

ANFIS YÖNTEMİ KULLANILARAK TÜRKİYE'DE GSYİH TAHMİNİ¹



Kafkas Üniversitesi
İktisadi ve İdari Bilimler
Fakültesi
KAÜİBFD
Cilt, 13, Sayı 26, 2022
ISSN: 1309 – 4289
E – ISSN: 2149-9136

Makale Gönderim Tarihi: 21.06.2022 Yayına Kabul Tarihi: 08.11.2022

Derya ŞENCAN
Gelir Uzmanı
T.C. Hazine ve Maliye Bakanlığı
Gelir İdaresi Başkanlığı,
Isparta, Türkiye
sencanderya80@gmail.com
ORCID ID: 0000-0001-6723-6198

Arzu ŞENCAN ŞAHİN
Prof. Dr.
Isparta Uygulamalı Bilimler
Üniversitesi
Teknoloji Fakültesi,
Isparta, Türkiye
arzusencan@isparta.edu.tr
ORCID ID: 0000-0001-8519-4788

ÖZ | Gayri Safi Yurtiçi Hasıla (GSYİH), bir ülkenin makro ekonomik durumunun önemli göstergelerinden biridir. GSYİH büyümesinin büyük bir hassasiyetle tahmin edilmesi; politika yapıcılar, merkez bankaları ve diğer ekonomik aktörler için mali ve para politikalarının belirlenmesi ve planlanmasında önem taşımaktadır. Bu çalışmada, Türkiye'nin ekonomik büyümesini (GSYİH) tahmin etmek için yapay zekâ yöntemlerinden biri olan uyarlamalı ağ tabanlı bulanık mantık çıkarım sistemi (ANFIS) kullanılmıştır. İhracat, ithalat, devlet harcamaları, tüketici fiyat endeksi (TÜFE) ve enflasyon oranı girdilerine bağlı olarak ekonomik büyüme yani GSYİH tahmin edilmiştir. ANFIS modelinin güvenilirliği, çeşitli istatistiksel göstergeler kullanılarak belirlenmiştir. Ortalama mutlak yüzde hata oranı (MAPE) 1.5137 ve determinasyon katsayısı (R^2) 0.9949 olarak elde edilmiştir. Bu değerlerin kabul edilebilir seviyelerde olduğu ve ekonomik büyümenin tahmin edilmesinde bu modelin başarıyla kullanılabileceği görülmüştür. Çalışmadan elde edilen sonuçlar, GSYİH büyümesini büyük bir hassasiyetle tahmin etmek, maliye ve ekonomi politikalarını belirlemek ve planlamak için kullanılabilir.

Anahtar Kelimeler: Ekonomik büyüme, tahmin, ANFIS

JEL Kodları: O4, F63, C53, C45

Alan: İktisat

Türü: Araştırma

DOI: 10.36543/kauibfd.2022.039

Atıfta bulunmak için: Şencan, D. & Şencan Şahin, A. (2022). ANFIS yöntemi kullanılarak Türkiye'de GSYİH tahmini. *KAÜİBFD*, 13(26), 953-971.

¹ İlgili çalışmanın etik kurallara uygunluğu beyan edilmiştir.

FORECASTING GDP IN TÜRKİYE USING ANFIS METHOD



Kafkas University
Economics and Administrative
Sciences Faculty
KAUJEASF
Vol. 13, Issue 26, 2022
ISSN: 1309 – 4289
E – ISSN: 2149-9136

Article Submission Date: 21.06.2022

Accepted Date: 08.11.2022

Derya ŞENCAN
Revenue Specialist
T.R. Ministry of Treasury and
Finance
President of Revenue Management,
Isparta, Türkiye
sencanderya80@gmail.com
ORCID ID: 0000-0001-6723-6198

Arzu ŞENCAN ŞAHİN
Prof. Dr.
Isparta University of Applied
Sciences
Technology Faculty,
Isparta, Türkiye
arzusencan@isparta.edu.tr
ORCID ID: 0000-0001-8519-4788

ABSTRACT | Gross Domestic Product (GDP) is one of the important indicators of a country's macroeconomic status. Predicting GDP growth with great precision; It is important for policymakers, central banks and other economic actors in determining and planning fiscal and monetary policies. In this study, an adaptive network-based fuzzy logic inference system (ANFIS), which is one of the artificial intelligence methods, is used to predict Turkey's economic growth (GDP). Economic growth, namely GDP, is estimated based on the inputs of exports, imports, government expenditures, consumer price index (CPI) and inflation rate. The reliability of the ANFIS model was determined using various statistical indicators. The mean absolute percent error rate (MAPE) was 1.5137 and the coefficient of determination (R^2) was 0.9949. It has been seen that these values are at acceptable levels and this model can be used successfully in estimating economic growth. The results from the study can be used to predict GDP growth with great precision, and to set and plan fiscal and economic policies.

Keywords: Economic growth, forecasting, ANFIS

JEL Codes: O4, F63, C53, C45

Scope: Economics

Type: Research

1. GİRİŞ

Gayri safi yurtiçi hasıla (GSYİH), bir ülke veya bölgenin ekonomisinde belirli bir süre içinde üretilen tüm ürün ve hizmetlerin değerini ifade eder ve çoğu zaman ülkenin ekonomik gelişmişliğini ölçmek için önemli göstergelerden biri olarak kabul edilir. Bu nedenle, GSYİH'nın bilimsel ve doğru bir şekilde tahmin edilmesi, ekonomik kalkınma hedeflerinin etkin bir şekilde belirlenmesinde önemli bir rol oynamaktadır. Tablo 1'de Türkiye ve bazı ülkelerde 1980-2020 yılları arasındaki GSYİH değişimleri görülmektedir. ABD ve Çin dışındaki ülkelerde GSYİH değerlerinin inişli çıkışlı bir seyir izlediği görülmektedir. Türkiye'de 2014'ten bu yana GSYİH'nın düşme eğiliminde olduğu görülmektedir.

Tablo 1: Türkiye ve Bazı Ülkelerdeki GSYİH Değişimleri (IMF, 2021)

	GSYİH (\$)									
	1980	1985	1990	1995	2000	2005	2010	2015	2020	
ABD	12553	18199	23848	28671	36313	44034	48586	56730	63358	
Almanya	11110	8679	20249	31830	23925	35020	42380	41107	46216	
Brezilya	1230	1720	3106	4852	3772	4820	11333	8846	6823	
Bulgaristan	3673	3821	2920	1958	1625	3870	6713	7080	10006	
Çin	307	293	347	604	951	1751	4500	8034	10511	
Endonezya	673	658	771	1254	870	1404	3178	3368	3922	
Güney Kıbrıs	4550	4825	10360	15397	14465	25527	31439	23429	26785	
Macaristan	2151	2023	3312	4491	4619	11188	13173	12690	15866	
Yunanistan	5898	4792	9598	12888	12165	22418	26743	17997	17657	
Türkiye	2134	1835	3738	3881	4238	7351	10533	10974	8610	

GSYİH gibi makroekonomik verileri tahmin etmek basit bir süreç değildir. Verileri tahmin etmek için, bağımlı değişken ile bağımsız değişken arasındaki nedensel ilişkiyi göz önünde bulundurmak gerekir. Bu süreç aynı zamanda, kullanılan veri ve yöntemlerle ilgili olarak tahmincilerin ekonomik sezgisini ve yargısını da gerektirir. Tahminciler tarafından yapılan varsayımlarda herhangi bir kusur varsa, modeller yanlış tahminler üretebilir. En uygun GSYİH tahmin yönteminin seçimi, araştırmacılar ve akademisyenler tarafından araştırma konusu olmaktadır (Kapetanios, Marcellino & Papailias, 2016). Literatürde, bazı GSYİH büyüme tahmin modelleri öne çıkmaktadır (Carriero, Galvao & Kapetanios, 2019; Claveria, Monte & Torra, 2019; Kapetanios vd., 2016; Marcellino, Porqueddu, & Venditti, 2016; Clark & Ravazzolo 2015; Ferrara, Marcellino & Mogliani, 2015; Schorfheide & Song, 2015). GSYİH tahmini ile ilgili mevcut literatürün çoğu, başta Amerika Birleşik Devletleri ve Avrupa olmak üzere gelişmiş ekonomiler üzerine yapılmış olup gelişmekte olan ülkelerle ilgili literatür sınırlıdır. GSYİH tahmini için de

genelde istatistiksel yöntemler kullanmıştır (Alaminos, Salas & Fernández-Gámez, 2022).

Birçok geleneksel ekonomik tahmin modelinin aksine, yapay zekâ modelleri çoğunlukla sadece tahminle ilgilenir. Yapay zekâ modelleri, geleneksel ekonomik tahmin modellerinden daha esnektir ve önceden belirlenmiş varsayımlar veya yargılar olmaksızın tahminler üretebilir. Birçok alanda farklı yapay zekâ modelleri aktif olarak uygulanmaktadır. Bu yöntemlerden biri uyarlamalı ağ tabanlı bulanık mantık çıkarım sistemidir (ANFIS).

Bu çalışmada Türkiye’de ihracat, ithalat, devlet harcamaları, tüketici fiyat endeksi (TÜFE) ve enflasyon oranı değişkenlerine bağlı olarak GSYİH tahmini için ANFIS modeli kullanılmıştır. Çalışmada ilk olarak literatür taraması yapılmıştır. Daha sonra çalışmada GSYİH tahmininde kullanılan yapay zeka yöntemlerinden biri olan ANFIS yöntemi ve uygulamasına yer verilmiştir. Son olarak elde edilen bulgular ve sonuçlar verilmiştir.

2. LİTERATÜR TARAMASI

Mevcut literatürde GSYİH tahmin çalışmalarının büyük bir kısmı ABD ve Avrupa ülkeleri için yapılmıştır (Clements & Galvão 2008; Kouziokas, 2020; Clark & Ravazzolo, 2015; Barsoum & Stankiewicz, 2015 ; Carriero vd., 2019). Bu çalışmalarda farklı tahmin yöntemleri kullanılmıştır. Öte yandan, ülkemizde daha çok istatistiksel yöntemler kullanılarak GSYİH tahmin çalışmaları yapılmıştır. Yapay zeka yöntemlerinin kullanıldığı çalışmalar oldukça sınırlıdır. Literatür taramasında istatistiksel yöntemler ve yapay zeka yöntemleriyle GSYİH tahmini yapılan çalışmalar incelenmiştir. Tablo 2 ’de GSYİH tahmininde kullanılan değişkenlerin ve kullanılan yöntemlerin verildiği bir literatür araştırması özeti verilmiştir.

Tablo 2: GSYİH Tahmini Konusunda Literatürde Yapılan Çalışmalar

Yazar	Ülke	Değişken	Metot
Clements ve Galvão, 2008	ABD	Ekonomik büyüme	Karışık frekanslı veri analizi (MIDAS)
Barsoum ve Stankiewicz, 2015	ABD	GSYİH	Karışık frekanslı veri analizi (MIDAS)
	ABD, İngiltere, Almanya, İtalya, Fransa, Japonya	Makro-ekonomik tahmin	Karışık frekanslı veri analizi (MIDAS)
Kouziokas, 2020	ABD	İhracatı, işsizlik oranı, nüfus, GSYİH	Yapay zeka yöntemleri
Kordanulivd., 2017	Avrupa ülkeleri	Devlet harcamaları, yatırımlar, doğurganlık	Yapay sinir ağları (YSA)

		oranı, GSYİH	
Zhang ve Rudholm, 2013	İsveç	Kısa vadeli GSYİH	ARIMA
Yoon, 2021	Japonya	GSYİH	Yapay zeka yöntemleri
Lehmannand Wohlrabe, 2015	Almanya	Kısa ve uzun vadeli GSYİH	Oto regresif kıyaslama
Liu vd., 2020	Çin	GSYİH	Gri tahmin modeli
Barhoumi vd., 2012	Fransa	Aylık GSYİH	Köprü model
Abonazel ve Abd-Elftah, 2019	Mısır	Kısa vadeli GSYİH	ARIMA
Alaminos vd., 2022	Farklı ülkeler	GSYİH	Derin öğrenme yöntemleri
Tkacz, 2001	Kanada	GSYİH	YSA
Cepni, 2019	Brezilya, Meksika, Güney Afrika ve Türkiye	GSYİH	Boyut küçültme yöntemleri
Sanusi vd., 2020	Malezya	İhracat, ithalat, devlet harcamaları, TÜFE, enflasyon oranı, GSYİH	YSA
Ghazo, 2021	Ürdün	TÜFE, GSYİH	ARIMA
Wabomba vd., 2016	Kenya	GSYİH	ARIMA
Mourougane, 2006	Kanada	GSYİH	Sayısal yöntemler
Abdiyeva ve Çetintaş, 2017	Kırgızistan	Kamu Harcamaları, ekonomik büyüme	ARDL
Söyler ve Kızılkaya, 2015	Türkiye	GSYİH	YSA
Erdoğan vd., 2018	Türkiye	Ekonomik büyüme	ARDL, FMOLS, DOLS, CCR
Türedi ve Berber, 2010	Türkiye	Finansal kalkınma, ticari açıklık, ekonomik büyüme	Nedensellik analizi
Şimşek ve Kadılar, 2010	Türkiye	GSYİH, ihracat, beşeri sermaye	Nedensellik analizi
Çiçek vd., 2010	Türkiye	Borçlanma, ekonomik büyüme	Regresyon analizi
Diler, 2016	Türkiye	Kamu harcamaları, ekonomik büyüme	ARDL
Özgür, 2015	Türkiye	İhracat, ithalat, ekonomik büyüme	ARDL
Genç ve Eser, 2021	OECD ülkeleri	Ekonomik büyüme, vergi	Panel veri analizi

Tablo 2’de verilen literatür çalışmalarında görüldüğü gibi birçok ülke için GSYİH tahminleri farklı yöntemlerle yapılmıştır. Türkiye için de genel

olarak geleneksel ekonomik tahmin modelleri kullanılarak GSYİH tahminleri yapılmıştır. Literatürdeki çalışmalara bakıldığında yapay zekâ yöntemlerinden biri olan ANFIS modelinin GSYİH tahmini için kullanılmadığı görülmektedir. Bu çalışmada literatürdeki çalışmalardan farklı olarak; Türkiye’de ihracat, ithalat, devlet harcamaları, tüketici fiyat endeksi (TÜFE) ve enflasyon oranı değişkenlerine bağlı olarak GSYİH tahmini için ANFIS modeli kullanılmıştır. Çalışmadan elde edilen sonuçlar, ekonomik büyümenin tahmin edilmesinde bu metodun başarılı bir şekilde kullanılabileceğini göstermiştir.

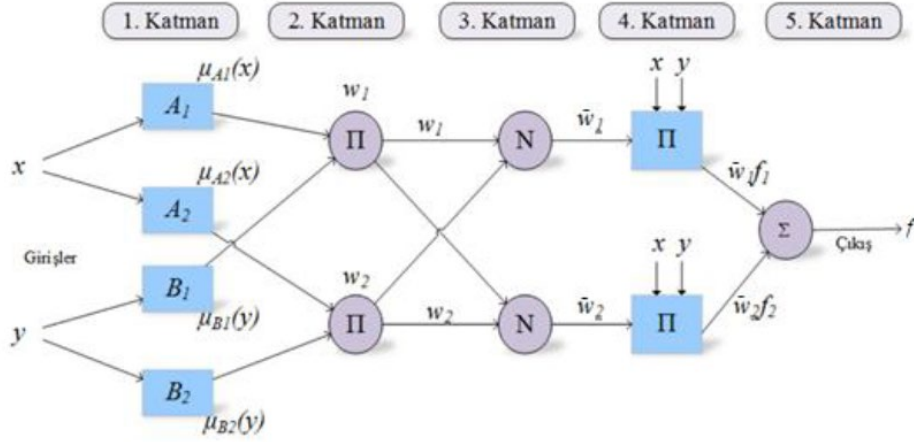
3. YÖNTEM

3.1. ANFIS Yöntemi ve Yapısı

1993 yılında Jang tarafından önerilen ANFIS, yapay sinir ağlarının hesaplama kabiliyetini ve bulanık mantığın çıkarım yöntemini kullanabilen hibrit bir yapay zekâ yöntemidir. Hibrit yaklaşımla bulanık mantık daha sistematik ve deneyime daha az bağımlı hale getirilir. ANFIS, hem yapay sinir ağlarını hem de bulanık mantığı birbiriyle uyumlu olarak kullanabildiğinden her iki yöntemin de güçlü yönlerinden yararlanır (Raju, 2011; Jang, 1993). ANFIS, birinci dereceden bir Sugeno tarzı bulanık sistem uygular. Mimarisinde Takagi-Sugeno-Kang formunun kuralını uygular.

Kural: $x \text{ A1 ve } y \text{ B1 ise } f(x) = px + qy + r$

Burada; x ve y girdiler, A ve B bulanık kümeler, f çıktılar, p , q ve r eğitim sürecinde belirlenen tasarım parametreleridir. ANFIS, ağ şeklinde kurullarla birbirine bağlanan birinci kısım öncül ve ikinci kısım sonuç olmak üzere iki kısımdan oluşmaktadır. Bu ağı oluşturmak için beş katman kullanılır. Her katman, Şekil 1’de gösterilen birkaç düğüm yapısını içermektedir (Silarbi, Abderrahmane & Benyettou, 2014; Yakut & Süzölmüş, 2020).



Şekil 1: ANFIS Yapısı

Kaynak: (Haznedar, 2017)

Şekil 1'de görülen ANFIS mimarisinde; x ve y girdi parametrelerini, f çıktı parametresini temsil etmektedir.

1. katmanda her düğüm, düğüm fonksiyonlarını ve girdi değişkenlerinin üyelik fonksiyonlarını (MF) oluşturur. Birinci katman, aldığı x ve y girdilerini üyelik fonksiyonları ile bulanıklaştırır. Üyelik derecelerinin değişimi üyelik fonksiyonları tarafından belirlenir. Üyelik fonksiyonunun şekli uygulama alanına göre değişir. Uygun üyelik fonksiyonu genellikle literatürde deneme yanılma yöntemi ile belirlenir. Bu çalışmada üyelik fonksiyonu olarak Gaussian üyelik fonksiyonu seçilmiştir.

$$O_i^1 = \mu_{A_i} = \exp\left(\frac{-(x-c)^2}{\sigma^2}\right)$$

(1)

2. katmanda tanımlanan kurallar kullanılarak bulanık çıkarım yapılmakta ve YSA sistemine benzer ağırlık fonksiyonları uygulanmaktadır.

$$O_i^2 = W_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2) \quad i = 1, 2, 3, 4$$

(2)

3. katmanda, ağırlık fonksiyonları ile çarpılan bulanık girdi değerlerinin toplam büyüklükleri normalize edilir.

$$O_i^3 = \overline{W}_i = \frac{w_i}{\sum_{j=1}^4 w_j} \quad i = 1, 2, 3, 4 \quad (3)$$

4. katman durulaştırma katmanıdır. Belirli bir kuralın ağırlıklı sonuç değerleri, durulaştırma katmanındaki her bir düğümde hesaplanır.

$$O_i^4 = \overline{W}_i y_i = \overline{W}_i (\alpha_1^i x_1 + \alpha_2^i x_2 + \alpha_3^i) \quad i = 1, 2, 3, 4 \quad (4)$$

5. katman toplam katmanıdır. Bu katmanda sadece bir düğüm vardır. 5. katmandaki her bir düğümün çıkış değeri toplanarak ANFIS sisteminin gerçek değeri elde edilir.

$$O_i^5 = \sum_{i=1}^4 \overline{W}_i y_i = \frac{\sum_{i=1}^4 w_i y_i}{\sum_{i=1}^4 w_i} \quad (5)$$

3.2. Öğrenme Algoritması

ANFIS model yapısında girdi ve çıktı değişkenlerinin bilinmesi gerekmektedir. Modelin öğrenme algoritması hem girdi hem de çıktı değerlerini optimize etmektedir. En yaygın kullanılan öğrenme algoritması hibrit öğrenmedir. Hibrit öğrenme, ileri beslemeli ve geri yayımlı olmak üzere iki kısımdan oluşmaktadır. İleri beslemede girdi değerleri sabit alınarak çıktı değerleri en küçük kareler yöntemi ile hesaplanırken, geri yayılmada hata oranları geriye doğru yayılır ve hatalar minimize edilir. Minimize edilen hata, ortalama karesel hatanın kareködür (RMSE) ve aşağıdaki gibi hesaplanır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{e,i} - t_{a,i})^2}{n}} \quad (6)$$


Bu eşitlikte; $y_{e,i}$ tahmin edilen değeri, $t_{a,i}$ gerçek değeri ve n veri sayısını ifade etmektedir.

3.3. Araştırmanın Etik İzinleri


Yapılan bu çalışmada “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması belirtilen tüm kurallara uyulmuştur. Yönergenin ikinci bölümü olan “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbiri gerçekleştirilmemiştir.

4. UYGULAMA

Bu çalışmada; Türkiye’de ihracat, ithalat, devlet harcamaları, TÜFE ve enflasyon oranı değişkenlerine bağlı olarak GSYİH’nın tahmini için ANFIS modeli kullanılmıştır. Bu değişkenler literatürdeki çalışmalar göz önüne alınarak belirlenmiştir (Sanusi, 2020; Dinh, 2020; Nguyenand Pham, 2020, Alaminos vd., 2022). Çalışmada kullanılan veriler 2003’den 2020’ye kadar olan dönemi kapsamakta olup resmi kaynaklardan alınmıştır (TÜİK,2022; T.C. Strateji ve Bütçe Başkanlığı, 2022). Veriler ANFİS modelinde eğitilmeden önce 0-1 değerleri arasında normalize edilmiştir. Farklı ANFIS yapıları denenmiş ve en uygun model yapısı oluşturulmuştur. Model, 1000 iterasyonla hibrit öğrenme kuralı kullanılarak eğitilmiştir. ANFIS modelinde Gaussian üyelik fonksiyonu kullanılmıştır. Şekil 2 ve Şekil 3’de ara yüz tarafından oluşturulan ANFİS modeli ve yapısı görülmektedir.



Şekil 2: Çalışmada Oluşturulan ANFIS Modeli



Şekil 3: Çalışmada Kullanılan ANFIS Yapısı

Yapılan denemeler sonucunda en uygun ANFIS modeli oluşturulmuş olup modele ait bilgiler Tablo 3'te verilmiştir.

Tablo 3: Optimum ANFIS Modelinin Özellikleri

Düğüm sayısı	47
Lineer parametre sayısı	20
Lineer olmayan parametre sayısı	32
Kural sayısı	4
Üyelik fonksiyonu tipi	Gaussian
Eğitim algoritması	Hibrit
Fuzzy yapısı	Sugeno
İterasyon sayısı	1000

Ayrıca ANFIS modelinin performansı, ortalama mutlak yüzde hata oranı (mean absolute percentage error, MAPE) ve determinasyon katsayısı (coefficient of multiple determination, R^2) gibi istatistiksel göstergelere göre de değerlendirilmiştir. Bu istatistiksel göstergeler, tahmin edilen ve gerçek

değerleri karşılaştırmak için kullanılmakta olup aşağıdaki denklemlerle hesaplanabilir.

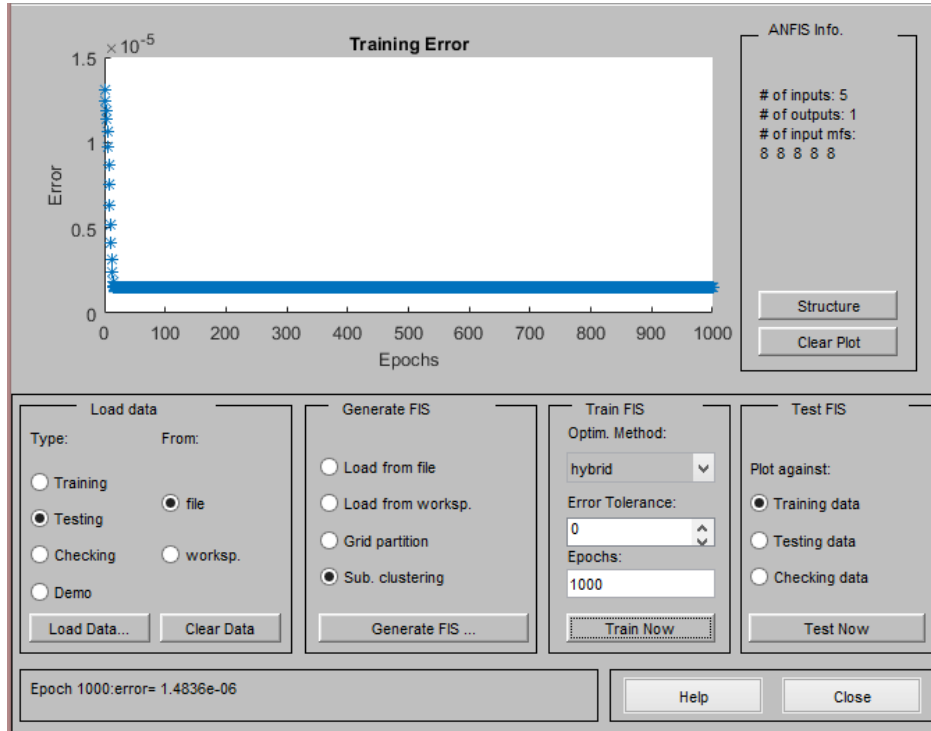
$$MAPE = \frac{1}{n} \left[\frac{\sum_{i=1}^n |y_{e,i} - t_{a,i}|}{\sum_{i=1}^n t_{a,i}} \times 100 \right] \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{e,i} - t_{a,i})^2}{\sum_{i=1}^n (t_{a,m} - \bar{t}_{a,m})^2} \quad (8)$$

Bu eşitliklerde; $y_{e,i}$ tahmin edilen değeri, $t_{a,i}$ gerçek değeri, $\bar{t}_{a,m}$ gerçek değerlerin ortalamasını ve n veri sayısını ifade etmektedir.

5. BULGULAR

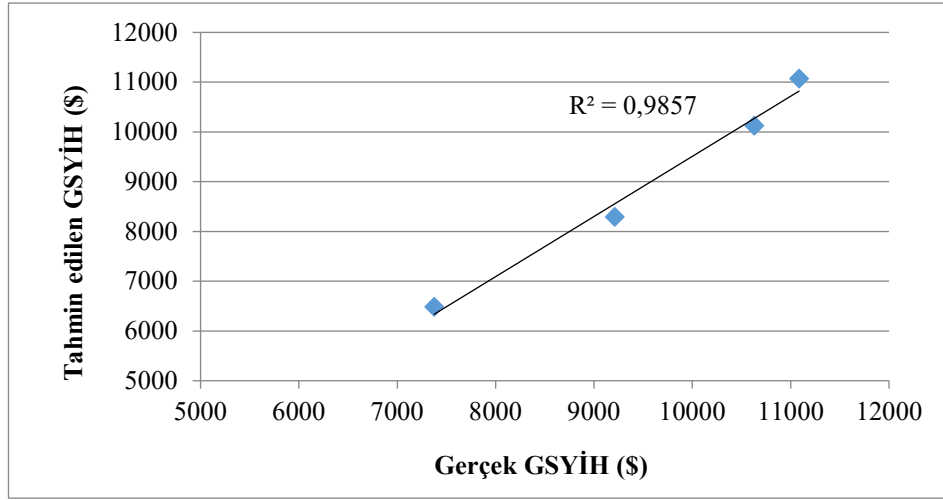
Bu çalışmada, 2003-2020 yılları arasında Türkiye’de GSYİH’nın tahmini için ANFIS modeli kullanılmıştır. Model, MATLAB programında bulanık mantık (fuzzy logic) araç kutusu kullanılarak oluşturulmuştur. Hibrit öğrenme algoritması kullanılarak eğitilen modelde 1000 iterasyon sonucunda RMSE değeri 1.4836e-06 olarak bulunmuş olup bu hatanın kabul edilebilir seviyede olduğu görülmüştür (Şekil 4).



Şekil 4: ANFIS Modelin Eğitim Sonuçları

Ayrıca ANFIS modelin performansını değerlendirmek için MAPE ve R^2 gibi istatistiksel göstergeler de kullanılmıştır. MAPE değerinin düşük, R^2 değerinin büyük olması tahminlerin doğruluğunu göstermektedir. ANFIS modelinde; MAPE değeri 1.5137, R^2 değeri 0.9949 olarak bulunmuş olup kabul edilebilir seviyelerde olduğu görülmektedir.

Şekil 5'te, gerçek ve tahmin edilen GSYİH değerlerin karşılaştırılması verilmiştir. Test verileri için korelasyon katsayı 0.9857 olarak bulunmuştur. Korelasyon katsayısı değerinin 1'e yakın olması modelin başarıyla kullanılabileceği anlamına gelmektedir.




Şekil 5: Gerçek ve ANFİS ile Tahmin Edilen GSYİH Değerlerin Karşılaştırılması

Tablo 4’te rastgele alınan ihracat, ithalat, devlet harcamaları, TÜFE ve enflasyon oranı değişkenlerine bağlı olarak gerçek GSYİH değerleri ve ANFİS modeli ile tahmin edilen GSYİH değerlerinin karşılaştırılması ile yüzde hata değerleri görülmektedir. Tablo 4’te görüldüğü gibi GSYİH tahmininde en büyük yüzde hata %12.04 olarak bulunmuştur.

Tablo 4: Gerçek ve ANFİS ile Tahmin Edilen GSYİH Değerlerinin Karşılaştırması ve Yüzde Hataları

Yıl	İhracat (Bin ABD \$)	İthalat (Bin ABD \$)	TÜFE (2003=100)	Enflasyon (%)	Devlet Harcamaları (Bin TL)	Gerçek GSYİH (\$)	Tahmin edilen GSYİH (\$)	Yüzde hata (%)
2005	73 476 408	116 774 151	122,65	7,72	214.119.894	7375,667	6487	12,04
2010	113 883 219	185 544 332	181,85	6,40	422.733.849	10629,47	10127	4,72
2015	150 982 114	213 619 211	269,54	8,81	801.531.824	11085,32	11076	0,08
2019	180 832 722	210 345 203	440,50	11,84	1.560.855.058	9212,735	8294	9,97

Şekil 6’ da ise 2003 ve 2020 yılları arasındaki gerçek GSYİH değerleri ve ANFİS ile tahmin edilen GSYİH’nın karşılaştırılmalı grafiği verilmiştir. Genel olarak gerçek ve ANFİS ile tahmin edilen GSYİH’nın tüm yıllarda birbirine oldukça yakın olduğu görülmektedir.



Şekil 6: Yıllık Olarak Gerçek ve ANFİS ile Tahmin Edilen GSYİH’nın Karşılaştırması

6. SONUÇ

GSYİH, bir ülkenin ekonomik gelişimini ölçmek için önemli bir göstergedir. Bir ülkenin GSYİH’sının gelecekteki gelişme eğilimi doğru bir şekilde tahmin edilebilirse, ülkenin gelecekteki ekonomik kalkınma politikalarının oluşturulması ve uygulanması üzerinde olumlu bir etkisi olacaktır.

GSYİH, afetler ve ekonomik kriz gibi çok sayıda faktörden etkilendiği için tahmin edilmesi oldukça zor ve karmaşıktır. GSYİH’nın hesaplanmasındaki zorluklar nedeniyle, istatistik kurumları, karmaşık hesaplama yöntemleri kullanmaktadırlar. Bütün iktisadi faaliyetleri ölçmenin imkânsız olması nedeniyle verilerin bulunamadığı veya eksik olduğu durumlarda da tahminler yapılır. Bu tür tahminlerde geleneksel ekonomik

tahmin modellerinden daha esnek olan yapay zekâ modelleri son yıllarda daha başarılı olabilmektedir.

Bu çalışmada, yapay zekâ modellerinden biri olan ANFİS modeli kullanılarak 2003-2020 yılları arasında Türkiye’de ihracat, ithalat, devlet harcamaları, TÜFE ve enflasyon değişkenlerine bağlı olarak GSYİH’nın tahmini yapılmıştır. Bu değişkenler literatürdeki çalışmalar incelenerek belirlenmiştir. Tahminde ANFİS modelinin seçilme nedeni, hem bulanık mantık sistemlerinin hem de yapay sinir ağlarının avantajlarını birlikte bulunduran bir yöntem olmasıdır. Hibrit öğrenme algoritması kullanılarak eğitilen modelde RMSE değeri 1.4836e-06 olarak bulunmuştur. ANFİS modeli ile tahmin edilen GSYİH ile gerçek GSYİH değerleri karşılaştırılmıştır. İstatiksel analizler sonucunda MAPE hata değeri 1.5137 ve R² değeri 0.9949 olarak bulunmuştur. En yüksek yüzde hata değeri %12.04, ortalama yüzde hata değeri ise %6.7 olarak bulunmuştur. Bu değerlerin kabul edilebilir seviyelerde olduğu görülmüştür.

Sonuç olarak; ihracat, ithalat, devlet harcamaları, TÜFE ve enflasyon değişkenlerine bağlı olarak GSYİH değerinin tahmin edilmesinde istatistiksel yöntemlere alternatif olarak ANFİS modelinin başarıyla kullanılabileceği görülmüştür. GSYİH makroekonomideki birçok değişkenle yakın ilişkide olduğundan GSYİH’nin bu değişkenlere bağlı olarak tahmin edilmesi oldukça önemlidir. Geliştirilen model oldukça pratik olup hükümetlerin ekonomik planlar ve politikalar hazırlamasında ön tahminlerin yapılması için faydalı olacaktır.

7. ÇIKAR ÇATIŞMASI BEYANI

Yazarlar arasında çıkar çatışması bulunmamaktadır.

8. MADDİ DESTEK

Bu çalışmada herhangi bir fon veya destekten yararlanılmamıştır.

9. YAZAR KATKILARI

DŞ: Fikir;

DŞ, AŞŞ: Verilerin toplanması ve işlenmesi;

DŞ, AŞŞ: Analizler;

DŞ, AŞŞ: Makale yazımı;

DŞ, AŞŞ: Son kontrol

10. ETİK KURUL BEYANI VE FİKRİ MÜLKİYET TELİF HAKLARI

Bu çalışmada etik kurul izni gerekmemektedir.

11. KAYNAKÇA

- Abdiyeva, R., & Çetintaş, H. (2017). Kamu harcamaları ve ekonomik büyüme arasındaki ilişki: Kırgızistan örneği. *Optimum Ekonomi ve Yönetim Bilimleri Dergisi*, 4(1), 19-34.
- Abonazel, M. R., & Abd-Elftah, A. I. (2019). Forecasting Egyptian GDP using ARIMA models. *Reports on Economics and Finance*, 5(1), 35-47.
- Alaminos, D., Fernández, S. M., García, F., & Fernández, M. A. (2018, July). Data mining for municipal financial distress prediction. *Industrial Conference on Data Mining* (pp. 296-308). Springer, Cham.
- Alaminos, D., Salas, M. B., & Fernández-Gámez, M. A. (2022). Quantum computing and deep learning methods for GDP growth forecasting. *Computational Economics*, 59(2), 803-829.
- Barhoumi, K., Darné, O., Ferrara, L., & Pluyaud, B. (2012). Monthly GDP forecasting using bridge models: Application for the French economy. *Bulletin of Economic Research*, 64, 53-70.
- Barsoum, F., & Stankiewicz, S. (2015). Forecasting GDP growth using mixed-frequency models with switching regimes. *International Journal of Forecasting*, 31(1), 33-50.
- Carriero, A., Galvao, A. B., & Kapetanios, G. (2019). A comprehensive evaluation of macroeconomic forecasting methods. *International Journal of Forecasting*, 35(4), 1226-1239.
- Cepni, O., Güney, I. E., & Swanson, N. R. (2019). Nowcasting and forecasting GDP in emerging markets using global financial and macroeconomic diffusion indexes. *International Journal of Forecasting*, 35(2), 555-572.
- Clark, T. E., & Ravazzolo, F. (2015). Macroeconomic forecasting performance under alternative specifications of time-varying volatility. *Journal of Applied Econometrics*, 30(4), 551-575.
- Claveria, O., Monte, E., & Torra, S. (2019). Evolutionary computation for macroeconomic forecasting. *Computational Economics*, 53(2), 833-849.
- Clements, M. P., & Galvão, A. B. (2008). Macroeconomic forecasting with mixed-frequency data: Forecasting output growth in the United States. *Journal of Business & Economic Statistics*, 26(4), 546-554.

- Çiçek, H., Gözegir, S., & Çevik, E. (2010). Bir maliye politikası aracı olarak borçlanma ve ekonomik büyüme ilişkisi: Türkiye örneği (1990–2009). *CÜ İktisadi ve İdari Bilimler Dergisi*, 11(1), 141-156.
- Diler, H. (2016). Kamu harcamaları–ekonomik büyüme: Türkiye üzerine bir uygulama. *Journal of Economic Policy Researches*, 3(1), 21-36.
- Dinh, D. V. (2020). Impulse response of inflation to economic growth dynamics: VAR model analysis. *Journal of Asian Finance, Economics and Business*, 7(9), 219-228.
- Erdoğan, L., Tiryaki, A., & Ceylan, R. (2018). Türkiye'de uzun dönem ekonomik büyümenin belirleyicilerinin ARDL, FMOLS, DOLS ve CCR yöntemleriyle tahmini. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 36(4), 39-57.
- Ferrara, L., Marcellino, M., & Mogliani, M. (2015). Macroeconomic forecasting during the great recession: The return of non-linearity?. *International Journal of Forecasting*, 31(3), 664-679.
- Genç, M. C., & Eser, L. Y. (2021). Ekonomik büyüme ile vergi kompozisyonu arasındaki ilişki: OECD ülkeleri için panel veri analizi. *Maliye Dergisi*, 180, 191-207.
- Ghazo, A. (2021). Applying the ARIMA model to the process of forecasting GDP and CPI in the Jordanian economy. *International Journal of Financial Research*, 12(3), 70.
- Haznedar B. 2017. *Benzetilmiş tavlama algoritması ile adaptif ağ tabanlı bulanık mantık çıkarım sisteminin (ANFIS) eğitilmesi*. Yayınlanmamış doktora tezi, Erciyes Üniversitesi, Kayseri.
- IMF (2021). <https://www.imf.org/en/Publications/WEO/weo-database/2021/October>
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665-685.
- Kapetanios, G., Marcellino, M., & Papailias, F. (2016). Forecasting inflation and GDP growth using heuristic optimisation of information criteria and variable reduction methods. *Computational Statistics & Data Analysis*, 100, 369-382.
- Kordanuli, B., Barjaktarović, L., Jeremić, L., & Alizamir, M. (2017). Appraisal of artificial neural network for forecasting of economic parameters. *Physica A: Statistical Mechanics and its Applications*, 465, 515-519.
- Kouziokas, G. N. (2020). A new W-SVM kernel combining PSO-neural network transformed vector and bayesian optimized SVM in GDP forecasting. *Engineering Applications of Artificial Intelligence*, 92, (103650), 1-11.
- Lehmann, R., & Wohlrabe, K. (2015). Forecasting GDP at the regional level with many predictors. *German Economic Review*, 16(2), 226-254.

- Liu, C., Xie, W., Lao, T., Yao, Y. T., & Zhang, J. (2020). Application of a novel grey forecasting model with time power term to predict China's GDP. *Grey Systems: Theory and Application*, 2043–9377.
- Marcellino, M., Porqueddu, M., & Venditti, F. (2016). Short-term GDP forecasting with a mixed-frequency dynamic factor model with stochastic volatility. *Journal of Business & Economic Statistics*, 34(1), 118-127.
- Mourougane, A. (2006). Forecasting monthly GDP for Canada. *OECD Economics Department Working Papers* No. 515.
- Nguyen, L. P., & Pham, V. H. T. (2020). Trade of ICT products, government, and economic growth: Evidence from East Asia-Pacific region. *Journal of Asian Finance, Economics and Business*, 7(8), 175-183.
- Özgür, M. I. (2015). İhracat, ithalat ve ekonomik büyüme arasındaki nedensellik ilişkileri: Türkiye örneği. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 7(2).
- Raju, D., Sumalatha, M., & Ramani, Lakshmi KV (2011). Solving uncertain problems using ANFIS. *International Journal of Computer Applications*, 29 (11),14–21.
- Sanusi, N. A., Moosin, A. F., & Kusairi, S. (2020). Neural network analysis in forecasting the Malaysian GDP. *The Journal of Asian Finance, Economics, and Business*, 7(12), 109-114.
- Schorfheide, F., & Song, D. (2015). Real-time forecasting with a mixed-frequency VAR. *Journal of Business & Economic Statistics*, 33(3), 366-380.
- Silarbi, S., Abderrahmane, B., & Benyettou, A. (2014). Adaptive network based fuzzy inference system for speech recognition through subtractive clustering. *International Journal of Artificial Intelligence & Applications*, 5(6), 43.
- Söyler, H., & Kızılkaya, O. (2015). Türkiye'nin GSYİH tahmini için yapay sinir ağları model performanslarının karşılaştırılması. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 16(1), 45-58.
- Şimşek, M., & Kadılar, C. (2010). Türkiye'de beşeri sermaye, ihracat ve ekonomik büyüme arasındaki ilişkinin nedensellik analizi. *CÜ İktisadi ve İdari Bilimler Dergisi*, 11(1), 115-140.
- Tariq, R., Khan, M. A., & Rahman, A. (2020). How does financial development impact economic growth in Pakistan? New evidence from threshold model. *Journal of Asian Finance, Economics and Business*, 7(8), 161-173.
- T.C. Strateji ve Bütçe Başkanlığı. (2022). <https://www.sbb.gov.tr/temel-ekonomik-gostergeler-veritabani/>
- TÜİK (2022). Türkiye İstatistik Kurumu. <https://www.tuik.gov.tr/>
- Tkacz, G. (2001). Neural network forecasting of Canadian GDP growth. *International Journal of Forecasting*, 17(1), 57-69.

- Türedi, S., & Berber, M. (2010). Finansal kalkınma, ticari açıklık ve ekonomik büyüme arasındaki ilişki: Türkiye üzerine bir analiz. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (35), 301-316.
- Wabomba, M. S., Mutwiri, M., & Fredrick, M. (2016). Modeling and forecasting Kenyan GDP using autoregressive integrated moving average (ARIMA) models. *Science Journal of Applied Mathematics and Statistics*, 4(2), 64-73.
- Yakut, E., & Süzülmüş, S. (2020). Modelling monthly mean air temperature using artificial neural network, adaptive neuro-fuzzy inference system and support vector regression methods: A case of study for Turkey. *Network: Computation in Neural Systems*, 31(1-4), 1-36.
- Yoon, J. (2021). Forecasting of real GDP growth using machine learning models: Gradient boosting and random forest approach. *Computational Economics*, 57(1), 247-265.
- Zhang, H., & Rudholm, N. (2013). *Modeling and forecasting regional GDP in Sweden using autoregressive models*. Working Paper, Hogskolan Dalarna University, Sweden.