

## Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

## Makine öğrenimi ile binek otomobil ihracat tahmini: MLP ve RBF modeli kullanımı

Yunus Emre Gür  
Kamil Abdullah Eşidir  
Şahin Göktuğ Kaldırımçı

Arş. Gör. Dr., Fırat Üniversitesi, [yegur@firat.edu.tr](mailto:yegur@firat.edu.tr), [0000-0001-6530-0598](https://orcid.org/0000-0001-6530-0598)

Dr., Fırat Kalkınma Ajansı, [abdullahesidir@yahoo.com](mailto:abdullahesidir@yahoo.com), [0000-0002-8106-1758](https://orcid.org/0000-0002-8106-1758)

Arş. Gör., Atatürk Üniversitesi, [ksahin@atauni.edu.tr](mailto:ksahin@atauni.edu.tr), [0009-0009-5925-9053](https://orcid.org/0009-0009-5925-9053)

Corresponding author/Sorumlu yazar: Yunus Emre Gür ✉ [yegur@firat.edu.tr](mailto:yegur@firat.edu.tr)

## Öz

Yapay Sinir Ağları (YSA), makine öğrenmesi alanında yaygın olarak kullanılan etkili bir yöntemdir ve tahmin yapmada başarılı sonuçlar sağlayabilir. YSA, biyolojik sinir sisteminden ilham alınarak matematiksel bir model oluşturur. Bu çalışmada, Türkiye'nin aylık binek otomobil ihracatını tahmin etmek için Yapay Sinir Ağı yaklaşımlarından Multilayer Perceptron (MLP) ve Radial Basis Function (RBF) modelleri kullanılmıştır. Geliştirilen sinir ağı modelleri, Türkiye'nin aylık binek otomobil ihracatını tahmin etmek için tasarlanmıştır. Bağımlı değişken olarak binek otomobil ihracat değeri kullanılırken, bağımsız değişkenler arasında Türkiye'nin aylık binek otomobil ithalatı, Amerikan Doları Kuru, Türkiye ithalatı, yeni otomobil satış adedi, motorlu kara taşıtları üretim endeksi ve yurt dışı üretici fiyat endeksi gibi faktörler bulunmaktadır. Türkiye İstatistik Kurumu ve Türkiye Cumhuriyet Merkez Bankası'ndan elde edilen aylık veriler (Ocak 2010 - Kasım 2023, 167 ay süresince) kullanılarak, Aralık 2023 ile Haziran 2024 arasındaki 7 aylık binek otomobil ihracat değerleri tahmin edilmiştir. İki farklı sinir ağı modelinin performansı karşılaştırılarak, tahminlerin farklılıkları ve sonuçları analiz edilmiştir. Bu çalışma, MLP modelinin RBF modele göre daha iyi sonuçlar verdiği sonucuna ulaşmıştır. Elde edilen sonuçlar, gelecekte binek otomobil ihracatının nasıl şekillenebileceği hakkında önemli bilgiler sunmaktadır.

**Anahtar Kelimeler:** Otomobil İhracatı, Yapay Sinir Ağları, Multilayer Perceptron (MLP), Radial Basis Function (RBF) ve İhracat Tahmini

JEL Kodları: C13, C32, C58

## Passenger car export forecasting with machine learning: Using MLP and RBF model

## Abstract

Artificial neural networks (ANN) are an effective method widely used in the field of machine learning and can provide successful results in making predictions. ANN creates a mathematical model inspired by the biological nervous system. This study uses multilayer perceptron (MLP) and radial basis function (RBF) models to predict Turkey's monthly passenger car exports. The neural network models are designed to forecast Turkey's monthly passenger car exports. The dependent variable is the value of passenger car exports. In contrast, the independent variables include Turkey's monthly passenger car imports, the USD exchange rate, Turkey's imports, the number of new car sales, the motor vehicle production index, and the foreign producer price index. Using monthly data obtained from the Turkish Statistical Institute and the Central Bank of the Republic of Turkey (January 2010–November 2023, 167 months), passenger car export values for seven months between December 2023 and June 2024 are estimated. The differences and results of the forecasts are analyzed by comparing the performance of two different neural network models. This study concludes that the MLP model gives better results than the RBF model. The obtained results provide important information about how passenger car exports may be shaped in the future.

**Keywords:** Automobile Export, Artificial Neural Networks, Multilayer Perceptron (MLP), Radial Basis Function (RBF) and Export Forecasting

JEL Codes: C13, C32, C58

## Extended Summary

The automotive sector has a key role in economies with its high-added value, employment, and contribution to technological development. This sector generates a large business volume and supports economic growth by receiving materials from various industries. Export increases have been observed even during times of crisis, but events such as the 2008 global crisis and the 2020 COVID-19 pandemic caused temporary declines in exports and imports. Turkey's automobile industry is strategically important for

## How to cite this article / Bu makaleye atıf vermek için:

Gür, Y. E., Eşidir, K. A., & Kaldırımçı, Ş. G. (2024). Makine öğrenimi ile binek otomobil ihracat tahmini: MLP ve RBF modeli kullanımı. *KOCATEPEİİBFD*, 26(Özel Sayı), 17-34. <https://doi.org/10.33707/akuiibfd.1426338>

its economic future and has become an important European production and export center. The Customs Union Agreement with the EU in 1996 gave the sector a significant boost. While exports and imports have steadily increased, it should not be forgotten that imports are also significant and sometimes lead to a trade deficit. This study aims to forecast Turkey's monthly passenger car exports using MLP and RBF artificial neural network models. These forecasts are based on data such as Turkey's automobile exports and imports, exchange rates, automobile sales, and production indices. The forecasts have the potential to anticipate economic developments and guide policymakers and industry participants in strategic planning.

This study forecasts passenger car exports using Python and artificial neural networks. With the right data and model architecture, artificial neural networks can predict export values. Model parameters and network structure should be set appropriately for model performance. The forecasters use MLP and RBF. The models are based on Turkey's monthly passenger car export value. Independent variables include Turkey's monthly passenger car imports, US dollar exchange rate, imports, new car sales, motor vehicle production index, and foreign producer price index. Monthly data from the Turkish Statistical Institute (January 2010–November 2023, 167 months~13 years) is used to estimate passenger car export values from December 2023 to June 2024.

As this study shows, there are many variables that affect vehicle exports. These include a country's economy, growth, exchange rates, consumer preferences, market trends, and export-import dependence. These variables can affect vehicle demand, design, production, and current account balance. In this study, TurkStat data is used to construct a model that includes dependent and independent variables. Moreover, the Dickey-Fuller test determines the stationarity of the data set variables. Using this statistical procedure, each variable in a multivariate data set should be independently tested for stationary time series. Additionally, time series analysis of independent variable data was conducted using ARIMA models, yielding forecasts for the independent variables for the period from December 2023 to June 2024. Python software was employed to forecast independent variable data. This software facilitated the automatic stationarization of the dataset. Given the inherent inability of MLP and RBF analyses to handle missing data, an approach was adopted where independent variable data for the prediction period were complete.

Regression, correlation, and mean percentage error (MAPE) values are considered performance measures. The MLP model gave better results in regression, correlation, and MAPE values than RBF; therefore, it was concluded that it modeled the relationships in the data set better and that its predictions were more accurate. Both models provided a fair comparison using the same number of observations (N = 167). In both models, 117 samples (70%) are used for training, and 50 samples (30%) are used for testing. The MAPE value was calculated as 12% in the MLP model and 18% in the RBF model. The motor vehicle production index was the most effective independent variable in both models.

The MLP model forecasts passenger car exports between 743 million USD and 957 million USD, while the RBF model forecasts 817 million USD. MLP's forecasts are more accurate, especially in March and November 2023. The RBF model underpredicts in some months but is closer to the export values. Both models reveal seasonal effects and general trends and perform differently over time. We conclude the analysis with the December 2023–June 2024 forecasts of both models. These forecasts suggest that further research is needed to understand how the models perform across market conditions and timeframes. The comparison reveals that MLP outperforms RBF. The MLP model can be improved and adjusted in the future. Additional features, data, and hyperparameter settings can be considered to improve model accuracy. Obtain more and better data to improve the model's performance. Adding new data can help the model provide more complete findings. Adding exogenous elements to the model, such as the economy, exchange rates, and international markets, can also improve future forecasts. This research only compared MLP and RBF models, but future studies could compare other machine learning or statistical models. This technique determines the most appropriate forecasting strategy. Hence, more powerful models, more data, and external variables can help the automobile industry make better decisions.

## Giriş

Otomotiv sektörü, ekonomilerde kilit bir rol oynamaktadır çünkü yüksek katma değer yaratması, istihdama doğrudan ve dolaylı katkı sağlaması ve teknolojik gelişimi öncülük etmesi gibi faktörler taşımaktadır. Otomotiv sektörü, demir-çelik, lastik-plastik, tekstil, cam, boya, elektrik-elektronik gibi birçok sektörden malzeme ve hizmet tedarik ederken, pazarlama, bakım-onarım, yedek parça satışı, finansman ve sigortacılık gibi geniş bir yelpazede iş hacmi oluşturarak ekonomik büyümeyi destekler. Bu sektör aynı zamanda, gelişmiş ve gelişmekte olan ekonomilerde büyümeyi destekleyen önemli bir faktör olarak ortaya çıkar ve teknolojik ilerlemeyi hızlandırarak diğer sektörlerin büyümesine katkıda bulunur (Karakaş, 2019: 318).

Oluşturduğu temel ile bu sektör, demir-çelik, tekstil, cam, lastik, petro-kimya gibi farklı sektörlerden malzemeleri alarak bunları işleyip çeşitli ürünlere dönüştürmekte ve sonuç olarak tarım, ulaştırma ve turizm gibi birçok sektörde kullanılmak üzere önemli bir rol üstlenmektedir. İhracat tarafında bakıldığında, 1992-2020 arası otomotiv sektörünün sürekli bir ihracat artışı gösterdiği söylenebilir. Kriz dönemleri, örneğin 2000 ve 2001 yıllarında olduğu gibi, sektör ihracatında bile artışlar görmüştür. Fakat 2008'deki küresel kriz, ihracatta düşüşe neden olmuştur. Bu düşüşe rağmen, sonrasında bir toparlanma yaşanmıştır. İç pazarda ise talebe

bağlı olarak ithalat önemli ölçüde yükselmiştir. 1994'teki ekonomik kriz döneminde iç talep azaldığından ithalat düşmüş; fakat sonraki yıllarda yeniden artış göstermiştir. Benzer şekilde, 2001 yılında yaşanan kriz döneminde de benzer bir düşüş gözlemlenmiştir (Nur ve Çalbörü, 2023: 40).

Türkiye'nin otomobil endüstrisi, ülkenin ekonomik geleceği için stratejik bir öneme sahiptir. Teknoloji ve bilgi temelli üretimler ulusal ve yerel kalkınmanın en önemli unsurudur (Yoğunlu, 2022). Avrupa'nın önde gelen ülkeleri arasında yer alarak otomobil üretimi ve ihracatında başarılı bir konum elde etmiştir. Otomobil ihracatı, Türkiye'nin dış ticaret dengesine olumlu etkiler sağlamakta ve aynı zamanda istihdam olanakları sunarak ülkenin ekonomik büyümesini desteklemektedir. 1980'li yılların ortalarında benimsenen serbest piyasa politikalarıyla birlikte Türkiye'de ithalat oranlarında belirgin bir artış gözlenmiştir. Bu dönemde alınan liberal ekonomi politikaları, yerli üretimi zorlamış ve dışarıdan gelen ürünlere olan talebi artırmıştır. Ancak bu durum, özellikle otomotiv sektörü gibi stratejik öneme sahip sektörlerde üretim ve ihracat rakamlarını olumsuz etkileyerek dış ticaret açığının artmasına neden olmuştur. Buna rağmen, Türkiye'nin 1996 yılında Avrupa Birliği ile imzaladığı Gümrük Birliği Anlaşması, otomotiv sektörüne dönük önemli sonuçlar doğurmuştur. Bu anlaşma sayesinde Türkiye, Avrupa'dan birçok üreticinin üretim üssü haline gelmiş ve otomotiv üretiminde büyük bir ivme kazanmıştır. Türkiye'nin en büyük otomobil ihracatı yaptığı ülkeler arasında Almanya, Fransa, Birleşik Krallık, İtalya ve İspanya yer almaktadır (Çokşen, 2023: 16-17).

Bununla birlikte, Harmonize Sistem (HS) kodu, uluslararası ticarete mal ve hizmetleri sınıflandırmak için kullanılan bir kodlama sistemidir. Çalışmada, TÜİK veri tabanından alınan 8703 HS4 kodlu "Binek otomobilleri ve insan taşımak üzere imal edilmiş diğer motorlu taşıtlar (steysin vagonlar ve yarış arabaları dâhil)" dış ticaret verileri kullanılmıştır. Tablo 1'de, Türkiye'nin 2000 yılı ile 2022 yılları arası döneme ait binek otomobil dış ticaret değerleri yer almaktadır. Türkiye'nin binek otomobil ihracatında, 2000 yılından itibaren sürekli bir artış trendi görülmektedir. İhracat değeri 2000 yılında 629 milyon dolar iken, 2022 yılında 9 milyar 269 milyon dolara yükselmiştir. 2017 yılında 11 milyar 815 milyon dolar ile binek otomobilde ihracat zirvesi görülmüştür. İthalat değerlerinde ise dalgalanma görülmektedir. 2000 yılında 2 milyar 596 milyon dolar olan ithalat değeri, 2022 yılında 7 milyar 808 milyon dolara yükselmiştir. En yüksek ithalat değeri ise 2011 yılında 8 milyar 477 milyon dolar olarak kaydedilmiştir.

**Tablo 1.**Yıllara Göre Türkiye Binek Otomobil Dış Ticaret Değerleri (HS: 8703)

| Yıllar | İhracat (Milyon USD) | İthalat (Milyon USD) | Yıllar | İhracat (Milyon USD) | İthalat (Milyon USD) |
|--------|----------------------|----------------------|--------|----------------------|----------------------|
| 2000   | 629                  | 2.596                | 2012   | 6.069                | 7.251                |
| 2001   | 973                  | 588                  | 2013   | 6.856                | 9.130                |
| 2002   | 1.298                | 814                  | 2014   | 7.256                | 7.721                |
| 2003   | 2.198                | 2.220                | 2015   | 6.900                | 9.227                |
| 2004   | 3.934                | 4.215                | 2016   | 8.356                | 9.842                |
| 2005   | 4.373                | 4.298                | 2017   | 11.815               | 8.607                |
| 2006   | 5.645                | 4.271                | 2018   | 12.442               | 5.906                |
| 2007   | 6.840                | 4.749                | 2019   | 11.898               | 3.382                |
| 2008   | 7.474                | 4.554                | 2020   | 9.536                | 7.762                |
| 2009   | 6.086                | 4.267                | 2021   | 9.497                | 6.698                |
| 2010   | 6.210                | 6.822                | 2022   | 9.269                | 7.808                |
| 2011   | 6.486                | 8.477                |        |                      |                      |

**Kaynak:** TÜİK, 2024.

Türkiye, binek otomobil dış ticaretinde aktif bir ihracatçı konumunda bulunmaktadır. Bununla birlikte, ithalatın da ihracat kadar kritik bir rol oynadığı ve bazen ticaret açığının ortaya çıktığı unutulmamalıdır. Yukarıdaki Tablo 1 incelendiğinde, özellikle 2013-2016 döneminde ithalat değerlerinde gözle görülür bir artış meydana gelmiş ve bu dönemde dış ticaret açığı daha belirgin hale gelmiştir. Diğer yandan, 2008 küresel mali krizi sırasında, Türkiye'nin ihracat ve ithalat değerlerinde bir düşüş yaşanmıştır. Ancak, krizin etkileri geçici olmuş ve hızla toparlanma görülmüştür. 2020'de ise dünya çapında yaşanan COVID-19 pandemisi, otomobil sektöründe daralmaya neden olmuştur (Çokşen, 2023: 31). Bu dönemde Türkiye'nin binek otomobil ihracat ve ithalat değerleri de olumsuz yönde etkilenmiştir. Türkiye'nin binek otomobil ve diğer motorlu taşıtlar ticaretinde ihracatın ithalatı aştığı gözlenmektedir. Bu durum, Türkiye'nin bu sektörde uluslararası pazarda rekabetçi olduğunu ve dış talebi karşılayabildiğini göstermektedir. Bununla birlikte, binek otomobil ithalatının da dikkatle izlenmesi gereken yüksek değerlere sahip olduğu unutulmamalıdır.

Bu çalışmanın amacı, MLP ve RBF yapay sinir ağı modellerini kullanarak Türkiye'nin aylık binek otomobil ihracatını tahmin etmektir. Bu tahminlerde bağımlı değişken olarak Türkiye'nin aylık binek otomobil ihracatı kullanılmıştır. Bağımsız değişkenler ise; Türkiye'nin aylık binek otomobil ithalatı, aylık Amerikan Dolar Kuru, aylık Türkiye ithalatı, aylık yeni otomobil satış adedi, motorlu kara taşıtları üretim endeksi ve yurt dışı üretici fiyat endeksi değerlerini içermiştir. Bu veriler, Türkiye İstatistik Kurumu ve Türkiye Cumhuriyet Merkez Bankası veri kaynaklarından temin edilmiştir. Toplamda Ocak 2010 ile Kasım 2023 arası 167 aya, yani 13 yıla ait veriler kullanılmıştır. Bu veriler doğrultusunda kullanılan modeller, Aralık 2023 ile Haziran 2024 arasındaki 7 aylık dönem için

binek otomobil ihracat değerlerini tahmin etmek için kullanılmıştır. İki farklı sinir ağı modelinin performansı kıyaslanmış ve tahmin sonuçları arasındaki farklar yorumlanmıştır.

Bununla birlikte, bu çalışma, binek otomobil ihracatının gelecekteki değerlerini tahmin ederek, olası ekonomik gelişmeleri önceden tespit etmeyi hedeflemektedir. Bu öngörüler, dış ticaret dengesi, istihdam ve ekonomik büyüme gibi alanlarda rehberlik sağlayabilir. Ayrıca, ekonomi politika yapımcılarına ve sektör katılımcılarına gelecekteki olası senaryoları değerlendirme ve uygun stratejiler geliştirme konusunda yardımcı olabilir. Elde edilen sonuçlar, işletmelerin ve karar alıcıların binek otomobil ihracatını etkileyen faktörleri daha iyi anlamalarına ve bu faktörleri göz önünde bulundurarak daha bilinçli kararlar almalarına imkân tanıyabilir. Endüstri açısından bakıldığında ise, bu tür modellerle sektörün gelecekteki performansını tahmin etmek, işletmelerin rekabetçilik çabalarına destek sunabilir. Genel olarak, bu çalışma, otomotiv sektörünün ekonomik önemini ve gelecekteki gelişimini anlamak, planlamak ve yönlendirmek bakımından büyük bir önem taşımaktadır.

## 1. Literatür İncelemesi

Makine öğrenmesi algoritmaları ile tahminleme çalışmaları, akademik literatürde oldukça geniş bir yer kaplamaktadır ve çeşitli alanlarda yoğun şekilde kullanılmaktadır. Makine öğrenmesi, veri analizi, tahmin, sınıflandırma ve kümeleme gibi birçok farklı problemin çözümünde etkili bir yaklaşım olarak öne çıkmaktadır. Özellikle büyük veri setlerinin olduğu alanlarda, gelecekteki değerleri tahmin etmek veya belirli olayların olasılığını değerlendirmek amacıyla makine öğrenmesi modelleri sıkça kullanılmaktadır. Makine öğrenmesi algoritmaları, karmaşık ilişkileri anlama ve gelecekteki olayları tahmin etme konularında büyük veri setleri üzerinde yapılan analizlerde ve öğrenme süreçlerinde önemli bir rol oynamaktadır. Bu sebeple, literatürde makine öğrenmesi tabanlı tahminleme çalışmalarının sayısı oldukça fazladır. Bu bağlamda, son yıllarda yapılan bazı örnek çalışmalara göz atıldığında;

Karaatlı vd. (2012)'nin çalışmasında, Türkiye'de yeni otomobil satış rakamlarının yapay sinir ağları (YSA) yöntemi kullanılarak tahmin edilmesi amaçlanmıştır. Çalışma, Ocak 2007'den Haziran 2011'e kadar olan aylık verileri kapsamakta ve otomobil satışlarını etkileyen çeşitli makroekonomik göstergeleri bağımsız değişken olarak kullanmaktadır. Araştırmada, gayri safi yurtiçi hasıla, reel kesim güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici güven endeksi, dolar kuru ve zaman gibi değişkenler ele alınmıştır. Çalışmanın sonuçları, YSA modelinin otomobil satış tahmininde kullanılabilecek etkili bir yöntem olduğunu göstermektedir.

Akyurt (2015)'un çalışmasında, Ocak 2011 - Eylül 2015 döneminde aylık yerli otomobil satış verileri kullanılarak, geri yayılım algoritması ile eğitilmiş ileri beslemeli yapay sinir ağı modeli uygulanmıştır. Modelin amacı, Türkiye'de üretilen yerli otomobillere olan talebi tahmin etmektir. Çalışmanın sonuçları, mevsimsel etkilerden arındırılmış veri seti kullanıldığında, gecikme uzunluğunun 2 ve gizli nöron sayısının 7 olduğu modelin en iyi tahmin sonuçlarını verdiğini göstermiştir. Bu bulgular, yerli otomobil satışlarına ilişkin gelecekteki taleplerin tahmin edilmesinde yapay sinir ağlarının etkili bir araç olabileceğini ortaya koymaktadır.

Topal (2019)'un çalışmasında, Türkiye'deki bir otomobil markasının satış miktarlarının tahmini için çevrimiçi tüketici bütünleşmesi ve arama motoru verileri kullanılarak yapay sinir ağları metodolojisi uygulanmıştır. Çalışma, Facebook marka sayfası ve Google Trends üzerinden elde edilen verileri kullanarak, 2012-2017 yılları arasında oluşturulan gönderiler ve bu gönderilere yapılan etkileşimler ile arama trend verilerine dayanmaktadır. Veriler Min-Max yöntemiyle normalleştirilmiş ve Bayesian Regülasyon geri yayılım yöntemiyle analiz edilmiştir. Çalışmanın sonuçları, çevrimiçi tüketici bütünleşmesi ve arama motoru verilerinin, yapay sinir ağları yöntemiyle Türkiye'deki bir otomobil markasının satış miktarlarını tahmin etmede etkili kullanılabileceğini göstermiştir. Analiz, %74 korelasyon ve %1 ortalama hata değeri ile yüksek bir tahmin başarısı sağlamıştır. Bu bulgular, sosyal medya ve arama motoru verilerinin, tüketici eğilimlerini ve markaya olan ilgiyi yansıttığı ve satış tahminlerinde değerli bir kaynak olabileceğini ortaya koymaktadır. Bu sonuçlar, pazarlama ve satış stratejilerinin geliştirilmesinde veriye dayalı yaklaşımların önemini vurgulamaktadır.

Karakaş (2019)'ın çalışmasında, Türkiye'nin otomotiv sektöründen elde edilen ihracat gelirlerini tahmin etmek için ARIMA modeli geliştirilmiştir. 2013-2018 yılları arasındaki aylık ihracat verileri kullanılarak, en uygun modelin ARIMA (1,2,1)(0,1,1) olduğu bulunmuştur. Bu model kullanılarak 2019 yılı için aylık ihracat geliri tahminleri yapılmış ve gerçekleşen verilerle karşılaştırıldığında, modelin doğru tahminler yaptığı gözlemlenmiştir. Modelin başarısı, düşük ortalama mutlak yüzde hata (MOYH) değeri ile desteklenmiştir, bu da modelin yüksek doğruluk derecesine sahip olduğunu gösterir. Ayrıca, otomotiv ihracat gelirlerine etki eden diğer değişkenlerin de analizi için farklı yöntemlerin kullanılabileceği ve bu yöntemlerin sonuçlarının kıyaslanabileceği belirtilmiştir.

Yurtsever (2022)'nin yapmış olduğu bir çalışmada, Ocak 2003 - Nisan 2021 arasında ABD'deki aylık otomobil satışlarının tahmini için derin öğrenme yöntemlerinden biri olan LSTM (Uzun Kısa Süreli Bellek) modeli kullanılmıştır. Çalışma, çeşitli ekonomik göstergeleri (ham petrol fiyatı, tüketici fiyat endeksi, işsizlik oranı gibi) kullanarak otomobil satışlarını tahmin etmeye odaklanmıştır. Bulgular, LSTM modelinin, ekonomik göstergelere dayalı çok değişkenli zaman serilerinde tahmin doğruluğu

açısından iyi performans sergilediğini göstermektedir. Beşinci model en düşük RMSE ve MAPE değerlerini elde ederek en iyi sonucu vermiştir. Bu sonuçlar, LSTM modelinin otomobil satış tahmininde etkili bir araç olabileceğini göstermektedir.

Kayakuş vd. (2023), yapmış oldukları bir çalışmada, Türkiye'deki hafif ticari araç satışlarının makine öğrenmesi yöntemleriyle tahmin edilmesi amaçlanmıştır. Araştırmada, yapay sinir ağları, çoklu doğrusal regresyon ve karar ağaçları regresyonu olmak üzere üç farklı makine öğrenmesi tekniği kullanılmıştır. Veri seti, Ocak 2006 - Haziran 2022 dönemini kapsayan aylık verilerden oluşmaktadır. Çalışmanın sonuçları, yapay sinir ağlarının hafif ticari araç satış tahmininde en başarılı yöntem olduğunu göstermiştir. Bu bulgular, hafif ticari araç satış tahminlerinde makine öğrenmesi yöntemlerinin etkili bir şekilde kullanılabileceğini ortaya koymaktadır.

Lasya vd. (2023), belirli parametrelere dayanarak kullanılmış arabanın fiyatını tahmin etmek amacıyla birden fazla makine öğrenmesi modeli kullanmışlardır. Bir dizi strateji bir araya getirilerek, kullanılmış bir arabanın maliyetini tahmin eden bir tahmin modeli oluşturulmuştur. Çalışmada doğrusal regresyon ve regresyon ağaçları gibi Sinir Ağı Modelleri uygulanmıştır. Önceki müşteri bilgileri ve bir dizi göstergelere dayanarak kullanılmış bir arabanın maliyetini tahmin edebilecek sentetik veriler oluşturulmuştur. Dolayısıyla, müşterilerin geçmiş verilerini kullanarak yeni sonuçlar tahmin edebilmiş ve tahmin edilen sonuçlar karşılaştırılmıştır.

## 2. Araştırmanın Metodolojisi

Bu çalışmada, yapay sinir ağları ile binek otomobil ihracat tahmini yapılırken python yazılımı kullanılmıştır. Yapay sinir ağları, doğru veri setleri ve uygun model yapılandırması ile ihracat değer tahminlerinde başarılı sonuçlar verebilmektedir. Tasarlanan modelin performansı için, model parametreleri ve ağ yapısının dikkatli biçimde ayarlanması önem arz etmektedir. Tahmin modelleri olarak MLP ve RBF modelleri kullanılmıştır. Tasarlanan modellerin bağımlı değişkeni, Türkiye'nin aylık binek otomobil ihracat değeridir. Bağımsız değişkenler ise Türkiye aylık binek otomobil ithalatı, aylık Amerikan Dolar kuru, aylık Türkiye ithalatı, aylık yeni otomobil satış adedi, motorlu kara taşıtları üretim endeksi ve yurt dışı üretici fiyat endeks (YD-ÜFE) değeridir. Türkiye İstatistik Kurumu'ndan (TÜİK) alınan aylık veriler (Ocak 2010 - Kasım 2023, 167 ay~13 yıl) kullanılarak, Aralık 2023 ile Haziran 2024 arasında gerçekleşecek 7 aylık binek otomobil ihracat değerleri tahmin edilmiştir.

### 2.1. Model Kurulumu ve Değişkenlerin Seçimi

Otomobil sektöründeki ihracatı etkileyen faktörler çeşitlilik gösterebilmektedir. Model kurulumu için literatürdeki bazı yayınlar ve akademik çalışmalar incelendiğinde, otomobil ihracatını etkileyebilecek faktörler tarafımızca tespit edilmiş aşağıdaki gibi sıralanmıştır:

**Ekonomik Durum ve Büyüme:** Bir ülkenin ekonomik performansı, otomobil ihracatını etkileyen en önemli faktörlerden biridir. Ekonomik büyüme, tüketici güveni ve gelir düzeyi otomobil talebini etkileyebilir (Ray, 2012).

**Döviz Kuru:** Yabancı para birimleri karşısındaki yerel para biriminin değeri, otomobil ihracatını etkileyen faktörlerden biridir. Örneğin, yerel para biriminin zayıflığı ihracatı artırabilir (Gagnon ve Knetter, 1995).

**Tüketici Tercihleri:** Hedef pazarların tüketici tercihleri ve ihtiyaçları, otomobil modellerinin tasarımını ve özelliklerini etkilemektedir (Gomez-Ibanez ve Harrison, 1982).

**Talep ve Pazar Trendleri:** İhracatçılar, hedef pazarlardaki talep ve tüketici tercihleri konusunda bilgi sahibi olmalıdır. Pazar trendleri, ürün tasarımından üretim süreçlerine kadar birçok yönü etkileyebilir (İnançlı ve Konak, 2011).

**İhracatın İthalata Bağımlılığı:** Otomotiv endüstrisinin yoğun bir şekilde teknolojiye odaklı üretimi, bu sektörde sermaye malları ve ithal edilen ara malzemelere olan talebi artırmıştır (Gerni vd., 2007). Aynı zamanda, Türkiye'deki bu sektörün ileriye dönük güçlü bağlantıları ve yerli ürünler ile ithal mallar arasındaki yüksek derecedeki değiştirme esnekliği, sektöre dair neredeyse her türlü parametre değişikliğinin cari hesap dengesini doğrudan etkileyebileceği anlamına gelmektedir (Aktaş, 2007).

Bu faktörler, otomobil ihracat tahminlerinde önemli bir rol oynamaktadır. Analizde, TÜİK verileri kullanılmıştır. Yukarıdaki bilgiler doğrultusunda; otomobil ihracat tahmini için kullanılacak olan bağımsız değişkenleri tarafımızca oluşturulmuştur. Bağımsız değişkenler, Türkiye aylık binek otomobil ithalatı, aylık Amerikan Dolar kuru, aylık Türkiye ithalatı, aylık yeni otomobil satış adedi, motorlu kara taşıtları üretim endeksi ve yurt dışı üretici fiyat endeks (YD-ÜFE) değeri olarak tarafımızca belirlenmiştir. Bu bağımsız değişkenlerin seçiminde birçok önemli neden bulunmaktadır. Döviz kurları, bir ülkenin para biriminin başka bir para birimi karşısındaki değerini temsil etmektedir ve uluslararası ticaret üzerinde doğrudan bir etkiye sahiptir. Bir ülkenin para birimi değer kaybettiğinde, o ülkenin ürünleri yabancı alıcılar için daha ucuz hale gelir, bu da ihracatın artmasına yol açabilir. Tersine, para birimi değer kazandığında, ürünler daha pahalı hale gelir ve bu da ihracatın azalmasına neden olabilir. Bu ilişki, döviz kurlarının otomobil ihracatı tahminlerinde önemli bir değişken olmasının nedenidir (Williamson, 2009). Buna ek olarak, otomobil sektörünün ekonomi üzerindeki etkisi ve tüketici talebi, üretim ve ithalat gibi faktörlerin sektör performansını nasıl etkileyebileceği üzerine yapılan çalışmalar, seçilen değişkenlerin önemini vurgulamaktadır. Örneğin, Deloitte Insights'ın otomobil sektörü üzerine yaptığı bir analiz,

pandemi sürecinde otomobil sektörünün nasıl etkilendiğini ve tüketici talebinin, üretim ve ithalatın bu süreçte nasıl değiştiğini detaylandırmaktadır (Samaddar ve Bachman, 2022). Bu tür analizler, aylık otomobil ithalatı ve ihracatının, yeni otomobil satışlarının ve üretim endekslerinin, bir ülkenin ekonomik performansını ve otomobil sektörünün sağlığını nasıl etkileyebileceğine dair içgörüler sunmaktadır.

Bununla birlikte, bu değişkenlerin seçimi, otomobil ihracatı tahminlerini doğrudan etkileyebilecek bir dizi faktörü kapsamaktadır. Örneğin, aylık binek otomobil ithalatı ve ihracatı, küresel ve yerel ekonomik koşulların yanı sıra tüketici talebinin ve rekabetçi dinamiklerin bir yansımasıdır. Aylık yeni otomobil satışları, ekonomik büyüme, tüketici güveni ve satın alma gücü gibi makroekonomik göstergelerle yakından ilişkilidir. Motorlu kara taşıtları üretim endeksi, sektörün üretim kapasitesi ve teknolojik yetkinliği hakkında bilgi vermektedir (Athukorala ve Veeramani, 2019). Yurtdışı üretici fiyat endeksi (YD-ÜFE), bir ülkenin ihracat fiyatlarının zaman içindeki değişimlerini ölçer ve bu da mal ve hizmetlerin uluslararası rekabetçiliğini etkileyebilir. Bir ülkenin YD-ÜFE'si artarsa, bu genellikle o ülkenin mallarının ve hizmetlerinin yurt dışında daha pahalı hale geldiğini gösterir, bu da ihracat talebinin azalmasına neden olabilir. Ters durumda, YD-ÜFE'nin düşmesi, ürünlerin yurt dışında daha ucuz hale gelmesi ve ihracat talebinin artması anlamına gelir. Bu bağlamda, YD-ÜFE'nin otomobil ihracatı tahminlerinde kullanılması, uluslararası pazarlardaki fiyat rekabetçiliği değişikliklerini yansıtır (de Soyres vd., 2020).

Bu değişkenlerin her biri, otomobil ihracatı tahminlerinde önemli bir rol oynamaktadır çünkü birbiriyle ve genel ekonomik durumla karmaşık ilişkiler içindedir. Bu nedenle, tahmin modellerinde bu değişkenler kullanılarak, otomobil ihracatının gelecekteki trendlerinin daha doğru bir şekilde çizilebileceği ve hem yerel hem de uluslararası pazar dinamiklerinin kapsamlı bir analizinin sağlanabileceği düşünülmektedir. Bu yaklaşım, ekonomik tahminler ve uluslararası ticaret üzerine yapılan genel çalışmalarla uyumludur ve sektörün genel performansını anlamada kritik bir öneme sahiptir.

Bununla birlikte, Python yazılımında, “describe()” fonksiyonu kullanılarak seçilen değişkenlerin minimum, maksimum, ortalama, standart sapma, ve yüzdelik değerleri (örneğin, %25, %50, %75) hesaplanmıştır. Ayrıca “mode()” fonksiyonu ile de her bir sütunun modu (en sık görülen değer) hesaplanmıştır. Bu istatistiksel bilgiler Tablo 2’de gösterilmiştir.

**Tablo 2.** Değişkenlere Ait İstatistiksel Bilgiler

| Değişkenler    | Otomobil Satış Adedi | MKT Üretim Endeksi | Amerikan Dolar Kuru | Türkiye İthalatı  | Yurt Dışı ÜFE | Otomobil İhracat | Otomobil İthalat |
|----------------|----------------------|--------------------|---------------------|-------------------|---------------|------------------|------------------|
| Veri Miktarı   | 167                  | 167                | 167                 | 167               | 167           | 167              | 167              |
| Ortalama Değer | 51.971,01            | 103,82             | 5,94                | 20.037.934.326,41 | 327,45        | 733.708.113,13   | 684.340.362,31   |
| Standart Sapma | 17.139,46            | 27,92              | 6,19                | 4.239.147.609,36  | 339,56        | 237.112.692,28   | 317.378.875,18   |
| Minimum Değer  | 18.249               | 38                 | 1,43                | 11.691.248.394    | 99,41         | 132.736.062      | 67.981.047       |
| %25'lik Değer  | 40.165               | 82,75              | 1,91                | 17.173.453.502,5  | 121,63        | 562.121.092,5    | 490.175.547      |
| Medyan (%50)   | 49.861               | 102,8              | 3,47                | 19.318.698.045    | 170,41        | 669.935.193      | 650.331.963      |
| %75'lik Değer  | 62.874               | 124,75             | 6,845               | 21.462.821.857    | 358,91        | 941.542.040      | 840.839.971      |
| Maksimum Değer | 95.960               | 166,2              | 28,64               | 31.837.035.091    | 1590,07       | 1.275.289.384    | 1.965.232.835    |
| Mod            | 18.249               | 95,5               | 1,79                | 11.691.248.394    | 99,72         | 132.736.062      | 67.981.047       |

**Açıklama:** Minimum Değerler: Her bir değişken için gözlemlenen minimum değerler.

Maksimum Değerler: Her bir değişken için gözlemlenen maksimum değerler.

Ortalama Değerler: Her bir değişkenin ortalama (mean) değerleri.

Standart Sapma: Her bir değişkenin değerlerinin dağılımının ne kadar yaygın olduğunu gösteren standart sapma değerleri.

Medyan (%50): Her bir değişken için medyan değeri. Veri setindeki değerler küçükten büyüğe sıralandığında, ortadaki değer medyandır.

Yüzdelik Değerler (%25 ve %75): Her bir değişken için alt ve üst çeyrek değerleri. Veri dağılımının %25'lik ve %75'lik dilimlerdeki değerlerdir.

Mod: Her bir değişken için en sık gözlemlenen değerdir.

## 2.2. Dickey-Fuller Testi

Bu çalışmada, verisetindeki değişkenlerin durağan olup olmadığını kontrol etmek için Dickey-Fuller testi uygulanmıştır. Dickey-Fuller testi, bir zaman serisinin durağan olup olmadığını belirlemek için kullanılan bir istatistiksel testtir (Paparoditis ve Politis, 2018). Bu çalışmada kullanılan veriseti birden fazla değişkenli bir veri seti olduğundan, her bir değişken için ayrı ayrı Dickey-Fuller testi uygulamak gerekmektedir. Bu test, bir zaman serisinin birim kök içerip içermediğini kontrol etmektedir. Dickey-Fuller testinin temel formu şu şekildedir:

$$\Delta y_t = a + \beta_t + \gamma y_{t-1} + \delta \Delta y_{t-1} + \epsilon_t \quad (1)$$

Burada,  $\Delta$  fark operatörüdür.  $y_t$ , zaman serisinin t zamanındaki değeridir.  $a$ , sabittir (eğer modelde sabit yoksa bu terim yoktur).

$\beta_t$ , zamana bağlı eğilimi temsil eder (eğer modelde zamana bağlı eğilim yoksa bu terim yoktur).  $\gamma$ , birim kök testinin ana parametresidir.  $\delta\Delta y_{t-1}$ , geçmiş dönemlerin farklarının katsayısıdır.  $\epsilon_t$ , hata terimidir. Testin ana odak noktası  $\gamma$  katsayısıdır. Eğer  $\gamma = 0$  ise bu zaman serisinin bir birim köke sahip olduğu ve durağan olmadığı anlamına gelir. Eğer  $\gamma < 0$  ise bu zaman serisinin durağan olduğunu gösterir. Test, genellikle  $H_0: \gamma = 0$  (null hipotezi, yani zaman serisi durağan değildir) ve  $H_1: \gamma < 0$  (alternatif hipotez, yani zaman serisi durağandır) arasında ayırım yapar (Phillips ve Perron, 1998).

Dolayısıyla, birim kök varsa, zaman serisi durağan değildir. Bu bilgiler doğrultusunda, aşağıdaki hipotezler oluşturulmuştur;

$H_0$ : Seri durağan değildir (birim kök içermektedir).

$H_1$ : Seri durağandır (birim kök yoktur).


Gözlem serilerinin p-değerleri %1, %5 veya %10 düzeyinde anlamlı ise  $H_0$  reddedilmektedir. Her bir değişken için Dickey-Fuller test sonuçları Tablo 3'te gösterilmiştir.

**Tablo 3.** Değişkenlere Ait Dickey-Fuller Testi Sonuçları

| Değişkenler                                      | p-değerleri | Test İstatistiği | %1'lik Kritik Değer | %5'lik Kritik Değer | %10'luk Kritik Değer |
|--|-------------|------------------|---------------------|---------------------|----------------------|
| Binek Otomobil İhracat Değeri                    | 0.00371     | -3.21821         | -2.77354            | -2.88049            | -2.57687             |
| Binek Otomobil İthalat Değeri                    | 0.00435     | -4.15348         | -3.47327            | -2.88019            | -2.57234             |
| Amerikan Dolar Kuru                              | 0.00278     | -5.15348         | -3.47412            | -2.88074            | -2.57701             |
| Aylık Türkiye İthalatı                           | 0.00394     | -4.60110         | -3.47382            | -2.88062            | -2.57694             |
| Aylık Yeni Otomobil Satış Adedi                  | 0.00497     | -3.60110         | -3.47363            | -2.88048            | -2.57671             |
| Motorlu Kara Taşıtları Üretim Endeksi (2015=100) | 0.00417     | -5.35454         | -3.47512            | -2.88058            | -2.57344             |
| Yurt Dışı ÜFE                                    | 0.00490     | -5.95748         | -3.47468            | -2.88749            | -2.57774             |

Tablo 3'teki Dickey-Fuller test sonuçlarına göre, analiz edilen tüm değişkenler için Dickey-Fuller test istatistikleri ve p-değerleri %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerlerin altındadır. Bu sonuçlar, tüm değişkenlerin zaman içinde sabit bir ortalamaya ve varyansa sahip olduğunu yani durağan olduğunu göstermektedir. Bu, ekonometrik modellerin kurulması ve zaman serisi analizlerinin yapılması için önemlidir, çünkü durağan veriler bu tür analizlerde daha güvenilir sonuçlar sağlamaktadır. Durağanlık, bu değişkenlerin zaman içinde sabit bir ortalamaya, sabit bir varyansa ve sabit bir otokorelasyona sahip olduğunu gösterir, bu da onları öngörülebilir ve analiz için uygun hale getirmektedir.

Ayrıca, çalışmanın veri setindeki her değişken ile diğer faktörler arasındaki ilişkiyi gösteren korelasyon matrisi Şekil 1'de gösterilmektedir. İki değişken arasında pozitif bir korelasyon olduğunda pozitif bir bağlantı, negatif bir korelasyon olduğunda ise negatif bir bağlantı vardır. Korelasyon değeri 1 veya -1 olduğunda değişkenler arasında tam bir bağlantı vardır. Bu korelasyon matrisini analizi python yazılımında pandas ve matplotlib kütüphanelerini kullanarak yapılmıştır.



Korelasyon matrisindeki 1.00 değerleri, değişkenlerin kendileriyle mükemmel pozitif ilişkisini gösterir; bu, matrisin simetrik yapısından kaynaklanan beklenen bir sonuçtur. “Yurtdışı ÜFE” ile “Amerikan Dolar Kuru” arasındaki ilişki dışında, diğer 1.00 değerleri her değişkenin kendisiyle olan ilişkisini ifade etmekte ve özel bir ilişkiyi göstermemektedir. Diğer yüksek değerler, değişkenler arasındaki güçlü ilişkilere işaret etmektedir. Örneğin, “Otomobil ihracatı” ve “Motorlu Kara Taşıtları Üretim Endeksi” arasında 0.81 gibi yüksek bir pozitif korelasyon vardır. Bu durumda, 0.81 gibi yüksek bir pozitif korelasyon değeri, otomobil ihracat miktarındaki artışların motorlu kara taşıtları tüketim endeksinde de benzer artışlara yol açtığını veya bu endekste artışların otomobil ihracatını pozitif yönde etkilediğini gösterir. Başka bir deyişle, bir ülkede otomobil ihracatı ne kadar yüksekse, o ülkenin motorlu kara taşıtları tüketim endeksi de o kadar yüksek olma eğilimindedir. Bu ilişki, otomobil ihracatının bir ülkenin ekonomik performansı ve tüketici güveni gibi faktörlerle ilişkili olabileceğini düşündürmektedir. Diğer taraftan, “Otomobil İhracatı” ve “Otomobil Satış Adedi” arasında 0.55 gibi orta seviye bir korelasyon göze çarpmaktadır. Bu, ithalat miktarlarının arttıkça ihracatın da eğilim olarak arttığına işaret etmektedir, fakat bu ilişki mükemmel değildir ve diğer faktörlerin de ihracat üzerinde etkili olabileceğini göstermektedir. Ayrıca, “Amerikan Dolar Kuru” ve “TR İhracatı” arasında 0.73 gibi oldukça yüksek bir korelasyon bulunmaktadır. Bu, dolar kurundaki değişikliklerin TR ihracat miktarlarını önemli ölçüde etkileyebileceğini düşündürülebilir. Ancak, korelasyon nedensellik anlamına gelmez ve bu durumda dolar kurunun ihracat üzerindeki doğrudan etkisinin olup olmadığı, ek analizlerle daha ayrıntılı incelenmelidir. Bu matrisin bir diğer ilginç noktası ise “Yurt Dışı ÜFE” ve “Otomobil İthalatı” arasındaki 0.48’lik korelasyondur. Bu orta düzeyde pozitif korelasyon, yurt dışındaki üretici fiyat endeksinin artışı ile otomobil ithalatı artışı arasında bir ilişki olabileceğini gösterse de, bu ilişki yine de nispeten zayıftır. Son olarak, en düşük korelasyon değerlerinden biri olan 0.10, “Otomobil İhracatı” ve “Otomobil Satış Adedi” arasında görülmektedir. Bu, beklenmedik bir sonuç olarak kabul edilebilir çünkü genellikle üretim miktarı ile ihracat miktarı arasında daha yüksek bir ilişki beklenmektedir. Ancak, bu düşük korelasyon, bu iki değişken arasındaki ilişkinin diğer faktörlerden etkilenebileceğini ya da veri setindeki belirli bir zaman dilimi için özgül bir durumu yansıttığını gösteriyor olabilir. Genel olarak, bir korelasyon matrisinin yorumlanması sırasında sadece sayısal değerlere değil, aynı zamanda bu değerlerin temsil ettiği ekonomik ve sosyal bağlamlara da dikkat etmek önemlidir. Bu matristeki korelasyonlar, değişkenlerin birbiriyle olan ilişkilerini anlamada bir başlangıç noktası sağlasa da, daha derin analizler ve kontekst anlayışı gereklidir. Örneğin, ekonometrik modeller, zaman serisi analizleri ve nedensellik testleri gibi daha gelişmiş istatistiksel yöntemler, bu korelasyonların altında yatan nedenleri ve mekanizmaları anlamak için kullanılabilir.

Çalışmada, Python yazılımı kullanılarak aylık binek otomobil ihracat değerlerinin tahmini hedeflenmiştir. Bu nedenle gerekli Python kütüphanelerinin içe aktarılması çalışmanın ilk adımdır. Bu kütüphaneler modellerin oluşturulmasını, verilerin işlenmesini ve sonuçların görselleştirilmesini sağlamaktadır. NumPy, Pandas, Matplotlib, Scikit-learn ve TensorFlow kullanılan kütüphanelerdir. Pandas, veri kümesini bir Excel dosyasından yüklemek için kullanılmıştır. Ek olarak, NaN değerleri “data.dropna()” kullanılarak veri setinden çıkarılmıştır. Daha sonra, veri çerçevesi bağımsız değişkenlere (X) ve bağımlı değişkenlere (Y) bölünmüştür. Verileri normalleştirmek için min-max ölçeklendirme yöntemi kullanılmıştır. Bu, her bir özelliği 0 ile 1 arasında bir değere dönüştürerek modelin performansını artırmaktadır.

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

Veri standardizasyonundan sonra, veri seti, modellerin eğitimi ve testi için uygun bir biçimde %70’i eğitim ve %30’u test olmak üzere alt kümelerine ayrılmıştır. Veri setinin %70 eğitim ve %30 test olarak ayrılması kararını literatüre dayandırmak gerekirse, Kohavi (1995) ve Breiman vd. (1984) gibi çalışmalar, veri setlerinin eğitim ve test olarak nasıl bölüneceği üzerine kapsamlı rehberlik sağlamaktadır. Bu çalışmalar, modelin genelleme kabiliyetini doğru bir şekilde test etmek için yeterli miktarda verinin ayrılmasının önemini vurgulamaktadır. %70-%30 ayrımı, veri setinin boyutuna ve modelin karmaşıklığına bağlı olarak genellikle iyi bir denge sağladığı için yaygın bir uygulamadır. Bu oran, modelin yeterli miktarda eğitim verisi ile eğitilmesini ve modelin performansının etkili bir şekilde değerlendirilmesini sağlamaktadır. Bununla birlikte, tahminlerin gerçek değerlere ne kadar yakın olduğu ve hangi bağımsız değişkenlerin tahminler üzerinde daha fazla etkisi olduğu da değerlendirilmiştir. Doğru ve güvenilir sonuçlar için sinir ağı modellerinin dikkatli bir şekilde oluşturulması, veri kalitesi ve özelliklerin seçimi önemlidir. MLP ve RBF modellerinin performansları karşılaştırılmış, analiz sonucu elde edilen tahminlerin farkları ve sonuçları yorumlanmıştır. R<sup>2</sup>, MAPE, MSE, RMSE gibi tahmini istatistiksel ölçütler kullanılarak modellerin performansı değerlendirilmiştir. R<sup>2</sup> (R-kare), modelin verilerin varyansını ne kadar iyi açıkladığını gösterir ve 0 ile 1 arasında değer almaktadır; 1, modelin veriyi mükemmel açıkladığını gösterir. MAPE (Ortalama Mutlak Yüzde Hata), tahminlerin gözlemlerden ne kadar sapma gösterdiğinin yüzdesel bir ölçüsüdür. MSE (Ortalama Kare Hata) ve RMSE (Kök Ortalama Kare Hata), hataların karelerinin ortalamasıdır; düşük değerler daha iyi tahminler anlamına gelmektedir. Bu metriklerin kullanımı ve önemi, tahmin modelinin performansını değerlendirme konusunda kritik öneme sahiptir ve geniş çapta kabul görmüş standartlardır. Hyndman ve Koehler’in (2006) çalışması, tahmin hatalarını değerlendirmede kullanılan çeşitli metriklerin önemini ve nasıl kullanılacağını detaylandırmaktadır. Özellikle, model performansını değerlendirme konusunda önemli bir kaynaktır. Bu istatistiksel veriler denklem 3, 4, 5 ve 6 kullanılarak hesaplanabilmektedir.



$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

$$MAPE = \frac{\sum_{t=1}^n \frac{u_t}{\bar{y}_t} * 100}{n} \quad (4)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (6)$$

Bununla birlikte, otomobil ihracat değerlerinin gelecek tahmini için, Arima modelleri kullanılarak bağımsız değişkenlere ait verilerin zaman serileri analizi yapılmış ve Aralık 2023 ile Haziran 2024 arasındaki dönem için bağımsız değişkenlerin gelecek tahminleri elde edilmiştir. Bağımsız değişkenlerin gelecek tahmini için python yazılımı kullanılmıştır. Öte yandan, MLP ve RBF analizlerinde yapısı gereği eksik veriler ile çalışmadığından ötürü, tahminleme işleminde, tahmin dönemine ait bağımsız değişken verilerinin eksik olmadığı bir yaklaşım benimsenmiştir.

### 2.3. Multi-Layer Perceptron (MLP)

MLP, "Çok Katmanlı Algılayıcı" (Multi-Layer Perceptron) anlamına gelmektedir ve yapay sinir ağları ailesine aittir. Bir MLP, birden fazla katmandan (genellikle bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı) oluşan bir beslemeli ileri yayılım (feedforward) sinir ağıdır. Her katman, bir önceki katmandan gelen sinyalleri alır, bir aktivasyon fonksiyonu uygular ve sonucu bir sonraki katmana iletir. MLP'ler, karmaşık problemleri modellemek ve çok boyutlu verilerden tahminler yapmak için kullanılmaktadır (Wilamowski, 2009).

Bir MLP'nin temel bileşeni olan her bir nöron (veya birim), girdilerin ağırlıklandırılmış toplamını alır, buna bir bias (sabit) ekler ve sonucu bir aktivasyon fonksiyonundan geçirerek çıktı üretir. Matematiksel olarak bir nöronun çıktısı şöyle ifade edilebilir:

$$a_j = f(\sum_{i=1}^n W_{ij}x_i + b_j) \quad (7)$$

Burada,  $a_j$   $j$ . nöronun aktivasyonunu veya çıktısını,  $f$  aktivasyon fonksiyonunu (örneğin, sigmoid, tanh veya ReLU),  $W_{ij}$ ,  $i$ . Girdi ile  $j$ . nöron arasındaki ağırlığı,  $x_i$ ,  $i$ . girdi değerini,  $b_j$ ,  $j$ . nöronun bias değerini temsil etmektedir.

MLP'deki her katman, bir önceki katmandaki tüm nöronlardan sinyal alır ve bu sinyalleri ağırlıklarla çarparak toplar. Her bir nöronun çıktısı, sonraki katmana girdi olarak aktarılır. Bu süreç, çıkış katmanına kadar devam eder. Çıkış katmanında, final aktivasyon fonksiyonu genellikle problemin türüne (regresyon, sınıflandırma, vb.) göre seçilir. Örneğin, bir regresyon problemi için çıkış katmanında genellikle lineer bir aktivasyon fonksiyonu kullanılırken, sınıflandırma problemlerinde softmax aktivasyon fonksiyonu tercih edilebilir. MLP'lerde öğrenme süreci, genellikle geri yayılım (backpropagation) algoritması ve bir optimizasyon algoritması (örneğin, stokastik gradyan inişi) kullanılarak gerçekleştirilir. Bu süreçte, ağırlık çıkışlarındaki hatalar hesaplanır ve bu hatalar, ağırlık değerlerini güncelleyerek minimize edilmektedir (Boughrara vd., 2016). Ağırlıkların güncellenmesi matematiksel olarak şu şekilde ifade edilebilmektedir:

$$w_{ij}^{(yeni)} = w_{ij}^{(eski)} - \eta \frac{\partial E}{\partial w_{ij}} \quad (8)$$

Burada,  $w_{ij}^{(yeni)}$  güncellenmiş ağırlık değeri,  $w_{ij}^{(eski)}$  mevcut ağırlık değeri,  $\eta$  öğrenme oranı (learning rate),  $E$  hata fonksiyonu (örneğin, MSE),  $\frac{\partial E}{\partial w_{ij}}$  hata fonksiyonunun ağırlığa göre kısmi türevidir.

Bu optimizasyon süreci, ağırlık tahminleri gerçek değerlere yaklaştığı ve hata oranı kabul edilebilir bir seviyeye düştüğü noktaya kadar iteratif olarak devam etmektedir. Ağırlık performansı, genellikle bir doğrulama (validation) veri seti üzerinde değerlendirilir ve aşırı öğrenme (overfitting) gibi sorunlara karşı koruma sağlamak için çeşitli düzenleme (regularization) teknikleri uygulanabilir.

### 2.4. Radial Basis Function (RBF)

Radial Basis Function (RBF) Sinir Ağı, girdi verileri ve çıkışlar arasındaki ilişkiyi modellemek için radyal baz fonksiyonları kullanan bir tür yapay sinir ağıdır. RBF ağları, özellikle fonksiyon yaklaşımı, zaman serisi tahmini, sınıflandırma ve sistem tanımlama gibi alanlarda kullanılır. Bu ağlar genellikle üç katmandan oluşur: bir giriş katmanı, bir gizli katman ve bir çıkış katmanı (Yingwei vd., 1998).

RBF ağlarının temel bileşeni, gizli katmandaki her bir nöronun bir radyal baz fonksiyonuna sahip olmasıdır. Bu fonksiyon, genellikle bir Gauss fonksiyonu şeklinde olup, girdi vektörü ile nöronun merkezi arasındaki uzaklığa bağlı olarak bir değer döndürür. Yani, her nöron girişler ile kendi merkezi arasındaki uzaklığa göre aktivasyon sağlamaktadır. RBF sinir ağının tipik bir matematiksel formülasyonu şöyledir:

$$\phi(x) = \exp\left(-\frac{\|x-c\|^2}{2\sigma^2}\right) \quad (9)$$

Burada,  $x$  girdi vektörü,  $c$  merkez vektörü (her bir RBF nöronu için bir merkez vektörü bulunur),  $\sigma$  ölçek parametresi (bazen her bir RBF nöronu için farklı olabilir),  $\|x - c\|$  girdi vektörü ile merkez vektörü arasındaki öklid mesafesi,  $\phi(x)$  radial basis fonksiyonunun çıktısıdır ve aktivasyon fonksiyonu olarak işlev görmektedir.

RBF sinir ağındaki her bir gizli katman nöronu için, girdi ile merkez arasındaki bu mesafeyi hesaplayarak bir aktivasyon değeri üretilir. Sonra, bu aktivasyonlar ağırlıklandırılarak çıkış katmanına iletilir ve bir çıktı üretilir. Çıkış genellikle, gizli katman nöronlarının çıktılarının ağırlıklı toplamı olarak hesaplanmaktadır:

$$y(x) = \sum_{j=1}^N w_j \cdot \phi(\|x - c_j\|) \quad (10)$$

Burada,  $y(x)$  RBF ağının girdi  $x$  için hesapladığı tahmin edilen değer,  $N$  gizli katmandaki nöron sayısı,  $w_j$  çıkış katmanına bağlanan  $j$ . nöronun ağırlığı,  $\phi(\|x - c_j\|)$   $j$ . nöronun aktivasyon fonksiyonudur.

Bu ağırlıklar genellikle bir çeşit öğrenme algoritması kullanılarak optimize edilmektedir. En yaygın yöntemlerden biri, merkezleri ve ölçek parametrelerini seçmek için bir önbelleme (clustering) algoritması kullanmaktır, daha sonra çıkış ağırlıklarını en küçük kareler yöntemi ile ayarlamaktır. Bu yaklaşım, RBF ağının veri üzerinde iyi bir genelleme yapmasını ve veri setindeki karmaşık ilişkileri öğrenmesini sağlar. RBF ağlarının avantajı, özellikle küçük ve orta ölçekli problemlerde, hızlı eğitilebilir olmaları ve genellikle tek bir gizli katman ile iyi sonuçlar verebilmeleridir. Bununla birlikte, büyük veri setleri ve çok sayıda giriş özelliği içeren durumlarda eğitim süresi ve ağın karmaşıklığı artabilir (Sing vd., 2003).

### 3. Uygulama ve Bulgular

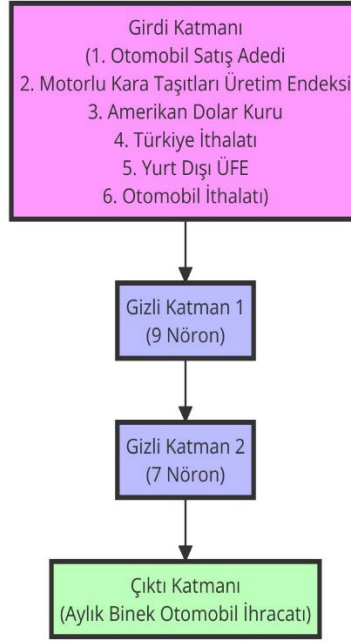
Çalışmada, YSA'nın iki farklı modeli (MLP ve RBF) kullanılarak, Türkiye'nin aylık binek otomobil ihracat değerleri tahmin edilmiştir. Modellerin bağımlı değişkeni, Türkiye'nin aylık binek otomobil ihracatıdır. Modellerde 6 adet bağımsız değişken bulunmaktadır.

Çalışmada, MLP ve RBF modellerindeki hiperparametrelerin otomatik olarak seçimi için Bayes Optimizasyon tekniği kullanılmıştır. Bu yöntem, model performansını maksimize edecek hiperparametre kombinasyonlarını belirlemek üzere olasılıksal bir model kullanmaktadır. Bayes Optimizasyonu, önceki denemelerden elde edilen bilgileri kullanarak hiperparametre arama alanında en umut verici bölgelere odaklanır, böylece daha az deneme ile daha iyi sonuçlar elde etmeyi amaçlamaktadır (Wu vd., 2019). Bu süreçte, Python yazılımı ve ilgili kütüphaneler aracılığıyla otomatik bir hiperparametre ayarlama işlemi gerçekleştirilmiştir.

Python'da Bayes Optimizasyonu için sıklıkla kullanılan kütüphaneler arasında Scikit-Optimize (skopt) ve Hyperopt bulunmaktadır. Scikit-Optimize, Gaussian Process tabanlı optimizasyon işlemleri için kullanıcı dostu bir arayüz sunar. Hyperopt, Bayes Optimizasyonu yanı sıra rastgele arama ve TPE (Tree of Parzen Estimators) gibi farklı algoritmaları da destekler ve geniş bir kullanım alanına sahiptir. Bu kütüphaneler, hiperparametre optimizasyonu sürecini kolaylaştırmak için geliştirilmiş ve Python ekosisteminde yaygın olarak kullanılmaktadır. Bayes Optimizasyonu, hedef fonksiyonun  $f(x)$  olduğu durumlarda kullanılmaktadır. Bu yöntemde, hedef fonksiyon üzerine bir Gaussian Process (GP) prior varsayılır ve her adımda GP'nin güncellenmesiyle posteriori elde edilmektedir. Hiperparametrelerin her bir kombinasyonu için elde edilen performans değerlendirme sonuçlarına göre, "Acquisition Function" kullanılarak sonraki en iyi hiperparametre değerleri tahmin edilmektedir. Bu süreç, belirlenen iterasyon sayısı kadar veya durdurma kriteri karşılanana kadar devam etmektedir. Bu optimizasyon yöntemi, hesaplama maliyeti yüksek fonksiyonlar için uygundur çünkü her adımda elde edilen bilgiyi maksimize etmeye çalışır (Feurer ve Hutter, 2019). Sonuç olarak, hem MLP hem de RBF modelinde, gizli katman sayısı, nöron sayısı ve aktivasyon fonksiyonu gibi hiperparametreler, Bayes Optimizasyon tekniği kullanılarak otomatik olarak seçilmiştir.

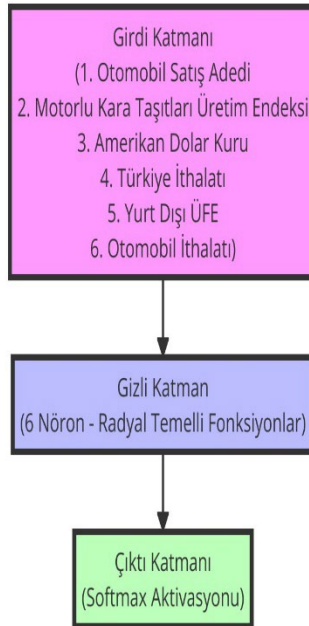
Çalışmada tasarlanan MLP modelinin; 6 adet girdi katmanı (bağımsız değişkenler), iki adet gizli katmanı ve bir adet çıktı katmanı vardır (Bias birimleri hariç). Şekil 2'de tasarlanan MLP modelinin katmanları gösterilmiştir. MLP modeli, iki adet gizli katmana sahiptir. Birinci gizli katmanda 9 adet birim (nöron) bulunurken, ikinci gizli katmanda 7 adet nöron bulunmaktadır. Gizli katmanlar, verinin karmaşıklığını yakalamak ve modelin öğrenme yeteneğini artırmak için kullanılan katmanlardır. Hem gizli katmanlarda hem de çıktı katmanında hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır. Hiperbolik tanjant, girişleri -1 ile 1 arasında sınırlayan ve non-linear davranışı olan bir fonksiyondur. Çıktı katmanı, bağımlı değişkeni temsil etmektedir. Daha önce de bahsedildiği gibi, hiperparametrelerin otomatik olarak seçimi için Bayes Optimizasyon tekniği kullanılmıştır. Çıktı katmanında bir adet birim bulunmaktadır. Bu birim, Türkiye'nin aylık binek otomobil ihracatını tahmin etmektedir.

Şekil 2. MLP Modelinin Katmanları



Bununla birlikte, Şekil 3'te RBF modelinin mimarisi ve katmanları gösterilmiştir. Giriş katmanı, bağımsız değişkenleri temsil etmektedir. MLP modelinde kullanılan aynı 6 adet değişken, RBF modelinde de kullanılmıştır. RBF modelinde bir adet gizli katman bulunmaktadır. Bu katman, giriş verilerini daha yüksek boyutta temsil eden radyal temelli fonksiyonlardan oluşmaktadır. Gizli katman altı adet birim (nöron) içermektedir. Aktivasyon fonksiyonu olarak softmax kullanılmıştır. Softmax fonksiyonu, çıktıları olasılık dağılımı şeklinde normalize eden bir fonksiyondur. Daha önce de bahsedildiği gibi, hiperparametrelerin otomatik olarak seçimi için Bayes Optimizasyon tekniği kullanılmıştır.

Şekil 3. RBF Modelinin Katmanları



Tablo 4, MLP modelinin katman yapılarını, mimarisini ve özelliklerini açıklamaktadır. Aktivasyon fonksiyonu olarak her iki gizli katmanda da hiperbolik tanjant (Hyperbolic Tangent) kullanılmıştır. Hiperbolik tanjant, gizli katmanlardaki nöronların çıkışlarını sınırlayan ve genellikle sigmoidal bir şekle sahiptir. Hata fonksiyonu, modelin performansını ölçmek için kullanılmaktadır. Modelde hata karelerinin toplamı (Sum of Squares) hata fonksiyonu olarak seçilmiştir. Bu fonksiyon, modelin tahminlerinin gerçek değerlerle olan farkını hesaplayarak modelin performansını ölçmektedir. MLP, karmaşık ilişkileri modelleyebilen ve tahmin yeteneği yüksek bir model türüdür.

**Tablo 4.** MLP Modelinin Katman Yapıları ve Özellikleri

| Giriş Katmanı | Bağımsız Değişkenler                     | Yeni Otomobil Satış Adedi             |                      |
|---------------|--|---------------------------------------|----------------------|
|               |  | Motorlu Kara Taşıtları Üretim Endeksi | Amerikan Dolar Kuru  |
|               |  | Türkiye İthalat Değeri                | Yurt Dışı ÜFE Değeri |
|               |  | Türkiye Otomobil İthalat Değeri       |                      |
|               | Giriş Katmanı Değişken Sayısı (a)        | 6                                     |                      |
| Gizli Katman  | Gizli Katman Sayısı                      | 2                                     |                      |
|               | Birinci gizli katmandaki birim sayısı(a) | 9                                     |                      |
|               | İkinci gizli katmandaki birim sayısı(a)  | 7                                     |                      |
|               | Aktivasyon Fonksiyonu                    | Hiperbolik Tanjant                    |                      |
| Çıktı Katmanı | Bağımlı Değişken sayısı                  | 1                                     |                      |
|               | Çıktı katmanındaki birim sayısı          | 1                                     |                      |
|               | Aktivasyon Fonksiyonu                    | Hiperbolik Tanjant                    |                      |
|               | Hata Fonksiyonu                          | Hata Kareler Toplamı                  |                      |
|               | Bağımlı Değişken                         | Türkiye Aylık Otomobil İhracatı       |                      |

a: Bias birimi hariç

Tablo 5, MLP (Çok Katmanlı Algılayıcı) ve RBF (Radyal Baz Fonksiyonu) modellerinde işleme tabi tutulan test ve eğitim verilerini göstermektedir. Her iki modelde de eğitim verisi olarak 117 adet örneklem (%70) kullanılmıştır. Ayrıca, test verisi olarak da 50 adet örneklem (%30) kullanılmıştır. Toplamda geçerli 167 adet veri seti (%100) bulunmaktadır. Hariç tutulan (excluded) veri olmamıştır. Tablo 5, her iki modelin de eğitim ve test verilerini aynı oranda kullandığını göstermektedir.

**Tablo 5.** MLP ve RBF Modelinde İşleme Tabi Tutulan Test ve Eğitim Verileri

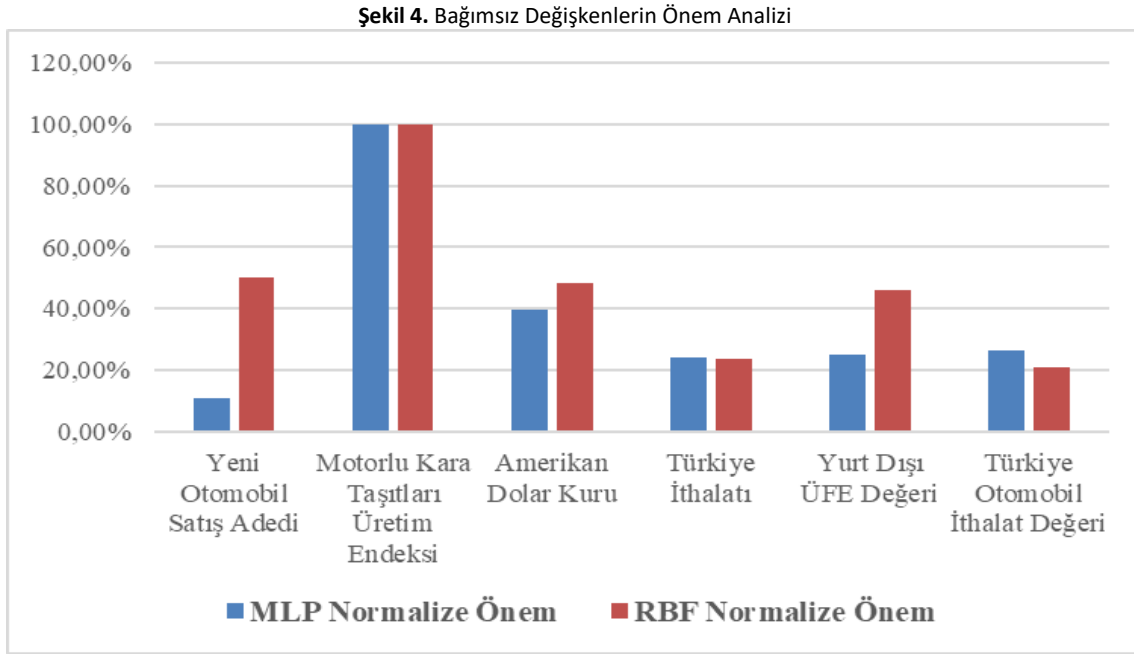
|                    |               | MLP        |       | RBF        |       |
|--------------------|---------------|------------|-------|------------|-------|
|                    |               | Adet       | Yüzde | Adet       | Yüzde |
| Örneklem           | Eğitim Verisi | 117        | % 70  | 117        | % 70  |
|                    | Test Verisi   | 50         | % 30  | 50         | % 30  |
| Geçerli Veriler    |               | 167        | % 100 | 167        | % 100 |
| <b>Toplam Veri</b> |               | <b>167</b> |       | <b>167</b> |       |

Tablo 6, modellerdeki bağımsız değişkenlerin önem derecesini göstermektedir. MLP modeline etki eden en önemli bağımsız değişken, motorlu kara taşıtları üretim endeksi'dir ve normalize önem değeri %100'dür. Diğer değişkenlerin normalize önem değerleri ise %10,7 ile %39,5 arasında değişmektedir. RBF modelinde ise en önemli bağımsız değişken yine motorlu kara taşıtları üretim endeksi'dir, normalize önem değeri %100'dür. Diğer değişkenlerin normalize önem değerleri ise %20,8 ile %50,3 arasında değişmektedir. Her iki modelde de motorlu kara taşıtları üretim endeksi en önemli bağımsız değişkendir.

**Tablo 6.** Bağımsız Değişkenlerin Önem Analizi

| Bağımsız Değişkenler                  | Önem  | MLP   |                | RBF   |                |
|---------------------------------------|-------|-------|----------------|-------|----------------|
|                                       |       | Önem  | Normalize Önem | Önem  | Normalize Önem |
| Yeni Otomobil Satış Adedi             | 0,047 | 0,174 | % 10,7         | 0,174 | % 50,3         |
| Motorlu Kara Taşıtları Üretim Endeksi | 0,443 | 0,346 | % 100          | 0,346 | % 100          |
| Amerikan Dolar Kuru                   | 0,175 | 0,167 | % 39,5         | 0,167 | % 48,1         |
| Türkiye İthalatı                      | 0,108 | 0,082 | % 24,3         | 0,082 | % 23,6         |
| Yurt Dışı ÜFE Değeri                  | 0,111 | 0,159 | % 25           | 0,159 | % 45,9         |
| Türkiye Binek Otomobil İthalat Değeri | 0,117 | 0,072 | % 26,4         | 0,072 | % 20,8         |

Şekil 4'te bağımsız değişkenlerin önemi grafik ortamında ifade edilmiştir. Her iki modelde motorlu kara taşıtları üretim endeksi'nin tahmin edilen değişken üzerinde en önemli etkiye sahip olduğu görülmektedir. Diğer bağımsız değişkenler de modele katkı sağlamaktadır, ancak farklı önem derecelerine sahiptirler.



Bu çalışmada kullanılan değişkenler zaman serisi verileri olduğu için, bu verilerin gelecek değerleri ARIMA, SARIMA, Holt-Winters gibi zaman serisi tahmin yöntemleri kullanılabilir. Bu yöntemler, geçmiş verilerin trendlerini, mevsimselliklerini ve diğer özelliklerini analiz ederek gelecek değerleri tahmin etmektedir. Öncelikle bağımsız değişkenlerin her birinin gelecek 7 aylık değerlerini tahmin etmek için ARIMA (AutoRegressive Integrated Moving Average) modeli tercih edilmiştir. Python yazılımında, "pmdarima" kütüphanesinin "auto\_arima" fonksiyonu, en uygun ARIMA model parametrelerini otomatik olarak bulmak için kullanılmıştır. "auto\_arima" fonksiyonu, ARIMA modelinin üç ana parametresi olan p (autoregressive terimlerin sayısı), d (entegrasyon derecesi) ve q (moving average terimlerin sayısı) için en uygun değerleri belirlemektedir. Daha sonra bu kapsamda belirlenen model parametreleri kullanılarak, gelecek 7 ay için tahminler oluşturulmuştur. ARIMA modeli ile gerçekleştirilen bağımsız değişkenlerin gelecek tahminlerine ilişkin değerler ve en iyi model sonuçları Tablo 7'de gösterilmiştir.

**Tablo 7. ARIMA Modeli ile Bağımsız Değişkenlerin Gelecek 7 Aylık Tahminleri**

| Değişkenler                   | ARIMA En İyi Model | Aralık 2023    | Ocak 2024      | Şubat 2024     | Mart 2024      | Nisan 2024     | Mayıs 2024     | Haziran 2024   |
|-------------------------------|--------------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| Otomobil Satış Adedi          | (1,0,1)(0,0,0)[0]  | 79.182         | 79.024         | 78.866         | 78.708         | 78.550         | 78.393         | 78.237         |
| MKT Üretim Endeksi (2015=100) | (0,1,1)(0,0,0)[0]  | 147.2          | 147.7          | 148.2          | 148.7          | 149.1          | 149.6          | 150.1          |
| Amerikan Dolar Kuru           | (4,2,1)(0,0,0)[0]  | 29.32          | 30.27          | 31.22          | 32.05          | 32.90          | 33.76          | 34.59          |
| Türkiye İthalatı              | (1,1,0)(0,0,0)[0]  | 27.506.800.000 | 27.493.720.000 | 27.499.180.000 | 27.496.900.000 | 27.497.850.000 | 27.497.460.000 | 27.497.620.000 |
| Yurt Dışı ÜFE                 | (2,2,2)(0,0,0)[0]  | 1679.33        | 1751.81        | 1802.80        | 1846.05        | 1894.48        | 1950.98        | 2011.30        |
| Otomobil İthalat              | (4,0,2)(0,0,0)[0]  | 1.451.593.000  | 1.314.580.000  | 1.230.122.000  | 1.203.006.000  | 1.204.926.000  | 1.189.612.000  | 1.135.984.000  |

Tablo 8'de sunulan model performans ölçütleri, iki farklı yapay sinir ağı modeli olan Çok Katmanlı Algılayıcı (MLP) ve Radyal Taban Fonksiyonu (RBF) ağlarının tahmin performanslarını karşılaştırmaktadır. Her iki modelin performansı,  $R^2$ , Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Kare Hata (MSE) ve Kök Ortalama Kare Hata (RMSE) değerleri üzerinden değerlendirilmiştir. Ayrıca, her iki model için de veri setindeki örnek sayısı (N) 167 olarak belirtilmiştir. Bu değerlendirme, her bir ölçütün ne anlama geldiğini ve modeller arasındaki farkları anlamamıza yardımcı olmaktadır.  $R^2$  değeri, modelin verilerin varyansını ne kadar iyi açıkladığını göstermektedir. 1'e yakın değerler, modelin veri setindeki varyansı yüksek oranda açıkladığını ve dolayısıyla tahminlerin

doğruluğunun yüksek olduğunu gösterir. Bu durumda, MLP modelinin (0,865) RBF modeline (0,765) göre veri setindeki değişkenliği daha iyi açıkladığı ve dolayısıyla daha iyi bir performans sergilediği görülmektedir. MAPE, tahmin edilen değerlerin gerçek değerlerden ne kadar sapma gösterdiğinin yüzdesel bir ifadesidir. Daha düşük MAPE değerleri, modelin tahminlerinin gerçek değerlere daha yakın olduğunu ve dolayısıyla daha iyi performans gösterdiğini belirtmektedir. Bu açıdan bakıldığında, MLP modelinin (% 12) RBF modeline (%18) göre daha az hata ile tahmin yaptığı görülmektedir. MSE, hataların karelerinin ortalamasıdır ve modelin tahmin hatalarının büyüklüğünü ölçmektedir. Daha düşük MSE değerleri, daha iyi model performansını göstermektedir. MLP modeli (0,45), RBF modeline (0,78) göre daha düşük MSE değerine sahip olduğu için, tahminlerinde daha az hata yapmıştır. RMSE, MSE'nin kareköküdür ve hata büyüklüklerinin ölçülmesinde kullanılır, birimleri ölçülen değerlerle aynıdır. RMSE değeri de tıpkı MSE gibi, daha düşük olduğunda daha iyi model performansı anlamına gelmektedir. Bu durumda da MLP modeli (0,67), RBF modeline (0,88) göre daha iyi performans sergilemektedir.

MLP modeli,  $R^2$ , MAPE, MSE ve RMSE değerleri açısından RBF modeline göre daha iyi performans sergilemektedir. Bu, MLP modelinin bu veri seti üzerinde tahminlerde daha doğru ve daha az hatalı olduğunu göstermektedir. Her iki model de aynı veri seti (N=167) üzerinde değerlendirilmiş olup, MLP modelinin bu özel durumda genel olarak daha iyi bir tercih olduğu sonucuna varılabilir.

**Tablo 8.** Modellerin Performans Ölçütleri

| Hata İstatistikleri | MLP   | RBF   |
|---------------------|-------|-------|
| $R^2$               | 0,865 | 0,765 |
| MAPE                | 0,12  | 0,18  |
| MSE                 | 0,45  | 0,78  |
| RMSE                | 0,67  | 0,88  |
| N sayısı            | 167   | 167   |

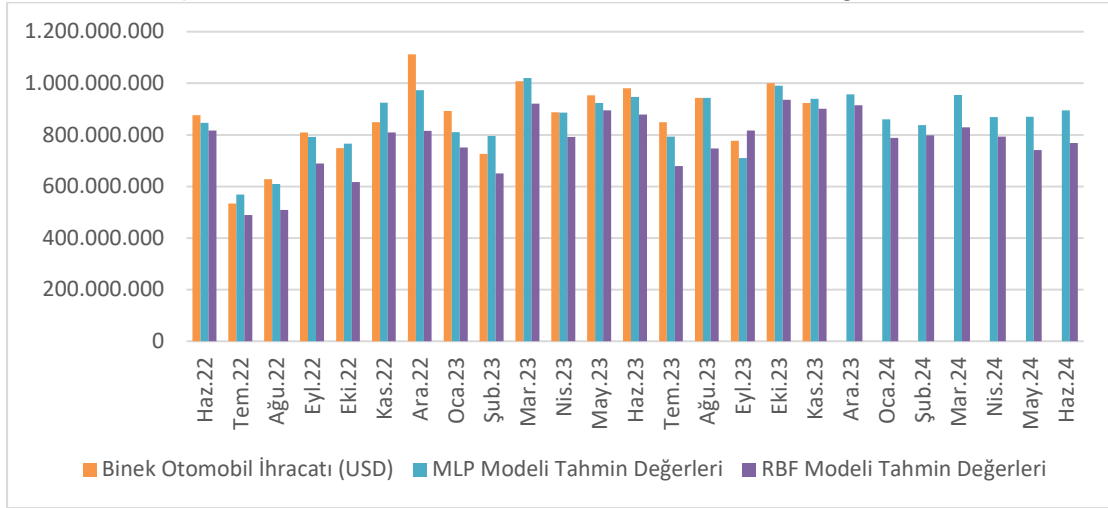
Tablo 9, MLP ve RBF modellerinin binek otomobil ihracatı tahmin değerlerini içermektedir. MLP modeline göre, önümüzdeki dönemde binek otomobil ihracat değerleri 743 milyon dolar ile 957 milyon dolar arasında değişim gösterecektir. RBF modelinde ise 817 milyon dolarlık ihracat değeri tahmin edilmiştir. Tabloya bakıldığında, genellikle tahmin edilen değerlerin gerçek değerlere yakın olduğu görülmektedir.

**Tablo 9.** MLP ve RBF Modelleri Binek Otomobil İhracat Tahmin Değerleri

| Aylar  | Binek Otomobil İhracatı (USD) | MLP Modeli Tahmin Değerleri | RBF Modeli Tahmin Değerleri |
|--------|-------------------------------|-----------------------------|-----------------------------|
| Haz.22 | 875.831.451                   | 846.877.280                 | 817.316.644                 |
| Tem.22 | 533.793.358                   | 568.275.863                 | 489.365.741                 |
| Ağu.22 | 628.683.279                   | 610.166.727                 | 509.378.148                 |
| Eyl.22 | 809.093.581                   | 791.959.991                 | 689.459.784                 |
| Eki.22 | 748.409.511                   | 765.993.866                 | 617.399.978                 |
| Kas.22 | 849.040.243                   | 924.521.368                 | 809.428.578                 |
| Ara.22 | 1.111.587.580                 | 973.673.183                 | 815.732.512                 |
| Oca.23 | 892.464.498                   | 810.824.989                 | 750.634.642                 |
| Şub.23 | 726.378.278                   | 795.148.661                 | 650.498.728                 |
| Mar.23 | 1.007.483.583                 | 1.019.905.052               | 920.996.345                 |
| Nis.23 | 886.984.413                   | 886.175.514                 | 792.197.378                 |
| May.23 | 952.954.769                   | 923.483.022                 | 894.544.771                 |
| Haz.23 | 980.663.330                   | 946.772.921                 | 878.994.516                 |
| Tem.23 | 849.614.776                   | 793.097.491                 | 678.487.578                 |
| Ağu.23 | 943.216.553                   | 943.973.458                 | 747.814.973                 |
| Eyl.23 | 776.611.857                   | 709.525.405                 | 817.316.642                 |
| Eki.23 | 1.000.184.780                 | 990.255.877                 | 935.456.665                 |
| Kas.23 | 922.989.219                   | 939.850.839                 | 900.780.452                 |
| Ara.23 |                               | 957.538.406                 | 914.378.741                 |
| Oca.24 |                               | 859.747.065                 | 787.698.427                 |
| Şub.24 |                               | 837.947.807                 | 798.543.209                 |
| Mar.24 |                               | 954.290.682                 | 829.677.315                 |
| Nis.24 |                               | 868.795.024                 | 793.198.703                 |
| May.24 |                               | 870.510.715                 | 741.048.689                 |
| Haz.24 |                               | 894.883.191                 | 768.703.436                 |

Şekil 5, MLP ve RBF modellerinin tahmin ettiği değerleri gerçek değerlerle daha açık bir şekilde karşılaştırmak amacıyla grafiksel olarak sunulmuştur. RBF modelinde, MLP'ye kıyasla daha düşük ihracat değerleri tahmin edilmiştir.

Şekil 5. MLP ve RBF Modellerinin Binek Otomobil İhracat Tahmin Değerleri



Genel olarak MLP (Çok Katmanlı Algılayıcı) modeli, gerçek ihracat değerlerine oldukça yakın tahminler yapmış gibi görünmektedir. Özellikle Mart 2023 ve Kasım 2023 dönemlerinde, modelin tahminleri gerçek değerlere oldukça yakındır. Bu, modelin bu aylar için ihracat dinamiklerini iyi öğrendiğini ve veriye iyi uyduğunu göstermektedir. Tahminler genel olarak gerçek değerlere yakın olsa da, belirli aylarda ve modeller arasında farklılıklar bulunmaktadır. Modeller, daha fazla veri ile eğitilip ayarlandığında veya daha karmaşık teknikler kullanıldığında daha iyi sonuçlar verebilmektedir. Buna ek olarak, RBF (Radial Basis Function) modeli ise bazı aylarda gerçek değerlerden daha düşük tahminler yapmıştır. Özellikle Temmuz 2022 ve Ağustos 2022 gibi aylarda, modelin tahminleri gerçek değerlerin altında kalmıştır. Ancak Mart 2023 ve Ekim 2023 gibi dönemlerde RBF modelinin tahminleri gerçekleşen ihracat değerlerine yaklaşmaktadır. MLP modeli genellikle RBF modeline kıyasla daha yüksek tahminler yapmıştır. Her iki modelin performansının aylara göre değiştiği gözlemlenmektedir. Bazı aylarda MLP, bazılarında ise RBF daha iyi performans göstermiştir. Bu durum, farklı zaman dilimlerinde ve piyasa koşullarında hangi modelin daha iyi performans gösterdiğini anlamak için daha detaylı bir analize ihtiyaç olduğunu göstermektedir. MLP ve RBF modellerinin her ikisi de mevsimsel etkileri ve genel trendi yansıtır gibi görünmektedir. Özellikle yüksek ihracat değerleri için (örneğin Aralık 2022 ve Mart 2023) her iki model de yüksek tahminler yapmış, bu durum modellerin mevsimsel etkileri kısmen yakalayabildiğini düşündürülebilir. Tablonun sonunda, Aralık 2023'ten Haziran 2024'e kadar olan aylar için her iki modelin gelecek tahmin değerleri verilmiştir.

## Sonuç, Tartışma ve Öneriler

Yapay sinir ağları yöntemi, tahmin yapmada kullanılan bir makine öğrenmesi yöntemidir. Bir yapay sinir ağı, veri analizi ve öğrenme yoluyla eğitildikten sonra yeni verilere dayalı tahminler yapabilir. Bu yöntem, çeşitli alanlarda kullanılabilir ve geniş bir uygulama alanına sahiptir. Yapay sinir ağları, tahmin yetenekleri ve geniş kullanım alanlarıyla popüler bir yöntemdir.

Türkiye otomobil sektörü ve ihracatı, ülke ekonomisi için stratejik öneme sahip bir sektördür. Otomobil ihracatı, ekonomik büyümeyi destekleyen döviz geliri ve istihdam oluşturma potansiyeli barındırmaktadır. Otomobil sektörü, devlet politikalarının ve ekonomik planlamaların önemli bir bileşenidir. Tahmin modelleri, otomobil ihracatının gelecekteki performansını değerlendirmek ve politika yapıcılarına rehberlik etmek için kullanılabilir. Otomobil üreticileri ve yatırımcılar, otomobil ihracatına ilişkin tahminlere dayanarak stratejilerini belirler. Bu nedenle, doğru ve güvenilir tahminler, yatırımcıların kararlarını destekleyebilir ve riskleri azaltabilir. Otomobil sektörü rekabetçi bir ortamda faaliyet göstermektedir. Doğru tahminler, otomobil üreticilerine ve ihracatçılara, talep ve pazar olanaklarını önceden görebilmeleri için avantaj sağlayabilir.

Bu çalışma, yapay sinir ağlarının (MLP ve RBF) performansını değerlendirerek Türkiye'nin binek otomobil ihracat tahminleri konusunda önemli bilgiler sunmaktadır. Elde edilen sonuçlar, Karakaş (2019) tarafından geliştirilen ARIMA modeliyle yaptığı ihracat tahminleri çalışması ve diğer literatürdeki benzer uygulamalarla karşılaştırıldığında, MLP'nin yüksek doğruluk derecesine işaret eden korelasyon skorları ile öne çıktığı görülmektedir. Bunun yanı sıra, MAPE değerlerinin düşük olması, modelin tahmin başarısını destekler niteliktedir. Bu çalışmada MLP'nin RBF'ye göre daha üstün performans gösterdiği belirtilmiş, bu da Lasya vd. (2023) tarafından yapılan çalışmalarla uyumlu bir sonuçtur. Bununla birlikte, bizim çalışmamız, Türkiye'nin aylık binek otomobil ihracatını tahmin etme üzerine odaklanırken, Karaatlı vd. (2012), Akyurt (2015), Topal (2019) ve Kayakuş vd. (2023) çalışmaları farklı otomobil pazar segmentlerinde ve satış tahminlerinde yapay sinir ağları (YSA) ve diğer makine öğrenmesi yöntemlerinin kullanımını incelemektedir. Karaatlı vd. (2012) ve Akyurt (2015), yeni ve yerli otomobil satışlarını, makroekonomik göstergeler ve mevsimsel etkileri dikkate alarak modellemişlerdir. Topal (2019), çevrimiçi verileri ve tüketici bütünleşmesini kullanarak bir otomobil markasının satış miktarlarını tahmin ederken, Kayakuş vd. (2023) hafif ticari araç satışlarını farklı makine öğrenmesi teknikleriyle değerlendirmiştir. Her biri, YSA ve makine öğrenmesinin otomobil pazarı tahminlerinde etkili olduğunu göstermekle birlikte, Gür vd. (2024).

yapmış olduğumuz çalışma, bu yöntemleri Türkiye'nin otomobil ihracatı bağlamında genişletmekte ve derinleştirmektedir, böylece bu alanda yeni bir perspektif sunmaktadır. Bu çalışmalar arasındaki temel fark, uygulama alanlarının çeşitliliği ve kullanılan veri setlerinin özgünlüğüdür. Çalışmamız, bu metodolojileri Türkiye'nin otomobil ihracatı bağlamında ele alarak, literatüre özgün bir katkı sunmaktadır.

Her iki modelde de eğitim verisi olarak 167 adet örneklem (% 70) ve test verisi olarak da 50 adet örneklem (% 30) kullanılmıştır. MLP modelinde MAPE değeri %12 ve RBF modelinde ise %18'dir. Her iki modelde de motorlu kara taşıtları üretim endeksi en önemli bağımsız değişkendir. Bununla birlikte iki modelin performansı karşılaştırıldığında, MLP modelinin RBF modeline göre daha iyi performans gösterdiği görülmüştür. Bu nedenle, gelecekte yapılacak çalışmalarda MLP modelinin daha fazla geliştirilmesi ve ayarlanması düşünülebilir. Modelin doğruluğunu artırmak için daha fazla özellik veya veri kullanımı, hiperparametre ayarları ve ağ yapısı gibi faktörler göz önünde bulundurulabilir. Model performansının artırılması için daha fazla ve yüksek kalitede veri toplanması önemlidir. Veri miktarı ve çeşitliliği artırılarak, modelin daha genel ve kapsamlı sonuçlar üretmesi sağlanabilir. Bununla birlikte, otomobil sektörünü etkileyen dışsal faktörlerin (örneğin ekonomik durum, döviz kurları, dünya piyasaları gibi) modelde dikkate alınması gelecekteki tahminlerin daha hassas ve gerçekçi olmasını sağlayabilir. Öte yandan, bu çalışmada sadece MLP ve RBF modelleri ele alınmıştır. Gelecekte, farklı makine öğrenimi yöntemleri veya istatistiksel modellerle de karşılaştırmalar yapılabilir. Bu şekilde, en iyi tahmin yönteminin belirlenmesi sağlanabilir.

Sonuç olarak, bu çalışma gelecekte otomobil ihracatını tahmin etmek için daha gelişmiş modeller geliştirme, daha fazla veri toplama ve dışsal faktörleri dâhil etme gibi adımları içerebilir. Bu tavsiyeler, otomobil sektörünün rekabetçi ortamında daha doğru ve bilinçli kararlar alınmasına yardımcı olabilir.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

#### Yazar Katkıları

Yazarlar çalışmaya katkı oranlarını bu şekilde beyan etmişlerdir: Yunus Emre Gür %35, Kamil Abdullah Eşidir %35, Şahin Göktuğ Kaldırımcı %30

#### Teşekkür Beyanı

Yazarlar teşekkür beyanında bulunmamışlardır.

#### Destek Beyanı

Yazarlar destek beyanında bulunmamışlardır.

#### Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

#### Etik Beyanı

Yazarlar çalışma için Etik Kurul Onayı alınmasına gerek olmadığını beyan etmişlerdir.

#### Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi



## Kaynakça/References

- Aktaş C. (2007). Otomobil İhracatı ve İthalatı Fiyat Endeksi Verilerinin Farklı Varyanslılığının İncelenmesi. *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 6(11), 149-162.
- Akyurt, İ. Z. (2015). Talep Tahmininin Yapay Sinir Ağlarıyla Modellenmesi: Yerli Otomobil Örneği. *Ekonometri ve İstatistik Dergisi*, 23, 147-157.
- Athukorala, P. C., & Veeramani, C. (2019). From import substitution to integration into global production networks: The case of the Indian automobile industry. *Asian Development Review*, 36(2), 72-99.
- Boughrara, H., Chtourou, M., Ben Amar, C., & Chen, L. (2016). Facial expression recognition based on a mlp neural network using constructive training algorithm. *Multimedia Tools and Applications*, 75, 709-731.
- Breiman, L., Friedman, J., Stone, C.J., & Olshen, R.A. (1984). *Classification and Regression Trees*. CRC press.
- Çokşen, E. (2023). *Covid-19'un Otomotiv Sektörüne Etkileri ve Bir Analiz*. [Yayımlanmamış Doktora Tezi] Marmara Üniversitesi.
- de Soyres, F., Frohm, E., & Gunnella, V. (2020). *How Global Value Chains Change the Trade-Currency Relationship*. FEDS Notes.
- Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. *İçinde: Automated machine learning: Methods, systems, challenges*. (ss. 3-33). Springer.
- Gagnon, J. E., & Knetter, M. M. (1995). Markup Adjustment and Exchange Rate Fluctuations: Evidence From Panel Data On Automobile Exports. *Journal of International Money and Finance*, 14(2), 289-310.
- Gerni C., Emsen Ö. S., & Değer, M. K. (2008). *İthalata Dayalı İhracat ve Ekonomik Büyüme: 1980-2006 Türkiye Deneyimi*, 2. Ulusal İktisat Kongresi , İzmir.
- Gomez-Ibanez, J. A., & Harrison, D. (1982). Imports and the Future of the US Automobile Industry. *The American Economic Review*, 72(2), 319-323.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688.
- İnançlı, S., & Konak, A. (2011). Türkiye'de İhracatın İthalata Bağımlılığı: Otomotiv Sektörü. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 6(2), 343-362.
- Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay sinir ağı yöntemi ile otomobil satış tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Karakaş, E. (2019). Türkiye'nin Otomotiv İhracat Gelirinin Arima Modeli ile Tahmin Edilmesi. *Yaşar Üniversitesi E-Dergisi*, 14(55), 318-328.
- Kayakuş, M., Terzioğlu, M., Yağmur, A., & Erdoğan, D. (2023). Türkiye'deki Hafif Ticari Araç Satışlarının Makine Öğrenmesi Yöntemleriyle Tahmin Edilmesi. *Gazi Mühendislik Bilimleri Dergisi*, 9(4-ICAIAME 2023), 100-112.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *İçinde: Ijcai* (Vol. 14, No. 2, ss. 1137-1145).
- Lasya, C. L., Pooja, S., Jeyashree, S., Ambhika, C., & Eswari, G. (2023). Forecasting Pre-Owned Car Prices Using Machine Learning. *İçinde 2023 2nd International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)* (ss. 1-6). IEEE.
- Nur, H. B., & Çalbörü, M. (2023). Türkiye'de Sektörlerin Dış Ticaret ve İstihdamdaki Yeri: Türkiye Otomotiv Sektörü Analizi. *Stratejik Ve Sosyal Araştırmalar Dergisi*, 7(1), 35-53.
- Paparoditis, E., & Politis, D. N. (2018). The asymptotic size and power of the augmented Dickey-Fuller test for a unit root. *Econometric Reviews*, 37(9), 955-973.
- Phillips, P. C., & Perron, P. (1988). Testing for a unit root in time series regression. *biometrika*, 75(2), 335-346.
- Ray, S. (2012). Economic Performance of Indian Automobile Industry: An Econometric Appraisal. *Business Intelligence Journal*, 5(1), 151-162.
- Samaddar, M., & Bachman, D. (2022). No longer a smooth drive: How automobiles' role in the US economy has evolved. *Deloitte Insights*. <https://www2.deloitte.com/us/en/insights/economy/spotlight/automobile-impact-us-economy.html> Erişim Tarihi: 19.02.2024
- Sing, J. K., Basu, D. K., Nasipuri, M., & Kundu, M. (2003, October). Improved k-means algorithm in the design of RBF neural networks. *İçinde TENCON 2003. Conference on Convergent Technologies for Asia-Pacific Region* (Vol. 2, ss. 841-845). IEEE.
- Türkiye İstatistik Kurumu (TÜİK) Verileri, <https://data.tuik.gov.tr/> Erişim tarihi: 10.01.2024
- Topal, İ. (2019). Çevrimiçi Tüketici Bütünleşmesi Ve Arama Motoru Verileri Kullanılarak Yapay Sinir Ağları İle Otomobil Satış
- Gür vd. (2024).

Tahmini. *Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 9(2), 534-551.

- Wilamowski, B. M. (2009). Neural network architectures and learning algorithms. *IEEE Industrial Electronics Magazine*, 3(4), 56-63.
- Williamson, J. (2009). Exchange rate economics. *Open Economies Review*, 20, 123-146.
- Wu, J., Chen, X. Y., Zhang, H., Xiong, L. D., Lei, H., & Deng, S. H. (2019). Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*, 17(1), 26-40.
- Yingwei, L., Sundararajan, N., & Saratchandran, P. (1998). Performance evaluation of a sequential minimal radial basis function (RBF) neural network learning algorithm. *IEEE Transactions on neural networks*, 9(2), 308-318.
- Yoğunlu, A., (2022). *Yenilik Ekosistem Yaklaşımına Dayalı Teknoloji Geliştirme Bölgeleri*. Gazi Kitabevi.