

Yayın Geliş Tarihi (Submitted): 07/03/2020

Yayın Kabul Tarihi (Accepted): 09/06/2020

Makele Türü (Paper Type): Araştırma Makalesi – Research Paper

TÜRKİYE’NİN GSYH DEĞERLERİNİN YAPAY SINIR AĞLARI İLE TAHMİNİ ÜZERİNE BİR İNCELEME

Gizem GEÇGİL¹ ve Yakup AKGÜL²

ÖZET

Makroekonominin en önemli konularından birisi milli gelir analizleri ve bu analizlerin yorumlanmasıdır. Milli gelirin en önemli araçlarından biri olan Gayrisafi Yurtiçi Hasıla (GSYH) kavramı ülkelerin ekonomisi hakkında genel bir görünüm vermektedir. GSYH ülkelerin ekonomik büyüme ve ekonomik kalkınma düzeyleri hakkında bilgi sahibi olmamızı sağlayan bir ölçüttür. Bu değerler ülke içindeki yerli ve yabancı vatandaşlar tarafından üretilen tüm mal ve hizmetleri kapsadığı için önem arz etmektedir. Gelişmekte olan Türkiye ekonomisi için de bu hasıla değerlerinin yüksek olması ekonomisinin gelişmesine katkıda bulunacaktır. Bu çalışmanın amacı Türkiye'nin GSYH değerlerini tahmin etmektir. Teknolojinin ivme kazanması ile son zamanlarda önemi daha çok artan yapay sinir ağı teknolojileri sayesinde birçok öngörü modellemesi yapılabilmektedir. Öngörü modellemesi ekonomik etkinlik ve milli gelir düzeyinin ölçülmesinde de kullanılabilir. Bu bağlamda bu çalışmada GSYH'ye etki edebilecek değişkenler seçilerek GSYH değerlerinin öngörülmesi amaçlanmıştır. Veriler 1998-2017 yıllarını kapsamaktadır. Bu çalışmada literatürde yer alan çalışmalar da göz önünde bulundurularak GSYH'yi etkileyebileceği düşünülen hanehalkı tüketim harcaması-devlet nihai tüketim harcaması, ithalat-ihracat, sabit sermaye yatırımı-toplam yurtiçi tasarruf, brüt dış borç stoku-sanayi-üretim ve döviz alış-döviz satış kurları bağımsız değişken olarak belirlenmiştir. Modelin bağımlı değişkeni ise GSYH'dir. Yapay sinir ağları (YSA) modellerinin geliştirilmesinde MATLAB R2013a programından faydalanılmıştır. 240 tane yıllık verinin %70'lik bölümü eğitim, %15'lik bölümü geçerlilik, kalan %15'lik bölümü ise test için rastgele

Bu çalışma, Doç. Dr. Yakup Akgül danışmanlığında Gizem Geçgil tarafından 20.06.2019 tarihinde tamamlanan "Türkiye'nin GSYH Değerlerinin Yapay Sinir Ağları ile Tahmini" başlıklı ve [569325](#) tez no'lu yüksek lisans tezinden türetilmiştir.

¹Sorumlu yazar, Uluslararası Ticaret, Sosyal Bilimler Enstitüsü, Alanya Alaaddin Keykubat Üniversitesi, Antalya, Türkiye, ORCID ID: <https://orcid.org/0000-0001-9876-2211>

²Doç. Dr, Uluslararası Ticaret, Sosyal Bilimler Enstitüsü, Alanya Alaaddin Keykubat Üniversitesi, Antalya, Türkiye, ORCID ID: <https://orcid.org/0000-0001-5344-4359>

ayrılmıştır. Öğrenme algoritması olarak Levenberg-Marquardt algoritması seçilmiştir. 2 ile 5 arasında gizli katman sayısı denenerek oluşturulan modelde en iyi sonuca gizli katman sayısı 5 olarak seçildiğinde ulaşılmıştır. 5 gizli katmanda $R^2=0,996140651$, $RMSE=19444911,6$, $MAE=15845918,2$ ve $MAPE=32,29791086$ değerleri elde edilerek kurulan modelin kabul edilebilir olduğu sonucuna ulaşılmıştır. Ayrıca istatistiksel olarak gizli katman sayısı arttıkça modelin daha iyi sonuç verdiği görülmüştür. GSYH' nin gerçek değerleri ile tahmin değerleri birbirine çok yakın çıkmıştır. Buradan Yapay Sinir Ağının tahmin gücünün yüksek olduğu tespit edilmiştir.

Anahtar Kelimeler: Yapay Sinir Ağı, GSYH, Milli Gelir, Tahmin

A STUDY ON THE PREDICTION OF NEURAL NETWORK VALUE OF TURKEY'S GDP

ABSTRACT

One of the most important issues of macroeconomics is national income analysis and interpretation of these analyzes. The concept of Gross Domestic Product (GDP), which is one of the most important tools of national income, gives an overview of the economy of countries. GDP is a criterion that enables us to have information about countries' economic growth and economic development levels. These values are important as they cover all goods and services produced by local and foreign citizens in the country. The high value for the output of these emerging economies will contribute to the development of Turkey's economy. This study aimed to estimate the value of Turkey's GDP. With the acceleration of technology, many predictive modeling can be done thanks to artificial neural network technologies, which have become more important recently. Forecasting modeling can also be used to measure economic efficiency and national income level. In this context, in this study, it is aimed to predict GDP values by selecting variables that may affect GDP. The data covers 1998-2017. In this study, considering the studies in the literature, household consumption expenditure-state final consumption expenditure, import-export, fixed capital investment-total domestic savings, gross foreign debt stock-industry-production, and foreign exchange buying foreign exchange sales

exchange rates are determined as independent variables. The dependent variable of the model is the GDP. MATLAB R2013a program was used in the development of artificial neural network (ANN) models. 70% of 240 annual data is reserved for education, 15% for validity, and the remaining 15% for testing. The Levenberg-Marquardt algorithm was chosen as the learning algorithm. In the model created by trying the number of hidden layers between 2 and 5, the best result was achieved when the number of hidden layers was selected as 5. It was concluded that the model established was acceptable by obtaining $R^2 = 0,996140651$, $RMSE = 19444911,6$, $MAE = 15845918,2$ and $MAPE = 32,29791086$ in 5 hidden layers. Besides, it was seen that the model gave better results as the number of hidden layers increased statistically. Real values of GDP and estimation values are very close to each other. It has been determined that the Artificial Neural Network has high predictive power.

Keywords: Artificial Neural Network, GDP, National Income, Prediction

1. GİRİŞ

GSYH hükümetlerin gelişmişlik düzeyinin belirlenmesinde yaygın olarak kullanılan bir ölçüttür. GSYH bir ülkede faaliyet gösteren o ülkeye ait vatandaşların ve ülkede yaşayan yabancıların da ürettiği mal ve hizmetlerin tümünü kapsamaktadır. Tüm bu mal ve hizmetlerin artış göstermesi ekonomik büyümeyi ifade etmektedir. Finansal ve ekonomik kuruluşlar GSYH değerlerine bakarak ekonomideki büyümeye göre karşılaştırma yapabilir, çıkarımlarda bulunabilir. Bu bağlamda GSYH değerinin doğru analiz edilmesi gelecekte ülke ekonomisine katkı sağlayabilir. GSYH değişkeni, ekonomik etkinlik ve gelir düzeyi kriteri olarak ekonomi politikası analizleri ve öngörü modellerinde tercih edilmektedir (Kaplan ve Tekeli, 2008:83). GSYH değerlerinin tahmin edilmesi gelecekte ekonomide oluşacak bir daralma veya genişlemenin önceden tespit edilmesi konusunda yararlı olacaktır. Bu bağlamda bu değer tahmin edilmesi önem arz etmektedir. GSYH değerlerinin tahmin edilmesinden elde edilecek sonuçlar ekonomiyi etkileyen birçok faktörün doğrudan veya dolaylı bir katkısı olup olmadığını belirleyebilir.

Son zamanlarda giderek önemi artan yapay sinir ağları modellemeleri ile birçok konuda tahminler yapılmakta ve yorumlanmaktadır. Yapay sinir ağları sayesinde insan beyninin özelliklerinden olan öğrenme gerçekleştirilebilir, bu öğrenmeler ile keşifler yapılarak yeni bilgiler

bilgisayar ortamında üretilebilir. Teknolojik gelişmelerle paralel seyir izleyen yapay sinir ağları teknolojileri ile daha iyi öğrenmeler gerçekleşmesi ekonomi alanında da gelişimini ve kullanımını artırmıştır. Bu bağlamda bu çalışmada da milli gelir analizi için YSA kullanılmıştır.

Bu çalışmanın amacı Türkiye'nin GSYH değerlerini etkileyebileceği düşünülen makroekonomik değişkenler seçilerek bu değerlerin yapay sinir ağları modeli ile öngörülmesini sağlamaktır. Bu bağlamda 1998-2017 yıllarını kapsayan 240 adet yıllık veri kullanılarak analiz yapılmıştır. Çalışma sonucunda gizli katman sayısı arttıkça yapay sinir ağı öğrenmesinin daha iyi gerçekleştiği görülmüştür. Analiz sonucunda elde edilen tahmin değerleri Türkiye'nin gerçek GSYH değerlerine çok yakın sonuçlar vermiştir. Bu bağlamda yapay sinir ağlarının tahmin gücünün yüksek olduğu tespit edilmiştir.

2. LİTERATÜR TARAMASI

Tkacz ve Hu (1999), ekonomik faaliyetlerde finansal ve parasal değişkenlerin tahmin performanslarının sinir ağı modelleri kullanılarak geliştirilip geliştirilemeyeceğini belirlemek istemişlerdir. Bulguları 1-çeyrek öngörme ufkunda, sinir ağlarının önemli bir tahmin iyileştirmesi sağlamadığıdır bununla birlikte, 4-çeyrek ufukta, gelişmiş tahmin doğruluğu istatistiksel olarak anlamlı çıkmıştır. En iyi sinir ağı modellerinin kök ortalama karesi tahmin hataları, doğrusal model benzerlerinden yüzde 15 ila 19 daha düşük sonuç vermiştir.

Aıken (2000), ABD'nin Gayri Safi Yurtiçi Hasılası'nı öngörmenin, ülke ekonomisinin gidişatı açısından tahmin yapmanın öneminden bahsetmiştir ve YSA'nın bu tahminleri nasıl geliştirebileceğine dair az sayıda çalışma olduğuna değinmiştir. Bu makalede, önde gelen ekonomik göstere verileri kullanılarak bir nöral ağı yıllık GSYİH yüzdesinin, bir yılı on yıllık bir süreçte rakip tekniklerden daha doğru bir şekilde tahmin ettiği sonucuna ulaşılmıştır.

Junoh (2004), 1995-2000 yılları arasında toplanan zaman serileri verilerine dayanan bilgi tabanlı ekonomi göstergeleri kullanılarak Malezya'da GSYİH büyümesini tahmin etmek için YSA ve ekonometrik yaklaşımlar arasında karşılaştırmalı bir çalışma yürütmüştür. YSA'nın, geleneksel ekonometrik yaklaşıma göre, bilgiye dayalı ekonomi göstergelerine dayalı olarak GSYİH büyümesini tahmin etme potansiyelini artırdığı sonucuna varmıştır.

Aminian vd. (2006), çalışmasını ABD'nin GSYİH ve Endüstriyel Üretimini kullanarak doğrusal veya doğrusal olmayan modellerin ekonomik verileri tahmin etme yeteneğini doğru

bir şekilde ölçen bir belirleme katsayısına dayandırmışlardır. Çalışmanın veri kümelerindeki doğal olmayan doğrusallıklardan kaynaklanan sinirsel ağların lineer regresyondan anlamlı şekilde daha iyi performans gösterdiğini ve girdiler arasındaki maksimum korelasyonu bulmayı garanti eden sistematik bir yaklaşım sağladığını belirtmişlerdir.

Wang ve Elhag (2007), YSA, kanıtsal muhakeme (ER) yaklaşımı ve çoklu regresyon analizi (MRA) yaklaşımlarını kullanarak, bir dizi köprü risk verisini modellemede üç alternatif yaklaşımın modelleme mekanizmalarını ve performanslarını karşılaştırmaktadır. YSA' nın, incelenen vaka çalışması için ER yaklaşımını ve MRA' yı geride bıraktığı bulunmuş ve bunun nedeni analiz edilmiştir. Üç alternatif yaklaşımın avantaj ve dezavantajları da karşılaştırılmıştır.

Düzgün (2008), Türkiye için 1987Q1:2007Q3 dönemleri arasında YSA ve ARIMA modelleri kullanarak GSYH tahmininde bulunmuştur. Araştırma sonucunda ARIMA modelinin YSA modeline göre daha iyi sonuç verdiğini tespit etmiştir.

Liliana ve Napitupulu (2010), Endonezya'da GSYİH büyümesini tahmin etmek amacıyla YSA kullanmış, önceki iki dönemde GSYİH büyümesi, nüfus artışı oranı, enflasyon, döviz kuru ve siyasi istikrar ve Endonezya'daki güvenlik koşulları gibi bazı değişkenler kullanmıştır. Bu çalışmadan elde edilen bulgular, YSA' nın GSYİH' yi hükümetin yayınladığı değerlerden daha iyi tahmin ettiğini göstermektedir.

Maliki vd. (2014), borsa ile ekonomik büyüme arasındaki ilişkiyi araştırmışlardır. GSYİH'yi Piyasa Kapitalizasyonu (MC), Fırsat Sayısı (ND), Tüm-Hisse Değeri Endeksi dahil olmak üzere önemli borsa göstergeleri (ASVI), İşlem Edilen Payların Toplam Değeri (TVST) ve Enflasyon Oranı değişkenlerini kullanarak modelin bağımsız değişkenlerinin hepsinin bağımlı değişkenle yüksek derecede ilişkili olduğunu ortaya çıkarmışlardır. GSYİH, enflasyon oranı hariç, yaklaşık 0.30 negatif korelasyon değeri, uyum iyiliği de (R^2) 0,85 olarak bulunmuştur. YSA ve regresyon analizi arasındaki verimin karşılaştırılmasında YSA' nın regresyon analizine göre daha iyi sonuçlar verdiği öne sürülmüştür.

Pasarica ve Popescu (2015), Romanya gibi çıkış ekonomilerinde GSYİH' nin ihracat, maliye politikası, tarım, inşaat, perakende vb. gibi bazı doğrusal olmayan faktörler tarafından olumlu ve olumsuz bir şekilde etkilendiğini belirtmişlerdir. Bu çalışmanın nöral ağ geri yayılımı ve regresyon modelleri arasında bir yol sağladığını öne sürmüşlerdir. Analiz için Matlab'da uygulanan nöral paketler kullanılmış ve gerçek veriler ile tahmin ediciler arasındaki korelasyonun 0.95'ten daha yüksek olduğunu kanıtlamışlardır. Nöral ağların GSYİH

modelleme ve öngörme sürecinde son derece güçlü bir yapıya sahip olduğu sonucuna ulaşmışlardır.

Söyler ve Kızılkaya (2015), Çok Katmanlı Algılayıcı (ÇKA), Radyal Tabanlı Fonksiyon Ağları (RTFA) ve geri dönüşümlü Elman Ağı kullanarak GSYİH tahmini yapmayı amaçlamışlardır. 4 girdi katmanına sahip RFTA modelinin en yüksek değeri sağladığı görülmüş ve bu model sayesinde 2013Q4:2014Q4 dönemleri ekonomik büyüme tahmin edilmiştir. YSA'nın ekonomik büyüme tahmini için başarılı bir model olduğu sonucuna ulaşılmıştır.

Vrbka (2016), GSYİH'nin öngörülmesi için yapay zekanın bilinen bir uygulama olduğundan bahsetmiş ve 2025 yılına kadar Euro Bölgesi ülkelerinin GSYİH büyümesini tahmin etmek amacıyla YSA uygulamıştır. Seçilen nöral yapıların tatmin edici sayısal özellikler sergilemekte olduğunu ve GSYİH gelişiminin gerçek değerleri ile eşdeğer olduğu sonucuna varmıştır.

Chuku vd. (2017), Afrika ekonomilerinde ekonomik zaman serilerinin tahmin edilmesinde uygulanan Box-Jenkins ve yapısal ekonometrik modelleme yaklaşımları ile ilgili olarak YSA'nın tahmin performanslarını araştırılmışlardır. Farklı tahminlerden elde edilen sonuçlarına göre özellikle ilgili emtia fiyatları, ticaret, enflasyon ve faiz oranları verileri kullanıldığında, seçilmiş sınır ekonomilerinde GSYİH büyümesini tahmin etmede yapay sinirsel ağ modellerinin yapısal ekonometrik ve ARIMA modellerinden çok daha iyi performans gösterdiği görülmüştür.

Jahn (2018), 1996-2016 döneminde on beş sanayileşmiş ekonominin GSYİH büyüme hızını tahmin etmek amacıyla araştırmasını yapmıştır. YSA modelinin, GSYİH büyüme oranlarının, karşılık gelen bir doğrusal modelden çok daha gerçekçi tahminler verebildiği gösterilmiştir. Özellikle, YSA modellerinin zaman trendlerini çok iyi bir şekilde yakaladığına değinilmiştir.

Literatüre bakıldığında genel olarak GSYH tahmini için YSA modelinin daha iyi sonuçlar verdiği tespit edilmiştir. YSA modelinin diğer modellere göre tahmin gücünün yüksek olduğu görülmektedir. Bu çalışmada da YSA kullanılarak Türkiye'nin 1998-2017 yıllarını kapsayan dönemi için GSYH değerleri tahmin edilmiştir. Elde edilen sonuçlara bakıldığında literatür ile benzer şekilde YSA'nın tahmin gücünün yüksek olduğu sonucuna ulaşılmıştır. Ayrıca Türkiye'de GSYH tahmini ile ilgili az sayıda çalışma olduğu görülmüştür. Bu bakımdan bu çalışmanın literatüre katkısı olacağı düşünülmektedir.

3. ARAŞTIRMANIN AMACI VE YÖNTEMİ

Bu çalışmanın amacı Türkiye'nin GSYH rakamlarını tahmin etmektir. Bu çalışmada 1998-2017 yılları ve bu yıllar arasındaki devlet nihai tüketim harcaması, hanehalkı tüketim harcaması, ihracat, ithalat, brüt dış borç stoku, sanayi, üretim, sabit sermaye yatırımı, toplam yurtiçi tasarruf, dolar alış ve dolar satış kuru verileri bağımsız değişken olarak seçilmiş ve aynı yılları kapsayan GSYH ise bağımlı değişken seçilerek model kurulmuştur. GSYH tahmini yapmak amacıyla YSA modeli kurulmuş olup değişkenler MATLAB R2013a programı ile analiz edilmiştir.

3.1. Araştırmada Kullanılan Veri Seti

Bu çalışmada veriler yıllık olarak seçilmiştir. Modelde kullanılan değişkenler Tablo 1'de gösterilmiştir.

Tablo 1. Modelde kullanılan değişkenler ve kaynakları

Değişkenler	Birim	Veri Türü	Simge	Kaynak
Brüt Dış Borç Stoku	Milyon \$	Yıllık	bdbs	https://evds2.tcmb.gov.tr/
Sanayi	\$	Yıllık	snyi	http://databank.worldbank.org
Üretim	\$	Yıllık	üretm	http://databank.worldbank.org
Devlet Nihai Tüketim Harcaması	Bin TL	Yıllık	dnth	http://www.tuik.gov.tr
Hanehalkı Tüketim Harcaması	Bin TL	Yıllık	hth	http://www.tuik.gov.tr
GSYH	Bin TL	Yıllık	gsyh	http://www.tuik.gov.tr
Kur (Döviz alış ve Döviz satış kuru)	\$	Yıllık	dalış/dstş	https://evds2.tcmb.gov.tr/
Sabit Sermaye Yatırımı	Bin TL	Yıllık	ssy	http://www.tuik.gov.tr
Toplam Yurtiçi Tasarruf	Bin TL	Yıllık	tyit	http://www.tuik.gov.tr
İhracat	Bin TL	Yıllık	ihret	http://www.tuik.gov.tr
İthalat	Bin TL	Yıllık	ithlt	http://www.tuik.gov.tr


Not: Tablo yazar tarafından üretilmiştir.

4. UYGULAMA VE BULGULAR

YSA modellerinin geliştirilmesinde MATLAB R2013a programından faydalanılmıştır. 240 tane yıllık verinin %70'lik (168 adet) bölümü eğitim, %15'lik (36 adet) bölümü geçerlilik, kalan %15'lik (36 adet) bölümü ise rastgele seçilerek test için ayrılmıştır. Gizli katman sayısının

belirlenmesinde literatürde herhangi bir formül bulunmamaktadır. Chamzini, vd. (2012:1001-1002) çalışmasında 7 girdi, 24 gizli katman ve 1 çıktı nöronuyla geliştirdikleri YSA modeli için en iyi sonucu 24 gizli katman deneyerek bulmuşlardır. Islam (2013) çalışmasında nöronların optimal sayısını bulabilmek için gizli katman sayısını 5 ile 36 arasında değiştirmiştir. Tkacz ve Hu (1999:4) GSYH büyümesini öngörmek amacıyla çalışmasında yeterli gizli nöron varsa herhangi bir doğrusal olmayan fonksiyonun doğruluk derecesine yaklaştırılabileceğini söylemişlerdir.

Modelde Öğrenme algoritması olarak Levenberg-Marquardt algoritması seçilmiştir. Levenberg-Marquardt maksimum komşuluk üzerine kurulmuş en az kareler hesaplama metodudur. Gauss-Newton ve Gradient-Descent algoritmalarının kısıtlamalarını kaldıran ve en iyi özelliklerinden oluşan bir algoritmadır (Aşkın, İskender ve Mamızadeh, 2011:908).



Şekil 1. YSA Model Profili


Bu çalışmada en iyi sonuca ulaşabilmek için 2, 3, 4 ve 5 gizli katman kullanılarak denemeler yapılmıştır. En iyi sonuç gizli katmanın 5 seçilmesi ile ortaya çıkmıştır. Model profili Şekil 1’de verilmiştir.

Tablo 2. Gizli Katman Sayıları ve Eğitim, Geçerlilik, Test Değerleri İçin R Değerleri

Gizli katman sayısı (N)	Eğitim	Geçerlilik	Test
2N	0,97294	0,99042	0,993580
3N	0,309338	-0,871062	0,912052
4N	0,992670	0,990308	0,999502
5N	0,998831	0,999720	0,999268

Not: Tablo yazar tarafından üretilmiştir.

Tablo 2’de oluşturulan YSA modeli için eğitim, geçerlilik ve test sonuçları ve bunlardan elde edilen R değerleri verilmiştir. Verilen R değerlerine göre gizli katman sayısı arttıkça öğrenmenin daha iyi sonuçlar verdiği görülmüştür.



Şekil 2. GSYİH Gerçek Değeri ve YSA Tahmin Değeri

Şekil 2’de 1998-2017 yılları arasındaki GSYİH değerlerinin gerçek değeri ve YSA sonucu elde edilen tahmin değerinin grafiği verilmiştir. Görüldüğü üzere tahmin değerleri gerçek değerlere çok yakın çıkmıştır. Bu durum GSYH tahmininde YSA modelinin güçlü sonuçlar verdiğini göstermektedir.

Tablo 3. GSYH Gerçek ve Tahmin Değerleri

Tarih	Gerçek Değerler	YSA Tahmin Değerleri
1998	710091468,8	745610416,7
1999	686024304	708720283
2000	731576737,1	727343784,7
2001	687957858,6	692044796,8
2002	732195465,8	736857512,9
2003	773258855,3	779362088,5
2004	847834433,7	855267662,5
2005	924223072,5	929074123,1
2006	989932592	1003093284
2007	1039730731	1062045065
2008	1048519070	1083604479
2009	999191848,1	1016265149
2010	1083996979	1095972567
2011	1204466935	1219644671
2012	1262160182	1295454616
2013	1369334107	1392874934
2014	1440083365	1453857103
2015	1527725206	1521508134
2016	1576365403	1578154812
2017	1693665799	1659734354

Tablo yazar tarafından üretilmiştir.

Tablo 3 Türkiye'nin 1998-2017 yılları arasındaki GSYH verilerinin gerçek değerlerini ve YSA modeli ile elde edilen tahmin değerlerini göstermektedir. Tablo 3'te görüldüğü üzere YSA' dan elde edilen tahminlerin gerçek değerlere çok yakın olduğu görülmektedir.

Aşağıda verilen formüllere göre R^2 , RMSE, MAE ve MAPE değerleri 5 gizli katmanda hesaplanarak YSA modelinin performansını ölçmek amaçlanmıştır. Sonuç Tablo 4'te verilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^N (A_i - P_i)^2}{\sum_{i=1}^N (A_i - \bar{A})^2} \quad (4.2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (A_i - P_i)^2}{N}} \quad (4.3)$$

$$MAE = \frac{\sum_{i=1}^N |A_i - P_i|}{N} \quad (4.4)$$

$$MAPE = \frac{\sum_{i=1}^N \frac{|A_i - P_i|}{A_i}}{N} * 100 \quad (4.5)$$

Bu formüllerde;

A_i = Gözlenen Değer,

P_i = Tahmin Edilen Değer,


\bar{A}_i = Gözlenen Değerlerin Ortalaması,

N = Gözlem Sayısı


Tablo 4. 5 Gizli Katman Sayısı İle Elde Edilen R^2 , RMSE, MAE ve MAPE(%) Değerleri

Gizli Katman Sayısı	R^2	RMSE	MAE	MAPE
5N	0,996140651	19444911,6	15845918,2	32,29791086

Lewis' e (1982) göre MAPE değeri %10'un altında ise model "çok iyi" , %10 ile %20 arasında ise "iyi" , %20 ile %50 arasında olan modelleri "kabul edilebilir" ve değer %50'nin üstünde ise "yanlış ve hatalı" olarak bölümlendirmiştir. 5 gizli katman ile eğitilip test edilen YSA modelini gösteren Tablo 4'e göre $R^2 = 0,996140651$, $RMSE = 19444911,6$, $MAE = 15845918,2$ ve $MAPE = \%32,29791086$ olarak hesaplanmıştır. MAPE değerinin Lewis'in kriterlerine göre %20 ile %50 arasındaki %32 değerini alması modelin kabul edilebilir bir model olduğunu göstermektedir.

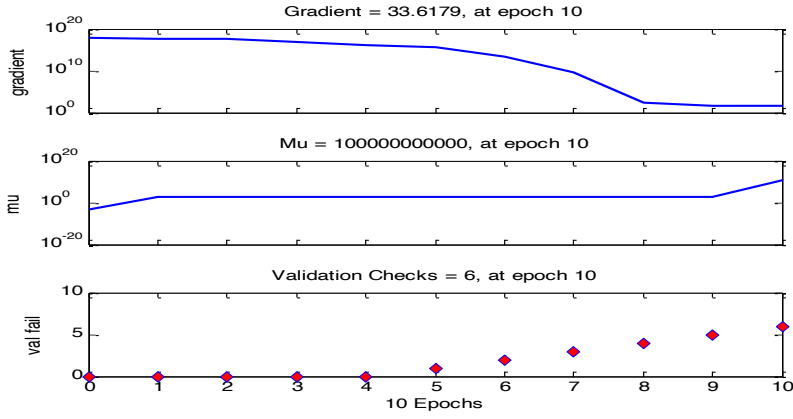


Şekil 3. Gizli Katman İle Oluşan Hata Grafiği

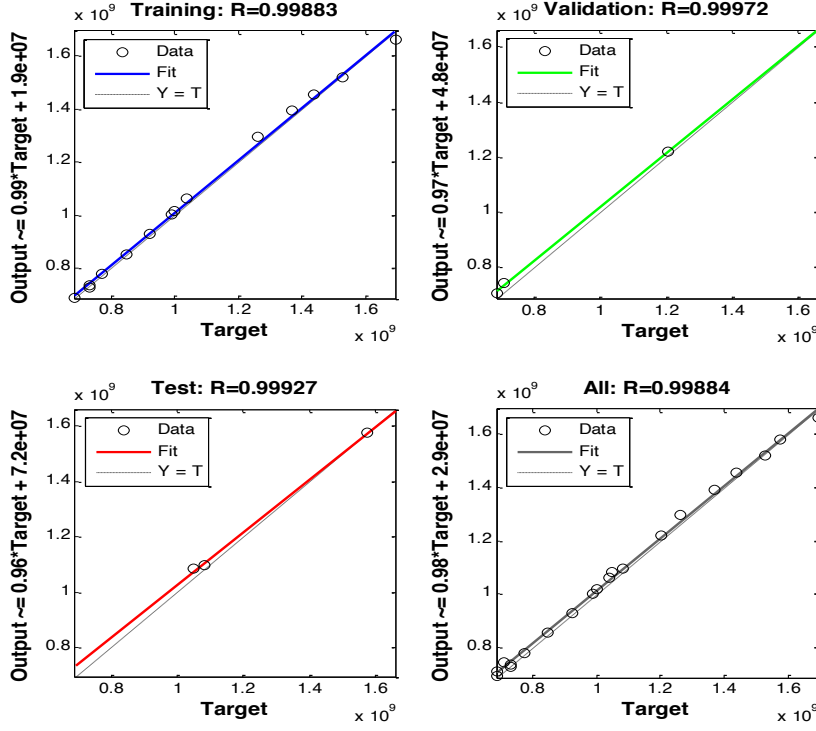


Şekil 4. Gizli Katmanda Öğrenilen Modelin Geçerlilik Performansı

Şekil 4 eğitim seti ve doğrulama setinin 10.iterasyon boyunca aldıkları ortalama hata değerlerini göstermektedir. En iyi doğrulama performansının 4. iterasyon da sağlandığı görülmektedir.



Şekil 5. Gizli Katmanda Oluşan Öğrenme Eğrileri



Şekil 6. YSA Modelinin 5 Gizli Katmanda Eğitim, Geçerlilik, Test ve Bütün Sonuçlarının R Değerleri

Şekil 6'ya bakıldığında oluşturulan YSA modelinin fit bir görünüm sergilediği görülmektedir.

5. TARTIŞMA

YSA ile GSYH tahmini için daha önce yapılan çalışmalarda (Aıken, 2000; Junoh, 2004; Amınian vd., 2006; Liliana ve Napitupulu, 2010; Vrbka, 2016; Chuku vd., 2017; Maliki vd., 2014; Pasarica ve Popescu, 2015; Söyler ve Kızılkaya, 2015 ve Jahn, 2018) YSA'nın tahmin etme gücünün yüksek olduğu sonucuna ulaşılmıştır. Ayrıca Chuku vd., 2017; Söyler ve Kızılkaya, 2015; Maliki vd., 2014; Wang ve Elhag, 2007; Tkacz ve Hu, 1999 yapay sinir ağlarına ek olarak başka modellerde kullanarak yapay sinir ağlarının diğer modellere göre daha iyi sonuç verdiğini tespit etmişlerdir. Düzgün (2008) ise çalışmasında ARIMA ile YSA

modellerini kullanarak Türkiye için GSYH tahmininde bulunmuş ve ARIMA modelinin YSA'ya göre daha başarılı olduğu sonucuna ulaşmıştır.

İncelenen literatüre benzer sonuç olarak bu çalışmada da YSA modelinin tahmin etme gücünün yüksek olduğu sonucuna ulaşılmıştır. Ayrıca literatürde Türkiye için GSYH tahmini yapılan çalışma sayısının oldukça az olduğu görülmüş olup bu çalışmanın literatüre katkı sağlayacağı düşünülmektedir.

6. SONUÇ VE ÖNERİLER

Günümüzde internetin yaygınlaşması, gelişen teknoloji ve ekonomilerin etkin yapısı sayesinde oluşan veri çokluğu insanoğlunu geleneksel sistemlerin aksine insan beynini taklit edebilen, hızlı çözümler sunabilen bir sisteme yönlendirmiştir.

Yapay zeka, insan beyninin taklit edilmesi gereksiniminden ortaya çıkan bir teknolojidir. Bu teknoloji sayesinde ortaya çıkan YSA çeşitli tahmin tekniklerini içerisinde barındırmaktadır. YSA, tahmin modellemesi kurmamızı sağlayarak gelecekte neyin nasıl olacağı konusundaki belirsizleri gidermeye yardımcı olan bir teknolojidir.

Birçok alanda hayatımızdaki yerini alan YSA ekonomi alanında da yaygın olarak kullanılmaktadır. Dünya nüfusunun sürekli artması, kaynakların kıtlığı, ihtiyaçların çeşitliliği ekonominin önemini artırmıştır. Ülkelerin gelişmişlik düzeyini ölçen, ekonomisi hakkında en genel bilgiyi veren en önemli kavramlardan birisi GSYH'dır. Milli gelirin temel belirleyicilerinden biri olan GSYH ülkelerin ekonomik büyüklüğünü hakkında bilgi sahibi olmamızın yanı sıra ekonomide bir genişlemeye veya daralmaya gidildiğini görebilmemiz açısından önem arz eden bir göstergedir. Bu bağlamda bu çalışmada gelişmekte olan Türkiye ekonomisi için GSYH tahmini yapılmıştır.

YSA'dan elde edilen sonuçlara baktığımızda modelde öncelikle 2 ile 5 arası gizli katman sayıları deneyerek tahminler oluşturulmuştur. En iyi sonuca gizli katman sayısının 5 olarak seçilmesi ile ulaşılmıştır. 5 gizli katman seçilerek oluşturulan YSA modelinde eğitim, geçerlilik ve test R^2 değerleri 0.99 olarak bulunmuştur. YSA tahmin değerleri gerçek GSYH değerlerine çok yakın çıkmıştır. 5 gizli katmanda $R^2=0,996140651$, $RMSE=19444911,6$, $MAE=15845918,2$ ve $MAPE=32,29791086$ olarak bulunmuştur. MAPE değeri Lewis' in kriterlerine göre yorumlanmış olup, %20 ile %50 arasında bir değer aldığından modelin kabul

edilebilir olduğu sonucuna ulaşılmıştır. Ayrıca bu değerler gizli katman sayısı arttıkça istatistiksel olarak daha iyi sonuçlar çıkacağı görüşünü de desteklemiştir. YSA' dan elde edilen GSYH tahmin değerlerinin gerçek değerlerine çok yakın çıkması YSA' nın tahmin gücünün yüksek olduğunu göstermiştir. İncelenen literatürle benzer olarak bu çalışmada da YSA' nın tahmin gücünün yüksek olduğu saptanmıştır.

Bu çalışma yıl sayısı, değişken sayısı verilerin yıllık olarak seçilmesi gibi bazı kısıtlılıklara sahiptir. Daha fazla yıl aralığı seçilerek, çeşitli değişkenler eklenerek ve veriler günlük veya aylık olarak seçilerek çalışma geliştirilebilir. Aynı zamanda farklı ağ modelleri kullanılarak, gizli katman sayısı ve deneme sayısı artırılarak daha başarılı sonuçlar da elde edilebilir.

KAYNAKÇA

Aiken, M. (2000), Forecasting the United States Gross Domestic Product with a Neural Network, *Journal of International Information Management*, 9(1), 67-75.

Aminian, F., Suarez, D., Aminian, M. and Walz, D. T. (2006), Forecasting Economic Data with Neural Networks, *Computational Economics*, 28, 71-88.

Aşkın, D., İskender, İ. ve Mamızadeh, A. (2011), Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 26(4), 905-913.

Chamzını-Yazdani, A., Yakhchali, S. H., Volungeviçienė, D. and Zavadskas, E. K. (2012), Forecasting Gold Price Changes by Using Adaptive Network Fuzzy Inference System. *Journal of Business Economics and Management*, 13(5), 994-1010.

Chuku, C., Oduor, J. and Simpasa, A. (2017), Intelligent Forecasting of Economic Growth for African Economies: Artificial Neural Networks Versus Time Series and Structural Econometric Models, *Washington Research Program on Forecasting*, 1-28.

Düzgün, R. (2008), A Comparison of Artificial Neural Networks and ARIMA Models Success in GDP Forecast, *Marmara Üniversitesi İ. İ. B. F. Dergisi*, XXV(2), 165-176.

<http://databank.worldbank.org>, Erişim Tarihi: 29.09.2018.

<https://evds2.tcmb.gov.tr/>, Erişim Tarihi: 27.09.2018.

<http://tuik.gov.tr/UstMenu.do?metod=temelist>, Erişim Tarihi: 10.01.2019.

<http://tuik.gov.tr/PreHaberBultenleri.do?id=27840>, Erişim Tarihi:17.01.2019.

<http://www.tuik.gov.tr>, Erişim Tarihi:25.09.2018.

Islam, R. (2013), Predicting Recessions: Forecasting US GDP Growth Through Supervised Learning, *Department of Electrical Engineering*, Stanford University.

Jahn, M. (2018), Artificial Neural Network Regression Models: Predicting GDP Growth, *Hamburg Institute of International Economics*, 185, 1-15.

Junoh, M. Z. H. M. (2004), Predicting GDP Growth in Malaysia Using Knowledge – Based Economy Indicators: A Comparison Between Neural Network and Econometric Approach, *Sunway College Journal*, 1, 39- 50.

Kaplan, M. ve Tekeli, R. (2008), *Ekonomide Bekleyişler ve Tahmin: Yapay Sinir Ağları Uygulamaları*, Tablet Yayınları, Konya.

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

Liliana, S. T., and Napitupulu, T. A. (2010), Artificial Neural Network Application in Gross Domestic Product Forecasting an Indonesia Case, *Second International Conference on Advances in Computing, Control and Telecommunication Technologies*, Indonesia.

Maliki, O. S., Emmanuel, I. and Obinwanne, E. E. (2014), Neural Network Applications in the Forecasting of GDP of Nigeria as a Function of Key Stock Market Indicators, *Advances in Applied Science Research*, 5(3), 204-212.

Pasarica, A. E., and Popescu, M. (2015), Prediction of the GDP of Romania Using Neural Networks, *Interdisciplinary Approaches Between Traditional and Modern Methods Nord 1 International Conference*, Romania.

Söyler, H. ve Kızılkaya, O. (2015), Türkiye'nin GSYİH Tahmini İçin Yapay Sinir Ağları Model Performanslarının Karşılaştırılması, *C.Ü. İktisadi ve İdari Bilimler Dergisi*, 16(1), 45-58.

Tkacz, G. and Hu, S. (1999), Forecasting GDP Growth Using Artificial Neural Networks, *Department of Monetary and Financial Analysis Bank of Canada*, 1-24.

Vrbka, J. (2016), Predicting Future GDP Development by Means of Artificial Intelligence, *Littera Scripta*, 9(3), 154-167.

Wang, Y.M. and Elhag, T. M. S. (2007), A Comparison of Neural Network, Evidential Reasoning and Multiple Regression Analysis in Modelling Bridge Risks, *Expert Systems with Applications*, 32, 336-348.