

## **Araştırma Makalesi**

### **Analysis of Causality Between Bitcoin and Ethereum Using Transfer Entropy**

*Bitcoin ile Ethereum Arasındaki Nedenselliğin Transfer Entropisi ile Analizi*

|  |   |
|--|---|
| <b>Baki ÜNAL</b><br>Dr. Öğr. Üyesi, İskenderun Teknik Üniversitesi<br>Mühendislik ve Doğa Bilimleri Fakültesi<br>Endüstri Mühendisliği Bölümü<br><a href="mailto:baki.unal@iste.edu.tr">baki.unal@iste.edu.tr</a><br><a href="https://orcid.org/0000-0001-9154-0931">https://orcid.org/0000-0001-9154-0931</a> | <b>Abdulla SAKALLI</b><br>Doç Dr., İskenderun Teknik Üniversitesi<br>Mühendislik ve Doğa Bilimleri Fakültesi<br>Endüstri Mühendisliği Bölümü<br><a href="mailto:abdulla.sakalli@iste.edu.tr">abdulla.sakalli@iste.edu.tr</a><br><a href="https://orcid.org/0000-0002-2488-7318">https://orcid.org/0000-0002-2488-7318</a> |
|--|---|

| <b>Makale Geliş Tarihi</b> | <b>Makale Kabul Tarihi</b> |
|----------------------------|----------------------------|
| <b>30.01.2022</b>          | <b>14.04.2022</b>          |

#### ***Abstract***

In the literature causality and information flow between time series are investigated. To analyze this relationship several causality tests are proposed. Mostly used causality tests are Granger, Toda-Yamamoto and Hatemi-J causality tests. These tests indicate whether there is causality and the direction of causality but do not measure the strength of causality. A new and information theory-based method transfer entropy can be used to analyze causality and information flow between time series. Unlike Granger, Toda-Yamamoto and Hatemi-J causality tests transfer entropy can detect nonlinear relationships between time series. Cryptocurrencies have gained significant importance in recent years. The most popular cryptocurrencies are Bitcoin and Ethereum. Demonstrating information flow and causality between these two cryptocurrencies are valuable for the investors. In this study we analyzed causality and information flow between Bitcoin and Ethereum by using transfer entropy method. We adopted a sliding window approach to demonstrate how transfer entropy between these two cryptocurrencies change through time. We used different window lengths to demonstrate whether obtained results are robust. In the analysis two datasets are used. These are daily and hourly data. In hourly data a significant causality is detected. However, in the daily data no evidence for causality is found.

**Keywords:** Transfer Entropy, Causality, Information Flow, Cryptocurrencies, Bitcoin

**JEL Codes:** G00, G10, G15

#### ***Öz***

Zaman serileri arasındaki nedenselliğin ve bilgi akışının analizi literatürde önemli bir araştırma konusudur. Bu tür ilişkileri analiz etmek için çeşitli nedensellik testleri önerilmiştir. Bu bağlamda en çok kullanılan nedensellik testleri Granger, Toda-Yamamoto ve Hatemi-J nedensellik testleridir. Bu testler bir nedenselliğin olup olmadığını ve nedenselliğin yönünü ortaya koymakta ancak nedenselliğin derecesini ölçmemektedir. Yeni ve bilgi teorisi tabanlı bir yöntem olan transfer entropisi zaman serileri arasındaki nedenselliğin ve bilgi akışının analizinde kullanılabilmektedir. Granger, Toda-Yamamoto ve Hatemi-J nedensellik testlerinin aksine transfer entropisi zaman serileri arasındaki doğrusal olmayan ilişkileri tespit edebilmektedir. Kripto paralar son yıllarda büyük önem kazanmıştır. En popüler kripto paralar arasında Bitcoin ve Ethereum bulunmaktadır. Bu iki kripto para birimi arasındaki bilgi akışının ve nedenselliğin gösterilmesi yatırımcılar için değerlidir. Bu çalışmada transfer entropisi yöntemini kullanılarak Bitcoin ve Ethereum arasındaki nedensellik ve bilgi akışı analiz edilmiştir. Bu iki kripto para birimi arasındaki transfer entropisinin zaman içinde nasıl değiştiğini göstermek için kayan bir pencere yaklaşımı kullanılmıştır. Elde edilen sonuçların sağlam olup olmadığını göstermek için farklı pencere uzunlukları ele alınmıştır. Çalışmada günlük ve saatlik olmak üzere iki veri seti kullanılmıştır. Saatlik veride belirgin bir nedensellik tespit edilmiş iken günlük veride herhangi bir nedensellik bulunamamıştır.

#### **Önerilen Atıf /Suggested Citation**

Ünal, B., Sakallı, A. 2022 Analysis of Causality Between Bitcoin and Ethereum Using Transfer Entropy, Üçüncü Sektor Sosyal Ekonomi Dergisi, 57(2), 803-815

**Anahtar Kelimeler:** Transfer Entropisi, Nedensellik, Bilgi Akışı, Kripto Paralar, Bitcoin

**JEL Kodları:** G00, G10, G15

## 1. Introduction

It is useful for both investors and policy makers to know whether there are cause-effect relationships between economic and financial time series. The dominant method used in the literature to reveal these relationships is the Granger causality (Granger, 1969). Although Granger causality reveals the existence and direction of causality, it does not measure the strength of causality. Different causality tests have also been proposed in the literature. Examples of these are the Toda-Yamamoto and Hatemi-J causality tests (Toda and Yamamoto, 1995; Hatemi-J, 2012). However, since all these tests are based on linear models, they cannot detect non-linear causality relationships. In the literature, interactions between time series are also discussed with correlation functions. However, these functions have two disadvantages. First, correlation functions reveal only linear relationships. Secondly, correlation functions do not show cause and effect relationship. Transfer entropy, a new method, can show the direction of causality between two time series and measure its strength numerically (Schreiber, 2000).

Within our study, the main aims were to determine whether there is a causality between Bitcoin and Ethereum, to reveal how causality between Bitcoin and Ethereum change through time and to demonstrate what statistical properties the causality possess.

## 2. Literature Review

In the literature, transfer entropy has been applied to economic and financial time series. Marschinski and Kantz (2002) investigated the information flow between Dow Jones and DAX stock indices between May 2000 and June 2001 by using transfer entropy and found a significant flow of information between these two indices. They showed that the Dow Jones index had a relatively larger effect on the German DAX index. Using transfer entropy, Dimpfl and Peter (2013) analyzed the information flow between the bond market and the CDS market for 27 iTraxx companies between 1 January 2004 and 31 December 2011, and analyzed the timing of the information transfer between the CDS market and the bond market. They showed that the CDS market gained importance during the crisis period. Jizba et al. (2012) applied transfer entropy to two datasets. The first dataset consists of 11 stock market indices and includes daily data from 2 January 1998 to 31 December 2009. The second dataset includes the DAX and S&P500 indices and consists of one minute high frequency data from 2 April 2008 to 11 September 2009. The authors revealed that there is a flow of information from the Asia-Pacific region to the United States (USA) and European countries. The information flow between the DAX and S&P500 indices also confirms this result. Dimpfl and Peter (2014) applied transfer entropy to S&P 500, DAX, CAC40 and FTSE indices. In this context, the authors considered one-minute data for the S&P 500 and DAX between 1 July 2003 and 30 April 2010, and for the CAC40 and FTSE between 1 July 2006 and 30 April 2010. The authors found that at the time of the 2008 financial crisis, the flow of information between the two sides of the Atlantic increased dramatically. García-Medina and Hernández (2020) examined the effect of the financial turbulence experienced in 2020 on the crypto money market using transfer entropy and found that the information flow in the crypto money market increased during this turbulence. Osei and Adam (2020) analyzed the information flow between the Ghana stock market index and its components between 2 January 2009 and 16 February 2018, using transfer entropy. Yao and Li (2020) analyzed the information flow between economic policy uncertainty, investor sentiment and stock market using transfer entropy. The authors revealed that economic policy uncertainty affects investor sentiment and stock price fluctuations have a significant effect on investor sentiment.

## 3. Methodology

The amount of information in a variable is measured by Shannon entropy (Shannon, 1948). The Shannon entropy is expressed by the formula (1).

$$H_J = - \sum_j p(j) \cdot \log(p(j)) \quad (1)$$

In the formula (1),  $J$  is a discrete random variable,  $p(j)$  is the distribution of this random variable,  $j$  is the possible outcomes of this random variable, and the logarithm is at log base two. Shannon entropy

simply measures the number of bits required to encode the outputs of a random variable. The concepts of Shannon entropy and Kullback-Leibler distance are combined to measure the information flow between two time series (Kullback and Leibler, 1951). It is also assumed that the evolution of each time series is governed by a Markov process (Schreiber, 2000).

Suppose two discrete random variables are expressed as  $I$  and  $J$ , their marginal distributions as  $p(i)$  and  $p(j)$ , and their joint distributions as  $p(i,j)$ . Also, let processes  $I$  and  $J$  be stationary Markov processes with degrees  $k$  and  $l$ , respectively. In this case, according to the Markov property, the probability of observing the state  $i$  at time  $t + 1$  depends on the previous  $k$  observations. This can be expressed as  $p(i_{t+1}|i_t, \dots, i_{t-k+1})$ . In this case, given the previous  $k$  values, the average number of bits required to encode the output at time  $t + 1$  is expressed by the formula (2).

$$h_I(k) = - \sum_i p(i_{t+1}, i_t^{(k)}) \cdot \log(p(i_{t+1}|i_t^{(k)})) \quad (2)$$

In formula (2)  $i_t^{(k)} = (i_t, \dots, i_{t-k+1})$ . Therefore, the flow of information from process  $J$  to process  $I$  is measured by the Shannon transfer entropy, which is expressed in formula (3):

$$T_{J \rightarrow I}(k, l) = \sum_{i,j} p(i_{t+1}, i_t^{(k)}, j_t^{(l)}) \cdot \log\left(\frac{p(i_{t+1}|i_t^{(k)}, j_t^{(l)})}{p(i_{t+1}|i_t^{(k)})}\right) \quad (3)$$

However, due to the small sample effect, the transfer entropy estimates given in (3) is biased. In order to overcome this problem, the concept of effective transfer entropy has been proposed (Marschinski and Kantz, 2002). In this method, the time series  $J$  is shuffled and the transfer entropy is calculated from this shuffled time series. This shuffled version of transfer entropy is then subtracted from the regular transfer entropy to obtain the effective transfer entropy. This process can be expressed by the formula (4).

$$ET_{J \rightarrow I}(k, l) = T_{J \rightarrow I}(k, l) - T_{J_{shuffled} \rightarrow I}(k, l) \quad (4)$$

In the formula (4),  $ET_{J \rightarrow I}(k, l)$  represents the effective transfer entropy, and  $T_{J_{shuffled} \rightarrow I}(k, l)$  represents the transfer entropy obtained from the shuffled  $J$ . At the end of this process, the dependencies in  $J$  and between  $I$  and  $J$  disappear. When the sample size is increased,  $T_{J_{shuffled} \rightarrow I}(k, l)$  converges to zero, so  $T_{J_{shuffled} \rightarrow I}(k, l)$  reflects the effect of small sample.

To evaluate the statistical significance of transfer entropy, Dimpfl and Peter (2013) proposed a Markov block bootstrap procedure. Contrary to shuffling, this procedure preserves dependencies in the time series. Under the null hypothesis that there is no information flow, this procedure produces the distribution of the transfer entropy and the related p-values.

In order to calculate the Shannon transfer entropy, the data must be discrete. If the data is not discrete, the it must be discretized. This discretization is accomplished by a method called symbolic recoding. In this method, the data is partitioned into several bins. This partitioning is accomplished by choosing the upper and lower bounds of the partitions or by determining the quantiles of the distribution of the data. If there are  $n$  bins and the boundaries of these partitions are selected as  $q_1, q_2, \dots, q_n$  ( $q_1 < q_2 < \dots < q_n$ ), the time series  $y_t$  can be discretized with a symbolic recoding procedure as follows:

$$S_t = \begin{cases} 1 & \text{for } y_t \leq q_1 \\ 2 & \text{for } q_1 < y_t \leq q_2 \\ \vdots & \\ n-1 & \text{for } q_{n-1} < y_t \leq q_n \\ n & \text{for } y_t \geq q_n \end{cases} \quad (5)$$

As a result of this method, values from 1 to  $n$  are assigned to each value of the time series.

#### 4. Application and Findings

In this work information flow between cryptocurrencies Bitcoin and Ethereum is analyzed with transfer entropy. In this analysis two datasets are used. These are daily and hourly prices between 17-08-2017 and 05-10-2021. Data are taken from the cryptocurrency market Binance. In the symbolic recoding procedure, the time series were divided into three partitions. In this partitioning, the boundaries are determined as 5% and 95% quantiles. The bootstrap iteration number used in calculation of the p-values and percentiles was selected as 300. The number of shuffles used in the calculation of the effective transfer entropy was determined as 100.

For transfer entropy to be applicable, the time series must be stationary. In order to make the time series stationary, the first difference of the logarithms of the time series is taken. By applying Augmented Dickey-Fuller (ADF) Test to the differenced time series stationarity of the series are verified. The results of the ADF tests are presented in Table 1.

**Table 1. ADF Test Results for First Difference Data**

| <b>First Difference Data</b> | <b>ADF Test Statistic</b> | <b>P-Value</b> |
|------------------------------|---------------------------|----------------|
| Daily Bitcoin Data           | -10.646                   | Less than 0.01 |
| Daily Ethereum Data          | -11.015                   | Less than 0.01 |
| Hourly Bitcoin Data          | -35.016                   | Less than 0.01 |
| Hourly Ethereum Data         | -34.669                   | Less than 0.01 |

In the first stage of our analysis, transfer entropy and effective transfer entropy were calculated for the whole sample covering the period between 17-08-2017 and 05-10-2021. The results of analysis were presented in Table 2 and Table 3 for daily and hourly data respectively. As seen from Table 2 transfer entropy which corresponds information flow from Bitcoin to Ethereum is calculated as 0.0027 and transfer entropy which corresponds information flow from Ethereum to Bitcoin is calculated as 0.0068. However, p-values for these transfer entropy calculations are greater than 0.05. Therefore, these information flows are not statistically significant. Transfer entropy results for hourly data is presented in Table 3. Unlike daily data, in hourly data there is a significant information flow between Bitcoin and Ethereum. This result is reflected by p-values in Table 3. As seen on Table 3, p-values are smaller than 0.05.

**Table 2. Shannon Transfer Entropy Results for Daily Data**

| <b>Direction</b> | <b>Transfer Entropy</b> | <b>Effective Transfer Entropy</b> | <b>Standard Error</b> | <b>P-Value</b> |
|------------------|-------------------------|-----------------------------------|-----------------------|----------------|
| BTC → ETH        | 0.0027                  | 0.0000                            | 0.0021                | 0.9033         |
| ETH → BTC        | 0.0068                  | 0.0019                            | 0.0021                | 0.2200         |

**Table 3. Shannon Transfer Entropy Results for Hourly Data**

| <b>Direction</b> | <b>Transfer Entropy</b> | <b>Effective Transfer Entropy</b> | <b>Standard Error</b> | <b>P-Value</b> |
|------------------|-------------------------|-----------------------------------|-----------------------|----------------|
| BTC → ETH        | 0.0025                  | 0.0022                            | 0.0001                | 0.0000         |
| ETH → BTC        | 0.0028                  | 0.0026                            | 0.0001                | 0.0000         |

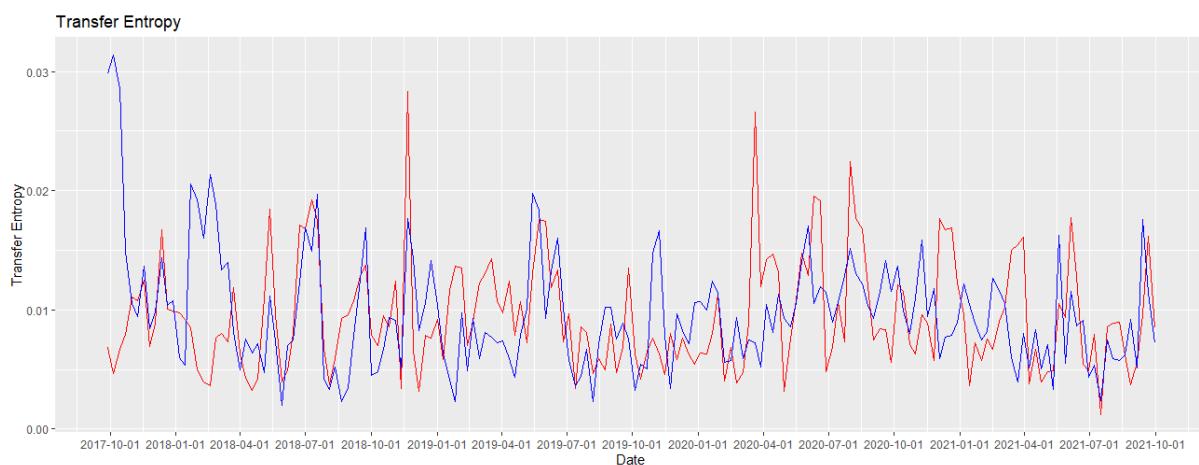
Since we found a significant information flow in hourly data we focused on this data and investigated how information flow between Bitcoin and Ethereum change through time by utilizing sliding window approach. For this purpose, three different window sizes such as 1000, 800 and 600 observations are considered. Also, window step size was selected as 200 observations. The results are depicted in Figure 1-3 for window sizes 1000, 800 and 600 respectively. In these figures red lines denote information flow from Bitcoin to Ethereum and blue lines denotes information flow from Ethereum to Bitcoin. As seen

from these figures there is no dominant pattern in the information flows. In addition to information flow between Bitcoin and Ethereum we also investigated how net information flow change through time. Net information flow is obtained by subtracting information flow from Ethereum to Bitcoin from information flow from Bitcoin to Ethereum. Obtained net information graphs for different window sizes are presented in Figure 4-6. In these figures positive values denotes there is a net information flow from Bitcoin to Ethereum and negative values denotes there is a net information flow from Ethereum to Bitcoin. Again, from these figures no dominant pattern is seen.

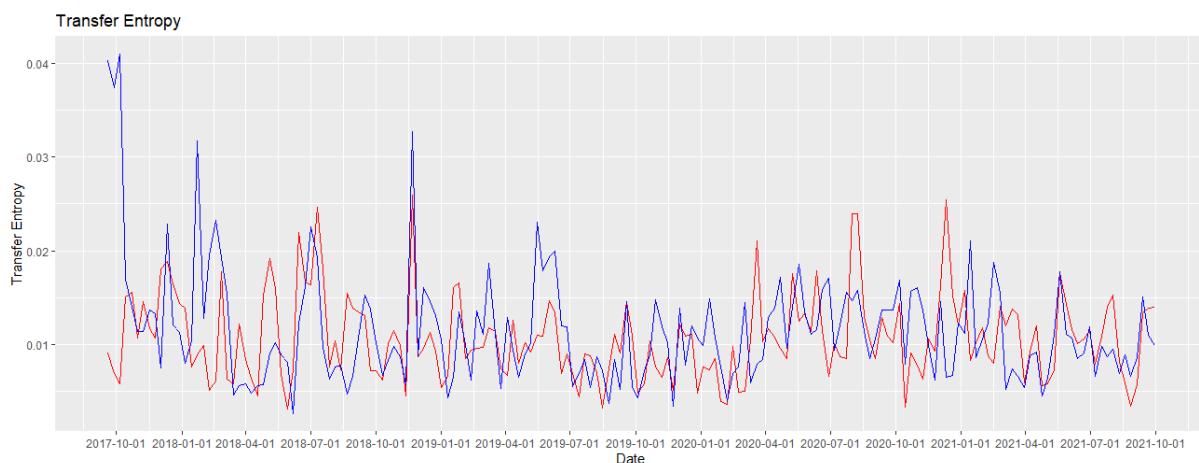
Since the data appears to be random in Figure 1-6, in the next stage of our analysis we investigated whether obtained transfer entropy data are normally distributed or not. For this purpose, we applied Shapiro-Wilk normality test to these data. The results are presented in Table 4. Since all p-values in Table 4 are less than 0.05, we could not say that the transfer entropy data are normally distributed.

We also visually investigated the distribution of the transfer entropy data by using histograms. Obtained histograms for different window lengths are presented in Figure 7-9. As seen from Figure 7 and Figure 8 transfer entropy data are right skewed for all window lengths and directions. However, from Figure 9 it is seen that net transfer entropy data are left skewed for all window lengths.

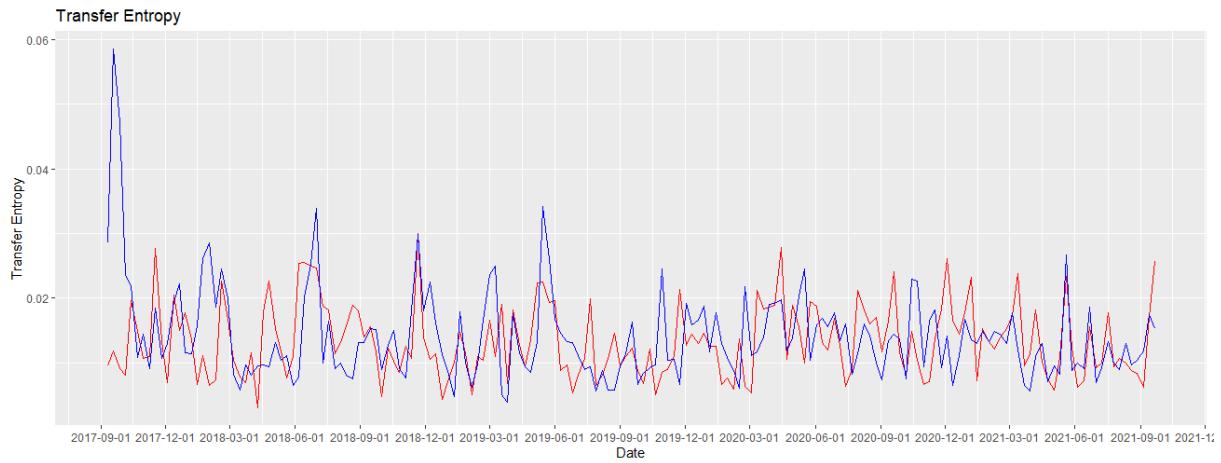
Finally, we investigated statistical dependence and serial autocorrelation in our transfer entropy data by using Ljung–Box test. Null hypothesis of this test is that the data are independently distributed. Resulting p-values of Ljung–Box tests for different window sizes are presented at the Table 8. As seen from the Table 8 all p-values are smaller than 0.05. Therefore, we strongly reject independence and can assume autocorrelation in all transfer entropy data.



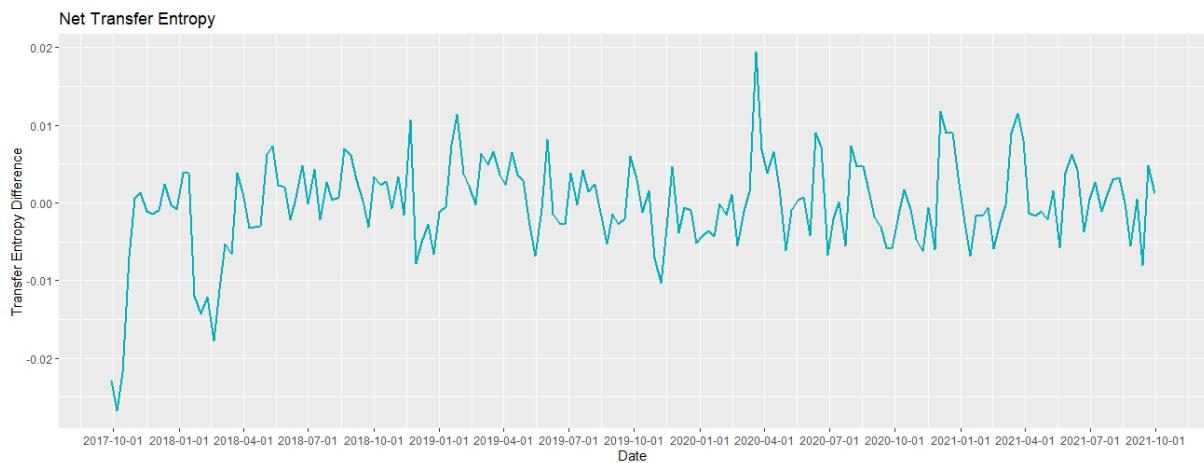
**Figure 1. Information Flow Between Bitcoin and Ethereum with Window Size 1000**



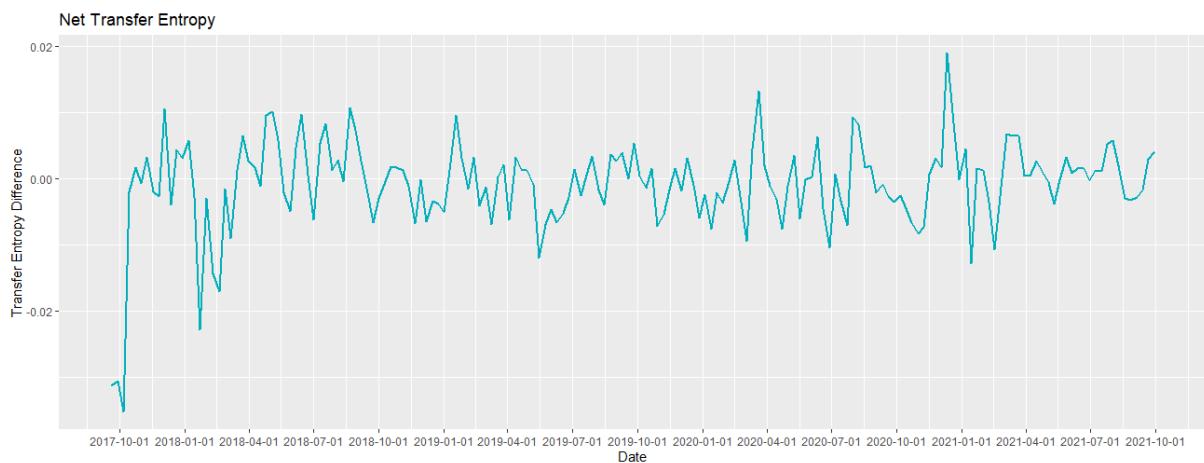
**Figure 2. Information Flow Between Bitcoin and Ethereum with Window Size 800**



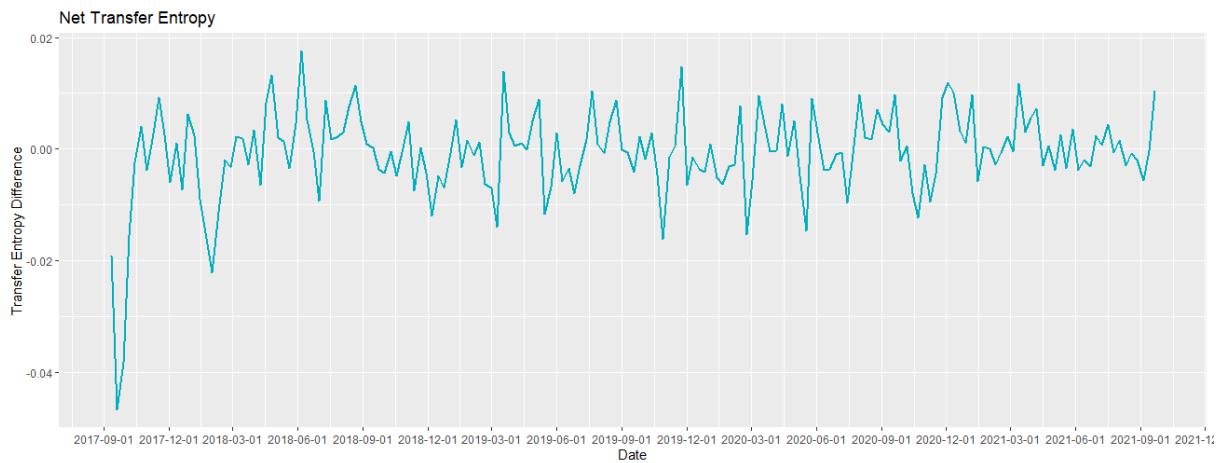
**Figure 3. Information Flow Between Bitcoin and Ethereum with Window Size 600**



**Figure 4. Net information flow from Bitcoin to Ethereum for window size 1000**



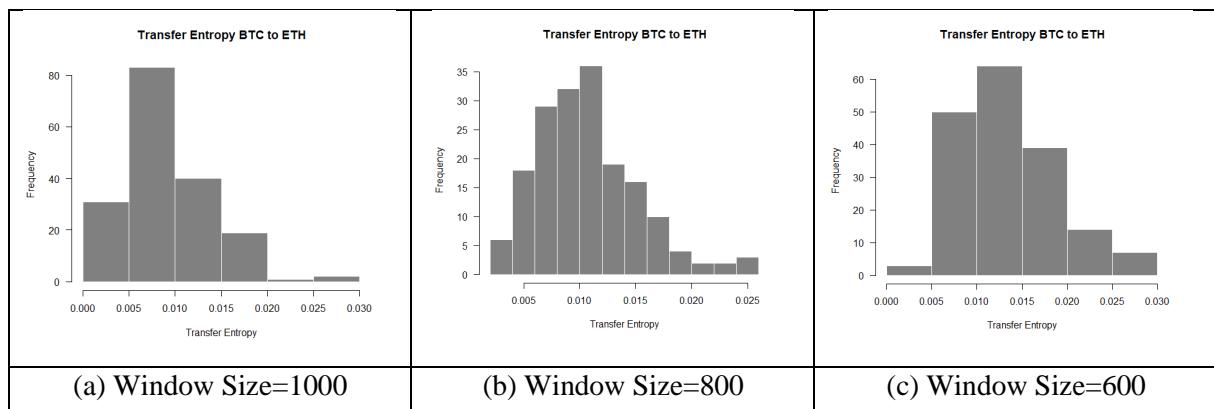
**Figure 5. Net information flow from Bitcoin to Ethereum for window size 800**



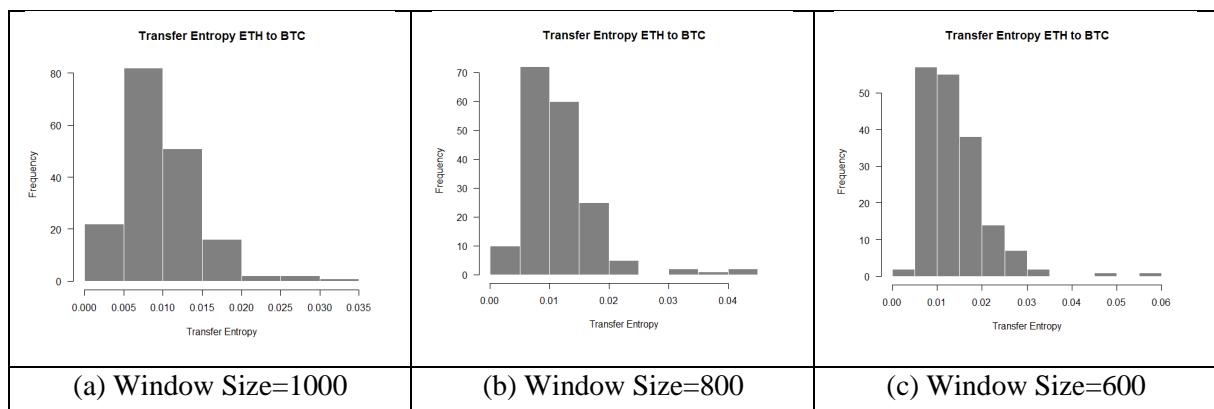
**Figure 6. Net information flow from Bitcoin to Ethereum for window size 600**

**Table 4. Shapiro-Wilk Normality Test P-Values**

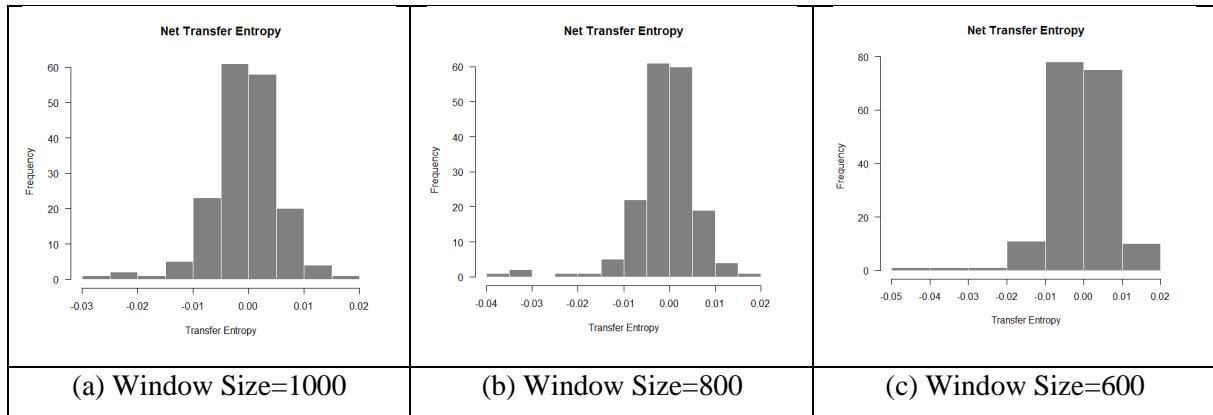
| Window Length | From Bitcoin to Ethereum | From Ethereum to Bitcoin | Net (From Bitcoin to Ethereum) |
|---------------|--------------------------|--------------------------|--------------------------------|
| 1000          | 8.937e-08                | 3.684e-09                | 7.351e-07                      |
| 800           | 2.855e-06                | 4.924e-13                | 3.64e-11                       |
| 600           | 5.503e-05                | 4.782e-13                | 3.395e-10                      |



**Figure 7. Histogram of Transfer Entropy from Bitcoin to Ethereum**



**Figure 8. Histogram of Transfer Entropy from Ethereum to Bitcoin**

**Figure 9. Histogram of Net Transfer Entropy from Bitcoin to Ethereum****Table 5. Ljung–Box Test P-Values for Independence**

| Window Length | From Bitcoin to Ethereum | From Ethereum to Bitcoin | Net (From Bitcoin to Ethereum) |
|---------------|--------------------------|--------------------------|--------------------------------|
| 1000          | 2.25e-06                 | 6.708e-13                | 3.665e-12                      |
| 800           | 8.875e-06                | 2.761e-09                | 2.071e-09                      |
| 600           | 0.000159                 | 2.07e-10                 | 8.917e-09                      |

## 5. Discussion

In this part we compare our results with the related studies in the literature. In the literature there are few studies applying transfer entropy methodology to cryptocurrencies (Dimpfl and Peter, 2019; García-Medina and González Farías, 2020; García-Medina and Hernández, 2020; Będowska-Sójka et al., 2021; Assaf et al., 2022).

Dimpfl and Peter (2019) proposed a method called effective group transfer entropy (EGTE) to measure how a random variable was affected from a group of other random variables. Authors applied EGTE to four cryptocurrencies including Bitcoin, Ethereum, Litecoin and Ripple. They used hourly data spanning the period between 1 July 2017 and 2 October 2018, and demonstrated that there was significant information flow towards any of the cryptocurrencies from the set of remaining ones. Results of Dimpfl and Peter (2019) are not directly comparable to our study because methodology used by authors reveal information flow between group of cryptocurrencies not between individual cryptocurrencies. However, their results confirm our finding that transfer entropy reveal causality in hourly cryptocurrency data.

García-Medina and González Farías (2020) utilized transfer entropy to solve the variable selection problem. In a variable selection problem predictor and response variables must be defined and transfer entropy is useful for this selection. Authors used hourly frequency data spanning between 23 May 2018 and 27 November 2018 in their analysis and found information flow from Ethereum to Bitcoin but not found information flow from Bitcoin to Ethereum. This difference from our study can be the result of the different time period used by the authors.

García-Medina and Hernández (2020) utilized multivariate transfer entropy to analyze cryptocurrency network. Authors analyzed the structure of their constructed cryptocurrency network by using network analysis tools such as clustering coefficient and degree distributions. They particularly investigated the effects of the financial turbulence of 2020 on the cryptocurrency market. Authors also investigated systematic risk and contagion between the currencies by using transfer entropy. In their analysis they used hourly 146 cryptocurrency data spanning between 1 December 2019 and 5 April 2020. Authors' methodology namely multivariate transfer entropy is different from ours since multivariate transfer entropy takes into account the all other sources in initial process. Therefore, direct comparison between

authors' study and our study is not possible. However, authors choice of hourly frequency data is in line with our study.

Będowska-Sójka et al. (2021) analyzed relationships between returns, volatility and liquidity of six cryptocurrencies including Bitcoin, Ethereum, Ripple, Dash, Litecoin, Monero and Iota. Authors used daily data in their analysis and asserted that lead-lag relationships between Bitcoin and other cryptocurrencies in terms of returns and volatility were almost indistinguishable in daily data. They could not detect information flow between Bitcoin and Ethereum in their daily data and this confirms our result that information flow is visible in high frequency hourly data.

By using transfer entropy Assaf et al. (2022) investigated causality and information flows between three cryptocurrencies including Bitcoin, Ethereum and Ripple. In their study, authors used daily data spanning the period between 9 August 2015 and 14 November 2019 which consist of 1560 observations. The authors also took into account the crash in the cryptocurrency market that took place at the end of 2017 in their analysis. Authors investigated transfer entropy values in full-sample period, pre-crash period and post-crash period separately. In full-sample period, pre-crash period and post-crash period authors could not detect information flow between Bitcoin and Ethereum in their daily data. In our study we also demonstrated that there is no information flow between Bitcoin and Ethereum in daily data. Therefore, for daily data our results agree with the authors' results. However, we demonstrated that in hourly data there is a significant bidirectional information flow between Bitcoin and Ethereum. Information flow does not reveal itself in daily data. Therefore, time resolution of the data is an important factor for detecting information flows with transfer entropy in cryptocurrency market.

## 6. Conclusion

In this study we analyzed causality and information flow between Bitcoin and Ethereum by using transfer entropy. We used two datasets, namely daily data and hourly data. While there is no evidence for information flow and causality in daily data, we found significant information flow and causality in hourly data. For that reason, we focused on hourly data and carry out additional analysis in this hourly data. Firstly, we investigated whether transfer entropy values are normally distributed by using Shapiro-Wilk normality test and rejected normality for all transfer entropy data and window sizes. Rejection of normality in transfer entropy data implies that statistical methods assuming normality are not appropriate for modeling transfer entropy. Secondly, we visually investigated the distribution of transfer entropy data by utilizing histograms. When we look at the histograms of transfer entropy data which are presented in Figure 7-9, we see that there are heavy tails in the transfer entropy distributions. These heavy tails are the main reason for rejecting normality. Heavy tails imply that observing extreme events in the tails are quite possible and this reflects a well-known stylized fact namely fat tails which is frequently observed in financial time series. Also, all the histograms presented in Figure 7-8 demonstrates right skewed distributions. However, histograms of net transfer entropy data demonstrated in Figure 9 reflect left skewed distributions. Skewed distributions imply that there are asymmetries in the information flows and causalities. Finally, we investigated independence in transfer entropy data by utilizing Ljung–Box test and found evidence of serial dependence and autocorrelations in all transfer entropy data and window sizes. Presence of serial dependence in transfer entropy implies that future values of transfer entropy depend on past values of transfer entropy. Therefore, future values of transfer entropy can be predicted from past values of transfer entropy. Our results revealing causalities and information flows between Bitcoin and Ethereum have policy implications for investors and portfolio managers. Portfolio managers can use causality information between Bitcoin and Ethereum to formulate investment strategies and to ensure better portfolio diversification. Bitcoin and Ethereum cover %52 of market cap of the cryptocurrency market therefore our study can be used as a reference for investors dealing with other cryptocurrencies. Also, presence of causality relationships in hourly data implies that high frequency trading strategies can be much more appropriate for investing in cryptocurrency market.

## References

- Assaf, A., Bilgin, M. H., & Demir, E. (2022). Using transfer entropy to measure information flows between cryptocurrencies. *Physica A: Statistical Mechanics and its Applications*, 586, 126484.

- Będowska-Sójka, B., Kliber, A., & Rutkowska, A. (2021). Is Bitcoin Still a King? Relationships between Prices, Volatility and Liquidity of Cryptocurrencies during the Pandemic. *Entropy*, 23(11), 1386.
- Dimpfl, T., & Peter, F. J. (2013). Using transfer entropy to measure information flows between financial markets. *Studies in Nonlinear Dynamics and Econometrics*, 17(1), 85-102.
- Dimpfl, T., & Peter, F. J. (2014). The impact of the financial crisis on transatlantic information flows: An intraday analysis. *Journal of International Financial Markets, Institutions and Money*, 31, 1-13.
- Dimpfl, T., & Peter, F. J. (2019). Group transfer entropy with an application to cryptocurrencies. *Physica A: Statistical Mechanics and its Applications*, 516, 543-551.
- García-Medina, A., & González Fariás, G. (2020). Transfer entropy as a variable selection methodology of cryptocurrencies in the framework of a high dimensional predictive model. *PLoS one*, 15(1), e0227269.
- García-Medina, A., & Hernández, J. B. (2020). Network analysis of multivariate transfer entropy of cryptocurrencies in times of turbulence. *Entropy*, 22(7), 760.
- Granger, C. W. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica: Journal of the Econometric Society*, 37, 424-438.
- Hatemi-j, A. (2012). Asymmetric causality tests with an application. *Empirical Economics*, 43(1), 447-456.
- Jizba, P., Kleinert, H., & Shefaat, M. (2012). Rényi's information transfer between financial time series. *Physica A: Statistical Mechanics and its Applications*, 391(10), 2971-2989.
- Kullback, S., & Leibler, R. A. (1951). On information and sufficiency. *The Annals of Mathematical Statistics*, 22(1), 79-86.
- Marschinski, R., & Kantz, H. (2002). Analysing the information flow between financial time series. *The European Physical Journal B-Condensed Matter and Complex Systems*, 30(2), 275-281.
- Osei, P. M., & Adam, A. M. (2020). Quantifying the information flow between Ghana Stock Market Index and its constituents using transfer entropy. *Mathematical Problems in Engineering* 2020, 1-10. doi:10.1155/2020/6183421.
- Schreiber, T. (2000). Measuring information transfer. *Physical Review Letters*, 85(2), 461-464.
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379-423.
- Toda, H. Y., & Yamamoto, T. (1995). Statistical inference in vector autoregressions with possibly integrated processes. *Journal of Econometrics*, 66(1-2), 225-250.
- Yao, C. Z., & Li, H. Y. (2020). Effective transfer entropy approach to information flow among EPU, Investor Sentiment and Stock Market. *Frontiers in Physics*, 8 (206).

**Research Article****Analysis of Causality Between Bitcoin and Ethereum Using Transfer Entropy***Bitcoin ile Ethereum Arasındaki Nedenselliğin Transfer Entropisi ile Analizi*

|  |   |
|--|---|
| <b>Baki ÜNAL</b><br>Dr. Öğr. Üyesi, İskenderun Teknik Üniversitesi<br>Mühendislik ve Doğa Bilimleri Fakültesi<br>Endüstri Mühendisliği Bölümü<br><a href="mailto:baki.unal@iste.edu.tr">baki.unal@iste.edu.tr</a><br><a href="https://orcid.org/0000-0001-9154-0931">https://orcid.org/0000-0001-9154-0931</a> | <b>Abdulla SAKALLI</b><br>Doç Dr., İskenderun Teknik Üniversitesi<br>Mühendislik ve Doğa Bilimleri Fakültesi<br>Endüstri Mühendisliği Bölümü<br><a href="mailto:abdulla.sakalli@iste.edu.tr">abdulla.sakalli@iste.edu.tr</a><br><a href="https://orcid.org/0000-0002-2488-7318">https://orcid.org/0000-0002-2488-7318</a> |
|--|---|

| <b>Makale Geliş Tarihi</b> | <b>Makale Kabul Tarihi</b> |
|----------------------------|----------------------------|
| <b>30.01.2022</b>          | <b>14.04.2022</b>          |

**Genişletilmiş Özet**

Literatürde çeşitli ekonomik ve finansal değişkenleri yansitan zaman serileri arasındaki nedenselliğin analizi önemli bir araştırma başlığıdır. Bu analizlerde daha çok Granger, Toda-Yamamoto ve Hatemi-J gibi nedensellilik testleri kullanılmıştır. Bu nedensellilik testleri zaman serileri arasında bir nedenselliğin bulunup bulunmadığını ve bulunuyorsa nedenselliğin yönünü ortaya koyabilmekte ancak nedenselliğin derecesini sayısal olarak ölçememektedir. Transfer entropisi zaman serileri arasındaki nedenselliğin ve bilgi akışının analizinde kullanılabilen bilgi teorisi tabanlı yeni bir yöntemdir. Transfer entropisi, Granger, Toda-Yamamoto ve Hatemi-J nedensellilik testlerinin aksine doğrusal olmayan nedensellik ilişkilerini de ortaya koyabilmektedir.

Kripto paralar iletişim teknolojileri ile hayatımıza giren yeni para birimleridir. Bu kripto paraları tedavüle koyan herhangi bir merkez bankası bulunmamaktadır. Bu paraların merkezi olmayan yapısı blok zincir adı verilen bir teknolojiden kaynaklanmaktadır. Yatırımcıların oldukça ilgisini çeken bu paralar speküasyon amacıyla yoğun olarak kullanılmaktadır. Dolayısıyla kripto paralar arasındaki nedenselliğin ve bilgi akışının ortaya koyulması yatırımcılar için faydalıdır. Bitcoin ve Ethereum en popüler iki kripto paradır. Bu çalışmada Bitcoin ve Ethereum arasındaki nedensellilik ve bilgi akışı transfer entropisi ile analiz edilmiştir. Bu bağlamda günlük ve saatlik olmak üzere iki veri kümesi üzerinde çalışılmıştır. Saatlik veride belirgin bir nedensellilik ve bilgi akışı tespit edilmesine rağmen günlük veride nedensellilik ve bilgi akışına dair bir kanıt bulunamamıştır. Bunun sonucu olarak saatlik veride kayan pencere yöntemi kullanılarak ek analizler yapılmıştır. Bu bağlamda saatlik veride transfer entropisinin normal dağılıp dağılmadığı ve oto korelasyon içerip içermediği araştırılmıştır. Ayrıca histogramlarla transfer entropilerinin nasıl dağıldığı ortaya koyulmuştur.

Bir değişkendeki bilgi miktarı Shannon entropisi ile ölçülebilmektedir (Shannon, 1948). Shannon entropisi aşağıdaki formülle hesaplanmaktadır:

$$H_J = - \sum_j p(j) \cdot \log(p(j)) \quad (1)$$

Yukarıdaki formülde  $J$  kesikli bir rassal değişkeni,  $p(j)$  bu rassal değişkenin dağılımını ve  $j$  bu rassal değişkenin olası çıktılarını göstermektedir. Sonuç olarak Shannon entropisi bir rassal değişkenin çıktılarını kodlamak için gerekli bit sayısını ölçmektedir. Shannon entropisi ve Kullback-Leibler

uzaklığı kavramları birleştirilerek iki zaman serisi arasındaki bilgi akışını ortaya koyan transfer entropisi kavramı elde edilmektedir (Kullback ve Leibler, 1951). Bu kavram sallaştırmada zaman serilerinin bir Markov süreci ile yönetildiği varsayılmaktadır (Schreiber, 2000).

Varsayılmı ki iki rassal değişken  $I$  ve  $J$  şeklinde, bunların marginal dağılımları  $p(i)$  ve  $p(j)$  şeklinde ve bunların ortak dağılımları  $p(i, j)$  şeklinde ifade ediliyor olsun. Ayrıca varsayılmı ki  $I$  ve  $J$  sırasıyla  $k$  ve  $l$  derecelerine sahip Markov süreçleri olsun. Bu durumda Markov özelliği sebebiyle  $t + 1$  zamanında  $i$  durumunu gözleme olasılığı daha önceki  $k$  gözleme bağlı olacaktır. Bu özellik  $p(i_{t+1}|i_t, \dots, i_{t-k+1})$  şeklinde ifade edilebilmektedir. Bu durumda daha önceki  $k$  gözlem değeri verildiğinde  $t + 1$  zamanındaki çıktıyı kodlamak için gerekli ortalama bit sayısı aşağıdaki formülle ifade edilmektedir.

$$h_I(k) = - \sum_i p(i_{t+1}, i_t^{(k)}) \cdot \log(p(i_{t+1}|i_t^{(k)})) \quad (2)$$

Yukarıdaki formülde  $i_t^{(k)} = (i_t, \dots, i_{t-k+1})$  şeklinde dir. Sonuç olarak  $J$  sürecinden  $I$  sürecine bilgi akışı aşağıdaki formülle ifade edilen transfer entropisi ile ölçülmektedir:

$$T_{J \rightarrow I}(k, l) = \sum_{i,j} p(i_{t+1}, i_t^{(k)}, j_t^{(l)}) \cdot \log\left(\frac{p(i_{t+1}|i_t^{(k)}, j_t^{(l)})}{p(i_{t+1}|i_t^{(k)})}\right) \quad (3)$$

Ancak örneklem büyülüğu küçük olduğunda yukarıdaki formülle ifade edilen transfer entropisi istatistiksel olarak sapmalıdır. Bu sorunun üstesinden gelinmesi için efektif transfer entropisi kavramı önerilmiştir (Marschinski ve Kantz, 2002). Bu yöntemde  $J$  zaman serisi karıştırılmakta ve transfer entropisi bu karıştırılmış seriden hesaplanmaktadır. Ardından bu karıştırılmış seriden elde edilmiş olan transfer entropisi normal transfer entropisinden çıkartılmakta ve böylece efektif transfer entropisi elde edilmektedir. Bu prosedür aşağıdaki formülle ifade edilmektedir:

$$ET_{J \rightarrow I}(k, l) = T_{J \rightarrow I}(k, l) - T_{J_{shuffled} \rightarrow I}(k, l) \quad (4)$$

Yukarıdaki formülde  $ET_{J \rightarrow I}(k, l)$  efektif transfer entropisini ve  $T_{J_{shuffled} \rightarrow I}(k, l)$  karıştırılmış  $J$ 'den elde edilen transfer entropisini göstermektedir. Örneklem büyülüğu artırıldığında  $T_{J_{shuffled} \rightarrow I}(k, l)$  sıfır yakınsamakta dolayısıyla  $T_{J_{shuffled} \rightarrow I}(k, l)$  küçük örneklemdeki sapmayı yansımaktadır.

Hesaplanan transfer entropisinin istatistiksel anlamlılığını değerlendirmek için Dimpfl ve Peter (2013) bir Markov blok bootstrap prosedürüne önermiştir. Bu prosedür karıştırılmanın aksine zaman serisi içerisindeki bağımlılıkları korumaktadır. Bilgi akışının bulunmadığını ifade eden sıfır hipotezinin altında bu prosedür transfer entropisi dağılımını ve karşılık gelen p-değerlerini üretmektedir.

Shannon entropisini hesaplayabilmek için verinin kesikli olması gerekmektedir. Eğer veri kesikli değilse verinin kesikli hale getirilmesi gerekmektedir. Bu kesiklileştirme sembolik yeniden kodlama adı verilen bir prosedürle gerçekleştirilmektedir. Bu yöntemde veri çeşitli aralara bölünmektedir. Bu bölgümlendirme bölgümlerin alt ve üst sınırlarının belirlenmesi ile veya verinin dağılımının yüzdelik dilimlerinin seçilmesi ile gerçekleştirilmektedir. Eğer  $n$  tane bölüm bulunuyorsa ve bölgümlerin sınırları  $q_1, q_2, \dots, q_n$  ( $q_1 < q_2 < \dots < q_n$ ) şeklinde belirlenmiş ise  $y_t$  zaman serisi aşağıdaki şekildeki gibi bir sembolik yeniden kodlama prosedürü ile kesikli hale getirilebilmektedir.

$$S_t = \begin{cases} 1 & y_t \leq q_1 \\ 2 & q_1 < y_t \leq q_2 \\ \vdots & \\ n-1 & q_{n-1} < y_t \leq q_n \\ n & y_t \geq q_n \end{cases} \quad (5)$$

Bu prosedürün sonucu olarak zaman serisinin her bir değerine 1'den  $n$ 'e kadar bir sayı atanmaktadır.

Bu çalışmada 17-08-2017 ile 05-10-2021 tarihleri arasını kapsayan iki veri kümesi kullanılmıştır. İlk veri kümesi günlük verileri içerenken ikinci veri saatlik verileri içermektedir. Transfer entropisinin hesaplanması için gereken yeniden kodlama prosedüründe sınırlar %5 ile %95'lik yüzdelik dilimler seçilerek veriler üç bölüme ayrılmıştır. P-değerlerinin bulunmasında kullanılan bootstrap yineleme

sayısı 300 olarak ve efektif transfer entropisinin hesaplanması sırasında kullanılan karıştırılma sayısı 100 olarak belirlenmiştir.

Transfer entropisinin uygulanabilmesi için zaman serilerinin durağan olması gerekmektedir. Bunun için Bitcoin ve Ethereum zaman serilerinin logaritmalarının ilk farkı alınmıştır. Bunun sonucu olarak Tablo 1'de görüldüğü üzere serilerin hepsi durağan hale gelmiştir.

Analizin ilk aşamasında 17-08-2017 ile 05-10-2021 arası dönemi kapsayan bütün örneklemeler için günlük ve saatlik verilerin transfer entropileri ve efektif transfer entropileri hesaplanmıştır. Günlük veri için elde edilen sonuçlar Tablo 2'de saatlik veri için elde edilen sonuçlar Tablo 3'te sunulmuştur. Tablo 2'ye bakıldığında günlük veride her iki yönde de anlamlı bir nedensellik ve bilgi akışı bulunmamaktadır. Ancak Tablo 3'e bakıldığında saatlik veride hem Bitcoin'den Ethereum'a hem de Ethereum'dan Bitcoin'e anlamlı bir nedenselliğin ve bilgi akışının bulunduğu görülmektedir. Bu sonuçlar tablolardaki p-değerleri tarafından yansıtılmıştır. Tablo 2'deki p-değerleri 0,05'ten yüksek iken Tablo 3'deki p-değerleri 0,05'den küçüktür.

Saatlik veride istatistiksel olarak belirgin bir nedensellik ve bilgi akışı tespit edildiği için saatlik veriye yoğunlaşılmış ve bu veride ek analizler yapılmıştır. İlk olarak kayan pencere yöntemi kullanılarak saatlik veride transfer entropilerinin zaman içinde nasıl değiştiği araştırılmıştır. Bunun için 1000, 800 ve 600 gözlemden oluşan üç pencere genişliği ele alınmıştır. Pencerelerin kaydırma büyülüklüğü ise 200 gözlem olarak seçilmiştir. Bu pencere genişlikleri için transfer entropilerinin nasıl değiştiği Şekil 1-3'te sunulmuştur. Bu grafiklerde kırmızı çizgiler Bitcoin'den Ethereum'a bilgi akışını, mavi çizgiler ise Ethereum'dan Bitcoin'e bilgi akışını göstermektedir. Şekil 1-3'te görüldüğü üzere transfer entropilerinde baskın bir desen görülmemektedir. Çalışmada ayrıca Bitcoin'den Ethereum'a net bilgi akışı da Şekil 4-6'da sunulmuştur. Bitcoin'den Ethereum'a net bilgi akışının elde edilmesi için Bitcoin'den Ethereum'a bilgi akışından Ethereum'dan Bitcoin'e bilgi akışı çıkartılmaktadır. Şekil 4-6'da pozitif değerler Bitcoin'den Ethereum'a net bir bilgi akışının olduğunu, negatif değerler ise Ethereum'dan Bitcoin'e net bir bilgi akışının olduğunu göstermektedir. Net bilgi akışlarını gösteren Şekil 4-6'da da baskın bir desen görülmemektedir.

Çalışmada ayrıca elde edilen transfer entropilerinin istatistiksel özellikleri araştırılmıştır. Şekil 1-6'da sunulan transfer entropileri rassal gibi görüldüğü için bunların normal dağılıp dağılmadığı araştırılmıştır. Bunun için Shapiro-Wilk normallik testi kullanılmış ve elde edilen p-değerleri Tablo 4'te sunulmuştur. Tablo 4'ten görüldüğü üzere bütün pencere büyülüklükleri ve bütün transfer entropileri için elde edilen p-değerleri 0,05'ten küçüktür ve verilerin normal dağıldığını ifade eden sıfır hipotezi reddedilmektedir. Dolayısıyla transfer entropileri normal dağılmamaktadır.

Çalışmada ayrıca transfer entropilerinin nasıl dağıldığını araştırmak için histogram grafikleri kullanılmış ve elde edilen sonuçlar Şekil 7-9'da sunulmuştur. Şekil 7-8'de görüldüğü üzere bütün pencere büyülüklükleri için transfer entropilerinin dağılımı sağa çarpiktır. Net transfer entropilerini gösteren Şekil 9'a bakıldığında ise bütün pencere büyülüklükleri için transfer entropilerinin sola çarpık olduğu görülmektedir. Dolayısıyla Shapiro-Wilk normallik testinde normallığın reddedilmesi bu çarpıklıklardan kaynaklanmaktadır.

Çalışmada son olarak elde edilen entropilerin otokorelasyon içerip içermediği Ljung–Box testi ile araştırılmıştır. Bu testten elde edilen sonuçlar Tablo 5'te sunulmuştur. Tablo 5'ten görüldüğü üzere bütün p-değerleri 0,05'ten küçüktür. Dolayısıyla kayan pencere yöntemi ile hesaplanan transfer entropisi değerleri otokorelasyon içermektedir. Dolayısıyla entropi değerleri arasında seri bir bağımlılık bulunmaktadır.