

TÜRKİYE LİMANLARINDAKİ KONTEYNER VE YÜK ELLEÇLEME HACİMLERİNİN NARX SİNİR AĞLARI MODELİ İLE ÖNGÖRÜLMESİ

Gamze KILINÇ¹, Meltem KARAATLI², Nuri ÖMÜRBEK³

ÖZET

Amaç: Bu çalışmada mevcut donanımı daha etkili ve verimli kullanabilmek amacıyla Türkiye'deki limanlarda gerçekleşen konteyner ve yük elleçleme miktarlarının öngörüsü yapılmıştır. Konteyner ve yük hacimlerinin öngörüsü, konteyner ve yük akışındaki planlamanın yapılmasını sağlayacak ve böylece işletmelerin hizmet kalitesinin iyileştirilmesine destek olacaktır.

Yöntem: Bu çalışmada Türkiye'deki limanlarda gerçekleşen konteyner ve yük elleçleme miktarının Yapay Sinir Ağları (YSA) Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) Modeli ile öngörüsü gerçekleştirilmiştir. Çalışmada iki bağımlı değişken olan konteyner elleçleme ve yük elleçleme miktarı ile ilgili bir öngöründe bulunabilmek için Döviz Sepeti Kuru (USD-EURO), Gayri Safi Yurtiçi Hasıla (GSYH), Tüketici Güven Endeksi, Brent Petrol, İhracat, İthalat ve Sanayi Üretim Endeksi bağımsız değişkenleri kullanılmıştır. Veri seti Ocak 2004-Ekim 2020 dönemine ait aylık verilerden oluşmaktadır.

Bulgular: Konteyner ve yük elleçleme miktarlarının, Temmuz 2020-Aralık 2021 dönemi için 18 aylık öngörü değerleri hesaplanmıştır. Bu öngörü değerlerinden açıklanan ilk 4 ay ile tahmin ve gerçek değer karşılaştırılması yapılmıştır. Ayrıca MAPE, MAE, RMSE ve MAD performans ölçütleri hesaplanmıştır.

Özgünlük: Türkiye limanlarında gerçekleşen konteyner ve yük elleçleme miktarlarının öngörüsü için daha önce kullanılan tahmin tekniklerinden farklı olarak NARX sinir ağları modeli kullanılmıştır.

Anahtar kelimeler: NARX Sinir Ağları, Konteyner Elleçleme, Yük Elleçleme, Öngörü.

JEL Kodları: C45, C53, R40.

FORECASTING CONTAINER AND CARGO HANDLING VOLUMES IN TURKEY'S PORTS WITH NARX NEURAL NETWORKS MODEL

ABSTRACT

Purpose: In this study, in order to use the existing equipment more effectively and efficiently, the amount of container and cargo handling realized at the ports in Turkey has been predicted. The forecast of container and cargo volumes will enable the planning of container and cargo flow and thus support the improvement of the service quality of the enterprises.

Methodology: In this study, the amount of container and cargo handling in ports in Turkey is forecasted with Artificial Neural Networks (ANN) Nonlinear External Input Autoregressive Network Model (NARX). In order to forecast the amount of container handling and cargo handling, which are two dependent variables in this study; The Foreign Exchange Basket Rate (USD-EURO), Gross Domestic Product (GDP), Consumer Confidence Index, Brent Oil, Export, Import and Industrial Production Index independent variables are used. Data set includes the monthly data for the period January 2004-October 2020.

Findings: For the period July 2020-December 2021, 18-month forecast values of container and cargo handling quantities are calculated. Forecast and actual value comparisons are made for the first 4 months with announced and predictive values. In addition, MAPE, MAE, RMSE and MAD performance measures are calculated.

Originality: Different from previous forecasting techniques, NARX neural network model is used for the prediction of container and cargo handling quantities in Turkish ports.

Keywords: NARX Neural Networks, Container Handling, Cargo Handling, Forecasting.

JEL Codes: C45, C53, R40.

¹ Lojistik Alt Alanında YÖK 100/2000 ve TÜBİTAK Doktora Bursiyeri, Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Isparta, Türkiye, gamzeeklncc@gmail.com, ORCID: 0000-0001-7746-3634 (Sorumlu Yazar-Corresponding Author).

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

³ Prof. Dr., Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Isparta, Türkiye, nuriomurbek@sdu.edu.tr, ORCID: 0000-0002-0360-4040.

1. GİRİŞ

Küreselleşen dünya ile birlikte giderek artan satın almalar ve stratejik ittifaklar, işletmelerin maliyet tasarrufu için yollar aramasına sebep olmuştur. İşletmelerin faaliyetlerini etkili ve verimli yürütebilmeleri için lojistik işlemlerinin en uygun şekilde yerine getirilmesi gerekir. Etkin ve verimli lojistik hizmetlerinin, lojistik maliyetlerini düşürmek, değer katmak ve kârlılığı artırmak gibi faydaları bulunmaktadır (Konings, 2008: 66). Dünya ticaretinin %90'ı deniz taşımacılığı ile gerçekleşmektedir. Ülkemizde ise bu oran %86'dır. Dünya genelinde deniz taşımacılığı ile kara taşımacılığının arayüzü olan limanlarda gerçekleşen trafik ise yılda ortalama %3 oranında artış göstermektedir (Trujillo ve Tovar, 2007; Yüksekıldız, 2021). Küresel tedarik zinciri ve lojistiğin bir alt dalı olan deniz taşımacılığında limanlar en önemli ulaştırma altyapılarıdır. Limanlarda gerçekleştirilen yük elleçleme işlemi; depolama, liman içi taşıma, yükleme ve tahliye işlemlerinden oluşmaktadır. Kısacası; tüm yük hareketlerinin planlama, örgütlenme ve denetimi işlemlerini kapsamaktadır. Konteynerler ise standart bir yük yapısına sahip oldukları ve diğer taşıma araçlarıyla kolayca bütünleşerek rahat taşıma imkânı sağladığı için konteyner taşımacılığına uluslararası ticarete ilgi giderek artmaktadır. Bu sebeple limanların etkin ve verimli bir şekilde işletilmesi son derece önemlidir. Bu durum sadece liman işletmecilerini değil aynı zamanda gemi şirketleri, malzemelerin sahipleri ve ulusal ve uluslararası liman planlamacıları açısından da önem arz etmektedir. Bu ilgi ile beraber, artan yük hacmini takip etmek için bilişim altyapısı zorunlu hale gelmiştir (Ateş ve Esmer, 2014; Esmer, 2009: 20-25).

Geleneksel bilgisayar programları; yeni bilgiler oluşturamaz, üretmez ya da keşfedemezler. Ancak insan beyninden ilham alınarak geliştirilen yapay sinir ağları geliştirilmiş adaptif bilgi işleme yeteneğine sahiptir. Yapay sinir ağları (YSA); eksik veri ile çalışabilme, belirsizlikler altında karar verebilme ve hatalara karşı toleranslı olma gibi yetenekleri sayesinde günümüzde sıkça tercih edilmektedir. Özellikle; sınıflandırma, örüntü tanıma, tahmin yapma, sinyal filtreleme, veri sıkıştırma ve optimizasyon çalışmalarında başarılı sonuçlar vermektedir (Öztemel, 2003: 29). YSA karmaşık ilişkileri saptayabilme ve doğrusal olmayan bağlantıları iyi derecede modelleyebilme yeteneğine sahiptir (Milenkovic, 2019). Bu sebeple; yük ve konteyner akışını takip etmek ve gelecekteki hacimlerini tahmin etmek amacıyla bu çalışmada YSA yöntemi kullanılmıştır. Böylece, konteyner ve yük hacimlerinin tahmini ile hizmet düzenliliğini etkileyen belirsizlik büyük ölçüde giderilmiş olur. İşletmeler; artan güvenilirlik ve esneklik, teslim süresinde azalma ve taşıma zincirlerindeki maliyetlerde azalma gibi faydalar sağlayarak rekabet gücünü artırır. Tahminlerin doğruluğu, işletmelerin varlıklarını daha verimli ve etkili kullanmasını sağlar (Milenkovic, 2019).

Günümüzde iş dünyasındaki yoğun rekabet, faaliyetlerin etkili ve verimli bir şekilde gerçekleştirilerek pazardaki rekabet gücünü artırmayı zorunlu kılmıştır. Dünya ticaretinde büyük ölçüde role sahip olan limanların da organizasyonel verimliliği önem arz etmektedir. Bu konu akademik hayatta da yansımalar bulmuş ve akademisyenlerin limanlar üzerine çeşitli verimlilik analiz çalışmaları gerçekleştirdikleri görülmüştür.

Valentine ve Gray (2001), özel ve/veya devlete ait limanların göreceli verimliliğini değerlendirmek için Veri Zarflama Analizi ve organizasyon yapılarını incelemek adına da kümeleme analizi gerçekleştirmişlerdir. Girdi değişkeni olarak toplam rıhtım uzunluğu ve konteyner rıhtım uzunluğu; çıktı değişkeni olarak ise elleçlenen konteyner sayısı ve elleçlenen toplam yük miktarı kullanılmıştır. Bu analiz sonucunda limanların nasıl daha verimli kullanılacağına dair kılavuz niteliğinde bir yeniden yapılandırmaya dikkat çekmişlerdir. Bichou (2013), 420 konteyner terminalinin liman pazarı, üretim ölçeği, kargolama ve aktarma oranı ve çalışma prosedürleri gibi durumlarının verimlilik üzerine duyarlılığını test etmek amacıyla bir dizi Veri Zarflama Analizi gerçekleştirmiştir. Girdi değişkeni olarak terminal alanı, draft, rıhtım uzunluğu, rıhtım kreyn endeksi, saha istif endeksi, kamyon, araç ve kapı sayıları; çıktı değişkeni olarak ise elleçlenen konteyner miktarı kullanılmıştır. Bu analiz sonucunda büyük çaplı teknolojik modern limanların daha verimli olduklarını tespit etmiştir. Barros (2003), limanların operasyonel faaliyetlerindeki göreceli verimliliklerin belirlenmesi ve düşük performanslı limanların işleyişini iyileştirmek adına Veri Zarflama Tekniği ile bir verimlilik analizi gerçekleştirmiştir. Girdi değişkeni olarak emek (işçi sayısı) ve sermaye (varlıkların defter değeri); çıktı değişkeni olarak ise gemiler, yük hareketi, brüt tonaj, pazar payı, dökme yük, konteynerli kargo, roll-on/roll-off (ro/ro) trafiği, kuru yük, sıvı dökme yük ve net gelir kullanılmıştır. Bu analiz sonucunda verimliliği iyileştirme adına verimlilik teşviklerine sahip kurumsal ortam gerekliliğine işaret edilmiştir.

Bahsedilen verimlilik analizi çalışmalarında görülmektedir ki limanlarda yeni yapılandırmalar ya da var olan yapıyı geliştirme üzerine potansiyel iyileştirme önerileri sunulmaktadır. Ancak limanların rıhtım uzunluğu, otomasyon sistemleri, terminal alanı vb. konularda mevcut donanımlarını ve kapasitelerini artırmak oldukça pahalı, riskli ve uzun soluklu işlemlerdir. Bu sebeple bazı durumlarda mevcut durumdaki var olan yapıyı daha etkili ve verimli kullanmak tercih söz konusu olabilir (Çağlar ve Oral, 2011). Bu durumda da literatürde, limanlarda elleçlenen yük miktarının tahmin çalışmaları yer almaktadır. Çünkü

gelecekteki elleçlenecek yük arını öngörmekle devletler, liman yöneticileri ve liman sahipleri planlamalarını daha gerçekçi yapma imkânı hacmini bulacaklardır. Bu sayede gereksinim duyulan doğru ürün ve/veya hizmeti, doğru zamanda, doğru hızda ve doğru bir biçimde yerine getirmiş olacaklardır. Bu kapsamda literatürde çeşitli modeller ile tahmin çalışmaları mevcuttur.

Chou ve diğerleri (2008) çalışmalarında; Tayvan'ın ithalat konteynerlerinin hacimlerini tahmin etmek için geliştirilmiş bir regresyon modeli önermişlerdir. Geleneksel regresyon modeli ile geliştirilen regresyon modelinin sonuçlarını karşılaştırmışlardır. Geliştirdikleri regresyon modelinin, geleneksel regresyon modeline göre tahmin hatalarının daha düşük olduğu sonucuna varmışlardır. Coto-Millan ve diğerleri (2005) çalışmalarında; deniz ithalat ve ihracatında, İspanyol ekonomisini etkileyen açıklayıcı değişkenleri gösteren bir model sunmuşlar ve talep tahmininde bulunmuşlardır. Analiz için Johansen ve Juselius çok değişkenli eşbütünlük tekniklerini kullanmışlardır. Çalışma sonucunda, İspanya deniz ithalatının belirleyicileri milli gelir, ithalat fiyatları ve deniz taşımacılığı hizmetleri; İspanyol deniz ihracatının belirleyicileri ise dünya geliri, ihracat ve deniz taşımacılığı fiyatları ve işletmelerin üretim kapasitesinin kullanım durumu olarak bulunmuştur. Köse (2018) çalışmasında; Trabzon Limanında elleçleme yapan ekipmanların yıllar bazında yakıt tüketim maliyetlerindeki değişimi analiz etmiş ve regresyon analizi yöntemi ile tahminleme çalışması yapmıştır. Abdirassilov ve Sładkowski (2018) çalışmalarında; Çin-Avrupa yönündeki konteyner tren akışlarını tahmin etmek için YSA yöntemini kullanmışlardır. Eğitim sürecinin nasıl ilerlediğine ve parametrelerin nasıl ayarlanabildiğine değinmişlerdir. Performans ölçütü olarak MAPE'yi ele almışlar ve yüzde 3,25 değerine ulaşmışlardır. Tsai ve Huang (2017) çalışmalarında; Asya limanlarındaki konteyner akışlarını tahmin etmek için YSA kullanmışlardır. Bağımlı değişkenler olarak; GSYİH, faiz oranları, ihracat ve ithalat ticaretinin değeri, ihracat ve ithalat konteynerlerinin sayısı ve rıhtım vinçlerinin sayısını dikkate almıştır.

Literatürde tek bir yöntem ile yapılan tahmin çalışmalarına ek olarak tahmin yöntemlerinin karşılaştırmalı analiz çalışmalarına da rastlanılmıştır. Yapay Sinir Ağları (YSA) yöntemi ile geleneksel tahmin yöntemlerinin karşılaştırmalı analiz çalışmalarında, YSA yönteminin daha iyi performans gösterdiği (Ding ve diğerleri, 2015; Eswari ve diğerleri, 2020; Karahan, 2015; Panda ve Narasimhan, 2007; Pulido-Calvo ve diğerleri, 2007) görülmektedir.

Gosasang ve diğerleri (2011) çalışmalarında; Bangkok limanındaki konteyner verimi için geleneksel tahmin yöntemi ve sinir ağları tahmin tekniklerinin karşılaştırmasını yapmışlardır. Yapay sinir ağlarının performansının daha üstün olduğu sonucuna ulaşmışlardır. Performans ölçütü olarak RMSE ve MAE'yi ele almışlardır. Geleneksel tahmin yöntemi olarak lineer regresyon; Sinir ağları yöntemi olarak, Çok katmanlı algılayıcı (MLP) kullanmışlardır. Lineer regresyon yöntemi için RMSE ve MAE değerleri sırası ile 7832.7717 ve 6028.5571'dir. Çok katmanlı algılayıcı (MLP) için RMSE ve MAE değerleri sırası ile 6410.4395 ve 4814.7768'dir. Korelasyon uyumluluğu ise 0,9509 olarak elde edilmiştir. Hamzaçebi ve Kutay (2004) çalışmalarında; uzun dönemli elektrik enerjisi tüketimi tahmininde YSA yöntemi, Box-Jenkins modelleri ve regresyon tekniği ile karşılaştırmalı analiz yapmışlardır. YSA yönteminin en iyi performansı gösterdiği sonucuna ulaşmışlardır. Regresyon tekniğinin ve Box-Jenkins modellerinin ise yüksek performans gösterebilmesinin, frekansa bağlı olduğunu bulmuşlardır. Karaatlı ve diğerleri (2020) çalışmalarında; ticari kredi faiz oranlarının NARX sinir ağları modelleri ve VAR modelleri ile öngörüsünü yapmışlardır. Performans ölçütü olarak MAD, MSE, RMSE ve MAPE değerlerini ele almışlardır. VAR modeli için; MAD 9.03157, MSE 96.94534, RMSE 9.84608, MAPE 57.15089 olarak elde edilmiştir. NARX sinir ağları modeli için ise MAD 0.875885, MSE 1.230978, RMSE 1.109495, MAPE 4.821409 olarak elde edilmiştir. Sonuç olarak, NARX sinir ağları modelinin VAR modeline kıyasla daha iyi performans elde ettiğini göstermişlerdir.

YSA'nın geleneksel tahmin modellerine göre daha üstün performans göstermesinin yanı sıra Lin ve diğerleri (1996) çalışmalarında; NARX sinir ağlarının, bilgileri geleneksel tekrarlayan yapay sinir ağlarından iki ile üç kat daha uzun süre saklayabildiğini gösteren sonuçlara ulaşmışlardır.

Di Piazza ve diğerleri (2016) çalışmalarında; NARX sinir ağları modeli ile güneş ışınımı ve rüzgâr hızı için tahmin modeli kurmuşlardır. Dışsal girdi olarak sıcaklık dahil edilmiştir. Performans ölçütü olarak NRMSE ve CV'yi (RMSE) ele aldıkları çalışmada güneş ışınımı tahmini için sırasıyla %6,1 ve %32; rüzgâr hızı tahmini için %7 ve %47 değerlerini elde etmişlerdir. Ayrıca en uygun ağ yapısını bulmak amacı ile çok sayıda tekrar yapan diğer ağ yapılarına göre NARX sinir ağları modelinin ağın performansını da iyileştirdiği sonucuna ulaşmışlardır. Boussaada ve diğerleri (2018) çalışmalarında; NARX sinir ağları modeli ile hareketli ve yatay bir zemindeki güneş radyasyonu için tahmin modeli kurmuşlardır. NARX sinir ağının eğitim aşaması, bulutluluk seviyesi, güneş seviyesi ve yelkenli hareketliliği gibi parametreler dahilinde analizi gerçekleştirmişlerdir. Performans ölçütü olarak MSE ve DMPE'yi ele aldıkları çalışmada sırasıyla 0,00279 ve 24.0584 W/m² değerlerini elde etmişlerdir. Siegelmann ve diğerleri (1997) çalışmalarında; NARX sinir ağları modelinin hesaplama yeteneğini incelemişlerdir. Sonuç olarak NARX sinir ağları modelinin, tekrarlayan ağ yapılarına göre gradyan inişli öğrenmenin ve uzun dönemli bağımlılıklara sahip

problemlerde daha etkili performans gösterdiğini bulmuşlardır. Ruslan ve diğerleri (2014) çalışmalarında; Malezya Sulama ve Drenaj Departmanından elde edilen gerçek zamanlı veriler ile sel suyu seviyesini tahmin etmeyi amaçlamışlardır. Doğrusal olmayan taşkın su seviyesini, doğrusal olmayan dinamik yapıları iyi tahminlediği bilinen NARX sinir ağı modeli ile tahminlemiştir. NARX sinir ağı modeli ile Kelang nehri sel suyu seviyesini 10 saat önceden belirleyen bir model elde etmişlerdir. Modelin %87 oranı ile gerçeğe yakınlık gösterdiği sonucuna ulaşmışlardır.

Gosasang ve diğerleri (2011), Bangkok limanındaki konteyner elleçleme hacmini tahmin etmek üzere, Gayri Safi Yurtiçi Hasıla (GSYİH), Gayri Safi Milli Hasıla (GSMH), döviz kurları, nüfus, enflasyon oranları, faiz oranları, yakıt fiyatları değişkenlerini kullanmışlardır. Chou ve diğerleri (2008), Tayvan'ın ithalat konteyner elleçleme hacimlerini tahmin etmek üzere, nüfus, sanayi üretim endeksi, Gayri Safi Yurtiçi Hasıla (GSYİH), Gayri Safi Milli Hasıla (GSMH) değişkenlerini kullanmışlardır. Köse (2018), Trabzon Limanında elleçleme yapan ekipmanların yakıt tüketim değişimini tahmin etmek üzere, yakıt tüketim verileri ve yakıt fiyatları değişkenlerini kullanmıştır. Akar ve Esmer (2015), konteyner limanlarının kapasitelerini karşılaştırmak için konteyner yük talebini tahmin etmek üzere, toplam ithalat ve ihracat miktarı, nüfus ve GSYH değişkenlerini kullanmıştır. Güzey (2019), genel yük, konteyner ve araç taşıma hacimlerini tahmin etmek üzere, dış ticaret, nüfus ve Gayri Safi Yurtiçi Hasıla (GSYİH) değişkenlerini kullanmıştır. Bu çalışmada da konteyner elleçleme ve yük elleçleme hacimlerini tahmin etmek üzere literatürde doğrudan ya da dolaylı ilişkisi olduğu tespit edilen Döviz Sepeti Kuru (USD-EURO), Gayri Safi Yurtiçi Hasıla (GSYH), Tüketici Güven Endeksi, Brent Petrol, İhracat, İthalat ve Sanayi Üretim Endeksi bağımlı değişkenleri kullanılmıştır. Değişkenlerin seçimi yapılırken literatürdeki makroekonomik göstergelerden faydalanılmıştır.

Bu çalışmada, Türkiye limanlarındaki verimliliğin artırılmasına yönelik bir çalışma yapılması amaçlanmıştır. Bu amaç doğrultusunda literatür incelemelerinde rastlanılan limanlarda yeni yapılanmalar inşa ederek artırılan bir performans iyileştirilmesinden ziyade var olan mevcut yapıları daha verimli kullanabilen organizasyonel verimlilik üzerine bir tahmin ve öngörü modeli kurulmasına karar verilmiştir. Literatürde yer alan karşılaştırmalı analizlerin performans sonuçlarında YSA yöntemi ön plana çıkmaktadır. YSA, doğrusal olmayan veri ilişkilerini modelleyebilmesi ve zaman serisi ile temsil edilen dinamik girdiler ile çalışabilmesi özellikleri ile ön plana çıkan bir yöntemdir. Bu özelliği ile daha önce hiç karşılaşmadığı durumlarda dahi göz ardı edilebilir hata oranı ile tahmin yapabilmektedir. Ayrıca, ağı bir kez eğitilmesi sonucu ile hızlı performans göstermektedir. Doğrusal Olmayan Dışsal Girdili Otoregresif Ağı (NARX) modeli; harici bilgiler kullanarak çok boyutlu zaman serilerini genişletmekte ve daha iyi tahmin sonuçları vermektedir (Ruiz ve diğerleri, 2016; Yavuz ve Devenci, 2013). NARX modelinin bu avantajlarına karşılık Türkiye limanları daha önce NARX sinir ağı modeli ile analiz edilmemiştir. Küreselleşen dünya ile birlikte Türkiye limanlarında oldukça yüksek maliyetli faaliyetler gerçekleştirilmektedir. Bu durumda limanlarda gerçekleşecek konteyner ve yük elleçleme işlemlerinin hacim miktarlarının olabildiğince minimum hata payı ile öngörüsü limanlardaki faaliyetlerin etkililik ve verimlerini büyük ölçüde artıracaktır. Bu doğrultuda, bu çalışmada Türkiye'de deniz yolu ile yapılan konteyner ve yük elleçleme işlemlerinin hacim miktarlarının doğrusal olmayan dinamik yapılarının NARX sinir ağı modeli ile tahmin ve öngörüsü yapılmıştır. Böylece işletmelerin yapacakları sağlıklı iş planlamaları doğrultusunda hizmet kalitelerinin iyileştirilmesine katkıda bulunacaktır.

Bu çalışmada, giriş bölümünden sonra, ikinci bölümde, YSA NARX sinir ağı modeli açıklanmıştır. Üçüncü bölümde Türkiye limanlarında gerçekleşen konteyner ve yük elleçleme miktarlarının tahmin ve öngörüsü yapılmıştır. Dördüncü bölümde ise sonuçlara yer verilmiş, değerlendirme ve öneriler yapılmıştır.

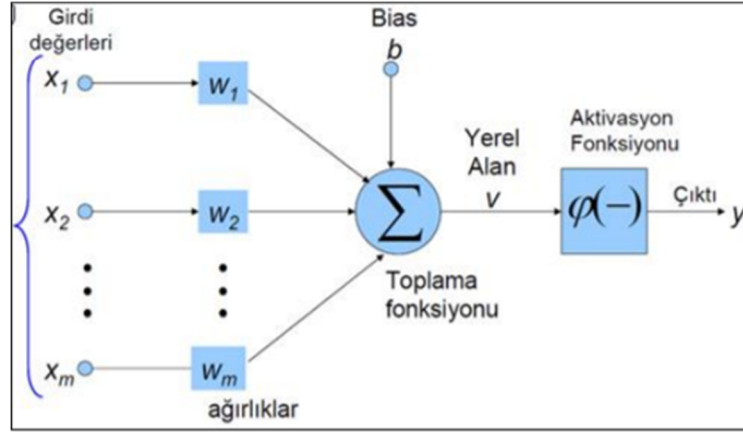
2. YÖNTEM

Yapay Sinir Ağları kavramı ilk olarak McCulloch ve Pitts (1943) tarafından ortaya atılmıştır. Daha sonra Rosenblatt (1958) örüntü sınıflandırma amacı ile geliştirmiş olduğu basit algılayıcı modeli ve algoritması ile kavrama katkıda bulunmuştur. Ancak basit algılayıcı modeli gerçek hayattaki doğrusal olmayan problemlerin çözümünde yetersiz kalmıştır. Rumelhart ve diğerleri (1986) geliştirdikleri çok katmanlı algılayıcı modeli diğer bir adı geriye yayılım modeli ile doğrusal olmayan problemlerde de başarılı sonuçlar elde etmişlerdir. Böylece yapay sinir ağları uygulamalarına olan ilgi hızlı bir biçimde artış göstermiştir.

Bu çalışmada da doğrusal olmayan ve daha önce karşılaşmadığı veri ilişkilerini dahi saptayabilmesi nedeniyle NARX modeli kullanılmıştır. Yapay sinir hücresinin işleyişi Şekil 1 ile verilmiştir. Yapay sinir hücre yapısında öğrenmenin gerçekleşebilmesi için girdi değerleri her bir girdinin önemine göre ağırlıklandırılmaktadır. İlk etapta rastgele öğrenme bağlantıları gerçekleştirilirken aşamalar tekrarlandıkça en uygun öğrenme katsayıları tespit edilir. Çok katmanlı ağlarda ileriye doğru hesaplama yapılırken, hatalarda ise geriye yayma hareketi vardır. Hataların geri yönlü hareketi için türevi alınabilen bir fonksiyona ihtiyaç duyulur. Aktivasyon fonksiyonu bu görevi görür. Toplama fonksiyonundan geçen verilerin optimum ağırlıkları bulduysa, aktivasyon fonksiyonu çıktı katmanına iletir. Eğer optimum öğrenme gerçekleşmedi

ise aktivasyon fonksiyonu türevlenebilen bir fonksiyon olma özelliği ile hatayı geri gönderir. Bu sayede öğrenme optimum şekilde gerçekleştirilmiş olur. Sonuç olarak ağ yapısı, genelleştirmeler yaparak artık daha önce hiç görmediği problemlere dahi çözüm bulabilir seviyeye gelir. Toplama fonksiyonu olarak genellikle ağırlıklı toplamı bulan fonksiyon tercih edilir. Burada yapılan işlem, her bir girdi değerinin bulunan ağırlık değeri ile çarpılması ve ağırlıklandırılmış tüm verilerin toplanması şeklinde gerçekleştirilir.

Yapay sinir ağlarının diğer yöntemlere göre avantajı; ağ yapısındaki geri yönlü hareketi gerçekleştiren aktivasyon fonksiyonunun bulunmasıdır. Türevlenebilen aktivasyon fonksiyonu sayesinde geri yönlü hareket edebilme yeteneği kazanan ağ yapısı, diğer yöntemlere göre optimum ağırlık bulma konusunda üstün performans elde etmiş olur.



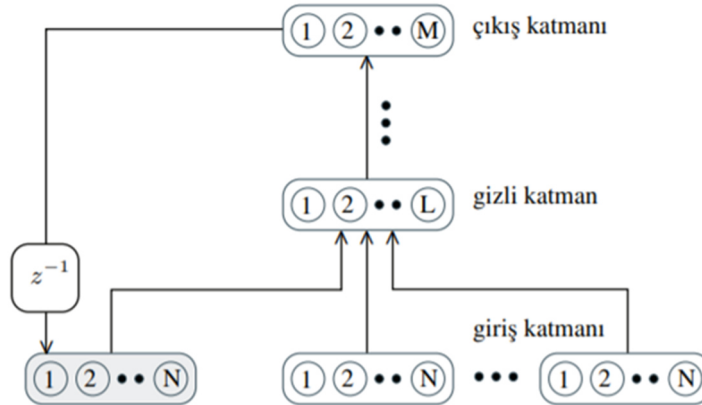
Şekil 1. Yapay sinir hücresinin mimarisini (Doğan, 2019: 12)

Yapay Sinir Ağlarında veriler analiz öncesi üç gruba ayrılır. Bunlar; eğitim, geçerlilik ve test gruplarıdır. Eğitim grubunda veriler ağırlıklandırılır. Ağın yüksek performans gösterebilmesi için verilerin büyük bir kısmı eğitim grubu için ayrılır. Geçerlilik aşamasında ağa daha önce tanıtılmamış olan veriler ile doğrulama gerçekleştirilir. Test grubundaki veriler ile de ağın genelleme yeteneği test edilerek aşamalar sonlandırılır (Sert, 2014: 19-20).

Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) modeli mimarisini Şekil 2'de verilen hiyerarşik yapıya sahiptir. Giriş katmanı, gizli katman ve çıktı katmanı olmak üzere birbirine bağlı üç farklı katman vardır. Şekil 2'de yer alan N , M ve L hücre sayılarını göstermektedir. Bu model matematiksel olarak Eşitlik 1'deki gibi ifade edilmektedir.


$$o(t) = F(o(t-1), o(t-2), \dots, o(t-p'), x(t-1), x(t-2), \dots, x(t-p)) \quad (1)$$

Eşitlik 1 ile ifade edilmektedir. $o(t-p')$ $\in R$ ağ çıktısını, $x(t-p) \in R$ ağ girdilerini, p' ve p ise sırasıyla geri besleme için uygulanacak geçmiş çıktılarının ve geçmiş girdilerin sayısını ifade etmektedir. Geri besleme ve girdi katmanları zaman gecikmeli olup geçmiş verileri içermektedir. Nöronlar aracılığıyla bağlanan katmanlar arasında eğitim aşaması uygulanır ve tahmin değerleri belirlenir. Doğrulama aşamasından sonra stabilize olan veriler test edilir (Chaudhuri ve Ghosh, 2016; Tatlı ve Kahvecioğlu, 2016).



Şekil 2. NARX modeli genel mimarisini (Tatlı ve Kahvecioğlu, 2016:131)

Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX), tekrarlı bir sürece sahip olduğu için dinamik bir sinir ağıdır. Ağın birkaç katmanı ile arasında geri bildirimlere sahip olup Şekil 3'te gösterilmiştir (Fiyadh ve diğerleri, 2018). Geri yayılma algoritması, en güçlü öğrenme algoritmalarından biridir. Geri yayılma eğitimi, bir gradyan iniş algoritmasıdır. Gradyan boyunca eğitim için ayrılan verilerin ağırlık ve sapmalarını ayarlayarak performansı iyileştirmeye çalışmaktadır (Cheng ve Tittreington, 1994; Kalogirou ve Bojic, 2000). Her bir ağırlık fonksiyonu farklı bir hata oranı verir. Eğitimin amacı, hata fonksiyonunu minimum değere ulaştıracak ağırlık ve sapmaların tespit edilmesidir. İlk olarak ağırlıklara küçük ve keyfi değerler verilirken öğrenme ilerledikçe ağırlıklar sistematik olarak en iyi halini almaya başlar (Maier ve Dandy, 1996). Tahmin edilen ya da gerçek zaman serilerinin geçmiş değerleri ile gelecekteki değerleri tahmin edebilme yeteneğine sahiptir (Boussaada ve diğerleri, 2018).



Şekil 3. NARX ağları (Tatlı ve Kahvecioğlu, 2016: 131)

Levenberg (1944) ve Marquardt (1963) tarafından geliştirilen Levenberg-Marquardt (LM) algoritması doğrusal olmayan bir fonksiyonun minimizasyonunu sağlama konusunda sayısal bir çözüm üretir. Küçük ve orta büyüklükteki veri setleri için uygun bir eğitim algoritmasıdır. Hızlı ve istikrarlı bir yapıya sahiptir. Newton algoritması hızını ve dik iniş metodunun kararlılığını birleştirerek öğrenme hızını oldukça artırdığı için etkili bir ağ eğitimi için tercih edilmektedir (Çavuşoğlu ve diğerleri, 2012; Wilamowski ve Yu, 2010; Yu ve Wilamowski, 2011). Bu çalışmada da Levenberg-Marquardt (LM) algoritması kullanılmıştır.

Modelin öngörü yeteneğinin, gerçeğe ne kadar yakın olduğunu görebilmek için performans ölçütleri kullanılmaktadır. Literatürde sıkça kullanılan performans ölçütleri; Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE), Ortalama Hata Kareleri (Mean Square Error-MSE), Ortalama Mutlak Hata (Mean absolute error, MAE), Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error-RMSE) ve Medyan Mutlak Sapma'dır (Median Absolute Deviation-MAD). Bu ölçütler Eşitlik 2-6 ile verilmektedir (Bolzan ve diğerleri, 2008; Pham-Gia ve Hung, 2001).

$$MAPE = (100/n) \left| \sum_{i=1}^n \frac{y_t - y'_t}{y_t} \right| \quad (2)$$

$$MSE = (1/n) \sum_{i=1}^n |(y_t - y'_t)|^2 \quad (3)$$

$$MAE = (1/n) \sum_{i=1}^n |y_t - y'_t| \quad (4)$$

$$RMSE = \sqrt{(1/n) \sum_{i=1}^n (y_t - y'_t)^2} \quad (5)$$

$$MAD = \text{medyan } |y'_t - m| \quad (6)$$

3. UYGULAMA

Bu çalışmada mevcut donanımı daha etkili ve verimli kullanabilmek amacıyla Türkiye'deki limanlarda gerçekleşen konteyner ve yük elleçleme miktarlarının Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) ile öngörüsü yapılmıştır. Konteyner ve yük hacimlerinin öngörüsü, yük ve konteyner akışındaki

planlamanın yapılmasını sağlayacak ve böylece işletmelerin hizmet kalitesinin iyileştirilmesine destek olacaktır. *Konteyner elleçleme ve yük elleçleme* miktarı bağımlı değişken; Döviz Sepeti Kuru (USD-EURO), Gayri Safi Yurtiçi Hasıla (GSYH), Tüketici Güven Endeksi, Brent Petrol, İhracat, İthalat ve Sanayi Üretim Endeksi bağımsız değişken olarak belirlenmiştir. Veri seti Ocak 2004-Haziran 2020 dönemine ait aylık verilerden oluşmaktadır. Bağımsız değişkenler, T.C. Ulaştırma ve Altyapı Bakanlığının Deniz İstatistikleri Veri Tabanından (T.C. Ulaştırma ve Altyapı Bakanlığı, 2020) alınmıştır. Bağımlı değişkenler ise Elektronik Veri Dağıtım Sistemi (EVDS) veri tabanından (Elektronik Veri Dağıtım Sistemi, 2020) ve Türkiye İstatistik Kurumu (TÜİK) veri tabanından (Türkiye İstatistik Kurumu, 2020) alınmıştır.

Yapay Sinir Ağları uygulaması için öncelikle verilerin normalize edilmesi gerekmektedir. Bu çalışmada min-max normalizasyon metodu uygulanmış ve veri seti değerleri 0 ile 1 arasında normalize edilmiştir. Min-Max normalizasyon yöntemi için Eşitlik 7 kullanılmıştır (Larose, 2005: 26).

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (7)$$

Eşitlik 7'de; x' , normalize edilmiş veriyi; x_i , girdi değerini; x_{min} , girdi değerleri arasındaki en küçük sayıyı; x_{max} , girdi değerleri arasındaki en büyük sayıyı temsil etmektedir.

Tüm değişkenler Microsoft Excel programına kaydedilip Eşitlik 7 ile normalizasyon işlemi gerçekleştirildikten sonra tahminleme için hazır hale getirilmiştir. Bu çalışmanın eğitim veri seti, Ocak 2004-Haziran 2020 dönemi aylık verilerini kapsamaktadır. Ayrıca yapılan denemeler sonucunda Train (Eğitim): %60 (238 veri), Validation (Doğrulama): %20 (79 veri) ve Testing (Test etme): %20 (79 veri) ile gizli nöron sayısı 25 ve gecikme sayısı 5 değerleri en iyi tahmin sonucunu vermiştir.

Doğrusal olmayan zaman serilerinde, gizli nöron sayısının optimum değeri için küçük bir değerden başlanıp artırılarak denemeler gerçekleştirilir. Performans bozulmaya başladığında bir önceki deneme değeri optimum değer olarak kabul edilir (Hamzeçebi, 2005: 145). Genel olarak veri setinin öğrenme amaçlı 3 gruba ayrıldığı eğitim, doğrulama ve test gruplarının yüzdeleri deneme yoluyla araştırmacı tarafından bulunmaktadır. En iyi performansı gösterdiğine karar verilen yüzdelik dilimler ile sinir ağlarına öğrenme işlemi gerçekleştirilmiş olur.

Tablo 1 ve Tablo 2 ile sırasıyla konteyner elleçleme miktarı ve yük elleçleme miktarı için NARX sinir ağları modelinin farklı eğitim, doğrulama, test ve farklı nöron sayıları ile performans sonuçları verilmiştir.

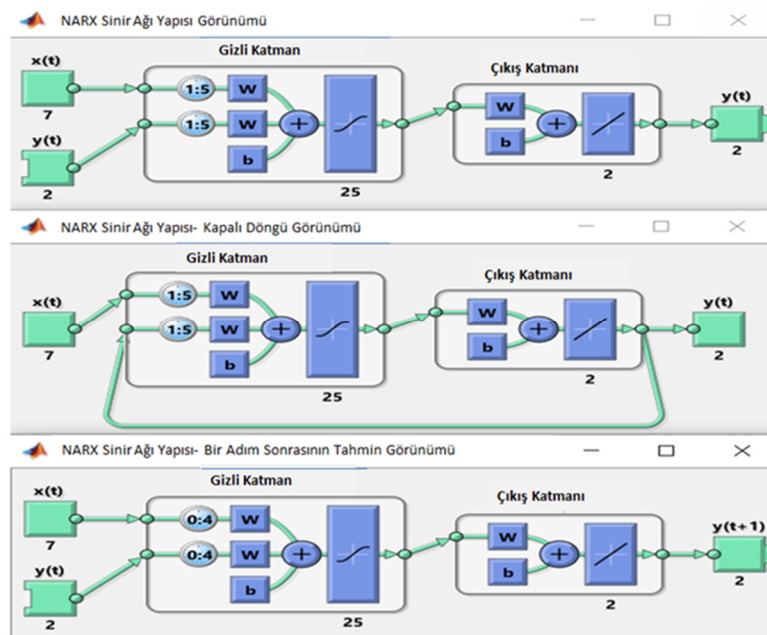
Tablo 1. Konteyner elleçleme miktarı için NARX modelinin farklı eğitim, doğrulama, test yüzdeleri ve farklı nöron sayıları ile performans sonuçları

Veri Seti	Nöron Sayısı	MAPE	MAE	RMSE	MAD
%70 eğitim	15 nöron	6,47	425.131	553.816	1.695.627
%15 doğrulama	20 nöron	6,04	388.274	488.135	1.746.340
%15 test	25 nöron	8,38	463.847	558.432	1.681.167
	30 nöron	9,98	498.751	526.982	1.459.143
%80 eğitim	15 nöron	6,39	420.186	513.992	1.720.780
%10 doğrulama	20 nöron	6,64	434.536	531.381	1.652.665
%10 test	25 nöron	6,98	450.606	546.237	1.649.964
	30 nöron	9,05	541.002	598.748	1.845.653
%60 eğitim	15 nöron	6,49	432.065	571.654	1.630.813
%20 doğrulama	20 nöron	7,09	456.589	553.342	1.590.073
%20 test	25 nöron	5,89	369.776	469.962	1.706.652
	30 nöron	7,61	445.898	563.927	1.570.567

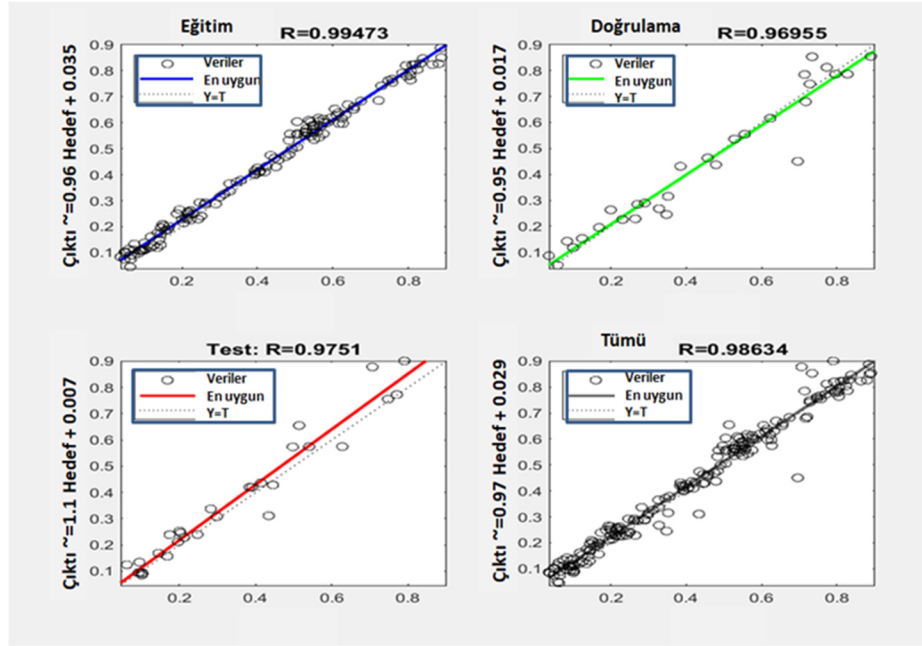
Tablo 2. Yük elleçleme miktarı için YSA NARX modelinin farklı eğitim, doğrulama, test yüzdeleri ve farklı nöron sayıları ile performans sonuçları

Veri Seti	Nöron Sayısı	MAPE	MAE	RMSE	MAD
%70 eğitim	15 nöron	3,99	1.169.775	1.637.342	5.007.947
%15 doğrulama	20 nöron	4,63	1.393.376	1.909.926	6.253.879
%15 test	25 nöron	3,62	1.081.086	1.587.707	5.696.235
	30 nöron	3,45	975.452	1.274.336	5.095.543
%80 eğitim	15 nöron	2,44	647.155	1.438.536	5.115.656
%10 doğrulama	20 nöron	4,14	1.241.022	1.745.110	5.967.116
%10 test	25 nöron	3,99	1.169.775	1.637.342	5.007.947
	30 nöron	5,51	1.476.305	2.051.913	4.394.785
%60 eğitim	15 nöron	6,00	1.633.107	2.155.852	6.254.758
%20 doğrulama	20 nöron	3,71	1.046.080	1.447.058	5.164.700
%20 test	25 nöron	1,97	549.198	1.167.306	5.539.374
	30 nöron	4,56	1.256.879	1.821.541	5.216.984

Şekil 4'te NARX sinir ağının yapısı, paralel ve seri paralel mimarileri gösterilmiştir. Burada $x(t)$, yedi bağımsız değişken, $y(t)$ ise iki bağımlı değişkeni göstermektedir. Ayrıca ağın yapısına bakıldığında iki giriş katmanı, bir gizli katman ve bir çıkış katmanından oluştuğu görülmektedir. Gizli katmanda yirmi beş, çıktı katmanında ise iki nöron bulunmaktadır.


**Şekil 4. NARX ağ modeli**

Oluşturulan NARX sinir ağları modeli; eğitim, doğrulama ve test başarısının ölçümü regresyon analizi ile değerlendirilir. Korelasyon katsayı (R) değerleri, çıktılar ve hedefler arasındaki korelasyonu ölçer. R değerinde, 1 yakın ilişkiyi, 0 rastgele ilişkiyi ifade eder. Şekil 5'te görüldüğü gibi çıktılar ve hedefler arasındaki değerler 1 değerine oldukça yakındır. Veri setinin genel olarak korelasyon katsayısı, 0,98634 olarak elde edilmiştir.



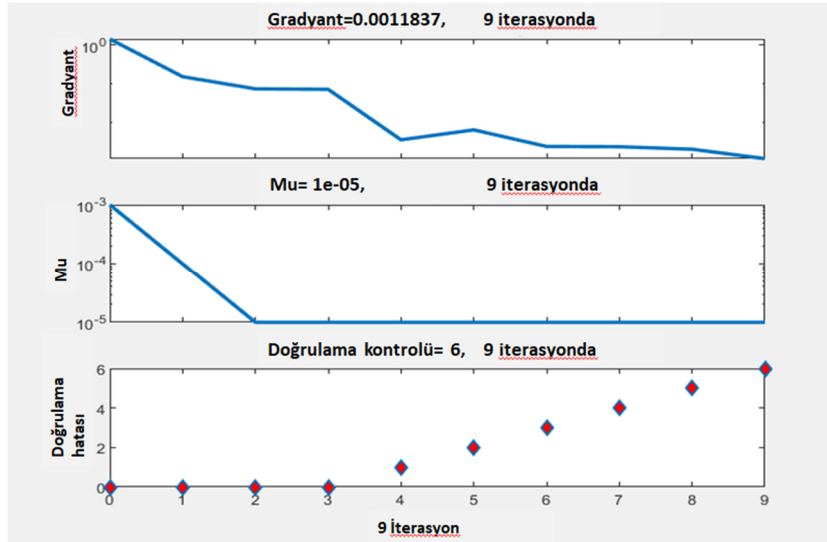
Şekil 5. NARX ağıının regresyon analiz grafiği

NARX sinir ağıının performansı MSE (Ortalama Hata Kareleri- Mean Square Error) ile ölçülmektedir. MSE, çıktılar ve hedefler arasındaki ortalama kare farkını ifade etmektedir. Bu değer ne kadar düşüğe modelin o kadar başarılı olduğu, sıfır ise hata olmadığı anlamına gelmektedir. Şekil 6'da oluşturulan modelin her adımındaki MSE değerleri ve performans grafiği verilmiştir. Görüldüğü gibi 9 iterasyonda tamamlanan eğitimin 3. iterasyonunda en düşük MSE değeri elde edilmiştir. Ayrıca NARX sinir ağı bu aşamada en iyi doğrulama ve performansı gerçekleştirmiştir.



Şekil 6. NARX ağı performans grafiği

NARX sinir ağıının 9 iterasyon sonundaki eğitim yapısını gösteren çıktı grafiği Şekil 7'de verilmiştir. Bu grafik 9 iterasyonluk eğitim sürecinin durumlarını, dönemlere ilişkin belirtmekte olup "Gradient, Mu ve Validation Check" göstergelerinden oluşmaktadır. Şekil 7'de de görüldüğü gibi gradient, kayıp fonksiyonunu hesaplayarak nöronların ağırlığının ayarlanması için geri yayılımın öğrenilmesi işlevini ifade eder. Hedef fonksiyonun minimum alt noktasına 9 iterasyonda ve 0.0011837 değerine ulaştığını göstermektedir. Mu ise algoritmanın parametresi olan değere eşit olmakla birlikte doğrulama kontrol grafiği ile ilişkilidir. Ağıın eğitiminin düşük performans sergilediği noktada eğitimi durdurur. 9 iterasyonluk eğitimin 4. iterasyonundan itibaren ağıın eğitim doğrulaması zayıf performans göstermeye başlamıştır.



Şekil 7. NARX ağıının eğitim sürecinin grafiği

Lewis'e göre (1982: 37-60) MAPE değeri %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. MAE, tahmindeki hataların ortalama büyüklüğünü; RMSE, tahmin hatalarının standart sapmasını; MAD ise tahmin değerlerinin dağılımını ölçmek için mutlak sapmanın medyanını hesaplamaktadır. MAE, RMSE ve MAD değerleri 0'dan sonsuza kadar değer alabilmektedir (Lahmiri, 2014).

Bu çalışmada Ocak 2004-Haziran 2020 dönemi aylık verilerinin eğitimi tamamlandıktan sonra Temmuz 2020-Aralık 2021 dönemini kapsayan 18 aylık bir öngörü yapılmıştır. 18 aylık yapılan öngörü içerisinde yer alan ilk dört ay yani Temmuz, Ağustos, Eylül ve Ekim aylarının verileri açıklanmıştır. Bu sebeple bu aylar üzerinden 4 aylık tahmin ve gerçek değer karşılaştırılması yapılmıştır. Ayrıca performans ölçütleri hesaplanmıştır.

Tablo 3'te Konteyner elleçleme miktarı için NARX sinir ağı modeli 4 aylık tahmin ve gerçek değerleri verilmiştir. Tablo 4'te ise bu 4 ayın tahmin değerlerinin MAPE, MAE, RMSE ve MAD performans ölçüt değerlerine yer verilmiştir. MAPE performans ölçüt değeri Eşitlik 2 yardımı ile %5,7 olarak elde edilmiştir. Dolayısıyla modelin MAPE değeri Lewis'e göre (1982: 37-60) %10'un altında bir değer aldığı için "çok iyi" modeller sınıfına girdiği söylenebilir. MAE performans ölçütü Eşitlik 4 yardımı ile 567.861; RMSE performans ölçütü Eşitlik 5 yardımı ile 750.153 ve MAD performans ölçütü Eşitlik 6 yardımı ile 386.954 olarak hesaplanmıştır.


Tablo 3. Konteyner elleçleme miktarı için NARX sinir ağı modeli 4 aylık tahmin ve gerçek değerleri

Tarih	Tahmin (Ton)	Gerçek Değerler (Ton)
2020-7	10.891.932,52	9.490.388,000
2020-8	10.804.613,21	10.592.790,000
2020-9	10.118.024,26	10.559.301,000
2020-10	11.800.525,29	11.583.724,000

Tablo 4. Konteyner elleçleme miktarı için en iyi NARX sinir ağı modelinin performans ölçüt değerleri

MAPE	MAE	RMSE	MAD
5,70	567.861	750.153	386.954

Şekil 8 ile konteyner elleçleme miktarının 4 aylık tahmin ve gerçek değerlerinin karşılaştırılması grafiği verilmiştir.



Şekil 8. Konteyner elleçleme miktarının 4 aylık tahmin ve gerçek değerlerinin karşılaştırılması

Tablo 5'te yük elleçleme miktarı için NARX sinir ağları modeli 4 aylık tahmin değerleri ve gerçek değerleri verilmiştir. Tablo 6'da ise bu 4 ayın tahmin değerlerinin MAPE, MAE, RMSE ve MAD performans ölçüt değerlerine yer verilmiştir. MAPE performans ölçüt değeri Eşitlik 2 yardımı ile %2,01 olarak elde edilmiştir. Dolayısıyla modelin MAPE değeri Lewis'e göre (1982: 37-60) %10'un altında bir değer aldığı için "çok iyi" modeller sınıfına girdiği söylenebilir. MAE performans ölçütü Eşitlik 4 yardımı ile 833.478; RMSE performans ölçütü Eşitlik 5 yardımı ile 946.119 ve MAD performans ölçütü Eşitlik 6 yardımı ile 371.000 olarak hesaplanmıştır.


Tablo 5. Yük elleçleme miktarı için NARX sinir ağları modeli 4 aylık tahmin ve gerçek değerleri

Tarih	Tahmin (Ton)	Gerçek Değerler (Ton)
2020-7	42.090.354,84	40.730.399,000
2020-8	42.063.834,44	40.901.116,000
2020-9	42.805.834,59	42.558.522,000
2020-10	43.314.618,47	43.878.546,000

Tablo 6. Yük elleçleme miktarı için en iyi NARX sinir ağları modelinin performans ölçüt değerleri

MAPE	MAE	RMSE	MAD
2,01	833.478	946.119	371.000

Şekil 9 ile yük elleçleme miktarının 4 aylık tahmin ve gerçek değerlerinin karşılaştırılmalı grafiği verilmiştir.



Şekil 9. Yük elleçleme miktarının 4 aylık tahmin ve gerçek değerlerinin karşılaştırılması

Tablo 7’de ise NARX sinir ağı modeli Konteyner ve Yük Elleçleme miktarı için Kasım 2020-Aralık 2021 dönemi öngörü değerleri verilmiştir.

Tablo 7. NARX sinir ağı modeli konteyner ve yük elleçleme miktarı için 14 aylık öngörü değerleri

<i>Tarih</i>	<i>Konteyner Elleçleme Öngörü (Ton)</i>	<i>Yük Elleçleme Öngörü (Ton)</i>
2020-11	11.049.753,21	43.008.599,08
2020-12	11.380.128,34	42.235.519,62
2021-1	11.212.742,78	41.456.681,32
2021-2	11.001.235,86	42.075.230,34
2021-3	10.093.796,34	42.789.284,60
2021-4	10.278.863,33	42.158.335,01
2021-5	10.012.906,13	42.402.043,77
2021-6	9.144.933,62	42.250.659,02
2021-7	9.612.154,87	42.357.398,12
2021-8	9.513.725,43	42.153.903,71
2021-9	9.412.795,67	42.044.592,14
2021-10	9.312.275,41	41.946.894,62
2021-11	9.357.475,87	41.454.365,70
2021-12	9.121.786,47	41.763.852,51

Devlet ve/veya özel işletmeler, liman yöneticileri ve liman sahipleri, NARX Sinir Ağı Modeli sonucu elde edilen, Tablo 7’de öngörülen konteyner ve yük elleçleme miktarlarını gelecekteki iş planlarında kullanmaları durumunda iş çıktılarına faydalı olabileceği düşünülmektedir. Ancak bu öngörülen değerler kullanılırken; konteyner elleçleme hacmindeki MAPE performans ölçütü %5,7 ve yük elleçleme hacmindeki MAPE performans ölçütünün %2,01 olduğu göz önünde bulundurularak, yapılacak planlamalarında bahsedilen miktarlarda hata payı bırakmaları daha sağlıklı olacaktır.

4. SONUÇ ve DEĞERLENDİRME

11. Kalkınma Planı (2019-2023) lojistik ve ulaştırma politikalarında, lojistik faaliyetlerinde esneklik, hız, öngörülebilirlik, güvenlik, kalite, ölçek ekonomisi ve yenilikçilik gibi hizmet düzeyi parametrelerinin iyileştirilmesi gerekliliği vurgulanmıştır. Bu bağlamda Türkiye’de deniz yolu ile yapılan konteyner ve yük elleçleme işlemlerinin hacim miktarlarının NARX sinir ağı modeli ile tahmini ve öngörüsü yapılmaya çalışılarak hizmet düzenliliğini etkileyen belirsizlikleri ortadan kaldıracığı ve böylece bu çalışmanın lojistik ve ulaştırma alanına katkı sağlayacağı düşünülmektedir. Konteyner elleçleme ve yük elleçleme ile doğrudan ya da dolaylı olarak ilişkisi olduğu tespit edilen yedi bağımlı değişken belirlenmiştir. Bunlar; Döviz Sepeti Kuru (USD-EURO), Gayri Safi Yurtiçi Hasıla (GSYH), Tüketici Güven Endeksi, Brent Petrol, İhracat, İthalat ve Sanayi Üretim Endeksi’dir. Sonuç olarak, NARX sinir ağı modeli ile konteyner elleçleme ve yük elleçleme işlem hacimlerinin Temmuz 2020- Ekim 2020 dönemlerine ait 4 aylık tahmin, Kasım 2020- Aralık 2021 dönemlerine ait 14 aylık öngörü sonuçları verilmiştir. Çalışmada elde edilen tahmin sonuçlarının doğruluğunu ve etkililiğini değerlendirmek için MAPE, MAE, RMSE ve MAD performans ölçüt değerleri hesaplanmıştır. Konteyner elleçleme miktarı için MAPE %5,7; MAE 567.861; RMSE 750.153 ve MAD 386.954 olarak elde edilmiştir. Yük elleçleme miktarı için MAPE %2,01; MAE 833.478; RMSE 946.119 ve MAD 371.000 olarak elde edilmiştir. Performans ölçüt değerlerinin sifıra olan uzaklığı, gerçek değerlere ne ölçüde yakın olduğunu ifade etmektedir. Bir model gerçeğe ne kadar yakın sonuçlar veriyorsa o kadar başarılı bir modeldir. Lewis’in (1982: 37-60) performans ölçütü değerlendirmesine göre, MAPE değeri hem konteyner elleçleme öngörüsünde hem de yük elleçleme öngörüsünde %10’un altında değerler olarak “çok iyi model” sınıfına girmiştir. NARX sinir ağı modeli, birden fazla değişken ile çalışabilme imkânı sunduğu ve durağanlığını yitirmiş değişkenlerin doğrusal olmayan ilişkilerini de yüksek performans ile tahminleyebildiği için gerçeğe çok yakın sonuçlar vermektedir.

Deniz yolu taşımacılığı diğer taşıma yollarına göre daha az maliyet ile fazla yük taşıma kapasitesine sahip olduğu için küresel çevrede daha çok tercih edilmektedir. Dünyada ticaret faaliyetlerindeki taşımacılığın yüzde 90’ının deniz yolu ile yapıldığı göz önüne alınırsa, dış ticaretin gelişimi Türkiye ekonomisine oldukça önemli katkılarda bulunacaktır. Bu anlamda lojistik sektörü, Türkiye’nin önemli stratejik konumu itibarıyla geliştirilmeye müsait bir alandır. Doğu ve Batı’yı birbirine bağlaması sebebi ile lojistik üs olma potansiyeline sahip ülkemizde limanlar, tedarik zincirini birbirine bağlayan önemli noktalardır (Tatar ve diğerleri, 2009). Türkiye İstatistik Kurumu ve Ticaret Bakanlığı iş birliğiyle oluşturulan taşıma

şekillerine göre dış ticaret verilerinde deniz yolu taşımacılığı, 2020 yılı içerisinde ihracatta 100 milyar 861 milyon ABD doları ile yüzde 59,5; ithalatta 125 milyar 859 milyon ABD doları ile yüzde 57,4'lük bir dilimi kapsamaktadır. Ocak 2021 ihracat verilerine göre bir önceki yılın aynı ayına göre yüzde 2,1 azalma, ithalatta ise yüzde 0,3'lük bir artış görülmektedir (T.C. Ticaret Bakanlığı, 2021). Ulaştırma ve Altyapı Bakanlığında alınan verilere göre; limanlarda gerçekleşen konteyner ve yük elleçleme işlemlerinde son yıllarda artış olduğu gözlemlenmektedir. Elleçlenen konteyner miktarının Aralık 2020'de bir önceki yılın aynı ayına göre yüzde 9, yük miktarının da yüzde 7 arttığı görülmektedir (T.C. Ulaştırma ve Altyapı Bakanlığı, 2021). Bu bilgiler bağlamında limanlar; ülkelerin hatta bölgelerin dünyaya açılan kapıları olarak bölgesel ya da ülke çapında ekonomiye katkı sağlamaktadır. Bu çalışmada önerilen NARX Sinir Ağları Modeli ile öngörülen konteyner ve yük elleçleme hacimleri doğrultusunda yapılan hizmet planlamaları ile limanlarımızın mevcut donanımı daha etkin ve verimli kullanılmasına altyapı sağlanmış olacaktır. Dolayısıyla bu öngörü yeteneği, ülkemizde gerçekleşen ithalat ve ihracat oranlarına pozitif yönde bir etki sağlayacaktır.

Sonuç olarak; Türkiye'nin stratejik konumunu daha etkili kullanabilmesi ve rekabet düzeyini artırabilmesi açısından limanlarda gerçekleşen konteyner ve yük elleçleme miktarlarının öngörülmesi hizmet düzenliliğini etkileyen belirsizlikleri ortadan kaldıracak düşünülmemektedir. Bu sayede işletmeler; doğru zamanda, doğru yerde, doğru ürün ile başarılı bir hizmet sunarak müşteri memnuniyetini olumlu yönde artırmış olacaklardır. Tablo 7'de verilen öngörü değerleri doğrultusunda, devlet ve/veya özel işletmeler gerçekleştirecekleri faaliyetlerde planlamalarını daha doğru ve yeni stratejiler doğrultusunda yönetim anlayışları geliştirerek yapma imkânı bulacaklardır. Böylece işletmeler ürün ve/veya hizmetlerini rakiplerinden daha hızlı ve ekonomik olarak pazar yerlerine ulaştırarak önemli bir avantaj sağlamış olacaklardır.

Türkiye'deki limanlarda gerçekleşen faaliyetler ile ilgili çeşitli iyileştirme, değerlendirme ve analiz çalışmaları (Ateş ve diğerleri, 2010; Karataş ve Çetin, 2010) ve limanlarda gerçekleşen konteyner ve yük hacimlerinin de çeşitli yöntemlerle tahminleme çalışmaları literatürde (Kara, 2011; Bal ve Çalışır, 2018) yer almaktadır. Ancak bu çalışmanın diğer çalışmalardan farkı; Türkiye limanlarında gerçekleşen konteyner ve yük elleçleme işlemlerinin hacmini daha önce yapılan tahmin tekniklerinden farklı olarak, doğrusal olmayan ilişkilerde dahi yüksek performans gösteren NARX sinir ağları modelinin kullanılması ile mevcut literatüre katkı sağlanacağına düşünülmesidir.

Çalışmanın kısıtı, bu çalışmada aylık frekansta veriler kullanılmıştır. Bunun yerine günlük, aylık ve yıllık frekanslı veri setleri hazırlanıp, NARX Sinir Ağları modelinin en iyi hangi frekansta optimum sonuçlar verdiği karşılaştırmalı bir analiz ile ortaya koyulabilir. Ayrıca gelecekte yapılabilecek diğer çalışmalar ise; farklı makine algoritmaları kullanılarak karşılaştırmalı analizler ve nitel-nicel çalışmaların beraber kullanıldığı farklı tahmin metodları ile birlikte hibrit tahmin modellerinin geliştirilebileceği düşünülmektedir. Bu durumlara ilaveten hızla değişen dünyada güncel koşullara uygun ve tahmin yeteneği yüksek değişkenlerin de analize dahil edilmesi çalışmayı zenginleştirecektir.

KAYNAKÇA

- Abdirassilov, Z. ve Sladkowski, A. (2018). "Application of Artificial Neural Networks for Shortterm Prediction of Container Train Flows in Direction of China–Europe via Kazakhstan", *Transport Problems*, 13, 103-113.
- Akar, O. ve Esmer, S. (2015). "Cargo Demand Analysis of Container Terminals in Turkey", *Journal of ETA Maritime Science*, 3(2), 117-122.
- Ateş, A. ve Esmer, S. (2014). "Farklı Yöntemler ile Türk Konteyner Limanlarının Verimliliği", *Verimlilik Dergisi*, (1), 61-76.
- Ateş, A., Karadeniz, Ş. ve Esmer, S. (2010). "Dünya Konteyner Taşımacılığı Pazarında Türkiye'nin Yeri", *Denizcilik Fakültesi Dergisi*, 2(2), 83-98.
- Bal, E.T. ve Çalışır, V. (2018). "Konteyner Elleçleme İçin Ekonometrik Tahminleme: Arma Modeli Uygulaması", *OPUS Uluslararası Toplum Araştırmaları Dergisi*, 9(16), 2067-2096.
- Barros, C.P. (2003). "Incentive Regulation and Efficiency of Portuguese Port Authorities", *Maritime Economics & Logistics*, 5(1), 55-69.
- Bichou, K. (2013). "An Empirical Study of the Impacts of Operating and Market Conditions on Container-Port Efficiency and Benchmarking", *Research in Transportation Economics*, 42(1), 28-37.
- Bolzan, A.C., Machado R.A.F. ve Piaia J.C.Z. (2008). "Egg Hatchability Prediction by Multiple Linear Regression and Artificial Neural Networks", *Brazilian Journal of Poultry Science*, 10(2), 97-102.
- Boussaada, Z., Curea, O., Remaci, A., Camblong, H. ve Mrabet Bellaaj, N. (2018). "A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation", *Energies*, 11(3), 620.
- Chaudhuri, T.D. ve Ghosh, I. (2016). "Artificial Neural Network and Time Series Modeling Based Approach to Forecasting the Exchange Rate in a Multivariate Framework", *Journal of Insurance and Financial Management*, 5, 92-123.
- Cheng, B. ve Titterington, D.M. (1994). "Neural Networks: A Review from a Statistical Perspective", *Statistical Science*, 2-30.
- Chou, C.C., Chu, C.W. ve Liang, G.S. (2008). "A Modified Regression Model for Forecasting the Volumes of Taiwan's Import Containers", *Mathematical and Computer Modelling*, 47(9-10), 797-807.
- Coto-Millán, P., Baños-Pino, J. ve Castro, J.V. (2005). "Determinants of the Demand for Maritime Imports and Exports", *Transportation Research Part E: Logistics and Transportation Review*, 41(4), 357-372.
- Çağlar, A.G.V. ve Oral, E.Z. (2011). "Liman Verimlilik ve Etkinlik Ölçme Yöntemlerinin Analizi", *Kıyı Mühendisliği Sempozyumu*, 665-676.
- 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).
- Di Piazza, A., Di Piazza, M.C. ve Vitale, G. (2016). "Solar and Wind Forecasting by NARX Neural Networks", *Renewable Energy and Environmental Sustainability*, 1, 39.
- Ding, N., Benoit, C., Foggia, G., Bésanger, Y. ve Wurtz, F. (2015). "Neural Network-Based Model Design for Short-Term Load Forecast in Distribution Systems", *IEEE Transactions on Power Systems*, 31(1), 72-81.
- Doğan, A. (2019). "Namazgâh Barajına Ait Buharlaştırma Miktarının Yapay Sinir Ağı ile Tahmin Edilmesi", Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- Elektronik Veri Dağıtım Sistemi, (2020). "EVDS Veri Tabanı", <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, (Erişim tarihi: 20.11.2020).
- Esmer, S. (2009). "Konteyner Terminallerinde Lojistik Süreçlerin Optimizasyonu ve Bir Simülasyon Modeli", Doktora Tezi, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, İzmir.
- Eswari, J.S., Majdoubi, J., Naik, S., Gupta, S., Bit, A., Rahimi-Gorji, M. ve Saleem, A. (2020). "Prediction of Stenosis Behaviour in Artery by Neural Network and Multiple Linear Regressions", *Biomechanics and Modeling in Mechanobiology*, 19(5), 1697-1711.
- Fiyadh, S.S., Alsaadi, M.A., Alomar, M.K., Fayaed, S.S. ve El-Shafie, A. (2018). "Arsenic Removal from Water Using N, N-Diethylethanolammonium Chloride Based DES-Functionalized CNTS:(NARX) Neural Network Approach", *Journal of Water Supply: Research and Technology-Aqua*, 67(6), 531-542.
- Gosasang, V., Chandraprakaiikul, W. ve Kiattisin, S. (2011). "A Comparison of Traditional and Neural Networks Forecasting Techniques for Container Throughput at Bangkok Port", *The Asian Journal of Shipping and Logistics*, 27(3), 463-482.
- Güzey, H. (2019). "Bir Liman İşletmesi için Kapasite Yeterlilik Analizi", Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa.

- Hamzaçebi, C. (2005). "Geleceği Tahminde Yapay Sinir Ağları İçin Sezgisel Öğrenme Algoritması", Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Hamzaçebi, C. ve Kutay, F. (2004). "Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3), 227-233.
- Kalogirou, S.A. ve Bojic, M. (2000). "Artificial Neural Networks for the Prediction of the Energy Consumption of a Passive Solar Building", *Energy*, 25(5), 479-491.
- Kara, A. (2011). "İzmir (Alsancak) Limanı Gelecek Talep Tahmini için Bir Yöntem Önerisi", Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- 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). "Yapay Sinir Ağları Metodu ile İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi", *Ege Academic Review*, 15(2), 165-172.
- Karataş, Ç. ve Çetin, P.S. (2014). "Liman İnovasyonları ve Bilgi Sistemleri: Türkiye Limanları Üzerine Bir Araştırma", *Girişimcilik ve İnovasyon Yönetimi Dergisi*, 3(2), 81-104.
- Konings, J.W. (2008). "The Future of Intermodal Freight Transport: Operations, Design and Policy", Edward Elgar Publishing.
- Köse, S., Uyar, B.B., Özkök, M. ve Demirel, F.B. (2018). "Trabzon Limanı Elleçleme Ekipmanlarının Yakıt Tüketim Maliyetleri Üzerine Bir Araştırma", *Technological Applied Sciences (NWSATAS)*, 13(3), 264-271.
- Lahmiri, S. (2014). "Wavelet Low-And High-Frequency Components as Features For Predicting Stock Prices with Backpropagation Neural Networks", *Journal of King Saud University-Computer and Information Sciences*, 26(2), 218-227.
- Larose, D.T. (2005). "Discovering Knowledge in Data: An Introduction to Data Mining", John Wiley and Sons Inc., New Jersey.
- Levenberg, K. (1944). "A Method for the Solution of Certain Non-Linear Problems in Least Squares", *Quarterly of Applied Mathematics*, 2(2), 164-168.
- Lewis, C.D. (1982). "Industrial and Business Forecasting Methods", Butterworths Publishing, Londra.
- Lin, T., Horne, B.G., Tino, P. ve Giles, C.L. (1996). "Learning Long-Term Dependencies in NARX Recurrent Neural Networks", *IEEE Transactions on Neural Networks*, 7(6), 1329-1338.
- Maier, H.R. ve Dandy, G.C. (1996). "The Use of Artificial Neural Networks for the Prediction of Water Quality Parameters", *Water Resources Research*, 32(4), 1013-1022.
- Marquardt, D.W. (1963). "An Algorithm for Least-Squares Estimation of Nonlinear Parameters", *Journal of the Society for Industrial and Applied Mathematics*, 11(2), 431-441.
- Mcculloch, W.S. ve Pitts, W. (1943). "A Logical Calculus of the Ideas Immanent in Nervous Activity", *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Milenkovic, M., Milosavljevic, N., Bojovic, N. ve Val, S. (2019). "Container Flow Forecasting through Neural Networks Based on Metaheuristics", *Operational Research*, 21, 965-997.
- Öztemel, E. (2003). "Yapay Sinir Ağları", PapatyaYayıncılık, İstanbul.
- Panda, C. ve Narasimhan, V. (2007). "Forecasting Exchange Rate Better with Artificial Neural Network", *Journal of Policy Modeling*, 29(2), 227-236.
- Pham-Gia, T. ve Hung, T.L. (2001). "The Mean and Median Absolute Deviations", *Mathematical and Computer Modelling*, 34(7-8), 921-936.
- Pulido-Calvo, I., Montesinos, P., Roldán, J. ve Ruiz-Navarro, F. (2007). "Linear Regressions and Neural Approaches to Water Demand Forecasting in Irrigation Districts with Telemetry Systems", *Biosystems Engineering*, 97(2), 283-293.
- Rosenblatt, F. (1958). "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain", *Psychological Review*, 65(6), 386.
- Ruiz, L.G.B., Cuéllar, M.P., Calvo-Flores, M.D. ve Jiménez, M.D.C.P. (2016). "An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings", *Energies*, 9(9), 684.
- Rumelhart, D.E., Hinton, G.E. ve Williams, R.J. (1986). "Learning Representations by Back-Propagating Errors", *Nature*, 323(6088), 533-536.
- Ruslan, F.A., Zain, Z.M. ve Adnan, R. (2014, March). "Flood Water Level Modeling and Prediction Using NARX Neural Network: Case Study at Kelang River", *2014 IEEE 10th International Colloquium on Signal Processing and its Applications*, 204-207.

- Sert, F. (2014). "Hava Durumunun Yapay Sinir Ağları ile Kestirimi ve Bulanık Mantıkla Sınıflandırılması", yüksek Lisans Tezi, Uludağ Üniversitesi Sosyal Bilimler Enstitüsü, Bursa.
- Siegelmann, H.T., Horne, B.G. ve 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.
- Süleyman, K. (2018). "Trabzon Limanı Elleçleme Ekipmanlarının Yakıt Tüketim Maliyetleri Üzerine Bir Araştırma", *Technological Applied Sciences*, 13(3), 264-272.
- T. C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı, (2019-2023). "On Birinci Kalkınma Planı", 1- 209.
- T.C. Ticaret Bakanlığı, (2021). "Bakanlık İstatistikleri", <https://ticaret.gov.tr/data>, (Erişim Tarihi: 25.02.2021).
- T.C. Ulaştırma ve Altyapı Bakanlığı, (2020). "Deniz İstatistikleri Veri Tabanı", https://atlantis.udhb.gov.tr/istatistik/istatistik_filo.aspx, (Erişim tarihi: 20.11.2020).
- T.C. Ulaştırma ve Altyapı Bakanlığı, (2021). "İstatistikler", <https://www.uab.gov.tr>, (Erişim Tarihi: 25.02.2021).
- Tatar, V., Özer, M. ve Kartal, A. (2019). "Deniz Taşımacılığı ve Limanların Ekonomik Etkileri: Hopa Limanı Analizi", *Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi*, 6(5), 138-150.
- Tatlı, A. ve S. Kahvecioğlu, (2016). "NARX Neural Networks Based Time Series Prediction for Amount of Airworthiness Time", *National Conference on Electrical, Electronics and Biomedical Engineering (ELECO)*, Bursa, 130-134.
- Trujillo, L. ve Tovar, B. (2007). "The European Port Industry: An Analysis of its Economic Efficiency", *Maritime Economics & Logistics*, 9(2), 148-171.
- Tsai, F.M. ve Huang, L.J. (2017). "Using Artificial Neural Networks to Predict Container Flows between the Major Ports of Asia", *International Journal of Production Research*, 55(17), 5001-5010.
- Türkiye İstatistik Kurumu, (2020). "TÜİK Veri Tabanı", <https://www.tuik.gov.tr>, (Erişim tarihi: 20.11.2020).
- Valentine, V.F. ve Gray, R. (2001). "The Measurement of Port Efficiency Using Data Envelopment Analysis", *Proceedings of the 9th World Conference on Transport Research*, Seoul.
- Wilamowski, B. M. ve Yu, H. (2010). Improved Computation for Levenberg–Marquardt Training, *IEEE Transactions on Neural Networks*, 21(6), 930-937.
- Yavuz, S. ve Deveci, M. (2012). "İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi", *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187.
- Yu, H. ve Wilamowski, B.M. (2011). "Levenberg-Marquardt Training", *Industrial Electronics Handbook*, 5(12), 1.
- Yüksekıldız, E. (2021). "Entropi ve EATWOS Yöntemleri ile Türkiye Konteyner Limanlarının Verimlilik Analizi", *Verimlilik Dergisi*, 2, 3-24.