

YAPAY SİNİR AĞLARI NARX MODELİ ile ELMA ÜRETİM MİKTARININ ÖNGÖRÜLMESİ*

Hatice YILDIRIM¹
Meltem KARAATLI²

ÖZET

Türkiye’de yaygın olarak tüketilen elma önemli besin kaynağıdır. Ekolojik şartların uygun olması sebebiyle elmanın gen merkezi olan Türkiye’nin her bölgesinde elma üretiminin yapılması mümkündür. 2020 yılına göre meyveler içinde önemli ürünlerin üretim miktarlarına bakıldığında bir önceki yıla göre en fazla artış gösteren meyve elmadır. Ayrıca elma üretiminde Türkiye, Dünya’da önemli bir konuma sahiptir. Üretim ve tüketim sektöründeki öneminden dolayı bu çalışmada, Yapay Sinir Ağları (YSA) Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) Modeli kullanılarak elma üretim miktarının öngörülmesi üzerine bir uygulama yapılmıştır. Çalışmanın amacı, elma üretim miktarının öngörülmesi ile üretim ve pazarlama aşamalarında organizasyonun güçlendirilerek, arz ve talep ilişkisinin dengelenmesine katkı sağlamaktır. Çalışma Türkiye’yi kapsamakta olup, 1966-2018 dönemine ait yıllık veriler kullanılmıştır. Çalışmada elma üretim miktarı bağımlı değişken, portakal basit fiyat endeksi, elma basit fiyat endeksi, elma üretim alanı, sıcaklık ve teknoloji bağımsız değişkenler olarak dikkate alınmıştır. Çalışma sonucunda 2019, 2020 ve 2021 yıllarına ait elma üretim miktarları öngörülmüş ve bulunan sonuçlar YSA NARX Modelinin elma üretim miktarı öngörüsünde kullanılabileceğini göstermiştir.

Anahtar Kelimeler: Elma Üretimi, Yapay Sinir Ağları, NARX Modeli, Öngörü

* Bu çalışma ASEAD 7. Uluslararası Sosyal Bilimler Sempozyumu’nda özet bildiri olarak sunulmuştur, 10-12 Nisan 2021, Kemer/Antalya.

¹ Hatice YILDIRIM, 100/2000 YÖK Doktora Burs Öğrencisi, Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, lhteyldrm@gmail.com, ORCID ID: 0000-0002-3472-1821, (Sorumlu Yazar).

² Meltem KARAATLI, Doç. Dr., Isparta Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, meltemkaraatli@sdu.edu.tr, ORCID ID: 0000-0002-7403-9587.

FORECASTING of APPLE PRODUCTION QUANTITY with ARTIFICIAL NEURAL NETWORKS NARX MODEL

ABSTRACT


Widely consumed in Turkey, apple is an important food source. Since it is the appropriate ecological conditions, apple production is possible in every region of Turkey that is the gene center of the apple. Considering the production quantity of important products among fruits compared to 2020, the fruit with the highest increase compared to the previous year is apple. In addition, apple production in Turkey has an important position in the world. In this study, because of its importance in the production and consumption sector, an application has been made to forecasting apple production quantity using Artificial Neural Networks (ANN) Nonlinear Autoregressive Exogenous (NARX) Model. The aim of the study is to strengthen the organization in the production and marketing stages and contribute to the balancing of the supply and demand relationship by forecasting the apple production quantity. The study covers Turkey, annual data for the 1966-2018 period has been used. In the study, apple production quantity has been considered as dependent variable, orange simple price index, apple simple price index, apple production area, temperature and technology as independent variables. As a result of the study, apple production quantity for the years 2019, 2020 and 2021 have been predicted and the results found have shown that the ANN NARX Model can be used in the forecasting of apple production quantity.

Keywords: *Apple Production, Artificial Neural Networks, NARX Model, Forecasting*

1. GİRİŞ

Türkiye coğrafi konumu ve ekolojik durumu dikkate alındığında, elma yetiştiriciliği açısından Dünya’da üretimin yoğun olduğu ender ülkelerden biridir (Öztürk vd., 2012: 120). Şekil 1’de 2019 yılı Dünya elma üretimi sıralamasında yer alan ilk 10 ülke ve bu ülkelerin üretim miktarları ton olarak verilmiştir. Çin 42.425.400 tonluk üretim ile Dünya’da elma üretiminde birinci sırada olup, %49’luk payla Dünya üretiminin yaklaşık 1/2’sine sahiptir. 4.997.680 tonluk üretim ile Amerika Birleşik Devletleri (%5,7) ikinci sıradadır. 3.618.752 tonluk üretim ile Türkiye (%4,2) üçüncü sırada yer almaktadır. Polonya (%3,5), Hindistan (%2,7), İtalya (%2,6), İran (%2,6), Rusya (%2,2), Fransa (%2) ve Şili (%1,9) elma üretiminde öne çıkan diğer ülkelerdir. Ayrıca Dünya genelinde 2019 yılında 87.236.221 ton elma üretilmiştir (FAO, 2021). Toplam üretimin %76’sı ise belirtilen 10 ülkede gerçekleştirilmektedir.

Şekil 1: Dünya Elma Üretimi (Ton)




Kaynak: <http://www.fao.org/faostat/en/#data/QC/visualize>, 2021.

Elma ekolojik uygunluğu nedeniyle Türkiye’de geniş bir yayılma alanı bulmuştur. Üretilen elmanın çoğu taze olarak iç pazarda tüketilmekte bir kısmı ise meyve suyu, meyve konsantresi vb. işleme sanayinde hammadde olarak değerlendirilmektedir (Ürün Raporu, 2017: 6). Türkiye’de elma üretimi 1966 yılından itibaren büyük bir gelişme göstermiştir. 1966 yılında 440000 ton olan elma üretimi günümüze kadar yaklaşık on kat artış göstererek dört milyon tonun üzerine çıkmıştır. 2020 yılına göre meyveler içinde önemli ürünlerin üretim miktarlarına bakıldığında, bir önceki yıla göre elma %18,8, şeftali %7,4, kiraz %9,1, çilek %12,3, nar ise %7,3 oranında artış göstermiştir. (TÜİK, 2021). En fazla artış gösteren meyve elma olmuştur.

Diğer tarım ürünlerinden farklı olarak Türkiye’nin 81 ilinde elma yetiştiriciliği yapılabilmektedir. Ancak 2020 yılı verilerine göre toplam üretimin %83,61’i yalnızca 10 ilde gerçekleştirilmektedir. Elma üretimi önemli bir gelişme göstermekte olup yıllık üretim 2020 yılı itibariyle dört milyon tona ulaşmıştır. Bununla birlikte elma üretimi en fazla Isparta ilinde yapılmaktadır. Isparta üretimde birinci sırada yer almasının yanı sıra depolama, işleme ve Ar-Ge faaliyetleri açısından da öne çıkmaktadır (Öztürk, Emre ve Karamürsel, 2015: 44). Isparta’da 2020 yılında 931.154 ton elma üretimi ile toplam elma üretiminin %21’i gerçekleşmiştir. Şekil 2’de Türkiye’de illere göre elma üretim miktarının oranları gösterilmiştir. Şekil 2’de görüldüğü üzere Isparta ilini sırasıyla Antalya (%14,22), Niğde

(%11,7), Karaman (%11,4), Denizli (%6,5), Konya (%5,37), Kayseri (%5,12), Mersin (%3,02), Çanakkale (%2,40) ve Kahramanmaraş (%2,16) illeri izlemektedir (TÜİK, 2021; Ürün Raporu, 2017: 9).

Şekil 2: Türkiye'de İllere Göre Elma Üretim Miktarının Oranları (2020)



Kaynak: <https://biruni.tuik.gov.tr/medas/?kn=92&locale=tr>, 2021.

TMMOB Ziraat Mühendisleri Odası'nın 2019 yılı raporunda, "Elma gibi önemli bir yumuşak çekirdekli meyve türünün Dünya üretiminde ilk sıralarda yer almamıza rağmen bilgi noksanlığı nedeniyle verim ve kalitede yeterli bir üretim artışı ve ihracatının sağlanamadığı" ifade edilmiştir (Elma Raporu, 2019). Bu bağlamda elma üretim miktarının öngörülmesi ile birtakım önlemlerin alınması mümkün olabilecektir. Söz konusu önlemler mevcut elma sektörü politikalarına ek olarak yeni politikaların belirlenmesine de katkı sağlayacaktır.

Yapay sinir ağları (YSA), birçok disiplinde yer almış bir bilgisayar sistemlerini temsil etmektedir. Nörobilim, matematik, istatistik, fizik, bilgisayar bilimi ve mühendislik alanlarında uygulanmaktadır. Yapay sinir ağlarının, öğretmenli veya öğretmensiz girdi verilerinden öğrenme yeteneği vardır. Bu özelliği sayesinde modelleme, zaman serileri analizi, örüntü tanıma, sinyal işleme ve kontrol gibi çeşitli alanlarda uygulamaları mevcuttur (Haykin, 1999: 12). Bu çalışmada da elma üretim miktarının öngörülmesi için YSA NARX Ağ Modelinden yararlanılmıştır.

Bu çalışma Türkiye’yi kapsamakta olup, 1966-2018 dönemine ait yıllık veriler kullanılmıştır. Çalışmada elma üretim miktarı bağımlı değişken, portakal basit fiyat endeksi, elma basit fiyat endeksi, elma üretim alanı, sıcaklık ve teknoloji bağımsız değişkenler olarak dikkate alınmış 2019, 2020 ve 2021 yılları için elma üretim miktarı öngörüsünde bulunulmuştur. Çalışmanın amacı elma üretim miktarının öngörülmesi ile üretim ve pazarlama aşamalarında organizasyonun güçlendirilerek arz ve talep ilişkisinin dengelenmesine katkı sağlamaktır.

Çalışmanın giriş bölümünde Dünya’da ve Türkiye’de elma yetiştiriciliği ve elma üretiminin durumu hakkında bilgiler verilmiştir. İkinci bölümde literatür taraması yapılmıştır. Literatürde ilk olarak tarım sektöründe yapılan tahmin ve öngörü çalışmalarına ve devamında YSA NARX modeli kullanılarak yapılan çalışmalara yer verilmiştir. Üçüncü bölümde YSA ve dördüncü bölümde zaman serileri için YSA NARX modeli ele alınmıştır. Beşinci bölümde elma üretim miktarı öngörülmesi ve gerçek değerler ile öngörü değerleri karşılaştırılmıştır.

2. LİTERATÜR TARAMASI

Literatürde yapay sinir ağları yöntemi ile ilgili birçok tahmin çalışması mevcuttur. Literatür taramasında ilk olarak Tablo 1’de görüldüğü üzere tarım sektöründe yapılan tahmin ve öngörü çalışmalarına, daha sonra Tablo 2’de YSA NARX modeli kullanılarak yapılan çalışmalara yer verilmiştir. Ayrıca literatürde yapay sinir ağları kullanılarak elma üretim miktarının tahmin edilmesi ve öngörülmesi ile ilgili yapılan bir çalışmaya rastlanılmamış olup bu anlamda çalışmanın literatüre katkı sağlaması amaçlanmaktadır.

Tablo 1: Tarım Sektöründe Yapılan Tahmin ve Öngörü Çalışmaları

Yıl	Yazar	Konu	Sonuç
2010	William GRIFFITHS vd. E.	Avustralya’daki yerel buğday verimliliği tahmin edilmiştir.	Sonuçlar, daha fazla yağış bilgisi elde edildikçe tahmin yoğunluğunun nasıl değiştiğini göstermektedir.
2014	Azme KHAMIS, Siti Nabilah Syuhada Bt ABDULLAH	Geri yayımlı yapay sinir ağları (BPNN) ve Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ Modeli kullanılarak uygun model araştırılmış ve gelecekteki buğday fiyatı tahmin edilmiştir.	Yöntemler, buğday fiyatını tahmin etmek için en iyi modeli elde etmek amacıyla karşılaştırılmıştır. Sonuçlara göre, gizli katmanda 8 düğüm ve 4 gecikme ile NARX modeli, buğday fiyatını öngören alternatif bir model olarak kullanılabilir.

2014	Snehal S. DAHIKAR, Sandeep V. RODE	Yapay sinir ağlarını kullanarak tarımsal ürün verimi tahmin edilmiştir. Ürün tahmin yöntemi, çeşitli toprak parametreleri ve ayrıca atmosferle ilgili parametreleri algılayarak uygun ürünü tahmin etmek için kullanılmıştır.	YSA'nın ürün tahmini için iyi bir araç olduğu sonucuna varılmıştır.
2015	Mehmet AYDOĞAN vd.	Türkiye'de kuru fasulye üretiminin mevcut durumunu ortaya koymak ve gelecek dönemlerin üretimi zaman serisi analizlerinden çift üstel düzeltme yöntemi ile tahmin edilmiştir.	Türkiye kuru fasulye arz miktarının kuru fasulye talebinden fazla olacağı, bu fazlalığın sebebinin de ithalattan kaynaklanacağı öngörülmüştür. Bir başka deyişle gelecek yıllarda kuru fasulyede dışa bağımlılığın artacağı tahmin edilmiştir.
2015	Mehmet KARAHAN	Türkiye'nin kuru kayısı ürününün dış talep -miktarı tahmini ARIMA ve YSA Metodları ile yapılarak karşılaştırılmıştır.	Önerilen YSA modelinin yaptığı tahminlerin güvenilir ve tutarlı olduğu tespit edilmiştir. Modelin tahmin gücünün geleneksel ve ekonometrik modellere göre çok daha iyi bir performans gösterdiği tespit edilmiştir.
2018	Şengül CAN, Mustafa GERŞİL	Manisa pamuk fiyatlarının zaman serisi analizi ve yapay sinir ağı teknikleri ile tahminlenmesi ve tahmin performanslarının karşılaştırılması ele alınmıştır.	Zaman serisi ve yapay sinir ağı yöntemleri kullanılarak 2017 yılına ait fiyatların değer tahminleri yapılmıştır. Yapılan tahminler MAE, MAPE ve RMSE değerleri üzerinden karşılaştırılarak hangi tekniğin daha başarılı tahmin performansı gösterdiğine karar verilmiştir. Elde edilen sonuçlar literatürdeki benzer çalışma sonuçlarıyla da karşılaştırılmıştır. Tüm bu sonuçlar doğrultusunda yapay sinir ağları yönteminin daha başarılı sonuçlar elde ettiği görülmüştür.
2020	Cansu BAŞARAN CANER, Sait ENGİNDENİZ	Türkiye'de pamuk üretimi ARIMA modeli ile tahmin edilmiştir.	1991-2018 yılları pamuk verileri analiz edilmiş ve ARIMA (4,1,4) modelinden yararlanarak gelecek beş yıllık dönemde Türkiye lif pamuk üretim tahmin edilmiştir. Türkiye'de lif pamuk üretiminin gelecek beş yıllık dönemde %9,5 artarak 1.065.235 tona ulaşması gerektiği sonucuna varılmıştır.
2020	Tamoor KHAN vd.	Tarımsal üretim için derin sinir ağlarını kullanarak meyve üretimi tahmin edilmiştir.	Pakistan'da gelecekteki meyve üretimini tahmin etmek için üç farklı derin sinir ağı algoritması kullanılarak ve öngörülen veriler 1980'den 2025'e kadar yıllık olarak verilmiştir. Bu algoritmalar farklı doğruluğa sahiptir, en iyi doğruluk Bayes metodu (76.3) ile elde edilmiştir.

Tablo 2: YSA NARX Modeli Kullanılarak Yapılan Çalışmalar

Yıl	Yazar	Konu	Sonuç
1996	Tsungnan LIN vd.	Tekrarlayan sinir ağlarında uzun vadeli bağımlılık modeli için NARX modeli önerilmiştir.	NARX modelinin çok daha hızlı yakınsamaya sahip güçlü bir modelleme ve doğrulama aracı olduğu ve diğer sinir ağı modellerinden çok daha iyi genelleme yaptığı belirtilmiştir.
2009	Hang XIE vd.	NARX modelinin zaman serileri tahminine kolayca ve verimli bir şekilde uygulanabileceği gösterilmiştir. Karbondioksit kompresöründen ölçülen titreşim verileri kullanılmıştır.	Önerilen yaklaşım zaman gecikmeli yapay sinir ağı mimarisi gibi standart sinir ağı tabanlı öngörücülerden tutarlı bir şekilde daha iyi performans göstermiştir.
2016	Ali TATLI, Sinem KAHVECİOĞLU	Uçuşa elverişlilik zaman serilerinin çıkarımı ve bu seriler üzerinde NARX yapay sinir ağı modelleriyle günlük uçuşa elverişlilik süresi tahminleri gerçekleştirilmiştir.	Eğitim başarısı yüksek olan ağların test başarısının da genellikle yüksek olduğu sonucuna ulaşılmıştır. En başarılı ağ için RMSE değeri eğitim ve test aşamalarında sırasıyla 0.158258 ve 1.482981 olarak elde edilmiştir.
2016	Nurdan DEĞİRMENCİ, Hakan PABUÇCU	Kredi Temerrüt Riski (CDS) ile BIST arasındaki etkileşim ve geleceğe yönelik daha güçlü tahminler yapabilmek için uygun sinir ağı modelleri araştırılmıştır. Çalışmada yöntem olarak VAR analizi, Granger Nedensellik testi ve Yapay Sinir Ağı (NARX) modelleri kullanılarak veriler analiz edilmeye çalışılmıştır.	Granger nedensellik analizi sonuçlarına bağlı olarak tahmin edilen NARX modeli geleceğe dönük tahminler yapma noktasında çok güçlü bir tahmin edici olarak belirlenmiştir. Kredi temerrüt riski (CDS) ile hisse senedi fiyatları arasında çift yönlü nedensellik ilişkisi vardır. NARX modelinin (0,00059) hata oranıyla başarılı bir performans gösterdiği sonucuna varılmıştır.
2016	Lidong ZHANG vd.	Tek bir rüzgâr türbininin güç tüketimini tahmin etmek için eksojen girdili (NARX) doğrusal olmayan bir otoresresif model geliştirilmiştir. Rüzgâr yönü, rüzgâr hızı ve rüzgâr türbininin makine dairesi konumu gibi farklı girdiler test edilmiştir.	NARX modeli kullanılarak elde edilen sonuçlar girdiler ve çıktılar arasındaki dinamik özellikleri etkili bir şekilde yakalayabildiğini göstermektedir.

2017	Saurabh LABDE vd.	Herhangi bir hisse senedinin kapanış fiyatını tahmin etmek için adaptif NARX sinir ağına dayalı bir model önerilmiştir. Ağı eğitmek için Levenberg-Marquardt algoritması kullanılmıştır.	NARX modeli, kapanış fiyatını analiz etmek ve tahmin etmek için bir zaman serisi yaklaşımı kullanmaktadır. Bu model durağan ve orta derecede durağan hisse senetleri için yüksek derecede bir öngörüye sahiptir. Modelin doğruluğu, tahmin edilen ve gerçek fiyatlar arasındaki ortalama hata karesi ile belirlenmiştir.
2019	Emre AKARSLAN, Fatih Onur HOCAOĞLU	Afyon Kocatepe Üniversitesi ana kampüs alanına ait saatlik olarak toplanan elektrik tüketimi verileri modelleme için kullanılmıştır. Bu verinin modellenmesinde tüketimin gerçekleştiği saat, gün, ay ve mevsim gibi zamana dayalı veriler de kullanılmıştır. Kullanılan yöntemde öncelikle Relieff algoritması yardımıyla mevcut girdilerden tüketim verisiyle en yüksek ilişkiye sahip olan veriler belirlenmiştir. Sonrasında ise NARX yöntemi kullanılarak tüketim verisi modellenmiş ve saatlik tahminler gerçekleştirilmiştir.	Relieff metodunun saatlik yük tahmini çalışmaları için uygun bir öznelik seçim yöntemi olduğu görülmüştür. Ayrıca NARX ağlarının saatlik yük talebi modellemesinde oldukça başarılı sonuçlara imkân sağladığı anlaşılmıştır.
2020	Meltem KARAATLI vd.	Yapay Sinir Ağları (YSA) Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) ve Vektör Otoregresif (VAR) modelleri ile ticari kredi faiz oranları öngörülme çalışılmıştır. Kredi faiz oranlarına doğrudan veya dolaylı olarak etkisi olduğu düşünülen bağımsız değişkenler enflasyon, döviz kuru, CDS primleri, para arzı, kredi hacmi ve Devlet İç Borçlanma Senedi (DİBS) olmak üzere toplam altı değişken tespit edilmiştir.	Doğrusal olmayan YSA NARX modelinin doğrusal model özelliğine sahip olan VAR modeline göre oldukça iyi sonuçlar verdiği görülmüştür.

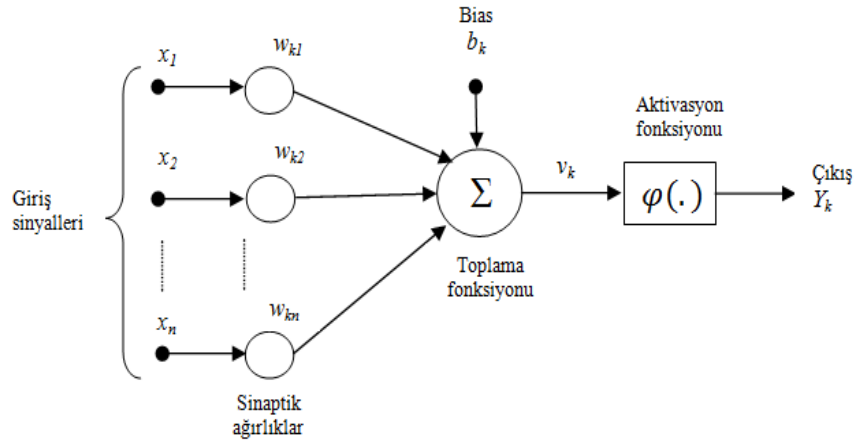
2020	Yelda FIRAT	NARX modeli kullanılarak hava kalitesi tahmin analizi gerçekleştirilmiştir.	Ölçülmemiş hava kalitesi parametrelerini tahmin etmek için bir NARX modeli oluşturulmuştur. Elde edilen sonuçlar, öngörülen parametre değerlerinin çok başarılı olduğunu ve hata ivmesinin çok düşük olduğunu göstermektedir. Öğrenme sürecinin başarısı ise %90'ın üzerindedir.
------	-------------	---	--

3. YAPAY SİNİR AĞLARI YÖNTEMİ

Yapay sinir ağları, insan beyninin özelliklerinden biri olan öğrenme yoluyla yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan gerçekleştirebilmek amacıyla geliştirilen bilgisayar sistemleridir (Öztemel, 2003: 29). Bir başka deyişle yapay sinir ağları, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır (Grosan ve Abraham, 2011: 281; Çetin, 2021: 25).

Genel olarak bir YSA modeli, n adet Katman, her katmanda biyolojik sinir hücrelerine benzer işlevi yerine getiren ve değişik sayılarda olabilen hesaplama elemanları, katmanlar boyunca bu hesaplama elemanları arasındaki yoğun bağlantılardan meydana gelmektedir. Çeşitli YSA modellerinde kullanılan hesaplama elemanları, yapay sinir hücresi, düğüm, birim veya işlem elemanı olarak isimlendirilmektedir (Akpınar, 1994: 49).

Şekil 3: YSA'nın Matematiksel Modeli



Kaynak: Simon Haykin, Neural Networks: A Comprehensive Foundation, Second Edition, McMaster University, Pearson Education, Canada, 1999, s. 35; Mehmet Karahan,

Turizm Talebinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 20(2), 195-209, 2015, s. 198.

Şekil 3'te yapay sinir ağlarının tasarlanması için temel oluşturan bir nöronun yapısını göstermektedir. x_1, x_2, \dots, x_n giriş verileri; $w_{k1}, w_{k2}, \dots, w_{kn}$ nöronunun sinaptik ağırlıklarıdır. u_k giriş verilerine göre doğrusal olarak birleştirilmiş çıkıştır. b_k bias, $\varphi(\cdot)$ aktivasyon fonksiyonu ve y_k sinir ağının çıkış sinyalidir. Buradaki bias b_k doğrusal birleştiricisi u_k çıkışını öngörülen şekilde etkiler (Haykin, 1999: 32-33; Karahan, 2015: 198).

YSA, geleneksel istatistiksel yöntemlerin etkili bir şekilde ele alabileceğinden daha genel ve esnek işlevsel formlara sahiptir. Herhangi bir tahmin modeli, girdiler (zaman serilerinin geçmiş değerleri veya diğer ilgili değişkenler) ile çıktılar (gelecekteki değerler) arasında temelde yatan (bilinen veya bilinmeyen) bir ilişki olduğunu varsayar. Çoğunlukla, geleneksel istatistiksel tahmin modelleri, gerçek sistemin karmaşıklığından dolayı bu temel işlevi tahmin etmede sınırlamalara sahiptir. YSA bu işlevi tanımlamak için iyi bir alternatif yöntem olabilmektedir (Zhang, Patuva ve Hu, 1998: 36).

YSA'nın; doğrusal olmayan yapıları modelleyebilmesi, paralel dağılmış yapısı, öğrenme ve genelleme yapma yeteneği, farklı problemlere aktarılabilirliği, hata toleransına sahip olması en önemli özelliklerindedir. YSA'nın söz konusu özellikleri işletme, finans, mühendislik, tıp vb. birçok farklı disiplinlerde tercih edilmelerini sağlamaktadır (Hamzaçebi, 2011:17).

4. ZAMAN SERİLERİ İÇİN YAPAY SİNİR AĞI NARX MODELİ

Gelecekte yapılacak olan her türlü faaliyet için bir plan yapılmalıdır. Planlar belirli bir varsayım ve tahminlere dayanarak yapılır. Elde edilen sonuçlar zamana göre bir dağılım gösteriyorsa zaman serilerinden söz edilir. Zaman serileri ürünlerin üretimi, tüketimi, fiyat değişimleri, gelirler vb. gruplara ilişkin ayrı zaman dönemlerine ait verilerin bütünü olarak tanımlanmaktadır. Böylece geçmişten yararlanarak geleceği tahmin etmek amaçlanmaktadır (Gavcar, 2013: 153).

Zaman serisi analizine dayalı tahmin problemleri, bir değişkenin zaman boyutunda mevcut verileri ile gelecek dönemlere ait değerlerin tahmin edilmesi olarak bilinmektedir. Zaman serileri analizine dayalı tahminde amaç, stokastik yapı gösteren serinin oluşmasına neden olan

ana faktörü belirleyerek serinin gelecekte alabileceği değerleri en az hata ile tespit etmektir (Hamzaçebi, 2011: 95).

NARX modeli, doğrusal olmayan dinamik sistemlerin girdi-çıkıtı modellenmesinde yaygın olarak kullanılan dinamik bir sinir yapısıdır (Menezes Jr. ve Barreto, 2008: 3335) ve ayrıca bu ağ doğrusal olmayan sistemleri ve özellikle zaman serilerini modellemek için uygun olduğu kanıtlanmış güçlü bir modeldir (Diaconescu, 2008: 185). NARX modeli, zaman serisi modellemede yaygın olarak kullanılan doğrusal ARX (Linear Auto Regression Models) modeline dayanmaktadır (Mathworks, 2021).

NARX modeli Eşitlik 1’de yer alan formül ile ifade edilebilir:

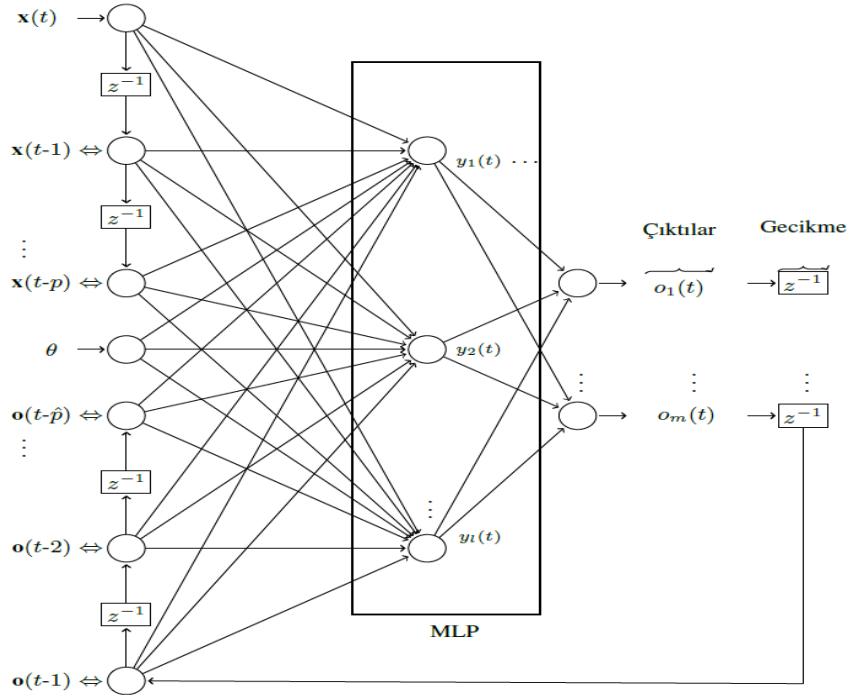
$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), x(t-1), x(t-2), \dots, x(t-n_x)) \quad (1)$$

Eşitlik 1’de yer alan $y(t-1), y(t-2), \dots, y(t-n_y)$ ağ çıktıları ve $x(t-1), x(t-2), \dots, x(t-n_x)$ ağ girdileridir. n_y ve n_x ise sırasıyla geri besleme için uygulanacak geçmiş çıkışların ve geçmiş girişlerin sayısını belirtmektedir. Bir başka deyişle geri bildirim ve girdi katmanları zaman gecikmeli olup geçmiş verileri içerir (Fırat, 450: 2020).

Zaman serisi tahmin modellerinde başarıyla kullanılan NARX modeli, tekrarlayan bir ağ modelidir (Lin vd., 1996). Ağın birkaç katmanını kapsayan geri bildirim bağlantılarına sahiptir. NARX modelinin performansını elde etmek için tahmin edilen veya gerçek zaman serilerinin geçmiş değerlerini kullanarak bellek yeteneğinden yararlanması ilgi çekici bir özelliğidir (Boussaada vd., 2018: 3-4).

NARX modeli son zamanlarda Turing makinelerine hesaplama açısından eşdeğer olduğu gösterilen güçlü bir model sınıfında yer almaktadır (Siegelmann vd., 1997). Isı eşanjörleri (Chen vd., 2007), atık su arıtma tesisleri (Su ve McAvoy, 1991), bir petrol rafinerisinde katalitik reform sistemleri (Su vd., 1992), biyolojik sistemlerde çok yönlü hareketle ilişkili doğrusal olmayan salınımlar (Venkataraman, 1994), zaman serileri (Connor vd., 1992) ve çeşitli yapay doğrusal olmayan sistemlerin modellenmesi için çok uygun oldukları kanıtlanmıştır. Diğer sinir ağı türleriyle karşılaştırıldığında NARX ağları daha hızlı yakınsamakta, diğer ağlardan daha iyi genelleme yapabilmekte ve daha etkili bir öğrenme ortaya koymaktadır (Lin vd. 1996: 1329).

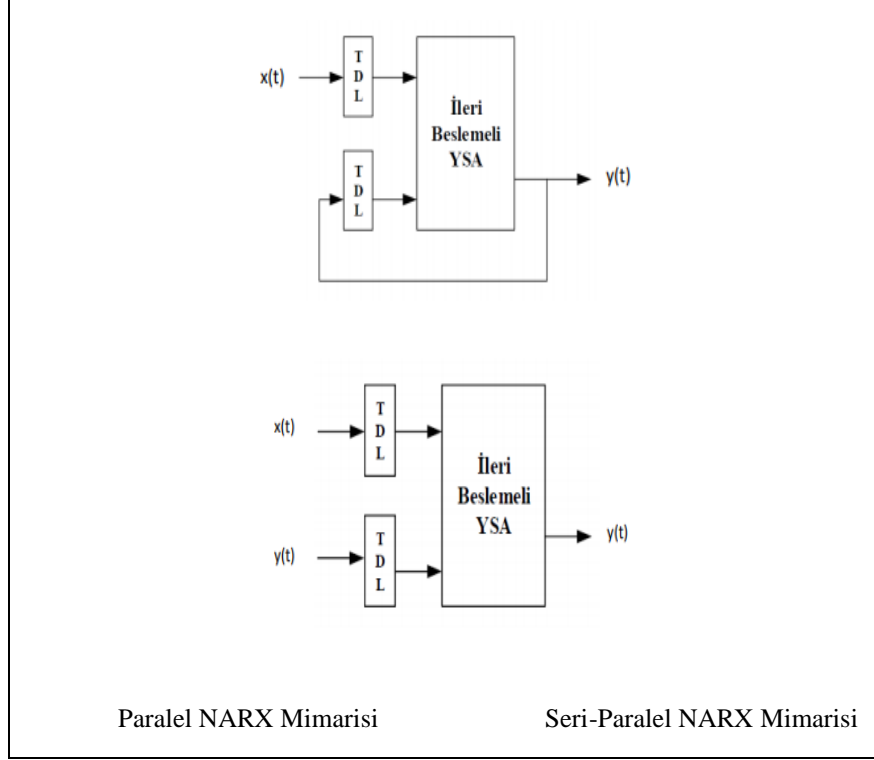
Şekil 4: NARX Ağ Modelinin Yapısı



Kaynak: Ali Tatlı ve Sinem Kahvecioğlu, Zaman Serilerinde NARX Sinir Ağları Modeliyle Uçuşa Elverişlilik Süresinin Kestirimi, 2016 Ulusal Elektrik, Elektronik ve Biyomedikal Mühendisliği Konferansı (ELECO), Bursa, 1-3 Aralık 2016, 130-134, s. 131.

Şekil 4'te NARX modeline ait ağ yapısı gösterilmiştir. NARX ağ modelinin eğitimi iki şekilde yapılmaktadır. Birincisi paralel, ikincisi seri paralel olarak adlandırılır. Paralel model, çıktının normal NARX yapısının bir parçası olarak ileri beslemeli sinir ağının girişine geri beslendiği modeldir. Seri-paralel model, tahmini çıktıyı geri beslemek yerine gerçek çıktının kullanıldığı modeldir. Seri paralel modelin iki avantajı vardır. Birincisi ağa giriş olarak verilen değerler birbirleriyle daha tutarlıdır. İkincisi ise ortaya çıkan ağın tamamen ileri beslemeli bir yapıya sahip olması ve eğitim için statik geri yayılımın kullanılabilmesidir (Xie, Tang ve Liao, 2009: 1276). Şekil 5'te YSA NARX mimarileri gösterilmiştir.

Şekil 5: NARX Mimarileri



Kaynak: Zina Boussaada vd., A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model For The Prediction Of The Daily Direct Solar Radiation, Energies 2018, 11(3), 620, s. 4.

Kullanılabilecek eğitim algoritmaları sırasıyla; Levenberg-Marquardt (LM) Metodu, Bayesian Regulation Metodu ve Scaled Conjugate Gradient Metotlarıdır. Levenberg-Marquardt (LM) algoritması yapay sinir ağlarının eğitiminde sağlamış olduğu hız ve kararlılık nedeni ile tercih edilmektedir (Çavuşlu, Becerikli, Karakuzu, 2012: 1). Çalışmada da Levenberg-Marquardt (LM) algoritması kullanılmıştır.

5. YÖNTEM

Uygulama bölümünde ilk olarak araştırmada kullanılan değişkenler ve veri setine, devamında çalışmada kullanılan normalizasyon tekniğine ve sonrasında YSA NARX modeli uygulama sonuçlarına yer verilmiştir.

5.1. Arařtırmada Kullanılan Deęiřkenler ve Veri Seti

Bu alıřma Trkiye'yi kapsamakta olup, 1966-2018 dnemine ait yıllık veriler kullanılmıřtır. alıřmada elma retim miktarı baęımlı deęiřken, portakal basit fiyat endeksi, elma basit fiyat endeksi, elma retim alanı, sıcaklık ve teknoloji baęımsız deęiřkenler olarak dikkate alınmıř 2019, 2020 ve 2021 yılları iin elma retim miktarı ngrsnde bulunulmuřtur.

Baęımlı deęiřken elma retim miktarını etkileyen baęımsız deęiřkenler uzman grř ve literatr taramasından faydalanılarak belirlenmiřtir.

Trkiye'de retimi yapılan bařlıca elma eřitleri Golden, Starking Delicious, Amasya, Granny Smith ve dięer olarak sınıflandırılmıřtır. 2020 yılında Trkiye'de yetiřtiricilięi en fazla yapılan elma eřidi %38'lik payla Starking Delicious'dır. Starking Delicious'ı sırasıyla dięer elmalar (%27), Golden (%24), Amasya (%5,5) ve Granny Smith (%4,08) izlemektedir (TİK, 2021). Elma fiyatı iin retilen bu beř elma eřidinin fiyatlarının ortalaması alınmıřtır.

Elmaya ikame rn olarak portakal seilmiřtir. Trkiye'de retimi yapılan bařlıca portakal eřitleri Washington, Yafa ve dięer olarak sınıflandırılmaktadır. Portakal fiyatı, retilen bu  portakal eřidinin fiyatlarının ortalaması alınarak hesaplanmıřtır.

Sıcaklık verileri iin meteoroloji genel mdrlęnden yararlanılmıřtır. alıřmada kullanılan her bir yıl iin o yılın ortalama sıcaklık deęerleri kullanılmıřtır.

Elma ıřlahında ve tarım teknolojilerinde yařanan geliřmelerin verimlilięi artırdıęı ve retime olumlu yansıdıęı dřnlmektedir (Aras, 2015: 7). Bu sebeple damla sulama teknięinin geliřtirilmesinin retimi olumlu etkiledięi dřnlmř ve teknoloji deęiřkeni kukla deęiřken olarak kullanılmıřtır.

Elma ve portakal fiyatları iin TİK ve FAO tarafından sunulan istatistiklerden yararlanılmıřtır. Elma ve portakal fiyatlarına ait bilgiler 1966 yılına kadar ulařılabildięi iin alıřma 1966 yılı ile sınırlandırılmıřtır. Gemiř yıllardaki para birimi deęiřiklięine baęlı olarak elma ve portakal fiyatları TL'ye uygun olacak řekilde gncellenmiřtir. alıřmada retici fiyatları dikkate alınmıřtır. Elma ve portakal basit fiyat endeksini hesaplamak iin kullanılacak forml Eřitlik 2'de gsterilmektedir.

$$I = \frac{X_i}{X_0} * 100 \quad (2)$$

$X_i = X$ değişkenine ait i 'ninci değer

$X_0 =$ Baz alınan temel değer

olarak hesaplanmıştır.

Elma üretim alanları ile ilgili veriler için FAO tarafından sunulan kayıtlardan yararlanılmıştır. Üretim alanları hektar (ha) alan olarak hesaplanmıştır. Sıcaklık verileri için Meteoroloji Genel Müdürlüğü web sayfasından yararlanılmıştır. Meteoroloji Genel Müdürlüğünden yararlanılan sıcaklık değerleri 1970 yılına kadar erişilebilmiş olup 1966 - 1969 yılları için Dünya Bankası web sayfasından ulaşılan veriler kullanılmıştır. Teknoloji değişkeni kukla değişken olarak kabul edilmiş, damla sulama tekniğine bağlı olarak 2000 yılına kadar olan yıllar için 0, 2000 yılı ve sonraki yıllar için ise 1 değeri verilmiştir. Elma üretim miktarı ton olarak dikkate alınmıştır. Veri seti Tablo 3'te gösterilmiştir.

Tablo 3: Veri Seti

Tarih	Elma Üretim Miktarı (Ton)	Portakal Basit Fiyat Endeksi	Elma Basit Fiyat Endeksi	Elma Üretim Alanı (Ha)	Sıcaklık (°C)	Teknoloji
1966	440000	0.076740238	0.126086957	66667	12.6	0
1967	640000	0.088794567	0.12026251	71640	10.2	0
1968	700000	0.099235993	0.097292863	60660	11.2	0
1969	620000	0.102801358	0.106726825	61217	11.2	0
1970	748000	0.121901528	0.130188679	63537	13.5	0
1971	780000	0.106451613	0.135520919	66823	12.9	0
1972	850000	0.119185059	0.130106645	72000	12.2	0
1973	850000	0.123089983	0.168990976	74000	12.6	0
1974	950000	0.158743633	0.214109926	75333	12.6	0
1975	900000	0.205432937	0.257588187	76667	12.6	0
1976	1000000	0.227504244	0.308449549	82000	12	0
1977	900000	0.308149406	0.392124692	82380	12.9	0
1978	1100000	0.589134126	0.665299426	86250	13.1	0
1979	1350000	0.792020374	1.031173093	86667	13.6	0

1980	1430000	1.243633277	1.511894996	92833	12.7	0
1981	1450000	1.843803056	1.954060705	93333	13.3	0
1982	1600000	2.310696095	2.714520098	95000	12.1	0
1983	1750000	2.844651952	2.997538966	96667	12.3	0
1984	1900000	3.078098472	4.39704676	98833	12.8	0
1985	1900000	7.894736842	7.567678425	100583	12.8	0
1986	1865000	11.57328806	10.78753076	100667	13.1	0
1987	1680000	13.46915676	13.98687449	102840	12.5	0
1988	1950000	31.04131296	27.33798195	104000	12.5	0
1989	1850000	35.7385399	33.77768663	104000	13	0
1990	1900000	51.3016412	58.65463495	105000	12.9	0
1991	1900000	100	100	106134	12.7	0
1992	2100000	170.5998868	187.2231337	104900	11.4	0
1993	2080000	243.3786078	268.1501231	162506	12.3	0
1994	2095000	575.155631	680.3937654	158341	13.7	0
1995	2100000	1303.735144	1462.530763	153422	13.1	0
1996	2200000	2390.605546	2172.846596	150231	13.3	0
1997	2550000	3589.332201	4284.946678	156144	12.5	0
1998	2450000	5514.148274	7575.266612	153245	13.8	0
1999	2500000	8548.556593	11773.49426	158469	14.1	0
2000	2400000	13232.88681	18122.21144	158800	13.1	1
2001	2450000	16611.71477	24332.31378	153420	14.2	1
2002	2200000	23179.62649	41752.9799	150000	13.2	1
2003	2600000	30898.69836	51484.65956	159000	13.2	1
2004	2100000	36874.36333	57413.12551	160000	13.2	1
2005	2570000	46123.37295	67596.39048	160240	13.3	1
2006	2002033	42444.82173	73666.94011	162666	13.3	1
2007	2457845	48387.09677	83511.07465	157750	13.8	1
2008	2504494	54895.30277	88925.34865	158400	13.6	1

2009	2782365	50084.88964	84987.69483	162650	13.7	1
2010	2600000	56876.06112	91386.38228	165078	15.1	1
2011	2680075	70175.4386	104675.9639	166673	12.8	1
2012	2888985	57441.99208	94339.62264	174811	13.8	1
2013	3128450	48953.02773	85151.76374	173095	13.8	1
2014	2480444	51782.68251	101230.5168	171417	14.5	1
2015	2569759	52065.64799	96964.72518	171410	13.8	1
2016	2925828	52631.57895	87940.93519	173394	14	1
2017	3032164	62252.40521	103199.3437	175357	13.7	1
2018	3625960	71024.33503	124856.4397	174690	15.1	1

5.2. YSA NARX Modelinin Uygulanması

YSA'da uygulamaya başlamadan önce verilerin normalize edilmesi gerekmektedir. Araştırmada normalizasyon tekniği olarak D_Min_Max tekniği kullanılmıştır. Eşitlik 2'de yer alan formüle göre verilerin normalizasyonu gerçekleştirilmiştir. Çalışmaya normalizasyon yapılmış verilerle devam edilmiştir. Eşitlik 3 kullanılarak tüm veriler 0,1 ile 0,9 arasında normalize edilmiş olup, veriler boyutsuz hale getirilmiştir (Doğan, Işık ve Sandalcı, 2007: 4121).

$$x' = 0.8 \times \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (3)$$

Tahmin sisteminin etkinliğini değerlendirmek için kullanılan birçok ölçüt mevcuttur. Bunların en önemlisi tahmin doğruluğudur. Tahmin metodunun doğruluğu, tahmin hatalarının analiz edilmesi ile belirlenir. Tahmin hatası, gerçek gözlem değeri ile tahmin edilen değer arasındaki farktır (Hamzaçebi, 2005: 11).

$$e_t = D_t - F_t \quad (4)$$

Eşitlik 4'te yer alan e_t herhangi bir t dönemi için tahmin hatasını göstermektedir. F_t t dönemi için tahmin değeri ve D_t ise t dönemi için gerçekleşen değeri olması durumunda tahmin hatasını göstermektedir.

YSA NARX modellerinin tahmin başarısını ölçmek için Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE), Ortalama Hata Kareleri (Mean Square Error-MSE) ve Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error-RMSE) performans ölçütleri kullanılmıştır. Ortalama hata kavramını temel alan ve yaygın

olarak kullanılan başlıca bu performans ölçütlerinin formülleri sırasıyla 5, 6 ve 7'de yer alan eşitliklerde verilmiştir. n dönemde gerçekleşen tahmin hataları $e_1, e_2 \dots, e_n$ olması durumunda;

$$MSE = (1/n) \sum_{i=1}^n |e_i|^2 \quad (5)$$

$$RMSE = \sqrt{(1/n) \sum_{i=1}^n e_i^2} \quad (6)$$

$$MAPE = (100/n) \sum \left| \frac{e_i}{y_t} \right| \quad (7)$$

Bu çalışmada girdi katmanı (input) için belirlenen 5 değişken portakal basit fiyat endeksi, elma basit fiyat endeksi, elma üretim alanı, sıcaklık ve teknolojidir. Çıktı (output) için elma üretim miktarı programa tanımlanmıştır. Yapılan analizde toplam 53 yıllık veri kullanılmıştır. Çalışma sonucunda üç yıllık öngörü gerçekleştirilmiştir. Bununla birlikte 2019 ve 2020 yılları elma üretim miktarları açıklandığı için yapılan öngörü gerçek değerler ile kıyaslanmıştır. Ancak 2021 yılı elma üretim miktarları açıklanmadığı için yapılan öngörü gerçek değerler ile kıyaslanamamıştır.

Uygulamada oluşturulan modellerin MAPE değerleri Tablo 4'te ve Tablo 5'te verilmiştir. Ayrıca bu model denemelerinin dışında birçok model denenmiş olup en düşük MAPE değerlerine sahip modellere yer verilmiştir.


Tablo 4: Eğitim, Doğrulama ve Test Değerleri İçin Hesaplanan MAPE Değerleri

Performans Ölçütü	%80 eğitim	%80 eğitim	%80 eğitim	%75 eğitim	%75 eğitim
	%10 doğrulama	%10 doğrulama	%10 doğrulama	%10 doğrulama	%10 doğrulama
	%10 test	%10 test	%10 test	%15 test	%15 test
	40 nöron	30 nöron	20 nöron	40 nöron	20 nöron
	4 gecikme	4 gecikme	4 gecikme	4 gecikme	4 gecikme
MAPE	5.32101061	9.801861887	7.458043104	20.12105075	12.64283902

Tablo 5: Eğitim, Doğrulama ve Test Değerleri İçin Hesaplanan MAPE Değerleri

	%75 eğitim %15 doğrulama %10 test 40 nöron 4 gecikme	%75 eğitim %15 doğrulama %10 test 30 nöron 4 gecikme	%70 eğitim %15 doğrulama %15 test 30 nöron 4 gecikme	%65 eğitim %15 doğrulama %20 test 30 nöron 4 gecikme	%60 eğitim %20 doğrulama %20 test 40 nöron 4 gecikme
MAPE	8.471253932	17.59797165	6.733425909	7.045104973	8.37298E+14

En iyi tahminlemeyi ise %80 eğitim, %10 doğrulama ve %10 test modeli gerçekleştirmiştir. Şekil 6'da ise bu modelin kapalı döngü NARX modeli yer almaktadır.

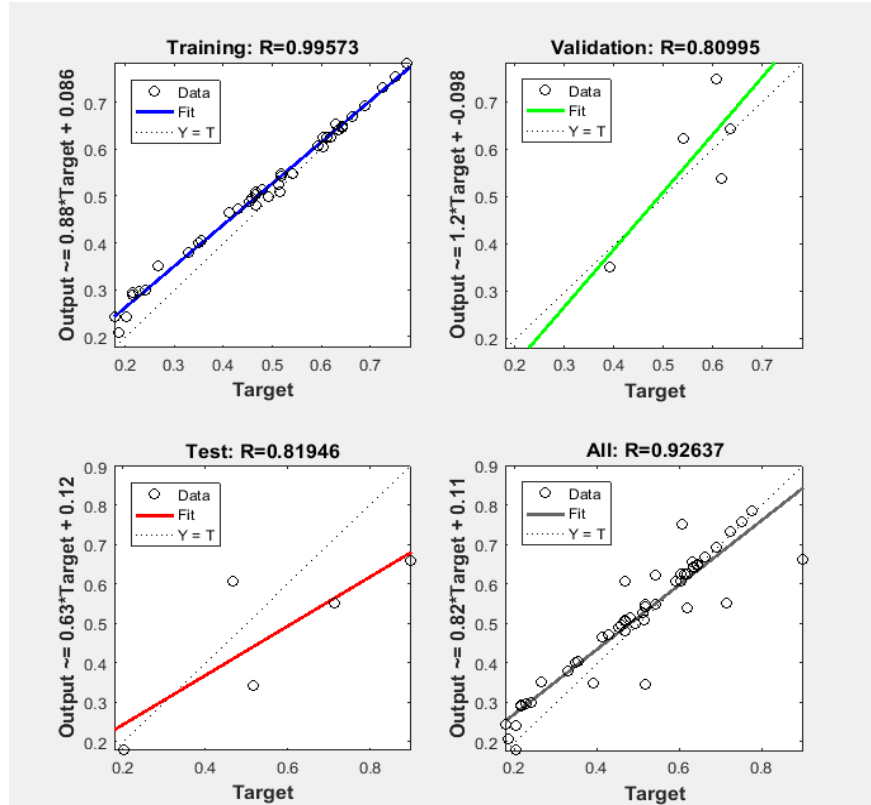
Şekil 6: Oluşturulan Kapalı Döngü NARX Modeli

Şekil 6'da yer alan modelde $x(t)$ bağımsız değişken sayısını, $y(t)$ ise bağımlı değişken sayısını göstermektedir. Bu modelde ağ iki giriş katmanı, bir gizli katman ve bir adet de çıkış katmanına sahiptir. Gizli katmanda kırk, çıkış katmanında ise bir adet nöron yer almaktadır. NARX modelinde ağı meydana getirecek olan nöron sayısı ile gecikme uzunluğu parametreleri araştırmacı tarafından belirlenebilmesi mümkündür. Ayrıca gecikme uzunluğu LR, FPE, AIC ve HQ gibi bilgi kriterleri kullanılarak da belirlenebilmektedir. Hem deneme yanılma hem de Akaike bilgi kriterine bağlı olarak VAR modeli tahmin edilerek optimal gecikme uzunluğu 4 olarak bulunmuştur. Çalışmada kırk gizli nöron ve 4 gecikme uzunluğu ile sonuçlar elde edilmiştir. Gizli

katmandaki nöron sayısının belirlenmesinde pek çok kez deneme yapılmış olup en iyi sonucu veren değer baz alınmıştır.

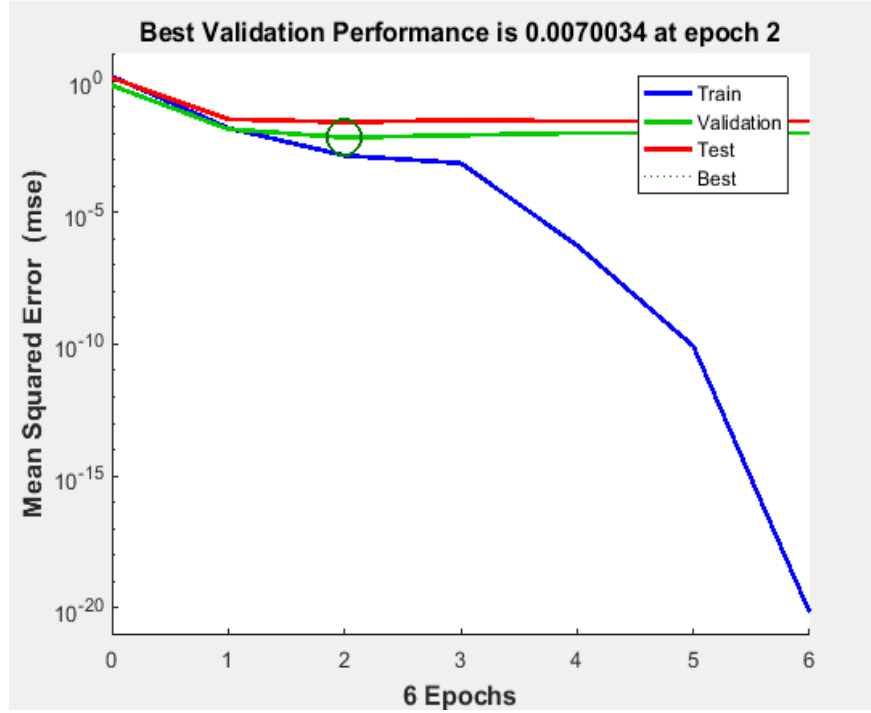
Eğitim işleminin başarısını R (Regresyon) parametresi ve hata oranı belirlemektedir. Ayrıca iki veya daha fazla değişkenin birbirleri ile olan ilişkisini ölçmek için de regresyon analizi kullanılmaktadır. Eğitim, doğrulama, test ve tüm aşamalar için bulunan regresyon sonuçlarına Şekil 7’de yer verilmiştir. Regresyon grafiğinde hedeflenen değer 1’e ne kadar yakın olursa sonuç o kadar iyidir. Grafikte hedeflenen değer 1’e yakın olduğu görülmektedir.

Şekil 7: Yapay Sinir Ağı Regresyon Grafiği



NARX ağının performansı MSE ile ölçülmektedir. MSE, çıktılar ve hedefler arasındaki ortalama kare farkını ifade etmektedir. Düşük değerler daha başarılı olduğu, sıfır ise hata olmadığı anlamına gelmektedir. Şekil 8’de grafiğin her adımındaki MSE değerleri ve performans grafiği verilmiştir.

Şekil 8: Yapay Sinir Ağı Performans Grafiği



Eğitim sonucunda her iterasyondaki eğitim, doğrulama ve test kümelerine bağlı olarak hata değerlerinin ne şekilde değiştiğini gösteren grafik Şekil 8'de gösterilmiştir. Grafikte görüldüğü üzere eğitim 6 iterasyonda tamamlanmış ve 2. iterasyonda en düşük MSE değeri elde edilmiştir. Ayrıca NARX ağı bu aşamada en iyi doğrulama ve performansı gerçekleştirmiştir.

Tablo 6'da 2019, 2020 ve 2021 yıllarına ait 3 yıllık öngörü değerleri görülmektedir.

Tablo 6: YSA NARX Modeli 3 Yıllık Öngörü Değerleri

Tarih	Öngörülen Elma Üretim Miktarı Değerleri (Ton)
2019	4086386.209
2020	4321019.359
2021	3573754.312

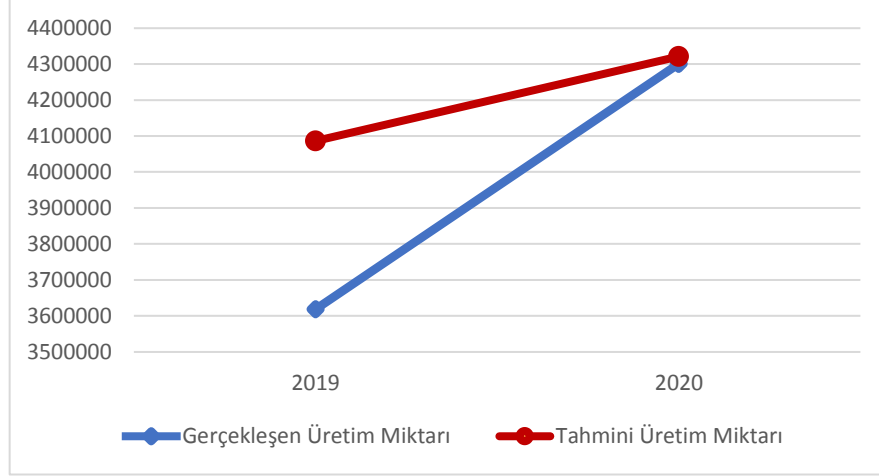
Tablo 7’de ise 2019 ve 2020 yıllarının gerçekleşen üretim değerleri ile bu çalışmada öngörülen üretim değerleri yer almaktadır. Ayrıca Tablo 7’de MAPE değeri de görülmektedir. %6,69 hata payı ile elde edilen öngörü değeri, yapılan çeşitli denemeler sonucunda optimum değer olarak bulunmuştur. Witt ve Witt (1992), MAPE değerleri %10’un altında olan tahmin modellerini “yüksek doğruluk” derecesine sahip, %10 ile %20 arasında olan modelleri ise “doğru tahminler” olarak sınıflandırmıştır. Benzer şekilde Lewis (1982), MAPE değerleri %10’un altında olan modelleri “çok iyi”, %10 ile %20 arasında olan modelleri “iyi”, %20 ile %50 arasında olan modelleri “kabul edilebilir” ve %50’nin üzerinde olan modelleri ise “yanlış ve hatalı” olarak sınıflandırmıştır (Çuhadar, 2013: 5288). MAPE değeri %6,69 ile yüksek doğruluk derecesine sahip veya çok iyi tahmin sınıfına girmektedir.

Tablo 7: Gerçekleşen Değerler ile Öngörü Değerlerinin Karşılaştırılması

Tarih	Gerçek Değerler	Öngörü Değerleri	Performans Ölçütleri	Performans Ölçüt Değerleri
2019	3618752	4086386.209	MSE	0,0070034
2020	4300486	4321019.359	RMSE	0,0836863
			MAPE	6,69999657

Tablo 7’de tahmin değerleri için hesaplanan MSE, RMSE ve MAPE performans ölçütleri ve bu ölçütlerin değerleri verilmiştir. Performans ölçüt değerlerinin düşük olması ağın iyi öğrendiğini göstermektedir.

Şekil 9’da gerçekleşen üretim miktarları ile bu çalışmada öngörülen üretim miktarlarının karşılaştırıldığı modelin performansını görsel olarak ifade eden grafik gösterilmiştir. Tahmin hatalarını ölçmede yaygın olarak kullanılan MAPE değeri %10’un altında olduğu için yüksek doğruluk derecesine sahip veya çok iyi tahmin sınıfına girdiği ve böylece yapılan tahminin başarılı bir şekilde sonuçlandığı Tablo 7’de görülmektedir. Şekil 9’daki grafikten de görüldüğü üzere hem 2019 için hem de 2020 yılı için tahmin edilen üretim miktarının gerçekleşen üretim miktarına göre daha fazla olduğu görülmektedir. Bunun sebebinin neler olabileceği ile ilgili bilgilere sonuç bölümünde yer verilmiştir.

Şekil 9: Gerçek Değerler ile Tahmin Değerlerinin Karşılaştırılması

6. SONUÇ VE DEĞERLENDİRME

Tarımsal üretim her ulus için önemlidir. Meyve endüstrisi; halkın beslenmesi, meyve işleyen sanayilere hammadde temin etmesi, istihdam sağlama, katma değerinin göreceli olarak daha yüksek olması ve dış ticarete konu olması bakımından güçlü bir sektördür. 2020 yılına göre meyveler içinde önemli ürünlerin üretim miktarlarına bakıldığında bir önceki yıla göre en fazla artış gösteren meyve elmadır. Bu bağlamda elma farklı ekolojilere uyum sağlayabilmesi sayesinde Dünya üzerinde geniş bir yayılım göstermiştir. Türkiye, Dünya’da elma üretiminde Çin ve Amerika Birleşik Devletleri’nden sonra üçüncü sırada yer almaktadır. Türkiye’nin yeterli elma alanlarına sahip olmasına karşın elma üretimini daha da artırması, çiftçilerin üretimlerini iyileştirmeleri için bilgilendirilmeleri ve daha iyi politikaların oluşturulması gerekmektedir.

Yapay sinir ağları öğrenme için daha çok veriye ihtiyaç duymaktadır. Bu yüzden çalışmada iyi bir tahminleme yapabilmek için verilere 1966 yılına kadar ulaşılmış olup çalışma 1966 yılı ile sınırlandırılmıştır.

NARX modeli, bilgiyi geleneksel ağlardan iki ila üç kat daha uzun süre saklayabilmektedir. NARX modeli, doğrusal olmayan dinamik sistemlerin giriş-çıkış modellemesi için yaygın olarak kullanılan dinamik bir yapay sinir ağı mimarisidir. Doğrusal olmayan dinamik sistemleri modellemede başarılı olduğu için YSA NARX modeli ile elma üretim miktarı öngörülmüştür.

Çalışmada TÜİK ve FAO tarafından sunulan istatistiklerden yararlanılmıştır. 1966-2018 yıllarına ait yıllık veriler kullanılmıştır. Bu kapsamda belirtilen yıllara ait portakal basit fiyat endeksi, elma basit fiyat endeksi, elma üretim alanı, sıcaklık ve teknoloji girdi değişkenleri kullanılarak elma üretim miktarı öngörülmüştür. Çalışma sonucunda 2019, 2020 ve 2021 yıllarına ait elma üretim miktarları öngörülmüş ve bulunan sonuçlar YSA NARX modelinin elma üretim miktarı tahmininde ve öngörülmesinde iyi bir araç olduğunu göstermiştir.

2019 ve 2020 yıllarına ait elde edilen öngörü değeri %6,69 olarak bulunmuştur. MAPE değeri %10'un altında olduğu için bu çalışma, yüksek doğruluk derecesine sahip veya çok iyi tahmin sınıfına girmektedir. Böylece yapılan tahminin başarılı olduğu söylenebilir.

YSA NARX modeline göre 2021 yılı için yapılan öngörü 3573754.312 ton olarak bulunmuştur. 2021 yılı elma üretim miktarları açıklanmadığı için yapılan öngörü gerçek değerler ile kıyaslanamamıştır.

Yapılan denemeler sonucunda 5 yıllık ve 4 yıllık yapılan öngörüler 2 yıllık ya da 3 yıllık yapılan öngörüye göre daha fazla hata vermektedir. Bu bağlamda yapay sinir ağlarının kısa dönemli tahminlerde iyi sonuçlar verdiği görülmüştür. Dolayısıyla elma üretim ve pazarlama sektöründe kısa dönemli tahminlerin yapılması elma üretim miktarı öngörüsünün daha isabetli sonuçlar vermesine katkı sağlayacaktır.

YSA NARX modeli kullanılarak elma üretim miktarının öngörülmesi için yapılan bu çalışma mevcut elma sektörü politikalarına ek olarak yeni politikaların belirlenmesine katkı sağlayacaktır. Çalışmanın geleceğe yönelik hedefi ise, başka tarım ürünlerine de örnek olması ve diğer tarım ürünleri üzerinde de uygulanmasıdır.

KAYNAKÇA

- Akarşlan, E. ve Hocoğlu, F. O. (2019). NARX ve Relieff Yöntemlerinin Kombinasyonu ile Saatlik Yük Tahmini. 6. Uluslararası Bilimsel Araştırmalar Kongresi (UBAK), 1-3 Kasım 2019, Şanlıurfa, 175-184.
- Akpınar, H. (1994). Yapay Sinir Ağları Gelişimi ve Yapılarının İncelenmesi. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 23(1), 41-78.
- Aras, İ. (2015). *Karaman Elma Raporu*. Mevlâna Kalkınma Ajansı Yayınları, Konya.

- Aydoğan, M., Demiryürek, K. ve Abacı, N. İ. (2015). Türkiye’de Kuru Fasulye Üretiminin Mevcut Durumu ve Gelecek Dönemler Üretiminin Tahmin Edilmesi. *Türk Tarım-Gıda Bilim ve Teknoloji Dergisi*, 3(12), 962-968.
- Başaran Caner, C. ve Engindeniz, S. (2020). Türkiye’de Pamuk Üretiminin ARIMA Modeli ile Tahmini. *Tarım Ekonomisi Dergisi*. 26(1), 63-70.
- Boussaada, Z., Curea, O., Remaci, A., Camblong, H. & Najiba, N. B. (2018). A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model For The Prediction Of The Daily Direct Solar Radiation, *Energies* 2018, 11(3), 620, <https://doi.org/10.3390/en11030620>.
- Can, Ş. ve Gerşil, M. (2018). Manisa Pamuk Fiyatlarının Zaman Serisi Analizi ve Yapay Sinir Ağı Teknikleri ile Tahminlenmesi ve Tahmin Performanslarının Karşılaştırılması. *Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 25(3), 1017–1031.
- Connor, J., Atlas, L., & Martin, R. (1991). Recurrent Networks and NARMA Modeling. Proceedings of the 4th International Conference on Neural Information Processing Systems (NIPS), Aralık 1991, 301-308.
- Çavuşlu, M. A., Becerikli, Y. ve Karakuzu, C. (2012). Levenberg-Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5(1).
- Çetin, E. (2021). *Yapay Zekâ Uygulamaları: Yapay Sinir Ağı-Makine Öğrenmesi-Derin Öğrenme-Derin Ağlar-Bulanık Mantık-Sinirsel Bulanık Mantık-Genetik Algoritma*. Seçkin Yayıncılık, Ankara.
- Çuhadar, M. (2013). Türkiye’ye Yönelik Dış Turizm Talebinin MLP, RBF ve TDNN Yapay Sinir Ağı Mimarileri ile Modellenmesi ve Tahmini: Karşılaştırmalı Bir Analiz. *Journal of Yaşar University*, 8(31), 5274-5295.
- Dahikar, S. S. & Rode, S. V. (2014). Agricultural Crop Yield Prediction Using Artificial Neural Network Approach. *International Journal of Innovative Research in Electrical, Electronics, Instrumentation and Control Engineering*, 2(1), 683-686.

- Değirmenci, N. ve Pabuçcu, H. (2016). Borsa İstanbul ve Risk Primi Arasındaki Etkileşim: VAR ve NARX Model. *Akademik Sosyal Araştırmalar Dergisi*, 35, Yıl: 4, 248-261.
- Diaconescu, E. (2008). The Use of NARX Neural Networks to Predict Chaotic Time Series. *WSEAS Transactions on Computer Research*, 3(3), 182-191.
- Doğan, E., Işık, S. ve Sandalcı, M. (2007). Günlük Buharlaşmanın Yapay Sinir Ağları Kullanarak Tahmin Edilmesi, *İMO Teknik Dergi*, 18(87), 4119-4131.
- FAOStat, 2021. Food and Agriculture Organization of the United Nations. <http://www.fao.org/faostat/en/#data/QC/visualize>, Erişim Tarihi: 21.01.2021.
- Fırat, Y. (2020). NARX Modellerini Kullanarak Hava Kalitesi Tahmin Analizinin Uygulanması, *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 10(2), 442-455.
- Gavcar, E. (2013). *İstatistik Yöntemler 1*. Gazi Kitabevi. Ankara.
- Griffiths, W. E., Newton, L. S. & O'Donnell, C. J. (2010). Predictive Densities for Models with Stochastic Regressors and Inequality Constraints: Forecasting Local-Area Wheat Yield, *International Journal of Forecasting*, 26(2), 397-412, <https://doi.org/10.1016/j.ijforecast.2009.12.008>.
- Grosan, C. & Abraham, A. (2011). *Intelligent Systems: A Modern Approach*. Intelligent Systems Reference Library, Volume 17, Springer-Verlag, Berlin.
- Hamzaçebi, C. (2005). Geleceği Tahminde Yapay Sinir Ağları İçin Sezgisel Öğrenme Algoritması, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Hamzaçebi, C. (2011). *Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı MATLAB ve Neurosolutions Uygulamalı*, Ekin Basım Yayın, Ankara.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Second Edition. McMaster University. Pearson Education, Canada.
- Karaatlı, M., Demirci, E. ve Baykaldı, A. (2020). Ticari Kredi Faiz Oranlarının YSA NARX ve VAR Modelleri ile Öngörülmesi, *İşletme Araştırmaları Dergisi*, 12(3), 2327-2343.

- Karahan, M. (2015). Turizm Talebinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 20(2), 195-209.
- Karahan, M. (2015). Yapay Sinir Ağları Metodu İle İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi, *Ege Akademik Bakış*, 15(2), 165-172.
- Khamis, A. & Abdullah, S. N. S. B. (2014). Forecasting Wheat Price Using Backpropagation and NARX Neural Network, *The International Journal of Engineering and Science (IJES)*. 3(11), 19-26.
- Khan, T., Qiu, J., Qureshi, M. A. A., Iqbal, M. S., Mehmood, R. & Hussain, W. (2020). Agricultural Fruit Prediction Using Deep Neural Networks, 2019 International Conference on Identification, Information and Knowledge in the Internet of Things (IIKI2019), 174. 72-78, DOI: 10.1016/j.procs.2020.06.058.
- Labde, S., Patel, S. & Shukla, M. (2017). Time Series Regression Model for Prediction of Closing Values of the Stock using an Adaptive NARX Neural Network. *International Journal of Computer Applications*, 158(10), 29-34.
- Lewis, C. D. (1982). *Industrial and Business Forecasting Methods: A Practical Guide to Exponential Smoothing and Curve Fitting*. London, Butterworth Scientific.
- Lin, T., Horne, B. G., Tino, P. & Giles, C.L. (1996). Learning Long-Term Dependencies in NARX Recurrent Neural Networks, *IEEE Transactions on Neural Networks*, 7(6), 1329-1338.
- Mathworks (2021). Design Time Series NARX Feedback Neural Networks. <https://www.mathworks.com/help/deeplearning/ug/design-time-series-narx-feedback-neural-networks.html>, Erişim Tarihi: 12.03.2021.
- Menezes Jr., J. M. P. & G. A. Barreto (2008). Long-Term Time Series Prediction with the NARX Network: An Empirical Evaluation, *Neurocomputing*, 71, 16–18 October 2008, 3335–3343 (Advances in Neural Information Processing (ICONIP 2006) /Brazilian Symposium on Neural Networks (SBRN 2006).
- Öztemel, E. (2003). *Yapay Sinir Ağları*. Papatya Yayıncılık. İstanbul.

- Öztürk, B., Özkan, Y., Yıldız, K., Çekiç, Ç. ve Kılıç, K. (2012). Red Chief Elma Çeşidinde Aminoethoxyvinylglycine'nin (AVG) ve Naftalen Asetik Asit'in (NAA) Hasat Önü Döküm ve Meyve Kalitesi Üzerine Etkisi, *Anadolu Tarım Bilimleri Dergisi*, 27(3), 120-126.
- Öztürk, F. P., Emre, M. ve Karamürsel, D. (2015). *Tarımsal Araştırmalardan Bakış 2015*, Elma, TEPGE Yayınları, Ankara.
- Siegelmann, H. T., Horne, B. G. & Giles, C. L. (1997). Computational capabilities of recurrent NARX neural networks. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 27(2), 208-215. DOI: 10.1109/3477.558801.
- Su, H.-T. & McAvoy, T. J. (1991). Identification of Chemical Processes using Recurrent Network. 1991 American Control Conference, 2314-2319.
- Su, H.-T., McAvoy, T. J. & Werbo, P. (1992). Long-Term Predictions of Chemical Processes Using Recurrent Neural Networks: A Parallel Training Approach. *Industrial & Engineering Chemistry Research*, 31(5), 1338-1352. <https://doi.org/10.1021/ie00005a014>.
- T. C. Gıda Tarım ve Hayvancılık Bakanlığı Tarım Gıda ve politika Geliştirme Enstitüsü (TEPGE). 2017. Ürün Raporu, <https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF%20%C3%9Cr%C3%BCn%20Raporlar%C4%B1/2017%20%C3%9Cr%C3%BCn%20Raporlar%C4%B1/Elma%20%C3%9Cr%C3%BCn%20Raporu%202017-296.pdf>, Erişim Tarihi: 21.01.2021.
- Tatlı, A. ve Kahvecioğlu, S. (2016). Zaman Serilerinde NARX Sınır Ağları Modeliyle Uçuşa Elverişlilik Süresinin Kestirimi. 2016 Ulusal Elektrik, Elektronik ve Biyomedikal Mühendisliği Konferansı (ELECO), Bursa, 1-3 Aralık 2016, 130-134.
- TMMOB Ziraat Mühendisleri Odası, (2019). Elma Raporu/2019. Erişim Tarihi: 19.01.2021. https://www.zmo.org.tr/genel/bizden_detay.php?kod=32410&tipi=38&sube=0.
- TÜİK (2021). Merkezi Dağıtım Sistemi, Bitkisel Üretim İstatistikleri. <https://biruni.tuik.gov.tr/medas/?kn=92&locale=tr>, Erişim Tarihi: 31.03.2021.

- TÜİK (2021). Türkiye İstatistik Kurumu, Bitkisel Üretim İstatistikleri 2020. <https://data.tuik.gov.tr/Bulten/Index?p=Bitkisel-Uretim-Istatistikleri-2020-33737>, Erişim Tarihi: 23.01.2021.
- Venkataraman, S. T. (1994). On Encoding Nonlinear Oscillations in Neural Networks for Locomotion. In: Proc. 8th Yale Workshop Adaptive and Learning Systems, 14–20.
- Witt, S. F. & Witt C. (1992). *Modeling and Forecasting Demand in Tourism*, Academic Press, London.
- World Bank (2021). Temperature (1901-2018). <https://climateknowledgeportal.worldbank.org/download-data>, Erişim Tarihi: 03.03.2021.
- Xie, H., Tang, H. & Liao, Y. (2009). Time Series Prediction Based on NARX Neural Networks: An Advanced Approach, Proceedings of the Eighth International Conference on Machine Learning and Cybernetics, China, 12-15 July 2009, 3, 1275-1279.
- Yavuz, S. ve Deveci, M. (2012). İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187.
- Zhang, G., Patuwa, B. E. & Hu, M. Y. (1998). Forecasting with Artificial Neural Networks: The State of The Art. *International Journal of Forecasting*, 14(1), 35-62. [http://dx.doi.org/10.1016/S0169-2070\(97\)00044-7](http://dx.doi.org/10.1016/S0169-2070(97)00044-7).
- Zhang, L., Ma, L., Zhu, M., Li, K., Gan, S., Yan, J., Xu, X. & Li, W. (2016). NARX Models for Predicting Power Consumption of a Horizontal Axis Wind Turbine, UKACC 11th International Conference on Control, Belfast, 31 August-2 September 2016.