



Araştırma Makalesi / Research Article

Gönderilme Tarihi: 27 Eylül 2021; Revize Edilmiş Hali: 5 Kasım 2021; Kabul Tarihi: 12 Kasım 2021

UYGUN NORMALİZASYON TEKNİĞİ VE YAPAY SİNİR AĞLARI ANALİZİ ile OTOMOBİL SATIŞ TAHMİNLEMESİ

Gökçe HAN¹

Eyüp Firat SÖNMEZ²

Selen AVCI³

Zerrin ALADAĞ⁴

ÖZ

Bu çalışmada, yapay zekâ temelli tahmin yöntemlerinden Yapay Sinir Ağları (YSA) ve bir üstel düzeltim yöntemi olan Holt Winters' ile Türkiye'de sıfır otomobil satış adetlerinin tahminlemesi gerçekleştirilmiştir. Çalışmada, bağımlı değişken "otomobil satış adetleri" iken; bağımsız değişkenler "döviz kuru, tüketici güven endeksi, gayrisafi yurt içi hasıla (GSYHİ) ve reel kesim güven endeksi" olarak seçilmiştir. Türkiye İstatistik Kurumu (TÜİK), Türkiye Cumhuriyeti Merkez Bankası ve Otomobil Distribütörleri Derneği'nden alınan 2015 – 2020 yılları arasındaki aylık veriler üzerinde çeşitli normalizasyon yöntemleri denenmiş, çoklu regresyon analizi yapılmış ve değişkenlik katsayısı hesaplanmıştır. Minimum hata performansı gösteren istatistiksel normalizasyon yöntemi (Z-Skor) seçilerek geçmiş verilerden hareketle ağ mimarisi ve çeşitli parametreler belirlenmiş ve YSA'nın ileri beslemeli geri yayılım algoritması kullanılarak 2019 ve 2020 yıllarında gerçekleşen sıfır otomobil satış adetleri tahmin edilmiştir. Ardından, YSA'nın performansı çeşitli performans göstergelerine göre Holt Winters' yöntemi ile karşılaştırılarak yorumlanmıştır. YSA'nın Holt Winters' yöntemine kıyasla daha iyi sonuç verdiği tespit edilmiş ve tahminlerdeki sapmaların sebepleri yorumlanmıştır.

Anahtar Kelimeler: Yapay Sinir Ağı (YSA), Holt Winters', talep tahmini, normalizasyon, otomotiv

Jel Kodları: C32, C45, C53

APPROPRIATE NORMALIZATION TECHNIQUE AND ARTIFICIAL NEURAL NETWORK ANALYSIS FOR AUTOMOBILE SALES FORECAST

ABSTRACT

In this study, new automobile sales in Turkey were estimated using Artificial Neural Networks (ANN), which is an artificial intelligence-based forecasting method, and Holt-Winters, which is an exponential smoothing method. In the study, the dependent variable is the number of sales of automobiles, while the independent variables are the exchange rate, consumer confidence index, gross domestic product (GDP), and real sector confidence index. Various normalization methods have been approved on the monthly data between 2015 and 2020 received from the Turkish Statistical Institute (TSI), the Central Bank of the Republic of Turkey, and the Automobile Distributors Association, multiple regression analysis has been performed and the coefficient of variation has been examined. The feed-forward backpropagation algorithm of ANN has been analyzed by using the statistical Z-Score normalization method which ensures the minimum error performance. The network architecture and parameters were determined based on historical data and sales quantity of new automobile were estimated in 2019-2020.

¹Endüstri Mühendisi, Kocaeli Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü, gokkcehan@gmail.com, 0000-0003-0979-9421

²Endüstri Mühendisi, Sakarya Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü, eyupfiratsonmez@hotmail.com, 0000-0002-3569-8846

³Arş. Gör., Kocaeli Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü, selen.avci@kocaeli.edu.tr, 0000-0001-7433-5696

⁴Prof. Dr., Kocaeli Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü, zaladag@kocaeli.edu.tr, 0000-0002-5986-7210

The estimation results were evaluated according to various error performances and the reasons for the estimation errors were interpreted. It has been determined that ANN gives better results compared to Holt-Winters' method.

Keywords: Artificial Neural Network (ANN), Holt-Winters', demand forecasting, normalization, automotive

JEL Codes: C32, C45, C53

GİRİŞ

Otomotiv sanayi; istihdam sağlaması, teknolojik gelişmelere katkısı ve desteklediği sanayi kollarının çeşitliliği ile küresel dünya ekonomisine büyük ölçekte fayda sağlayan sanayi kollarının başında gelmektedir. Gelişmiş ülkelerin, araştırma ve geliştirme (AR-GE) çalışmalarının yoğun olarak yapıldığı ve ileri derece üretim tekniklerinin kullanıldığı otomotiv sanayide de güçlü olduğu görülmektedir.

Geçmişte otomotiv sanayi yalnızca üretimin tamamını gerçekleştirebilecek teknolojik düzeydeki ülkelerde bulunurken, günümüzde ise bu sektörün üretim faaliyetleri bakımından global bir değer zinciri şeklinde örgütlendiği görülmektedir. Otomotiv sektörüyle eş zamanlı olarak imalat sanayisinde yaşanan teknolojik gelişmeler, geniş kapsamda otomotiv üretici firmalarının talepleri doğrultusunda şekillenmektedir. Otomotiv sektörü aynı zamanda hizmet ve enerji sektörleriyle de doğrudan ilişkili olan ana sanayi konumundadır. Hizmet sektörü açısından incelendiğinde ise otomotiv sektörü; satış, distribütörler, perakende, bakım-onarım, sigortacılık ve kiralama faaliyetleri başta olmak üzere çeşitli sektörlerin gelişmesinde önemli paya sahiptir.

Türkiye’de otomotiv sektörü, 1950’li yıllarda yalnızca montaj ile başlamış, 1996 yılında Avrupa Birliği (AB) ile yapılan Gümrük Birliği Anlaşması’nın ardından sürekli artış gösteren yatırımlar ile bugünkü noktaya gelmiştir. Yapılan araştırmaya göre 2016 yılında AB ülkelerinde 100 kişiye 50,5 adet otomobil düşerken eş zamanlı olarak Türkiye’de bu sayı 100 kişi için 14,2 adettir (Özer, Ayhan ve İrdem, 2017). Tablo 1’de gösterildiği üzere 2020 yılında otomobil satışı bir önceki yıla göre %61,7 oranında artarak 610.109 adede ulaşmıştır.

Tablo-1: Yıllık Perakende Otomobil Satış Miktarları

Yıllar	Otomobil Satış Miktarları (Adet)
2015	725.596
2016	756.958
2017	722.759
2018	486.321
2019	376.277
2020	610.109

Kaynak: ODD, Perakende Satış Raporları (2017, 2018, 2019, 2020)

Günümüz otomotiv sektöründe üretici firmalar, üretimden satış sonrası hizmete kadar müşteri memnuniyetini en yüksek seviyede tutacak yeni ve etkin çalışmalar yapmaktadır. Dünyanın çeşitli yerlerinde faaliyet gösteren birçok üretici firma, düşük iş gücü maliyetine sahip ülkelere daha çok yatırım yapmaktadır. Bunların arasında Türkiye de yer almaktadır. Türkiye; Avrupa pazarına yakınlığı, stratejik konumunun önemi ve gelişmiş otomotiv yan sanayisi ile üretici firmaların ilgi odağı olmuştur.

Bunun yanı sıra Türkiye, 2019 yılında prototipini tanıtmış olduğu elektrikli otomobiller ile ilerleyen yıllarda pazara giriş yapacaktır.

AR-GE ve üretim kapsamında otomotiv sektörü için dünyada 85 Milyar Euro'luk yatırım harcamaları gerçekleşirken, yatırım yapılmış ülkelerde 433 Milyar Euro'yu aşan vergi gelirleri elde edilmektedir (Sanayi Genel Müdürlüğü, 2013). Bu bağlamda rekabet, otomotiv sektörü için önemli bir noktadır. İşletmeler, rekabet ortamında varlıklarını sürdürebilmek için müşteri isteklerini ve taleplerini doğru anlayabilmeli ve yatırımlarını bu doğrultuda yapmalıdır. Hammadde, yarı mamul, insan gücü ve makine gereksinimlerinin belirlenmesinde talep tahminleri büyük önem arz etmektedir.

Bu çalışmada Yapay Sinir Ağları (YSA)'nın ileri beslemeli geri yayılım algoritması kullanılarak 2019-2020 yıllarında Türkiye'de gerçekleşen sıfır otomobil satış adetleri tahmin edilmiştir. Çalışmanın ilk bölümünde Türkiye İstatistik Kurumu, Türkiye Cumhuriyeti Merkez Bankası ve Otomobil Distribütörleri Derneği'nden alınan 2015 – 2020 yılları arasındaki döviz kuru, tüketici güven endeksi, gayrisafi yurt içi hasıla, reel kesim güven endeksi ve sıfır otomobil verileri üzerinde çeşitli normalizasyon yöntemleri denenmiş, çoklu regresyon analizi yapılarak değişkenler arasındaki ilişki tespit edilmiş ve değişkenlik katsayısı hesaplanmıştır. Minimum hata payını veren normalizasyon yöntemi tespit edilmiş, yapay sinir ağının gizli katman sayısı ve nöron sayısı belirlenmiş ve ağ eğitime başlanmıştır. Ağın eğitilmesinde kullanılan optimum parametreler, ağı test etmek için de kullanılmıştır. İkinci bölümde ise YSA'nın etkinliğini ölçebilmek adına mevsimsellik etkiyi iyi yansıtabilmesi ve diğer tahmin yöntemlerine kıyasla en iyi tahmin performansını vermesi sebebi ile Holt Winters' tahmin yöntemi kullanılmıştır. Tahmin sonuçları çeşitli hata performansları ile ölçülmüş ve değerlendirilmiştir.

1. BİLİMSEL YAZIN TARAMASI

Literatürde otomotiv satış tahminlemesi kapsamında çeşitli çalışmalar yer almaktadır.

Alper ve Mumcu (2000), panel veri analizini kullanarak 1996-1999 yıllarında Türkiye pazarında otomobil piyasasının durumunu analiz etmiş ve otomobil fiyatlarını tahmin ederek, 2005 yılı için talep tahmini yapmışlardır. Asilkan ve Irmak (2009), ikinci el araç arz fiyatlarından yararlanarak YSA yöntemi ile ikinci el piyasası için araç satış fiyatlarını tahminlemiş ve sonrasında zaman serisi analizleri ile buldukları sonuçları karşılaştırmışlardır. Karşılaştırma sonuçlarına göre YSA ile tahminledikleri modelin çok daha iyi sonuç verdiklerini belirlemişlerdir. Sa-ngasoongsong, Bukkapatnana, Kim, Iyer ve Suresh (2012) otomobil satışları ve ekonomik göstergeler arasındaki dinamik bağlantıları belirlemek amacıyla istatistiksel birim kök, zayıf dışsallık, Granger-nedensellik ve eşbütünleşme testlerinden oluşan yapısal bir ilişki modeli sunmuştur. Ampirik analizler, otomobil satışlarının, belirlenen ekonomik göstergelerle uzun dönemli bir denge ilişkisine (eşbütünleşme) sahip olduğunu göstermiştir. Akyurt (2015), geri yayılım algoritması ile eğitilen ileri beslemeli YSA modelini kullanarak Türkiye'de üretim kararı verilmiş yerli otomobil için talep tahminlemesi gerçekleştirmiştir. Modelin performansı ortalama hata kare (MSE) ve ortalama mutlak yüzde hata (MAPE) ile test edilmiştir. Sonuç kısmında ise talep tahmini yapılacak çalışmalarda mevsimsellikten arındırılmış verilerle hareket etmenin daha sağlıklı sonuçlar vereceği belirtilmiştir. Kuvvetli ve diğ. (2015), aylık otomobil satışlarını tahminlemesinde

ekonomik ve çevresel parametreleri dikkate almış; çeşitli segment ve markaları kullanmıştır. Ürünlerin segmentleri, taşıt kredilerinde faizler, geçmiş zamanda gerçekleşmiş satış adetleri, gayrisafi milli hasıla, yakıt tüketimi, CO₂ emisyonları gibi farklı parametreler girdi olarak belirlenmiştir. Söz konusu girdiler kullanılarak 2008 – 2012 yılları arasındaki satış miktarlarını tahmin edebilecek bir YSA modeli önerilmiştir. Sonuç olarak, otomotiv sektöründe yapılacak tahminleme çalışmalarında girdi değişkenlerinin çeşitlendirilmesini önermişlerdir. Ayrıca, ülkemiz için yapılacak çalışmaların pazar araştırmalarına ışık tutacağını vurgulamışlardır. Vahabi, Hosseininia ve Alborzi (2016) İran'ın önde gelen otomobil üreticilerinden Saipa grubunun gelecekteki otomobil satışlarını tahmin etmek için iki yapay zekâ algoritması olan ANFIS ile genetik algoritma yöntemlerini birleştirmiştir. Değişkenler; kişi başına düşen gelir, enflasyon oranı, konut, ithalat, döviz kuru (USD), kredi faiz oranı ve otomobil ithalat tarifeleri olarak seçilmiştir. Son olarak, önerilen model YSA modeli ile karşılaştırılmıştır. Arslankaya ve Öz (2018), Türkiye'de otomotiv sektörünün önde gelen firmalarından birinin gelecek aylardaki satış adedini tahmin etmek için zaman serisi analizi yöntemlerinden hareketli ortalama ve basit üstel düzleştirme yöntemleri ile YSA'yı kullanmıştır. Bağımsız değişkenler olarak; trafiğe kayıtlı araç sayısı, gayri safi yurtiçi hasıla, tüketici fiyat endeksi, dolar kuru, reel sektör güven endeksi, tüketici güven endeksi ve aylık çalışma saatleri kullanılmıştır. Toplam satılan araç sayısı ise bağımlı değişken olarak alınmıştır. Tahminler gerçek değerlerle karşılaştırıldığında YSA'nın daha başarılı olduğu tespit edilmiştir. Abdellatief, Shaaban ve Abu-Raya (2019) birim satış fiyatı, enflasyon oranı, kişi başına düşen gelir, akaryakıt fiyatı ve önceki dönem satış hacmi değişkenlerini inceleyerek Mısır'daki en büyük otomobil üreticisi şirket için otomotiv satış tahminini ele almıştır. Model, YSA, ANFIS ve çoklu doğrusal regresyon yöntemleri kullanılarak eğitilmiştir. Son olarak, önerilen model ile gerçek satış miktarları karşılaştırılmış ve YSA'nın diğer tekniklere göre daha iyi sonuç verdiği tespit edilmiştir.

Literatürde YSA; pazarlama, finans, üretim, stratejik yönetim ve işletme politikası, enerji, kimya, tekstil gibi birçok farklı problemde kullanılmıştır (Hakimpoor, Arshad, Tat, Khani ve Rahmandoust, 2011; Pirdashti, Curteanu, Kamangar, Hassim ve Khatami, 2013, Chattopadhyay ve Guha, 2004).

Ekici ve Aksoy (2009) binaların enerji ihtiyaçlarını YSA ile tahmin etmiştir. Erdoğan ve Ekonomou (2010) Yunanistan'ın uzun vadeli enerji tüketimini çok katmanlı algılayıcı modeli (MLP) ile ele almıştır. Özyürek (2012), hisse senedi fiyatlarını etkileyen faktörleri belirlemiş ve YSA yöntemini kullanarak İMKB 100 endeksinde yer alan beyaz eşya işletmelerinin gün içinde kullandıkları fiyatların tahminlemesini yapmıştır. Sonuç kısmında ise YSA modelini uygulanabilirlik açısından test edilmiştir. Böylece, hisse senedi alımlarında yatırımcılara yol göstermek amaçlanmıştır. Susanto, Tanaya ve Soembagijo (2012), YSA kullanarak bir tekstil fabrikasında kumaş üretimi için ürün tedarik süresini formüle etmek amacıyla bir metodoloji önermiştir. Ketrez ve Saldanlı (2018), YSA yöntemi ile farklı modeller oluşturarak petrol fiyatlarındaki dalgalanmaları öngörmeye çalışmış ve bu modelleri karşılaştırmıştır. Sonuç olarak, veriler günlük olarak ele alındığında hata oranlarının daha düşük olduğu tespit edilmiştir. Ayrıca günlük periyot ile yapılmış çalışmalarda, girdi sayıları arttırıldığında daha

anamlı sonuçlar elde edilirken, aylık periyot ile yapılmış çalışmalarda nöron sayısının artması durumunda hata oranında düşüş gözlenmiştir. Salari vd. (2018) içme suyunun kimyasal ve fiziksel parametrelerinin karakterizasyonu için kalite değerlendirmesinde ileri beslemeli YSA modelini kullanmıştır. Doğan (2019), karar destek sistemi tasarlayarak bir havayolu firmasının beklenmeyen yönlendirmeden kaynaklı maliyetlerini minimuma indirmeyi amaçlamıştır. Havayolu firmasından alınan veriler doğrultusunda R programlama dili kullanılarak görüş mesafesi tahminlemesi gerçekleştirilmiştir. Çalışmanın bir bölümünde YSA kullanılarak yapılan tahminler zaman serisi analizi ile elde edilen sonuçlarla karşılaştırılmıştır. Sistem iyileştirilmesi, uçuşların yönlendirilmesi ile ölçülmüştür. Yapılan çalışma sonucunda zaman serisi analizleri %30 oranında bir iyileşme sağlarken YSA %36 oranında iyileşme ile daha iyi bir sonuç vermiştir. Vural ve diğ. (2019), Türkiye’de elektronik perakendede öncü işletmelerden birinin “bilgisayar” satış tahminlerini dikkate alarak YSA ile gelecek aylar için satış tahminlemesi gerçekleştirmiştir. Çelik (2019), müşterilerin perakende mağazasında geçmişteki ürün ya da hizmetler üzerindeki satın alma davranışlarını inceleyerek bir model oluşturmuştur. Benzer davranışları gösteren tüketiciler, kümeleme analizi kullanılarak sınıflandırılmıştır. Sonrasında birliktelik kuralları oluşturulmak için Apriori Algoritması kullanılarak Pazar Sepet Analizi yapıp müşteriler tarafından satın alınan ürünler arasında oluşan ilişki ölçülmüştür. Birliktelik kuralları, YSA ile tahminleme modeline dönüştürülmüş ve ağın etkinliğini kontrol edebilmek için Lojistik Regresyon Analizi kullanılarak yöntemler kıyaslanmıştır. YSA, lojistik regresyon analizi yöntemine kıyasla daha doğru tahmin sonuçları vermiştir. Erenler (2019), seri üretimini otomasyona dayalı olarak yapan işletmelerde oluşacak kalite kayıplarından dolayı yaşanan maliyeti minimuma indirmek için gelecek dönemlerdeki kalite kayıplarını tahmin etmeyi amaçlamıştır. Çalışmada, 650 günlük veri girdi değişkeni olarak kullanmış, KNN (K-En Yakın Komşuluk) algoritması ve YSA modelleri ile kalite kaybı tahminlemiştir. Sonuç olarak en az sapma değerine sahip tahminleme modelinin YSA olduğuna karar verilmiştir. Çınaroğlu ve Avcı (2020), bir YSA modeli ile Türk Hava Yolları firmasının hisse senet değerlerini tahminlemiştir. Çalışmada, 2015 ve 2018 arasındaki günlük hisse senedi fiyatları kullanılarak farklı YSA modelleri oluşturulmuş, sonrasında bu değerler eş zamanlı gerçekleşen sonuçlarla kıyaslanmış ve en başarılı YSA modeli belirlenmiştir. Analizlerde, çıktı değişkeni olarak hisse senedi değeri; girdi değişkenleri olarak ise BIST100 ve BIST Ulaştırma endeksleri, dolar ve petrol fiyatları seçilmiştir. Analizde pazartesi, salı, çarşamba ve perşembe günleri eğitim verisi olarak kullanılırken cuma günü ise test verisi olarak kullanılmıştır. En başarılı model kullanılarak 2019 Ocak ayı için 10 günlük hisse senedi tahminlemesini yapılmış ve gerçek değerler ve tahmin değerlerinin birbirlerine çok yakın olduğu ortaya konmuştur.

2.YÖNTEM

Bu çalışmada, yapay zekâ temelli YSA ve serilerdeki mevsimsellik etkiyi yansıtma konusunda başarılı Holt Winters’ tahmin yöntemi ile Türkiye’de 2019 ve 2020 yıllarında satılan toplam sıfır otomobil sayısı tahmin edilmiştir.

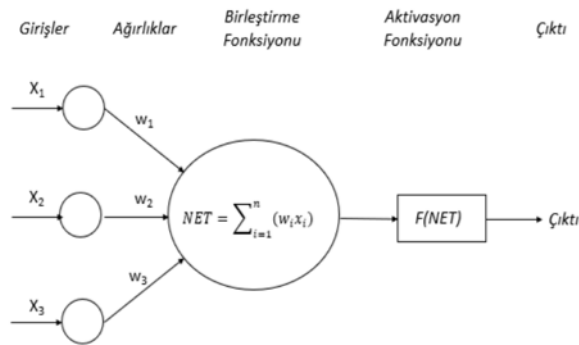
2.1 Yapay Sinir Ağları (YSA)

Bilgisayarlar geçmiş dönemlerde yalnızca hesap yapabilir veya veri transferi gerçekleştirirken, zamanla büyük miktardaki veriyi kullanarak bunları özetleyebilen ve yorumlayabilen bir duruma gelmiştir. Günümüz koşullarında bilgisayarlar olaylar hakkında karar vermenin yanında olaylar arasındaki ilişkiyi de öğrenmektedir. Matematiksel formülasyona dönüştürülemeyen veya çözümü mümkün gözükmeyen problemler, bilgisayarlar aracılığı ile çözülebilmektedir.

Yapay zekâ, insana özel olan algılama, karar verme, düşünme veya bilgi edinme gibi özellikler ile insan zekasını taklit etme yeteneğine sahip bilgisayarları temsil etmektedir (Vaishya, Javaid, Khan ve Haleem, 2020). Talep tahmin yöntemlerinde sıklıkla kullanılan yapay zekâ yöntemleri; YSA, genetik algoritmalar ve bulanık mantıktır. YSA; çok boyutlu, kesin veya doğrusal olmayan, karmaşık, kusurlu verilerle karşılaşılması durumunda, özellikle matematiksel modelin veya algoritmanın bulunamadığı problemlerde yaygın olarak kullanılan güçlü bir tekniktir (Yang ve Wang, 2020).

YSA, insan beyninden yola çıkarak düşünme ve çalışabilme potansiyeline sahip bilgi işlem teknolojisidir (Yaşar, 2004). Diğer bir deyişle, biyolojik sinir ağlarının çalışma şeklini taklit eden bilgisayar programlarıdır. Karmaşık yapıdaki ilişkilere sahip problemler için çözüm bulmak adına geliştirilmişlerdir. Yapay sinir ağı, basit işlemlerden oluşmuş, deneyim ile bilgileri biriktiren doğal bir öğrenme eğilimine sahip olan ve bunları kullanabilmeye olanak sağlayan bir işlemcidir (Ataseven, 2013).

YSA'lar, yapay sinir hücrelerinin birleşerek farklı katmanlar içinde paralel bir şekilde bağlantı kurmasıyla meydana gelmektedir. Modellenmeye çalışılan bir yapay sinir hücresi Şekil 1'de verilmiştir (Ersoy ve Kara, 2012). Yapay sinir hücresinde, girdiler (X_1, X_2, \dots, X_n) kendisine ait ağırlıklar ile çarpılıp toplanarak aktivasyon fonksiyonuna işlenmek için gönderilirler. Sinyal, aktivasyon fonksiyonuna ulaştığında burada işlem görüp çıktı şekline dönüştürülür (Drew ve Monson, 2000).



Şekil 1: Yapay Sinir Hücresi (Ersoy ve Kara, 2012)

Girişler, yapay sinir hücrelerine dışarıdan veya diğer hücrelerden aktarılan bilgilerdir. Girdi katmanına ulaşan girdiler, ağıın öğrenmesi gereken bilgilerdir. İstatistiksel analizler için bu girdiler bağımsız değişkenlere karşılık gelir. Ağırlık, girdi değişkeninin sinir hücresi üzerindeki etkisini ve önemini gösteren katsayıdır. Ağırlıklar girdi olarak kullanılmış değerlerin önemini gösterirken, bilgiler ağırlıklar ile hücrelere girer. Ağırlıklar başlangıç olarak rastgele olarak girilmekte ve ağıın eğitimiyle

paralel olarak değişmektedir. Ağırlık değişimi önemsenmeyecek seviyeye ulaşınca ağırlık istenilen eğitim seviyesine ulaştığı söylenebilir. Toplama fonksiyonu, yapay sinir hücrelerine ulaşan girdilerin kendi ağırlık katsayıları ile çarpılarak birleştirilme işleminin gerçekleştiği fonksiyondur. Fonksiyon genellikle toplama işlemini kullanırken araştırmacının kendi kurguladığı işlemi kullanmasına da olanak sağlar. Toplama fonksiyonunda yapılan işlem, genel olarak seçilmiş ağ mimarisine bağlıdır (Gerven ve Bohte, 2017). Sık olarak kullanılan fonksiyonlar arasında toplama, maksimum, minimum, çarpım ve kümülatif toplam fonksiyonları sayılabilir. Aktivasyon fonksiyonu, yapay sinir hücrelerinin çıktısının boyutunu sınırlandıran başka bir fonksiyondur. Ağ içerisindeki tüm hücrelerin, aktivasyon fonksiyonu farklı olabilir. Doğrusal fonksiyonlar genellikle aktivasyon fonksiyonu içinde kullanılmazlar. İkili değişkenler için adım fonksiyonu önerilirken, zaman serileri için sigmoid fonksiyonu önerilmektedir. Sık kullanılan aktivasyon fonksiyonlarını şu şekilde sıralanabilir: Doğrusal, eşik değer, adım, hiperbolik tanjant, sigmoid fonksiyonları. Çıktılar, aktivasyon fonksiyonundan iletilen değerlerdir. Çıkan değerler, başka bir hücreye veya dış dünyaya gönderilebilir. Yapay sinir hücrelerinin birden çok girdisi olmasına rağmen yalnızca bir çıktısı vardır. İstatistiksel analizlerde çıktı değerleri bağımlı değişkenler olarak da kullanılır (Kubat, 2021).

Yapay sinir hücreleri, ağırları meydana getirirken katmanlarda paralel bir şekilde dizilirler. Bir yapay sinir ağında üç temel katman bulunur: girdi katmanı, gizli katman ve çıktı katmanı. Girdi ve çıktı katmanları birer tanedir. Gizli katman sayısı YSA'nın yapısına göre çeşitli sayılarla olabilir. Girdi katmanından girilen veriler, girdi ile gizli katmanın arasında olan bağlantı ağırlığı ile çarpılıp sonrasında gizli katmana iletilir. Gizli katmanda, nöronlara ulaşan giriş verileri toplanarak, bir önceki sürece benzer olarak; gizli katman ve çıktı katmanı arasında bulunan bağlantı sürecinde, katmanlar arasında bulunan bağlantıların ağırlık kat sayıları belirlenir (Basheer ve Hajmeer, 2000).

2.2 Holt Winters' Yöntemi

Talep tahmini, birçok operasyonel karar için oldukça önemlidir (Huber ve Stuckenschmidt, 2020). Bu nedenle literatürde farklı talep tahmin yöntemleri geliştirilmiştir. Holt Winters' modeli, Winters tarafından Holt Doğrusal Trend modelini temel alarak geliştirilen bir tahmin tekniğidir. Winters, çift parametrelü üssel düzeltim yönteminin mevsimsel etkiye sahip zaman serileri üzerinde yeterince iyi sonuç vermediği tespit ederek Holt-Winters (1960) yöntemini geliştirmiştir. Yöntemin tahmin kısmı toplamsal ve çarpımsal olmak üzere iki farklı şekilde işlem yapmaya uygundur. Çarpımsal model, seride mevsimsel etkinin trende göre azalış ya da artış gösterdiği durumlarda; toplamsal model ise mevsimsel dalgalanmalar bir trende sahip olduğunda kullanılabilir. Çarpımsal model Eşitlik (1), (2), (3) ve (4)'te gösterilmiştir.

$$L_t = \alpha \cdot \left(\frac{Y_t}{S_{t-s}} \right) + (1 - \alpha) \cdot (L_{t-1} + b_{t-1}) \quad (1)$$

$$b_t = \beta \cdot (L_t - L_{t-1}) + (1 - \beta) \cdot (b_{t-1}) \quad (2)$$

$$S_t = \gamma \cdot \left(\frac{Y_t}{L_t} \right) + (1 - \gamma) \cdot (S_{t-s}) \quad (3)$$

$$F_{t+m} = (L_t + b_t m) \cdot S_{t-s+m} \quad (4)$$

Yöntemde kullanılan toplamsal model ise Eşitlik (5), (6), (7) ve (8)'de verilmiştir.

$$L_t = \alpha \cdot (Y_t - S_{t-s}) + (1 - \alpha) \cdot (L_{t-1} + b_{t-1}) \quad (5)$$

$$b_t = \beta \cdot (L_t - L_{t-1}) + (1 - \beta) \cdot (b_{t-1}) \quad (6)$$

$$S_t = \gamma \cdot (Y_t - L_t) + (1 - \gamma) \cdot (S_{t-s}) \quad (7)$$

$$F_{t+m} = (L_t + b_t m) + S_{t-s+m} \quad (8)$$

Notasyon aşağıdaki gibidir:

L_t : Eğim

b_t : Trend

S_t : Mevsimsel faktör

Y_t : Gözlemlenen değer

s : Mevsimsellik uzunluğu

F_{t+m} : m periyot gelecek tahmini

α : Modelin ortalama seviyeyi düzgünleştirme parametresi ($0 \leq \alpha \leq 1$)

β : Modelin ortalama seviyeyi düzgünleştirme parametresi ($0 \leq \beta \leq 1$)

γ : Modelin ortalama seviyeyi düzgünleştirme parametresi ($0 \leq \gamma \leq 1$) (Tüzemen, 2020).

2.3 Tahmin Doğruluğunun Ölçülmesi

Tahmin yöntemleri ile gerçekleştirilen tüm tahminlerde bir mutlak hata oluşmaktadır. Modellerin öngörü başarılarını karşılaştırmak üzere tahmin doğrulukları ölçülür. Yapılan tüm tahminlerde amaç, hata değerleri küçük tahmin modelini oluşturabilmektir.

Literatürde birçok hata parametresi tanımlanmış olup hangisinin dikkate alınması gerektiği konusunda bazı kıstaslar bulunmaktadır. Lewis, ortalama mutlak yüzde hata (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. (Lewis, 1982). Bu çalışmada ele alan hata istatistikleri Eşitlik (9) ve (10)'da ifade edilmiştir. Notasyonda Y_t gerçek değeri, \hat{Y}_t tahmin değerini ve n dönem sayısını temsil etmektedir.

$$\text{Ortalama mutlak yüzde hata (MAPE)} = \frac{\sum \frac{|(Y_t - \hat{Y}_t)|}{Y_t}}{n} * 100 \quad (9)$$


$$\text{Ortalama hata kare (MSE)} = \frac{\sum |(Y_t - \hat{Y}_t)|^2}{n} \quad (10)$$

MAPE yüzde olarak ifade edilebilmesi ve Lewis (1982)'in sınıflandırması sayesinde yorumlanması kolay bir hata istatistiğidir. MSE ise hata değerlerinin büyüklükleri benzer ise kullanılabilir. Bu nedenle bu çalışmada tahmin verilerindeki başarı MAPE ve MSE hata değerlerinin kıyaslanması ile ölçülmüştür.

3. PROBLEMİN TANIMLANMASI

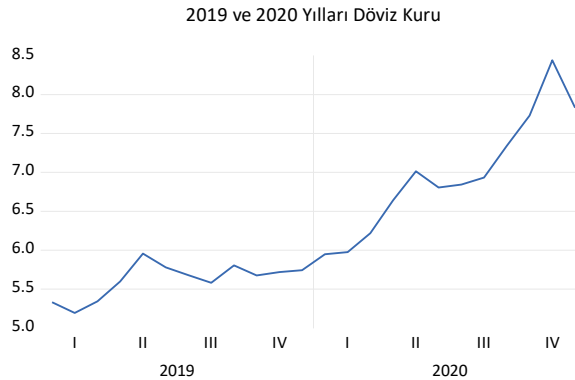
Bu çalışmada, 2015-2019 yılları arasındaki sıfır otomobil satış verileri kullanılarak YSA ve Holt Winters' yöntemleri ile 2019 ve 2020 yılları için Türkiye satış miktarları tahmin edilmiştir. Literatür taraması ile otomobil satışlarını etkileyen dört girdi değişkeni belirlenmiştir. Bunlar; döviz kuru, tüketici güven endeksi, reel kesim tüketici güven endeksi ve gayri safi yurt içi hasıladır (GSYİH).

Belirli bir zaman diliminde üretilen toplam nihai ürünlerin piyasadaki değerinin ekonomik ölçüsü GSYİH olarak adlandırılır. (Gültekin ve Aslan, 2015). Ekonomik büyüme bir ülkede genelde GSYİH'deki değişim ile tespit edilir. GSYİH'nin değişkenliği müşterilerin alım gücünü değiştirirken, satın alma davranışlarını etkilemektedir. Şekil 2'de 2019 ve 2020 yıllarında gerçekleşen GSYİH değerleri verilmiştir.



Şekil 2: 2019 ve 2020 Yılları GSYİH Değerleri (Tüik, 2021)


Dış ekonomik ilişkiler her ülke için döviz kullanmayı gerektirir. Ülkemize giriş yapan otomobiller, döviz kuru üzerinden hesaplanır. (Büker ve Çelikkol, 2019). Yabancı markaların büyük çoğunluğu satış anında geçerli olan kur fiyatlarını Türk lirasına çevirerek satış gerçekleştirmektedir. Doğal olarak döviz kurunda yaşanacak yükseliş veya azalış doğrudan otomobil fiyatlarını etkileyecektir. Otomobil fiyatlarındaki değişim ise müşterinin alım gücüne yani bir diğer ifade ile talep oluşumuna yansır. Şekil 3'te 2019 ve 2020 yıllarında gerçekleşen döviz kuru değerleri verilmiştir.



Şekil 3: 2019 ve 2020 Yılları Döviz Kuru Değerleri (Türkiye Cumhuriyeti Merkez Bankası, 2021)


Tüketici güven endeksi, tüketicilerin gelecek dönemdeki beklentilerini veya yakın zamandaki harcama ve tasarruf eğilimlerini ölçmek için kullanılan göstergedir. Tüketicilerin kişisel olarak maddi durumlarının ve genel ekonomi ile ilişkili durumlarının değerlendirilmesine yardımcı olur. Bu noktadan

hareketle, endekste oluşabilecek dalgalanmalar tüketicinin satın alma davranışlarının yanında alım gücündeki değişimin de göstergesidir (Özdemir, 2013). Şekil 4'te 2019 ve 2020 yıllarında gerçekleşen tüketici güven endeksi değerleri verilmiştir.



Şekil 4: 2019 ve 2020 Yılları Tüketici Güven Endeksi Değerleri (Tüik, 2021)


Reel kesim güven endeksi; reel sektörde aktif olarak bulunan işletmelerin gelecek dönemde ekonomi hakkındaki görüşleri ve bu görüşlere göre üretim ve yatırım faaliyetlerinde ne tür bir değişikliğe gideceklerini gösteren bir endekstir (Albayrak, 2018). GSYİH beklentisini belirlemek için kullanılan önemli göstergelerden biridir. Şekil 5'te 2019 ve 2020 yıllarında gerçekleşen reel kesim güven endeksi değerleri verilmiştir.



Şekil 5:2019 ve 2020 Yılları Reel Kesim Güven Endeksi Değerleri (Tüik, 2021)

3.1 Çoklu Regresyon Analizi

Çalışmada, sıfır otomobil satışı etkileyen değişkenlerin birbirleri ile ilişkisini analiz etmek adına 2019 yılı veri seti üzerinde çoklu regresyon analizi gerçekleştirilmiştir. Normallik testi ile modelde yer alan değişkenlerin (Dolar, GSYİH, TGE, REGE) normal dağılıma uyduğu tespit edilmiş ve Şekil 6'da gösterilmiştir.



Şekil 6: Değişkenlerin Normallik Analizi

Tablo 2’de model değişkenlerinin tanımlayıcı istatistikleri verilmiştir.

Tablo-2: Tanımlayıcı İstatistikler

	Ortalama	Std. Sapma
SatisHacmi	32271,33	16413,315
Dolar	5,617233	0,2228810
TGE	79,73580	1,798260
GSYİH	356698,25	36626,4589
REGE	100,25800	4,294900

Tablo 3’te çoklu regresyon analizi sonucunda ulaşılan modelin özeti verilmiştir.

Tablo-3: Regresyon Analizi Model Özeti

Model	R	R ²	Düzeltilmiş R ²	Durbin-Watson
1	,949 ^a	0,901	0,845	2,971

a. Tahmin Ediciler: (Sabit), REGE, Dolar, TGE, GSYİH

b. Bağımlı değişken: SatisHacmi

Çoklu regresyon analizinde sonradan eklenen değişkenlerin modele katkısını ölçebilmek adına düzeltilmiş R² değerleri incelenir (Kaya, 2018).

Modele göre, otomobil satış hacminin %84,5'e yakın bir bölümünün bağımsız değişkenler tarafından açıklanabildiği görülmüştür. Çoklu regresyon analizi yapabilmek adına bir diğer ölçüt Durbin-Watson (DW) katsayısının incelenmesidir. Anlamli otokorelasyon modelin yanlış tanımlandığını gösterebilir. Modelde önemli bir değişken unutulmuş veya fonksiyonel ilişki yanlış tanımlanmış olabilir. DW 2 civarında ise otokorelasyon olmadığı, 0'a yakın ise pozitif otokorelasyon olduğu, 4'e yakın ise negatif otokorelasyon olduğu söylenebilir (Birgili ve Düzer, 2010).

Modelde DW 2,971 olduğundan otokorelasyon yoktur. Regresyon modelinin anlamlı olup olmadığını tespit etmek için gerçekleştirilen ANOVA testi sonuçları Tablo 4'te verilmiştir.

Tablo-4: Anova Sonuçları

Model	Kareler Toplamı	Serbestlik Derecesi	Ortalama Kare	F	Sig.	
1	Regresyon	2,67E+09	4	66761875	15,956	,001
	Artık	29289116	7	41841595		
	Toplam	2,963E+0	11			

a. Bağımlı Değişken: SatisHacmi

b. Tahmin Ediciler: (Sabit), REGE, Dolar, TGE, GSYİH

Sig. değeri $0,001 < 0,05$ olduğu için dolar, reel kesim güven endeksi, tüketici güven endeksi ve gayrisafi yurt içi hasıla değişkenlerinin otomobil satış hacmini istatistiksel olarak anlamlı olarak etkilediği söylenebilir. Her bir değişkenin bağımlı değişken üzerindeki etkisi Tablo 5'te incelenmiştir.

Tablo-5: Regresyon Modeli Bağımsız Değişkenler ve Katsayı Değerleri

Model	Standart Olmayan Katsayılar		Standart Katsayılar	t	Sig.	VIF
	B	Std. Hata	Beta			
1	(Sabit)	-383629,9	118789,29	-3,229	0,014	
	Dolar	37384,428	12346,5	0,508	3,028	1,991
	TGE	-2395,504	1365,7	-0,262	-1,754	0,123
	GSYİH	-0,369	0,112	-0,825	-3,285	0,013
	REGE	5273,467	830,313	1,38	6,351	0

a. Bağımlı Değişken: SatisHacmi

Beta değerleri incelendiğinde satış hacmi üzerinde etkili olan en önemli değişkenin reel kesim güven endeksi olduğu görülmüştür. Bunu sırasıyla; gayri safi yurtiçi hasıla, dolar ve tüketici güven endeksi izlemiştir. Reel kesim güven endeksindeki bir birimlik standart sapma oranında artışın, otomobil satış hacminin standart sapmasını %138 arttıracığı ve dolardaki bir birimlik standart sapma oranında yaşanacak artışın, otomobil satış hacminin standart sapmasını %50,8 oranında arttıracığı görülmüştür.

Çoklu doğrusal bağıntıyı tespit etmek için kullanılan bir diğer ölçüt ise varyans artış faktörüdür. Varyans artış faktörü (VIF) bir bağımsız değişkenin diğer bağımsız değişkenlerle olan ilişkisinin derecesini belirlemek için hesaplanır. VIF 10'a eşit veya daha büyük ise, çoklu doğrusal bağıntı

problemi mevcuttur (Büyükuysal ve Öz, 2016). Hesaplanan VIF değerleri sırası ile 1,91, 1,58, 4,46, 3,34'tür. Analiz sonucuna göre modelde çoklu doğrusal bağıntı problemi olmadığı tespit edilmiştir.

Dolar ve REGE değişkenleri için sig. değerleri 0,05'ten küçük ve t değerleri 0'dan büyük olduğundan bu değişkenlerin otomobil satışına anlamlı ve pozitif yönde etkisi olduğu söylenebilir. Benzer sebeplerle GSYİH değişkeninin otomobil satışına anlamlı ve negatif yönde bir etkisi olduğu tespit edilmiştir. TGE değişkeni ise otomobil satışlarını istatistiksel olarak anlamlı bir ölçüde etkilememektedir.


Veri setlerinin değişkenlik durumlarını karşılaştırmak gerektiğinde yalnızca standart sapmaya bakmak yeterli olmayabilir. Farklı birimlere sahip veri setlerinin değişkenliklerini kıyaslarken değişkenlik (varyasyon) katsayısı kullanılmaktadır (Büyükcangaz ve diğ., 2018).

Çalışmada 2019 ve 2020 yılları otomobil satış adetlerini karşılaştırmak adına değişkenlik katsayısı hesaplanmış Tablo 6'da gösterilmiştir.

Tablo-6: Değişkenlik Katsayısının Karşılaştırılması

Yıl	Standart Sapma	Aritmetik Ortalama	Değişkenlik Katsayısı
2019	15714,55	32271,33	49%
2020	20814,6	50842,42	41%

Değişkenlik katsayısının yüksek çıkmasının nedeninin aylık otomobil satışlarının mevsimsellikten etkilenmesi olduğu düşünülmektedir. Otomobil satışlarındaki mevsimsellik etkisi Şekil 7'de verilmiştir.



Şekil 7: 2015-2019 Yılları Otomobil Satış Adetleri (Otomotiv Distribütörleri Derneği, 2021)

3.2 YSA Mimarisi

Ağ mimarisi oluşturulmasında en uygun modeli bulabilmek için parametreler belirlenirken zor ve karmaşık çeşitli tekniklere başvurulmaktadır. Aynı zamanda probleme uygun çözüm bulabilecekleri de kesin değildir. YSA'nın bu özelliklerinden dolayı ağ tasarımının bir bilimden öte bir sanat olduğu vurgulanmaktadır (Zhang ve diğ., 1998).

YSA nöron bağlantılarının ağırlık katsayıları belirlenirken ağırlık eğitilmesi de gerçekleştirilir. Ağırlık değerleri başlangıçta rastgeledir. YSA'lara örnekler girildikçe ağırlık değerleri de değişim göstermektedir. Literatürde, eğitim ve test verileri dağılım oranları genellikle %90-%10, %80-%20 veya %70-%30 olarak belirlenmiştir (Çuhadar ve diğ., 20019). Eğitim veri seti, YSA modelinin geliştirilmesi için kullanılırken, test verisi modelin tahmin becerisini geliştirmekte kullanılır.

Çalışmada, satış tahmini için çok katmanlı ileri beslemeli geri yayılım algoritması seçilmiştir. 2015 – 2020 yıllarına ait verilerin; %70'i ağırlık eğitimi, %15'i ağırlık doğrulaması ve %15'i de ağırlık test edilmesinde kullanılmıştır. Farklı normalizasyon yöntemleri ile modelin ürettiği değerler ve gerçek değerler karşılaştırılarak hangi normalizasyon yönteminin daha gerçekçi sonuçlar verdiği tespit edilmiştir. 2015, 2016, 2017 ve 2018 yıllarını içeren veriler eğitim; 2019 yılını içeren veriler ise test için kullanılmıştır. Ağırlık, eğitim ve test aşamasında bugünkü gerçek veriler kullanılmıştır. Burada amaç YSA'nın öğrenip öğrenmediğini bugünkü değerler ile ölçmektir. Ağ sonucu gerçek değerlere yakın sonuçlar verdiğinde, ağırlık öğrenme işlemi gerçekleşmiştir.

Farklı normalizasyon yöntemleri Eşitlik (11), (12) ve (13)'de ifade edilmiştir. Notasyonda X_i girdi değeri, X_{min} girdi verisi içerisindeki en küçük sayıyı, X_{maks} girdi verisi içerisindeki en büyük sayıyı, σ_i girdi verisinin standart sapmasını, μ_i girdi setinin ortalamasını temsil etmektedir.

$$D \text{ Min Maks Normalizasyonu} = 0,8 * \frac{X_i - X_{min}}{X_{maks} - X_{min}} + 0,1 \quad (11)$$

$$Z \text{ Score Normalizasyonu} = \frac{X_i - \mu_i}{\sigma_i} \quad (12)$$

$$\text{Min Maks Normalizasyonu} = \frac{X_i - X_{min}}{X_{maks} - X_{min}} \quad (13)$$

Uygulanan normalizasyon yöntemlerinin tahmin doğruluğunu ve tahmin başarısını test edebilme noktasında MAPE ve MSE istatistiği kullanılmıştır. Tahmin hatasının küçülmesi yöntemin doğruluğunu arttırmaktadır. Bu sebeple, farklı tahmin yöntemleri kıyaslanırken minimum hata değerine sahip yöntem en iyi yöntem olarak seçilmektedir.

Normalizasyon yöntemleri uygulanarak elde edilmiş MAPE ve MSE sonuçları Tablo 7'de verilmiştir.

Tablo-7: Veri Normalizasyonu Analiz Sonuçları

Analiz Sonuçları	TANSİG (3,1,12)		TANSİG (3,1,15)		LOGSİG (3,1,12)		LOGSİG (3,1,15)	
	MAPE (%)	MSE	MAPE (%)	MSE	MAPE (%)	MSE	MAPE (%)	MSE
D_Min_Maks Normalizasyonu	31,545	0,003	22,436	0,002	39,281	0,005	28,089	0,003
Z-Skor Normalizasyonu	22,703	0,005	20,365	0,076	32,409	0,14	25,14	0,091
Min_Maks Normalizasyonu	22,795	0,002	23,078	0,003	37,076	0,008	37,524	0,009

YSA eğitimi için aktivasyon fonksiyonları, gizli katman sayısı, iterasyon sayısı (750-1000) ve nöron sayısı değiştirilerek ağırlık performansı ölçülmeye çalışılmıştır. İterasyon sayısının 1000

seçilmesiyle model daha iyi sonuçlar verdiğiinden 1000 iterasyonda çalıştırılmış modelin çıktıları gösterilmiştir.

Tablo 8’de gösterildiği gibi Z-score normalizasyonu diğer yöntemlere göre daha iyi sonuçlar vermiştir. Aktivasyon fonksiyonu, Tanjant Sigmoid (tansig) fonksiyonu ile Logaritmik Sigmoid (logsig) fonksiyonu test için denenmiştir. Tansig (3,1,15) gösterimi sırasıyla katman sayısını, gizli katman sayısını ve gizli katmandaki nöron sayılarını belirtmektedir.

Tablo-8: Veri Normalizasyonu ve Aktivasyon Fonsiyonları En iyi Analiz Sonuçları

En İyi Analiz Sonuçları	YSA Girdi Parametreleri	MAPE (%)	MSE
Z-Skor Normalizasyonu	TANSİG (3,1,15)	20,365	0,076
D_Min_Maks Normalizasyonu	TANSİG (3,1,15)	22,436	0,002
Z-Skor Normalizasyonu	TANSİG (3,1,12)	22,703	0,005

Sonuç olarak, YSA’nın gerçekleşmiş değerlere yakın değerler ürettiği kabul edilebilir. Ağ veriler arasında doğrusal olmayan ilişkiyi öğrenip bu verileri genelleme yaparken, öncesinde hiç karşılaşmadığı problemlere de kabul edilebilir bir hata derecesiyle cevap verebilmektedir. Bu özelliği sayesinde YSA, tahmin yöntemlerinde etkili sonuçları veren bir yöntemdir.

3.2.1 Gizli Katman ve Nöron Sayısının Belirlenmesi

Gizli katman sayısını değiştiren faktörler arasında; üzerinde çalışılan konu, veri büyüklüğü ve ağ tasarımı yer almaktadır. Genel olarak bir veya iki gizli katman modeller için yeterli olabilmektedir. Gizli katman sayısındaki artış ağda gerçekleşen işlem hızını düşürmekte ve ağın öğrenmesine değil ezberlemesine yol açmaktadır. Giriş katmanı, gizli katman ve çıkış katmanı olmak üzere genellikle üç katmanlı yapı tercih edilir. Sonuçların tatmin derecesi iki veya üç ara katmanlı yapılarda denenmiştir. Problemin çözümünde iki gizli katmandan fazlasına ihtiyaç duyulmadığı gözlenmiştir. Başarı performansını negatif yönde etkileyen faktörlerden biri de gizli katman sayısının toplamda dört katmandan fazla olmasıdır.

Genel olarak modellerde az sayıda nöron tercih edilmektedir. Bu şekilde ağ yapısının genelleştirme becerisi daha güçlü olmaktadır. Nöron sayısını belirlemek için kesinliği olmayan farklı kurallar geliştirilmiştir. Üç katman, n giriş hücreli ve m çıkış hücreli bir ağ modeli için nöron sayısı minimum olarak $n \times m$, maksimum $2n$ sayıda olabilir. Bu kural geometrik piramit kuralı olarak adlandırılır. Bailiy ve Thompson üç katmana sahip bir ağ modeli için gizli hücre sayısının, gizli katmanda bulunan hücre sayısının %75’i kadar olabileceğini önermektedir (Kaastra ve Boyd, 1996).

Çalışmadaki nöron sayısı deneme yanılma yoluyla belirlenmiş ve 15 nöronla gerçekleştirilen denemenin en iyi sonuç verdiği tespit edilmiştir. Model girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katman ile oluşturulmuştur. Girdi katmanı içinde dört, çıktı katmanı içinde bir hücre bulunmaktadır. Gizli katmanda yer alacak en uygun sayıdaki nöronu tespit etmek için çeşitli testler yapılmıştır.

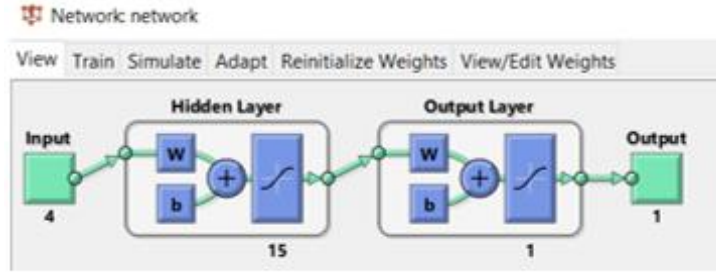
3.3 Modelin Çözümü

3.3.1 2019 verileri için YSA'nın Eğitilmesi ve Test Edilmesi

YSA'nın eğitiminde, MATLAB 9.4 R2018a sürümünde bulunan Neural Network paketi kullanılmıştır. İlk olarak MATLAB programında Workspace sekmesine normalize edilmiş ve eğitimde kullanılacak olan girdi ve çıktı verileri girilmiştir.

YSA'yı programa tanımlamak için Network kısmına, oluşturmak istediğimiz ağ yapısının tipinin, eğitim girdi-çıkı verisinin, eğitim – öğrenme algoritmasının, katman sayısının, nöron sayısının, gizli hücre sayısının ve aktivasyon fonksiyonunun seçim işlemi yapılmıştır.

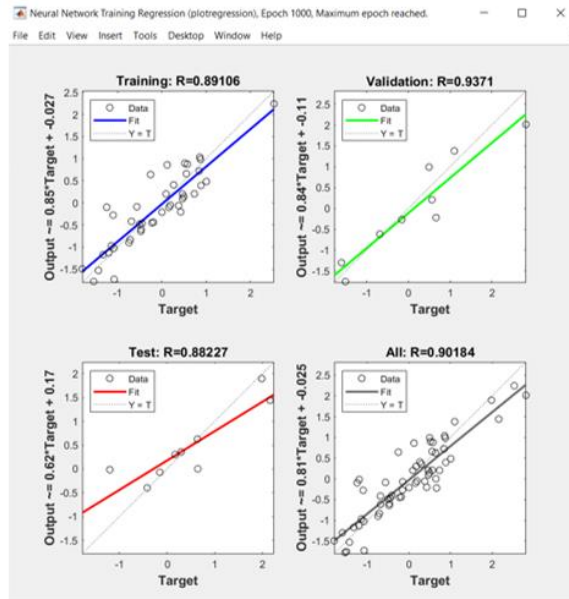
Şekil 8'de oluşturulmuş YSA modeli verilmiştir.



Şekil 8: YSA Gösterimi

Network - Train sekmesinden ağı öğrenme performansını etkileyecek parametrelerin seçimi yapılmıştır. Bunlar momentum katsayısı, çevrim sayısı ve öğrenme katsayısıdır. Sonrasında “Train Network” butonu ile ağ eğitilir. Eğitim sonrasında her iterasyonda karşılaşılan eğitim, doğrulama, test kümelerine ait hata değerlerinin nasıl değiştiği izlenmiştir.

MATLAB programında öğrenme işlemi gerçekleştirildikten sonra elde edilmiş regresyon grafiği Şekil 9'da verilmiştir. Grafiğe göre minimum değer 0,8822 olan test kümesine aittir.



Şekil 9: Öğrenme, Doğrulama ve Test Kümelerine Ait Regresyon Grafiği (2019)

Tablo 9’da YSA’nın eğitimi sonucu minimum hatayı veren parametreler belirtilmiştir. YSA’yı test etme işlemi tablodaki parametreler kullanılarak yapılmıştır.

Tablo-9: YSA Parametreleri (2019)

Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması
Eğitim Fonksiyonu	Traingdx
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig- Tanjant Sigmoid Fonksiyonu
Performans	MSE - Hata Kareleri Ortalaması
Öğrenme Katsayısı	0,01
Devir Katsayısı	1000
Çevrim Katsayısı	1000
Gizli Katman Sayısı	1
Katman Sayısı	3
Momentum Katsayısı	0,9
Gizli Katmandaki Nöron Sayısı	15

YSA’nın eğitim sürecinin tamamlanması ile ağ, öğrenme işlemini tamamlamıştır. Sonrasında ağın eğitimini test edip ölçmek amacıyla çeşitli denemeler yapılmıştır. Test için 2019 yılına ait veriler kullanılmıştır. Eğitim sırasında ağın belirlediği değerler kullanarak yeni çıktılar üretilmiştir. YSA eğitildikten sonra aynı ekranda yer alan “Simulate” kısmından test girdi verileri için YSA’nın tahmini test verilerini üretmesi sağlanmıştır.

Test işlemi tamamlandıktan sonra ağın ürettiği tahmini satış değerleri ile gerçek değerler normalize edilmiş değerlerden dönüştürülerek karşılaştırılmıştır. Bu karşılaştırma sonucunda MSE değeri 0,076 çıkarken, MAPE değeri %20,365 bulunmuştur.

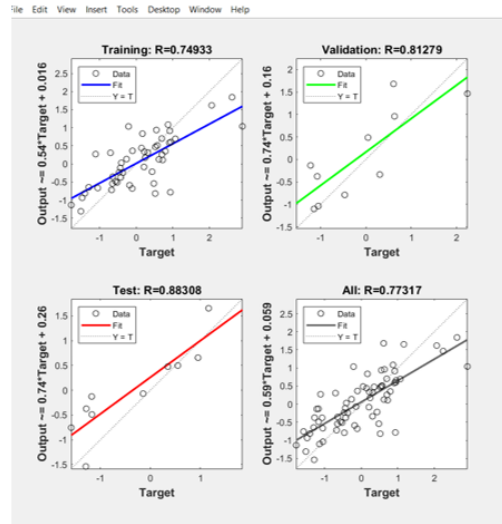
3.3.2 2020 verileri için YSA’nın Eğitilmesi ve Test Edilmesi

Çalışmanın bundan sonraki aşamasında geçmiş verilerden hareketle 2020 yılı on iki aylık otomobil satış tahminlemesi yapılmıştır. Ağ eğitimine başlanmadan önce 2015-2019 yıllarında gerçekleşmiş girdi ve çıktı verileri istatistiksel normalizasyon (Z-score) yöntemi ile normalize edilmiştir. YSA’nın öğrenme sürecinde girdi katmanı, gizli katman ve çıktı katmanından oluşan üç katmanlı bir yapı seçilmiştir. Aktivasyon fonksiyonlarından biri olan tanjant sigmoid fonksiyonu kullanılmıştır. Tablo 10’da minimum hata performansını gösteren parametreler verilmiştir.

Tablo-10: YSA Parametreleri (2020)

Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması
Eğitim Fonksiyonu	Traingdx
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig- Tanjant Sigmoid Fonksiyonu
Performans	MSE - Hata Kareleri Ortalaması
Öğrenme Katsayısı	0,01
Devir Katsayısı	1000
Çevrim Katsayısı	1000
Gizli Katman Sayısı	1
Katman Sayısı	3
Momentum Katsayısı	0,9
Gizli Katmandaki Nöron Sayısı	15


Veri setinin %70'lik kısmı YSA'nın eğitimi, %15'lik kısmı veri setinin doğrulanması ve kalan %15'lik kısmı ise ağın test aşaması için kullanılmıştır. Öğrenme işlemi tamamlandıktan sonra elde edilmiş regresyon grafiği Şekil 10'da verilmiştir.

**Şekil 10: Öğrenme, Doğrulama ve Test Kümelerine Ait Regresyon Grafiği (2020)**

3.3.3 2020 verileri için Holt Winters' Tahmini

Çalışmanın bu bölümünde 2015-2019 yılları arasında gerçekleşen otomobil satış verileri kullanılarak 2020 yılı 12 aylık otomobil satış adetleri Holt Winters' ile tahmin edilmiştir. MINITAB paket programı, belirli bir güven aralığında tahmin yapmaya imkân vermektedir. Çalışmada güven aralığı %95 olarak belirlenmiştir.

Tahmin değerleri Şekil 11'de gösterilmiştir.



Şekil 11: Holt-Winters' Yöntemi


4. BULGULAR

Tablo 11'de Ocak 2019'dan Aralık 2019'a kadar gerçekleşmiş sıfır otomobil satış adetleri ve YSA'nın tahmin ettiği değerler yer almaktadır.

Tablo-11: YSA Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması (2019)

Aylar	Gerçek Değer (Adet)	Tahmini Değer (Adet)
2019 Ocak	10.979	17.890
2019 Şubat	19.205	17.102
2019 Mart	38.628	49.368
2019 Nisan	24.416	26.039
2019 Mayıs	27.126	12.652
2019 Haziran	36.024	37.498
2019 Temmuz	15.398	22.197
2019 Ağustos	21.544	25.128
2019 Eylül	35.308	32.655
2019 Ekim	39.996	40.529
2019 Kasım	47.803	45.249
2019 Aralık	70.829	73.381

YSA'nın eğitilmesi sonrasında test değerlerinin ve gerçek değerlerin daha iyi karşılaştırılması ve gözlemlenebilmesi için Şekil 12'de çizgi grafiği verilmiştir.




Şekil 12: YSA Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması (2019)

Tablo 11 ve Şekil 12 incelendiğinde YSA'nın şubat, haziran, eylül, ekim, kasım ve aralık ayları için gerçek değerlere yakın tahminleme yaptığı görülmektedir. Fakat ocak, mart ve mayıs ayları incelendiğinde tahminlerde sapmalar olduğu gözükmemektedir. En yakın tahmin 553 fark ile ekim, en uzak tahmin ise 14.474 fark ile mayıs ayında gerçekleşmiştir. Tablo 12'de Ocak 2020'den Aralık 2020'ye kadar gerçekleşmiş sıfır otomobil satış adetleri ve YSA'nın tahmin ettiği veriler yer almaktadır.

Tablo-12: YSA Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması (2020)

Aylar	Gerçek Değer (Adet)	Tahmini Değer (Adet)
2020 Ocak	22.016	50.014
2020 Şubat	37.727	41.106
2020 Mart	39.887	34.587
2020 Nisan	21.825	21.672
2020 Mayıs	25.073	15.329
2020 Haziran	57.067	44.827
2020 Temmuz	69.427	63.727
2020 Ağustos	44.372	52.340
2020 Eylül	71.296	61.074
2020 Ekim	76.341	83.311
2020 Kasım	64.357	55.651
2020 Aralık	80.721	73.769

YSA'nın ürettiği 2020 yılı tahmin verileri ile gerçek değerleri daha iyi karşılaştırabilmek için Şekil 13'te grafik gösterimi verilmiştir.



Şekil 13: YSA Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması (2020)

Tablo 12 ve Şekil 13 incelendiğinde YSA'nın ocak, mayıs, haziran ve eylül aylarındaki tahmin değerlerinin gerçek değerlere kıyasla farklı değerler üretmiş olduğu görülmektedir. En yakın tahmin 153 fark ile nisan, en uzak tahmin ise 14.474 fark ile mayıs ayında gerçekleşmiştir.


YSA'nın ürettiği tahmin değerleri doğrultusunda aralık ayında diğer aylara oranla satışların arttığı görülmektedir. Araba satış merkezlerinin yıl sonu stoklarını bitirmek için yapmış olduğu indirim müşterilerin alış yapmak için bu zaman dilimini tercih etmesine neden olmaktadır. Bu durum aralık ayında ülke ekonomisinde hareketliliğe neden olmaktadır.

Tablo 13'te Ocak 2020'den Aralık 2020'ye kadar gerçekleşmiş sıfır otomobil satış adetleri ve Holt Winters' yönteminin tahmin ettiği veriler yer almaktadır.

Tablo-13: Holt Winters' Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması

Aylar	Gerçek Değer (Adet)	Tahmini Değer (Adet)
2020 Ocak	22.016	15.190
2020 Şubat	37.727	24.931
2020 Mart	39.887	44.092
2020 Nisan	21.825	41.659
2020 Mayıs	25.073	46.645
2020 Haziran	57.067	49.318
2020 Temmuz	69.427	38.132
2020 Ağustos	44.372	39.326
2020 Eylül	71.296	40.684
2020 Ekim	76.341	46.499
2020 Kasım	64.357	67.213
2020 Aralık	80.721	95.086

Holt Winters' yönteminin ürettiği 2020 yılı tahmin verilerini daha iyi karşılaştırabilmek için Şekil 14'te grafik gösterimi kullanılmıştır.




Şekil 14: Holt Winters' Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması (2020)

Tablo 13 ve Şekil 14 incelendiğinde Holt Winters' tahmin yönteminin mart, ağustos ve kasım aylarında gerçek değerlere yakın tahmin değerler ürettiği gözlemlenmiştir. Mayıs, temmuz, eylül ve ekim aylarında ise tahmin değerlerinde oldukça sapma görülmüştür. En yakın tahmin 2.856 fark ile kasım, en uzak tahmin ise 31.295 fark ile temmuz ayında gerçekleşmiştir.

YSA'nın ürettiği tahmin değerleri ile Holt Winters' yönteminin ürettiği tahmin değerleri Tablo 14'te verilmiş ve Şekil 15'te gösterilmiştir. Şekil 15'e göre YSA'nın trendi Holt Winters' yöntemine kıyasla daha başarılı tahminlediği söylenebilir.

Tablo-14: 2020 Yılı için Tahmin Yöntemlerinin Kıyaslanması

Aylar	Gerçekleşen Satış Adeti	YSA Tahmin	Holt Winters' Tahmin
2020 Ocak	22.016	50.014	15.190
2020 Şubat	37.727	41.106	24.931
2020 Mart	39.887	34.587	44.092
2020 Nisan	21.825	21.672	41.659
2020 Mayıs	25.073	15.329	46.645
2020 Haziran	57.067	44.827	49.318
2020 Temmuz	69.427	63.727	38.132
2020 Ağustos	44.372	52.340	39.326
2020 Eylül	71.296	61.074	40.684
2020 Ekim	76.341	83.311	46.499
2020 Kasım	64.357	55.651	67.213
2020 Aralık	80.721	73.769	95.086



Şekil 15: 2020 Yılı İçin Tahmin Yöntemlerinin Kıyaslanması

Tablo-15: 2020 Yılı Verileri ile Model Performanslarının Karşılaştırılması

Tahmin Yöntemi	MAPE
Holt Winters' Yöntemi	36%
YSA	23%

Tahmin yöntemlerinin karşılaştırılması ve model performanslarının ölçülmesi adına MAPE değerleri Tablo 15'te verilmiştir. Holt Winters' yönteminin MAPE değeri %36 iken YSA için MAPE değerinin %23 olduğu görülmektedir. 2020 yılı otomobil satış adetlerinin tahmin edilmesinde YSA'nın Holt Winters' tahmin yöntemine kıyasla daha başarılı olduğu görülmüştür.

SONUÇ

Çalışmada 2015 – 2020 yılları arasında gerçekleşmiş döviz kuru, GSYİH, tüketici güven endeksi, reel kesim güven endeksi ve otomobil satış verileri ile öncelikle çoklu regresyon analizi yapılmıştır. Çoklu regresyon analizi sonucunda otomobil satış hacmini etkileyen faktörlerin seçilen bağımsız değişkenler tarafından açıklanabildiği tespit edilmiştir. Aylık otomobil satış adetlerinin farklılık göstermesinin ana nedeninin mevsimsel etkiden kaynaklı olduğu düşünülmektedir. Çalışmanın sonraki bölümünde YSA ve Holt Winters' yöntemleri kullanılarak 2019 ve 2020 yıllarında Türkiye'de satılan sıfır otomobil satış tahminlemesi yapılmıştır. Otomobil Distribütörleri Derneği'nden alınan bilgiler doğrultusunda Türkiye'de satılan sıfır otomobil satış adetleri 2015 yılında 725.596, 2016 yılında 756.958, 2017 yılında 722.759, 2018 yılında 436.321, 2019 yılında 376.277 ve 2020 yılında 610.109'dur. Satış adetleri incelendiğinde ülkemizde 2016 yılından 2020 yılına kadar sıfır otomobil pazarında bir daralma olduğu görülmektedir. Bunun sebebi olarak ülkemize gelen otomobillerin ve otomobil parçalarının döviz kuruna bağlı olması söylenebilir. Halkın alım gücündeki azalma ve eş zamanlı olarak GSYİH'nin döviz kuru karşısındaki azalışı bu olayı desteklemiş, sıfır otomobil satışları düşmüştür. YSA'nın ürettiği 2019 tahmin değerlerinin gerçekleşmiş satış adetlerine kıyasla daha fazla

olmasının nedeninin bu olduğu düşünülmektedir. Yılın eylül, ekim ve kasım aylarında otomobil satışlarında düşüşler gözükmeyle birlikte aralık ayında diğer aylara oranla daha fazla otomobil satışı gerçekleşmiştir. Müşteriler, aralık ayındaki yıl sonu indiriminden yararlandığı için bir sonraki yılın ocak ayında otomobil satışlarına talep azalmaktadır. Yaz döneminin gelmesi ile insanların seyahat durumlarındaki artış otomobil pazarına olan talebi arttırmaktadır. Fakat YSA'nın ürettiği 2019 yılı haziran, temmuz ve ağustos ayı tahmin değerlerine bakıldığında gerçek değerlerden saptığı görülmektedir. 2019 yılında yüksek araç fiyatlarından ve vergilerden kaynaklı otomobil pazarının %30 daraldığı görülmektedir. Ağ tahminlemesi bu noktada bazı aylar için başarısız olmuştur. 2020 yılı için Holt Winters' tahmin verileri incelendiğinde mart, ağustos ve kasım aylarında yöntemin gerçek değerlere yakın değerler ürettiği gözlenirken; temmuz, eylül ve ekim aylarında tahmin değerlerinden oldukça saptığı görülmüştür. YSA'nın 2020 yılı için ürettiği çıktı değerleri incelendiğinde mayıs, haziran ve temmuz aylarının tahmin değerlerinde sapma olduğu görülse de yıl bazında incelendiğinde tahmin değerleri ve gerçek değerler arasında paralellik olduğu tespit edilmiştir. İki yöntem karşılaştırıldığında, YSA'nın eğitim, doğrulama ve test aşamaları düşünüldüğünde bilgiyi öğrenip tahmin edebilme özelliği ile Holt Winters' yöntemine göre daha başarılı olduğu görülmüştür. 2020 yılının mart ayında Covid-19 pandemisinin ülkemizde de görülmeye başlamasıyla insanların toplu taşıma kullanma konusundaki endişeleri artmış, binek araçlara yönelimlerinin olduğu gözlenmiştir. Üretici firmalar müşteri taleplerine cevap veremeyip müşterileri aylar sonrası için listeye almışlardır. Eğer üretici firmalar müşteri taleplerine yetişebilseydi muhtemelen 2020 yılı Türkiye otomobil pazarında daha çok otomobil satışı gerçekleşecekti ancak tüm bunlara rağmen 2020 yılında Türkiye otomobil pazarı %60 oranda büyümüştür. 2020 yılı tahmin sonuçlarındaki tutarsızlığın en önemli sebebinin küresel boyutta gerçekleşmiş pandemiden kaynaklı olarak insanların toplu taşıma yerine bireysel araçlara yönelmesi olduğu söylenebilir. Gelecek çalışmalarda, otomobiller segmentlere göre sınıflanabilir ve her segment için farklı değişkenler kullanılabilir, değişken sayısı artırılabilir, firma özelinde çalışılarak rekabet unsuru göz önüne alınabilir ve gri tahminleme gibi farklı tahmin teknikleri YSA ile karşılaştırılabilir.

KAYNAKÇA

- Abdellatif, M., Shaaban, E. M., & Abu-Raya, K. A. (2019, December). Egyptian Case Study-Sales forecasting model for automotive section. In 2019 International Conference on Smart Applications, Communications and Networking (SmartNets) (pp. 1-6). IEEE. Doi: [10.1109/SmartNets48225.2019.9069751](https://doi.org/10.1109/SmartNets48225.2019.9069751)
- Albayrak, Ş. G. (2018). Türkiye'de reel kesim güven endeksi ve imalat sanayi kapasite kullanım oranı arasındaki ilişki üzerine ampirik bir uygulama (2007-2017). *Akademi Sosyal Bilimler Dergisi*, 5(15), 18-27. Erişim Adresi: <https://dergipark.org.tr/en/pub/اسبider/issue/41362/500080>
- Alper, E., ve Mumcu, A. S. (2000). Türkiye'de Otomobil Talebinin Tahmini. *İstanbul: Boğaziçi Üniversitesi, Ekonomi Bölümü, Ekonomi ve Ekonometri Merkezi*. Erişim Adresi: <https://core.ac.uk/download/pdf/7362337.pdf>
- Akyurt, İ. (2015). Talep tahmininin yapay sinir ağlarıyla modellenmesi: yerli otomobil örneği. *Ekonometri ve İstatistik*, 23, 147-157. Erişim Adresi: <https://dergipark.org.tr/tr/download/article-file/411177>

- Arslankaya, S., & Öz, V. (2018). Time series analysis of sales quantity in an automotive company and estimation by Artificial Neural Networks. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(5), 1482-1492. Erişim adresi: <http://www.saujs.sakarya.edu.tr/en/download/article-file/536468>
- Asilkan, Ö., ve Irmak, S. (2009). İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Süleyman Demirel Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*. 14(2), 375-391. Erişim Adresi: <https://dergipark.org.tr/en/pub/sduiibfd/issue/20830/223124>
- Aslay F., ve Özen Ü. (2013). Meteorolojik parametreler kullanılarak yapay sinir ağları ile toprak sıcaklığının tahmini. *Politeknik Dergisi*, 16(4), 139-145. Erişim Adresi: <https://dergipark.org.tr/tr/pub/politeknik/issue/33068/367992>
- Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellenmesi. *Öneri Dergisi*, 10(39), 101-115. Doi: [10.14783/od.v10i39.1012000311](https://doi.org/10.14783/od.v10i39.1012000311)
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31. Doi: [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
- Birgili, E., ve Düzer, M. (2010). Finansal analizde kullanılan oranlar ve firma değeri ilişkisi: imkb’de bir uygulama. *Muhasebe ve Finansman Dergisi*, 46, 74-83. Erişim Adresi: <https://dergipark.org.tr/en/pub/mufad/issue/35625/395935>
- Büker, S., ve Çelikkol, H. (2019). Döviz kuru riski yönetim teknikleri ve sdş ortağı kobi’lerin bu tekniklerden yararlanabilme olanakları. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 59, 123-139. Erişim Adresi: <https://dergipark.org.tr/en/pub/dpusbe/issue/43067/486450>
- Büyükuysal, M. Ç., ve Öz, İ. İ. (2016). Çoklu doğrusal bağıntı varlığında en küçük karelere alternatif yaklaşım: Ridge regresyon. *Düzce Üniversitesi Sağlık Bilimleri Enstitüsü Dergisi*, 6(2), 110-114. Erişim Adresi: <https://dergipark.org.tr/tr/pub/duzcesbed/issue/24384/258502>
- Büyükcangaz, H., Değirmenci, H., ve Kartal, S. (2018). Bursa bölgesi sulama şebekelerinin istatistiksel yöntemlerle değerlendirilmesi. *Türk Tarım ve Doğa Bilimleri Dergisi*, 5(4), 501-508. Erişim Adresi: <https://dergipark.org.tr/en/pub/duzcesbed/issue/24384/258502>
- Chattopadhyay, R. & Guha, A. (2004) Artificial neural networks: applications to textiles, *Textile Progress*, 35(1), 1-46, Doi: 10.1080/00405160408688961
- Çelik, B. (2019). *Tüketici tercihlerinin yapay sinir ağları yöntemiyle tahmini: perakende sektöründe bir uygulama*. Doktora Tezi, Manisa Celal Bayar Üniversitesi, Manisa, TR. Erişim Adresi: <https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=mex0flfUXwRE2QTNTk1vRQ&no=oM0y GgOOpXGU k9x mRJ8g>
- Çınaroğlu E. ve Avcı T. (2020). THY hisse senedi değerinin yapay sinir ağları ile tahmini. *İktisadi ve İdari Bilimler Dergisi*, 34(1), 1-19. Doi: <https://doi.org/10.16951/atauniiibd.530322>
- Çuhadar, M., Güngör, İ., ve Göksu, A. (2009). Turizm talebinin yapay sinir ağları ile tahmini ve zaman serisi yöntemleri ile karşılaştırmalı analizi: Antalya iline yönelik bir uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 99-114. Erişim Adresi: <https://dergipark.org.tr/en/pub/sduiibfd/issue/20831/223138>
- Doğan, H., (2019). *Beklenmedik Uçak Yönlendirmelerini Azaltma: Zaman Serisi Analizi ve Yapay Sinir Ağları ile Modelleme*. Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi, Ankara, TR. Erişim Adresi: <http://earsiv.etu.edu.tr/handle/20.500.11851/3431>
- Drew, P. J., & Monson, J. R. (2000). Artificial neural networks. *Surgery*, 127(1), 3-11.
- Efendigil, T. (2008). *Müşteri odaklı sistemler için yapay sinir ağı ve bulanık çıkarım tabanlı bir karar destek sistemi yaklaşımı*. Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul. Erişim Adresi: <http://dspace.yildiz.edu.tr/xmlui/handle/1/1480>
- Ekici, B. B., & Aksoy, U. T. (2009). Prediction of building energy consumption by using artificial neural networks. *Advances in Engineering Software*, 40(5), 356-362. Doi: <https://doi.org/10.1016/j.advengsoft.2008.05.003>
- Ekonomou, L. (2010). Greek long-term energy consumption prediction using artificial neural networks. *Energy*, 35(2), 512-517. Doi: <https://doi.org/10.1016/j.energy.2009.10.018>

- Erenler, A. (2019). *KNN ve yapay sinir ağları kullanarak sistem etkinliği ve kalite kaybı tahmini*. Yüksek Lisans Tezi, Çukurova Üniversitesi, Adana, TR. Erişim Adresi: https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=MZ_hN7i67FBLoOP0NkvndQ&no=SohXeIfll8WrZ02nRjJa1A
- Erdoğan, E. ve Özyürek, H. (2012). Yapay sinir ağları ile fiyat tahminlemesi. *Sosyal ve Beşeri Bilimler Dergisi*, 4(1), 85-92. Erişim Adresi: <https://dergipark.org.tr/en/download/article-file/117281>
- Ersoy, E., ve Karal, Ö. (2012). Yapay sinir ağları ve insan beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188-205. Erişim Adresi: <http://www.itobiad.com/tr/download/article-file/92756>
- Gültekin, M. (2015). Ham petrol fiyatlarındaki oynaklık ile gayri safi yurt içi hasıla arasındaki ilişki: türkiye uygulaması 1970-2013. Yüksek Lisans Tezi, Nevşehir Hacı Bektaş Veli Üniversitesi, Nevşehir, TR. Erişim Adresi: http://acikerisim.nevsehir.edu.tr/bitstream/handle/20.500.11787/242/meryem_gultekin_tez.pdf?sequence=1&isAlloWed=y
- Hakimpoor, H., Arshad, K. A. B., Tat, H. H., Khani, N., & Rahmandoust, M. (2011). Artificial neural networks' applications in management. *World Applied Sciences Journal*, 14(7), 1008-1019. Erişim adresi: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.389.6419&rep=rep1&type=pdf>
- Huber, J., & Stuckenschmidt, H. (2020). Daily retail demand forecasting using machine learning with emphasis on calendric special days. *International Journal of Forecasting*, 36(4), 1420-1438. Doi: <https://doi.org/10.1016/j.ijforecast.2020.02.005>
- Kaya, H. (2008). Kamu ve özel sektör kuruluşlarının örgütsel kültürünün analizi ve kurum kültürünün çalışanların örgütsel bağlılığına etkisi: görgül bir araştırma. *Maliye Dergisi*, 155, 119,143. Erişim Adresi: https://ms.hmb.gov.tr/uploads/2019/09/08.Harun_KAYA_.pdf
- Ketrez, Ö., ve Saldanlı, A., (2018). Yapay sinir ağları yöntemi ile petrol fiyatları tahmini. *Kırklareli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(3), 91-106, Erişim Adresi: <https://dergipark.org.tr/en/pub/klujfeas/issue/39222/446784>.
- Kubat M. (2021) Artificial Neural Networks. In: An Introduction to Machine Learning. Springer, Cham. https://doi.org/10.1007/978-3-030-81935-4_6
- Kuvvetli, Y., Dağsuyu, C. ve Oturakçı, M. (2015). Türkiye'deki araç satışları için ekonomik ve çevresel faktörleri göz önüne alan yapay sinir ağı tabanlı bir tahmin yaklaşımı. *Endüstri Mühendisliği*, 26(3), 23-31, Erişim Adresi: <https://dergipark.org.tr/en/pub/endustrimuhendisligi/issue/46767/586076>
- Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworth-Heinemann.
- Otomobil Distribütörleri Derneği. (2020). *2015-2019 Yılları Otomobil Satış Adetleri* [Çevrim-içi: http://www.odd.org.tr/web_2837_1/neuralnetwork.aspx?type=36], Erişim tarihi: 30.8.2021
- Otomobil Distribütörleri Derneği. (2020). *Özet Değerlendirme – 2019/2020*. [Çevrim-içi: <http://www.osd.org.tr/sites/1/upload/files/2020-06 OSD Ozet Rapor-5502.pdf>], Erişim tarihi: 30.8.2021
- Otomobil Distribütörleri Derneği. (2020). *Pazar-Perakende Satışlar*. [Çevrim-içi: http://www.odd.org.tr/web_2837_1/neuralnetwork.aspx?type=36], Erişim tarihi: 30.8.2021
- Özer, M., Ayhan, U. ve İrdem, İ. (2017). Avrupa Birliği'nin akdeniz politikası ve bölgesel güvenlik. *Güvenlik Çalışmaları Dergisi*, 19(3), 165-184. Erişim Adresi: <https://dergipark.org.tr/en/pub/gcd/issue/53129/704278>
- Özdemir, G. Z. (2013). *Tüketici güveninin tüketim harcamaları ile ilişkisi ve öngörü gücü: türkiye örneği*. Uzmanlık Yeterlilik Tezi, Türkiye Cumhuriyet Merkez Bankası İletişim ve Dış İlişkiler Genel Müdürlüğü, Ankara, TR. Erişim Adresi: <http://www3.tcmb.gov.tr/kutuphane/TURKCE/tezler/goncaozdemir.pdf>
- Pençe, İ., Kalkan, A., ve Şişeci Çeşmeli, M. (2019). Türkiye sanayi elektrik enerjisi tüketiminin 2017-2023 dönemi için yapay sinir ağları ile tahmini. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 3(2), 206-228. Doi: <https://doi.org/10.31200/makuubd.538878>

- Pirdashti, M., Curteanu, S., Kamangar, M. H., Hassim, M. H., & Khatami, M. A. (2013). Artificial neural networks: applications in chemical engineering. *Reviews in Chemical Engineering*, 29(4), 205-239. Doi: <https://doi.org/10.1515/revce-2013-0013>
- Salari, M., Shahid, E. S., Afzali, S. H., Ehteshami, M., Conti, G. O., Derakhshan, Z., & Sheibani, S. N. (2018). Quality assessment and artificial neural networks modeling for characterization of chemical and physical parameters of potable water. *Food and Chemical Toxicology*, 118, 212-219. Doi: <https://doi.org/10.1016/j.fct.2018.04.036>
- Sa-Ngasoongsong, A., Bukkapatnam, S. T., Kim, J., Iyer, P. S., & Suresh, R. P. (2012). Multi-step sales forecasting in automotive industry based on structural relationship identification. *International Journal of Production Economics*, 140(2), 875-887. Doi: <https://doi.org/10.1016/j.ijpe.2012.07.009>
- Susanto, S., Tanaya, P. I., & Soembagijo, A. S. (2012, August). Formulating standard product lead time at a textile factory using artificial neural networks. 2nd International Conference on Uncertainty Reasoning and Knowledge Engineering (pp. 99-104). IEEE.
- Vahabi, A., Hosseininia, S. S., & Alborzi, M. (2016). A sales forecasting model in automotive industry using Adaptive Neuro-Fuzzy Inference System (ANFIS) and Genetic Algorithm (GA). *International Journal of Advanced Computer Science and Application*, 7(11), 24-30. Erişim adresi: <https://pdfs.semanticscholar.org/9920/c6f7a9d89f88f09c2a2f1da00d1ef496ceceb.pdf>
- Vaishya, R., Javaid, M., Khan, I. H., & Haleem, A. (2020). Artificial Intelligence (AI) applications for COVID-19 pandemic. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, 14(4), 337-339. Doi: <https://doi.org/10.1016/j.dsx.2020.04.012>
- Van Gerven, M., & Bohte, S. (2017). Artificial neural networks as models of neural information processing. *Frontiers in Computational Neuroscience*, 11, 114. Doi: <https://doi.org/10.3389/fncom.2017.00114>
- Vural, D., Küçükaşçı, E. ve Ayvaz, B. (2019). Türkiye’de perakende sektöründe elektronik ürünlere olan talebin yapay sinir ağı ile modellenmesi, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 18(35), 1-16. Erişim Adresi: <https://dergipark.org.tr/en/pub/ticaretfbd/issue/55970/509724>
- Yang, G. R., & Wang, X. J. (2020). Artificial neural networks for neuroscientists: A primer. *Neuron*, 107(6), 1048-1070. Doi: <https://doi.org/10.1016/j.neuron.2020.09.005>
- Yaşar, M. (2004). *Günlük akışlardaki boşlukların yapay sinir ağları kullanılarak tamamlanması*. Yüksek Lisans Tezi, Pamukkale Üniversitesi, Denizli, TR. Erişim Adresi: <http://acikerisim.pau.edu.tr/xmlui/handle/11499/1220>
- T.C. Bilim Sanayi ve Teknoloji Bakanlığı. (2013). *Faaliyet Raporu*. [Çevrim-içi:<https://www.sanayi.gov.tr/plan-program-raporlar-ve-yayinlar/faaliyet-raporlari/mu1607011625>], Erişim tarihi: 30.8.2021.
- Türkiye Cumhuriyeti Merkez Bankası. (2021). *2019 ve 2020 Yılları Döviz Kuru Değerleri*. [Çevrim-içi: https://www.tcmb.gov.tr/kurlar/kurlar_tr.html]. Erişim tarihi: 30.10.2021.
- Türkiye İstatistik Kurumu. (2021). *2019 ve 2020 Yılları GSYİH Değerleri*. [Çevrim-içi: <https://data.tuik.gov.tr/Bulten/Index?p=Quarterly-Gross-Domestic-Product-Quarter-I:-January-March,-2021-37181>]. Erişim tarihi: 3.11.21.
- Türkiye İstatistik Kurumu. (2021). *2019 ve 2020 Yılları Reel Kesim Güven Endeksi Değerleri*. [Çevrim-içi: <https://data.tuik.gov.tr/Search/Search?text=reel%20kesim%20g%C3%BCven%20endeksi>]. Erişim tarihi: 3.11.21.
- Türkiye İstatistik Kurumu. (2021). *2019 ve 2020 Yılları Tüketici Güven Endeksi Değerleri*. [Çevrim-içi: <https://data.tuik.gov.tr/Search/Search?text=reel%20kesim%20g%C3%BCven%20endeksi>]. Erişim tarihi: 3.11.21.
- Tüzemen, A. (2020). Cumhuriyet altını fiyatlarının arıma yöntemi kullanılarak ileri tahmini. *Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü Sosyal Bilimler Dergisi*, 10(20), 361-381. Erişim Adresi: <https://dergipark.org.tr/tr/pub/sbed/issue/59236/757262>

KATKI ORANI / CONTRIBUTION RATE	AÇIKLAMA / EXPLANATION	KATKIDA BULUNANLAR / CONTRIBUTORS*
Fikir veya Kavram / Idea or Notion	Araştırma hipotezini veya fikrini oluşturmak / Form the research hypothesis or idea	Gökçe HAN Eyüp Fırat SÖNMEZ Selen AVCI Zerrin ALADAĞ
Tasarım / Design	Yöntemi, ölçeği ve deseni tasarlamak / Designing method, scale and pattern	Gökçe HAN Eyüp Fırat SÖNMEZ Selen AVCI Zerrin ALADAĞ
Veri Toplama ve İşleme / Data Collecting and Processing	Verileri toplamak, düzenlenmek ve raporlamak / Collecting, organizing and reporting data	Gökçe HAN Eyüp Fırat SÖNMEZ Selen AVCI Zerrin ALADAĞ
Tartışma ve Yorum / Discussion and Interpretation	Bulguların değerlendirilmesinde ve sonuçlandırılmasında sorumluluk almak / Taking responsibility in evaluating and finalizing the findings	Gökçe HAN Eyüp Fırat SÖNMEZ Selen AVCI Zerrin ALADAĞ
Literatür Taraması / Literature Review	Çalışma için gerekli literatürü taramak / Review the literature required for the study	Gökçe HAN Eyüp Fırat SÖNMEZ Arş.Gör. Selen AVCI Prof.Dr. Zerrin ALADAĞ

*Katkı oranlarının tümü eşit olması durumunda oranlar belirtilmeyecektir/ If the contribution rates are all equal, the rates will not be specified

Hakem Değerlendirmesi: Dış bağımsız.

Çıkar Çatışması: Yazar çıkar çatışması bildirmemiştir.

Finansal Destek: Yazar bu çalışma için finansal destek almadığını beyan etmiştir.

Teşekkür: -

Peer-review: Externally peer-reviewed.

Conflict of Interest: The author has no conflict of interest to declare.

Grant Support: The author declared that this study has received no financial support.

Acknowledgement: -