



Fındık Fiyatlarının Yapay Sinir Ağları ile Tahminlenmesi: Türkiye Örneği

Mehmet Akif KARA^{1*}

Giresun Üniversitesi, TÜRKİYE

Doi: 10.55024/buyasambid.1394033

MAKALE BİLGİSİ

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 21.11.2023

Düzeltilme tarihi: 11.01.2024

Kabul tarihi: 11.01.2024

Yayın tarihi: 07.07.2024

Anahatar Kelimeler:

Yapay Sinir Ağları, Öngörü,
Fındık, Fiyat Tahmini.

*¹Mehmet Akif KARA

E-mail address:

akifkara28@gmail.com

Orcid: 0000-0003-4308-9933

ÖZET

Fındık hiç kuşkusuz Türkiye için önemli bir tarım ürünüdür. Fındık fiyatlarının tahminlenmesi fiyatın belirlenmesi, ürünün pazarlanması vs. açıdan çok önemlidir. Fiyat tahminlemede birçok yöntem kullanılmaktadır. Bu yöntemlerden birisi de yapay zekânın bir alt türü olan yapay sinir ağlarıdır. Bu çalışmada yapay sinir ağları ile fındık fiyatının tahminlenmesi yapılmıştır. Çalışmanın amacı fiyat tahminlenmesinde yapay sinir ağları kullanılarak bir model ortaya konulması ve uygulamasının gerçekleştirilmesidir. Alan yazındaki çalışmalardan farkı da bu yöntem ile fındık fiyatı tahminlenmesi üzerine uygulanmasıdır. Çalışmada, Giresun Ticaret Borsası'ndan elde edilen 2000-2023 yıllarına ait aylık fındık fiyatlarından oluşan 214 veriden oluşan zaman serisi kullanılmıştır. Çalışmanın analizi için MATLAB Neural Network Toolbox aracı kullanılmıştır. Çalışmada kullanılan veri seti tek değişkenli zaman serisi olduğu için Nonlinear Autoregressive (NAR) ile analiz gerçekleştirilmiştir. Çalışma neticesinde fındık fiyatlarının tahminine ilişki yapay sinir ağı modeli kurulmuş ve 0.33 derecelik ortalama hata ile tahminleme yapılmıştır.

2024 Batman Üniversitesi. Her hakkı saklıdır.

Forecasting Hazelnut Prices with Artificial Neural Networks: The Case of Turkey

Mehmet Akif KARA^{1*}

Giresun University, TURKEY

Doi: 10.55024/buyasambid.1394033

ARTICLE INFO

Article Type: Research Article

Article history:

Received: 11.01.2024

Received in revised form

Accepted: 11.01.2024

Available online: 07.07.2024

ABSTRACT

Hazelnut is undoubtedly an important agricultural product for Turkey. Forecasting hazelnut prices is very important in terms of price determination, marketing of the product, etc. Many methods are used in price forecasting. One of these methods is artificial

Keywords:
Artificial Neural Networks,
Forecasting, Hazelnut, Price
Forecasting.

*¹Mehmet Akif KARA
E-mail address:
akifkara28@gmail.com
Orcid: 0000-0003-4308-9933

neural networks, which is a subtype of artificial intelligence. In this study, hazelnut price forecasting is done with artificial neural networks. The aim of the study is to present a model using artificial neural networks in price forecasting and to realize its application. The difference from the studies in the literature is that it is applied on hazelnut price forecasting with this method. In the study, a time series of 214 data consisting of monthly hazelnut prices for the years 2000-2023 obtained from Giresun Commodity Exchange was used. MATLAB Neural Network Toolbox tool package was used for the analysis of the study. Since the data set used in the study is a univariate time series, the analysis was performed with Nonlinear Autoregressive (NAR). As a result of the study, an artificial neural network model was established for the prediction of hazelnut prices and prediction was made with an error margin of 0.33.

2024 Batman University. All rights reserved

1. GİRİŞ

Türkiye tarımında en önemli ürünlerden birisi hiç kuşkusuz fındıktır. Fındık, üretim yoğunluğunun çoğunluğunu Karadeniz bölgesinde bulundurmaktadır. Bu bölgede yaşayan hemen herkesin fındık üretimi ile doğrudan ilişkisi bulunmakta ve bölgenin en önemli geçim kaynağı olarak karşımıza çıkmaktadır. Bölge halkı için önemli ve birincil geçim kaynağı olan fındık üretim alanları iki standart gruba ayrılmıştır. İlk standart grupta; Giresun, Ordu, Trabzon, Rize ve Artvin yer almaktadır. İkinci standart grupta ise; Samsun, Sinop, Kastamonu, Bolu, Düzce, Sakarya, Zonguldak ve Kocaeli illeri yer almaktadır (Hazneci, Naycı ve Çelikkan, 2022). Türkiye’de fındık üretimi/tarımı genel itibarıyla aile işletmeciliği şeklinde yapılmaktadır (Karaman, 2022:23).

Fındık ürünü çok farklı alanlarda kullanılmaktadır. Bu nedenle Dünya ekonomisinde de önemli bir tarım ürünü olarak karşımıza çıkmaktadır. Kuruyemiş, tatlı, helva, çikolata, fırıncılık vs. gibi sektörlerde hammadde olarak kullanılmaktadır. Dolayısı ile sıradan bir tarım ürünü olmasının ötesinde önemli bir sanayi hammaddesidir (Kırhasanoğlu, 2022: 166). Bu bağlamda değerlendirildiğinde fındık fiyatlarının tahmin edilmesi stratejik politikaların gerçekleştirilebilmesi için elzemdir. Hem Türkiye’nin diğer üretici ülkelerle rekabeti hem de fındık fiyatının belirlenmesi sürecine müdahil olabilmesi için stratejik politikaların belirlenmesi gerekmektedir.

24 Ocak 1980 yılı itibarıyla uygulanmaya konulan neoliberal ekonomi politikaları birçok alan gibi tarım alanını da doğrudan etkilemiştir (Öztürk, Nas, İçöz, 2008). Tarım alanında liberalizasyon politikalarının giderek yoğunlaşması ve pazar odaklı politikaların uygulanması, tarımsal ürünlerde fiyat oynaklığı (volatilité) konusunda bir çok tartışmayı beraberinde getirmiştir. Koşullara bağlı olarak oluşan ürün fiyatlarındaki oynaklığın varlığı da tarım üreticisi için verimlilik, yatırım ve birçok konuda karar alma sürecinde önemli bir unsur haline gelmiştir (Yang, Haigh ve Leathem, 2001: 593). Fındık fiyatına etki eden birçok faktör söz konusudur. Yapılan araştırmalar neticesinde fındık üretim miktarı (Hüsnoğlu, 2018), fındık ihracat miktarı (Kırhasanoğlu, 2022), Pazar yoğunlaşması ve Pazar gücü (Spaulding, Tulum, Sahgaian ve Özertan, 2009), gibi değişkenler fındık fiyatları üzerinde etkili olmaktadır.

Özellikle, dünyada en yaygın olarak yetiştiriciliği yapılan sert kabuklu meyve grubunda bademden sonra fındık yer almaktadır. Fındık ürünü bu özelliğinin yanı sıra Türkiye açısından tarım sektörünün önemli ürünlerinden birisidir. Fındık ihracatından ülkeye önemli oranda döviz geliri sağlanmaktadır. Aynı zamanda, Türkiye, dünya fındık üretiminde lider ülke konumunda bulunmaktadır (Bozoğlu ve Kabaoğlu, 2023). Tablo 1’de ülkelerin fındık üretim miktarları gösterilmektedir.

Tablo 1. Dünya fındık üretimi (2021)

Ülke	Üretim (Ton)	Kişi Başına Üretim (Kg)	Yüzölçümü (Hektar)	Verim (Kg/Hektar)
Türkiye	515.000	6,373	728.381	707
İtalya	132.699	2,196	78.593	1.688,4
Azerbaycan	52.067	5,26	39.021	1.334,3
ABD	46.270	0,141	17.806	2.598,6
Çin Halk C.	24.790	0,018	11.775	2.105,3
Gürcistan	17.000	4,558	9.484	1.792,5
İran	15.839	0,194	17.957	882
Fransa	14.988	0,223	6.644	2.255,9
Şili	9.019	0,513	13.104	688,3
İspanya	8.033	0,172	13.505	594,8
Polonya	6.642	0,173	3.716	1.787,4
Sırbistan	5.428	0,775	4.363	1.244,1
Kırgızistan	4.346	0,689	6.824	636,9
Özbekistan	3.711	0,114	3.219	1.152,8
Hırvatistan	1.753	0,418	4.810	364,4
Beyaz Rusya	1.275	0,135	2.057	619,8
Romanya	1.036	0,053	715	1.449
Tacikistan	997	0,112	802	1.242,7
Yunanistan	810	0,075	420	1.928,6
Bulgaristan	393	0,056	799	491,9
Ermenistan	342	0,115	192	1.781,3
Moğolistan	326	0,101	358	910,3
Moldova	267	0,075	515	519,4
Portekiz	240	0,023	348	689,7
Slovenya	223	0,108	119	1.873,9
Kamerun	167	0,007	149	1.117,1
Macaristan	134	0,014	348	385,1
Tunus	46	0,004	50	918,1
Kıbrıs	23	0,027	17	1.352,9
Ukrayna	20	0	100	200

Kaynak: FAO (2021) akt. Kara, 2022).

Fındık endüstrisi bu bağlamda üreticisinden tüketicisine ve aracısına kadar birçok sektörle doğrudan ilişki kurmaktadır (Kara, 2022: 105). Fındık fiyatlarının belirlenmesi süreci de bu paydaşların faaliyetlerini doğrudan etkilemektedir. Hem üretici açısından hem de satıcı/işletmeci açısından fiyatların makul seviyelerde olması gerekmektedir. Aynı zamanda tarımsal ürünlerin fiyatlarını tahmin etmek, hem ilgili paydaşlar hem de politika yapıcılar açısından her zaman önemli bir yerdedir (Wang, Wang, Li ve Zhou (2022).

Fındık fiyatlarının tahminlenmesine ilişkin alan yazında az sayıda çalışma vardır. Fındık üzerine olan çalışmalar daha çok üretim miktarının tahmini ya da fındık fiyatı ile farklı değişkenler arasındaki ilişkinin ekonometrik olarak belirlenmesine dayalıdır. Buna karşı farklı tarım ürünlerinin fiyatlarının tahminine ilişkin farklı yöntemlerle yapılmış çalışmalar vardır. Özer ve Yavuz (2014) çalışmalarında literatürde sıklıkla kullanılan Box Jenkins modeli yardımıyla fındık fiyatlarının tahminlenmesini gerçekleştirmiştir. Khamis ve Abdullah (2014) yılında yaptıkları çalışmada, geri yayımlı sinir ağı ve NARX modellerini kullanılarak gelecekteki buğday fiyatının tahmin edilmesi amaçlanmıştır. Can ve Gerşil (2018) yaptıkları çalışmada Manisa ilinde pamuk fiyatlarını zaman serisi analizi ve yapay sinir ağı teknikleri ile tahminlemiştir. Şeyranlıoğlu (2022) fındık fiyatları ile döviz kuru arasındaki ilişkiyi incelemiştir. Bayyurt ve Deveci Kocakoç (2023) yapay sinir ağları NARX ile fındık üretim miktarını tahminlemiştir. Wang (2023) çalışmasında Çin'de son 10 yılda domuz eti satış fiyatını ve yenilenebilir sarımsak talebini etkileyen faktörleri geliştirilmiş RBF sinir ağı modeli ile tahmin etmektedir. Xu ve Zhang (2023), Çin'de mısır fiyatlarını 1 Ocak 2010-10 Ocak 2020 döneminde haftalık toptan fiyat endeksi için tahmin etmiştir. Sonuç modeli doğru ve istikrarlı sonuçlara yol açmış ve eğitim, geçerlilik ve test için sırasıyla %1.05, %1.08 ve %1.03'lük göreceli kök ortalama kare hataları üretmektedir. Yapay sinir ağları ise tahmin problemlerinde son yıllarda sıklıkla kullanılmaktadır. Alhendi, Al-Sumaiti,

Marzband, Kumar ve Diab (2023), geliştirilmiş Markov zinciri ile yapay sinir ağı kullanarak kısa vadeli yük ve fiyat tahminini hesaplamıştır. Çalışma sonucunda geliştirilmiş YSA-MC modelinin daha etkili ve doğru tahmin yaptığı bulunmuştur. Kurani, Doshi, Vakharia ve Shah (2023) yaptıkları araştırmada hisse senedi tahmininde yapay sinir ağlarını kullanmıştır. Çalışmada geri yayılım algoritması ve çok katmanlı ileri besleme ağının bir kombinasyonu olan hibrit YSA modelleri uygulanmıştır. Kumari, Goswami ve Pundir (2023) yılında Hindistan’da muz fiyatlarının tahmini için YSA kullanmış ve sonuçları diğer yöntemlerle karşılaştırmıştır. Tekrarlayan sinir ağı (RNN) bu çalışmada çeşitli istatistiksel ve makine öğrenimi teknikleriyle karşılaştırıldığında doğru fiyatları tahmin etmede diğer modellerden daha iyi performans göstermektedir. ARIMA, SARIMA, ARCH GARCH ve ANN gibi diğer metodolojilerin doğruluğu beklentilerin altında kalmaktadır. Saplıoğlu ve Çimen (2010) ise çalışmalarında yapay sinir ağlarını kullanarak günlük yağış miktarını tahmin etmiştir. Çalışma verileri ABD Portland bölgesinde bulunan yağış gözlem istasyonlarından elde edilen, günlük yağış verileridir. Çalışma sonucunda, YSA modeli en küçük hata değerlerini vermiş ve standart hesap yöntemlerine göre daha üstün olduğu ortaya konulmuştur. Akkan, Mutlu ve Baş (2022), 2010-2020 yılları arasında Rize istasyonundan elde edilen aylık ortalama deniz suyu sıcaklığına ait zaman serisinin tahminini ileri beslemeli yapay sinir ağı ile gerçekleştirmiştir. Çalışma sonunda ileri beslemeli yapay sinir ağları en uygun öngörü performansına sahip yöntem olmuştur. Szoplik ve Muchel (2023) doğal gaz bileşimlerinin tahmini için yapay sinir ağları metodunu kullanmıştır. Tahminde 8760 gerçek veri üzerinden model eğitimi gerçekleştirilmiştir. Şenol ve Denizhan (2023) yaptıkları çalışmada kripto para değerinin tahmininde yapay sinir ağları ve regresyon analizini kullanmıştır. Çalışma sonrasında tahmini değer ile gerçek değerler arasındaki karşılaştırmada yapay sinir ağları ile yapılan tahminin daha başarılı sonuç verdiği ortaya konulmuştur.

Bu çalışmada da MATLAB programı Neural Network Toolbox aracı kullanılarak fiyat tahmininde bulunulacaktır. Çalışmanın amacı fiyat tahmininde yapay sinir ağları kullanılarak bir model ortaya konulması ve uygulamasının gerçekleştirilmesidir. Alan yazındaki çalışmalardan farkı da bu yöntem ile fındık fiyatı tahmini üzerine uygulanmasıdır. Oluşturulan model ile birlikte hem politika yapıcılar, hem işletmeler hem de fındık piyasasında faaliyet gösteren paydaşlar açısından geleceğe ilişkin bir projeksiyonun ortaya konulması da çalışmanın ikincil amaçları arasında yer almakta ve literatüre katkı sunacağı düşünülmektedir.

2. YÖNTEM

2.1. Yapay Sinir Ağları

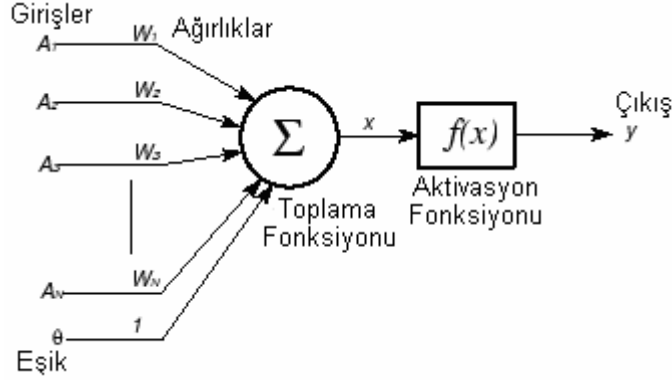
Yapay Sinir Ağları (YSA) yapay zekâ yöntemlerinden birisidir. Yapay sinir ağı, insan beynindeki biyolojik nöronların mimarisinden esinlenmiştir. İlk yapay sinir ağı modellemesi 1943 yılında bir nörobilimci olan Warren McCulloch ve bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. Basit biyolojik sinir sistemlerin çalışma şekillerinin taklit edilerek oluşturulan matematiksel modellemelerdir (Eğrioğlu, Yolcu ve Baş, 2019:1).

YSA yönteminde örnekler kullanılarak öğrenme işlemi gerçekleştirilir. Bilinen hesaplama tekniklerinden farklılaşan bir yöntem önermektedir. Bu yöntemi öne çıkaran çeşitli özellikleri söz konusudur. Bu özellikler; bulunduğu ortama uyum sağlayabilmesi, adapte olabilmesi, eksik veri ile çalışabilmesi, belirsizlik durumunda karar verebilmesi ve hata toleransının bulunmasıdır (Eğrioğlu, Yolcu ve Baş, 2019). Bu bağlamda ele alındığında yaşanan her alanında başarılı bir şekilde uygulanması mümkündür. Keza, son yıllarda, özellikle sınıflandırma, sinyal filtreleme, örüntü tanımlama, veri sıkıştırma ve optimizasyon konularında YSA güçlü sonuçlar üreten teknikler arasında yer almaktadır (Eğrioğlu, Aladağ, Yolcu ve Baş, 2015; Cansu, Kölemen, Karahasan, Baş ve Eğrioğlu, 2023).

YSA için kullanılan veri seti eğitim, geçerlilik ve test verisi olarak parçalanır. Eğitim verisi, YSA’nın optimal ağırlıklarını belirlemek için kullanılırken; geçerlilik kümesi ise eğitimi erken durdurmak için aşırı belirleme probleminde çözüm bulmak amacıyla kullanılmaktadır. Test verisi ise

mimarinin nihai performansının diğer mimari yapı veya diğer yöntemler ile karşılaştırılmasında kullanılabilir. YSA girdi, gizli ve çıktı olmak üzere üç ana tabakadan oluşmaktadır. Her bir tabaka ise nöronlardan oluşmaktadır. Nöronların birbirleri ile bağlantıları ağı oluşturmaktadır. Şekil 1’de üç ana katmandan oluşan yapay sinir ağı bağlantıları verilmiştir.

Şekil 1. Yapay sinir ağı bağlantıları



Kaynak: www.akanesen.com

Yapay sinir ağları için çeşitli programlama dillerinde birçok kütüphane ve araç geliştirilmiştir. Bunlar arasında öne çıkanlar Stuttgart Neural Network Simulator (SNNS), Fast Artificial Neural Network Library (FANN), Java Object Oriented Neural Engine (JOONE) ve MATLAB Neural Network Toolbox gibi araçlardır (Arı ve Berberler, 2017).

Çalışmada yapay sinir ağları ile uygulama yapmakta kullanılan araçlar arasında yer alan MATLAB Neural Network Toolbox aracı kullanılmıştır. Bu araç paketi içerisinde bulunan zaman serilerinin YSA ile çözümlenmesinde Neural Time Series aracı kullanılmıştır. Çalışmada kullanılan veri seti tek değişkenli zaman serisi olduğu için Nonlinear Autoregressive (NAR) kısmı kullanılmıştır. NAR; $y(t)$ zaman serisi, kendi gecikmeli değişkenleri yardımıyla çözümlenmektedir. Elde edilen model doğrusal olmayan bir otoregressif model olacaktır. Literatürde sıkça kullanılmaktadır (Eğrioğlu, Yolcu ve Baş, 2019; Çakır Sönmez, 2019). Neural Fitting Tool gizli katmanda sigmoid aktivasyon fonksiyonu, çıktıda ise doğrusal aktivasyon fonksiyonunu kullanan birçok katmanlı algılayıcı mimarisi ile çözüm yapmaktadır. Eğitim algoritması olarak ise LM (Levenberg-Marquardt) algoritması tercih edilmiştir. Bu yöntem ikinci derecede eğitim algoritmasıdır. Geri yayılım algoritmasından farklı olarak ağırlıklar bir devirde bir kez değiştirilmektedir (Khosravi, Barghinia ve Ansarimehr, 2006).

Bu çalışmada veri seti eğitim, geçerlilik ve test kümesi olarak parçalanmıştır. Bunun nedeni ise eğitim ve geçerlilik kümeleri optimum ağırlıklarının belirlemektir. Aynı zamanda geçerlilik kümesini kullanarak, eğitim sürecinin ağırlık ezberlemesini engelleyecek şekilde durdurulması sağlanmaktadır.

3. BULGULAR

Verilerin çözümlenmesi sürecinde ilgili araç kullanılırken karar verilmesi gereken önemli bir parametre gizli tabaka birim sayısı olmaktadır. Her farklı gizli tabaka sayısı için YSA şekil olarak farklı bir doğrusal olmayan model ile çalışılmasına imkân vermektedir. Bu nedenle uygun gizli tabakadaki birim sayısının belirlenmesi kritik olmaktadır. Farklı girdi ve katman sayılarına göre hata oranı düşük model belirlenmektedir. En iyi test kümesi performansı üreten model bizim için tercih edilmesi gereken model olmaktadır (Eğrioğlu, Yolcu ve Baş, 2019).

Çalışmada 2000-2023 yılları arasında Giresun Ticaret Borsası’ndan elde edilen fındık satış fiyatlarını içeren 214 veri kullanılmıştır. Çalışmadaki MSE değerleri Tablo 2’de verilmiştir. MSE

değerleri birim başına hatanın karesini gösteren ve YSA’larda kullanılan temel hata ölçütlerinden birisidir (Eğrioğlu, Yolcu ve Baş, 2019). MSE değerlerinin küçük olması ağın eğitiminin başarılı olduğunu göstermektedir (Yaman Selçi, 2021: 26).


Eğitim, geçerlilik ve test kümesi oranları sırasıyla %70, %15 ve %15 olarak alınmıştır. Literatürde olan genel kabul eğitim kümesinin geçerlilik ve test kümelerine göre daha büyük alınması gerektirir (Eğrioğlu, Yolcu ve Baş, 2019: 96).

Tablo 2. Aylık fındık fiyatları verilerinde gizli tabaka birimleri için sonuçlar

HKO (MSE) Değerleri			
Gizli tabaka birim sayısı	Eğitim	Geçerlilik	Test
1	0.12	0.19	0.66
2	0.12	0.57	0.11
3	0.97	0.12	0.27
4	0.68	0.17	0.17
5	0.55	0.64	0.13
6	0.62	0.11	0.30
7	0.79	0.27	0.82
8	0.83	0.14	0.23
9	0.53	0.95	0.59
10	0.77	0.56	0.36
11	0.92	0.27	0.30
12	0.77	0.74	0.19


Sonuçlar incelendiğinde en iyi test sonucunun gizli tabaka birim sayısı 2 olduğunda elde edildiği görülmektedir. Bu mimari eğitim ve geçerlilik sonuçlarının da kötü olmadığı dikkate alınarak zaman serisinin modellenmesinde seçilebilir. Eğitim süreci için grafik Şekil 2’de gösterilmiştir. On altıncı iterasyondan itibaren geçerlilik kümesi için MSE değerleri iyileşme sağlayamadığından eğitim süreci on yedinci iterasyon itibarıyla durdurulmuştur ve 11. İterasyondaki optimal ağırlık ve yan değerlerinde karar kılınmıştır.

Şekil 2. Gizli tabaka birim sayısı 2 olduğunda eğitim süreci grafiği



Şekil 3’de eğitim, geçerlilik ve test için ayrılan verilerin regresyon değerleri verilmiştir. Grafik incelendiğinde r square değerlerinin yüksek olduğu görülmektedir. Bu sonuçlar, ağıın öğrenme işlemini başarıyla tamamladığını göstermektedir. Yapay sinir ağları için r square değerlerinin 0.80’in üzerinde olması beklenmektedir (Eğrioğlu, Yolcu ve Baş, 2019). Bu değerin yüksek olması model uyumunun iyi olduğunu göstermektedir (Yaman Selçi, 2021:26). Şekil 3’de gösterilen kesikli çizgi, çıktı ve hedeflerin birbirine eşit olması mükemmel uyum çizgisidir. Daireler veri noktalarıdır ve renkli çizgi çıktılar ile hedefler arasındaki en iyi uyumu temsil etmektedir (Caner, Kesik ve Keçebaş, 2011).

Şekil 3. Regresyon grafiği



Gizli tabaka ile çıktı tabakası arasındaki ağırlıklar (LW) -0.20 ve 1.87 olarak elde edilmiştir. Çıktı tabakası için optimal yan değeri (b) -0.1332 ve gizli tabaka birimleri için optimal yan değerleri ise sırasıyla 0.8397 ve 0.1230 olarak elde edilmiştir. Diğer optimal ağırlıklar (IW) ise Tablo 3’de gösterilmektedir. Optimal ağırlık yapay sinir ağının eğitim verisi ile eğitilmesi sonucunda elde edilen optimum ağırlık ve yan değerlerini göstermektedir (Eğrioğlu, Yolcu ve Baş, 2019). Bu ağırlıkları kullanarak gelecek yıllarda modelden tekrar öngörülerin elde edilmesi mümkün olabileceği için makalede yer verilmektedir.

Tablo 3. Girdi tabakası ile gizli tabaka arasındaki optimal ağırlıklar


Gizli Tabaka	Girdi Tabakası											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0.96	0.19	0.64	-0.19	-0.12	-0.05	0.12	-1.17	-0.39	-0.15	-0.11	0.16
2	0.65	-0.08	0.11	-0.01	-0.07	0.02	-0.03	0.01	-0.25	0.07	0.12	-0.05

Çalışmada ele alınan fındık fiyatları aylık verileri için çok katmanlı algılayıcı model oluşturulmuştur. Çok katmanlı algılayıcı model bir tür ileri beslemeli yapay sinir ağıdır. Modelin tahminlerinin gerçek değerler ile birlikte grafiği Şekil 4’de gösterilmektedir. Modelin yorumlanmasında test kümesi için MSE değeri 0.11 olduğundan karekökü alınarak sonraki bir ay için fiyat tahminimizi 0.33 derecelik bir ortalama hata ile tahmin etmemiz mümkündür. Modelin gelecek değerleri de bu ortalama hata ile tahmin edilmesi beklenmektedir.

Tablo 4. Aylık fındık fiyatları ve YSA tahmin fiyatlarının seçili tablosu


Gözlem	Gerçek Değerler	YSA Tahmin değerleri	Gözlem	Gerçek Değerler	YSA Tahmin Değerleri
1	1.56	1.56	8	1.27	1.21
2	1,56	1.56	9	1.68	1.55
3	1,66	1.30	10	1.73	1.49
4	1,7	1.52	11	1.53	1.55
5	1,7	1.46	12	0.99	1.08
6	1,65	1.46	13	0.94	0.83
7	1,37	1.42	14	1.18	1.12

Şekil 4. Aylık fındık fiyatları ile YSA tahminlerinin birlikte grafiği



Şekil 4’te aylık fındık fiyatları ile yapay sinir ağı tahminlerinin birlikte grafiği yer almaktadır. Çalışmada kullanılan aylık fındık fiyatları <https://www.giresuntb.org.tr/Istatistikler> adresinde yer almaktadır.

Şekil 5. Çalışmanın yapay sinir ağı mimari grafiği



Şekil 5’de görüldüğü üzere modelin yapay sinir ağı mimari grafiği tek katmanlı algılayıcı girdi, 2 gizli tabaka birimi ve 1 çıktıdan oluşmaktadır.

4. TARTIŞMA VE SONUÇ

Fındık ürünü Türkiye için önemli bir gelir kaynağıdır (Çamoğlu, Akıncı ve Bozkurt, 2015:28). Çok sayıda paydaşı doğrudan ilgilendiren, birçok sektörle ilişki içerisinde bulunan önemli bir tarım ürünüdür. Fındık endüstrisinin gelişimi aynı zamanda Türkiye’nin diğer fındık üreticisi ülkelerle rekabetini de güçlendirecektir. Bu açıdan fındık fiyatlarının sadece rekabet edirlilik düzeyi açısından değil bu üründen geçinen yüzbinlerce üreticinin de refahı için yüksek olması beklenmektedir. Ürünün ana geçim kaynağı haline getirilmesi aynı zamanda üretimde kullanılacak muhtemel teknolojik yeniliklerinde yaygınlaşmasını beraberinde getireceği aşikârdır.

Bu çalışmada 2000-2023 yıllarına ait aylık fındık fiyatı verileri kullanılarak fındık fiyatının tahminine ilişkin bir model ortaya konulmaktadır. Çalışmada uygulama kolaylığı nedeniyle MATLAB Neural Network Toolbox aracı kullanılmıştır. Yapılan analiz sonucunda yapay sinir ağları yöntemi ile birlikte tahminlemenin iyi bir sonuç verdiği ifade edilebilir. 0.33 ortalama hata payı ile tahmin değerinin gerçek değere yakın olduğu görülmektedir. Yapay sinir ağlarının özellikle zaman serisi ve tahminleme problemlerinde kullanımının diğer yöntemlere göre daha gerçeğe yakın sonuç verdiği ifade edilebilir.

Konuya ilişkin yapılan benzer çalışmalarda elde edilen sonuca göre yapay sinir ağlarının reel olana daha yakın sonuçlar ürettiği görülmektedir (Şenol ve Denizhan, 2023; Kotan ve Erener, 2023).

Yapay sinir ağlarının tasarımlarının kolay olması, herhangi bir probleme kolayca adapte edilebilmesi ve veri setinin az olmasına karşı başarılı sonuçlar üretebilmesi nedeniyle birçok alanda uygulandığı gibi tarım ekonomisi alanında da uygulanması muhtemel araştırmacılara önerilmektedir.

5. KAYNAKÇA

- Akan Esen, B. (2023).Yapay sinir ağının ana öğeleri, www.akanesen.com, Erişim tarihi: 18.12.2023.
- Akkan, T., Mutlu, T. ve Baş, E. (2022). Forecasting sea surface temperature with feed-forward artificial networks in combating the global climate change: The sample of Rize, Türkiye. *Ege Journal of Fisheries and Aquatic Sciences*, 39 (4), 311-315.
- Alhendi, A., Al-Sumaiti, A.S., Marzband, M., Kumar, R., ve Diab, A.A.Z. (2023). Short-term load and price forecasting using artificial neural network with enhanced markov chain for ISO New England, *Energy Reports*, 9, 4799-4815.
- Arı, A. ve Berberler, M.E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *ACTA INFOLICA*, 2(1), 55-73.
- Bayyurt, D. ve Deveci Kocakoç, İ. (2023). Yapay sinir ağları NARX ile Türkiye fındık üretim miktarı tahmini, *Giresun Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 15-35.

- Bozođlu, M. ve Kabaođlu, S. (2023). Türkiye'deki fındık kırma ve işleme sanayinin yapısı. *Tarım Ekonomisi Araştırmaları Dergisi (TEAD)*, 9(1), 68-80.
- Can, Ş., ve Gerşil, M. (2018). Manisa pamuk fiyatlarının zaman serisi analizi ve yapay sinir ađı teknikleri ile tahminlenmesi ve tahmin performanslarının karşılaştırılması. *Yönetim ve Ekonomi Dergisi*, 25(3), 1017-1031.
- Caner, M., Gedik, E., & Keçebaş, A. (2011). Investigation on thermal performance calculation of two type solar air collectors using artificial neural network. *Expert Systems with Applications*, 38(3), 1668-1674.
- Cansu, T., Kolemen, E., Karahasan, Ö., Bas, E., ve Egrioglu, E. (2023). A new training algorithm for long short-term memory artificial neural network based on particle swarm optimization. *Granular Computing*, 1-14.
- Çakır Sönmez, F. (2019). *Yapay sinir ađları matlab kodları ve matlab toolbox çözümleri*, Ankara: Nobel.
- Çamođlu, S., Akıncı, M. ve Bozkurt, A. (2015). Fındık sektörü, ekonomik ve yapısal problemleri: Ordu ili deđerlendirmesi, *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 6, 27-48.
- Eđriođlu, E., Aladađ, C.H., Yolcu, U. ve Baş, E. (2015). Recurrent multiplicative neuron model artificial neural network for non-linear time series forecasting. *Neural Processing Letters*, 41(2), 249-258.
- Eđriođlu, E., Yolcu, U. ve Baş, E. (2019). *Yapay sinir ađları öngörü ve tahmin uygulamaları*. Ankara: Nobel.
- Giresun Ticaret Borsası (2023). <https://www.giresuntb.org.tr/Istatistikler>. Erişim Tarihi: 09.08.2023.
- Hazneci, E., Naycı, E. ve Çelikkan, G. (2022). Fındık üretiminde maliyet ve karlılık analizi: Giresun ili örneđi, *Ege Üniversitesi Ziraat Fakültesi Dergisi*, 59(3), 499-511.
- Hüsnüođlu, N. (2018). Türkiye'de fındık üretim miktarı ve fiyat ilişkisi: ARDL sınır testi yaklaşımı. *Sosyal Bilimler Araştırma Dergisi*, 7(4), 24-41.
- Kara, M.A. (2022). *Fındık ekonomisi*. K.Y.Genç, Y.Mamur Işıkçı & M.Özdemir (Edt.) Fındık ekonomisinde kooperatiflerin yeri: dünden bugüne Fiskobirlik, (ss.105-120). Bursa: Ekin.
- Karaman, G. (2022). *Fındık ekonomisi*, K.Y.Genç, Y.Mamur Işıkçı & M.Özdemir(Edt.), İnsan Kaynakları yönetimi perspektifinde Türkiye'de fındık ekonomisi, (s.22-37). Bursa: Ekin.
- Khamis, A., ve Abdullah, S. N. S. B. (2014). forecasting wheat price using back propagation and NARX neural network. *The International Journal Of Engineering And Science*, 3(11), 19-26.
- Khosravi, Z.M.H., Barghinia, S., Ansarimehr, P. (2006). New momentum adjustment technique for Levenberg-Marquardt neural network used in short term load forecasting, in Proc. of 21st International Power System Conference (PSC 2006), Tehran, Iran.

- Kırsahanoğlu, Ş. (2022). *Fındık ekonomisi*. K.Y.Genç, Y.Mamur Işıkçı & M.Özdemir (Edt.), fındık fiyatını etkileyen faktörlerin VAR modeliyle analizi, (s.165-182). Bursa: Ekin.
- Kotan, B. ve Erener, A. (2023). PM10, SO2 hava kirleticilerinin çoklu doğrusal regresyon ve yapay sinir ağları ile sezonsal tahmini, *Geomatik*, 8(2), 163-179.
- Kumari, P., Goswami, V., N, H., ve Pundir, R. S. (2023). Recurrent neural network architecture for forecasting banana prices in Gujarat, India. *Plos one*, 18(6), e0275702.
- Kurani, A., Doshi, P., Vakharia, A., ve Shah, M. (2023). A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting. *Annals of Data Science*, 10(1), 183-208.
- Öztürk, Ş. , Nas, F. ve İçöz, E. (2008). 24 Ocak kararları, neo-liberal politikalar ve Türkiye tarımı. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (2) , 15-32.
- Saplıoğlu, K. ve Çimen, M. (2010). Yapay sinir ağlarını kullanarak günlük yağış miktarının tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(1), 14-21.
- Spaulding, A.D., Tulum, O., Saghaian, S. ve Özertan, G. (2009). Impact of a new price support policy on the Turkish hazelnut industry. *Acta Horti*, 845, 795-800.
- Szoplik, J., ve Muchel, P. (2023). Using an artificial neural network model for natural gas compositions forecasting. *Energy*, 263, 126001.
- Şenol, D. ve Denizhan, B. (2023). Kripto para değerinin yapay sinir ağları ile tahmini, *Endüstri Mühendisliği*, 34(1), 42-69.
- Şeyranlıoğlu, O. (2022). *Fındık ekonomisi*. K.Y.Genç, Y.Mamur Işıkçı & M.Özdemir (Edt.), Fındık fiyatları ile döviz kuru arasındaki saklı ilişkinin analizi, (s.261-278). Bursa: Ekin.
- Özer, O. O., ve Yavuz, G. G. (2014). Box-Jenkins Modeli Yardımıyla Fındık Fiyatının Tahmini. XI. Ulusal Tarım Ekonomisi Kongresi, 3(5).
- Wang, J., Wang, Z., Li, X., ve Zhou, H. (2022). Artificial bee colony-based combination approach to forecasting agricultural commodity prices. *International Journal of Forecasting*, 38, 21–34.
- Wang, Y. (2023) Agricultural Products price prediction based on improved RBF neural network model, *Applied Artificial Intelligence*, 37:1, DOI: 10.1080/08839514.2023.2204600.
- Xu, X., ve Zhang, Y. (2023). Yellow corn wholesale price forecasts via the neural network. *EconomiA*. 24 (1), 44-67. <https://doi.org/10.1108/ECON-05-2022-0026>.
- Yang, J., Haigh, M. S., ve Leatham, D. J. (2001). Agricultural liberalization policy and commodity price volatility: a GARCH application. *Applied Economics Letters*, 8(9), 593-598.
- Yaman Selçi, B. (2021). Türkiye'nin konut satışı değerlerinin yapay sinir ağları ile öngörülmesi. *EKOIST Journal of Econometrics and Statistics*, (35), 19-32.