

AIZANOI

FINANCE REVIEW

ISSUE: 2



THE WORLD'S FIRST
Stock Exchange

info@aizanoifr.com | <http://www.aizanoifr.com>

AIZANOI FINANCE REVIEW
SAYI:2 / ISSUE:2
Ekim - 2023 / October-2023
<https://aizanoifr.com/>

Sahibi / Owner

Assoc. Prof. Adil AKINCI – Bilecik Şeyh Edebali University, Türkiye

Editör / Editor

Assoc. Prof. Hakan ÇELİKKOL – Kütahya Dumlupınar University, Türkiye

Editör Yardımcısı / Assistant Editor

Asst. Prof. Dr. Göksel KARAŞ – Kütahya Dumlupınar University, Türkiye

Yayın Kurulu / Editorial Board

Prof. Dr. Niyazi KURNAZ - Kütahya Dumlupınar University, Türkiye
Prof. Dr. Şakir SAKARYA - Balıkesir University, Türkiye
Prof. Dr. Gülizar KURT GÜMÜŞ - Dokuz Eylül University, Türkiye
Prof. Dr. Cantürk KAYAHAN - Afyon Kocatepe University, Türkiye
Prof. Dr. Nazan YELKİKALAN - Çanakkale 18 Mart University, Türkiye

Kapak Tasarımı / Cover Design

Prof. Dr. Niyazi KURNAZ - Kütahya Dumlupınar University, Türkiye

Dil Editörü / Language Editor

Dr. Eren AKDAĞ KURNAZ / Kütahya Dumlupınar University, Türkiye

Yazışma Adresi / Correspondence Address

info@aizanoifr.com

E-ISSN

2980-1850

İÇİNDEKİLER / CONTENTS

| | |
|---|--------------|
| 1.Çiğdem YILMAZ ÖZSOY..... | 1-12 |
| <i>LONG MEMORY AND VOLATILITY IN THE BRIC COUNTRIES' STOCK MARKET RETURN</i> | |
| <i>BRIC ÜLKELERİ HİSSE SENEDİ PİYASALARINDA UZUN HAFIZA VE VOLATİLİTE</i> | |
| (Araştırma Makalesi/Research Article) | |
| 2.Elçin NOYAN..... | 13-26 |
| <i>BANKALARIN ÇEVRESEL SÜRDÜRÜLEBİLİRLİKLERİNİN ÇOK KRİTERLİ ANALİZİ</i> | |
| <i>MULTI-CRITERIA ANALYSIS OF BANKS' ENVIRONMENTAL SUSTAINABILITY</i> | |
| (Araştırma Makalesi/Research Article) | |
| 3.Fatma Selen MADENOĞLU..... | 27-48 |
| <i>COMPARISON OF ARTIFICIAL NEURAL NETWORK AND LOGISTIC REGRESSION METHODS IN CLASSIFYING THE HAPPINESS STATUS OF COUNTRIES</i> | |
| <i>ÜLKELERİN MUTLULUK DURUMUNUN SINIFLANDIRILMASINDA YAPAY SİNİR AĞLARI VE LOJİSTİK REGRESYON YÖNTEMLERİNİN KARŞILAŞTIRILMASI</i> | |
| (Araştırma Makalesi/Research Article) | |
| 4.Fatih Volkan AYYILDIZ..... | 49-57 |
| <i>G-7 ÜLKELERİNDE EĞİTİM HARCAMALARI-İKTİSADİ BÜYÜME İLİŞKİSİ: FOURIER SHİN EŞBÜTÜNLEŞME TESTİ</i> | |
| <i>THE EDUCATION EXPENDITURE-ECONOMIC GROWTH RELATIONSHIP IN G-7 COUNTRIES: FOURIER SHİN COINTEGRATION TEST</i> | |
| (Araştırma Makalesi/Research Article) | |
| 5.İbrahim Halil UÇAR & Erkan ALSU..... | 58-76 |
| <i>HİSSE SENEDİ GETİRİSİ VE ENFLASYON ORANI ARASINDAKİ İLİŞKİ: BORSA İSTANBUL ÖRNEĞİ</i> | |
| <i>THE RELATIONSHIP BETWEEN STOCK RETURN AND INFLATION RATE: EXAMPLE OF THE BORSA İSTANBUL</i> | |
| (Araştırma Makalesi/Research Article) | |
| 6.Afra AKGÜL..... | 77-86 |
| <i>SERMAYE PİYASASI KANUNU'NUN 106. MADDESİNDE DÜZENLENEN BİLGİ SUİSTİMALİ SUÇU</i> | |
| <i>ARTICLE 106 OF CAPITAL MARKET CODE: INFORMATION ABUSE CRIME</i> | |
| (Araştırma Makalesi/Research Article) | |

Bilim Kurulu / Advisory Board

- Prof. Dr. Aslı AFŞAR / Anadolu University, Türkiye
Prof. Dr. Mehmet BAŞER / Anadolu University, Türkiye
Prof. Dr. Feride HAYIRSEVER BAŞTÜRK / Bilecik Şeyh Edebali University, Türkiye
Prof. Dr. Levent ÇITAK / Erciyes University, Türkiye
Prof. Dr. Metin COŞKUN / Anadolu University, Türkiye
Prof. Dr. Metin Kamil ERCAN / Ankara Hacı Bayram Veli University, Türkiye
Prof. Dr. Bilge Leyli DEMİREL ERGÜN / Yalova University, Türkiye
Prof. Dr. Gülizar KURT GÜMÜŞ / Dokuz Eylül University, Türkiye
Prof. Dr. Tuğrul KANDEMİR / Afyon Kocatepe University, Türkiye
Prof. Dr. Ferudun KAYA / Bolu Abant İzzet Baysal University, Türkiye
Prof. Dr. Cantürk KAYAHAN / Afyon Kocatepe University, Türkiye
Prof. Dr. Mustafa Mesut KAYALI / Kütahya Dumlupınar University, Türkiye
Prof. Dr. Turhan KORKMAZ / Mersin University, Türkiye
Prof. Dr. Niyazi KURNAZ / Kütahya Dumlupınar University, Türkiye
Prof. Dr. Nezih Metin ÖZMUTAF / İzmir Katip Çelebi University, Türkiye
Prof. Dr. Mutlu Başaran ÖZTÜRK / Niğde Ömer Halisdemir University, Türkiye
Prof. Dr. Şakir SAKARYA / Balıkesir University, Türkiye
Prof. Dr. Ufuk SELEN / Bursa Uludağ University, Türkiye
Prof. Dr. Güven SEVİL / Anadolu University, Türkiye
Prof. Dr. Mehmet ŞAHİN / Çanakkale Onsekiz Mart University, Türkiye
Prof. Dr. Seyfettin ÜNAL / Kütahya Dumlupınar University, Türkiye
Prof. Dr. Nazan YELKİKALAN / Çanakkale Onsekiz Mart University, Türkiye
Assoc. Prof. Dr. Işıl EREM CEYLAN / Uşak University, Türkiye
Assoc. Prof. Dr. Betül HAYRULLAHOĞLU / Uşak University, Türkiye
Assoc. Prof. Dr. İbrahim Emre KARAA / Manisa Celal Bayar University, Türkiye
Assoc. Prof. Dr. Serdar ÖGEL / Afyon Kocatepe University, Türkiye
Assoc. Prof. Dr. Letife ÖZDEMİR / Afyon Kocatepe University, Türkiye
Assoc. Prof. Dr. Ercan ÖZEN / Uşak University, Türkiye
Assoc. Prof. Dr. Cumhuriyet ŞAHİN / Bilecik Şeyh Edebali University, Türkiye
Assoc. Prof. Dr. Yener ŞİŞMAN / Anadolu University, Türkiye

INDEXING

INDEX  COPERNICUS
I N T E R N A T I O N A L

AIZANOI FINANCE REVIEW

ISSUE: 2 / 2023

www.aizanoifr.com

info@aizanoifr.com

LONG MEMORY AND VOLATILITY IN THE BRIC COUNTRIES' STOCK MARKET RETURN¹

BRIC ÜLKELERİ HİSSE SENEDİ PİYASALARINDA UZUN HAFIZA VE VOLATİLİTE

Çiğdem YILMAZ ÖZSOY*,

*Assistant Professor, Istanbul Topkapı University, Department of Economics, cigdemyilmazozsoy@topkapi.edu.tr, ORCID: 0000-0002-7436-7273

| ARTICLE INFO | ABSTRACT |
|---|---|
| <p>Received 25.08.2023</p> <p>Revized 18.09.2023</p> <p>Accepted 25.10.2023</p> <p>Article Classification: Research Article</p> <p>JEL Codes A10 C10 C20</p> | <p>In this study, the existence of long memory effect in IBOVESPA, RTSI, S&P BSE, and SSE COMPOSITE stock market indexes of BRIC countries and the long memory volatility in the series were investigated by using, one of the discrete – time models, fractionally integrated ARFIMA and FIGARCH models. For this purpose, daily closing data for the period of 01.07.1997- 30.09.2014 are included in the model. The stationary behavior of IBOVESPA, RTSI, S&P BSE, and SSE COMPOSITE stock market indexes are tested by using ADF, Phillips Perron, and KPSS unit root tests. As a result of classical unit root tests, IBOVESPA, RTSI, S&P BSE, and SSE COMPOSITE stock market indexes are found stationary in I(0). The long memory feature in the series is investigated by using the ARFIMA model, and the long run volatility of the series is researched by using FIGARCH model. According to the result of ARFIMA model, RTSI, S&P BSE and SSE COMPOSITE series have a stationary long memory, and only the SSE COMPOSITE stock market index parameter is statistically significant in FIGARCH model. Thus, the long memory behavior of the SSE Composite stock index displays predictable behavior.</p> <p>Keywords: BRIC Countries Stock Market, Long Memory, Volatility, ARFIMA, FIGARCH</p> |

| MAKALE BİLGİSİ | ÖZ |
|--|---|
| <p>Gönderilme Tarihi 25.08.2023</p> <p>Revizyon Tarihi 18.09.2023</p> <p>Kabul Tarihi 25.10.2023</p> <p>Makale Kategorisi Araştırma Makalesi</p> <p>JEL Kodları A10 C10 C20</p> | <p>Bu çalışmada, BRIC ülkelerine ait Bombay Menkul Kıymetler Borsası (S&P BSE), Bovespa (IBOVESPA), Rusya Ticaret Sistemi (RTSI), ve Şangay Kompozite (SSE COMPOSITE) endekslerinde uzun hafıza etkisinin varlığı ve serideki uzun hafıza oynaklığı, kesikli bütünlük zaman serisi modellerinden olan "Otoregresif Kesirli Bütünlük Hareketli Ortalama (ARFIMA)" ve "Kesirli Bütünlük Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (FIGARCH)" modelleriyle incelenmiştir. Bu amaçla çalışmaya 01.07.1997-30.09.2014 dönemine ait günlük kapanış verileri modele dahil edilmiştir. IBOVESPA, RTSI, S&P BSE ve SSE COMPOSITE borsa endekslerinin durağanlık davranışları ADF, Phillips Perron ve KPSS birim kök testleri kullanılarak test edilmiştir. Klasik birim kök testleri sonucunda IBOVESPA, RTSI, S&P BSE ve SSE COMPOSITE borsa endeksleri I(0) noktasında durağan bulunmuştur. Serilerdeki uzun hafıza özelliği ARFIMA modeli kullanılarak, serilerin uzun dönem oynaklığı ise FIGARCH modeli kullanılarak araştırılmıştır. ARFIMA modelinin sonucuna göre RTSI, S&P BSE ve SSE COMPOSITE serilerinin durağan uzun belleğe sahip olduğu; FIGARCH modelinin sonucuna göre ise sadece SSE COMPOSITE hisse senedi endeksinin uzun hafıza davranışının öngörülebilir olduğu belirlenmiştir.</p> <p>Anahtar Kelimeler: BRIC Ülkeleri, Hisse Senedi, Uzun Hafıza, Oynaklık, ARFIMA, FIGARCH</p> |

¹This paper is extracted from the master thesis of Çiğdem YILMAZ ÖZSOY.

Atıf (Citation): Yılmaz Özsoy, Ç. (2023). "Long Memory and Volatility in the BRIC Countries' Stock Market Return", *Aizanoi Finance Review*, (2): 1-12



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

1. Introduction

Interest in long-term dependence or long memory processes first appeared in physical sciences, and the first study on the subject was made by Hurst (1951), a British hydrologist. In this study, Hurst tried to determine how to set the overflow periods of the Nile river. After that Mandelbrot and Wallis (1968) identified long memory as "Joseph influence". Based on the Joseph's influence, Egypt will have an abundance for seven years and famine for seven years. According to this study, the long memory is a phenomenon of an event in the distant past to be highly correlated with future observations. The effect of the long memory period on the financial markets was revealed by Mandelbrot (1971). In the study, it was suggested that Hurst's "Transformed Width" statistic be used to determine the long memory behavior of stocks. Long memory models are divided into two as discrete and continuous models. The continuous long memory model is described by Mandelbrot (1965) as a "fractional Brownian motion", generalized by Mandelbrot and Van Ness (1968). The discrete long memory model was developed as a fractional autoregressive motion model, ARFIMA (p, d, q), by Granger (1980), Granger, and Joyeux (1980) and Hosking (1981).

In capital markets, it has long been a matter of curiosity for how effective the markets are. In particular, investors want to know how much they will get or how much they will lose when they make investments. This has prompted both academicians and market professionals to investigate these issues. Researchers have found the so-called "volatility" to be able to determine how much of the capital has risen. While the volatility models have been developed for the short memory series before, later they have also been developed for long memory models. FIGARCH model, which detects volatility in long memory series was presented by Baille et al (1996). In recent years, there have been several studies that have demonstrated the use of long memory by using fractionally integrated models.

Doornik and Ooms (2004) compared the methods used for estimating the ARFIMA model with each other. The quarterly UK inflation series for the period 1959.1 - 2002.2 and the monthly inflation series for the United States of America from 1957.1 to 2003.4 were included in the study. Exact Maximum Likelihood, Modified Profile Likelihood (MPL) and Nonlinear Least Squares methods were compared with each other and the MPL method was found to give more accurate results than other methods.

Kang and Yoon (2006) investigated the asymmetric long memory effect of the volatility of stocks in Japan, South Korea, Hong Kong, and Singapore with ARFIMA, FIGARCH, and FIEGARCH models. As a result of the study, the FIEGARCH model proved to be more successful in catching asymmetrical effects in long memory.

Kasman and Torun (2007) investigated a long memory feature of Turkey's stock index in the period of 1988-2007 with fractionally integrated models. As a result of Turkey's stock index was also found to have a long memory both in returns and volatility.

In the study of Leite, Rocha, Silva, et al. (2007), they tried to determine the long-term correlations using circadian rhythm, sleeping in different regimes, walking periods, and increasing age values using DFA combined with segmentation and selective adaptive ARFIMA models. As a result of the study, the selective adaptive ARFIMA model predicted long memory based on shorter segments, therefore, it is more advantageous to use ARFIMA models.

Siew, Chin, and Wee (2008) aimed to demonstrate and exemplify the use of time series models in Air Pollution Index (API) estimates. The data used in the study consist of API observations covering the period of 03.1998 - 12.2003. ARIMA and ARFIMA time series methods were used. As the model selection criterion, the lowest values of MAE, RMSE, and MAPE are taken into consideration. When considering these two models, the integrated ARFIMA model is better because it has the lowest MAPE value.

In the Wiphatthanananthaku and Sriboonchitta (2010), implemented the SET50 index option in conjunction with the Chicago Board Options Exchange (CBOE) in their study as Thailand volatility index. Long memory predicted ARFIMA - FIGARCH and ARMA - FIAPARCH models with the ability to capture the effect of asymmetry in conditional variance and power transfer in the conditional variance of the process. As a result of the study, while ARMA-FIGARCH model is more adaptive, ARMA-FIAPARCH has a longer memory than ARMA-FIGARCH and catches asymmetrical effects better.

In the study of Zhou, Chen, and Dong (2012), they estimate the traffic network in the northeastern part of China was based on the ARFIMA model. The data consist of traffic data for 3 days from 0:00 to 24:00 in October 2009. The MATLAB program was used to analyze the data. According to the findings, the ARFIMA model provides better results than traditional time series methods in the long correlation analysis.

In the study of Guhathakurda, Bhattacharya, and Bhattacharya (2012) used daily returns, absolute returns, and square returns of the stock markets from developed markets (USA, UK, Germany, Australia, New Zealand, Hong Kong, France, Netherlands, Japan, Singapore) and from developing markets (Russia, Hungary, Brazil, Chile, Mexico, Malaysia, Korea, Taiwan, China, and India) investigated the long memory properties of them. Hurst exponent, Lo's statistics, and semi-parametric GPH statistics were calculated to determine the long memory of asset returns. As a result, it has been found that there is volatility in the long memory acquisition both in the developing and developed markets, and there is no significant difference between the long memory statistics of the two market groups.

In Kristoufek (2013) investigated mix-related ARFIMA (MC-ARFIMA) processes, which allowed various properties of univariate and bivariate long memory and found that mix-related ARFIMA processes enhance to create Maximum Likelihood Estimators, Generalized momentum estimators, and Frequency domain estimators.

In the article of Wook Han (2014), it was investigated the effects of the global crises of 1997-1998 and the global crises of 2008 - 2009 on the long memory volatility of exchange rates compared with the parametric FIGARCH model and the semi-parametric Local Whittle method. Daily exchange rates of KRW-USD and JPY-USD are included in the study. As a result of the study, the KRW-USD reflects the long-term volatility dependence more than of JPY-USD and two financial crises affect the dynamics of volatility in all return series.

In the study of Türkyılmaz ve Balıbey (2014), the efficiency of the Pakistani stock index for the period 2010-2013 was estimated by ARFIMA - FIGARCH methods under different distributions (Normal, Student - t, Skewed Student - t and GED distributions). While the ARFIMA model does not reflect

long memory behaviors for the Pakistan stock index, it is determined that the volatility of the index return series is long memory as a result of the estimated FIGARCH model.

In this paper, it is investigated that whether the stocks of the BRIC countries, which have the largest land pieces on the map, have strong memory by using the ARFIMA model, and the existence of long memory volatility is determined using the FIGARCH model. In this paper, we applied ARFIMA-FIGARCH models to BRIC countries, due to the long memory is a feature of emerging market stock market indices rather than a feature of developed countries' stock market indices.

The organization of the paper is as follows. Section II introduces employed econometric methodology, Section III reveals data and empirical results and Section IV presents the conclusion of the study.

2. Method

2.1. ARFIMA Method

The concept of fractional integration is the definition of time series, often with a long memory or long-term dependence. Time series with a purely stationary ARIMA process have a short memory. The AR (p) model has infinite memory and all past values of the error term are stored in y_t . However, the effect of these past values follows geometric decline. The MA (q) model has a short memory and the effect of the present value disappears after q delay. In the ARIMA model, the researchers treat "d" as an integer number to make sure that the series formed by taking the difference have a stationary process. However, the ARIMA model becomes fractional when d gets all real numbers and is often referred to as the ARFIMA model (Baum, 2013). The ARFIMA method was developed by Granger (1980), Granger and Joyeux (1980), and Hosking (1981). The mathematical formulation of the method is shown as below.

Classic ARMA process:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}, \quad (1)$$

$$t = 1, 2, \dots, T \quad \varepsilon_t \sim \text{NID}(0, \sigma^2_\varepsilon), E[\varepsilon_t] = 0, E[\varepsilon_t^2] = \sigma^2_\varepsilon.$$

When latency polynomials and μ are written using mean term, the model can be written as equation (2) (Doornik ve Ooms, 2012, s. 5).

$$\phi(L)(y_t - \mu) = \theta(L)\varepsilon_t \quad (2)$$

ARFIMA (p, d, q) model with d integration level, p autoregressive level and q moving average levels are:

$$\phi(L)(1-L)^d(y_t - \mu) = \theta(L)\varepsilon_t \quad (3)$$

Here, d is the difference parameter, $\phi(L)$ and $\theta(L)$ are polynomial roots that all roots are outside the unit circle. ε_t is the white noise process

$$\phi(L) = 1 - \sum_{j=1}^p \phi_j(L)^j \quad (4)$$

$$\theta(L) = 1 - \sum_{j=1}^q \theta_j(L)^j \quad (5)$$

The binomial expansion of $(1-L)^d$ is as shown below (Balcilar, 2002).

$$(1 - L)^d = \sum_{j=-\infty}^{\infty} b_j L^j \quad (6)$$

$$b_j = \frac{\Gamma(j-d)}{\Gamma(j+d)\Gamma(-d)} = \prod_{0 < k < j} (k - 1 - d)/k, j = 0, 1, 2, \dots \quad (7)$$

The spectral density $f(0) = 0$ for the $I(d)$ process and $f_x(\omega) = c\omega^{-2d}$ for the low frequencies (Granger, 1980). Here, the value of the fractional coefficient "d" is less than zero, which indicates that the series has a weak memory. If "d" is between (0, 1/2), the series has a stationary long memory, and if "d" is between (1/2, ∞) indicates that the series has non-stationary long memory processes (Banerjee ve Urga, 2005, s.14).

2.2. FIGARCH Method

Due to the development in financial markets, the number of investors has been increased in time. This situation has let to the close relationship between financial markets and macroeconomic variables. Thus, to prevent losses and damages that could be caused by high volatility, it is necessity to model the changes observed in prices in financial market. To achieve this, "Fractional Integrated Conditional Variance Models", which incorporate long memory conditions, have started to be applied frequently (Nazarian, Nederi ve Alikhani, 2014, s. 16-17).

FIGARCH (p,d,q) model, which was found by Baille et al. (1996) is defined as:

$$[1 - \beta(L)] \sigma_t^2 = \omega + [1 - \beta(L) - \phi(L)(1 - L)^d] \varepsilon_t^2$$

$B(L)$ and $\phi(L)$ are polynomial roots in the delay operator and d is the long memory parameter; are shown as follows:

$$\phi(L) = (1 - \alpha(L) - \beta(L))(1 - L)^d,$$

$$\alpha(L) \equiv \alpha_1 L + \dots + \alpha_q L^q$$

$$\beta(L) \equiv \beta_1 L + \dots + \beta_q L^q$$

It is also assumed that all the roots belonging to polynomials $\phi(L)$ and $(1 - \beta(L))$ extend outside the unit circle. In ARFIMA class models, while long term dependence of time series is modeled by fractional difference parameter, short term behaviors are captured by traditional ARMA parameters. The same situation holds for the validity of the model of conditional variance. In the covariance stationary GARCH (p, q) model, the optimal estimate of the future conditional variance is decreasing exponentially and it is important for the estimation of the IGARCH (p, q) model. In the FIGARCH (p, d, q) model, a shock effect in the prediction of the future running variance will disappear with a slow hyperbolic rate (Bollerslev ve Mikkelsen, 1996: 158). In the FIGARCH model, when $d = 0$, the process becomes the standard GARCH (1,1) process, and when $d = 1$, it becomes the IGARCH (1,1) process. The main point of the FIGARCH algorithm is to allow the autocorrelation of absolute values and squares to decrease in slow hyperbolic order when $0 \leq d \leq 1$ (Wook Han, 2014).

3. Data Set and Empirical Results

3.1. Data Set

To investigate the long memory effect and the long-term volatility of the return series of BRIC countries' stock market indexes; RTSI for Russia, SSE COMPOSITE for China, S&P BSE for India, and

IBOVESPA index for Brazil were examined. All data belonging to the series were obtained from the "finans.yahoo.com" website and daily closing values covering the period 01.07.1997 - 30.09.2014 were used.

To be able to perform the analysis, the daily sample prices are converted to the daily nominal return series by using the formula as shown below:

$$r_t = 100 \ln (P_t/P_{t-1}), \quad t = 1, \dots, T.$$

In the formula, r_t is the rate of return at time t , P_t is the price of the series at time t , P_{t-1} is the price of the previous day of the series.




Figure 1. Daily returns of SSE COMPOSITE, IBOVESPA, S&P BSE and RTSI indexes.

As you can see in Figure 1, large changes are followed by large changes, while small changes are followed by small changes in the series. Also, it appears that the two major financial crises experienced seriously affected the series. The first of them is the Asian Crisis. The Asian crisis began with the serious depreciation of the Thai currency in early July 1997 and the effects were seen for a long time. This situation mostly affected Asian countries. As seen in the yield graphs, among the BRIC countries, China was the most affected country during that period. The second of them is the Global Crisis. The global crisis started to show its effect in March 2007, and in September 2008 the crisis reached its peak. The collapse of the risky mortgage industry in America is the underlying cause of this crisis and almost all the countries of the world are affected by this crisis. Again, as observed in the graphs, the volatility of the stocks of the countries increased in 2008.

Table 1. Descriptive Statistics of SSE COMPOSITE, IBOVESPA, S&P BSE, and RTSI Indexes

| Series | SSE COMPOSITE(China) | IBOVESPA(Brazil) | S&P BSE (India) | RTSI (Russia) |
|---------------------------|----------------------|------------------|-----------------|---------------|
| N | 4406 | 4277 | 4268 | 4414 |
| Average | 0.0114459 | 0.03335 | 0.042729 | 0.022093 |
| Median | 0 | 0.080179 | 0.098388 | 0.07898 |
| Maksimum | 9.400787 | 28.83245 | 15.98998 | 20.20392 |
| Minimum | -9.25615 | -17.20824 | -11.80918 | -21.19942 |
| Standart deviation | 1.544692 | 2.14248 | 1.62114 | 2.564148 |
| Skewness | -0.11791 | 0.336796 | -0.09542 | -0.485892 |
| Kurtosis | 7.700897 | 16.29452 | 8.760846 | 11.46483 |

| | | | | |
|----------------------|----------|----------|---------|----------|
| Jarque-Bera | 4066.191 | 31570.76 | 5906.91 | 13348.91 |
| p prob. value | 0.00 | 0.00 | 0.00 | 0.00 |

Table 1 contains descriptive statistics of the return series. According to the obtained descriptive statistical results, the return series show small average values and large standard deviations. The skewness values of the series show negative asymmetry – except Brazil -, and the kurtosis values of the series are greater than 3. Thus, there is a thick tail problem in all of the series, and the series don't fit to the normal distribution. To understand whether the series exhibit the normal distribution, the Jarque - Bera test is also applied. As a result of the Jarque - Bera test, the zero hypothesis is rejected because the probability value is found less than 0.05. Thus, the series are not normally distributed. Besides, whether the error terms of the series distribute normal are examined and it is found that the error terms are not appropriate for the normal distribution.

3.2. Unit Root Test Results

The stationary behaviors of the series must be investigated before analysis whether the series have a long memory. For this reason, classical unit root tests [ADF (Augmented Dickey-Fuller), PP (Phillips Perron), and KPSS (Kwiatkowski, Phillips, Schmidt, and Shin)] is applied to all sample returns. These tests differ in terms of the null hypothesis. While the null hypothesis of ADF and PP tests is “The time series have unit root”, the null hypothesis of the KPSS test is “time series is stationary”. The experimental results of classical unit root tests are given in Table 2.

Table 2. Classical Unit Root Test Results

| | | SSE COMPOSITE(China) | IBOVESPA(Brazil) | S&P BSE (India) | RTSI (Russia) |
|-------------|-------------------------|-----------------------------|-------------------------|----------------------------|----------------------|
| ADF | Trend + Constant | -15.20437 | -19.65331 | -14.72035 | -11.63873 |
| | <i>p</i> value | 0.000 | 0.000 | 0.000 | 0.000 |
| | Constant | -15.20177 | -19.655 | -14.70319 | -11.6369 |
| | <i>p</i> value | 0.000 | 0.000 | 0.000 | 0.000 |
| | None | -15.19273 | -19.6264 | -14.60706 | -11.63444 |
| | <i>p</i> value | 0.000 | 0.000 | 0.000 | 0.000 |
| PP | Trend + Constant | -66.09908 | -64.25673 | -60.71386 | -59.05919 |
| | <i>p</i> value | 0.000 | 0.000 | 0.000 | 0.000 |
| | Constant | -66.10376 | -64.26464 | -60.71455 | -59.06549 |
| | <i>p</i> value | 0.0001 | 0.0001 | 0.0001 | 0.0001 |
| | None | -66.10472 | -64.23049 | -60.70076 | -59.05642 |
| | <i>p</i> value | 0.0001 | 0.0001 | 0.0001 | 0.0001 |
| KPSS | Trend + Constant | | | | |
| | LM -STAT | 0.083011 | 0.083422 | 0.083625 | 0.168024 |
| | 1% | 0.216000 | 0.216000 | 0.216000 | 0.216000 |
| | 5% | 0.146000 | 0.146000 | 0.146000 | 0.146000 |
| | 10% | 0.119000 | 0.119000 | 0.119000 | 0.119000 |
| | Constant | | | | |
| | LM -STAT | 0.097192 | 0.088441 | 0.126369 | 0.165125 |
| | 1% | 0.739000 | 0.739000 | 0.739000 | 0.739000 |
| | 5% | 0.463000 | 0.463000 | 0.463000 | 0.463000 |
| | 10% | 0.347000 | 0.347000 | 0.347000 | 0.347000 |

As a result of ADF, PP, and KPSS unit root tests, the series do not show unit root behaviors with the significance levels of 1%, 5%, and 10%. Therefore, the null hypothesis is rejected in the ADF and PP tests and is accepted in the KPSS test. The series are stationary. All series used in the study are suitable for the analysis of long memory models.

3.3. ARFIMA Test Results

The "Approximate Whittle Method" is used when analyzing ARFIMA (p, d, q) series. To find out the best ARFIMA(p,d,q) model, all possible models are tested for $p + q \leq 2$. When the best model is determined, the significance of the parameters and the AIC information criterion are taken into account. The "d" and AIC information criterion values obtained in Table 3 are given.

Table 3. ARFIMA Test Results

| Modeller | (0,d,0) | (0,d,1) | (1,d,0) | (1,d,1) | (0,d,2) | (2,d,0) | (2,d,1) | (1,d,2) | (2,d,2) | |
|----------|---------------|---------------|---------------|---------------|---------|---------|--------------|---------|----------|---------|
| SSE COM. | d-coefficient | 0.0151 | 0.0329 | 0.0291 | 0.0098 | 0.0771 | 0.078 | 0.0727 | 0.0712 | 0.0465 |
| | p value | 0.20212 | 0.09056 | 0.11839 | 0.4553 | 0.00448 | 0.0004 | 0.00442 | 0.00925 | 0.00486 |
| | AIC | 144.107 | 144.664 | 144.93 | 145.88 | 136.94 | 135.015 | 136.7 | 137.7964 | 127.893 |
| | Q(5) | 17.4145 | 16.8925 | 17.0563 | 16.881 | 5.35974 | 3.47227 | 3.48557 | 4.880354 | - |
| | Q(10) | 30.9098 | 31.533 | 31.426 | 27.686 | 23.9354 | 22.0638 | 21.4148 | 22.43315 | 9.64122 |
| | Q(15) | 46.3365 | 45.5654 | 45.7315 | 42.981 | 35.9621 | 34.1021 | 33.6107 | 34.57738 | 22.2551 |
| | IBOSVEPA | d-coefficient | -0.0076 | -0.04584 | -0.049 | -0.0477 | -0.0497 | -0.0464 | -0.05293 | 0.00339 |
| p value | | 0.52594 | 0.01248 | 0.01607 | 0.0547 | 0.03768 | 0.06707 | 0.01039 | 0.86187 | 0.03987 |
| AIC | | 2937.46 | 2931.98 | 2931.97 | 2933.9 | 2933.91 | 2933.93 | 2924.35 | 2938.342 | 2926.45 |
| Q(5) | | 16.4342 | 4.65703 | 4.18249 | 4.3512 | 4.02569 | 4.52555 | 3.45535 | 19551.75 | - |
| Q(10) | | 54.1024 | 43.7498 | 43.4417 | 43.541 | 43.3069 | 43.6383 | 39.0494 | 36365.11 | 35699.1 |
| Q(15) | | 61.3675 | 50.570 | 50.2845 | 50.371 | 50.1456 | 50.455 | 50.2971 | 50823.62 | 49512.3 |
| S&P BSE | | d-coefficient | 0.0362 | -0.0221 | -0.0216 | -0.0084 | 0.0077 | 0.012 | 0.0122 | 0.0456 |
| | p value | 0.00256 | 0.21681 | 0.29952 | 0.6635 | 0.75862 | 0.61745 | 0.67482 | 0.31313 | 0.36015 |
| | AIC | 544.994 | 530.477 | 532.572 | 530.03 | 528.956 | 528.626 | 530.625 | 530.3258 | 528.576 |
| | Q(5) | 23.7508 | 5.20062 | 7.54474 | 3.5498 | 3.07677 | 2.85757 | 2.86016 | 3.735355 | - |
| | Q(10) | 50.6757 | 30.8537 | 33.5805 | 28.535 | 27.423 | 26.8876 | 26.8816 | 25.52207 | 23.721 |
| | Q(15) | 61.3547 | 41.5326 | 44.2717 | 39.027 | 37.8213 | 37.2628 | 37.2567 | 36.23475 | 33.9029 |
| | RTSI | d-coefficient | 0.0855 | 0.0414 | 0.0361 | 0.0359 | 0.0305 | 0.0357 | 0.0278 | 0.0273 |
| p value | | 0.000 | 0.02112 | 0.07444 | 0.1556 | 0.1869 | 0.15694 | 0.22447 | 0.17606 | 0.01504 |
| AIC | | 4563.53 | 4555.16 | 4554.93 | 4556.9 | 4556.62 | 4556.92 | 4556.8 | 4555.25 | 4553.74 |
| Q(5) | | 21.077 | 8.97864 | 8.18116 | 8.1584 | 7.21386 | 8.13351 | 4.45902 | 3.050378 | - |
| Q(10) | | 39.5419 | 26.8746 | 26.2337 | 26.217 | 25.541 | 26.1994 | 23.7754 | 22.5423 | 24.0822 |
| Q(15) | | 59.7941 | 49.604 | 49.2084 | 49.199 | 48.7591 | 49.1888 | 46.8279 | 45.51328 | 40.9972 |

As a result of ARFIMA method, ARFIMA(2, d, 0) model for China, ARFIMA(0, d, 0) model for India, and ARFIMA(0, d, 1) model for Russia are found as suitable models. Those return series have a long memory. For Brazilian stocks, even though the d parameter is in the range of 0 to 0.5, the appropriate model is not found because the d, AR and MA parameters are not significant. Thus, Brazilian stock does not have a long memory. To avoid the autocorrelation problem in the series, the NEW-WEST robust method is applied to the models and the problem is abolished. Also, Ljung-Box statistical values are examined to determine whether error terms have ARCH effects, and $X^2_{(m-k)}$ distribution is used to decide whether the statistic is significant. In the $X^2_{(m-k)}$, k refers to the number of parameters estimated. In table 3, the values for Q(5), Q(10), and Q(15) are given. It is seen that the SSE COMPOSITE stock market doesn't have an ARCH effect in Q(5)'th delay, but it has

an ARCH effect in Q(10), Q(15), Q(20). India and Russia are also found to have an ARCH effect for the above 3 delays and more.

3.4. FIGARCH Test Results

In GARCH models, it is necessary to satisfy the conditions for the conditional variance to be positive. For this purpose, while estimating the FIGARCH models, the constraints specified by Conrad and Haad (2006) are used in this study. The results of estimated FIGARCH models is shown in Table 4.

Table 4. Estimated FIGARCH (1,d,1) Model Results of Indexes

| | SSE COMPOSITE | S&P BSE | RTSI |
|-----------|------------------|-------------------|-------------------|
| M | 0.011 (0.017) | 0.092 (0.024) | 0.082 (0.034) |
| Ω | 0.283 (0.096) | 0.027 (0.014) | 0.139 (0.07) |
| α1 | 0.066 (0.049) | -0.225 (0.164) | -0.274 (0.182) |
| β1 | -0.066 (0.02) | 0.729 (0.095) | 0.524 (0.208) |
| d | 0.306 (0.038) | 0.573 (0.09) | 0.439 (0.073) |

Note: The values in parentheses are the standard errors of the parameters.

According to the results obtained from the FIGARCH test, only the SSE COMPOSITE stock market index provides the necessary constraints from all the series. SSE COMPOSITE index is different from zero with $d = 0.306$ and is suitable for a long memory. Although S&P BSE and RTSI have a long memory and show ARCH effect, they do not confirm to the long memory volatility model. Based on the obtained results, for SSE COMPOSITE index future volatility will depend on past events, and for this reason, future forecasts can be made.

4. Conclusion

In this study, the volatility of stock market indexes of BRIC countries is investigated by using ARFIMA and FIGARCH models. To find out the fractional behavior of the series, data covering the period 01.07.1997 - 30.09.2014 is included in the study. Firstly, classical unit root tests are applied to determine the stationary behavior of the series. As a result of ADF, Phillips Perron, and KPSS unit root tests, the series are found stationary at $I(0)$ level. Secondly, to investigate whether the series have a long memory, the ARFIMA model is applied to the series separately. As a result of the ARFIMA model estimated by using the Whittle method, it is found that the RTSI, SSE COMPOSITE, and S&P BSE indexes have a stationary long memory feature with the exception of the Brazilian IBOVESPA index. Lastly, the FIGARCH model is used in the modeling of volatility. According to the obtained result, only the Chinese's SSE COMPOSITE index provides a long memory volatility. These findings reveal that the long memory behavior of the return series indicates that stock prices display predictable behavior.

Author Contributions (Yazar Katkı Oranı): Çiğdem YILMAZ ÖZSOY (%100)

Ethical Responsibilities of Authors (Yazarın Etik Sorumlulukları): This study was prepared in accordance with the rules of the required ethical approval

Conflicts of Interest (Çıkar Çatışması): There is no conflict of interest with any institution related to the study.

Plagiarism Checking (İntihal Denetimi): This study has been checked for plagiarism using a plagiarism scanning programme.

REFERENCES

- Baum, C.F. (2013). "ARIMA and ARFIMA Models". The access adress: <http://fmwww.bc.edu/EC-C/S2013/823/EC823.S2013.nn08.slides.pdf>
- Baillie, R.T. (1996). "Long Memory Process and Fractional Integration in Econometrics". *Journal of Econometrics*, 73, 5-59.
- Balcılar, M. (2002, September). "Persistence in Inflation Long Memory, Aggregation or Level Shifts?". *METU International Conference on Economics*, 6, 1-50.
<https://pdfs.semanticscholar.org/e1d8/fb513830b86191d5686f66f0bc4cee8edf46.pdf>
- Banerjee, A. & Urga, G. (2005). "Modelling Structural Breaks, Long Memory and Stock Market Volatility An Overview". *Journal of Econometrics*, 129 (1-2), 1-34.
- Bollerslew, T. & Mikkelsen, H. O. (1996). "Modelling and Pricing Long Memory in Stock Market Volatility". *Journal of Econometrics*, 73, 151-184.
- Conrad, C. & Haag, B. R. (2006). "Inequality Constraints in the Fractionally Integrated GARCH Model". *Journal of Financial Econometrics*, 4(3), 413-449.
- Doornik, J.A. & Ooms, M. (2012). A Package for Estimating, Forecasting and Simulating ARFIMA Models: ARFIMA Package 1.06 for Ox, 1-35. <http://www.doornik.com/ox/>
- Granger, C.W.J. & Joyeux, R. (1980). "An Introduction to Long Memory Time Series Models and Fractional Differencing". *Journal of Time Series Analysis*, 1,1980, 15-39.
- Granger, C.W. J. (1980). "Long Memory Relationships and The Aggregation of Dynamic Models". *Journal of Econometrics*, 14(2), 227-238.
- Guhathakurda, K., Bhattacharya, S. N. & Bhattachary, M. (2012). "Exploring Presence of Long Memory in Emerging and Developed Stock Markets". *Indian Institute of Management Kozhikode*, 10,1-30.
- Han, Y. W. (2014). "Effects of Financial Crises on the Long Memory Volatility Dependency of Foreign Exchange Rates: the Asian Crisis vs. the Global Crisis". *Journal of East Asian Economic Integration*, 18 (1), 3-27.
- Hosking, J. R.M. (1981). "Fractional Differencing". *Biometrika*, 68(1), 165-176.
- Hurst, H.E. (1951). "Long Term Storage Capacity of Reservoirs". *Transactions of the American Society of Civil Engineers*, 116, 770-799.
- Kang, S. H. & Yoon, S.M. (2006). "Asymmetric Long Memory Feature in the Volatility of Asian Stock Markets". *Asia - Pacific Journal of Financial Studies*, 35(5), 175-198.
- Kasman, A. & Torun, E. (2007). "Long Memory in the Turkish Stock Market Return and Volatility". *Central Bank Review*, 2, 13-27.
- Kristoufek, L. (2013). "Mixed-Correlated ARFIMA Processes for Power-Law Cross-Correlations". *Physica A: Statistical Mechanics and its Applications*, 392(15), 6484-6493.

- Leite, A., Rocha, A.P., Silva, M.E., Gouveia, S., Carvalho, J. & Costa, O. (2007). "Long-Range Dependence in Heart Rate Variability Data: ARFIMA Modelling vs Detrended Fluctuation Analysis". *Computers in Cardiology*, 34, 21-24.
- Mandelbrot, B.B. (1965). "The Variation of Some Other Speculative Prices". *The Journal of Business*, 40, 393-393.
- Mandelbrot, B.B. & Wallis, J.R. (1968). "Noah, Joseph, and Operational Hydrology". *Water Resources Research*, 4(5), 909-918.
- Mandelbrot, B. B. & Van Ness, J.W. (1968). "Fractional Brownian Motions, Fractional Noises and Applications". *SIAM Review*, 10(4), 422-437.
- Mandelbrot, B.B. (1971). "When Can Price Be Arbitraged Efficiently? A Limit to the Validity of the Random Walk and Martingale Models". *The Review of Economics and Statistics*, 53(3), 225-236.
- Nazarian, R., Naderi, E., Alikhani, N.G. & Amiri, A. (2014). "Long Memory Analysis: An Empirical Investigation". *International Journal of Economics and Financial Issues*, 4(1), 16-26.
- Siew, L. Y., Chin, L.Y. & Wee, M.J. (2008). "ARIMA and Integrated ARFIMA Models for Forecasting Air Pollution Index in Shah Alam, Selangor". *The Malaysian Journal of Analytical Sciences*, 12(1), 257-263.
- Türkyılmaz, S. & Balıbey, M. (2014). "Long Memory Behavior in the Returns of Pakistan Stock Market: ARFIMA-FIGARCH Models". *International Journal of Economics and Financial Issues*, 4(2), 400-410.
- Zhou, D., Chen, S. & Dong, S. (2012). "Network Traffic Prediction Based on ARFIMA Model". *International Journal of Computer Science Issues*, 9(3), 106-111.
- Wiphatthanananthaku, C. & Sriboonchitta, S. (2010). "ARFIMA-FIGARCH ve ARFIMA - FIAPARCH on Thailand Volatility Index". *The Thailand Econometrics Society*, 2(2), 280-294.

AIZANOI FINANCE REVIEW

ISSUE: 2 / 2023

www.aizanoifr.com

info@aizanoifr.com

BANKALARIN ÇEVRESEL SÜRDÜRÜLEBİLİRLİKLERİNİN ÇOK KRİTERLİ ANALİZİ¹

MULTI-CRITERIA ANALYSIS OF BANKS' ENVIRONMENTAL SUSTAINABILITY

Elçin NOYAN*,

*Dr. Öğr. Üyesi, Antalya Belek Üniversitesi, İİBF, Uluslararası Ticaret ve İşletmecilik Bölümü, elcin.noyan@belek.edu.tr, ORCID: 0000-0003-2630-0274

| MAKALE BİLGİSİ | ÖZ |
|--|---|
| Gönderilme Tarihi 06.07.2023 Revizyon Tarihi 03.09.2023 Kabul Tarihi 16.09.2023 Makale Kategorisi Araştırma Makalesi JEL Kodları D70 M15 M41 | <p>Çevresel sürdürülebilirlik uygulamaları, küresel ısınma ile iklim değişikliğinin dünyadaki doğal kaynakları tehdit etmesini önlemek amacıyla işletmeler için önemli bir araç haline gelmektedir. Bankacılık sektörü, ülke ekonomisi ve kalkınması açısından önemli yere sahiptir. Bankaların diğer işletmeler gibi çevreyi koruma, gelecek nesillere yeterli kaynak aktarma konularında sorumlulukları bulunmaktadır. Çevresel sürdürülebilirlik konuları; yeşil enerji uygulamaları, enerji, su tüketiminin, sera gazı emisyonunun, atık yönetiminin sağlanması, karbon ayak izinin azaltılması, yenilenebilir kaynak kullanımına yönelim, geri dönüşümün sağlanması, su sanitasyonu, ormansızlaşmanın engellenmesi için tedbirler alınması olarak sayılabilir. Sürdürülebilir kalkınma için çevresel teknolojiler, enerji sistemleri, çevre bilinci ve bilgi teknolojileri geliştirilmelidir. Çalışmada çevresel sürdürülebilirlik kavramı, bu kavramı etkileyen kriterlerin açıklanması amaçlanmış olup BIST sürdürülebilirlik endeksinde yer alan bankaların, çevresel sürdürülebilirlik performanslarına göre Çok Kriterli Karar Verme (ÇKKV) yöntemlerinden olan DEMATEL ve PROMETHEE yöntemleri ile literatür araştırması sonucu belirlenen 5 kriter sıralanmıştır. Çalışmadan elde edilen sonuçlarla araştırmacılara, banka yöneticilerine öneriler sunulmaktadır.</p> <p>Anahtar Kelimeler: Çevresel Sürdürülebilirlik, Yeşil Bankacılık, Çok Kriterli Karar Verme Yöntemleri, DEMATEL, PROMETHEE Yöntemleri</p> |

| ARTICLE INFO | ABSTRACT |
|---|--|
| Received 06.07.2023 Revized 03.09.2023 Accepted 16.09.2023 Article Classification: Research Article JEL Codes D70 M15 M41 | <p>Environmental sustainability practices are becoming an important tool for businesses in order to prevent global warming and climate change from threatening natural resources in the world. The banking sector has an important place in terms of national economy and development. Banks, like other businesses, have responsibilities in protecting the environment and transferring sufficient resources to future generations. Environmental sustainability can be counted as green energy practices, energy, water consumption, greenhouse gas emission, waste management, reduction of carbon footprint, orientation to the use of renewable resources, ensuring recycling, water sanitation, and taking measures to prevent deforestation. Environmental technologies, energy systems, environmental awareness and information technologies should be developed for sustainable development. In the study, it was aimed to explain the concept of environmental sustainability and the criteria affecting this concept, and banks included in the BIST sustainability index, DEMATEL and PROMETHEE methods, which are among the Multi-Criteria Decision Making (MCDM) methods, and 5 criteria determined as a result of the literature research were listed. With the results obtained from the study, suggestions are presented to researchers and bank managers.</p> <p>Keywords: Environmental Sustainability, Green Banking, Multi-Criteria Decision Making Methods, DEMATEL, PROMETHEE Methods</p> |

¹Bu çalışma '5. Uluslararası Palandöken Bilimsel Araştırmalar Kongresi'nde 19 Mart 2023 tarihinde sözlü bildiri olarak sunulmuştur.

Atf (Citation): Noyan, E. (2023). "Bankaların Çevresel Sürdürülebilirliklerinin Çok Kriterli Analizi", *Aizanoi Finance Review*, (2): 13-26



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

Giriş

Sürdürülebilirlik, iklim değişikliği ve küresel ısınma konuları, işletmelerin güncel konuları arasında yer almaktadır. Bu süreçlerin iyileştirilmesi ile ilgili uygulamaların geliştirilmesi hedeflenmektedir (Kurbanova, 2020). Teknolojik gelişmeler beraberinde çevreye verilen zararı da ortaya çıkarmıştır. Küresel ısınmanın ortaya çıkardığı olumsuz etkilere karşı bireylerin ve işletmelerin farkındalıklarının artması gereksinimi, çevrenin korunmasına ve sürdürülebilirliğe olan ilgiyi artırmıştır. Yenilenemeyen kaynakların kullanımından kaynaklanan çevre kirliliğinden tüketicinin sorumlu hale geldiği görülmektedir (Padmavathi, 2012). Bankacılık ürünleri kapsamında bilinçlenme ile değişim, dönüşüm süreçleri başlamıştır. Yenilikçi ürünlere olan talepte artışlar görülmüştür. Bunlar; ATM kullanımı, internet bankacılığı, online havaleler, banka kartları ve kredi kartlarıdır. Yenilikçi ürünler hem bankaya hem de tüketicilerine zamandan tasarruf sağlarken maliyet avantajı da yaratmaktadır. Sosyal sorumluluk, kalite ve çevresel sürdürülebilirlik gibi kavramların gelecekte işletmeler açısından önemli hale gelmesi beklenmektedir (Özoğul ve Baran, 2016). Çevresel sürdürülebilirlik uygulamaları ile sadece çevre üzerindeki etkiyi azaltmak değil çevreye zarar vermeden uzun vadede kaynakları korumak için ortaya çıkarılan süreçler ifade edilmektedir (<https://pnbindia.in>). Çalışma ile sürdürülebilir bankacılık, çevresel sürdürülebilirlik kavramları ve bu kavramları etkileyen kriterler açıklanmış BIST sürdürülebilirlik endeksindeki 5 banka, çevresel sürdürülebilirlik performanslarına göre ÇKKV yöntemlerinden DEMATEL ve PROMETHEE yöntemleri ile sıralanmıştır.

1. Kavramsal Çerçeve

1.1. Sürdürülebilir Bankacılık

Ekonomik kalkınmanın temeli olan bankacılık sektörü, sürdürülebilir kalkınmayı teşvik etmede önemli rol oynamaktadır (Weber vd., 2010). Bankacılık sektöründe çevre dostu uygulamaların teşvik edilmesinin önemi artmaktadır. Yeşil bankacılık, bankaların faaliyetlerinin çevre yönetimine yönlendirilmesi ile gerçekleşmektedir (Dewi ve Dewi, 2017). Bose vd. (2018) tarafından yeşil bankacılık; çevre dostu teknolojilerin benimsenmesi ve teşvik edilmesi, karbon ayak izini azaltmak için bankaların iç ve dış operasyonları, çevre yönetimi olarak tanımlanmaktadır. Bouma vd. (2001) sürdürülebilir bankacılığı; “finansal hizmet ve ürünlerin, aktivitelerinden doğabilecek çevresel ve sosyal etkilerini göz önünde bulunduran şahıs ve işletmelere sağlanması” olarak tanımlamışlardır.

1.2. Yeşil Bankacılık

2010 yılında gelişen kavram ile çevreyi korumayı ekonomik kârla bütünleştiren yeni bir finansal yapıdır (Wang ve Zhi, 2016). Yeşil bankacılık kavramı, etik bankacılık, sosyal bankacılık ve sürdürülebilir bankacılığın kapsamına girmektedir. Türkiye’de sürdürülebilirlik kavramı sürekli gelişmektedir (Weber ve Feltsmate, 2016).

Yeşil bankacılık, sürdürülebilir büyüme için çevre dostu uygulamalar ile bankacılık sektöründe karbon ayak izini azaltmayı amaçlamaktadır. Şube bankacılığı yerine internet bankacılığı ile erişimin sağlanması, fatura ödemelerinin hesaplardan otomatik olarak gerçekleşmesi, çevrimiçi banka hesabının açılması, üretimde düşük karbon salınımının gerçekleştirilmesi ve birçok uygulamanın geliştirilmesi Yeşil bankacılığa örnek olarak verilebilir. Finans sektöründe yeni bir kavram olan Yeşil bankacılık, bankacılıkta müşterilerin alışkanlıklarını değiştirerek kalkınmayı sağlamayı amaçlamaktadır (<https://rbidocs.rbi>). Yeşil bankacılık stratejilerini benimseyen bankalar, yatırımlara

fon sağlayıp işletmelerin ve projelerin risklerini kontrol ederler. Toplum tarafından desteklenen ve çevreye faydalı olabilecek projelere mali kaynaklar sağlamaktadırlar (Sahoo ve Nayak 2008).

Bankalar, yeni girişimlerde bulunup yeşil bankacılık ürünlerini teşvik etmektedirler.

-Yeşil Bankacılık Uygulamalarının Adımları (Masukujjaman ve Aktar; 2013).

a) Çevrimiçi olmak, internet bankacılığının sıkça kullanılması, hesap bakiyelerinin kontrolleri, faturaların ödenmesi, para transferi ve uzaktan para yatırma işlemlerinin gerçekleştirilmesidir. Kâğıt kullanmadan daha az harcama ile daha az enerji, kâğıt kullanımı teşvik edilmelidir.

b) İnternet bankacılığı, bir internet sitesi üzerinden yapılan işlemler (perakende banka, sanal banka, kredi birliği veya yapı kooperatifi) bütününe ifade etmektedir.

c) Hesapların yeşil kontrolü, müşterilerin hesap özetlerini çevrimiçi olarak ATM veya özel dokunmatik ekranlar ile görüntülemeleridir. Hesapların yeşil kontrolü, çevresel sürdürülebilirliğe ve küresel ısınmanın azaltılmasına katkı sağlamaktadır.

d) Ev iyileştirmeleri için yeşil krediler, güneş ekipmanlarının satın alınarak finansmanlarının düşük maliyetlerle gerçekleştirilmeleridir.

e) Yeşil kredi kartı kullanımı, yeşil kredi kartlar ile harcanan her lira, bankaların kâr amacı gütmeyen çevre dostu kuruluşlarına fon bağış yapma yoluyla çevresel sürdürülebilirlik programına destek verilmesidir.

f) Kağıt tasarrufu, müşteriler geri dönüştürülmüş ürünleri satın alarak para yatırma fişi, ATM fişi, yıllık rapor vb. işlemlerinin gerçekleştirilmesidir.

g) Güç tasarrufu ekipmanları ile daha az güç tüketen ekipman kullanması, bu yönde uygulanan kampanyaları kapsamaktadır.

h) Mobil bankacılık, banka müşterilerinin hesap bakiyelerin kontrol etmeleri, işlemlerini gerçekleştirmeleri ile zamandan ve kâğıt kullanımından tasarruf etmelerine yardımcı olmaktadır.

i) Güneş ve rüzgâr enerjisi kullanımları ile yeni yatırımlar geliştirilebilir.

j) ATM ile banka müşterileri, şube yardımı olmadan temel işlemleri tamamlayabilirler (Gupta, 2015; Kumar ve Prakash, 2019).

2.Yöntem

Bankaların çevresel sürdürülebilirlik performanslarının belirlenen kriterler doğrultusunda sıralanmalarında kullanılan veriler, bankaların 2022 yılındaki sürdürülebilirlik raporlarından ve her bir bankanın resmi internet sitelerinden alınmıştır. Çalışmada BIST sürdürülebilirlik endeksinde yer alan 5 bankanın çevresel sürdürülebilirlik performansları DEMATEL ve PROMETHEE yöntemleri ile sıralanmıştır.

2.1.DEMATEL Yöntemi

DEMATEL (Decision Making Trial and Evaluation Laboratory) Yöntemi, Cenevre Battelle Memorial Enstitüsü tarafından ortaya koyulmuştur (Wu vd., 2010). Wu ve Tsai (2011) yöntemi karışık problemlerin birbirleri ile ilişkilerinin tespiti için geliştirmişlerdir (Erdal, 2017).

-DEMATEL Yöntemi'nin Adımları:

1. Adım: Kriterlerin ikili karşılaştırma ölçeği kullanılarak uzman grup tarafından belirlenmesidir.

2. Adım: Direkt ilişki matrisinin hesaplanması ve kriterlerin ilişkilerinin değerlendirilmeleridir.

3. Adım: Direkt ilişki matrisinin normalizasyonu, matrisin satır ve sütun değerlerinin toplanıp tüm elemanların en büyük değere bölünmesidir.

$$x=1/\max(\max_j \sum_{i=1}^n dij), \max_i \sum_{j=1}^n dij) \quad (1)$$

4. Adım: Toplam ilişki matrisinin elde edilmesidir. Normalize edilen ilişki matrisinin (M) I birim matrisinin (M) farkının tersi ile çarpılması ile bulunur.

$$S =M(I M) -1 \quad (2)$$

5. Adım: Kriterler arası ilişkilerin tespit edilmesidir.

$$c=(ci)nx1(\sum_{j=1}^n tij)nx1 \quad (3)$$

$$r=(rj)nx1(\sum_{i=1}^n tij)1xn \quad (4)$$

c ve r vektörlerinin toplamları ve farkları alınır. (c+r) toplamı kriterlerin önemini belirtir, (c-r) farkı ise kriterlerin etki durumlarını ifade eder. (c-r)< 0 ise diğer kriterler tarafından etkilenmektedir.

6. Adım: Ağ yapısının oluşturulması için öncelikle bir eşik değeri tespit edilir. Daha sonra toplam ilişki matrisinde bu eşik değerine eşit veya bu değerden büyük olan hücre değerleri, kriterler arası ilişkilerin yönünü göstermektedir (Tsai ve Chou, 2009).

2.2. PROMETHEE Yöntemi

PROMETHEE (The Preference Ranking Organization METHOD for Enrichment Evaluation) yöntemi, ÇKKV problemlerin çözümü için kullanılır (Dağdeviren ve Eraslan, 2008).

GAIA (Geometrical Analysis for Interactive Aid) Düzlemi, PROMETHEE yönteminden elde edilen bulguların grafik gösteriminden oluşmaktadır. PROMETHEE yöntemi alternatifleri değerlendirirken uyumsuzlukları tespit edip, çelişen kriterler, duyarlılık hesaplamaları ile ağırlıklar test edilebilmektedir (Tavana vd., 2013).


PROMETHEE Yöntemi'nin Adımları (Brans vd., 2005):

1. Adım: Alternatif kriterler ve kriter ağırlıkları tespit edilir,

$$Dj(a,b)= gj(a)-gj(b) \quad (5)$$

2. Adım: Tercih fonksiyonları belirlenir,


3. Adım: Ortak tercih fonksiyonları belirlenir, bunlar: (1) Olağan (2) U-tipi (3) V-tipi (4) Seviyeli (5) Doğrusal (6) Gaussian'dır.



Şekil 1: Ortak Tercih Fonksiyonu

$$P(a,b) = \sum_{j=1}^k (p_j(a,b)), P(b,a) = \sum_{j=1}^k (p_j(b,a)) \quad (6)$$

4. Adım: Pozitif ve negatif üstünlük değerleri hesaplanır,



Şekil 2: Pozitif ve Negatif Üstünlük Akımları

$$\phi^+(a) = \frac{1}{n-1} \sum_{x \in A} \pi(a, b), \quad (7)$$

$$\phi^-(a) = \frac{1}{n-1} \sum_{x \in A} \pi(b, a) \quad (8)$$

5. Adım: Alternatiflerin pozitif (Φ^+) ve negatif (Φ^-) üstünlükleri hesaplanıp kısmi sıralamaları elde edilir (Dağdeviren vd., 2008).

6. Adım: Kısmi öncelik değerleri belirlenir.

$$\phi^+(a) > \phi^+(b) \text{ ve } \phi^-(a) < \phi^-(b) \quad (9)$$

$$\phi^+(a) = \phi^+(b) \text{ ve } \phi^-(a) < \phi^-(b) \quad (10)$$

$$\phi^+(a) > \phi^+(b) \text{ ve } \phi^-(a) = \phi^-(b) \quad (11)$$

$$\phi^+(a) = \phi^+(b) \text{ ve } \phi^-(a) = \phi^-(b) \quad (12)$$

$$\phi^+(a) > \phi^+(b) \text{ ve } \phi^-(a) > \phi^-(b) \quad (13)$$

$$\phi^+(a) < \phi^+(b) \text{ ve } \phi^-(a) < \phi^-(b) \quad (14)$$

Eşitliklerden 9, 10 ya da 11. denklem koşullarından biri oluşur ise; a alternatifi b alternatifine göre daha üstün bir alternatiftir. 9. eşitlik koşulunun sağlanırsa iki alternatif arasında fark yoktur. 10. ya da 11. denklem oluşursa, a alternatifi b alternatifi ile karşılaştırılmaz dolayısıyla tam bir sıralama elde edilemez. Böylece, sıralamanın elde edilmesi için bir sonraki aşamaya PROMETHEE II'ye geçilir.

$$\phi(a) = \phi^+(a) - \phi^-(a) \quad (15)$$

Denklem 15'teki gibi pozitif akım değerinin, negatif akım değerinden çıkarılmasıyla bulunur (Brans ve Mareschal, 2005).

7. Adım: Tam sıralama değerleri elde edilir, karar seçeneklerinin tam öncelikleri belirlenir ve büyükten küçüğe doğru sıralanır.

2.3. Bulgular

Çalışmada yer alan bankalar; Halkbank, Yapı Kredi Bankası, Akbank, Garanti BBVA ve Türkiye İş Bankası'dır. Çalışmada kullanılan bankaların çevresel sürdürülebilirlik kriterleri Tablo 1'de görülmektedir.

Tablo 1. Çevresel Sürdürülebilirlik Kriterleri

| Kriterler | |
|-----------|---------------------------|
| K1 | Toplam enerji tüketimi |
| K2 | Toplam su tüketimi |
| K3 | Toplam sera gazı emisyonu |
| K4 | Toplam atık miktarı |
| K5 | Kâğıt tüketimi |

DEMATEL Yöntemi ile Kriterlerin Ağırlıklandırılması

Uzman görüşleri yardımları ile Eşitlik 2 ve 3 kullanılarak kriterler puanlanıp direkt ilişki matrisi normalize edilmiştir. Tablo 2’de normalize edilmiş matris yer almaktadır.

Tablo 2. Normalize Edilmiş Direkt İlişki Matrisi

| | K1 | K2 | K3 | K4 | K5 |
|----|-------|-------|-------|-------|-------|
| K1 | 0,000 | 0,214 | 0,286 | 0,214 | 0,143 |
| K2 | 0,214 | 0,000 | 0,286 | 0,214 | 0,143 |
| K3 | 0,286 | 0,214 | 0,000 | 0,286 | 0,071 |
| K4 | 0,143 | 0,143 | 0,286 | 0,000 | 0,143 |
| K5 | 0,143 | 0,143 | 0,143 | 0,143 | 0,000 |

Toplam İlişki Matrisi Tablo 3’te yer almaktadır.

Tablo 3. Toplam İlişki Matrisi

| | | | | |
|-------|-------|-------|-------|-------|
| 0,227 | 0,193 | 0,289 | 0,434 | 0,289 |
| 6,938 | 1 | 1,11 | 0 | 4,44 |
| 1,734 | 1,249 | 1 | 1,665 | 0 |
| 3,469 | 2,782 | 1,11 | 1 | 2,22 |
| 2,775 | 1,111 | 8,326 | 1,11 | 1 |

Tablo 4. Önem Ağırlıklarının Hesaplanması

| | D | R | D-R | D+R | wia | wi |
|----|--------|--------|---------|--------|--------|-------|
| K1 | 1,432 | 15,143 | -13,711 | 16,575 | 21,511 | 0,214 |
| K2 | 13,488 | 6,335 | 7,153 | 19,823 | 21,074 | 0,210 |
| K3 | 5,648 | 11,835 | -6,187 | 17,483 | 18,545 | 0,185 |
| K4 | 10,581 | 4,209 | 6,372 | 14,790 | 16,104 | 0,160 |
| K5 | 14,322 | 7,949 | 6,373 | 22,271 | 23,165 | 0,231 |

Tablo 4’te D , R , $D+R_j$ ve $D-R_j$, wia ve wi değerleri yer almaktadır. Önem ağırlıklarını etkileyen ve önem ağırlıklarından etkilenen kriterler belirlenmiştir. Tablodaki wi değerleri, hesaplanan kriter ağırlıklarını göstermektedir.


2.4. PROMETHEE Yöntemi ile Bankaların Çevresel Sürdürülebilirlik Performanslarının Sıralanması

Tablo 5’te bankaların internet sayfalarındaki 2022 yılı sürdürülebilirlik raporlarından alınan veriler yer almaktadır.

Tablo 5. Alternatif Bankaların Kriterlerinin Karar Matrisi


| Kriterler | Alternatifler | | | | |
|-----------|---------------|-------------|------------|-------------|-------------|
| | A1 | A2 | A3 | A4 | A5 |
| K1 | 59.937,000 | 479.471,000 | 62.104,000 | 161.320,000 | 168.617,000 |
| K2 | 206,000 | 225,000 | 184,000 | 233,000 | 282,000 |
| K3 | 72.962,330 | 14.555,000 | 41.860,120 | 18.981,000 | 22.119,000 |
| K4 | 693,000 | 1.272,100 | 1.689,000 | 204,000 | 765,000 |
| K5 | 1.764,820 | 874,900 | 214,100 | 730,000 | 963,000 |

Visual PROMETHEE programından Şekil 3'teki kısmi ve Şekil 4'teki tam sıralamalara ulaşılmıştır.



Şekil 3. PROMETHEE I Kısmi Sıralama

Şekil 3'teki PROMETHEE I ile kısmi sıralama sonucunda A4 kodlu bankanın en iyi alternatif olduğu ve kısmi önceliğe sahip olduğu görülmektedir. A4 kodlu bankayı A3, A2, A1 ve A5 kodlu bankalar takip etmektedir.




Şekil 4. PROMETHEE II Tam Sıralama

Şekil 4'te PROMETHEE II yöntemiyle elde edilen tam sıralama görülmektedir. Tablo 7'de alternatiflerden hangilerinin tercih edilebilir oldukları ifade edilmektedir.

Tablo 7. PROMETHEE II Tam Sıralama Sonucu

| Sıra | Bankalar | Phi | Phi+ | Phi- |
|------|----------|---------|--------|--------|
| 1 | A4 | 0,3434 | 0,5254 | 0,182 |
| 2 | A3 | 0,1675 | 0,4688 | 0,3013 |
| 3 | A2 | 0,0803 | 0,3959 | 0,3156 |
| 4 | A1 | -0,2675 | 0,2262 | 0,4937 |
| 5 | A5 | -0,3237 | 0,2316 | 0,5553 |

Tablo 7'de PROMETHEE ağı, hangi alternatiflerin birbirlerine üstünlük sağladıklarını ifade eder. Alternatiflere ilişkin pozitif ve negatif akım değerleri görülmektedir (Genç, 2013).



Şekil 5. GAIA Düzlemi

Şekil 5'te bankaların sürdürülebilirlik performansları GAIA düzleminde gösterilmiştir. Karar çubuğu kırmızı renklidir. GAIA Düzlemi, A4, A3, A2, A1 ve A5 kodlu bankaların tercih edilebilir oldukları hakkında fikir vermektedir. En önemli kriterin 'kâğıt tüketimi' olduğu görülmektedir. GAIA düzleminde birbirleri ile aynı doğrultudaki eksenler ile temsil edilmektedirler.

3. Sonuç ve Tartışma

Bankalar, sürdürülebilir kalkınmaya katkıda bulunmak için uygulamalarını çeşitlendirmeliler ve bu doğrultuda birbirlerine model olmalıdırlar. Ürün yelpazelerini, çevre dostu ürünlerden oluşturmalıdırlar. Yıllık olarak yayınlanan GRI onaylı sürdürülebilirlik raporlarında; çevrenin korunması, kaynakların etkin biçimde kullanılmaları, sosyal sorumluluk projelerinin geliştirilmeleri konuları yer almaktadır.

Literatürde yapılan çalışmalarda, çevresel sürdürülebilirlikte yeşil bankacılığın rolünü araştırılmış, bankalar için önemli olabilecek uygulamalar vurgulanmıştır. Sürdürülebilir bankacılık performansı değerlendirilirken enerji verimliliğinin önemine dikkat çekilmiş, çevre yönetimi, yeşil ürünlerin ve hizmetlerin geliştirilmelerine yönelik değerlendirmeler yapılmıştır. Bankalarda çevresel sürdürülebilirliğin farkındalığı incelenmiş, çevresel ve sosyal risklerin ölçülmesi önlenmesi ve yönetilmesi konularının önemi fark edilmiştir. Sürdürülebilir kalkınma için eğitim ve bilinçlenmenin önemi vurgulanmıştır (Gupta, 2015; Kumar ve Prakash, 2018; Kurbanova ve Çalıyurt, 2020; Aksaray ve Ateş, 2019).

Bu çalışma kapsamında bankaların çevresel sürdürülebilirlik performansları 2022 yılı sürdürülebilirlik ve faaliyet raporlarındaki veriler DEMATEL yöntemi ile ağırlıklandırılıp PROMETHEE yöntemi ile sıralanmıştır. Çalışmada hesaplanan kriter ağırlıkları $K5 > K1 > K2 > K3$ ve $K4$ şeklindedir. Yapılan analizler sonucunda çevresel sürdürülebilirlik performansını en çok etkileyen kriterin 'kâğıt tüketimi' olduğu görülmüştür. Çevresel sürdürülebilirlik uygulamaları konusunda banka yöneticileri bu bağlamda bilinçlendirme çalışmaları yapabilirler. Bankaların çevresel sürdürülebilirlik uygulamaları kapsamında sıralanmaları; $A4 > A3 > A2 > A1$ ve $A5$ şeklinde gerçekleşmiştir.

Gelecekte yapılacak olan çalışmalarda, işletmelerin farklı konularda seçim, sınıflandırma ve sıralama problemlerine diğer ÇKKV yöntemleri, Bulanık Mantık veya Yapay Zekâ Yöntemleri uygulanabilir. Elde edilecek olan sonuçlar birbirleri ile kıyaslanabilir. Çevresel sürdürülebilirlik performanslarının

değerlendirilmesi ile ilgili farklı uzman görüşlerinden yararlanılarak çalışmalar çeşitlendirilebilir. Çevresel sürdürülebilirliğin benimsenmesi ve sağlanması noktasında belirli uygulamalar için kamudan destek alınabilir. Kamu spotları hazırlanabilir, banka personellerine gerekli eğitimler verilebilir.

Author Contributions (Yazar Katkı Oranı): Elçin NOYAN (%100)

Ethical Responsibilities of Authors (Yazarın Etik Sorumlulukları): This study was prepared in accordance with the rules of the required ethical approval

Conflicts of Interest (Çıkar Çatışması): There is no conflict of interest with any institution related to the study.

Plagiarism Checking (İntihal Denetimi): This study has been checked for plagiarism using a plagiarism scanning programme.

KAYNAKÇA

- Aksaray, M. & Ateş, A. (2019). "Turist Rehberlerinin Hizmet Kalitesinin Destinasyon İmajına Etkisi". *Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi*, 22(1), 112-132.
- Bankaların Sürdürülebilirlik Raporları (Erişim Tarihi: 01/04/2023).
<https://www.akbankinvestorrelations.com/tr/images/pdf/akbank-2022-entegre-faaliyet-raporu.pdf>
- <https://www.borsaistanbul.com/tr/duyuru/44/bist-surdurulebilirlik-endeksi-kasim-2019-ekim-2020-donemi-sirketleri-belli-oldu>
- <https://www.garantibbvainvestorrelations.com/tr/kutuphane/faaliyet-raporlari/Entegre-Faaliyet-Raporlari/666/0/0>
- <https://www.halkbank.com.tr/content/dam/halkbank/tr/dokumanlar/bankamiz/surdurulebilirlik/2021-Entegre-Raporu.pdf>
- <https://www.isbank.com.tr/contentmanagement/IsbankSurdurulebilirlik/pdf/EFR2022.pdf>
- https://www.yapikrediinvestorrelations.com/tr/images/pdf/faaliyet-raporlari/2022/yk22_faaliyet_tr-web-final-c.pdf
- Bose, S., Khan, H.Z., Rashid, A. & Islam, S. (2018). "What Drives Green Banking Disclosure? An Institutional and Corporate Governance Perspective". *Asia Pacific Journal of Management*, 35(2), 501-527.
- Bouma, J. J., Jeucken, M. & Klinkers, L. (2001). "Sustainable Banking: The Greening of Finance. Sheffield". *Greenleaf Publishing and Deloitte&Touche*.
- Brans, J. P. & Vincke, P. (1985). "A Preference Ranking Organization Method: The PROMETHEE Method for MCDM". *Management Science*, 31(6), 647-656.
- Padmavathi, D. (2012). *Green Consumer Behavior-An Empirical Study with Respect to Select Eco-Friendly Products*. PhD Thesis Submitted to Bharathair University.
- Dağdeviren, M. & Eraslan, E. (2008). "PROMETHEE Sıralama Yöntemi İle Tedarikçi Seçimi". *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 23(1), 69-75.
- Dewi, I.G.A.A.O. & Dewi, I.G.A.A.P. (2017). "Corporate Social Responsibility, Green Banking and Going Concern on Banking Company in Indonesia Stock Exchange". *International Journal of Social Sciences and Humanities*, 1(3), 118-134.
- Erdal, H. (2017). *Tedarik Zinciri Ağında Riskin Yönetimi: Tedarik Yönlü Bir Karar Destek Sistemi Tasarımı*. Atatürk Üniversitesi Sosyal Bilimler Enstitüsü, Yayınlanmamış Doktora Tezi, Erzurum.
- Garanti Bankası Sürdürülebilirlik raporu
(<https://www.garantibbvainvestorrelations.com/tr/images/pdf/ESG-Analyst-Data-TR-2021.pdf>) (Erişim Tarihi: 01/04/2023).

- Genç, T. (2013). "PROMETHEE Yöntemi ve GAIA Düzlemi". *Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(1), 133-154.
- Genel Sürdürülebilirlik Bankacılık Verileri (<https://www.tbb.org.tr/tr/bankacilik/arastirma-ve-yayinlar/surdurulebilirlik/4507>), (Erişim Tarihi: 01/04/2023).
- Gupta, J. (2015). "Role of Green Banking in Environment Sustainability-A Study of Selected Commercial Banks in Himachal Pradesh". *International Journal of Multidisciplinary Research and Development*, 2(8), 349-353.
- Kumar, K. & Prakash, A. (2019). "Developing a Framework for Assessing Sustainable Banking Performance of the Indian Banking Sector". *Social Responsibility Journal*, 15(5), 689-709.
- Kurbanova, M. & Çalıyurt, K. (2020). *Bankalarda Çevresel Sürdürülebilirlik Farkındalığı: Uluslararası İnceleme*. Yüksek Lisans Tezi, Sosyal Bilimler Enstitüsü.
- Mareschal, B. & Brans, J. P. (1988). "Geometrical Representations for MCDA". *European Journal of Operational Research*, 34, 69-77.
- Masukujjaman, M. D. & Aktar, S. (2013). "Green banking in Bangladesh: a Commitment Towards the Global Initiatives". *Journal of Business and Technology (Dhaka)*, VIII, (1, 2), January-June, July- December:17-40.
- Özogul, G. & Baran, G. G. (2016). "Accessible Tourism: The Golden Key in the Future for the Specialized Travel Agencies". *Journal of Tourism Futures*, 2(1), 79-87.
- Punjab National Bank, annual report 2014-15 http://pnbindia.in/new/upload/english/financials/pdfs/PN_bannualreport201314pdf.
- RBI (2017), Report on trend and progress of banking in India 2016-17 <https://rbidocs.rbi>. (Date of Access: 01/04/2023).
- Sahoo, P. ve Nayak, B. P. (2008). "Green Banking in India". *Indian Economic Journal*, 1: 1-22.
- Tavana, M., Behzadian, M., Pirdashti, M. & Pirdashti, H. (2013). "A PROMETHEE-GDSS for Oil and Gas Pipeline Planning in the Caspian Sea Basin". *Energy Economics*, 36, 716-728.
- Tsai, W. H. & Chou, W.C. (2009). "Selecting Management Systems for Sustainable Development in SMEs: A Novel Hybrid Model Based on DEMATEL, ANP and ZOGP". *Expert Systems with Applications*, 36(2), 1444-1458.
- Weber, O. & Feltsmate, B. (2016). *Sustainable Banking: Managing The Social and Environmental Impact of Financial Institutions*. University of Toronto Press, Toronto.
- Weber, O., Scholz, R.W. & Michalik, G. (2010). "Incorporating Sustainability Criteria Into Credit Risk Management". *Business Strategy and the Environment*, 19(1), 39-50.
- Wu, H. H. & Tsai Y. N. (2011). "An Integrated Approach of AHP and DEMATEL Methods in Evaluating the Criteria of Auto Spare Parts Industry". *International Journal of Systems Science*, 1-1.

Wu, H., Chen, H. K. & Shieh, J. (2010). "Evaluating Performance Criteria of Employment Service Outreach Program Personnel by DEMATEL Method". *Expert System with Applications*, 37, 5219-223.

EXTENDED ABSTRACT

It is stated that with environmental sustainability practices, not only to prevent the impact on the environment, but also to protect the long-term sources of exhibition damage (<https://pnbindia.in>). The banking sector, which is the basis of economic development, plays an important role in promoting sustainable development (Weber et al., 2010). It increases the importance of promoting environmentally friendly in the banking sector. Green banking is realized by directing banks to environmental management (Dewi and Dewi, 2017). Bose et al. (2018) internal and external operations of banks for green banking, adoption and promotion of environmentally friendly technologies, carbon footprint prevention, environmental management.

Green Banking: It is a new financial structure that integrates environmental protection with economic profit with the concept never in 2010 (Wang and Zhi, 2016). The green banking concept encompasses ethical banking, social banking and sustainable banking. The concept of sustainability in Turkey is continuous improvement (Weber and Feltmate, 2016). Steps of Green Banking Practices (Masukujjaman and Aktar; 2013): Going online, internet banking, green checking of accounts, green loans for home restrictions, green credit card use, paper savings, power consumption equipment, mobile banking, solar and wind energy uses, and ATM (Gupta, 2015; (Kumar & Prakash, 2019).

In the study, it was aimed to explain the concept of environmental sustainability and the criteria affecting this concept and banks in the BIST sustainability index were listed according to their environmental sustainability performances with the DEMATEL and PROMETHEE methods, which are multi-criteria decision-making (MCDM) methods, and 5 criteria determined as a result of the literature research. The DEMATEL (Decision Making Trial and Evaluation Laboratory) method was introduced by the Geneva Battelle Memorial Institute (Wu et al., 2010). The method was developed by Wu and Tsai (2011) to determine the relationships between complex problems (Erdal, 2017). The PROMETHEE Method (The Preference Ranking Organization METHOD for Enrichment Evaluation) method is used to solve MCDM problems (Dağdeviren & Eraslan, 2008). The GAIA (Geometrical Analysis for Interactive Aid) Plane consists of a graphical representation of the findings obtained from the PROMETHEE method. While the PROMETHEE method is evaluating alternatives, it is possible to detect inconsistencies and test weights with conflicting criteria and sensitivity calculations (Tavana et al., 2013). Sustainability performances of banks are shown on the GAIA level. The decision bar is shown in red. It gives the idea that A4, A3, A2, A1 and A5 coded banks are preferable. It is represented by axes in the same direction with each other on the GAIA plane, where the most important criterion is the 'paper consumption' criterion.

Studies in the literature have investigated the role of green banking in environmental sustainability and emphasized the practices that may be important for banks. Sustainable banking performance was evaluated, attention was drawn to the importance of energy efficiency, and evaluations were made for environmental management and the development of green products and services. The awareness of environmental sustainability in banks was examined, and it was argued that banks, realizing the importance of measuring, preventing and managing environmental and social risks in terms of sustainability, had a strong social and environmental credit policy.

The importance of education and awareness for sustainable development was emphasized (Gupta, 2015; Kumar and Prakash, 2018; Kurbanova and Çalilyurt, 2020; Aksaray and Ateş, 2019). In future

studies, analyzes can be carried out with other MCDM, Fuzzy Logic or Artificial Intelligence Methods for different businesses to decide on different subjects, in their selection, classification or ranking problems. The results to be obtained can be compared with each other. Studies can be diversified by making use of different expert opinions on the evaluation of environmental sustainability performances.

AIZANOI FINANCE REVIEW

ISSUE: 2 / 2023

www.aizanoifr.com

info@aizanoifr.com

COMPARISON OF ARTIFICIAL NEURAL NETWORK AND LOGISTIC REGRESSION METHODS IN CLASSIFYING THE HAPPINESS STATUS OF COUNTRIES

ÜLKELERİN MUTLULUK DURUMUNUN SINIFLANDIRILMASINDA YAPAY SİNİR AĞLARI VE LOJİSTİK REGRESYON YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Fatma Selen MADENOĞLU*,

*Assist. Prof. Dr., Abdullah Gül University, Faculty of Managerial Sciences, Department of Business Administration, selen.madenoglu@agu.edu.tr, <http://orcid.org/0000-0002-5577-4471>

| ARTICLE INFO | ABSTRACT |
|---|---|
| <p>Received 15.07.2023</p> <p>Revized 13.08.2023</p> <p>Accepted 07.09.2023</p> <p>Article Classification: Research Article</p> <p>JEL Codes C30 C40 M10</p> | <p>In recent years, happiness has become one of the main indicators of economic development. In this case, happiness has become a social goal rather than an individual goal. This study aims to classify the happiness status of countries. In order to achieve this goal, happiness situations are determined using the criteria. The study is applied to the countries included in the world happiness report. Logistic regression and artificial neural network methods are used to determine the happiness status of countries. As a result of the analysis, it shows that the logistic regression method is the appropriate method for classifying the happiness status of countries for this study.</p> <p>Keywords: Happiness, Classification, Artificial Neural Network, Logistic Regression Analysis</p> |

| MAKALE BİLGİSİ | ÖZ |
|--|--|
| <p>Gönderilme Tarihi 15.07.2023</p> <p>Revizyon Tarihi 13.08.2023</p> <p>Kabul Tarihi 07.09.2023</p> <p>Makale Kategorisi Araştırma Makalesi</p> <p>JEL Kodları C30 C40 M10</p> | <p>Son yıllarda mutluluk ekonomik kalkınmanın temel göstergelerinden biri haline dönüşmüştür. Bu durumda mutluluk bireysel hedef olmaktan çıkıp toplumsal hedef haline gelmiştir. Bu çalışmada ülkelerin mutluluk durumunun sınıflandırılması amaçlanmaktadır. Bu amaca ulaşmak için kriterler kullanılarak mutluluk durumları tahmin edilmektedir. Çalışma dünya mutluluk raporunda yer alan ülkelere uygulanmıştır. Lojistik regresyon ve yapay sinir ağları yöntemleri ülkelerin mutluluk durumunun belirlenmesinde kullanılmıştır. Yapılan analizler sonucunda, ele alınan çalışma için lojistik regresyon yönteminin ülkelerin mutluluk durumunu sınıflandırmada uygun yöntem olduğu belirlenmiştir.</p> <p>Anahtar Kelimeler: Mutluluk, Sınıflandırma, Yapay Sinir Ağları, Lojistik Regresyon</p> |

Atf (Citation): Madenoğlu, F. S. (2023). "Comparison of Artificial Neural Network and Logistic Regression Methods in Classifying the Happiness Status of Countries", *Aizanoi Finance Review*, (2): 27-48



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

Introduction

Happiness appears as an ultimate goal that everyone strives to achieve (Frey and Stutzer, 2022). Over the years, the concept of happiness has been presented with various aspects ranging from the subjective appreciation of individuals with their material or spiritual values to having values that will gain the appreciation of society, to their combination in various proportions, to the satisfaction with the lifestyle they lead. However, today, when considering happiness, perceived happiness, that is, whether the individual feels happy as an outcome of his/her own evaluation, has gained importance. A person's state of being happy with any subject can be learned by asking the question "how happy that person is with that thing" for his or her opinion on this subject. Such questions can refer to many topics, such as "work, health, income" or "life as a whole" (Van Praag, 2007). The happiness status of the countries is also determined by this analysis of the happiness status of the individuals.

An interdisciplinary area of computer science called machine learning automates the creation of sophisticated prediction models and algorithms by combining methods from other disciplines, including statistics, game theory, information theory, and optimization (Shalev-Shwartz and Ben-David, 2014). Since its inception in Arthur Samuel's 1952 Checkers-playing program and the early research by Hunt, et al. (1966) in inductive problem solving, Nilsson (1965) in statistical functions and data classification, Rosenblatt (1961) in neural networks, machine learning has undergone a significant evolution. It is currently a widely accepted approach that is utilized in fields including pattern recognition, the creation of new knowledge, and predictive analytics (Siegel, 2016). The successful application of machine learning as a classification techniques in areas such as: marketing and financial services, retail, travel, healthcare, sociology, and most recently social media (Finlay, 2014). This suggests that classification techniques could also be used to classify the happiness status of countries.

Saputri and Lee (2015) used a machine learning technique called Support Vector Machine for classifying the country happiness. Using data of 187 countries from the UN Development Project, the present model identify the most important factor needed to be improved by a certain country to increase the happiness of their citizens. Chaipornkaew and Prexawanprasut (2019) presented a happiness prediction model based on the survey. They used four machine learning techniques, namely KNN, Decision Tree, Naïve Bayes, and Multi-Layer Perceptron. Güneş et al. (2020) proposed an ordinal logistic regression for the variables affecting the happiness of provinces in Turkey. The data from the TUIK life satisfaction survey 2013 were used. The model resulted in the conclusion that happy people are those who are female, university graduates, upbeat, have positive relationships with their social surroundings, and are satisfied with their money, marriage, health, and social life. Ibnat et al. (2021) used machine learning, artificial intelligence, and computational strategy to predict the life satisfaction score of any specific country based on the defined parameters, emphasizing the happiest countries and regions based on the 2019 happiness report findings. You (2021) utilized the linear model and some tree models to analyze the features that are related to the happiness index and to make some predictions for Chinese adults. Jannani et al. (2021) predicted the quality of life by using different machine learning techniques on data from the World Happiness Report and made a comparative analysis to determine the most appropriate

machine learning algorithms. The best algorithms are Lasso regression, multiple linear regression, and long short-term memory (LSTM) to predict quality of life indicators for 2021. In order to investigate the impact of inequality on the degree of happiness in the globe, Kandemir (2021) employed the logistic regression by using the world happiness index data. According to the results of the logistic regression, disparities in health and education have a detrimental impact on people's levels of happiness, with disparities in education having a disproportionately greater impact. Khder et al. (2022) used the Neural Network training model and the OneR models to classify the happiness status of countries and identify the main features. The results were evaluated using different performance metrics such as accuracy and confusion matrix. Farooq and Shanmugam (2022) presented the results of the different machine learning algorithms to analyze the happiness status using the happiness report dataset which shows the data that how much citizens have freedom and the COVID-19 dataset. They identified the best algorithm based on computational studies. Lin and Horng (2023) presented the machine learning approach to explain and predict happiness scores. They used the given five prediction models: linear regression, random forest regressor, decision tree, Bayesian linear model, and Lasso Lars.

In the literature study, it was seen that there was no study used logistic regression and artificial neural networks together in the classification of the happiness status of countries using the 2021 World happiness report data. With this motivation, the presented paper aims to classify the happiness status of the countries in the World Happiness Report by using logistic regression and artificial neural networks.

The remained part of the paper has represented an order as follows. The second part explains the methodology. The third part presents the application. In the last part, results and conclusions are represented.


1. Methodology

In the study, it's aimed to classify the happiness status of the countries. The World Happiness Index published in the World Happiness Report 2022 are used in the study. In the interest of establishing a composite index by which the countries can be ranked according to their happiness, the World Happiness Index (HI) attempts to define happiness based on a number of indicator variables, each of which is said to reflect a component of the general happiness of a country. Each of these indicators can also be connected to numerous sustainability-related topics. In support of the United Nations high-level summit on "Well-being and Happiness: Establishing a New Economic Paradigm," the World Happiness Report was first released in April 2012 and has since been released yearly. The first paper analyzed the growing science of happiness and offered current worldwide statistics on country happiness, demonstrating that a range of parameters can be used to consistently, legitimately, and reliably evaluate people's quality of life. Updated evaluations, in-depth special themes on the science of wellbeing, and a number of chapters on happiness in certain regions and countries are all included in each issue. The reports were typically prepared around a particular theme, but occasionally they had a different focus. World Happiness Report data is collected by a company called "Gallup World Poll". The company conducts this survey to approximately 1000 people over the age of 15 in more than 150 countries each year. When conducting these surveys, the company asks respondents to think of a 10-step ladder and on which rung they see themselves,

with 10 as the best possible life and 0 as the worst possible life. This ladder is called the "Cantril Ladder". The World Happiness Council combines the data from this survey with other data sources to form the World Happiness Report. The countries in the World Happiness Report are ranked according to the "Happiness Index", which is a single index, although it consists of many data and factors. The six key factors most related to the Happiness Index were determined. These factors are; economy, health, freedom, trust, generosity and corruption. These factors are used in the calculation of the happiness index. In addition to these factors, an additional factor called "Dystopia" is taken into account. Dystopia is an imaginary country with the most unhappy people in the world. The sum of these seven factors is called the "Happiness Score" and allows us to rank the countries according to their happiness with a single value. According to the latest report published in 2022, Finland is the happiest country in the world. Ranking of countries by happiness index values according to the World Happiness Report for 2022 are given in Figure 1. When the rankings in the world happiness report are examined, it is also seen how much of the total values given are caused by which factor. According to the world happiness report, Finland, Denmark, Iceland, Switzerland, Netherlands, Luxembourg, Sweden, Norway, Israel, New Zealand, which are the top 10 happiest countries, have high scores in terms of factors. According to the world happiness report, the 10 countries with the lowest scores are Zambia, Malawi, Tanzania, Sierra Leone, Lesotho, Botswana, Rwanda, Zimbabwe, Lebanon, Afghanistan. Six of the G20 countries (Australia, Germany, Canada, USA, United Kingdom, France) with the world's largest economy in dollar terms are in the top 20 of the happiness ranking. The G20 Group countries represent 85% of the world's population and 65% of the world's GDP. Only ten countries in G20 countries are in the top 50 of the happiness ranking. Turkey ranks one hundred and twelfth in this ranking.

The study is carried out on behalf of 140 countries for which variable values can be obtained and are in the World Happiness Index. In this study, countries are classified according to their happiness values. First of all, the happiness index value, which is planned to be classified according to the logistic regression and artificial neural network, is rearranged into two categories. Here, while creating the categories, the average of the happiness index values given for the countries are taken and the countries below the average are coded as 0, that is, unhappy, and the countries above the average are coded as 1, that is, happy. When the data set did not contain outliers, the arithmetic mean instead of the median is taken as a measure of central position. From this point of view, in all methods to be used in the continuation of the study, the groups related to the happiness index will be expressed as output variable. Population, labor force, life expectancy at birth, school enrollment, primary (% gross), GDP per capita (current US\$), poverty headcount ratio at national poverty lines (% of population) of each country are taken into account as factors in order to examine the happiness status of countries. Population, labor force, life expectancy at birth, school enrollment, GDP per capita, poverty headcount ratio data taken from the World Bank database and happiness data is taken from the 2022 World Happiness Report.

Figure 1. Ranking of Countries by Happiness Index Values According to the World Happiness Report for 2022



COMPARISON OF ARTIFICIAL NEURAL NETWORK AND LOGISTIC REGRESSION METHODS IN CLASSIFYING THE HAPPINESS STATUS OF COUNTRIES

Figure 1. Ranking of Countries by Happiness Index Values According to the World Happiness Report for 2022 (continued)





Figure 1. Ranking of Countries by Happiness Index Values According to the World Happiness Report for 2022 (continued)



1.1. Logistics Regression

In statistical applications, many regression methods have been developed to establish a relationship between the independent variable and the outcome variable. It is known that results cannot always be obtained by using only one of the developed methods. Therefore, alternative methods have been developed. The Logistic Regression (LR) has also been introduced for this purpose. LR is one of the machine learning models (Sperandei, 2014). LR is generated from a linear regression where the dependent variable is binary (Bailly et al. 2022). LR is useful in estimating a categorical variable. LR, which is similar to linear regression in many ways, is more suitable when the dependent variable is

a categorical data type with two or more options (Leech et al., 2004). Many of the variables studied in the social sciences are measured using a sensitivity scale, others are two-choice data, such as positive-negative, successful-unsuccessful, yes-no, and satisfied-not satisfied. Binary data is the most prevalent type of category data. The most popular model used in econometrics where the dependent variable has two-choice qualitative characteristics, such as yes/no, successful/unsuccessful, etc., is the logit model (Hill and Lim, 2011). For investigating the cause-and-effect relationship between the dependent variable and the independent variable, LR is utilized when the dependent variable is categorical data with two variables (Agresti, 2002).

Logit model is used in many fields such as economics, market research, politics, finance, and transportation engineering (Greene, 2012). The dependent variable is typically coded as "1" or "0" in binary logit models. The dependent variable is coded as "1" when the outcome is favorable or successful. The dependent variable is recorded as "0" since the outcome was unsuccessful or negative. Unlike conventional regression models ($Y_i = \alpha_0 + \alpha_1 X_i + \varepsilon_i$), logit models conceal the error term. In logit models, there is not a ε_i as in the traditional regression model, but there is a ε_i in the background. Therefore, the estimated dependent variable can be interpreted as the probability of causing it (Kennedy, 2008).

LR allows us to construct a regression model without many assumption checks. LR is analysis where variables can be continuous or discrete. If necessary, in order to establish the LR model, a continuous result variable, in other words, the predicted variable can be transformed into a discrete variable (Tabachnick and Fidell, 1996). The method is widely used because it offers a more flexible structure and is easier to apply compared to similar analyzes.

In the LR, a model is established between one or more independent variables and the outcome variable. LR is used to model the relationships between the dependent variable measured in categories and some independent variables measured categorically or continuously. The difference from other methods is that in other regression methods, the outcome variable takes continuous values, while in LR, it is used when the outcome variable takes two or more discrete values (Hosmer et al., 2013). The major conclusion that can be reached from this investigation is that it is actually possible for the relationship between the dependent variable and the independent factors to be realized (Umar and Nashir, 2009).

The basis of the LR is based on the odds ratio. The odds ratio compares the probability that an event will occur with the probability that the same event will not occur. Thus, LR is obtained by taking the natural logarithm of the odds ratio. The maximum likelihood method is widely used when estimating the parameters of the obtained LR (Berenson and Levine, 1996).

LR is also an alternative to discriminant analysis and crosstabs. The validity criterion of the normality assumption is also discarded in this analysis because the dependent variable is one that may be classified as a binary preference with a range of 0 to 1. The results of this method are also incredibly adaptable and simple to interpret, which contributes to its high level of interest. In addition, conditions such as normality, linearity, covariance, and continuity, which are required in linear regression analysis, are not required in LR. The maximum likelihood method is used. The maximum likelihood method, on the other hand, refers to the parameter findings that provide the maximum

compatibility of the parameter values obtained from the application findings with the real data set we have (Alpar and Karabulut, 2007).

In any regression model, the expression $E(y/x)$ represents the conditional mean value. This expression shows the mean value of the dependent variable (y) given the independent variable (x). The most important quantity in any regression problem is the mean value of the result for a given independent variable value. This quantity is the "conditional mean" and is denoted as " $E(y/x)$ ". $E(y/x)$ is interpreted as "The expected value of y for a given value of x ".

$$E(y/x) = \beta_0 + \beta_1 x \quad (1)$$

Given x in LR (1), the conditional distribution mean of Y is shown as $\pi(x) = E(y/x)$. The special case of LR model is as follows.

$$E(y/x) = \pi(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}} \quad (2)$$

A transformation of $\pi(x)$ that will be at the center of our logistic regression work is the "logit* transformation". This transformation is defined in terms of $\pi(x)$ as follows.

$$g(x) = \ln \left[\frac{\pi(x)}{1 - \pi(x)} \right] = \beta_0 + \beta_1 x \quad (3)$$

There is a linear relationship between the logit value and the independent and dependent variables. The logit $g(x)$, which is linear in its parameters, can be continuous and take values from $-\infty$ to $+\infty$, depending on the definition range of x .

In the binary LR, there are two situations, 0 and 1, for the event to occur and not to occur. The ratio of the probability of an event to its probability of occurrence is defined as the odds ratio. Odds ratio (4) can take values between 0 and $+\infty$ (Agresti, 1996).

$$\text{Odds ratio} = \frac{\pi(x)}{1 - \pi(x)} = e^{\beta_0 + \beta_1 x} \quad (4)$$

β_0 in the function represents the constant term. β_1 is the slope coefficient. β_1 represents the change in odds ratio versus a one-unit change in x (Gujaranti, 2010). In logistic regression, the maximum likelihood method is used instead of the least squares method in estimating the regression coefficients. In the maximum likelihood method, the probability of an event occurring is desired to be maximum (Alpar, 2013).

1.2. Artificial Neural Networks

Artificial neural networks (ANNs) are revealed by the design of nerve cells in the human brain and consist of interconnected processing elements with different levels of importance. ANNs are among the classification algorithms and are frequently preferred in practice today, where machine learning algorithms are increasingly being used. Although McCulloch and Pitts first used the concept of artificial neurons in their study in 1943, it started to be used quite frequently, especially after the 90s (Rojas, 1993). ANN is a mathematical model created by imitating the operation of simple biological nervous systems. The basic principles of ANN include gaining new information by learning the brain, gaining abilities such as critical thinking, problem solving and estimation. ANN is of interest to researchers because of its features such as producing solutions by learning the

relationship between input and output related to any event, whether linear or not, from the examples at hand, and correlating previously unseen events with past examples (Kaftan, 2010).

ANNs have been thoroughly utilized in many different fields for prediction in last years. Especially in non-linear time series, the superior success of ANN over traditional methods has been an important factor in the preference of this method (Zhang et al., 1998). Artificial neural networks can be applied in many different applications such as robotics, pattern recognition, medicine, power systems, signal processing, prediction and system modeling (Dogan and Atik, 2004; Ataman et al., 1998; Demir et al., 1998; Kalogirou and Bojic, 2000; Bayram et al., 2013; Sahin, 2014; Özdemir, 2011).

Haykin (1999) introduced the following definition for ANN: "A neural network is a densely parallel distributed processor composed of simple processing units, which has a natural tendency to accumulate experiential information and enable it to be used. This processor is similar to the brain in two ways: 1. Information is obtained by the network from the environment through a learning process. 2. Interneuron connection strengths, also known as synaptic weights, are used to accumulate the obtained information". As a machine learning technique, ANN is described as having the capacity to generate and find new information through behavior modification, similar to how the human brain does (Chehreh et al., 2008). Gamache et al. (2018) defined ANN a machine learning technique used to measure the relationship between input and output variables. Yakubu et al. (2019) presented artificial neural network models as an alternative to traditional regression models and defined them as a nonlinear parametric method that mimics the processing mechanism of the human brain. Kumar and Giri (2019) defined ANN as the simplification of biological neural structures and defined them as highly interconnected processing units (neurons) for understanding, acquiring information and using this information. ANN, which are commonly described as neural networks, are a prediction-based model in the common set of statistics, cognitive psychology and artificial intelligence, designed with inspiration from biological observations of human brain functions (Yang et al., 2016; Bhosale, 2016; Kasiviswanathan et al., 2016).

ANNs include traditional prediction models such as regression analysis, correlation analysis, moving averages, exponential smoothing method, box-jenkins method, autoregressive moving average, autoregressive integrated moving averages, simulation methods. The method differs from these methods in that it is a nonlinear model using the sum and transfer functions in the middle layer (Karahan, 2011; McNelis, 2005).

ANN can provide nonlinear modeling without making any assumptions, without the need for any prior knowledge between input and output variables. By giving the input information and the corresponding output information to the network, it is ensured that the network learns the relationship between input and output, and in this way, the training of the network is carried out (Hosmer, 1999).

Neural networks consist of three layers: input layer, hidden layer and output layer. Each layer consists of neurons. The basic element of the technique is the processing elements called neurons (Bağış and Konar, 2010). The input layer shows the level corresponding to the independent variable in the statistical analysis, and the output layer shows the level corresponding to the dependent variable. The hidden layer ensures that only the signals from the input layer are transmitted to the


output layer (Budak and Erpolat, 2012). The connections of neurons to each other in various ways form a network. The function of the neuron is to add the values obtained by multiplying each of the input data with the weight values, with the threshold (addition function) value, and to pass this sum through the sigmoid or tanh activation functions and give it to the output. In general, neuron output is expected to be between (0-1) for *sigmoid* and (-1,1) for *tanh* (Şencan and Çiçek Bezir, 2003). ANN can be represented in many different ways. The structure of the multilayer perception model is as shown in Figure 2 (Ivan et al., 2016).

The information transmitted from the input layer is processed within the framework of certain standards and transmitted to the output layer. The main task of the network is the hidden layer. The number of hidden layers varies from network to network in line with the purpose to be realized. In the output layer, the information from the intermediate layer is processed. Output is produced in the output layer, which must be produced according to the inputs presented to the input layer. There are as many neurons in the output layer as the number of outputs of each data presented to the network. The values produced from the output layer constitute the output values created by the artificial neural networks against the problem. In modeling a problem in which the artificial neural network method is used, it is very important to determine the number of processing elements in the layers together with the number of hidden layers to be used for the best solution of the problem (Şahan and Okur, 2016).

In ANN, the process of updating the connection settings in the network to perform functions such as classification, modeling, optimization or prediction is called learning. This process, which is done in order to increase the performance of the network, is carried out in computer programs in the form of iterations. The learning process is carried out with algorithms (Çalışkan and Deniz, 2015).

Many classifications of artificial neural networks are encountered in the literature. Artificial neural networks are classified as feed forward and feedback recurrent artificial neural networks according to the direction of the information flow between the nerves in their structures, and are classified as supervised and unsupervised artificial neural networks according to the learning structure of the network. In feed forward artificial neural networks, there are multi-layer structures, one of which is the input layer, one is the output layer, and the others are hidden layers. In this artificial neural network structure, the information flow is forward-directed by being transmitted from the input layer to the hidden layer and transmitted from the hidden layer to the output layer. Examples of such networks are; multilayer perceptron and learning vector quantization. In feedback recurrent artificial neural networks, there is a multi-layered structure as in feed-forward networks. However, unlike the feed forward network structure, the information flow in this network structure can be backwards. Outputs of cells; it can also be used as an input to itself or another cell in the network (Sağiroğlu et al., 2003). Multilayer perceptrons are used in this study due to the usefulness of feed forward networks.

Figure 2. Structure of the Multi-Layer Sensor Model



Resource: Ivan Nunes da Silva, Danilo Hernane Spatti, Rogerio Andrade Flauzino, Luisa Helena Bartocci Liboni, Silas Franco dos Reis Alves,(2016), Artificial Neural Networks: A Practical Course, Springer, New York.

2. Application

2.1. Logistic Regression Results

LR is applied to the variables used in the study. LR is carried out with the WEKA program. The Weka program is a data analysis tool developed at the University of Waikato using the Java software language. It is also widely used in the field of data mining. There is a lot of information about machine learning, clustering and statistics available on the Weka program. The variables were determined and the significance of the model was tested. The Omnibus test was applied to evaluate the significance of the coefficients in LR. Omnibus test results obtained as a result of the analysis are presented in Table 1. Since $p=0,000 < 0,05$, the coefficients of the independent variables are nonzero. It is observed that there is a significant difference between the model with independent variables and the model with only constant variables. In other words, at least one of the independent variables added to the model contributes to the estimation of the dependent variable. The results show that the model is generally significant.

Table 1. Omnibus Tests of Model Coefficients

| | | Chi-square | df | Sig. |
|--------|-------|------------|----|------|
| Step 1 | Step | 98,186 | 6 | ,000 |
| | Block | 98,186 | 6 | ,000 |
| | Model | 98,186 | 6 | ,000 |

The Hosmer-Lemeshow test is one of the methods used to determine whether the obtained model has fit to the data. The Hosmer-Lemeshow test is one of the methods used to determine whether the obtained model fits well with the data. This test tests whether there is a significant difference between the values predicted by the model and the observed values. The insignificance of the result of this test ($p > 0.05$) indicates that the model-data fit is sufficient, in other words, the model has an

acceptable fit (Toraman and Karaca, 2016). As a result of the test, it's concluded that there is no significant difference between the estimation values and the observation values, in other words, the theoretical data represent the model well and significant ($p=0,976>0,05$).

Table 2. Hosmer and Lemeshow Test

| Step | Chi-square | df | Sig. |
|------|------------|----|------|
| 1 | 2,155 | 8 | ,976 |

The relationship between the estimated probabilities and the actual probabilities, showing how the model represents the data, and statistics of $-2\log L$ are given in Table 3. In LR, the strength of the relationship between the dependent variable and the independent variables is determined by the Cox-Snell R Square and Nagelkerle R Square values. The values of the logistic regression explanatory coefficients (R Square statistics) show what percentage of the dependent variable is explained by the independent variables. As presented in Table 3, the explanatory power of the independent variables for the dependent variable was 53.6% according to the Cox&Snell R square value, while this value was 71.5% according to the Nagelkerke R square value.

Table 3. Model Summary

| Step | -2 Log likelihood | Cox & Snell R Square | Nagelkerke R Square |
|------|-------------------|----------------------|---------------------|
| 1 | 78,759 | ,536 | ,715 |

The results of LR are presented in Table 4. In this table, the number of countries correctly identified as happy (True positive-TP) is 60, the number of countries incorrectly as happy (False positive- FP) is 13, the number of countries correctly identified as unhappy (True negative-TN) is 56, the number of countries incorrectly identified as happy (False negative-FN) is 11. The calculated correct assignment rate must be greater than 50% to conduct the analysis. According to the results presented, countries defined as happy as a result of LR are classified as correct at a rate of 84.5%, while countries defined as unhappy are classified correctly at a rate of 81.2%. The overall accuracy rate is also found to be 84.5%. As a result, it can be said that the classification effectiveness of the model is quite good.

Table 4. The Results of Logistic Regression Classification

| | | Predicted | | |
|--------------------|---------|-----------|---------|--------------------|
| | | Happy | Unhappy | Percentage Correct |
| Happiness | Happy | 60 | 11 | 84,5 |
| | Unhappy | 13 | 56 | 81,2 |
| Overall Percentage | | | | 82,85 |

The results of the LR of the variables affecting the dependent variable are examined. The coefficients of the independent variables: population, labor force, life expectancy at birth, school enrollment, GDP per capita, poverty headcount ratio at national poverty lines are -0.0001, 0.0001, 0.2526, 0.0109, 0.0001, 0.0176, respectively. According to these coefficients (p values): population, labore force, school enrollment, GDP, poverty are determined as important factors, while life expectancy ($p=0.2526>0.05$) are determined as unimportant factor. The odds ratios of the independent

COMPARISON OF ARTIFICIAL NEURAL NETWORK AND LOGISTIC REGRESSION METHODS IN CLASSIFYING THE HAPPINESS STATUS OF COUNTRIES

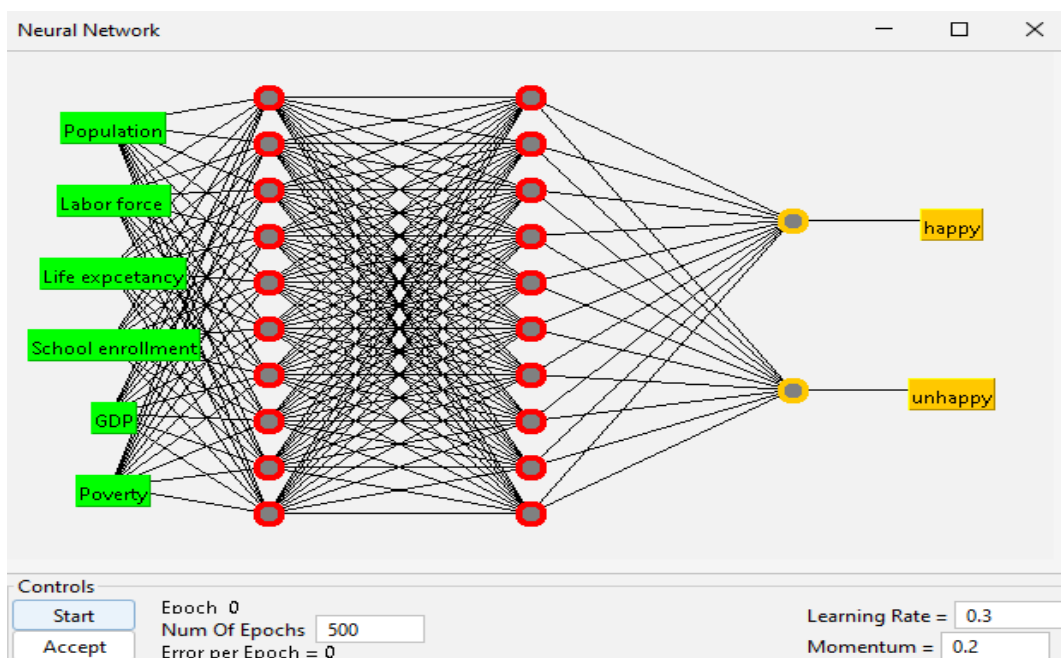
variables: population, labore force, life expectancy, school enrollment, GDP, poverty are 0.9999, 1.0001, 1.2873, 1.011, 1.0001, 1.178, respectively. The labor force, school enrollment, GDP, poverty have a positive, statistically significant effect on happiness. A one-point increase in the labor force component increases the happiness level of countries by about 1.0001 times. A one-point increase in the school enrollment component increases the happiness level of countries by about 1.011 times. A one-point increase in GDP component increases the happiness level of countries by about 1.0001 times. A one-point increase in the poverty component increases the happiness level of countries by about 1.0178 times.

2.2. Artificial Neural Networks Results

In the study, it is aimed to predict the happiness status of the countries. While estimating the state of happiness (happy, unhappy), artificial neural network method is used with the help of Weka software. Since the network has better learning ability in the presence of more than one layer in the artificial neural network structure to be used in the prediction analysis, the multi-layered network structure is determined as the network structure and the generated network structure is shown in Figure 3. As seen in Figure 3; The artificial neural network has an input parameter and an output parameter. In other words, the happiness status (output parameter) of the countries was estimated based on the population, labor force, life expectancy at birth, school enrollmen, GDP per capita, poverty headcount ratio at national poverty lines of the countries (input parameters).

As a result of the evaluation of the results of different parameter values, the use of the model using 2 hidden layer and 10 neurons is applied in the study. The classification models' performance for prediction was evaluated using cross-validation. It was also employed in previous studies (Hall et al., 2009; Wahbeh et al.,2011) since it evaluates how well a model works with new or test data. Cross validation is crucial, because a model is often fitted exclusively to the training dataset. Cross-validation enables the model's prediction accuracy to be seen when there is new data. The classification models in this study were evaluated using WEKA's 10-fold cross validation feature.

Figure 3. Artificial Neural Network Structure for the Prediction of Happiness Status of Countries



ANN classification values are presented in Table 5. In this table, the number of countries correctly identified as happy (True positive-TP) is 59, the number of countries incorrectly as happy (False positive- FP) is 14, the number of countries correctly identified as unhappy (True negative-TN) is 55, the number of countries incorrectly identified as happy (False negative-FN) is 12. The calculated correct assignment rate must be greater than 50% to conduct the analysis. According to the results presented, countries defined as happy as a result of ANN are classified as correct at a rate of 83.1%, while countries defined as unhappy are classified correctly at a rate of 79.7%. The overall accuracy rate is also found to be 81.4%. As a result, it can be said that the classification effectiveness of the model is quite good.

Table 5. *The Results ANN Classification*

| | | Predicted | | |
|--------------------|---------|-----------|---------|--------------------|
| | | Happy | Unhappy | Percentage Correct |
| Happiness | Happy | 59 | 12 | 83,1 |
| | Unhappy | 14 | 55 | 79,7 |
| Overall Percentage | | | | 81,4 |


2.3. Performance Evaluation

To evaluate the performance of LR and ANN, different evaluation metrics are taken into account. An indicator of the model's performance across all classes is accuracy. It is measured as the proportion of correctly predicted events to all predicted events. The accuracy is calculated as the ratio of Positive samples that are correctly classified to all samples that are classified as Positive (either correctly or incorrectly). The precision assesses how well the model categorizes a sample as positive. The recall is determined as the proportion of Positive samples that are correctly identified as Positive to all Positive samples. The recall evaluates how well the model can identify Positive samples. The weighted harmonic mean of recall and precision is the F-measure. ROC area is the area under the curve of a plot that presents the True Positive Rate against the False Positive rate and measures the overall performance of the model. Table 6 and Figure 4 present the result of the evaluation metrics of LR and ANN. The given chart shows that LR gives better results for all evaluation metrics and has better accuracy for this dataset.

Table 6. *The Performance Evaluation of LR and ANN*

| Method/Measurement | LR | ANN |
|--------------------|-------|------|
| Accuracy | 82.85 | 81,4 |
| Precision | 82.9 | 81.4 |
| Recall | 82.9 | 81.4 |
| F-measure | 82.9 | 81,4 |
| ROC Area | 90.9 | 87.3 |

Figure 4. Accuracy Chart



Additional evaluation metrics are considered to compare the performance of the presented approaches. The consolidation between two sets of categorized data is measured by the kappa statistic (Melville et al., 2005). Kappa values range from zero to one. The stronger the agglomeration, the higher the value of the Kappa statistic. There is perfect agreement if Kappa = 1. There is no agreement when Kappa is equal to 0. If Kappa statics values vary between 0.40 and 0.59, they are regarded as moderate, 0.60 to 0.79, as substantial, and above 0.80, as extraordinary (Landis and Koch, 1977). The mean absolute error (MAE) is calculated by dividing the total absolute error by the number of estimates. It is a measurement of how closely a predicted model matches a given collection of actual values. The square root of the sum of squared errors divided by the number of estimates is the root mean square error (RMSE). The disparities between values assumed by a model and the values actually observed are measured. Better accuracy of the model is shown by a low RMSE value. So, the more accurate and precise the estimate, the lower the RMSE and MAE. The variation in errors in a group of forecasts can be identified by combining the MAE and the RMSE. The variation in the individual errors in the sample will always be bigger than the MAE or greater than the RMSE, depending on how much of a difference there is between the two. All errors have the same magnitude if the value of RMSE is equal to the value of MAE. When comparing a mean error (also known as a residual) to errors generated by a simple model, the relative absolute error (RAE) is expressed as a ratio. A ratio of less than one is the outcome of an acceptable model, or one that generates results that are better to those of a simple model. A ratio that is nearly zero will be generated by an accurate forecasting model; A poor model (one that performs worse than the simplistic model) will result in a ratio higher than 1. The square root of the squared errors of a predictive model normalized by the squared errors of a simple model is known as the Root Relative Squared Error (RRSE). The model outperforms the simple model when the RRSE is less than one. Therefore, the model is better the lower the RRSE.

Figure 3 show the obtained results by using LR. Figure 4 presents the results of ANN. These results state that the performance of LR better than the performance of ANN. There are a number of evidence that utilize LR is superior to ANN. Firstly, the kappa statistic offers a substantial boost in

predictions, and LR is of greater value than ANN. Secondly, a prediction is more accurate if the RMSE and MAE values are as low as possible. When compared to the ANN approach, the RMSE and MAE values for LR are the lowest. Third reason is the the value of RAE and RRSE. LR has higher RAE. LR outperforms ANN has lower RRSE.

Figure 3. *The Obtained Results by Using Logistic Regression*

```

=== Summary ===
Correctly Classified Instances      116      82.8571 %
Kappa statistic                    0.6569
Mean absolute error                0.2292
Root mean squared error            0.345
Relative absolute error            45.8431 %
Root relative squared error        68.9899 %
Total Number of Instances         140

```

Figure 4. *The Obtained Results by Using Artificial Neural Networks*

```

=== Summary ===
Correctly Classified Instances      114      81.4286 %
Kappa statistic                    0.6283
Mean absolute error                0.2272
Root mean squared error            0.3606
Relative absolute error            45.4449 %
Root relative squared error        72.1061 %
Total Number of Instances         140

```

3. Results

In recent years, there has been a general tendency to study the concept of happiness as an indicator of economic development. There has been an increase in the studies carried out on this subject, that happiness is the goal that is desired to be achieved socially rather than an individual goal. The status of happiness of countries is examined by survey studies and by considering different development factors as well as economic status indicators. Within the scope of this study, the classification of the happiness status of the countries is discussed by using LR and ANN. The happiness status of countries is determined by using the variables: population, labor force, life expectancy at birth, school enrollment, GDP per capita, poverty headcount ratio at national poverty lines. The world happiness index values is used to determine the happiness status of countries. Since the dependent variable in the model has 2 categories (happy, unhappy), the results of the multiple classification method were examined to determine the relationship between the independent variables. Within the scope of this study, current happiness values were first adapted to the analysis. The missing data in the data set was cleaned and made suitable for the .arff file format. The results obtained were divided into two categories, happy and unhappy countries. The cleaned data set was estimated using LR, and ANNs, which is the estimation tool of WEKA software. Statistical analyzes was performed with SPSS statistic software package.

The results show that population, labor force, school enrollment, GDP per capita, poverty headcount ratio at national poverty lines have a positive, statistically significant effect on happiness status. Different evaluation metrics are used to compare the performances of the classification methods.

COMPARISON OF ARTIFICIAL NEURAL NETWORK AND LOGISTIC REGRESSION METHODS IN CLASSIFYING THE
HAPPINESS STATUS OF COUNTRIES

These are as follows: Accuracy, precision, recall, F-measure, ROC Area, Kappa statistic, mean absolute error, root mean squared error, relative absolute error, root relative square error. The comparative analysis revealed that LR offers better results. It is concluded that the LR is more appropriate than ANN for determining the happiness situations of countries using given variables. The study is expected to assist decision-makers by offering data assistance during the process of making strategic decisions and by identifying the indications that countries should take into account while attempting to improve their position.

Author Contributions (Yazar Katkı Oranı): Fatma Selen MADENOĞLU (%100)

Ethical Responsibilities of Authors (Yazarın Etik Sorumlulukları): This study was prepared in accordance with the rules of the required ethical approval

Conflicts of Interest (Çıkar Çatışması): There is no conflict of interest with any institution related to the study.

Plagiarism Checking (İntihal Denetimi): This study has been checked for plagiarism using a plagiarism scanning programme.

REFERENCES

- Agresti, A. (1996). *An Introduction To Categorical Data Analysis* (Vol. 1350), New York: Wiley.
- Agresti, A. (2002), *Categorical Data Analysis*, Second Edition, John Wiley and Sons Inc., New Jersey.
- Alpar , R. (2013). *Çok Değişkenli İstatistiksel Yöntemler* (4. Baskı), Detay Yayıncılık, Ankara.
- Alpar, R. & Karabulut, E. (2017). *Uygulamalı Çok Değişkenli İstatistiksel Yöntemler*. 5.Baskı, Detay Yayıncılık, Ankara.
- Ataman, F., Kaynak, T., & Yüncü, S. Analysing of Solutions Containing Artificial Intelligence Through System Modeling on Computer. In *Electrical, Electronic and Computer Engineering 8th National Congress* (pp. 677).
- Bailly, A., Blanc, C., Francis, É., Guillotin, T., Jamal, F., Wakim, B., & Roy, P. (2022). Effects of dataset size and interactions on the prediction performance of logistic regression and deep learning models. *Computer Methods and Programs in Biomedicine*, 213, 106504.
- Bağış, A. ve Konar, M. (2010) “Uçuş Kontrol Sistemi Yakıt Parametresinin Yapay Sinir Ağları Kullanılarak Belirlenmesi”, *Akıllı Sistemlerde Yenilikler Ve Uygulamaları Sempozyumu*, 21-24 Haziran 2010, Kayseri&Kapadokya, Türkiye.
- Bayram, S., Kaplan, K., Kuncan, M., & Ertunç, H. M. (2013, September). Ball bearings space of time statistical feature extraction and neural networks with error estimation method size. In *Automatic Control National Meeting, TOK2013, Malatya* (Vol. 26, pp. 28).
- Berenson, M. L. ve Levine, D. M. (1996), *Basic Business Statistics: Concepts and Applications*, Sixth Edition, Prentice-Hall International, New Jersey.
- Bhosale, B. (2016). Curvelet Interaction with Artificial Neural Networks. *Artificial Neural Network Modelling*, 109-125.
- Budak, H. & Erpolat, S., (2012). “Kredi Riski Tahmininde Yapay Sinir Ağları ve Lojistik Regresyon Analizi Karşılaştırması”. *Online Academic Journal of Information Technology*, 3(9), 23-30.
- Chaipornkaew, P., & Prexawanprasut, T. (2019, October). A prediction model for human happiness using machine learning techniques. In *2019 5th International Conference on Science in Information Technology (ICSITech)* (pp. 33-37). IEEE.
- Chehreh, C S, James, C H, Jorjani, E, Mesroghli, S & Bagherieh, A H, (2008). “Prediction of Coal Grindability Based on Petrography, Proximate and Ultimate Analysis Using Multiple Regression And Artificial Neural Network Models”. *Fuel Processing Technology*, 89,13- 20.
- Çalışkan, M. M. T. & Deniz, D. (2015) “Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları ve Yönlerinin Tahmini”, *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 31, 177-194.
- Demir, Y., Tuntaş, R., & Köksal, M. (1998). Analysis of Switched Circuit with Neural Networks. In *Electrical and Computer Engineering 8th National Congress* (pp. 673).
- Dogan, H., & Atik, K. (2004). Providing Persistence in Comfort Conditions by the Application of Artificial Neural Networks to Air-Conditioning Systems. *Technology*, 7(2).
- Farooq, S. A., & Shanmugam, S. K. (2022). A Performance Analysis of Supervised Machine Learning Techniques for COVID-19 and Happiness Report Dataset. In *Sentimental Analysis and Deep Learning: Proceedings of ICSADL 2021* (pp. 591-601). Springer Singapore.
- Finlay, S. (2014). *Predictive analytics, data mining and big data: myths, misconceptions and methods*. Basingstoke: Palgrave Macmillan., pp. 6 – 9.
- Frey, B. S. & Stutzer, A. (2002). “What Can Economists Learn From Happiness Research?”. *Journal of Economic Literature*, 40(2), 402-435.

COMPARISON OF ARTIFICIAL NEURAL NETWORK AND LOGISTIC REGRESSION METHODS IN CLASSIFYING THE HAPPINESS STATUS OF COUNTRIES

- Gamache, K., Giardino, J. R., Zhao, P. & Owens, R. H., (2018). Bivouacs of the Anthropocene: Urbanization, Landforms, and Hazards in Mountainous Regions. *Urban Geomorphology: Landforms and Processes in Cities*. London: Elsevier, 205-230.
- Greene, W. H., (2012). *Econometric Analysis*. USA: Pearson Education Inc. ISBN: 0-13-066189-9.
- Gujarati, D. N. (2010). *Temel ekonometri*. (Çev. Ü. Şenesen ve G.G. Şenesen), Literatür Yayıncılık, İstanbul.
- Güneş, B., İsmail, T. A. Ş., & Sedat, A. C. A. R. (2020). "Türkiye'de İllerin Mutluluğu". *Ankara Üniversitesi SBF Dergisi*, 75(2), 747-774.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H. (2009). "The WEKA Data Mining Software: An Update". *ACM SIGKDD Explorations Newsletter*, 11(1), 10-18.
- Haykin, S., *Neural Networks: A Comprehensive Foundation*, Perenctice Hall, New Jersey, 1999.
- Hill, R. C., Griffiths, W. E. & Lim, G. C., (2011). *Principles Of Econometrics*. Usa: Wiley. ISBN: 978-0-470-62673-3
- Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression (Vol. 398)*. John Wiley & Sons.
- Ivan Nunes da Silva, Danilo Hernane Spatti, Rogerio Andrade Flauzino, Luisa Helena Bartocci Liboni, Silas Franco dos Reis Alves,(2016), *Artificial Neural Networks: A Practical Course*, Springer, New York.
- Jannani, A., Sael, N., & Benabbou, F. (2021, December). Predicting Quality of Life using Machine Learning: case of World Happiness Index. In *2021 4th International Symposium on Advanced Electrical and Communication Technologies (ISAECT)* (pp. 1-6). IEEE.
- Kaftan, İ., 2010. Batı Türkiye Gravite ve Deprem Katalog Verilerinin Yapay Sinir Ağları ile Değerlendirilmesi. Doktora Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Kalogirou, S. A., & Bojic, M. (2000). "Artificial Neural Networks for the Prediction of the Energy Consumption Of A Passive Solar Building". *Energy*, 25(5), 479-491.
- Kandemir, O., & Kürkcü, M . (2016). "Bir Refah Göstergesi Olan "Yaşam Endeksi" Bağlamında TR82 (Kastamonu, Çankırı, Sinop) Bölgesinin Analizi". *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(4) , 22-35.
- Kandemir, O. (2021). "Dünya Ülkelerinde Sosyal Eşitsizliklerin Mutluluk Düzeyine Etkisi: Lojistik Regresyon Analizi". *Uluslararası Avrasya Sosyal Bilimler Dergisi*, 12(45), 612-625.
- Karahan, M. (2011). İstatistiksel tahmin yöntemleri: yapay sinir ağları metodu ile ürün talep tahmini uygulaması. Yayınlanmamış Doktora Tezi. Konya: Selçuk Ü. Sosyal Bilimler Enstitüsü.
- Kasiviswanathan, K. S., Sudheer, K. P., & He, J. (2016). "Quantification Of Prediction Uncertainty İn Artificial Neural Network Models". *Artificial Neural Network Modelling*, 145-159.
- Kennedy, P., 2008. *A Guide to Econometrics*. (2008): Blackwell Publishing. ISBN: 978-1405182577.
- Khder, M. A., Sayfi, M. A., & Fujo, S. W. (2022). Analysis of World Happiness Report Dataset Using Machine Learning Approaches. *International Journal of Advances in Soft Computing & Its Applications*, 14(1), 14-34.
- Kumar, H. & Giri, S., (2019). "A Flow Shop Scheduling Algorithm Based On Artificial Neural Network". *Bulletin of Pure and Applied Sciences*, 38(E)(1), 62-71.
- Landis, J. R., & Koch, G. G. (1977). "The Measurement of Observer Agreement for Categorical Data". *biometrics*, 159-174.
- Leech, N. L., Barrett, K. C. & Morgan, G. A. (2004), *Spss For Intermediate Statistics: Use and Interpretation*, Second Edition, Lawrance Erlbaum Associates Publishers, Manwah New Jersey, London.
- Lin, Y. L., & Horng, S. C. (2023, May). Data analysis and prediction on world happiness score 2020. In *AIP Conference Proceedings* (Vol. 2685, No. 1). AIP Publishing.

- McNelis, P. D. (2005). *Neural Networks in Finance: Gaining Predictive Edge in the Market*. Elsevier, Amsterdam.
- Melville, P., Yang, S. M., Saar-Tsechansky, M., & Mooney, R. (2005). Active learning for probability estimation using Jensen-Shannon divergence. In *Machine Learning: ECML 2005: 16th European Conference on Machine Learning, Porto, Portugal, October 3-7, 2005. Proceedings 16* (pp. 268-279). Springer Berlin Heidelberg.
- Özdemir, V. E. Y. S. E. L. (2011). Determination of Turkey's Carbonization Index Based On Basic Energy Indicators By Artificial Neural Networks. *Journal of The Faculty of Engineering and Architecture of Gazi University*, 26(1), 9-15.
- Rojas, R. (1993). *Theorie der Neuronalen Netze*, Springer, Berlin.
- Sahin, İ. (2014). "Prediction Of Surface Roughness Of Al/Sic Composite Material With Artificial Neural Networks Yapay Sinir Ağları İle Al/Sic Kompozit Malzemenin Yüzey Pürüzlülüğünün Tahmini". *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29(1), 209-216.
- Sağiroğlu, Ş.; Beşdok E. & Erler, M., *Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları*. Kayseri: Ufuk Kitap KirtasiyeYayıncılık, 2003.
- Saputri, T. R. D., & Lee, S. W. (2015). "A Study of Cross-National Differences in Happiness Factors Using Machine Learning Approach". *International Journal of Software Engineering and Knowledge Engineering*, 25(09n10), 1699-1702.
- Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding Machine Learning: From Theory To Algorithms*. Cambridge University Press.
- Siegel, E. (2016). *Predictive Analytics: The Power to Predict Who Will Click, Buy, Lie, or Die*. Hoboken, NJ: Wiley., pp.1-16.
- Sperandei, S. (2014). Understanding logistic regression analysis. *Biochemia medica*, 24(1), 12-18.
- Şahan, M. & Okur, Y., (2016). Akdeniz Bölgesine Ait Meteorolojik Veriler Kullanılarak Yapay Sinir Ağları Yardımıyla Güneş Enerjisinin Tahmini. *SDU Journal of Science (E-Journal)*, 11(1), 61- 71.
- Şencan, A. & Çiçek Bezir, N., 2003. Ölçülebilir Meteorolojik Verilerle Güneş Radyasyonunun Yapay Sinir Ağları Metoduyla Tayini. *TMMOB Makine Mühendisleri Odası Güneş Enerjisi Sistemleri Sempozyumu ve Sergisi*, 20-21 Haziran 2003, Mersin, pp. 235-239.
- Tabachnick, B. G. & Fidell, L. S. (1996). *Using multivariate statistics*. New York, USA: Harper Collins College Publishers.
- Toraman, C. & C. Karaca (2016), "Kimya Endüstrisinde Faaliyet Gösteren Firmalar Üzerinde Mali Başarısızlık Tahmini: Borsa İstanbul'da Bir Uygulama". *Muhasebe ve Finansman Dergisi*, 111-127.
- Umar İ. K. & Bashir S. (2019). "Investigation of the Factors Contributing to Truck Driver's Involvement in an Injuty Accident". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*. 26(3), 402 – 408.
- Van Praag, B. M. (2007). "Perspectives from the Happiness Literature and the Role of New Instruments for Policy Analysis". *CESifo Economic Studies*, 53(1), 42-68.
- Wahbeh, A. H., Al-Radaideh, Q. A., Al-Kabi, M. N., & Al-Shawakfa, E. M. (2011). "A Comparison Study between Data Mining Tools Over Some Classification Methods". *International Journal of Advanced Computer Science and Applications*, 8(2), 18-26.
- Yakubu, A., Dahloun, L., Shoyomb, A. & Yahaya, U., (2019). "Modelling Hatchability and Mortality in Muscovy Ducks Using Automatic Linear Modelling and Artificial Neural Network". *Journal of the Indonesian Tropical Animal Agriculture*, 44(1), 65-76.
- Yang, J., Ma, J., & Howard, S. K. (2016). "A Structure Optimization Algorithm of Neural Networks for Pattern Learning from Educational Data". *Artificial Neural Network Modelling*, 67-82.

COMPARISON OF ARTIFICIAL NEURAL NETWORK AND LOGISTIC REGRESSION METHODS IN CLASSIFYING THE HAPPINESS STATUS OF COUNTRIES

- You, L. (2021, March). Utilizing machine learning to predict happiness index. In *2021 2nd International Conference on E-Commerce and Internet Technology (ECIT)* (pp. 233-238). IEEE.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). "Forecasting with Artificial Neural Networks: The State of the Art". *International Journal of Forecasting*, 14(1), 35-62.
- Saputri, T. R. D., & Lee, S. W. (2015). "A Study of Cross-National Differences in Happiness Factors Using Machine Learning Approach". *International Journal of Software Engineering and Knowledge Engineering*, 25(09n10), 1699-1702.
- Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding Machine Learning: From Theory To Algorithms*. Cambridge University Press.
- Siegel, E. (2016). *Predictive Analytics: The Power to Predict Who Will Click, Buy, Lie, or Die*. Hoboken, NJ: Wiley., pp.1-16.
- Sperandei, S. (2014). Understanding logistic regression analysis. *Biochemia medica*, 24(1), 12-18.
- Şahan, M. & Okur, Y., (2016). Akdeniz Bölgesine Ait Meteorolojik Veriler Kullanılarak Yapay Sinir Ağları Yardımıyla Güneş Enerjisinin Tahmini. *SDU Journal of Science (E-Journal)*, 11(1), 61- 71.
- Şencan, A. & Çiçek Bezir, N., 2003. Ölçülebilir Meteorolojik Verilerle Güneş Radyasyonunun Yapay Sinir Ağları Metoduyla Tayini. *TMMOB Makine Mühendisleri Odası Güneş Enerjisi Sistemleri Sempozyumu ve Sergisi*, 20-21 Haziran 2003, Mersin, s. 235-239.
- Tabachnick, B. G. & Fidell, L. S. (1996). *Using multivariate statistics*. New York, USA: Harper Collins College Publishers.
- Toraman, C. & C. Karaca (2016), "Kimya Endüstrisinde Faaliyet Gösteren Firmalar Üzerinde Mali Başarısızlık Tahmini: Borsa İstanbul'da Bir Uygulama". *Muhasebe ve Finansman Dergisi*, 111-127.
- Umar İ. K. & Bashir S. (2019). "Investigation of the Factors Contributing to Truck Driver's Involvement in an Injuty Accident". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*. 26(3), 402 – 408.
- Van Praag, B. M. (2007). "Perspectives from the Happiness Literature and the Role of New Instruments for Policy Analysis". *CESifo Economic Studies*, 53(1), 42-68.
- Wahbeh, A. H., Al-Radaideh, Q. A., Al-Kabi, M. N., & Al-Shawakfa, E. M. (2011). "A Comparison Study between Data Mining Tools Over Some Classification Methods". *International Journal of Advanced Computer Science and Applications*, 8(2), 18-26.
- Yakubu, A., Dahloun, L., Shoyomb, A. & Yahaya, U., (2019). "Modelling Hatchability and Mortality in Muscovy Ducks Using Automatic Linear Modelling and Artificial Neural Network". *Journal of the Indonesian Tropical Animal Agriculture*, 44(1), 65-76.
- Yang, J., Ma, J., & Howard, S. K. (2016). "A Structure Optimization Algorithm of Neural Networks for Pattern Learning from Educational Data". *Artificial Neural Network Modelling*, 67-82.
- You, L. (2021, March). Utilizing machine learning to predict happiness index. In *2021 2nd International Conference on E-Commerce and Internet Technology (ECIT)* (pp. 233-238). IEEE.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). "Forecasting with Artificial Neural Networks: The State of the Art". *International Journal of Forecasting*, 14(1), 35-62.

AIZANOI FINANCE REVIEW

ISSUE: 2 / 2023

www.aizanoifr.com

info@aizanoifr.com

G-7 ÜLKELERİNDE EĞİTİM HARCAMALARI-İKTİSADİ BÜYÜME İLİŞKİSİ: FOURIER SHİN EŞBÜTÜNLEŞME TESTİ

THE EDUCATION EXPENDITURE-ECONOMIC GROWTH RELATIONSHIP IN G-7 COUNTRIES: FOURIER SHİN COINTEGRATION TEST

Fatih Volkan AYYILDIZ*,

*Öğr.Gör.Dr., Ardahan Üniversitesi, İktisat Bölümü, fatihvolkanayyildiz@ardahan.edu.tr, ORCID: 0000-0001-5991-3574

| MAKALE BİLGİSİ | ÖZ |
|--|---|
| Gönderilme Tarihi 10.09.2023 Revizyon Tarihi 28.09.2023 Kabul Tarihi 14.10.2023 Makale Kategorisi Araştırma Makalesi JEL Kodları E60 F43 C82 | <p>Eğitim harcamaları beşerî sermaye bileşenleri içinde önemli bir yere sahiptir. Özellikle içsel büyüme teoremleri ile ön plana çıkan beşerî sermaye kavramı içinde yer alan eğitim faktörünün de büyüme olumlu katkı sağladığını belirtilmiştir. Bu çalışmanın amacı G-7 ülkelerinde 1990-2021 döneminde eğitim harcamaları ve büyüme değişkenleri arasındaki ilişkiyi analiz etmektir. Amaç doğrultusunda Fourier fonksiyonlara dayalı Fourier ADF birim kök testleri ve Fourier Shin eşbütünleşme testleri gerçekleştirilmiştir. Araştırmanın sonucunda G-7 ülkelerinin genelinde eğitim harcamaları ve büyüme değişkenleri arasında eşbütünleşme ilişkisi çıkmıştır. Çıkan sonuçlar içsel büyüme teoremleri ile genel olarak uyum göstermektedir. Dolayısıyla karar birimlerinin merkezi bütçeden eğitime ayırdıkları payı daha fazla artırımlarının büyümeye katkı sağlayacağı ifade edilebilir.</p> <p>Anahtar Kelimeler: Eğitim Harcamaları, İktisadi Büyüme, Beşerî Sermaye, Fourier ADF Birim Kök Testi, Fourier Shin Eşbütünleşme Testi</p> |

| ARTICLE INFO | ABSTRACT |
|---|--|
| Received 10.09.2023 Revized 28.09.2023 Accepted 14.10.2023 Article Classification: Research Article JEL Codes E60 F43 C82 | <p>Education expenditures have an important place among human capital components. It has been stated that the education factor, which is included in the concept of human capital, which comes to the fore with endogenous growth theorems, also contributes positively to growth. The aim of this study is to analyze the relationship between education expenditures and growth variables in the G-7 countries in the 1990-2021 period. For this purpose, Fourier ADF unit root tests and Fourier Shin cointegration tests based on Fourier functions were performed. As a result of the research, a cointegration relationship emerged between education expenditures and growth variables across G-7 countries. The results are generally compatible with endogenous growth theorems. Therefore, it can be stated that increasing the share allocated to education from the central budget by decision-making units will contribute to growth.</p> <p>Keywords: Education Expenditures, Economic Growth, Human Capital, Fourier ADF Unit Root Test, Fourier Shin Cointegration Test</p> |

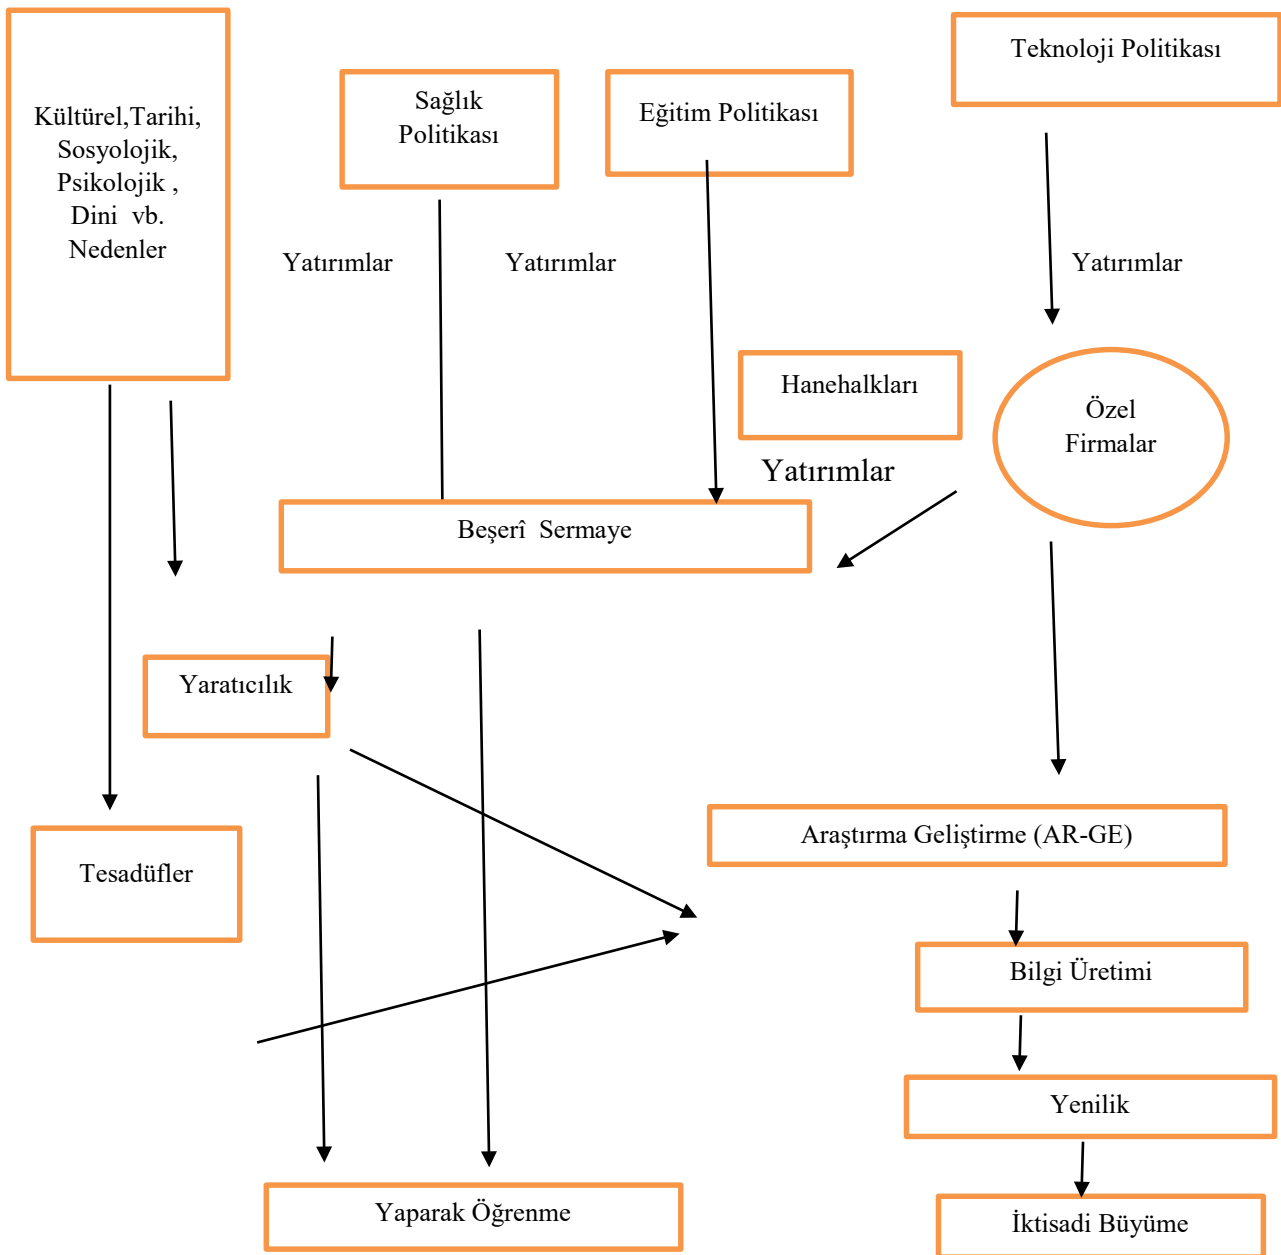
Atif (Citation): Ayyıldız, F. V. (2023). "G-7 Ülkelerinde Eğitim Harcamaları-İktisadi Büyüme İlişkisi: Fourier Shin Eşbütünleşme Testi", *Aizanoi Finance Review*, (2): 49-57



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

Giriş

Eğitim harcamaları-büyüme arasındaki ilişki iktisat biliminin ilgi çekici konularından biridir. Eğitim harcamalarının beşerî sermayenin ana ögesi olması nedeniyle öncelikle beşerî sermaye kavramını incelemek gerekmektedir. Beşerî sermaye (Erkan,1998:27) bireyin bilgi ve yeteneklerinin bileşimi şeklinde ifade edilebilir. A.Smith'e kadar götürebilecek olan eğitim-büyüme ilişkisini inceleyen çalışmalar esasen insana yapılan yatırımın bir ülkenin büyüme ve kalkınmasını temelini oluşturması nedeniyle önem arz etmektedir. Eğitim harcamaları ilk aşamada maliyet kalemi olarak ifade edilmesine karşın uzun dönemde kalkınma carilerinin içerisinde yer almaktadır. Bu kapsamda Endüstri Devrimi'ni gerçekleştirmiş İngiltere'nin 19.yüzyılın ikinci yarısından beri uygulamış olduğu zorunlu ilköğretim uygulaması ve eğitim faaliyetlerine yönelik bu harcamaların kamu tarafından finanse edilmesinin sağlanması politikaları eğitimin büyüme ve kalkınma için önemini gösteren tarihsel bir gelişmedir (Parasız,2003:47)



Şekil 1. İçsel Büyüme Modellerinin Temel Belirleyicileri (Kibritçioğlu,1998:217)

Şekil 1’de içsel büyümenin temel belirleyicilerine yer verilmiştir. İçsel büyüme modelleri çerçevesinde büyümenin temel unsurlarının eğitim, sağlık ve teknoloji politikalarıdır. Kültürel, tarihi, sosyolojik, psikolojik vb. unsurlar ise dolaylı olarak iktisadi büyümeye etki etmektedir. Ülkeye has dolaylı faktörler ise tesadüfler ve yaratıcılık unsurları vasıtasıyla AR-GE harcamalarının artmasına neden olmaktadır. Hem temel unsurlar hem de dolaylı unsurlar AR-GE faaliyetlerinin artmasına yola açarak iktisadi büyümeye neden olmaktadır. Ülkeye has dolaylı faktörler ise tesadüfler ve yaratıcılık unsurlarıyla AR-GE harcamalarının artmasına neden olmaktadır (Berber,2006:174)

İçsel büyüme modellerinde beşerî sermayenin önemi Lucas(1988)’un modellemesiyle ön plana çıkmıştır. Lucas’ın beşerî sermaye modeli özetleyecek bir denklem biçiminde aşağıda ifade edilmiştir. Denklem 1’de beşerî sermayenin dışsallık etkisinin yer aldığı ortalama beşerî sermaye düzeyi h_a ve teknoloji seviyesi A sabiti ile ifade edilmiştir. γ simgesi ise beşerî sermayenin dışsallık etkisini göstermektedir.

$$Y = F(A, K, N, h) = AK^\beta (uhN)^{1-\beta} h_a^\gamma \quad (1)$$

$$h(t) = h(t)\delta[1 - u(t)] \quad \delta > 0 \quad (2)$$

Çalışılan süre u , işçilerin ortalama yetenek düzeyi h , $1 - u$ ise çalışmadan kalan zamanla okullaşmaya bağlı sermaye birikimini ifade etmektedir. $u(t) = 1$ durumunda işçilerin bütün vakitlerini üretime harcamalarından ötürü kendi yeteneklerini geliştirmeye zaman ayırmamaları sonucu beşerî sermaye birikimi sıfırken, $u(t) = 0$ durumunda ise işçilerin üretime vakit ayırmayıp, bütün vakitlerini yetenekleri geliştirmek için kullandıklarını dolayısıyla beşerî sermaye birikiminin bu istisnai durumda ise maksimum olduğu ifade edilir. Modellemeye $u(t)$ değeri sıfıra yaklaştıkça beşerî sermaye artacaktır veya vice versa (Üzümcü,2018:266)

Eğitimin, beşerî sermayenin en önemli unsuru olarak kabul edilmesinin altında bireylerin işgücü kabiliyetinin ve verimliliğinin artmasına yol açmasıdır (Herndon, 2008; Langelett, 2000; Lau vd., 1991). Eğitim yoluyla içselleştirme süreci arz ve talep yönlü yaklaşımlarla ifade edilebilir. Bireylerin rasyonel hareket ettiği varsayımı altında eğitim düzeyi ne kadar yüksekse mal talebinde hata yapma olasılığı daha düşüktür. Arz yönlü içselleştirme süreci ise eğitim düzeyi görece yüksek olan bireylerin bu bilgi birikimlerini gelecek nesillere aktarmaları, daha fazla sosyal faaliyette bulunmaları ve etkileşimde buldukları çevrenin iyileşmesine katkı sunmaları biçiminde ifade edilebilir (Demir, Üzümcü ve Duran,2006: 28).

Çalışmada şu şekilde bir planlama yapılmıştır. Öncelikle çalışmanın giriş kısmında beşerî sermaye kavramı, beşerî sermaye içinde eğitimin önemi, içsel büyümenin temel belirleyicileri ve eğitim-büyüme ilişkine ait teorik bir bakış sunulmuştur. Bu aşamadan sonra konuyla ilgili literatür çalışmalarına, ekonometrik analiz ve sonuç kısmına yer verilecektir.

1. Literatür Taraması

Çalışmanın bu kısmında konuyla ilgili ulusal ve uluslararası yazında yer alan çalışmalar kronolojik biçimde tasnif edilmiştir.

Tablo 1: Literatür Çalışmaları

| Yazar(lar) Yılı | Ülke/Ülke Grubu | Dönem | Yöntem(ler) | Sonuç |
|--------------------------|-----------------|-----------|---|--|
| Varsak ve Bakırtaş(2006) | Türkiye | 1970-2008 | Vektör hata düzeltme modeli, varyans ayrıştırma analizi | Eğitim harcamalarından büyüme doğru tek yönlü nedensellik ilişkisi vardır. |

G-7 ÜLKELERİNDE EĞİTİM HARCAMALARI-İKTİSADI BÜYÜME İLİŞKİSİ: FOURIER SHİN EŞBÜTÜNLEŞME TESTİ

| | | | | |
|------------------------|---|---------------|--|--|
| Aka ve Dumont(2008) | ABD | 1929-1997 | Hata düzeltme modeli | Eğitim harcamalarından büyümeye doğru tek yönlü nedensellik vardır. |
| Cooray(2009) | 46 düşük ve orta gelirli ülke | 1999-2005 | Panel GMM | Okullaşma oranı iktisadi büyüme için önemlidir. Hükümet harcamaları eğitim kalitesini artırarak ekonomide büyümeye neden olur. |
| Atherton vd.(2013) | 42 ülke | 1960-2004 | Panel veri analizi | Eğitim kalitesi iktisadi büyümeyi artırmaktadır |
| Eggoh vd. (2015) | 49 Afrika ülkesi | 1996-2010 | Panel GMM | Eğitim ve sağlık harcamaları iktisadi büyümeyi olumsuz etkilemektedir. |
| Lingaraj vd. (2016) | 14 Asya ülkesi | 1973-2012 | Panel FMOLS | Eğitim harcamaları iktisadi büyümeyi artırmaktadır. |
| Hanif ve Arshed (2016) | Güney Asya Bölgesel İşbirliği Teşkilatı'na üye 5 ülke | 1960-2013 | Panel FMOLS | İlköğretim harcamaları iktisadi büyümeyi olumsuz etkilemesine rağmen ortaokul ve yükseköğretim harcamaları iktisadi büyümeyi olumlu etkilemektedir. |
| Akıncı(2017) | Türkiye | 2006Q1-2017Q2 | ARDL testi | Eğitim harcamaları büyümeyi hem kısa dönemde hem uzun dönemde artırmaktadır. Uzun dönemde eğitim harcamalarının büyüme üzerindeki etkisi kısa dönemden daha fazladır. |
| Goumrhar (2017) | 65 gelişmekte olan ülke | 1985-2010 | Statik panel veri analizi | Okullaşma oranının iktisadi büyüme üzerinde pozitif ve anlamlı bir etkisi varken; eğitimde eşitsizlik unsurunu iktisadi büyümeyi olumsuz etkilediğini sonuçlarına ulaşılmıştır |
| Köse vd.(2022) | OECD ülkeleri | 1984-2018 | Panel regresyon analizi | Eğitim harcamaları iktisadi büyümeyi artırmaktadır |
| Yıldız(2023) | Türkiye | 2006Q1-2022Q4 | ARDL, FMOLS ve DOLS tahminleri | Kamu eğitim harcamaları ve iktisadi büyüme değişkenleri arasında çift yönlü nedensellik ilişkisi vardır |
| Fahim vd. (2023) | Fas | 2001-2018 | VAR analizi ve Vektör hata düzeltme modeli | Yükseköğretime yapılan yatırımlar ile büyüme arasında pozitif bir ilişki vardır. Fakat büyümenin yüksek öğretime yapılan yatırımları teşvik etmede sınırlı bir rolü vardır. |

Not: Yazar tarafından oluşturulmuştur.

2. Ekonometrik Analiz ve Bulgular

Bu çalışmanın amacı G-7 ülkelerinde 1990-2021 döneminde olası kişi başına düşen eğitim harcamaları büyüme ilişkisini tespit etmektir. Büyüme değişkeni; için kişi başına düşen milli gelir, eğitim harcamaları için ilköğretimde öğrenci başına yapılan harcamalar kullanılmıştır. Değişkenlere ait veriler OECD(2023) ve Worldbank(2023) resmi sitelerinde elde edilmiştir. Amaç doğrultusunda Fourier fonksiyonlarına dayalı testler kullanılmıştır. Analizde Fourier tabanlı fonksiyonlara ait testlerin kullanılmasının nedeni yapısal kırılmaları dikkate almayan geleneksel birim kök testlerinin ve eşbütünlüşme sınamalarının sonuçlarının bir tarafa daha yatkın olması ve bu yönüyle bu testlerin güvenilirliğinin tartışmalı olmasıdır. Yapısal kırılmaları dikkate alan testlerde ise kırılmanın tespiti için kukla değişken kullanımı nedeniyle kukla değişkenin modele nasıl dahil edildiği, kırılma sayısı ve

kırılma biçimleri sorun olmaktadır. Dolayısıyla iktisat bilimi içinde yapısal değişimin belli bir süreç gerektirdiğinden hareketle ani bir yapısal kırılmadan ziyade yumuşak geçişli bir yapısal değişimin daha rasyonel olduğunu ifade etmek gerekir. Fourier fonksiyonlarına dayalı testler yapısal değişimin kademeli olduğu, yapısal değişim sayısının, konumun ve biçiminin önem arz etmeden modellere dahil edildiği modellemelerdir. Fourier fonksiyonları trigonometrik terimleri (Sinüs, kosinüs gibi) içerir.

Fourier ADF birim kök testi istatistikleri aşağıdaki gibi hesaplanır;

$$\Delta y_t = \alpha + y_1 \sin\left(\frac{2\pi kt}{T}\right) + y_2 \cos\left(\frac{2\pi kt}{T}\right) + \delta y_{t-1} + \varepsilon_t \quad (3)$$

$$\Delta y_t = \alpha + \beta_t + y_1 \sin\left(\frac{2\pi kt}{T}\right) + y_2 \cos\left(\frac{2\pi kt}{T}\right) + \delta y_{t-1} + \varepsilon_t \quad (4)$$

denklemlerde belirtilen y fourier tahmin fonksiyonu, t zaman trendini, k uygun frekans değerini ($1 \leq k \leq 5$) ve T gözlem büyüklüğünü temsil eder (Enders ve Lee, 2012).

Değişkenlerin düzey değerlerine uygulanan Fourier ADF birim kök testine ilişkin sonuçlar Tablo 2’de verilmiştir.

Tablo 2: Büyüme Değişkeni İçin Fourier ADF Birim Kök Testi Sonuçları

| Ülkeler | k* | F ADF İstatistiği | F İstatistiği |
|-----------|----|-------------------|---------------|
| Almanya | 1 | -3.630 | 4.581 |
| Amerika | 1 | -4.428 | 5.217 |
| İngiltere | 1 | -3.361 | 4.549 |
| İtalya | 1 | -3.225 | 3.947 |
| Fransa | 2 | -2.699 | 5.807 |
| Japonya | 1 | -3.804 | 5.799 |
| Kanada | 2 | -1.888 | -5.447 |

Not: %5 anlamlılık düzeyinde temel hipotez olan “birim kök vardır” ı ifade etmektedir. k* uygun frekans dağılımı ifade eder.

Tablo 2’de ulaşılmış bulgulara göre büyüme değişkeni düzey değerleri dikkate alındığında G-7 ülkelerinin tamamında Fourier terimlerinin istatistiki bakımdan anlamsız olduğu sonucuna ulaşılmıştır. Fourier terimlerinin istatistiksel açıdan anlamsız olduğu G-7 ülkelerinin tamamı için büyüme değişkenine ADF birim kök testi uygulanmıştır (Tablo 4’te verilmiştir)

Tablo 3: Eğitim Harcamaları Değişkeni İçin Fourier ADF Birim Kök Testi Sonuçları

| Ülkeler | k* | F ADF İstatistiği | F İstatistiği |
|-----------|----|-------------------|---------------|
| Almanya | 1 | -3.662 | 4.183 |
| Amerika | 1 | -3.403 | 5.183 |
| İngiltere | 1 | -3.034 | 4.673 |
| İtalya | 1 | -3.373 | 3.808 |
| Fransa | 1 | -3.239 | 3.875 |
| Japonya | 1 | -4.554 | 5.299 |
| Kanada | 1 | -2.456 | 2.009 |

Not: %5 anlamlılık düzeyinde temel hipotez olan “birim kök vardır” ı ifade etmektedir. k* uygun frekans dağılımı ifade eder.

Tablo 3’e göre, F-ADF test sonuçlarına göre G-7 ülkelerin tamamında eğitim harcamaları değişkeni için birim kökün varlığını ifade eden temel hipotez kabul edilmiştir. Fourier terimlerinin istatistiksel açıdan anlamsız olduğu G-7 ülkelerinin tamamı için eğitim harcamaları değişkenine ait ADF testi uygulanmıştır.

Tablo 4: Değişkenlerin Düzey Değerlerine Uygulanan ADF Birim Kök Testi Sonuçları

| Ülkeler | Büyüme(Düzey) | Eğitim Harcamaları (Düzey) |
|-----------|---------------|----------------------------|
| Almanya | -2.403*(0) | -2.393(0) |
| Amerika | -1.955*(1) | -2.649(2) |
| İngiltere | -1.978*(0) | -1.738(0) |
| İtalya | -2.466*(0) | -1.676*(0) |
| Fransa | -2.379*(0) | -1.818*(0) |
| Japonya | -2.921*(0) | -2.803*(0) |
| Kanada | -0.871*(0) | -1.485*(0) |

Not: * %5 anlamlılık düzeyinde temel hipotez olan anlamlılık düzeyinde temel hipotez olan “birim kök vardır” ı göstermektedir.

Tablo 4 ADF birim kök sınama bulgularına göre, G-7 ülkelerin tamamında hem büyüme hem de eğitim harcamaları değişkenlerinin düzey değerleriyle durağan olmadıklarını göstermiştir Dolayısıyla hem F-ADF hem de ADF sonuçlarına göre birim köke sahip büyüme ve eğitim harcamaları değişkenlerinin birinci farklarına ADF testi uygulanmıştır.

Tablo 5: Birinci Farkı Alınmış Değişkenlere Uygulanmış ADF Birim Kök Testi Sonuçları

| Ülkeler | Büyüme(1. Farkı alınmış) | Eğitim Harcamaları (1.farkı alınmış) |
|-----------|--------------------------|--------------------------------------|
| Almanya | -5.999 ^a | -6.974 ^a |
| Amerika | -5.821 ^a | -4.836 ^a |
| İngiltere | -5.376 ^a | -6.537 ^a |
| İtalya | -7.264 ^a | -6.412 ^a |
| Fransa | -7.789 ^a | -7.728 ^a |
| Japonya | -5.482 ^a | -8.889 ^a |
| Kanada | -6.928 ^a | -5.568 ^a |

Not: ^a ifadesi %5 anlamlılık düzeyinde temel hipotez olan anlamlılık düzeyinde temel hipotez olan “birim kök vardır” ın reddedildiğini göstermektedir.

Tablo 5'teki sonuçlara göre büyüme ve eğitim harcamaları değişkenlerinin birinci farklarında durağan oldukları bulgusuna ulaşılmıştır. Dolayısıyla çalışmanın bu aşamasında G-7 ülkelerinde 1990-2021 dönemi için söz konusu değişkenlere ait eşbütünleşme testi uygulanmıştır. Değişkenlere ait Tsong vd. (2016) tarafından geliştirilen Fourier eşbütünleşme (FSHIN) test bulguları Tablo 6' da verilmiştir. Bu test Shin(1994) tarafından geliştirilen eşbütünleşme testinin Fourier fonksiyonlarına dönüştürülmüş bir formudur. Bu testte temel hipotez “eşbütünleşmenin varlığı” olarak tanımlanmıştır.

Tablo 6: Fourier FSHIN Eşbütünleşme Test Sonuçları

| Ülkeler | k* | Test İstatistiği | F İstatistiği |
|-----------|----|------------------|---------------|
| Almanya | 2 | 0.048* | 10.830** |
| Amerika | 2 | 0.052* | 14.495** |
| İngiltere | 2 | 0.047* | 7.877** |
| İtalya | 1 | 0.050 | 8.914 |
| Fransa | 2 | 0.221 | 6.740 |
| Japonya | 2 | 0.072* | 6.649** |
| Kanada | 3 | 0.069* | 7.656** |

Not: * %1, %5 ve %10 anlamlılık düzeylerinde sıfır hipotezi olan eşbütünleşme ilişkinin reddedilemediğini göstermektedir. ** %5 anlamlılık düzeyin Fourier terimlerinin istatistiki anlamlılığını göstermektedir. k* uygun frekans sayısını göstermektedir.

Tablo 6'daki Fourier Shin eşbütünleşme test bulgularına göre 1990-2021 döneminde İtalya ve Fransa hariç G-7 ülkelerinin tamamında eğitim harcamaları ile büyüme değişkenleri arasında eşbütünleşme ilişkisi vardır.

3. Sonuç

Gelişmiş ülke ekonomilerin büyümeyi destekleyen önemli faktörlerden biri eğitime ayrılan paydır. Ülkede eğitim seviyesinin artması beşerî sermayeye destek sağlayarak içsel büyüme teorilerinde üzerinde durulduğu üzere büyümeye katkı sağlayacaktır. Bu çalışmada gelişmiş ülke ekonomileri örnekleme için G-7 ülkeleri seçilmiş olup eğitimin büyüme ilişkisi eşbütünleşme analiziyle sınanmıştır. Ekonometrik analiz kısmında Fourier tabanlı fonksiyonlara bağlı ADF ve eşbütünleşme testleri uygulanmıştır. Çalışmanın sonucunda G-7 ülkelerinde (Fransa ve İtalya hariç) 1990-2021 döneminde eğitim harcamaları ile büyüme değişkenleri arasında eşbütünleşme ilişkisi bulunmuştur. Çalışmada ortaya çıkan sonuçlar genel olarak içsel büyüme teoremleri önermeleriyle uyumludur. Bu bağlamda politika yapıcıların/karar birimlerinin eğitimden merkezi bütçeden ayrılan payı daha da artırmasının (eğitimin kalitesini ve verimliliğine etki ederek dışsallıklar yoluyla ekonomiyi pozitif etki edeceği) önemi vurgulanmıştır.

Yazar Katkı Oranı (Author Contributions): Fatih Volkan AYYILDIZ (%100)

Yazarın Etik Sorumlulukları (Ethical Responsibilities of Authors): Bu çalışma bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır.

Çıkar Çatışması (Conflicts of Interest): Çalışmadan kaynaklı çıkar çatışması bulunmamaktadır.

İntihal Denetimi (Plagiarism Checking): Bu çalışma intihal tarama programı kullanılarak intihal taramasından geçirilmiştir.

KAYNAKÇA

- Aka, B. F., & Dumont, J. C. (2008). "Education and Economic Growth: Testing for Long-Run Relationships and Causal Links in the United States". *Applied Econometrics and International Development*, 8(2), 101-110.
- Akıncı, A. (2017). "Türkiye’de Eğitim Harcamalarının Ekonomik Büyüme Üzerindeki Etkisi". *Maliye Dergisi*, (173), 387-397
- Atherton, P., Appleton, S., & Bleaney, M. (2013). "International School Test Scores and Economic Growth". *Bulletin of Economic Research*, 65(1), 82-90.
- Awan, A.G, (2012). "Diverging Trends of Human Capital in BRICS Countries". *International Journal of Asian Social Science*, 2195-2219.
- Berber, M.(2006) İktisadi Büyüme ve Kalkınma, Derya Kitabevi (3. Basım),Trabzon.
- Cooray, A. (2009). "The Role of Education in Economic Growth". *Asian-Pacific Economic Literature*, 23(1), 1–20.
- Demir, O, Üzümcü A. & Duran S.(2006). "İçsel Büyümede İçselleşme Süreçleri: Türkiye Örneği, *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21 (1), 27-46.
- Eggoh, J., Houeninvo, H., & Sossou, G.-A. (2015). "Education, Health and Economic Growth in African Countries". *Journal of Economic Development*, 40(1), 93–111.
- Enders, W., & Lee, J. (2012). "A Unit Root Test Using a Fourier Series to Approximate Smooth Breaks". *Oxford bulletin of Economics and Statistics*, 74(4), 574-599.
- Erkan, H. (1998) *Bilgi Toplumu ve Ekonomik Gelişme*, Türkiye İş Bankası Yayını, No: 326, Ankara.
- Goumrhar, H. (2017). "Human Capital, Inequality and Economic Growth in Developing countries: Analysis in Panel Data". *Int. Journal of Innovation and Applied Studies*, 20(2), 441–46
- Hanif, N., & Arshed, N. (2016). "Relationship Between School Education and Economic Growth:SAARC Countries". *International Journal of Economics and Financial Issues*, 6(1), 294–300
- Herndon, M. C. (2008). *The Public Benefits of Higher Education: Examining the Relationship between State Spending on Higher Education and the Formation of Human Capital*. (Doctoral Dissertation)Virginia Polytechnic Institute and State University Educational Leadership and Policy Studies.
- Kibritçioğlu, A. (1998). "İktisadi Büyümenin Belirleyicileri ve Yeni Büyüme Modellerinde Beşeri Sermayenin Yeri". *Ankara Üniversitesi SBF Dergisi*, 53(Sayı:1-4), 207-230.
- Köse, Z. , Gölpek, F. & Erkılıç, T. A. (2022). "Eğitim Harcamalarının Ekonomik Büyüme Üzerinde Etkisi". *İstanbul Gelişim Üniversitesi Sosyal Bilimler Dergisi*, 9(2), 492-503.
- Langelett, G. L. (2000). *Human Capital and Economic Growth iOn the Open Economy-An Appeal to Robustness*. Doctoral Dissertation, University of Nebraska Economics Faculty of The Graduate College, Nebraska.
- Lau, L. J., Jamison, D. T., & Louat, F. F. (1991). "Education and Productivity in Developing Countries: An Aggregate Production Function Approach". Policy, Research, and External Affairs Working Papers; No. WPS 612. World Development Report.

- Lingaraj, M., Pradeep, K. D., & Kalandi, C. P. (2016). "Impact of Educational Expenditure on Economic Growth in Major Asian Countries: Evidence from Econometric Analysis". *Theoretical and Applied Economics*, XXIII(607), 173–186.
- Lucas Jr, R. E. (1988). "On the Mechanics of Economic Development". *Journal of monetary Economics*, 22(1), 3-42.
- OECD[Organisation for Economic Co-operation and Development] (2023) Education spending <https://data.oecd.org/eduresource/education-spending.htm> (Eriřim Tarihi: 06.08.2023)
- Parasız, İ (2003). Modern Büyüme Teorileri: Dinamik Makro Ekonomiye Giriř. Bursa: Ezgi Kitabevi Yayınları.
- Shin, Y. (1994). "A Residual-Based Test of the Null of Cointegration Against the Alternative of No Cointegration". *Econometric Theory*, 10(1), 91-115.
- Tsong, C. C., Lee, C. F., Tsai, L. J., & Hu, T. C. (2016). "The Fourier Approximation and Testing for the Null of Cointegration". *Empirical Economics*, 51, 1085-1113.
- Üzümcü, A.(2018) İktisadi Büyüme, Beta Yayınevi(3. Baskı). İstanbul.
- Varsak, S., & Bakırtaş İ. (2009). "Ekonomik Büyüme Üzerinde Beseri Sermayenin Etkisi: Türkiye Örneđi". *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 25, 49-60.
- Worldbank (2023) GDP Per capita (Current US\$) <https://data.worldbank.org/indicator/NY.GDP.PCAP.CD> (Eriřim Tarihi: 02.08.2023)
- Yıldız, F. (2023). "Türkiye’de Merkezi Yönetim Bütçesinden Yapılan Eğitim Harcamalarının Ekonomik Büyüme Üzerindeki Etkisi". *Dumlupınar Üniversitesi İİBF Dergisi* ,(11), 33-40.

AIZANOI FINANCE REVIEW

ISSUE: 2 / 2023

www.aizanoifr.com

info@aizanoifr.com

HİSSE SENEDİ GETİRİSİ VE ENFLASYON ORANI ARASINDAKİ İLİŞKİ: BORSA İSTANBUL ÖRNEĞİ

THE RELATIONSHIP BETWEEN STOCK RETURN AND INFLATION RATE: EXAMPLE OF THE BORSA İSTANBUL

İbrahim Halil UÇAR*, Erkan ALSU**

*Dr. Gaziantep Üniversitesi, Sosyal Bilimler Enstitüsü İşletme ABD, bodrum351@hotmail.com, ORCID: 0000-0002-6046-1285

**Doç.Dr., Gaziantep Üniversitesi, İktisadi İdari Bilimler Fakültesi, İşletme Bölümü, erkanalsu@gmail.com, ORCID: 0000-0001-6102-1786

| MAKALE BİLGİSİ | ÖZ |
|--|--|
| Gönderilme Tarihi 01.09.2023 Revizyon Tarihi 23.09.2023 Kabul Tarihi 11.10.2023 Makale Kategorisi Araştırma Makalesi JEL Kodları E31 E32 E44 | <p>Ulusal pay piyasasının makroekonomik değişkenlere duyarlılığının incelenmesi son dönemlerde birçok araştırmanın konusu olmuştur. Bu çalışmada, Borsa İstanbul 100(BİST100) ile Tüketici Fiyat Endek-si(TÜFE)/Toptan Eşya Fiyat Endeksi(TEFE) endeksleri arasındaki ilişki incelenmiştir. Çalışmada BİST100, TÜFE ve TEFE, endekslerinin aylık getirileri kullanılarak uzun dönem ilişkisi, Ocak 2003- Aralık 2021 veri dönemi için ARDL sınır testi ile incelenmiştir. Aynı zamanda değişkenler arasındaki kısa dönem ne-densellik ilişkisinin tespiti için Tado Yamamoto nedensellik testi kullanılmıştır. Çalışmanın sonuçlarına göre, TÜFE ve TEFE'den BİST100 endeksine doğru %1 önem seviyesinde tek yönlü bir nedensellik sap-tanmıştır. Diğer taraftan, uzun dönemde TÜFE ve TEFE'deki %1'lik değişimlerin BİST100'ü sırasıyla (0.067116) ve (0.059280) oranlarında pozitif yönde etkilediği saptanmıştır. Bu bağlamda BİST100 getirile-ri üzerinde TÜFE ve TEFE değişkenlerinin önemli etkisinin olduğu, dolayısıyla da BİST100 endeksine yatırım yapanlar için ilgili değişkenlerin öncü gösterge olabileceği düşünülmektedir. Bu çalışma portföy yatırımcıları ve politika uygulayıcıları için önemli sonuçlar içermektedir.</p> <p>Anahtar Kelimeler: ARDL, Uzun Dönem İlişkisi, Enflasyon, Hisse Senedi Getirisi</p> |

| ARTICLE INFO | ABSTRACT |
|---|---|
| Received 01.09.2023 Revized 23.09.2023 Accepted 11.10.2023 Article Classification: Research Article JEL Codes E31 E32 E44 | <p>The sensitivity of the national equity market to macroeconomic variables has been the subject of many recent studies. In this study has been examined the relationship between Borsa Istanbul 100 (BIST100) and Consumer Price Index (CPI)/Wholesale Goods Price Index (WPI) indices. In this study has been used the monthly returns of BIST100, CPI and WPI indices, the long-run relationship has been analyzed with the ARDL bounds test for the data period January 2003- December 2021. At the same time, Tado Yamamoto-causality test has been used to determine the short-run causality relationship between the variables. According to the results of the study, there is a unidirectional causality from CPI and WPI to BIST100 index at 1% significance level. On the other hand, in the long run, 1% changes in CPI and WPI have a positive effect on BIST100 by (0.067116) and (0.059280), respectively. In this context, it is thought that CPI and WPI variables have a significant effect on BIST100 returns and therefore, these variables may be leading indicators for those who invest in the BIST100 index. This study has important implications for portfolio investors and policy makers.</p> <p>Keywords: ARDL, Long-Term Relationship, Inflation, Stock Return</p> |

Atıf (Citation): Uçar, İ. H. & Alsu, E. (2023). "Hisse Senedi Getirisi ve Enflasyon Oranı Arasındaki İlişki: Borsa İstanbul Örneği", *Aizanoi Finance Review*, (2): 58-76



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

Giriş

Makroekonomik göstergelerde meydana gelen değişimlerin finansal piyasalar üzerinde meydana getirdiği etkiler literatürde sıkça tartışılan bir konu olarak görülmektedir. Gelişmekte olan ülkelerde finansal piyasalar oldukça kırılgan bir yapıya sahiptir. Bu kırılganlık, finansal piyasalardaki karşılıklı bağlantıların karmaşıklığına bağlıdır. Bu tür bir karmaşıklık sistematik likidite krizleri şeklinde bulaşmaya yol açabilmektedir. Ekonomilerdeki makroekonomik temeller uluslararası ticaret, enflasyon, faiz oranları gibi faktörler özellikle finansal kriz dönemlerinde bulaşma açısından önemlidir.

Ekonomik büyüme, GSYİH, faiz oranı, enflasyon ve diğer makro ekonomik değişkenler, piyasada işlem gören finansal varlıkların gerçek değerinde fiyatlandırmasında önemli katkıda bulunmaktadır (Glikas & diğerleri 2019:350-351).

Enflasyon oranları en önemli makroekonomik göstergelerden biridir. Sermaye piyasalarında işlem gören hisse senedi fiyatları çeşitli makroekonomik politikalardan etkilenmektedir. Günümüz serbest piyasa ekonomisinde enflasyon veya enflasyon oranları emtia fiyatlarının ağırlığını gösteren en önemli makroekonomik göstergedir. Emtia fiyatlarındaki değişiklikler piyasadaki her türlü fonun bir dereceye kadar aşınmasına veya değişmesine yol açabilmektedir. Hisse senedi piyasaları sadece makroekonomik ve uygulanan politikalardan değil aynı zamanda yatırımcı beklentilerinden de etkilenmekte ve oynaklıklar göstermektedir. Piyasada işlem yapan çoğu yatırımcı geleceğin nasıl değişeceğini gelecekteki makroekonomik durumu tahmin ederek mevcut ekonomik konjoktüre göre yatırımlarını şekillendirmektedirler. Enflasyonun kendisi yatırımcıların gelecekteki ekonomik duruma ilişkin belirsizliği açıkça arttıracak olan makroekonomik göstergelerin başında gelmektedir. Enflasyon yatırımcıların beklenen getirilerini ve reel getirilerini doğrudan azaltmaktadır. Bu durum gelecekteki reel gelirin azalmasına doğrudan bir sonucu olan enflasyon vergisi gibidir. Ayrıca bir ekonomide enflasyonist durum diğer bir ifade ile enflasyon baskısı yatırımcıların beklenen gelirlerinin azalmasına yol açmaktadır (Bai,2014:263-264).

Gelişmekte olan ülkelerde zayıf siyasi ve ekonomik kurumlar, yüksek ve değişen enflasyon ekonomik büyüme ve refah üzerinde olumsuz etkiye sahiptir. Gelişmekte olan ekonomilerde enflasyon belirsizliği yatırım düzeyini ve ekonomik faaliyetleri azaltarak iş ve finansal faaliyetler üzerinde önemli etkilere neden olabilmektedir (Arwatchanakarn&Akhand, 2016:2792-2794).

Pay getirileriyle enflasyon arasındaki etkileşimi araştıran çoğu deneysel çalışma daha kısa dönemlere odaklanmaktadır. Fakat hisse senedi ve enflasyon arasındaki uzun vadeli ilişkiyi incelemek önemlidir. Çünkü pratik bir açıdan bakıldığında, çoğu yatırımcı hisse senedi yatırımlarını uzun vadeli yatırım olarak görmekte ve dolayısıyla uzun süre elde tutma eğilimindedir. Bu nedenle pay fiyatlarının enflasyonla uzun dönem etkileşimi hakkında bilgi sahibi olmak kazançlı bir yatırım için önem arz etmektedir. Bu konuda yapılan çoğu akademik çalışmalar makroekonomik değişkenlerle, hisse senedi fiyat endeksi arasındaki etkileşimin olduğunu bulmuştur. Bu nedenle enflasyonun borsa performansı üzerindeki etkisinin araştırılması piyasa katılımcıları ve politika yapıcılar için önemli sonuçlar doğurmaktadır. Bu makalenin geri kalanı şu şekilde düzenlenmiştir. Birinci bölümde önerilen başlık altında daha önce yapılmış ampirik çalışmalar incelenmektedir. İkinci bölümde çalışmanın kavramsal çerçevesi anlatılmakta, üçüncü bölümde çalışma için kullanılan araştırma metodolojisini

ele almaktadır. Dördüncü bölümde ampirik sonuçlar tartışılmakta, son bölümünde ise tartışma ve sonuç bölümleri yer almaktadır.

1. Literatür Özeti

Makroekonomik değişkenler ve ülke borsaları arasındaki etkileşim literatürde sıkça tartışılan bir konudur. Örneğin, Choudhry. (2001) çalışmasında, Arjantin, Şili, Meksika ve Venezuela gibi Latin ve Orta Amerika ülkelerinde pay kazançları ve enflasyon arasındaki ilişkiyi araştırmıştır. Çalışmanın sonucunda, cari pay piyasası getirileri ile cari enflasyon arasında pozitif bir ilişkinin olduğunu ve ayrıca geçmiş enflasyon oranlarının mevcut pay getiri oranını da etkilediğini tespit etmiştir. Fakat, Spyros. (2001) çalışmasında, Yunanistan ekonomisi için enflasyon ile hisse senedi getirileri arasındaki etkileşimi Ocak 1990- Haziran 2000 dönemi için incelemiştir. Çalışmanın sonucunda, enflasyon ve hisse senedi arasında negatif ancak istatistiksel olarak anlamlı bir ilişki olmadığını bulmuştur. Diğer taraftan, Kim&Francis(2005) çalışmasında, hisse senedi getirileri ile enflasyon arasındaki ilişkiyi ABD için Ocak 1926- Aralık 2000 dönemini kapsar şekilde incelemiş ve çalışmanın sonucunda, hisse senedi getirileri ile enflasyon arasında en kısa (1 aylık dönem) ve en uzun (128 aylık dönem) ölçekte pozitif ilişki, ara ölçeklerde ise negatif ilişki tespit etmiştir. Görüldüğü üzere hisse senedi getirileri ve enflasyon oranı arasındaki ilişki olduğu tüm çalışmalarda tespit edilmiş ise de, değişkenler arasındaki ilişkinin yönü çalışmalarda farklılıklar göstermektedir. Bu farklılıkların seçilen ülke, veri dönemi, analiz yöntemi vb. gibi nedenlerden kaynaklandığı görülmektedir.

Fakat ilerleyen yıllarda yapılan bazı çalışmalarda hisse senedi getirileri ve enflasyon oranı arasında herhangi bir ilişkinin olmadığı ileri sürülmüştür. Örneğin, Hondroyiannis&Papaterou. (2006) çalışmasında, Yunanistan'da hisse senedi getirileri ile enflasyon arasındaki etkileşimi incelemişlerdir. Çalışmanın sonucunda, hisse senedi piyasası performansının ekonomideki herhangi bir enflasyon kaynağı ile ilişkili olmadığını diğer bir ifade ile reel pay getirilerinin beklenen ve beklenmeyen enflasyonla ilişkili olmadığını tespit edilmiştir. Diğer taraftan, Keun Yeong Lee (2008) çalışmasında, reel hisse senedi getirileri ile enflasyon arasındaki dinamik etkileşimi incelemiştir. Çalışmanın sonucunda, enflasyon oranı ve hisse senedi performansı arasında negatif bir ilişki tespit ederken, 1970-2000 döneminde ise iki değişken arasında herhangi bir ilişki tespit edememiştir. İki çalışma arasındaki fark seçilen dönemin ilişkinin tespiti açısından önem arz ettiğini göstermektedir.

İlerleyen yıllarda aşağıda kronolojik olarak sunulan çalışmaların literatürde yer aldığı tespit edilmiştir.

İbrahim&Agbaje (2013) Pay getirileri ve enflasyon arasındaki uzun ve kısa dönemli dinamikleri incelemişlerdir. Ocak 1997 ile Aralık 2010 dönemine ilişkin aylık hisse senedi ve tüketici fiyat endeksi verilerini Nijerya merkez bankasından temin ederek ARDL sınır testi ile yaptıkları çalışmalarda enflasyonun pay getirileri üzerinde olumlu etkisinin olduğu ve enflasyon ile pay getirilerinin uzun dönemde eşbütünleşik olduklarını tespit etmişlerdir.

John Khumalo (2013) Güney Afrika sermaye piyasasında enflasyon ve pay fiyatları arasındaki ilişkiyi araştırmıştır. 1980q1 ve 2010q4 dönemini kapsayan çeyrek dönemlik verileri kullanarak ARDL modeli ile yaptığı çalışmasında pay getirileri ile enflasyon ve diğer açıklayıcı parametreler arasında güçlü bir ilişkinin olduğu, pay fiyatlarının enflasyon ve faiz oranlarına olumsuz tepki verdiği ve enflasyonun pay getirilerini olumsuz etkilediğini tespit etmiştir.

Bai. (2014) Çin’de enflasyonun borsa üzerindeki etkisini incelemiştir. Ocak 2001 – Ekim 2010 dönemini kapsayan tüketici fiyat endeksi ve Şangay borsası bileşik endeksi yıllık ortalama verilerini ulusal istatistik bürosu ve Şangay borsasından alarak vektör otoregresif VAR modeli ile yaptığı çalışmada enflasyonun Çin hisse senedi fiyatı üzerindeki etkisinin çok az ve hisse senedi fiyatı ile korelasyonunun çok zayıf olduğunu tespit etmiştir.

Özkan (2015) Türkiye’de enflasyon, hisse senedi getirileri ve reel iktisadi faaliyetler arasındaki ilişkileri incelemiştir. Ocak 2003 ile Aralık 2014 dönemini kapsayan TÜFE endeksi, cari ayın TÜFE beklentisi ve sanayi üretim endeksi (SÜE) aylık verilerini TCMB ve Türkiye istatistik kurumundan, Borsa İstanbul100 endeksi verilerini ise Borsa İstanbul internet sayfasından temin ederek Fisher hipotezi modeli ile araştırdığı çalışmada reel iktisadi faaliyetler ile reel hisse senedi getirileri arasında pozitif ilişki tespit etmiştir. Öte yandan enflasyon ile reel iktisadi faaliyetler arasında net bir ilişki tespit edememiştir.

Uçan&diğerleri (2017). Borsa İstanbul-100 ile petrol, döviz, enflasyon ve faiz gibi makroekonomik değişkenler arasındaki ilişkiyi panel veri analizi ile test etmişlerdir. 2005 ve 2016 dönemine ilişkin aylık verileri TCMB veri dağıtım sistemi, TÜİK, maliye bakanlığı ve iş yatırım gibi çeşitli birimlerden alarak makroekonomik değişkenlerle Borsa İstanbul-100 endeksi arasındaki ilişkinin varlığını Johansen eş bütünleşme testi ile belirlemeye çalıştıkları çalışmalarında Borsa İstanbul-100 endeksinin analize kapsamındaki değişkenlerle anlamlı bir ilişkinin olduğu, enflasyonun tüm ekonomik faaliyetleri doğrudan ve dolaylı yoldan etkileyen önemli bir faktör olduğu tespit edilmiştir.

lorember&diğerleri (2017) Enflasyonun Nijerya hisse senedi piyasası üzerine etkisini incelemiştir. Ocak 1995 ve Aralık 2016 dönemini kapsayan tüketici fiyat endeksi ve borsa endeksine ait aylık veriler Nijerya merkez bankası istatistik bülteninden alınarak E-GARCH modeli ile yaptıkları incelemelerinde enflasyonun Nijerya borsasında işlem gören hisse senedi getirilerini etkilemediği ve borsa performansı ile enflasyon arasında bir ilişkinin olmadığı saptanmıştır.

Isnandari&Chalid (2017) Çin, Hindistan, Endonezya, Güney Kore, Malezya, Filipinler, Tayvan ve Tayland gibi sekiz Asya ülkesinde pay getirileri ile enflasyon arası etkileşimi araştırmışlardır. 2001-2014 yıllarını kapsayan aylık tüketici fiyat endeksi ve hisse senedi verileri datastream ve ilgili borsaların veri tabanlarından alınarak doğrusal regresyon analizi ile yaptıkları çalışmalarında test edilen 35 sektörden yiyecek içecek, tütün, elektrik ve kamu hizmetleri, yapı ve inşaat malzemeleri ve savunma sanayisi hisse senetlerinin enflasyon riskinden korunma kabiliyetine sahip oldukları tespit edilmiştir.

Sathyanarayana&Gargesa (2018) Enflasyonun borsa performansı üzerindeki etkisini incelemiştir. Mart 2000 ile Mart 2017 dönemine ilişkin aylık enflasyon ve hisse senedi verileri www.yahoo.finans ve diğer ilgili veri tabanlarından alınarak ADF birim kök testi ve Pearson korelasyon katsayısı ile yaptıkları çalışmada Japon Endeksi (Nikkei) ile enflasyon arasında negatif bir ilişki saptanırken, Avusturya endeksi (ATX), Belçika Endeksi (BEL20), Kanada Endeksi (GSPTSE), Şili Endeksi (IPSA), Çin Endeksi (SSEC), İrlanda (ISEQ), Fransa Endeksi (FTHI) ve Endonezya Endeksi JKSE için enflasyon ile hisse senedi getirileri arasında pozitif ilişki saptanmıştır.

Akçalı&diğerleri (2019) Türkiye’de enflasyon, döviz kuru ve faiz gibi makroekonomik değişkenlerde oluşan şokların birbirlerini etkileme ve bulaşıcılık etkilerini incelemiştir. Mart 1999 ve Aralık 2018 dönemini kapsayan tüketici fiyat endeksi ve faiz oranlarının üç aylık, reel efektif döviz kurunun ise

aylık verileri kullanılarak ARMA-EGARCH yöntemi ile yaptıkları çalışmada faiz oranları, enflasyon ve döviz kurunda oluşan şokların birbirlerinin koşullu değişkenleri üzerinde tek ve çift yönlü etkilerinin olduğu ve değişkenler arasında güçlü karşılıklı bulaşıcılık etkiler tespit etmişlerdir.

2. Veri Seti ve Yöntem

Bu çalışmada, Borsa İstanbul Endeksi ve TEFE/TÜFE endeksleri arasında ilişki incelenmektedir. Bu kapsamda BİST100, TÜFE ve TEFE, endekslerinin aylık getirileri kullanılarak uzun dönem ilişkisi, Ocak 2003- Aralık 2021 veri dönemi için ARDL sınır testi ile incelenmiştir. Aynı zamanda değişkenler arasındaki kısa dönem nedensellik ilişkisinin tespiti için Tado Yamamoto nedensellik testi kullanılmıştır. 2003-2021 dönemini kapsayan BİST100, TÜFE ve TEFE değişkenlerine ait aylık veriler TCMB veri tabanından alınmıştır. Değişkenler arası uzun periyot ilişkisini belirlemek için yapılan çalışmada öncelikle Genişletilmiş Dickey&Fuller (ADF) ve Fuller&Phillip (PP) birim kök testleriyle serilerin birim kökleri incelenmiştir. Çalışmada değişkenler arasındaki nedensellik ilişkisi Toda Yamamoto nedensellik testi ile analiz edilmiştir. BİST100, TÜFE ve TEFE arasındaki uzun dönem ilişkisi araştırılan parametrelerin 2003-2021 dönemini kapsayan aylık verilerinin logaritmik değerleri baz alınarak ARDL modeli ile incelenmiştir. Çalışmanın en önemli kısıtlarından biri döviz kuru, GSYİH, faiz oranı, işsizlik oranları gibi diğer makroekonomik unsurlar da pay getirisini etkilemekle birlikte çalışmada diğer şartlar sabitken varsayımı dikkate alınmıştır.

2.1. Birim Kök Testi

Çalışmada analiz edilen değişkenlerin, birim kök sürecinin diğer bir deyişle değişkenlerin durağanlık durumlarının kontrol edilmesi güvenilir istatistiksel sonuçlar için önemlidir. Çünkü incelenen bir değişkenin durağan olup olmaması analizin sürecini ve sonucunu etkileyebilmektedir. Bu nedenle çalışmada değişkenlerin durağanlık durumları genişletilmiş Dickey&Fuller ve Phillip&Perron birim kök testleri ile kontrol edilmiştir.

2.1.1. Genişletilmiş Dickey ve Fuller Testi

Genişletilmiş Dickey&Fuller testi zaman serisinin durağanlığını test etmek için uygulanan bir istatistiksel testtir. Bu test aşağıda verilen regresyon denklemini kullanır.

$$\Delta Y_t = \beta_1 + \beta_2 + \delta Y_{t-1} + \sum_{i=1}^k \omega_i \Delta Y_{t-i} + \varepsilon_t \quad (2)$$

Burada Δ = birinci farkta duraganlık, ΔY_{t-i} = bağımlı değişkenin gecikme değerleri, ε_t =hata terimi, β_1 = sabit katsayı, β_2 = t zamandaki eğim katsayısı, δ = gecikme katsayısı, Y_{t-1} ve Y_t ise hisse senedinin ya da piyasa değer endeksinin logaritmik değeridir (Guney&Komba,2016:10).

2.1.2. Phillips ve Perron Testi

Birim kök testi uygulanırken ardışık bağımlılığı ele alan parametrik nitelik göstermeyen yaklaşım Phillips&Perron tarafından geliştirilmiştir. Dickey&Fuller birim kök testine dayanan Phillip&Perron testi, t istatistiğinde parametrik özellik göstermeyen bir düzeltme yapar. Phillips&Perron testi birinci dereceden otoregresif yöneme dayanmaktadır.

$$\Delta Y_t = \alpha_0 + \beta Y_{t-1} + \mu_t \quad (3)$$

burada α bir katsayıdır, Δ farklılıkları göstermektedir., β eğilim (trend), Y tahmin edilen bağımlı değişken, μ_t ise hata terimini temsil etmektedir (Polat&Olgun,2020:210; Jebran&Iqbal,2016:6)

2.1.3. Nedensellik Testi

Çalışmada BİST100 ile Enflasyon arasındaki nedensellik araştırılan değişkenlerin aylık logaritmik verileri kullanılarak Toda Yamamoto nedensellik testiyle incelenmiştir.

2.1.4. Toda Yamamoto Testi

Toda Yamamoto yönteminde test edilen değişkenlerin durağanlık mertebeleri farklı olabilir. Bu teste önem verilmesi gereken en önemli nokta parametrelerin maksimum bütünleşme derecesi olan (dmax)'ın testin uygun gecikme uzunluğu olan (k)'dan büyük olmamasıdır. Toda Yamamoto testinde parametreler arasındaki ilişkiyi test eden hipotezler; H_0 : değişkenler arasında nedensellik yoktur. H_1 : değişkenler arasında nedensellik vardır.

Toda Yamamoto testi ile değişkenler arası nedensellik tespit edilirken tahmin edilen VAR (k+dmax) denklemi şöyle ifade edilebilir.

$$Y_t = \omega + \sum_{i=1}^k \alpha_{1i} X_{t-i} + \sum_{i=1}^k \beta_{1i} Y_{t-i} + \sum_{j=k+1}^{dmax} \delta_{1j} X_{t-j} + \sum_{j=k+1}^{dmax} \theta_{1j} Y_{t-j} + \varepsilon_{1t} \quad (4)$$

Uygun gecikme uzunluğunu gösteren (k) bilgi kriterlerinden faydalanarak, maksimum bütünleşme derecesini gösteren (dmax) ise birim kök testleri ile saptanabilmektedir. Analiz edilen değişkenler arasında karşılıklı nedenselliğin olup olmadığını saptamak için $H_0 = \alpha_{1j} = 0$ hipotezi Wald testi ile kontrol edilmektedir. Modellenen diğer bir deyişle hesaplanan wald testi istatistiği değeri k serbestlik derecesi olan K^2 tablo değerinden daha büyük ise bahsi geçen hipotez kabul edilmemektedir (Aydın&Afsal,2018:235).

2.1.5. ARDL Modeli

ARDL modeli Paseran vd çalışmalarıyla önceki eş bütünleşme modellerindeki eksiklikleri gidermek gayesi ile geliştirilen çok kullanışlı eş bütünleşme modelidir. Bu modelde test edilen parametrelerin bütünleşme dereceleri dikkate alınmaksızın seriler arasındaki uzun ve kısa dönem ilişkileri test edilebilmektedir. ARDL modelinin diğer modellerden üstün yanı test edilen parametrelerin birim köklerine bakılmaksızın uygulanabilmesidir. Bu nedenle ARDL modeli epeyce kullanışlı ve güvenilir neticeler veren bir modeldir.

Araştırmada pay getirileri ile enflasyon arayüzündeki ilişkiyi açıklamaya çalışan teorik çerçeveye dayanarak tahmin modelleri belirlenmiştir. BİST ile ifade edilen hisse senedi getirisi bağımlı değişkendir, açıklayıcı değişkenler ise tüketici fiyat endeksi (TÜFE) ve toptan eşya fiyat endeksi (TEFE) ile temsil edilen enflasyondur. Bu durum aşağıda verilen işlevsel biçimlerde ifade edilebilir

$$BİST_t = f(TÜFE_t) \quad (5)$$

$$BİST_t = f(TEFE_t) \quad (6)$$

Hisse senedi getirisi (BİST) ile enflasyon değişkenleri olan (TÜFE) ve (TEFE) arasındaki işlevsel ilişki ARDL modeli ile aşağıdaki şekillerde ifade edilebilir.

$$\Delta BİST = \alpha_0 + \beta_1 BİST_{t-1} + \beta_2 TÜFE_{t-1} + \sum_{i=1}^k \delta_{1i} + \Delta BİST_{t-i} + \sum_{i=1}^k \delta_{2i} \Delta TÜFE_{t-i} + \varepsilon_t \quad (7)$$

$$\Delta BİST = \alpha_0 + \beta_1 BİST_{t-1} + \beta_2 TEFE_{t-1} + \sum_{i=1}^k \delta_{1i} + \Delta BİST_{t-i} + \sum_{i=1}^k \delta_{2i} \Delta TEFE_{t-i} + \varepsilon_t \quad (8)$$

BİST= BİST100 endeksi, TÜFE: tüketici fiyat endeksi, TEFE: toptan eşya fiyat endeksi, α : sabit terimi, k: optimal gecikme uzunluğu, Δ : fark işlemcisi, ε : hata terimini temsil etmektedir.

ARDL yaklaşımındaki ilk adım denklemi (7 ve 8) kullanarak en küçük kareyi (OLS) tahmin etmektir. İkinci adım ise denklem (5 ve 6)'de tahmin edilen gecikmeli düzey değişkenlerinin katsayılarının sıfıra eşit olmasını kısıtlayarak uzun dönem ilişkisinin olup olmadığını belirlemektedir. Modelde

$H_0 =$ Değişkenler arası uzun dönem ilişkisi yoktur.

H_1 = Değişkenler arası uzun dönem ilişkisi vardır.

Wald testi ile hesaplanan F istatistiği Pesaran vd tarafından belirlenen standart özellik göstermeyen kritik sınır değerleriyle mukayese edilir. ARDL sınır testinden elde edilen test istatistiği $I(0)$ ve $I(1)$ kritik değerleriyle mukayese edildiğinde tahmin edilen F istatistiğinin değeri üst kritik değerden yani $I(1)$ 'in kritik değerinden büyük ise test edilen parametreler arasında uzun periyot eş bütünleşme ilişkisinin olduğu sonucuna varılır. Aksi durumda ise test edilen parametreler arasında uzun dönemli bir ilişkisinin olmadığı temel hipotezi kabul edilir. Tahmin edilen test istatistiğinin alt ve üst kritik değerler arasında olması halinde ise parametreler arasında uzun dönem ilişkisi hakkında net bir karar verilemez. ARDL sınır testi ile uzun dönem ilişkisine dair sonuçlar elde edilirse uzun ve kısa dönem katsayıları modellenenabilir. Uzun dönem katsayısı aşağıdaki modeller kullanılarak modellenenabilir.

$$BİST = \alpha_0 + \beta_1 BİST_{t-1} + \beta_2 TÜFE_{t-1} + \varepsilon_t \quad (9)$$

$$BİST = \alpha_0 + \beta_1 BİST_{t-1} + \beta_2 TEF E_{t-1} + \varepsilon_t \quad (10)$$

Değişkenler arası uzun dönem ilişkisi belirlendikten ve test edilen parametreler arası uzun periyot ilişkisine dair katsayılar modellendikten sonra ARDL yönteminin bir sonraki süreci olan kısa dönem ilişkisine dair katsayılar ve olasılık değerlerinin modellenmesidir. Bu doğrultuda değişkenler arasında uzun dönemli ilişkileri tespit etmek için oluşturulan regresyon denklemi kalıntılarının açıklayıcı parametreler olarak dahil edildiği bir hata düzeltme modeli oluşturularak kısa dönem ilişkisine dair katsayı ve olasılık değerlerinin yanında modelin çalışıp çalışmadığını yani anlamlı olup olmadığını gösteren hata düzeltme terimi de tahmin edilir. Değişkenler arası kısa dönemli dinamik modeller aşağıdaki şekillerde ifade edilebilir.

$$\Delta BİST = \alpha_0 + \sum_{i=1}^k \delta_{1i} \Delta BİST_{t-i} + \sum_{i=1}^k \delta_{2i} \Delta TÜFE_{t-i} + \delta_3 \varepsilon_{t-1} + \varepsilon_t \quad (11)$$

$$\Delta BİST = \alpha_0 + \sum_{i=1}^k \delta_{1i} \Delta BİST_{t-i} + \sum_{i=1}^k \delta_{2i} \Delta TEF E_{t-i} + \delta_3 \varepsilon_{t-1} + \varepsilon_t \quad (12)$$

Burada ε_{t-1} :: bir dönem gecikmeli hata düzeltme terimi, δ ise denklemden düzeltme hızını ölçme katsayısını temsil etmektedir.

Hata düzeltme terimi modelin kısa dönem katsayılarını verir. Eğer hata düzeltme modeli çalışmıyorsa kurulan model anlamsızdır. Modelin çalışması için hata düzeltme modelinin katsayısı 1'den küçük, işareti (-) ve olasılık değeri anlamlı olmalıdır. Hata düzeltme katsayısı eş bütünleşik değişkenler arasında uzun dönemde bir sapma olduğunda bu değişkenlerin tekrar birbirine yaklaşım yaklaşmadığını gösteren bir katsayıdır (İbrahim&Agbaje,2013:152-154; Gönüllü,2020:228-229).

2.2. Araştırma Bulguları ve Tartışma

Çalışmanın bu kısmında analiz edilen değişkenlerin sırasıyla tanımlayıcı istatistikleri, korelasyon dereceleri, fiyat serisi grafikleri, birim kök, nedensellik, ARDL sınır testi ve tanısız test sonuçları sunulmuştur.

2.2.1. BİST100, TÜFE ve TEF E Değişkenlerinin Tanımlayıcı İstatistikleri Sonuçları

Tanımlayıcı istatistikler incelenen değişkenlere ilişkin serilerin normal dağılım gösterip göstermediğini belirlemek açısından önemlidir. Bu nedenle BİST100, TÜFE ve TEF E parametrelerine ait aylık fiyat serilerine ilişkin tanımlayıcı istatistikler hesaplanmıştır.

Tablo 1. BİST100, TÜFE ve TEFE Değişkenlerinin Tanımlayıcı İstatistikleri

| | BİST100 | TÜFE | TEFE |
|--------------|---------|--------|--------|
| Ortalama | 6.5584 | 5.4966 | 18.310 |
| Ortanca | 6.6210 | 5.4435 | 18.264 |
| Maksimum | 7.5270 | 6.5322 | 19.465 |
| Minumum | 5.4817 | 4.8168 | 17.586 |
| Std sapma | 0.4184 | 0.4302 | 0.4647 |
| Çarpıklık | -0.2767 | 0.3738 | 0.3702 |
| Basıklık | 2.6980 | 2.1367 | 2.1426 |
| Jarque Berra | 3.1796 | 10.435 | 10.268 |
| Olasılık | 0.2039 | 0.0054 | 0.0058 |
| Gözlem | 192 | 192 | 192 |

Tablo 1, getiri serileri için özet istatistikleri raporlamaktadır. Jarque Berra istatistiği olasılık değerlerinin TÜFE ve TEFE değişkenleri için 0.05'ten küçük çıkması fiyat serilerinin normal dağılmadığı, BİST100 için ise 0.05'ten büyük olması serilerin normal dağılım gösterdiği şeklinde yorumlanabilir. Fiyat serilerinin normal dağılımı için önemli katsayılar olan eğiklik, basıklık ve Jarque Berra istatistiği olasılık değerlerinin TÜFE ve TEFE değişkenleri için normal değerlerin altında çıkması fiyat serilerinin normal dağılım göstermediğini göstermektedir. Eğikliğin BİST100 için (-0.27) değeri ile sola, TÜFE ve TEFE için (0.37) değerleri ile sağa doğru olduğu görülmektedir. TÜFE ve TEFE serileri pozitif çarpıklığa sahiptir ve bu da dağılımın uzun bir sağ kuyruğa sahip olduğunu göstermektedir. Diğer taraftan hisse senedi getiri serileri negatif çarpıklığa sahiptir ve bu da dağılımların uzun bir sol kuyruğa sahip olduğunu göstermektedir. Ayrıca BİST100 için çarpıklık katsayısının negatif (-) çıkması zararın kardan daha çok diğer bir ifade ile negatif getirilerin pozitif getirilerden daha fazla olduğu şeklinde yorumlanabilir.

2.2.2. BİST100 ile TÜFE ve TEFE Arasındaki Korelasyon

Araştırmanın amacı ve içeriği açısından önem arz eden BİST100, TÜFE ve TEFE arasındaki ilişki derecesini tespit etmek amacıyla ilgili değişkenlerin aylık logaritmik fiyatları kullanılarak korelasyon matrisi düzenlenmiştir.

Tablo 2. BİST100, TÜFE ve TEFE Arasındaki Korelasyon Matrisi Sonuçları


| Değişkenler | BİST | TÜFE | TEFE |
|-------------|------------|------------|------|
| BİST | 1 | | |
| TÜFE | 0.90722568 | 1 | |
| TEFE | 0.91103451 | 0.99862524 | 1 |

Tablo 2'te korelasyon matrisi incelendiğinde BİST100 ile TÜFE ve TEFE değişkenleri arasında sırasıyla 0.90 ve 0.91 değerleriyle yüksek korelasyonun olması BİST100 endeksinin bu değişkenlerle ilişkisinin güçlü olduğunu göstermektedir.

2.2.3. BİST100, TÜFE ve TEFE Değişkenlerinin Fiyat Serisi Grafikleri

Piyasa dalgalanması, aşağı veya yukarı doğru fiyat değişimlerinin sıklığı ve büyüklüğüdür. Fiyat değişimleri ne kadar büyük ve sık gerçekleşirse piyasanın o kadar değişken olduğu kabul

edilmektedir. BİST100, TÜFE ve TEFE değişkenlerine ait aylık fiyat değişimlerinin eğilimleri grafiklerle incelendiğinde değişkenlere ait serilerin durağan olmadıkları söylenebilir.



Şekil 1. BİST100, TÜFE ve TEFE Değişkenlerinin Fiyat Serisi Grafikleri

Şekil 1’de Fiyat grafikleri incelendiğinde BİST100 fiyat serilerinde 2008, 2013, 2016 ve Covid19 dönemlerinde aşağı doğru kırılmalar olmasına rağmen uzun dönemde artış gösteren bir trend eğilimi gösterdiği görülmektedir. TÜFE ve TEFE fiyat serilerinin ise sürekli artış gösteren bir trend eğilimi gösterdiği görülmektedir.

2.3. Birim Kök Testi Sonuçları

Analiz kapsamında incelenen BİST100, TÜFE ve TEFE değişkenlerine ait fiyat serilerinin durağanlığı diğer bir ifade ile birim kökleri ADF ve PP birim kök testleri ile araştırılmıştır. Çalışmada kullanılan

H_0 = seride birim kök vardır, H_1 = seride birim kök yoktur biçiminde kurulan hipotezlerin geçerliliği hem seviye değerleri hem de birinci farkları alınarak yapılan birim kök testleriyle araştırılmıştır.

Tablo 3: Genişletilmiş Dickey&Fuller Testi Sonuçları

| | Seviye | | | |
|---------|---------------|----------|---------------|----------|
| | Sabitli | | Sabit&Trendli | |
| | t istatistiği | Olasılık | t istatistiği | Olasılık |
| BİST100 | -0.4122 | 0.9033 | -3.092 | 0.1218 |
| TÜFE | 2.9794 | 1.0000 | 3.0891 | 1.0000 |
| TEFE | 2.8981 | 1.0000 | 2.3887 | 1.0000 |
| 1.FARK | | | | |
| BİST100 | -13.7793 | 0.0000 | -13.8062 | 0.0000 |
| TÜFE | -5.5333 | 0.0000 | -6.0974 | 0.0000 |
| TEFE | -5.7383 | 0.0000 | -6,2887 | 0.0000 |

Tablo 4: Phillips&Perron Testi Sonuçları

| | Seviye | | | |
|---------|----------|----------|-----------------|----------|
| | Sabitli | | Sabitli&Trendli | |
| | t ist | Olasılık | t ist | Olasılık |
| BİST100 | -0.4178 | 0.9024 | -3.1913 | 0.0893 |
| TÜFE | 3.6422 | 1.0000 | 2.9902 | 1.0000 |
| TEFE | 3.2933 | 1.0000 | 2.6816 | 1.0000 |
| 1.FARK | | | | |
| BİST100 | -13.7799 | 0.0000 | -13.8061 | 0.0000 |
| TÜFE | -5.3501 | 0.0000 | -5.7662 | 0.0000 |
| TEFE | -5.7383 | 0.0000 | -6.3071 | 0.0000 |

Tablo 3 ve 4 incelendiğinde analiz kapsamında incelenen değişkenlere ait serilerin düzey değerleri ile birim kök içerdikleri ve rastgele yürüyüş hipotezine göre hareket ettikleri görülmektedir. Fiyat serilerinin birincil farkları alındığında değişkenlerin %1 önem seviyesinde durağanlaştıkları ve birim kök içermedikleri saptanmıştır.

2.4. Toda Yamamoto Testi Sonuçları

Çalışmada BİST100, TEFE ve TÜFE arasındaki nedensellik Toda Yamamoto testi ile incelenmiş ve elde edilen sonuçlar %5 önem seviyesine göre değerlendirilmiştir.

Tablo 5. Toda Yamamoto Nedensellik Testi Sonuçları

| Değişkenler | dmax | k | Hipotez | Ki Kare Test İstatistiği | Ki Kare Değeri | Nedensellik |
|-------------|------|---|--------------|--------------------------|----------------|-------------|
| TÜFE | 1 | 3 | TÜFE→BİST100 | 11.9461 | 0.0025 | VAR |
| | | | BİST100→TÜFE | 4.1827 | 0.1235 | YOK |
| TEFE | 1 | 3 | TEFE→BİST100 | 12.3509 | 0.0020 | VAR |
| | | | BİST100→TEFE | 3.9447 | 0.1391 | YOK |

Tablo 5 incelendiğinde TÜFE ve TEFE'den BİST100'e doğru %1 anlamlılık düzeyinde tek yönlü bir nedensellik saptanırken, BİST100'den TÜFE ve TEFE'ye doğru %5 önem seviyesinde anlamlı bir nedensellik tespit edilememiştir. Toda Yamamoto testi sonuçlarına göre TÜFE ve TEFE gibi iki önemli enflasyon değişkeninin BİST100 endeksini anlamlı bir şekilde etkilediği fakat BİST100'ün enflasyon üzerinde herhangi bir anlamlı etkisinin olmadığı sonucuna varılabilir.

2.5. BİST ile TÜFE Arası ARDL (1,0) Modeli ile Tahmin Edilen Eş bütünleşme Testi Sonuçları

BİST100 ile TÜFE arasındaki eş bütünleşme derecesi ARDL sınır testi (1,0) modeli ile modellenmeden içerisinde sabit ve hata teriminin olduğu; $BİST_T = \alpha_0 + \alpha_1 T\ddot{U}FE_t + \varepsilon_t$ şeklinde doğrusal bir denklem kurulmuştur.

Tablo 6. ARDL (1,0) Modeli ile Tahmin Edilen F İstatistiği ve Kritik Değerler

| Model | K | M | F İst | Önem Seviyesi | Alt Sınır | Üst Sınır |
|------------|---|---|----------|---------------|-----------|-----------|
| ARDL (1,0) | 2 | 8 | 5.485237 | %10 | 4.04 | 4.78 |
| | | | | %5 | 4.94 | 5.73 |
| | | | | %1 | 6.84 | 7.84 |

Not: M, Maksimum gecikme uzunluğu, K: Açıklayıcı parametre sayısını temsil etmektedir.

Tablo 6'da BİST100 ile TÜFE arasındaki uzun dönem ilişki derecesini gösteren ARDL (1,0) sınır testi ile hesaplanan F istatistiği ve kritik değerler incelendiğinde ARDL modeli ile hesaplanan F istatistiğinin Paseran vd tarafından %1 ve %5 önem düzeyi için belirlemiş oldukları üst kritik değerlerin tamamından düşük olması nedeniyle değişkenler arası uzun dönem ilişkisinin olmadığını söyleyen sıfır hipotezi kabul edilmektedir. Bu sonuç BİST100 ile TÜFE endekslerinin uzun dönemde eş bütünleşik olmadığı anlamına gelmektedir.

Tablo 7. ARDL (1,0) Modeli ile Tahmin Edilen Uzun Dönem Katsayıları

| Değişkenler | Katsayı | Standart Sapma | t-istatistiği | Olasılık |
|--------------|---------|----------------|---------------|----------|
| Sabit | 0.0563 | 0.0570 | 0.9875 | 0.3244 |
| BİST100 (-1) | -0.0636 | 0.0195 | -3.2634 | 0.0013 |
| TÜFE | 0.0671 | 0.0247 | 2.7108 | 0.0072 |

Tablo 7'de değişkenlere ait uzun dönem katsayıları incelendiğinde BİST100'ün uzun dönemde kendi gecikmeli değeri ile %1 anlamlılık düzeyinde istatistiksel olarak anlamlı fakat negatif yönde, TÜFE ile ise pozitif bir uzun dönem ilişkisine sahip olduğu görülmektedir. Sonuçlara göre TÜFE'deki %1'lik bir değişimin BİST100'ü (0.067116) oranında pozitif yönde etkilediği tespit edilmiştir.

Tablo 8. ARDL (1,0) Modeli ile Tahmin Edilen Hata Düzeltme Katsayıları


| Değişkenler | Katsayı | Standart sapma | T istatistiği | Olasılık |
|-------------------------|---------|----------------|---------------|----------|
| Sabit | 0.0563 | 0.0141 | 3.9676 | 0.0001 |
| Hata düzeltme katsayısı | -0.0636 | -0.0191 | -3.3195 | 0.0011 |

Tablo 8 incelendiğinde ARDL (1,0) modelinin hata düzeltme katsayısı negatif ve istatistiksel olarak %1 anlamlılık düzeyinde anlamlıdır. Bu durum hata düzeltme modelinin sorunsuz işlediğini, modelin anlamlı olduğunu göstermektedir. Modelde hata düzeltme teriminin (-0.063699) olması kısa dönemdeki sapmaların (-0.063699) dönem sonrası tekrar uzun dönem dengesine ulaştığını göstermektedir.

Tablo 9. ARDL (1,0) Modelinin Tanımsal Test Sonuçları

| Test | Değer | Statistik | Olasılık |
|-------------------------------|---------------------|----------------------|---------------------|
| $R^2 \rightarrow$ | 0.046689 | X_{BGLM}^2 | 0.444407 (0.6418) |
| Düzeltilmiş $R^2 \rightarrow$ | 0.042452 | X_{ARCH}^2 | 1.688664 (0.1951) |
| F istatistiği (Olasılık) | 11.01945 (0.001052) | $X_{Jarque Berra}^2$ | 13.28530 (0.001304) |
| Durbin Watson \rightarrow | 2.043984 | $X_{Ramsey Reset}^2$ | 2.267619 (0.1335) |

Tablo 9’da ARDL (1,0) modelinin tanımsal test sonuçları sunulmuştur. Modelin bütününün anlamlılığı hakkında bilgi veren F istatistiği değerinin pozitif ve anlamlı olduğu görülmektedir. Serilerin durağanlığı hakkında bilgi veren Durbin Watson istatistiğinin 2.043984 ile 2’ye yakın bir değer olması serilerin birim kök içermeyebileceğini yani durağan olabileceklerini işaret etmektedir. R^2 ve ayarlanmış R^2 değerleri parametrelerin BİST100’deki değişimi sırasıyla % 0.046689 ve % 0.042452 oranında açıkladığını göstermektedir. Breuch-Godfrey LM serisel korelasyon, ARCH varyans ve Ramsey Reset testleri olasılık değerlerinin sırasıyla 0.6418, 0.1951 ve 0.1335 oldukları görülmektedir. Olasılık değerlerinin 0.05’ten büyük çıkması modelde değişen varyans ve otokorelasyon ve model kurma hatasının olmadığı göstermektedir. Jarque Berra normallik testinin olasılık değerinin $0.001304 < 0.05$ ’ten küçük çıkması serilerin normal bir şekilde dağılmadığını göstermektedir.



Şekil 2. CUSUM ve CUSUMSQ Grafikleri (BİST100 ve TÜFE)

Şekil 2’de değişkenlerin istikrar şartını yerine getirip getirmediğini test etmek için yapılan CUSUM ve CUSUMSQ testlerinden elde edilen grafikler incelendiğinde BİST100 ile TÜFE arasındaki etkileşimi tespit etmek için yapılan ARDL sınır testi ile tahmin edilen parametrelere ait uzun periyot katsayılarının CUSUM grafiğinde %5 anlamlılık düzeyinde ve %95 güven aralığını gösteren kırmızı kesikli çizgilerin içinde hareket ettiği ve herhangi bir yapısal kırılmanın olmadığı ve parametre tahmininin istikrar koşulunu sağladığı görülmektedir. CUSUMSQ testinde kırmızı kritik çizgileri aşan eylemler değişkende ya da oynaklıkta oluşan bir istikrarsızlığı işaret etmektedir. Kırmızı kritik çizgilerin üzerinde ya da kırmızı kritik değerleri aşan kırılmalar modelde bir yapısal kırılma olarak tespit edilmektedir. Modelde CUSUMSQ testi ile tespit edilen yapısal kırılma tarihleri hem BİST100-TÜFE hem de BİST100-TEFE grafiğinde 2008Q2 ile 2015Q3 arası dönem olarak tespit edilmiştir.

2.6. BİST ile TEFE Arası ARDL (1,0) Modeli ile Tahmin Edilen Eş bütünleşme Testi Sonuçları

BİST100 ile TEFE arası eş bütünleşme ilişkisi ARDL (1,0) modeli sınır testi ile hesaplanan F istatistiği değeri bağlamında incelenmiş ve %5 önem seviyesinde değerlendirilmiştir. Elde edilen sonuçlar aşağıdaki Tablo 10’da gösterilmiştir.

Tablo 10. ARDL (1,0) Modeli ile Tahmin Edilen F İstatistiği ve Kritik Değerler

| | K | M | F İst | Önem Seviyesi | Alt Sınır | Üst Sınır |
|------------|---|---|----------|---------------|-----------|-----------|
| ARDL (1,0) | 2 | 8 | 5.216501 | %10 | 4.04 | 4.78 |
| | | | | %5 | 4.94 | 5.73 |
| | | | | %1 | 6.84 | 7.84 |

Not: M; maksimum gecikme uzunluğu, K açıklayıcı değişken sayısını temsil etmektedir.

Tablo 10’da BİST100 ile TEFE arası uzun dönem ilişkisi incelendiğinde değişkenler arası uzun dönem etkileşimini gösteren F istatistiği değerinin Paseran, Shin ve Smith’in %5 ve %1 önem seviyesi için belirlemiş oldukları değerlerin üst sınırlarından küçük çıkması nedeniyle (5.21<5.73 ve 7.84) BİST100 ile TEFE arasında eş bütünleşme yoktur diyen sıfır hipotezi kabul edilmektedir. Bu durumda BİST100 ile TEFE’nin eşbütünleşik olmadığı sonucuna varılabilir. Dolayısıyla BİST100 ve TEFE endekslerinin birbirinin alternatifi olmadıklarını söylemek mümkündür.

Tablo 11. ARDL (1,0) Modeli ile Tahmin Edilen Uzun Dönem Katsayıları

| Değişkenler | Katsayı | Standart Sapma | t-istatistiği | Olasılık |
|-------------|-----------|----------------|---------------|----------|
| Sabit | -0.683181 | 0.309456 | -2.207680 | 0.0283 |
| BİST (-1) | -0.060213 | 0.018926 | -3.181482 | 0.0017 |
| TEFE | 0.059280 | 0.022700 | 2.611462 | 0.0096 |

Tablo 11’de ARDL (1,0) modeli elde edilen BİST100 ile TEFE arasındaki uzun dönem ilişkisine ait katsayılar ve olasılık değerleri sunulmuştur. Değişkenlere ait uzun dönem katsayıları incelendiğinde BİST100’ün TEFE ile ise %1 anlamlılık düzeyinde uzun dönemde pozitif bir ilişkiye sahip olduğu görülmektedir. Sonuçlara göre TEFE’deki %1’lik bir değişimin BİST100’ü (0.059280) oranında pozitif yönde etkilediği tespit edilmiştir.

Tablo 12. ARDL (1,0) Modeli ile Tahmin Edilen Hata Düzeltme Katsayıları

| Değişkenler | Katsayı | Standart Sapma | t-istatistiği | Olasılık |
|-------------------------|---------|----------------|---------------|----------|
| Sabit | -0.6831 | 0.2149 | -3.1784 | 0.0017 |
| Hata Düzeltme Katsayısı | -0.0602 | 0.0186 | -3.2372 | 0.0014 |


Hata düzeltme aygıtının çalışması için koşul hata düzeltme katsayısının negatif ve istatistiksel olarak anlamlı olmasıdır. ARDL (1,0) modeli ile modellenen hata düzeltme katsayısının koşulları sağladığı ve çalıştığı görülmektedir. Hata düzeltme terimi negatif ve anlamlı çıkması parametreler arası kısa dönemde oluşacak bir sapmanın (-0.060213) dönem sonra tekrar uzun dönem dengesine geleceği anlamına gelmektedir.

Tablo 13. ARDL (1,0) Modelinin Tanımsal Test Sonuçları

| Test | Değer | Statistik | Olasılık |
|-----------------------------|-----------------------|----------------------|-------------------|
| $R^2 \rightarrow$ | 0.044503 | X_{BGLM}^2 | 0.452968 (0.6363) |
| Düzeltilmiş R^2 | 0.040256 | X_{ARCH}^2 | 1.691522 (0.1947) |
| F istatistiği (Olasılık) | 10.47958 (0.00389) | $X_{Jarque Berra}^2$ | 1261120 (0.0018) |
| Durbin Watson \rightarrow | 2.044367 | $X_{Ramsey Reset}^2$ | 2.367364 (0.1253) |

Tablo 13’te ARDL (1,0) modelinin tanımsal test sonuçları görülmektedir. Modelde R^2 ve düzeltilmiş R^2 değerleri değişkenlerin BİST100’deki değişimi sırasıyla % 0.044503 ve % 0.040256 oranında açıkladığını göstermektedir. Modelin anlamlılığını gösteren F istatistiğinin pozitif ve anlamlı çıktığı görülmektedir. Serilerin durağanlığı hakkında bilgi sunan Durbin Watson istatistiğinin 2.044367 değeri ile 2’ye yakın bir değer çıkması serilerin birim kök içermeyebileceklerini işaret etmektedir. Breuch-Godfrey LM serisel korelasyon, ARCH değişen varyans ve Ramsey Reset testleri olasılık değerlerinin sırasıyla 0.6363, 0.1947 ve 0.1253 >0.05’ten büyük çıkması modelde değişen varyans, otokorelasyon ve model kurma hatasının olmadığını ifade etmektedir. Ayrıca Jarque Berra normallik testinin olasılık değerinin 0.001826<0.05’ten küçük çıkması kalıntıların normal dağılmadığını göstermektedir. Modelde seriler normal dağılım göstermezse de otokorelasyon, değişen varyans ve model kurma hatasının olmaması modelden sağlanan sonuçların güvenilir olduğu sonucuna varılabilir.

HİSSE SENEDİ GETİRİSİ VE ENFLASYON ORANI ARASINDAKİ İLİŞKİ: BORSA İSTANBUL ÖRNEĞİ



Şekil 3. CUSUM ve CUSUMSQ Grafikleri (BİST ve TEFE)

CUSUM&CUSUMSQ testleri serilerin istikrar koşulunu sağlayıp sağlamadıklarını test etmek için yapılır. Grafiklerde kırmızı kesikli çizgiler %95 güven aralığını göstermektedir. Düz çizgi ise parametre tahminlerini ifade etmektedir. BİST100 ile TEFE arasındaki etkileşim derecesini belirlemek için ARDL (1,0) modeli ile tahmin edilen değişkenlere ait uzun dönem katsayılarının CUSUM grafiğinde kırmızı kritik değerlerin içinde hareket ettikleri yapısal kırılmanın olmadığı görülmektedir. Ancak CUSUMSQ grafiğinde değişkenlere ait uzun dönem katsayılarının karelerinin %95 güven aralığını gösteren kırmızı kritik çizgiler içinde hareket etmedikleri kırılğan bir yapıda oldukları ve durağan olmadıkları görülmektedir. Bu durum değişkenlere ait uzun dönem katsayılarının istikrar koşulunu sağlamadıkları modelde yapısal kırılmanın olduğunu göstermektedir. CUSUMSQ grafiğinde bu yapısal kırılma tarihlerinin 2008Q2 ile 2015Q3 arası olduğu görülmektedir.

3. Sonuç Ve Öneriler

Hisse senedi getirileri ile enflasyon gibi makroekonomik değişkenler arasındaki uzun dönem ilişkisi yatırımcılar, yabancı sermaye yatırımları ve piyasa etkinliği açısından çok önemlidir. Çünkü piyasalarda işlem yapan çoğu yatırımcı hisse senedi yatırımlarını uzun vadeli yatırım olarak görmekte ve dolayısıyla uzun süre elde tutma eğilimindedir. Dolayısıyla pay fiyatları ile enflasyon arası uzun dönem etkileşimi hakkında bilgi sahibi olmak kazançlı bir yatırım için önem arz etmektedir.

Bu çalışmada BİST100 ile TÜFE ve TEFE endeksleri arasındaki uzun dönem ilişkisi ve dinamik etkileşim araştırılmıştır. Enflasyon gibi makroekonomik değişkenler işletmelerin kar oranı, gelecekteki nakit akışları, iş ve üretim faaliyetlerini etkileyerek hisse senedi fiyatını etkilemesi nedeniyle hisse senedi piyasaları üzerinde etkili olabilmektedir. Bu amaçla BİST100, TÜFE ve TEFE endeksleri analiz kapsamına alınmıştır. Analiz kapsamında incelenen BİST100, TÜFE ve TEFE endekslerinin 2003 ve 2021 dönemine ilişkin aylık kapanış endeks fiyatlarının logaritmik değerleri kullanılmıştır. Araştırmada parametreler arasındaki nedensellik ilişkisi Toda Yamamoto nedensellik testi ile araştırılmıştır.

BİST100 ile TÜFE ve TEFE endeksleri arasındaki uzun dönem ilişkisinin tespit edilmesinde Paseran, Shin ve Smith'in katkılarıyla daha önceki eş bütünleşme modellerindeki eksiklikleri gidermek için geliştirilen çok kullanışlı ve daha güvenilir sonuçlar veren bir eş bütünleşme yaklaşımı olan ARDL sınır testi tercih edilmiştir. Bu model ile test edilen parametrelerin bütünleşme dereceleri ve durağanlık durumları dikkate alınmaksızın zaman serileri arasındaki uzun dönem ilişkisi araştırılabilmektedir. Çalışmada kullanılan değişkenlere ait veriler TCMB veri tabanından alınmıştır. Toda Yamamoto

nedensellik testi ile TÜFE ve TEFE'den BİST100 endeksine doğru %1 önem seviyesinde tek yönlü bir nedensellik saptanmıştır.

BİST100 ile TÜFE, TEFE arasındaki eş bütünleşme derecesi ARDL (1,0) sınır testi tahmin edilmiş, elde edilen F istatistik değerlerinin Paseran vd tarafından %1 ve %5 önem düzeyi için hesaplanmış olan üst kritik değerlerin tamamından düşük çıkması nedeniyle değişkenlerin eşbütünleşik olmadıkları fakat uzun dönem katsayıları bağlamında pozitif ve anlamlı bir uzun dönem ilişkisi içinde oldukları tespit edilmiştir. Dolayısıyla uzun dönemde TÜFE ve TEFE'deki %1'lik değişimlerin BİST100'ü sırasıyla (0.067116) ve (0.059280) oranlarında pozitif yönde etkilediği saptanmıştır. Çalışmada değişkenler arasındaki eş bütünleşme ilişkisinin tespit edilmesinde tercih edilen ARDL modeli ve nedensellik testleri sonuçları hisse senedi fiyatları ile enflasyon arasında anlamlı ve pozitif bir uzun dönem ilişkisinin olduğunu göstermektedir.

Çalışmada elde edilen sonuçlar pay getirileri ile enflasyon değişkenleri arasında güçlü bir eş bütünleşme ilişkisinin olmadığı fakat enflasyonun pay getirileri üzerinde uzun dönemde anlamlı ve pozitif bir etkiye sahip olduğunu göstermektedir. Bu durum enflasyonun Borsa İstanbul'da yatırım akışını etkileyen ve BİST100'de işlem gören hisse senetlerinin getirisinde fark edilen yönü ve değişiklikleri belirleyen önemli bir makroekonomik değişken olduğu anlamına gelmektedir. Dolayısıyla bu çalışma enflasyonun hisse senedi getirileri üzerinde olumlu bir etkisi olduğunu belirten Fisher hipotezinin önermesini de doğrulamaktadır.

BİST100 ile TÜFE ve TEFE değişkenleri arasındaki eş bütünleşme derecesini tahmin eden ARDL kısa ve uzun periyot ilişkilerine ilişkin tanımsal testlerden ARDL modellerinde hata terimlerinin normal dağıldığı, model kurma hatası, otokorelasyon ve değişen varyansın olmadığı, modellerle tahmin edilen hata düzeltme katsayılarının negatif ve anlamlı olduğu saptanmıştır. Dolayısıyla modellerden elde edilen sonuçların güvenilir olduğu ve modellerin sorunsuz çalıştığı söylenebilir.

Ekonomi söz konusu olduğunda enflasyon arz ve talep taraflarındaki uyumsuzluğun bir sonucudur. Diğer bir ifade ile toplam arzın toplam talepteki artışı karşılayamamasıdır. Dolayısıyla enflasyon, gerekli mal ve hizmetlerin arzının artırılmasıyla kontrol altına alınabilir. Çalışmada elde edilen sonuçlar, ekonomistler, yatırım analistleri ve araştırmacılar arasında yaygın olarak kabul edilen inancı destekler nitelikte hisse senedi fiyatlarının enflasyonla ilgili değişimlere olumlu tepki verdiğini göstermektedir. Mevcut çalışma enflasyonun borsa getirileri üzerindeki etkisine açık bir şekilde ışık tutmaktadır, bu nedenle fon yöneticileri, finansal piyasa düzenleyicileri ve yatırımcılar gibi piyasa katılımcılarının beklenen enflasyon ve beklenmeyen enflasyon hakkındaki bilgilere dayanarak iyi portföy kararları almalarına yardımcı olabilir. Çalışma, borsa getirileri ile enflasyon arasında ters yönlü bir ilişki olduğunu teyit etmektedir. Politika yapımcılar da ekonomideki enflasyonist eğilimleri düzenlemek amacıyla ihtiyatlı para politikaları oluşturmak için mevcut bulgulardan bir ipucu elde edebilirler.

Yazar Katkı Oranı (Author Contributions): İbrahim Halil UÇAR (%50), Erkan ALSU (%50)

Yazarın Etik Sorumlulukları (Ethical Responsibilities of Authors): Bu çalışma bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır.

Çıkar Çatışması (Conflicts of Interest): Çalışmadan kaynaklı çıkar çatışması bulunmamaktadır.

İntihal Denetimi (Plagiarism Checking): Bu çalışma intihal tarama programı kullanılarak intihal taramasından geçirilmiştir.

KAYNAKÇA

- Adam.M.H.M. (2009). "Financial Markets: The Recent Experience of a Developing Economy, Savings and Development", *No 1, January 2009*, 27-40.
- Akçalı.Y.B, Mollaahmetoglu.E&Altay.E. (2019). "Türkiye'de Faiz, Enflasyon ve Kur Şoklarının Bulaşıcılığının ARMA-EGARCH Yöntemiyle Analizi". *İstanbul Gelişim Üniversitesi Sosyal Bilimler Dergisi*, 6, Ekim 2019, 29-43.
- Andrieş,A.M. (2009). The Importance of Capital Market in Economy, *CES Working Papers*, 1 (2), 69-75.
- Arwatchanakarn.P & Akhand.H.A. (2016). "Inflation and Inflation Volatility in Thailand". *Applied Economics*, Vol.48, No.30, 2792-2806.
- Bagh.T, Azad.T, Razzaq.S, Liaqat,İ&Khan.M.A. (2017). "The Impact of Exchange Rate Volatility on Stock Index: Evidence from Pakistan Stock Exchange (PSX)". *International Journal of Academic Research in Accounting, Finance and Management Sciences*, Vol.7, No.3, July 2017, 70-86.
- Bai.Z.(2014). "Study on the Impact of Inflation on the Stock Market in China". *International Journal of Business and Social Science Vol. 5, No. 7(1); June 2014*, 261-271.
- Baig, M.M, Aslam, W, Malik,Q&Bilal,M. (2016). "Volatility of Stock Markets (an Analysis of South Asian and G8 Countries)". *Economica Financial Institutions And Services*, Vol.11, No.6, 58-70.
- Choudhry.T. (2001). "Inflation and Rates of Return on Stocks: Evidence from High Inflation Countries". *Journal of International Financial Markets, Institutions and Money*, (11), 75-96.
- Duy,V.Q. (2016). "The Impact of Macroeconomic Factors on Stock Price Index, VN-Index, *IJSET*". *International Journal of Innovative Science, Engineering ve Technology*, Vol. 3 Issue 7, July 2016, 69-84.
- Gkilas.K., Tsagkanos.A&Vortelinos.D.(2019). "Integration and Risk Contagion in Financial Crises: Evidence from International Stock Markets". *Journal of Business Research*, 104 November (2019), 350-365.
- Gönüllü,O. (2020). "Borsa İstanbul ile Asya Pasifik Sermaye Piyasaları Arasındaki Eşbütünleşme Analizi: Panel ARDL Modeli". *Turkish Studies- Social Sciences*,15(2), 221-238.
- Hondroyiannis.G&Papaterou.E. (2006). "Stock Returns and Inflation in Greece: A Markov Switching Approach". *Review of Financial Economics* 15 (2006), 76-94
- John Khumalo. (2013). "Inflation and Stock Prices Interactions in South Africa: VAR Analysis". *International Journal of Economics and Finance Studies Vol.5, No.2*,23-34.
- Ibrahim,T.M&Agbaje,O.M. (2013). "The Relationship Between Stock Return and Inflation in Nigeria". *European Scientific Journal February 2013*, Vol.9, Issue.4,146-157.
- Isnandari,M.L&Chalid,D.A. (2017). "Stock Returns and Inflation: Evidence from Emerging Markets in Asia". *Indonesian Capital Market Review (9)*, 53-61.
- Ilorember.T.P, Sokpo,J.T&Terzungwe,U. (2017). "Inflation and Stock Market Returns Volatility: Evidence from the Nigerian Stock Exchange 1995Q1-2016Q4: An E-GARCH Approach". *International Journal of Econometrics and Financial Management*, Vol. 5, Issue. 2, 69-76

- Keun Yeong Lee (2008). "Causal Relationships Between Stock Returns and Inflation". *Applied Ekonomice Letters*, Vol.15, Issue.2, 125–129.
- Kim.S& Francis.I. (2005). "The Relationship Between Stock Returns and Inflation: New Evidence From Wavelet Analysis". *Journal of Empirical Finance* Vol.12, Issue.3, 435-444
- Özkan.N. (2015). "Türkiye’de Enflasyon, Hisse Senedi Getirileri ve Reel İktisadi Faaliyetler Arasındaki İlişkilerin İncelenmesi". *Bankacılar Dergisi*, Sayı.94, Cilt.26, 81-94.
- Rehan.R, Zehrab.I, Chhaprac.I.U&Pooja.M. (2019). "The Relationship Between Exchange Rate and Stock Prices in South Asian Countries". *International Journal of Innovation, Creativity and Change*. Volume 6, Issue 9, 113-135.
- Sathyanarayana. S&Gargesa. S. (2018). "An Analytical Study of the Effect of Inflation on Stock Market Returns". *IRA-International Journal of Management & Social Sciences*, Vol.13, Issue. 02 November,2018, 48-64.
- Spyros.I. (2001). "Stock Returns And Inflation: Evidence From An Emerging Market". *Applied Economics Letters*, Vol.8, 447-450.
- Uçan.O, Güzel.F&Melek.M. (2017). "Makroekonomik Göstergelerin Borsa Endeksi Üzerine Etkisi: Panel Veri Analizi ile Borsa İstanbul’da Bir Uygulama". *Muhasebe Bilim Dünyası Dergisi Haziran 2017; 19(2)*, 509-523.

İnternet

1. <https://www.tcmb.gov.tr/wps/wcm/connect/EN/TCMB+EN/Main+Menu/Core+Functions/Monetary+Policy/PRICE+STABILITY+AND+INFLATION/Reasons+for+Inflation> (Erişim Tarihi:20.04.2023)
2. <https://data.oecd.org/price/inflation-cpi.htm> (Erişim Tarihi: 26.04.2023)

EXTENDED ABSTRACT

The long-run relationship between stock returns and macroeconomic variables such as inflation is very important for investors, foreign capital investments and market efficiency. This is because most investors who trade in the markets consider stock investments as long-term investments and therefore tend to hold them for a long time. Therefore, having information about the long-run interaction between stock prices and inflation is important for a profitable investment.

This study investigated the long-run relationship and dynamic interaction between BIST100 and CPI and WPI indices. Macroeconomic variables such as inflation can have an impact on stock markets as they affect the profit rate, future cash flows, business and production activities of enterprises and affect the stock price. For this purpose, BIST100, CPI and WPI indices were included in the scope of the analysis. The logarithmic values of the monthly closing index prices of the BIST100, CPI and WPI indices for the period between 2003 and 2021 were used in the analysis. In the study, the causality relationship between the parameters was investigated by Toda Yamamoto causality test.

In determining the long-run relationship between BIST100 and CPI and WPI indices, ARDL bounds test was preferred which is a very useful and more reliable co-integration approach developed by Paseran, Shin and Smith to overcome the deficiencies in previous co-integration models. With this model, the long-run relationship between time series can be investigated regardless of the degree of integration and stationarity of the parameters tested. The data on the variables used in the study are taken from the CBRT database. The Toda Yamamoto causality test revealed a unidirectional causality from CPI and WPI to BIST100 index at 1% significance level.

The degree of cointegration between BIST100 and CPI, WPI was estimated using the ARDL (1,0) bounds test, and since the F statistic values obtained were lower than the upper critical values calculated by Paseran et al. for 1% and 5% significance levels, it was determined that the variables were not cointegrated but had a positive and significant long-run relationship in terms of long-run coefficients. In the long run, 1% changes in CPI and WPI positively affect BIST100 by (0.067116) and (0.059280), respectively. The results of the ARDL model and causality tests, which are preferred in determining the cointegration relationship between the variables in the study, show that there is a significant and positive long-run relationship between stock prices and inflation.

The results of the study show that there is no strong cointegration relationship between equity returns and inflation variables, but inflation has a significant and positive effect on equity returns in the long run. This implies that inflation is an important macroeconomic variable that affects investment flows in Borsa Istanbul and determines the direction and changes in the returns of stocks traded in BIST100. Therefore, this study also confirms the premise of the Fisher hypothesis, which states that inflation has a positive effect on stock returns

In the ARDL models that estimate the degree of co-integration between BIST100 and CPI and WPI variables, it is found that the error terms in the ARDL models are normally distributed, there was no model fitting error, autocorrelation and changing variance, and the error correction coefficients estimated by the models were negative and significant. Therefore, it can be said that the results obtained from the models are reliable and the models run smoothly.

When it comes to the economy, inflation is the result of a mismatch between the supply and demand sides. In other words, it is the inability of aggregate supply to meet the increase in aggregate

demand. Therefore, inflation can be controlled by increasing the supply of necessary goods and services. The results of the study support the widely accepted belief among economists, investment analysts and researchers that stock prices respond positively to changes in inflation. The current study clearly sheds light on the impact of inflation on stock market returns, so it can help market participants such as fund managers, financial market regulators and investors to make good portfolio decisions based on information about expected inflation and unexpected inflation. The study confirms that there is an inverse relationship between stock market returns and inflation. Policy makers can also take a cue from the present findings to formulate prudent monetary policies to regulate inflationary trends in the economy.

AIZANOI FINANCE REVIEW

ISSUE: 2 / 2023

www.aizanoifr.com

info@aizanoifr.com

SERMAYE PİYASASI KANUNU'NUN 106. MADDESİNDE DÜZENLENEN BİLGİ SUİSTİMALİ SUÇU

ARTICLE 106 OF CAPITAL MARKET CODE: INFORMATION ABUSE CRIME

Afra Akgül*,

* Bilecik Şeyh Edebali Üniversitesi İktisadi ve İdari Bilimler Fakültesi, Siyaset Bilimi ve Kamu Yönetimi Bölümü, Hukuk Bilimleri Anabilim Dalı, av.akgulafra@gmail.com, ORCID: 0000-0003-1786-8757

| MAKALE BİLGİSİ | ÖZ |
|---|--|
| Gönderilme Tarihi 01.03.2023 Revizyon Tarihi 27.03.2023 Kabul Tarihi 20.10.2023 Makale Kategorisi Araştırma Makalesi | Sermaye piyasaları, ekonominin bir parçasıdır. Piyasaların etkin şekilde çalışması ve güvenilirliği yatırımcılar ve ülke ekonomisinin menfaatleriyle yakın ilişki içerisindedir. Bu anlamda sermaye piyasalarındaki faaliyetlerin artması, beraberinde borsa manipülasyonlarını da arttırmaya başlamıştır. Bu çalışmada da söz konusu manipülasyonların suç olarak düzenlendiği 6362 sayılı Sermaye Piyasası Kanunu'nun 106. maddesinde düzenlenen bilgi suistimali suçu incelenecektir. Anahtar Kelimeler: Manipülasyon, Bilgi Suistimali Suçu, Sermaye Piyasaları, Sermaye Piyasası Kanunu |
| JEL Kodları K10 K20 K30 | |

| ARTICLE INFO | ABSTRACT |
|--|---|
| Received 01.03.2023 Revized 27.03.2023 Accepted 20.10.2023 Article Classification: Research Article | Capital markets are part of the economy. The effective functioning and reliability of the markets are in close relationship with the interests of investors and the country's economy. In this sense, the increase of activities in the capital markets also started the increase of the manipulations of the stock market. In this study, the crime of information abuse, which is enacted in Article 106 of the Capital Market Code no. 6362 that regulates the mentioned manipulations as a crime, will be examined. Keywords: Manipulation, Information Abuse Crime, Capital Markets, Capital Market Code |
| JEL Codes K10 K20 K30 | |

Atf (Citation): Akgül, A. (2023). "Sermaye Piyasası Kanunu'nun 106. Maddesinde Düzenlenen Bilgi Suistimali Suçu", *Aizanoi Finance Review*, (2): 77-86



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

Giriş

Sermaye piyasasında yapılan işlem sayısı her geçen gün artmaktadır. İşlem yapan kişiler; ilk bakışta ekonomik çıkarları doğrultusunda emir veren, alım – satım yapan kişiler olsalar da söz konusu kişilerin arasında piyasa manipülasyonları yapanlar ya da piyasanın güvenilir şekilde çalışmasını engelleyen kişiler de bulunmaktadır ve bu durum da gün geçtikçe artma eğilimi göstermektedir. Doğal bir sonuç olarak bu durumla mücadele etme ihtiyacı da artmıştır ve Sermaye Piyasası Kanunu'nda (SerPK) öngörülen hükümler ile bu manipülatif eylemler suç olarak düzenlenmiştir. Yürürlükteki 6362 sayılı SerPK'de iki temel sermaye piyasası suçu düzenlenmiştir. Bu suçlar; bilgi suiistimali ve manipülasyon suçudur. Bu çalışmada da sermaye piyasası suçlarından bilgi suiistimali suçu; suçun konusu, faili, mağduru, maddi ve manevi unsurları, ortaya çıkış biçimleri, muhakeme ve yaptırımı ve zamanaşımı başlıkları altında incelenecektir.

1. Bilgi Suistimali Suçunun Genel Esasları

Bilgi suiistimali suçunun oluşmasına neden olan durum, piyasayı etkileyebilecek önemli bir bilginin kamuya duyurulmasından önce, bu bilgi sayesinde bir işlem yapılarak kâr ya da kazanç sağlanmasıdır¹. Zira piyasa değerinin etkilenebileceği her türlü bilgi halka duyurulmak zorundadır. Bu husus, güven unsuru temeline kurulmuş olan sermaye piyasası için önemlidir. SerPK'de hüküm altına alınmış olan bilgi suiistimali suçundaki ekonomik anlamda temel unsur, üzerinde genel olarak alım – satım emri verilebilecek mal varlığı değerleri hakkında birinin önceden daha fazla bilgiye sahip olmasıdır.

1.1. Konu

1.1.1. Hukuki Konu

Bilgi suiistimali suçunun düzenlenişi ile korunması amaçlanan hukuki menfaat; piyasada işlem yapan her kimsenin fırsat eşitliğine sahip olması, piyasanın güvenilirliğinin korunması, piyasanın düzenli ve düzgün biçimde işlenmesidir². Nitekim suç normunun düzenleniş şekline ve düzenlendiği yere bakıldığında, bilgi suiistimali suçunun hukuki konusunun piyasanın düzenli ve düzgün biçimde faaliyet göstermesindeki toplum menfaati olduğu ortaya çıkacaktır³.

1.1.2. Maddi Konu

Bilgi suiistimali suçunda hareket; alım – satım emri, emir değişikliği ya da emir iptali gibi işlemler olduğundan, bu işlemler sermaye piyasası araçları üzerinde yapılabilmektedir⁴. Dolayısıyla bilgi suiistimali suçunun maddi konusunu sermaye piyasası araçları oluşturmaktadır⁵. Öğretide bu suçun maddi konusunun sermaye piyasası araçları değil, bilgi olduğu yönünde de görüşler bulunmaktadır⁶.

1.2. Mağdur

Suçun mağduru ya da diğer bir ifadeyle suçun pasif süjesi; ceza normunda suçun hukuki konusunu oluşturmakta olan ve norm ile korunmakta olup da suç tarafından ihlal edilen, hukuki varlık ya da

¹ Gündoğdu, Aysel. "Türk Sermaye Piyasasında Bilgi Suistimali ve Piyasa Dolandırıcılığı Suçu Düzenlemelerinin İrdelenmesi", Maliye Finans Yazıları, Yıl 2017, Sayı 108, s. 13.

² Okuyucu Ergün, Güneş. "Bilgi Suistimali Yasağının Muhatabı", Banka ve Ticaret Hukuku Dergisi, Yıl 2021, Cilt XXXVII, Sayı 1, s. 8.

³ Okuyucu Ergün, s. 8.

⁴ Duman, Buminhan. "Türk Sermaye Piyasası Hukukunda Bilgi Suistimali (İçeriden Öğrenenlerin Ticareti) Suçu". Kırıkkale Hukuk Mecmuası 2 (2022), s. 393.

⁵ Okuyucu Ergün, s. 22.

⁶ Arslan, Çetin. – Özdemir, Didar. Türk Ceza Hukukunda Bilgi Suistimali Suçu, International Conference On Eurasian Economies, Session 2D: Hukuk, 2018, s. 406.

menfaatin sahibi ya da hamilidir⁷. Bu nedenle suçun mağduru kavramının tanımı, suçun hukuki konusu ile ilişki içindedir. Bilgi suistimali suçuna vücut veren işlemin niteliği hakkında bilgisi veya haberi olmayan ve bu bilgisizlik ve habersizlik içerisinde piyasada işlem yapan gerçek veya tüzel kişiler, bilgi suistimali suçunun mağduru olacaklardır⁸.

Bilgi suistimali suçunun mağdur sayısı, kamuya açıklanmayan esaslı bilginin ne kadar çok kişiye ulaştığıyla doğru orantılıdır⁹. Diğer bir deyişle, sermaye piyasasının kamusal niteliğinden dolayı, piyasanın etkin şekilde işlerlik göstermesine ve güvenilirliğine dair menfaati olanlar ve dolayısıyla toplum, bu suçun mağduru¹⁰. Söz konusu suç sebebiyle menfaatleri dolaylı biçimde zarara uğrayan kimseler, suçtan zarar gören sıfatını taşıyacaklardır¹¹.

1.3. Fail

Suçun faili ya da diğer bir ifadeyle suçun aktif süjesi; ceza hukukunda hukuka aykırı fiili gerçekleştiren gerçek kişidir¹². Her suçun bir faili olmakla birlikte¹³, özgü suçlar olarak ifade edilen bazı suç tiplerinde ise suçun işlenebilmesi için failin, o suçun kanuni düzenlemesinden kaynaklanan özel bir sıfatının olması gerekir¹⁴. Bilgi suistimali suç, bir özgü suç olmayıp herkes tarafından işlenebilen bir suçtur¹⁵.

SerPK md. 106 hükmünde bilgi suistimali suçunun failinin kimler olabileceği yazılmıştır. Anılan düzenlemeye göre; *“a) ihraççıların veya bunların bağlı veya hâkim ortaklıklarının yöneticileri, b) ihraççıların veya bunların bağlı veya hâkim ortaklıklarında pay sahibi olmaları nedeniyle bu bilgilere sahip olan kişiler, c) iş, meslek ve görevlerinin icrası nedeniyle bu bilgilere sahip olan kişiler, bu bilgileri suç işlemek suretiyle elde eden kişiler, d) sahip oldukları bilginin bu fıkrafta belirtilen nitelikte bulunduğunu bilen veya ispat edilmesi hâlinde bilmesi gereken kişiler”* bilgi suistimali suçunun faili olabileceklerdir¹⁶.

Suçun faili olacak olan içerden öğrenen kişinin kim olabileceği ikili bir ayrıma tabi tutulmuştur¹⁷. Bu ayrıma göre, işi veya mesleği ya da statüsü uyarınca doğrudan erişme imkanı ile içerden bilgi öğrenenler birinci derece içerden öğrenen olmaktadır. Bilgiye doğrudan erişme imkanı olmamasına rağmen içerden bilgi öğrenenler ise ikinci derece içerden öğrenen kişi olarak tanımlanmıştır. İçerden öğrenen sıfatı, öğretide anıldığı şekilde ayrıma tutulsa da SerPK md. 106 hükmü uyarınca verilecek

⁷ Toroslu, Nevzat. Cürümlerin Tasnifi Bakımından Suçun Hukuki Konusu, Savaş Yayınevi, Ankara, 2019, s. 56; Hafizoğulları, Zeki. – Özen, Muharrem. Türk Ceza Hukuku Genel Hükümler, US-A Yayıncılık, 11. Baskı, Ankara, 2018, s. 208; Toroslu - Toroslu, s. 114; Orhan, Uğur. “Manipülasyon (Piyasa Dolandırıcılığı) Suçu”, DEÜHFD, 2021; 23(2), s. 1646; Katoğlu, Tuğrul. “Ceza Hukukunda Suçun Mağduru Kavramının Sınırları”, AÜHFD, C. 61, S. 2, Y. 2012, s. 657 vd.

⁸ Arslan, Abdullah. Sermaye Piyasası Hukukunda İçerden Öğrenenlerin Ticareti, AÜSBE, Yayınlanmış Doktora Tezi, Ankara, 2021, s. 235.

⁹ Arslan, s. 235.

¹⁰ Arslan – Özdemir, s. 407.

¹¹ Usluadam, Asena Kamer. “Bilgi Suistimali Suçu”, Anadolu Üniversitesi Hukuk Fakültesi Dergisi, 5 / 1 (Kasım 2019), s. 238; Uğraş, Dilek Özge. “Bilgi Suistimali Suçu (İçerden Öğrenenlerin Ticareti Suçu)”, TAAAD, Yıl: 12, Sayı: 47, 2021, s. 469.

¹² Doktrinde hakim görüş tüzel kişilerin cezaî sorumluluk altında olmadığını kabul etmektedir. Bu yönde bkz. Hafizoğulları – Özen, s. 375-376; Centel, Nur. – Zafer, Hamide. – Çakmut, Özlem. Türk Ceza Hukukuna Giriş, Beta, 11. Baskı, İstanbul, 2020, s. 253; Toroslu - Toroslu, s. 107. Aksi yönde bkz. Yalçın, Türkan. – Köprülü, Timuçin. Ceza Hukuku Genel Hükümler Uygulamalı Çalışmaları. Savaş Yayınevi, Ankara, 6. Baskı, 2019, s. 156.

¹³ Hafizoğulları – Özen, s. 373; Toroslu, s. 55.

¹⁴ Özbek, Veli Özer. Ekonomi Ceza Hukuku Birinci Kitap Genel Hükümler, Seçkin Yayıncılık, 3. Baskı, Ankara, 2021, s. 67; Toroslu, s. 54.

¹⁵ Okuyucu Ergün, s. 18 vd.

¹⁶ Kanuni düzenlemede fail olarak sayılan kişilerin sınırlı sayıda sayılmadığı, bu kişilerin örnek niteliğinde olup somut olayın özelliklerine göre kanunda sayılmış örnekler dışındaki kişilerin de suçun faili olabileceğine dair görüşler için bkz. Memiş, Tekin. – Turan, Gökçen. Sermaye Piyasası Hukuku, Seçkin Yayıncılık, 6. Baskı, Ankara, 2022, s. 216; Arslan, s. 234;

¹⁷ Arslan, s. 234.

cezada, içerden öğrenenin birinci derece ya da ikinci derece olmasının bir önemi bulunmamaktadır¹⁸.

2. Suçun Unsurları

2.1. Maddi Unsur

2.1.1. Davranış

Bilgi suistimali suçunun hangi hareketlerle ortaya çıkacağı SerPK md. 106'da düzenlemiştir. Bu bağlamda, sermaye piyasası araçları için alım – satım emri, emir değişikliği ya da emir iptali gibi işlemler ile kendine veya bir başkasına menfaat sağlandığında, bilgi suistimali suçuna vücut verilmiş sayılmaktadır¹⁹. Söz konusu suç, SerPK md. 106'nın lafzından anlaşıldığına göre farklı biçimlerde de gerçekleşebilecektir. Diğer bir ifadeyle SerPK md. 106 hükmü, bilgi suistimali suçunun oluşumunda seçimlik hareketler öngörmüştür²⁰.

Söz konusu hareketlerden bir tanesinin ya da bunlardan bazılarının yapılmasıyla suç işlenebilir; ancak birden fazla seçimlik hareketle suçun işlenmesi, suçun tekliğini değiştirmeyecektir²¹. Dolayısıyla SerPK md. 106 hükmünde sayılan seçimlik hareketlerden birinin ya da birden fazlasının gerçekleşmesi sadece bir kez bilgi suistimali suçu işlenmiş olacaktır²².

Örneğin, içerden öğrenilen bilgi ile bir pay senedi satın alındığında ve söz konusu pay senedinin değeri belirli bir seviyeye geldikten sonra satıldığında iki ayrı suç oluşmayacaktır²³. Bilgi suistimali suçu, sadece SerPK'da düzenlenmiş olan hareketlerle işlenebilecektir. Bu anlamda suçun bağlı hareketli bir suç olduğu söylenebilir²⁴.

2.1.2. Netice

Bilgi suistimali suçunun tamamlanabilmesi için suç ile menfaat elde edilmesi gerekmektedir²⁵. Suçun neticeli bir suç olduğu ve netice için bir menfaatin ortaya çıkması koşulu belirlendiğinde, söz konusu menfaat ortaya çıkmadığı hallerde, kişi hakkında teşebbüs hükümlerinden sorumluluğuna gidilmesi ihtimali ortaya çıkabilecektir²⁶.

Suç sonucunda elde edilmesi gereken menfaat, sadece failin kendi namına elde ettiği maddi bir menfaat değil; üçüncü kişi yararına elde edilen bir menfaat de olabilir²⁷. Bilgi suistimali neticesinde herhangi bir zarardan kurtulma durumu ortaya çıkmışsa, bu husus da menfaat elde etme kapsamında değerlendirilecektir²⁸.

2.1.3. Nedensellik Bağı

Bir bilginin bilgi suistimali suçuna vücut verecek nitelikte içerden öğrenilen bir bilgi olarak değerlendirilmesi için SerPK md. 106 hükmünde birtakım özellikler öngörülmüştür. Anılan düzenlemeye göre *“doğrudan ya da dolaylı olarak sermaye piyasası araçları ya da ihraççılar*

¹⁸ Usludam, s. 235.

¹⁹ Memiş – Turan, s. 215; Arslan, s. 235.

²⁰ Usludam, s. 239.

²¹ Hafizoğulları – Özen, s. 188.

²² Okuyucu Ergün, s. 113.

²³ Arslan, s. 235.

²⁴ Usludam, s. 239.

²⁵ Usludam, s. 243.

²⁶ Buna karşın menfaat temini, objektif cezalandırılabilme koşulu olarak değerlendirildiğinde; SerPK'da düzenlenen içerden öğrenenlerin ticareti suçu bakımından belirlenen fiillerin icrası sonucu menfaat temin edilemediyse sorumluluk söz konusu olmayacağına dair bkz. Usludam, s. 244; Arslan, s. 237.

²⁷ SerPK md. 106; Arslan, s. 237.

²⁸ Arslan, s. 237.

hakkında, ilgili sermaye piyasası araçlarının fiyatlarını, değerlerini veya yatırımcıların kararlarını etkileyebilecek nitelikteki ve henüz kamuya duyurulmamış” bilgiler, bilgi suistimali suçuna vücut verebilecek türde içerden öğrenilen bilgi niteliğini taşıyacaktır. Bu kategoride olmayan bilgiler, suçun oluşumu için gereken tipiklik unsurunun gerçekleşmesini önleyeceklerinden, içerden öğrenilen bilgi sıfatını taşımayacaktır²⁹.

2.2. Manevi Unsur

Bilgi suistimali suçunun manevi unsuru, 2499 sayılı mülga SerPK'nın md. 47A-1 hükmüne göre *“kendisine veya üçüncü kişilere menfaat sağlamak amacıyla”* ifadesinden ötürü özel kastı³⁰. Ancak 6362 sayılı SerPK'nın md. 106 hükmünde menfaat temini bir amaç olarak düzenlenmediğinden, bilgi suistimali suçunun manevi unsuru için genel kast yeterli olacaktır³¹.

2.3. Hukuka Uygunluk Nedenlerinin Bulunmaması

Türk Ceza Kanunu'nun md. 24 ve devamındaki hükümlerde düzenlenen hukuka uygunluk nedenlerinin yanı sıra SerPK md. 108 hükmünde, bilgi suistimali suçuna özel hukuka uygunluk nedenleri düzenlenmiştir. Buna göre aşağıdaki hâller bilgi suistimali suçuna vücut vermeyecektir:

“a) TCMB ya da yetkilendirilmiş başka bir resmî kurum veya bunlar adına hareket eden kişiler tarafından para, döviz kuru, kamu borç yönetim politikalarının uygulanması veya finansal istikrarın sağlanması amacıyla işlem yapılması

b) Kurul düzenlemelerine göre uygulanan geri alım programları, çalışanlara pay edindirme programları ya da ihraççı veya bağlı ortaklığının çalışanlarına yönelik diğer pay tahsis edilmesi

c) Kurulun bu Kanun kapsamındaki fiyat istikrarını sağlayıcı işlemlere ve piyasa yapıcılığına ilişkin düzenlemelerine uygun olarak icra edilmeleri kaydıyla, münhasıran bu araçların piyasa fiyatının önceden belirlenmiş bir süre için desteklenmesi amacıyla sermaye piyasası araçlarının alım veya satımının yapılması yahut emir verilmesi veya emir iptal edilmesi.”

3. Suçun Ortaya Çıkış Biçimleri

3.1. Teşebbüs

Tamamlanmamış suçlara ilişkin TCK md. 35 hükmü gereğince teşebbüs kurumu gündeme gelebilmektedir. Tamamlanmayan her suç bakımından teşebbüs hükümlerinin uygulanacağını söylemek doğru olmamakla birlikte, bilgi suistimali suçunda teşebbüsün cezalandırılabilmesi kabul edilmektedir³². Suçun hazırlık ve icrai hareketleri gerçekleştikten sonra, menfaat temini neticesi oluşmasa dahi, kişi hakkında teşebbüs kurumu uygulama alanı bulabilecektir³³. Nitekim bilgi suistimali suçunun kanuni düzenlemesinde yer alan menfaat elde etme; suç tipinin ağırlaştırıcı bir nedeni değil, suçun maddi unsurunun bir parçasıdır³⁴.

Öte yandan TCK md. 36 hükmünde gönüllü vazgeçme kurumu düzenlemektedir. Buna göre: *“fail,*

²⁹ Usludam, s. 240. Ayrıca içerden öğrenilen bir bilginin SerPK md. 106 hükmü bağlamında, doğrudan ihraççı ya da sermaye piyasası aracı ile ilgili olmayan; ancak, sermaye piyasalarını etkileme kapasitesine sahip bilgilerin de içerden öğrenilen bilgi olarak değerlendirilmesi gerektiği hakkında bkz. Arslan, s. 236. Örneğin bu görüşe göre hükümetin uygulamaya koyacağı sermaye piyasalarını etkileme kapasitesine sahip politikaların uygulamaya konulmadan önce öğrenilmesi durumunda edinilen bilginin içerden öğrenilen bilgi olarak değerlendirilmesi gerekmektedir.

³⁰ Özel kast hakkında bkz. Hafizoğulları - Özen, s. 251 vd.

³¹ Karakehya, Hakan. İradilik Unsuru Bağlamında Ceza Hukukunda Kast, Ankara: Savaş 2010, s. 24. Taksirli suçların cezalandırılabilmesi için kanunda açıkça düzenlenmeleri gerektiğinden ve bilgi suistimali suçunun taksirli hali açıkça düzenlenmediğinden bu suç taksirle işlenemez.

³² Usludam, s. 248.

³³ Hafizoğulları - Özen, s. 304 vd.; Toroslu - Toroslu, s. 270 vd.; Usludam, s. 248.

³⁴ Memiş - Turan, s. 216, dp. 323.

suçun icra hareketlerinden gönüllü vazgeçer veya kendi çabalarıyla suçun tamamlanmasını veya neticenin gerçekleşmesini önlerse, teşebbüsten dolayı cezalandırılmamakta; fakat tamam olan kısım esasen bir suç oluşturduğu takdirde, sadece o suçta ait ceza ile cezalandırılmaktadır”. Gönüllü vazgeçme kurumunun özellikleri, bilgi suistimali suçuna somut olayın özellikleri elverdiği sürece uygulanabilecektir.

3.2. İştirak

Soyut anlamda, bir kimsenin tek başına suçu işlemek suretiyle ihlal edebileceği bir norm, başka kimselerle bir araya gelinerek ihlal edilmişse suçta iştirak söz konusu olur³⁵. Bilgi suistimali suç bakımından da TCK’de düzenlenen iştirak hükümleri uygulama alanı bulabilecektir³⁶.

3.3. İçtima

3.3.1. Fikri İçtima

Suçların içtimaı, bilgi suistimali suç için gerçek içtima şeklinde tezahür edebilir³⁷. Özel norm-genel norm ilişkisi dikkate alınarak, bu görünüşte çatışma durumu çözüme kavuşacaktır. SerPK ile TCK arasında da özel norm - genel norm ilişkisi mevcut olduğundan, anılan örnek suçlar yönünden SerPK özel norm niteliğinde olacaktır.

3.3.2. Zincirleme Suç

Zincirleme suç; birden çok kez aynı suçun, aynı kişiye karşı, farklı zamanlarda, suç işleme kararındaki birlik doğrultusunda işlendiği hallerde ortaya çıkmaktadır³⁸. Zincirleme suç, TCK md. 43’te düzenlenmiştir. Bilgi suistimali suçunun kanuni tanımında belirtilen seçimlik hareketlerden birden fazlasının işlenmesi halinde zincirleme suç hükümleri uygulanmayacaktır. Bu durumda tek fiil ve tek suç mevcut olacaktır.

4. Muhakeme ve Yaptırım

Bilgi suistimali suçunun soruşturulmasına ilişkin hüküm, SerPK md. 115’te³⁹ yer almaktadır. Anılan düzenlemeye göre SerPK’de düzenlenmiş olan suçlar bakımından soruşturma yapılabilmesi için Cumhuriyet Başsavcılığına yazılı olarak Kurul tarafından başvurulması gerekmektedir. Söz konusu başvuru, bu suç bakımından muhakeme şartı olarak belirlenmiştir⁴⁰. Kovuşturma evresinde uyuşmazlığı görecek olan, diğer bir ifadeyle görevli mahkeme ise SerPK md. 116⁴¹ hükmünde

³⁵ Detaylı bilgi için bkz. Toroslu – Toroslu, s. 322 vd; Centel – Zafer – Çakmut, s. 486 vd.

³⁶ Hafizoğulları - Özen, s. 324 vd.; Arslan, s. 239.

³⁷ Okuyucu Ergün, s. 22; Örneğin “güveni kötüye kullanma” ya da “ticari sır, bankacılık sırrı veya müşteri sırrı niteliğindeki bilgi veya belgelerin açıklanması” suçu bakımından, iki normun da ihlal edilmiş olabileceği ihtimali akıllara gelse de bu durumdaki çatışmanın görünüşte olduğuna ilişkin olarak bkz. Usluadam, s. 249.

³⁸ Hafizoğulları – Özen, s. 360 vd.

³⁹ SerPK m. 115: “(1) Bu Kanunda tanımlanan veya atıfta bulunulan suçlardan dolayı soruşturma yapılması, Kurul tarafından Cumhuriyet başsavcılığına yazılı başvuruda bulunulmasına bağlıdır. Bu başvuru muhakeme şartı niteliğindedir.

(2) Başvuru üzerine kamu davası açılması hâlinde iddianamenin kabulü ile birlikte, bir örneği Kurula tebliğ edilir ve Kurul aynı zamanda katılan sıfatını kazanır.

(3) Bu Kanunda tanımlanan veya atıfta bulunulan suçlardan dolayı yapılan soruşturmada Cumhuriyet savcısı, Kurul meslek personelinden yararlanabilir. Bu suçlardan dolayı şüpheli veya tanık sıfatıyla kişilerin ifadesinin alınması sırasında Kurul meslek personelinin de hazır bulunması sağlanabilir.

(4) Bu Kanunda tanımlanan veya atıfta bulunulan suçlardan dolayı yapılan soruşturmada kovuşturmaya yer olmadığı kararının verilmesi hâlinde, Kurul bu karara karşı itiraza yetkilidir.

(5) 4/5/2007 tarihli ve 5651 sayılı *İnternet Ortamında Yapılan Yayınların Düzenlenmesi ve Bu Yayınlar Yoluyla İşlenen Suçlarla Mücadele Edilmesi Hakkında Kanunun 8 inci maddesi, 109 uncu maddede yer alan suçlar bakımından da uygulanır.*”

⁴⁰ Çoşkun, s. 230.

⁴¹ SerPK m. 116: “(1) Bu Kanunda tanımlanan veya atıfta bulunulan suçlardan dolayı yargılama yapmaya Hâkimler ve Savcılar Yüksek Kurulunun ihtisas mahkemesi olarak görevlendireceği asliye ceza mahkemeleri yetkilidir.”

düzenlenmiş olup bu mahkeme, asliye ceza mahkemeleridir. Ancak hangi asliye ceza mahkemesi olacağı hususu, Hakimler ve Savcılar Kurulu'nun ihtisas mahkemesi olarak bir mahkemeyi görevlendirilmesiyle çözülecektir.

5. Zamanaşımı

Dava zamanaşımı süresi, TCK'nın dava zamanaşımı başlıklı md. 66/1 hükmünde düzenlenmiştir. Anılan normun (e) bendinde; *"beş yıldan fazla olmamak üzere hapis veya adlî para cezasını gerektiren suçlarda sekiz yıl geçmesiyle kamu davasının düşeceği"* yer alır. Dava zamanaşımının belirlenmesinde, suça ilişkin öngörülen cezanın üst sınırı göz önünde bulundurulur⁴². Kanun hükmünde birden çok türde seçimlik cezaların bulunduğu suç tiplerinde ise TCK md. 66/4 hükmü uyarınca söz konusu hükümde yer alan hapis cezası, zamanaşımının belirlenmesinde esas alınacaktır⁴³.

Dava zamanaşımının durmasına ilişkin olarak TCK md. 67 hükmü gündeme gelecektir. Dava zamanaşımının durduğu hallerde, bu durmanın ne zaman son bulacağı anılan hükümde yer almamakla birlikte, dava zamanaşımı süresinin ne zaman durmuş olacağına ilişkin de herhangi bir düzenleme mevcut değildir. Öğretideki baskın görüş, Savcılığın yetkili mercie izin ya da karar için başvurduğu günden itibaren zamanaşımının duracağı yönündedir⁴⁴.

Bilgi suistimali suçu bakımından, suçun işlendiği tarihten itibaren zamanaşımı işlemeye başlar ve bu süre Savcılık tarafından Kurul'a soruşturma izni için başvurulduğu tarihte durur⁴⁵. Söz konusu izin ya da karar işlemi hukuka uygun biçimde tamamlandığı tarihte ise zamanaşımı kaldığı yerden işlemeye devam eder⁴⁶. Dolayısıyla TCK md. 67/1 hükmüne göre, Kurul'un denetleme faaliyetleri kapsamında personelini görevlendirdiği tarih ile SerPK md. 115 hükmüne göre ilgililer hakkında suç duyurusunda bulunulmasına dair kararın verildiği zaman aralığında zamanaşımı süresi duracaktır⁴⁷. Söz konusu kararın verilmesiyle birlikte; bilgi suistimali suçunun işlenmesi tarihinden, Kurul'un suçun işlendiğini öğrendiği tarihe kadar zamanaşımı süresi işleyecektir ve işlendiği iddia edilen suç hakkında Kurul'un karar organınca gerekli denetim ve inceleme faaliyetlerinin yapılması için başlatılacak görevlendirme tarihinden, SerPK md. 115/1 hükmüne göre suç duyurusunda bulunulacak süreye kadar zamanaşımı süresi duracaktır.

6. Sonuç

Gelişen dünyada teknolojik ilerlemeler ışığında, sermaye piyasasında yapılan işlem sayısı her geçen gün artmaktadır. İşlem yapan kişiler ilk bakışta ekonomik çıkarları doğrultusunda emir veren, alım – satım yapan kişiler olsalar da söz konusu kişiler arasında borsa manipülasyonları yapanlar ya da piyasanın güvenilir şekilde çalışmasını engelleyen kişiler de bulunmaktadır ve bu durum da gün geçtikçe artma eğilimi göstermektedir. Doğal bir sonuç olarak bu durumla mücadele etme ihtiyacı da artmıştır ve Sermaye Piyasası Kanunu (SerPK) ile bu manipülatif eylemler hukuki düzenleme ile buluşturulmuştur.

⁴² Taner, Fahri Gökçen. Ceza Hukukunda Zamanaşımı, AÜSBE, Yayınlanmış Yüksek Lisans Tezi, Ankara 2007, s. 64-68.

⁴³ Çoşkun, s. 229.

⁴⁴ Toroslu – Toroslu, s. 504 vd.; Taner, s. 108.

⁴⁵ Çoşkun, s. 231.

⁴⁶ Taner, s. 108.

⁴⁷ Yarg. 5. CD'nin 26.9.2012 tarih ve E.2012/12185, K.2012/42119 (aktaran Çoşkun, s. 231).

Bilgi suistimali suçuna vücut veren işlemin niteliği hakkında bilgisi veya haberi olmayan ve bu bilgisizlik ve habersizlik içerisinde piyasada işlem yapan gerçek veya tüzel kişiler bilgi suiistimali suçunun mağduru olacaklardır. Bilgi suistimali suç, bir özgü suç olmayıp, herkes tarafından işlenebilen bir suçtur. Bilgi suistimali suçunda hareket, alım – satım emri, emir değişikliği ya da emir iptali gibi işlemler olduğundan, bu işlemler sermaye piyasası araçları üzerinde yapılabilmektedirler. 6362 sayılı SerPK md. 106 hükmü, bilgi suistimali suçunun hangi nedenlerle ortaya çıkacağını düzenlemiştir. Bu bağlamda, sermaye piyasası araçları için alım – satım emri, emir değişikliği ya da emir iptali gibi işlemler ile kendine veya bir başkasına menfaat sağlandığında, bilgi suistimali suçuna vücut verilmiş sayılmaktadır. Söz konusu suç, SerPK md. 106'nın lafzından anlaşıldığı üzere farklı biçimlerde de gerçekleşebilecektir. Diğer bir ifadeyle 6362 sayılı SerPK'nin md. 106 hükmü, bilgi suistimali suçunun oluşumunda seçimlik hareketler öngörmüştür.

Yazar Katkı Oranı (Author Contributions): Afra AKGÜL (%100)

Yazarın Etik Sorumlulukları (Ethical Responsibilities of Authors): Bu çalışma bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır.

Çıkar Çatışması (Conflicts of Interest): Çalışmadan kaynaklı çıkar çatışması bulunmamaktadır.

İntihal Denetimi (Plagiarism Checking): Bu çalışma intihal tarama programı kullanılarak intihal taramasından geçirilmiştir.

KAYNAKÇA

- Arslan, Çetin. – Özdemir, Didar. “Türk Ceza Hukukunda Bilgi Suistimali Suçu”, International Conference On Eurasian Economies, Session 2D: Hukuk, 2018, ss. 405-410.
- Arslan, Abdullah. Sermaye Piyasası Hukukunda İçerden Öğrenenlerin Ticareti, AÜSBE, Yayınlanmış Doktora Tezi, Ankara, 2021.
- Centel, Nur. – Zafer, Hamide. – Çakmut, Özlem. Türk Ceza Hukukuna Giriş, Beta, 11. Baskı, İstanbul, 2020.
- Çoşkun, Seçil. Sermaye Piyasası Hukukunda Piyasa Dolandırıcılığı Suçu (6362 Sayılı SPKn MD. 107), AÜSBE, Yayınlanmış Yüksek Lisans Tezi, Ankara, 2020.
- Duman, Buminhan. “Türk Sermaye Piyasası Hukukunda Bilgi Suistimali (İçerden Öğrenenlerin Ticareti) Suçu”. Kırıkkale Hukuk Mecmuası 2 (2022), ss 389-409.
- Gündoğdu, Aysel. “Türk Sermaye Piyasasında Bilgi Suistimali ve Piyasa Dolandırıcılığı Suçu Düzenlemelerinin İrdelenmesi” , Maliye Finans Yazıları, Yıl 2017, Sayı 108, ss. 9-26.
- Hafizoğulları, Zeki. – Özen, Muharrem. Türk Ceza Hukuku Genel Hükümler, US-A Yayıncılık, 11. Baskı, Ankara, 2018.
- Karakehya, Hakan. İradilik Unsuru Bağlamında Ceza Hukukunda Kast, Ankara: Savaş 2010.
- Katoğlu, Tuğrul. “Ceza Hukukunda Suçun Mağduru Kavramının Sınırları”, AÜHFD, C. 61, S. 2, Y. 2012.
- Memiş, Tekin. – Turan, Gökçen. Sermaye Piyasası Hukuku, Seçkin Yayıncılık, 6. Baskı, Ankara, 2022.
- Okuyucu Ergün, Güneş. “Bilgi Suistimali Yasağının Muhatabı”, Banka ve Ticaret Hukuku Dergisi, Yıl 2021, Cilt XXXVII, Sayı 1, ss. 5-33.
- Orhan, Uğur. “Manipülasyon (Piyasa Dolandırıcılığı) Suçu”, DEÜHFD, 2021; 23(2), ss. 1635-1673.
- Özbek, Veli Özer. Ekonomi Ceza Hukuku Birinci Kitap Genel Hükümler, Seçkin Yayıncılık, 3. Baskı, Ankara, 2021.
- Tacir, Hamide. “Sermaye Piyasasında İçerden Öğrenenin Ticareti Suçu”, MAÜHFD, 2006, C. 5, S. 2.
- Taner, Fahri Gökçen. Ceza Hukukunda Zamanaşımı, AÜSBE, Yayınlanmış Yüksek Lisans Tezi, Ankara 2007.
- Toroslu, Nevzat. Cürümlerin Tasnifi Bakımından Suçun Hukuki Konusu, Savaş Yayınevi, Ankara, 2019.
- Toroslu, Nevzat. – Toroslu, Haluk. Ceza Hukuku Genel Kısım. Savaş Yayınevi, Ankara, 2021.
- Usluadam, Asena Kamer. “Bilgi Suistimali Suçu”. Anadolu Üniversitesi Hukuk Fakültesi Dergisi 5 / 1, Kasım 2019, ss. 229-254.
- Uğraş, Dilek Özge. “Bilgi Suistimali Suçu (İçerden Öğrenenlerin Ticareti Suçu)”, TAAD, Yıl: 12, Sayı: 47, 2021, ss. 463-499.

Yalçın, Türkan. – Köprülü, Timuçin. Ceza Hukuku Genel Hükümler Uygulamalı Çalışmaları. Savaş Yayınevi, Ankara, 6. Baskı, 2019.