

An examination of socio-economic factors affecting fraud in Türkiye using panel ARDL analysis¹

Ufuk Işık*² and Selahattin Kaynak³

² Ordu University, Ünye Vocational School, Ordu, Türkiye; ³ Samsun University, Faculty of Political Science, Samsun, Türkiye.

ABSTRACT

This study analyzes the relationship between socio-economic factors and fraud offenses in Türkiye between 2011 and 2020. The study examines the impact of variables such as unemployment, inflation, national income per capita, migration, infrastructure investments, and population density on fraud crime rates, based on the Türkiye NUTS-2 Classification of Statistical Regional Units. The panel ARDL analysis is employed as the method of analysis because it enables the examination of long-run relationships between variables with differing levels of stationarity. According to the findings, PMG ARDL long-run analysis results are more in line with the literature. Contrary to the existing literature, an increase in the number of unemployed individuals is found to have a decreasing effect on fraud offenses. The study's findings reveal that an increase in unemployment rates does not lead to an increase in fraud; rather, it directs individuals to more legal and secure income paths under certain economic conditions. However, increases in inflation, infrastructure investment, migration, and population density also lead to an increase in fraud offences. In particular, it is noteworthy that inflation exacerbates economic difficulties by negatively affecting the purchasing power of individuals, while increases in migration, urbanization, and infrastructure investments are the primary factors contributing to higher crime rates. Moreover, the increase in the number of illiterate people has a decreasing effect on the crime of fraud, which is a qualitative crime. These findings contribute to a better understanding of the relationship between socio-economic factors and fraud offences.

KEYWORDS

Inflation, migration, PANEL ARDL, number of unemployed

Türkiye'de dolandırıcılık suçunu etkileyen sosyo-ekonomik faktörlerin panel ARDL analizi ile incelenmesi

ÖZET

Bu çalışmada, 2011-2020 yılları arasında Türkiye'deki dolandırıcılık suçlarının sosyo-ekonomik faktörlerle ilişkisi incelenmektedir. Çalışma, Türkiye İBBS-2 İstatistik Bölge Birimleri Sınıflamasına göre, işsizlik, enflasyon, kişi başına düşen milli gelir, alınan göç, altyapı yatırımları ve nüfus yoğunluğu gibi değişkenlerin dolandırıcılık suç oranlarına etkilerini analiz etmektedir. Analiz yöntemi olarak Panel ARDL analizi kullanılmıştır, çünkü bu yöntem farklı düzeylerde durağanlığa sahip değişkenler arasındaki uzun dönemli ilişkileri incelemeye olanak sağlamaktadır. Bulgulara göre, PMG ARDL uzun dönem analiz sonuçları literatüre daha uygundur. Literatürün aksine, işsiz sayısındaki artışın dolandırıcılık suçunu azaltıcı bir etkiye sahip olduğu tespit edilmiştir. Çalışmanın bulguları, işsizlik oranlarındaki artışın dolandırıcılığı artırmadığını, aksine belirli ekonomik koşullarda bireyleri daha fazla yasal ve güvenli gelir yollarına yönlendirdiğini ortaya koymaktadır. Bununla birlikte, enflasyondaki artışlar, altyapı yatırım miktarı, alınan göç ve nüfus yoğunluğu dolandırıcılık suçunu artırmaktadır. Özellikle, enflasyonun bireylerin satın alma gücünü olumsuz yönde etkileyerek, ekonomik zorlukları artırması; göç, kentleşme ve altyapı

¹ Produced from the doctoral thesis entitled 'The Economics of Crime: In the Context of Socio-Economic Factors', completed on 14 August 2024 at Ondokuz Mayıs University, Department of Economics.

Cite: Işık, U., & Kaynak, S. (2026). An examination of socio-economic factors affecting fraud in Türkiye using panel ARDL analysis. *Ordu University Institute of Social Sciences Journal of Social Sciences Research*, 16(1), Article Number 5. <https://doi.org/10.48146/odusobiad.1721682>

*Corresponding Author: Ufuk5852@hotmail.com

yatırımlarındaki artışların ise suç oranlarını yükselten başlıca faktörler olarak ortaya çıkması dikkat çekmektedir. Ayrıca, okuma yazma bilmeyenlerin sayısının artması nitelikli suç olan dolandırıcılık suçunu azaltıcı bir etkiye sahiptir. Bu bulgular, sosyo-ekonomik faktörlerin dolandırıcılık suçuyla olan ilişkisini daha iyi anlamamıza katkı sağlamaktadır.

ANAHTAR KELİMELER

Enflasyon, göç, PANEL ARDL, işsiz sayısı

Introduction

The crime of fraud has shown a significant increase both globally and in Turkey in recent years. The rapid development of technology, the widespread use of digital platforms, and the proliferation of transactions conducted over the internet have led to fraud crimes acquiring new methods. Modern types of crime, particularly cyber fraud, bank and credit card fraud, and investment scams, result in significant economic losses and victimization on an international level. In Turkey, fraud cases have also increased due to the effects of digitalization and financial conditions, raising risks to individuals' assets and having negative repercussions on societal trust. Therefore, taking more effective legal and technological measures in the fight against fraud has become a critical necessity, both globally and nationally.

The increase in fraud is closely linked to socio-economic factors. In particular, economic difficulties such as unemployment, income inequality, and poverty can lead individuals to resort to illegal means of obtaining unjust gains. During crisis periods, such as economic contractions and inflation, the loss of income and decline in living standards strengthen the tendency to commit crime. Furthermore, demographic changes like rapid urbanization and migration weaken social bonds; differences in social status and financial insecurity are among the factors that increase the motivation of those who commit fraud. Consequently, preventing fraud requires not only criminal sanctions but also addressing economic injustices and improving socio-economic conditions.

This study will examine the relationship between fraud crimes in Turkey between 2011 and 2020 and socio-economic factors, including the number of unemployed individuals, inflation, national income per capita, immigration, infrastructure investment amount, and population density. The analyses are conducted according to the Turkey NUTS-2 (Nomenclature of Territorial Units for Statistics) statistical region units classification. The reason for choosing the NUTS-2 level is that this classification is sufficiently detailed to reflect regional differences and also ensures the accessibility of TURKSTAT (Turkish Statistical Institute) data at this level. Thus, the relationship between socio-economic indicators and crime can be revealed more reliably.

The phenomenon of crime has traditionally been explained by sociological, psychological, and biological factors; however, these approaches have been insufficient in fully revealing the causes of crime. This deficiency has highlighted the need to address crime from an economic perspective as well. Indeed, Gary Becker's 1968 work titled "Crime and Punishment: An Economic Approach" pioneered the financial analysis of crime and filled an important gap in the literature. Becker's rational choice approach shows that crime can be analyzed within the framework of individuals' economic motivations and cost-benefit calculations. Based on this framework, the study above aims to examine fraud crime through socio-economic factors, targeting the creation of an original contribution to both the theoretical and empirical literature.

This study's contribution to the literature is that it is one of the first empirical analyses associating fraud crime with socio-economic factors at the regional level (NUTS-2) in Turkey. Thus, the findings obtained provide a new perspective for understanding the economic dimension of crime and shed light on policy implications for reducing crime rates.

deepens the theoretical and empirical gaps in this field. This study aims to address the deficiency in the literature by examining the potential Kuznets effect of economic growth on fraud, as well as assessing the relationship between factors such as education and urbanization and fraud in a more systematic manner. This section presents a general framework of studies on the subject by examining the main approaches and findings in the literature that deal with the relationship between fraud crime and socio-economic factors.

Lastauskas and Tatsi (2013) applied a spatial regression model to examine the relationship between the unemployment rate and property crimes in Germany between 2009 and 2010. The analysis results revealed a statistically significant relationship between the unemployment rate and property crimes.

Janko and Popli (2015) examined the relationship between types of crime and unemployment in Canada from 1979 to 2006. The study used the number of people incarcerated for violent crime, theft, robbery, extortion, and fraud as the dependent variable. The study applied unit root tests, time series analysis, and panel analysis methods. The analyses revealed a positive relationship between types of crime and unemployment in both the short and long term.

Dündar and Kesbiç (2019) employed spatial panel data analysis methods to investigate the relationship between property crimes and socio-economic factors, including unemployment, education, migration, and income, in Turkey from 2008 to 2014. The analyses conducted revealed that all socio-economic factors were effective on property crimes.

Ahmad et al. (2021) examined economic and non-economic factors affecting fraud in 41 European countries between 2014 and 2020 in their study. The study included countries consisting of developed, transition, and developing economies. Panel data analysis methods were employed in the research, with the generalized method of moments (GMM) and fixed effects models used to assess effects in both cross-sectional and time dimensions. According to the analysis results, political stability, economic freedom, poverty rates, and Gross Domestic Product (GDP) have a significant impact on fraud crimes.

Odabaşı (2022) used the least squares method in their study examining the relationship between the general crime rate and unemployment and income in Turkey between 2015 and 2019. According to the research results, it was found that an increase in the unemployment rate is associated with higher crime rates. In contrast, a rise in income level is associated with lower crime rates.

Sirohi and Misra (2024) examine individuals' vulnerability to economic crimes and the role of financial literacy in preventing these crimes in their study. A survey method was used in their research, and data were collected from 400 randomly selected participants from India. Within the scope of the study, the levels of financial literacy among individuals, their awareness of economic crimes, and their experiences with the effects of these crimes were analyzed. Data were evaluated using descriptive statistics and regression analysis. The results show that financial literacy significantly reduces the risk of being a victim of economic crime, highlighting the importance of policies aimed at increasing individuals' financial knowledge.

Shahid et al. (2024) investigated the impact of factors such as unemployment, income level, education level, infrastructure, and poverty on property crimes in Pakistan between 2000 and 2018. Based on panel data analysis, this study concluded that an increase in educational level is associated with a reduction in crime rates. In contrast, crime rates tend to increase in regions with low income and high unemployment rates.

Dataset, econometric methodology, and model

Dataset

In this study, using annual data from 2011 to 2020, the effects of socio-economic variables such as the number of unemployed, the inflation rate, national income per capita, the number of illiterate persons, received migration, and population density on the number of people

imprisoned for fraud crime across 26 regions at the NUTS2 level in Turkey were analyzed. The reason for selecting the 2011-2020 period data is that reliable data on the number of people imprisoned for fraud crime is only available up to the year 2020. The year 2011 is the starting year from which the independent variables could be obtained consistently. Therefore, the analysis period was limited to the most current and comprehensive data available. The data used in the study were obtained from the Turkish Statistical Institute (TURKSTAT) and the İller Bankası databases. The descriptive statistics and explanations of the variables are included in Table 1. To normalize the distribution of variables in the models and mitigate issues such as heteroscedasticity, all variables used in the study were transformed into natural logarithms.

Table 1. Descriptive statistics

Variable	Variable Description	Number of Observations	Mean	Stand. Deviation	Min.	Max.	Expected Impact
Dependent Variables							
LNFR	Number of people imprisoned for fraud crimes		4.583	1.198	0	7.598	
Independent Variables							
LNUNE	Number of unemployed persons by year	260	11.354	0.837	9.546	13.825	Positive
LNINF	Annual inflation rate	260	2.294	0.309	1.713	2.904	Positive
LNGDP	National income per capita	260	9.024	0.380	8.109	9.946	Negative / Positive
LNGDP2	Square of national income per capita	260	81.591	6.876	65.769	98.936	Negative
LNINR	Total infrastructure investment amount	260	30.502	4.378	14.963	34.524	Negative
LNMIĞ	Number of immigrants received annually	260	11.263	0.535	10.213	13.119	Positive
LNEDU	Number of illiterate persons	260	11.305	0.556	10.129	12.738	Negative
LNPOP	Share of urban population in total population by year	260	4.397	0.198	3.873	4.605	Positive

According to the data in Table 1, (i) Among the independent variables, the infrastructure investment amount variable shows higher variance compared to other variables, with its mean (30.502) and standard deviation (4.378) values.

The econometric models used in this study differ from those in previous research in terms of the variables and methods employed. Specifically, this research makes an original contribution to the crime literature by examining the impact of infrastructure investments and the number of illiterate individuals on crime rates. To investigate the effect of different income levels on crime, GDP per capita and its square were used as independent variables in the econometric models. This enables the analysis of potential non-linear effects that depend on income level.

Econometric method

The Panel ARDL (Autoregressive Distributed Lag) model is a method that allows for the analysis of both short-term and long-term dynamic relationships using time series data. This model is applied to panel datasets consisting of time and cross-sectional units (e.g., countries, firms). The Panel ARDL model is employed to investigate long-term equilibrium relationships and short-term dynamics among variables. The Panel ARDL (PARDL) approach allows for the examination of short- and long-term relationships between dependent and independent variables, even when the variables are at different levels of integration [I(0) or I(1)]. Additionally, when the panel data model is homogeneous, cross-sectional dependence (CD) is not a problem. However, when the model exhibits a heterogeneous structure, the absence of CD is crucial for the reliability of the estimates (Topaloğlu ve Bayraktaroğlu, 2023, p. 312).

The PARDL analysis statistic is as follows:

$$Y_{it} = \sum_{j=1}^p \lambda_{ij} Y_{i,t-j} + \sum_{j=0}^p \delta'_{ij} X_{i,t-j} + \mu_i + \varepsilon_{it} \quad (1)$$

$$\Delta Y_{it} = \phi_i(Y_{it-1} - \phi' X_{it}) + \sum_{j=1}^{p-1} \lambda^*_{ij} + \Delta Y_{it-j} + \sum_{j=0}^{p-1} \delta^*_{ij} + \Delta X_{it-j} + \mu_i + \varepsilon_{it} \quad (2)$$

In the formula, N represents the number of cross-sections, and $t = 1, 2, 3, \dots, T$ represents the time dimension, $k \times 1$ is the vector of explanatory variables, $\delta_{ij} \times 1$ represents coefficient vectors, λ_{ij} represents scales, μ_j represents cross-sectional effects, β_j represents vector coefficients, ϕ_j represents the error correction mechanism, and ε_{it} represents the error term. Pesaran, Shin, and Smith (1999) developed the Mean Group (MG) and Pooled Mean Group (PMG) estimators for use in panel data analyses, as part of their studies on the ARDL method. These estimators offer different methods for estimating model parameters. While the MG estimator produces separate estimates for each cross-sectional unit, the PMG estimator accommodates heterogeneity in short-term parameters while assuming that long-term parameters are homogeneous across all cross-sections. These approaches enable a more flexible and effective application of the ARDL model in panel datasets (Tatoğlu, 2018).

When the stationarity levels of the variables in this study are examined, it is determined that not all variables are at the same stationarity level. This situation created the need for a model that allows the use of series with different orders of integration together to analyze the long-term relationships between the variables accurately. Therefore, the Panel ARDL model was preferred for estimating the research model. The Panel ARDL was deemed suitable as a model that allows for determining both short-term and long-term relationships and does not cause stationarity problems.

Model

The following equations present the mathematical expressions of the empirical models used in the econometric analyses conducted in this study.

$$\ln fra_{i,t,m} = \alpha + \beta_1 \ln gdp_{i,t} + \beta_2 \ln gdp_{i,t}^2 + \beta_3 \ln une_{i,t} + \varepsilon_{i,t}$$

$$\ln dol_{i,t,m} = \alpha + \beta_1 \ln gdp_{i,t} + \beta_2 \ln gdp_{i,t}^2 + \beta_3 \ln inf_{i,t} + \varepsilon_{i,t}$$

$$\ln dol_{i,t,m} = \alpha + \beta_1 \ln gdp_{i,t} + \beta_2 \ln gdp_{i,t}^2 + \beta_3 \ln nr_{i,t} + \varepsilon_{i,t}$$

$$\ln dol_{i,t,m} = \alpha + \beta_1 \ln gdp_{i,t} + \beta_2 \ln gdp_{i,t}^2 + \beta_3 \ln mig_{i,t} + \varepsilon_{i,t}$$

$$\ln dol_{i,t,m} = \alpha + \beta_1 \ln gdp_{i,t} + \beta_2 \ln gdp_{i,t}^2 + \beta_3 \ln edu_{i,t} + \varepsilon_{i,t}$$

$$\ln dol_{i,t,m} = \alpha + \beta_1 \ln gdp_{i,t} + \beta_2 \ln gdp_{i,t}^2 + \beta_3 \ln pop_{i,t} + \varepsilon_{i,t}$$

In the equations above, $\ln fra_{i,t,m}$ represents the number of persons incarcerated for fraud crimes, $\ln gdp_{i,t}$ represents GDP per capita, $\ln gdp_{i,t}^2$ represents the square of GDP per capita,

$\ln nr_{i,t}$ represents the amount of infrastructure investment, $\ln mig_{i,t}$ represents the number of immigrants received, $\ln edu_{i,t}$ represents the number of illiterate persons, $\ln une_{i,t}$ number of unemployed people, $\ln inf_{i,t}$ inflation rate and $\ln pop_{i,t}$ represents urban population density. The square of GDP per capita ($\ln gdp_{i,t}^2$) is added to the equation because it is assumed that the effect of economic development on fraud crime rates may be non-linear and may differ after a threshold value (for example, it may show a Kuznets-type relationship). Additionally, in the equation, the subscripts i , t and m represent the region, year, and crime type, respectively; β represents the elasticity coefficients of the variables, α represents the model constant, \ln represents the natural logarithm, and ε represents the error terms.

Results

Before conducting the dynamic panel data analysis, it is critical to perform preliminary tests to ensure the model's validity and the reliability of the estimates. In this context, it is necessary to apply pre-analyses, such as cross-sectional dependence tests, homogeneity tests, and unit root tests, to ensure the validity of the results. In this study, the Pesaran CDLM test developed by Pesaran (2004) was initially applied. This test can be applied to both homogeneous and heterogeneous panel datasets and is valid in both situations where $T > N$ and $N > T$ (Pesaran, 2004, p. 4).

Table 2. Pesaran CD test results

Models	Pesaran Cd
Fraud Model 1	44.154 (0.000)
Fraud Model 2	48.126 (0.000)
Fraud Model 3	46.363 (0.000)
Fraud Model 4	40.920 (0.000)
Fraud Model 5	40.099 (0.000)
Fraud Model 6	24.010 (0.000)

As seen in Table 2, all models related to fraud crime exhibit cross-sectional dependence. Another important point to consider in panel data analyses is determining whether the variables are homogeneous. The homogeneity test is crucial for assessing the stationarity of a series and examining the presence of cointegration among them (Pesaran & Yamagata, 2008). In the literature, tests commonly used to examine homogeneity and heterogeneity include the "Swamy test (S)" developed by Swamy (1970) and the "Slope Homogeneity (Delta Tilde, Δ)" test developed by Pesaran and Yamagata (2008) to detect slope heterogeneity (Tatoglu, 2018).

Table 3. Homogeneity (Swamy) test results

Models	Chi2	Chi2 > Prob.
Fraud Model 1	522.65	0.0000
Fraud Model 2	637.08	0.0000
Fraud Model 3	725.88	0.0000
Fraud Model 4	641.22	0.0000
Fraud Model 5	8271.49	0.0000
Fraud Model 6	1599.82	0.0000

As presented in Table 3, since the probability values for all models are less than 0.05, the slope coefficients of the models are heterogeneous. Another crucial aspect is determining whether the variables used in the study are stationary over time, which is identified through panel unit root tests. Since the models exhibit cross-sectional dependence, this study employs the second-generation panel unit root test, namely the CIPS (Cross-sectionally Augmented IPS) test developed by Pesaran (2007). The CIPS statistics are based on the CADF test statistics. The CADF test was developed to provide reliable results in panel data analyses with cross-sectional dependence and is effective in both $T > N$ and $N > T$ cases (Küçükaksoy & Akalın, 2017, p.27).

Table 4. CIPS panel unit root test results

Variable (ln)	Level		First Difference	
	Costant	Constant and Trend	Costant	Constant and Trend
Fraud	-2.366**	-2.279		
GDP	-2.377**	-2.230		
GDP2	-2.384**	-2.234		
Inflation	-3.126***	-3.246***		
Unemployment	-1.895	-2.029	-2.544***	-2.353
Infrastructure	-2.394**	-2.333		
Education	-3.372***	-4.385***		
Migration	-2.870***	-2.635		
Population	-1.715	-2.320	-2.841***	-2.583

Note: (***) , (**), and (*) denote significance levels at 1%, 5%, and 10%, respectively.

As shown in the table, the dependent variable (fraud) is stationary at the level, implying it does not contain a unit root. The fraud variable is stationary only at the constant level. Among the independent variables, only the number of unemployed and population density are non-stationary at the level. Inflation and education variables exhibit stationarity at both constant and trend levels. GDP, GDP², migration, and investment variables are stationary at the constant level. The series of unemployment and population density contain unit roots but become stationary after first differencing, indicating they are stationary at their first difference under a constant level.

In Panel ARDL analysis, the Hausman test is conducted to determine whether the Mean Group (MG) or Pooled Mean Group (PMG) estimator is more appropriate. The Hausman test helps evaluate which estimator provides more consistent and reliable results for the model. Before performing the Hausman test, the lag length in the panel ARDL analysis is determined using the Akaike Information Criterion (AIC) and the Bayesian Information Criterion (BIC) (Verbeek, 2017; Hsiao, 2014; Baltagi, 2005).

Table 5. Hausman test results

Fraud	Chi-Square Value Chi2	Prob. (p-value) >	Chi-Square Value Chi2	Prob. (p-value) >
Model 1 (1,0,0,0)	0.70		0.9725	
Model 2 (1,0,0,0)	0.75		0.9911	
Model 3 (1,1,0,0)	0.77		0.9912	
Model 4 (1,0,0,0)	0.72		0.9743	
Model 5 (1,0,0,0)	0.81		0.9976	
Model 6 (1,1,1,1)	0.65		0.9147	

According to the Hausman test results presented in Table 5, since the probability values between the MG and PMG estimators are greater than 0.05, the PMG estimator is preferred. The Panel ARDL-PMG analysis results are presented in Tables 6 and 7 below.

Table 6. PMG ARDL Analysis Results (Fraud Offence - Short Term) (SR)

Variables	(1a) PMG-SR	(1b) PMG-SR	(1c) PMG-SR	(1d) PMG-SR	(1e) PMG-SR	(1f) PMG-SR
GDP	-18.428 (0.526)	34.988 (0.155)	85.679** (0.012)	-37.591 (0.224)	40.159 (0.146)	-22.514 (0.570)
GDP2	1.2698 (0.426)	-1.8937 (0.173)	-4.826** (0.013)	2.2323 (0.195)	-2.1936 (0.160)	1.2320 (.0582)
Unemployment	-0.24981** (0.013)					
Inflation		-0.0073 (0.929)				
Infrastructure			-0.00727 (0.585)			

Migration				-0.41338*** (0.004)		
Education					-0.0962 (0.865)	
Populaiton						-3.0798 (0.157)
ECT	-0.21959*** (0.000)	-0.2815*** (0.000)	-0.3725*** (0.000)	-0.3284*** (0.000)	-0.5224*** (0.000)	-0.5298*** (0.000)
Constant Term	-47.972*** (0.000)	-1.30666** (0.000)	4.4389*** (0.000)	-11.92067*** (0.000)	11.0710*** (0.000)	37.5758*** (0.000)

The findings obtained from the models constructed to examine the socio-economic factors affecting fraud crimes provide significant insights into the influence of various variables on crime dynamics. According to the results of Model 1a, income variables were found to be statistically insignificant, while the unemployment variable was significant. It was determined that a 1% increase in unemployment leads to an average decrease of 0.24981% in fraud crimes. This result contradicts the common findings in the literature, which generally suggest that unemployment increases crime. Considering that unemployment does not always imply a complete loss of income, as individuals may partially mitigate their economic difficulties through informal employment, unemployment benefits, and social assistance, the theoretical foundation of this finding is strengthened. In this regard, the result can be evaluated as consistent with the study of Yildiz et al. (2013).

In Model 1b, the inflation and income variables were found to be insignificant. This suggests that price instability and changes in income levels do not directly affect fraud crimes.

The results of Model 1c present a more comprehensive picture of the relationship between income and crime. According to the findings, a 1% increase in GDP raises fraud crimes by 85.679%, while GDP² reduces this effect by 4.826%. This finding indicates that the relationship between income and crime is nonlinear: up to a certain level of income, rising prosperity may trigger more crimes; however, as income inequality decreases, crime rates tend to decline. This result supports the studies of Donchev and Ujhelyi (2014) and Metz and Burdina (2018).

The findings of Model 1d reveal the role of migration in crime dynamics. A 1% increase in migration was found to reduce fraud crimes by 0.41338%. Particularly, skilled migration has the potential to reduce crime rates by contributing to the labor market and strengthening social capital. This result is consistent with the findings of Orrenius and Zavodny (2015).

In Models 1e and 1f, the variables representing the number of illiterate individuals and population density were found to be insignificant. This finding suggests that fraud crimes may be more closely associated with economic and demographic dynamics rather than educational deficiencies or population pressure.

Finally, the error correction term (ECT) obtained through the PARDL analysis was found to be negative and statistically significant across all models, indicating the existence of a long-term equilibrium relationship among the variables. This result demonstrates that socio-economic factors influence fraud crimes in a structural and long-term manner, rather than merely reflecting short-term fluctuations.

Table 7. PMG ARDL Analysis Results (Fraud Crime - Long Term) (ECT)

Variables	(1a)	(1b)	(1c)	(1d)	(1e)	(1f)
	PMG-ECT	PMG-ECT	PMG-ECT	PMG-ECT	PMG-ECT	PMG-ECT
GDP	54.610*** (0.000)	2.510 (0.783)	-33.897*** (0.000)	7.6320 (0.583)	3.1937 (0.638)	-15.3648** (0.030)
GDP2	-3.185*** (0.000)	-0.1761 (0.726)	1.688*** (0.000)	-0.4501 (0.557)	-0.1144 (0.763)	0.7672** (0.053)
Unemployment	-0.797*** (0.000)					

Inflation		0.7615***				
		(0.000)				
Infrastructure			0.0463***			
			(0.008)			
Migration				1.3561***		
				(0.000)		
Education					-3.161***	
					(0.000)	
Populaiton						2.2464***
						(0.000)
Constant Term	-47.972***	-1.30666**	4.4389***	-11.92067***	11.0710***	37.5758***
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)

The figures in brackets indicate the t-statistics. * < 0.10, ** < 0.05, *** < 0.01

According to the long-term analysis, all variables in Model 1a are statistically significant in explaining fraud crimes. A 1% increase in the number of unemployed individuals reduces fraud crimes by 0.797%, holding other variables constant. This finding can be explained by the fact that unemployed individuals may access alternative sources of income through informal employment, unemployment benefits, and social assistance. Such supplementary income sources alleviate economic hardship, reducing the likelihood of individuals engaging in illegal activities. This result is consistent with Yıldız et al. (2013). However, while a 1% increase in GDP raises fraud crimes by 54.610%, a 1% increase in GDP² reduces them by 0.797%. When GDP growth deepens, income inequality, social tension, and unequal opportunities may trigger fraudulent behavior. Conversely, improvements in income distribution have been shown to reduce crime rates. These findings align with Krahn et al. (1986) and Oliver (2002).

Within the scope of Model 1b, only the inflation variable was found to be significant—a 1% increase in inflation results in a 0.7615% increase in fraud crimes. Since inflation erodes purchasing power, individuals may face greater financial pressure, which in turn increases their tendency to engage in illegal activities. This result is consistent with Ahmad (2021).

According to the findings of Model 1c, all variables significantly affect fraud crimes. A 1% increase in infrastructure investment results in a 0.0463% increase in fraud crimes. Although the literature generally emphasizes that infrastructure investments reduce crime, lack of transparency and oversight may increase the risk of fraud (Tanzi & Daavoodi, 1998). In addition, a 1% increase in GDP reduces fraud crimes by 33.897%. Higher income levels can reduce exposure to fraud by increasing individuals' access to legal and financial protection. This finding is consistent with Cohen's (2008) work; however, a 1% increase in GDP² results in a 1.688% increase in fraud crimes. As income rises, some individuals may be tempted to pursue rapid wealth accumulation and social status through illicit means, explaining this result. This finding is similar to Baharom and Habibullah (2009).

According to the PARDL-ECT analysis results of Model 1d, migration is the only variable that significantly affects fraud crimes. A 1% increase in inbound migration results in a 1.3561% increase in fraud crimes. Difficulties in finding employment and financial hardships faced by newcomers may lead them to engage in illegal activities. This result aligns with Wasem (2008).

The findings of Model 1e indicate that only the number of illiterate individuals is significant. A 1% increase in the number of illiterate individuals reduces fraud crimes by 3.161%. Fraud offenses often require a certain level of knowledge and skills, which may explain this result. A similar perspective is presented by Gordon (1971).

Finally, according to the PARDL-ECT results of Model 1f, all variables are significant—a 1% increase in population density results in a 2.2464% increase in fraud crimes. In densely populated areas, weakened social ties and anonymity may facilitate the commission of crimes (Clinard, 1942). Conversely, a 1% increase in GDP reduces fraud crimes by 15.3648%. Rising income levels provide individuals with better educational opportunities, employment prospects, and improved living conditions, thereby reducing their likelihood of committing crimes (Irmak,

2012); however, a 1% increase in GDP results in a 0.7672% increase in fraud crimes. Income growth may create a more complex economic environment, generating new opportunities for fraudsters to exploit. This finding is consistent with Pare (2006).

Discussion and conclusions

The analysis of socio-economic factors affecting fraud crimes reveals that various variables have a significant impact on crime rates. Factors such as unemployment, inflation, infrastructure investment, migration, illiteracy, and population density influence fraud crimes in different ways. Short-term PARDL analyses indicate that certain socio-economic variables have a significant and direct influence on fraud crimes. The key findings are as follows:

- Unemployment: In the short run, higher unemployment reduces fraud crimes. This can be explained by the ability of unemployed individuals to access alternative income sources such as informal work, social assistance, or unemployment benefits.
- Inflation: Rising inflation increases individuals' financial stress and the likelihood of seeking illegal sources of income.
- Income and Income Squared (GDP and GDP²): Income growth can either increase or decrease crime rates in the short term, depending on income inequality and differences in social opportunity.
- Migration: In the short term, increased migration raises fraud crimes, mainly due to migrants' difficulties in finding jobs and weak social integration.

Short-term findings suggest that economic and social shocks can have a rapid impact on fraud crimes, although these effects are often temporary and variable. Long-term analyses, however, show stable and persistent relationships between fraud crimes and socio-economic factors:

- Unemployment and Alternative Income Sources: In the long run, higher unemployment reduces fraud crimes due to informal employment and social assistance. This aligns with short-term findings, showing that unemployment does not automatically lead to higher crime.
- Income and Income Squared (GDP and GDP²): When income growth is unevenly distributed, it may increase fraud, whereas higher overall prosperity (captured by GDP²) and reduced inequality lower crime rates. This highlights the dual effect of income on crime.
- Inflation: Persistently high inflation increases the risk of fraud in the long term, as individuals under prolonged economic pressure are more likely to engage in illegal activities.
- Infrastructure Investment: Due to insufficient oversight and transparency, infrastructure investments may increase opportunities for fraud.
- Migration and Population Density: Both migration and high population density weaken social cohesion and increase long-term crime risk.
- Literacy: Low literacy levels are associated with lower fraud rates, as such crimes typically require specific skills and knowledge.

These findings provide a comprehensive understanding of how socio-economic factors affect fraud crimes and offer key insights for developing preventive and corrective strategies. Economic and social policies designed with these factors in mind can help reduce crime rates. Policy Recommendations:

1. Unemployment and Economic Support: Since higher unemployment is associated with lower fraud crimes due to alternative income sources, expanding the scope and efficiency of unemployment insurance and social assistance programs is essential. Strengthening legal income opportunities for economically vulnerable individuals can further reduce the likelihood of engaging in fraud. Additionally, policies promoting fair income distribution can help mitigate the long-term impact of inequality on crime rates.

2. Inflation Management: Economic policies aimed at controlling inflation should be implemented to protect purchasing power and reduce the economic stress that drives individuals toward fraud.
3. Transparency and Oversight: Establishing transparent and accountable monitoring mechanisms for infrastructure projects can reduce fraud-related risks.
4. Migrant Support Programs: Developing employment and integration programs for migrants can help them overcome financial and social challenges, reducing the likelihood of engaging in illegal activities.
5. Education and Awareness: Literacy and adult education programs should be expanded. Education enhances individuals' capacity for legal economic participation while reducing their involvement in complex fraudulent activities.
6. Population Density Management: Social programs that strengthen community ties and neighborly relations in densely populated areas should be promoted, making it harder for crimes to go unnoticed.

These recommendations can support the development of effective strategies for reducing fraud crimes. Considering both the empirical results and the findings in the literature, the implementation of diverse social and economic policies is crucial for effective and sustainable crime prevention.

Conflict of interest declaration

Conflict of interest

Our article titled "Examination of Socio-economic Factors Affecting Fraud Crimes in Türkiye Using Panel ARDL Analysis" has no conflict of financial interest with any institution, organization, or individual. There is also no conflict of interest among the authors.

Funding

No external funding was received for this research.

Author contributions (CRediT)

Author 1 (Ufuk IŞIK): Conceptualization; Methodology; Research/Review; Data organization and analysis; Original draft writing; Writing review and editing; Visualization.

Author 2 (Selahattin KAYNAK): Conceptualization; Methodology; Verification; Control; Writing review and editing.

All authors have read and approved the final version of the manuscript.

Data availability statement

Data may be obtained from the responsible author upon reasonable request.

Ethics approval and consent to participate

This study does not require ethical committee approval.

Use of artificial intelligence (AI) tools

In this article, AI-powered tools were used only in the language editing process. No AI-powered tools were used in any other part of the article.

TÜRKÇE SÜRÜM

Giriş

Dolandırıcılık suçu, hem dünya genelinde hem de Türkiye’de son yıllarda önemli bir artış göstermiştir. Teknolojinin hızla gelişmesi, dijital platformların yaygınlaşması ve internet üzerinden gerçekleştirilen işlemlerin çoğalması, dolandırıcılık suçlarının yeni yöntemler kazanmasına yol açmıştır. Özellikle siber dolandırıcılık, banka ve kredi kartı dolandırıcılığı, yatırım sahtekârlıkları gibi modern suç tipleri, uluslararası düzeyde ciddi ekonomik kayıplara ve mağduriyetlere neden olmaktadır. Türkiye’de de dolandırıcılık vakaları, dijitalleşme ve ekonomik koşulların etkisiyle artış göstermiş; bireylerin malvarlıklarına yönelik riskleri artırmış ve toplumsal güvene olumsuz yansımalar doğurmuştur. Bu nedenle hem küresel hem de ulusal düzeyde dolandırıcılıkla mücadelede daha etkin hukuki ve teknolojik önlemler alınması kritik bir gereklilik haline gelmiştir.

Dolandırıcılık suçunun artışı, sosyo-ekonomik faktörlerle yakından ilişkilidir. Özellikle işsizlik, gelir eşitsizliği ve yoksulluk gibi ekonomik sıkıntılar, bireyleri haksız kazanç elde etmeye yönelik yasa dışı yollara yöneltebilmektedir. Ekonomik daralmalar ve enflasyon gibi kriz dönemlerinde bireylerin gelir kaybı ve yaşam standartlarındaki düşüş, suç işleme eğilimini güçlendirmektedir. Ayrıca, hızlı kentleşme ve göç gibi demografik değişiklikler sosyal bağları zayıflatmakta; sosyal statü farklılıkları ve finansal güvensizlik ise dolandırıcılık suçunu işleyenlerin motivasyonunu artıran unsurlar arasında yer almaktadır. Dolayısıyla dolandırıcılığın önlenmesi için yalnızca cezai yaptırımlar değil, aynı zamanda ekonomik adaletsizliklerin giderilmesi ve sosyo-ekonomik koşulların iyileştirilmesi de gereklidir.

Bu çalışmada, Türkiye’de 2011–2020 yılları arasında dolandırıcılık suçunun işsiz sayısı, enflasyon, kişi başına düşen milli gelir, alınan göç, altyapı yatırım miktarı ve nüfus yoğunluğu gibi sosyo-ekonomik faktörlerle ilişkisi incelenecektir. Analizler, Türkiye İBBS-2 İstatistiki Bölge Birimleri Sınıflamasına göre yapılmaktadır. İBBS-2 düzeyinin tercih edilme nedeni, bu sınıflandırmanın hem bölgesel farklılıkları yansıtacak ölçüde ayrıntılı olması hem de TÜİK verilerinin bu düzeyde erişilebilirliğinin sağlanmasıdır. Böylece, sosyo-ekonomik göstergelerle suç arasındaki ilişki daha sağlıklı bir şekilde ortaya konabilecektir.

Suç olgusu, geleneksel olarak sosyolojik, psikolojik ve biyolojik faktörlerle açıklanmaya çalışılmış; ancak bu yaklaşımlar suçun nedenlerini tam anlamıyla ortaya koymada yetersiz kalmıştır. Bu eksiklik, suçun ekonomik perspektiften de ele alınması gerekliliğini gündeme getirmiştir. Nitekim Gary Becker’in 1968 yılında yayımladığı “Crime and Punishment: An Economic Approach” başlıklı çalışması, suçun ekonomik analizine öncülük etmiş ve literatürde önemli bir boşluğu doldurmuştur. Becker’in rasyonel tercih yaklaşımı, suçun bireylerin ekonomik motivasyonları ve fayda-maliyet hesapları çerçevesinde analiz edilebileceğini göstermektedir. Bu çerçeveden hareketle, söz konusu çalışma dolandırıcılık suçunu sosyo-ekonomik faktörler üzerinden incelemeyi amaçlamakta; hem teorik hem de ampirik literatüre özgün bir katkı sağlamayı hedeflemektedir.

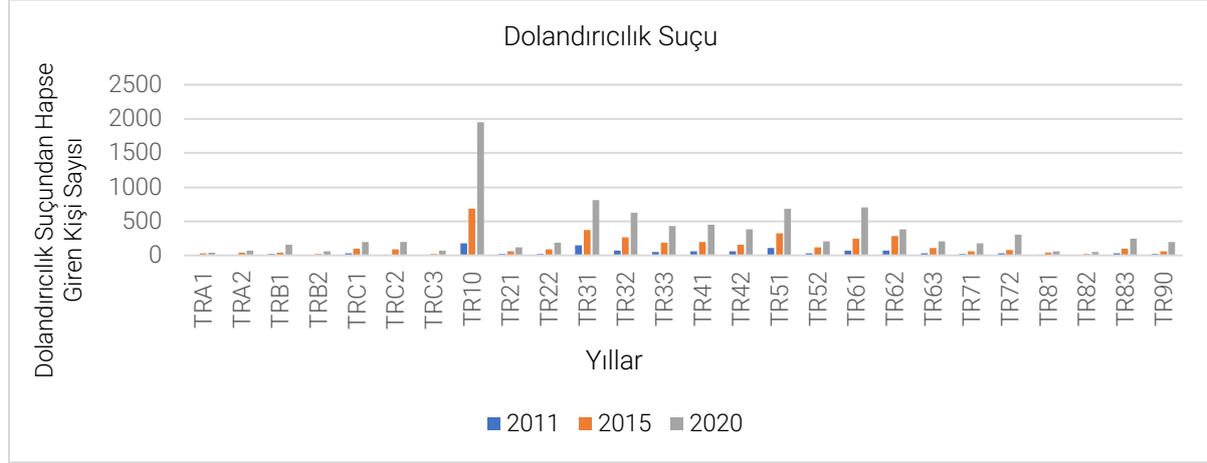
Bu çalışmanın literatüre katkısı, Türkiye’de dolandırıcılık suçunu bölgesel düzeyde (İBBS-2) sosyo-ekonomik faktörlerle ilişkilendiren ilk ampirik analizlerden biri olmasıdır. Böylece, elde edilen bulgular suçun ekonomik boyutunu anlamaya yönelik yeni bir bakış açısı kazandırmakta ve suç oranlarını azaltmaya yönelik politika çıkarımlarına ışık tutmaktadır.

Dolandırıcılık

Mal varlığına karşı işlenen suçlar arasında yer alan dolandırıcılık, ekonomik menfaat sağlamaya yönelik hileli davranışlarla karakterize edilen bir suç tipidir. Türk Ceza Kanunu’nun 157. maddesinde düzenlenen bu suç, failin, mağduru yanıltıcı hareketlerle aldatarak, onun veya üçüncü kişilerin malvarlığında zarara neden olması ve bu suretle kendisine veya başka birine

haksız kazanç sağlaması ile vücut bulmaktadır. Dolandırıcılık suçu, ekonomik düzeni bozucu etkisi ve mağdurları üzerindeki maddi kayıplarla, toplumun genel güven ve istikrarını tehdit eden önemli bir suç tipi olarak değerlendirilmektedir. Bu suçun işlenmesi halinde fail, kanunda öngörülen hapis cezası ve adli para cezası ile cezalandırılmakta olup, suçun nitelikli halleri ise daha ağır yaptırımlarla karşılaşmaktadır. 5237 sayılı Türk Ceza Kanunu'nun 157. maddesi, dolandırıcılık suçunu tanımlamaktadır. Dolandırıcılık suçu, hileli davranışlarla bir kişiyi aldatıp onun malvarlığına zarar vermek ve bu yolla failin kendisine veya üçüncü bir kişiye menfaat sağlamasıyla meydana gelir. Bu suçu işleyenler, bir yıldan beş yıla kadar hapis ve beş bin güne kadar adli para cezası ile cezalandırılır. (Artuç, 2007, s.363).

Şekil 1'de Türkiye'de İBBS2 bölge düzeyinde yer alan 263 bölgeye ait dolandırıcılık suçundan mahkûm olan kişi sayısı gösterilmektedir.



Şekil 1. Dolandırıcılık Suçundan Hapse Giren Kişi Sayısı (2011-2020)

2011 yılına odaklandığımızda, dolandırıcılık suçlarından mahkûm olan kişilerin en yoğun bulunduğu bölgeler sırasıyla TR10 İstanbul (178 kişi), TR31 İzmir (144 kişi) ve TR51 Ankara (110 kişi) olarak kaydedilmiştir. 2015 yılı verileri incelendiğinde ise, 2011 yılı ile benzer bir eğilim görülmektedir; bu dönemde en fazla mahkûm sayısına sahip bölgeler TR10 (685 kişi), TR31 (372 kişi) ve TR51 (325 kişi) olarak sıralanmıştır. 2020 yılına gelindiğinde ise, dolandırıcılık suçlarının en yoğun olduğu bölgeler TR10 İstanbul (1954 kişi), TR31 İzmir (808 kişi) ve TR61 Antalya, Isparta ve Burdur (706 kişi) olmuştur.

Literatür taraması

Literatürde dolandırıcılık suçunu etkileyen ekonomik ve sosyal faktörlere dair çalışmalar, genellikle birbirinden bağımsız şekilde ele alınmış ve kapsamlı bir çerçeve sunmaktan uzak kalmıştır. Özellikle, dinamik panel veri analizine dayanan araştırmaların yetersiz olması, bu alandaki teorik ve ampirik boşlukları derinleştirmektedir. Bu çalışma, ekonomik büyümenin dolandırıcılık üzerindeki olası Kuznets etkisini incelemenin yanı sıra, eğitim, kentleşme gibi faktörlerin dolandırıcılık suçuyla olan ilişkisini daha sistematik bir şekilde değerlendirerek literatürdeki bu eksikliği gidermeyi hedeflemektedir. Bu bölümde, dolandırıcılık suçunun sosyo-ekonomik faktörlerle ilişkisini ele alan literatürdeki temel yaklaşımlar ve bulgular incelenerek, konuya dair yapılan çalışmaların genel bir çerçevesi sunulacaktır.

Lastauskas ve Tatsi (2013), Almanya'da 2009-2010 yılları arasında mal varlığına karşı işlenen suçlarla işsizlik oranı arasındaki ilişkiyi incelemek amacıyla mekânsal regresyon modeli

³ TR10 (İstanbul), TR21 (Tekirdağ, Edirne, Kırklareli), TR22 (Balıkesir, Çanakkale), TR31 (İzmir), TR32 (Aydın, Denizli, Muğla), TR33 (Manisa, Afyonkarahisar, Kütahya, Uşak), TR41 (Bursa, Eskişehir, Bilecik), TR42 (Kocaeli, Sakarya, Düzce, Bolu, Yalova), TR51 (Ankara), TR52 (Konya, Karaman), TR61 (Antalya, Isparta, Burdur), TR62 (Adana, Mersin), TR63 (Hatay, Kahramanmaraş, Osmaniye), TR71 (Kırıkkale, Aksaray, Niğde, Nevşehir, Kırşehir), TR72 (Kayseri, Sivas, Yozgat), TR81 (Zonguldak, Karabük, Bartın), TR82 (Kastamonu, Çankırı, Sinop), TR83 (Samsun, Tokat, Çorum, Amasya), TR90 (Trabzon, Ordu, Giresun, Rize, Artvin, Gümüşhane), TRA1 (Erzurum, Erzincan, Bayburt), TRA2 (Ağrı, Kars, Iğdır, Ardahan), TRB1 (Malatya, Elâzığ, Bingöl, Tunceli), TRB2 (Van, Muş, Bitlis, Hakkâri), TRC1 (Gaziantep, Adıyaman, Kilis), TRC2 (Şanlıurfa, Diyarbakır), TRC3 (Mardin, Batman, Şırnak, Siirt)

uygulamışlardır. Analiz sonuçları, işsizlik oranı ile mal varlığına karşı işlenen suçlar arasında istatistiksel olarak anlamlı bir ilişki bulunduğunu ortaya koymuştur.

Janko ve Popli (2015), 1979-2006 yılları arasında Kanada'da suç türleri ile işsizlik arasındaki ilişkiyi incelemişlerdir. Araştırmada, bağımlı değişken olarak şiddet suçu, hırsızlık, soygun, gasp ve dolandırıcılık suçlarından hapse giren kişi sayısı kullanılmıştır. Çalışmada, birim kök testi ve zaman serisi analizi ile panel analizi yöntemleri uygulanmıştır. Analizler, suç türleri ile işsizlik arasında hem kısa hem de uzun vadeli pozitif bir ilişkinin varlığını göstermiştir.

Dündar ve Kesbiç (2019), 2008-2014 dönemi Türkiye'de mal varlığına karşı işlenen suçlarla işsizlik, eğitim, göç ve gelir gibi sosyo-ekonomik faktörler arasındaki ilişkiyi mekânsal panel veri analizi yöntemi kullanarak incelemişlerdir. Yapılan analizler, tüm sosyo-ekonomik faktörlerin mala karşı işlenen suçlar üzerinde etkili olduğunu ortaya koymuştur.

Ahmad vd. (2021), çalışmalarında 2014-2020 yılları arasında 41 Avrupa ülkesinde dolandırıcılığı etkileyen ekonomik ve ekonomik olmayan faktörler incelemişlerdir. Çalışmalarında gelişmiş, geçiş sürecindeki ve gelişmekte olan ekonomilerden oluşan ülkeler ele alınmıştır. Araştırmada panel veri analizi yöntemleri kullanılmış; özellikle genelleştirilmiş momentler yöntemi (GMM) ve sabit etkiler modelleri, hem kesitsel hem de zaman boyutunda etkileri değerlendirmek için tercih edilmiştir. Analiz sonuçlarına göre, siyasi istikrar, ekonomik özgürlük, yoksulluk oranları ve gayrisafi yurt içi hasıla (GSYİH), dolandırıcılık suçları üzerinde anlamlı bir etkiye sahiptir.

Odabaşı (2022), Türkiye'de 2015-2019 yılları arasında genel suç sayısı ile işsizlik ve gelir arasındaki ilişkiyi incelediği çalışmada, en küçük kareler yöntemi kullanmıştır. Araştırma sonuçlarına göre, işsizlik oranındaki artışın suç oranlarını artırdığı, buna karşın gelir düzeyindeki yükselişin suç oranlarını azalttığı bulunmuştur.

Sirohi ve Misra (2024) çalışmalarında, bireylerin ekonomik suçlara karşı savunmasızlıklarını ve finansal okuryazarlığın bu suçların önlenmesindeki rolünü incelemektedirler. Çalışmalarında anket yöntemi kullanılmış olup, Hindistan'dan rastgele seçilen 400 katılımcının verileri toplanmıştır. Araştırma kapsamında, bireylerin finansal okuryazarlık düzeyleri, ekonomik suçlara karşı farkındalıkları ve bu suçların etkilerini nasıl deneyimledikleri analiz edilmiştir. Veriler, betimsel istatistikler ve regresyon analiziyle değerlendirilmiştir. Sonuçlar, finansal okuryazarlığın ekonomik suç mağduru olma riskini önemli ölçüde azalttığını göstermekte ve bireylerin finansal bilgi seviyelerini artırmaya yönelik politikaların önemini vurgulamaktadır.

Shahid vd. (2024) çalışmalarında 2000 ile 2018 yılları arasında Pakistan'da işsizlik, gelir düzeyi, eğitim seviyesi, altyapı ve yoksulluk gibi faktörlerin mal varlığına karşı işlenen suçlar üzerindeki etkisi araştırmışlardır. Panel veri analizine dayanan bu çalışmada, eğitim düzeyinin artmasının suç oranlarını azalttığı ve düşük geliri ve yüksek işsizlik oranına sahip bölgelerde ise suçların arttığı sonucuna ulaşılmıştır.

Veri seti, ekonometrik metodoloji ve model

Veri seti

Bu çalışmada, 2011-2020 yılları arasındaki yıllık veriler kullanılarak işsiz sayısı, enflasyon oranı, kişi başına düşen milli gelir, okuma yazma bilmeyen kişi sayısı, alınan göç ve nüfus yoğunluğu gibi sosyo-ekonomik değişkenlerin, Türkiye'de İBBS2 düzeyinde yer alan 26 bölge için dolandırıcılık suçundan hapse giren kişi sayısı üzerindeki etkileri analiz edilmiştir. Çalışmada 2011-2020 dönemi verilerinin seçilmesinin nedeni, dolandırıcılık suçu nedeniyle hapse giren kişi sayısına ilişkin güvenilir verilerin yalnızca 2020 yılına kadar mevcut olmasıdır. 2011 yılı ise bağımsız değişkenlerin tutarlı şekilde elde edilebildiği başlangıç yılıdır. Bu nedenle, analiz dönemi mevcut en güncel ve kapsamlı verilerle sınırlandırılmıştır. Çalışmada kullanılan veriler, Türkiye İstatistik Kurumu (TÜİK) ve İller Bankası veritabanlarından temin edilmiştir. Değişkenlerin tanımlayıcı istatistikleri ve açıklamaları Tablo 1'de yer almaktadır. Modellerdeki değişkenlerin dağılımını normalleştirmek ve değişen varyans gibi sorunları azaltmak için çalışmada kullanılan tüm değişkenler doğal logaritmaya dönüştürülmüştür.

Tablo 1. Tanımlayıcı istatistikler tablosu

Değişkenler	Değişkenlerin Açıklaması	Gözlem Sayısı	Ortalama	Standart Sapma	Minimum	Maksimum	Beklenen Etki
Bağımlı Değişkenler							
LNDOL	Dolandırıcılık suçundan hapse giren kişi sayısı		4.583	1.198	0	7.598	
Bağımsız Değişkenler							
LNIŞSİZ	Yıllara göre işsiz sayısı	260	11.354	0.837	9.546	13.825	Pozitif
LNENF	Yıllık enflasyon oranı	260	2.294	0.309	1.713	2.904	Pozitif
LNGSYİH	Kişi başına düşen milli gelir (dolar cinsinden)	260	9.024	0.380	8.109	9.946	Negatif / Pozitif
LNGSYİH2	Kişi başına düşen milli gelirin karesi	260	81.591	6.876	65.769	98.936	Negatif
LNİYAT.	Toplam altyapı yatırım miktarı	260	30.502	4.378	14.963	34.524	Negatif
LNGOC	Yıllık alınan göç sayısı	260	11.263	0.535	10.213	13.119	Pozitif
LNEĞİT	Okuma yazma bilmeyen kişi sayısı	260	11.305	0.556	10.129	12.738	Negatif
LNNÜFUS	Yıllara göre şehir nüfusunun toplam nüfus içindeki payı	260	4.397	0.198	3.873	4.605	Pozitif

Tablo 1’de yer alan verilerine göre, (i) bağımsız değişkenler arasında altyapı yatırımı miktarı değişkeni, ortalama (30.502) ve standart sapma (4.378) değerleriyle diğer değişkenlere kıyasla daha yüksek bir varyans göstermektedir. Bu çalışmada kullanılan ekonometrik modeller, önceki araştırmalardan kullanılan değişkenler ve yöntemler açısından farklılık göstermektedir. Özellikle, bu araştırma suç literatürüne altyapı yatırımlarının ve okuma yazma bilmeyen bireylerin sayısının suç oranları üzerindeki etkisini inceleyerek özgün bir katkı sunmaktadır. Farklı gelir düzeylerinin suç üzerindeki etkisini incelemek amacıyla, kişi başına düşen GSYİH ve bu değişkenin karesi, ekonometrik modellerde bağımsız değişkenler olarak kullanılmıştır. Bu sayede gelir düzeyine bağlı olası doğrusal olmayan etkiler analiz edilmiştir.

Ekonometrik yöntem

Panel ARDL (Autoregressive Distributed Lag) modeli, zaman serisi verilerini kullanarak hem kısa vadeli hem de uzun vadeli dinamik ilişkilerin analizine imkân veren bir yöntemdir. Bu model, zaman ve kesit birimlerinden (örneğin, ülkeler, firmalar) oluşan panel veri setlerinde uygulanır. Panel ARDL modeli, değişkenler arasındaki uzun dönem denge ilişkilerini ve kısa dönemli dinamikleri incelemek için kullanılır. Panel ARDL (PARDL) yaklaşımı, bağımlı ve bağımsız değişkenler arasında kısa ve uzun vadeli ilişkilerin, değişkenlerin farklı entegrasyon seviyelerinde [I(0) veya I(1)] olmasına rağmen incelenmesine olanak tanır. Ayrıca, panel veri modeli homojen olduğunda yatay kesit bağımlılığı (YKB) sorun teşkil etmez. Ancak model heterojen bir yapı sergilediğinde, YKB'nin bulunmaması tahminlerin güvenilirliği açısından kritiktir (Topaloğlu ve Bayraktaroğlu, 2023, s.312).

PARDL analiz istatistiği aşağıdaki gibidir;

$$Y_{it} = \sum_{j=1}^p \lambda_{ij} Y_{i,t-j} + \sum_{j=0}^p \delta_{ij} X_{i,t-j} + \mu_i + \varepsilon_{it} \quad (1)$$

$$\Delta Y_{it} = \phi_i (Y_{it-1} - \phi X_{it}) + \sum_{j=1}^{p-1} \lambda^*_{ij} + \Delta Y_{it-j} + \sum_{j=0}^{p-1} \delta^*_{ij} + \Delta X_{it-j} + \mu_i + \varepsilon_{it} \quad (2)$$

Formülde N yatay kesit sayısını, $t=1,2,3,\dots$ T zaman boyutunu, $k \times 1$, açıklayıcı değişken vektörünü, δ_{ij} $k \times 1$ katsayı vektörlerini, λ_{ij} , ölçekleri, μ_j , yatay kesit etkilerini, β_j , vektör katsayılarını, \emptyset_j , hata düzeltme mekanizmasını ve ε_{it} ise hata terimini ifade etmektedir. Pesaran, Shin ve Smith (1999), ARDL yöntemine ilişkin çalışmalarında panel veri analizlerinde kullanılmak üzere Mean Group (MG) ve Pooled Mean Group (PMG) tahmincilerini geliştirmişlerdir. Bu tahminciler, model parametrelerini tahmin etmek için farklı yöntemler sunar. MG tahmincisi, her bir kesit birimi için ayrı tahminler yaparken, PMG tahmincisi kısa vadeli parametrelerde heterojenlik olmasına izin verirken, uzun vadeli parametrelerin tüm kesitlerde homojen olduğunu varsayar. Bu yaklaşımlar, ARDL modelinin panel veri setlerinde daha esnek ve etkili bir şekilde uygulanmasını sağlamaktadır (Tatoğlu, 2018).

Bu çalışmada değişkenlerin durağanlık düzeyleri incelendiğinde, tüm değişkenlerin aynı durağanlık seviyesinde olmadığı tespit edilmiştir. Bu durum, değişkenler arasındaki uzun dönem ilişkilerinin doğru şekilde analiz edilebilmesi için farklı mertebede durağanlık serilerinin bir arada kullanılmasına olanak tanıyan bir model gereksinimi doğurmuştur. Bu nedenle, araştırma modelinin tahmininde Panel ARDL modeli tercih edilmiştir. Panel ARDL, hem kısa dönem hem de uzun dönem ilişkilerini belirlemeye imkan tanıyan, aynı zamanda durağanlık sorunu oluşturmayan bir model olarak uygun görülmüştür.

Model

Aşağıdaki eşitlikler, çalışmada gerçekleştirilen ekonometrik analizlere ilişkin ampirik modellerin matematiksel ifadelerini sunmaktadır.

$$lndol_{i,t,m} = \alpha + \beta_1 lngsyih_{i,t} + \beta_2 lngsyih_{i,t}^2 + \beta_3 lnışsz_{i,t} + \varepsilon_{i,t}$$

$$lndol_{i,t,m} = \alpha + \beta_1 lngsyih_{i,t} + \beta_2 lngsyih_{i,t}^2 + \beta_3 lnenf_{i,t} + \varepsilon_{i,t}$$

$$lndol_{i,t,m} = \alpha + \beta_1 lngsyih_{i,t} + \beta_2 lngsyih_{i,t}^2 + \beta_3 lnyat_{i,t} + \varepsilon_{i,t}$$

$$lndol_{i,t,m} = \alpha + \beta_1 lngsyih_{i,t} + \beta_2 lngsyih_{i,t}^2 + \beta_3 lngöc_{i,t} + \varepsilon_{i,t}$$

$$lndol_{i,t,m} = \alpha + \beta_1 lngsyih_{i,t} + \beta_2 lngsyih_{i,t}^2 + \beta_3 lnoku_{i,t} + \varepsilon_{i,t}$$

$$lndol_{i,t,m} = \alpha + \beta_1 lngsyih_{i,t} + \beta_2 lngsyih_{i,t}^2 + \beta_3 lnnüf_{i,t} + \varepsilon_{i,t}$$

Yukardaki denklemlerde $lndol_{i,t,m}$ dolandırıcılık suçundan hapse giren kişi sayısını, $lngsyih_{i,t}$ kişi başı düşen milli geliri, $lngsyih_{i,t}^2$ kişi başı düşen milli gelirin karesini, $lnyat_{i,t}$ alt yapı yatırım miktarını, $lngöc_{i,t}$ alınan göç sayısını, $lnoku_{i,t}$ okuma yazma bilmeyen kişi sayısını, $lnışsz_{i,t}$ işsiz kişi sayısını, $lnenf_{i,t}$ enflasyon oranını ve $lnnüf_{i,t}$ şehir nüfus yoğunluğunu ifade etmektedir. Denklemde kişi başına düşen milli gelirin karesi ($lngsyih_{i,t}$) eklenmiştir, çünkü ekonomik gelişmenin dolandırıcılık suç oranı üzerindeki etkisinin doğrusal olmayabileceği ve bir eşik değerden sonra farklılaşabileceği (örneğin, Kuznets tipi bir ilişki gösterebileceği) varsayılmaktadır. Ayrıca eşitlikteki alt simgeler i , t ve m sırasıyla bölgeyi, yılı ve suç türünü; β değişkenlere ait esneklik katsayılarını, α model sabitini, \ln doğal logaritmayı ve ε hata terimlerini göstermektedir.

Bulgular

Dinamik panel veri analizi öncesinde, modelin geçerliliğini ve tahminlerin güvenilirliğini sağlamak amacıyla belirli ön testlerin yapılması kritik öneme sahiptir. Bu bağlamda, yatay kesit bağımlılığı, homojenlik testi ve birim kök testleri gibi ön analizlerin uygulanması gerekmektedir.

Çalışmada ilk olarak Pesaran (2004) tarafından geliştirilen Pesaran CDLM testi uygulanmıştır. Pesaran tarafından geliştirilen bu analiz hem homojen hem de heterojen panel veri setlerine uygulanabilir ve $T > N$ ya da $N > T$ durumlarında da geçerlidir (Pesaran, 2004, s.4).

Tablo 2. Pesaran CD testi sonuçları

Modeller	Pesaran Cd
Dolandırıcılık Model 1	44.154 (0.000)
Dolandırıcılık Model 2	48.126 (0.000)
Dolandırıcılık Model 3	46.363 (0.000)
Dolandırıcılık Model 4	40.920 (0.000)
Dolandırıcılık Model 5	40.099 (0.000)
Dolandırıcılık Model 6	24.010 (0.000)

Tablo 2'de görüldüğü gibi dolandırıcılık suçuna ait bütün modellerde yatay kesit bağımlılığı problemi vardır. Panel veri analizlerinde dikkate alınması gereken bir diğer önemli nokta, değişkenlerin homojen olup olmadığını belirlemektir. Homojenlik testi, serilerin durağanlığını değerlendirmek ve seriler arasında eşbütünleşmenin varlığını incelemek açısından önemlidir (Pesaran ve Yamagata, 2008). Literatürde, homojenlik ve heterojenlik konularını incelemek için kullanılan testler arasında Swamy (1970) tarafından geliştirilen "Swamy testi (S^*)" ve Pesaran ve Yamagata (2008) tarafından eğitim heterojenliğini tespit etmek amacıyla geliştirilen "Slope Homogeneity (Delta Tilde, Δ^*) testi" bulunmaktadır (Tatoğlu, 2018).

Tablo 3. Homojenite (Swamy) testi sonuçları

Modeller	Chi2	Chi2 > Prob.
Dolandırıcılık Model 1	522.65	0.0000
Dolandırıcılık Model 2	637.08	0.0000
Dolandırıcılık Model 3	725.88	0.0000
Dolandırıcılık Model 4	641.22	0.0000
Dolandırıcılık Model 5	8271.49	0.0000
Dolandırıcılık Model 6	1599.82	0.0000

Tablo 3'te görüldüğü üzere, çalışmaya dair bütün modeller için olasılık değeri 0.05'ten küçük olduğu için modellerin eşbütünleşme eğim katsayıları heterojendir. Diğer dikkat edilmesi gerek husus çalışmada kullanılan serilerin (değişkenlerin) zaman içinde durağan olup olmadığının panel birim kök testleri ile tespit edilmesidir. Modeller yatay kesit bağımlılığı söz konusu olduğu için, çalışmamızda ikinci kuşak panel birim kök testlerinden CIPS (Im-Pesaran-Shin) tercih edilmiştir. CIPS test istatistikleri, CADF test istatistiklerine dayanmaktadır. Pesaran (2007) tarafından geliştirilen CADF testi, yatay kesit bağımlılığı olan panel veri analizlerinde güvenilir sonuçlar sağlamak amacıyla kesit bazında geliştirilmiştir. Bu test, hem $T > N$ hem de $N > T$ durumlarında etkili sonuçlar verecek şekilde tasarlanmıştır (Küçükaksoy ve Akalın, 2017, s.27).

Tablo 4. CIPS panel birim kök test sonuçları

Değişkenler (ln)	Düzye Seviye		Farkı Alınmış Seriler	
	Sabit	Sabit ve Trend	Sabit	Sabit ve Trend
Dolan. Suçu	-2.366**	-2.279		
GSYİH	-2.377**	-2.230		
GSYİH2	-2.384**	-2.234		
Enflasyon	-3.126***	-3.246***		
İşsiz Sayısı	-1.895	-2.029	-2.544***	-2.353
Alt Yapı Yatırımı	-2.394**	-2.333		
Eğitim	-3.372***	-4.385***		
Aldığı Göç	-2.870***	-2.635		
Nüfus Yoğunluğu	-1.715	-2.320	-2.841***	-2.583

Not: (***) , (**) ve (*) sırasıyla %1, %5, %10 anlam düzeyinde anlamlılığı göstermektedir.

Tabloda görüldüğü üzere bağımlı değişkenimiz dolandırıcılık düzeyde durağan olup, birim kök içermemektedir. Dolandırıcılık değişkeni sadece sabit düzeyde durağandır. Bağımsız değişkenlerimizden sadece işsiz sayısı ve nüfus yoğunluğu değişkenleri düzeyde durağan değildir. Diğer değişkenlerden enflasyon ve eğitim değişkenleri hem sabit hem de trend düzeyde durağanlık göstermektedir. Kişi başına düşen GSYİH, GSYİH2, alınan göç ve yatırım değişkenleri

ise sabit düzeyde durağandır. İşsiz sayısı ve nüfus yoğunluğu değişkenleri düzeyde durağan olmayıp birim kök içermektedir. Ancak, bu iki değişkenin serilerinin farkı alındığında durağan hale gelmektedir ve farklarında sabit düzeyde durağanlık gözlemlenmektedir.

Panel ARDL analizinde, Mean Group (MG) ve Pooled Mean Group (PMG) tahmincilerinden hangisinin uygun olduğunu belirlemek amacıyla öncelikle Hausman testi yapılmaktadır. Hausman testi, bu iki yöntem arasındaki farkları değerlendirerek hangisinin model için daha tutarlı ve güvenilir sonuçlar sağladığını belirlemeye yardımcı olmaktadır. Hausman testinden önce, panel ARDL analizinde gecikme uzunluğu belirlenmektedir. Gecikme uzunlukları belirlenirken "Akaike Bilgi Kriteri" ve "Bayes Bilgi Kriteri" dikkate alınmıştır (Verbeek, 2017; Hsiao, 2014; Baltagi, 2005).

Tablo 5. Hausman test sonuçları

Dolandırıcılık	Ki Kare Değeri	Prob (Olasılık) Değeri > Chi2
Model 1 (1,0,0,0)	0.70	0.9725
Model 2 (1,0,0,0)	0.75	0.9911
Model 3 (1,1,0,0)	0.77	0.9912
Model 4 (1,0,0,0)	0.72	0.9743
Model 5 (1,0,0,0)	0.81	0.9976
Model 6 (1,1,1,1)	0.65	0.9147

Tablo 5'te yer alan Hausman analiz sonuçlarına göre grup içi tahmincisi (MG) ve havuzlanmış grup içi tahmincisi (PMG) arasında olasılık değerleri 0.05'ten büyük olduğu için PMG analizinin uygulanmasına karar verilmiştir. Panel ARDL-PMG analiz sonuçları tablo 6 ve 7'de sunulmuştur.

Tablo 6. PMG ARDL analizi sonuçları (Dolandırıcılık Suçu-Kısa Dönem (SR))

Değişkenler	(1a) PMG-SR	(1b) PMG-SR	(1c) PMG-SR	(1d) PMG-SR	(1e) PMG-SR	(1f) PMG-SR
GSYİH	-18.428 (0.526)	34.988 (0.155)	85.679** (0.012)	-37.591 (0.224)	40.159 (0.146)	-22.514 (0.570)
GSYİH2	1.2698 (0.426)	-1.8937 (0.173)	-4.826** (0.013)	2.2323 (0.195)	-2.1936 (0.160)	1.2320 (.0582)
İşsiz sayısı	-0.24981** (0.013)					
Enflasyon		-0.0073 (0.929)				
Yatırım			-0.00727 (0.585)			
Göç				-0.41338*** (0.004)		
Eğitim					-0.0962 (0.865)	
Nüfus yoğunluğu						-3.0798 (0.157)
ECT	-0.21959*** (0.000)	-0.2815*** (0.000)	-0.3725*** (0.000)	-0.3284*** (0.000)	-0.5224*** (0.000)	-0.5298*** (0.000)
Sabit Terim	-47.972*** (0.000)	-1.30666** (0.000)	4.4389*** (0.000)	-11.92067*** (0.000)	11.0710*** (0.000)	37.5758*** (0.000)

Parantez içindekiler t-istatistiklerini göstermektedir. * < 0.10, ** < 0.05, *** < 0.01

Dolandırıcılık suçunu etkileyen sosyo-ekonomik faktörleri incelemek amacıyla oluşturulan modellerden elde edilen bulgular, farklı değişkenlerin suç dinamikleri üzerindeki etkilerine ilişkin önemli sonuçlar sunmaktadır.

Model 1a sonuçlarına göre, gelir değişkenleri istatistiksel olarak anlamlı bulunmamış, ancak işsizlik değişkeni anlamlı çıkmıştır. İşsizlikteki %1'lik artışın dolandırıcılık suçlarını ortalama %0,24981 oranında azalttığı tespit edilmiştir. Bu sonuç, işsizliğin suçu artırdığı yönündeki yaygın literatür bulgularıyla çelişmektedir. İşsizliğin her zaman gelir kaybı anlamına gelmediği, kayıt dışı istihdam, işsizlik ödeneği ve sosyal yardımlar yoluyla bireylerin ekonomik sıkıntılarını kısmen hafifletebildiği dikkate alındığında, bulgunun teorik temeli güçlenmektedir. Bu yönüyle sonuç, Yıldız vd. (2013) çalışmasıyla uyumlu bir şekilde değerlendirilebilir.

Model 1b kapsamında incelenen enflasyon ve gelir değişkenleri ise anlamlı bulunmamıştır. Bu durum, fiyat istikrarsızlığının ve gelir seviyesindeki değişimlerin dolandırıcılık suçunu doğrudan etkilemediğini göstermektedir.

Model 1c sonuçları, gelir ile suç arasındaki ilişkiye dair daha kapsamlı bir tablo ortaya koymaktadır. Bulgulara göre, GSYİH'daki %1'lik artış dolandırıcılık suçlarını %85,679 oranında artırırken, GSYİH² bu etkiyi %4,826 oranında azaltmaktadır. Bu bulgu, suç ile gelir arasındaki ilişkinin doğrusal olmadığını, belli bir gelir düzeyine kadar artan refahın suçları tetikleyebileceğini, ancak gelir eşitsizliklerinin azalmasıyla birlikte suç oranlarının düşüşe geçtiğini göstermektedir. Bu sonuç, Donchev ve Ujhelyi (2014) ile Metz ve Burdina (2018) çalışmalarını desteklemektedir.

Model 1d bulguları ise göçün suç dinamikleri üzerindeki rolünü ortaya koymaktadır. Göçteki %1'lik artışın dolandırıcılık suçlarını %0,41338 oranında azalttığı tespit edilmiştir. Özellikle nitelikli göçün, işgücü piyasasına katkı sağlayarak ve toplumsal sermayeyi güçlendirerek suç oranlarını düşürme potansiyeli bulunmaktadır. Bu sonuç, Orrenius ve Zavodny (2015) ile paralellik göstermektedir.

Model 1e ve 1f kapsamında incelenen okuma-yazma bilmeyen kişi sayısı ve nüfus yoğunluğu değişkenleri anlamlı çıkmamıştır. Bu bulgu, dolandırıcılık suçunun eğitim yetersizliği ya da nüfus baskısından ziyade ekonomik ve demografik dinamiklerle daha yakından ilişkili olabileceğine işaret etmektedir.

Son olarak, tüm modellerde PARDL analiziyle elde edilen hata düzeltme teriminin (ECT) negatif ve istatistiksel olarak anlamlı bulunması, değişkenler arasında uzun dönemli bir denge ilişkisi olduğunu ortaya koymaktadır. Bu sonuç, sosyo-ekonomik faktörlerin dolandırıcılık suçunu kısa vadeli dalgalanmaların ötesinde, yapısal ve uzun vadeli bir biçimde etkilediğini göstermektedir.

Tablo 7. PMG ARDL Analizi Sonuçları (Dolandırıcılık Suçu-Uzun Dönem (ECT))

Değişkenler	(1a)	(1b)	(1c)	(1d)	(1e)	(1f)
	PMG-ECT	PMG-ECT	PMG-ECT	PMG-ECT	PMG-ECT	PMG-ECT
GSYİH	54.610*** (0.000)	2.510 (0.783)	-33.897*** (0.000)	7.6320 (0.583)	3.1937 (0.638)	-15.3648** (0.030)
GSYİH ²	-3.185*** (0.000)	-0.1761 (0.726)	1.688*** (0.000)	-0.4501 (0.557)	-0.1144 (0.763)	0.7672** (0.053)
İşsiz sayısı	-0.797*** (0.000)					
Enflasyon		0.7615*** (0.000)				
Yatırım			0.0463*** (0.008)			
Göç				1.3561*** (0.000)		
Eğitim					-3.161*** (0.000)	
Nüfus yoğunluğu						2.2464*** (0.000)
Sabit Terim	-47.972*** (0.000)	-1.30666** (0.000)	4.4389*** (0.000)	-11.92067*** (0.000)	11.0710*** (0.000)	37.5758*** (0.000)

Parantez içindekiler t-istatistiklerini göstermektedir. * < 0.10, ** < 0.05, *** < 0.01

Uzun dönem analizine göre, Model 1a'da tüm değişkenler dolandırıcılık suçu üzerinde istatistiksel olarak anlamlıdır. İşsiz sayısındaki %1'lik artış, diğer değişkenler sabitken dolandırıcılık suçlarını %0,797 oranında azaltmaktadır. Bu bulgu, işsiz bireylerin kayıt dışı istihdam, işsizlik ödemeleri ve sosyal yardımlar aracılığıyla alternatif gelir kaynaklarına erişebilmesiyle açıklanabilir. Söz konusu ek gelirler, bireylerin ekonomik sıkıntılarını hafifleterek yasa dışı faaliyetlere yönelme riskini azaltmaktadır. Bu sonuç Yıldız vd. (2013) ile uyumludur. Bununla birlikte, GSYİH'deki %1 artış dolandırıcılık suçlarını %54,610 oranında artırırken, GSYİH²'deki %1 artış bu suçu %0,797 oranında azaltmaktadır. GSYİH'nin artışı gelir eşitsizliklerini derinleştirdiğinde toplumsal gerilim ve fırsat eşitsizlikleri dolandırıcılığı tetikleyebilmektedir.

Buna karşılık, gelir dağılımının iyileşmesi suç oranlarını düşürmektedir. Bu bulgular Krahn vd. (1986) ve Oliver (2002) ile tutarlıdır.

Model 1b kapsamında yalnızca enflasyon değişkeni anlamlı bulunmuştur. Enflasyondaki %1'lik artış, dolandırıcılık suçlarını %0,7615 oranında artırmaktadır. Enflasyonun satın alma gücünü düşürmesi, bireylerin ekonomik baskı altında yasa dışı faaliyetlere yönelme riskini artırmaktadır. Bu bulgu, Ahmad (2021) ile uyumludur.

Model 1c'nin bulgularına göre, tüm değişkenlerin dolandırıcılık suçu üzerinde anlamlı etkiler yarattığını göstermektedir. Altyapı yatırımlarındaki %1'lik artış, suç oranlarını %0,0463 artırmıştır. Literatürde altyapı yatırımlarının genellikle suçları azalttığı vurgulansa da, denetim ve şeffaflık eksiklikleri dolandırıcılık riskini artırabilmektedir (Tanzi ve Daavoodi, 1998). Buna ek olarak, GSYİH'deki %1'lik artış dolandırıcılık suçlarını %33,897 oranında azaltmaktadır. Yüksek gelir düzeyleri bireylerin hukuki destek imkanlarını artırarak dolandırıcılığa maruz kalma riskini azaltabilir. Bu sonuç Cohen (2008) ile uyumludur. Ancak, GSYİH²'deki %1'lik artış dolandırıcılık suçlarını %1,688 oranında artırmaktadır. Gelir artışına paralel olarak bazı bireylerin hızlı zenginleşme ve sosyal statü kazanma amacıyla yasa dışı yollara yönelmeleri bu sonucu açıklamaktadır. Bu bulgu Baharom ve Habibullah (2009) ile benzerlik göstermektedir.

Model 1d için PARDL-ECT analiz sonuçlarına göre, dolandırıcılık suçu üzerinde istatistiksel olarak anlamlı olan tek değişkenin alınan göç olduğu tespit edilmiştir. Alınan göçteki %1'lik artış dolandırıcılık suçlarını %1,3561 oranında artırmaktadır. Yeni gelen göçmenlerin iş bulma güçlükleri ve geçim sıkıntıları, yasa dışı faaliyetlere yönelmelerine zemin hazırlayabilmektedir. Bu bulgu, Wasem (2008) çalışmasıyla uyumludur.

Model 1e'nin bulgularına göre, yalnızca okuma yazma bilmeyen kişi sayısının anlamlı olduğunu göstermektedir. Okuma yazma bilmeyenlerin sayısındaki %1'lik artış, dolandırıcılık suçlarını %3,161 oranında azaltmaktadır. Dolandırıcılık suçlarının genellikle belirli bilgi ve beceri düzeyi gerektirmesi, bu sonucu açıklamaktadır. Gordon (1971)'de benzer bir görüş ortaya koymaktadır.

Son olarak, Model 1f'nin PARDL-ECT analiz sonuçlarına göre, tüm değişkenler anlamlıdır. Nüfus yoğunluğundaki %1'lik artış, dolandırıcılık suçlarını %2,2464 oranında artırmaktadır. Kalabalık bölgelerde toplumsal bağların zayıflaması ve anonimleşme, suçların daha kolay işlenmesine neden olabilmektedir (Clinard, 1942). Buna karşılık, GSYİH'deki %1'lik artış suçları %15,3648 oranında azaltmaktadır. Gelir artışının bireylere daha iyi eğitim, iş ve yaşam koşulları sağlaması suça yönelimi azaltmaktadır (Irmak, 2012). Ancak, GSYİH²'deki %1'lik artış dolandırıcılık suçlarını %0,7672 oranında artırmaktadır. Gelir artışının ekonomik ortamı karmaşıkleştirmesi, dolandırıcılar için yeni fırsatlar yaratabilmektedir. Bu bulgu Pare (2006) ile tutarlıdır.

Sonuç ve öneriler

Dolandırıcılık suçunu etkileyen sosyo-ekonomik faktörlerin analizi, çeşitli değişkenlerin suç oranları üzerinde önemli etkiler yarattığını ortaya koymaktadır. İşsizlik, enflasyon, altyapı yatırımları, göç, okuma yazma bilmeyen kişi sayısı ve nüfus yoğunluğu gibi faktörler dolandırıcılık suçlarını farklı şekillerde etkilemektedir. Kısa dönem PARDL analizleri, dolandırıcılık suçunun bazı sosyo-ekonomik değişkenlerden hızlı ve doğrudan etkilendiğini göstermektedir. Öne çıkan bulgular şunlardır:

- İşsizlik: Kısa dönemde işsizlik artışı dolandırıcılık suçlarını azaltmaktadır. Bu durum, işsiz bireylerin kayıt dışı istihdam, sosyal yardımlar veya işsizlik ödemeleri gibi alternatif gelir kaynaklarına erişebilmesiyle açıklanabilir.
- Enflasyon: Enflasyondaki artış, bireylerin maddi baskı altında yasa dışı yollarla gelir elde etme riskini yükseltmektedir.
- Gelir ve Gelirin Karesi (GSYİH ve GSYİH²): Gelir artışları kısa dönemde suç oranlarını hem artırabilir hem de azaltabilir; bu, gelir dağılımı eşitsizliği ve toplumsal fırsat farklılıkları ile ilgilidir.

- Göç: Kısa dönemde göç artışı, dolandırıcılık suç oranlarını artırmaktadır; bu durum özellikle göçmenlerin iş bulma güçlükleri ve yeni toplumla kurdukları toplumsal bağların zayıf olmasıyla açıklanabilir.

Kısa dönem bulguları, ekonomik ve sosyal şokların dolandırıcılık üzerinde hızlı etkileri olabileceğini göstermektedir; ancak bu etkiler genellikle geçici ve değişkenlik gösterebilir. Uzun dönem analizleri, dolandırıcılık suçuyla sosyo-ekonomik değişkenler arasında istikrarlı ve kalıcı ilişkiler olduğunu ortaya koymaktadır:

- İşsizlik ve Alternatif Gelir Kaynakları: Uzun dönemde işsizlik artışı, kayıt dışı istihdam ve sosyal yardımlar sayesinde dolandırıcılığı azaltmaktadır. Bu, kısa dönem bulgularıyla tutarlıdır ve işsizliğin otomatik olarak suçu artırmadığını göstermektedir.
- Gelir ve Gelirin Karesi (GSYİH ve GSYİH²): Gelir artışı, eşitsiz dağıldığında dolandırıcılığı artırabilirken, gelir karesi ile ölçülen yüksek refah düzeyi ve azalan eşitsizlik, suçu azaltmaktadır. Bu bulgu, gelir düzeyinin suç üzerindeki ikili etkisini ortaya koymaktadır.
- Enflasyon: Yüksek enflasyon uzun dönemde de dolandırıcılık riskini artırmaktadır; bireylerin ekonomik baskıya uzun süre maruz kalması, yasa dışı gelir elde etme eğilimini güçlendirebilir.
- Altyapı Yatırımları: Yetersiz denetim ve şeffaflık nedeniyle altyapı yatırımlarının dolandırıcılığı artırıcı etkisi gözlemlenmiştir.
- Göç ve Nüfus Yoğunluğu: Göç ve yoğun nüfus, uzun dönemde de toplumsal bağları zayıflatmakta ve suç riskini yükseltmektedir.
- Okuryazarlık: Okuryazarlığın düşük olması dolandırıcılığı azaltmaktadır; suçun bilgi ve beceri gerektirmesi nedeniyle eğitim eksikliği suç işleme kapasitesini sınırlandırmaktadır.

Bu bulgular, dolandırıcılık suçlarının sosyo-ekonomik faktörlerden nasıl etkilendiğine dair kapsamlı bir anlayış sağlamakta ve suç öncesi ve sonrası stratejilerin geliştirilmesinde temel bilgiler sunmaktadır. Ekonomik ve sosyal politikaların, suç oranlarını etkileyen bu faktörleri dikkate alarak tasarlanması, suçların azaltılmasına yönelik etkili çözümler geliştirilmesine katkıda bulunabilir. Bu konuda öneriler;

1. İşsizlik ve Ekonomik Destek: Analiz sonuçlarına göre, işsizlik oranlarındaki artış dolandırıcılık suçlarını azaltmaktadır. Bu durum, işsiz bireylerin kayıt dışı istihdam, işsizlik sigortası ve sosyal yardımlar gibi alternatif gelir kaynaklarına yönelerek yasa dışı faaliyetlere başvurma riskinin düştüğünü göstermektedir. Bu çerçevede, işsizlik sigortası ve sosyal yardım programlarının kapsamının genişletilmesi ve etkinliğinin artırılması önemlidir. Böylece, ekonomik zorluk yaşayan bireyler için yasal gelir kaynakları güçlendirilerek dolandırıcılık gibi suçlara yönelme ihtimali daha da azaltılabilir. Ayrıca, gelir dağılımı eşitsizliğinin uzun vadede suç oranları üzerindeki etkisini göz önünde bulundurarak, ekonomik büyümenin toplumun tüm kesimlerine daha adil şekilde yayılmasını sağlayacak politikalar geliştirilmelidir.
2. Enflasyon Yönetimi: Enflasyonu kontrol altına alacak ekonomik politikalar uygulanmalıdır. Bu, bireylerin satın alma gücünü koruyarak dolandırıcılık suçlarına eğilimlerini azaltabilir.
3. Şeffaflık ve Denetim: Altyapı projelerinde şeffaflık ve etkili denetim mekanizmaları oluşturulmalıdır. Projelerin hesap verebilir şekilde yönetilmesi, dolandırıcılık risklerini azaltabilir.
4. Göçmen Destek Programları: Göçmenlere yönelik iş bulma ve entegrasyon programları geliştirilmelidir. İş bulma zorluklarını aşmalarına yardımcı olarak dolandırıcılık suçlarına yönelmelerini engelleyebilir.
5. Eğitim ve Bilinçlendirme: Okuma yazma bilmeyen bireyler için eğitim programları sunulmalıdır. Eğitim, suç tekniklerini öğrenme ve uygulama kapasitesini artırarak dolandırıcılık suçlarını azaltabilir.

6. Nüfus Yoğunluğu Yönetimi: Nüfus yoğunluğunun yüksek olduğu bölgelerde toplumsal bağları güçlendirecek ve komşuluk ilişkilerini artıracak sosyal programlar uygulanmalıdır. Bu, suçların fark edilmeden işlenmesini zorlaştırabilir.

Bu öneriler, dolandırıcılık suçlarını azaltmaya yönelik etkili stratejiler geliştirilmesine yardımcı olabilir. Analiz sonuçları ve literatür bulguları dikkate alınarak, çeşitli sosyal ve ekonomik politikaların uygulanması önem arz etmektedir.

Çıkar çatışması beyanı

Çıkar çatışması

"Türkiye'de dolandırıcılık suçunu etkileyen sosyo-ekonomik faktörlerin panel ARDL analizi ile incelenmesi" başlıklı makalemizin herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur. Yazarlar arasında da herhangi bir çıkar çatışması bulunmamaktadır.

Finansman

Bu araştırma için dış finansman desteği alınmamıştır.

Yazar katkıları (CRediT)

Yazar 1 (Ufuk IŞIK): Kavramsallaştırma; Yöntem; Araştırma/İnceleme; Veri düzenleme ve analizi; Özgün taslak yazımı; Yazım gözden geçirme ve düzenleme; Görselleştirme.

Yazar 2 (Selahattin KAYNAK): Kavramsallaştırma; Yöntem; Doğrulama; Denetim; Yazım—gözden geçirme ve düzenleme.

Tüm yazarlar makalenin yayımlanan son hâlini okumuş ve onaylamıştır.

Veri erişilebilirliği

Veriler, makul talep üzerine sorumlu yazardan temin edilebilir.

Etik kurul onayı ve katılımcı onamı

Bu çalışmada etik kurul onayı gerekmemektedir.

Yapay zekâ (YZ) araçlarının kullanımı

Bu makalede yalnızca makalenin dil düzenleme sürecinde yapay zeka destekli araçlar kullanılmıştır. Makalede bunun dışında herhangi bir bölümde yapay zeka destekli araçlar kullanılmamıştır.

Kaynakça

- Ahmad, B., Ciupac-Ulici, M., & Beju, D. G. (2021). Economic and non-economic variables affecting fraud in European countries. *Risks*, 9(6), 119. <https://doi.org/10.3390/risks9060119>
- Artuç, M. (2007). *Malvarlığına karşı suçlar*. Kartal Yayınevi.
- Baltagi, B. H. (2008). *Econometric analysis of panel data* (4th ed.). Wiley.
- Clinard, M. B. (1942). The process of urbanization and criminal behavior. *American Journal of Sociology*, 48(2), 202–213.
- Donchev, D., & Ujhelyi, G. (2014). What do corruption indices measure? *Economics & Politics*, 26(2), 309–331. <https://doi.org/10.1111/ecpo.12037>
- Dündar, Ö., & Kesbiç, C. Y. (2019). Türkiye'de malvarlığına karşı işlenen suçların mekânsal bağımlılığı. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 19(2), 171–188. <https://doi.org/10.18037/ausbd.566788>
- Gillani, S., Khan, R. E. A., & Rashid Gill, A. (2011). Unemployment and property crimes in Pakistan. *Asian Economic and Financial Review*, 1(3), 124–133.
- Gordon, D. M. (1971). *Problems in political economy: An urban perspective*. Heath.

- Hsiao, C. (2007). Panel data analysis—Advantages and challenges. *TEST*, 16(1), 1–22. <https://doi.org/10.1007/s11749-007-0046-x>
- Hsiao, C. (2022). *Analysis of panel data* (3rd ed.). Cambridge University Press.
- Irmak, F. (2012). Can social capital explain the property crimes in Turkey? *Polis Bilimleri Dergisi*, 14(4), 133–148.
- Janko, Z., & Popli, G. (2015). Examining the link between crime and unemployment: A time-series analysis for Canada. *Applied Economics*, 47(37), 4007–4019. <https://doi.org/10.1080/00036846.2015.1023942>
- Krahn, H., Hartnagel, T. F., & Gartrell, J. W. (1986). Income inequality and homicide rates: Cross-national data and criminological theories. *Criminology*, 24(2), 269–294. <https://doi.org/10.1111/j.1745-9125.1986.tb01496.x>
- Küçükaksoy, İ., & Akalın, G. (2017). Fisher hipotezinin panel veri analizi ile test edilmesi: OECD ülkeleri uygulamaları. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 35(1), 19–40. <https://doi.org/10.17065/huniibf.303303>
- Lastauskas, P., & Tatsi, E. (2013). Spatial nexus in crime and unemployment in times of crisis: Evidence from Germany (Cambridge Working Papers in Economics, Working Paper). University of Cambridge. <https://doi.org/10.17863/CAM.5685>
- Metz, N., & Burdina, M. (2018). Neighbourhood income inequality and property crime. *Urban Studies*, 55(1), 133–150. <https://doi.org/10.1177/0042098016643914>
- Odabaşı, S. (2022). Türkiye’de suç ve iktisadi belirleyicileri: Panel veri analizi. *İzmir İktisat Dergisi*, 37(3), 586–606. <https://doi.org/10.24988/ije.1013433>
- Oliver, A. (2002). The economics of crime: An analysis of crime rates in America. *The Park Place Economist*, 10(1), 30–35.
- Orrenius, P., & Zavodny, M. (2015). Undocumented immigration and human trafficking. In B. R. Chiswick & P. W. Miller (Eds.), *Handbook of the economics of international migration* (Vol. 1, pp. 659–716). Elsevier. <https://doi.org/10.1016/B978-0-444-53764-5.00013-X>
- Paré, P.-P. (2006). *Income inequality and crime across nations reexamined* (Doctoral dissertation, The Pennsylvania State University). <https://etda.libraries.psu.edu/catalog/7184>
- Pesaran, M. H. (2006). A simple panel unit root test in the presence of cross-section dependence (Working paper). University of Cambridge. <https://doi.org/10.1002/jae.951>
- Pesaran, M. H., Ullah, A., & Yamagata, T. (2008). A bias-adjusted LM test of error cross-section independence. *The Econometrics Journal*, 11(1), 105–127. <https://doi.org/10.1111/j.1368-423X.2007.00227.x>
- Shahid, M., Ahmad, K., Inayat, M. A., & Bhatti, M. K. (2024). Socio-economic determinants of property crime across the districts of Punjab: Highlighting the role of law enforcement agencies of Pakistan. *Bulletin of Business and Economics*, 13(2), 22–36. <https://doi.org/10.61506/01.00289>
- Sirohi, N., & Misra, G. (2024). Vulnerability of individuals to economic crime and the role of financial literacy in its prevention: Evidence from India. *Crime, Law and Social Change*, 1–32. <https://doi.org/10.1007/s10611-024-10138-w>
- Tatoğlu, F. Y. (2018). *İleri panel veri analizi: Stata uygulamalı*. Beta Yayıncılık.
- Topaloğlu, E. E., & Bayrakdaroğlu, A. (2024). Entelektüel sermaye ve finansal performans: Bankacılık sektörü üzerine bir araştırma. *Bulletin of Economic Theory and Analysis*, 9(1), 297–327. <https://doi.org/10.25229/beta.1407187>
- Verbeek, M. (2017). *A guide to modern econometrics* (5th ed.). Wiley.
- Yildiz, R., Ocal, O., & Yildirim, E. (2013). The effects of unemployment, income and education on crime: Evidence from individual data. *Journal of Economic & Management Perspectives*, 7(2), 32.