


NARX (Doğrusal Olmayan Otoregresif Dışsal Girdili) Yapay Sinir Ağları Model ile Otomobil Satışı Talep Tahmini*

Automobile Demand Forecasting with NARX (Nonlinear AutoRegressive with Exogenous Inputs) Artificial Neural Networks Model

Mehmet Zeki SEÇMEN^a, Sait PATIR^b

^a(Sorumlu yazar/Corresponding author) Bilgisayar İşletmeni, Bingöl Gençlik ve Spor İl Müdürlüğü, m.zeki12@hotmail.com,

 0000-0002-7664-4916

^bProf. Dr., Bingöl Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, spatir@bingol.edu.tr,  0000-0002-1592-1094

Makale Türü: Araştırma Makalesi
Article Type: Research Article

Makale Geçmiş/Article History
Makale Geliş
Tarihi/Received:20/05/2024
Makale Kabul Tarihi/Accepted:09/07/2024

Anahtar Kelimeler: Yapay zekâ, NARX yapay sinir ağları model, otomobil talep tahmini.

Keywords: Artificial intelligence, NARX artificial neural networks model, automobile demand forecasting.

Öz

Amaç: Bu çalışmanın amacı, günümüzde teknoloji alanında yaşanan hızlı değişim ve yapay zekânın da toplum içerisindeki önemini giderek artmasıyla NARX (Doğrusal Olmayan Otoregresif Dışsal Girdili) YSA (Yapay Sinir Ağları) modelini kullanarak otomobil talep tahmini yapmaktır. **Gereç ve Yöntem:** Çalışmada, MATLAB (Matris Laboratuvarı) programı kullanılarak Türkiye’de otomobil üretip en çok satış yapan altı firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) Otomotiv Distribütörleri ve Mobilite Derneği (ODMD)’nin 2014–2024 yılları arasında yayımlanmış olduğu aylık otomobil satış verilerinden NARX YSA modeli ile satış tahmini yapılmıştır. Tahmin modelinin geliştirilmesinde Sanayi ve Teknoloji Bakanlığının yıllık yayımlanmış olduğu faaliyet raporlarından 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 altı firmanın toplam otomobil satış âdeti olarak belirlenmiştir. **Bulgular:** NARX YSA, altı girdi, on gizli nöron ve bir çıktıdan oluşmaktadır. Önerilen modelin, test seviyesindeki performansı MSE=0,0654, MAPE=%12,23’dür. Bu sonuçlar, NARX YSA modelinin genel olarak iyi performansı sergilediğini göstermektedir. **Sonuç:** Önerilen modelin eğitim ve test aşamasından sonra 2024 yılının 12 aylık otomobil satış talep tahmini yapılmıştır. Yapay sinir ağları ile talebin doğru tahmin edilmesi, otomobil üreten firmaların gelecekte tarifelerini hızlı bir şekilde pazar planlamasına olanak tanır, bu da güvenilirliğinin artmasına yardımcı olabilecektir.

Abstract

Purpose: The aim of this study is to forecast automobile demand using the NARX (Non-Linear Autoregressive External Input) ANN (Artificial Neural Networks) model, with the rapid change in technology today and the increasing importance of artificial intelligence in society. **Material and Method:** In the study, using the MATLAB (Matrix Laboratory) program, the data of the six companies that produce and sell automobiles in Turkey (OYAK Renault, Tofaş, Toyota, Ford, Honda and Hyundai) were published by the Automotive Distributors and Mobility Association (ADMA) between 2014 and 2024. Sales prediction was made with the NARX ANN model from monthly automobile sales data. In the development of the forecast model, the independent variables that are thought to have an impact on automobile demand from the annual activity reports published by the Ministry of Industry and Technology are Brent oil price, dollar exchange rate, vehicle loan interest, CPI, vehicle purchase level, automobile production quantity, and the dependent variable, that is, the output value, is the total of six companies. determined as automobile sales volume. **Findings:** NARX ANN consists of six inputs, ten hidden neurons and one output. The performance of the proposed model at the test level is MSE=0.0654, MAPE=% 12.23. These results show that the NARX ANN model generally exhibits good performance. **Results:** After the training and testing phase of the systematic model, automobile sales demand for the 12 months of 2024 is predicted. Accurate prediction of demand with artificial neural networks allows timetables generated in automobiles to be quickly marketed, which can help increase reliability.



Bu çalışma [Creative Commons Atf-GayriTicari 4.0](https://creativecommons.org/licenses/by-nc/4.0/) (CC BY-NC 4.0) kapsamında açık erişimli bir makedir.

*Bu çalışma Mehmet Zeki SEÇMEN isimli kişinin doktora tezinden türetilmiştir.

Bu yayına atıfta bulunmak için/Cite as: Seçmen, M. Z., & Patir, S. (2024). NARX (Doğrusal Olmayan Otoregresif Dışsal Girdili) yapay sinir ağları model ile otomobil satış talep tahmini. *Güncel Pazarlama Yaklaşımları ve Araştırmaları Dergisi*, 5(1), 31-47. <https://doi.org/10.54439/gupayad.1486360>

Etik kurul beyanı/Ethics committee statement: Bu çalışma bilimsel araştırma ve yayın etiği izni gerektiren bir çalışma olmadığı için etik kurul onayı alınmamıştır.

1. Giriş

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).

Otomobiller, insanlara kendi başlarına hareket etme, istedikleri yere gitme ve bağımsız seyahat etme özgürlüğü sağlamaktadır. Bu da onları günlük yaşamın ayrılmaz bir parçası haline getirmektedir (Benkachcha vd., 2015). Günümüzde, birçok kişi bir veya birden fazla araca sahip olup, bu araçlar günlük yaşamın her alanında kullanılmaktadır. Bu durum, otomobillerin sadece bir ulaşım aracı olmanın ötesine geçtiğini ve hayatın her anında önemli bir yer tuttuğunu göstermektedir. İşe gitmekten aile gezilerine, alışverişten tatil planlarına kadar pek çok etkinlikte otomobillerin rolü büyüktür (Yıldız ve Ustaoglu, 2012).

Otomobil üretimi, hammadde tedarikinden nihai montaja kadar uzanan karmaşık ve entegre bir süreçtir. Üretim hatlarının ve fabrika organizasyonunun doğru planlanması için güvenilir talep tahminlerine ihtiyaç vardır (Akyurt, 2015).

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).

İşletmelerin gelecekte daha kesin ve daha az hatayla tahminde bulunma ihtiyacı, rekabet ortamında gerçekleşen 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 tahmin yaklaşımı benimserler (Heizer ve Render, 2004).

Son zamanlarda yapay zeka tabanlı yöntemlerin gelişmesiyle, klasik tahmin yöntemlerine kıyasla daha gerçekçi tahminler yapılabildiği gözlemlenmektedir. Özellikle yapay sinir ağları, tahmin alanında sıkça kullanılan bir yapay zeka 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).

Günümüzde teknoloji alanında yaşanan hızlı değişim ve inovasyonun hayatımızın neredeyse her alanında yer alması, yapay zekânın da toplum içerisindeki öneminin giderek artmasına neden olmaktadır. Forbes'in 2018 yılı sonunda yayınladığı rapora göre, işletmelerin şu anda %44'ü, tekrar eden işleri yapay zekâyâ devrederek, bilgi işçilerini güçlendirme çabasıyla çalışmalarını sürdürmektedir (Forbes, 2019). İrlandalı ünlü yönetim danışmanlık şirketi Accenture, yapay zekâ uygulamalarını faaliyetlerinde ilk defa kullanma kararı alan organizasyonlar, yapay zekâyâ ve insan-makine işbirliğine bağlı olarak başarılı performans gösteren organizasyonların stratejilerini taklit etmelerini ve bu yönde yatırım yapmaları halinde, 2019–2022 yılları arasında, gelirlerini %38'e kadar, istihdamı da %10'a kadar arttırabileceklerini vurgulamaktadır (Accenture, 2023). Dolayısıyla bu bilgiler göz önüne alındığında yapay zekâ çağında işletmelerin

başarısının insanların ve makinelerin işbirliğine bağlı hale geldiği söylenebilir. Yapay zekâyı kullanan işletmelerde, kendini yöneten ekiplerin ortaya çıkmasına, dağıtılmış sorumluluk ve yerinden örgütsel yapıların iş akışlarının mekândan bağımsız hale gelmesine ve karar verme süreçlerinde yeni olanaklar sunmaktadır. Çünkü bugün işletmelerde yapay zekâ kullanımının henüz yüksek seviyelere ulaşmamasına rağmen, işletmelerin karar verme aşmalarında isabetli ve güvenilir tahminlerde bulunması işletmeler için ilgi çekici hale gelmektedir. Söz konusu yeni teknolojiler; çeşitli sektörlere, yakın zamana kadar farkında bile olmadıkları değişkenlerin etkisinde kalacaklarının habercisi olurken, verimliliğin teknolojik gelişmeler sayesinde, toplum ve birey bütünleşmesi ile artacağını vurgulamaktadır (Arslan, 2019).

Bu çalışmanın temel amacı, Türkiye'de otomobil üretip en çok satış yapan 6 firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) 2014–2024 yılları arasındaki aylık satış verilerinden yola çıkarak NARX yapay sinir ağı modeli ile Ocak 2024 ile Aralık 2024 arasındaki 12 aylık satış talep tahmini yaparak otomobil üreten firmaların gelecekte tarifelerini hızlı bir şekilde ayarlamalarına ve karşılaşılabilecekleri belirsiz durumları önceden tahmin ederek buna uygun önlemler almalarına yardımcı olmaktır.

Bu çalışmada NARX modelinin seçilmesinin nedeni, genelleme yapabilmesi ve üretim miktarının tahmin etmek gibi karmaşık ve zaman serisi özelliği gösteren problemlerde bu modelin kullanımının faydalı olabileceği düşüncesidir. Otomobil sektörünün seçilmesinin nedeni ise, otomotiv sektörünün en önemli üretim faaliyet alanlarından birisi olması ve ülke sınırlarını aşan bir nitelikte olmasıdır.

2. Yapay Zekâ

Yapay zekâ konsepti ilk kez 1955 yılında John McCarthy tarafından tanımlanmış ve "Zeki makineler yapmanın bilimi ve mühendisliği" olarak ifade edilmiştir. 1960 yılında Marvin Minsky, bu tanımı daha da geliştirerek "Yapay zekâ, insanların makineleri kullanarak görevlerini yerine getirme bilimidir" şeklinde

açıklamıştır (Wawrzyński, 2014). Newell ve Simon, 1957 yılında ilk yapay zekâ programlarından biri olan "General Problem Solver" (GPS) programını geliştirdiler. Joseph Weizenbaum, 1966 yılında insanlarla doğal dilde iletişim kurabilen ilk programlardan biri olan ELIZA'yı geliştirdi. Geoffrey Hinton ve David Rumelhart, 1986 yılında geri yayılım (backpropagation) algoritmasını tanıtarak yapay sinir ağları çalışmalarında bir devrim yarattılar. IBM'in geliştirdiği Deep Blue, 1997 yılında dünya satranç şampiyonu Garry Kasparov'u yendi. IBM'in Watson adlı yapay zekâ sistemi, 2011 yılında "Jeopardy!" adlı bilgi yarışmasında insan rakiplerini yendi. Google DeepMind'in AlphaGo programı, 2016 yılında dünya Go şampiyonu Lee Sedol'u yendi. 2020'li yıllarda Yapay zekâ uygulamaları sağlık, finans, otomotiv, perakende ve birçok diğer sektörde yaygınlaştı. GPT-3 gibi büyük dil modelleri, doğal dil işleme alanında büyük ilerlemeler sağladı (TÜBİTAK, 2001).

Yapay zekâ, bilgisayarların ve makinelerin insanlar gibi düşünmesini ve öğrenmesini sağlama amacını taşıyan bir bilim dalıdır. Yapay zeka, çeşitli teknolojiler ve yöntemler kullanarak, bilgi işleme, mantık yürütme, karar verme, problem çözme ve doğal dil anlama gibi insan benzeri yetenekleri geliştirmeye çalışır. Bu sayede, yapay zekâ sistemleri karmaşık verileri işleyebilir, örüntüleri tanımlayabilir ve kararlar alabilir (Sağıroğlu vd., 2003).

İşletmeler, rekabetin arttığı ve globalleşen dünyada müşterilere kaliteli ürünleri düşük maliyetlerle sunarak daha fazla kazanç elde etme amacıyla çalışmaktadır (İleri & Horasan, 2010). 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 (Özdal, 2023).

Yapay zeka, günümüzde birçok sektörde kullanılmakta ve sektörlerdeki gelişime katkı sağlamaktadır. Bu yüzden teknolojinin etkin kullanımı, tüm ülkeler açısından oldukça önemli ve vazgeçilmez bir unsur haline gelmiştir

(Alpaydın, 2021). Bu teknoloji sayesinde işletmeler, trendleri belirleyebilir ve stratejik kararlar alabilirler. Sonuç olarak, yapay zekâ, işletmelerin verimliliğini artırırken rekabet avantajı elde etmelerine de yardımcı olur (Kesici & Yıldız, 2016).


Yapay zekâ, birçok alt alana ayrılır ve bu alt alanlar, çeşitli uygulama ve tekniklerle farklı sorunları çözmeyi amaçlar. Yapay zekâyâ ait alt alanlar aşağıda kısaca açıklanmıştır (Öztürk & Şahin, 2018).

Makine Öğrenmesi: Makine Öğrenmesi, bilgisayarların veri ile öğrenmesini ve kararlar almasını sağlayan bir yapay zekâ alt alanıdır. Makine öğrenmesi, algoritmalar ve istatistiksel modeller kullanarak, belirli bir görevi yerine getirme performansını artırmak için verilerden örüntüler ve ilişkiler çıkarır (Mitchell, 1997). Makine öğrenmesi, elde edilen bilgileri çeşitli matematiksel formüller kullanarak farklı çözümler sunabilen bir yöntemdir. Bu yöntem, geniş bir kullanım alanına sahip olup her geçen gün hızla yayılmakta ve gelişim göstermektedir. Günümüzde, sosyal medya uygulamaları, online alışveriş siteleri, sağlık hizmetleri, eğitim sektörü, bankacılık ve finans gibi birçok alanda yaygın olarak kullanılmaktadır (Rende vd., 2016). Makine öğrenmesi teknolojisi, çağdaş topluma birçok açıdan önemli katkılar sağlamaktadır. Bu teknoloji, kullanıldığı alanlarda yüksek etkinlik ve verimlilik sunarak önemli çalışmalara imkan tanımaktadır. Makine öğrenmesi sayesinde birçok ticari firma satışlarını artırmakta ve tüketici davranışlarını analiz ederek stratejilerini geliştirmektedir. Örneğin, tüketicilerin hangi ürünlere talep gösterdiği, hangi günlerde daha fazla alışveriş yaptığı gibi veriler analiz edilerek, bu bilgiler doğrultusunda ürün tavsiyelerinde bulunulabilir. Ayrıca, internet uygulamalarında içerik filtreleme ve kişiselleştirilmiş içerik önerileri gibi pek çok alanda yaygın olarak kullanılmaktadır (Jones, 2009).

Derin Öğrenme: Derin Öğrenme, Makine Öğrenmesinin bir alt kümesi olup, çok katmanlı sinir ağları kullanarak daha karmaşık veri yapılarını öğrenir. Derin Öğrenme, özellikle büyük veri setleri ve yüksek işlem gücü

gerektiren karmaşık sorunları çözmede etkilidir. (Ian vd., 2016). Derin öğrenme, beynin yapısı ve işlevinden ilham alan yapay sinir ağları algoritmalarını kullanarak işlemlerini gerçekleştiren bir yöntemdir. Bu sistem, yapay zekâ ve makine öğrenmesine kıyasla daha fazla veriyi daha karmaşık şekillerde öğrenebilir ve sürekli olarak öznetelik değerleri oluşturur. Bu öznetelikler üzerinden çıkarımlar yapar ve bunları kullanarak çeşitli işlemler gerçekleştirir. Aşağıda Şekil 1'de derin öğrenmenin çalışma adımları gösterilmiştir. Öncelikle çözülmek istenen problemin ne olduğu belirlenir ve bu problemin derin öğrenme yöntemleriyle çözülebilir olup olmadığı değerlendirilir. İlgili

veri kümeleri seçilir ve analiz için uygun hale getirilir. Bu adımda veri temizleme, normalizasyon ve öznetelik çıkarımı gibi işlemler yapılabilir. Problemin veri türüne en uygun derin öğrenme algoritması seçilir. Tanımlı veriler kullanılarak seçilen algoritma ile analitik bir model oluşturulur. Model, eğitim verileri ile eğitilir ve performansı değerlendirilir. Gerekliğinde model parametreleri ve yapısı revize edilir. Eğitim tamamlandıktan sonra model, test verileri ile çalıştırılır ve test skorları elde edilir. Bu skorlar, modelin performansını ve doğruluğunu değerlendirir. Elde edilen sonuçlara göre ileriye yönelik tahminler yapılır (Akın, 2023).



Şekil 1. Derin Öğrenme Çalışma Adımları

Kaynak: Akın, E., & Şahin, M. E. (2024). Derin öğrenme ve yapay sinir ağı modelleri üzerine bir inceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.

Doğal Dil İşleme: Doğal Dil İşleme, bilgisayarların insan dilini anlamasını, yorumlamasını ve üretmesini sağlayan bir yapay zekâ alt alanıdır. Doğal Dil İşleme, dilbilim, bilgisayar bilimi ve makine öğrenmesi tekniklerini kullanarak metin ve konuşma verilerini analiz eder ve anlamlandırır (Jurafsky & Martin, 2020). Doğal Dil İşlemenin temel amacı, dillerin bilgisayarlar aracılığıyla


işlenmesi ve anlamlandırılmasıdır. Bu yöntem sayesinde, bir konuşmanın veya yazının anlaşılabilirliği ve diller arasında çeviri yapılabilirliği mümkün hale gelmiştir (Adalı, 2012).

Bilgisayarla Görme: Bilgisayarla Görme, bilgisayarların görüntü ve video verilerini anlamasını ve yorumlamasını sağlayan bir

yapay zekâ alt alanıdır. Bilgisayarla görme, görüntü işleme, makine öğrenmesi ve derin öğrenme tekniklerini kullanarak, görsel verileri analiz eder ve yorumlar (Szeliski, 2010).

Robotik: Robotik, fiziksel robotların tasarımı, inşası, işletimi ve kullanımıyla ilgilenen bir yapay zekâ alt alanıdır. Robotlar, çeşitli sensörler ve yapay zeka algoritmaları kullanarak çevreleriyle etkileşime girer ve görevleri yerine getirir (Thrun, 2002). Robotik alanındaki araştırmalar, belirli görevlerin belirlenmiş dizilimlere uygun olarak programlanmış robotlar tarafından gerçekleştirilmesine dayanmaktadır (Barr & Feigenbaum, 1981).

Uzman Sistemler: Yapay zeka alanının alt dallarından en fazla bilineni Uzman Sistemlerdir. Bilgiler, bilgi tabanında depolanır, herhangi bir sorunla karşı karşıya gelme durumunda içerisinde bulunan bilgileri kullanır ve bu bilgiler ışığında bir çıkarım yapar (Naser & Alhabbash, 2016). Uzman Sistemler, belirli bir alanda insan uzmanların bilgi ve deneyimlerini modelleyen ve karar verme süreçlerini destekleyen yazılımlardır. Bu sistemler, bilgi tabanları ve kural tabanları kullanarak, kompleks problemleri çözer. Bu sistemler, özellikle tıbbi teşhis, finansal analiz, mühendislik, bakım ve yasal danışmanlık gibi alanlarda yaygın olarak kullanılır (Jackson, 1998). Aşağıda Şekil 2’de uzman sistemlerin yapısı gösterilmiştir.



Şekil 2. Uzman Sistem Yapısı

Kaynak: Bozdemir, M. (2019). Mekanik tasarım eğitimi için bir uzman sistem uygulaması. *Uludağ University Journal of The Faculty of Engineering*, 219-230.

3. Yapay Sinir Ağları

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 & 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 yapay sinir ağları, paralel bilgi işleme sistemi

olarak düşünülebilirler (Öztemel, 2006, s. 29). Bu ağlara, ilgili olaya ait örnekler üzerinde eğitim verilir. Bu şekilde, örneklerden elde edilen bilgilerle çeşitli genelleştirmeler yapılarak daha önce karşılaşılmamış ya da belirli özellikleri belirlenmemiş olaylara da çözümler üretir (Elmas, 2018).


Yapay Sinir Ağları, talep tahmininde giderek daha fazla popülerlik kazanmaktadır. 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. Bu nedenle, Yapay sinir ağları, finans ve mühendislikten ses tanıma, denetim, meteorolojik yorumlama, elektrik işareti tanıma ve tıp alanlarına kadar birçok farklı uygulama alanında kullanılabilir (Keskenler & Keskenler). Yapay sinir ağı algoritmaları genellikle tahmin,

sınıflandırma, veri yorumlama ve veri filtreleme gibi problemlere uygulanır (Yılmaz, 2019).

Bu sistemlerin en önemli avantajı, karmaşık veri birimlerini öğrenmek için gelişmiş hesaplama ve eğitim tekniklerinden yararlanmalarıdır. Yapay sinir ağları, geçmiş verilerden öğrenerek sorunları tanımlar ve matematiksel algoritmalar oluşturarak gelecekle ilgili tahminlerde bulunur (Hu, 2002, s.74).

3.1. Yapay Sinir Ağlarının Yapısı

Yapay Sinir Ağları, insan sinir hücrelerinin çalışma şekline benzer bir yöntemle işler. 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).



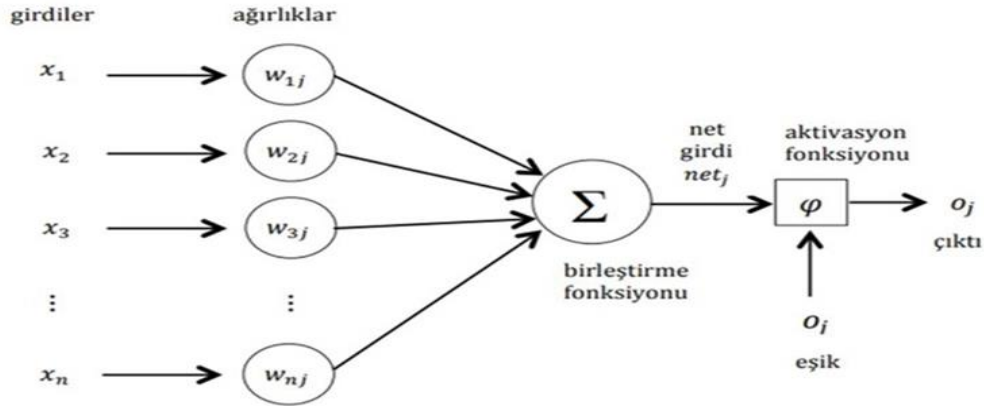
Şekil 3. Yapay Sinir Ağ Örneği

Kaynak: Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.

Yukarıda Şekil 3'te bir yapay sinir ağı örneği verilmiştir. Girdi katmanı, dış dünyadan veya sistemden gelen verileri alır. Bu veriler sayısal formda olmalıdır. Girdi katmanındaki her nöron, gelen verileri belirli ağırlıklarla çarparak ara katmana iletir. Ara katman, gelen verileri çıktı katmanına daha uygun bir formatta iletilmesini sağlar. Ara katmandan gelen veriler, çıktı katmanında birleştirilir ve sonuçları verir.

Yapay sinir ağları, dışarıdan aldığı verileri işleyerek öğrenme sürecini gerçekleştirir ve

öğrendiği bilgileri hafızada tutarak veriler arasındaki ilişkileri belirler. Aşağıdaki şekilde basit bir yapay sinir ağı hücresinin yapısı gösterilmiş olup Yapay Sinir Ağı hücresi, girdi verilerini toplayarak ve aktivasyon fonksiyonunu kullanarak çıktı üretir. Bu çıktı, dış dünyaya sunulabileceği gibi başka bir sinir hücresine girdi olarak da kullanılabilir (Aktaş vd., 2003).



Şekil 4. Yapay Sinir Hücresinin Yapısı

Kaynak: Fırat, M., & Güngör, M. (2004). Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi. *İMO Teknik Dergisi*, 3267-3282.

Yapay Sinir Ağının hücre yapısı beş elemandan oluşmaktadır. Bunlar yukarıda Şekil 4'te görüldüğü gibi girdiler, ağırlıklar, toplama fonksiyonu (birleştirme fonksiyonu), aktivasyon fonksiyonu ve çıkışlardır (Fırat & Güngör, 2004).

Girdiler: Girdi elemanı, ağın dış dünyadan aldığı verileri temsil eder ve modelin işleyişinin ilk adımını oluşturur. Girdi elemanları, verilerin sayısal temsilini sağlar. Bu veriler, modelin öğrenmesi ve işleyebilmesi için sayısal formda olmalıdır. Girdiler genellikle normelleştirilir. Bu işlem, verilerin belirli bir aralıkta tutulmasını sağlar ve modelin daha hızlı ve verimli öğrenmesine yardımcı olur (Bishop, 1995).

Ağırlıklar: Ağırlıklar, nöronlar arasındaki bağlantıların güçlerini belirleyen değerlerdir. Ağırlıklar, ağın öğrenme sürecinde önemli bir rol oynar çünkü girdilerin çıktılara nasıl dönüştürüleceğini belirlerler (Brownlee, 2019).

Toplama Fonksiyonu (Birleştirme Fonksiyonu): Toplama fonksiyonu bir nöronun aldığı girdilerin ağırlıklı toplamını hesaplar. Bu fonksiyon, her bir girdiyi ilgili ağırlığı ile çarpıp ve ardından bu çarpımların toplamını alır. Bu işlem, nöronun aktivasyon fonksiyonuna girmeden önceki ara değerini oluşturur (Bishop, 1995).

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonları, her nöronun çıktısını belirlemek

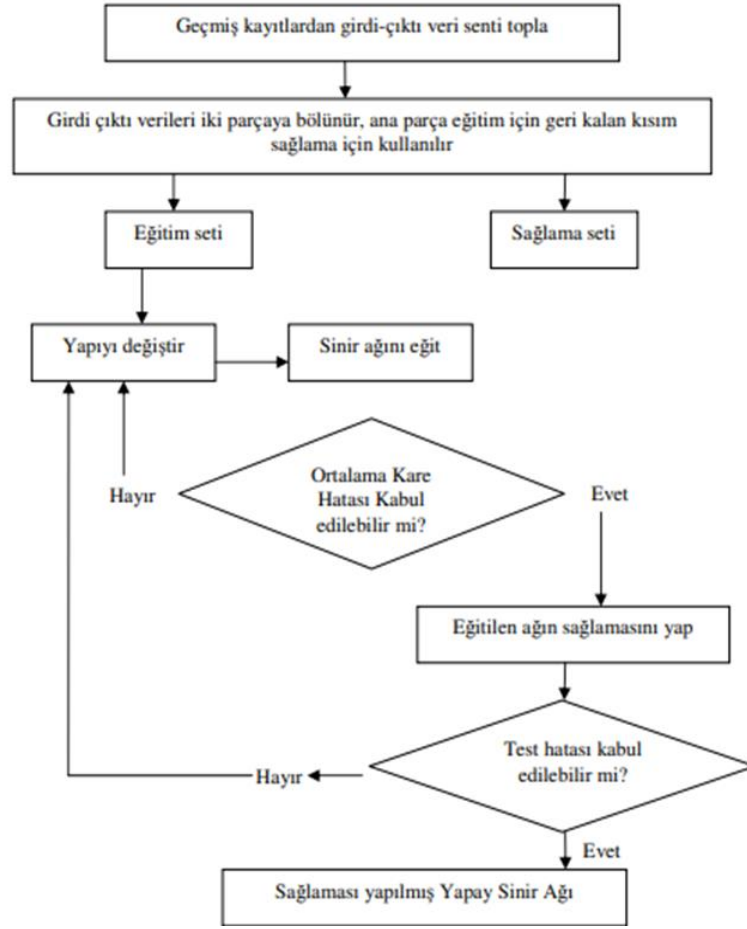
için kullanılan matematiksel fonksiyonlardır. Girdiler, ağırlıklarla çarpıldıktan ve toplandıktan sonra aktivasyon fonksiyonuna geçirilir. Bu fonksiyonlar, YSA'nın karmaşık verileri daha iyi öğrenmesine olanak tanır (Nwankpa vd., 2018).

Çıkışlar: Çıkışlar, ağın en son katmanındaki nöronların aktivasyon fonksiyonları aracılığıyla üretilir ve modelin belirli bir görevi nasıl yerine getirdiğini gösterir. Çıkışlar, YSA'nın en son katmanıdır ve modelin nihai sonuçlarını üretir. Çıkış katmanı, modelin giriş verilerini işleyerek nihai tahminleri veya kararları üretir (Bishop, 1995).

3.2. Yapay Sinir Ağlarının Eğitilmesi

Yapay sinir ağları, tıpkı insanlar gibi örnekler üzerinden eğitim alırlar. Bu öğrenme süreci, bir çocuğun deneyimle öğrenmesine benzetilebilir. Örneğin, bir çocuk sıcak bir nesneye dokunmaması gerektiğini deneyerek öğrenir. Zamanla, daha az sıcak olan bir cisme dokunma cesareti gösterir ve sıcak süt dolu bardağı elleriyle tutabilir. Bu süreçte çocuk, sıcaklık bilgisini öğrenmiş olur. Benzer şekilde, yapay nöronlar da mevcut örnek kümesi üzerinde, girdi ile çıktı arasındaki sinaptik ağırlıkları değiştirerek eğitilirler (Efendigil, 2008, s. 44-46).

Yapay sinir ağlarının eğitiminde, genel olarak aşağıdaki adımlar izlenmektedir:



Şekil 5. Yapay Sinir Ağı'nın Eğitim Aşamaları

Kaynak: Rajpal, P., Shishodia, K. S., & Sekhon, G. (2006). An artificial neural network for modeling reliability, availability and maintainability of a repairable system. *Reliability engineering and system safety*, 809-819


Yukarıda Şekil 5'te yapay sinir ağı eğitimi sürecine ait akışı gösterilmiştir.

3.3. NARX Yapay Sinir Ağ Modeli

NARX (Nonlinear AutoRegressive with eXogenous inputs), yapay sinir ağı olarak zaman serisi tahmininde yaygın olarak kullanılan bir modeldir. NARX modeli, geçmiş değerlere dayalı otoregresif (AR) bileşenlerinin yanı sıra dışsal veya 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 (Wagle & Harikrishnan, 2021).

NARX modeli, tipik olarak 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 (Canan, 2006).



Şekil 6. NARX Yapay Sinir Ağ Örneği

Yukarıda Şekil 6’da bir NARX yapay sinir ağı örneği verilmiştir. Geçmiş zaman serisi verileri ve dışsal girdiler hazırlanır. Veriler normalleştirilerek $y(t)$ ve $x(t)$ değerleri girdi katmanına verilir. Gizli katman, bu değerleri işler ve tahmin edilen $y(t+1)$ değerini üretir. (Diaconescu, 2008)

NARX modeli, birçok zaman serisi probleminde kullanılabilir. Örneğin, finansal veri analizi, endüstriyel süreç kontrolü, hava tahmini gibi alanlarda yaygın olarak kullanılır. NARX modelinin temel avantajlarından biri, otoregresif modelleme ve dışsal değişkenlerin etkisini bir araya getirerek daha kapsamlı bir

tahmin yeteneği sağlamasıdır (Karaatlı vd., 2020).

3.4. Yapay Sinir Ağı Modellerinin Performans Ölçütlerinin Belirlenmesi

Yapay Sinir Ağı modellerinin performansını ölçmek için farklı kriterler bulunmasına rağmen, en önemli performans ölçütü genellikle ağı eğitimi 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 & Shih, 2003; Al-Hamadi & Soliman, 2004; Hamzaçebi, 2011). Çok kullanılan doğruluk ölçütleri aşağıda Tablo 1’de gösterilmektedir.

Tablo 1.
Yapay Sinir Ağı Performans Ölçütleri

Performans Ölçütü	Matematiksel İfadesi
Ortalama Mutlak Sapma (The Mean Absolute Deviation- MAD)	$Y_t = \text{Gerçek Değer}$ $F_t = \text{Elde Edilen Çıktı Değeri olmak üzere,}$ $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)	$MAPE = \frac{1}{n} \sum_{t=1}^n \left \frac{Y_t - F_t}{Y_t} \right \times 100$

Kaynak: Zhang, G., Patuwo, B., & Hu, M. (1998). Forecasting with artificial neural networks: the state of the art. International Journal of Forecasting, 35-62.

4. Yöntem

Bu çalışmanın temel amacı, NARX yapay sinir ağı modeli ile Ocak 2024 ile Aralık 2024 arasındaki 12 aylık otomobil talep tahminini yapmaktır. Veri toplama yöntemi olarak, nicel bir veri toplama yöntemi olan zaman serileri analizi yapılmıştır. Bu amaç doğrultusunda Türkiye’de otomobil üretip en çok satış yapan 6 firma (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) evren olarak seçilmiştir. Çalışmada bu otomobil markalarına ait 01.01.2014-31.12.2023 yılları arasındaki 120 aylık satış verisi dikkate alınmıştır. Bu verilerden yola çıkarak Octave Programı ile

NARX Yapay Sinir Ağı Modeliyle tahmin gerçekleştirilmiştir.

Uygulamada kullanılmasına karar verilen ve otomobil talebi üzerine etkisi olduğu düşünülen bağımsız değişkenler şunlardır:

- Brent Petrol Fiyatı
- Dolar/TL Kuru
- Taşıt Kredi Faiz Oranları
- TÜFE
- Araç Satın Alım Düzeyi
- Otomobil Üretim Adeti

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).

NARX modelinin algoritmasının oluşturulabilmesi için 2014-2024 tarihleri arasındaki verilerden aşağıda Tablo 2’de örnek olarak verilen son bir yılın gerçek verileri, model kurulmadan önce normalizasyon tekniği olarak en çok kullanılan aşağıdaki Formül 1 kullanılarak, Octave programında, tüm veriler [0, 1] arasında normalize edilip programa aktarılmış ve Tablo 3’te gösterilmiştir. (Söylemez, 2020).

x_i girdi değişkeni olmak üzere;

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

Tablo 2.
Örnek Tahminde Kullanılan Giriş Verileri

Tarih	Brent Petrol	Dolar/TL	Taşıt Faiz Oranları	Araç Satın Alım Düzeyi	TÜFE	Otomobil Üretim Adeti	Otomobil Satış Adeti
2023-01	83,42	18,76	25,39	1.071,56	1.203,48	70.723	16.040
2023-02	83,21	18,82	25,34	1.113,87	1.241,33	63.751	28.423
2023-03	79,19	18,97	24,95	1.128,48	1.269,75	87.577	34.930
2023-04	81,32	19,30	25,09	1.175,67	1.300,04	73.637	33.573
2023-05	71,98	19,68	27,80	1.248,13	1.300,60	90.739	35.428
2023-06	74,51	23,06	33,54	1.374,11	1.351,59	75.974	40.761
2023-07	85,22	26,42	40,49	1.593,81	1.479,84	88.214	28.206
2023-08	87,29	26,95	37,93	1.733,03	1.614,31	49.300	22.625
2023-09	95,86	26,94	42,93	1.738,81	1.691,04	87.902	31.996
2023-10	86,82	27,80	46,52	1.732,51	1.749,11	91.511	35.284
2023-11	81,72	28,59	43,92	1.745,49	1.806,50	96.922	36.064
2023-12	77,69	29,02	35,38	1.768,20	1.859,38	76.416	50.092

Tablo 3.
Örnek Tahminde Kullanılan Normalize Edilmiş Veriler


Tarih	Brent Petrol	Dolar/TL	Taşıt Faiz Oranları	Araç Satın Alım Düzeyi	TÜFE	Otomobil Üretim Adeti	Otomobil Satış Adeti
2023-01	0,619533791	0,619012254	0,394516702	0,569049563	0,596577769	0,61195406	0,224529036
2023-02	0,617636429	0,621240253	0,393227525	0,595223072	0,619858043	0,542081738	0,492049775
2023-03	0,581315504	0,626810249	0,382054661	0,604261005	0,637338237	0,78086228	0,632626167
2023-04	0,600560173	0,639064241	0,386065433	0,633453344	0,655968607	0,641157724	0,603309713
2023-05	0,51617275	0,653174898	0,463774136	0,678278029	0,656313044	0,812551362	0,643384895
2023-06	0,539031442	0,778685481	0,628258752	0,756210873	0,687675294	0,664578782	0,758598341
2023-07	0,635796892	0,903453398	0,82732195	0,89212011	0,766557595	0,787246197	0,487361735
2023-08	0,654499458	0,923134051	0,753767261	0,978243387	0,84926561	0,397256018	0,366790529
2023-09	0,731929888	0,922762718	0,897152352	0,981818969	0,896459676	0,78411938	0,569240408
2023-10	0,650252982	0,954697364	1	0,977921708	0,932176598	0,820288228	0,640273937
2023-11	0,604174196	0,984032677	0,925514238	0,985951303	0,967475274	0,874516446	0,657124957
2023-12	0,56776292	1	0,680857159	1	1	0,669008438	0,960184065

5. Bulgular

NARX modeliyle tahmin için Octave programı kullanılmıştır. NARX Ağ Mimarisinde, altı adet girdi ve bir adet çıktı değişkeni bulunmaktadır. Girdi katmanında, ağa sunulan altı bağımsız değişkene ait altı adet girdi işlemci elemanı, çıktı katmanında ise bağımsız değişkene ait bir adet çıktı işlemci elemanı bulunmaktadır. Ara katmandaki gizli işlemci eleman sayısı, modelin kurulumu sırasında, sistemin oluşturduğu ağlardan uygunluk değeri en iyi olan ağdaki katman sayısı kadardır. Çalışma sonucunda 10 nöron sayısına sahip olan ağ uygun bulunmuştur. Bu sayının belirlenmesi için çeşitli işlemci eleman sayıları ile yapılan denemeler sonucunda

açıklayıcılığı yüksek olan bu sayıda karar kılınmıştır.

Bu ağ ayrıca $x(t)$ ve $y(t)$ dizilerinin önceki değerlerini depolamak için bağlantılandırılmış gecikme hatlarını kullanır. $y(t)$, $y(t - 1)$, $y(t - 2)$ 'nin bir fonksiyonu olduğundan, NARX ağının çıkışının ($y(t)$) ağın girişine (gecikmeler yoluyla) geri beslendiği görülmektedir. NARX ağ yapısı genellikle geri beslemeli (feedback) bir yapıya sahiptir. Bu, ağın önceki zaman adımlarındaki çıktıları geri besleyerek tahminlerde bulunmasına olanak tanır. Bu geri besleme mekanizması, modelin daha karmaşık ve dinamik zaman serilerini tahmin etme yeteneğini artırır. Geliştirilen yapay sinir ağında iteratif tahmin yöntemi benimsendiğinden çıktı nöron sayısı birdir.




Şekil 7. NARX Ağ Modelinin Yapısını Gösteren Ekran

Şekil 7'de NARX Ağ Yapısı, gizli katmanda sigmoid transfer fonksiyonu ve çıkış katmanında doğrusal transfer fonksiyonu bulunan iki katmanlı bir ağıdır. Ağ yapısı, 6 girdi, 10 gizli nöron ve 1 çıktıdan oluşmaktadır.

Ağın eğitimi için Levenberg-Marquardt algoritması kullanılmıştır. Programa tanıtılan


veri setinin %70'i (84 veri) ağın eğitilmesi için eğitim seti olarak, %15'i (18 veri) uygun yapay sinir ağı mimarisini belirlemek amacıyla doğrulama seti olarak ve %15'i (18 veri) de ağın performansını ölçmek amacıyla test seti için program tarafından rastgele seçilmiştir.



Şekil 8. NARX Modelinde Hata Histogramunu Gösteren Grafik

Yukarıda Şekil 8'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

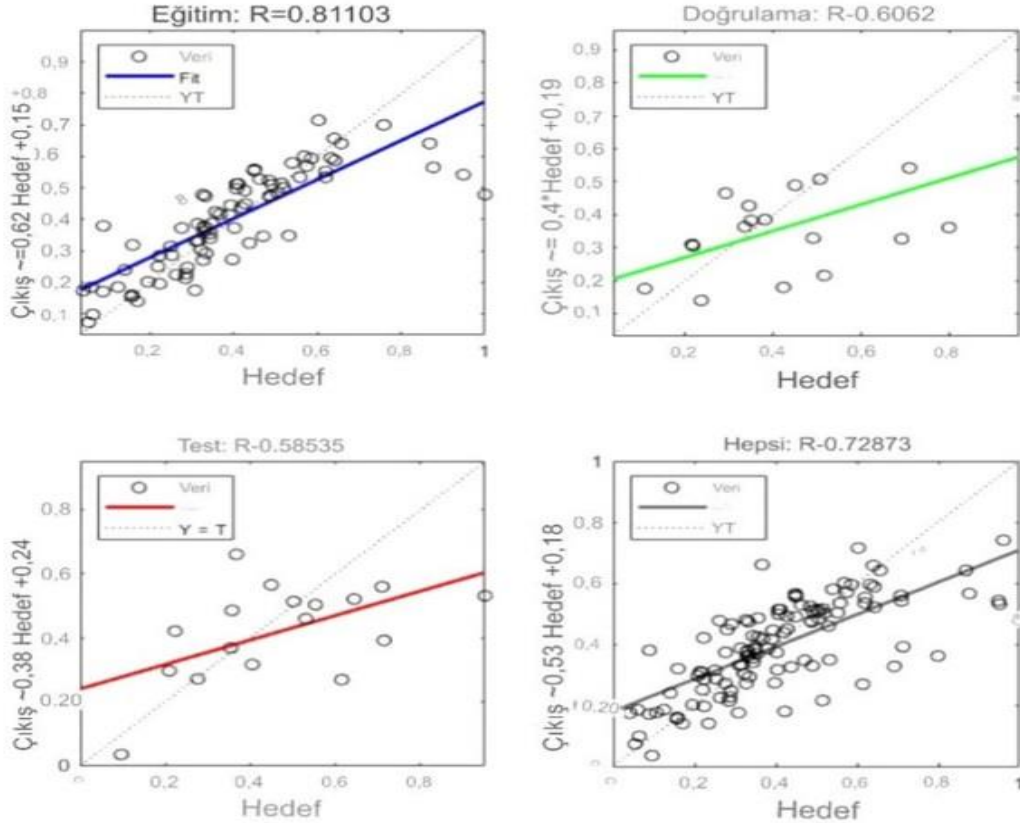
verilerinde olan aykırı değer sayısı en fazla iken eğitim verilerinde en azdır. Bu nedenle modelin, eğitim verilerinde daha doğru tahmin yaptığını söyleyebiliriz.



Şekil 9. NARX Modelinde Doğrulama Performansını Gösteren Ekran

Yukarıdaki Şekil 9'da görüldüğü gibi test seti hatası ve doğrulama seti hatası benzer özelliklere sahiptir. Herhangi bir aşırı uyum meydana geldiği görülmektedir. Epoch

(Yineleme) 6'da (en iyi doğrulama performansının gerçekleştiği yerde) önemli bir aşırı uyum meydana gelmemiştir.



Şekil 10. NARX Modelinde Eğitim, Doğrulama ve Test Verileri İçin Regresyon Grafikleri

Yukarıdaki Şekil 10'da regresyon grafikleri eğitim, doğrulama ve test kümelerine ilişkin hedeflere göre ağ çıktıları gösterir. Mükemmel bir uyum için verilerin, ağ çıktılarının hedeflere eşit olduğu 45 derecelik bir çizgi boyunca düşmesi gerekir. Bu modelde, eğitim seti için uyum kabul edilebilir. Ancak test ve doğrulama

seti için ağ çıktıları hedefleri iyi takip etmiyor ve toplam yanıt için R değeri 0,72873'dur.


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
Ortalama Mutlak Sapma (The Mean Absolute Deviation- MAD)	0,192511339
Hata Kareler Ortalaması (Mean Squared Error-MSE)	0,065403124
Hata Kareler Toplamı (Sum Squared Error-SSE)	7,84837488
Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE)	0,255740344881288
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE)	%12,23

Bu ölçütler, NARX modelinin tahmin yeteneğini ve doğruluğunu değerlendirmek için kullanılır. Düşük MAD, MSE, SSE, RMSE ve

MAPE değerleri, modelin iyi performans gösterdiğini gösterir.



Şekil 11. NARX Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırma Grafiği

NARX modeli tahmin değerleri ile gerçek değerlerin karşılaştırmasının yapıldığı grafik, yukarıda Şekil 11'de gösterilmiştir. Grafikte yatay eksen tarihleri, dikey eksen ise normalleştirilmiş verileri göstermektedir.

2014 ile 2024 yılları arasındaki aylık otomobil satış verileri temel alınarak, gelecekte gerçekleşmesi beklenen Ocak 2024 ile Aralık 2024 arasındaki 12 aylık satış tahmini aşağıda Tablo 5'te gösterilmiştir.

Tablo 5.
NARX Modeliyle Yapılan 12 Aylık Otomobil Satış Tahmin Verileri

Tarih	YSA NARX Modeli ile Otomobil Satış Tahmini
Ocak 24	16.293
Şubat 24	28.755
Mart 24	35.069
Nisan 24	37.912
Mayıs 24	33.105
Haziran 24	39.303
Temmuz 24	27.835
Ağustos 24	24.332
Eylül 24	33.229
Ekim 24	34.179
Kasım 24	42.676
Aralık 24	43.614

6. Sonuç ve Tartışma

Yapay sinir ağları, tahmin modellemesinde geliştirilen yeni yöntemlerden biridir. Bu çalışmada, tahmin modellerinden NARX Yapay Sinir Ağları modeli kullanılmıştır. Uygulama çalışmamızda, 2014-2024 yılları arasında ülkemizde otomobil üretimi yapan 6 firmanın satış adetleri dikkate alınmıştır. Otomobil satışını etkileyen 6 ana faktör olduğu düşünülmüştür. Bunlar; Brent petrol fiyatı, dolar kuru, taşıt kredi faizleri, tüfe, araç alım düzeyi, otomobil üretim âdetidir. Modelin altı girdi, bir çıktı değişkeni ve 10 elemanlı tek gizli katmanı vardır. Kurulan modelin kendi içinde değerlendirilmesi ve performans testleri yapılmıştır.

Korelasyon katsayısının 0.20 olması düşük, 0.80 olması ilişkinin yüksek olduğu anlamına gelmektedir (Akbulut, 2016). MSE ve RMSE birer hata ölçüsü olması nedeniyle düşük sonuçlar, yüksek performansı gösteren ölçülerdir (Wang & Xu, 2004). Lewis (1982) yılında yazdığı eserinde 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. Geliştirilen modele ait test sonuçlarından, Korelasyon değeri 0,72873, tahminin ortalama hata kareleri toplamı (MSE) değeri 0,0654, kareler ortalaması karekök hatası (RMSE) 0,255 ve ortalama mutlak yüzde hata (MAPE) değeri %12,23 olarak bulunmuştur. Bu sonuçlara göre, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğu görülmüştür.

Değirmenci ve Papuççu (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.

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 ağlarıyla talebin doğru tahmin edilmesi, otomobil üreten firmaların gelecekteki tarifelerini hızlı bir şekilde ayarlamalarına olanak tanır. Bu da hizmet kalitesinin artmasına ve müşterilere daha güvenilir bir deneyim sunulmasına yardımcı olabilir. Bu sayede, otomobil üreticisi firmalar rekabet avantajlarını artırabilir ve piyasadaki değişen taleplere daha hızlı yanıt verebilirler. 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.

7. Sınırlılıklar ve Gelecek Çalışmalar

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

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.

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.

8. Araştırma ve Yayın Etiği Beyanı

Araştırmada kurum, kuruluş ve organizasyonlar tarafından yayınlanan ikincil

Kaynakça

- Accenture, (2023). Create your AI-ready workforce with continuous learning, Retrieved from: <https://www.accenture.com/us-en/services/data-ai>. Retrieved date: 10.11.2023
- Akın, E., & Şahin, M. E. (2024). Derin öğrenme ve yapay sinir ağı modelleri üzerine bir inceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.
- Adalı, E. (2012). *Doğal dil işleme ve uygulamaları*. ABC Yayınevi.
- Akbulut, Ö. (2016). *Korelasyon ve regresyon, İstatistiğe giriş II TUBİTAK*. Erişim adresi: <https://esatis.tubitak.gov.tr/ekitap.htm> Erişim tarihi: 18.10.2023
- Akyurt, İ. Z. (2015). Talep tahmininin yapay sinir ağlarıyla modellenmesi: yerli otomobil örneği. *Ekonometri ve İstatistik Dergisi*, (23), 147-157.
- Al-Hamadi, H., & 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. [https://doi.org/10.1016/S0378-7796\(03\)00150-0](https://doi.org/10.1016/S0378-7796(03)00150-0)
- Alpaydin, E. (2021). *Machine learning*. MIT Press.
- Anonim, (2014/a). *Otomotiv Sektör Raporu (2013/1)*. T.C. Bilim Sanayi ve Teknoloji Bakanlığı, Sanayi Genel Müdürlüğü, Sektörel Raporlar ve Analizler Serisi. Erişim adresi: <https://www.sanayi.gov.tr/plan-program-raporlar-ve-yayinlar/sector-raporlari> Erişim tarihi: 22.11.2023.
- Barr, A., & Feigenbaum, Edward, A. (1981). *The Handbook of Artificial Intelligence*. Volume 1, Heuristtech Press.
- Benkachcha, S, Benhra, J., & El Hassani, H. (2015). Seasonal time series forecasting models based on artificial neural network. *International Journal of Computer Applications (0975 – 8887)*, 116(20), 1-14.

veriler kullanıldığı için bilimsel araştırma ve yayın etiği kurulu onayı gerektirmemektedir.

9. Yazarların Makaleye Katkı Oranları

Bu çalışmada, Mehmet Zeki SEÇMEN tarafından literatür incelemesi, yöntem, verilerin toplanması, analizlerin yapılması gerçekleştirilmiş olup, metnin tamamının kontrolü, sonuç ve tartışma kısmında Prof. Dr. Sait PATIR'ın katkısı bulunmaktadır.

10. Çıkar Beyanı

Bu araştırma herhangi bir çıkar çatışmasına konu değildir.

11. Finansman

Bu çalışma için herhangi bir kurumdan destek alınmamıştır. Çalışma için gereken harcamalar yazarlar tarafından karşılanmıştır.

- Bishop, C. M. (1995). *Neural networks for pattern recognition*. Oxford University Press.
- Bozdemir, M. (2019). Mekanik tasarım eğitimi için bir uzman sistem uygulaması. *Uludağ University Journal of The Faculty of Engineering*, 219-230. <https://doi.org/10.17482/uumfd.411684>
- Brown, S., Lammings, R., Bessant J., & Jones, P. (2005). *Strategic Operations Management*. Elsevier Butterworth-Heinemann.
- Brownlee, J. (2019). A gentle introduction to weight initialization in neural networks. *Machine learning mastery*. Retrieved from <https://machinelearningmastery.com/weight-initialization-for-deep-learning-neural-networks/>
- Canan, S. (2006). *Yapay sinir ağları ile GPS destekli navigasyon sistemi* (Doktora tezi). Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Değirmenci, N., & Pabuççu, H. (2016). Borsa İstanbul ve risk primi arasındaki etkileşim: VAR ve NARX model. *The Journal of Academic Social Science*, 4(35), 248-261.
- Diaconescu, E. (2008). The use of NARX neural networks to predict chaotic time series. *WSEAS Transactions on Computer Research*, 3(3), 182-191.
- Elmas, Ç. (2018). *Yapay zeka uygulamaları*. Seçkin Yayıncılık.
- Efendigil, T. (2008). *Müşteri odaklı sistemler için YSA ve bulanık çıkarım tabanlı karar destek sistemi yaklaşımı* (Doktora tezi). Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Firat, M., & 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*.

- Retrieved from: <https://124.im/ya7ux> Retrieved date: 12.12.2023
- Hamzaçebi, C. (2011). *Yapay sinir ağları tahmin amaçlı kullanımı matlab ve neurosolutions uygulamalı*. Ekin Basım Yayın Dağıtım.
- Hocaoğlu, F. O., Kaysal, K., & Kaysal, A. (2015). Yük tahmini için hibrit (YSA ve regresyon) model. *Academic Platform Journal of Engineering and Science*, 3(2), 33-39. <https://doi.org/10.5505/apjes.2015.94695>
- Hu, C. (2002). *Advanced tourism demand forecasting ANN and box-jenkins modelling* (Doctoral Dissertation). Purdue University, MI, USA.
- Huang, S., & Shih, K. (2003). Short-Term load forecasting via ARMA model identification including non-gaussian process considerations. *IEEE Transactions on Power Systems*, 673-679. <https://doi.org/10.1109/TPWRS.2003.811010>
- Ian, G., Yoshua, B., & Aaron, C. (2016). *Deep learning*. MIT Press.
- İleri, H., & Horasan, A. (2010). Küresel rekabet ortamında işletmelerin teknoloji ve ar-ge yönetimlerinin rekabete etkileri üzerine araştırma ve örnek bir uygulama. *Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi*, 13(1-2), 171-190.
- Jackson, P. (1998). *Introduction to expert systems* (3rd ed.). Addison Wesley.
- Jones, M. (2009). *Machine learning applications in modern business*. Tech Publications.
- Jurafsky, D., & Martin, J. H. (2020). *Speech and language processing* (3rd ed.). Pearson.
- Karaatlı, M., Demirci, E., & Baykaldı, A. (2020). Ticari kredi faiz oranlarının ysa NARX ve VAR modelleri ile öngörülmesi. *İşletme Araştırmaları Dergisi*, 12(3), 2327-2343. <https://doi.org/10.20491/isarder.2020.979>
- Kesici, B., & Yıldız, M. (2016). Kalite kontrol faaliyetlerinde yapay zekâ kullanımı ve bir otomotiv yan sanayisinde uygulanması. *Yalova Sosyal Bilimler Dergisi*, 307-323.
- Keskenler, M. F., & Keskenler, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.
- Lewis, C. D. (1982). *Industrial and business forecasting methods*. Butterworths Publishing.
- ODMD, (2023). *Pazar-Otomobil Hafif Ticari*. Erişim adresi: https://www.odmd.org.tr/web_2837_1/neuralnetwork.a_spx?type=35 Erişim tarihi: 5.11.2023
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- Naser, S., & Alhabbash, M. (2016). Male infertility expert system diagnoses and treatment. *American Journal of Innovative Research and Applied Sciences*, 2(4), 181-192.
- Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). Activation functions: comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
- Özdal, M. A. (2023). Görüntü içeriği sınıflandırmasında yapay zekânın rolü ve uygulamaları. *Van İnsani ve Sosyal Bilimler Dergisi*, 1(6), 37-61. <https://doi.org/10.62068/visbid.1352901>
- Öztemel, E. (2006). *Yapay sinir ağları*. Papatya Yayıncılık.
- Rajpal, P., Shishodia, K. S., & Sekhon, G. (2006). An artificial neural network for modeling reliability, availability and maintainability of a repairable system. *Reliability Engineering and System Safety*, 809-819. <https://doi.org/10.1016/j.res.2005.08.004>
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Pirim, A. G. H. (2006). Yapay zekâ. *Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93. <https://doi.org/10.19168/jyu.72783>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Rende, E., Özdemir, A. S., & Yılmaz, R. (2016). *Makine öğrenmesi ve uygulamaları*. Türkiye Bilişim Vakfı.
- Sağroglu, S., Besdok, E., & Erler, M. (2003). *Muhendislikte yapay zeka uygulamaları-I*. Ufuk Yayıncılık.
- Szeliski, R. (2010). *Computer vision: Algorithms and applications*. Springer.
- Söylemez, Y. (2020). Çok katmanlı yapay sinir ağları yöntemi ile altın fiyatlarının tahmini. *Sosyoekonomi*, 271-291. <https://doi.org/10.17233/sosyoekonomi.2020.04.13>
- Sanayi ve Teknoloji Bakanlığı, (2023). *Faaliyet raporları*. Erişim adresi: <https://www.sanayi.gov.tr/plan-program-raporlar-ve-yayinlar/faaliyet-raporlari> Erişim tarihi: 01.11.2023
- TCMB, (2023). *Türkiye Cumhuriyeti Merkez Bankası Elektronik Veri Dağıtım Sistemi*. Erişim adresi: <https://evds2.tcmb.gov.tr/index.php?evds/serieMarket> Erişim tarihi: 5.11.2023
- Thrun, S. (2002). Robotic mapping: A survey. G. Lakemeyer & B. Nebel (Eds.), In *Exploring artificial intelligence in the new millennium* (pp. 1-35). Morgan Kaufmann.
- TÜBİTAK, (2001). *Bilim ve Teknik Dergisi*, 38-43.
- Ulgen, K. E. (2024, Mart 14). *Makine öğrenimi bölüm-6 (regresyon)*. Erişim adresi: <https://medium.com/>.
- Yıldırım, H., & Karaatlı, M. (2022). Yapay sinir ağları NARX modeli ile elma üretim miktarının öngörülmesi. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (42), 1-29.
- Yıldız, B., & Ustaoglu, M. (2012). Optimal production model for evs manufacturing process in Turkey: a comparable case of EMQ/JIT production models for EVs' battery production. *Procedia-Social and Behavioral Sciences*, 58, 1482-1490. <https://doi.org/10.1016/j.sbspro.2012.09.1135>
- Yılmaz, A. (2019). *Yapay zeka*. İstanbul: KODLAB Yayın Dağıtım.
- Yücesoy, M. (2011). *Temizlik kağıtları sektöründe yapay sinir ağları ile talep tahmini* (Doktora Tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Wagle, S. A., & Harikrishnan, R. (2021). A bibliometric analysis of plant disease classification with artificial intelligence based on Scopus and WOS. *Library Philosophy and Practice*, 1-27.
- Wang, W., & Xu, Z. (2004). A heuristic training for support vector regression. *Neurocomputing*, 61, 259-275. <https://doi.org/10.1016/j.neucom.2003.11.012>
- Wawrzyński, P. (2014). *Fundamentals of artificial intelligence*. Warsaw University of Technology Publishing House.
- Zhang, G., Patuwo, B., & Hu, M. (1998). Forecasting with artificial neural networks. *The State of The Art. International Journal of Forecasting*, 35-62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)