

PAPER DETAILS

TITLE: Yapay sinir aglarinin farkli aktivasyon fonksiyonlarinda uygulaması: Türkiye'de ördek popülasyonu öngörüsü

AUTHORS: Senol ÇELİK

PAGES: 800-811

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/1956827>

Yapay Sinir Ağlarının Farklı Aktivasyon Fonksiyonlarında Uygulaması: Türkiye’de Ördek Popülasyonu Öngörüsü

Şenol ÇELİK^{1*}

¹Bingöl Üniversitesi Ziraat Fakültesi Zootečni Bölümü Biyometri ve Genetik Anabilim Dalı, Bingöl

¹<https://orcid.org/0000-0001-5894-8986>

*Sorumlu yazar: senolcelik@bingol.edu.tr

Araştırma Makalesi

ÖZ

Makale Tarihiçesi:

Geliş tarihi: 03.10.2021

Kabul tarihi: 10.11.2021

Online Yayınlanma: 18.07.2022

Anahtar Kelimeler:

Yapay sinir ağları
Aktivasyon fonksiyonu
Geri yayılım
Ördek

Bu çalışmada farklı aktivasyon fonksiyonlarında Türkiye’de ördek sayısını modellenmiş ve öngörü yapacak bir Yapay Sinir Ağı (YSA) modeli geliştirilmiştir. YSA modelinin geliştirilmesinde girdi parametresi olarak zaman değişkeni olan yıllar, çıkış parametresi olarak ise ördek sayısı kullanılmıştır. Araştırma verileri 1991-2020 dönemine ait Türkiye’deki ördek sayısından oluşmaktadır. En uygun modeli belirlemek için yarı doğrusal, sigmoid, bipolar sigmoid ve hiperbolik tanjant gibi 4 farklı aktivasyon fonksiyonları kullanıldı. En uygun aktivasyon fonksiyonunu belirlemek için modelin etkinliğini belirleyen Hata Kareler Ortalaması (MSE) ve Hatanın Mutlak Ortalaması (MAE) istatistikleri kullanılmıştır. Farklı aktivasyon fonksiyonlarının performansları karşılaştırıldığında en uygun aktivasyon fonksiyonu hiperbolik tanjant fonksiyonu olmuştur. Çünkü hiperbolik tanjant fonksiyonu kullanıldığında en küçük MSE ve MAE değerlerine ulaşılmıştır. YSA modeli tek gizli katmanlı, 12 işlem elemanlı (1-12-1) ve öğrenme algoritması Levenberg–Marquardt geri yayılım algoritması olarak kullanılan bir ağ mimarisi şeklindedir. YSA ile ördek sayısının 2021-2025 yılları arası öngörüsü yapılmıştır. Öngörü sonuçlarına göre, 2021-2025 yılları arasında ördek sayısının 479,407-531,242 arasında olacağı beklenmektedir.

Application of Artificial Neural Networks in Different Activation Functions: Prediction of Duck Population in Turkey

Research Article

ABSTRACT

Article History:

Received: 03.10.2021

Accepted: 10.11.2021

Published online: 18.07.2022

Keywords:

Artificial neural networks
Activation function
Back propagation
Duck

In this study, an Artificial Neural Network (ANN) model was developed to model and forecast the number of ducks in Turkey in different activation functions. In the development of the ANN model, years were used, which is a time variable, as the input parameter and the number of ducks as the output parameter. The research data consists of the number of ducks in Turkey for the period 1991-2020. 4 different activation functions such as semi-linear, sigmoid, bipolar sigmoid, and hyperbolic tangent were used in order to determine the most suitable model. Mean Squares Error (MSE) and Absolute Mean Error (MAE) statistics, which determine the efficiency of the model, were used to determine the most suitable activation function. When the performances of different activation functions were compared, the most suitable activation function was the hyperbolic tangent function. Because the smallest MSE and MAE values were achieved when the hyperbolic tangent function was used. The single hidden layer of the ANN model is in the form of a network architecture used as Levenberg–Marquardt backpropagation algorithm (*trainlm*), with 12 processing elements (1-12-1) and as a learning algorithm. With the ANN, the number of ducks was predicted between 2021 and 2025. According to the forecast results, the number of ducks in 2021-2025 is expected to be between 479,407-531,242.

1. Giriş

Dünyanın en karmaşık makinesi olarak değerlendirilebilen insan beyni sayısal bir işlemi birkaç dakikada yapabilse de; algılamaya yönelik olayları çok kısa bir sürede yapmaktadır. Örneğin, yolda araçla seyreden bir şoför, yolun kayganlık derecesini, önündeki tehlikeden uzak durumu, sayısal olarak değerlendiremese bile tecrübesine dayanarak aracın hızını azaltır. Bu nedenle, o anda çok kısa bir sürede tehlikeyi algılamış ve ona karşı koymuştur (Elmas, 2007).

Yapay sinir ağları (YSA), bazı özelliklere sahiptir. Bunlar; Doğrusal olmama, paralel çalışma, öğrenme, genelleme, eksik verilerle çalışma, hata toleransı, uyarlanabilirlik, çoklu değişken ve parametre kullanımıdır. YSA yöntemi dört grupta incelenir. Bunlar tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağlarıdır (Öztemel, 2012; Güzeller ve Aksu, 2018).

Bir yapay sinir ağında, üç katman bulunur. Bu katmanlar; birbirleriyle bağlantılı sinir hücrelerinin yer aldığı girdi katmanı, çıktı katmanı ve gizli katmanıdır. Girdi katmanı, dışarıdan gelen verilerin yapay sinir ağına alınmasını sağlar. Girdi katmanı probleme etki eden parametrelerden oluşur ve girdi katmanındaki nöron sayısı parametre sayısına göre şekillenir. Çıktı katmanı, bilgilerin dışarıya iletilmesini sağlar. Gizli katman ise girdi katmanı ile çıktı katmanı arasında yer alır. Gizli katmana ait nöronların dış ortamla bağlantıları olmayıp, sadece girdi katmanından gelen sinyalleri alıp, çıktı katmanına sinyal gönderirler (Benli, 2002). Ayrıca toplama fonksiyonu ve aktivasyon fonksiyonu da yapay sinir ağlarının diğer önemli öğeleridir (Öztemel, 2012).

YSA yöntemi ile değişik alanlarda yapılmış araştırmalara rastlanılmıştır. Bu araştırmaların birinde İstanbul’da toplu taşıma yolculuk talepleri yapay sinir ağları ile analiz edilmiştir. İstanbul’da deniz işletmeleri, belediye otobüsleri, özel halk otobüsleri, demiryolları ve Ulaşım AŞ’den toplanan günlük yolculuk değerleri kullanılarak farklı YSA algoritmasıyla modeller oluşturulmuştur (Topuz, 2008). Yapay zekanın internet üzerindeki uygulama alanları üzerinde durulmuş, web sayfası sınıflandırılmıştır (Uğur ve Kınacı, 2006). Psikiyatrik tanılarının sınıflanmasında yapay sinir ağları yöntemi kullanılmıştır. Çok katmanlı algılayıcı ağlarının en yüksek doğruluk veren 5 öğrenme algoritması için teşhis doğruluğu kontrol edilmiş ve gerçek performansları gösterilmiştir (Etikan ve ark., 2009). Hane halkı bütçe anketi uygulayarak Türkiye’de kira değerlerini saptayan faktörler araştırılmıştır. İncelenen modelin lineer olmaması nedeniyle yapay sinir ağları (YSA) alternatif bir yöntem düşünülmüştür. Araştırmada yapay sinir ağları ve hedonik regresyon modelinin yeterliliği kıyaslanmış ve konutların kira fiyatlarının tahmin edilmesinde yapay sinir ağları tercih edilmiştir (Selim ve Demirbilek, 2009). Yapay sinir ağlarının örüntü tanıma, işaret işleme, sistem tanılama ve doğrusal olmayan denetim alanlarında kullanılmış çeşitli çalışmalar bulunmaktadır (Efe ve Kaynak, 1999; Efe ve ark., 1999).

Bu çalışmanın amacı, yapay sinir ağları analiz edilerek Türkiye’de ördek varlığının modellenmesi ve tahmin edilmesidir.

2. Materyal ve Metot

Çalışmada kullanılan verileri, Türkiye İstatistik Kurumu (TÜİK)’nin www.tuik.gov.tr web sitesinden derlenen “Türlerine göre kümes hayvanları sayısı” başlığı altında ördek sayıları oluşturmıştır. Çalışmada, 1991-2020 yılları arası veriler kullanılmış ve yapay sinir ağları (YSA) ile analiz edilmiştir. Uygun modeller belirlendikten sonra 2021-2025 dönemi ördek sayısı öngörüsü yapılmıştır.

Yapay sinir ağları (YSA), deneme yoluyla öğrenme ve genelleştirme yapmaktadır. Son zamanlarda gerçekleşen önemli yaklaşımlardan biri YSA kullanarak geleceği tahmin etmedir. Aynı zamanda veriler arasındaki karmaşık ilişkileri ortaya çıkarma işlemi YSA ile yapılabilir. Öğrenme, optimizasyon, analiz, sınıflandırma, genelleme ve ilişkilendirme konularında da YSA iyi bir performans göstermektedir (Öztemel, 2012).

YSA genellikle çok farklı şekillerde oluşturulan enformasyon verilerinin çok hızlı bir biçimde tanımlayarak anlaşılmasını sağlar. Böylece, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ve varsayıma gerek kalmadan, lineer olmayan modellemesini gerçekleştirmektedir (Kaastra ve Boyd, 1996).

YSA’nın çalışmasına temel oluşturan en küçük birimlere yapay sinir hücresi denir. Yapay sinir hücresi beş ana bileşene sahiptir. Bu bileşenler girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış bileşenleridir.

Girdiler, bir yapay sinir hücresine dış dünyadan gelen bilgilerden ibarettir. Dış dünyadan alınan bilgiler giriş olarak yapay sinir hücrelerine aktarılır (Özveren, 2006).

Ağırlıklar bir yapay hücreye gelen bilginin nöron üzerindeki etkisini ifade eder (Öztemel, 2012). Ağırlıklar yapay sinir aracılığıyla alınan girişlerin sinir üzerindeki etkisini gösteren katsayılardır ve $(w_1, w_2, w_3, \dots, w_i)$ ile ifade edilir (Elmas, 2003). Toplama-fonksiyonu bir hücreye gelen net girdiyi hesaplar. Bu fonksiyon aşağıdaki gibi formüle edilir.

$$z_i = \sum_{i=1}^n (w_{ij} x_i + b_j) \quad (1)$$

Burada w girdiler, x ağırlıklar, n ise girdi (proses elemanı) sayısıdır.

Toplam fonksiyonu kullanılarak elde edilen değer, lineer veya lineer olmayan türevlenebilir bir aktivasyon fonksiyonundan geçirilen işlem elemanının çıktısı aşağıdaki gibi ifade edilir (Yavuz ve Deveci, 2012).

$$y = f(z_i) = f\left(\sum_{i=1}^n (w_{ij} x_i + b_j)\right) \quad (2)$$

2.1. Aktivasyon fonksiyonları

Aktivasyon fonksiyonu, nöron davranışını belirleyen önemli etmenlerden biridir (Efe ve Kaynak, 2000). YSA’da nöronun çıkış genliği, istenilen değerler arasında sınırlanır. Genel olarak $[0, 1]$ veya $[-1, 1]$ arasındaki değerlerden oluşur (Sağıroğlu ve ark., 2003). Aktivasyon fonksiyonu hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Aktivasyon fonksiyonu için genelde lineer olmayan bir fonksiyon kullanılır (Çayıroğlu, 2015). Genel olarak en yaygın kullanılan aktivasyon fonksiyonları doğrusal (lineer), sigmoid, bipolar sigmoid ve hiperbolik tanjant aktivasyon fonksiyonlarıdır.

Doğrusal aktivasyon fonksiyonu, doğrusal problemleri çözmek için aktivasyon fonksiyonu doğrusal bir fonksiyon olarak kullanılabilir. Toplama fonksiyonundan elde edilen sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısını oluşturur.

$$F(NEt) = A * NEt \quad (3)$$

Burada A, sabit bir sayıdır.

Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyon olup, girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir ve aşağıdaki gibi ifade edilir (Çayıroğlu, 2015).

$$F(NEt) = \frac{1}{1 + e^{-NEt}} \quad (4)$$

Bipolar Sigmoid aktivasyon fonksiyonu hiyerarşik kademeli bir ağ yapısı oluşturmak için geliştirilmiş bipolar aktivasyon fonksiyonunu kullanma fırsatı sunar. Kısaca, geliştirilmiş bipolar sigmoid aktivasyonu kullanılmıştır. Bu etkinleştirme işlevi, ağırlıklarının -1 ve $+1$ aralığında tutan bir gösterim seçerek hatayı en aza indirmek için tasarlanmıştır. Bu fonksiyon,

$$F(NEt) = \frac{1 - e^{-2NEt}}{1 + e^{-2NEt}} \quad (5)$$

şeklindedir (Kaur ve Gupta, 2020).

Hiperbolik tanjant aktivasyon fonksiyonu, sigmoid fonksiyonuna benzer yapıdadır. Ancak hiperbolik tanjant fonksiyonuna ait çıkış değerleri ise -1 ile $+1$ aralığındadır (Çayıroğlu, 2015). Bu fonksiyon,

$$F(NEt) = \frac{e^{NEt} - e^{-NEt}}{e^{NEt} + e^{-NEt}} \quad (6)$$

şeklinde hesaplanır (Öztemel, 2012; Alp ve Öz, 2019).

2.2. Geri yayılım algoritması seçimi

YSA yönteminde önemli problemler geri yayılım algoritması ile çözülmüştür. Geriye yayılım ağında ara katmanlardaki birimlerinin hatalarının, çıktı katmanındaki birimlerin hatalarının geriye yayılması ile belirlenir. Bu nedenle, yöntem Geri Yayılım Öğrenme Algoritması olarak isimlendirilmiştir. Geri yayılım algoritmada sigmoidal transfer fonksiyonu ile doğrusallıktan arındırılmış birden fazla çıktı birimi kullanılabilir. Çıktı birimleri $[-1,1]$ aralığında reel sayılar üretebilir (Kröse ve Smagt, 1996).

2.3. Model uygunluk kriterleri

YSA model performansı genellikle Hata Kareler Ortalaması (MSE) ve Ortalama Mutlak Hata (MAE) ile tespit edilir. MSE aşağıdaki gibi hesaplanır (Singh ve ark., 2009).

$$MSE = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n} \quad (7)$$

MAE ise aşağıdaki gibi hesaplanır.

$$MAE = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n} = \frac{\sum_{i=1}^n |\varepsilon_i|}{n} \quad (8)$$

Burada Y_i : Bağımlı değişkenin gözlenen değerleri, $\hat{Y}_i$: Bağımlı değişkenin tahmini değerleri, n ise gözlem sayısıdır.

3. Bulgular ve Tartışma

YSA giriş, gizli ve çıktı tabakalarının sayıları sırasıyla 1-12-1 olarak belirlenmiş olup, geri yayılma öğrenimi (Back Propagation Learning) ile 1000 iterasyonlu olarak uygulanmıştır. YSA yönteminde ördek popülasyonu için 4 farklı aktivasyon fonksiyonları kullanılmıştır. Bunlar; semi lineer, sigmoid, bipolar sigmoid ve hiperbolik tanjant aktivasyon fonksiyonlarıdır. En uygun aktivasyon fonksiyonun kullanıldığı modeli belirlemek için MSE ve MAE istatistikleri kullanılmıştır. Ördek sayısı için kullanılan farklı aktivasyon fonksiyonlarına göre hesaplanan MSE ve MAE istatistikleri Tablo 1’de verilmiştir.


Tablo 1. Aktivasyon fonksiyonlarında hesaplanan MSE ve MAE deęerleri

Aktivasyon fonksiyonu	MSE	MAE
Doęrusal fonksiyon	29.070.704.899,239	87.663,588
Sigmoid fonksiyon	70.262.492.220,925	208.089,912
Bipolar sigmoid fonksiyon	30.591.664.564,726	93.862,621
Hiperbolik tanjant fonksiyonu	25.294.373.727,547	80.242,634

Ördek sayısı için YSA yönteminde kullanılan aktivasyon fonksiyonlarında en düşük MSE ve MAE deęeri hiperbolik tanjant aktivasyon fonksiyonunda elde edilmiştir. $MSE=25.294.373.727,547$ ve $MAE=80.242,634$ bulunmuştur (Tablo 1). Dolayısıyla hiperbolik tanjant aktivasyon fonksiyonu kullanılarak elde edilen YSA analizi deęerlendirilmiştir.

YSA yöntemi sonucunda tahmin edilen ve gözlenen deęerlerle birlikte hata terimleri deęerleri Tablo 2’de sunulmuştur.

Ördek varlığı tahmini için YSA uygulaması sonucu gerçek ve tahmini deęerlerin seyri ve dağılımı grafięi Şekil 1’de verilmiştir.

**Şekil 1.** Gözlenen ve tahmin edilen deęerlerin grafięi

Şekil 1 incelendięinde, gözlenen deęerler ile tahmin edilen deęerler birbirine yakın olup uyum içindedir. Bu durum, özellikle 2000 yılından sonra daha belirgin olmuştur.


Tablo 2. Gözlenen, tahmini ve artık deęerler (residual)

Yıllar	Gözlenen	Tahmini deęerler	Artık deęerler
1991	1.112.015	NaN	NaN
1992	1.154.743	1.102.413	52.329,64
1993	1.171.961	1.146.093	25.867,85
1994	1.186.891	1.163.199	23.691,74


1995	1.199.925	1.177.789	22.136,09
1996	1.093.860	1.190.336	-96.476,1
1997	1.828.792	1.083.361	745.431,3
1998	1.339.468	1.589.222	-249.754
1999	1.294.824	1.312.973	-18.149,2
2000	1.104.176	1.276.110	-171.934
2001	913.748	1.094.221	-180.473
2002	832.091	883.885,8	-51.794,8
2003	810.910	792.333,7	18.576,25
2004	770.436	769.087,5	1.348,546
2005	656.409	725.610,3	-69.201,3
2006	525.250	612.617,8	-87.367,8
2007	481.829	505.995,4	-24.166,4
2008	470.158	476.886,8	-6.728,78
2009	412.723	469.587,8	-56.864,8
2010	396.851	436.813	-39.962
2011	382.223	428.648	-46.425
2012	356.730	421.451	-64.721
2013	367.821	409.637,2	-41.816,2
2014	399.820	414.665,1	-14.845,1
2015	398.387	430.146,9	-31.759,9
2016	413.841	429.421,8	-15.580,8
2017	491.561	437.402,4	54.158,62
2018	532.841	483.142,1	49.698,86
2019	519.575	511.403,3	8.171,716
2020	559.620	502.014,7	57.605,32

YSA uygulaması sonucu elde edilen hata terimlerinin grafiği Şekil 2’de sunulmuştur.


Şekil 2’de artık değerlerin rasgele dağıldıkları görülmüştür. Ördek sayısı gerçek değerleri ile artık değerlerin grafiği Şekil 3’te verilmiştir. Gerçek değerler ile artık değerler birbirinden bağımsız olup rasgele dağılmışlardır. Şekil 4’te ise artık değerlerle tahmin edilen değerlerin grafiği verilmiştir.



Şekil 2. Artık değerler grafiği



Şekil 3. Gerçek değerler ve artık değerlerin grafiği




Şekil 4. Tahmini değerler ve artık değerlerin grafiği

Bu aşamadan sonra 4 farklı aktivasyon sonuçlarına göre elde edilen 2021-2025 yılları arası ördek sayısı öngörüsü Tablo 3’te verilmiştir. En uygun bulunan hiperbolik tanjant fonksiyonuna göre elde edilen öngörü grafiği Şekil 5’te gösterilmiştir.

Tablo 3. Gelecek dönem için ördek sayısı öngörüsü

Yıllar	Doğrusal	Sigmoid	Bipolar sigmoid	Hiperbolik tanjant
2021	565 660	675 028	533 325	531 242
2022	571 032	714 859	518 178	510 256
2023	575 810	728 994	509 841	495 593
2024	580 059	734 056	505 370	485 779
2025	587 200	735 874	503 006	479 407



Şekil 5. Gelecek dönem için gerçekleşen değerler ve öngörü

Tablo 3'te görüldüğü gibi ördek sayısının 2021 yılında 531,242 olacağı bunu izleyen yıllarda bu değer azalarak 2025 yılında 479,407 olacağı tahmin edilmektedir.

Grzesiak ve ark. (2010), yapay sinir ağları ve MARS algoritmalarını kullanarak suni tohumlamada sorunlu olan inekleri belirlemişler ve riskli olanların elenmesini göstermişlerdir. İnekler iki gruba ayrılmıştır. Bunlar; Bir veya iki çiftleştirmeden sonra gebe kalanlar “iyi” ve gebelik için iki çiftleştirmeden fazlasına ihtiyaç olanlar “kötü” gruplarıdır. Suni tohumlamada problemi olan inekleri tespit etmek için belirli değişkenler kullanılmıştır. Her iki yöntemde de en önemli belirleme değişkeni buzağılama aralığıdır.

Zaborski ve Grzesiak (2011)'in çalışmasında ER α -BgII, ER α -SnaBI ve CYP19- PvuII genotipleri ile ilgili yapay sinir ağları uygulaması ile sürülerde zorlu doğum belirlenmiştir. Düve genotiplerinde Holstein-Friesian genlerinin yüzdesi, gebelik süresi, vücut durum skoru, buzağılama mevsimi, buzağılama yaşı ve genotip girdi değişkeni olmuştur. Çıktı değişkeni ise doğum zorluğudur. Zorluk derecesi kolay ve zor olarak sınıflanmıştır. Yazarlar düvelerde doğum zorluğunu en doğru sınıflandırmak için gizli tabakada 4 nöronlu çok tabakalı algılayıcı sinir ağlarını uygulamışlardır. Doğum zorluğunu doğru belirlemede en önemli faktörlerin gebelik süresi, vücut durum skor endeksleri arasındaki farklılık, düve genotiplerinde Holstein-Friesian genlerinin yüzdesi ve ER α -BgII, CYP19-PvuII genotipleri olduğu görülmüştür.

Grzesiak ve ark. (2003) bir barınaktaki 305 günlük süt verimi ortalaması, sağımda geçen gün sayısı, 1., 2., 3. ve 4. periyodunda süt verim ortalaması ve buzağılama ayının Holstein-Friesian ineklerindeki süt verimine etkisini tahmin etmek için yapay sinir ağları ve çoklu regresyon modeli uygulamışlardır. Yazarlar süt tahmininde yapay sinir ağlarının daha uygun olduğunu açıklamışlardır.

Çelik (2021)'in çalışmasında, Türkiye’de deve sayısını tahmin etmek için yapay sinir ağları ve zaman serileri analizi uygulanmıştır. 1961-2020 dönemi için 1000 iterasyonlu 12 gizli katmanlı, 12 işlem elemanlı (12-12-1) ve Levenberg–Marquardt geri yayılım algoritmali (trainlm) bir ağ kurularak analiz

edilmiştir. Analiz sonucunda, 2021-2025 yılları arası deve sayısı öngörüsü elde edilmiş ve deve sayısının bu dönemde inişli çıkışlı bir seyir göstereceği beklenmektedir.

4. Sonuç

Bu çalışmada yapay sinir ağları ile Türkiye’de ördek sayısı modellenmiştir. Girdi değişkeni yıllar (1991-2020) olup, çıktı değişkeni ise ördek sayısı kullanılmıştır. Aktivasyon fonksiyonlarından semi lineer, sigmoid, bipolar sigmoid ve hiperbolik tanjant fonksiyonları kullanılmıştır ve bunlar karşılaştırılmıştır. Aktivasyon fonksiyonları en iyiden en kötüye doğru hiperbolik tanjant > lineer > bipolar sigmoid > sigmoid şeklinde sıralanmıştır. Kısaca, en uygun aktivasyon fonksiyonu hiperbolik tanjant fonksiyonu olmuştur. Çünkü, bu aktivasyon fonksiyonunda en küçük MSE ve MAE değerleri elde edilmiştir.

Elde edilen sonuçlar, uygulanan YSA yönteminin iyi tahminler verdiğini ortaya koymuştur. Eğitim, test ve doğrulama aşamalarındaki düşük MSE ve MAE değerleri de bunu göstermektedir.

Hiperbolik tanjant fonksiyonu kullanılarak analiz edilen YSA ile, Türkiye’de 2021-2025 döneminde ördek popülasyonunun 479,407 ile 531,242 arasında olacağı beklenmektedir. 2020 yılına göre gelecek 5 yıllık periyotta ördek popülasyonunda düşüş beklenmektedir. 5 yıl sonra bu düşüşün %14,33 olacağı beklenmektedir. Geleceğe ait tahmin çalışmalarında yapay sinir ağları ve alternatif teknikleri kullanarak hayvancılık verilerinde iyi sonuçlar vereceği umulmaktadır.

Çıkar Çatışması Beyanı

Makale yazarı herhangi bir çıkar çatışması olmadığını beyan eder.

Araştırmacıların Katkı Oranı Beyan Özeti

Yazar makaleye tam olarak katkı sağlamıştır.

Kaynakça

Alp S., Öz E. Makine öğrenmesinde sınıflandırma yöntemleri ve R uygulamaları. Nobel Akademik Yayıncılık 2019, Ankara.

Ataseven B. Yapay sinir ağları ile öngörü modellemesi. Öneri Dergisi 2013, 10(39): 101-115.

Benli Y. Finansal başarısızlığın tahmininde yapay sinir ağı kullanımı ve İMKB’de bir uygulama. Muhasebe Bilim Dünyası Dergisi 2002, 4(4): 17-30.

Çayiroğlu İ. İleri Algoritma Analizi-5 Yapay Sinir Ağları, 2015

<http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf>

- Çelik Ş. Modeling and estimation of camel population in Turkey with time series analysis and Artificial Neural Networks. *International Journal of Research in Engineering and Science (IJRES)* 2021, 9(5): 38-44.
- Efe MÖ., Kaynak O. A Comparative study of neural network structures in identification of nonlinear systems. *Mechatronics* 1999; 9(3): 287-300.
- Efe MÖ., Abadoğlu E., Kaynak O. Analysis and design of a neural network assisted nonlinear controller for a bioreactor. *International Journal of Robust and Nonlinear Control* 1999; 9(11): 799-815.
- Efe Ö., Kaynak O. Yapay sinir ağları ve uygulamaları, Boğaziçi Üniversitesi Yayını, 2000, İstanbul
- Elmas Ç. Yapay sinir ağları, Birinci Baskı, Seçkin Yayıncılık 2003, Ankara
- Elmas Ç. Yapay zeka uygulamaları. Seçkin Yayıncılık San ve Tic. A. Ş., 2007, 425 s
- Etikan İ., Cumurcu BE., Çelikel FÇ, Erkorkmaz Ü. Yapay sinir ağları yöntemi ve bu yöntem kullanılarak psikiyatrik tanılarının sınıflandırılması. *Türkiye Klinikleri Tıp Bilimleri Dergisi* 2009; 29(2): 314-320.
- Grzesiak W., Lacroix R., Wójcik J., Blaszczyk P. A comparison of neural network and multiple regression prediction for 305-day lactation yield using partial lactation records. *Canadian Journal of Animal Science* 2003; 83: 307-310.
- Grzesiak W., Zaborski D., Sablik P., Zukiewicz A., Dybus A., Szatkowska I. Detection of cows with insemination problems using selected classification models. *Computers and Electronics in Agriculture* 2010, 74(2): 265-273.
- Güzeller CO., Aksu G. MATLAB Yapay zeka ve istatistik uygulamaları. Maya Akademi, 2018; Ankara. ISBN: 978-605-4515-68-4
- Kaasra I., Boyd M. Designing a neural network for forecasting financial and economic time series. *Neurocomputing* 1996, 10: 215-236
- Kaur J., Gupta N. Bipolar sigmoid algorithm for designing constructive neural network. *International Journal on Emerging Technologies* 2020; 11(2): 991-996.
- Kröse B., Smagt, P. V. D. An introduction to neural networks. Eight Ed., The University of Amsterdam, 1996
- Öztemel E. Yapay sinir ağları. Papatya Yayıncılık 2012, İstanbul.
- Özveren U. Pem yakıt hücrelerinin yapay sinir ağları ile modellenmesi. Yayınlanmamış Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü 2006, İstanbul
- Sağiroğlu Ş., Beşdok E., Erler M. Mühendislikte yapay zeka uygulamaları-I Yapay Sinir Ağları 2003. Ufuk Kitap Yayıncılık.
- Selim S., Demirbilek A. Türkiye'deki konutların kira değerinin analizi: Hedonik model ve yapay sinir ağları yaklaşımı. *Aksaray Üniversitesi İİBF Dergisi* 2009, 1(1): 73-90.
- Singh KP., Basant A., Malik A., Jain G. Artificial neural network modeling of the river water quality- A case study. *Ecological Modelling* 2009, 220(6): 888-895.

- Topuz S. İstanbul ilindeki toplu taşıma yolculuk taleplerinin yapay sinir ağlarıyla modellenmesi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, 2008, İstanbul.
- TÜİK. Hayvansal Üretim İstatistikleri. Türlerine göre kümes hayvanları sayısı. Türkiye İstatistik Kurumu, www.tuik.gov.tr, 2019.
- Uğur A., Kınacı AC. Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması. inet-tr'06 - XI. "Türkiye'de İnternet" Konferansı Bildirileri 21-23 Aralık 2006, TOBB Ekonomi ve Teknoloji Üniversitesi, Ankara
- Yavuz S., Deveci M. İstatiksel normalizasyon tekniklerinin yapay sinir ağın performansına etkisi. Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 2012, 40: 167-187.
- Zaborski D., Grzesiak W. Detection of heifers with dystosia using artificial neural networks with regard to ER α -BgII, ER α -SnaBI and CYP19-PvuII genotypes. Acta Scientiarum Polonorum Zootechnica 2011; 10(2): 105-116