlık Sınıfı	Sınıf Sembolü	Ağırlık (g)
Çok Büyük	XL	$XL \geq 73$
Büyük	L	$73 > L \geq 63$
Orta	M	$63 > M \geq 53$
Küçük	S	$S < 53$

Bu amaç ile S sınıfından örnek 30 yumurta, M sınıfından örnek 30 yumurta, L sınıfından örnek 30 yumurta ve XL sınıfından örnek 30 yumurta alınmış ve çalışmada toplamda 120 yumurta kullanılmıştır. Çalışmanın ilk aşamasında, veri setinin


oluşturulabilmesi için kullanılacak tüm yumurtalar hassas dijital terazi ile tartılmış ve bu değerler kaydedilmiştir. Yumurta ağırlıklarının ölçülmesi işlemi için platform tipi exproof yük hücresi (load-cell) içeren OIML (International Organization of Legal Metrology) standardına sahip sınıf 3 (minimum doğrulama ölçek aralıkları (minimum verification scale intervals) 1 g) seviyesinde Baykon marka terazi kullanılmıştır. Ölçülen değerler 6 adet 7 parçalı göstergeye (seven segment display) sahip Baykon marka BX11 An modeli üzerinde gözlemlenmiştir. Ayrıca tartılan her yumurtanın, ışık kaynağına sabitlenmiş kamera aracılığıyla 20 cm mesafeden görüntüsü alınmış ve ilgili yumurta görüntüleri etiketlenerek kaydedilmiştir. Ardından etiketli 120 adet yumurta görüntüsüne saat yönü tersine doğru 30° , 100° ve 200° görüntü döndürme işlemi uygulanmıştır. Böylece S, M, L ve XL sınıflarında olmak üzere toplamda 480 farklı yumurta görüntüsüne sahip bir veri seti oluşturulmuştur. İkinci aşamada, kaydedilen görüntü üzerinden beyaz piksel oranı tespit edilmiş olup aynı yumurtanın gramajıyla eşleştirilmiştir. Diğer bir değişle gerçek hayattaki sayısal değer olan gramaj ile sanal görüntü üzerinden tespit edilen beyaz piksel değerleri eşlenmiş ve bu bilgiler YSA ile eğitilmiştir. Ağırlık tespiti yapabilmek için elde edilen görüntüler kamera aracılığıyla kaydedilmiş ve bu görüntüler YSA eğitimlerinde kullanılmak üzere ağ eğitim seti oluşturulmuştur. Elde edilen görüntüler görüntü işleme algoritmaları ile matematiksel değerlere dönüştürülmüş ve bu matematiksel değerler yapay sinir ağı yardımıyla eğitilmiştir. Şekil 3’te YSA-tabanlı ağırlık tahmin uygulamasının eğitim aşamasında kullanılan örnek bir görüntü verilmiştir. Şekil 4, Şekil 5 ve Şekil 6’da sırasıyla saat yönü tersine uygulanan 30° , 100° ve 200° görüntü döndürme işlemi örnek yumurta görüntüleri verilmiştir.




Şekil 3. YSA-tabanlı ağırlık tahmin uygulamasının eğitim aşamasında kullanılan örnek yumurta görüntüsü.



Şekil 4. YSA-tabanlı ağırlık tahmin uygulamasının eğitim aşamasında kullanılan saat yönü tersinde 30° döndürülmüş örnek yumurta görüntüsü.



Şekil 5. YSA-tabanlı ağırlık tahmin uygulamasının eğitim aşamasında kullanılan saat yönü tersinde 100° döndürülmüş örnek yumurta görüntüsü.



Şekil 6. YSA-tabanlı ağırlık tahmin uygulamasının eğitim aşamasında kullanılan saat yönü tersine 200° döndürülmüş örnek yumurta görüntüsü.

YSA üzerinde eğitmek için yumurta görüntüleri elde edilmiştir. Yumurta rengi için ise beyaz renkli olanlar tercih edilmiştir. Beyaz renkte olan yumurtaların tespiti kolaylaştırmak için arka plan rengi siyah olarak belirlenmiştir. Böylece siyah ve beyaz gibi iki zıt renk kullanılarak görüntü işleme algoritmaları ile elde edilen sonuçların güvenliği sağlanmış olmaktadır. Elde edilen yumurta görüntülerinin yapay sinir ağları tarafından doğru ve objektif olarak yorumlanabilmesi için her yumurta görselinin aydınlatması için kullanılan ışık kaynağı ve kamera aynı tip ve aynı mesafeden uygulanarak etkisi her ürün için sabit tutulmuştur.

Kamera ve fotoğraf makinesi gibi araçlar ile temin edilen görüntüler genellikle RGB renk uzayına sahip olan renkli görüntülerinden oluşmaktadır. Renkli görüntüler Kırmızı (R), Yeşil (G) ve Mavi (B) gibi renk kanallarının birleşmesiyle dijital halde oluşturulmakta ve saklanmaktadır. Her kanal ayrı ayrı değerlendirildiğinde gri seviye görüntü olarak adlandırılmaktadır. Ancak bu tek kanal değerleri, gri formattaki resmi doğru bir şekilde temsil etmemektedir. Sonuç olarak tüm renk kanallarının kullanılması ile resme ait özneliteler ifade edilebilmektedir. Literatürde RGB görüntüden gri seviye görüntüye dönüşüm için çeşitli yöntemler önerilmiştir. Aşağıda bu çalışmada gri seviye dönüşümü için kullanılan denklem (3) verilmiştir (Prasad vd. 2015).


$$\text{Gri} = (0.3 * R) + (0.59 * G) + (0.11 * B) . \quad (3)$$

Uygulamalarda hem işlemcideki işlem yükünü hem de hafızada kapladığı alanı azaltmak için RGB kanallı renkli görüntüler gri seviye görüntüye dönüştürülmektedir. Renkli görüntüden gri seviye görüntüye dönüşüm sağlamak için RGB kanallarının her bir renk kanalının ayrı ayrı gri seviye görüntü olarak değerlendirilmesi yerine bu kanalların belirli katsayılar ile çarpılıp toplanması, bütün renk değerlerinin bulunduğu gri seviye bir görüntü elde edilmesini sağlamaktadır. Aşağıda Şekil 7’de Gri seviye yumurta görüntüsü verilmiştir.



Şekil 7. Gri seviye yumurta görüntüsü.


Görüntü işleme uygulamalarında filtreler nesne tespiti, kenar ve köşe tespiti gibi alanlarda çokça tercih edilmektedir. Sunulan çalışmada Gaussian filtresi, görüntüyü bulanıklaştırmak amacı ile kullanılmıştır. Görüntü üzerinde bulunan toz partikülleri ışık parlamaları gibi çok küçük, anlamsız oluşumlar bulanıklaştırılarak resim üzerindeki olumsuz etkileri giderilmektedir. Gaussian filtresi görüntü üzerinde piksel değerlerine matrisler aracılığıyla etki eden bir filtredir. Gaussian filtresinde 3x3, 5x5, 7x7 ve 9x9 gibi maskeler kullanılarak filtreleme işlemi yapılabilmektedir. Bulanıklığı artırılması için filtrenin boyutunun büyütülmesi veya maskenin daha fazla resim üzerinde gezdirilmesi gerekmektedir. Sunulan bu çalışmada, Gaussian filtresi için 5x5'lik bir maske kullanılmıştır. Aşağıda Şekil 8'de gri görüntü üzerine uygulanan Gaussian filtresinden elde edilen bulanıklaştırılmış yumurta resmi verilmiştir.



Şekil 8. Gaussian filtresinden elde edilen bulanıklaştırılmış yumurta görüntüsü.


Bulanıklaştırma işleminin ardından resmin siyah beyaz formata dönüştürülmesi aşamasına geçilmiştir. Siyah ve beyaz bir görüntü oluşturmanın ana amacı tespit edilecek olan nesne, kenar ya da benzer etmenlerin, YSA tarafından matematiksel olarak algılanmasının sağlanmasıdır. Tespit edilen optimum eşik değeri belirlendikten sonra bu eşik değerinin altında kalan piksel değerleri siyah (logic veri tipi için 0) renge ve

üstünde olan değerler ise beyaz (logic veri tipi için 1) renge sahip olmaktadır. Aşağıda Şekil 9'da bulanıklaştırma işleminin ardından siyah beyaz formata dönüştürülmüş yumurta resmi verilmiştir.



Şekil 9. Siyah beyaz formata dönüştürülmüş örnek yumurta resmi.

Öncelikle Siyah beyaz görüntü elde görüntünün üzerinde arka ve ön planda bulunan nesnelere ayrıştırılmaktadır. Ön planda bulunan nesnelere beyaz renkle, beyaz renkteki nesnenin arkasında kalan kısımlar ise siyah renkte gösterilmektedir. Bu süreçte beyaz renkte oluşan piksel değerleri sayılmaktadır. Elde edilen beyaz piksel değerleri ise YSA ile eğitilmektedir. YSA-tabanlı ağırlık tahmin sistemi, gizli katmanında Tanjant Sigmoid (Tansig) aktivasyon fonksiyonu kullanılan 35 nörona sahip çok katmanlı 1-35-1 ileri beslemeli ağ yapısı kullanılmıştır. Şekil 10'da YSA-tabanlı tahmin sistemi yapısı verilmiştir.

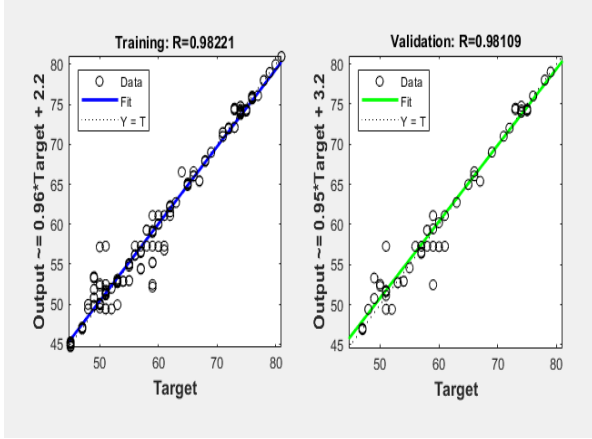


Şekil 10. Çok katmanlı ileri beslemeli YSA-tabanlı ağırlık tahmin sistemi yapısı.

4. YSA-Tabanlı Ağırlık Tahmini Sistemi Sonuçları

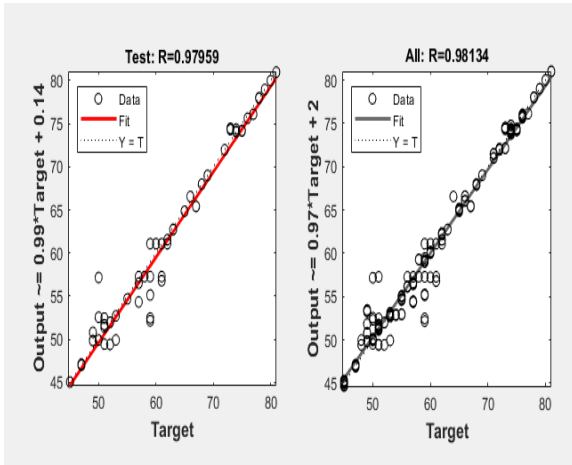
Çalışmanın bu bölümünde yumurta görüntüleri kullanılarak tasarımı yapılan YSA-tabanlı ağırlık sistemi için gerçekleştirilen eğitim ve test işlemlerine ait sonuçlar verilecektir. Tasarımı yapılan YSA-tabanlı ağırlık sisteminde, eğitim aşamasında, eğitim algoritması olarak Levenberg-

Marquardt algoritması kullanılmıştır. Yumurta görüntü veri setinin %70'i (336 adet) eğitim, %15'i (72 adet) validasyon işlemi için ayrılmıştır. Yumurta görüntü veri setinin %15'si (72 adet) ise test amaçlı kullanılmıştır. Şekil 11'de YSA-tabanlı ağırlık tahmin sistemi için gerçekleştirilen eğitim ve validasyon işlemine ait performans sonuçları verilmiştir. YSA-tabanlı ağırlık tahmin sistemine ait eğitim sonucu %98.2 ve validasyon sonucu %98.1 olarak elde edilmiştir.



Şekil 11. YSA-tabanlı yumurta ağırlık tahmin sisteminin eğitim ve validasyon performansı.

YSA-tabanlı ağırlık tahmin sistemine ait eğitim aşamasından sonra test aşamasına geçilmiştir. Bu aşamada, 72 adet yumurta test verileri ağa yüklenmiş ve sonuçta yaklaşık olarak %97.9 oranında bir başarı elde edilmiştir. YSA-Tabanlı yumurta ağırlık tahmini sistemine ait test sonuçları Şekil 12'de sunulmuştur.



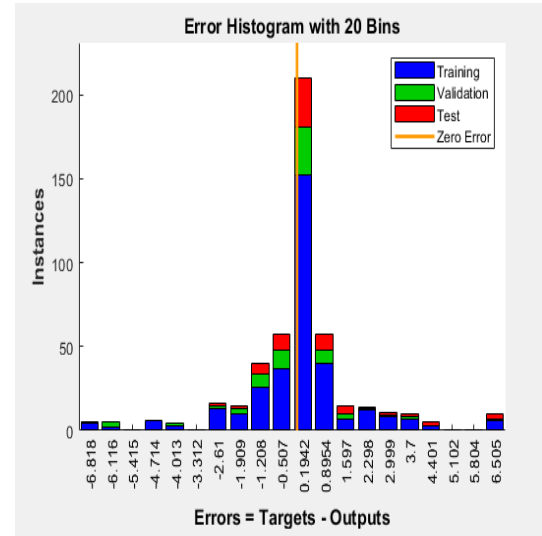
Şekil 12. YSA-tabanlı yumurta ağırlık tahmin sisteminin test performansı.

Yumurta ağırlıklarının tahmini için literatürde yapılmış bazı çalışmalar ve bu çalışmalardan elde edilen sonuçlar Tablo 2'de sunulmuştur.


Tablo 2. Yumurta ağırlıklarının tahmini için literatürde yapılmış bazı çalışmalar ve sonuçları

Çalışma	Alan	Yöntem	Başarı Oranı %
Alikhanov vd.	Regresyon Analizi	Öznitelik vektörleri	94.39
Dangphonhong vd.	Görüntü işleme	Boyut tespiti	97.67
Raoufat vd.	YSA-MLP	Özellik çıkartımı	96
Çanga vd.	MARS	İç dış kalite özellikleri	-
Asadi vd.	Makine Görüsü	Yumurta özellikleri	95
Arı vd.	YSA-MLP	Görüntü	96.02
Bu çalışma	YSA-FF	Piksel yoğunluğu	97.96

Şekil 13'te YSA-tabanlı ağırlık tahmin sistemine ait eğitim ve test aşamalarından elde edilen hata histogramı ve Şekil 14'te sisteme ait MSE (Mean Square Error (Ortalama Karesel Hata)) değerleri grafiği verilmiştir.



Şekil 13. YSA-tabanlı yumurta ağırlık tahmin sisteminin hata histogramı.



Şekil 14. YSA-tabanlı yumurta ağırlık tahmin sisteminin MSE hata değerleri grafiği.

5. Tartışma ve Sonuç

Günümüzde Dünya nüfusunun artması, besleyici özelliği, ekonomik açıdan düşük maliyete sahip olması gibi birçok sebepler ile başta unlu mamul üretimi ve işlenmiş gıdalar gibi çok farklı sektörlerde yaygın bir alanda yumurtanın kullanımı gün geçtikçe artmaktadır. Bununla beraber yumurtaların ağırlık sınıfının doğru bir şekilde tespit edilerek tüketiciye sunulması gerekmektedir. Fakat S, M, L ve XL sınıflarında olmak üzere 3 ayrı yumurta markasının 4 farklı paketlenmiş ürünleri üzerinde hassas terazi ile yapılan güncel ağırlık incelemesinde %14.17 oranında sınıflandırma hatası tespit edilmiştir. Sunulan bu çalışmada, S, M, L ve XL sınıflarında olmak üzere 480 adet yumurta görüntüsü kullanılarak YSA tabanlı ağırlık tahmini yapılmış ve bu sonuçlara göre yumurta sınıflandırma işlemi gerçekleştirilmiştir. Tasarımda çok katmanlı ileri beslemeli YSA yapısı kullanılmıştır. YSA-tabanlı yumurta ağırlık tahmin sisteminden elde edilen sonuçlara göre, YSA-tabanlı tahmin sistemi yaklaşık olarak %97.9 oranında bir başarı ile yumurta ağırlıklarını tahmin etmiştir. Sunulan bu çalışma ile ağırlıklarına göre yumurtaların sınıflandırılması işlemi için YSA-tabanlı tahmin sisteminin başarılı bir şekilde kullanılabilirliği gösterilmiştir. İleriki çalışmalarda, bu çalışmada sunulan YSA-tabanlı yumurta ağırlık tahmin sistemi referans alınarak, yüksek hız ve performans sağlayan FPGA (Alan Programlanabilir Kapı Dizileri-Field Programmable Gate Array) veya GPU (Grafik İşlemci Birimi-Graphics Processing Unit) donanımları kullanılarak düşük hata oranına sahip gerçek zamanlı yumurta ağırlık ve sınıflandırma tahmin sistemi gerçekleştirilebilir.

6. Referanslar

- Akçay, M. Ş., Koyuncu, İ., Alçın, M. V. & Tuna, M., 2022. FPGA Tabanlı LogSig ve TanSig Transfer Fonksiyonlarının IQ-Math Sayı Standardında Tasarımı ve Gerçeklenmesi. *Journal of Materials and Mechatronics: A*, **3**(2), 225-239.
- Akçay, M. Ş., Koyuncu, İ., Alçın, M. & Tuna, M. 2020. Implementation of IQ-Math Based RadBas Activation Function on FPGA. *In International Asian Congress on Contemporary Sciences-IV*, Baku Azerbaijan Vol. **599**, p. 607.
- Ali Khanov, D., Penchev, S., Georgieva, T., Moldajanov, A., Shynybaj, Z. & Daskalov, P. 2015. Indirect method for egg weight measurement using image processing. *International Journal of Emerging Technology and Advanced Engineering*, **5**, 30-34.
- Altuntaş, C. & Çorumluoğlu, Ö., 2011. Filtreleme Yöntemi İle Digital Görüntü Zenginleştirme ve Örnek Bir Yazılım, *Teknik-Online Dergi*, **10**, 99-107.
- Asadi, V., Raoufat, M. & Nassiri, S. 2012. Fresh egg mass estimation using machine vision technique. *Int. Agrophys.*, **26**(3), 229-234.
- Avcı, D., Leblebicioğlu, M. K., Poyraz, M. & E., Dogantekin, A., 2014. New method based on adaptive discrete wavelet entropy energy and neural network classifier (ADWEENN) for recognition of urine cells from microscopic images independent of rotation and scaling, *J. Med. Syst.* **38** 1–9.
- Arı, A. & Berberler, M. E., 2017. Yapay sinir ağırları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, **1**(2), 55-73.
- Bahtiyar, T. & Olhan, E. 2023. Dünya Yumurta Ticaretindeki Değişimler ve Türkiye'nin Dünya Yumurta Ticaretindeki Yeri. *Adnan Menderes Üniversitesi Ziraat Fakültesi Dergisi*, **20**(2), 265-274.
- Balcı, Z., Yumurtacı, M., Yabanova, İ. & Ergin, S. 2021. Yumurta Kabuğundan Alınan Akustik Sinyalin Dalgacık Paket Dönüşümü ve Entropiye Dayalı Olarak İşlenmesi ve Yapay Sinir Ağlarıyla Çatlağın Belirlenmesi. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, **8**(1), 125-135.
- Barakat, M., L., Mansingka, A., S., Radwan, A., G. & Salama, K., N., 2014. Hardware Stream Cipher with Controllable Chaos Generator for Colour Image Encryption, *Image Processing*, **8**, 33–43.
- Çanga, D., Yavuz, E., & Efe, E. 2021. Prediction of Egg Weight Using MARS data mining Algorithm through R. *Kahramanmaraş Sütçü İmam Üniversitesi Tarım Ve Doğa Dergisi*, **24**(1), 242-251.

- Dangphonthong, D. & Pinate, W., 2016. *Analysis of weight egg using image processing*. Proceedings of Academics World 17th International Conference. Tokyo, Japan, pp. 55-57.
- Demirci, R. & Okur, Ü., 2019. Renkli Görüntülerin Ortalama Tabanlı Çok Seviyeli Eşiklenmesi, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, **7**, 664-676.
- Du, X. K., 2011. The New Elman ANN Application in Accuracy Improvement of Robot Navigation and Obstacle Avoidance Technology, *Advanced Materials Research*, **383-390**, 1447-1451.
- Ersoy, E. & Karal, Ö., 2012. Yapay sinir ağları ve insan beyni, *Journal of the Human and Social Science Researches*, **1**, 188-205.
- Fei, J. & Ding, H., 2012. Adaptive sliding mode control of dynamic system using RBF neural network, *Nonlinear Dyn.*, **70**, 1563–1573.
- Gilandeh, A., Molaei, Y., Sabzi, A., Nabipur, S., Shamshirband, N., S., & Mosavi, A. 2020. A combined method of image processing and artificial neural network for the identification of 13 Iranian rice cultivars. *Agronomy*, **10**(1), 117.
- Hao, F., Guoping, Q., Jie, S. & İlyas, M., 2014. A Novel Polar Space Random Field Model for the Detection of Glandular Structures, *IEEE Transactions on Medical Imaging*, **33**, 764–776.
- Jiang, Z., Carlson, B., Deiana, A., Eastlack, J., Hauck, S., Hsu, S. C., & Zuo, B. 2024. Machine learning evaluation in the Global Event Processor FPGA for the ATLAS trigger upgrade. *Journal of Instrumentation*, **19**(05), P05031.
- Karatas F., Koyuncu I., Tuna M. & Alçın M., 2020. Implementation of Fuzzy Logic Membership Functions on FPGA. *Bilgisayar Bilimleri ve Teknolojileri Dergisi*, **1**(1), 01-09.
- Koyuncu, I., Akçay, M. S., Tuna, M. & Alçın, M., 2019. Implementation of IQ-Math-based Linear Activation Functions on FPGA, *1st International Congress of Multidisciplinary Studies and Research*, 114-124.
- Lin, C. J. & Tsai, H., M., 2008. FPGA implementation of a wavelet neural network with particle swarm optimization learning, *Math. Comput. Model.*, **47**, 982–996, 2008.
- Li, L., Gong, M., Chui, Y. H. & Schneider, M., 2014. A MATLAB-based Image Processing Algorithm For Analyzing Cupping Profiles of Two-Layer Laminated Wood Products, *Measurement*, **53**, 234 – 239.
- Lu, W., Lifan, Z., Guoan, B., Chunru, W. & Lei, Y., 2013. Enhanced ISAR Imaging by Exploiting the Continuity of the Target Scene, *IEEE Transactions on Geoscience and Remote Sensing*, **52**, 5736 - 5750.
- Prakash, J., Dehghani H., Pogue, B. W. & Yalavarthy, P. K., 2014. Model-Resolution-Based Basis Pursuit Deconvolution Improves Diffuse Optical Tomographic Imaging, *IEEE Transactions on Medical Imaging*, **33**, 891–901.
- Prasad, S., Kumar, P. ve Sinha, K. P. 2015. Grayscale to color map transformation for efficient image analysis on low-processing devices. *In Advances in Intelligent Informatics* (pp. 9-18). Springer International Publishing.
- Rana, K., B., Agrawal, G. D., Mathur, J. & Puli, U., 2014. Measurement of Void Fraction in Flow Boiling of ZnO Water Nanofluids Using Image Processing Technique, *Nuclear Engineering and Design*, **270**, 217–226.
- Raoufat, M. H. & Asadi, V. 2010. Estimation of egg weight by machine vision and neural networks techniques. *In CIGR XVIIth World Congress—Québec City, Canada*.
- Şalvarcı, Ü. B. & Ayten, U. E. 2019. Yapay sinir ağları ile görüntü işlemeye dayalı uzaklıktan bağımsız ağırlık tahmin sistemi: yumurta ve portakal örnekleri. *Jeodezi ve Jeoinformasyon Dergisi*, **6**(1), 26-46.
- Tanguy, L., Tulechki, N., Urieli, A., Hermann, E. & Raynal, C., 2015. Natural language processing for aviation safety reports: From classification to interactive analysis, *Computers in Industry*, **78**, 80-95.
- Tasdemir M. F., Koyuncu I., Cosgun E. & Katircioğlu F. 2020. Real-Time Fast Corner Detection Algorithm Based Image Processing Application on FPGA. *International Asian Congress on Contemporary Sciences-III*, 01-06.
- Tombul, H. & Kavzoğlu, T., 2018. Nesne Tabanlı Görüntü Analizinde Görüntü Bölütleme Yaklaşımları ve Bölütleme Kalitesinin Analizi, *Harita Dergisi*, **160**, 12-23.
- Tuna, M., 2020. A novel secure chaos-based pseudo random number generator based on ANN-based chaotic and ring oscillator: design and its FPGA implementation. *Analog Integr Circ Sig Process* **105**, 167–181.
- Türkoğlu, M., 2021. Yumurta Kabuğu Görüntülerinde Kırık Tespiti İçin Daha Hızlı Bölgesel Tabanlı Çok Katmanlı Evrimsel Sinir Ağları, *Gazi University Journal of Science Part C: Design and Technology*, **9**(1), 148-157.
- Türkoğlu, M., 2021. Detection of eggshell defects using convolutional neural Networks, *Turkish Journal of Agriculture-Food Science and Technology*, **9**(3), 559-567.
- Vaidyanathan, S., Pehlivan, I., Dolvis, L. G., Jacques, K., Alcin, M., Tuna, M. & Koyuncu, I. 2020. A novel ANN-based four-dimensional two-disk hyperchaotic

dynamical system, bifurcation analysis, circuit realisation and FPGA-based TRNG implementation. *International Journal of Computer Applications in Technology*, **62**(1), 20-35.

- Xiao, Y. & Dong, S., 2015. Multilevel-Based Topology Design and Cell Patterning With Robotically Controlled Optical Tweezers, *IEEE Transactions on Control System Technology*, **23**, 176–185.
- Yıldız, G. & Yıldız, D., 2018. Morfolojik İşlemler ve Kenar Algılama Yöntemler Vasıtasıyla Beyin Tümör Yeri Tespiti ve Tümör Alan Hesabının Yapılması, *International Journal of Multidisciplinary Studies and Innovative Technologies*, **2**, 39-42.
- Yiğitbaşı, E. D., 2014. Yapay Arı Kolonisi Optimizasyonu ile Kenar Bulma, *Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*, 96s, Konya.
- Zorlu, H. & Sunca, Ş., 2017. Genetik Algoritma Kullanılarak Ağırlıklandırılmış Myriad Filtrelerin Optimizasyonu. *International Journal of Multidisciplinary Studies and Innovative Technologies*, **1**, 9-14.

Internet resources

1-Resmî Gazete, 2014, *Türk Gıda Kodeksi Yumurta Tebliği*,
www.resmigazete.gov.tr/eskiler/2014/12/20141220-5.htm (09.08.2024)