

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ: TÜRKİYE'DEKİ OTOMOBİL SEKTÖRÜNDE BİR UYGULAMA*

Mehmet Zeki SEÇMEN¹

Sait PATIR²

Öz

Bu çalışmada, yapay sinir ağları kullanarak yeni bir tahmin modeli geliştirilmiştir. Çalışmada, Türkiye'de otomobil üretip en çok otomobil satan 6 firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) 2014-2024 yılları arasındaki aylık satış verileri kullanılarak Çoklu Regresyon Analizi, NARX modeli ve yapay sinir ağı modeli ile satış tahmini yapılmıştır. Tahmin modellerinin geliştirilmesinde otomobil talebi üzerine etkisi olduğu düşünülen bağımsız değişkenler Brent Petrol Fiyatı, Dolar Kuru, Taşıt Kredi Faizleri, TÜFE, Araç Alım Düzeyi, Otomobil Üretim Âdeti, bağımlı değişken ise yani çıktı değeri 6 firmanın toplam otomobil satış âdeti olarak belirlenmiştir. Önerilen modelin, test seviyesindeki performansı MSE=0.021, MAPE=% 11.66'dir. Bu sonuçlar karşılaştırılan diğer iki modelden otomobil satış talebini tahmin etmede diğerlerinden daha güçlü olduğunu göstermektedir. Önerilen modelin eğitim ve test aşamasından sonra Ocak 2024 ile Aralık 2024 arasındaki 12 aylık otomobil talep tahmini yapılmıştır.

Anahtar Kelimeler: Yapay Zekâ, Yapay Sinir Ağları, Otomobil Talep Tahmini

Jel Kodları : C40, C45, C51

DEMAND FORECASTING WITH ARTIFICIAL NEURAL NETWORKS: AN APPLICATION IN THE AUTOMOBILE INDUSTRY IN TURKEY

Abstract

In this study, a new prediction model was developed using artificial neural networks. In the study, sales prediction was made with Multiple Regression Analysis, NARX model and artificial neural network model, using the monthly sales data of the 6 companies (OYAK Renault, Tofaş, Toyota, Ford, Honda and Hyundai) that produce

* "Bu çalışma YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ: TÜRKİYE'DEKİ OTOMOBİL SEKTÖRÜNDE BİR UYGULAMA isimli doktora tezinden üretilmiştir".

¹ Sorumlu yazar Bilgisayar İşletmeni, Bingöl Gençlik ve Spor İl Müdürlüğü, E-posta: m.zeki12@hotmail.com, [ORCID: 0000-0002-7664-4916](https://orcid.org/0000-0002-7664-4916)

² Prof. Dr., Bingöl Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, E-posta: spatir@bingol.edu.tr, [ORCID: 0000-0002-1592-1094](https://orcid.org/0000-0002-1592-1094)

Atf: Seçmen, M.Z., & Patır, S. (2024). Yapay sinir ağları ile talep tahmini: türkiye'deki otomobil sektöründe bir uygulama, *Van Yüzüncü Yıl Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 9(18), 148-169.

DOI: 10.54831/vanyuiibfd.1485384

and sell the most automobiles in Turkey between 2014 and 2024. In the development of forecast models, the independent variables that are thought to have an impact on automobile demand were determined as Brent Oil Price, Dollar Exchange Rate, Vehicle Loan Interest Rates, CPI, Vehicle Purchase Level, Number of Automobile Production, and the dependent variable, that is, the output value, was determined as the total number of automobile sales of 6 companies. The performance of the proposed model at the test level is $MSE = 0.021$, $MAPE = \% 11.66$. These results show that it is more powerful in predicting automobile sales demand than the other two compared models. After the training and testing phase of the proposed model, 12-month automobile demand forecast between January 2024 and December 2024 was made.

Keywords: Artificial Intelligence, Artificial Neural Networks, Automobile Demand Forecasting

Jel Classification : C40,C45,C51

GİRİŞ

Bir otomobil firmasının gelecekteki ihtiyaçları karşılayacak tesislerini ve altyapısını planlamak için, otomobil talebinin düzeyini tahmin etmek önemlidir. İşletmeler gelecekteki belirsizlikler fazla olduğundan ihtiyaç duyacakları talebi zamanında hazırlama gereksinimi duyarlar. Piyasayı gerçek anlamda çözümleyen ve talep tahminini gerçeğe yakın önemsiz hatayla tahmin eden işletmeler, yarışın arttığı ve ürün ömürlerinin azaldığı günümüz şartlarında, faaliyetlerini en iyi şekilde dizayn etme imkânına ulaşacaklardır. İşletmelerin gelecekte her seviyede alacakları idari kararlar, yaptıkları tahminle de ilgilidir (Yücesoy, 2011). İşletmelerin gelecekte daha kesin ve daha az hatayla tahminde bulunma ihtiyacı, rekabet ortamında gerçekleşen dolu dizgin değişimlerle artış göstermektedir. İşletmelerin bu ihtiyacını hedef ve süre etkenine göre giderecek değişik talep tahmin yöntemleri bulunmaktadır. Talep tahmininde kullanılan yöntemler esas olarak “nitel yöntemler” ve “nicel yöntemler” olmak üzere ikiye ayrılır (Eski, 2006). Nitel yöntemler, çoğunlukla kişisel deneyimlere, uzman görüşlere ve çözümlenmelere dayanır. Nicel yöntemler ise, sonuç çıkarmak için verileri yöntemli bir biçimde sayı olarak belirtme ve kuşkulardan uzak verilere dayanan yöntemlerdir. Pratikte, işletmeler genellikle bu iki yöntemi bir arada kullanır ve karma bir tahminleme yaklaşımı benimserler (Heizer ve Render, 2004).

Son zamanlarda yapay zekâ tabanlı yöntemlerin gelişmesiyle, klasik tahmin yöntemlerine kıyasla daha gerçekçi tahminler yapılabildiği gözlemlenmektedir. Özellikle yapay sinir ağları, tahminleme alanında sıkça kullanılan bir yapay zekâ yöntemidir. Yapay sinir ağları, istatistiksel verileri kullanarak nicel yöntemlerle benzer şekilde tahmin yapabilirken, aynı zamanda faktörler arasındaki ilişkileri ve derecelerini öğrenme yeteneğiyle nitel yöntemlere benzerlik gösterir. Bu nedenle, yapay sinir ağları son zamanlarda talep tahmini için etkin bir yöntem olarak öne çıkmaktadır (Sarı, 2006).

Talep tahminine başlamadan önce işletmenin mevcut durumu, hangi ürünleri ürettiği, hangi çevre ortamında yer aldığı, rekabet ettiği işletmelerdeki konumu, gelecekte olmak istediği yer, fiyat ve talep ilişkisi, ekonomik değişimler, endüstriyel değişimler, teknolojik ilerlemeler, sosyal değişimler, ulusal ve uluslararası yönelimler gibi talebi etkileyen etkenler tespit edilmelidir (Bolt, 1994). Kesin ve doğru

bir şekilde tahmin yapmak, işletmelerin hammadde tedarikini ve lojistik süreçlerini optimize etmelerine yardımcı olabilir. Doğru tahminler, işletmelerin ihtiyaç duydukları hammaddeleri doğru zamanda ve miktarda temin etmelerini sağlayarak maliyetlerini azaltabilir. Ayrıca, taşıma birimleri için uzun vadeli anlaşmalar yaparak maliyetlerini düşürebilirler. Ancak, bu tür anlaşmaların gerçekleştirilmesi, talebin doğru bir şekilde kestirilebilmesine bağlıdır. İyi bir tahmin aynı zamanda işletmenin stok düzeyini belirlemede de önemli bir rol oynar. Eğer tahminler doğru yapılmışsa, işletmeler gereksiz stok birikimlerinden kaçınarak maliyetlerini düşürebilirler. Ayrıca, tahminin doğruluğu beklenen seviyede değilse, işletmeler güvenlik stokları oluşturarak operasyonlarını sürdürebilirler. Bu, ani talep artışları veya tedarik zinciri kesintileri gibi beklenmedik durumlara karşı hazırlıklı olmalarını sağlar. (Moon vd., 2003).

Talep tahmini işletmeler için oldukça kritik bir konudur. Doğru talep tahmini, işletmelerin ihtiyaç duyacakları hammadde miktarının doğru bir şekilde planlanmasına olanak sağlar. Bu sayede gereksiz stoklar oluşması ya da hammadde kıtlığı yaşanması önlenir. İşletmeler, ellerinde bulundurmaları gereken stok miktarını belirleyebilir. Fazla stok tutmak maliyetleri artırırken, yetersiz stok da müşteri taleplerinin karşılanamamasına neden olur. Doğru talep tahmini, işletmelerin finansal ihtiyaçlarını daha iyi planlamasına yardımcı olur. Böylece gereksiz borçlanma ya da likidite sıkıntısı yaşanması önlenir. Beklenen talebe göre, işletmeler gerekli personel sayısını ve niteliğini önceden belirleyebilir. Bu da işgücü planlamasına ve maliyetlerin kontrol altında tutulmasına katkı sağlar. Talep tahmini, yeni yatırım kararlarının alınmasında da önemli rol oynar. İşletmeler, gelecekteki talebi doğru tahmin ederek, doğru yer ve zamanda yatırım yapabilirler. Talep tahmini, işletmelerin müşteri ihtiyaçlarını daha iyi anlamasına ve yeni ürün/hizmet geliştirme süreçlerini daha etkili yönetmesine yardımcı olur (Brown vd., 2005).

Günümüzde teknoloji alanında yaşanan hızlı değişim ve inovasyon, yapay zekânın toplum içerisindeki öneminin giderek artmasına neden olmaktadır. Forbes'in 2018 yılı sonunda yayınladığı rapora göre, işletmelerin %44'ü tekrar eden işleri yapay zekâyâ devrederek bilgi işçilerini güçlendirme çabası içindedir. İrlandalı ünlü yönetim danışmanlık şirketi Accenture, yapay zekâ uygulamalarını ilk kez faaliyetlerinde kullanma kararı alan organizasyonların, yapay zekâ ve insan-makine işbirliği stratejilerini benimseyerek, 2019–2022 yılları arasında gelirlerini %38'e kadar, istihdamlarını ise %10'a kadar artırmabileceklerini vurgulamaktadır. Bu bilgiler ışığında, yapay zekâ çağında işletmelerin başarısının insanların ve makinelerin işbirliğine bağlı hale geldiğini söyleyebiliriz. Yapay zekâ kullanan işletmelerde, kendini yöneten ekiplerin ortaya çıkması, dağıtılmış sorumluluk ve yerinden örgütsel yapıların iş akışlarını mekândan bağımsız hale getirmesi gibi yeni olanaklar sunulmaktadır. Yapay zekânın işletmelerde henüz yüksek seviyelerde kullanılmamasına rağmen, karar verme süreçlerinde isabetli ve güvenilir tahminlerde bulunma yeteneği, işletmeler için oldukça ilgi çekicidir. Yeni teknolojiler, çeşitli sektörlerde, yakın zamana kadar farkında bile olmadıkları değişkenlerin etkisinde

kalacaklarının habercisidir. Verimliliğin teknolojik gelişmeler sayesinde, toplum ve birey bütünleşmesi ile artacağını vurgulamaktadır (Arslan, 2019).

Bu çalışmanın temel amacı, Türkiye'de otomobil üretip en çok otomobil satan 6 firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) 2014-2024 yılları arasındaki aylık satış verileri kullanılarak yapay sinir ağı modeli ile Ocak 2024 ile Aralık 2024 arasındaki 12 aylık talep tahmini yapmaktır.

Çalışmada, Türkiye'deki otomobil satış miktarı, Çoklu Regresyon Analizi, NARX modeli ve YSA (Yapay Sinir Ağları) tahmin modelleriyle yapılarak YSA modelinin talep tahmininde diğer iki yöntemden daha başarılı olduğu gösterilmeye çalışılmıştır.

1. YAPAY ZEKÂ

Yapay zekâ, bilgisayarların hesaplama ve problem çözme yeteneklerini insan benzeri şekilde uygulayan ve insanın bilişsel yeteneklerini taklit eden bir bilim dalıdır. Bu teknoloji, insanların düşünme, algılama, yorumlama ve karar verme gibi yeteneklerini modelleyen bir dizi algoritmayı içerir. Bu sayede, yapay zekâ sistemleri karmaşık verileri işleyebilir, örüntüleri tanımlayabilir ve kararlar alabilir (Sagiroglu vd., 2003).

İşletmeler, rekabetin arttığı ve globalleşen dünyada müşterilere kaliteli ürünleri düşük maliyetlerle sunarak daha fazla kazanç elde etme amacıyla çalışmaktadır. Bu süreçte, yapay zekâ gibi teknolojilerin önemi giderek artmaktadır. İnsan beyninin çalışma sistemi üzerine yapılan araştırmalar, yapay zekâ kavramının doğuşuna yol açmıştır. Yapay zekâ, insan benzeri düşünme yeteneklerini taklit ederek, büyük veri setlerini analiz edebilme, örüntüleri tanımlama ve hızlı kararlar alma gibi yetenekler sağlar. Yapay zekâ teknolojisi, büyük veri setlerini hızlı bir şekilde analiz ederek örüntüleri tanımlayabilir ve insanlardan daha hızlı ve doğru sonuçlar üretebilir. Bu, işletmelerin müşteri hizmetlerini iyileştirmesine yardımcı olurken aynı zamanda zamandan da tasarruf sağlar. Yapay zekâ, bilgisayarların insan benzeri bilişsel yeteneklerini taklit eden ve problem çözme kabiliyetini mekanik olarak uygulayan bir bilim dalıdır. Bu teknoloji sayesinde işletmeler, karmaşık veri setlerini daha etkili bir şekilde analiz edebilir, trendleri belirleyebilir ve stratejik kararlar alabilirler. Sonuç olarak, yapay zekâ, işletmelerin verimliliğini artırırken rekabet avantajı elde etmelerine de yardımcı olur (Kesici ve Yıldız, 2016).

2. YAPAY SİNİR AĞLARI

1943 yılında sinir hekimi Warren McCulloch ve matematikçi Walter Pitts tarafından yayımlanan "Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap" adlı makale ile ortaya çıkarılmıştır. Bu çalışma, biyolojik nöronların çalışma prensiplerine dayanan ve onların davranışlarını matematiksel olarak modelleyen ilk girişimdir. McCulloch ve Pitts, bu makalelerinde, nöronların birbirlerine bağlanma şekilleriyle karmaşık mantıksal işlemleri gerçekleştirebileceğini ve bu sayede bilişsel

işlevlerin modellenebileceğini göstermişlerdir. Bu model, yapay sinir ağlarının temelini oluşturmuş ve ilerleyen yıllarda bu alanda yapılan çalışmalar için önemli bir referans noktası olmuştur (Öztürk ve Şahin, 2018).

Yapay sinir ağları, büyük veri setleri üzerinde etkili ve karmaşık problemleri çözmeye başarılı bir şekilde kullanılmaktadır. Gelişmiş donanım ve yazılım teknolojileri sayesinde yapay sinir ağları, ses tanıma, görüntü işleme, oyun stratejileri ve diğer alanlarda önemli başarılar elde etmektedir. (Pirim, 2006)

Yapay sinir ağları, insan beynindeki sinir ağlarını taklit eden bilgisayar programlarıdır. Bu sistemler, paralel bilgi işleme sistemleri olarak düşünülebilir. Yapay sinir ağları, ilgili olaya ait örnekler üzerinde eğitilerek çalışır. Bu eğitim süreci, örneklerden elde edilen bilgilerle çeşitli genelleştirmeler yapmayı ve daha önce karşılaşılmamış ya da belirli özellikleri tanımlanmamış olaylara çözümler üretmeyi mümkün kılar (Elmas, 2018).

Yapay sinir ağları, insan beynine özgü özellikleri taklit ederek yeni bilgileri oluşturma, keşfetme ve öğrenme gibi yetenekleri otomatik olarak gerçekleştirmeyi amaçlayan bilgisayar sistemleridir (Öztemel, 2006, s. 29).

Yapay Sinir Ağları, talep tahmininde giderek daha fazla popülerlik kazanıyor. Bu teknoloji, sayısal verilerle hesaplama yapma, bilgi depolama, verilen örneklerden problem öğrenme, geçmiş verileri kullanarak tahmin yapma ve önceki deneyimlerden öğrendiklerini yeni durumlara uygulama gibi özelliklere sahiptir. Yapay sinir ağları, geniş bir uygulama yelpazesine sahip çok yönlü bir teknolojidir. Finans, mühendislik, tıp ve üretim gibi birçok alanda kullanılabilirler. Yapay sinir ağları, sınıflandırma, tahmin, veri yorumlama ve veri süzme gibi çeşitli problemlere uygulanabilir. Bu esneklik, yapay sinir ağlarının geniş bir kullanım alanına sahip olmasını sağlar ve birçok endüstride fayda sağlayabilir (Yılmaz, 2019). Bu sistemlerin en önemli avantajı, karmaşık veri birimlerini öğrenmek için gelişmiş hesaplama ve eğitim tekniklerinden yararlanmalarındır. Yapay sinir ağları, geçmiş verilerden öğrenerek sorunları tanımlar ve matematiksel algoritmalar oluşturarak gelecekle ilgili tahminlerde bulunabilirler. (Hu, 2002, s.74).

Son yıllarda YSA ile yapılan çalışmalara bakıldığında Değirmenci ve Papuçcu (2016) Türkiye'ye ait 5 yıllık günlük olarak alınmış CDS primlerini, aynı döneme ait menkul kıymet borsa endeksi kapanış değeri ile karşılaştırmışlardır. Çalışmada NARX modelini güçlü bir tahmin modeli olarak belirlemişlerdir.

Karaatlı, Demirci ve Baykaldı (2021) özel sektör yatırım kararları üzerinde belirleyici bir etkisi olan ticari kredi faiz oranlarının YSA NARX ve VAR modeli ile yapılan öngörü çalışmasının performansını karşılaştırmışlardır. YSA NARX modelinin VAR modeline göre oldukça iyi sonuçlar verdiğini bulmuşlardır.

Yıldırım ve Karaatlı (2022) YSA NARX modeli ile 2019, 2020 ve 2021 yıllarına ait elma üretim miktarlarını tahmin ederek YSA NARX Modelinin elma üretim miktarı öngörüsünde kullanılabileceği göstermişlerdir.


Ünal (2024) NARX YSA modeli ile Safranbolu turist sayı analizinde NARX YSA modelinin yüksek ve etkili bir performans gösterdiğini saptamıştır.

2.1. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları, insan beynindeki sinir hücrelerinin işleyişine benzer bir şekilde çalışır. Günlük hayatta algılanması gereken bir olay, sinir hücrelerine sinyal olarak iletilir. Sinir hücreleri bu sinyalleri işleyerek bir eylem gerçekleştirirler. Yapay Sinir Ağları, bu sinir hücrelerinin işleyişini taklit ederek öğrenmeyi gerçekleştirir ve veriler arasındaki ilişkileri ortaya çıkarır (Öztemel, 2006).

Yapay Sinir Ağları, dışarıdan aldığı verileri işleyerek öğrenme sürecini gerçekleştirir ve bu veriler arasındaki ilişkileri belirlemek için öğrendiği bilgileri hafızada tutar. Aşağıdaki Şekil 1'de Yapay Sinir Ağı hücresinin yapısı gösterilmiştir. Yapay Sinir Ağı hücresi, girdi verilerini toplar ve bir aktivasyon fonksiyonu kullanarak çıktı üretir. Bu çıktı, dış dünyaya sunulabileceği gibi başka bir sinir hücresine girdi olarak da kullanılabilir (Aktaş vd., 2003).

Şekil 1. Yapay Sinir Hücresinin Yapısı (Fırat ve Güngör, 2004)



Yapay Sinir Ağı hücresi yapısı biyolojik sinir ağlarının hücre yapısına benzer şekilde beş elemandan oluşmaktadır. Bunlar yukarıda Şekil 1'de görüldüğü gibi girdiler, ağırlıklar, toplama fonksiyonu (birleştirme fonksiyonu), aktivasyon fonksiyonu ve çıkışlardır.

2.2. Yapay Sinir Ağlarının Performans Ölçütlerinin Belirlenmesi

Yapay Sinir Ağı modellerinin performansını ölçmek için farklı kriterler bulunmasına rağmen, en önemli performans ölçütü genellikle ağı eğitim sonrası tahmin doğruluğudur. Gerçek değerlerle modelden elde edilen değerler arasındaki fark, hata olarak kabul edilir ve bu hata değeri ne kadar küçükse, model o kadar tercih edilir. (Huang ve Shih, 2003; Al-Hamadi ve Soliman, 2004; Hamzaçebi, 2011) Çok kullanılan doğruluk ölçütleri aşağıda Tablo 1'de gösterilmektedir.

Tablo 1. Yapay Sinir Ağı Performans Ölçütleri (Zhang vd., 1998)

Performans Ölçütü	Matematiksel İfadesi
Ortalama Mutlak Sapma (The Mean Absolute Deviation- MAD)	$Y_t =$ Gerçek Değer $F_t =$ Elde Edilen Çıktı Değeri olmak üzere, $MAD = \frac{1}{n} \sum_{t=1}^n Y_t - F_t $
Hata Kareler Ortalaması (Mean Squared Error-MSE)	$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2$
Hata Kareler Toplamı (Sum Squared Error-SSE)	$SSE = \sum_{t=1}^n (Y_t - F_t)^2$
Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE)	$RMSE = \sqrt{MSE}$
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE)	$MAPE = \frac{1}{n} \sum_{t=1}^n \left \frac{Y_t - F_t}{Y_t} \right \times 100$

MSE, ortalama kare hatası anlamına gelir ve tahmin modellerinin doğruluğunu değerlendirmek için yaygın olarak kullanılan bir ölçüttür. MSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasını alarak hesaplanır. MSE, ve RMSE birer hata ölçüsü olması nedeniyle düşük sonuçlar, yüksek performansı gösteren ölçülerdir (Wang ve Xu, 2004).

Ortalama Mutlak Sapma (MAD): Modelin tahminlerinin gerçek değerlerden ortalama olarak ne kadar sapma gösterdiğini ölçer.

Hata Kareler Ortalaması (MSE): Modelin tahminlerinin gerçek değerlerden sapmalarının karelerinin ortalama değeridir. Bu değer ne kadar düşükse, modelin tahminlerinin gerçek değerlere ne kadar yakın olduğunu gösterir.

Hata Kareler Toplamı (SSE): Modelin tahminlerinin gerçek değerlerden sapmalarının karelerinin toplamıdır. Bu da modelin ne kadar iyi uyum sağladığını ölçer. Daha düşük bir SSE, modelin daha iyi uyum sağladığı anlamına gelir.

Kök Ortalama Kare Hata (RMSE): MSE'nin kareköküdür. Gerçek değerler ile tahmin edilen değerler arasındaki ortalama sapmanın bir ölçüsüdür.

Ortalama Mutlak Hata Yüzdesi (MAPE): Modelin tahminlerinin gerçek değerlerden ortalama olarak yüzde kaç oranında sapma gösterdiğini ölçer.

Düşük MAD, MSE, SSE, RMSE ve MAPE değerleri, modelin daha iyi performans gösterdiğini gösterir. Ancak, bu ölçütlerin tek başına değerlendirilmesi yerine, birlikte değerlendirilmesi tavsiye edilir.

3. UYGULAMA

Türkiye'de otomobil üretip en çok satışı yapan 6 firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) 01.01.2014-31.12.2023 yılları arasındaki 120 aylık satış verisinden Octave Programı ile ÇRA (Çoklu Regresyon Analizi), NARX ve YSA Modeliyle tahmin gerçekleştirilmiş ve performansları karşılaştırılmıştır.

3.1. Veri Setinin Hazırlanması

Uygulamada kullanılmak üzere seçilen ve otomobil talebi üzerinde etkisi olduğu düşünülen bağımsız değişkenler şunlardır:

- Brent Petrol Fiyatı
- Dolar/TL Kuru
- Taşıt Kredi Faiz Oranları
- TÜFE
- Araç Satın Alım Düzeyi
- Otomobil Üretim Adeti (Türkiye'de otomobil üretip en çok satışı yapan 6 firmanın OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai)

Uygulamanın bağımlı değişkeni, yani hedeflenen değer ise Türkiye'de en çok otomobil üretimi yapan 6 firmanın,

- Toplam Otomobil Satış Adeti olarak belirlenmiştir.

Otomobil satışını etkileyen faktörlerin belirlenmesi aşamasında Sanayi ve Teknoloji Bakanlığının yıllık yayınlamış olduğu Otomotiv Sektör Raporlarına başvurulmuştur (ODMD, 2023). Uygulamada kullanılan bu verilerin tamamı Türkiye Cumhuriyeti Merkez Bankasından alınan verilerden derlenmiş ve uygulamada kullanılmıştır (TCMB, 2023).

3.2. Tahmin Modellerin Kurulması

Tahmin modellerinin algoritmasını oluşturulabilmek için, verileri belirli bir aralığa yeniden ölçeklendirmek gerekmektedir. Çünkü farklı ölçeklerde değişkenler içeren veri setlerinde, makine öğrenmesi algoritmalarının daha iyi performans göstermesine yardımcı olur. Gerçek veriler model kurulmadan önce normalizasyon olarak en çok kullanılan aşağıdaki Min-Max normalizasyon Formül (1) ile verileri 0 ile 1 arasında bir aralığa ölçeklendirir. Bu yöntem, özellikle verilerdeki en düşük ve en

yüksek değerler arasında büyük farklılıklar olduğunda etkilidir. Formül 1 ile Octave programında tüm veriler [0, 1] aralığında normalize edilmiş ve programa aktarılmıştır (Söylemez, 2020).

x_i girdi değişkeni olmak üzere;

$$x'_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (1)$$

3.2.1. ÇRA Modelinin Uygulaması

Çoklu regresyon analizi, istatistiksel bir yöntem olup bir bağımlı değişkenin birden fazla bağımsız değişkenle ilişkisini incelemek için kullanılır. Bu analiz, bağımlı değişkenin değerini, bağımsız değişkenler değerlerine bağlı olarak tahmin etmeye çalışır. (Ulgen, 2024). Çoklu regresyon analizinde, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi ifade eden bir denklem oluşturulur. Bu denklem, bağımsız değişkenlerin katsayılarıyla çarpılarak bağımlı değişkenin tahmini değeri elde edilir. Bu yöntem, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini nicel olarak ölçmek için kullanışlıdır. (Hocaoğlu, vd. 2015). ÇRA modelinin matematiksel gösterimi aşağıda Formül 2'de gösterilmiştir.

$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (2)$$

Bu formülde,

y_i = Bağımlı Değişkeni

β_0 = Sabit Katsayısı

ε = Hata Terimini

x_n = Bağımsız Değişkenleri

$\beta_1, \beta_2, \dots, \beta_n$ = Değişken Katsayıları ifade etmektedir.

Octave programında çoklu regresyon modeli uygulandığında modelin vermiş olduğu katsayı değerleri aşağıda Tablo 2'de gösterilmiştir.

Tablo 2. Çoklu Regresyon Analizi Modelinde Tahmin Edilen Katsayı Değerleri

	Estimate (Tahmin)	SE (Standart Hata)	tStat (t istatistiği)	pValue (p değeri)
Intercept (Sabit Katsayı)	0.17	0.07	2.39	0.01
X₁ (Brent Petrol)	-0.11	0.08	-1.36	0.17
X₂ (Dolar/TL)	-0.79	0.73	-1.09	0.27
X₃ (Taşıt Faiz Oranları)	-0.66	0.12	-5.17	0.10e-4
X₄ (Araç Satın Alma Düzeyi)	1.57	0.88	1.77	0.07
X₅ (TÜFE)	-0.05	0.72	-0.07	0.94
X₆ (Araç Üretim Adeti)	0.46	0.08	5.44	0.31e-5

Tablo 2'de elde edilen sonuçlar kapsamında oluşturulan ÇRA denklemi aşağıdaki gibidir.

$$Y=0.17-0.11*X_1-0.79*X_2-0.66*X_3+1.57*X_4-0.05*X_5+0.46*X_6$$

• X₁ (Brent Petrol) ve X₆ (Araç Üretim Adeti) değişkenleri en düşük standart hata değerlerine sahiptir, bu da tahminlerinin diğer değişkenlere göre daha güvenilir olduğunu gösterir.

• X₃ (Taşıt Faiz Oranları) ve X₆ (Araç Üretim Adeti) değişkenlerinin t-İstatistik değerlerinin diğerlerine göre daha büyük olduğu görülüyor. Bu, bu değişkenlerin tahmini katsayılarının sıfıra olan uzaklığının standart hatalarla orantılı olarak daha büyük olduğunu ve dolayısıyla istatistiksel olarak daha anlamlı olduklarını gösterir.

• Taşıt Faiz Oranları (X₃) ve Araç Üretim Adeti (X₆) değişkenlerinin tahmini katsayıları istatistiksel olarak anlamlıdır çünkü bunların p-değerleri alfa düzeyi olarak kabul edilen 0,05'ten küçüktür.

ÇRA modelinin tahmin ettiği sonuçlara Tablo 1'deki YSA Performans Ölçüt Formülleri uygulandığında ÇRA Modelinin Performans Değerleri aşağıda Tablo 3'te gösterildiği gibi olmaktadır.

Tablo 3. ÇRA Modelinin Performans Değerleri


Performans Ölçütü	Değer
MAD	0.24
MSE	0.07
SSE	9.30
RMSE	0.27
MAPE	%13.91

3.2.2. NARX Modelinin Uygulaması

NARX (Nonlinear AutoRegressive with eXogenous inputs), yapay sinir ağları kullanılarak zaman serisi tahmininde yaygın olarak kullanılan bir modeldir. NARX modeli, geçmiş değerlere dayalı otoregresif (AR) bileşenlerinin yanı sıra dışsal (exogenous) değişkenleri de girdi olarak alabilir. Örneğin, bir NARX modeli, geçmiş dolar fiyatlarının yanı sıra faiz oranları veya ekonomik göstergeler gibi dışsal faktörleri de kullanabilir.

NARX modeli, genellikle birkaç katman içeren bir yapay sinir ağı yapısı kullanır. Bu katmanlar arasında giriş (input) katmanı, gizli (hidden) katmanlar ve çıkış (output) katmanı bulunur. Model, girdi katmanından başlayarak gizli katmanlardan geçer ve çıkış katmanında tahminler üretir.


Şekil 2. NARX Modelinin Ağ Yapısını Gösteren Ekran



Şekil 2'de gösterilen NARX Modelinin Ağ Yapısı, gizli katmanda sigmoid transfer fonksiyonu ve çıkış katmanında doğrusal transfer fonksiyonu bulunan iki katmanlı bir ağıdır. Bu ağ yapısı, 6 giriş, 10 gizli nöron ve 1 çıkıştan oluşmaktadır.


Ağ eğitiminde Levenberg-Marquardt algoritması kullanılmıştır. Programa tanıtılan veri setinin %70'i (84 veri) ağı eğitmek için eğitim seti olarak kullanılmıştır. %15'i (18 veri), uygun yapay sinir ağı mimarisini belirlemek amacıyla doğrulama seti olarak ayrılmıştır. Geriye kalan %15'i (18 veri) ise ağın performansını ölçmek amacıyla test seti olarak rastgele seçilmiştir.

Şekil 3. NARX Modelinde Hata Histogramını Gösteren Grafik



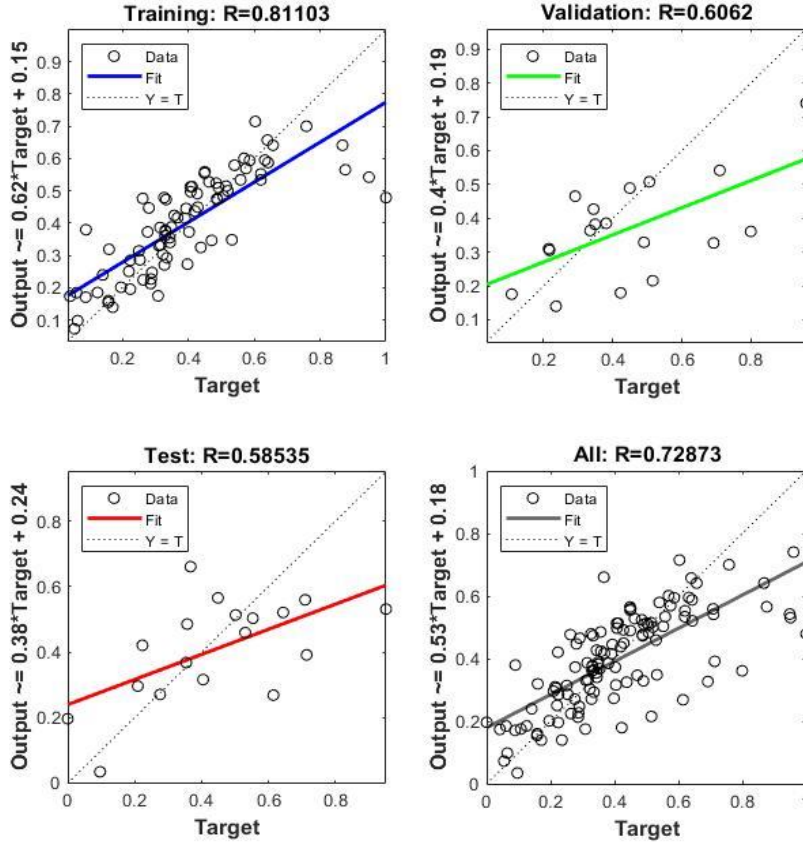
Yukarıdaki Şekil 3'teki grafik, modelin eğitim, doğrulama ve test tahmin hatalarının dağılımını göstermektedir. Mavi çubuklar eğitim verilerini, yeşil çubuklar doğrulama verilerini ve kırmızı çubuklar test verilerini temsil eder. Grafikte, test verilerindeki aykırı değer sayısının fazla olduğu, ancak eğitim verilerinde az olduğu görülmektedir. Bu durum, modelin eğitim verilerinde daha doğru tahminler yaptığını düşündürülebilir.

Şekil 4. NARX Modelinde Doğrulama Performansını Gösteren Ekran



Yukarıdaki Şekil 4'te görüldüğü gibi test seti hatası ve doğrulama seti hatası benzer özelliklere sahiptir. Herhangi bir aşırı uyumun meydana geldiği görülmemektedir. Epoch (Yineleme) 6'da (en iyi doğrulama performansının gerçekleştiği yerde) önemli bir aşırı uyum meydana gelmemiştir.

Şekil 5. NARX Modelinde Eğitim, Doğrulama ve Test Verileri İçin Regresyon Grafikleri



Yukarıdaki Şekil 5'te, regresyon grafikleri eğitim, doğrulama ve test kümelerine ilişkin hedeflere göre ağ çıktılarını gösterir. İdeal bir durumda, verilerin ağ çıktılarıyla hedefler arasında 45 derecelik bir çizgi boyunca düşmesi beklenir. Bu modelde, eğitim seti için uyum kabul edilebilir görünüyor. Ancak test ve doğrulama setleri için ağ çıktıları hedefleri iyi takip etmiyor gibi görünüyor ve toplam yanıt için R değeri 0,72 olarak belirlenmiştir.

NARX modelinin tahmin ettiği sonuçlara Tablo 1'deki YSA Performans Ölçüt Formülleri uygulandığında NARX Modelinin Performans Değerleri aşağıda Tablo 4'te gösterildiği gibi olmaktadır.


Tablo 4. NARX Modelini Değerlendirmek İçin Kullanılan Performans Ölçütlerinin Değerleri

Performans Ölçütü	Değer
MAD	0.19
MSE	0.06
SSE	7.84
RMSE	0.25
MAPE	%12.23

3.2.3. YSA Modelinin Uygulaması

Uygulamada kullanılan yapay sinir ağı modeli, yapay sinir ağlarında en yaygın kullanılan ileri beslemeli geri yayımlı ağıdır. Bu modelin tercih edilme nedeni, hem tahmin çalışmalarında yaygın olarak kullanılması hem de doğrusal veya doğrusal olmayan modellerdeki tahmin başarısıdır. Ayrıca, bu modelin kullanımının kolaylığı da seçilmesinde etkili olmuştur.


Şekil 6. YSA Modelinin Ağ Yapısını Gösteren Ekran Görüntüsü



Şekil 6'da gösterilen standart yapay sinir ağı (YSA), fonksiyon uyumu için kullanılan bir ileri beslemeli ağ yapısına sahiptir. Bu ağ, gizli katmanda sigmoid transfer fonksiyonu ve çıkış katmanında doğrusal transfer fonksiyonu bulunan iki katmanlı bir yapıya sahiptir. Ağ yapısı, 6 girdi, 10 gizli nöron ve 1 çıktıdan oluşmaktadır.


Ağın eğitimi için Levenberg-Marquardt algoritması gibi yapay sinir ağları modellerinin eğitimi için yaygın olarak kullanılan bir algoritma kullanılmıştır. Programa aktarılan veri setinin %70'i (84 veri), ağı eğitmek için eğitim seti olarak kullanılmıştır. %15'i (18 veri) uygun ağ mimarisini belirlemek için doğrulama seti olarak, ve %15'i (18 veri) de ağın performansını ölçmek amacıyla test seti olarak kullanılmıştır.

Şekil 7. YSA Modelinde Hata Histogramını Gösteren Grafik



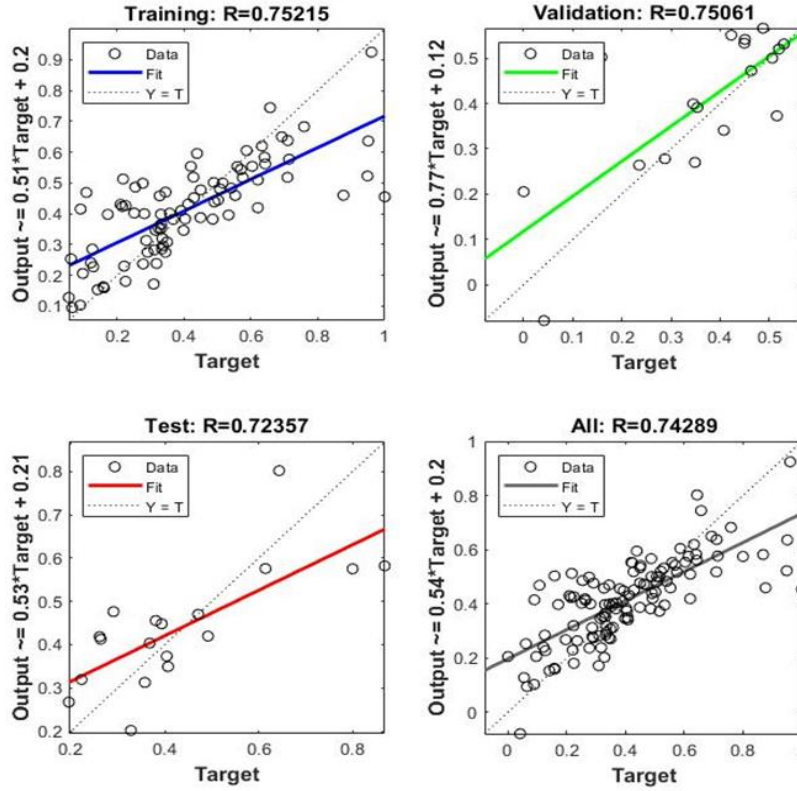
Yukarıda Şekil 7'deki grafik, modelin eğitim, doğrulama ve test tahmin hatalarının dağılımını göstermektedir. Grafikte mavi çubuklar eğitim verilerini, yeşil çubuklar doğrulama verilerini ve kırmızı çubuklar test verilerini temsil eder. Test verilerinde olan aykırı değer sayısı fazla iken eğitim verilerinde azdır. Bu nedenle modelin, eğitim verilerinde daha doğru tahmin yaptığını söyleyebiliriz.

Şekil 8. YSA Modelinde Doğrulama Performansını Gösteren Ekran



Yukarıdaki Şekil 8'de görüldüğü gibi test seti hatası ve doğrulama seti hatası benzer özelliklere sahiptir. Herhangi bir aşırı uyumun meydana geldiği görülmemektedir. Epoch (Yineleme) 4'te (en iyi doğrulama performansının gerçekleştiği yerde) önemli bir aşırı uyum meydana gelmemiştir.

Şekil 9. YSA Modelinde Eğitim, Doğrulama ve Test Verileri İçin Regresyon Grafikleri



Yukarıdaki Şekil 9'da gösterilen regresyon grafikleri, eğitim, doğrulama ve test kümelerine ilişkin hedeflere göre ağ çıktılarını göstermektedir. Mükemmel bir uyum için, verilerin ağ çıktılarıyla hedefler arasında 45 derecelik bir çizgi boyunca düşmesi beklenir. Bu modelde, en iyi uyum eğitim setinde gözlenmektedir ve toplam yanıt için R değeri 0.74'tür. Bu, eğitim verilerinin hedeflere daha yakın olduğunu ve modelin eğitim setinde daha iyi bir performans gösterdiğini göstermektedir.

YSA modelinin tahmin ettiği sonuçlara Tablo 1'deki YSA Performans Ölçüt Formülleri uygulandığında YSA Modelinin Performans Değerleri aşağıda Tablo 5'te gösterildiği gibi olmaktadır.

Tablo 5. YSA Modelini Değerlendirmek İçin Kullanılan Performans Ölçütlerinin Değerleri

Performans Ölçütü	Değer
MAD	0.10
MSE	0.02
SSE	2.52
RMSE	0.14
MAPE	%11.66

3.2.4. ÇRA, NARX ve YSA Modellerin Karşılaştırılması

Çalışmanın bu kısmında, gerçek değerler ile ÇRA, NARX ve YSA modeliyle yapılan talep tahmin yöntemleriyle karşılaştırılarak performansları değerlendirilmiştir.

Tablo 6. Tahmin Modellerinin Karşılaştırmalı Performans Verileri

Tahmin Yöntemi	Korelasyon	MSE	RMSE	MAPE
ÇRA	0.64	0.07	0.27	%13.91
NARX	0.72	0.06	0.25	%12.23
YSA	0.75	0.02	0.14	%11.66

Yukarıdaki Tablo 6'da ÇRA, NARX ve YSA modellerinin performansını karşılaştırdığı bir sonuç tablosu gösterilmektedir. Buna göre,

- YSA yöntemi en yüksek korelasyona sahiptir. Yüksek korelasyon, modelin gerçek verilere daha iyi uyum sağladığını, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkinin daha güçlü olduğunu işaret edebilir.

- YSA modelinin en düşük MSE'ye sahip olduğu görülüyor, bu da modelin tahmin değerlerinin gerçek değerlere daha yakın olduğunu gösterebilir.

- YSA modelinin en düşük RMSE'ye sahip olduğu görülüyor, yani tahminlerinin gerçek değerlere daha yakın olduğu anlamına gelir.

- Lewis (1982) MAPE değerinin diğer ölçümlerden daha etkin sonuçlar verdiğini ve belirli değerler arasındaki MAPE değerlerinin değişimi açıklamakta yeterli olduğunu söylemiştir. Lewis'e göre MAPE değeri %10'dan küçük ise model yüksek doğruluğa sahip (çok iyi tahmin edici), değer %10 ile %20 aralığında ise orta derecede doğruluğa sahip (iyi tahmin edici), %20 ile %50 aralığında ise düşük derecede doğruluğa sahip ancak kabul edilebilir. %50'nin üzerinde ise tahmin değeri yok (kötü tahmin

edici) olarak sıralanabilir. YSA modeli, MAPE açısından en düşük değere sahiptir, yani tahminlerinin gerçek değerlere oranla daha az hata içerdiği anlamına gelir.

Sonuç olarak, bu değerlerin incelenmesi, YSA modelinin genel olarak en iyi performansı sergilediğini göstermektedir. Yüksek korelasyon, düşük MSE, RMSE ve MAPE değerleri, YSA'nın tahmin performansının diğer yöntemlere göre daha iyi olduğunu ortaya koymaktadır. Bu, Yapay Sinir Ağı modelinin talep tahmini sürecinde etkili bir şekilde kullanılabileceğini ve doğru tahminler yapma yeteneği ile işletmelere önemli avantajlar sağlayabileceğini göstermektedir.

3.2.5. YSA Modelinin 12 Aylık Tahmin Değerleri

En iyi performans gösteren yapay sinir ağı modelinin, 2014 ile 2024 yılları arasındaki aylık otomobil satış verilerini temel alarak yapılan analizler sonucunda, gelecekte gerçekleşmesi beklenen Ocak 2024 ile Aralık 2024 arasındaki 12 aylık satış tahminleri Tablo 7'de gösterilmiştir.

Tablo 7. YSA Modeliyle Yapılan 12 Aylık Otomobil Satış Tahmin Verileri

Tarih	YSA ile Otomobil Satış Tahmini
Ocak 24	16.219
Şubat 24	18.605
Mart 24	34.406
Nisan 24	33.197
Mayıs 24	35.321
Haziran 24	31.352
Temmuz 24	28.203
Ağustos 24	22.566
Eylül 24	31.991
Ekim 24	35.284
Kasım 24	37.577
Aralık 24	42.146

SONUÇ

Ülkemizde yapay sinir ağları üzerine yapılan çalışmaların artmasıyla birlikte, bu yöntemin tahmin modellemesindeki önemi de giderek artmaktadır. Yapay sinir ağları, otomobil talep tahmini gibi konularda da kullanılarak ülkemiz bilimine önemli katkılar sağlayabilir. Bu bağlamda, çalışmada yapay sinir ağları modeli seçilmiş ve otomobil talep tahmini için bir model geliştirilmiştir. Model, ileri beslemeli geri yayılım ağı kullanılarak oluşturulmuş olup 6 girdi, 1 çıktı değişkeni ve 10 elemanlı bir tek gizli katmanı içermektedir. Uygulama çalışmasında, Türkiye'deki otomobil üretimi yapan firmaların 2014-2024 yılları arasındaki satış adetleri dikkate alınmış ve otomobil satışını etkileyen altı ana faktör belirlenmiştir: Brent Petrol Fiyatı, Dolar Kuru, Taşıt Kredi Faizleri, TÜFE, Araç Alım Düzeyi ve Otomobil Üretim Adedi. Kurulan model, kendi içinde değerlendirilmiş ve performans testlerine tabi tutulmuştur. Bu çalışma, yapay sinir ağlarının otomobil talep tahmini gibi alanlarda etkin bir şekilde kullanılmasını sağlamıştır.

Geliştirilen modele ait test sonuçlarından, Korelasyon değeri 0.75 olarak, MSE değeri 0.0210 olarak, RMSE 0.144 ve MAPE değeri %11.66 olarak bulunmuştur. Bu değerlere göre, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğu görülmüştür. Tahmin çalışmasının başarısını ölçebilmek için ÇRA Modeli ve NARX tahmin sonuçları YSA tahmin sonuçları ile karşılaştırılmıştır. YSA modelinin ÇRA ve NARX modeline göre daha iyi tahmin performansı sergiledikleri gözlemlenmiştir. Test verilerine göre en düşük hata değeri hem MSE, hem de MAPE esas alındığında yapay sinir ağları ile bulunan değerdir. Yapılan tahminler gerçek değerler ile karşılaştırıldığında YSA ile yapılan tahminlerin gerçekleşen değerlere yakın olduğu görülmektedir.

Bu çalışmada, talep miktarlarının yapay sinir ağları yöntemiyle tahmin edilerek, ülkemizdeki otomobil üretici firmalarına üretim planlamalarını önceden yapabilmeleri ve gelecekteki talep eğilimlerini görebilmeleri için bir yol haritası oluşturulmuştur. Bu bağlamda, çalışmanın sonuçlarına dayanarak geliştirilebilecek öneriler arasında şunlar bulunmaktadır:

- Otomobil üretici firmaları için geleceği öngörmek ve belirsiz durumları tahmin etmek, stratejik planlama ve karar alma süreçlerinde önemli bir rol oynar. Yapay sinir ağları gibi tahmin modelleri, bu tür belirsizliklerin önceden tespit edilmesi ve karar verme süreçlerine rehberlik etmek için değerli araçlar sağlar. Bu modeller, pazar talebi, tüketici davranışları, ekonomik koşullar ve diğer faktörler üzerinde tahminler yaparak, firmaların gelecekteki ihtiyaçları ve zorlukları öngörmelerine yardımcı olabilir.

- Yapay sinir ağları gibi tahmin modelleri, otomobil üretici firmalarının sadece satış tahminlerini değil, aynı zamanda stok yönetimi gibi diğer stratejik konularda da kullanılabilir. Özellikle satılmayan ürünlerin stoklarda tutulma süreçleri, maliyetlerin azaltılması ve operasyonel verimliliğin artırılması açısından önemlidir.

- Yapay sinir ağlarıyla yapılan talep tahmini, otomobil üreticileri ve yatırımcılar için sadece nihai ürün talebini değil, aynı zamanda hammadde ve bileşenler gibi temel girdi malzemelerinin talebini de

tahmin etmelerine yardımcı olabilir. Bu, üreticilerin tedarik zinciri yönetimi süreçlerini optimize etmelerine ve kaynakları daha etkili bir şekilde kullanmalarına olanak tanır.

• Yapay sinir ağları gibi ileri teknoloji uygulamaları, ülkemizde bilimsel ve teknolojik gelişmelerin ivme kazanmasına katkı sağlayabilir. Bu tür teknolojilerin araştırılması ve geliştirilmesi, bilim insanlarımızın uluslararası alanda rekabet gücünü artırabilir ve ülkemizin teknolojik yeniliklere daha fazla katkıda bulunmasını sağlayabilir.

• Yapay sinir ağlarıyla talep tahmini yapmak, otomobil üreten firmaların gelecekteki satışlarına dair daha doğru ve güvenilir tahminlerde bulunmalarını sağlar.

Bu çalışma, 6 otomotiv firması ve 2014-2023 yılları arasındaki satışlar ile sınırlıdır. YSA modelinde veri boyutu ve model karmaşıklığı gibi zorluklarla karşılaşılabilir. Bununla birlikte, doğru bir şekilde uygulandığında YSA modeli, zaman serilerini ve dinamik sistemleri modellemede güçlü bir araç olabilir.

Ülkemizde, yapay sinir ağları uygulamaları üzerine yoğunlaşmamış olmamıza rağmen, araştırmacıların bu alana daha fazla ilgi göstermesi ve yapay sinir ağları yöntemiyle sınıflandırma, tahmin, veri analizi ve kontrol problemlerinin çözümü gibi konularda çözümler geliştirmesi, literatüre katkı sağlayacağı düşünülmektedir.

Sonuç olarak, yapay sinir ağlarıyla yapılan doğru talep tahminleri, otomobil üreten firmaların operasyonel etkinliklerini artırır, maliyetleri azaltır, hizmet kalitesini artırır ve rekabet avantajı elde etmelerine yardımcı olur. Bu nedenle, yapay sinir ağlarıyla talep tahmini yapmak, otomotiv endüstrisinde önemli bir stratejik araç haline gelmiştir.

KAYNAKÇA

Aktaş, R., Doğanay, M., ve Yıldız, B. (2003). Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırması. Ankara Üniversitesi SBF Dergisi, 58(4), 1-24.

Al-Hamadi, H., ve Soliman, S. (2004). Short-Term Electric Load Forecasting Based on Kalman Filtering Algorithm with Moving Window Weather and Load Model. Electric Power Systems Research, 47-59.

Anonim. (2014/a). Otomotiv Sektör Raporu (2013/1). T.C. Bilim Sanayi ve Teknoloji Bakanlığı, Sanayi Genel Müdürlüğü, Sektörel Raporlar ve Analizler Serisi. 11 22, 2023 tarihinde alındı.

Arslan, B. (2019). Gelecekte Karar Vericiler Kim Olacak? Uluslararası Yönetim, Ekonomi ve Politika Kongresi. İstanbul.

Bolt, G. (1994). Market and Sales Forecasting: A Total Approach. Londra: Kogan Page.

Brown, S., Lamming, R., Bessant J. ve Jones, P. (2005). Strategic Operations Management. Elsevier Butterworth-Heinemann.

Değirmenci, N., Pabuçcu, H. (2016). Borsa İstanbul ve Risk Primi Arasındaki Etkileşim: VAR ve NARX Model. *The Journal of Academic Social Science*, 4(35), 248-261.

Elmas, Ç. (2018). *Yapay zekâ Uygulamaları*. Ankara: Seçkin Yayıncılık.

Eski, H. V. (2006). Ankara: Gazi Kitabevi.

Fırat, M., ve Güngör, M. (2004). Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi. *İMO Teknik Dergisi*, 3267-3282.

Forbes, (2019). 4 ways AI and associated technologies are changing the nature of work -- and the structure of business, Erişim adresi:<https://www.forbes.com/sites/insights-microsoftai/2019/02/04/4-ways-ai-and-associated-technologies-are-changing-the-nature-of-work-and-the-structure-of-business/?sh=4d6bf328110e>. Erişim tarihi: 12.12.2023

Hamzaçebi, C. (2011). *Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı*. Ekin Basım Yayın Dağıtım.

Heizer, J., ve Render, B. (2004). *Operations Management*. Uluslararası Basım 7. Baskı: Prentice Hall.

Hocaoğlu, F. O., Kaysal, K., ve Kaysal, A. (2015). Yük Tahmini İçin Hibrit (YSA ve Regresyon) Model. *Academic Platform Journal of Engineering and Science*, 3(2), 33-39.

Hu, C. (2002). *Advanced Tourism Demand Forecasting ANN and Box-Jenkins Modelling*. MI, USA: Doktora Tezi, Purdue University.

Huang, S., ve Shih, K. (2003). Short-Term Load Forecasting via ARMA Model Identification Including Non-Gaussian Process Considerations. *IEEE Transactions on Power Systems*, 673-679.

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.

Kesici, B. ve Yıldız, M. (2016). Kalite Kontrol Faaliyetlerinde Yapay Zekâ Kullanımı ve Bir Otomotiv Yan Sanayisinde Uygulanması. *Yalova Sosyal Bilimler Dergisi*, 307-323.

Lewis, C. D. (1982). *Industrial and Business Forecasting Methods*. Butterworths Publishing(40).

Moon, M. A., Mentzer, J. T., ve Smith, C. D. (2003). Conducting A Sales Forecasting Audit. *International Journal of Forecasting*, 19(1), 5-25.

ODMD, (2023). Otomotiv Distribütörleri ve Mobilite Derneği, Erişim adresi: https://www.odmd.org.tr/web_2837_1/neuralnetwork.aspx?type=35, Erişim tarihi: 5.11.2023.

Öztemel, E. (2006). *Yapay Sinir Ağları* (2. b.). İstanbul: Papatya Yayıncılık.

Öztürk, K., ve Şahin, M. E. (2018). Yapay Sinir Ağları Ve Yapay Zekâ'ya Genel Bir Bakış. *Takvim-İ Vekayi*, 6(2), 25-36.

Pirim, A. G. H. (2006). Yapay Zeka. Yaşar Üniversitesi E-Dergisi, 1(1), 81-93.
<https://doi.org/10.19168/jyu.72783>, Erişim Tarihi: 10.06.2024

Sagiroglu, S., Besdok, E., ve Erler, M. (2003). Muhendislikte Yapay Zekâ Uygulamaları. Kayseri: Ufuk Yayıncılık.

Sarı, M. (2006). Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması. Sakarya Üniversitesi.

Söylemez, Y. (2020). Çok Katmanlı Yapay Sinir Ağları Yöntemi ile Altın Fiyatlarının Tahmini. Sosyoekonomi, 271-291.

TCMB, (2023). Türkiye Cumhuriyeti Merkez Bankası Erişim adresi: <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, Erişim tarihi: 5.11.2023

Ulgen, K. E. (2024). Makine Öğrenimi Bölüm-6 (Regresyon). Erişim adresi: <https://medium.com/> Erişim tarihi: 24.03.2024

Ünal, Ş. N. (2024), NARX Sinir Ağı Yöntemi ile Safranbolu Turist Sayısının Analizi, Turizm ve İşletme Bilimleri Dergisi,

Wang, W. ve Xu, Z. (2004). A Heuristic Training For Support Vector Regression, Neurocomputing, 61: 259-275

Yıldırım, H. ve Karaatlı, M. (2022). Yapay Sinir Ağları NARX Modeli ile Elma Üretim Miktarının Öngörülmesi. Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi (42), 1-29.

Yılmaz, A. (2019). Yapay Zekâ. İstanbul: KODLAB Yayın Dağıtım.

Yücesoy, M. (2011). Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini. İstanbul: (Doktora Tezi, Fen Bilimleri Enstitüsü).

Zhang, G., Patuwo, B., ve Hu, M. (1998). Forecasting With Artificial Neural Networks: The State Of The Art. International Journal of Forecasting, 35-62.