

İSTATİSTİK ARAŞTIRMA DERGİSİ

JOURNAL OF STATISTICAL
RESEARCH

JSRTR

E-ISSN 2791-7614

Cilt
Volume **13**

Sayı
Issue **2**

Yıl
Year **2023**

**İSTATİSTİK ARAŞTIRMA DERGİSİ
ULUSLARARASI HAKEMLİ DERGİ**

JOURNAL OF STATISTICAL RESEARCH
INTERNATIONAL PEER-REVIEWED JOURNAL

**ISSN: 2791-7614
CİLT/VOL. 13 • SAYI / ISSUE 2 • 2023**

**Türkiye İstatistik Kurumu Adına Sahibi / Owner on Behalf of Turkish Statistical Institute
Erhan ÇETİNKAYA**

**Baş Editör / Editor - in - Chief
Prof. Dr. Selahattin GÜRİŞ**

**Editör Yardımcısı / Assistant Editor
Prof. Dr. Nurcan METİN
TÜİK Uzmanı Orçun AYDIN**

**Sorumlu Müdür / Responsible Manager
Stratejik Planlama, İzleme ve Değerlendirme Grup Başkanı Gönül KALENDER**

**Yabancı Dil Editörü / Foreign Language Editor
TÜİK Uzmanı Nilgün DORSAN**

İletişim / Communication
Türkiye İstatistik Kurumu
Devlet Mah.
Necatibey Cad. No: 114
06420 Çankaya/Ankara/TÜRKİYE

Tel. / Phone: +90 312 454 73 50
Belgeç / Fax: +90 312 454 82 96
E-posta / E-mail: journal@tuik.gov.tr
İnternet Sayfası / Web Site:
<https://journal.tuik.gov.tr>

Türkiye İstatistik Kurumu yayını olan İstatistik Araştırma Dergisi, yılda iki kez yayımlanan uluslararası hakemli bir dergidir. Makalelerin bilimsel ve etik kurallara uygunluğu yazarların sorumluluğundadır; Türkiye İstatistik Kurumu sorumlu tutulamaz.

Journal of Statistical Research, the publication of the Turkish Statistical Institute, is an international peer-reviewed journal published twice a year. Compliance of the articles with scientific and ethical rules is the responsibility of the authors; Turkish Statistical Institute can not be held responsible.

**©Türkiye İstatistik Kurumu Yayını
©Turkish Statistical Institute Publication**

Baş Editör'den

Değerli okuyucular,

İstatistik Araştırma Dergisi, Türkiye İstatistik Kurumu'nun 2002 yılında yayınlanmaya başladığı uluslararası akademik bir dergisidir.

Yayın politikası yenilenen ve kısa bir aradan sonra Temmuz 2021'de yeniden yayınlanmaya başlayan İstatistik Araştırma Dergisi'nde istatistik yanında ekonometri, yöneylem araştırması ve istatistiğin araç olarak kullanıldığı diğer bilim dallarında teorik çalışmalara yer verdiğimiz gibi, uygulamalı orijinal çalışmalara yer verilmektedir.

İstatistik Araştırma Dergisi'nin hedefi söz ettiğimiz konularda yayınlayacağı makaleler ile literatüre katkı sağlamaktır. Bu doğrultuda, derginin farklı endekslerde taranmasına yönelik çalışmalara da yer verilmektedir.

Bu sayıda makaleleri ile destek veren yazarlarımıza, dergimizin bilimsel çizgisine yön veren hakemlerimize, dergimizin Editörler Kuruluna üye olmayı kabul ederek bizi onurlandıran değerli bilim insanlarına, desteklerinden ötürü TÜİK Başkanı Sayın Erhan ÇETİNKAYA'ya ve emeği geçen herkese teşekkürlerimi sunarım.

Dergimizin Aralık 2023 (Cilt 13, Sayı 2) sayısının bilim dünyasına katkı sağlamasını diler, bundan sonraki sayılarımıza da ilgi ve desteğinizin devamını diler, saygılarımı sunarım.

Prof. Dr. Selahattin GÜRİŞ
Baş Editör

Editörler / Editors

- Prof. Dr. Ebru ÇAĞLAYAN AKAY, Marmara Üniversitesi, İstanbul
Fikri AKDENİZ, Çag Üniversitesi, Mersin
Cem CANEL, University of North Carolina Wilmington, Amerika Birleşik Devletleri
Mehmet Ali CENGİZ, Ondokuz Mayıs Üniversitesi, Samsun
Meral ÇETİN, Hacettepe Üniversitesi, Ankara
Özlem İLK DAĞ, Orta Doğu Teknik Üniversitesi, Ankara
Burak GÜRİŞ, İstanbul Üniversitesi, İstanbul
Jamal HUSEİN, Angelo State University, Amerika Birleşik Devletleri
Cem KADILAR, Hacettepe Üniversitesi, Ankara
Safet KOZAREVIC, University of Tuzla, Bosnia and Herzegovina, Bosna-Hersek
Sakkthivel Annamalai MANICKAM, Skyline University College, Birleşik Arap Emirlikleri
Ünal Halit ÖZDEN, İstanbul Ticaret Üniversitesi, İstanbul
Ömer ÖZTÜRK, The Ohio State University, Amerika Birleşik Devletleri
Muthucattu Thomas PAUL, Papua New Guinea University of Technology, Papua Yeni Gine
Mustafa SEVÜKTEKİN, Bursa Uludağ Üniversitesi, Bursa
Ram SHANMUGAM, Texas State University, Amerika Birleşik Devletleri
Kutluk Kağan SÜMER, İstanbul Üniversitesi, İstanbul
Semra ERPOLAT TAŞABAT, Mimar Sinan Güzel Sanatlar Üniversitesi, İstanbul
Mustafa TEKİN, İstanbul Üniversitesi, İstanbul
Münevver TURANLI, İstanbul Ticaret Üniversitesi, İstanbul
- Prof. Emeritus Barry C. ARNOLD, University of California, Amerika Birleşik Devletleri
Hanna DUDEK, Warsaw University of Life Sciences, Polonya
Nikolai KOLEV, University of Sao Paulo, Brezilya
Debasis KUNDU, Indian Institute of Technology, Hindistan
W. Y. Wendy LOU, University of Toronto, Kanada
- Doç. Dr. İbrahim DEMİR, Türkiye İstatistik Kurumu Başkanlığı, Ankara
Dr. Ojonugwa USMAN, Federal College of Education (Technical), Nijerya
Subhash Kumar YADAV, Babasaheb Bhimrao Ambedkar University, Hindistan

2023 Yılında ‘İstatistik Araştırma Dergisi’ne Bilimsel Katkı Sağlayan Hakemler
Referees Who Provided Scientific Contributions to The Journal of Statistical Research in 2023

Prof. Dr.

Ahmet ÖZEN, Dokuz Eylül Üniversitesi, İzmir
Betül ALTAY TOPCU, Kayseri Üniversitesi, Kayseri
Burak GÜRİŞ, İstanbul Üniversitesi, İstanbul
Cem KADILAR, Hacettepe Üniversitesi, Ankara
Hüsnü Levent DALYANCI, Çanakkale Onsekiz Mart Üniversitesi, Çanakkale
Mehmet GÜRCAN, Fırat Üniversitesi, Elazığ
Mustafa SEVÜKTEKİN, Bursa Uludağ Üniversitesi, Bursa
Mustafa TEKİN, İstanbul Üniversitesi, İstanbul
Münevver TURANLI, İstanbul Ticaret Üniversitesi, İstanbul
Özlem İLK, Orta Doğu Teknik Üniversitesi, Ankara
Selay Giray YAKUT, Marmara Üniversitesi, İstanbul
Semra ERPOLAT TAŞABAT, Mimar Sinan Güzel Sanatlar Üniversitesi, İstanbul

Doç. Dr.

Erol TERZİ, Ondokuz Mayıs Üniversitesi, Samsun
Hasan BULUT, Ondokuz Mayıs Üniversitesi, Samsun
Mustafa KIRCA, Ordu Üniversitesi, Ordu
Servet SAY, Selçuk Üniversitesi, Konya
Ulaş AKKÜÇÜK, Boğaziçi Üniversitesi, İstanbul
Z. Berna AYDIN, Uludağ Üniversitesi, Bursa

Dr.

Emre YILDIRIM, Ankara Hacı Bayram Veli Üniversitesi
Fatma İdil BAKTEMUR, Osmaniye Korkut Ata Üniversitesi, Osmaniye
Melike SARAÇ, Hacettepe Üniversitesi, Ankara
Turgut ÜN, Marmara Üniversitesi, İstanbul

Dergimize gönderilen makalelerin tümü intihal tespit aracıyla incelenmektedir.

All articles submitted to our journal are analyzed by plagiarism detection tools.

İÇİNDEKİLER / CONTENTS

ARAŞTIRMA MAKALELERİ / ORIGINAL RESEARCH ARTICLES

- 1-12 Burak KORKUSUZ
Forecasting Realized Volatility: Evidence from Nordic Stock Markets / Volatilite Tahmini: İskandinav Hisse Senedi Piyasalarından Bulgular
- 13-27 Muhammed Fatih TÜZEN, Gülsüm Merve GÖKÇİN, Özlem YİĞİT
The Calculation of Composite Calendar Regressors Including Moving Holidays in Türkiye / Türkiye'de Hareketli Tatilleri İçeren Birleşik Takvim Regresörlerinin Hesaplanması
- 28-41 Zeynep ŞENGÜL, Nazan ŞAK
Tarımsal Üretim ve Hayvancılığın Çevresel Kirliliğe Etkisi: Toplamsal Olmayan Panel Kantil Yöntemi / Impact of Agricultural Production and Livestock on Environmental Pollution: Non-Additive Fixed Effect Panel Quantile Method
- 42-59 Mesut DOĞAN, Fatma Gül ALTIN, Samet GÜRİSOY, Enes Burak ERGÜNEY
The Analysis of the Relationship Among Climate Policy Uncertainty, Logistic Firm Stock Returns and ESG Scores: Evidence from the TVP-VAR Model / İklim Politikası Belirsizliği, Lojistik Firma Hisse Getirileri ve ESG Puanları Arasındaki İlişkinin Analizi: TVP-VAR Modelinden Kanıtlar
- 60-74 Kübra KARADAŞ, Necati Alp ERİLLİ
Gri Kümeleme Analizi ile Türkiye'deki Şehirlerin Sosyo-Ekonomik Verilere Göre Sınıflandırılması / Classification of Provinces in Türkiye According to Socio-Economic Data with Gray Cluster Analysis



Forecasting Realized Volatility: Evidence from Nordic Stock Markets

Burak KORKUSUZ

University of Stirling, Division of Accounting and Finance / Dr.

Accounting and Finance Division

burak.korkusuz@stir.ac.uk

Orcid No: 0000-0001-9374-2350

Abstract

This study aims to determine the most effective model for forecasting volatility within the Nordic stock markets. In this regard, the forecasting power of HAR-RV, RSV, and PS models is compared to the ARFIMA-RV model using high frequency data for 7 Nordic stock market indices spanning from 2010 to 2019. One-day-ahead out-of-sample realized volatility forecasts are produced using a recursive window mechanism. The out-of-sample forecast losses are measured by the MSE and QLIKE criteria. The results indicate several noteworthy points. Firstly, the HAR-RV (PS and RSV) models are suggested to be best performing realized volatility models over the ARFIMA-RV model. Secondly, the separation of realized variance into positive and negative realized semivariances, which is known as good and bad volatilities, might offer valuable financial insights in certain situations, aiding the prediction of future realized volatility. Lastly, the results and findings are specific to market, data frequency, time horizon, and some characteristics of data, emphasizing the importance of these factors in interpreting the findings.

Keywords: Volatility, Forecasting, HAR-RV and ARFIMA-RV, Nordic stock markets

Corresponding Author / Sorumlu Yazar: 1- Burak KORKUSUZ, University of Stirling, Accounting and Finance Division.

Citation / Atıf: KORKUSUZ B. (2023). Forecasting Realized Volatility: Evidence from Nordic Stock Markets. *İstatistik Araştırma Dergisi*, 13 (2), 1-12.

Bu çalışma yazarın doktora tezinden türetilmiştir.

Volatilite Tahmini: İskandinav Hisse Senedi Piyasalarından Bulgular

Özet

Bu çalışma, İskandinav borsaları için en etkin volatilite tahmin modelini belirlemeyi amaçlamaktadır. Bu bağlamda, HAR-(RV, RSV ve PS) modellerinin tahmin gücü, 2010-2019 yılları arasında 7 İskandinav borsa endeksi için yüksek frekanslı veriler kullanılarak ARFIMA-RV modeli ile karşılaştırılmıştır. Özyinelemeli pencere mekanizması kullanılarak bir gün sonra gerçekleşen örneklem dışı volatilite tahminleri üretilmektedir. Örneklem dışı tahmin kayıpları, MSE ve QLIKE kriterleri ile ölçülür. Sonuçlar birkaç önemli noktaya işaret etmektedir. İlk olarak, HAR-RV (PS ve RSV) modellerinin, ARFIMA-RV modeline göre daha iyi performans gösteren model grubu olduğu öne sürülmektedir. İkincisi, varyansın pozitif ve negatif yarı varyanslara veya diğer bir deyişle iyi ve kötü varyanslara ayrıştırılması, bazı durumlarda, gelecekteki varyansın tahminine yardım eden faydalı finansal bilgiler sunabilir. Son olarak, sonuçlar ve bulgular pazara, veri sıklığına, zaman ufkuna ve verilerin bazı karakteristik özelliklerine özgüdür ve bulguların yorumlanmasında bu faktörlerin önemi vurgulanmaktadır.

Anahtar sözcükler: Volatilite, Tahmin, HAR-RV ve ARFIMA-RV, İskandinav hisse senedi piyasaları

1. Introduction

Although numerous studies have explored volatility predictability, a consensus on the optimal forecasting model remains elusive in the literature. Stocks, exchange rates, and crude oil constitute the most examined assets, predominantly using GARCH family models since the 1980s. GARCH models with daily data have become prevalent. However, the availability of minute-wise data prompted the adoption of intraday data for volatility forecasting. Consequently, realized measures, derived from tick-by-tick data using diverse statistical formulas, emerged as a result of these significant advancements. Corsi introduced the paradigm-shifting Heterogeneous Autoregressive model of the Realized Variance (HAR-RV) in 2009, which has since become a prominent model in recent volatility research.

The HAR-RV model extends standard realized volatility models, typically based on high-frequency financial data, to incorporate lower-frequency inter-day data. This study employs HAR-RV type models for volatility forecasting across 7 Nordic stock markets between 2010 and 2019, comparing the outcomes with the ARFIMA-RV model. Utilizing 5-minute realized variance series derived from high-frequency data, the study generates one-day-ahead out-of-sample volatility forecasts employing recursive windows forecasting technique. Forecast accuracy is assessed using criteria such as MSE, QLIKE, and the conditional Giacomini-White pairwise test (2006) to determine statistical significance in forecast errors between competing models.

The focus on Nordic stock markets stems from the region's reputation for innovation and technological advancements, attracting successful companies particularly in biotechnology, clean energy, information technology, and gaming. Despite this, there is a lack of empirical studies within the wider body of literature that specifically focused on Nordic stock markets from the perspective of realized volatility. Therefore, this research seeks to identify the most effective model for predicting volatility within these markets. The findings highlight several key points: the superiority of HAR-RV (PS and RSV) models over the ARFIMA-RV model; the potential insights gained from separating realized variance into positive and negative realized semivariances for predicting future volatility; and the specificity of results based on market, data frequency, time horizon, and data characteristics, emphasizing the importance of each contribution in the literature. These findings hold practical implications in financial econometrics, especially in risk management, option pricing, and portfolio management, where accurate realized volatility forecasts are essential.

This paper is organised as follows: Section 2 presents the review of related literature. In Section 3, the data and methods used in this study are explained in more detail. Afterwards, Sections 4 gives the empirical results and their evaluations respectively. Finally, the conclusion is presented in Section 5.

2. Literature Review

During the 2000s, the accessibility of high-frequency data revolutionized financial volatility research. Numerous studies, including works by Andersen and Bollerslev (1997), Andersen, Bollerslev, Diebold, and Labys (2001), Martens and Zen (2004), Koopman, Jungbacker, and Hol (2005), Chortareas, Jiang, and Narkervis (2011), and Sevi (2014), demonstrate that models utilizing intraday or high-frequency data notably enhance the precision of volatility forecasts. This enhancement can be attributed to several reasons. Firstly, owing to the persistence property of volatility, high-frequency data offer a more accurate assessment of current volatility, thus enhancing future volatility predictions. Secondly, these data contribute to better volatility forecast evaluations by minimizing inconsistencies in volatility model rankings. Additionally, high-frequency data aid in comprehending the dynamic nature of financial volatility, a crucial aspect for effective modelling and forecasting.

The availability of high-frequency data prompted the use of intraday data to create more direct proxies for financial volatility, referred to as "realized measures" or "realized variance" in this context. Studies by Barndorff-Nielsen, Kinnebrock, and Shephard (2010), Andersen, Bollerslev, Diebold, and Labys (2003), among others, validate the superiority of realized variance as a proxy for true volatility. As a result, realized variance has become the most commonly used volatility measure among alternative proxies. This measure, derived from the summation of squared intraday returns, necessitates careful consideration of the frequency interval for intraday data to ensure accuracy. Scholarly investigations, such as those by Martens and Zein (2004), suggest that increased intraday observation frequency leads to more precise daily volatility estimations. However, excessively high frequencies, termed ultra-frequency data, may distort data efficiency due to microstructure noise, leading scholars like Hol and Koopman (2002) to propose frequency intervals between 5 and 30 minutes.

Liu, Patton, and Sheppard (2015) conducted a comprehensive analysis comparing various realized measures, concluding that surpassing the accuracy of the five-minute realized variance is challenging. Consequently, the consensus among researchers and practitioners leans towards utilizing the 5-minute realized variance as the target volatility. This study opts for the simple realized variance based on 5-minute squared returns for estimations. Andersen and Bollerslev's (1998) introduction of the realized variance as a more accurate measure of true volatility compared to daily squared returns marked a pivotal moment. Initially employed as an estimator for true volatility assessment in volatility models' forecasting performance, the realized variance gained prominence with the increasing availability of high-frequency data. Andersen et al. (2001, 2003) emphasized that higher data frequencies lead to more accurate volatility forecasts. However, ultra-high frequency data may introduce microstructure noise, destabilizing parameter estimates. Evidence from various studies, including Blair, Poon, and Taylor (2001), Engle (2002), Andersen (2003), Koopman et al. (2005), and Bollerslev (2009), supports the notion that high-frequency returns data outperform daily returns data in measuring true volatility.

Corsi (2009) proposed the Heterogeneous Autoregressive model of realized variance (HAR-RV) based on the Heterogeneous Market Hypothesis, showcasing its impressive performance despite its simple structure. Subsequent research by Andersen et al. (2011), Patton and Sheppard (2009), and Bollerslev et al. (2016) corroborated the superior performance of the HAR-RV model. Barndorff-Nielsen, Kinnebrock, and Sheppard (2010) introduced positive and negative realized semivariance measures derived from signed high-frequency intraday returns. Expanding the HAR-RV model, Sevi (2014) decomposed volatility into jump and continuous components, negative and positive realized semivariances, and incorporated the leverage effect. Patton and Sheppard (2015) emphasized the significance of negative realized semivariance in future volatility forecasting, advocating for an asymmetric HAR model that includes both positive and negative realized semivariances. Fang, Jiang, and Luo (2017) highlighted the importance of decomposing only the daily component of the HAR model, suggesting that considering all components alters the influence of explanatory variables.

Research on realized variance has become a highly explored area in forecasting volatility, particularly after significant advancements in this field. The abovementioned studies were among the pioneers in demonstrating that realized variance proves to be a more precise gauge of volatility when compared to squared returns. Using the data of different financial assets many studies aim to find out the best performing volatility forecasting model. However, the literature has still to reach a consensus. Most of the papers concentrate mainly on the stock markets, yet in the context of single (or several) stocks or market indices. Even though stock market indices become one of the most investigated financial assets, there is still a gap in the literature in terms of the most recent developments in the research of tick-by-tick data such as the introduction of new models and applications of those in international markets. Therefore, this study fills this gap in the literature by carrying out a volatility forecasting exercise within 7 Nordic stock market indices between 2010-2019.

3. Data and Methodology

3.1. Data Description

The data used in this study is provided by the Oxford-Man Institute of Quantitative Finance Realized Library. 5-min realized (and semi) variance series are employed for the volatility prediction of 7 Nordic stock market indices which are Amsterdam Exchange Index, Belgium 20 Index, OMX Copenhagen 20 Index, OMX Helsinki All Share Index, OMX Stockholm All Share Index, Oslo Exchange All Share Index, and Swiss Stock Market Index. Majority of them consist of the indices of developed countries. The full list of index names and abbreviations is given at Table 1. The reason of investigating Nordic stock markets is that Nordic region has a reputation for being at the forefront of innovation and technology. The stock markets in this region have seen listings of many successful and innovative companies, especially in sectors such as information technology, biotechnology, clean energy, and gaming. These companies contribute to the growth and development of the Nordic stock markets and attract investor interest.

The dataset of this forecasting exercise is the post-2007/2008 global financial crisis period. Each index covers the period of 9 years, specifically from January 4, 2010 to October 3, 2019.¹ The number of observations in each index is approximately 2400 trading days. However, total trading days in a year can differ between each countries due to different public holidays and nontrading periods. In this forecasting exercise, the initial sample comprises approximately one year period (330 obs. [2010-2011]), whilst the time interval of out-of-sample volatility forecasts is 8 years (2070 obs. [2011-2019]). We arbitrarily choose the in-sample length as 330 observations considering the length at least one year period to let the regression fit normally and obtain a longer out-of-sample period. This is because the main objective of this work is to evaluate the out-of-sample performance of the models.

Table 1. The full list of index names and abbreviations

Symbol	Name	Mean	St. Dev.	Skew.	Ex. Kur.
AEX	Amsterdam Exchange Index	7.23E-05	0.00011	9.1184	135.49
BFX	Belgium 20 Index	6.66E-05	8.51E-05	8.1125	109.33
OMXC20	OMX Copenhagen 20 Index	8.74E-05	0.00031	29.286	1039.0
OMXHPI	OMX Helsinki All Share Index	7.33E-05	0.00046	46.596	2253.9
OMXSPI	OMX Stockholm All Share Index	6.31E-05	0.00024	34.113	1410.1
OSEAX	Oslo Exchange All Share Index	8.74E-05	0.00015	8.8676	129.06
SSMI	Swiss Stock Market Index	5.51E-05	0.00012	21.799	680.43

Source: (Author's calculation)

Table 1 presents the first four statistical moments of 5-minute realized variance series for different indices respectively, namely; mean, standard deviation, skewness, and excess kurtosis. The values of the moments are as commonly seen in the literature. The means of realized variance series are close to zero for each index that is consistent with the literature. The series also have a high positive skew. Lastly, the values of the fourth moment indicate the leptokurtic distribution for all the dataset. Therefore, it can be pointed out that the series have non-Gaussian distribution.

Liu, Patton, and Sheppard (2015) conducted a comparison of more than 400 realized measures, noting that the challenge in outperforming the five-minute realized variance significantly has failed. Hence, we opt for the 5-minute realized variance as a stand-in for true volatility. Generally, higher data frequency tends to enhance the precision of volatility estimation. However, increased frequency may introduce errors in measurement and price discreteness due to microstructure noise, potentially affecting the efficiency of the data in higher frequencies.

¹ The Oxford-Man Institute's Realized Library is no longer available after 2020 and they have no future plans to replace this.

3.2. Methods

3.2.1. Realized Volatility and Realized Volatility Models

Volatility, being latent, requires a substitute to represent the true volatility. Initially, researchers commonly utilized daily squared returns until Andersen and Bollerslev's work in 1998 revealed their inadequacy compared to cumulative intraday squared returns. Subsequently, Andersen, Bollerslev, Diebold, and Labys (ABDL; 2003) introduced the concept of realized variance, which sums the squared intraday returns. Both realized variance and daily squared returns serve as unbiased estimates of volatility, but realized variance is renowned for its high efficiency as a measure of volatility.

$$RV_t = \sum_{i=1}^m r_{t,i}^2 \quad (1)$$

As expressed in Equation (1), realized variance is computed by summing the squared intraday returns, where 'm' signifies the number of intraday observations on day 't'. In theory, a higher 'm' value leads to a more precise estimation of daily volatility. However, excessively high 'm' numbers can distort the efficiency of high-frequency data due to microstructure noise effects. ABDL (2003), Martens (2001), and Hol and Koopman (2002) recommend a frequency interval between 5 and 30 minutes. In a recent study by Liu, Patton, and Sheppard (2015), comparing over 400 realized measures, it was noted that surpassing the accuracy of the five-minute realized variance is challenging. Consequently, we opt for the 5-minute realized variance in estimating the HAR and ARFIMA models. Barndorff-Nielson et al. (2010) separate realized variance into positive and negative realized semivariances, depicting good and bad volatilities.

3.2.2. HAR-RV Models

The HAR-RV model is based on the heterogeneous market hypothesis of Muller, Dacorogna, Dave, Olsen, Pictet and von Weizsacker (1997). According to this hypothesis, there are three types of investors that have different risk preferences and different reactions to the same new market information. In addition to the hypothesis, the same researchers develop the Heterogenous Autoregressive Conditional Heteroskedasticity (HARCH) model. Inspired by the HARCH model and its background hypothesis, Corsi (2009) proposes the HAR-RV model that is an additive cascade model of different volatility components. The model is specified as:

$$RV_{t+h}^d = \beta_0 + \beta_d RV_t^d + \beta_w RV_t^w + \beta_m RV_t^m + \varepsilon_{t+h} \quad (2)$$

where RV_t^d is daily realized volatility; RV_t^w refers to weekly realized volatility, and then RV_t^m indicates monthly realized volatility. RV_t^w and RV_t^m can easily be calculated as follows:

$$RV_t^w = \frac{1}{5} (RV_{t-5}^d + RV_{t-4}^d + \dots + RV_{t-1}^d)$$

$$RV_t^m = \frac{1}{22} (RV_{t-22}^d + RV_{t-21}^d + \dots + RV_{t-1}^d)$$

The main point of the HAR-RV model is to predict future volatility using three different volatility components; a daily (RV_t^d), a weekly (RV_t^w), and a monthly (RV_t^m) components. The HAR-RV model can simply be estimated by the ordinary least square (OLS) method. The model is such a good alternative to the ARFIMA model. The HAR-RV model can also capture long memory characteristics of volatility even though it is not in the class of long memory models. In practice, the HAR-RV model is found to be such a promising model as the model performance is remarkably good in spite of its simple structure.

Different types of investors have different objectives in financial markets. For instance, some investors are completely hedgers whilst some others are completely speculators. Hence the HAR-RV model is based on capturing different reactions of different investors through the simple autoregressive process. Financial interpretation of the model is that the investors are divided into three different categories. In the model, RV_t^d , RV_t^w , and RV_t^m components represent short-term, middle-term, and long-term investors respectively and indicate the degree of different investors' impact on current realized volatility. In other words, the model coefficients provide an understanding of how these different market participants react and perceive to volatility. Moreover, the HAR-RV model can successfully capture the persistence feature of realized volatility.

$$RSV_t^+ = \sum_{i=1}^m r_{t,i}^2 I \{r_{t,i} > 0\} \quad (3)$$

$$RSV_t^- = \sum_{i=1}^m r_{t,i}^2 I \{r_{t,i} < 0\} \quad (4)$$

where $I\{\cdot\}$ is an indicator function. We should also note that $RV_t = RSV_t^+ + RSV_t^-$. Barndorff-Nielsen, Kinnebrock, and Sheppard (2010) first introduce positive and negative realized semivariance measures, which are obtained from the signed high frequency intraday returns. Patton and Sheppard (2015) decompose only the daily explanatory HAR model component into negative and positive realized semivariances. In this study, we call Patton and Sheppard (2015)'s model as the HAR-PS model. The HAR-PS specification is presented in Equation (5):

$$RV_{t+h}^d = \beta_0 + \beta_d^- RSV_t^- + \beta_d^+ RSV_t^+ + \beta_w RV_t^w + \beta_m RV_t^m + \varepsilon_{t+h} \quad (5)$$

Following that it is added one more realized semivariance specification to the model comparison that decomposes not only the daily component, but also separates weekly and monthly components. The model of Patton and Sheppard (2011) is called here as the HAR-RSV and the model is given as follows:

$$RV_{t+h}^d = \beta_0 + \beta_d^- RSV_t^- + \beta_d^+ RSV_t^+ + \beta_w^- RSV_t^- + \beta_w^+ RSV_t^+ + \beta_m^- RSV_t^- + \beta_m^+ RSV_t^+ + \varepsilon_{t+h} \quad (6)$$

According to the seminal research of Patton and Sheppard (2011) and Barndorff-Nielsen, Kinnebrock, and Sheppard (2010), the decomposition of realized variance into positive and negative realized semivariances (or good and bad volatilities) adds more information for the prediction of future volatility.

3.2.3. ARFIMA-RV model

The long memory autoregressive fractionally integrated moving average (ARFIMA) model is in the class of long memory models and therefore can successfully capture the persistency feature of volatility. Andersen et al. (2003) suggest the univariate ARFIMA model in order to model the realized volatility. An ARFIMA (p, d, q) model is presented by:

$$\varphi(L)(1-L)^d(RV_t - \mu) = \theta(L)\varepsilon_t \quad (7)$$

where $\varphi(L)$ and $\theta(L)$ are the lag polynomials of the autoregressive (AR) and moving average (MA) components. ε_t is the error term which is distributed approximately as a Gaussian white noise $[N(0, \sigma_\varepsilon^2)]$. The fractional differencing parameter is represented by d in equation (7). The AR and MA components explain the short memory properties of volatility and as for the d , it accounts for the long memory properties of volatility. The value of d is expected between 0 and 0.5 in order to capture long memory property. Andersen et al. (2003) found $d=0.401$. In this context, a general empirical conclusion with ARFIMA model is that this framework outperforms traditional GARCH models which are based on daily returns (Hansen and Lunde, 2010).

3.2.4. Recursive window forecasting method and loss functions

The recursive window method is used for obtaining the volatility forecasts. The loss functions; the mean squared error (MSE) and the quasi-Gaussian log-likelihood (QLIKE) are considered in order to compare the models. Lastly, the Giacomini and White (2006) pairwise test is employed to evaluate the forecasting performance of two models. Initially, the whole sample needs to be divided into two subgroups such as the initial sample and out-of-sample windows. In the literature, there is no consensus on how to select an appropriate forecasting window. Since the main objective of this work is to evaluate the out-of-sample performance of the models, we arbitrarily choose the initial and out-of-sample windows considering a length that allows the regression fit normally and obtain longer out-of-sample period. The recursive window's working principle does work the way that the estimation sample is then rolled forward by adding one new observation and not dropping the most distant observation. In this way, the size of initial sample window used to estimate the models grows in each step.

Since the main goal of this work is to compare the performance of the competing models, we need to measure the ability of the models using some loss functions. Many different forecasting criteria can be used for comparison purpose. Lopez (2001) points out that it is not clear to decide which measure is the most accurate to which model. On the other hand, Patton (2011) documents the robustness of the QLIKE and MSE criteria. The reason is explained as such: in the case of such a noisy volatility proxy, the QLIKE and MSE provide consistent rankings

for volatility models. In this regard, these two criteria are selected, namely the mean squared error (MSE) and the quasi-Gaussian log-likelihood (QLIKE). The loss functions are specified as follows:

$$QLIKE = \frac{1}{\tau} \sum_{t=T+\tau}^{T+\tau} [\log \widehat{RV}_t^2 + \frac{RV_t^2}{\widehat{RV}_t^2}] \quad (8)$$

$$MSE = \frac{1}{\tau} \sum_{t=T+\tau}^{T+\tau} [RV_t^2 - \widehat{RV}_t^2]^2 \quad (9)$$

where RV_t^2 is the proxy of the true volatility and \widehat{RV}_t^2 is the volatility forecast. The number of observations is represented by τ . The QLIKE and MSE loss functions are frequently used criterion in the literature due to being robust to the noisy volatility proxy. Patton and Sheppard (2009) indicate that the QLIKE is powerful in the Diebold-Mariano test, which is quite similar test to the Giacomini and White (GW) test that we use here. Although the MSE and QLIKE are the most frequently used criteria, there is still a possibility that such a model with the lower error may not be exactly better than the other model. For further robustness, it is necessity to apply the GW test.

4. Empirical Results

Employing one-step-ahead recursive window forecasting method this study assesses the forecast results of four competing models (HAR-RV, HAR-PS, HAR-RSV, and ARFIMA-RV) for seven Nordic stock market indices. The forecasting exercise results of the four models are given in Table 2 and 3. Those forecasts are generated using the recursive window technique and then the forecasts' losses are measured by the QLIKE and MSE criterion. Lower QLIKE and MSE values in these tables indicate better performance and higher accuracy in forecasting the future volatility of stock market indices.

According to the results of QLIKE and MSE loss functions, it is clear that HAR-RV type models (e.g. HAR-RV, HAR-PS, and HAR-RSV) outperform ARFIMA-RV model. This means that HAR-type models are found to be promising models at forecasting realized volatility and exhibits remarkably good performance in spite of its simple structure in comparison with ARFIMA-RV model.

Table 2. QLIKE for recursive window forecast models

Index/Model	HAR-RV	HAR-PS	HAR-RSV	ARFIMA-RV
AEX	-8.8430	-8.8420	-8.8407	-8.6583
BFX	-8.8527	-8.8528	-8.8532	-8.7515
OMXC20	-8.4475	-8.4293	-8.3141	-8.1909
OMXHPI	-8.6986	-8.6938	-8.6664	-8.6894
OMXSPI	-8.9579	-8.9805	-9.0016	-7.9089
OSEAX	-8.6303	-8.6371	-8.6183	-8.4479
SSMI	-9.0730	-9.0746	-9.0708	-8.8375

Source: (Author's estimation)

Table 3. MSE for recursive windows forecast models

Index/Model	HAR-RV	HAR-PS	HAR-RSV	ARFIMA-RV
AEX	8.29E-09	8.40E-09	8.42E-09	9.42E-09
BFX	4.85E-09	5.06E-09	5.19E-09	5.47E-09
OMXC20	3.90E-08	3.93E-08	4.05E-08	4.42E-08
OMXHPI	7.85E-09	7.81E-09	7.63E-09	1.15E-08
OMXSPI	8.77E-09	8.25E-09	8.29E-09	6.77E-08
OSEAX	1.76E-08	1.79E-08	1.81E-08	1.95E-08
SSMI	1.48E-08	1.69E-08	1.78E-08	1.52E-08

Source: (Author's estimation)

When these results are examined in more details, the best performing HAR-RV genre models differ from one market index to another index and also between the employed two loss functions. Therefore, this analysis evaluates those results index by index separately and then try to draw a more precise picture in the end. In terms of the AEX and OMXC20 stock market indices, HAR-RV model is superior to the other counterparts such as HAR-PS and HAR-RSV models. We should remember here that while the HAR-PS model decomposes only the daily component, the HAR-RSV model decomposes the daily, weekly and monthly components. When the BFX index is evaluated, it can be seen that the loss functions give opposite results. For instance, the HAR-RSV is the best performing volatility forecasting model for the QLIKE criterion whereas the MSE loss function favours the HAR-RV for this stock market index. Afterwards, when it comes to the OMXHPI index, the findings of the QLIKE and MSE tell vice versa compared to the BFX such that the HAR-RSV is the best performing volatility forecasting model for the MSE criterion, whilst the QLIKE loss function suggests the HAR-RV for this stock market index. The decomposition of positive and negative semi variances does work for the index of the OMXSPI. However, the only difference is that while the QLIKE supports the HAR-RSV, the MSE criteria shows the HAR-PS as a best performing volatility forecasting model for the OMXSPI. Lastly, the results of the OSEAX and SSMI stock market indices are in the same direction even though the loss functions yield opposite results. For example, the QLIKE selects the HAR-PS as a best performing model for both the indices, but the HAR-RV is suggested by the MSE for the same indices. It is important here to note that each one of these loss functions has a specific calculation method that could cause to yield different results, which is unsurprising.

Table 4. Conditional Giacomini-White test results

AEX	HAR-PS	HAR-RSV	ARFIMA-RV
HAR-RV	0.084 (-)	0.095 (-)	0.050 (-)
HAR-PS	-	0.023 (-)	0.002 (-)
HAR-RSV	-	-	0.005 (-)
BFX	HAR-PS	HAR-RSV	ARFIMA-RV
HAR-RV	0.181 (-)	0.184 (-)	0.197 (-)
HAR-PS	-	0.086 (-)	0.046 (-)
HAR-RSV	-	-	0.030 (-)
OMXC20	HAR-PS	HAR-RSV	ARFIMA-RV
HAR-RV	0.079 (-)	0.000 (-)	0.000 (-)
HAR-PS	-	0.000 (-)	0.000 (-)
HAR-RSV	-	-	0.000 (-)
OMXHPI	HAR-PS	HAR-RSV	ARFIMA-RV
HAR-RV	0.045 (+)	0.018 (+)	0.000 (-)
HAR-PS	-	0.000 (+)	0.000 (-)
HAR-RSV	-	-	0.000 (-)
OMXSPI	HAR-PS	HAR-RSV	ARFIMA-RV
HAR-RV	0.000 (+)	0.001 (+)	0.000 (-)
HAR-PS	-	0.017 (-)	0.000 (-)
HAR-RSV	-	-	0.000 (-)
OSEAX	HAR-PS	HAR-RSV	ARFIMA-RV
HAR-RV	0.264 (-)	0.024 (-)	0.000 (-)
HAR-PS	-	0.181 (-)	0.000 (-)
HAR-RSV	-	-	0.000 (-)
SSMI	HAR-PS	HAR-RSV	ARFIMA-RV
HAR-RV	0.451 (-)	0.151 (-)	0.084 (-)
HAR-PS	-	0.089 (-)	0.110 (+)
HAR-RSV	-	-	0.286 (+)

Source: (Author's estimation)

In order to underpin those results, further robustness tests need to be done, in particular the pairwise GW test to test the equal conditional predictive ability of the forecasts produced by the competing models. For instance, we have two different forecasted series, namely X and Y. Assuming that the values of loss functions of X are lower than Y. Can it be said that the forecast X has a superior performance compared to the forecast Y? Or is it possible that the difference between the forecasts X and Y is inherently insignificant? In order to test conditional predictive ability Giacomini and White (2006) suggest a pairwise test on equal conditional predictive ability, which examines

whether two different forecasting models statistically have the same accuracy or not. In short, this test evaluates the forecasting performance of two competing models.

The p-values of the conditional GW test results are reported in Table 4. The null hypothesis is that “the two models (row and column) statistically have the equal predictive accuracy” is tested in terms of squared forecast error. The signs, + and –, in bracket show which model outperforms best and which model is outperformed. A positive sign indicates the superiority of the column model, whilst a negative sign means that the model in row outperforms the column model. In more detail, a positive sign means that the model in row has larger forecast loss in comparison with the model in column, which implies that the column model is significantly superior. In a similar vein, a negative sign does imply that the row model forecast performs significantly better compared to the column model forecast, since the latter produces larger loss. If the test statistics higher than 0.05 critical value (which implies the null hypothesis cannot be rejected), this means that the column and row models perform equally well, so that it is difficult to say that whether the row model or column model is superior. The results in Table 4 further confirm the superiority of the HAR specification over the ARFIMA-RV model as the last column signs are mostly negative and the null hypothesis “row and column models statistically have the equal predictive accuracy” is rejected. Therefore, column model (HAR) is superior to the row model (ARFIMA-RV). However, the evaluation among the HAR type models is unclear, meaning equal forecasting performance between the column and row (HAR-RV, HAR-PS, and HAR-RSV) models. This is because the values of loss functions between the winning model and the second winning model in Tables 2 and 3 are quite close to each other. It is difficult to say which HAR model is best among only HAR models regardless of ARFIMA-RV model. These findings are also in line with the results of both loss functions.

In a nutshell, each one of the loss functions has a specific calculation method, causing to produce different results. The QLIKE and MSE are the most popular and frequently used ones in the literature due to being robust to the noisy volatility proxies. In this work, the QLIKE and MSE criteria indicate that the HAR specification is the winner against the ARFIMA-RV model in all the indices, whereas the superiority among only the HAR models differs in the stock market indices.

5. Conclusion

This exercise compares the forecasting power of HAR-RV, RSV, and PS models to the ARFIMA-RV models which are derived from high frequency data. In this regard, 7 different Nordic stock market indices in the region between 2010-2019 are included. One-day-ahead out-of-sample realized volatility forecasts are produced using the recursive window mechanism. The out-of-sample forecast losses are measured by the MSE and QLIKE loss functions. Afterwards, the conditional Giacomini-White pairwise test is used to test the forecasting accuracy of the competing models. In this volatility forecasting exercise, the HAR-type models are found to be promising models against the ARFIMA-RV model. Moreover, the decomposition of realized variance into positive and negative realized semivariances (or good and bad volatilities), in certain cases, could add more information for the prediction of future volatility.

In the end, the aim of this empirical exercise is an attempt to find which model best fits in the data of Nordic stock markets. Nordic region has an enviable reputation for being at the forefront of innovation and technology and therefore the Nordic stock markets have seen listings of many successful and innovative companies. These companies contribute to the growth and development of the Nordic markets and attract institution and investor attention. Therefore, the findings of this study could be utilized in many practices in the Nordic stock markets where the realized volatility forecasts are required to generate accurate volatility forecasts, especially for the applications of risk and portfolio managements.

References

- Andersen, T. G. & Bollerslev, T. (1998). Answering the skeptics: Yes, standard volatility models do provide accurate forecasts. *International Economic Review*, 39(4), 885-905.
- Andersen, T. G., & Bollerslev, T. (1997). Intraday periodicity and volatility persistence in financial markets. *Journal of Empirical Finance*, 4, 115–158.
- Andersen, T. G., Bollerslev, T., Diebold, F. X., & Labys, P. (2001). The distribution of exchange rate volatility. *Journal of the American Statistical Association*, 96, 42–55.
- Andersen, T. G., Bollerslev, T., Diebold, F. X., & Labys, P. (2003). Modelling and Forecasting Realized Volatility. *Econometrica*, 71(2), 579-625.
- Barndorff-Nielsen, O., S. Kinnebrock, & N. Shephard. (2010). Measuring Downside Risk: Realized Semi-variance. In *Volatility and Time Series Econometrics: Essays in Honour of Robert F. Engle*, T. Bollerslev, J. Russell, and M. Watson, eds. Oxford; New York: Oxford University Press, 117–136.
- Blair, B. J., Poon, S.-H., & Taylor, S. J. (2001). Forecasting S&P100 volatility: the incremental information content of implied volatilities and high-frequency index returns. *Journal of Econometrics*, 105(1), 5-26.
- Bollerslev, T.; S. Z. Li; & V. Todorov. (2016). Roughing up Beta: Continuous vs. Discontinuous Betas and the Cross-Section of Expected Stock Returns. *Journal of Financial Economics*, 120, 464–490.
- Chortareas, G., Jiang, Y., & Nankervis, J. (2011). Forecasting exchange rate volatility using high-frequency data: Is the euro different? *International Journal of Forecasting*, 27, 1089-1107.
- Corsi, F. (2009). A simple approximate long-memory model of realized volatility. *Journal of Financial Econometrics*, 7(2), 174-196.
- Engle, R. (2002). New frontiers for arch models. *Journal of Applied Econometrics*, 17(5), 425-446.
- Fang, N., Jiang, W., & Luo, R. (2017). Realized Semivariances and the Variation of Signed Jumps in China's Stock Market. *Emerging Markets Finance and Trade*, 53(3), 563-586.
- Hansen, P. R., & Lunde, A., (2010). Forecasting volatility using high frequency data. A systematic review, 1-37.
- Koopman, S. J., Jungbacker, B., & Hol, E. (2005). Forecasting daily variability of the S&P 100 stock index using historical, realized and implied volatility measurements. *Journal of Empirical Finance*, 12, 445–475.
- Liu, L. Y., Patton, A. J., & Sheppard, K. (2015). Does anything beat 5-minute rv? a comparison of realized measures across multiple asset classes. *Journal of Econometrics*, 187(1), 293-311.
- Martens, M., & Zein, J. (2004). Predicting financial volatility: high-frequency time-series forecasts vis-à-vis implied volatility. *Journal of Futures Markets*, 24, 1005–1028.
- Martens, M., & Zein, J. (2004). Predicting financial volatility: high-frequency time-series forecasts vis-à-vis implied volatility. *Journal of Futures Markets*, 24, 1005–1028.
- Merton, Robert C. (1980). On Estimating the Expected Return on the Market: An Exploratory Investigation, *Journal of Financial Economics*, 8, 1-39.
- Müller, U. A., Dacorogna, M. M., Davé, R. D., Olsen, R. B., Pictet, O. V. Von Weizsäcker, J. E. (1997). Volatilities of different time resolutions, Analysing the dynamics of market components, *Journal of Empirical Finance*, 4 (2-3) (1997), 213-239.
- Patton, A. J. (2011). Volatility forecast comparison using imperfect volatility proxies. *Journal of Econometrics*, 160(1), 246 - 256.
- Patton, A. J. & Sheppard, K. (2009). Optimal combinations of realized volatility estimators. *International Journal of Forecasting*, 25(2), 218-238.

Citation / Atif: KORKUSUZ B. (2023). Forecasting Realized Volatility: Evidence from Nordic Stock Markets. *İstatistik Araştırma Dergisi*, 13 (2), 1-12.

Patton, A. J. & Sheppard, K. (2015). Good Volatility, Bad Volatility: Signed Jumps and The Persistence of Volatility. *The Review of Economics and Statistics*, 97(3), 683-697.

Sevi, B. (2014). Forecasting the volatility of crude oil futures using intraday data. *European Journal of Operational Research*, 235, 643–659.



The Calculation of Composite Calendar Regressors Including Moving Holidays in Türkiye

Muhammed Fatih TÜZEN
Türkiye İstatistik Kurumu / TÜİK Uzmanı
fatih.tuzen@tuik.gov.tr
Orcid No: 0000-0003-2779-2151

Gülsüm Merve GÖKÇİN
Türkiye İstatistik Kurumu / TÜİK Uzmanı
merve.gokcin@tuik.gov.tr
Orcid No: 0000-0002-2644-1942

Özlem YİĞİT
Türkiye İstatistik Kurumu / TÜİK Uzmanı
ozlem.yigit@tuik.gov.tr
Orcid No: 0000-0002-0652-7271

Abstract

The calendar effects are categorized into working days, trading days, leap years, moving holidays and fixed holidays. In order to analyze the calendar effects for short term statistics ten different composite calendar regressors were calculated. Theoretical averages were used instead of a specific date range to calculate long-term averages. This study explains how to calculate ten composite calendar regressors, including moving holidays such as Ramadan and Sacrifice Feast, which significantly impact economic activities in Türkiye. Furthermore, the consistency analysis of the composite calendar regressors over the periods was also mentioned. The calendar effects of the Industrial Production Index (IPI) time series are determined by reducing the number of observations backward as a case study. This study will make significant contributions to the literature and be beneficial for other countries where there are moving holidays according to the Lunar Calendar.

Keywords: Composite Calendar Regressor, Türkiye, Lunar Calendar, Moving Holiday, Seasonal Adjustment

Corresponding Author / Sorumlu Yazar: 1- Gülsüm Merve GÖKÇİN, Türkiye İstatistik Kurumu.

Citation / Atıf: TÜZEN M. F., GÖKÇİN G. M., YİĞİT Ö. (2023). The Calculation of Composite Calendar Regressors Including Moving Holidays in Türkiye. *İstatistik Araştırma Dergisi*, 13 (2), 13-27.

Çalışmada ifade edilen görüşler tamamen yazarlara aittir ve Türkiye İstatistik Kurumu'nu bağlamaz.

Türkiye'de Hareketli Tatilleri İçeren Birleşik Takvim Regresörlerinin Hesaplanması

Özet

Takvim etkileri, iş günü, ticaret günü, artık yıl, hareketli tatil (Hicri takvime bağlı tatiller) ve sabit tatil (Miladi takvime bağlı tatiller) gibi kategorilere ayrılır. Kısa dönemli istatistiklerdeki bu takvim etkilerini analiz etmek amacıyla on farklı birleşik takvim etkisi regresörleri oluşturulmuştur. Uzun dönem ortalamaların hesaplanmasında belirli bir tarih aralığı yerine teorik ortalamalar kullanılmaktadır. Bu çalışma Türkiye'de ekonomik aktiviteler üzerinde önemli etkisi olan Ramazan Bayramı ve Kurban Bayramı gibi dini tatillerin de kapsandığı on farklı birleşik takvim etkisinin nasıl elde edildiğini açıklamaktadır. Ayrıca çalışmada elde edilen birleşik takvim regresörlerinin dönemler içerisindeki tutarlılığının analiz sürecinden de bahsedilmiştir. Uygulama örneği olarak, Sanayi Üretim Endeksi (SUE) zaman serilerinin geriye doğru gözlem sayısı azaltma yöntemiyle takvim etkileri belirlenmiştir. Bu çalışmanın literatüre önemli katkılar sağlayacağı ve ay takvimine göre hareketli tatillerin olduğu diğer ülkeler için faydalı olacağı düşünülmektedir.

Anahtar sözcükler: Birleşik Takvim Regresörü, Türkiye, Ay Takvimi, Hareketli Tatil, Mevsimsel Düzeltme

1. Introduction

Seasonal movements observed in economic indicators can make it challenging to understand the actual trend of these series. For the series' general tendencies to be measured in a reliable way, they must be seasonally adjusted. However, adjusting the seasonal component only is not sufficient for this purpose. Another reason of short-term fluctuations in economic indicators is the "holidays," which occur in time series depending on the composition of the calendar in the month and year, are classified under the name of "calendar day" effects and differ from month to month and year to year (Atabek et al. 2009). Ignoring the possible effects of holidays, one of the deterministic components of the time series, on economic activities causes biased results in determining time series models. This situation causes erroneous evaluations of economic indicators. In particular, the effects of Ramadan (Eid al-Fitr) and Sacrifice (Eid-al-Adha) holidays, which are called moving holidays depending on the Lunar (Hijri) calendar, on the number of working days in a month can be tremendous and cause fluctuations in economic indicators. Therefore, it is essential to accurately estimate the effects of moving holidays to compare the monthly/quarterly and annual growth of economic time series.

There are many studies in the literature on calendar effects. Young (1965) put forward the pioneer study on this subject. Theoretical and applied studies on calendar effects include Cleveland and Devlin (1982), Hillmer et al. (1983), Bell and Hillmer (1983), Cano et al. (1996), Soukup and Findley (2000), Lin and Liu (2002), Shuja et al. (2007) can be cited as examples. On this subject, a detailed literature review on calendar effects was made by Ladiray (2006). However, the number of studies examining the effects of Lunar calendar holidays is limited. Bessa et al. (2009) examined the effect of Ramadan on sectors in Tunisia. On the other hand, Faye et al. (2019) compared the effects of Ramadan on prices in Morocco, Senegal, and Tunisia.

In Türkiye, a country with a large Muslim population, although moving holidays are based on the Lunar calendar, the country's official calendar is the Solar (Gregorian) calendar. Therefore, the calendar effects on the Turkish economy should be handled in more detail, mainly due to the moving holidays. The first study on this subject in terms of Türkiye belongs to Atuk and Ural (2002). This study examined the performances of X-12 ARIMA and TRAMO/SEATS seasonal adjustment methods on monetary aggregates, considering the calendar effects. Alper and Aruoba (2004) found that the deterministic part of seasonal effects is significant in monthly economic time series. According to the results of the Reg-ARIMA model in his study, Koçak (2009) revealed that moving holidays have a negative and significant effect on the Industrial Production Index (IPI). On the other hand, Atabek et al. (2009) analyzed calendar effects with production indicators within the framework of working days. This study introduced a regression variable created to eliminate calendar day effects. As a result, the importance of calendar-adjusted series in annual comparisons of industrial production index (IPI) was revealed. Bozok and Kanli (2013), in their study on the effect of bridge days on production indicators, found that half-day eve days and bridge days before and after moving holidays were significant on industrial production. Demirhan (2016) demonstrated the calendar and working day effect in detail for foreign trade statistics using daily data. Eyerci et al. (2021) examined the effect of Ramadan on prices and production by converting the Solar calendar to the Lunar calendar. In a similar study, Eyerci (2021) investigated the possible effect of Sacrifice Feast on red meat prices.

In the studies examined in the literature, it has been observed that calendar effects regressors in time series models are examined separately for working days, trading days, public holidays, and moving holidays or by considering

several common dates. This study explains how to obtain ten different composite calendar regressors, including moving holidays such as Ramadan Feast and Sacrifice Feast, which significantly impact on economic activities in Türkiye. Unlike other studies, this study used theoretical averages instead of a specific date range to calculate long-term averages while constructing the composite calendar regressors. The disadvantages of long-term averages obtained by using a specific date range, such as subjectivity and variability over time, are also mentioned in the study. By considering these issues, the usability of the more objective and fixed theoretical averages structure over time has been expressed as a new approach in the theoretical and applied framework. In addition, the analysis process of the consistency of the composite calendar regressors over the periods is also mentioned. For this purpose, the IPI - Manufacture of Food Products time series for the period 2010-01:2021-12 was used for the case study. Calendar effects were determined using datasets with different time spans obtained by decreasing the observations backward one at a time. The lack of options to analyze the effects of moving holidays depending on the Lunar calendar in the existing software used for seasonal and calendar adjustment studies has also been a source of motivation for producing composite calendar regressors for Türkiye.

2. Methodology

It is assumed that the calendar effect in an observed time series consists of two parts: the seasonal and non-seasonal parts. The seasonal part of the calendar effect consists of effects whose cycle is completed in a year (for example, March has 31 days each year). In contrast, the non-seasonal part consists of effects that have a cycle longer than one year (February has 29 days every four years, or the number of Saturday-Sunday in a given month varies over the years). According to the Seasonal Adjustment Guide¹ of the European Statistical System, only the non-seasonal part of the calendar effect should be adjusted from the relevant series during the calendar adjustment process.

In order to adjust for the non-seasonal part of the calendar effect, it is first necessary to estimate the seasonal part of the calendar effect. For this purpose, long-term monthly averages are estimated for each month. The number of days worked is then adjusted for the long-term monthly average estimated for each month. The date length of the long-term average used here should "sufficiently" cover the seasonal cycle of the relevant calendar effect. Therefore, this study used theoretical averages instead of a specific date range in calculating long-term averages. In order to better understand the reason for using theoretical averages, both the Lunar² calendar and the Solar³ calendar cycle should be discussed in detail.

2.1. Lunar Calendar Effect

While a calendar year is 354.37 days on average in the Lunar calendar, a calendar year is 365.24 days in the Solar calendar. The Lunar year is 10-12 days shorter than the Solar year compared to the leap year in the two calendars. For this reason, Ramadan and Sacrifice holidays go back 10-12 days every year. The difference between the Lunar and Solar calendars is approximately one year in 33 years. To put it more clearly, once every 33 or 34 Lunar (32 or 33 Solar) years, the first day of the Lunar year (1 Muharram) coincides with one of the first ten days of January. In this case, the total number of days in the 34 Lunar year is 12048.58 ($354.37 \times 34 = 12048.58$), while the total number of days in the 33 Solar years is 12052.92 ($365.24 \times 33 = 12052.92$). According to this calculation, the difference ($12052.92 - 12048.58 = 4.34$) between the Lunar and Solar calendars has still not been eliminated. For this reason, it can be stated that considering 33 years or different year periods in calculating the average number of holidays for Ramadan and Sacrifice Feasts may cause bias. For example, in July 1982, there was a 3-day Ramadan holiday, and 33 years later, in July 2015, there was a 3-day Ramadan holiday. However, in August 1981, there were three days of Ramadan holiday, and 33 years later, in July 2014, there were three days of Ramadan holiday. While the first day of the Ramadan holiday was August 1, 1981, it was July 28, 2014. In this case, the Ramadan holidays coincide with a deviation of 4 days. In theory, this difference should be 4.34 days.

In light of this information, the long-term averages of the moving holidays within the Lunar calendar are calculated with a theoretical average rather than a specific calendar period. According to the Lunar calendar, it is a moving holiday for eight days (including eve days) every 354.37 days. For example, $0.70 (31 \times 8 / 354.37 = 0.70)$ days of moving holidays fall on average in a year in January. Table 1 shows the number of moving holidays per month based on 32-year intervals.

¹ <https://ec.europa.eu/eurostat/web/products-manuals-and-guidelines/-/KS-GQ-15-001>

² https://en.wikipedia.org/wiki/Islamic_calendar

³ https://en.wikipedia.org/wiki/Gregorian_calendar

Table 1. Total number of moving holidays per months

	1984-2015	1974-2005	1975-2006	Theoretical Average *
January	20	17	17	19.6
February	18	18	18	17.9
March	21	21	21	19.6
April	20	20	20	19.0
May	18	18	18	19.6
June	19	19	19	19.0
July	20	20	20	19.6
August	20	21	21	19.6
September	16	21	21	19.0
October	20	15	15	19.6
November	21	20	20	19.0
December	18	21	18	19.6
Total	231	231	228	230.9

Note:* The calculation of theoretical averages will be explained in the following sections.

As can be seen from the Table 1, the number of moving holidays per month varies for different 32-year time intervals, even if it is taken into account that the cycle of moving holidays is approximately 32 years. Therefore, the theoretical averages calculated according to the months for each holiday effect should be used to adjust for calendar effects.

2.2. Solar Calendar Effect

The approach suggested above for Lunar holidays can be similarly applied to holidays within the Solar calendar. Below, it is explained how the theoretical averages are calculated for the effect of days of the week, national holidays, and leap years within the scope of the Solar calendar. Since February is 29 days every four years, 28.25 days are included in the calculations.

2.2.1. Weekend-Sunday Effect

The cycle, as mentioned earlier, mainly affects the Saturday-Sunday distribution per month. From this point of view, the long-term average of the weekend or Sunday effect can be calculated as follows. If one of every seven days is a Sunday, for example, in January, an average of 4.43 ($31 \times 1/7 = 4.43$) days is Sunday. With a similar approach, an average of 4.04 ($28.2524 \times 1/7 = 4.04$) days in February is Sunday.

2.2.2. Fixed (National) Holidays

In Türkiye, there are seven national holidays within the scope of the Solar calendar, according to Law No. 2739 dated 27/5/1935, Law No. 2429 dated 17/3/1981, and Law No. 6752 dated 29/10/2016. These holidays are January 1, April 23, May 1, May 19, July 15, August 30, and October 29. October 29 holiday starts in the afternoon of October 28 and lasts for 1.5 days, while other national holidays are one day. National holidays take place on the same date yearly, depending on the Solar calendar. Due to these features, there is no shift like calendar events in the Lunar calendar. From this point of view, National holidays depending on the Solar calendar, can be evaluated within the scope of seasonality, not within the scope of the calendar effect. However, in the event that national holidays overlap (coinciding with the same date) with other Lunar or Solar calendar events, these effects should now be considered within the scope of the calendar effect. Due to the laws enacted on different dates in Türkiye, national and religious holidays and durations vary from 1936 to the present. These differences are shown in Table 2.

Table 2. National and Religious holidays between 1936 and 2027

Holidays	1936/January - 1981/March	1981/April - 2009/April	2009/May - 2017/June	2017/July - 2027/December
New Year	31 December (half-day), 1 January	1 January	1 January	1 January
National Sovereignty and Children's Day Labour and Solidarity Day	22 April (half- day), 23 April	23 April	23 April	23 April
Commemoration of Atatürk, Youth and Sports Day	1 May	-	1 May	1 May
Democracy and National Unity Day	-	19 May	19 May	19 May
Victory Day	-	-	-	15 July
Republc Day	30 August	30 August	30 August	30 August
Ramadan Feast (Eid al-Fitr) Sacrifice Feast (Eid al-Adha)	28 October (half-day), 29-30 October	28 October (half-day), 29 October	28 October (half-day), 29 October	28 October (half-day), 29 October
	3 day	3.5 day	3.5 day	3.5 day
	4 day	4.5 day	4.5 day	4.5 day

2.3. Composite Calendar Regressors

Calculating the composite calendar regressors is based on the number of days effectively worked. For this purpose, holiday effects are subtracted from the month's total number of working days. It is possible to group the calendar effects used in short-term statistics under the following four main headings:

- Weekend (Saturday-Sunday) or Sunday effect
- Fixed (national) holidays depending on the Solar calendar
- Moving (religious) holidays depending on the Lunar calendar (Ramadan and Sacrifice Feast)
- Leap year (February 29) effect

Ten composite calendar regressors were calculated using these four primary calendar effects with different combinations. (Table 3).

Table 3. Composite Calendar Regressors

No	Composite Calendar Regressor
1	Exc. Saturday and Sunday
2	Exc. Sunday
3	Exc. Saturday, Sunday, fixed and moving holiday
4	Exc. Sunday, fixed and moving holiday
5	Exc. Saturday, Sunday and moving holiday
6	Exc. Sunday and moving holiday
7	Exc. Saturday, Sunday and fixed holiday
8	Exc. Sunday and fixed holiday
9	Exc. fixed and moving holiday
10	Exc. moving holiday

One of the essential points to consider when calculating composite calendar regressors is that there are holidays that coincide with the same date. The effects of Ramadan and Sacrifice Feasts, national holidays, and the day of the week may coincide. For example, January 1 of any year can coincide with a fixed holiday, a Sunday, and the first day of the Ramadan Feast. In such cases, defining each calendar effect to different dummy variables will lead to the problem of over-weighting the relevant day in case of overlapping calendar effects. Therefore, composite calendar regressors were used to fix this problem.

Composite calendar regressors are calculated monthly, quarterly, and annually. The equations used in the calculation of the monthly regressors are given below. Equations can be easily converted accordingly when quarterly or monthly regressors are needed.

$$R_{i,t} = Y_{i,t} - \tilde{Y}_{i,t} \quad (1)$$

$$Y_{i,t} = X_t - Z_{i,t} \quad (2)$$

$$\tilde{Y}_{i,t} = X_t - P_i X_t \quad (3)$$

- i : composite calendar regressor in Table 3 ($i = 1,2, \dots, 10$)
- t : index of year-month between 1936-January:2027- December⁴ ($1 \leq t \leq 1104^5$)
- $R_{i,t}$: composite calendar regressor i in the month t
- $Y_{i,t}$: the number of working days in month t for the composite calendar regressor i
- $\tilde{Y}_{i,t}$: the theoretical average of working day in month t for the composite calendar regressor i
- X_t : the total number of days in the month t
- $Z_{i,t}$: the total number of holidays in month t for the composite calendar regressor i

Composite calendar regressor i is calculated in month t by using Equation (1). In this equation, the theoretical average of working days ($\tilde{Y}_{i,t}$) is the difference between the total number of days in a month and the total number of number of holidays. In Equation (2), the number of working days for the composite calendar regressor i can be calculated by differencing the total number of days from the total number of holidays in the month t . The total number of days in months are as follows:

$$X_t = \begin{cases} 31, & \text{mod}(t, 12) = 1 \\ 28.25, & \text{mod}(t, 12) = 2 \\ 31, & \text{mod}(t, 12) = 3 \\ 30, & \text{mod}(t, 12) = 4 \\ 31, & \text{mod}(t, 12) = 5 \\ 30, & \text{mod}(t, 12) = 6 \\ 31, & \text{mod}(t, 12) = 7 \\ 31, & \text{mod}(t, 12) = 8 \\ 30, & \text{mod}(t, 12) = 9 \\ 31, & \text{mod}(t, 12) = 10 \\ 30, & \text{mod}(t, 12) = 11 \\ 31, & \text{mod}(t, 12) = 0 \end{cases} \quad (4)$$

⁴ Data on the days of Ramadan and Sacrifice Feast holidays in Türkiye can be accessed on the Time Calculation page of the Presidency of Religious Affairs. The Presidency of Religious Affairs calculates religious days with Islamic and astronomical criteria determined by experts in the field at the International Hijri Calendar Union Congress (2016). The dates of religious days have been determined until 2027. As the data on the dates of religious days are updated, the composite calendar regressors are updated accordingly.

⁵ It represents the total number of months between January 1936 and December 2027.

The probabilities required to calculate the long-term averages of the holidays are represented by P_i . These probabilities are weighted by the total number of days per month to obtain the number of month-specific holidays. Holiday probabilities for ten different composite calendar regressors specified in Table 3 are shown below.

$$P_i = \begin{cases} n_1, & i = 1 \\ n_2, & i = 2 \\ n_1 + (1 - n_1)n_3 + (1 - n_1)(1 - n_3)m_t, & i = 3 \\ n_2 + (1 - n_2)n_3 + (1 - n_2)(1 - n_3)m_t, & i = 4 \\ n_1 + (1 - n_1)n_3, & i = 5 \\ n_2 + (1 - n_2)n_3, & i = 6 \\ n_1 + (1 - n_1)m_t, & i = 7 \\ n_2 + (1 - n_2)m_t, & i = 8 \\ n_3 + (1 - n_3)m_t, & i = 9 \\ n_3, & i = 10 \end{cases} \quad (5)$$

Here n and m represent holiday probabilities. n represents holidays whose cycle lasts longer than one year, and m refers to holidays whose cycle is completed within one year. n_1 and n_2 represent Lunar holidays and n_3 represent Solar calendar holidays. In other words, with the probability, $n_1 = 2/7$, shows the weekend holidays, and $n_2 = 1/7$ shows the Sunday holidays.

$$n_3 = \begin{cases} 7/354.37, & t < 544^6 \\ 8/354.37, & t \geq 544 \end{cases} \quad (6)$$

n_3 represents the probability that half-day eve holidays were excluded before April 1981 but included after. The $(1 - n_{1,2,3})$ terms are used to avoid duplication when more than one calendar effect is defined together. Since there is a national holiday specific to each month, m_t is calculated by considering the number of national holidays specified in Table 2.

⁶ In March 1981, there were legal changes regarding the duration of national and religious holidays. Accordingly, May 19 (Commemoration of Atatürk - Youth and Sports Day) has been declared a public holiday. April 23 holiday (National Sovereignty and Children's Day) was changed to 1 day, while it was celebrated as a 1.5-day holiday starting in the afternoon of April 22. The October 29 holiday (Republic Day) was changed to 1.5 days, while it was celebrated as 2.5 days, starting from the afternoon of October 28. While the 1st January holiday (New Year's Day) was 1.5 days to start in the afternoon of December 31, it was changed to 1 day. The days before religious holidays have been declared half-day holidays since 1981. Therefore, the value of 544 corresponds to the common year-month (1981-April) index on which the changes made are reflected.

$$m_t = \begin{cases} 1/X_t, & \text{mod}(t, 12) = 1 \\ 0/X_t, & \text{mod}(t, 12) = 2 \\ 0/X_t, & \text{mod}(t, 12) = 3 \\ 1,5/X_t, t < 544 \\ 1/X_t, t \geq 544, & \text{mod}(t, 12) = 4 \\ 1/X_t, t < 8817 \\ 2/X_t, t \geq 881, & \text{mod}(t, 12) = 5 \\ 0/X_t, & \text{mod}(t, 12) = 6 \\ 0/X_t, t < 9798 \\ 1/X_t, t \geq 979, & \text{mod}(t, 12) = 7 \\ 1/X_t, & \text{mod}(t, 12) = 8 \\ 0/X_t, & \text{mod}(t, 12) = 9 \\ 2,5/X_t, t < 544 \\ 1,5/X_t, t \geq 544, & \text{mod}(t, 12) = 10 \\ 0/X_t, & \text{mod}(t, 12) = 11 \\ 0,5/X_t, t < 544 \\ 0/X_t, t \geq 544, & \text{mod}(t, 12) = 0 \end{cases} \quad (7)$$

The situations in Table 2 are considered both for the total number of holiday days ($Z_{i,t}$) specific to the relevant month and year in Equation (2) and the P_i values reflecting the long-term averages of the holidays in Equation (1).

The calculation of the composite calendar regressor "*Exc. Saturday, Sunday, fixed and moving holiday*" ($i=3$) for the year 2022 is explained below as an example. In addition, the calculation of the theoretical average number of working days for July 2022 is explained as an example. This month was chosen because a fixed holiday coincides with the Feast of Sacrifice in July 2022. In order to obtain the monthly composite calendar regressors, first of all, a daily table should be prepared in which the days with and without holidays are determined. Accordingly, the daily table design for July 2022 is given in Table 4.

⁷ It corresponds to the year-month (2009-May) index, which expresses the period when May 1 (Labor Day - Labor and Solidarity Day) was declared a national holiday again as of May 2009.

⁸ It corresponds to the year-month (2017-July) index, which expresses the period when July 15 (Democracy and National Unity Day) was declared as a national holiday in May 2017.

Table 4. Daily Table Design of 2022 July

Date	A	B	C	D	E = max(A,B,C,D)
	Sacrifice Feast	15 July	Saturday	Sunday	Saturday, Sunday, Fixed and Moving Holidays
Friday,1.7.2022	0	0	0	0	0
Saturday,2.7.2022	0	0	1	0	1
Sunday,3.7.2022	0	0	0	1	1
Monday,4.7.2022	0	0	0	0	0
Tuesday,5.7.2022	0	0	0	0	0
Wednesday,6.7.2022	0	0	0	0	0
Thursday,7.7.2022	0	0	0	0	0
Friday,8.7.2022	0.5	0	0	0	0.5
Saturday,9.7.2022	1	0	1	0	1
Sunday,10.7.2022	1	0	0	1	1
Monday,11.7.2022	1	0	0	0	1
Tuesday,12.7.2022	1	0	0	0	1
Wednesday,13.7.2022	0	0	0	0	0
Thursday,14.7.2022	0	0	0	0	0
Friday,15.7.2022	0	1	0	0	1
Saturday,16.7.2022	0	0	1	0	1
Sunday,17.7.2022	0	0	0	1	1
Monday,18.7.2022	0	0	0	0	0
Tuesday,19.7.2022	0	0	0	0	0
Wednesday,20.7.2022	0	0	0	0	0
Thursday,21.7.2022	0	0	0	0	0
Friday,22.7.2022	0	0	0	0	0
Saturday,23.7.2022	0	0	1	0	1
Sunday,24.7.2022	0	0	0	1	1
Monday,25.7.2022	0	0	0	0	0
Tuesday,26.7.2022	0	0	0	0	0
Wednesday,27.7.2022	0	0	0	0	0
Thursday,28.7.2022	0	0	0	0	0
Friday,29.7.2022	0	0	0	0	0
Saturday,30.7.2022	0	0	1	0	1
Sunday,31.7.2022	0	0	0	1	1
Total	4.5	1	5	5	13.5

The table includes all fixed and moving holidays in July 2022. It takes 1 if the holiday exists on the relevant date and 0 otherwise. One day before the first day of Sacrifice Feast, a value of 0.5 is assigned since it is a half-day holiday. Column E in the table gives the combination of Saturday, Sunday, fixed (July 15 - Democracy and National Unity Day), and moving holidays (Sacrifice Feast) on the relevant date. Holidays coinciding with the same date are counted as one by taking the maximum value of the relevant date. Since there are no Ramadan Feast and other fixed holidays in July 2022, they are not included in the table. Then, the daily table is aggregated, and the monthly table is obtained. Table 5 shows the values of the other months, along with July.

Table 5. Creation of the Composite Calendar Regressor 3 (for monthly data)

	A	B	C = A-B	D	E = C-D
2022	Total number of days	Total number of Saturday-Sunday, fixed and moving holidays	Number of days worked	Theoretical average number of working days	Composite Calendar Regressor (i=3)
	X_t	$Z_{i,t}$	$Y_{i,t} = X_t - Z_{i,t}$	$\tilde{Y}_{i,t} = X_t - P_i X_t$	$R_{i,t} = Y_{i,t} - \tilde{Y}_{i,t}$
January	31	10	21	20.94	0.06
February	28.25	8	20	19.72	0.28
March	31	8	23	21.64	1.36
April	30	9	21	20.25	0.75
May	31	13	18	20.25	-2.25
June	30	8	22	20.94	1.06
July	31	13.5	17.5	20.94	-3.44
August	31	9	22	20.94	1.06
September	30	8	22	20.94	1.06
October	31	10.5	20.5	20.60	-0.10
November	30	8	22	20.94	1.06
December	31	9	22	21.64	0.36

Column B in Table 5 consists of the number of Saturday-Sunday days and the sum of fixed and moving holidays excluding Saturday-Sunday. In other words, fixed and moving holidays that coincide with Saturday and Sunday are combined. In calculating probability of the theoretical average number of working days for July 2022, Equation (5) was used.

$$P_{i=3} = n_1 + (1 - n_1)n_3 + (1 - n_1)(1 - n_3)m_t$$

In the equation, $n_1 = 2/7$ indicates the probability of Saturday-Sunday holiday, and $n_3 = 8/354.37$ (Equation 6) indicates the probability of a moving holiday. m_t (Equation 7) is the fixed holiday probability in July. Therefore, its value in July 2022 is obtained with $m_t = 1/X_t$. The theoretical average number of days for July 2022 is obtained using this information.

$$P_{i=3} = \frac{2}{7} + \left(\left(1 - \frac{2}{7} \right) \left(\frac{8}{354.37} \right) \right) + \left(\left(1 - \frac{2}{7} \right) \left(1 - \frac{8}{354.37} \right) \right) \left(\frac{1}{31} \right) = 0.32436078877$$

The theoretical average number of working days is obtained using the holiday probability obtained for the composite calendar regressor no. 3 (column D).

$$\tilde{Y}_{3,2022-7} = X_{2022-7} - P_3 X_{2022-7} = 31 - 0.32436078877 * 31 = 20.9448155479$$

In order to obtain composite calendar regressor (column E) subtract the theoretical average number of working days ($\tilde{Y}_{3,2022-7}$) from the number of days worked ($Y_{3,2022-7}$).

$$R_{3,2022-7} = Y_{3,2022-7} - \tilde{Y}_{3,2022-7} = 17.5 - 20.94 = -3.44$$

3. Case Study

In the seasonal and calendar adjustment process of short-term statistics, the model, filters, outliers, and appropriate calendar variables are determined each year following the release of the data for the last period, and parameters and factors are re-estimated in each newsletter period throughout the year. In this direction, calendar effects are also reviewed annually. At this stage, first of all, the statistical and sectoral significance of the calendar effect is examined. Then, the determined significant calendar effect is compared with the previous year, and its consistency is checked. Thus, revisions due to calendar effects are kept at a minimum as much as possible. In order to determine whether the relevant time series has the same calendar effect in the past periods, the data is analyzed with the backward reduction method during the analysis phase. For this, data sets with different observation numbers are produced by decreasing the time series backward one by one (month-quarter) for a total of 2-5 years. Then, the significance of ten different composite calendar regressors for each data set is tested with Reg-ARIMA models.

As a case study, monthly time series (2010-01:2021-12) was used for the Industrial Production Index (IPI)-Manufacture of food products (NACE Rev. 2 - C10). The composite calendar regressor will be determined by the backward reduction of the number of time series observations. In this direction, ten different composite calendar

regressors will be tested with datasets of different lengths, reducing observations one by one for two years (24 months) backward from the last observation period (2021-12). The datasets mentioned here consist of time series obtained by excluding the last time series period at each observation reduction. Table 6 shows the design plan for the period covered by the time series and the number of observations it contains. Thus, each composite calendar regressor will be tested in 24 different time spans.

Table 6. Backward Observation Reduction Design of Time Series

No of time span	Period	Number of Observations
1	2010-01:2021-12	144
2	2010-01:2021-11	143
3	2010-01:2021-10	142
...
22	2010-01:2021-03	123
23	2010-01:2021-02	122
24	2010-01:2021-01	121

The t-statistics of the parameter estimates of the composite calendar regressors are used to determine the calendar effect. Using the t statistics, the calendar effect is decided with essential statistical criteria and graphical tools. The graph of the t statistics of the composite calendar regressors obtained is given below (Figure 1).




Figure 1. t-stats of Composite Calendar Regressors

The t statistics were interpreted according to the critical value of 1.96 at the $\alpha=0.05$ significance level. The red dashed lines in Figure 1 represent the 1.96 threshold value. According to the figure, some regressors proceed in a fixed line above the threshold value, while others follow a volatile path quite close to the threshold value. From this point of view, we can quickly eliminate regressors with a volatile and inconsistent structure in the first stage. Accordingly, the t statistics of the regressors "*Exc. Saturday, Sunday, fixed and moving holiday*" and "*Exc. Saturday, Sunday and moving holiday*" seem more consistent than the others. Summary statistics were calculated to examine the analysis with numerical data (Table 7).

Table 7. Summary Statistics of t-stats

Composite Calendar Regressor	Number of time spans	Mean of t-stat	Std.Dev. of t-stat	Min of t-stat	Max of t-stat	Number of time spans with t-stat > 2	Number of time spans with maximum t-stat
Exc. Sunday, fixed and moving holiday	24	13.44	1.88	5.79	15.73	24	16
Exc. Saturday, Sunday, fixed and moving holiday	24	13.00	1.10	10.67	14.13	24	2
Exc. Sunday, moving holiday	24	12.28	1.57	5.98	13.56	24	0
Exc. Saturday, Sunday and moving holiday	24	10.68	0.95	8.76	12.21	24	0
Exc. moving holiday	24	9.36	2.04	5.29	11.84	24	0
Exc. fixed and moving holiday	24	8.82	2.35	5.31	12.41	24	0
Exc. Saturday and Sunday	24	8.13	10.25	1.97	28.10	23	2
Exc. Sunday	24	6.34	10.38	1.10	29.53	10	4
Exc. Saturday, Sunday and fixed holiday	24	4.83	0.79	3.30	6.67	24	0
Exc. Sunday and fixed holiday	24	2.46	0.68	1.24	3.91	19	0

According to the summary statistics, the regressor "*Exc. Sunday, fixed and moving holiday*" has the highest significance regarding the mean value of the t statistics. In addition, this regressor has significant t statistics in all time spans and the highest t statistics in 16 of the time spans. Although it is seen as the most significant regressor, its inconsistency in the past periods should also be considered. Considering the mean of t statistics among the regressors selected according to Figure 1, "*Exc. Saturday, Sunday, fixed and moving holiday*" and "*Exc. Saturday, Sunday and moving holiday*" can be preferred. On the other hand, when the standard deviations are compared, it is seen that the regressor "*Exc. Saturday, Sunday and moving holiday*" has less volatility than "*Exc. Saturday, Sunday, fixed and moving holiday*". When we evaluate the situation from a sectoral point of view, it is known that fixed holidays significantly impact the food manufacturing sector in Türkiye. According to all these evaluations, the "*Exc. Saturday, Sunday, fixed and moving holiday*" regressor for the IPI - Manufacture of Food Products time series was preferred because it includes all effective holidays. This preference is also compatible with the composite calendar regressor for the previous year.

In order to emphasize the importance of calendar effects, a forecast analysis was also carried out for the selected "Industrial Production Index (IPI)-Manufacture of food products (NACE Rev. 2 - C10)" time series in this paper. In this context, the period (2010-01:2020-12) was considered for the the C10 index time series and was estimated for the period (2021-01:2021:12) with and without "*Exc. Saturday, Sunday, fixed and moving holiday*" calendar effect. Information about the models is given in the Table 8. In both models, (0,1,1)(0,1,1) Airline model and (2020-4) TC outlier were considered so the effects that may arise from the model and the outlier were fixed.

Table 8. Summary Statistics of models with calendar and without calendar for C10 series

	With Calendar	Without Calendar
<i>Arima model</i>	(0,1,1)(0,1,1)	(0,1,1)(0,1,1)
<i>Log</i>	Yes	Yes
<i>Theta</i>	coef= -0.5198 t-stat:-6.50 P-value:0.000	coef= -0.7754 t-stat:-13.16 P-value:0.000
<i>BTheta</i>	coef= -0.295 t-stat:-3.31 P-value:0.001	coef= -0.3139 t-stat:-3.36 P-value:0.001
<i>Calendar Effect</i>	Exc. Saturday, Sunday, fixed and moving holiday coef= 0.0278 t-stat:13.40 P-value:0.000	None
<i>Outlier</i>	TC (4-2020) coef= -0.1580 t-stat:-4.38 P-value:0.000	TC (4-2020) coef= -0.1812 t-stat:-3.57 P-value:0.0005
<i>AIC</i>	681.37	778.81
<i>BIC</i>	-6.33	-5.54

In order to compare forecast values for (2021-01:2021:12) period with and without calendar effect with the level values for the original time series, firstly annual growth rates (Year over Year -YoY) were calculated (Fig.2). Our expectation in annual growth rates graphs is that the with calendar model will obtain results close to the original series, especially during moving holiday periods. In 2021 Ramadan Feast was on May 13-15 and Sacrifice Feast was on July 20 - 23. When the relevant periods are examined graphically, we can say that the annual growth rates of the calendar effect model follow the direction in the original series and produce results close to the real annual growth rates. However, the annual growth rate of the without calendar model doesn't reflect this situation, especially in the May and July period, and differs from the original data.

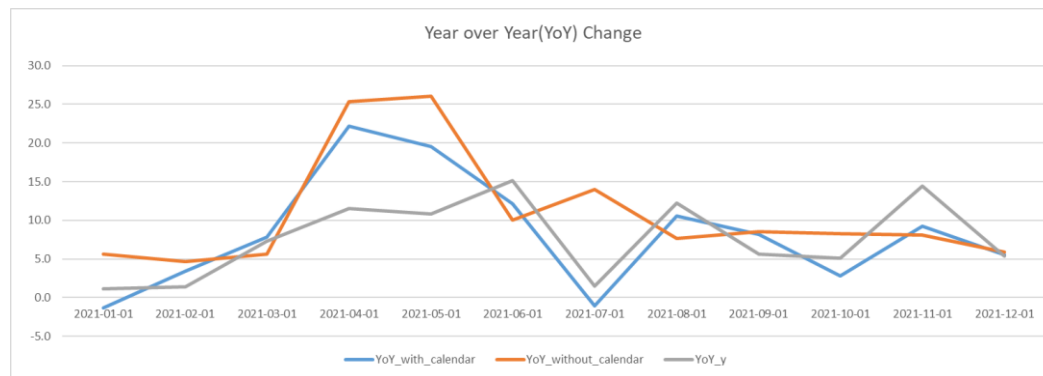


Figure 2. Year over Year (YoY) change with calendar, without calendar and original series

In the paper, a study was also conducted on the absolute revisions of the with calendar and without calendar model (Table 9). The table contains the Root Mean Square Revision (RMSR) results of the growth rates for monthly, annual and level values with and without calendar. According to these results, the model containing the calendar effect was found to be more successful because the revisions of the calendar results were smaller than without calendar model.

Table 9. Root Mean Square Revision (RMSR) results with and without calendar added

	Calendar Added	Without Calendar
<i>MoM</i>	5.02	8.13
<i>YoY</i>	4.60	7.72
<i>Level</i>	4.16	7.12

3. Conclusion

This study discusses how the composite calendar regressors are constructed, how the calendar effect is analyzed, and how the statistically significant calendar effect is determined. Using a specific date range in the generation of composite calendar regressors will only reflect the effect for that period. Instead, using theoretical averages is considered a more consistent and reliable way to obtain long-term averages. The usability of the more objective and invariant theoretical averages structure is expressed in this study as a new approach within the theoretical and practical framework. In this direction, ten composite calendar regressors were calculated with different combinations using the effects of the weekend (Saturday-Sunday) or Sunday, a Solar calendar based on fixed (national) holidays, a Lunar calendar based on moving (religious) holidays, and Leap year (February 29).

The significance of the composite calendar regressors for the IPI - Manufacture of Food Products sector was analyzed at different time spans with the method of backward reduction. When both numerical statistics and graphics were evaluated for this sector, the most suitable composite calendar regressor was tried to be preferred. While making this choice was also considered whether the calendar effect had a consistent structure in different time spans. Especially from a sectoral perspective, since working days or holiday durations in the sectors do not vary much, it is expected that the calendar effects will not have volatile structure. Therefore, when deciding on the composite calendar regressor, it is essential to interpret it in terms of the sector as well as its statistical significance.

One of the main purposes of time series analysis is to predict the future (forecasting) based on the past values of the relevant time series. In order to emphasize the importance of the calendar effect for forecasting the time series, a forecast analysis was also carried out for the selected time series with and without calendar effect. The monthly and annual growth rates and RMSR values of these prediction values were calculated and it was determined that the model containing the calendar effect was more successful in prediction because the revisions of the calendar results were smaller than without calendar model.

As a result, it is thought that the approach of calculation and analysis of composite calendar regressors will be a guide for other countries such as Türkiye, where there are moving holidays according to the Lunar calendar, and will contribute to the literature.

References

- Alper, C.Emre, and S.Boragan Aruoba. 2004. "Moving holidays and seasonal adjustment: the case of Turkey." *Review of Middle East Economics and Finance* 2 (3):203-209.
- Atabek, Aslihan, Oguz Atuk, Evren Erdogan Cosar, and Cagri Sarikaya. 2009. "Mevsimsel Modellerde Çalışma Günü Değişkeni." *TCMB Ekonomi Notları* 09/03.
- Atuk, Oguz, and Beyza Pinar Ural. 2002. "Seasonal adjustment methods: an application to the Turkish monetary aggregates." *Central Bank Review* 2 (1):21-37.
- Bell, William R, and Steven C Hillmer. 1983. "Modeling time series with calendar variation." *Journal of the American statistical Association* 78 (383):526-534.
- Bessa, Mohamed, Rim Dhifalli, Dominique Ladiray, Adnen Lassoued, and Bechir Maghrabi. 2009. "Les effets de calendrier dans les séries tunisiennes." *STATECO* (103).
- Bozok, İhsan, and İbrahim Burak Kanlı. 2013. "Impact of "De Facto" Bridge Holidays." *TCMB Ekonomi Notları* 13/08.
- Cano, Stephanie, Patricia Getz, Jurgen Kropf, Stuart Scott, and George Stamas. 1996. "Adjusting for a calendar effect in employment time series." Proceedings of the Survey Research Methods Section of the American Statistical Association, U.S. Bureau of Labour Statistics.
- Cleveland, William S, and Susan J Devlin. 1982. "Calendar effects in monthly time series: modeling and adjustment." *Journal of the American Statistical Association* 77 (379):520-528.
- Demirhan, Aslihan Atabek. 2016. "Dış Ticaret İstatistiklerinde Mevsimsel Anomaliler." *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 18 (2):471-484.
- Eyerci, Cem. 2021. "Kurban Bayramının Kırmızı Et Fiyatlarına Etkisi." *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 12 (23):107-126.
- Eyerci, Cem, A. Ömer Toprak, and Ömer Demir. 2021. "Ramadan effect on prices and production: Case of Turkey." *Statistika: Statistics and Economy Journal* 101(2):159-186.
- Faye, Modou Ndour, Béchir Maghrabi, Adnen Laoussed, Amal Mansouri, and Dominique Ladiray. 2019. "The Effects Of Ramadan On Prices : A Comparison Between 3 Countries (Marocco, Senegal, Tunisia)." Time Series Workshop, Paris,France, 26-27 September 2019.
- Hillmer, SC, WR Bell, and GC Tiao. 1983. "Modeling Considerations in the Seasonal Adjustment of Economic Time Series, in Zellner, A., Applied Time Series Analysis of Economic Data."74-100.
- Koçak, Necmettin Alpay. 2009. "Sanayi Üretiminde Tatil Etkileri." *İstanbul University Econometrics and Statistics e-Journal* (10):20-28.
- Ladiray, Dominique. 2006. "Calendar Effects and Seasonal Adjustment:A Review." Conference On Seasonality, Seasonal Adjustment And Their Implications For Short-Term Analysis And Forecasting, Luxembourg.
- Lin, Jin-Lung, and Tian-Syh Liu. 2002. "Modeling lunar calendar holiday effects in Taiwan." *Taiwan Economic Forecast and Policy* 33 (1):1-37.
- Shuja, Norhayati, Mohd Alias Lazim, and Wah Yap Bee. 2007. "Moving holiday effects adjustment for malaysian economic time series." *Journal of the Department of Statistics, Malaysia* 1:35-50.
- Soukup, Raymond J, and David F Findley. 2000. "Detection and Modeling of Trading Day Effects." ICES II: Proceedings of the Second International Conference on Establishment Surveys (2001).
- Young, Allan H. 1965. *Estimating trading-day variation in monthly economic time series*. Vol. Technical paper No. 12. Washington, DC: Department of Commerce, U.S. Bureau of the Census, Washington D.C.

Tarımsal Üretim ve Hayvancılığın Çevresel Kirliliğe Etkisi: Toplamsal Olmayan Panel Kantil Yöntemi

Zeynep ŞENGÜL

Marmara Üniversitesi / Doktora Öğrencisi

zzeynepsengul@gmail.com

Orcid No: 0000-0002-0461-6203

Nazan ŞAK

Marmara Üniversitesi / Doç. Dr.

nazan.sak@marmara.edu.tr

Orcid No: 0000-0002-7155-2940

Özet

Çevresel kirlilik ile ekonomik büyüme arasındaki ilişkiyi göstermek için Çevresel Kuznets Eğrisi (ÇKE) hipotezi önerilmektedir. Literatür incelendiğinde karbondioksit için birçok çalışma mevcutken metan gazına dair çalışmaların daha az sayıda olduğu görülmektedir. Bu sebeple iklim değişikliğinde en büyük ikinci faktör olan metan gazı salınımı için Çevresel Kuznets hipotezinin geçerliliği, toplamsal olmayan panel kantil yöntemi ile incelenmiştir. 2050'ye kadar dünyanın en büyük ekonomisine sahip olacağı düşünülen BRICS ülkelerinde 1990-2019 yılları arasındaki dönem için çalışma yapılmıştır. Metan gazı için gerçekleştirilen uygulamada gelir göstergesine ek olarak ekilebilir arazi, yenilenebilir enerji kullanımı, gübre tüketimi, büyükbaş hayvan üretim indeksi, tarımsal alan makine sayısı, toplam alan içindeki ormanlık alan verisi dahil edilmiş ve tüm değişkenler için anlamlı sonuçlar elde edilmiştir. Bu çalışma için ÇKE hipotezinin geçerli olduğu belirlenmiş ve çevre kirliliği ile gelir arasındaki ilişkinin N biçiminde olduğu sonucuna varılmıştır. Çalışmanın bulgularına göre büyükbaş hayvan indeksi, gübre tüketimi, tarımsal alan makine sayısı, ekilebilir alan ve ormanlık alan değişkenlerinin metan gazını arttırdığı görülmüştür. Büyükbaş hayvan yetiştiriciliğinde çevreyi koruyucu düzenlemeler yapılmasının ve toprağı korumaya yönelik inorganik gübrelerin kullanımının metan gazı salınımını azaltıcı etkisi olacağı düşünülmektedir. Çalışmada yenilenebilir enerji kullanımının kirliliği azalttığına yönelik bulgular elde edilmiştir. Bu sebeple rüzgâr, güneş, dalga panelleri kurularak temiz enerji üretmenin metan gazı salınımını azaltmada etkili olacağı öngörülmektedir.

Anahtar sözcükler: Çevresel Kuznets Eğrisi, Metan Gazı, Ekonomik Büyüme, Toplamsal Olmayan Sabit Etkili Panel Kantil Regresyon Yöntemi

Corresponding Author / Sorumlu Yazar: 1- Zeynep ŞENGÜL, Marmara Üniversitesi /Doktora Öğrencisi.

Atf / Citation: ŞENGÜL Z., ŞAK N. (2023). Tarımsal Üretim ve Hayvancılığın Çevresel Kirliliğe Etkisi: Toplamsal Olmayan Panel Kantil Yöntemi. *İstatistik Araştırma Dergisi*, 13 (2), 28-41.

Impact of Agricultural Production and Livestock on Environmental Pollution: Non-Additive Fixed Effect Panel Quantile Method

Abstract

The Environmental Kuznets Curve (EKC) hypothesis is proposed to demonstrate the relationship between environmental pollution and economic growth. When the literature is examined, it is seen that while there are many studies on carbon dioxide, there are fewer studies on methane gas. For this reason, the validity of the Environmental Kuznets hypothesis for methane gas emissions, which is the second largest factor in climate change, was examined with the non-additive panel quantile method. The study was conducted for the period between 1990 and 2019 in BRICS countries, which are thought to have the largest economy in the world by 2050. In addition to the income indicator in the application for methane gas, arable land, renewable energy use, fertilizer consumption, large head animal production index, number of agricultural machinery, forest area data in the total area is included and meaningful results are obtained for all variables. It was concluded that the EKC is valid for this study and the relationship between environmental pollution and income is in the form N. According to the findings of the study, it was observed that the variables of livestock index, fertilizer consumption, number of agricultural machinery, arable land and forest area increased methane gas. It is thought that making environmentally protective regulations in cattle breeding and the use of inorganic fertilizers to protect the soil will have a reducing effect on methane gas emissions. For this reason, it is predicted that producing clean energy by installing wind, solar and wave panels will be effective in reducing methane gas emissions.

Keywords: Environmental Kuznets Curve, Carbon Dioxide Emissions, Methane Gas, Economic Growth, Panel Quantile Regression Method

1. Giriş

Ekonomik gelişme süreci içerisinde tarım toplumundan sanayi toplumuna geçişiyle birlikte, artan kentleşme ve nüfus artışı, üretim ve tüketimde fosil yakıt kullanımı artışına sebep olmuş; ekonomik ve toplumsal dönüşüm süreci büyüme artışıyla birlikte çevresel kirliliğin artışı da beraberinde getirmiştir.

Kuznets (1955) çalışmasında, gelir dağılımı ile ekonomik büyüme arasındaki ilişkinin incelenmesinden sonra 1990'lı yıllarda küresel ısınmanın çok hissedilmesi, hava kirliliğinin artması, artan nüfus ile doğal kaynak kullanımının artması sebebiyle Kuznets Eğrisi yaklaşımı çevre sorunlarına uyarlanmıştır.

Çevresel Kuznets hipotezi yaklaşımına göre, ekonomik büyüme arttıkça üretim ve tüketimden dolayı çevre kirliliğine sebep olan zararlı gazların salınımı artış göstermektedir. Belli bir ekonomik büyüme seviyesinden sonra çevreyi koruyucu politikaların uygulanması, yasal düzenlemeler gibi sebeplerle çevre kirliliğinde düşüş meydana gelmektedir. Bu çalışmada çevresel kirletici olarak metan gazı emisyonu değişkeni kullanarak Çevresel Kuznets Eğrisi hipotezinin (ÇKE) geçerliliği araştırılacaktır.

Karbondioksit emisyonu %61, metan gazı emisyonu %15, CFC gazları %11, ozon gazı %9 ve N₂O %4 oranında küresel ısınmaya sebep olan gazlardır. (Temur, 2017). Günlük yaşamda insanların kullanmış olduğu plastikler, evsel ve hayvansal atıklar çevre sorunlarını tetiklemektedir. Gelişmiş ve gelişmekte olan ülkeler atığın geri dönüştürülmesi için çalışmalar sağlarken geri dönüşüme gitmeyen atıklar yakılarak veya toprağa gömülerek yok edilmektedir. Yakılarak yok edilmek istenen atıklar evrene karbondioksit yayarken toprağa gömülerek yok edilmek istenen atıklar kimyasal tepkimeye uğrayarak iklim değişikliğinin büyük sebeplerinden olan metan gazının yayılmasına yol açmaktadır (Kahvecioğlu, 2004). Metan gazı salınımı, sulak tarımsal alan kullanımından (pirinç üretimi vb.), hayvancılık sektöründen ve fosil yakıtların kullanımından etkilenmektedir. Tarımda metan gazı hem gübrenin kullanımı kaynaklı hem de sulama ile oluşmaktadır.

Karbondioksit emisyonu dünyada iklim değişikliğinde en büyük etken iken metan gazı iklim değişikliğinde ikinci büyük etken olarak görülmektedir. Metan gazı, atmosferi birim başına düşen karbondioksitten 20 kat daha güçlü ısıtma potansiyeline sahiptir (Euronews, 2021). Bu sebeple karbondioksit emisyonu yerine metan gazı üzerine yoğunlaşarak çevre politikası geliştirildiği takdirde daha hızlı bir şekilde iklim değişikliğinin önüne geçilebileceği düşünülmektedir.

Çalışmada metan gazı salınımını etkileyen faktörler, BRICS ülkelerinin 1990-2019 yılları arasındaki verileri kullanılarak düşük (0.20), orta (0.50) ve yüksek (0.80) kantiller dikkate alınarak toplamsal olmayan sabit etkili panel kantil regresyon yöntemi ile araştırılacaktır. Yapılan çalışmalar incelendiğinde, tarımsal ve hayvansal üretim faktörlerinin metan gazı salınımı üzerindeki etkisinin toplamsal olmayan panel kantil yöntemiyle incelendiği bir çalışmanın olmaması bu çalışmanın literatüre katkısı olarak belirtilebilir.

Çalışma planına göre ikinci bölümde ilgili literatür sunulacaktır. Üçüncü bölümde Çevresel Kuznets Eğrisi hipotezi ve dördüncü bölümde toplamsal olmayan panel kantil modeli hakkında bilgi verilecektir. Beşinci bölümde veri yapısı ve uygulama ile ilgili sonuçlar sunulacak; sonuç ve değerlendirme bölümü ile çalışmaya devam edilecektir.

2. Literatür

Literatür incelendiğinde metan gazına göre karbondioksit emisyonu üzerine birçok çalışmanın farklı ekonometrik modeller kullanılarak incelendiği görülmektedir. Grossman ve Krueger (1991), Panayotou (1993), Selden ve Song (1994), Torras ve Boyce (1998), Baret ve Graddy (2000) çalışmalarında ÇKE hipotezinin varlığı incelenmiştir.

Cole ve ark., (1997) çalışmalarında, OECD üyesi 11 ülke için nitrojen dioksit, sülfür dioksit, metan gazı gibi göstergeleri dikkate alarak ÇKE hipotezinin varlığını araştırmış; küresel kirlilik göstergeleri için gelirin artması ile karbondioksitin arttığını ifade etmişlerdir.

Jaunky (2001) yapmış olduğu çalışmada, yüksek gelirli 36 ülkenin 1980-2005 dönemi verilerini kullanarak karbondioksit emisyonu ve GSYİH değişkenleriyle ÇKE hipotezinin geçerliliğini araştırmıştır. Çalışmada panel birim kök ve eşbütünlük testleri uygulanmıştır. Analiz sonucunda Malta, Umman, Portekiz, İngiltere ve Yunanistan ülkeleri için ÇKE hipotezinin geçerli olduğu sonucuna varılmıştır.

Hamilton ve Turton (2002) çalışmalarında OECD ülkelerini dikkate alarak 1982-1997 dönemleri arasında ÇKE hipotezinin geçerliliğini incelemek için sera gazı, ekonomik büyüme, enerji yoğunluğu değişkenlerini kullanmıştır. Çalışmada Avrupa Birliği ile Amerika'da enerji yoğunluğu düşerken, Japonya'da artış gösterdiği sonucuna ulaşılmıştır.

Dijkgraaf ve Vollebergh (2005) çalışmasında OECD ülkelerinde 1960-1997 dönemi için karbondioksit emisyonu ve kişi başı GSYİH değişkenleri kullanılarak panel veri yöntemi ile ÇKE hipotezinin geçerliliği incelenmiştir. Analiz sonucunda ÇKE hipotezinin geçerli olduğu sonucuna varılmıştır.

Ang (2007), yapmış olduğu çalışmada Fransa'da 1960-2000 dönemi için karbondioksit emisyonu, GSYİH ve enerji kullanımı değişkenleri dikkate alınarak ÇKE hipotezinin geçerliliğini incelemiştir. Çalışma sonucunda ÇKE hipotezinin varlığı tespit edilmiştir.

Jalil ve Mahmud (2009), ARDL yaklaşımını kullanarak Çin'in karbondioksit emisyonu, enerji kullanımı, gelir, ticaret etkisi göstergeleri için 1975-2005 dönemi verilerini kullanılarak ÇKE hipotezinin geçerliliğine yönelik bulgulara ulaşılmıştır.

Hao (2016) çalışmasında, ÇKE hipotezini test etmek için Çin'in 29 vilayetine ait 1995-2012 dönemi dikkate alınarak kişi başına düşen kömür tüketimi ile gelir göstergeleri kullanılmıştır. Analiz sonucunda hipotezin geçerli olduğu ifade edilmiştir.

Lebe (2016) yapmış olduğu çalışmada ARDL-Sınır testi yaklaşımı ve VECM model ile ÇKE hipotezini test etmiştir. Türkiye'ye ait 1960-2010 dönemi için karbondioksit salınımı, GSYİH, enerji tüketimi, dışa açıklık, finansal gelişme göstergeleri ile analiz gerçekleştirmiştir. Analiz sonucunda ÇKE hipotezinin varlığına yönelik bulgulara ulaşılmıştır.

Williamson (2017) çalışmasında iki farklı konu dikkate alınarak 181 ülke için 2012 yılına ait hem karbondioksit emisyonu için hem de metan gazı için uygulama gerçekleştirilmiştir. Araştırma sonucuna göre karbondioksit emisyonu için ÇKE hipotezinin geçerli olduğu, metan gazı için ÇKE hipotezinin geçerli olmadığı ifade edilmiştir.

Benavides ve ark. (2017), Avusturya için ÇKE hipotezini gelir, metan gazı, elektrik tüketimi ve ticaret açıklığı değişkenlerini kullanarak ARDL ile incelemiştir. Çalışma sonucunda ters U şeklinde ilişki olduğu bulgusuna ulaşılmıştır.

Güriş ve Şak (2019) çalışmalarında seçilmiş 32 OECD ülkesi için 1993-2014 dönemindeki yıllık frekanstaki verileri dikkate alarak karbondioksit emisyonu, kişi başı GSYİH, yenilenebilir enerji tüketimi, enerji kullanımı, kent nüfusunun toplam içindeki payı, ticari açıklık, finansal gelişme değişkenlerini kullanmıştır. ÇKE hipotezini test etmek için toplamsal olmayan panel kantil regresyon yöntemini kullanılarak elde edilen bulguların ÇKE hipotezinin geçerliliğini desteklediği belirtilmiştir.

Shahbaz ve ark., (2019) çalışmalarında, ABD için 2000-2015 dönemini kapsayan karbondioksit emisyonu, enerji tüketimi, ticari açıklık ve doğrudan yabancı yatırımlar değişkenleri ile ÇKE hipotezini test etmişlerdir. Analiz sonucunda ÇKE hipotezinin geçerli olduğu belirtilmiştir.

Beyene ve Kotosz (2020) çalışmasında, 1990-2013 dönemi arası 12 Doğu Afrika Ülkesi için ÇKE hipotezi, Havuzlanmış Ortalama Grup yöntemi ile sınanmış ve hipotezin geçerli olduğu ifade edilmiştir.

Chu (2021) çalışmasında 118 ülkeye ait ekonomik karmaşıklık ve karbondioksit değişkenleri kullanılarak 2002-2014 dönemi için ÇKE hipotezi ARDL yaklaşımı ile test edilmiş ve hipotezin geçerli olduğu belirtilmiştir.

Ajam ve ark. (2021) çalışmasında, İran için 1979-2016 dönemi için küreselleşme, karbondioksit emisyonu ve tarımsal katma değer değişkenleri ile NARDL yaklaşımı kullanılarak ÇKE hipotezi test edilmiştir. Değişkenlerin karbondioksit emisyonları ile ters ilişkili olduğu ifade edilmiştir.

Djoukouo (2021), Orta Afrika Ekonomik ve Parasal Topluluğu (CEMAC) altı ülkesi için ÇKE hipotezini ve metan gazı emisyonları ile GSYİH arasındaki ilişkiyi Panel Granger Nedensellik testini kullanarak incelemiştir. Test sonucunda çift yönlü nedensellik ilişkisi olduğu ve ÇKE eğrisi hipotezinin geçerli olduğu ifade edilmiştir.

Handoyo ve ark. (2022), Asya ülkelerinde üst ve orta gelirli grup için iki analiz gerçekleştirmiştir. Analizde 2010-2019 yılları arasında ithalat, ihracat, karbondioksit emisyonu, doğrudan yabancı yatırımlar değişkenleri kullanılarak Poisson Maksimum Olabilirlik yöntemi ile ÇKE hipotezi test edilmiş ve hipotezin geçerliliğine yönelik bulgulara ulaşılmıştır.

Ericson (2022), çalışmasında 1992-2018 yılları arasında G20 ülkelerine ait metan gazı, ekonomik büyüme, enerji tüketimi ve doğal gaz tüketimi değişkenleri dikkate alınarak sabit etkiler regresyon modeli ile ÇKE hipotezi test edilmiştir. Analiz sonucunda ÇKE hipotezinin geçerli olduğu ifade edilmiştir.

Ramos ve ark. (2023), Kolombiya için GSYİH ve metan emisyonları değişkenlerini kullanarak ARDL testi ile ÇKE hipotezini geçerliliğini sınamışlardır. Çalışma sonucunda ters-U şeklinde ÇKE hipotezinin geçerli olduğunu ifade etmişlerdir.

Literatür incelendiğinde ekonometrik yöntem olarak çoğunlukla regresyon, ARDL ve eşbütünleşme yöntemlerinin tercih edildiği görülmektedir. Bu çalışmada tahmin yöntemi olarak Toplamsal Olmayan Sabit Etkili Panel Kantil Regresyon yöntemi kullanılmaktadır. Bu yöntemin seçilmesinin sebebi, normal dağılım varsayımının geçerli olmaması ve veri setinde uç değer olması durumunda etkin tahmin yapılabilmesidir. Bu yöntemin bir diğer avantajı, düşük-orta-yüksek kantillerde değişkenlerin katsayı değişimindeki farklılıkları görmemize olanak sağlamasıdır. Çalışmada BRICS ülkeleri için 1990-2019 dönemi dikkate alınarak metan gazı emisyonu ile ekonomik büyüme, yenilenebilir enerji kaynaklarının kullanımı, büyükbaş hayvan indeksi, gübre kullanımı, ekilebilir arazi, tarım makinesi sayısı ve ormanlık alanın toplam alan içindeki payı arasındaki ilişki, ÇKE hipotezi ile test edilecek; değişkenler arasındaki ilişkinin yönü farklı kantiller için belirlenmeye çalışılacaktır.


3. Çevresel Kuznets Eğrisi Hipotezi

Ekonominin gelişmesiyle beraber, sanayinin artması, üretim ve tüketim sonucu salınan karbondioksitin havaya karışması ve atıkların denizlere dökülmesi, nüfusun artması, çok fazla makinenin kullanımı çevresel kirliliği ve iklim değişimini etkilemektedir. Çevresel kirlilik ile gelir arasındaki ilişkiyi incelemek için Çevresel Kuznets Eğrisi (ÇKE) hipotezi literatüre kazandırılmıştır.

ÇKE hipotezi, Simon Kuznets (1955)'in yapmış olduğu çalışmada ekonomik büyüme ile gelir eşitsizliği arasındaki ters-U ilişkisinin ekonomik büyüme ve çevresel bozulma arasındaki ilişkiye uyarlanmış şeklidir (Bo, 2011: 1323). Grossman ve Krueger (1991) çalışmasında Kuznets eğrisi hipotezinin, çevresel bozulma ve ekonomi ilişkisini ortaya koyacak şekilde genişletildiği görülmektedir. Grossman ve Krueger (1991)'e benzer olarak ÇKE ile ilgili literatürde yer alan ilk çalışmalarda çevresel kirlilik ile ekonomik büyüme arasındaki ilişkinin yapısı incelenirken, zamanla ekonomik büyümenin yanı sıra farklı değişkenlerin etkisinin de modellere dahil edildiği görülmektedir.

ÇKE hipotezine göre ekonomik gelişmenin ilk durumda artan milli gelirin ve ekonomik faaliyetin etkisiyle çevre kirliliğini arttıracak; belirli bir seviyeye kadar gelirin artmasından sonra ise çevre kirliliğindeki artışın düşüş göstereceği ifade edilmektedir. Bu durumun ortaya çıkmasında zamanla üretim sektöründen hizmetler sektörüne hareketliliğin ve teknolojik gelişmelerin özellikle çevreye duyarlı teknolojilerin kullanımındaki artışın etkisi olduğu belirtilmektedir. (Spilker, 2013:11). Agram ve Chapman (1999)'un ÇKE'nin işleyiş mekanizmasını geliştirmiş ve geliştirmekte olan ülkelerin ekonomik yapıları için farklı sektörleri dikkate alarak oluşturdukları şema, Şekil 1'de yer almaktadır.

Çevresel Bozulma



Şekil 1. Çevresel Kuznets Eğrisinin Zıt Dinamikleri (Kaynak: Agras ve Chapman, 1999: 275)

Şekil 1 incelendiğinde, gelişmekte olan ülkeler tarım ekonomisinden sanayi ekonomisine geçmeye başladığında çevresel bozulmanın arttığı gözlenirken; gelişmiş ülkelerde ekonomi hizmetler sektörüne kaydıkça çevresel bozulmanın aşağı yönde hareket ettiği görülmektedir. Bu durum, gelişmekte olan ülkeler için kişi başına düşen milli gelirin ve kirliliğin artmasına sebep olurken; gelişmiş ülkelerde ithalattaki artışın kirliliğin azalmasına sebep olduğu görülmektedir. İncelenen şemada enerji fiyatlarının çevresel bozulma üzerindeki etkisi dikkate alındığında, enerji fiyatlarındaki düşüşün iki ülke kategorisi için de bozulmaya sebep olduğu görülmektedir.

Çevresel Kuznets Eğrisi modeli;

$$Y_{it} = \alpha_i + \beta_1 X_{it} + \beta_2 X_{it}^2 + \beta_3 X_{it}^3 + \beta_4 Z_{it} + e_{it} \quad (1)$$

olarak ifade edilmektedir. Denklemden i ve t sırasıyla ülkeleri ve yılları ifade etmektedir. Y çevresel bozulmayı ifade eden bağımlı değişken, X değişkeni ekonomik göstergiyi ifade eden bağımsız değişkeni ve Z çevresel bozulmaya sebep olabilecek diğer değişkenleri ifade etmektedir.

Çevresel etki ile ekonomik gösterge arasındaki ilişki durumu β_i katsayılarının anlamlılığına göre yedi farklı biçimde sınıflandırılmaktadır (Dinda, 2004: 340-341). X ile Y arasında ilişki için;

- i) $\beta_1 = \beta_2 = \beta_3 = 0$ olduğu durumda ilişki olmadığı,
- ii) $\beta_1 > 0$ ve $\beta_2 = \beta_3 = 0$ olduğu durumda doğrusal artan ilişki olduğu,
- iii) $\beta_1 < 0$ ve $\beta_2 = \beta_3 = 0$ olduğu durumda doğrusal azalan bir ilişki,
- iv) $\beta_1 > 0$, $\beta_2 < 0$ ve $\beta_3 = 0$ olduğu durumda ters-U şeklinde ilişki,
- v) $\beta_1 < 0$, $\beta_2 > 0$ ve $\beta_3 = 0$ olduğu durumda U şeklinde ilişki,
- vi) $\beta_1 > 0$, $\beta_2 < 0$ ve $\beta_3 > 0$ olduğu durumda N şeklinde fonksiyonel ilişki,
- vii) $\beta_1 < 0$, $\beta_2 > 0$ ve $\beta_3 < 0$ olduğu durumda ise ters-N şeklinde ilişki mevcuttur.

4. Yöntem

Ekonometride en yaygın olarak kullanılan En küçük Kareler tahmin yöntemi için geçerli olan temel varsayımlardan bir tanesi, normal dağılımın sağlanmasıdır. Anakütlede yer alan aşırı değerler sebebiyle normal dağılım varsayımının sağlanamadığı durumlarda kantil regresyon yönteminin kullanımı önerilmektedir.

Koenker ve Basset (1978) tarafından literatüre kazandırılan kantil regresyon, farklı kantil seviyelerinde tahmin sonuçlarının elde edilmesine olanak sağlamaktadır. Farklı kantillerdeki tahminlere dair katsayılar dağılım boyunca değişim göstermektedir. Bu sebeple, farklı kantillerde farklı katsayı ve test istatistiklerine ulaşılmaktadır. Kantil regresyon modeli;

$$Y_i = X_i' \beta_\theta + u_{\theta i} \quad (2)$$

olarak ifade edilmektedir. Denklemden yer alan Y_i , bağımlı değişken, X_i , açıklayıcı değişken ve β_θ , farklı kantiller için tahmin edilen katsayıdır. Bu değer (θ), $0 < \theta < 1$ arasında yer almaktadır. $u_{\theta i}$, hata terimidir. Kantil regresyon modeli minimizasyon problemini ele alarak çözümü sağladığı için θ . kantil regresyon;

$$\min_{\beta} \frac{1}{n} \left\{ \sum_{i: Y_i \geq X_i' \beta} \theta |Y_i - X_i' \beta| + \sum_{i: Y_i < X_i' \beta} (1 - \theta) |Y_i - X_i' \beta| \right\} \quad (3)$$

şeklinde ifade edilmektedir (Koenker ve Bassett, 1978). Kantil regresyon yönteminin zamanla veri alanının genişlediği ve farklı tahmin yöntemlerinde kullanıldığı görülmektedir. Koenker (2004) makalesinde, panel kantil regresyon modelinin sabit etki varsayımı altında genişletilerek tanımlandığı kantil fonksiyonu;

$$Q_{Y_{ij}}(\tau | X_{ij}) = \alpha_i + X_{ij}' \beta(\tau) \quad j = 1, 2, \dots, m_i, \quad i = 1, 2, \dots, n \quad (4)$$

olarak ifade edilmektedir. Denklemden yer alan α_i , koşullu kantil üzerinde konum değişikliğini ifade etmektedir. Değişkenlerin belirlenen kantil değerlerine (τ) bağlı olmasına izin verilmektedir (Koenker, 2004). Zamanla farklı panel kantil çalışmalarının literatürde yer aldığı görülmektedir. Bu çalışmada Powell (2016) çalışmasıyla tanıtılan ve Powell (2023) çalışmasında geliştirilen toplamsal olmayan sabit etkili panel kantil regresyon modeli kullanılmıştır. Bu panel veri modelinde sabit etkilerin bilindiği varsayılmaktadır. Toplamsal sabit etkiler modelinde $(Y_{it} - \alpha_i) | X_{it}$ dağılımı hakkında bilgi elde edilmektedir. Toplamsal olmayan sabit etkiler modelinde ise $(Y_{it} - \alpha_i) | X_{it}$ dağılımı yerine $Y_{it} | X_{it}$ bağımlı değişken dağılımı hakkında bilgi elde edildiğinden heterojenlik göz ardı edilmeden bağımlı değişken üzerindeki etki ortaya çıkarılabilmektedir. Toplamsal olmayan panel kantil modeli;

$$Y_{it} = X_{it}' \beta(U_{it}^*) \quad (5)$$

olarak tanımlanmaktadır. Denklemden yer alan $U_{it}^* = f(\alpha_i, U_{it})$ şeklinde sabit etkileri kapsayacak şekilde ifade edilmektedir (Powell, 2022: 2682).

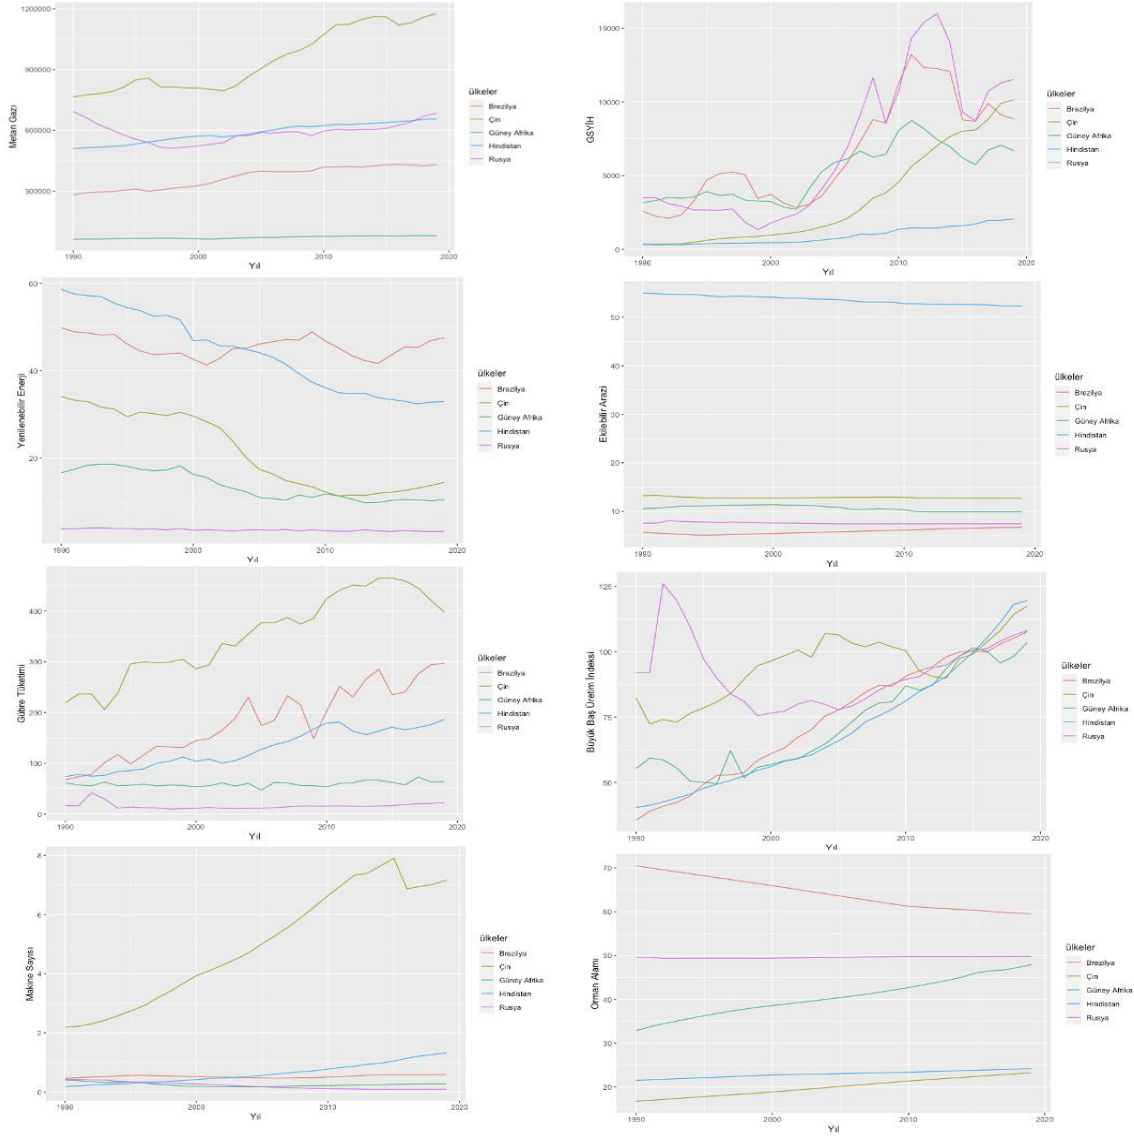
5. Veri ve Uygulama

Çalışmada BRICS ülkeleri için 1990-2019 yılları arasındaki veriler kullanılarak metan gazı emisyonunu etkileyen faktörler araştırılacaktır. Tablo 1'de çalışmada kullanılan değişkenler yer almaktadır.

Tablo1. Değişken Tanımları

	Uygulamaya Ait Değişkenler	Kaynak
MG	Metan emisyonu (kiloton karbondioksitin eşiti)	World Bank
GSYH	Kişi başı GSYİH (US \$)	World Bank
YE	Yenilenebilir enerji tüketimi (toplam enerji tüketiminin %)	World Bank
EA	Ekilebilir arazi (arazinin %)	World Bank
BUI	Büyükbaş hayvancılık üretim indeksi (2014-2016=100)	World Bank
GT	Gübre tüketimi (ekilebilir arazinin hektar başına düşen kilogramı)	World Bank
MS	Makine Sayısı (1000 hektar tarım arazi başına düşen)	Our World in Data
OA	Ormanlık Alan (toplam alan içindeki %) (meyve tarlaları ve tarımsal orman alanları hariç)	World Bank


Değişkenlere ait grafikler Şekil 2'de yer almaktadır.



Şekil 2. Değişkenlere ait Grafikler

Şekil incelendiğinde, 2019 yılı dikkate alındığında, metan gazının en fazla Çin’de en az Güney Afrika’da olduğu görülmektedir. Kişi başına düşen GSYİH en fazla Rusya en az Güney Afrika’da yer almaktadır. Yenilenebilir enerji kullanımı en fazla Brezilya’da en az Rusya’dadır. Ekilebilir Arazi en fazla Hindistan en az Brezilya’dadır. Gübre tüketimi en fazla Çin’de en az Rusya’dadır. Büyükbaş üretim indeksi en fazla Hindistan’da en az Güney Afrika’dadır. Makine Sayısı en fazla Çin en az Rusya’dadır. Orman alanı en fazla Brezilya’da en az ise Çin’dedir. Grafikler incelendiğinde, bazı değişkenlerin zaman içinde sıçramalara sahip olduğu görülmektedir. Bu durum aşırı değer olmasına sebep olabilmektedir.

Şekil 3'te bağımlı değişken Metan Gazına ait aşırı değerleri gösteren kutu grafiği yer almaktadır.



Şekil 3. Metan Gazı Kutu Grafiği

Şekil 3 incelendiğinde, noktalar metan gazı değişkenine ait veri setinde aykırı değerlerin olduğunu göstermektedir. Bu sebeple, aykırı gözlemlere karşı dirençli olan panel kantil regresyon kullanımı çalışma için avantajlı olacaktır.

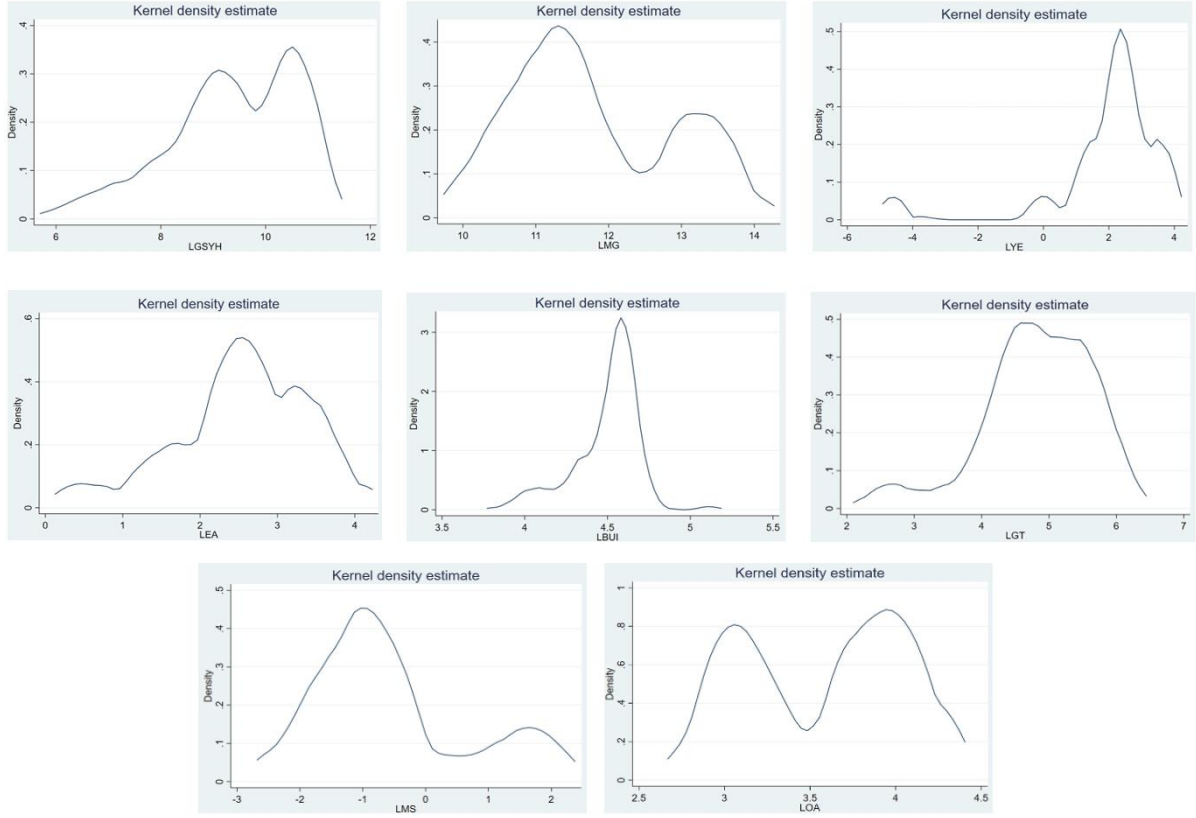
Değişkenlere ait tanımlayıcı istatistikler Tablo 2'de yer almaktadır. Değişkenler logaritmik formda modele dahil edilmiştir.

Tablo 2. Tanımlayıcı İstatistikler

Değişkenler	Ortalama	Medyan	Mak.	Min.	Std. Sapma	Çarpıklık	Basıklık	JB (prob.)
LMG	11.7674	11.5291	13.9778	10.0301	1.0730	0.4115	2.0061	9.5449* (0.000)
LGSYH	9.1922	9.2755	11.1296	5.7088	1.2938	-0.6738	2.7696	44.3889* (0.000)
LYE	1.9412	2.3154	4.0716	-4.7069	1.8040	-2.1631	8.2967	110.807* (0.000)
LEA	2.5402	2.5414	4.0069	0.3557	0.8682	-0.5914	2.9360	3.2117* (0.000)
LBUI	4.4363	4.5192	5.1446	3.5743	0.2580	-1.0128	3.5552	4.3941* (0.000)
LGT	4.8053	4.8404	6.3562	1.8290	0.8494	-0.8025	3.7956	75.9419* (0.000)
LMS	39.444	40.2168	70.4580	16.7380	16.7979	0.2167	1.6805	150.81* (0.000)
LOA	1.3183	0.4729	7.9045	0.0933	2.0337	2.0257	5.7776	12.057* (0.002)

*: %1'e göre normal dağılmadığını ifade etmektedir.

Tablo 2, değişkenler için tanımlayıcı istatistik sonuçlarını sunmaktadır. Jarque Bera test istatistikleri incelendiğinde, "seriler normal dağılmaktadır" temel hipotezinin reddedildiği görülmektedir.



Şekil 4. Uygulamaya Ait Değişkenlerin Kernel Yoğunluk Fonksiyonu Grafikleri

Şekil 4 incelendiğinde, değişkenlerin Kernel Yoğunluk fonksiyon grafiklerinin normal dağılım sergilemediği ve birden fazla tepeye sahip oldukları görülmektedir.

Yapılan inceleme sonucunda, normal dağılmayan, aşırı değerler barındıran değişkenler için farklı heterojen etkilerin modellenmesini sağlayan toplamsal olmayan panel kantil regresyon tahmin yöntemi kullanılarak BRICS ülkeleri için Çevresel Kuznets eğrisi hipotezinin geçerliliği incelenmiş ve sonuçları Tablo 3'te sunulmuştur.

Tablo 3. Toplamsal Olmayan Sabit Etkili Panel Kantil Regresyon Modeli Sonuçları

Q. Kantil	LMG	Katsayı	Std. Hata	Z (prob.)	Güven Aralıkları	
Q(20)	LGSYH	28.33291	1.077385	26.30* (0.000)	26.22127	30.44454
	LGSYH ²	-4.191281	0.1449334	-28.92* (0.000)	-4.475345	-3.907216
	LGSYH ³	0.1971537	0.0063729	30.94* (0.000)	0.1846629	0.2096444
	LYE	-0.6765331	0.045379	-14.91* (0.000)	-0.7654743	-0.587592
	LEA	0.8664791	0.0294095	29.46* (0.000)	0.8088375	0.9241207
	LGT	0.1378428	0.0474057	2.91* (0.004)	0.0449294	0.2307563
	LBUI	0.1531695	0.0291351	5.26* (0.000)	0.0960659	0.2102732
	LMS	1.13532	0.0213579	53.16* (0.000)	1.093459	1.177181
	LOA	3.020708	0.0756803	39.91* (0.000)	2.872377	3.169038
Q(50)	LGSYH	28.16399	1.645976	17.11* (0.000)	24.93794	31.39005
	LGSYH ²	-4.267471	0.2208818	-19.32* (0.000)	-4.700391	-3.83455
	LGSYH ³	0.2044287	0.0097623	20.94* (0.000)	0.185295	0.2235624
	LYE	-0.903096	0.0262113	-34.45* (0.003)	-0.9544691	-0.8517229
	LEA	1.029338	0.0221885	46.39* (0.000)	0.9858494	1.072827
	LGT	0.2760092	0.0243066	11.36* (0.000)	0.2283691	0.3236494
	LBUI	0.3381451	0.0211134	16.02* (0.000)	0.2967636	0.3795265
	LMS	1.07919	0.0188575	57.23* (0.000)	1.04223	1.11615
	LOA	3.544028	0.0701607	50.51* (0.000)	3.406515	3.68154

Tablo 3. Toplamsal Olmayan Sabit Etkili Panel Kantil Regresyon Modeli Sonuçları (Devam)

Q(80)	LGSYH	2.524009	0.9809861	2.57*	0.6013114	4.446706
				(0.010)		
	LGSYH ²	-0.4497282	0.1268149	-3.55*	-0.6982808	-0.2011756
				(0.000)		
	LGSYH ³	0.0236576	0.0054817	4.32*	0.0129138	0.0344015
				(0.000)		
	LYE	-0.4219534	.0071041	-59.40*	-0.4358771	-0.4080297
				(0.000)		
	LEA	0.1746625	0.0061573	28.37*	0.1625944	0.1867306
				(0.000)		
LGT	0.1690149	0.0262309	6.44*	0.1176033	0.2204266	
			(0.000)			
LBUI	0.1575232	0.0381946	4.12*	0.0826633	0.2323832	
			(0.000)			
LMS	0.1719574	0.0112324	15.31*	0.1499422	0.1939726	
			(0.000)			
LOA	0.195286	0.0510375	3.83*	0.0952544	0.2953176	
			(0.000)			

*: %5'e göre istatistiksel olarak anlamlılığı ifade etmektedir.

Çalışmanın sonuçları incelendiğinde; LGSYH, LGSYH², LGSYH³ değişkenlerinin tüm kantiller için sırasıyla; arttırıcı, azaltıcı, arttırıcı etkisi olduğu görülmektedir. Büyükbaş hayvan üretim indeksinin de metan gazını arttırıcı etkisi olduğu görülmektedir. Bunun temel sebebi, büyükbaş hayvanların geviş getirirken karbonhidratların mikroorganizmalar tarafından parçalanması sebebiyle metan gazının açığa çıkmasıdır (Karaalp, 2008). Gübre tüketiminin ve ekilebilir arazinin metan gazı salınımı arttırdığı yönünde sonuçlar elde edilmiştir. Toprağın verimli mahsul vermesi için kullanılan gübrenin oksijensiz ortamda parçalanması sebebiyle metan gazı açığa çıkmaktadır. Toprağın gübrelili olması ekilebilir arazinin metan gazı salınımını arttıracaktır. Tarım alanları için kullanılan makinenin gübrelili toprağı işleme sebebiyle metan gazını arttırdığı görülmektedir. Orman alanı değişkeni incelendiğinde, metan gazını arttırdığı görülmektedir. Biyogenik olmayan metan gazı ormanlardan, okyanuslardan, sulak alanlardan, pirinç üretiminden kaynaklanmaktadır (Işık ve Ökmen, 2013). Tarım alanında aşırı miktarda gübre kullanımı toprağı etkilemekte, yeraltı suları için de kirlilik kaynağı oluşturmaktadır. Toprağa ve suya uygulanan gübreler amonyak ve azot oksitlere ayrılmaktadır. Sürekli sulama yapılan alanlarda metan gazı salınımı olmaktadır (Atış 2005). Ormanlık alanlarda su kanalları, dere daha fazladır ve yağış diğer alanlara göre daha fazla gerçekleşmektedir. Bu durum, metan gazı artışına neden olmaktadır. Yenilenebilir enerjinin ise tüm kantil değerleri için metan gazı salınımını azaltıcı etkiye sahip olduğu görülmektedir.

BRICS ülkeleri için metan gazı salınımını etkileyen faktörlerin panel kantil regresyon yöntemi ile analiz edilmesiyle elde edilen tahmin sonuçları incelendiğinde, farklı kantil seviyelerinde eğim parametrelerinin $\beta_1 > 0$, $\beta_2 < 0$, $\beta_3 > 0$ ve anlamlı olduğu sonucuna varılmıştır. Sonuç olarak, BRICS ülkeleri için N biçiminde ÇKE hipotezinin geçerli olduğu belirlenmiştir.

6. Sonuç

Çevresel Kuznets eğrisi hipotezine göre ekonomi ve çevresel kirlilik birbirini etkileyen iki önemli kavramdır. Literatürdeki çalışmalar incelendiğinde, birçok çalışmada Çevresel Kuznets eğrisi hipotezinin geçerliliğinin ekonomik büyüme ve karbon emisyonu üzerindeki etkisinin araştırıldığı görülmektedir. Fakat çevre kirliliğine dair veriler incelendiğinde, iklim değişikliğine sebep olan ikinci büyük etkenin metan gazı salınımı olduğu

görülmektedir. Bu sebeple, metan gazı salınımının Çevresel Kuznets eğrisi hipotezi ile incelendiği çalışmanın kullanılan yöntem ve incelenen değişkenler açısından literatüre katkı sağlayacağı düşünülmektedir.

İnsan ırkının ortaya çıkması ve zamanla nüfusun artması sebebiyle tarım ve hayvancılığa olan talep artmaktadır. Nüfusun artmasıyla beraber gıda ihtiyacının karşılanması için tarım alanlarının verimli olması gerekliliğinden dolayı gübreye ihtiyaç duyulmaktadır. Kullanılan gübre ve bazı mahsuller (pirinç vb.) metan gazı salınımına sebep olmaktadır.

Bu sebeple, çalışmada ekonominin metan gazı salınımına etkisini incelerken büyükbaş hayvan üretim indeksi, gübre kullanımı, ekilebilir alan, yenilenebilir enerji kullanımı, tarım makine sayısı ve mahsul ekilmeyen ormanlık alanın toplam alan içindeki payı modele dahil edilerek ÇKE hipotezi incelenmiştir.

Çalışmada toplamsal olmayan panel kantil regresyon yönteminin tercih edilmesinin sebebi, farklı kantillerde dağılım yüzdelere göre olmamasıdır. Bu çalışmada düşük-orta-yüksek kantiller (Q20-Q50-Q80.) dikkate alınmıştır. Çalışma sonucunda farklı kantil seviyesindeki metan gazı salınımı üzerine değişkenlerin etkisi benzer yönde bulunmuştur. Büyükbaş hayvan indeksi, gübre tüketimi, ekilebilir alan, orman alanı, makine sayısı metan gazını arttırmaktadır. Gübrenin oksijensiz ortamda parçalanması sebebi ile metan gazı açığa çıkmaktadır. Büyükbaş hayvanlardan metan gazı yayılımı hem gübre hem de geviş getirmeleri sırasında gerçekleşmektedir. Ekilebilir alandaki artış daha fazla gübre kullanımı sebebiyle metan gazını arttırmaktadır. Ormanlık alanların fazla yağmur alması, dere, akarsu alanlarının fazla olması, metan gazı üzerinde arttırıcı etkiye sahiptir. Yenilenebilir enerjinin metan gazını azalttığı; bu sebeple, kullanımının iklim değişikliği için kıymetli olduğu görülmektedir. Bu sebeple, kömür, fosil yakıt, benzin yerine yenilenebilir enerji kullanımı önem arz etmektedir. Büyüme değişkenleri incelendiğinde Çevresel Kuznets hipotezinin geçerli ve N şeklinde olduğu belirlenmiştir.

Çalışma sonucunda büyükbaş hayvanların sayısını azaltmaya yönelik bir politika önerisi sunmak gıda tüketimi açısından temel protein kaynağı olan büyükbaş hayvanlar için pek mümkün değildir. Bu konuda hayvanların çevreye zarar vermeyecek şekilde yetiştiriciliğine yönelik önlemler alınabileceği düşünülmektedir. Gübre tüketimi ve ekilebilir arazi için toprağı korumaya ve işlemeye yönelik politikaların geliştirilerek toprağın verimli olması için farklı yöntemlerin kullanılması ve gübre tüketiminin azaltılması, çevreye zararlı olmayan inorganik gübrelerin kullanılması da uygulanacak politikalar arasında olabilir. Metan gazı salınımını azaltıcı etkisi olduğu görülen yenilenebilir enerji kaynaklarının kullanımı yaygınlaştırılmalı; bu sebeple, rüzgâr, güneş, dalga, hidrolik güç, jeotermal enerji panelleri kurularak temiz enerji sağlanmalıdır.

Kaynaklar

- Atış, E. (2005). *Tarımsal yapı ve üretim*. F. Yavuz (Ed.), Türkiye’de Tarım içinde (161-176).
- Acevedo-Ramos, J. A., Valencia, C. F., & Valencia, C. D. (2023). The Environmental Kuznets Curve Hypothesis for Colombia: Impact of Economic Development on Greenhouse Gas Emissions and ecological footprint. *Sustainability*, 15(4), 3738.
- Agras, J. & Chapman, D. (1999). A Dynamic Approach to the Environmental Kuznets Curve Hypothesis. *Ecological Economics*, 28, 267-277.
- Ang, J. B. (2007). CO2 Emissions, Energy Consumption, and Output in France. *Energy Policy*, 35(10), 4772-4778.
- Ajam, N., Moghaddasi, R., & Mohammadnejad, A. (2021). Environmental Impacts of Globalization (An Empirical Examination of Iran’s Agriculture). *Journal of Southwest Jiaotong University*, 56(4).
- Barrett, S., & Graddy, K. (2000). *Freedom, Growth, and The Environment*. *Environment and Development Economics*, 5(4), 433-456.
- Benaides, M., Ovalle, K., Torres, C., & Vences, T. (2017). Economic Growth, Renewable Energy and Methane Emissions: Is There an Enviromental Kuznets Curve in Austria?. *International Journal of Energy Economics and Policy*, 7(1), 259-267.
- Bo, S. (2011), A Literature Survey on Environmental Kuznets Curve, *Energy Procedia*, 5: 1322-1325.
- Chu, L. K. (2021). Economic Structure and Environmental Kuznets Curve Hypothesis: New Evidence from Economic Complexity. *Applied Economics Letters*, 28(7), 612-616.
- Cole, M.A., Rayner, A.J. & J.M Bates (1997), The Environmental Kuznets Curve: An Empirical Analysis, *Environment and Development Economics*, 2 (04), 401–416.
- Demissew Beyene, S., & Kotosz, B. (2020). Testing the Environmental Kuznets Curve Hypothesis: An Empirical Study for East African Countries. *International Journal of Environmental Studies*, 77(4), 636-654.
- Dijkgraaf, E., & Vollebergh, H. R. (2005). A Test for Parameter Homogeneity in CO 2 Panel EKC Estimations. *Environmental and Resource Economics*, 32, 229-239.
- Dinda, S. (2004). Environmental Kuznets Curve Hypothesis: A Survey. *Ecological Economics*, 49(4), 431-455.
- Djoukouo, A. F. D. (2021). Relationship Between Methane Emissions and Economic Growth in Central Africa Countries: Evidence from Panel Data. *Global Transitions*, 3, 126-134.
- Ericsson, A. (2022). Methane Emissions and Economic Growth: An N-shaped Environmental Kuznets Curve for the G20 Countries?.
- Guriş, S., & Şak, N. (2019). Çevresel Kuznets Eğrisi Hipotezinin Toplamsal Olmayan Sabit Etkili Panel Kantil Yöntemiyle İncelenmesi. *Business and Economics Research Journal*, 10(2), 327-340.
- Grossman, G. M., & Krueger, A. B. (1991). Environmental Impacts of the North American Free Trade Agreement. *NBER Working Paper*, No: 3914.
- Hamilton, C. & Turton, H. (2002). Determinant of Emissions Growth in OECD Countries, *Energy Policy*, 30, 63-71.
- Handoyo, R. D., Rahmawati, Y., Rojas Altamirano, O. G., Ahsani, S. F., Hudang, A. K., & Haryanto, T. (2022). An Empirical Investigation Between FDI, Tourism, and Trade on CO2 Emission in Asia: Testing Environmental Kuznet Curve and Pollution Haven Hypothesis. *International Journal of Energy Economics and Policy*, 12(4), 385-393.
- Hao, Y., Liu, Y., Weng, J. H., & Gao, Y. (2016). Does the Environmental Kuznets Curve for Coal Consumption in China exist? New Evidence from Spatial Econometric Analysis. *Energy*, 114, 1214-1223.

Citation / Atf: ŞENGÜL Z., ŞAK N. (2023). Tarımsal Üretim ve Hayvancılığın Çevresel Kirliliğe Etkisi: Toplamsal Olmayan Panel Kantil Yöntemi. *İstatistik Araştırma Dergisi*, 13 (2), 28-41.

Jalil, Abdul & Syed F. Mahmud (2009), Environment Kuznets Curve for CO2 Emissions: A Cointegration Analysis for China, *Energy Policy*, 37, 5167–5172.

Jaunky, V.C. (2011). The CO2 Emissions-Income Nexus: Evidence from Rich Countries, *Energy Policy*, 39, 1228-1240.

Kahvecioğlu, Y. (2004). *Tüketim Toplumu, Ekolojik Risk ve Türkiye* (Doctoral dissertation, Bursa Uludağ University (Turkey)).

Karaalp, H. S. (2008). *Sektörel Açından İklim Değişikliği: Tarım, Ulaştırma ve Sanayi*. E. Karakaya (Ed.), Küresel Isınma ve Kyoto Protokolü İçinde (S. 265- 307). Ankara: Bağlam Yayıncılık.

Koenker, R. (2004). Quantile Regression for Longitudinal data. *Journal of Multivariate Analysis*, 91(1), 74-89.

Koenker, R., & Bassett Jr, G. (1978). Regression Quantiles. *Econometrica: Journal of the Econometric Society*, 33-50.

Lebe, F. (2016). Çevresel Kuznets eğrisi hipotezi: Türkiye için Eşbütünlük ve Nedensellik analizi. *Doğuş Üniversitesi Dergisi*, 17(2), 177-194.

Işık, D., & Ökmen, G. (2013). Metan üreten mikroorganizmalar. *Türk Bilimsel Derlemeler Dergisi*, (2), 79-85.

Panayotou, T. (1993). *Empirical Tests And Policy Analysis Of Environmental Degradation At Different Stages Of Economic Development*.

Powell, D. (2022). Quantile Regression With Nonadditive Fixed Effects. *Empirical Economics*, 63(5), 2675-2691.

Shahbaz, M., Gozgor, G., Adom, P. K., & Hammoudeh, S. (2019). The Technical Decomposition of Carbon Emissions and the Concerns about FDI and Trade Openness Effects in the United States. *International Economics*, 159, 56-73.

Selden, T. M., & Song, D. (1994). Environmental Quality and Development: Is There A Kuznets Curve For Air Pollution Emissions?. *Journal Of Environmental Economics And Management*, 27(2), 147-162.

Spilker, G. (2013). *Globalization, Political Institutions and the Environment in Developing Countries*. New York: Routledge.

Temur, B. (2017). *Küresel Isınmanın Türkiye'de Tarım Sektörü Üzerine Etkisi: Bir Ardl Modeli Uygulaması* (Doctoral dissertation, Anadolu University (Turkey)).

Torras, M., & Boyce, J. K. (1998). Income, İnequality, and Pollution: a Reassessment of the Environmental Kuznets Curve. *Ecological Economics*, 25(2), 147-160.

Williamson, C. (2017). Emission, Education, and Politics: an Empirical Study of the Carbon Dioxide and Methane Environmental Kuznets Curve. *The Park Place Economist*, 25(1), 9.

“Dünyanın Gözü Metan Gazında”. *Euronews* (2023, Nisan 23). Erişim Tarihi: 23 Nisan 2023.
<https://tr.euronews.com/green/2021/07/14/dunyan-n-gozu-metan-gaz-nda>



The Analysis of the Relationship Among Climate Policy Uncertainty, Logistic Firm Stock Returns and ESG Scores: Evidence from the TVP-VAR Model

Fatma Gül ALTIN

Mehmet Akif Ersoy University / Assoc. Prof.

gulaltin@mehmetakif.edu.tr

Orcid No: 0000-0001-9236-0502

Samet GÜRİSOY

Mehmet Akif Ersoy University / Assist. Prof.

sametgursoy@mehmetakif.edu.tr

Orcid No: 0000-0003-1020-7438

Mesut DOĞAN

Bilecik Şeyh Edebali University / Assoc. Prof.

mesutdogan07@gmail.com

Orcid No: 0000-0001-6879-1361

Enes Burak ERGÜNEY

Mehmet Akif Ersoy University / Master Student

enesburakergney@gmail.com

Orcid No: 0000-0002-1538-1489

Abstract

This study examines the relationship between climate policy uncertainty (CPU), China's environmental impact, social responsibility and corporate governance practices (ESG) leader scores and logistics stocks. China Ocean Shipping Company (COSCO), one of the pioneers in global markets, was chosen to represent the logistics industry. The variables were analyzed with the Time-Varying Parameter Vector Autoregressive Model (TVP-VAR) using monthly data from October 2007 to July 2022. As a result of the analysis, it was determined that the COSCO logistics sector variable spreads the volatility to the Chinese ESG Leaders and CPU variables. This indicates that COSCO, one of the leading companies in the global markets, has an impact on the sustainability scores of the CHINA Stock Exchange. In other words, it has been observed that shock transfer occurs from the COSCO variable to the China ESG Leader and CPU variables. Finally, it proves that the sustainability scores of companies operating in the Logistics sector, especially for China, are dominant among all other sector scores.

Keywords: Climate Policy Uncertainty, ESG, Logistics Sector, COSCO

Corresponding Author / Sorumlu Yazar: 1- Mesut DOĞAN, Bilecik Şeyh Edebali University.

Citation / Atf: ALTIN F. G., GÜRİSOY S., DOĞAN M., ERGÜNEY E. B. (2023). The Analysis of the Relationship Among Climate Policy Uncertainty, Logistic Firm Stock Returns and ESG Scores: Evidence from the TVP-VAR Model. *İstatistik Araştırma Dergisi*, 13 (2), 42-59.

İklim Politikası Belirsizliği, Lojistik Firma Hisse Getirileri ve ESG Puanları Arasındaki İlişkinin Analizi: TVP-VAR Modelinden Kanıtlar

Özet

Bu çalışma iklim politikası belirsizliği (CPU), ESG skorları ve lojistik hisse getirileri arasındaki ilişkiyi incelemektedir. Lojistik sektörünü temsilen China Ocean Shipping Company (COSCO) seçilmiştir. Ekim 2007-Temmuz 2022 döneminin aylık verileri kullanılarak Zamanla Değişen Parametre Vektörü Otopregresif Modeli (TVP-VAR) uygulanmıştır. Analiz sonucunda COSCO'nun volatilitiyi Çin ESG ve CPU'ya yaydığı tespit edilmiştir. Bu durum küresel piyasalarda öncü firmalardan olan COSCO'nun Çin Borsasının sürdürülebilirlik skorları üzerinde etkili olduğunu işaret etmektedir. Başka bir ifadeyle, COSCO değişkeninden Çin ESG skorları ve CPU değişkenlerine şok aktarımı gerçekleştirdiği görülmüştür. Son olarak, özellikle Çin için Lojistik sektöründe faaliyet gösteren firmaların sürdürülebilirlik skorlarının tüm diğer sektör skorları içinde de baskın olduğunu kanıtlar niteliktedir.

Anahtar sözcükler: İklim Politika Belirsizliği, ESG, Lojistik Sektörü, COSCO

1. Introduction

Global warming and climate change are not only one of the most important problems facing humanity in the 21st century, but also a problem that changes the future plans of companies (Chen et al. 2023). On the other hand, policies aimed at combating climate change bring along the efforts of countries around the world to reduce greenhouse gas emissions for a more sustainable future (Gavriilidis, 2021). Therefore, how to regulate environmental protection along with economic growth in the face of climate change has become an important issue all over the world (Ren et al. 2022). The Paris Agreement has brought a new perspective to climate policy, such as promoting the use of clean energy, carbon emission permits and green bonds. However, there are concerns about the uncertainties in the implementation of these policies and the macroeconomic effects of these uncertainties (Li, 2022).

Logistics has become a rapidly growing and developing industry around the world, playing a very important role in global trade and economic growth (Yingfei et al., 2022). The primary purpose for companies is to organize logistics activities in a way that maximizes profitability. However, in recent times, as a result of growing public and governmental emphasis on ecological matters, company have faced mounting demands to diminish the ecological footprint arising from their logistical activities (McKinnon, 2015). The growing trend of globalization, coupled with the rising prominence of outsourcing and commercial interactions within the logistics industry, underscores the critical significance of effective supply chain management. However, this heightened connectivity and economic activity also contribute to environmental challenges. Greenhouse gas emissions stemming from fuel consumption, escalating use of natural resources, and the mounting volume of packaging and other waste types present substantial issues, impacting sustainability across environmental, economic, and social dimensions (Yontar, 2022).

Logistics pertains to the systematic administration of procurement, conveyance, and warehousing of resources, components, and finalized goods across companies and distribution networks, encompassing the associated streams of information to meet order requirements (Christopher, 2011). Green logistics is the main sustainability trend of modern logistics. The notion of eco-friendly logistics pertains to a collection of supply chain management practices concentrated on the handling of materials, waste disposal, packaging, and transportation. Its objective is to minimize the environmental and energy impacts associated with the distribution of goods (Seroka-Stolka & Ociepa-Kubicka, 2019). Maritime transport accounts for more than 80% of world trade, which constitutes a large area for global logistics applications (Pang et al., 2021:423). Although this situation offers shipping companies new opportunities in the global economy, it has caused the maritime industry to cope with some new challenges. The globalization of commercial practices has brought with it climate change and environmental problems caused by maritime transport (Felicio et al. 2021).

Supply chain practices, especially logistics practices, are part of the critical practices of companies that consume more energy and release dangerous gases and wastes into the environment (Agyabeng-Mensah et al., 2020:1). Logistics is the most dependent on fossil fuels of all sectors. In addition, 37% of CO₂ emissions in 2021 originate from the logistics sector. Although logistics is one of the sectors most affected by the Covid-19 epidemic, this rate is increasing day by day due to global trade (IEA, 2021). In 2021, global CO₂ emissions from the logistics sector rose 8% to around 7.7 Gt CO₂, as pandemic restrictions were lifted and passenger and goods movements resumed after the big drop in 2020 (IEA Transport Report, 2022). Figure 1 shows the global CO₂ emission rates in transport by mode for 2020. In Figure 1, “shipping” CO₂ emissions rank third after “passenger cars” and “medium and heavy trucks”.

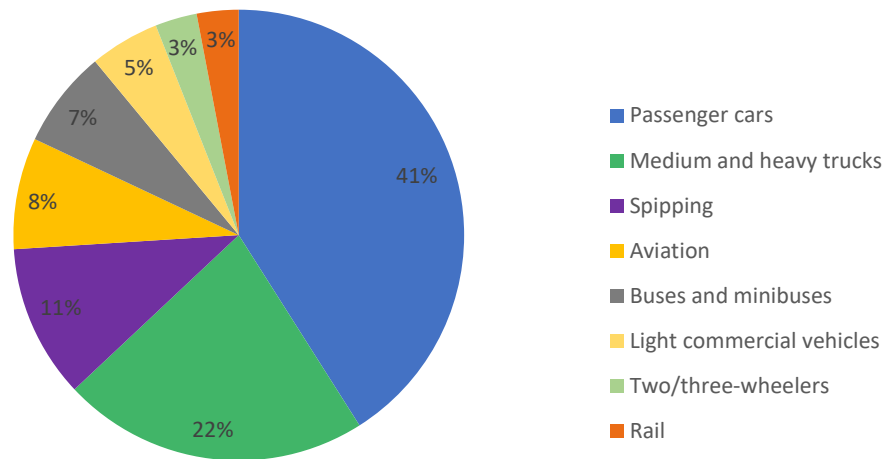


Figure 1. Global CO₂ emissions in transport by mode of 2020

Source: IEA, 2022

The possible stagnation of economies in an environment of uncertainty is supported by academic literature. On the other hand, it is seen that many prediction and calculation methods have been developed for the uncertainties in global markets. Apart from the known methods, an indexing that has been trying to find a place in the academic literature in recent years has come to the fore. These indexes, in which economic and political uncertainties are calculated, appear as a form of calculation that includes political discourses along with financial risk. The climate policy uncertainty index(CPU) is also an index created using this method (Gürsoy, 2021). Combating environmental degradation worldwide is of great importance for both developed and developing countries. The fact that the issue has global as well as local effects forces countries to cooperate in improving environmental quality in this field. Researchers examine numerous determinants of environmental quality that can help reduce the growing ecological footprint and achieve sustainable development and make recommendations on how environmental quality can be improved worldwide. Financial and economic variables can influence environmental dynamics in various ways, ultimately causing environmental degradation or contributing to environmental recovery. As a result of both situations, there is an expectation that environmental sustainability has a two-way interaction, especially with logistics (Shahbaz et al. (2023)

This study explores the correlation spread between CPU, ESG and COSCO stock returns. Previous studies have shown that CPU index and sustainability were examined together. In particular, the relationship between climate policy uncertainty and variables such as sustainable financial assets (stock market, bonds), fossil fuel prices, geopolitical risk, EPU, exchange rate is frequently investigated. The number of studies investigating the relationship between CPU, ESG and stock market is quite limited. In the study, the share prices of China Ocean Shipping Company (COSCO) were taken to represent the logistics sector. COSCO is one of the world's leading conglomerates for container shipping. On the other hand, it is the largest company in China. COSCO is the world's fourth largest container shipping company in 2022, with operations spread over 40 countries with a fleet of approximately 480 container ships with a container carrying capacity of 2,932,779 TEU (Marine Insight, 2023). On the other hand, it is still the fourth largest company in the world with a container transport capacity of 2,888,256 TEU and a market share of 10.8% as of May 19, 2023 (Alphaliner, 2023). In addition, the results of the study are important for investors and company managers. The results obtained will allow policy makers to develop more realistic and accurate sustainable environmental policies.

The rest of this study is created as follows: In the subsequent section a brief literature review is given. In section 3, detailed explanations are given about the time-varying parameter vector autoregressive (TVP-VAR) model. In Chapter 4, after giving information about the variables and data set, analyses are made to determine the asymmetric dynamic spillover relationship and empirical findings are discussed. Finally, the results are evaluated and suggestions for next studies are presented.

2. Literatür Review

In the last few years, the Climate Policy Uncertainty (CPU) Index, MSCI China ESG Leaders Index (China ESG Leaders) and the shipping market have been evaluated from different perspectives in the literature using the time-varying parameter vector autoregressive (TVP-VAR) model. Below is a three-dimensional literature review. First of all, studies on CPU and TVP-VAR model, and secondly, studies on MSCI Index and TVP-VAR model were examined. Finally, studies focusing on the shipping market and TVP-VAR model were examined.

- CPU Index and TVP-VAR Model

Yan and Cheung (2023) explored the changing impacts of Central Processing Unit (CPU) and coal price on the carbon price in China through the implementation of the TVP-VAR model. The research involved the development of a CPU index specifically for China. The findings of the analysis revealed that both CPU and coal price exhibited noteworthy time-varying influences on the carbon price. Yu et al. (2023) examined the time-varying effects of CPU on green bond market volatility using the TVP-VAR model. With short-term overreactions or underreactions as well as medium and long-term inversions were found from the analyses.

Xiao and Liu (2023) evaluated the effect of uncertainty measures of CPU, geopolitical risk (GPR), economic policy uncertainty (EPU), and equity market volatility (EMV) on the oil implied volatility index (OVX) using TVP-VAR model. Empirical results have shown that the CPU is more important to trigger oil market fears since the last Paris Agreement. During the COVID-19 pandemic, CPU, EPU and EMV instead of GPR play an important role in increasing the fear of the oil market.

Zhou et al. (2023) investigated a model known as the time-varying parameter vector autoregressive model with stochastic volatility (TVP-VAR-SV) to ascertain the changing association between CPU, oil prices, and renewable energy consumption. The outcomes of their examination revealed that the relationship between these variables fluctuates over time. In a separate study, Guo et al. (2022) examined the nonlinear impacts of CPU, financial speculation, economic activity, and the US dollar exchange rate on global prices of crude oil and natural gas by employing TVP-VAR-SV models. The findings underscored the existence of significant nonlinear effects in how energy prices respond to various shocks.

- MSCI Index and TVP-VAR Model

Polat et al. (2023) investigated the influence of the media coverage index (MCI) related to COVID-19 on the interconnectedness of return and volatility among five MSCI Climate Changes Indices, namely the USA, Emerging Markets (EMU), Japan, Europe, and the Asia Pacific. The research employed the TVP-VAR model and the frequency-dependent connectedness network approach for analysis. Empirical results underscore that the MCI acts as a recipient of net shocks across all waves, with the highest level of interconnectedness observed in the initial wave. Similar patterns were observed regarding volatility in the findings. Cepni et al. (2023) assessed the influence of climate-related uncertainty on the transmission of effects among conventional and environmental, social, and governance (ESG) financial markets in Europe. The study examined the spillover effects stemming from climate uncertainty within these markets. TVP-VAR and asymmetric dynamic conditional correlation (ADCC) models and portfolio analysis were used in the analyses. The results show substantial evidence of climate uncertainty, important insights into managing climate risk exposures, and the driver of information spillovers across conventional and ESG assets.

Liu et al. (2023) examined the effect of ESG investment on return and volatility spillover effects in major Chinese financial markets such as stock, bond, interbank and foreign exchange markets using the TVP-VAR method. In the study, it was found that sustainability and stability are positively related. Akhtaruzzaman et al. (2022) investigated the dynamic connectedness between the COVID-19 MCI and the ESG leader indices. The results of the analysis showed that MCI facilitated the contagion during the pandemic to the developed and emerging equity markets.

- Shipping Market and TVP-VAR Model

Xie et al. (2023) analyzed risk spillovers in China's financial and maritime markets using dynamic spillover measures based on TVP-VAR and generalized forecast error variance decompositions (GFEVD). Unexpectedly, the study found that bonds, gold, and shipping were safe tools that facilitate portfolio optimization. Samitas et al. (2022-a) evaluated the dynamic interconnections between fine wine, equities, bonds, crude oil, commodities, gold, copper, shipping, and real estate markets using the TVP-VAR model. The research investigated the presence of positive spillovers in terms of volatility among these markets. However, the study revealed that the overall connectedness is susceptible to external shocks, which reach their highest levels during periods of stress.

Samitas et al. (2022-b) analyzed the transmission of volatility between natural alternative investments (such as timber and water) and a range of traditional financial instruments (including bonds, crude oil, gold, real estate, shipping, and currency) using a time-varying spillover methodology. The results indicate that these markets demonstrate a moderate level of integration, and the overall interconnectedness amplifies during periods of heightened stress. In a separate study, Chen et al. (2021) explored the nonlinear and dynamic relationship between the global oil market, the global shipping market, the Chinese stock market, and GDP using the TVP-VAR-SV model. The findings suggest that the impact intensity of the Baltic Dry Index (BDI) on China's economy triggers diverse changes, ranging from positive to negative, across various lag periods.

In Table 1, the author, variable, period information and methodology of the studies in the literature are summarized, respectively.

Table 1. Literature Summary

<i>CPU Index and TVP-VAR Model</i>			
Yan and Cheung (2023)	- CPU Index - Coal Price - Carbon Emission	02.01.2019- 05.05.2022 (daily)	- TVP-VAR Model
Yu, Zhang, Liu and Wang (2023)	- CPU Index - Green Bond Index - Green bond volatility	01.01.2010 - 31.12.2021 (monthly)	- TVP-VAR Model
Xiao and Liu (2023)	- CPU Index - OVX Index - GPR Index - EPU Index - EMV Index	01.05.2007 - 31.10.2021 (monthly)	- TVP-VAR Model
Zhou, Siddik, Guo and Li (2023)	- CPU Index - Oil Prices - Renewable Energy Consumption	01.01.2005 - 30.04.2021 (monthly)	- TVP-VAR-SV Model
Guo, Long and Luo (2022)	- CPU Index - Oil Prices - Natural Gas Prices - Baltic Dry Index - US dollar exchange rate - T-index (WT)	01.01.2000 - 31.03.2021 (monthly)	- TVP-VAR-SV Model

Table 1. Literature Summary (Continuing)

<i>MSCI Index and TVP-VAR Model</i>			
Polat, Khoury, Alshater and Yoon (2023)	- MSCI Climate Change Index - Media Coverage Index	11.03.2020 - 19.01.2023 (daily)	- TVP-VAR Model - Frequency-based TVP-VAR Network Connectedness
Cepni, Demirer, Pham and Rognone (2023)	- MSCI Europe ESG Various Euro-based Leaders Index - ESG Bond Indexes	03.01.2014 - 30.09.2021 (daily)	- TVP-VAR Model - ADCC Model - Portfolio analysis
Liu, Guo, Ping and Luo (2023)	- ESG Stock - General Stock - Interbank Market - Bond Market - FX Market	01.09.2010 - 31.08.2022 (monthly)	- TVP-VAR Model
Akhtaruzzaman, Boubaker and Umar (2022)	- Media Coverage Index - ESG leader Index (EMU, China, Brazil, Russia, India, and South Africa, UK and US)	01.01.2020- 21.04.2021 (daily)	- TVP-VAR Model
<i>Shipping Market and TVP-VAR- (SV) Model</i>			
Xie, Cheng, Liu, Zheng and Li (2023)	- Stock, - Fund - Bond, - Interbank - Forex, - Futures - Gold, - Shipping	20.01.2020 - 26.05.2022 (daily)	- TVP-VAR Model - GFEVD
Samitas, Papathanasiou, Koutsokostas and Kampouris (2022-a)	- Fine wine, Bonds - Equities, Gold - Bonds, - Crude oil, - Commodities, -, Shipping - Copper, -, - Real estate	01.01.2010- 31.05.2021 (monthly)	- TVP-VAR Model
Samitas, Papathanasiou, Koutsokostas and Kampouris (2022-b)	- Timber, - Water - Equities, - Bonds - Crude oil, - Gold - Real estate, - Shipping - Currency	01.01.2010 - 30.09.2021 (monthly)	- TVP-VAR Model
Chen, Zhang and Chai (2021)	- World oil market - Global bulk shipping market - Stock market - Economic growth	01.01.1998 - 31.12.2020 (quarterly)	- TVP-VAR-SV Model

3. Research Methodology

This section provides an elaborate description of the time-varying parameter vector autoregressive (TVP-VAR) model, elucidating its conceptual framework. Figure 2 below illustrates the methodological structure employed in the study.

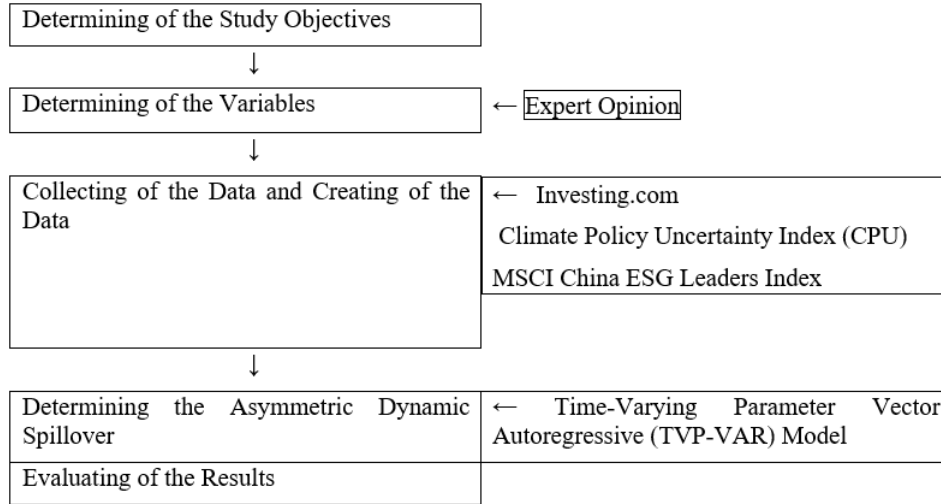


Figure 2. Methodological Framework

In this study, time-varying parameter vector autoregressive (TVP-VAR) model was used to investigate the time-dependent dynamic relationship between the returns of the series, proposed by Antonakakis et al. (2020). The TVP-VAR approach proposed by Antonakakis et al. (2020) allows variation of the variance-covariance matrix over time through a Kalman Filter estimation based on Koop and Korobilis (2014) forgetting factors. In fact, it extends the connectedness approach proposed by Diebold and Yilmaz (2009, 2012, 2014). In this way, the model avoids the possibility that the rolling-windows technique, which has no consensus in the literature about the selection criteria and which is usually chosen arbitrarily, leads to irregular or flattened parameters and the loss of valuable observations (Antonakakis & Gabauer, 2017; Gabauer & Gupta, 2018; Korobilis & Yilmaz, 2018). Accordingly, the model can be used to examine dynamic connectivity measures for both low-frequency data and limited time-series data. The lag length of the series was determined as 1 according to the Bayes information criterion (BIC) and the TVP-VAR (1) estimation was performed.

The TVP-VAR model is expressed as follows:

$$y_t = A_t z_{t-1} + \epsilon_t \quad \epsilon_t | \Omega_{t-1} \sim N(0, \Sigma_t) \quad (1)$$

$$vec(A_t) = vec(A_{t-1}) + \xi_t \quad \xi_t | \Omega_{t-1} \sim N(0, \Xi_t) \quad (2)$$

with

$$z_{t-1} = \begin{pmatrix} y_{t-1} \\ y_{t-2} \\ \vdots \\ y_{t-p} \end{pmatrix} \quad A'_t = \begin{pmatrix} A_{1t} \\ A_{2t} \\ \dots \\ A_{pt} \end{pmatrix}$$

Here, respectively, it represents; all available information till Ω_{t-1} , $t-1$; y_t and z_t $m \times 1$ and $mp \times 1$ vectors; A_t and A_{it} , $m \times mp$ and $m \times m$ dimensional matrix; ϵ_t one $m \times 1$ vector and ξ_t one $m^2p \times 1$ dimensional matrix. The time-varying variance-covariance matrices Σ_t ve Ξ_t are $m \times m$ and $m \times m$ and $m^2p \times m^2p$ dimensional matrixes, respectively. Also, $vec(A_t)$, $m^2p \times 1$ is a vectorization of A_t , which is a $m^2p \times 1$ vector.

Prior prediction is used to initialize the Kalman filter. Based on equations, with A_{OLS} , Σ_{OLS}^A and Σ_{OLS} equal to the VAR estimate for the first 20 months:

$$vec(A_0) \sim N(vec(A_{OLS}), \Sigma_{OLS}^A)$$

$$\Sigma_0 = \Sigma_{OLS}$$

To ensure numerical stability in the Kalman filter algorithm, the decay factors were applied as $k_1=0,99$ and $k_2=0,99$ recommended by Koop and Korobilis (2014)

Time-varying coefficients and time-varying variance-covariance matrices, Koop et al. (1996) and Pesaran and Shin (1998), based on generalized impulse response functions (GIRF) and generalized prediction error variance decompositions (GFEVD) to estimate the generalized connectivity procedure. For the calculation of GIRF and GFEVD, TVP-VAR needs to be converted to a vector moving average (VMA) representation within the framework of the Wold Decomposition theorem. The VMA representation is converted as follows (Dogan et al., 2023; Akkus and Dogan, 2023):

$$y_t = J'(M_t(z_{t-2} + \eta_{t-1}) + \eta_t) \quad (3)$$

$$= J'(M_t(M_t(z_{t-3} + \eta_{t-2}) + \eta_{t-1}) + \eta_t) \quad (4)$$

$$\vdots \quad (5)$$

$$= J'(M_t^{k-1}z_{t-k-1} + \sum_{j=0}^k M_t^j \eta_{t-j}) \quad (6)$$

M_t indicate a dimension matrix of the $mp \times mp$, η_t is dimension vector of a $mp \times 1$, J indicate a dimension matrix of the $mp \times m$

GIRFs ($\Psi_{ij,t}(H)$) express the response in all variables j to a shock in variable i . it is not a structural model, an estimate of H (H step ahead) is calculated in which variable i is both shock and non-shock, and the difference between is attributed to variable i . This is as follows

$$GIRF_t(H, \delta_{j,t}, \Omega_{t-1}) = E(y_{t+H} | e_j = \delta_{j,t}, \Omega_{t-1}) - E(y_{t+H} | \Omega_{t-1}) \quad (7)$$

$$\Psi_{j,t}(H) = \frac{B_{H,t} \Sigma_t e_j}{\sqrt{\Sigma_{jj,t}}} \frac{\delta_{j,t}}{\sqrt{\Sigma_{jj,t}}} \quad \delta_{j,t} = \sqrt{\Sigma_{jj,t}} \quad (8)$$

$$\Psi_{j,t}(H) = \Sigma_{jj,t}^{-\frac{1}{2}} B_{H,t} \Sigma_t e_j \quad (9)$$

Calculating GFEVD ($\tilde{\phi}_{ij,t}(H)$) which represents bidirectional dependency from j to i . The effect of variable j on variable i is explained in terms of estimation error variance shares. The said variance shares are normalized and all variables together explain 100% of the estimation error variance of the variable i . Its mathematical expression is as follows:

$$\tilde{\phi}_{ij,t}(H) = \frac{\sum_{t=1}^{H-1} \Psi_{ij,t}^2}{\sum_{j=1}^m \sum_{t=1}^{H-1} \Psi_{ij,t}^2} \quad (10)$$

$\sum_{j=1}^m \tilde{\phi}_{ij,t}(H) = 1$ Ve $\sum_{i,j=1}^m \tilde{\phi}_{ij,t}(H) = m$. The denominator in this equation is the cumulative effect of all shocks; The numerator represents the cumulative effect of a shock in the variable i . Using the GFEVD, the Total Connectedness Index (TCI) is calculated as follows:

$$C_t(H) = \frac{\sum_{i,j=1,i \neq j}^m \tilde{\phi}_{ij,t}(H)}{\sum_{i,j=1}^m \tilde{\phi}_{ij,t}(H)} * 100 = \frac{\sum_{i,j=1,i \neq j}^m \tilde{\phi}_{ij,t}(H)}{m} * 100 \quad (11)$$

This connectedness approach shows the spread of the shock in one variable to other variables. Based on this approach, Total Directional Connectedness to Others (TO), which shows the spread of the shock in variable i to all other variables j , is calculated as follows:

$$C_{i \rightarrow j,t}(H) = \frac{\sum_{j=1,i \neq j}^m \tilde{\phi}_{ji,t}(H)}{\sum_{j=1}^m \tilde{\phi}_{ji,t}(H)} * 100 \quad (12)$$

Total Directional Connectedness from Others (FROM), that shows the spread of shock in all j variables to variable i , is calculated as follows:

$$C_{i \leftarrow j,t}(H) = \frac{\sum_{j=1,i \neq j}^m \tilde{\phi}_{ij,t}(H)}{\sum_{i=1}^m \tilde{\phi}_{ij,t}(H)} * 100 \quad (13)$$

To unveil the Net Total Directional Connectedness, which signifies the impact a variable exerts on the examined network, the disparity between Total Directional Connectedness to Other Variables (TO) and Total Directional Connectedness from Other Variables (FROM) is computed:

$$C_{i,t} = C_{i \rightarrow j,t}(H) - C_{i \leftarrow j,t}(H) \quad (14)$$

In this equation, if $C_{i,t}$ takes a positive value, it indicates that variable i directs the network by affecting other variables more than it has; If $C_{i,t}$ takes a negative value, it means that variable i is driven by the network under the influence of other variables.

Finally, Net Pairwise Directional Connectedness is calculated by decomposing Net Total Directional Connectedness to examine bidirectional relationships:

$$NPDC_{ij}(H) = (\tilde{\phi}_{jit}(H) - \tilde{\phi}_{ijt}(H)) * 100 \quad (15)$$

NPDC indicate the situation where variable i dominates variable j or variable j dominates variable i (Antonakakis et al., 2020, pp. 4–7).

4. Analysis

In this section, firstly, information about the variables and data set used in the study was given. Then, explanations were made regarding the findings obtained in the analyses.

4.1. Data Set

This study examined the asymmetric dynamic spillover relationship between China Ocean Shipping Company (COSCO) stock returns, Climate Policy Uncertainty (CPU) and MSCI China ESG Leaders Index (China ESG Leaders). This index is a publicly adjusted, market capitalization weighted index. It was created by taking into account the performance of companies selected from a core index based on Environmental, Social and Governance (ESG). Factor Groups (e.g. Value, Size, Momentum, Quality, Return and Volatility) that have been extensively documented in academic literature. Calculated by taking into account data in the literature and confirmed by MSCI Research as the main drivers of risks and returns in stock portfolios.

A dataset containing monthly data was used for the sampling period from October 2007 to July 2022. First of all, it was determined that the series were not stationary according to the ERS unit root test (Elliott et al., 1996), which takes into account an unknown mean or trend in the series. and the logarithmic return of the series was calculated with the formula $\ln(y_t/y_{t-1})$. The graph expressing the logarithmic return of the series is given in Figure 3. Adekoya et al. (2022)'s approach was followed to observe the asymmetric spread in the series and monthly returns were decomposed into positive and negative as follows;

$$y_t^+ = \begin{cases} y_t, & \text{eğer } y_t > 0 \\ 0, & \text{eğer } y_t < 0 \end{cases}$$

$$y_t^- = \begin{cases} y_t, & \text{eğer } y_t < 0 \\ 0, & \text{eğer } y_t > 0 \end{cases}$$




Figure 3. Logarithmic Return of Series

Descriptive statistics of the return series are given in Table 2. According to the ERS unit root test, it was determined that each series has a unit root, that is, the null hypothesis was rejected for all series at 1% or 5% significance level. Fisher and Gallagher's weighted Ljung-Box results show that the returns of all series have significant autocorrelation in their squares. This means that each series has time-varying variances and it is appropriate to use the TVP-VAR model in the study.

Table 2. Descriptive Statistics

	COSCO	CPU	CHINA.ESG.LEADERS
Mean	-0.008	0.008	0.001
Varyans	0.024	0.132	0.004
Skewness	0.185	0.089	-0.524***
	-0.298	-0.616	-0.005
Ex.Kurtosis	3.586***	0.326	0.365
	0	-0.285	-0.248
JB	96.372***	1.022	9.142***
	0	-0.6	-0.01
ERS	-4.231***	-5.208***	-1.479*
	0	0	-0.141
Q(10)	9.523*	27.712***	4.025
	-0.087	0	-0.661
Q2(10)	5.24	13.443**	24.735***
	-0.47	-0.013	0

Note: *, ** and *** represent significance level at 1, 5 and 10% respectively

Within Table 2, you will find an overview of the descriptive statistics pertaining to the variables utilized in this research. The results show that the variables are not normally distributed and do not include unit root. In addition, Q and Q2 test statistics show that it contains autocorrelation.

4.2. Findings

4.2.1. Average connectedness

Average connectivity results are given in Table 3. The upper section of Table 3 displays the comprehensive outcomes, disregarding any asymmetry. The lower sections, however, focus on assessing measures of asymmetric interconnectedness concerning both positive and negative returns. The values along the diagonal represent the impact of past shocks from the variables on their respective error variance. Conversely, off-diagonal values indicate the binary correlation between variables within the network. It is evident that the diagonal values surpass other values within the network, highlighting the significant contribution of variables' own shocks to the estimation error variance. For example, the largest value in the COSCO column is 87.49, which represents an 87% contribution to its own forecast error variance. A value of 22.77 in the column indicates a 23% return spillover from COSCO to China ESG Leaders.

The Corrected Total Connected Index (cTCI) value shows the total connectivity within the network regardless of time. The cTCI value at the top of the table is 29%, implying that the interdependence of the variables within the network is partially high. The “From” column represents the connectedness to a variable that is passed from all other variables in the network; The “To” line indicates the transfer of connectivity from one variable to all other variables in the network. When the relationship between “From” and “To” is examined for each variable, the correlation of COSCO stock returns to other variables in the network; It is observed that the China ESG Leaders index is the variable that is transferred from the other variables in the network. However, looking at the average net donors and net buyers, the main net giver within the network is COSCO stock returns. China ESG Leaders and CPU indices are net buyers in the network.

The middle and bottom of Table 3 represent positive and negative returns, respectively. It shows that both the main findings and the findings from positive and negative returns are similar in terms of ranking of network transmitters and network receivers. It should be noted, however, that cTCI is greater in connectivity based on negative returns (31%) compared to that based on positive returns (ie 16%). Negative returns have higher overall network connectivity, implying evidence for asymmetric effects.

Table 3. Average Connectivity

	COSCO	CPU	CHINA.ESG.LEADERS	FROM
COSCO	87.49	1.74	10.77	12.51
CPU	4.4	85.42	10.18	14.58
CHINA.ESG.LEADERS	22.77	8.4	68.82	31.18
TO	27.17	10.14	20.95	58.27
Inc.Own	114.66	95.56	89.78	cTCI/TCI
NET	14.66	-4.44	-10.22	29.13/19.42
NPT	2	0	1	
+	COSCO	CPU	CHINA.ESG.LEADERS	FROM
COSCO	91.94	4.15	3.91	8.06
CPU	5.12	88.32	6.56	11.68
CHINA.ESG.LEADERS	7.04	6.14	86.82	13.18
TO	12.16	10.29	10.47	32.92
Inc.Own	104.1	98.61	97.29	cTCI/TCI
NET	4.1	-1.39	-2.71	16.46/10.97
NPT	2	0	1	

Table 3. Average Connectivity (Continuing)

-	COSCO	CPU	CHINA.ESG.LEADERS	FROM
COSCO	77.17	2.1	20.73	22.83
CPU	4.83	92.29	2.89	7.71
CHINA.ESG.LEADERS	29.5	2.21	68.29	31.71
TO	34.33	4.31	23.61	62.25
Inc.Own	111.5	96.6	91.9	cTCI/TCI
NET	11.5	-3.4	-8.1	31.12/20.75
NPT	2	0	1	

Note: The outcomes are derived from an analysis utilizing a TVP-VAR model with a lag length determined by the Bayesian Information Criterion (BIC) and a generalized prediction error variance decomposition conducted up to 20 steps ahead.

4.2.2. Dynamic total connectivity

The above-mentioned measures of mean connectivity are time-independent and, therefore, it is not possible to observe the dynamic evolution of spillovers between variables. Considering that various economic and political events occurred during the sample period that could affect the returns of the series positively or negatively, it would be more accurate to focus on dynamic measurements. From this perspective, the Total Connectedness Index (TCI) results, which show the change in the dynamic total interconnectedness between the returns of the variables during the sample period, are given in Figure 4. The black shaded area shows the evolution of the TCI, which includes both positive and negative values. With this, the green line on the Chart represents the TCI consisting of only positive returns, while the red line represents only negative returns.

Focusing on the black shaded area to observe the evolution of connectivity within the network throughout the sample period, it is seen that the connectivity between the variables exhibits a decreasing trend over time. Despite the downtrend from 80% to 20%, the correlation between the variables is relatively strong. Also, although the three different series exhibit a qualitatively downward trend, the correlation between positive returns is very low, while the correlation between negative returns is much higher, supporting previous findings. The fact that the correlation between negative returns is relatively higher and volatile compared to positive returns reveals that negative news is more effective on stability in the network.

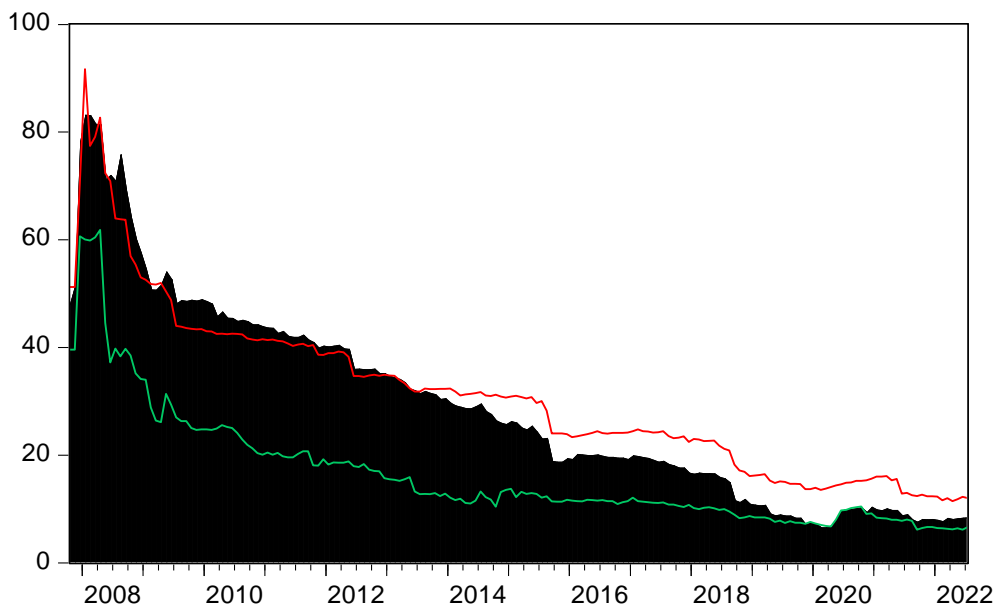


Figure 4. Total Connectedness Index (TCI)

Notes: Results presented herein are derived from a TVP-VAR model utilizing a lag length of one (selected based on the Bayesian Information Criterion) and a generalized prediction error variance decomposition conducted up to 20 steps ahead. In the visual representation, the black region corresponds to the symmetrical total interconnectedness, while the green and red lines signify positive and negative total interconnectedness, respectively.

4.2.3. Net total and net bidirectional connectivity

Net Total Directional Connectivity provides a dynamic view of the net-receiving or net-transmitting role of a variable. The results are given in Figure 5. A positive value in Figure 5 indicates that the variable is a net transmitter in the network, and a negative value indicates that it is a net receiver. It should be noted that the role of a variable in the network may change over time.

In Figure 5, according to the total returns without considering the asymmetric relations; During the entire sample period, China ESG Leaders are net receiver and COSCO is net transmitters. However, the role of the CPU index changes over time, but is usually in the receiver position.

According to the results of asymmetrical interconnectedness relations, a role change occurs between the positive returns of all variables. In terms of negative returns; There is no role change in the negative returns of COSCO and China ESG Leaders. Unlike general findings, especially in some periods, COSCO is the receiver of positive returns from China ESG Leaders.




Figure 5. Net Total Directional Connectivity

Notes: The outcomes stem from an analysis employing a TVP-VAR model with a lag length determined by the Bayesian Information Criterion (BIC) and a generalized prediction error variance decomposition extending up to 20 steps ahead. The shaded region depicted in black signifies the overall balanced interconnectedness, while the presence of green and red lines denotes positive and negative interconnectedness, respectively.

For more detailed inferences, we focus on Net Bidirectional Connectivity results. The Net Bidirectional Connectivity results given in Figure 6 show the dynamic interconnectedness between two variables in the network. Each graph represents the net transmitter/receiver role of the variable named in the first row with respect to the variable named in the second row. For example, when we examine the black shaded area in the "COSCO-CHINA ESG LEADERS" graph, we can say that China ESG Leaders were net recipients of emissions from COSCO during the entire sample period. Findings from both general and positive and negative returns support previous findings.

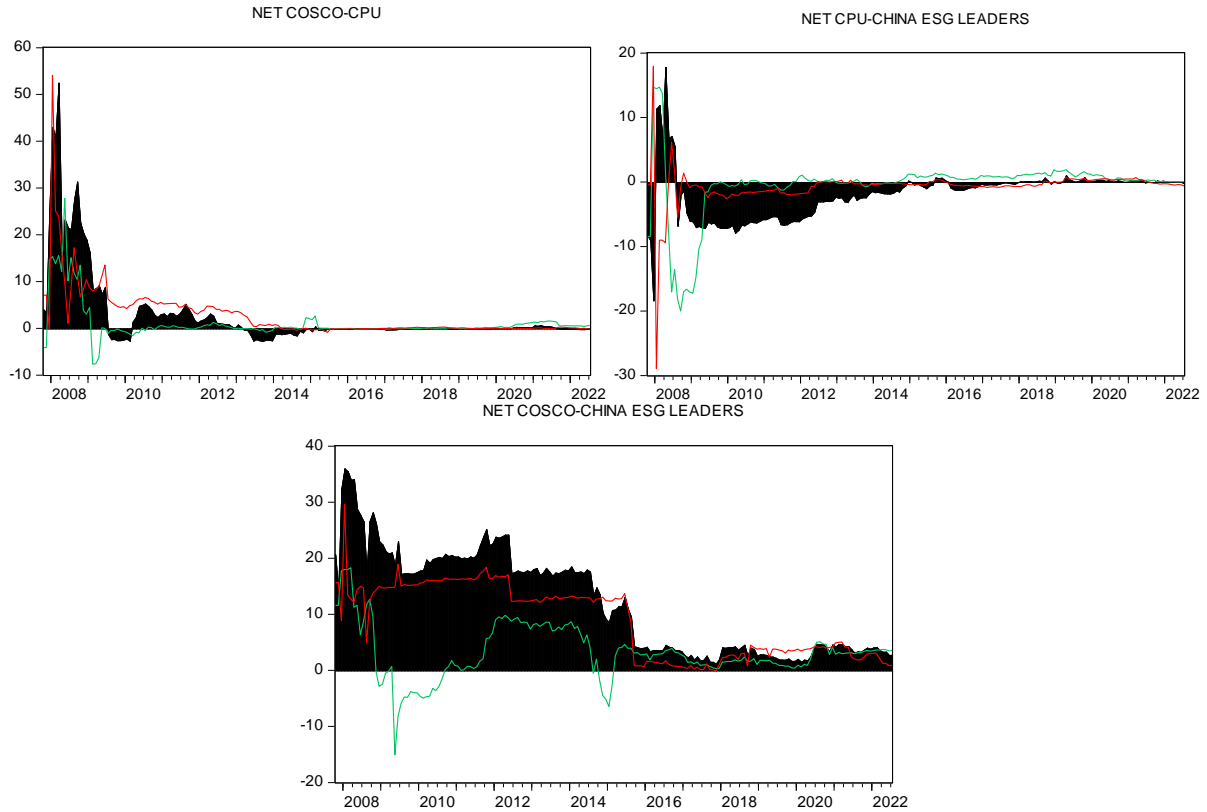


Figure 6. Net Bidirectional Connectivity

Notes: The findings presented in this study are derived from an analysis conducted using a TVP-VAR model, employing a lag length determined by the Bayesian Information Criterion (BIC), and a generalized prediction error variance decomposition carried out up to 20 steps ahead. The shaded region in black illustrates the comprehensive interconnectedness, while the presence of green and red lines indicates positive and negative connectivity, respectively.




Figure 7. Network graph representation of volatility spillover of variables.

In Figure 7, the connectivity transfer network between the variables is presented. The blue dots represent the transmitter variables that conduct connectivity to other variables, and the yellow dots represent the receiver variables that are linked from other variables. The size of the variable circles indicates the effect size of the transmitter or receiver variable. The arrows drawn from the circles show the direction of the relationship between the variables, while the thickness of these arrows shows the strength of the relationship. When the graph is examined, COSCO is the variable that transmits the shock, while the China ESG Leaders and the CPU are the variables that receive the shock. Shock transfer takes place from the COSCO variable to the China ESG Leaders variable.

5. Conclusion

This study explored the link between CPU, ESG and COSCO stock return spread. An autoregressive model with time-varying parameter vector was used in monthly data covering the period October 2007-July 2022. As a result of the analysis, it was seen that the volatility spread to the COSCO variable, China ESG Leaders and CPU variables. In other words, shock transfer occurred from the COSCO variable to the China ESG Leader and CPU variables.

As a result of industrialization, environmental degradation increases significantly with the developing economic development. Countries need to realize their management and strategies within the framework of sustainability. Since the logistics sector acts as a bridge in trade, it is important to take measures to prevent environmental degradation. In addition, determining the leading criteria in the realization of green logistics activities and ensuring the selection of areas according to these criteria is one of the steps that should be taken in order to prevent environmental degradation caused by the logistics sector. Based on the findings obtained as a result of the study, the evaluation of the logistics sector in terms of green transformation and the centralization of the sector with this awareness will make a great contribution to solving the greenhouse gas problem in the world.

There are a number of limitations to this research, which examines the correlation spread between CPU, ESG and COSCO stock returns. First of all, the results should be evaluated in terms of COSCO share returns, which represent the logistics industry. Future studies on green logistics activities will help environmental sustainability policy makers. In addition, examining the relationship between the logistics sector index and sustainability indices, clean energy indices and carbon emission indices will contribute to the literature.

References

- Adekoya, O. B., Akinseye, A. B., Antonakakis, N., Chatziantoniou, I., Gabauer, D., & Oliyide, J. (2022). Crude oil and Islamic sectoral stocks: Asymmetric TVP-VAR connectedness and investment strategies. *Resources Policy*, 78, 102877. <https://doi.org/10.1016/J.RESOURPOL.2022.102877>
- Agyabeng-Mensah, Y., Afum, E., & Ahenkorah, E. (2020). Exploring financial performance and green logistics management practices: examining the mediating influences of market, environmental and social performances. *Journal of cleaner production*, 258, 120613. <https://doi.org/10.1016/j.jclepro.2020.120613>.
- Akhtaruzzaman, M., Boubaker, S., & Umar, Z. (2022). COVID-19 media coverage and ESG leader indices. *Finance Research Letters*, 45, 102170. <https://doi.org/10.1016/j.frl.2021.102170>
- Akkus, H. T., & Dogan, M. (2023). Analysis of dynamic connectedness relationships between cryptocurrency, NFT and DeFi assets: TVP-VAR approach. *Applied Economics Letters*, 1-6.
- Alphaliner (2023). <https://alphaliner.axsmarine.com/PublicTop100/> Accessed: 19 May 2023.
- Antonakakis, N., & Gabauer, D. (2017). Refined Measures of Dynamic Connectedness based on TVP-VAR. In MPRA Paper (No. 78282; MPRA Paper). University Library of Munich, Germany.
- Antonakakis, N., Chatziantoniou, I., & Gabauer, D. (2020). Refined Measures of Dynamic Connectedness based on Time-Varying Parameter Vector Autoregressions. *Journal of Risk and Financial Management*, 13(4), 84. <https://doi.org/10.3390/JRFM13040084>.
- Cepni, O., Demirer, R., Pham, L., & Rognone, L. (2023). Climate uncertainty and information transmissions across the conventional and ESG assets. *Journal of International Financial Markets, Institutions and Money*, 83, 101730. <https://doi.org/10.1016/j.intfin.2022.101730>.
- Chen, Z., Zhang, L., & Weng, C. (2023). Does climate policy uncertainty affect Chinese stock market volatility?. *International Review of Economics & Finance*, 84, 369-381. <https://doi.org/10.1016/j.iref.2022.11.030>.
- Chen, Z., Zhang, X., & Chai, J. (2021). The dynamic impacts of the global shipping market under the background of oil price fluctuations and emergencies. *Complexity*, 2021, 1-13. <https://doi.org/10.1155/2021/8826253>.
- Christopher, M. (2011). *Logistics & Supply Chain Management* (4th edition), Pearson Education, London, UK.
- Diebold, F. X., & Yilmaz, K. (2009). Measuring Financial Asset Return and Volatility Spillovers, with Application to Global Equity Markets. *The Economic Journal*, 119(534), 158-171. <https://doi.org/10.1111/J.1468-0297.2008.02208.X>
- Diebold, F. X., & Yilmaz, K. (2012). Better to give than to receive: Predictive directional measurement of volatility spillovers. *International Journal of Forecasting*, 28(1), 57-66. <https://doi.org/10.1016/J.IJFORECAST.2011.02.006>.
- Diebold, F. X., & Yilmaz, K. (2014). On the network topology of variance decompositions: Measuring the connectedness of financial firms. *Journal of Econometrics*, 182(1), 119-134. <https://doi.org/10.1016/J.JECONOM.2014.04.012>.
- Doğan, M., Raikhan, S., Zhanar, N., & Gulbagda, B. (2023). Analysis of Dynamic Connectedness Relationships among Clean Energy, Carbon Emission Allowance, and BIST Indexes. *Sustainability*, 15(7), 6025.
- Elliott, G., Rothenberg, T. J., & Stock, J. H. (1996). Efficient Tests for An Autoregressive Unit Root. *Econometrica*, 64(4), 813-836.
- Felicio, J. A., Rodrigues, R., & Caldeirinha, V. (2021). Green shipping effect on sustainable economy and environmental performance. *Sustainability*, 13(8), 4256. <https://doi.org/10.3390/su13084256>.
- Fisher, T. J., & Gallagher, C. M. (2012). New Weighted Portmanteau Statistics for Time Series Goodness of Fit Testing. *Journal of the American Statistical Association*, 107, 777-787. <https://doi.org/10.1080/01621459.2012.688465>.

- Citation / Atıf:** ALTIN F. G., GÜRSOY S., DOĞAN M., ERGÜNEY E. B. (2023). The Analysis of the Relationship Among Climate Policy Uncertainty, Logistic Firm Stock Returns and ESG Scores: Evidence from the TVP-VAR Model. *Istatistik Araştırma Dergisi*, 13 (2), 42-59.
- Gabauer, D., & Gupta, R. (2018). On the transmission mechanism of country-specific and international economic uncertainty spillovers: Evidence from a TVP-VAR connectedness decomposition approach. *Economics Letters*, 171, 63–71. <https://doi.org/10.1016/J.ECONLET.2018.07.007>.
- Gavriilidis, K. (2021). Measuring climate policy uncertainty. Available at SSRN 3847388. <http://dx.doi.org/10.2139/ssrn.3847388>.
- Guo, J., Long, S., & Luo, W. (2022). Nonlinear effects of climate policy uncertainty and financial speculation on the global prices of oil and gas. *International Review of Financial Analysis*, 83, 102286. <https://doi.org/10.1016/j.irfa.2022.102286>.
- Gürsoy, S. (2021). Küresel Ekonomik Politik Belirsizliğin (Gepu) Döviz Kuru, Enflasyon Ve Borsa Etkisi: Türkiye Den Kanıtlar. *Türkiye Mesleki Ve Sosyal Bilimler Dergisi* (5), 120-131. <https://doi.org/10.46236/jovosst.877608>.
- IEA, (2021). Improving the sustainability of passenger and freight transport, <https://www.iea.org/topics/transport> Accessed 8 April 2023.
- IEA, (2022). Global CO2 emissions in transport by mode in the sustainable development scenario, <https://www.iea.org/data-and-statistics/charts/global-co2-emissions-in-transport-by-mode-in-the-sustainable-development-scenario-2000-2070> Accessed 8 April 2023.
- IEA Transport Report (2022). Sectoral overview, <https://www.iea.org/reports/transport>
- Koop, G., & Korobilis, D. (2014). A new index of financial conditions. *European Economic Review*, 71, 101–116. <https://doi.org/10.1016/J.EUROCOREV.2014.07.002>.
- Koop, G., Pesaran, M. H., & Potter, S. M. (1996). Impulse response analysis in nonlinear multivariate models. *Journal of Econometrics*, 74(1), 119–147. [https://doi.org/10.1016/0304-4076\(95\)01753-4](https://doi.org/10.1016/0304-4076(95)01753-4).
- Korobilis, D., & Yilmaz, K. (2018). Measuring Dynamic Connectedness with Large Bayesian VAR Models. *SSRN Electronic Journal*. <https://doi.org/10.2139/SSRN.3099725>.
- Li, X. (2022). Dynamic spillovers between US climate policy uncertainty and global foreign exchange markets: the pass-through effect of crude oil prices. *Letters in Spatial and Resource Sciences*, 15, 665–673. <https://doi.org/10.1007/s12076-022-00318-4>.
- Liu, M., Guo, T., Ping, W., & Luo, L. (2023). Sustainability and stability: Will ESG investment reduce the return and volatility spillover effects across the Chinese financial market?. *Energy Economics*, In Press, Journal Pre-proof, 106674. <https://doi.org/10.1016/j.eneco.2023.106674>.
- Marine Insight, (2023). 20 Largest container shipping companies in the world in 2023, https://www.marineinsight.com/know-more/10-largest-container-shipping-companies-in-the-world/#1_MSC_%E2%80%9393_Mediterranean_Shipping_Company Accessed 19 May 2023.
- McKinnon, A. (2015). *Green Logistics: Improving the Environmental Sustainability of Logistics (third edition)*. McKinnon, A., Browne, M., Piecyk, M. & Whiteing, A. (Eds.), Environmental sustainability: A new priority for logistics managers (pp. 3-31). Kogan Page.
- Pang, K., Lu, C.-S., Shang, K.-C. & Weng, H.-K. (2021). An empirical investigation of green shipping practices, corporate reputation and organisational performance in container shipping. *International Journal of Shipping and Transport Logistics*, 13(3/4), 422–444. <https://doi.org/10.1504/IJSTL.2021.113996>.
- Pesaran, H. H., & Shin, Y. (1998). Generalized impulse response analysis in linear multivariate models. *Economics Letters*, 58(1), 17–29. [https://doi.org/10.1016/S0165-1765\(97\)00214-0](https://doi.org/10.1016/S0165-1765(97)00214-0).
- Polat, O., El Khoury, R., Alshater, M. M., & Yoon, S. M. (2023). Media Coverage of COVID-19 and Its Relationship with Climate Change Indices: A Dynamic Connectedness Analysis of Four Pandemic Waves. *Journal of Climate Finance*, In Press, Journal Pre-proof, 100010. <https://doi.org/10.1016/j.jclimf.2023.100010>.
- Ren, X., Zhang, X., Yan, C., & Gozgor, G. (2022). Climate policy uncertainty and firm-level total factor productivity: Evidence from China. *Energy Economics*, 113, 106209. <https://doi.org/10.1016/j.eneco.2022.106209>.

- Samitas, A., Papathanasiou, S., Koutsokostas, D., & Kampouris, E. (2022-a). Volatility spillovers between fine wine and major global markets during COVID-19: A portfolio hedging strategy for investors. *International Review of Economics & Finance*, 78, 629-642. <https://doi.org/10.1016/j.iref.2022.01.009>.
- Samitas, A., Papathanasiou, S., Koutsokostas, D., & Kampouris, E. (2022-b). Are timber and water investments safe-havens? A volatility spillover approach and portfolio hedging strategies for investors. *Finance Research Letters*, 47, 102657. <https://doi.org/10.1016/j.frl.2021.102657>.
- Seroka-Stolka, O., & Ociepa-Kubicka, A. (2019). Green logistics and circular economy. *Transportation Research Procedia*, 39, 471-479. <https://doi.org/10.1016/j.trpro.2019.06.049>.
- Shahbaz, M., Dogan, M., Akkus, H.T. et al. The effect of financial development and economic growth on ecological footprint: evidence from top 10 emitter countries. *Environmental Science and Pollution Research*. 30, 73518–73533 (2023). <https://doi.org/10.1007/s11356-023-27573-2>.
- Xiao, J., & Liu, H. (2023). The time-varying impact of uncertainty on oil market fear: Does climate policy uncertainty matter?. *Resources Policy*, 82, 103533. <https://doi.org/10.1016/j.resourpol.2023.103533>.
- Xie, Q., Cheng, L., Liu, R., Zheng, X., & Li, J. (2023). COVID-19 and risk spillovers of China's major financial markets: Evidence from time-varying variance decomposition and wavelet coherence analysis. *Finance Research Letters*, 52, 103545. <https://doi.org/10.1016/j.frl.2022.103545>.
- Yan, W. L. & Cheung, A. (W.K.) (2023). The dynamic spillover effects of climate policy uncertainty and coal price on carbon price: Evidence from China. *Finance Research Letters*, 53, 103400. <https://doi.org/10.1016/j.frl.2022.103400>.
- Yingfei, Y., Mengze, Z., Zeyu, L., Ki-Hyung, B., Avotra, A. A. R. N., & Nawaz, A. (2022). Green logistics performance and infrastructure on service trade and environment-measuring firm's performance and service quality. *Journal of King Saud University-Science*, 34(1), 1-10. <https://doi.org/10.1016/j.jksus.2021.101683>.
- Yontar, E. (2022). Assessment of the logistics activities with a structural model on the basis of improvement of sustainability performance. *Environmental Science and Pollution Research*, 29(45), 68904-68922. <https://doi.org/10.1007/s11356-022-20562-x>.
- Yu, J., Zhang, M., Liu, R., & Wang, G. (2023). Dynamic Effects of Climate Policy Uncertainty on Green Bond Volatility: An Empirical Investigation Based on TVP-VAR Models. *Sustainability*, 15(2), 1692. <https://doi.org/10.3390/su15021692>.
- Zhou, D., Siddik, A. B., Guo, L., & Li, H. (2023). Dynamic relationship among climate policy uncertainty, oil price and renewable energy consumption - findings from TVP-SV-VAR approach. *Renewable Energy*, 204, 722-732. <https://doi.org/10.1016/j.renene.2023.01.018>.



Gri Kümeleme Analizi ile Türkiye'deki Şehirlerin Sosyo-Ekonomik Verilere Göre Sınıflandırılması

Kübra KARADAŞ

Sivas Cumhuriyet Üniversitesi, Ekonometri Bölümü
kubrakaradas45@gmail.com
Orcid No: 0000-0003-4858-313X

Necati Alp ERİLLİ

Sivas Cumhuriyet Üniversitesi, Ekonometri Bölümü / Prof. Dr.
aerilli@cumhuriyet.edu.tr
Orcid No: 0000-0001-6948-0880

Özet

Sınıflandırma, herhangi bir konu hakkında gözlemlenen verilerin yapılarını inceleyerek verileri birbirlerine benzer gruplara, içeriklere ve belirlediğimiz bazı özelliklere göre gruplandırma işlemi olarak tanımlanabilir. Böylece birbirlerine benzeyen gruplarda yer alan gözlemlerin araştırma amaçlarına göre değerlendirilmesi ve yorumlanması kolaylaşacaktır. Kümeleme analizi sınıflandırma çalışmalarında en sık kullanılan yöntemlerden biridir. Kümeleme analizi doğal grupları bulunmayan verileri grup veya kümelerin sınırlı bir sayısına ayırmayı amaçlayan çok değişkenli istatistiksel bir yöntemdir. Gri İlişkisel Kümeleme yönteminde kümelerin belirli bir kurala göre gruplanmış nesnelere oluştuğu için kümeler homojenliğe sahip olması ve yeniden hesaplama yapılmaya gerek duymadan nesnelere kendi içerisinde ayrımını yapabilen bir yöntemdir. Ayrıca küme sayısı analiz öncesinde değil, kümeleme gerçekleştirildikten sonra belirlenebileceği için yaygın kullanılan diğer kümeleme algoritmalarına göre alternatif bir yaklaşım sunabilmektedir.

Bu çalışmada Türkiye'deki illerin sosyo-ekonomik veriler yardımıyla gri kümeleme analizi ile sınıflandırılması amaçlanmıştır. Türkiye İstatistik Kurumu'ndan alınmış veriler ile öncelikle gri ilişkisel katsayı matrisleri oluşturulmuş ve sonrasında kümeleme analizi yapılarak illerin sosyo-ekonomik verilere göre dağılımı belirlenmiştir. Analizler eğitim, tarım, istihdam gibi alt başlıklarda verilen veri kategorileri için de ayrı ayrı yapılarak Türkiye'nin sosyo-ekonomik haritası belirlenmeye çalışılmıştır.

Anahtar sözcükler: Gri Kümeleme Analizi, Sosyo-Ekonomik Veri, Sınıflandırma, Gri İlişkisel Analiz

Corresponding Author / Sorumlu Yazar: 1- Necati Alp ERİLLİ, Sivas Cumhuriyet Üniversitesi.

Atıf / Citation: KARADAŞ K., ERİLLİ N. A. (2023). Gri Kümeleme Analizi ile Türkiye'deki Şehirlerin Sosyo-Ekonomik Verilere Göre Sınıflandırılması. *İstatistik Araştırma Dergisi*, 13 (2), 60-74.

Bu çalışma Prof. Dr. N. Alp Erilli danışmanlığında Kübra Karadaş tarafından yazılan ve Sivas Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri bölümü tarafından onaylanan "Gri Kümeleme Analizi ve Bir Uygulama" isimli yüksek lisans tezinden türetilmiştir.

Classification of Provinces in Türkiye According to Socio-Economic Data with Gray Cluster Analysis

Abstract

Classification can be defined as the process of examining the structures of the data observed on any subject and grouping the data according to similar groups, contents and some characteristics we have determined. Thus, it will be easier to evaluate and interpret the observations in similar groups according to the research objectives. Cluster analysis is one of the most frequently used methods in classification studies. Cluster analysis is a multivariate statistical method that aims to classify data without natural groups into a limited number of groups or clusters. In the Gray Relational Clustering method, since the clusters consist of objects grouped according to a certain rule, the clusters have homogeneity and it is a method that can distinguish objects within itself without the need for recalculation. In addition, since the number of clusters can be determined after clustering is performed, not before the analysis, it can offer an alternative approach to other commonly used clustering algorithms.

In this study, it is aimed to classify the provinces in Türkiye by using gray clustering analysis with the help of socio-economic data. Gray relational coefficient matrices were first created with the data obtained from the Turkish Statistical Institute and then clustering analysis was performed to determine the distribution of provinces according to socio-economic data. Analyses were also conducted separately for the data categories given under sub-headings such as education, agriculture and employment, and with this it is aimed to determine the socio-economic map of Türkiye.

Keywords: Gray Clustering Analysis, Socio-Economic Data, Classification, Gray Relational Analysis

1. Giriş

Bireyler, kurumlar veya organizasyonlar kendi ihtiyaçları doğrultusunda çeşitli amaç veya hedeflerini gerçekleştirmek için karar vermek durumundadırlar. Kendilerine maksimum fayda elde etmek için birçok alternatif karşısında en iyi seçimi belirlemek çoğu zaman kolay olamamaktadır. Bu seçimleri bazı alternatif tekniklerden yararlanarak yapmak hem zaman hem de maliyet açısından tasarruf sağlanmasına yardımcı olmaktadır. Bu teknikler genel olarak karar verme ve sınıflama olarak iki genel başlık altında toplanabilir. Karar verme ve sınıflandırma neredeyse benzer faaliyetlerdir. Her iki durumda da bir problem hakkındaki bilgi ve veriler bir çözüm aramak için kullanılır. Karar kuralları ve sınıflandırma algoritmaları bilgi çıkarımını gerçekleştirir. Kullanıcı tanımlı sınıflar bağlamında veriler dönüştürülür, sınıf etiketleriyle eşleştirilir. Bilgi, bir dizi soru bağlamında ilgili verilerdir (Mulder, 1985). Karar vermede eylemler genellikle gerçek dünyada gerçekleşen sorunlardır ve elde edilen çözümler direkt sonuca etki edebilmektedir. Sınıflandırma çalışmalarında eylemler ise genellikle bir gözlemin bir gruba dahil edilmesi veya isimlendirilmesi olarak karşımıza çıkmaktadır ve sonuçlar bazen gerçek dünyada teori düzeyinde kalabilmektedirler.

Genel bir tanım vermek gerekirse sınıflandırma, herhangi bir konu hakkında gözlemlenen verilerin yapılarını inceleyerek verileri birbirlerine benzer gruplara, içeriklere ve belirlenen bazı özelliklere göre gruplandırma işlemi olarak tanımlanabilir. Sonuç olarak birbirlerine benzeyen gruplarda yer alan gözlemlerin araştırma amaçlarına göre değerlendirilmesi ve yorumlanması kolaylaşacaktır. Karar verme, canlıların çeşitli alternatifler ve imkanlar arasında amaçlarına uygun olanlarını seçmek olarak tanımlanabilir. Karar verme süreci, karar vericinin değerlerine, tercihlerine ve inançlarına dayanan bir akıl yürütme sürecidir. Her karar verme süreci bir seçimden oluşur ve bireyin bazen lehine bazen de aleyhine sonuçlar verebilir.

Kıtalar, ülkeler veya bölgesel çalışmalarda gelişmenin ve kalkınmanın en önemli göstergelerinden biri sosyo-ekonomik gelişmişlik verileri gösterilebilir. Birçok yerde olduğu gibi Türkiye’de de il veya bölgesel bazda kullanılan bu veriler ile gelişmişliğin düzeyi belirlenebilmektedir. Türkiye’de yapılacak olan kamu veya özel yatırımlar ve bunlara ayrılacak paylar, bu veriler esas alınarak hazırlanmaktadır. Türkiye’de gelişmenin mekân üzerinde dağılımı iller çevresinde yoğunlaşma tarzındadır. Bu dağılımın kapsamı ve çevre iller üzerinde etkisi, merkezlerdeki iktisadi ve sosyal faaliyetlerin yoğunluğu ile de doğru orantılıdır. Mekânsal gelişme eğilimleri bölgesel ve bütünsel gelişmelere de altyapı oluşturmaktadır (Erilli, 2009). Yine de yapılacak birçok çalışmadan elde edilen sonuçların doğru ve tarafsız bir şekilde değerlendirilmesi, bölgesel gelişmişlik farklarının azaltılması konusunda önemli bir yer tutmaktadır.

Literatürde sosyo-ekonomik veriler yardımıyla yapılan sınıflama çalışmaları her geçen gün artış göstermektedir. Farklı istatistiksel yöntemler ile elde edilen farklı sınıflama sonuçları ile araştırmacılar, Türkiye’nin sosyo-ekonomik haritasına katkı sağlamaktadırlar. Filiz (2005) çalışmasında Türkiye’deki illeri k-ortalama tekniği ile sınıflandırmış ve 16 sosyo-ekonomik değişken ile 7 küme elde edilmiştir. Albayrak (2005) çalışmasında Türkiye’deki illerin sosyo-ekonomik gelişmişlik düzeylerini faktör analiziyle araştırmış ve 8 faktör elde etmiştir. Kaygısız vd. (2005) çalışmalarında Path analizi ve Kümeleme analizi birlikte kullanılmış ve sonuç olarak Türkiye’de iller 5 kümeye ayrılmıştır. Erilli vd. (2009) çalışmalarında Türkiye’deki iller, bulanık kümeleme analizi ile 58 değişken kullanılarak sınıflandırılmış ve sonuç olarak 5 küme bulunmuştur. Çelik (2013) çalışmasında k-ortalamalar yöntemi kullanarak Türkiye’deki illeri sağlık değişkenlerine göre sınıflandırmış ve elde edilen sonuçları 7, 10 ve 15’li küme bölünmesi için yorumlamıştır. Tekin (2015), sağlık göstergeleri yardımıyla Türkiye’deki illeri Ward yöntemi ile gruplandırmış ve sonuçta 5, 7 ve 11’li küme bölünmeleri elde edilmiştir. Zorlutuna ve Erilli (2018) çalışmalarında 2002, 2008 ve 2013 yıllarına ait 3 farklı dönem sosyo-ekonomik veriler kullanarak Bulanık C-ortalamalar yöntemi ile Türkiye’deki illeri sınıflandırmışlardır. Çalışmada her 3 dönem için iller ve yıllar arası korelasyon değerleri hesaplanarak yorumlanmıştır. Kandemir (2018) çalışmasında konaklama verileri kullanarak Türkiye’deki illeri Bulanık kümeleme yöntemi ile sınıflandırmıştır. Yerli ve yabancı turizm için ayrı ayrı yapılan analizlerde illerin 2 kümede toplandıkları belirlenmiştir. Bulut (2019) çalışmasında Türkiye’deki illeri memnuniyet endeks verilerine göre modele dayalı EM algoritması ve k-ortalamalar yöntemi kullanarak kümelere ayırmıştır. Analizlerin sonucunda EM algoritması ile 2 küme, k-ortalamalar yöntemi ile 5 küme elde edilmiştir. Birkalan ve Bay (2022) çalışmalarında Türkiye İBBS Düzey-2 bölgelerini bölgesel asgari ücret varsayımı altında, 2015-2020 yılları için Ward kümeleme yöntemi ile analiz etmişler ve bazı yıllar için 3, bazı yıllar için de 4 küme bulmuşlardır. Tüm bu çalışmalarda kullanılan farklı sınıflama yöntemleri ve farklı sayıda değişkenler ile elde edilen küme sayılarının değişkenlik göstermesi beklenen bir sonuçtur. Önemli olan kullanılan değişkenlerin, yapılan sınıflama çalışmalarındaki yapıyı ne derece etkilediğinin belirlenmesi ve kullanılan istatistiksel yöntemlerin sonuçlar üzerindeki etkilerinin yorumlanabilmesidir.

Bu çalışmada 2019 yılına ait sosyo-ekonomik veriler kullanılarak Türkiye’nin sosyo-ekonomik haritası belirlenmeye çalışılmıştır. Demografik, Eğitim, Nüfus ve Göç, Tarım ve Hayvancılık, Sağlık ve Finans başlıkları altında hazırlanan bu veriler ile oluşturulacak sosyo-ekonomi haritaları, Çok Kriterli Karar Verme (ÇKKV) ve sınıflama yöntemlerinin ortak yönlerini barındıran Gri kümeleme analizi ile gerçekleştirilmiştir.

2. Materyal ve Metot

2.1. Kümeleme Analizi

Kümeleme analizi sınıflandırma çalışmalarında en sık kullanılan yöntemlerden biridir. Kümeleme analizi sınıfları (doğal grupları) bulunmayan verileri grup veya kümelerin sınırlı bir sayısına ayırmayı amaçlayan çok değişkenli istatistiksel bir yöntem olarak tanımlanabilir. Ayırma, aynı gruptaki gözlemlerin birbirine benzer iken farklı gruplardaki gözlemlerin birbirlerinden farklı olacak şekilde yapılandırılması işlemleridir. Böylece gruplar içi homojen, gruplar arası ise heterojen yapılar elde edilebilecektir. Kümeleme analizi ilk kez Tryon tarafından 1939 yılında kullanılmış ve 1960’lı yıllardan sonra kullanımı yaygınlaşmıştır (Anderberg 1973). Kümeleme analizi, iş ve bilim dünyasında sık kullanılan çok değişkenli istatistiksel yöntemlerinden belki de en önemlisidir. Kümeleme Analizi incelenen bir çalışmada gözlemler arasındaki benzerliklerine veya benzemezliklerine göre kümeler oluşturularak sınıflandırma yapmayı, birimlerin benzer özelliklerini belirlemeyi, bu sınıflar ile ilgili genel düzenlemeler yapmayı ve genel yargılarda bulunmayı sağlayan bir yöntem olarak tanımlanabilir. Yöntemin amacı grup oluşturmamış gözlemleri benzerliklerine (benzemezliklerine) göre sınıflandırmak ve araştırma yapanlara uygun, genellenebilir özet bilgiler elde etmelerinde yardımcı olmaktır (Tatlıdil, 2002). Kümeleme Analizi, birbirine çok benzeyen gözlemleri aynı küme içinde gruplandırır ve bunun sonucunda oluşan kümeler kendi içlerinde yüksek homojen ve kümeler arası düşük heterojen değerler taşımaktadırlar (Kalaycı, 2005). Kümeleme analizindeki genel amaçların dışında bazı özel amaçları da bulunmaktadır. Bunlar; örneklemelerin bağlı olduğu gerçek tiplerin belirlenmesi, modelleştirmenin kolaylaştırılması, gruplar için önsel tahminler, önceden belirlenen hipotezlerin test edilmesi, veri yapısının belirginleştirilmesi, veri (boyut) azaltma ve uç (aykırı) değerlerin bulunması olarak özetlenebilir (Tatlıdil, 2002). Kümeleme analizinde kullanılmak üzere bireylerin veya nesnelerin aralarındaki benzerlik için uzaklık ölçüleri, korelasyon ölçüleri veya katsayıları karşılaştırma ölçütleri kullanılmaktadır. Uzaklık ölçüleri bireyleri sınıflandırmak için kullanılırken, korelasyon ölçüleri ise değişkenleri sınıflandırmada kullanılır (Erilli, 2009).

2.2. Gri Sistem Teorisi

Çok Kriterli Karar Verme (ÇKKV) Teknikleri, sayıca fazla olan kriterlere göre seçeneklerin avantaj ve dezavantajlarını değerlendirebilen analitik yöntemler topluluğu olarak özetlenebilir. ÇKKV, çok sayıda ve aynı anda uygulanan kriterler arasında en iyi ve en doğru alternatifi seçilmesini sağlayan yöntemdir (Hamurcu ve Eren, 2015). Başka bir ifade ile ÇKKV teknikleri ile karar vericiler farklı özelliğe sahip seçenekleri birden çok kritere göre değerlendirerek sıralayabilirler. Bu yöntemlerden biri de Gri Sistem Teorisidir.

Gri sistem teorisi (GST) ilk defa Deng (1982) çalışması ile tanıtılmıştır. GST küçük örnekleme sahip ve yeterli bilgi içermeyen problemlerin çözümünde kullanılmak üzere önerilen bir yöntemdir (Liu ve Forrest, 2010). GST, belirsizliğin sayısallaştırılmasında kullanılan bir yöntem olarak da tanımlanmaktadır (Köse vd, 2013). Son yıllarda dünya genelinde çok kriterli çalışmalarda sıklıkla görülmeye başlanan Gri sistem teorisi istatistik, işletme, mühendislik gibi birçok alanda farklı konu başlıkları altında hızla yayılmıştır. Bulanık matematik yöntemi kullanılarak incelenen tüm nesnelere belirgin olmayan sınırları ve kesin bir içselliğe sahiptir. Örneğin “sıcak çorba” kavramı bulanık bir kavramdır. Zira birçok kişi sıcak çorba denilince aslında neyin anlaşılması gerektiğini bilir fakat belirgin bir sıcaklık kavramını tanımlamak zordur. Çünkü “Sıcak çorba” dediğimiz kavram çok geniş anlamları ifade eder. Gri sistem teorisinde ise incelenen nesnelere kesin sınır ve kesin olmayan bir içselliğe sahiptir. Örneğin, “Türkiye Merkez Bankası, 2023 yılsonu için dolar kur aralığını 28 ile 30 TL arasında kontrol etmeyi planlıyor” cümlesindeki “28 ile 30 TL” aralığı parasal büyüklük ile ilgili kesin bir sınırı belirtirken, tanımlanan aralığın bilinen (veya hesaplanan) değeri hakkında herhangi bir netlik içeren bilgiye sahip olamamız gri bir kavram olarak tanımlanabilir.

Problem çözümlerinde kullanılan matematiksel veya istatistiksel sistemler, gerçek hayatın küçük bir bölümünün modellenmesine benzer. Sistem modelleri karmaşık yapıları, farklı güvenilirlik düzeyleri veya belirsizlik noktaları arasındaki yapılar ile değerlendirilir. Ortaya çıkarılan matematiksel modeller ne kadar ayrıntı içerse de üzerinde araştırma yapılan gerçeği tam olarak yansıtamamaktadırlar. Çünkü gerçek dünya gerek işleyişi gerekse kavramları ile karmaşık bir yapı içermektedir. Bu karmaşıklıkların temel sebebi kavramlar üzerindeki belirsizlik, kesinlikten yoksunluk veya kararsızlıklardan kaynaklanmaktadır. Bilim insanları bu tarz sorunların yaşandığı problemlere her geçen gün farklı analizler ile yaklaşarak gerçeği farklı boyutlarda aramaya çalışmaktadırlar. Bu yöntemlerden biri de gri sistem teorisi ile kümeleme analizinin birleşimi olana Gri Kümeleme Analizi yaklaşımıdır.

2.3. Gri Kümeleme Analizi

Gri kümeleme analizinin temeli Deng (1982) tarafından geliştirilen Gri Sistem Teorisine (GST) dayanmaktadır. GST küçük örnekleri ve sınırlı bilgileri içeren problemlerin incelenmesine olanak sağlayan bir teoridir (Liu ve Forrest, 2010). Kümeleme; nesnelere ayrılmasına göre gri kümeleme analizi ve gri beyaz ağırlık fonksiyonu kümeleme analizi olarak ayrılabilir. Gri beyaz ağırlık fonksiyonu kümeleme analizi, bir gözlemin belirlenen farklı kategorilere ait olup olmadığını kontrol etmek için kullanılır. Gri kümeleme analizi ise temel olarak karmaşık sistemleri basitleştirilmiş hale getirmek için benzer faktörlerde kullanılır (Ke vd, 2012).

Gri kümeleme analizi; gözlemleri sınıflandırmak veya önceden belirlenen bir kümeye gözlemleri dahil etmek için gri sayıların beyazlaştırma ağırlık fonksiyonu kullanır. Gri kümeleme analizi birbirlerine benzeyen unsurların sınıflandırılması yoluyla karmaşık sistemlerin basitleştirilmesi için kullanılmaktadır (Liu ve Forrest, 2010).

Beyazlaştırma ağırlık fonksiyonlarını kullanan gri kümeleme yöntemi esas olarak gözlem nesnelere önceden belirlenmiş sınıflara ait olup olmadıklarını test etmek için uygulanır. Gri Kümeleme Yöntemi gözlem nesnelere tanımlanabilir gruplarla sınıflandırmak için geliştirilmiş ve gri insidans matrisleri veya beyazlaştırma ağırlık fonksiyonları aracılığıyla gerçekleştirilebilir (Liu ve Forrest, 2010). Gri kümeleme analizinin avantajları kümeleme nesnesinin örnek dağılımını özel bir gereksinim olmaksızın ele alması ve basit bir hesaplama süreci aracılığıyla daha yararlı kümeleme sonuçları elde edilebilmesidir (Ke vd, 2012). Gri kümeleme analizindeki, değerlendirilen nesnelere, fonksiyon değerine ve gri kategori değerine göre alt bölümlere ayrılır. Temel adımları aşağıda verildiği gibidir (Lin, 2015).

1. Gri kümeleme analizinin m göstergesi ve n tane gri kategorisi olmak üzere;
2. Gri kümeleme analizi işlevleri δ_{ij} ; m göstergenin ve n gri kategoriye ait olacaktır.

3. Gerçek değere veya tahmini değere göre gri kümeleme analizinin değerleri $n_j^k = \frac{\lambda_j^k}{\sum_{j=1}^m \lambda_j^k} u_i^j(P)$ dir. P

değerlendirmesinin altındaki nesnelere elde edilir ve R matrisi elde edilir.

$$R = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1m} \\ r_{21} & r_{22} & \cdots & r_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p1} & r_{p2} & \cdots & r_{pm} \end{bmatrix} \quad (1)$$

4. Gri kümeleme analizinin değerine göre matris δ^t , t nesnesinin yaklaşık m göstergesi ve n gri kategorisi elde edilir.

$$\delta^t = \begin{bmatrix} \delta^t_{11} & \delta^t_{12} & \cdots & \delta^t_{1n} \\ \delta^t_{21} & \delta^t_{22} & \cdots & \delta^t_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \delta^t_{m1} & \delta^t_{m2} & \cdots & \delta^t_{mn} \end{bmatrix} \quad (2)$$

5. Değer γ^t_m t nesnesinin i -inci gri kategorisinin kapsamlı bir gri kümeleme analizi fonksiyonu elde edilir. T nesnesinin gri kategori fonksiyon değerine göre onaylanır.

$$\gamma^t_j = \frac{1}{m} \sum_{i=1}^m \delta^t_{ij} \quad (3)$$

Gri kümeleme adımları şu şekilde sıralanır (Chang ve Yeh, 2005):

Adım 1: Geçici bir küme tanımlanır.

$C = \{c_1, c_2, \dots, c_q\}$ şeklinde geçici bir küme tanımlanır. Geçici küme $C = X$ şeklinde düşünülmüş bir veri setidir.

Bu durumda $q = m$ ve $c_i = x_i$ olacaktır. Geçici küme, öğrenme sürecinde bir veri kümesi olarak kullanılır ve tam bir öğrenme yinelemesinden sonra C 'deki öğeler güncellenir.

Adım 2: Eşiğin başlangıç değeri ayarlanır.

Başlangıç eşik değeri ε olarak $[0, 1]$ aralığında olmak üzere bir gerçek sayı seçilmelidir. İlk eşik değeri, nihai kümeleme sonuçlarını (yani kümelerin sayısı ve küme merkezlerinin konumu) güçlü bir şekilde etkileyecektir (Bu daha sonra tanımlanacaktır).

Adım 3: Bir öğrenme süreci başlatılır.

$X_r = X_c = C$ olmak üzere ve $i = 1$ olarak tanımlanır.

Adım 4: Gri ilişkisel ilişki dereceleri hesaplanır.

Bu yineleme için $x_{ri} \in X_r$ ilgili referansı eğitim modeli yapın. Ardından, referans x_{ri} ile X_c 'deki tüm örüntüler

arasında gri ilişkisel örüntü dereceleri; $v(x_{ri}, x_{cj}), J = 1, 2, \dots, q$ ile gösterilen $v(x_{ri}, x_{cj}) = \left(\frac{d_{\max} - d_{ij}}{d_{\max} - d_{\min}} \right)^\xi$ ile

belirlenebilir. ($\xi \in (0, \infty)$ ayırt edici bir katsayıdır).

Adım 5: Etkin modeli güncellenir.

Karşılaştırmalı bir model x_{cj} için; gri ilişkisel örüntü derecesi $v(x_{ri}, x_{cj}) \geq \varepsilon$ 'yi karşılıyorsa; o zaman C 'de karşılık gelen öğeye anlamlı bir örüntü denir. Bu anlamlı örüntüler arasında, aktif bir örüntü olan C_l , kendisine karşılık gelen karşılaştırma örüntüsü en büyük gri ilişkisel örüntü derecesi olan $v(x_{ri}, c_l) = \max_{j \in \{1, 2, \dots, q\}} v(x_{ri}, x_{cj})$ eşitliğine

sahip olacak şekilde tanımlanır. Böylece aktif olan örüntü C_l şu şekilde güncellenir: $c_l = \frac{\sum_{k=1}^N w_k c_k^*}{\sum_{k=1}^N w_k}$. Burada w_k ,

önemli c_k^* modelinin ağırlıklandırma faktörüdür. Genellikle tüm k değerleri için $w_k = 1/N$ alınır. Başka bir seçenek ise, $w_k = v(x_{ri}, c_k^*)$ eşitliğinin aktif örüntünün yeni konumunu daha büyük ilişki dereceli örüntülere daha

yakın hale getirmesine izin vermektir. Birden fazla aktif örüntü varsa, hepsi aynı anda $c_l = \frac{\sum_{k=1}^N w_k c_k^*}{\sum_{k=1}^N w_k}$ ile

güncellenir.

Eğer her eğitim verisi $i=q$ şeklinde tanımlanırsa Adım 6'ya gidilir. Aksi takdirde, l 'yi 1 artırıp ardından Adım 4'ten devam edilir.

Adım 6: Elde edilen sonuçlar kontrol edilir.

Güncellemeden sonra geçici küme aynı kalırsa, yani C 'nin yakınsaması sağlanırsa, öğrenme sürecini durdurulur ve küme merkezlerini belirlemek için Adım 8'e gidilir. Aksi takdirde, bir sonraki adıma geçilir.

Adım 7: Elde edilen sonuca göre eşik değeri artırılır.

Eşik değeri (ε) gerekirse artırılır. Böylece başka bir öğrenme yinelemesi için güncellenmiş C kümesiyle 3. adıma gidilir. ε eşik, $\varepsilon = 1$ olana kadar doğrusal veya üstel olarak arttırılabilir.

Adım 8: Kümeleri ve küme merkezleri belirlenir.

C 'nin yakınsaması sağlandıktan sonra, C 'deki bazı elemanlar eşit olabilir. Son güncellenen C kümesini, aynı alt kümedeki tüm öğelerin aynı olduğu birkaç ayrı alt kümeye bölün. Alt kümelerin sayısı verideki küme sayısıdır. C 'nin bir alt kümesindeki öğeler için, orijinal X veri kümesindeki karşılık gelen kalıpları bir küme olarak bölünebilir ve küme merkezi bu alt kümedeki öğelerden biri olacaktır.

Yüksek ilişkisel dereceli kalıpları bir küme olarak gruplamak için, referansa oldukça benzeyen N anlamlı kalıp seçilmeli ve ardından 5. Adımda aktif kalıbın yeni konumu olarak bunların ortalamasını alınmalıdır. Adım 5 ayrıca, düşük ilişkisel dereceli kalıpların eğitildikten sonra değişmediğini ortaya koymaktadır. Adım 7'deki eşik artırılması, kendi kendini organize eden özellik haritalarındaki mahalle boyutunu küçültme fikrine çok benzer (Kohonen, 1995). Eşik arttıkça, bu önemli modeller yakınsak bir duruma doğru hareket ederler. Nihai sonuçlar, istenen küme merkezleridir. Tüm prosedür, yalnızca veri kümesinin altında yatan yapıya dayandığından, önerilen yöntem denetimsiz bir kümeleme yaklaşımı olarak tanımlanabilir.

Adım 5'te, anlamlı modellerin seçiminin eşik değere bağlı olduğu görülmektedir. Aslında, Adım 2'de seçtiğimiz eşik başlangıç değeri, yöntemimizin nihai sınıflandırma sonuçlarını güçlü bir şekilde etkilemektedir. Genel olarak konuşursak, farklı başlangıç eşikleri, veri kümeleme probleminde farklı sonuçlar verebilir. Başlangıç eşik parametresinin duyarlılığı farklı örneklerde farklılık gösterilecektir. Yukarıda önerilen gri kümeleme algoritması, sabit bir başlangıç eşik için bir veri kümesini bölmek için kullanılır. $[0, 1]$ içinde farklı başlangıç eşikleri için sonuçlar almak için gri kümeleme algoritmasında fazladan bir prosedür kullanılabilir. Bu sonuçlar arasında, uygun bir kümeleme sonucu bulmamıza yardımcı olacak bir kritere ihtiyacımız olacaktır. Bir performans endeksi şu şekilde tanımlanmıştır (Jain ve Dubes, 1988):

$$PI = \frac{\sum_{d=1}^h m_d}{\sum_{d=1}^h m_d s_d} \quad (4)$$

Burada h küme sayısını, $m_d, d = 1, 2, \dots, h$ d-nci kümeyle ait örüntü sayısını ve s_d ise aşağıda verildiği gibi tanımlanmıştır:

$$s_d = \frac{\min_{j, j \neq d} \|o_d - o_j\|^2}{\sqrt{\sum_{t=1}^{m_d} \|x_{dt} - o_d\|} / m_d} \quad (5)$$

Burada o_d , d-nci kümenin küme merkezini ve x_{dt} ise d-nci kümeyle ait örüntülerini ifade etmektedir.

Bu indeks, bir kümedeki kalıpların merkeze yakın olması ve küme merkezlerinin birbirinden uzakta ayrılması gerektiği anlamında veri kümelemenin amacını yansıtır. s_d performans indeksi ne kadar büyük olursa, kümeleme sonucunun o kadar iyi olduğunu görebiliriz (Wong vd, 2001).

Şimdi, sonucun performans indeksini (PI) maksimize etmesi anlamında optimal bir sonuç belirlemek için gri kümeleme algoritmasının son adımını verilebilir.

Adım 9: En uygun sonuç belirlenir.

Adım 8’de farklı başlangıç eşikleri kullanılarak elde edilen her sonuç için performans indeksi (*PI*) hesaplanmalıdır. Optimal kümeleme sonucu, performans indeksini maksimize eden sonuçtur. *PI* yerine, Adım 9’da farklı performans indeksleri de kullanılabilir. Örneğin, küme merkezi ile kümedeki örüntüler arasındaki mesafelerin ortalaması, ele alınan tek amaç ise, alternatif performans indeksini en aza indiren sonucu aramak için Adım 9 değiştirilmelidir.

3. Uygulama

Bu çalışmada, Türkiye’deki şehirler 2019 yılına ait Türkiye sosyo-ekonomik verileri kullanılarak gri kümeleme analizi yöntemi sınıflandırılmaya çalışılmıştır. Çalışmada kullanılan 2019 yılı verileri Türkiye İstatistik Kurumu’nun internet adresinden alınmış ve derlenmiştir (URL-1).

2019 yılı verileri ile ilk olarak gri ilişkisel katsayı matrisleri oluşturulmuş ve sonrasında gri kümeleme analizi yapılarak illerin sosyo-ekonomik verilere göre dağılımı belirlenmiştir. Analizler MATLAB 2009, SPSS.25 ve Microsoft Excel paket programları ile yapılmıştır. Çalışmada Sosyo-Ekonomik verilerin tümü kullanılarak gri kümeleme analizi sonuçları elde edildikten sonra sırasıyla Demografik, Eğitim, Sağlık, Tarım, Nüfus ve Finans alt başlıkları için de ayrı ayrı gri kümeleme analizi uygulanmış ve Türkiye’nin sosyo-ekonomik haritası belirlenmeye çalışılmıştır.

Gri kümeleme analizi hesaplamalarında uygun küme sayılarının belirlenmesi için geçerli bir yöntem bulunmamaktadır. Bu yüzden uygun küme sayılarının belirlenmesinde klasik kümeleme yöntemlerinde sıklıkla kullanılan Silhouette ve bulanık kümeleme yöntemlerinde kullanılan Xie-Beni küme geçerlilik yöntemleri beraber kullanılmıştır (Rousseuw, 1987; Xie ve Beni, 1991). Her 2 yöntemde göre de aynı küme sayısının ulaşıldığı küme sayıları optimal küme sayısı olarak alınmıştır. Analizlerde kullanılan sosyo-demografik verileri oluşturan başlıklar ve bileşenleri Tablo 1’de verilmiştir.

Tablo 1. Analizlerde kullanılan 2019 yılı Türkiye Sosyo-ekonomik değişkenleri

<i>Demografik</i>	<i>Eğitim</i>
Bebek Ölüm Hızı (binde)	İlkokul okullaşma oranı 2012 ve sonrası (kadın)-net (%)
5 yaş altı ölüm hızı (binde)	İlkokul okullaşma oranı 2012 ve sonrası-net (%)
Toplam doğurganlık hızı (çocuk sayısı)	İlkokul /Öğretmen başına düşen öğrenci sayısı
Kaba evlenme hızı (binde)	İlköğretim okullaşma oranı 2012 ve sonrası (kadın)-net (%)
Kaba ölüm hızı (binde)	İlköğretim okullaşma oranı 2012 ve sonrası-net (%)
Kaba doğum hızı (binde)	Okuma yazma bilen oranı (%)
Kaba boşanma hızı (binde)	Ortaokul /Öğretmen başına düşen öğrenci sayısı
Doğuştan beklenen yaşam süreleri (yıl)	İlk ve ortaokul /Derslik başına düşen öğrenci sayısı
Nüfusa göre boşanma oranları	
<i>Nüfus ve Göç</i>	<i>Tarım-Hayvancılık</i>
Net göç hızı (binde)	Küçükbaş hayvan sayısı (baş)
Nüfus yoğunluğu (kilometrekareye düşen kişi sayısı)	Tahıllar ve diğer bitkisel ürünlerin üretim miktarı (ton)
Ortalama hane halkı büyüklüğü	Büyükbaş hayvan sayısı (baş)
Yıllık nüfus artış hızı (binde)	
Türkiye'den yurt dışına giden göç	
<i>Sağlık</i>	<i>Finans</i>
Yüzbin kişi başına toplam hastane yatak sayısı	Toplam ithalat (bin \$)
Bin kişi başına düşen toplam hekim sayısı	Toplam ihracat (bin \$)
	Kişi başına GSYH (TL)

Kaynak: www.tuik.gov.tr (Erişim Tarihi: 10.11.2022)

Yukarıda da belirtildiği üzere Silhouette ve Xie-Beni küme geçerlilik yöntemlerinin aynı uygun sonuçları verdiği küme sayıları optimal küme sayısı olarak alınmış ve gri kümeleme analizi bu küme sayılarına göre yapılmıştır. Silhouette kriterine göre toplamda en büyük Silhouette değerini veren küme sayısı uygun küme sayısı olarak alınır (Rousseuw, 1987). Buna karşılık Xie-Beni indeksinde en küçük indeks değerini veren küme sayısı uygun küme sayısı olarak alınır (Balasko vd., 2005). Değişken grupları için hesaplanan Silhouette ve Xie-Beni indeks değerleri Ek.1'de verilmiştir. EK.1'de verilen tablo sonuçlarına göre sadece Eğitim ve Tarım-Hayvancılık değişken gruplarında bu 2 endeks değeri istenen durumda çıkmamış, diğerlerinde istenen durumlarda çıkmıştır (Silhouette indeksinin en büyük olduğu yerde Xie-Beni indeksinin en düşük çıkması). Eğitim ve Tarım-Hayvancılık değişkenlerinde Silhouette indekslerinin istenen duruma oldukça yakın çıkmalarından dolayı, minimum Xie-Beni indeks değerinin olduğu küme sayısı optimal sayı olarak belirlenmiştir. Bulunan optimal küme sayıları Tablo 2'de verilmiştir.

Tablo 2. Değişken gruplarına göre optimal küme sayıları

Değişken Grubu	Küme Sayısı
Sosyo-Ekonomik	7
Demografik	8
Eğitim	8
Sağlık	3
Tarım-Hayvancılık	7
Nüfus-Göç	8
Finans	10

Tablo 2'de verilen küme sayılarına uygun Gri kümeleme analizi sonuçları Türkiye haritası üzerinde her değişken için ayrı ayrı gösterilmiştir. EK.2'de ilgili değişken gruplarına göre yapılan kümeleme sonuçlarından elde edilen kümelerin ilgili değişkenlere göre tanımlayıcı istatistikleri verilmiştir. Şekil 1'de Demografik değişkenlere göre illerin kümelerine dağılımı gösterilmiştir.



Şekil 1. Demografik değişkenlere göre illerin kümelerine dağılımı

Şekil 1'de verilen sonuçlara göre Tokat, Zonguldak, Isparta gibi küçük illerin İstanbul, Ankara, İzmir ile aynı kümede yer alması, Karabük'ün tek başına bir kümeyi oluşturması ve Bartın ile Giresun'un aynı kümede yer alması beklenenden farklı sonuçlar olarak karşımıza çıkmaktadır. Şekil 2'de Eğitim değişkenlerine göre illerin kümelerine dağılımı gösterilmiştir.



Şekil 2. Eğitim değişkenlerine göre illerin kümelere dağılımı

Şekil 2’de verilen sonuçlara göre Hakkâri ve Tokat’ın aynı kümede yer alması, Gümüşhane’nin ise tek bir küme oluşturması farklı bir sonuç olarak ele alınabilir. İstanbul, İzmir, Ankara gibi illerin aynı kümede yer alması beklenen bir durumdur. 7. ve 8. kümelerdeki illerin eğitim olanaklarının diğer kümelerden daha az olduğu düşünülebilir. Şekil 3’te Sağlık değişkenlerine göre illerin kümelere dağılımı gösterilmiştir.



Şekil 3. Sağlık değişkenlerine göre illerin kümelere dağılımı

Şekil 3’te verilen sonuçların en dikkat çekici olanı İstanbul’un gerek nüfus gerekse demografik olarak benzediği birçok il ile aynı kümede yer alması olarak gösterilebilir. Şekil 4’te Tarım ve Hayvancılık değişkenlerine göre illerin kümelere dağılımı gösterilmiştir.



Şekil 4. Tarım ve Hayvancılık değişkenlerine göre illerin kümelere dağılımı

Şekil 4’te verilen sonuçlarına göre Konya tahıl üretimindeki lider konumuyla tek bir kümede yer aldığı söylenebilir. 4. küme genel olarak tarım alanı kısıtlı illerden oluşmuştur. Van ilinin tek kümede olması

hayvancılığın ildeki önemi ile açıklanabilir. Şekil 5’te Nüfus ve Göç değişkenlerine göre illerin kümelere dağılımı gösterilmiştir.



Şekil 5. Nüfus ve Göç değişkenlerine göre illerin kümelere dağılımı

Şekil 5’te verilen sonuçlarına göre İstanbul’un tek bir kümeyi oluşturmasının nedeni en fazla göç alması ve buradaki iş olanaklarının fazla olması etkili bir faktördür. Çanakkale ve Giresun illerinin de tek başlarına bir küme oluşturdukları görülmektedir. Şekil 6’da Finans değişkenlerine göre illerin kümelere dağılımı gösterilmiştir.



Şekil 6. Finans değişkenlerine göre illerin kümelere dağılımı

Şekil 6’da verilen sonuçlarına göre İstanbul, Ankara ve Gaziantep illerinin ticaret ve sanayi kaynaklı ayrı ayrı tek bir kümeyi oluşturduğu söylenebilir. Genellikle sanayi ve ticaretin az olduğu illerin 9. kümede yoğunlaştığı görülmektedir. Son olarak 30 değişkenden oluşan Sosyo-Ekonomik veriler yardımıyla elde edilen Gri Kümeleme sonuçları Şekil 7’de verilmiştir.



Şekil 7. Sosyo-Ekonomik verilere göre illerin kümelere dağılımı

Şekil 7’de verilen sonuçlarına göre Tüm veriler değerlendirildiğinde Ankara, İzmir ve İstanbul illerinin aynı kümede yer aldığı görülmektedir. Bartın ve Giresun illerinin aynı kümede yer alması ve Karabük ilinin tek bir

kümeyi oluşturması farklı sonuçlar olarak söylenebilir. 3. küme genel olarak kırsal nüfusun çok olduğu iller olarak karşımıza çıkmaktadır. Sosyo-Ekonomik dağılımının beklenildiği gibi homojen şehirlerden oluşmadığı görülmektedir. Bazı benzer yapıdaki şehirlerin aynı kümede yer almalarına karşın genel olarak bazı kümelerde küme içi farklılıklar göze çarpmaktadır.

4. Sonuç ve Tartışma

Bu çalışmada gri kümeleme analizi yardımıyla Türkiye'deki iller 2019 yılına ait sosyo-ekonomik verileri kullanılarak kümelere ayrılmıştır. Sosyo-ekonomik veri başlığı altında 30 değişken ile yapılan analizlerin yanı sıra sosyo-ekonomik başlığı altındaki sırasıyla demografik, eğitim, sağlık, tarım, nüfus ve finans alt başlıkları için de ayrı ayrı gri kümeleme analizi uygulanmış ve yorumlanmıştır.

Sonuçlara genel olarak bakıldığında Gri kümeleme analizi ile belirlenen küme sayılarının Tarım-Hayvancılık alt kategorisi hariç 7 ve 7'den büyük oldukları görülmektedir. Bu sonuçların hepsinde de ayrıca en az 1 şehrin tek başına küme oluşturdukları görülmektedir. Genelde İstanbul ilinin gerek nüfus yapısı gerekse ekonomik yapısı dolayısıyla tek başına küme oluşturduğu çalışmalara nazaran bu çalışmada Karabük, Gümüşhane, Van, Konya gibi illerin farklı kategorilerde tek başlarına küme oluşturdukları görülmektedir. Eski dönemlerde Devlet Planlama Teşkilatı, günümüzde Kalkınma Ajanslarının yaptığı Türkiye'deki illerin sınıflandırma çalışmalarında 5 veya 6 küme yapısı görülürken bu çalışmada hesaplanan 7 veya üzeri küme oluşumlarının gri kümeleme analizinde kullanılan gri ilişkisel matris hesaplamalarının etkisi olduğu düşünülmektedir. Özellikle tüm değişkenlerin kullanıldığı Sosyo-Ekonomik verilerin değerlendirilmesinde oluşan küme yapılarının bir bütünlük göstermemesi ve hemen her bölgeden benzer sosyo-kültürel ve büyüklükteki şehirlerin farklı kümelerde yer alması gri kümeleme analizinin farkı olarak görülmektedir. Kümeleme, diskriminant analizi gibi sınıflama çalışmalarında genellikle değişken başına 20 gözlemin olması önerilir. Bunun daha azı nispeten belirsizlik sorununa yol açabilir. Bu çalışmada kullanılan 30 değişkene sadece 81 gözlem kullanılmıştır. Bu ise kümeleme analizinde belirsiz sonuçların oluşmasına sebep olabileceği düşünülmektedir. Gri kümeleme analizi ile yapılan sınıflandırmaların, belirsizlik altında karar vermede yardımcı olduğu düşünülmektedir.

Bu çalışmada Gri Kümeleme analizi ile elde edilen küme sayılarının Türkiye sosyo-ekonomik verileri ile yapılan benzer çalışmalara göre daha farklı sonuçlar elde edildiği görülmüştür. Gri kümeleme analizinde küme sayısının belirlenmesi için henüz belirgin yöntemlerin bulunmaması ve gözlem sayısı-değişken sayısı farkının az olmasının bu farklılıklarda etkisi olduğu düşünülmektedir. Gri kümeleme analizinin etkinliğinin test edilmesi için literatürde sıklıkla kullanılan veriler ile benzer çalışmaların yapılarak gerek yöntem hakkında gerekse küme sayısının belirlenmesi hakkında daha detaylı bilgiler elde edilebilecektir.

Kaynaklar

- Albayrak, A. S. (2005). Türkiye'deki illerin Sosyoekonomik Gelişmişlik Düzeylerinin Çok Değişkenli İstatistik Yöntemlerle İncelenmesi, *ZKÜ Sosyal Bilimler Dergisi*, Cilt:1 Sayı:1.
- Anderberg, M. R. (1973). *Cluster Analysis for Applications*, Academic Press, New York.
- Balasko, B., Abonyi, J., Feil, B. (2005). *Fuzzy clustering and data analysis toolbox*. Department of Process Engineering, University of Veszprem, Veszprem.
- Birkalan, A. Ö., Bay, H. (2022). Bölgesel Asgari Ücret Varsayımı Altında Bölgelerin Kümeleme Analizi Yöntemleriyle Tespiti. *Maliye Dergisi*, Temmuz-Aralık; 183: 24-48.
- Bulut, H. (2019). Türkiye'deki illerin yaşam endekslerine göre kümelenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23 (1), 74-82.
- Chang, K. C., Yeh, M. F. (2005). Grey relational analysis-based approach for data clustering, *IEE Proceedings - Vision Image and Signal Processing*, 152 (2), 165-172.
- Çelik, Ş. (2013). Kümeleme analizi ile sağlık göstergelerine göre Türkiye'deki illerin sınıflandırılması. *Doğuş Üniversitesi Dergisi*, 14 (2), 175-194.
- Deng, J. L. (1982). Control Problems of Grey Systems, *Systems & Control Letters*, 1 (5), 288-294.
- Erilli, N.A. (2009). *Kümeleme Analizine Bulanık Yaklaşım Algoritmaları ve Uygulamalar*, Yayınlanmamış Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı, Samsun.
- Erilli, N. A., Tunç, T., Yüksel, Ö., Yolcu, U. (2009). İllerin Sosyoekonomik Verilere Dayanarak Bulanık Kümeleme Analizi ile Sınıflandırılması, *e-Journal of New World Sciences Academy*, 4(1), 1-11.
- Filiz, Z. (2005). İllerin sosyo-ekonomik düzeylerine göre gruplandırılmasında farklı yaklaşımlar, *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 6(1), 77-100.
- Hamurcu, M., Tamer, E. (2015). Ankara Büyükşehir Belediyesi'nde çok ölçütlü karar verme yöntemi ile monoray güzergâh seçimi, *Transist*, 8 s. 410-419.
- Jain, A.K., Dubes, R.C. (1988). *Algorithms for clustering data*, Prentice Hall, New Jersey.
- Kalaycı, Ş. (2005). *SPSS Uygulamalı Çok Değişkenli İstatistik Teknikleri*, Asil Yayıncılık, Ankara.
- Kandemir, A. Ş. (2018). Bulanık Kümeleme Analizi ile Türkiye'deki İllerin Konaklama İstatistiklerine Göre Sınıflandırılması. *Journal of Travel and Hospitality Management*, 15(3), 657-668.
- Kaygısız, Z., Saraçlı, S., Dokuzlar, K., (2005). İllerin Gelişmişlik Düzeyini Etkileyen Faktörlerin Path Analizi ve Kümeleme Analizi İle İncelenmesi, *VII. Uluslararası Ekonometri ve İstatistik Sempozyumu*, İ. Ü., Ekonometri Bölümü, İstanbul, 26-27 Mayıs.
- Ke, L., Xiaoliub, S., Zhongfua, T., Wenyanb, G. (2012). Grey Clustering Analysis Method for Overseas Energy Project Investment Risk Decision, *Systems Engineering Procedia* 3 (3), 55-62.
- Kohonen, T. (1995). *Self-organizing maps*, Springer-Verlag, New York.
- Köse, E., Aplaç H. S., Kabak, M. (2013). Personel Seçimi için Gri Sistem Teori Tabanlı Bütünsel Bir Yaklaşım, *Ege Akademik Bakış*, 13(4), 461.
- Lin, Z. (2015). A Multi-attribute Evaluation Model of the Development Competitiveness of Tourism cities based on Grey Clustering Analysis, *International Journal of Hybrid Information Technology*, 8(10), 331-338.
- Liu, S., Forrest J. Y. L. (2010). *Grey systems: Theory and applications*. Springer-Verlag Berlin Heidelberg.
- Mulder, N.J. (1985). Decision Making and Classification. *Photogrammetria*, 40. 95-116.

Citation / Atıf: KARADAŞ K., ERİLLİ N. A. (2023). Gri Kümeleme Analizi ile Türkiye'deki Şehirlerin Sosyo-Ekonomik Verilere Göre Sınıflandırılması. *İstatistik Araştırma Dergisi*, 13 (2), 60-74.

Rousseuw, P. J. (1987). Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis. *Journal of Computational and Applied Mathematics*. 20: 53- 65.

Tatlıdil, H. (2002). *Uygulamalı Çok Değişkenli İstatistiksel Analiz*, Akademi Matbaası, Ankara.

Tekin, B. (2015). Temel Sağlık Göstergeleri Açısından Türkiye'deki İllerin Gruplandırılması: Bir Kümeleme Analizi Uygulaması. *Çankırı Karatekin Üniversitesi İİBF Dergisi*, 5(2), 389-416.

URL-1: www.tuik.gov.tr (Erişim tarihi: 10.10.2022)

Wong, C. C., Chen, C. C., Su, M. C. (2001). A novel algorithm for data clustering, *Pattern Recognition*, 34(2), 425-442.

Xie, L., Beni, G. (1991). A Validity Measure for Fuzzy Clustering, *IEEE Trans. On Pattern Analysis and Machine Int.* 13(4), 841-846.

Zorlutuna, Ş., Erilli, N. A. (2018). Sosyo-Ekonomik Verilere göre İllerin Bulanık C-Ortalamalar Yöntemi ile Sınıflandırılması: 2002-2008-2013 Dönemleri Karşılaştırması. *İktisadi Yenilik Dergisi*, 5 (2), 13-31.

Ek 1. Değişken gruplarına göre Silhouette ve Xie-Beni indeks değerlerinin farklı küme sayılarına göre değerleri

Küme Sayısı	Sosyo-Ekonomik		Demografik		Eğitim		Sağlık	
	Silh.	XB	Silh.	XB	Silh.	XB	Silh.	XB
2	0,6552	9,87	0,7165	10,41	0,6933	21,45	0,7362	8,25
3	0,6475	10,01	0,7453	14,78	0,6984	18,75	0,7481	6,99
4	0,7142	8,88	0,7586	8,61	0,7045	12,36	0,7259	11,67
5	0,6968	9,85	0,7438	10,28	0,7068	11,57	0,7148	7,82
6	0,6940	6,35	0,7781	3,79	0,7166	13,4	0,7236	7,4
7	0,7304	4,38	0,7912	4,89	0,7257	8,9	0,7369	8,52
8	0,7161	5,88	0,7986	2,99	0,7235	6,01	0,7389	9,91
9	0,6832	7,91	0,7864	5,08	0,7135	6,94	0,7301	13,34
10	0,6936	10,09	0,7784	3,87	0,7194	7,99	0,7291	12,78

Ek 1. Değişken gruplarına göre Silhouette ve Xie-Beni indeks değerlerinin farklı küme sayılarına göre değerleri (Devam)

Küme Sayısı	Tarım-Hayvancılık		Nüfus-Göç		Finans	
	Silh.	XB	Silh.	XB	Silh.	XB
2	0,6833	16,87	0,6418	15,76	0,7095	12,54
3	0,6912	14,5	0,6568	10,54	0,7066	9,89
4	0,6988	12,31	0,6591	11,86	0,7032	12,36
5	0,7064	8,61	0,6601	6,37	0,6981	10,01
6	0,7099	5,91	0,6734	8,56	0,6988	8,67
7	0,7092	3,22	0,6781	3,78	0,6881	4,99
8	0,7051	6,45	0,6824	2,73	0,7011	5,98
9	0,6984	6,75	0,6818	4,02	0,7182	3,21
10	0,6831	8,88	0,6799	6,48	0,7194	3,01

Ek 2. Kümeleme analizi sonuçlarına göre ortaya çıkan kümelerin ilgili değişkenlere göre tanımlayıcı istatistikleri

	Değişkenler	1.Küme	2.Küme	3.Küme	4.Küme	5.Küme	6.Küme	7.Küme	8.Küme	9.Küme	10.Küme
Demografik	Bebek Ölüm Hızı (binde)	4,75	11,4462	7,43333	8,55789	6,24	3	10,1667	14,2286		
	5 yaş altı ölüm hızı (binde)	6,3	14,0385	8,88	10,7789	7,7866667	3	12,1889	17,1286		
	Toplam doğurganlık hızı (çocuk sayısı)	1,455	2,52308	1,54533	1,91421	1,6153333	1,41	1,85556	2,57429		
	Kaba evlenme hızı (binde)	5,625	6,91692	6,108	6,69842	6,0426667	5,74	6,14	6,71714		
	Kaba ölüm hızı (binde)	8,2	4,53077	6,92	5,85789	7,0266667	7,1	5,77778	4,24286		
	Kaba doğum hızı (binde)	9,45	19,3615	10,9333	14,1895	11,313333	9,4	13,8778	19,9429		
	Kaba boşanma hızı (binde)	1,755	1,06769	2,07533	1,68579	1,78	1,9	1,19444	0,98286		
	Doğuşta beklenen yaşam süreleri (yıl)	78,8	77,8308	78,34	78,2316	78,486667	78,4	78,5556	77,8286		
	Nüfusa göre boşanma oranları	572,18	1406,9	520,928	681,014	609,76938	526,394	1065,24	1845,27		
	Eğitim	İlkokul okullaşma oranı 2012 ve sonrası (kadın)-net (%)	92,472	89,765	94,542	93,207	91,272	93,939	86,780	68,410	
İlkokul okullaşma oranı 2012 ve sonrası-net (%)		92,677	90,010	94,560	93,416	91,712	93,975	87,215	68,200		
İlkokul /Öğretmen başına düşen öğrenci sayısı		15,556	15,500	15,381	14,778	15,286	15,571	14,500	13,000		
İlköğretim okullaşma oranı 2012 ve sonrası (kadın)		97,243	94,423	97,941	97,439	97,847	97,642	92,325	70,330		
İlköğretim okullaşma oranı 2012 ve sonrası-net (%)		97,264	94,325	97,823	97,349	97,870	97,532	92,435	70,180		
Okuma yazma bilen oranı (%)		95,864	95,573	97,788	96,604	94,062	97,201	96,710	96,330		
Ortaokul /Öğretmen başına düşen öğrenci sayısı		13,222	12,500	13,524	12,667	13,357	12,857	12,500	9,000		
İlk ve ortaokul /Derslik başına düşen öğrenci sayısı		21,111	18,250	20,524	17,667	20,429	20,619	23,000	13,000		
Sağlık	Yüzbin kişi başına toplam hastane yatak sayısı	386,25	232,371	307,524							
	Bin kişi başına düşen toplam hekim sayısı	3	1	2							
Tarım ve Hayvancılık	Küçükbaş hayvan sayısı (baş)	1895245	403085	1143401	110349	2708012	2459960	738916			
	Tahullar ve diğer bitkisel ürünlerin üretim miktarı (ton)	2315467	1224438	1776096	438517	1707764	1,6E+07	2131025			
	Büyükbaş hayvan sayısı (baş)	417158	214520	245221	111866	180693	927082	295044			
Nüfus-Göç	Net göç hızı (binde)	-55,08	8,75364	-12,455	4,93	-101,31	-19,579	-5,5544	0,92429		
	Nüfus yoğunluğu (kilometrekareye düşen kişi sayısı)	65,63	75,6227	57,08	2986,77	54,58	104,13	87,6389	132,997		
	Ortalama hanehalkı büyüklüğü	2,76	3,46091	3,30273	3,33	2,63	3,27824	3,69667	3,51143		
	Yıllık nüfus artış hızı (binde)	-12,22	3,95545	-16,018	29,53	2,76	5,38176	4,63667	8,50333		
	Türkiye'den yurt dışına giden göç	1071	3863,91	1155,18	140223	2014	3338,29	1243,06	2506,9		
Finans	Toplam ithalat (bin \$)	756186	258384	3208794	1310107	7854288,7	40513,9	2397621	5006595	1,1E+07	1,05E+08
	Toplam ihracat (bin \$)	916187	390852	4054981	1590084	10122356	123260	2187391	7418005	8313060	85636418
	Kişi başına GSYH (TL)	45092	41131,6	40828	43899,6	66913	34230,6	43144	37633	71027	86798